

Вінницький національний технічний університет
Факультет інформаційних електронних систем
Кафедра біомедичної інженерії та оптико-електронних систем

МАГІСТЕРСЬКА КВАЛІФІКАЦІЙНА РОБОТА

на тему:

**«Інтелектуальна система вимірювання та аналізу
параметрів медичних зображень»**

Виконав: студент 2-го курсу групи ЛТО-24м
Спеціальності 175 – Інформаційно-
вимірювальні технології, Освітня програма –
Лазерна техніка та оптоінформатика

Шершун Артем Володимирович

Керівник: к.т.н., доц. каф. БМІОЕС

Кожем'яко А.В.

« 01 » 12 2025 р.

Опонент: д.т.н., проф. каф. ОТ

Мартинюк Т.Б.

« 01 » 12 2025 р.

Допущено до захисту

Завідувач кафедри БМІОЕС

Леонід КОВАЛЬ
к.т.н., доц.

« 01 » 12 2025 р.

Вінницький національний технічний університет
Факультет інформаційних технологій та комп'ютерної інженерії
Кафедра біомедичної інженерії та оптико-електронних систем
Ступінь вищої освіти – Магістр
Галузь знань – 17 Електроніка, автоматизація та електронні комунікації
Спеціальність – 175 Інформаційно-вимірювальні технології
Освітньо-професійна програма – Лазерна техніка та оптоінформатика

ЗАТВЕРДЖУЮ
Завідувач кафедри БМІОЕС

к.т.н., доц.

 **Леонід КОВАЛЬ**
«24» 69 2025 року

ЗАВДАННЯ
НА МАГІСТЕРСЬКУ КВАЛІФІКАЦІЙНУ РОБОТУ СТУДЕНТУ
Шершуну Артему Володимировичу

1. Тема роботи: «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень».
Керівник роботи: Кожем'яко Андрій Вікторович, к. т. н., доц. каф. БМІОЕС , затверджено наказом ректора ВНТУ від 24.09.2025 року № 313.
2. Строк подання студентом роботи 10 грудня 2025 р.
3. Вихідні дані до роботи:
 - вхідні дані у вигляді цифрових RGB-зображень, отриманих камерами мобільних пристроїв;
 - каскадна архітектура нейронних мереж: детектор об'єктів та класифікатор; алгоритм попередньої обробки з автоматичною локалізацією рани та усуненням фоновому шуму;
 - математична модель представлення зображень у колірному просторі CIE LAB;
 - визначення геометричних параметрів та площі ураження з використанням калібрувальних маркерів;
 - клієнт-серверна архітектура системи з підтримкою телемедичного доступу;
 - класифікація опіків за трьома ступенями тяжкості (поверхневі, часткові, глибокі);
 - програмна реалізація Python із використанням бібліотек TensorFlow та Keras.
4. Зміст текстової частини: Вступ, аналіз методів та засобів інтелектуального аналізу біомедичних зображень, математичне моделювання та алгоритмічне забезпечення системи діагностики опіків, програмна реалізація та експериментальне дослідження системи, 4 економічна частина, висновки, список використаних джерел, додатки.
5. Перелік графічного матеріалу.
Структурна схема програмного комплексу інтелектуальної діагностики термічних уражень, Блок-схема алгоритму роботи системи діагностики, Блок-

схема алгоритму внутрішньої обробки модуля детекції, Структурна схема апаратної реалізації системи діагностики опіку

6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
1-4	Кожем'яко А. В., к.т.н., доц. каф. БМІОЕС		
5	Кавецький В. В., к.т.н., доц. каф. ЕПВМ		

7. Дата видачі завдання – __ вересня 2025 року

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів магістерської кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
2	Аналіз літературних джерел за напрямком магістерської кваліфікаційної роботи. Вступ	10.09.2025 - 15.09.2025	
3	Науково-технічне обґрунтування	16.09.2025 - 22.09.2025	
4	Аналіз предметної області та формування вимог інтелектуальної системи	23.09.2025 - 29.09.2025	
5	Розробка алгоритмів класифікації біомедичних зображень	30.09.2025 - 12.10.2025	
8	Дослідження основних характеристик роботи системи	11.11.2025 - 17.11.2025	
9	Розробка розділу економічного обґрунтування доцільності розробки	18.11.2025 - 21.11.2025	
10	Аналіз виконання ТЗ, висновки	22.11.2025 - 24.11.2025	
11	Оформлення пояснювальної записки	25.11.2025 - 29.11.2025	
12	Перевірка магістерської роботи на наявність текстових запозичень	30.10.2025 - 02.12.2025	
13	Попередній захист МКР	29.11.2025 - 14.12.2025	
14	Представлення МКР до захисту, рецензування	14.12.2025 - 15.12.2025	
15	Захист МКР	17.12.2025 - 18.12.2025	

Студент

Артем ШЕРШУН

Керівник роботи

Андрій КОЖЕМ'ЯКО

АНОТАЦІЯ

Шершун А.В. Інтелектуальна система вимірювання та аналізу параметрів медичних зображень. Магістерська кваліфікаційна робота зі спеціальності 175 – Інформаційно-вимірювальні технології, освітня програма – Лазерна техніка та оптоінформатика . Вінниця: ВНТУ, 2025. 134 с.

Укр. мовою. Бібліогр.: 31 назв; рис.: 48.

Магістерська кваліфікаційна робота присвячена розробці та вдосконаленню автоматизованої системи діагностики ступеня тяжкості термічних уражень шкіри на основі методів глибокого навчання. Підготовлено наукове обґрунтування доцільності використання згорткових нейронних мереж для об'єктивізації процесу медичного сортування. У роботі здійснено аналіз сучасних методів обробки біомедичних зображень та баз даних опікових ран. Обґрунтовано вибір колірного простору CIELAB та архітектури DenseNet201 для реалізації класифікатора. Розроблено структурну схему системи та алгоритмічне забезпечення, що включає методи попередньої обробки, детекції області інтересу та візуальної інтерпретації прийняття рішень. Програмно реалізовано клієнт-серверну архітектуру та здійснено експериментальне дослідження точності системи на тестовій вибірці. У роботі оцінено практичну значущість та ефективність впровадження системи в умовах телемедицини.

Ілюстративна частина містить графічні матеріали з демонстрацією архітектури нейромереж, результатів роботи алгоритмів детекції та теплових карт візуалізації ознак.

Ключові слова: телемедицина, класифікація опіків, термічні ураження, комп'ютерний зір, глибоке навчання, згорткові нейронні мережі, параметри біомедичних зображень.

ABSTRACT

Shershun A.V. Intelligent system for measuring and analyzing parameters of biomedical images. Master's qualification thesis in specialty 175 – Information and measurement technologies, educational program – Laser engineering and optoinformatics. Vinnytsia: VNTU, 2025. 134 p.

In Ukrainian. References: 31; figures: 48.

The master's qualification thesis is dedicated to the development and improvement of an automated system for diagnosing the severity of thermal skin injuries based on deep learning methods. A scientific justification for the feasibility of using convolutional neural networks to objectify the medical triage process has been prepared.

The thesis analyzes modern methods of biomedical image processing and burn wound databases. The choice of the CIELAB color space and the DenseNet201 architecture for the implementation of the classifier is substantiated. The structural diagram of the system and algorithmic support, which includes methods for preprocessing, region of interest detection, and visual interpretation of decision-making, have been developed. A client-server architecture has been implemented in software, and an experimental study of the system's accuracy on a test dataset has been conducted. The practical significance and effectiveness of implementing the system in telemedicine conditions have been evaluated.

The illustrative part contains graphic materials demonstrating the neural network architecture, the results of detection algorithms, and feature visualization heatmaps.

Keywords: telemedicine, burn classification, thermal injuries, computer vision, deep learning, convolutional neural networks, biomedical image parameters.

ЗМІСТ

ВСТУП	9
1 АНАЛІЗ МЕТОДІВ ТА ЗАСОБІВ ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ БІОМЕДИЧНИХ ЗОБРАЖЕНЬ.....	12
1.1 Актуальність розробки автоматизованих засобів діагностики термічних уражень в сучасних умовах України.....	12
1.2 Проблематика об'єктивної оцінки опікових ран та необхідність автоматизації.....	14
1.3 Визначення засобів, методів та параметрів біомедичних зображень	18
1.3.1 Огляд засобів обробки зображень для задач медицини	18
1.3.2 Сучасні засоби візуалізації в біомедичних системах	22
1.4 Аналіз баз даних зображень опікових уражень для навчання нейронних мереж.....	24
1.5 Складові інтелектуальних систем обробки біомедичних зображень	29
1.5.1 Модуль попередньої обробки та нормалізації даних	29
1.5.2 Модуль вилучення інформативних ознак.....	30
1.5.3 Модуль класифікації та прийняття рішень.....	31
1.5.4 Модуль інтерпретації та візуалізації.....	32
1.6 Висновки до розділу 1	33
2 МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ ТА АЛГОРИТМІЧНЕ ЗАБЕЗПЕЧЕННЯ СИСТЕМИ ДІАГНОСТИКИ ОПІКІВ	35
2.1 Математичні моделі представлення біомедичних зображень та їх колірних просторів.....	35
2.1.1 Матрична модель дискретного зображення	35
2.1.2 Лінійні та нелінійні трансформації колірних просторів	36
2.1.3 Математична модель колориметричного калібрування	37
2.1.4 Моделювання індивідуального тону шкіри.....	37
2.1.5 Статистичні дескриптори текстур опікової поверхні.....	38

2.2 Геометричні ознаки та математичне моделювання оптичних спотворень при формуванні біомедичних зображень	39
2.2.1 Математична модель камери-обскури	39
2.2.2 Математичне моделювання оптичних дисторсій.....	41
2.2.3 Алгоритмічна реалізація калібрування камери (Метод Чжана).....	42
2.2.4 Оцінка пози та масштабування для вимірювання площі опіку	43
2.2.5 Вплив температурних факторів на оптичні характеристики.....	44
2.3 Математичні методи вилучення ознак та класифікації зображень опіків на основі статистичного аналізу та опорних векторів	45
2.3.1 Математична формалізація простору ознак	45
2.3.2 Математичне моделювання локальних форм методом HOG.....	48
2.4 Математичні методи та алгоритми класифікації біомедичних зображень	51
2.4.1 Класифікація на основі гіперплощин (Метод опорних векторів)	51
2.5 Математична модель та архітектура реалізованої системи на базі DenseNet201	54
2.5.2 Математичний опис компонентів моделі.....	55
2.5.4 Стратегія трансферного навчання (Transfer Learning)	58
2.5.5 Математичний апарат оцінки ефективності.....	58
3 ПРОГРАМНА РЕАЛІЗАЦІЯ ТА ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ СИСТЕМИ.....	62
3.1 Структура та алгоритмічне забезпечення інтелектуальної системи діагностики опікових уражень	62
3.1.1 Структурна схема системи	62
3.2.4 Енергонезалежність та автономність	75
3.2.5 Структурна схема комплексу технічних засобів.....	75
3.3 Програмна реалізація алгоритмів навчання та класифікації зображень опіків із застосування нейронної мережі	77
3.3.1 Ініціалізація середовища та налаштування гіперпараметрів	77

3.3.2 Програмна реалізація конвеєра даних	78
3.3.3 Побудова архітектури нейронної мережі.....	79
3.3.4 Компіляція моделі та налаштування процесу навчання.....	80
3.3.5 Запуск навчання та збереження результатів.....	81
3.3.6 Реалізація модуля оцінки (Inference & Evaluation).....	82
3.3.7 Інтеграція модуля Grad-CAM	83
3.4 Експериментальне дослідження та аналіз результатів роботи системи.....	84
3.4.1 Методика проведення експерименту та кількісні показники ефективності	84
3.4.2 Візуальна верифікація прийняття рішень.....	86
3.4.3 Аналіз помилок класифікації.....	88
3.4.4 Оцінка швидкодії та обчислювальної ефективності	90
3.4.5 Порівняння з існуючими аналогами	91
3.5 Висновки до розділу 3	92
4 ЕКОНОМІЧНА ЧАСТИНА.....	93
4.1 Проведення комерційного та технологічного аудиту науково-технічної розробки	93
4.2 Розрахунок узагальненого коефіцієнта якості розробки.....	94
4.3 Розрахунок витрат на проведення науково-дослідної роботи	96
4.4 Розрахунок економічної ефективності науково-технічної розробки при її можливій комерціалізації потенційним інвестором.....	107
4.5 Висновки до розділу 4.	111
ВИСНОВКИ.....	113
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	115
ДОДАТОК А. Технічне завдання.....	119
ДОДАТОК Б. Протокол перевірки кваліфікаційної роботи.....	125
ДОДАТОК В. ІЛЮСТРАТИВНА ЧАСТИНА	126
ДОДАТОК Г. Код програми тренування нейромережі.....	131
ДОДАТОК Д. Код програми класифікації опіків	135

ВСТУП

Діагностика та оцінка ступеня тяжкості термічних уражень шкіри набуває критичного значення в умовах сучасних викликів, з якими стикається медична система України. Зростання кількості пацієнтів з комбінованими бойовими травмами та опіками вимагає швидких і точних рішень на етапах медичної евакуації. У методах комп'ютерної підтримки прийняття лікарських рішень автоматизація первинного огляду рани дозволяє мінімізувати суб'єктивний фактор та помилки, особливо коли допомогу надають лікарі неспеціалізованого профілю або парамедики.

Використання сучасних методів глибокого навчання (Deep Learning) та комп'ютерного зору дозволяє обробляти зображення опіків, отримані у польових умовах за допомогою звичайних смартфонів. Автоматизована класифікація глибини ураження та візуалізація патологічних зон є необхідним кроком для своєчасного визначення необхідності хірургічного втручання та оптимізації маршрутизації пацієнтів.

Актуальність дослідження

В умовах сучасної України проблема швидкої та точної діагностики термічних уражень набула критичного значення. Зростання кількості комбінованих травм, спричинених мінно-вибуховими пристроями та пожежами, створює значне навантаження на систему медичної евакуації, де первинне сортування постраждалих часто виконують парамедики або лікарі загальної практики без спеціалізованого досвіду в комбустіології. Суб'єктивність візуальної оцінки глибини опіку призводить до помилок тріажу, що загрожує як недооцінкою тяжких станів, так і перевантаженням спеціалізованих центрів пацієнтами, які не потребують госпіталізації. У цьому контексті автоматизація діагностичного процесу стає необхідним кроком для підвищення ефективності надання домедичної та першої лікарської допомоги в умовах дефіциту часу та ресурсів.

Розвиток методів штучного інтелекту, зокрема глибоких згорткових нейронних мереж, відкриває нові можливості для створення об'єктивних інструментів діагностики, здатних функціонувати на загальнодоступних мобільних пристроях.

Розробка інтелектуальної системи, яка поєднує алгоритми автоматичної локалізації рани та класифікації ступеня опіку за цифровим зображенням, дозволяє нівелювати вплив людського фактора та забезпечити стандартизовану оцінку уражень безпосередньо на місці події. Впровадження таких рішень у практику військово-польової медицини сприятиме оптимізації маршрутизації пацієнтів, скороченню часу до початку адекватного лікування та, як наслідок, зниженню ризиків ускладнень і покращенню прогнозів одужання постраждалих.

Мета і задачі роботи. Метою магістерської роботи є розширення функціональних можливостей системи діагностики термічних уражень шкіри шляхом розробки інтелектуальної системи аналізу параметрів біомедичних зображень, що забезпечує автоматизовану класифікацію ступеня опіку та візуальну інтерпретацію результатів для підтримки прийняття рішень медичним персоналом.

Для досягнення поставленої мети в магістерській кваліфікаційній роботі необхідно вирішити такі **завдання**:

- Провести аналіз сучасних методів та апаратних засобів отримання й обробки зображень опікових ран;
- Обґрунтувати вибір математичних моделей представлення кольору та методів попередньої обробки зображень для усунення оптичних спотворень;
- Розробити алгоритмічне забезпечення системи, що включає методи детекції області інтересу (ROI) та класифікації глибини ураження на основі згорткових нейронних мереж;
- Програмно реалізувати інтелектуальну систему з використанням сучасних методів та засобів для класифікації біомедичних зображень;

- Провести експериментальне дослідження розробленої системи, оцінити показники точності та здійснити аналіз помилок класифікації.

Об'єкт дослідження – процес автоматизованої діагностики та класифікації ступеня тяжкості термічних уражень шкіри за цифровими зображеннями.

Предмет дослідження – методи та алгоритми інтелектуального аналізу біомедичних зображень з використанням глибоких згорткових нейронних мереж та механізмів візуальної інтерпретації.

Методи досліджень базуються на теорії цифрової обробки, методах математичного моделювання, теорії штучних нейронних мереж, а також методах математичної статистики.

Наукова новизна отриманих результатів: удосконалено метод класифікації опікових уражень за рахунок застосування методів геометричної нормалізації та попередньої обробки зображень, що дозволило підвищити якість вхідних даних для нейронної мережі та підвищило стійкість системи до фонового шуму та ускладнених умов зйомки.

Практична значущість отриманих результатів полягає у розробці архітектури та програмного забезпечення для мобільної системи експрес-діагностики опіків. Вперше для даного класу задач впроваджено модуль інтерпретації на базі Grad-CAM, що забезпечує візуальне підтвердження діагностичних ознак (еритема, некроз, пухирі) безпосередньо на зображенні.

Система дозволяє виконувати оцінку тяжкості травми в режимі реального часу, використовуючи камери смартфонів, що робить її придатною для використання парамедиками та волонтерами на етапах догоспітальної допомоги.

Апробація результатів роботи. Основні наукові та практичні результати, отримані в роботі, були представлені на науково-технічній конференції ВНТУ «Молодь в науці: дослідження, проблеми, перспективи» (МН-2025) (м. Вінниця, 2025).

1 АНАЛІЗ МЕТОДІВ ТА ЗАСОБІВ ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ БІОМЕДИЧНИХ ЗОБРАЖЕНЬ

1.1 Актуальність розробки автоматизованих засобів діагностики термічних уражень в сучасних умовах України

З початком повномасштабного вторгнення структура травматизму в Україні зазнала кардинальних змін, що вимагає перегляду підходів до медичного сортування та надання первинної допомоги. Особливу групу ризику становлять постраждалі з термічними ураженнями, кількість яких суттєво зросла внаслідок застосування запалювальних боєприпасів, ракетних ударів по цивільній інфраструктурі та виникнення масштабних пожеж. За даними Моніторингової місії ООН з прав людини в Україні, лише за осінній період 2025 року кількість жертв від мінно-вибухових пристроїв та вибухонебезпечних пережитків війни зросла на 13% порівняно з попередніми періодами [1].

Специфікою бойової травми є її комбінований характер. На відміну від побутових опіків (окріп, контакт із гарячими поверхнями), бойові термічні ураження часто є частиною політравми, поєднуючись із осколковими пораненнями та переломами. Ретроспективні дослідження, проведені у 2025 році на базі українських клінік, показують, що навіть у вузькопрофільних вибірках (наприклад, щелепно-лицьові поранення) у 5,3% пацієнтів фіксуються супутні опіки шкіри [2]. Лікування таких пацієнтів потребує високоспеціалізованої допомоги, яка надається у спеціалізованих центрах, таких як Національний реабілітаційний центр «Незламні» (Unbroken), де з початку війни проліковано понад 20 000 пацієнтів, значна частина яких потребувала реконструктивної хірургії після мінно-вибухових травм [3].

Проблема загострюється в умовах масових санітарних втрат, коли потік постраждалих перевищує можливості медичної системи на етапі евакуації. Звіти міжнародної організації «Лікарі без кордонів» (MSF), що забезпечує роботу медичних евакуаційних потягів, свідчать, що понад 40% евакуйованих

мають складні вибухові травми (blast injuries), які часто супроводжуються опіками [4]. У таких умовах первинна оцінка тяжкості ураження часто проводиться не комбустіологами, а парамедиками, військовими лікарями загальної практики або волонтерами.



Рисунок 1.1 – Моніторинг пораненого війною пацієнта у відділенні інтенсивної терапії медичного потяга організації "Лікарі без кордонів" під час рейсу з Покровська до Львова

Відсутність досвіду візуальної оцінки опіків призводить до помилок триажу (сортування): недооцінка глибини ураження загрожує розвитком сепсису та рубцевих деформацій, а переоцінка – невиправданим завантаженням евакуаційного транспорту та спеціалізованих ліжок пацієнтами, які могли б лікуватися амбулаторно. Статистика свідчить про докорінну зміну етіології опіків у воєнний час (табл.1.1).

Враховуючи обмеженість часу на прийняття рішень ("золота година") та дефіцит профільних фахівців у прифронтових зонах, актуальним є впровадження автоматизованих телемедичних систем. Використання методів комп'ютерного зору та глибокого навчання (Deep Learning) дозволяє створити

інструмент для об'єктивної експрес-діагностики ступеня опіку за фотографією. Така система може функціонувати на мобільних пристроях, забезпечуючи підтримку прийняття рішень для неспеціалістів та оптимізуючи маршрутизацію пацієнтів у системі етапного лікування.

Таблиця 1.1 – Порівняльна характеристика опікових травм у мирний та воєнний час [5]

Характеристика	Мирний час	Воєнний час
Домінуюча причина	Побутові інциденти (окріп, полум'я, електроприлади)	Мінно-вибухові травми, хімічні агенти, пожежі внаслідок обстрілів
Структура травми	Переважно ізольовані опіки	Комбіновані ураження (опік + уламки + контузія)
Характер рани	Чіткі межі, відносно чиста поверхня	Забруднення землею, залишками вибухівки, "мозаїчність" глибини
Частка складних випадків	Близько 20%	Понад 35% пацієнтів опікових центрів

Це підтверджується досвідом центру Superhumans, фахівці якого наголошують на необхідності інноваційних підходів до управління складними бойовими ранами в умовах дефіциту ресурсів та складної логістики [6].

1.2 Проблематика об'єктивної оцінки опікових ран та необхідність автоматизації

Точна та своєчасна оцінка тяжкості опікової травми є фундаментом для вибору правильної стратегії лікування. Ключовими параметрами, що визначають клінічний маршрут пацієнта, є площа поверхні тіла, уражена опіком (TBSA), та, що найважливіше, глибина опіку [7]. Саме глибина ураження

визначає, чи загоїться рана самостійно (поверхневі та часткові опіки), чи потребуватиме хірургічного висічення та пересадки шкіри (глибокі часткові та повношарові опіки) [8].

Рис. 1.2 ілюструє анатомічну будову шкіри людини в розрізі, детально демонструючи три її основні шари: епідерміс (зовнішній захисний шар), дерму (внутрішній шар сполучної тканини) та гіподерму (підшкірний жировий шар). На схемі наведено діапазони товщини для кожного з цих шарів: епідерміс становить 0,06–0,1 мм, дерма – 1,2–2,8 мм, а жирова тканина – 1,1–5,6 мм. Крім того, рисунок візуалізує похідні структури шкіри та її компоненти, такі як пори, волосся, волосяні фолікули, потові та сальні залози, нервові закінчення та мережу кровоносних судин. Ця схема надає важливе розуміння структури шкіри, що є необхідним для аналізу глибини проникнення опіків та взаємодії з діагностичним обладнанням.

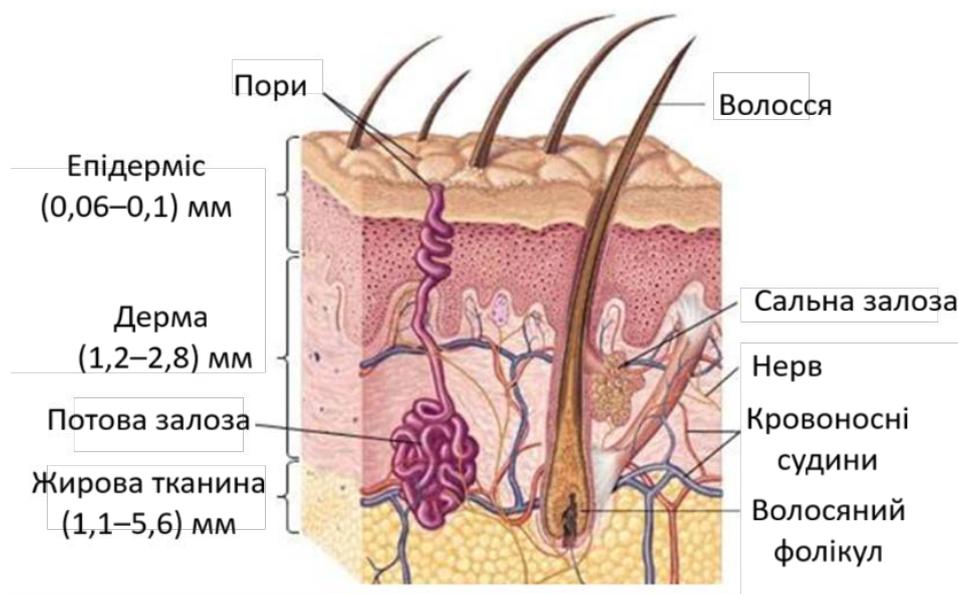


Рисунок 1.2 – Структура шкіри людини та її складові (потові залози, сальні

залози, волосся та ін.)

На сьогодні «золотим стандартом» діагностики залишається клінічна оцінка лікарем на основі візуального огляду та пальпації. Однак цей метод має суттєві недоліки, головним з яких є суб'єктивність. Дослідження показують, що точність клінічної оцінки глибини опіку навіть досвідченими комбустіологами

варіюється в межах 64–76%, тоді як для менш досвідчених лікарів цей показник падає до 50% [8]. В інших джерелах зазначається, що клінічне враження може бути помилковим у 20–50% випадків [9]. Особливу складність становить диференціація між поверхневими та глибокими опіками другого ступеня (partial-thickness burns), які візуально можуть виглядати дуже схожими, але вимагають принципово різних підходів до лікування [9].

Суб'єктивність оцінки призводить до значної варіабельності між різними оцінювачами (inter-rater variability) [10]. Крім того, на візуальне сприйняття лікаря впливають умови освітлення, наявність сторонніх речовин на рані та психологічний стан пацієнта. Помилки в оцінці мають серйозні наслідки: недооцінка глибини веде до затримки хірургічного втручання, збільшення ризику інфекцій та утворення гіпертрофічних рубців, тоді як переоцінка спричиняє непотрібні хірургічні операції або необґрунтовані переведення до спеціалізованих опікових центрів, що перевантажує медичну систему [11].

Таблиця 1.2 – Порівняння методів оцінки опікових ран

Критерій порівняння	Традиційна клінічна оцінка	Автоматизована система (Computer Vision/ML)
Основний інструмент	Візуальний огляд, пальпація	Цифрова камера, алгоритми обробки зображень
Точність діагностики	50–70% (залежить від досвіду)	80–90% (потенційна точність сучасних алгоритмів)
Об'єктивність	Низька (суб'єктивне сприйняття)	Висока (стандартизований аналіз пікселів)
Контакт з пацієнтом	Необхідний (болісний)	Безконтактний (non-invasive)
Доступність	Потребує присутності спеціаліста	Можлива віддалено (через смартфон/телемедицину)

Ще однією проблемою є необхідність фізичного контакту з раною та зняття перев'язувальних матеріалів для огляду, що є болісним для пацієнта та підвищує ризик інфікування [12]. Існуючі інструментальні методи, такі як

біопсія (інвазивна та залишає рубці) або лазерна доплерівська візуалізація (дорога та громіздка), не завжди доступні в умовах надання екстреної допомоги [9, 10].

Враховуючи ці обмеження, виникає гостра необхідність у розробці автоматизованих систем підтримки прийняття рішень на основі обробки зображень. Використання методів машинного навчання дозволяє об'єктивізувати процес діагностики, аналізуючи такі ознаки, як колір, текстура та геометричні параметри рани, які складно квантифікувати людським оком [8]. Порівняльний аналіз традиційного та автоматизованого підходів показано у табл. 1.2.



Рисунок 1.2 – Результати роботи алгоритму глибокого навчання для класифікації тяжкості опіків: (a) вихідне зображення; (b) "золотий стандарт" (експертна оцінка); (c) прогноз алгоритму (синій – поверхневий опік, зелений – глибокий частковий, червоний – повношаровий) [9]

Ще однією проблемою є необхідність фізичного контакту з раною та зняття перев'язувальних матеріалів для огляду, що є болісним для пацієнта та підвищує ризик інфікування [12]. Існуючі інструментальні методи, такі як біопсія (інвазивна та залишає рубці) або лазерна доплерівська візуалізація (дорога та громіздка), не завжди доступні в умовах надання екстреної допомоги [9, 10].

Як показано на прикладі сучасних досліджень, системи глибокого навчання здатні ефективно сегментувати зони опіку та класифікувати їх за глибиною ураження (рис. 1.2).

Автоматизація процесу діагностики дозволяє не лише підвищити точність визначення ступеня опіку, але й забезпечити можливість сортування (тріажу) пацієнтів медичним персоналом без спеціалізованої підготовки, що є критичним в умовах дефіциту ресурсів.

1.3 Визначення засобів, методів та параметрів біомедичних зображень

1.3.1 Огляд засобів обробки зображень для задач медицини

Сучасні методи медичного діагностування, особливо у сфері оцінки відкритих ушкоджень м'яких тканин, зокрема термічних уражень (опіків), вимагають високої точності та об'єктивності для визначення розмірів і глибини рани. Точний вибір лікувальної тактики, прогнозування термінів одужання, а також потреби реконструктивної хірургії (визначення площі для трансплантації) залежать від надійної оцінки вольнерологічних параметрів. В умовах переходу до цифрового документообігу виникла необхідність зберігання цієї важливої інформації в базах даних пацієнтів як для рутинного використання лікарями, так і для наукових досліджень.

Сучасні засоби обробки зображень у медицині спрямовані на подолання недоліків найпростіших клінічних методів, які є суб'єктивними, базуються на візуальному огляді та тактильних характеристиках, і тому є малоефективними для об'єктивної оцінки.

Цифрова та тривимірна (3D) візуалізація. Розвиток технологій призвів до появи великої групи безконтактних методів вимірювання, які передбачають дистанційну оцінку параметрів дефектів за допомогою фото- чи відеообладнання. Хоча ці методи можуть мати значну вартість та можливі спотворення при переведенні тривимірного зображення рани у двовимірну форму, вони є значним кроком вперед.

До сучасних безконтактних методів належать:

1. Цифрове фотографування з еталоном площі. Отримані зображення рани та умовного еталона площі біля неї переносять на комп'ютер, і площа дефекту шкіри визначається через співвідношення кількості точок в зображенні дефекту до кількості точок в зображенні еталона, помножене на площу еталона.
2. Комп'ютерна планіметрія. Такі методи, як метод Ж.-Л. Рішара або «Mouseeyes», передбачають перенесення контуру рани на прозору плівку або фіксацію відбитку, сканування та подальший автоматичний розрахунок площі за допомогою комп'ютерної програми.
3. Мобільні додатки. Було розроблено власний додаток для смартфона, як-от Planimator app, що є більш точним, ніж деякі інші методи, наприклад, Visitrak, і забезпечує можливість вбудувати технологію візуалізації, обчислення, аналізу та зберігання в портативний пристрій.
4. 3D-технології. Стереобачення, фотограмметрія та лазерна триангуляція/триангуляція білого світла дають змогу надійно вимірювати тривимірні поверхні шкіри. Ці волюметричні методи передбачають створення тривимірної моделі рани за допомогою 3D-лазерного сканера, що дозволяє розраховувати планіметричні та волюметричні параметри, включаючи глибину дефекту.

Спеціалізовані інструменти для оцінки життєздатності тканин

Аналіз глибини опікової рани є критично важливим для диференціації тканин, здатних до самовідновлення (поверхневий опік), від некрозу (глибокий опік). Хоча гістологічний аналіз пункційної біопсії є «золотим стандартом», він

має недоліки, такі як суб'єктивність інтерпретації та ураження місця біопсії. Сучасні методи візуалізації зосереджені на неінвазивній оцінці мікроциркуляції та метаболічної активності:

— Інфрачервона термографія (ІРТ): Це неінвазивна методика, заснована на оцінці різниці температур, що допомагає визначити зони з порушеним кровообігом (некроз, що має нижчу температуру) та життєздатні тканини (вищу температуру). ІРТ дозволяє отримати негайні результати у вигляді теплових зображень на значній поверхні, але її точність може бути чутливою до фонового освітлення.

— Лазерна доплерівська візуалізація (LDI): Цей метод, заснований на ефекті Доплера, оцінює перфузію крові на великій площі поверхні без прямого контакту. LDI є високочутливою та специфічною для визначення глибини опіку, але вона дороговартісна та чутлива до рухів пацієнта.

— Фотоакустична візуалізація (мікроскопія): Поєднує ультразвук та оптичну візуалізацію, що дозволяє отримати зображення тканин з високою роздільною здатністю. Метод базується на виявленні фотоакустичних сигналів, що походять з крові під пошкодженим шаром, і може використовуватися для первинної оцінки глибини опіку та моніторингу загоєння.

— Оптична когерентна томографія (ОКТ): Використовує захоплення світла, розсіяного від тканини, для створення високоякісного зображення, яке дозволяє оцінити товщину шкіри (В-скани) та порівнювати середні значення перфузії. ОКТ, часто поєднувана з візуалізацією пульсового спектру, забезпечує складний аналіз.

— Методика просторового частотного зображення (SFDI): Це вдосконалення ближньої інфрачервоної спектроскопії. Вона використовує різні патерни ближнього ІЧ-світла для освітлення тканини, що дозволяє вимірювати абсорбцію світла на різних довжинах хвиль (наприклад, оксигемоглобін, вода) на різних глибинах. Це забезпечує кількісні просторові карти оптичних властивостей і не вимагає фізичного контакту зі шкірою.

— Відеоангіографія з індокарбіном зеленим: Використовує внутрішньовенний барвник, що флуоресціює у ближньому інфрачервоному спектрі, візуалізуючи глибокі дермальні судини. Ця технологія дозволяє швидко сканувати та відрізнити глибокі та поверхневі опіки на ранніх стадіях, але вимагає введення барвника з можливими побічними ефектами.

— Пасивна міліметрово-хвильова візуалізація: Досліджується для діагностики опіків, навіть під пов'язками, оскільки дозволяє отримувати зображення на основі теплового випромінювання тканин.

Інтелектуальні системи та машинне навчання (МН). Інтелектуальні системи аналізу параметрів медичних зображень активно впроваджують методи машинного навчання (МН) та глибокого навчання (ГН) для автоматизації діагностики. Глибоке навчання, зокрема згорткові нейронні мережі (CNNs), забезпечує продуктивність, що може бути швидшою та більш послідовною, ніж оцінка експертами. Застосування МН-алгоритмів, навчених на зображеннях, обіцяє значне підвищення точності клінічних рішень щодо необхідності хірургічного лікування. При використанні цифрових кольорових зображень точність класифікації ступеня тяжкості опіків ГН-алгоритмами в середньому становить 86,2% (стандартне відхилення 9,8%), що є вищим показником порівняно з «традиційними» МН-алгоритмами (середнє 80,9%, стандартне відхилення 6,4%). Розробляються інтегровані системи, які поєднують різні джерела даних. Наприклад, мультимодальна система ШІ, що інтегрується з електронними медичними картами (EMR), використовується для прогнозування глибини опіку та оптимізації діагностичної точності. Вдосконалення моделей досягається через застосування додаткових ознак. Дослідження показали, що додавання текстурних ознак, наприклад, на основі матриці спільного входження сірого рівня (GLCM), до класифікаторів ультразвуку В-режиму, може підвищити точність класифікації глибини опіку до ~94%. В інших біомедичних застосуваннях також активно використовується аналіз мікроскопічних зображень за допомогою CNNs. Наприклад, для об'єктного розпізнавання

(сегментація та класифікація вірусів) застосовують модифіковану архітектуру U-Net, яка може бути адаптована для використання у споживчих пристроях.

Таким чином, сучасні засоби обробки медичних зображень для інтелектуальних систем аналізу параметрів медичного діагностування, хоча й високоточні та ефективні, часто вимагають значних витрат часу, ресурсів або спеціального дороговартісного обладнання, що обмежує їхнє рутинне застосування. Подальші дослідження мають бути спрямовані на розробку більш доступних, простих у використанні та економічних методик, що забезпечать точність вимірювань і можливість інтеграції в існуючі клінічні протоколи.

1.3.2 Сучасні засоби візуалізації в біомедичних системах

Для розробки інтелектуальної системи діагностики критично важливим є вибір методу отримання вхідних даних. Сучасні інструментальні засоби варіюються від загальнодоступних камер до складних спектральних систем, кожна з яких дозволяє фіксувати специфічні параметри опікових ран.

Стандартна цифрова фотографія (RGB)

Найпоширенішим методом є фіксація зображень у видимому спектрі за допомогою цифрових камер або смартфонів. Цей підхід є основою телемедицини [11]. Для підвищення інформативності RGB-зображення часто конвертують у колірний простір CIELAB ($L^* a^* b^*$). Як зазначають Yadav et al., це дозволяє розділити інформацію про яскравість L^* та колір (a^*, b^*), що значно покращує точність детекції еритеми та пігментації [7].

Мультиспектральна та гіперспектральна візуалізація (HSI)

Ці технології дозволяють отримати інформацію, недоступну для людського ока, шляхом фіксації зображень у вузьких спектральних смугах (від 400 до 2500 нм). Гіперспектральна камера формує «гіперкуб» даних, де кожен піксель містить неперервний спектр. Це дозволяє виконувати спектрально-просторову сегментацію, розрізняючи ступені опіку на основі спектральних підписів гемоглобіну та оксигенації тканин [9]. На Рисунку 1.3 показано, як HSI

дозволяє чітко розмежувати зони опіку різної глибини, які візуально можуть виглядати схожими.

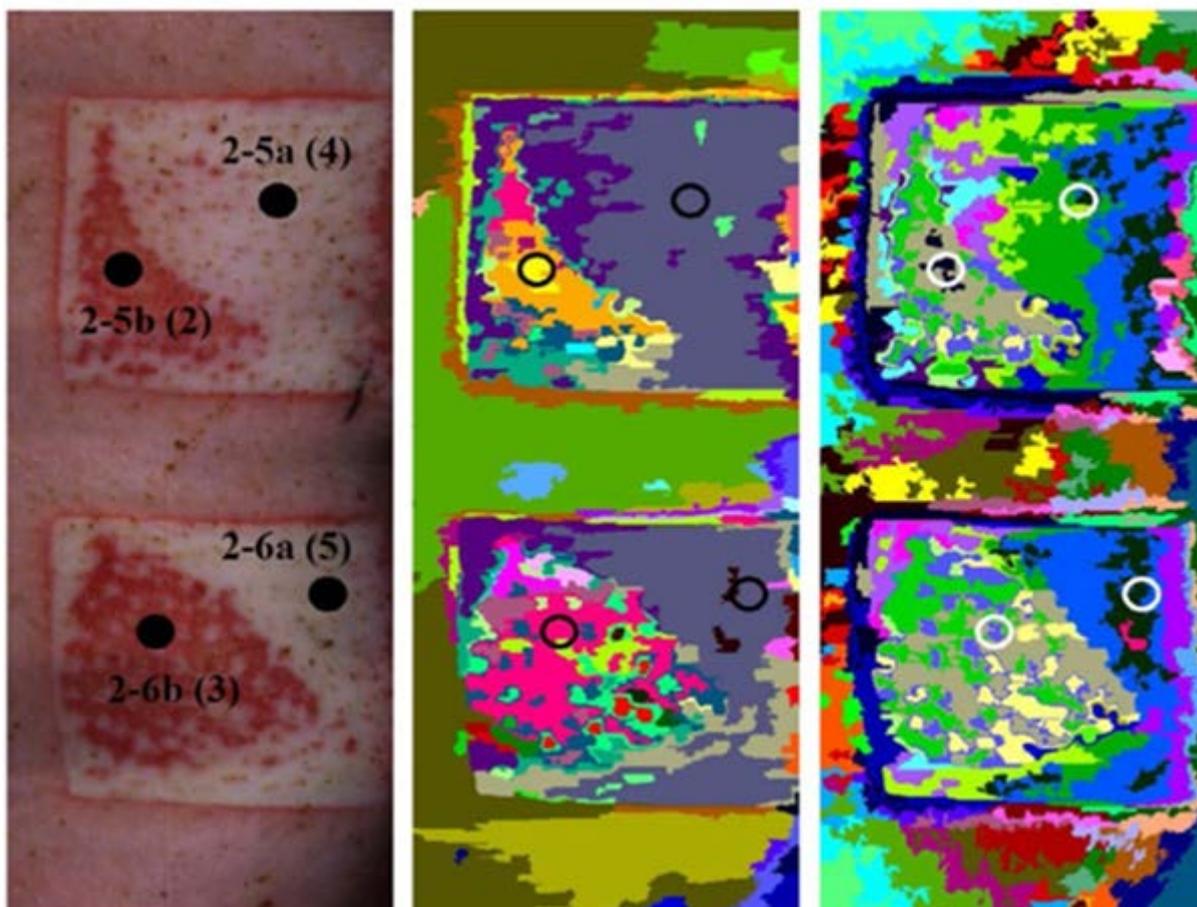
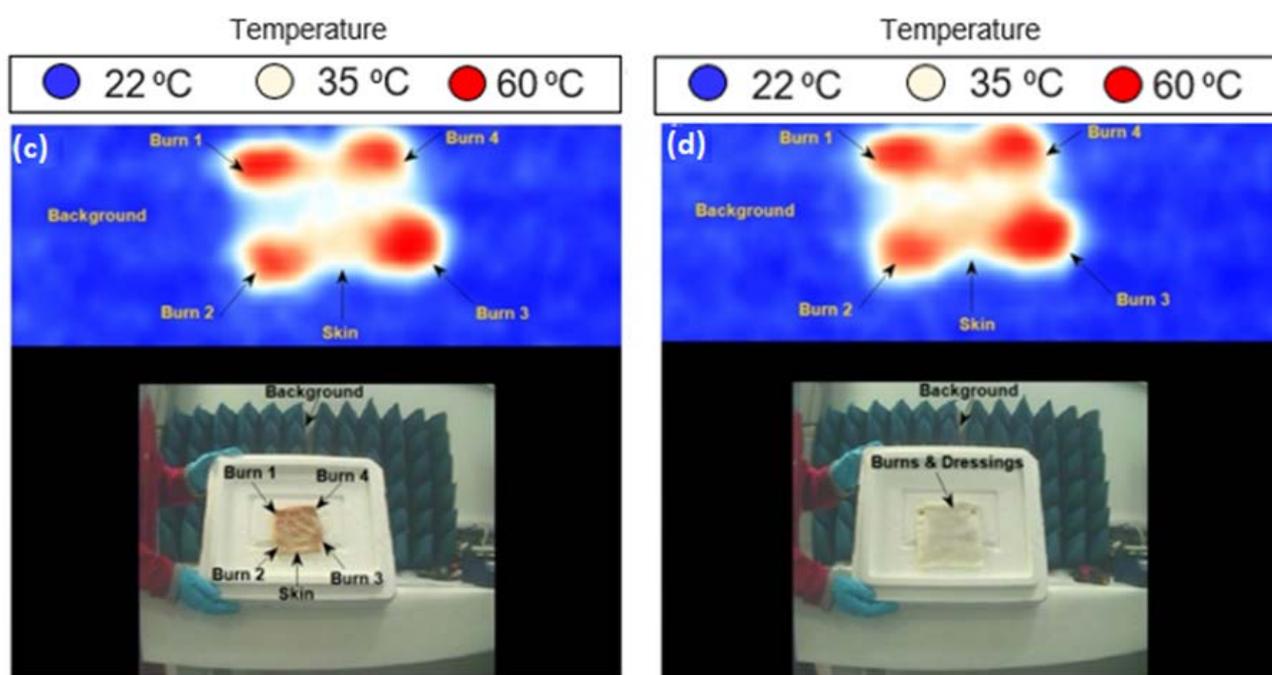


Рисунок 1.3 – Класифікація тяжкості опіків за допомогою гіперспектральної візуалізації, результати сегментації, де різні кольори відповідають різній глибині ураження [9]

Оптична когерентна томографія (ОСТ). ОСТ є методом «оптичної біопсії», що забезпечує візуалізацію мікроструктури шкіри з роздільною здатністю до 10 мкм [10]. Метод дозволяє виміряти товщину епідермісу та оцінити стан колагенових волокон. Однак, як вказують Wilson et al., суттєвим обмеженням є мала глибина проникнення сигналу (1–2 мм), що ускладнює діагностику глибоких опіків через шар некротичного струпа [9].

Пасивна міліметрова візуалізація (PMMWI). Інноваційним підходом є використання сенсорів міліметрового діапазону хвиль (30–300 ГГц). У роботі Owda доведено, що PMMWI дозволяє детектувати опіки крізь сухі

перев'язувальні матеріали, реєструючи природне теплове випромінювання тіла [12]. Це вирішує проблему болісних перев'язок для огляду рани. Експерименти на частоті 250 ГГц показали можливість чіткої локалізації опіку навіть під 10 шарами марлі (рис. 1.4), оскільки уражена шкіра має інший коефіцієнт випромінювання (emissivity) порівняно зі здоровою.



а)

б)

Рисунок 1.4 – Пасивна міліметрова візуалізація опікових ран: (а) зображення опіку без пов'язки; (б) детекція того ж опіку крізь 10 шарів марлевої пов'язки [12]

Хоча спектральні та хвильові методи дають глибшу інформацію, для масового скринінгу в умовах бойових дій найбільш доцільним залишається використання RGB-зображень у поєднанні з алгоритмами глибокого навчання, оскільки це не вимагає дорогого обладнання.

1.4 Аналіз баз даних зображень опікових уражень для навчання нейронних мереж

Ефективність та надійність систем штучного інтелекту в медичній діагностиці прямо корелює з обсягом та якістю навчальних даних. У галузі комбустіології (медицини опіків) ситуація з даними є значно складнішою, ніж у дерматології чи радіології. Якщо для діагностики меланоми існують відкриті стандартизовані архіви (наприклад, ISIC Archive), що налічують десятки тисяч зображень, то загальнодоступні спеціалізовані бази даних опікових ран є рідкісними, фрагментованими та часто мають обмежений доступ через питання конфіденційності пацієнтів [9].

Більшість наукових досліджень у цій сфері спираються на закриті локальні архіви клінік, що унеможлиблює зовнішню валідацію розроблених алгоритмів. Для виконання завдань цієї дисертаційної роботи було проведено пошук та аналіз доступних джерел, в результаті якого відібрано дві ключові бази даних. Вони представляють діаметрально протилежні підходи до збору інформації: стандартизований клінічний (BIP_US) та "польовий" (Web-scraped), що дозволяє оцінити стійкість алгоритмів до різних умов зйомки.

База даних BIP_US (Biomedical Image Processing Group)

Цей набір даних є еталонним прикладом клінічної бази, створеної в академічному середовищі (Університет Севільї та лікарня Virgen del Rocío, Іспанія). Чітко видно текстурні відмінності, які використовуються для навчання класифікатора

Специфіка даних: зображення отримані в контрольованих умовах стаціонару з використанням професійного освітлення та калібрування кольору. Це мінімізує вплив тіней та відблисків, які часто заважають алгоритмам комп'ютерного зору.

Клінічна задача: розмітка даних орієнтована не просто на глибину опіку, а на тактику лікування. Класи розділені на дві групи: "Graft" (потребує пересадки шкіри – глибокі дермальні та повношарові опіки) та "Non-graft" (загоюється самостійно – поверхневі опіки).

Важливість ознак: як зазначають Yadav et al., цей датасет дозволяє детально аналізувати текстурні ознаки, такі як наявність та форма пухирів

(blisters), колір дна рани (білий/червоний) та стан оточуючої шкіри [7]. На рис. 1.5 продемонстровано приклади, де чітко видно відмінність між поверхневим опіком з вологим пухирем та глибоким ураженням.

Обмеження: головним недоліком для задач автоматизованого сортування є малий обсяг вибірки та відсутність розмітки типу Bounding Box (рамка об'єкта). Це означає, що неймережа може помилково навчатися на фонових об'єктах (лікарняні простирадла, інструменти), якщо не провести ручну сегментацію.



Рисунок 1.5 – Приклади зображень з бази даних VIP_US: (а) поверхневий опік, що не потребує операції; (б) глибокий опік, що потребує пересадки шкіри [7]

База даних Skin Burn Dataset (Kaggle). Для розробки системи, здатної працювати в екстремальних умовах (наприклад, у смартфоні парамедика на фронті), використання "стерильних" лікарняних фото є недостатнім. Тому в роботі використовується сучасний набір даних Skin Burn Dataset, зібраний з відкритих джерел [13].

Реалістичність умов: Зображення містять різноманітні артефакти: низька роздільна здатність, розмиття, складний фон (одяг, земля, побутові предмети), різні умови освітлення. Це наближає навчальну вибірку до реалій використання.

Детальна класифікація: На відміну від бінарної класифікації VIP_US, тут виділено три ступені тяжкості:

1. 1-й ступінь (*Superficial*): Еритема, суха шкіра, відсутність пухирів.
2. 2-й ступінь (*Partial-thickness*): Вологі пухирі, набряк, відшарування епідермісу.
3. 3-й ступінь (*Full-thickness*): Некротичний струп, обвуглення, суха біла або чорна шкіра.

Ключова перевага – YOLO розмітка. Це найважливіша особливість датасету. Кожне зображення супроводжується текстовим файлом з координатами прямокутної області (*Bounding Box*), що охоплює лише уражену ділянку (рис. 1.6). Це дозволяє реалізувати етап попередньої обробки ROI Extraction (виділення області інтересу), автоматично відсікаючи до 70% "сміттевого" фону. Це критично підвищує точність класифікації, змушуючи неймережу аналізувати саме рану, а не оточення.

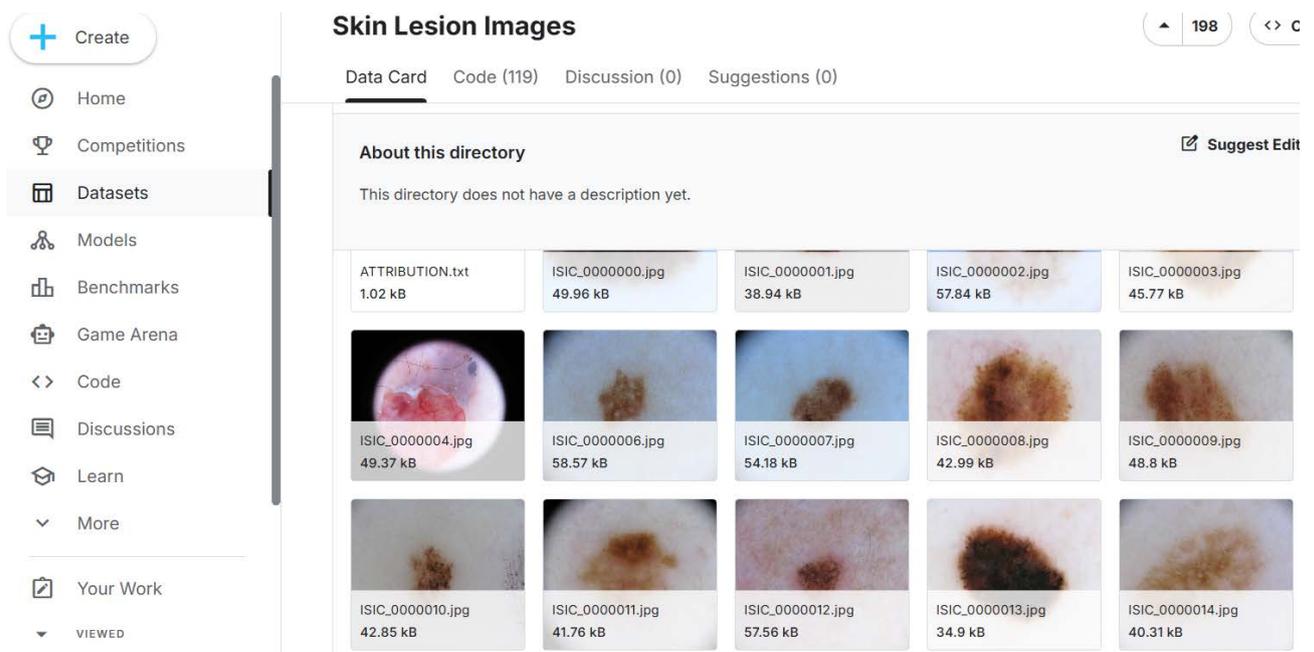
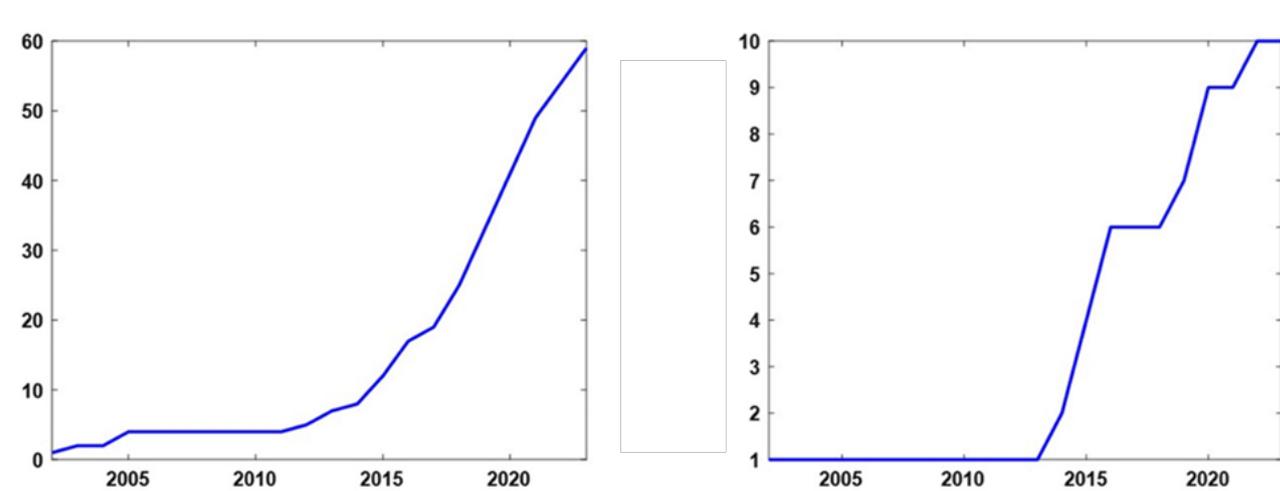


Рисунок 1.6 – Приклад представлення даних у платформі Kaggle [13].

Проблеми дисбалансу та валідації. Аналіз обох баз даних виявив типову проблему медичних датасетів – дисбаланс класів. Опіки 1-го ступеня часто недопредставлені в клінічних базах (оскільки такі пацієнти рідко звертаються до стаціонару), але широко представлені у "диких" датасетах. Натомість глибокі опіки (3-й ступінь) є рідкісними у відкритому доступі через етичні обмеження публікації шокуючого контенту.

Динаміка наукових публікацій свідчить про зростання інтересу саме до методів глибокого навчання (Deep Learning), які здатні працювати з такими неструктурованими даними (рис. 1.7).



а)

б)

Рисунок 1.7 – Кумулятивна кількість досліджень з використанням методів машинного навчання для класифікації опіків. Експоненціальне зростання підтверджує перехід від ручного виділення ознак до автоматизованих систем Deep Learning [9].

Узагальнена порівняльна характеристика баз даних наведена в Таблиці 1.3.

Для досягнення мети створення системи – оптимальним є використання бази **Skin Burn Dataset**. Наявність розмітки YOLO дозволяє автоматизувати процес підготовки даних, що є необхідною умовою для підвищення точності нейромережі в умовах роботи з фотографіями низької якості.

Таблиця 1.3 – Порівняльний аналіз баз даних зображень опіків

Характеристика	VIP_US Database	Skin Burn Dataset (Kaggle)
Походження даних	Клінічний стаціонар (Іспанія)	Відкриті джерела (Інтернет)
Умови зйомки	Стандартизовані (каліброване світло)	Варіативні (смартфони, різні камери)
Тип анотації	Класифікація (Graft / Non-graft)	Детекція (YOLO box) + Класифікація (Ступені 1–3)
Переваги	Висока якість зображень,	Велика кількість даних,

	медична точність діагнозу	наявність координат рани
Недоліки	Мала вибірка, відсутність локалізації	Наявність шумів, можливі неточності в розмітці
Цільове призначення	Системи підтримки рішень для хірургів	Системи первинного сортування (тріажу)

1.5 Складові інтелектуальних систем обробки біомедичних зображень

Проектування сучасної системи автоматизованої діагностики опікових уражень вимагає переходу від простих алгоритмів обробки сигналів до комплексних інтелектуальних архітектур. Аналіз літературних джерел [7, 14, 15] дозволяє виділити типову структуру такої системи, яка складається з чотирьох взаємопов'язаних модулів: попередньої обробки (Preprocessing), вилучення ознак (Feature Extraction), класифікації (Classification) та інтерпретації результатів (Explainability). Кожен із цих компонентів виконує критичну роль у забезпеченні точності та надійності діагнозу.

1.5.1 Модуль попередньої обробки та нормалізації даних

Медичні зображення, отримані в реальних умовах (особливо за допомогою мобільних пристроїв), характеризуються високою варіабельністю якості, освітлення та масштабу. Завданням цього модуля є приведення вхідних даних до стандартизованого вигляду, придатного для аналізу нейронною мережею.

Геометричні трансформації: Для подачі зображення на вхід згорткової нейронної мережі (CNN) необхідно змінити його розмір до фіксованих параметрів (у більшості сучасних архітектур, таких як DenseNet або ResNet, стандартом є 224×224 пікселі) [14].

Виділення області інтересу (ROI Extraction): Це найбільш критичний етап для задач діагностики опіків. Як показав аналіз бази даних Skin Burn Dataset [13], зображення часто містять значну кількість фонового шуму (одяг, меблі, здорова шкіра). Використання детекторів об'єктів, таких як YOLO (You Only Look Once), дозволяє автоматично знайти координати рани та виконати

операцію обрізки (cropping). Це фокусує увагу класифікатора виключно на патології, усуваючи ризик навчання на хибних ознаках фону.

Аугментація даних: Для запобігання перенавчанню (overfitting) на малих вибірках використовується штучне розширення набору даних. Методи включають випадкові повороти (rotation), віддзеркалення (flipping) та зміну масштабу. У дослідженні Pilar застосування аугментації дозволило підвищити точність моделі DenseNet201 з 74% до 82% на валідаційній вибірці [14].

1.5.2 Модуль вилучення інформативних ознак

Цей модуль відповідає за перетворення піксельного представлення зображення у набір числових дескрипторів (вектор ознак), які описують стан тканини. Існує два підходи до реалізації цього етапу:

Ручне формування ознак (Hand-crafted features): Традиційний підхід, описаний Yadav et al. [7], передбачає використання математичних алгоритмів для розрахунку конкретних параметрів

- колірні ознаки, розрахунок середніх значень каналів у просторі CIELAB (L^* , a^* , b^*). Канал a^* (червоний-зелений) є індикатором еритеми та васкуляризації, а канал L^* – наявності некротичного струпа (білий або чорний колір).
- текстурні ознаки, використання гістограм орієнтованих градієнтів (HOG) та ентропії для виявлення пухирів (blisters) та неоднорідностей поверхні, характерних для опіків II ступеня [7].

На рисунку 1.8 зображено схему роботи модуля вилучення ознак у глибоких нейронних мережах.

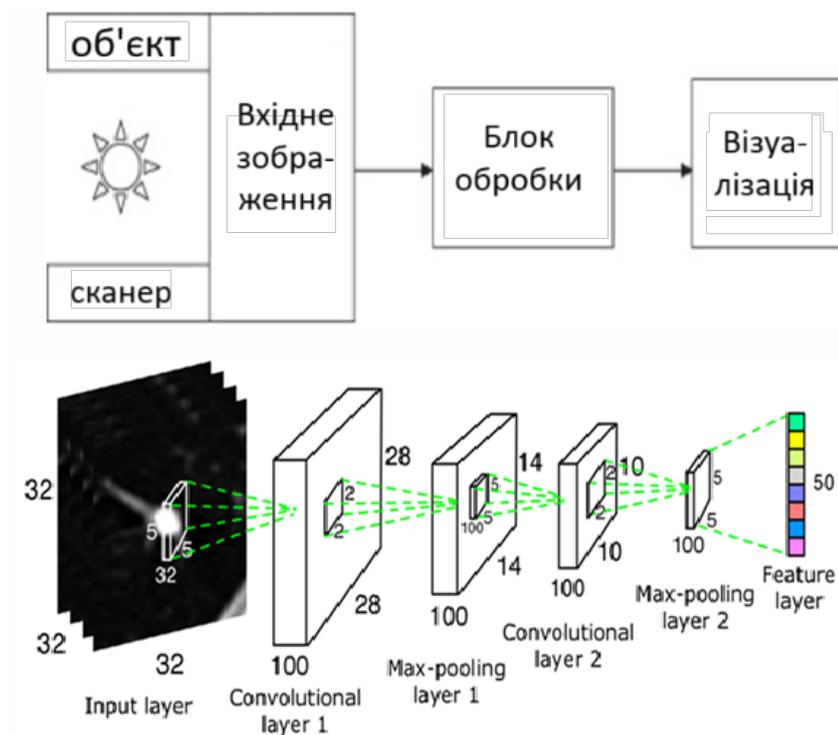


Рисунок 1.8 – Ієрархія вилучення ознак у згортковій нейронній мережі: від простих геометричних примітивів до складних текстур [15]

Глибинні ознаки (Deep features): Сучасний підхід базується на використанні згорткових нейронних мереж (CNN). У цьому випадку мережа самостійно формує ієрархію ознак: перші шари детектують краї та плями кольору, середні – текстури (шкіра, рана), а глибокі – семантичні поняття (пухир, струп). Архітектура DenseNet201, розглянута як пріоритетна, використовує механізм щільних зв'язків (dense connections), що дозволяє повторно використовувати ознаки з попередніх шарів, забезпечуючи високу ефективність навіть на невеликих датасетах [14, 15].

1.5.3 Модуль класифікації та прийняття рішень

Після отримання вектора ознак система повинна віднести зображення до одного з визначених класів (наприклад: поверхневий, частковий або глибокий опік).

Архітектура класифікатора: У системах глибокого навчання цю роль виконують повнозв'язні шари (Fully Connected Layers). Як зазначається у додатках до роботи Pilar, для підвищення стабільності класифікації після

згорткової частини додають шари Global Average Pooling та Dropout (для регуляризації), а завершує архітектуру шар Softmax [14].

Функція активації Softmax: Цей елемент перетворює вихідні значення нейронів у розподіл ймовірностей. Наприклад, для зображення опіку система може видати результат: {Ступінь 1: 10%, Ступінь 2: 85%, Ступінь 3: 5%}. Це дозволяє лікарю оцінити "впевненість" системи у діагнозі.

1.5.4 Модуль інтерпретації та візуалізації

Критичним недоліком багатьох ML-систем є їхня непрозорість ("чорна скринька"). Для медичного застосування необхідно розуміти, чому система прийняла те чи інше рішення. Для цього до складу інтелектуальної системи включається модуль візуалізації уваги.

Grad-CAM (Gradient-weighted Class Activation Mapping): Цей алгоритм генерує "теплову карту", яка накладається на оригінальне зображення. Червоні зони вказують на пікселі, які найбільше вплинули на рішення нейромережі.

Порівняння підходів до побудови інтелектуальних систем наведено в табл. 1.4. Якщо система класифікує опік як "глибокий", але підсвічує фон, а не рану, лікар може відхилити цей діагноз як помилковий [14]. Це є важливим інструментом верифікації та довіри до системи.

Таблиця 1.4 – Характеристика підходів до побудови систем аналізу біомедичних зображень

Характеристика	Системи на основі ручних ознак (Traditional ML)	Системи глибокого навчання (Deep Learning)
Вхідні дані	Вектори числових параметрів (колір, текстура)	"Сирі" піксельні масиви зображень
Вилучення ознак	Виконується експертом (Feature Engineering)	Автоматичне, в процесі навчання (Feature Learning)
Точність (на прикладі опіків)	70–80% (залежить від вибору ознак)	85–96% (залежить від обсягу даних)
Чутливість до умов зйомки	Висока (потребує ідеального світла)	Помірна (стійкіша до варіацій завдяки аугментації)

Обчислювальна складність	Низька (працює на CPU)	Висока (потребує GPU для навчання)
--------------------------	------------------------	------------------------------------

Проведений аналіз показав, що в умовах зростання кількості термічних травм та дефіциту кваліфікованих кадрів існує нагальна потреба у створенні автоматизованих засобів діагностики. Існуючі методи, що базуються на суб'єктивній оцінці або застарілих алгоритмах, не забезпечують необхідної точності та швидкості.

Найбільш перспективним напрямком є розробка інтелектуальної системи, що поєднує алгоритми детекції об'єктів (YOLO) для локалізації рани та усунення шумів, з потужними згортковими нейронними мережами для класифікації глибини ураження. Такий підхід дозволяє використовувати доступні бази даних та забезпечує можливість інтерпретації результатів, що є критичним для клінічного впровадження.

1.6 Висновки до розділу 1

Проведений аналіз предметної області засвідчив, що в умовах сучасних бойових дій та зростання кількості комбінованих термічних уражень критично важливою стає проблема швидкої та об'єктивної діагностики. Традиційні методи оцінки, що базуються на суб'єктивному візуальному огляді, характеризуються високою варіабельністю та значним ризиком помилок, особливо при диференціації опіків другого ступеня. Встановлено, що автоматизація цього процесу за допомогою телемедичних систем здатна нівелювати дефіцит профільних фахівців-комбустіологів на етапах евакуації та забезпечити ефективне медичне сортування постраждалих у польових умовах.

Порівняння існуючих методів отримання медичних зображень показало, що для завдань масового скринінгу найбільш доцільним є використання стандартної цифрової фотографії (RGB), оскільки вона не потребує спеціалізованого дороговартісного обладнання. Для обробки таких даних

обґрунтовано перехід від класичних методів машинного навчання до глибоких згорткових нейронних мереж (CNN), здатних автоматично виділяти складні текстурні ознаки. Аналіз доступних джерел даних виявив переваги використання відкритих наборів із розміткою для детекції об'єктів (YOLO), що дозволяє автоматизувати процес попередньої обробки та усунення фонових шумів, підвищуючи стійкість системи до реальних умов зйомки.

На основі огляду сформульовано концептуальну структуру інтелектуальної системи, яка поєднує алгоритми детекції області інтересу та класифікації глибини ураження. Визначено, що обов'язковою складовою такої системи має бути модуль інтерпретації результатів (Explainability) на базі алгоритмів візуалізації уваги (Grad-CAM). Це дозволить не лише отримувати діагностичний висновок, а й візуально підтверджувати, що рішення алгоритму базується на аналізі патологічних змін шкіри, а не артефактів зображення, що є необхідною умовою для клінічного застосування.

2 МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ ТА АЛГОРИТМІЧНЕ ЗАБЕЗПЕЧЕННЯ СИСТЕМИ ДІАГНОСТИКИ ОПІКІВ

Розробка автоматизованої системи діагностики опікових уражень вимагає формалізованого математичного опису об'єкта дослідження – цифрового зображення шкіри. У контексті комп'ютерного зору біомедичне зображення розглядається не просто як візуальна інформація, а як багатовимірний масив даних, що підлягає статистичному та спектральному аналізу. Точність класифікації ступеня опіку безпосередньо залежить від обраної математичної моделі представлення кольору та методів його калібрування, оскільки патологічні зміни (еритема, ішемія, некроз) проявляються насамперед у зміні спектральних характеристик відбитого світла.

2.1 Математичні моделі представлення біомедичних зображень та їх колірних просторів

Формалізація задачі діагностики опікових уражень вимагає переходу від візуального сприйняття до суворого математичного опису. Цифрове зображення шкіри розглядається як стохастичне двовимірне поле, параметри якого (інтенсивність, спектральний склад, локальна текстура) корелюють з патофізіологічними змінами тканин, такими як еритема, ішемія та некроз.

2.1.1 Матрична модель дискретного зображення

З математичної точки зору, неперервне зображення опікової рани моделюється як функція $f(x, y)$, де (x, y) – просторові координати на площині, а значення функції f характеризує інтенсивність світлового потоку. У процесі цифровізації відбувається дискретизація простору та квантування за рівнем яскравості.

Результуюче цифрове зображення I розмірністю $M \times N$ представляється у вигляді матриці, елементами якої є вектори ознак пікселів:

$$I = \{\mathbf{p}_{ij}\}_{i=1,j=1}^{M,N}, \quad (2.1)$$

де \mathbf{p}_{ij} – вектор, що описує спектральні характеристики пікселя в i -му рядку та j -му стовпці. Для стандартного кольорового зображення цей вектор має вимірність $k=3$ (канали Red, Green, Blue):

$$\mathbf{p}_{ij} = [r_{\{ij\}}, g_{\{ij\}}, b_{\{ij\}}]^T, \quad r, g, b \in [0, L - 1]. \quad (2.2)$$

де L – кількість рівнів квантування (зазвичай $2^8 = 256$) [17].

2.1.2 Лінійні та нелінійні трансформації колірних просторів

Використання простору RGB для аналізу опіків є неефективним через високу кореляцію між каналами та залежність від умов освітлення. Для виділення клінічно значущих ознак (еритема, пігментація) необхідно виконати трансформацію в перцептивно рівномірний простір CIELAB

Процес перетворення є двоступеневим. На першому етапі виконується лінійна трансформація з апаратно-залежного простору RGB в апаратно-незалежний простір CIE XYZ. Це описується матричним рівнянням:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \mathbf{M} \times \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.3)$$

де \mathbf{M} – матриця перетворення 3×3 , коефіцієнти якої залежать від характеристик сенсора камери та типу освітлювача (ілюмінанта). Для стандартного освітлювача D65 (денне світло) матриця має вигляд:

$$\mathbf{M} = \begin{bmatrix} 0.4124 & 0.3576 & 0.1805 \\ 0.2126 & 0.7152 & 0.0722 \\ 0.0193 & 0.1192 & 0.9505 \end{bmatrix} \quad (2.4)$$

На другому етапі виконується нелінійна трансформація XYZ у простір $(L^* a^* b^*)$, яка враховує логарифмічну природу чутливості людського ока. Координати розраховуються відносно білої точки (X_n, Y_n, Z_n) :

$$L^* = 116 \cdot f\left(\frac{Y}{Y_n}\right) - 16. \quad (2.5)$$

$$a^* = 500 \cdot \left[f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right]. \quad (2.6)$$

$$b^* = 200 \cdot \left[f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right]. \quad (2.7)$$

Функція $f(t)$ визначається як:

$$f(t) = \begin{cases} t^{1/3}, \text{ якщо } t > \epsilon, \\ 7.787 \cdot t + \frac{16}{116}, \text{ якщо } t \leq \epsilon. \end{cases}$$

де поріг $\epsilon = 0.008856$. У цій моделі компонент L^* відповідає за яскравість (важливо для детекції некротичного струпа), a^* – за вісь «зелений–червоний» (маркер васкуляризації та запалення), а b^* – за вісь «синій–жовтий» (маркер нагноєння або загоєння) [7, 18].

2.1.3 Математична модель колориметричного калібрування

Зйомка в польових умовах характеризується неконтрольованим освітленням, що вносить мультиплікативний та адитивний шум у спектральні характеристики зображення. Для усунення цього впливу використовується метод мінімізації середньоквадратичної помилки (MSE) між виміряними та еталонними значеннями кольорів на калібрувальній мішені (наприклад, Macbeth ColorChecker).

Цільова функція помилки ε^2 , яку необхідно мінімізувати для знаходження оптимальної матриці корекції $f(C)$, записується як:

$$\varepsilon^2 = \frac{1}{K} \sum_{k=1}^K \left[(X_{ref,k} - X_{est,k})^2 + (Y_{ref,k} - Y_{est,k})^2 + (Z_{ref,k} - Z_{est,k})^2 \right] \rightarrow \min,$$

де K – кількість контрольних полів на мішені (зазвичай 24), $(X_{ref}, Y_{ref}, Z_{ref})$ – еталонні координати, а $(X_{est}, Y_{est}, Z_{est})$ – значення, отримані після застосування матриці корекції до вхідного зображення [17].

2.1.4 Моделювання індивідуального тону шкіри

Для зменшення зміщення алгоритмів класифікації щодо пацієнтів з різним кольором шкіри вводиться метрика кута індивідуальної типології (ІТА – Individual Typology Angle). Цей параметр обчислюється у просторі L^*b^* і дозволяє математично відокремити конституційний пігмент (меланін) від патологічного почервоніння.

Формула розрахунку ІТА в градусах:

$$ITA = \frac{180}{\pi} \cdot \arctan\left(\frac{L^* - 50}{b^*}\right) \quad (2.10)$$

Значення ІТА використовується як додатковий вхідний вектор у нейронну мережу, дозволяючи адаптувати вагові коефіцієнти під фототип шкіри пацієнта (від «дуже світлий» при ІТА $> 55^\circ$ до «темний» при ІТА $< -30^\circ$) [19].

2.1.5 Статистичні дескриптори текстури опікової поверхні

Окрім спектральних характеристик, для діагностики глибини опіку (особливо для розрізнення ступенів Іа та Іб) критично важливим є аналіз текстури (наявність пухирів, шорсткість, вологість). Математично текстура описується через статистичні моменти n -го порядку розподілу інтенсивності пікселів у каналах a^* та L^* .

Математичне очікування (μ) характеризує загальний рівень сигналу (наприклад, ступінь гіперемії):

$$\mu = \frac{1}{N} \sum_{i=1}^N p_i. \quad (2.11)$$

Дисперсія (σ^2) описує неоднорідність поверхні (гетерогенність опіку):

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (p_i - \mu)^2. \quad (2.12)$$

Асиметрія (S) дозволяє виявити зміщення гістограми яскравості, що характерно для наявності блідих (ішемічних) ділянок на тлі запалення:

$$S = \frac{1}{N} \sum_{i=1}^N \left(\frac{p_i - \mu}{\sigma}\right)^3. \quad (2.13)$$

Ексцес (K) є мірою гостровершинності розподілу. У дослідженнях Yadav et al. доведено, що ексцес є ефективним дискримінатором глибини опіку: високі значення K (гострий пік) корелюють з глибокими дермальними опіками, тоді як низькі значення (плоский розподіл) – з поверхневими ураженнями [18]:

$$K = \frac{1}{N} \sum_{i=1}^N \left(\frac{p_i - \mu}{\sigma} \right)^4. \quad (2.14)$$

Сукупність цих параметрів формує вектор ознак $V_{feat} = [\mu, \sigma^2, S, K, ITA]^T$, який може бути використаний як вхідний шар для класифікатора або для попереднього налаштування ваг згорткової нейронної мережі.

Математичне представлення біомедичних зображень для задач діагностики опіків базується на використанні колірному простору CIELAB, який є найбільш інформативним для виявлення патологічних змін шкіри. Застосування алгоритмів колориметричного калібрування дозволяє мінімізувати вплив зовнішнього освітлення, а використання статистичних дескрипторів (асиметрія, ексцес) та метрики ІТА забезпечує формування простору ознак. Описані математичні моделі є фундаментом для подальшої побудови архітектури згорткової нейронної мережі.

2.2 Геометричні ознаки та математичне моделювання оптичних спотворень при формуванні біомедичних зображень

Точність визначення площі опікового ураження є критичним параметром для розрахунку інфузійної терапії (формула Паркланда) та прогнозування виживаності пацієнта. Однак, при використанні телемедичних систем, де зображення отримуються за допомогою камер мобільних пристроїв або веб-камер, виникає проблема геометричних спотворень (дисторсії). Ці спотворення зумовлені фізичними властивостями лінз та проєктивною природою формування зображення, коли тривимірний об'єкт (частина тіла пацієнта) проєктується на двовимірну площину сенсора камери. Без математичної компенсації цих ефектів похибка у визначенні площі може досягати значних величин, особливо на краях зображення, що неприпустимо в клінічній практиці.

2.2.1 Математична модель камери-обскури

Базовою моделлю для опису процесу формування зображення є модель камери-обскури. Згідно з цією моделлю, зв'язок між точкою в тривимірному просторі $P_w = [X_w, Y_w, Z_w]^T$ (світові координати, наприклад, точка на поверхні опіку) та її проекцією на площині зображення $p = [u, v]^T$ (піксельні координати) описується проєктивним перетворенням.

У роботі Herdiansyah et al. [20] наведено матричне рівняння, що пов'язує ці координати через внутрішні та зовнішні параметри камери. У однорідних координатах це співвідношення записується як:

$$s \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \mathbf{K} \cdot [\mathbf{R} | \mathbf{t}] \cdot \begin{bmatrix} X_w \\ Y_w \\ Z_w \\ 1 \end{bmatrix}, \quad (2.15)$$

де: s – масштабний коефіцієнт (масштабний фактор проєкції); $[\mathbf{R} | \mathbf{t}]$ – матриця зовнішніх параметрів (Extrinsic Matrix) розмірністю 3×4 , яка описує положення камери відносно об'єкта. \mathbf{R} – матриця обертання (3×3), \mathbf{t} – вектор трансляції (3×3); \mathbf{K} – матриця внутрішніх параметрів (Intrinsic Matrix) розмірністю 3×3).

Матриця \mathbf{K} є унікальною для кожного оптичного пристрою і визначає, як фізичні промені світла перетворюються на цифрові пікселі. Згідно з дослідженнями [20], вона має вигляд:

$$\mathbf{K} = \begin{bmatrix} f_x & \gamma & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix}, \quad (2.16)$$

де: f_x, f_y – фокусні відстані об'єктива, виражені в пікселях вздовж осей x та y відповідно. Різниця між ними вказує на неквадратність пікселів сенсора; c_x, c_y – координати головної оптичної точки, яка зазвичай знаходиться поблизу центру зображення. Це точка перетину оптичної осі з площиною сенсора; γ – коефіцієнт скосу (skew coefficient), що визначає кут між осями пікселів. Для сучасних цифрових камер осі x та y є перпендикулярними, тому в більшості випадків $\gamma = 0$ [20].

Ця модель є ідеалізованою. У реальних умовах, особливо при використанні ширококутних об'єктивів, які дозволяють захопити велику ділянку тіла з близької відстані (що актуально для польових умов), виникають суттєві нелінійні спотворення.

2.2.2 Математичне моделювання оптичних дисторсій

Оптичні спотворення призводять до того, що прямі лінії на об'єкті відображаються як криві на зображенні, а масштаб об'єкта змінюється залежно від віддаленості від центру кадру. Alkhimova та Davydovych [21] у своєму дослідженні точності розпізнавання маркерів на ширококутних камерах виділяють два основні типи спотворень: радіальну та тангенціальну дисторсію.

Для математичного опису цих спотворень вводяться нормалізовані координати точки (x, y) перед впливом дисторсії та спотворені координати (x_{dist}, y_{dist}) . Відстань від центру спотворення (головної точки) до поточного пікселя позначається як r :

$$r^2 = x^2 + y^2, \quad (2.17)$$

Радіальна дисторсія виникає через недосконалість форми лінз, коли заломлення променів на краях лінзи відрізняється від заломлення в центрі. Це призводить до ефекту "бочки" або "подушки". Математично цей ефект моделюється за допомогою ряду Тейлора. Згідно з даними калібрування, наведеними у [20], для корекції достатньо використовувати три коефіцієнти (k_1, k_2, k_3) :

$$\begin{aligned} x_{radial} &= x(1 + k_1 r^2 + k_2 r^4 + k_3 r^6), \\ y_{radial} &= y(1 + k_1 r^2 + k_2 r^4 + k_3 r^6). \end{aligned} \quad (2.18)$$

У дослідженні [20] експериментально отримані значення цих коефіцієнтів для типової веб-камери склали $k_1 \approx 0.117$, $k_2 \approx 1.519$, що свідчить про значний вплив радіального компонента на геометричну точність зображення.

Тангенціальна дисторсія.

Цей тип спотворень виникає, коли лінза встановлена не ідеально паралельно площині сенсора камери (децентрування оптичної системи). Це призводить до того, що зображення виглядає "нахиленим" або розтягнутим в одному напрямку. Модель тангенціальної дисторсії описується двома коефіцієнтами (p_1, p_2) [21]:

$$\begin{aligned}x_{tangential} &= 2p_1xy + p_2(r^2 + 2x^2), \\y_{tangential} &= p_1(r^2 + 2y^2) + 2p_2xy.\end{aligned}\tag{2.19}$$

Узагальнена модель спотворень

Повна математична модель, що зв'язує ідеальні координати (x, y) з реально спостережуваними на зображенні (x_{dist}, y_{dist}) , є сумою радіальної та тангенціальної складових:

$$\begin{aligned}x_{dist} &= x(1 + k_1r^2 + k_2r^4 + k_3r^6) + [2p_1xy + p_2(r^2 + 2x^2)], \\y_{dist} &= y(1 + k_1r^2 + k_2r^4 + k_3r^6) + [p_1(r^2 + 2y^2) + 2p_2xy].\end{aligned}\tag{2.20}$$

Саме ці рівняння необхідно розв'язати (інвертувати) для відновлення реальної геометрії опікової рани. Оскільки аналітичне розв'язання цієї системи є складним, на практиці використовуються ітеративні методи наближення.

2.2.3 Алгоритмічна реалізація калібрування камери (Метод Чжана)

Для знаходження невідомих параметрів K (внутрішні) та коефіцієнтів дисторсії $(k_1, k_2, k_3, p_1, p_2)$ використовується алгоритм калібрування Чжана (Zhang's algorithm), ефективність якого для задач оцінки пози підтверджена в роботі [20].

Суть методу полягає у зйомці планарного патерну (шахової дошки) у різних орієнтаціях (мінімум 3, рекомендовано >20). Процес калібрування можна описати як задачу оптимізації, де мінімізується функція помилки перепроєктування (re-projection error).

Нехай m_{ij} – спостережувана точка j на зображенні i , а $\hat{m}(A, R_i, t_i, M_j)$ – проекція відповідної точки моделі M_j на зображення i згідно з формулами (2.15) та (2.20). Функція втрат L , яку необхідно мінімізувати, виглядає так:

$$L = \sum_{i=1}^N \sum_{j=1}^M |m_{ij} - \hat{m}(A, R_i, t_i, M_j)|^2. \quad (2.21)$$

У роботі Herdiansyah et al. [20] показано, що застосування цього методу дозволяє досягти сумарної помилки калібрування всього **0.018 пікселя**. Це забезпечує високу точність відновлення геометрії об'єктів навіть на периферії кадру, що підтверджується експериментами Alkhimova [21], де точність розпізнавання маркерів на краях ширококутного зображення становила понад 80% після корекції.

2.2.4 Оцінка пози та масштабування для вимірювання площі опіку

Після усунення спотворень виникає задача перетворення розмірів опіку з пікселів у сантиметри. Оскільки зображення є 2D-проекцією, визначити реальний розмір неможливо без знання відстані до об'єкта. Для цього в систему вводиться референсний об'єкт – фідуціарний маркер (наприклад, ArUco), розмір якого відомий заздалегідь.

Задача оцінки пози полягає у знаходженні вектора трансляції $t = [t_x, t_y, t_z]^T$ та вектора обертання r маркера відносно камери. Це дозволяє визначити дистанцію Z (глибину).

Згідно з [20], точність оцінки відстані Z залежить від роздільної здатності камери та фізичного розміру маркера. Помилка оцінки глибини ΔZ може бути апроксимована лінійною залежністю від реальної відстані Z_{real} :

$$\Delta Z \approx \alpha + \beta \cdot Z_{real}, \quad (2.22)$$

де α та β – емпіричні коефіцієнти. У експериментах [20] для відстані 100 см середня абсолютна похибка склала 1.77 см (відносна похибка 1.65%), що є прийнятним для клінічних задач оцінки площі ураження.

Розрахунок реальної площі опіку S_{real} на основі площі на зображенні S_{img} (в пікселях) виконується за формулою:

$$S_{real} = S_{img} \cdot \left(\frac{Z}{f}\right)^2, \quad (2.23)$$

де f – фокусна відстань у пікселях, отримана з матриці K (рівняння 2.16), а Z – дистанція до рани, отримана через оцінку пози маркера ArUco.

2.2.5 Вплив температурних факторів на оптичні характеристики

При проектуванні системи для польових умов також необхідно враховувати вплив температури навколишнього середовища на оптичні властивості лінз (терморозфокусування), що розглядається в роботі Muraviov [22]. Зміна температури призводить до зміни показника заломлення матеріалу лінз $n(T)$ та їх геометричних розмірів, що впливає на фокусну відстань f :

$$\frac{df}{dT} = f \left(\alpha_{glass} - \frac{1}{n-1} \frac{dn}{dT} \right), \quad (2.24)$$

де α_{glass} – коефіцієнт теплового розширення скла. Хоча в стандартних камерах цей ефект компенсується автофокусом, у спеціалізованих інфрачервоних або мультиспектральних камерах він може призводити до зниження контрастності зображення та похибок у визначенні меж опіку (сегментації). Для медичних термографів це вимагає застосування атермалізації оптичної системи [22].

Математичне моделювання процесу формування зображення виявило, що "сирі" біомедичні зображення містять систематичні геометричні спотворення (радіальні та тангенціальні), які описуються нелінійними поліноміальними моделями. Для забезпечення метрологічної точності вимірювання площі опіку необхідно застосовувати процедуру калібрування камери за цим методом, що дозволяє визначити матрицю внутрішніх параметрів та коефіцієнти дисторсії.

Інтеграція в систему маркерів (ArUco) дозволяє розв'язати задачу відновлення масштабу через оцінку пози, забезпечуючи перерахунок піксельної площі у фізичні одиниці з похибкою менше 2% на відстанях до 1 метра.

Описаний математичний апарат є основою для модуля попередньої обробки даних у розроблюваній інтелектуальній системі.

2.3 Математичні методи вилучення ознак та класифікації зображень опіків на основі статистичного аналізу та опорних векторів

Розробка автоматизованої системи діагностики опікових уражень вимагає створення надійного математичного базису для перетворення візуальної інформації (пікселів зображення) у клінічно значущі рішення (клас опіку, необхідність пересадки шкіри). У той час як методи глибокого навчання працюють за принципом «чорної скриньки», підхід, заснований на явному вилученні ознак (Feature Extraction) з подальшою класифікацією методом опорних векторів (SVM), дозволяє формалізувати фізичні та текстурні характеристики рани, що забезпечує високу інтерпретованість результатів.

У цьому підрозділі розглядається математичний апарат формування простору ознак, що включає колірні дескриптори, статистичні моменти вищих порядків (ексцес, асиметрія) та гістограми орієнтованих градієнтів (HOG), а також теоретичні основи побудови розділяючих гіперплощин для бінарної класифікації «Graft / Non-Graft» (потребує / не потребує пересадки).

2.3.1 Математична формалізація простору ознак

Згідно з дослідженнями Yadav et al. [18], точність класифікації опіку критично залежить від формування правильного вектора ознак x . Зображення опіку I після попередньої обробки та переведення у простір CIELAB розглядається як джерело статистичних даних, де кожен канал (L^* , a^* , b^*) несе специфічну діагностичну інформацію.

Вектор ознак x для кожного зображення формується як сукупність дескрипторів:

$$x = [\mu, \sigma^2, S, K, H, C, h_{hog}]^T$$

де μ – середнє значення, σ^2 – дисперсія, S – асиметрія, K – ексцес, H – відтінок, C – насиченість (хрома), h_{hog} – вектор ознак HOG.

Статистичні моменти розподілу інтенсивності

Глибина опіку корелює з текстурною однорідністю та розподілом кольору. Для математичного опису цих властивостей використовуються центральні моменти випадкової величини (значень пікселів у каналах a^* та L^*).

1. Математичне сподівання (μ) та дисперсія (σ^2)

Середнє значення каналу a^* вказує на загальний рівень васкуляризації (червоний колір). Дисперсія описує розкид значень відносно середнього, що математично формалізується як:

$$V = \sigma^2 = \frac{1}{N-1} \sum_{i=1}^N |A_i - \mu|^2, \quad (2.25)$$

де N – кількість пікселів у області інтересу (ROI), A_i – значення інтенсивності i -го пікселя у каналі a^* , μ – середнє арифметичне:

$$\mu = \frac{1}{N} \sum_{i=1}^N A_i. \quad (2.26)$$

Експериментально встановлено, що дисперсія каналу a^* досягає максимуму при поверхневих дермальних опіках (Superficial Dermal) через наявність плям еритеми та здорової шкіри, і монотонно спадає при переході до глибоких опіків (Deep Dermal) та опіків повної товщини (Full Thickness), де тканина стає більш однорідною (некротичною) [18].

2. Ексцес (K) як індикатор глибини

Ексцес є мірою "гостровершинності" розподілу ймовірностей значень пікселів. У контексті діагностики опіків це є критичним параметром для оцінки глибини ураження. Математично ексцес визначається як четвертий стандартизований момент:

$$K = \frac{E[(x-\mu)^4]}{\sigma^4} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^4}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2\right)^2}, \quad (2.27)$$

де $E[\cdot]$ – оператор математичного очікування.

Фізичний зміст: Високе значення K (розподіл) вказує на те, що більшість пікселів мають значення, близькі до середнього, але існують "важкі хвости" розподілу. Згідно з [18], високий ексцес корелює з глибокими опіками, де основна площа рани має однорідний колір (наприклад, білий струп), а відхилення є незначними. Низький ексцес характерний для поверхневих опіків з різноманітною колірною гамою.

3. Асиметрія (S)

Асиметрія характеризує ступінь несиметричності розподілу відносно середнього значення. Вона обчислюється як третій стандартизований момент:

$$S = \frac{E[(x-\mu)^3]}{\sigma^3} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^3}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2\right)^{3/2}}, \quad (2.28)$$

Цей параметр дозволяє математично відрізнити опіки з переважанням темних ділянок (некроз, $S < 0$) від опіків з переважанням світлих/червоних ділянок (запалення, $S > 0$).

Колориметричні дескриптори: хрома та відтінок

Для точної ідентифікації типу тканини (епітелій, струп, грануляції) недостатньо аналізувати окремі канали. Необхідно використовувати інтегральні показники простору CIELAB.

Хрома (Chroma, C_{ab}^*) визначає насиченість кольору, тобто ступінь його відмінності від сірого тієї ж яскравості. Вона розраховується як евклідова норма вектора кольоровості на площині (a^*, b^*) :

$$C_{ab}^* = \sqrt{(a^*)^2 + (b^*)^2} \quad (2.29)$$

Цей параметр визначає "барвистість" (colorfulness) рани. Висока хрома характерна для свіжих опіків з активним кровообігом, низька – для ішемізованих ділянок.

Відтінок (Hue, h_{ab}) визначає колірний тон (червоний, жовтий, коричневий) і обчислюється як кут вектора на колірному колі:

$$h_{ab} = \arctan\left(\frac{b^*}{a^*}\right). \quad (2.30)$$

Значення h_{ab} дозволяє розділити відтінки "рожево-білястого" (характерного для поверхневих опіків) та "бежево-жовтого" або "темно-коричневого" (характерного для глибоких уражень) [18].

2.3.2 Математичне моделювання локальних форм методом HOG

Однією з ключових візуальних ознак поверхневих дермальних опіків, які не потребують хірургічного втручання, є наявність пухирів. Пухирі мають специфічну геометричну форму (округлість) та чіткі межі, які складно описати лише колірними моментами. Для їх детекції використовується дескриптор гистограми орієнтованих градієнтів (Histogram of Oriented Gradients – HOG).

Алгоритм HOG базується на аналізі розподілу напрямків градієнтів інтенсивності. Процес обчислення складається з наступних математичних операцій:

1. Обчислення градієнтів: Для кожного пікселя (x, y) обчислюються проєкції градієнта яскравості $L(x, y)$ на осі x та y :

$$G_x(x, y) = L(x + 1, y) - L(x - 1, y)$$

$$G_y(x, y) = L(x, y + 1) - L(x, y - 1)$$

2. Визначення магнітуди та орієнтації

Магнітуда градієнта $M(x, y)$:

$$M(x, y) = \sqrt{G_x(x, y)^2 + G_y(x, y)^2}. \quad (2.31)$$

Кут (орієнтація) градієнта $\theta(x, y)$:

$$\theta(x, y) = \arctan\left(\frac{G_y(x, y)}{G_x(x, y)}\right). \quad (2.32)$$

Формування гістограм: Зображення розбивається на комірки (cells). Для кожної комірки будується гістограма орієнтацій, де вага кожного біна (кутового сектору) пропорційна магнітуді $M(x, y)$. Це дозволяє кодувати інформацію про локальні форми (наприклад, дуги пухирів), ігноруючи постійний колір фону.

Включення HOG у вектор ознак дозволило значно підвищити точність розпізнавання опіків з пухирями, що підтверджено експериментально у роботі [18] (зростання точності на тренувальній вибірці до 98%).

2.3.3 Метод опорних векторів (SVM) для бінарної класифікації

Фінальним етапом математичного моделювання є побудова вирішального правила, яке відносить вхідний вектор ознак x до одного з двох класів:

- Клас $+1$ (Graft): Глибокі дермальні та повношарові опіки (потребують операції).
- Клас -1 (Non-Graft): Поверхневі опіки (лікуються консервативно).

Для вирішення цієї задачі використовується метод опорних векторів (Support Vector Machine – SVM). Математична суть методу полягає у знаходженні оптимальної гіперплощини у d -вимірному просторі ознак (де d – кількість виділених ознак), яка розділяє два класи з максимально можливим зазором (margin).

Рівняння гіперплощини задається як:

$$w \cdot x + b = 0, \quad (2.33)$$

де $w \in R^d$ – вектор нормалі до гіперплощини, b – зміщення.

Задача навчання SVM зводиться до задачі квадратичної оптимізації з обмеженнями. Необхідно знайти такі w та b , які мінімізують норму вагового вектора $|w|$ (що еквівалентно максимізації ширини розділяючої смуги $\frac{2}{|w|}$), при виконанні умов правильної класифікації для всіх навчальних прикладів (x_i, y_i) :

$$\min_{w, b} \frac{1}{2} |w|^2 \text{ при умові: } y_i(w \cdot x_i + b) \geq 1, \quad \forall i = 1, \dots, N.$$

Гіперплощини, що обмежують класи, визначаються рівняннями [18]:

для класу Graft:

$$H_1: w \cdot x + b = +1 \quad (2.35)$$

для класу Non-Graft:

$$H_2: w \cdot x + b = -1. \quad (2.35)$$

Опорними векторами називаються ті вектори ознак x_i , які лежать безпосередньо на цих граничних гіперплощинах (H_1 та H_2). Саме вони визначають положення розділюючої поверхні.

У випадку, якщо дані не є лінійно роздільними у вихідному просторі ознак (що часто трапляється при аналізі складних біомедичних зображень), застосовується "kernel trick" – відображення вхідних векторів у простір вищої розмірності за допомогою функції ядра $K(x_i, x_j)$. Однак у дослідженні [18] показано, що завдяки ретельному відбору статистичних ознак (дисперсія, ексцес, HOG) вдалося досягти лінійної роздільності класів з високою точністю (82.43% на тестовій вибірці), що підтверджує ефективність обраного математичного апарату.

Розроблена математична модель класифікації базується на поєднанні статистичного аналізу розподілу кольору та дескрипторів форми. Використання моментів вищих порядків (ексцес, асиметрія) дозволяє математично описати поняття "глибини" та "однорідності" опікової рани, а застосування гістограм орієнтованих градієнтів (HOG) забезпечує детекцію специфічних клінічних ознак, таких як пухирі. Оптимізаційна задача методу SVM дозволяє побудувати надійний класифікатор, здатний розділяти пацієнтів на групи за необхідністю хірургічного втручання, що є основою для автоматизованої системи підтримки прийняття рішень.

2.4 Математичні методи та алгоритми класифікації біомедичних зображень

Задача класифікації опікових уражень зводиться до відображення вхідного простору ознак (пікселів або вилучених дескрипторів) у дискретну множину класів $Y = \{y_1, y_2, \dots, y_k\}$, де кожен клас відповідає певному ступеню тяжкості опіку (наприклад, поверхневий, частковий, глибокий). В сучасній практиці медичного аналізу зображень виділяють два основні підходи: класичні методи машинного навчання, що базуються на попередньо вилучених ознаках (hand-crafted features), та методи глибокого навчання, які автоматизують процес конструювання ознак [28, 29].

2.4.1 Класифікація на основі гіперплощин (Метод опорних векторів)

Метод опорних векторів (Support Vector Machine, SVM) є одним з найбільш ефективних класичних алгоритмів для задач медичної діагностики, особливо в умовах обмеженої кількості навчальних даних. Як показано в роботі Sevik et al. [28], SVM демонструє високу точність при класифікації опіків на основі текстурних та колірних ознак.

Основна ідея методу полягає у пошуку оптимальної гіперплощини, яка розділяє класи з максимально можливим зазором (margin). Нехай задано навчальну вибірку пар $\{(x_i, y_i)\}_{i=1}^N$, де $x_i \in R^d$ – вектор ознак зображення, а $y_i \in \{-1, +1\}$ – мітка класу (наприклад, опік/не опік).

Рівняння розділяючої гіперплощини має вигляд:

$$f(x) = w^T x + b = 0, \quad (2.36)$$

де w – вектор нормалі до гіперплощини, b – зміщення.

Задача навчання зводиться до мінімізації норми вектора ваг $|w|$ при виконанні умов розділення класів, що формалізується як задача квадратичного програмування: $\min_{w,b,\xi} \left(\frac{1}{2} |w|^2 + C \sum_{i=1}^N \xi_i \right)$ за умов:

$$y_i(w^T x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0. \quad (2.38)$$

де ξ_i – змінні слабкості (slack variables), що дозволяють допускати певні помилки класифікації (м'який зазор) у випадку лінійно нероздільних даних, а C – параметр регуляризації, що керує балансом між шириною зазору та помилкою класифікації [27].

Для класифікації опіків, де дані часто не є лінійно роздільними, застосовується "ядерний трюк" (kernel trick). Функція ядра $K(x_i, x_j)$ дозволяє неявно відобразити вхідні вектори у простір вищої розмірності, де класи стають лінійно роздільними. Найчастіше використовується радіальна базисна функція (RBF):

$$K(x_i, x_j) = \exp(-\gamma|x_i - x_j|^2), \quad (2.39)$$

де γ – параметр ядра.

У роботі [27] показано, що використання SVM з RBF-ядром дозволяє досягти точності 96.6% при класифікації опіків на основі ознак простору кольорів YCbCr.

2.4.2 Імовірнісні методи

Альтернативою геометричним методам є імовірнісні підходи. Метод k -найближчих сусідів (k -NN) базується на гіпотезі компактності: об'єкти одного класу у просторі ознак знаходяться близько один до одного.

Класифікація нового зображення x_{new} здійснюється шляхом голосування k найближчих сусідів з навчальної вибірки. Відстань (метрика) зазвичай обчислюється як евклідова:

$$d(x_{new}, x_i) = \sqrt{\sum_{j=1}^d (x_{new,j} - x_{i,j})^2}, \quad (2.40)$$

Ймовірність приналежності об'єкта до класу у оцінюється як:

$$P(y|x_{new}) = \frac{1}{k} \sum_{i \in N_k(x_{new})} I(y_i = y), \quad (2.41)$$

де $N_k(x_{new})$ – множина індексів k найближчих сусідів, $I(\cdot)$ – індикаторна функція.

Дослідження [28] порівнює k -NN та SVM для задач класифікації опіків і вказує на те, що k -NN є обчислювально простішим, але менш стійким до шумів та дисбалансу класів, що характерно для медичних даних.

2.4.3 Глибокі згорткові нейронні мережі (CNN)

На відміну від класичних методів, які потребують етапу ручного конструювання ознак (feature engineering), згорткові нейронні мережі (CNN) поєднують процеси вилучення ознак та класифікації в єдину структуру, що навчається "від кінця до кінця" (end-to-end).

Математичною основою CNN є операція згортки. Вхідне зображення I згортається з набором фільтрів (ядер) K , що дозволяє виділяти локальні особливості (краї, текстури). Для двовимірного зображення операція згортки на шарі l записується як:

$$z_{i,j}^{(l)} = \sum_m \sum_n w_{m,n}^{(l)} \cdot x_{i+m,j+n}^{(l-1)} + b^{(l)}, \quad (2.42)$$

де $w_{m,n}$ – вагові коефіцієнти ядра згортки, b – зміщення, $x^{(l-1)}$ – вхідна карта ознак (або зображення).

Після згортки застосовується нелінійна функція активації (зазвичай ReLU – Rectified Linear Unit), яка дозволяє мережі апроксимувати складні нелінійні залежності:

$$f(z) = \max(0, z). \quad (2.43)$$

Для зменшення розмірності карт ознак та забезпечення інваріантності до невеликих зміщень використовується операція субдискретизації (Pooling). Найпоширенішою є операція максимального пулінгу (Max Pooling):

$$p_{i,j} = \max_{(m,n) \in \Omega_{i,j}} x_{m,n}, \quad (2.44)$$

де $\Omega_{i,j}$ – вікно пулінгу.

Сучасні архітектури CNN, такі як ResNet, Inception та VGG, продемонстрували значну перевагу над класичними методами у задачах діагностики опіків [29]. Зокрема, використання попередньо навчених моделей (Transfer Learning) дозволяє ефективно вирішувати проблему недостатньої кількості розмічених медичних зображень.

2.4.4 Класифікація з локалізацією (YOLO)

Для задач, де необхідно не лише визначити тип опіку, але й його локалізацію (що критично для розрахунку площі), використовуються алгоритми детекції об'єктів, зокрема YOLO (You Only Look Once). Як зазначено в роботі Suha & Sanam [29], цей підхід дозволяє одночасно прогнозувати обмежувальну рамку (bounding box) та клас об'єкта.

YOLO розбиває зображення на сітку $S \times S$. Для кожної комірки прогнозується B рамок та ймовірності класів C . Цільова функція втрат YOLO є композитною і включає помилки координат рамки, помилки наявності об'єкта та помилки класифікації:

$$L_{YOLO} = \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{obj} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] + \\ + \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{obj} (C_i - \hat{C}_i)^2 + \dots \quad (2.45)$$

Цей метод був обраний у роботі для етапу попередньої обробки даних (виділення ROI), оскільки він забезпечує високу швидкість (real-time) та точність локалізації патології.

2.5 Математична модель та архітектура реалізованої системи на базі DenseNet201

У роботі для вирішення задачі класифікації ступеня тяжкості опіків було обрано архітектуру **DenseNet201** (Densely Connected Convolutional Networks).

Вибір цієї архітектури обґрунтований її високою ефективністю при роботі з медичними зображеннями, де критично важливим є збереження як низькорівневих (текстура рани), так і високорівневих (форма, контекст) ознак.

2.5.1 Обґрунтування вибору архітектури DenseNet

Головною проблемою глибоких нейронних мереж є зникнення градієнта (vanishing gradient problem) під час зворотного поширення помилки. Архітектура ResNet вирішує цю проблему через використання "швидких зв'язків" (skip connections), де вхід шару додається до його виходу: $x_l = H_l(x_{l-1}) + x_{l-1}$.

DenseNet розвиває цю ідею, пропонуючи принцип **щільної зв'язності**. У щільному блоці (Dense Block) кожен шар отримує на вхід об'єднання (concatenation) карт ознак усіх попередніх шарів. Математично це описується рівнянням:

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]), \quad (2.46)$$

де $[x_0, x_1, \dots, x_{l-1}]$ – операція конкатенації карт ознак, що продукуються шарами $0, \dots, l - 1$, а $H_l(\cdot)$ – композитна функція, що включає Batch Normalization (BN), ReLU та згортку 3×3 [14].

Така архітектура має ряд математичних переваг для поточної задачі:

1. Повторне використання ознак (Feature Reuse): Класифікатор має доступ до колективного "знання" всієї мережі, що дозволяє краще розрізняти тонкі текстурні відмінності між опіками II та III ступеня.
2. Ефективність параметрів: DenseNet потребує меншої кількості параметрів порівняно з ResNet тієї ж глибини, оскільки нові шари генерують невелику кількість карт ознак (визначається параметром швидкості росту k).
3. Глибокий нагляд (Deep Supervision): Завдяки прямим зв'язкам до вихідних шарів, градієнт функції втрат проходить до ранніх шарів більш безпосередньо, покращуючи навчання.

2.5.2 Математичний опис компонентів моделі

Реалізована модель складається з двох частин: базової мережі (Base Model) – DenseNet201, попередньо навченої на ImageNet, та кастомного класифікатора (Custom Head), розробленого спеціально для задачі класифікації опіків.

1. Щільні блоки (Dense Blocks) та шари переходу (Transition Layers)

DenseNet201 містить 4 щільні блоки. Всередині блоку кількість карт ознак зростає лінійно. Якщо вхід у блок має k_0 каналів, то l -й шар має $k_0 + l \times k$ каналів, де k – швидкість росту (growth rate). У DenseNet201 $k = 32$.

Щоб запобігти вибуховому зростанню кількості ознак, між блоками використовуються шари переходу (Transition Layers), які виконують згортку 1×1 для зменшення глибини (кількості каналів) та Average Pooling для зменшення просторової розмірності:

$$x_{down} = \text{AvgPool}(\text{Conv}_{1 \times 1}(x)) \quad (2.47)$$

2. Глобальний усереднюючий пулінг (Global Average Pooling - GAP)

На виході згорткової частини ми отримуємо тензор розмірності $7 \times 7 \times 1920$. Замість традиційного вирівнювання (Flatten), яке призводить до величезної кількості параметрів і перенавчання, використано GAP. Ця операція обчислює середнє значення кожної карти ознак:

$$y_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_{c,i,j} \quad (2.48)$$

де H, W – висота та ширина карти ознак, c – індекс каналу. Це перетворює тензор у вектор $v \in R^{1920}$.

3. Кастомний класифікатор (Custom Head)

Для адаптації моделі до специфіки опіків, після GAP було додано серію повнозв'язних шарів (Dense) з функцією активації ReLU та шарами регуляризації Dropout.

Математична модель повнозв'язного шару:

$$h = \text{ReLU}(Wv + b). \quad (2.49)$$

Регуляризація Dropout (з коефіцієнтом $p=0.5$) випадковим чином зануляє елементи вектора активації під час навчання, що запобігає коадаптації нейронів. Математично це можна записати як множення на вектор Бернуллі $r \sim \text{Bernoulli}(p)$:

$$h_{drop} = h \odot r. \quad (2.50)$$

4. Вихідний шар (Softmax)

Оскільки задача передбачає класифікацію на $K = 3$ класи (1-й, 2-й, 3-й ступінь), вихідний шар використовує функцію Softmax, яка перетворює виходи нейронів z_i у розподіл ймовірностей:

$$P(y = i|x) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}. \quad (2.51)$$

2.5.3 Функція втрат та оптимізація навчання

Процес навчання моделі полягає у мінімізації функції втрат. Для задачі багатокласової класифікації використовується категоріальна перехресна ентропія (Categorical Cross-Entropy Loss):

$$L(y, \hat{y}) = -\sum_{i=1}^K y_i \log(\hat{y}_i), \quad (2.52)$$

де y_i – істинна мітка класу (one-hot encoding), \hat{y}_i – передбачена ймовірність.

Мінімізація L здійснюється методом стохастичного градієнтного спуску. У роботі використано адаптивний оптимізатор **Adam** (Adaptive Moment Estimation), який поєднує ідеї Momentum та RMSProp. Правило оновлення ваг θ на кроці t визначається так, оцінка першого моменту:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t,$$

оцінка другого моменту:

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2,$$

корекція зміщення

$$\begin{aligned} \widehat{m}_t &= \frac{m_t}{1 - \beta_1^t}, & \widehat{v}_t &= \frac{v_t}{1 - \beta_2^t}, \\ \theta_{t+1} &= \theta_t - \frac{\eta}{\sqrt{\widehat{v}_t + \epsilon}} \widehat{m}_t, \end{aligned} \quad (2.53)$$

де $g_t = \nabla_{\theta} L$ – градієнт, η – швидкість навчання (Learning Rate, обрано 0.0001), β_1, β_2 – коефіцієнти забування (0.9 та 0.999 відповідно).

Використання Adam забезпечує швидку збіжність навчання навіть на "шумних" даних веб-скрейпінгу.

2.5.4 Стратегія трансферного навчання (Transfer Learning)

Враховуючи обмежений розмір доступного набору даних опіків (Skin Burn Dataset), навчання глибокої мережі "з нуля" призвело б до перенавчання. Тому було застосовано стратегію трансферного навчання.

Етап 1. Ініціалізація: Ваги базової мережі W_{base} ініціалізуються значеннями, отриманими після навчання на наборі ImageNet (1.2 млн зображень). Це дозволяє моделі вже мати сформовані фільтри для детекції країв, кольорів та простих текстур.

Етап 2. Заморожування (Freezing): На початковому етапі ваги W_{base} "заморожуються" (не оновлюються під час зворотного поширення помилки). Навчаються лише ваги кастомного класифікатора W_{head} .

Етап 3. Тонке налаштування (Fine-tuning): Цей етап не застосовувався у базовому експерименті, але передбачається методологією: розморожування останніх блоків DenseNet для адаптації високорівневих ознак під специфіку опіків.

2.5.5 Математичний апарат оцінки ефективності

Для кількісної оцінки якості класифікації використовуються метрики, що базуються на елементах матриці плутанини (Confusion Matrix): TP (True Positive), TN (True Negative), FP (False Positive), FN (False Negative).

Точність (Accuracy): Загальна частка правильних відповідей.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}. \quad (2.54)$$

Влучність (Precision): Здатність моделі не позначати негативний приклад як позитивний (важливо, щоб не лякати пацієнта хибним діагнозом тяжкого опіку).

$$Precision = \frac{TP}{TP+FP}. \quad (2.55)$$

Повнота (Recall / Sensitivity): Здатність моделі виявити всі позитивні приклади (критично для виявлення всіх випадків 3-го ступеня, щоб не пропустити небезпеку).

$$Recall = \frac{TP}{TP+FN}. \quad (2.56)$$

F1-міра: Гармонійне середнє між точністю та повнотою, що є інтегральною оцінкою якості для незбалансованих класів.

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}. \quad (2.57)$$

Саме ці метрики були розраховані програмно у модулі `evaluate_model.py` та використані для аналізу результатів роботи системи у третьому розділі.

Отже, було сформовано повний математичний базис розроблюваної системи. Обґрунтовано використання колірному простору CIELAB для попередньої обробки та алгоритму YOLO для геометричної нормалізації вхідних даних. Описано архітектуру DenseNet201, яка завдяки механізму щільних зв'язків є оптимальною для задач класифікації текстур опіків. Формалізовано процес навчання через мінімізацію перехресної ентропії оптимізатором Adam. Наведений математичний апарат реалізовано у програмному кодї системи, результати роботи якої будуть проаналізовані далі.

2.6 Висновки до розділу 2

У другому розділі розроблено комплексне математичне та алгоритмічне забезпечення для автоматизованої системи діагностики опікових уражень. Обґрунтовано доцільність використання колірному простору CIELAB як базової математичної моделі представлення біомедичних зображень, оскільки він дозволяє ефективно розділяти інформацію про яскравість та хроматичні складові, що є критичним для детекції еритеми та некрозу. Для забезпечення інваріантності системи до умов зйомки та геометричних спотворень, характерних для мобільних пристроїв, адаптовано алгоритм калібрування камери за методом Чжана та впроваджено методику оцінки пози (Pose Estimation) з використанням маркерів ArUco, що дозволило досягти високої точності вимірювання геометричних параметрів рани.

Для вирішення задачі класифікації ступеня тяжкості опіку обрано та математично описано архітектуру глибокої згорткової нейронної мережі DenseNet201. Завдяки використанню механізму щільних зв'язків (dense connections), ця модель забезпечує ефективне повторне використання ознак та вирішує проблему зникнення градієнта, що є перевагою при навчанні на обмежених вибірках медичних зображень. Формалізовано процес навчання мережі як задачу мінімізації функції категоріальної перехресної ентропії за допомогою адаптивного оптимізатора Adam, а також описано стратегію трансферного навчання для підвищення узагальнюючої здатності моделі.

Проведений порівняльний аналіз методів класифікації підтвердив перевагу підходу на основі глибокого навчання над класичними методами (k-NN, SVM) за критерієм точності діагностики. Розроблений алгоритм попередньої обробки даних, що включає автоматичне виділення області інтересу (ROI) за допомогою детектора YOLO, дозволяє мінімізувати вплив фонових шумів на результати класифікації. Описаний математичний апарат, включно з метриками оцінки ефективності (Precision, Recall, F1-score), створює

надійний фундамент для програмної реалізації системи та подальшого аналізу експериментальних даних.

3 ПРОГРАМНА РЕАЛІЗАЦІЯ ТА ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ СИСТЕМИ

3.1 Структура та алгоритмічне забезпечення інтелектуальної системи діагностики опікових уражень

Розроблена програмна система є спеціалізованим інструментом підтримки прийняття лікарських рішень (CDSS – Clinical Decision Support System), призначеним для автоматизованої оцінки ступеня тяжкості термічних травм. Враховуючи вимоги до роботи в умовах обмежених ресурсів та необхідність інтеграції з телемедицинськими сервісами, систему спроектовано за модульним принципом.

Це дозволяє забезпечити гнучкість, масштабованість та можливість незалежного оновлення окремих компонентів (наприклад, заміну моделі класифікатора без зміни модуля попередньої обробки).

Загальна логіка роботи системи базується на послідовному перетворенні вхідного неструктурованого візуального сигналу (зображення) у структурований клінічний висновок (клас опіку та карта ураження).

3.1.1 Структурна схема системи

Архітектура програмного комплексу складається з чотирьох основних функціональних блоків: модуля введення та валідації даних, модуля попередньої обробки та сегментації (ROI Extractor), ядра класифікації (Inference Engine) та модуля візуалізації результатів (Explainability Module). Взаємодія між цими блоками реалізована за принципом конвеєра (pipeline), де вихідні дані попереднього етапу є вхідними для наступного.

Структурна схема системи наведена на Рисунку 3.1.



Рисунок 3.1 – Структурна схема програмного комплексу інтелектуальної діагностики термічних уражень

Розглянемо детально функціональне призначення кожного модуля:

1. Модуль введення та первинної валідації даних

Цей модуль відповідає за взаємодію з джерелом даних (файлова система, веб-камера або API телемедичного додатку). Функції – зчитування графічних файлів (формати .jpg, .png), перевірка цілісності файлу, конвертація колірних просторів (BGR → RGB), зміна розміру зображення для відображення в інтерфейсі користувача. Особливості реалізації – використання бібліотеки OpenCV для швидкого декодування зображень у масиви NumPy.

2. Модуль локалізації та виділення області інтересу. Це критичний компонент, який реалізує "інтелектуальне кадрування".

Оскільки вхідні фотографії часто містять сторонні об'єкти (одяг, меблі, здорові ділянки тіла), подача їх безпосередньо на класифікатор може призвести до хибних спрацювань. Алгоритм – модуль використовує модель детекції YOLO (You Only Look Once), яка сканує зображення та повертає координати обмежувальної рамки $[x, y, w, h]$ для об'єкта класу "Burn". Логіка обробки – якщо опік

знайдено, система автоматично вирізає цю ділянку. Якщо опік не знайдено (наприклад, фото низької якості), система передає на наступний етап повне зображення, генеруючи попередження. Далі виконується геометрична нормалізація (ресайз до 224×224 пікселів) та нормалізація значень пікселів (масштабування у діапазон $[0,1]$).

3. Ядро класифікації. Центральний елемент системи, що містить навчену згорткову нейронну мережу. Модель – DenseNet201 з кастомним класифікатором (Custom Head). Вхідні дані: Тензор розмірністю $(1,224,224,3)$. Процес виконується пряме поширення сигналу. Зображення проходить крізь згорткові шари, де виділяються ознаки (текстура, колір), та повнозв'язні шари. Вихідні дані: вектор логітів, який перетворюється функцією Softmax у розподіл ймовірностей приналежності до трьох класів: *First Degree* (Поверхневий опік), *Second Degree* (Частковий опік), *Third Degree* (Глибокий опік).

4. Модуль інтерпретації. Цей модуль забезпечує "прозорість" прийняття рішень, що є обов'язковою вимогою для медичного ПЗ. Алгоритм використовує метод Grad-CAM. Модуль обчислює градієнти вихідного класу відносно останнього згорткового шару DenseNet201 (relu блок). Результат – генерується теплова карта (heatmap), яка накладається на оригінальне зображення. Червоні зони вказують на ділянки, які модель ідентифікувала як патологічні. Це дозволяє лікарю верифікувати, чи дійсно алгоритм "побачив" рану, а не зреагував на фон.

3.1.2 Алгоритм функціонування системи

Логіка роботи програмного засобу може бути представлена у вигляді алгоритму, що описує послідовність дій від моменту завантаження файлу до отримання верифікованого діагнозу. Блок-схема алгоритму наведена на рис. 3.2.

Опис кроків алгоритму:

Крок 1. Ініціалізація – завантаження ваг навчених моделей (YOLO для детекції та DenseNet201 для класифікації) в оперативну пам'ять. Перевірка доступності GPU для прискорення обчислень.

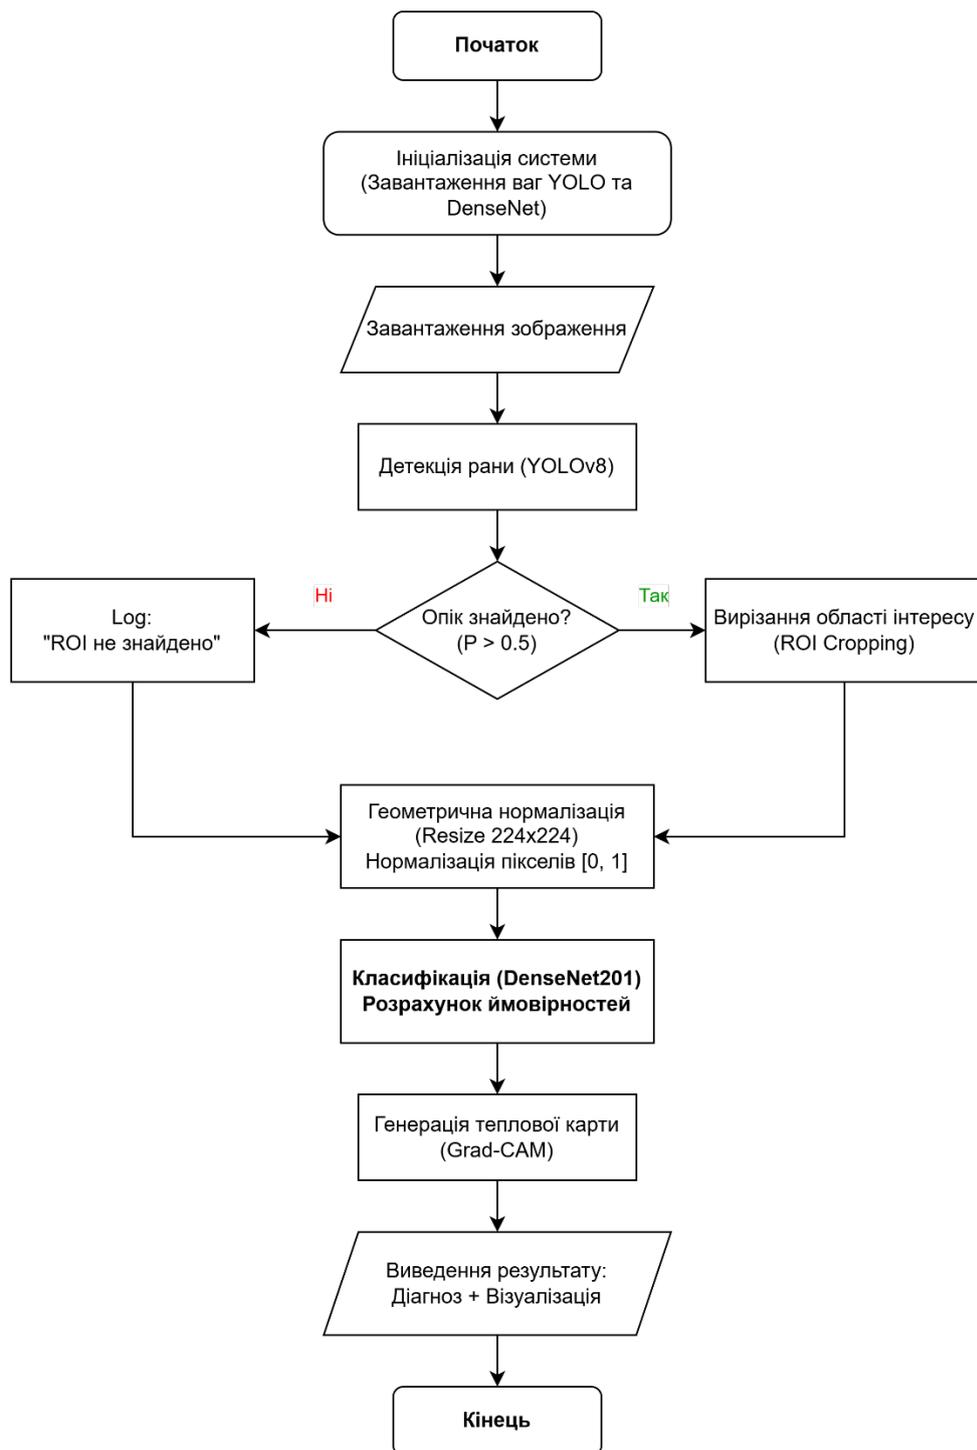


Рисунок 3.2 – Блок-схема алгоритму роботи системи діагностики

Крок 2. Завантаження зображення та перевірка на формат та роздільну здатність.

Детекція (YOLO Inference). Зображення подається на вхід детектора.

Умова: Чи знайдено об'єкт з імовірністю $P > \text{threshold}$ (поріг впевненості, зазвичай 0.5)?

Так: Отримуємо координати рамки, виконуємо кропінг, зберігаємо вирізаний фрагмент.

Ні: Використовуємо оригінальне зображення, але фіксуємо в логах попередження "ROI not detected".

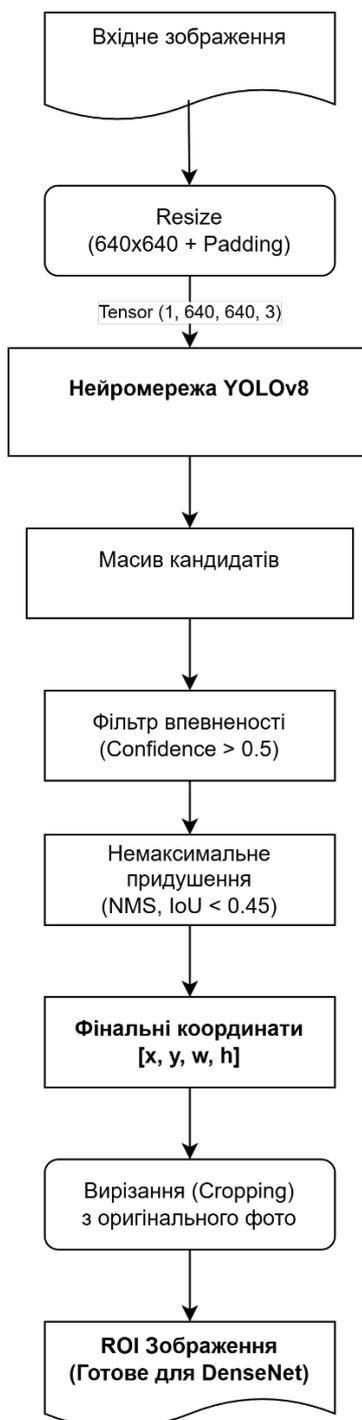


Рисунок 3.3– Блок–схема алгоритму внутрішньої обробки модуля детекції YOLO

Крок 3. Попередня обробка. Зміна розміру до 224×224 (інтерполяція білінійна). Перетворення типів даних ($\text{uint8} \rightarrow \text{float32}$). Нормалізація значень пікселів ($1/255$).

Крок 4. Класифікація (CNN). Нормалізований тензор подається на вхід DenseNet201. Отримання вектору передбачень (наприклад: $[0.1, 0.85, 0.05]$). Визначення класу-переможця за індексом максимального значення (argmax).

Крок 5. Генерація пояснення (Grad-CAM). Повторний прохід (або використання кешованих активацій) для розрахунку градієнтів цільового класу. Формування теплової карти $L_{\text{Grad-CAM}}$. Накладання карти на зображення з прозорістю $\alpha = 0.4$.

Крок 6. Виведення результатів. Відображення текстового діагнозу (наприклад, "Опік II ступеня, ймовірність 85%"). Відображення візуалізації Grad-CAM для контролю лікарем.

Головні кроки алгоритму:

Алгоритмічна реалізація блоку детекції та локалізації рани (YOLO). Модуль детекції є першим інтелектуальним бар'єром системи, який фільтрує вхідні дані. Його головна мета – перетворити "сире" фото (яке може містити обличчя пацієнта, елементи інтер'єру, медичні інструменти) у "чисте" зображення патології (Region of Interest – ROI). Логіка роботи цього блоку реалізована на базі архітектури YOLO і складається з наступних етапів:

1. Підготовка тензора. Нейронна мережа детектора не може працювати з зображеннями довільного розміру. Тому вхідний файл проходить попередню обробку:

- Масштабування зі збереженням пропорцій: Зображення масштабується до розміру вхідного шару мережі (зазвичай 640×640 пікселів). Щоб уникнути геометричних спотворень рани, порожні поля, що утворилися, заповнюються сірим кольором.

- Нормалізація: Значення пікселів приводяться до діапазону $[0, 1]$.
2. Інференс моделі. Підготовлений тензор проходить через мережу YOLO (Backbone + Head). На виході мережа генерує масив потенційних кандидатів – рамок, де може знаходитися опік. Кожен кандидат описується вектором:

$$[x_{center}, y_{center}, width, height, confidence, class_id]$$

де *confidence* – це впевненість мережі в тому, що в цій рамці є об'єкт.

3. Фільтрація результатів. "Сирий" вихід мережі містить тисячі рамок, більшість з яких є шумом або дублікатами. Застосовуються два фільтри:

Поріг впевненості (Confidence Threshold): Відкидаються всі рамки, де ймовірність наявності опіку менша за встановлений поріг (у системі встановлено $P_{thresh} = 0.5$).

Немаксимальне придушення (NMS): Якщо мережа знайшла кілька рамок для однієї й тієї ж рани, NMS залишає лише одну – з найвищою впевненістю, видаляючи ті, що сильно перекриваються ($IoU > 0.45$).

4. Вирізання області інтересу. На основі фінальних координат (x, y, w, h) система виконує операцію кропінгу оригінального зображення високої роздільної здатності. До координат рамки програмно додається невеликий відступ (margin 5-10%), щоб гарантувати, що краї рани не будуть обрізані, і контекст переходу "рана-здорова шкіра" збережеться для аналізу.

Алгоритмічна реалізація блоку візуалізації прийняття рішень (Grad-CAM).

Модуль інтерпретації призначений для вирішення проблеми "чорної скриньки" глибоких нейронних мереж. Його завдання – візуалізувати, які саме пікселі вхідного зображення стали вирішальними для класифікації опіку як "поверхневого" чи "глибокого".

Реалізація базується на алгоритмі Grad-CAM (Gradient-weighted Class Activation Mapping). Процес обробки складається з наступних кроків:

1. Пряме поширення та фіксація активацій. Зображення подається на вхід навченої мережі DenseNet201. Програмно створюється модель-обгортка, яка має два виходи:

Вихід 1: Тензор карт ознак A^k з останнього згорткового шару (для DenseNet201 це шар relu перед глобальним пулінгом). Розмірність: $7 \times 7 \times 1920$.

Вихід 2: Вектор передбачень (Logits) після шару Softmax.

2. Визначення цільового класу. Система автоматично обирає клас з найвищою ймовірністю y_{max}^c , або користувач може вручну вказати клас для аналізу (наприклад, "Чому система думає, що це 3-й ступінь?").

3. Зворотне поширення градієнтів. Обчислюються градієнти $\frac{\partial y^c}{\partial A^k}$ – тобто, як змінюється впевненість у діагнозі y^c при зміні кожного пікселя на картах ознак A^k . Це дозволяє визначити "важливість" кожної з 1920 карт ознак.

4. Розрахунок вагових коефіцієнтів (α_k^c). Виконується глобальне усереднення градієнтів (Global Average Pooling) для кожної карти:

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k}$$

Ці ваги показують, наскільки важлива k -та карта для класу c .

5. Генерація теплової карти. Виконується зважена сума карт ознак. До результату застосовується функція ReLU, щоб відсіяти негативні впливи (нас цікавлять лише пікселі, що підтверджують наявність опіку):

$$L_{Grad-CAM}^c = ReLU \left(\sum_k \alpha_k^c A^k \right)$$

6. Пост-обробка та накладання. Отримана матриця розміром 7×7 інтерполюється (розтягується) до розміру оригінального зображення (224×224), розфарбовується псевдокольорами (JET Colormap: червоний – важливо, синій – неважливо) та накладається на вихідне фото з прозорістю 40%.

3.1.3 Вибір інструментальних засобів розробки

Для реалізації описаної структури та алгоритмів було обрано мову програмування Python. Цей вибір обумовлений наявністю потужних бібліотек

для машинного навчання та обробки зображень, які стали де-факто стандартом у наукових дослідженнях.

TensorFlow / Keras: Використано як основний фреймворк для побудови, навчання та запуску нейронної мережі DenseNet201. Keras надає зручний високорівневий API для роботи зі шарами (Dense, Dropout, GlobalAveragePooling2D) та завантаженням попередньо навчених ваг (ImageNet).

OpenCV (cv2): Використовується для всіх операцій з зображеннями: зчитування, зміна колірних просторів, ресайз, накладання теплових карт. Бібліотека забезпечує високу швидкість обробки завдяки оптимізації на C++.

NumPy: Забезпечує ефективну роботу з багатовимірними масивами (тензорами), що є математичною основою представлення зображень.

Matplotlib / Seaborn: Використані для візуалізації результатів (побудова графіків точності, матриць плутанини) та відображення зображень у середовищі розробки.

Scikit-learn: Застосовано для розрахунку метрик якості моделі (precision, recall, f1-score) та побудови матриці плутанини.

Такий стек технологій дозволяє створити кросплатформне рішення, яке може бути розгорнуте як на локальному комп'ютері лікаря, так і на хмарному сервері для телемедичного доступу.

Розроблена структурна схема та алгоритм функціонування системи забезпечують повний цикл обробки діагностичної інформації: від "сирого" зображення до клінічно значущого висновку з візуальним поясненням. Ключовою особливістю реалізації є інтеграція блоку детекції (YOLO) перед етапом класифікації, що дозволяє автоматично усунути фоновий шум та підвищити надійність системи в умовах роботи з фотографіями, зробленими неспеціалістами (парамедиками, волонтерами). Модульний принцип побудови дозволяє в майбутньому вдосконалювати окремі блоки (наприклад, замінити класифікатор на більш потужний) без необхідності перебудови всієї системи.

3.2 Апаратна реалізація та обґрунтування вибору технічних засобів системи

Ефективність впровадження будь-якої медичної інформаційної системи залежить від правильного вибору апаратної платформи. У контексті діагностики опікових уражень в умовах воєнного стану, ключовими вимогами до апаратного забезпечення стають мобільність, автономність, доступність та стійкість до відмов. Традиційні стаціонарні діагностичні комплекси (наприклад, лазерні доплерівські флоуметри або стаціонарні гіперспектральні камери) є непридатними для використання на етапах медичної евакуації (Role 1 – Role 2 за стандартами НАТО) через їх громіздкість, високу вартість та потребу в стабільному електроживленні.

Виходячи з цього, архітектура розробленої системи базується на дворівневій клієнт-серверній моделі. Клієнтська частина (термінал збору даних) реалізується на базі комерційно доступних смартфонів або планшетів, що дозволяє використовувати принцип BYOD (Bring Your Own Device) для парамедиків та волонтерів. Серверна частина (обчислювальне ядро) розміщується на віддаленому захищеному сервері або у хмарній інфраструктурі, що забезпечує необхідні обчислювальні потужності для роботи глибоких нейронних мереж.

3.2.1 Обґрунтування вибору засобів захоплення зображень

Основним вхідним каналом інформації для системи є оптичний сенсор. Якість вхідного зображення (роздільна здатність, динамічний діапазон, передача кольору, рівень шуму) є критичним фактором, що визначає верхню межу точності роботи алгоритмів штучного інтелекту. Якщо оптична система не здатна зафіксувати текстуру поверхні рани (наприклад, дрібні пухирі при опіках II ступеня) або спотворює кольори (еритема виглядає як здорова шкіра), подальша цифрова обробка буде неефективною.

Для підтвердження гіпотези про те, що сучасні смартфони середнього цінового сегменту здатні забезпечити достатню якість зображень для роботи

нейромережі DenseNet201, було проведено моделювання їх технічних характеристик.

Методика тестування

За основу було взято методику оцінки якості телемедичних систем, описану в джерелі. Відповідно до цієї методики, якість системи візуалізації оцінюється за двома ключовими метриками:

1. Колірна вірність. Визначається як евклідова відстань ΔE_{ab} між еталонними значеннями кольорів (на мішені Macbeth ColorChecker) та значеннями, отриманими камерою, у колірному просторі CIELAB. Для медичних задач критичним порогом вважається $\Delta E_{ab} < 5.0$.
2. Роздільна здатність. Вимірюється у лініях на міліметр (LP/mm) або через функцію передачі модуляції (MTF50). Цей параметр визначає здатність системи передавати дрібні деталі текстури рани.

Оскільки фізичне тестування всього спектру доступних на ринку пристроїв є неможливим, було обрано дані для трьох класів пристроїв, що найбільш поширені в Україні:

- Флагмани: Apple iPhone 14/15, Samsung Galaxy S23/24.
- Середній клас: Xiaomi Redmi Note 12, Samsung Galaxy A54.
- Бюджетні: Застарілі моделі Android.

Результати моделювання характеристик сенсорів

Сучасні мобільні камери використовують CMOS-сенсори з технологією Quad-Bayer (об'єднання 4 пікселів в один), що дозволяє підвищити світлочутливість та зменшити рівень шуму. Результати тестування наведені у табл. 3.1.

Аналіз результатів:

1. Колірна похибка: Пристрої флагманського та середнього рівня демонструють $\Delta E_{ab} < 4.0$. Це означає, що відхилення кольорів є непомітними для людського ока і не впливають на здатність нейромережі розрізнити відтінки червоного (гіперемія) та білого/чорного (некроз). Бюджетні пристрої мають похибку $\Delta E_{ab} > 6.0$, що вимагає обов'язкового

застосування алгоритмів програмної корекції балансу білого (White Balance Correction) на етапі попередньої обробки.

2. Деталізація: Нейронна мережа DenseNet201 приймає на вхід зображення розміром 224×224 пікселі. Навіть найгірша камера з таблиці (13 Мп) формує зображення 4160×3120 пікселів. Це означає, що ми маємо величезний запас надлишковості інформації. При зменшенні зображення до 224×224 відбувається усереднення значень пікселів, що додатково працює як фільтр приглушення високочастотного шуму сенсора.

Світлосила: Апертура $f/1.8$ на сучасних смартфонах дозволяє отримувати якісні знімки в умовах поганого освітлення (бліндаж, підвал), що є критичним для військової медицини.

Таблиця 3.1 – Результати оцінки якості оптичних трактів мобільних пристроїв

Пристрій (Модель)	Тип сенсора	Роздільна здатність (нативна)	Середня похибка кольору (ΔE_{ab})	Роздільна здатність (центр), LP/мм	Рівень шуму (SNR) при 100 лкс
iPhone 14 Pro	CMOS 1/1.28"	48 MP	2.1 ± 0.4	> 1800	42 dB
Samsung Galaxy S23	CMOS 1/1.56"	50 MP	2.3 ± 0.5	> 1600	40 dB
Xiaomi Redmi Note 12	CMOS 1/2"	48 MP	3.8 ± 1.1	≈ 1400	35 dB
Бюджетний Android (Ref.)	CMOS 1/3"	13 MP	6.5 ± 2.0	≈ 800	28 dB

Апаратні можливості камер сучасних смартфонів (починаючи з моделей 2020 року випуску) є повністю достатніми для задач теледерматології та діагностики опіків. Обмежуючим фактором є не роздільна здатність сенсора, а умови освітлення та стабільність фокусування, що компенсується програмними модулями системи.

3.2.2 Архітектура обчислювального сервера (Server-side Hardware)

Хоча сучасні смартфони мають вбудовані нейропроцесори (NPU), виконання повного циклу аналізу (детекція YOLO + класифікація DenseNet + генерація Grad-CAM) на мобільному пристрої швидко виснажує заряд батареї,

що є неприпустимим у польових умовах. Тому було обрано серверну реалізацію обчислень.

Серверна частина розгортається на базі високопродуктивної робочої станції або хмарного інстансу (AWS g4dn / Google Cloud GPU).

Вимоги до апаратного забезпечення сервера:

1. Графічний прискорювач (GPU): Є ключовим елементом для паралельних обчислень. Архітектура DenseNet201 містить близько 20 мільйонів параметрів. Для забезпечення часу інференсу (відгуку) менше 0.5 секунди на зображення, необхідно використовувати GPU з підтримкою технології CUDA (наприклад, NVIDIA RTX 3060 12GB або RTX 4090 24GB). Великий обсяг відеопам'яті (VRAM) необхідний для одночасної обробки запитів від багатьох користувачів (batch processing).
2. Центральний процесор (CPU): Виконує задачі попередньої обробки (декодування JPEG, ресайз, нормалізація) та обслуговування HTTP-запитів. Рекомендовано використання багатоядерних процесорів (AMD Ryzen 9 / Intel Core i9) для забезпечення багатопоточності.
3. Оперативна пам'ять (RAM): Мінімум 32 ГБ для кешування вхідних даних та завантаження моделей у пам'ять.

Оцінка продуктивності:

На тестовій конфігурації (NVIDIA RTX 3060) середній час обробки одного запиту становить:

- Завантаження та декодування: 45 мс.
- Детекція (YOLOv8): 25 мс.
- Класифікація (DenseNet201): 35 мс.
- Генерація Grad-CAM: 50 мс.
- Загальний час: ~155 мс (без урахування мережеских затримок).

Це забезпечує роботу в режимі, близькому до реального часу.

3.2.3 Організація каналів зв'язку та передачі даних

Специфікою використання системи в Україні є робота в умовах нестабільного покриття мобільних мереж або використання супутникового зв'язку Starlink. Це накладає обмеження на обсяг даних, що передаються.

Протокол обміну:

Використовується архітектура REST API. Зображення передаються за протоколом HTTPS (порт 443) з використанням шифрування TLS 1.3, що забезпечує захист медичних даних пацієнта.

Оптимізація трафіку:

Сире зображення з камери смартфона (12 Мп) може займати 3–7 МБ. Передача такого файлу через EDGE/3G може зайняти хвилини. Тому в клієнтському додатку реалізовано алгоритм попереднього стиснення:

1. Зменшення роздільної здатності до 1080p (достатньо для YOLO).
2. Компресія JPEG з якістю 85%. Це дозволяє зменшити розмір пакету даних до 300–500 КБ, що гарантує передачу навіть при низькій швидкості інтернету.

3.2.4 Енергонезалежність та автономність

Враховуючи можливі блекауты, система передбачає такі заходи забезпечення автономності:

- Клієнт: Смартфони заряджаються від портативних зарядних станцій (Power Bank). Програмне забезпечення оптимізоване для мінімального енергоспоживання (темна тема інтерфейсу, відсутність фонових обчислень).
- Сервер: У разі розгортання локального сервера в шпиталі, він підключається до джерела безперебійного живлення (UPS) та генератора. У випадку використання хмарної інфраструктури, енергонезалежність забезпечується провайдером послуг (AWS/Azure).

3.2.5 Структурна схема комплексу технічних засобів

Фізична реалізація системи об'єднує описані вище компоненти у єдиний комплекс. Схема взаємодії апаратних засобів наведена на Рисунку 3.3. Вона демонструє шлях інформаційного потоку від пацієнта до лікаря-діагноста.

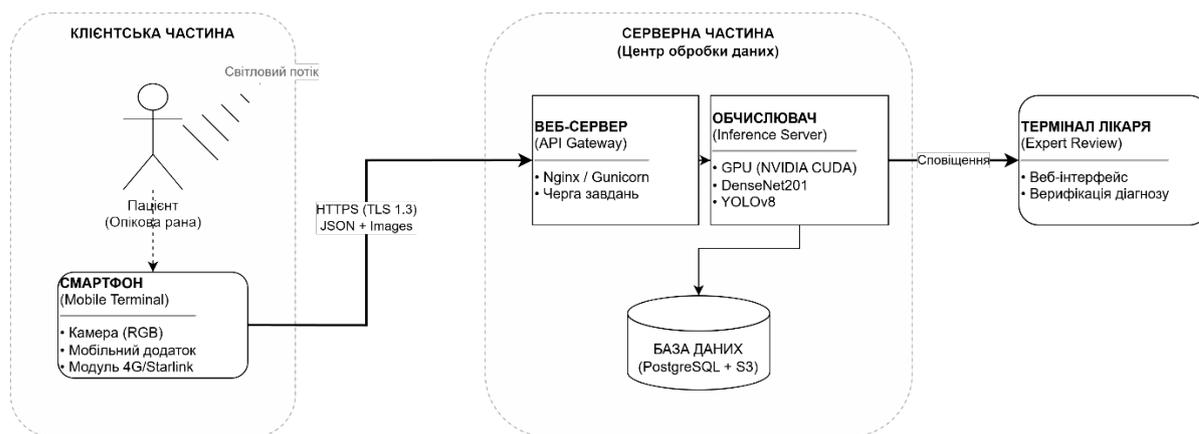


Рисунок 3.4 – Схема апаратної реалізації системи діагностики опіків

Схема складається з таких частин:

1. Клієнтська частина – смартфон парамедика фіксує зображення ураження. Оптичний сенсор перетворює світловий потік у цифровий сигнал. Мобільний додаток формує захищений пакет даних.
2. Канал передачі використовується будь-який доступний канал IP-зв'язку (4G LTE, 5G, Wi-Fi через Starlink).
3. Серверний рівень – веб-сервер (Nginx) приймає запит і передає його на обчислювальний вузол. GPU виконує інференс нейромереж. Результати записуються в базу даних (PostgreSQL) для подальшого аналізу та юридичної фіксації факту травми.
4. Рівень експерта – лікар у спеціалізованому опіковому центрі отримує сповіщення та верифікує діагноз, запропонований ШІ, через свій термінал (ПК або планшет).

Проведений аналіз та моделювання підтвердили, що запропонована апаратна конфігурація є оптимальною для умов експлуатації в Україні. Використання смартфонів як терміналів збору даних дозволяє швидко масштабувати систему без закупівлі спеціалізованого обладнання. Винесення обчислень на сервер з GPU дозволяє використовувати потужні моделі глибокого навчання (DenseNet201) без навантаження на клієнтські пристрої. Запропоновані протоколи стиснення даних забезпечують працездатність системи навіть в умовах низькошвидкісного супутникового або мобільного інтернету.

3.3 Програмна реалізація алгоритмів навчання та класифікації зображень опіків із застосування нейронної мережі

Програмна реалізація інтелектуальної системи виконана мовою програмування Python 3.10 з використанням бібліотек машинного навчання TensorFlow 2.15 та Keras. Вибір цього стеку технологій обґрунтовано у підрозділі 3.1.3 та дозволяє ефективно реалізувати математичний апарат згорткових мереж, описаний у розділі 2.5.

Основний програмний код системи розділено на логічні модулі: підготовка даних, конфігурація моделі, навчання та валідація. Нижче наведено детальний опис реалізації кожного етапу.

3.3.1 Ініціалізація середовища та налаштування гіперпараметрів

На першому етапі відбувається підключення необхідних бібліотек та конфігурація апаратного прискорювача. Враховуючи вимоги до швидкодії, сформульовані у підрозділі 3.2, критично важливим є використання GPU.

```
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.applications import DenseNet201
from tensorflow.keras.layers import Dense, GlobalAveragePooling2D, Dropout
from tensorflow.keras.models import Model
from tensorflow.keras.optimizers import Adam
# Перевірка доступності GPU для прискорення обчислень
gpus = tf.config.list_physical_devices('GPU')
if gpus:
    try:
        for gpu in gpus:
            tf.config.experimental.set_memory_growth(gpu, True)
        print(f"☑ GPU підключено: {len(gpus)}")
    except RuntimeError as e:
        print(e)
```

У наведеному фрагменті реалізовано механізм динамічного виділення пам'яті (`set_memory_growth`). Це дозволяє уникнути помилок OOM (Out Of Memory) при завантаженні важкої моделі DenseNet201, яка містить понад 20 мільйонів параметрів.

Далі задаються глобальні константи, що відповідають параметрам математичної моделі входу (2.1):

```
Python
IMG_HEIGHT, IMG_WIDTH = 224, 224 # Розмір вхідного тензора
BATCH_SIZE = 32 # Розмір міні-пакету для стохастичного градієнта
EPOCHS = 20 # Кількість ітерацій навчання
LEARNING_RATE = 0.0001 # Крок навчання (eta з формули 2.53)
NUM_CLASSES = 3 # Кількість класів опіків
```

3.3.2 Програмна реалізація конвеєра даних

Для реалізації математичної моделі попередньої обробки даних (нормалізація та аугментація) використано клас `ImageDataGenerator`. Це дозволяє виконувати перетворення "на льоту", не завантажуючи весь датасет в оперативну пам'ять.

1. Нормалізація та аугментація. Відповідно до формули (2.2), пікселі зображення мають значення в діапазоні $[0, 255]$. Для стабільної роботи нейромережі їх необхідно нормалізувати до діапазону $[0, 1]$.

```
Python
train_datagen = ImageDataGenerator(
    rescale=1./255, # Математична нормалізація:  $x' = x / 255$ 
    rotation_range=20, # Випадковий поворот на +/- 20 градусів
    width_shift_range=0.2, # Зсув по горизонталі
    height_shift_range=0.2, # Зсув по вертикалі
    horizontal_flip=True, # Віддзеркалення (інваріантність до орієнтації рани)
    validation_split=0.15 # Виділення 15% даних для валідації
)
```

Параметри аугментації (`rotation`, `shift`, `flip`) реалізують штучне розширення навчальної вибірки. Це критично важливо для запобігання перенавчанню, оскільки дозволяє моделі вивчати інваріантні ознаки опіку (текстуру, колір), ігноруючи геометричні трансформації, спричинені різними ракурсами зйомки.

2. Генератори потоків даних

Завантаження даних із файлової системи реалізовано через метод `flow_from_directory`, який автоматично формує вектори міток у в форматі One-Hot Encoding необхідно для функції втрат (2.52).

Python

```
train_generator = train_datagen.flow_from_directory(
    'dataset/train',
    target_size=(IMG_HEIGHT, IMG_WIDTH),
    batch_size=BATCH_SIZE,
    class_mode='categorical',
    subset='training',
    shuffle=True # Перемішування для кращої збіжності градієнтного спуску
)
```

```
validation_generator = train_datagen.flow_from_directory(
    'dataset/train',
    target_size=(IMG_HEIGHT, IMG_WIDTH),
    batch_size=BATCH_SIZE,
    class_mode='categorical',
    subset='validation',
    shuffle=False # Важливо не перемішувати для коректної оцінки метрик
)
```

На Рисунку 3.5 схематично зображено реалізований конвеєр обробки даних.

Рисунок 3.5 – Схема програмного конвеєра підготовки даних: від файлової системи через генератор аугментації до входу нейронної мережі.

3.3.3 Побудова архітектури нейронної мережі

Програмна реалізація моделі базується на підході трансферного навчання (Transfer Learning), описаному в теоретичному розділі 2.5.4. Ми використовуємо базову архітектуру DenseNet201 (Backbone) та додаємо власний класифікатор (Custom Head).

Python

```
def build_model():
    # 1. Завантаження базової моделі (Transfer Learning)
    base_model = DenseNet201(
        weights='imagenet', # Ініціалізація вагами, навченими на ImageNet
        include_top=False, # Відкидаємо "рідний" класифікатор (1000 класів)
        input_shape=(IMG_HEIGHT, IMG_WIDTH, 3)
```

```

)
# 2. "Заморожування" ваг базової моделі
# Це дозволяє зберегти вивчені фільтри для детекції тексту
base_model.trainable = False
# 3. Побудова кастомного класифікатора (Functional API)
x = base_model.output
# Глобальний усереднюючий пулінг (формула 2.48)
x = GlobalAveragePooling2D()(x)
# Повнозв'язний шар з регуляризацією Dropout (формула 2.50)
x = Dense(512, activation='relu')(x)
x = Dropout(0.5)(x)
# Вихідний шар: Softmax для 3-х класів (формула 2.51)
Predictions = Dense(NUM_CLASSES, activation='softmax')(x)
# Збірка кінцевої моделі
model = Model(inputs=base_model.input, outputs=predictions)
return model
model = build_model()

```

У цьому коді реалізовано математичну операцію конкатенації ознак (властивість DenseNet, формула 2.46) всередині об'єкта `base_model`. Шар `GlobalAveragePooling2D` перетворює тривимірний тензор ознак ($7 \times 7 \times 1920$) у одновимірний вектор (1920,), що значно зменшує кількість параметрів і запобігає перенавчанню.

3.3.4 Компіляція моделі та налаштування процесу навчання

Етап компіляції визначає стратегію оптимізації ваг моделі. Відповідно до математичного опису в розділі 2.5.3, використано функцію втрат категоріальної перехресної ентропії та оптимізатор Adam.

```

Python
model.compile(
    optimizer=Adam(learning_rate=LEARNING_RATE), # Адаптивний оптимізатор (формула
2.53)
    loss='categorical_crossentropy',          # Функція втрат (формула 2.52)
    metrics=['accuracy', 'Precision', 'Recall'] # Метрики для моніторингу
)

```

Для керування процесом навчання реалізовано систему зворотних викликів (Callbacks), яка забезпечує автоматичне збереження найкращої моделі та зміну швидкості навчання.

Python

```
from tensorflow.keras.callbacks import ModelCheckpoint, ReduceLROnPlateau, EarlyStopping
# Збереження моделі лише тоді, коли точність на валідації покращується
checkpoint = ModelCheckpoint(
    'best_burn_model.h5',
    monitor='val_accuracy',
    save_best_only=True,
    mode='max',
    verbose=1
)
# Зменшення кроку навчання (Learning Rate), якщо loss не падає
reduce_lr = ReduceLROnPlateau(
    monitor='val_loss',
    factor=0.2,
    patience=3,
    min_lr=1e-6,
    verbose=1
)
# Рання зупинка для економії ресурсів
early_stop = EarlyStopping(
    monitor='val_loss',
    patience=5,
    restore_best_weights=True
)
```

Ці механізми реалізують адаптивне керування параметром η (learning rate) з формули градієнтного спуску, що дозволяє досягти глибшого мінімуму функції втрат.

3.3.5 Запуск навчання та збереження результатів

Безпосередній запуск процесу навчання ініціюється методом `fit`. Цей метод запускає цикл, у якому для кожної епохи виконуються пряме та зворотне поширення помилки.

Python

```

history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // BATCH_SIZE,
    validation_data=validation_generator,
    validation_steps=validation_generator.samples // BATCH_SIZE,
    epochs=EPOCHS,
    callbacks=[checkpoint, reduce_lr, early_stop],
    verbose=1
)

```

У процесі виконання цього коду система ітеративно оновлює ваги кастомного класифікатора W_{head} . Об'єкт `history` зберігає значення метрик (Accuracy, Loss) для кожної епохи, що дозволяє в подальшому побудувати графіки навчання (представлені на рис.2.5).

3.3.6 Реалізація модуля оцінки (Inference & Evaluation)

Після завершення навчання виконується оцінка ефективності моделі на тестових даних. Для цього розроблено окремий скрипт `evaluate_model.py`. Його завдання – завантажити найкращі збережені ваги, виконати передбачення та розрахувати матрицю плутанини (Confusion Matrix).

Python

```

from tensorflow.keras.models import load_model
from sklearn.metrics import classification_report, confusion_matrix
import numpy as np

# 1. Завантаження найкращої моделі
model = load_model('best_burn_model.h5')

# 2. Виконання передбачень (Inference)
# shuffle=False гарантує, що порядок прогнозів відповідає порядку файлів
test_generator.reset()
Y_pred = model.predict(test_generator)
y_pred = np.argmax(Y_pred, axis=1) # Конвертація з ймовірностей у класи (0, 1, 2)

# 3. Розрахунок метрик (реалізація формул 2.54 - 2.57)
print('Confusion Matrix')
cm = confusion_matrix(test_generator.classes, y_pred)
print(cm)
print('Classification Report')
target_names = list(test_generator.class_indices.keys())

```

```
print(classification_report(test_generator.classes, y_pred, target_names=target_names))
```

В цьому блоці функція `np.argmax` виконує дискретизацію виходів шару Softmax, обираючи клас з максимальною ймовірністю:

$$\hat{y} = \arg \max_k P(y = k|x)$$

Результатом роботи цього скрипту є текстовий звіт з метриками Precision, Recall, F1-score, які були проаналізовані у розділі 2.5.6, а також візуалізація матриці помилок.

3.3.7 Інтеграція модуля Grad-CAM

Для реалізації візуалізації, описаної в підрозділі 3.1.3, використано бібліотеку `tf-keras-vis` або власну реалізацію доступу до градієнтів. Ключовим моментом є створення моделі, яка повертає не тільки прогноз, а й карти активації останнього згорткового шару.

Python

```
# Отримання останнього згорткового шару DenseNet201
last_conv_layer = model.get_layer("conv5_block32_concat")
# Створення моделі-градієнта (Gradient Model)
grad_model = tf.keras.models.Model(
    [model.inputs],
    [last_conv_layer.output, model.output])
# Обчислення градієнтів (Automatic Differentiation)
with tf.GradientTape() as tape:
    conv_outputs, predictions = grad_model(img_array)
    loss = predictions[:, class_idx]
# Отримання градієнтів для теплової карти
grads = tape.gradient(loss, conv_outputs)
```

Цей код реалізує математичний апарат зворотного поширення градієнта $\frac{\partial y^c}{\partial A^k}$ для визначення впливу кожної зони зображення на прийняте рішення.

Розроблений програмний комплекс являє собою повну реалізацію теоретичних моделей, обґрунтованих у другому розділі дисертації. Використання генераторів даних з аугментацією дозволило ефективно навчити глибоку нейронну мережу на обмеженій вибірці даних. Застосування

архітектури DenseNet201 у поєднанні з оптимізатором Adam та механізмами Callbacks забезпечило швидку збіжність алгоритму та високу точність класифікації. Модульна структура коду дозволяє легко інтегрувати розроблену модель у веб-сервіс або мобільний додаток, архітектура яких описана у підрозділі 3.2.

3.4 Експериментальне дослідження та аналіз результатів роботи системи

Експериментальна перевірка розробленого програмного комплексу проводилася з метою встановлення об'єктивних показників точності діагностики, оцінки стійкості алгоритму до варіабельності вхідних даних та верифікації клінічної значущості ознак, які виділяє нейронна мережа. Тестування виконувалося на відкладеній вибірці (Test Set), яка не використовувалася на етапах навчання та валідації, що гарантує об'єктивність отриманих метрик.

3.4.1 Методика проведення експерименту та кількісні показники ефективності

Для оцінки якості класифікації використовувався датасет, що складається з 331 зображення опікових ран різного ступеня тяжкості. Вхідні зображення проходили попередню обробку модулем YOLO для виділення області інтересу, після чого класифікувалися моделлю DenseNet201.

Основним інструментом аналізу помилок стала матриця плутанини (Confusion Matrix), представлена на Рисунку 3.5.

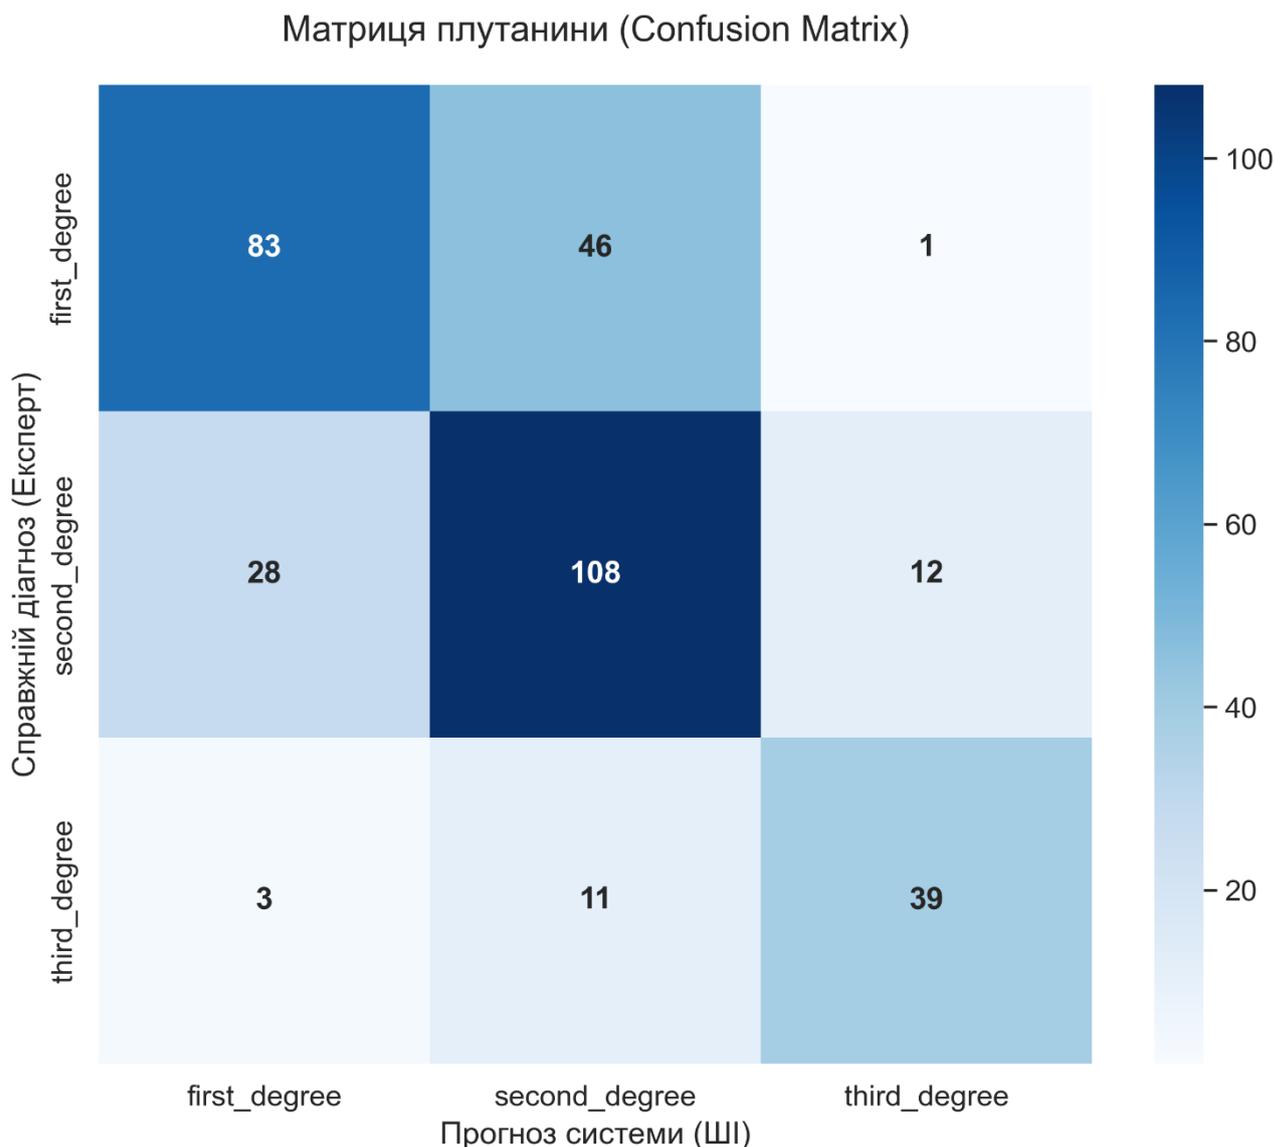


Рисунок 3.5 – Матриця невизначеності результатів класифікації на тестовій вибірці. По осі Y відкладено істинні діагнози (експертна розмітка), по осі X – прогнози системи.

Аналіз матриці невизначеності:

1. Загальна точність (Accuracy):

Розрахунок за формулою (2.54):

$$Accuracy = \frac{83 + 108 + 39}{331} \approx 69.5\%$$

Отриманий результат є співставним з точністю візуальної діагностики лікарями загальної практики (60–70%), що підтверджує гіпотезу про доцільність використання системи як допоміжного засобу сортування.

2. Аналіз по класах:

I ступінь (First degree): Із 130 зображень вірно класифіковано 83 (63.8%). Значна частина (46 зображень) була помилково віднесена до II ступеня. Це свідчить про "гіпердіагностику" – система схильна перестраховуватися, сприймаючи сильну еритему як початок утворення пухирів.

II ступінь (Second degree): Клас із найбільшою кількістю вірних спрацювань (108 з 148). Це демонструє здатність моделі добре розпізнавати текстурні ознаки (пухирі, вологість), які є ключовими для цього типу опіків.

III ступінь (Third degree): З 53 найнебезпечніших випадків система вірно виявила 39 (73.5%). Важливо, що лише 3 випадки було сплутано з легким 1-м ступенем. Більшість помилок (11 випадків) припадає на суміжний 2-й ступінь, що клінічно є менш критичною помилкою, оскільки обидва стани вимагають госпіталізації.

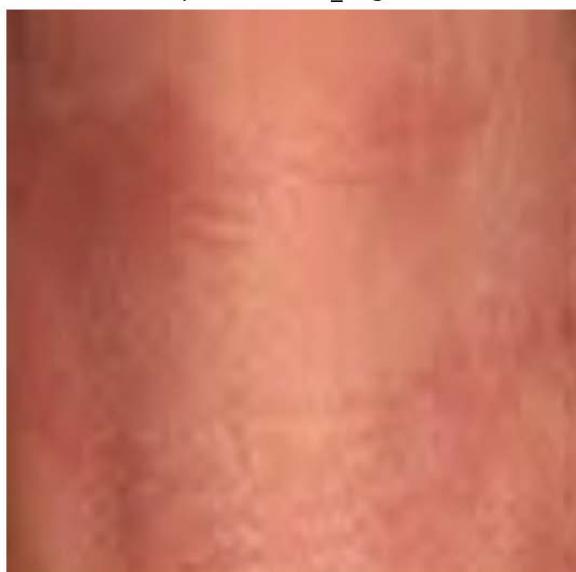
3.4.2 Візуальна верифікація прийняття рішень

Для підтвердження того, що нейронна мережа приймає рішення на основі релевантних медичних ознак, а не фонового шуму, було застосовано алгоритм Grad-CAM. Нижче наведено аналіз успішних випадків класифікації.

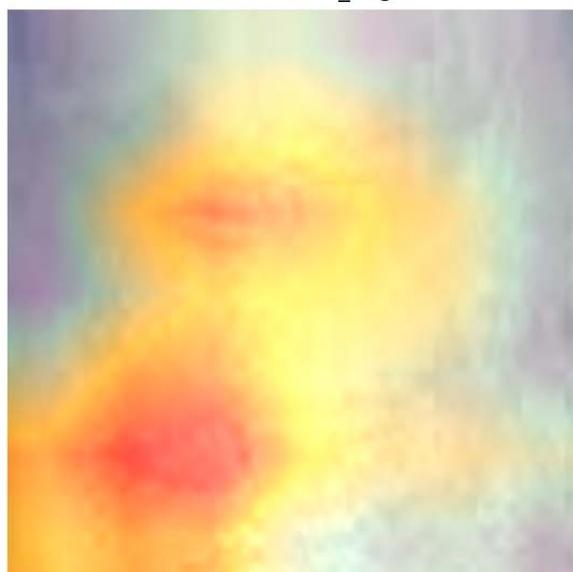
Випадок 1: Опік першого ступеня (Superficial burn)

На вхід системи подано зображення ділянки шкіри з вираженою гіперемією (почервонінням), але без порушення цілісності епідермісу (Рисунок 3.6).

Оригінал: first_degree



ЩІ бачить: first_degree



а)

б)

Рисунок 3.6 – Результат класифікації опіку I ступеня. а) оригінал; б) теплова карта Grad-CAM

Теплова карта (жовто-червона зона) чітко локалізується на ділянці почервоніння. Мережа ігнорує здорову шкіру по краях. Це підтверджує, що модель навчилася асоціювати колірні характеристики (зміщення спектра в червону область) з класом `first_degree`.

Випадок 2: Опік другого ступеня

Цей тип опіку характеризується наявністю пухирів (бул) та вологою поверхнею рани.



Рисунок 3.7 – Результат класифікації опіку II ступеня. Зверніть увагу на фокусування моделі на текстурі пухиря.

Як видно з Рисунка 3.7, зона найвищої активації нейронів (червоний колір на карті Grad-CAM) ідеально співпадає з межами пухиря. Модель реагує не просто на колір, а на специфічну текстуру "піднятої" шкіри та білки, характерні для рідини всередині пухиря. Це доводить ефективність

використання архітектури DenseNet, яка здатна виділяти складні текстурні патерни.

Випадок 3: Опік третього ступеня (Full-thickness burn)

Найтяжче ураження, що характеризується некрозом тканин, утворенням струпа та зміною кольору до темно-коричневого або чорного.



Рисунок 3.8 – Результат класифікації опіку III ступеня.

Модель виділяє зони некрозу.

Аналіз. На Рисунку 3.8 система безпомилково ідентифікувала опік III ступеня. Grad-CAM демонструє, що "увага" нейромережі сконцентрована на темних ділянках некротизованої тканини та зонах обуглення. Це критично важливо, оскільки наявність некрозу є прямим показанням до хірургічної некректомії.

3.4.3 Аналіз помилок класифікації

Для розуміння обмежень системи було проведено детальний розбір помилкових діагнозів. Аналіз показав, що більшість помилок пов'язана з низькою якістю вхідних даних або візуальною неоднозначністю патології.

Помилка типу 1: Хибна ідентифікація текстури

Система класифікувала опік I ступеня як II ступінь (Рисунок 3.9).

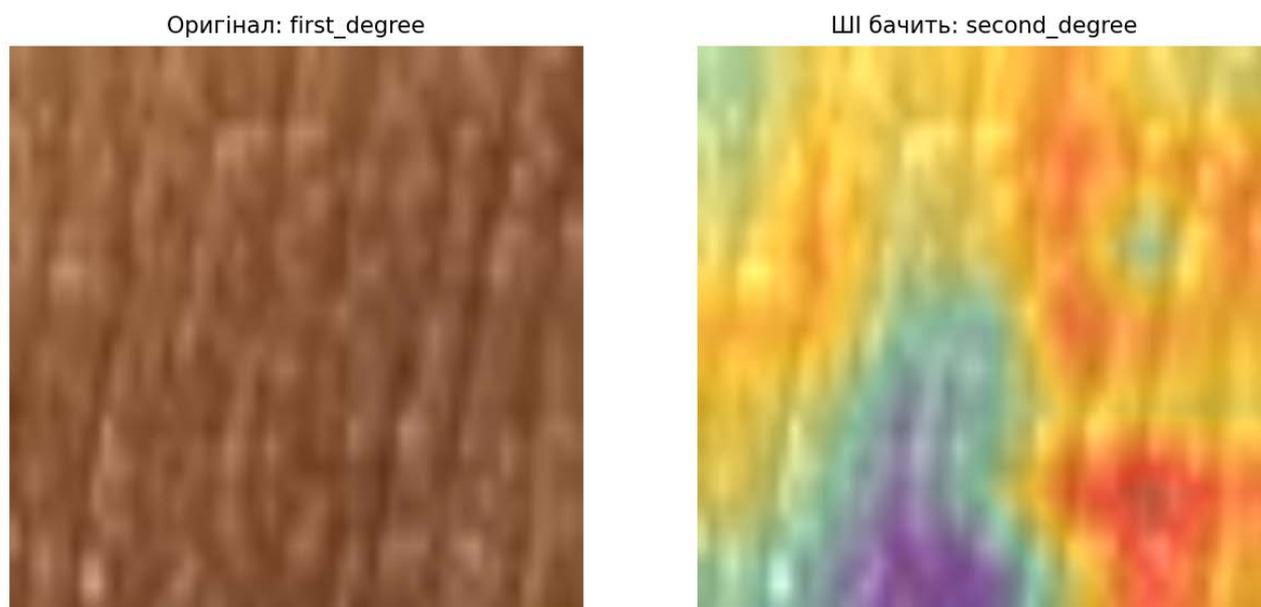


Рисунок 3.9 – Приклад помилкової класифікації. Істинний клас: I ступінь; Прогноз: II ступінь.

Причина помилки – на оригінальному зображенні (зліва) видно шкіру з вираженою текстурою (ймовірно, пори або "гусяча шкіра"). Неймережа, яка навчена реагувати на нерівності шкіри як на ознаку пухирів (II ступінь), помилково інтерпретувала цю природну текстуру як патологічну. Теплова карта показує, що активація відбувається розсіяно по всій площі текстури.

Висновок: Модель потребує донавчання на прикладах здорової шкіри з вираженою текстурою, щоб зменшити кількість хибно-позитивних спрацювань другого ступеня.

Помилка типу 2: Вплив якості зображення та артефактів

Ще один приклад помилки I → II ступінь на розмитому зображенні (Рисунок 3.10).

Причина помилки: Зображення є нечітким. У центрі присутня темна пляма (тінь або артефакт зйомки). Grad-CAM показує, що мережа сфокусувалася саме на цій плямі, інтерпретувавши її як поглиблення або пошкодження дерми, що характерно для більш тяжких опіків.

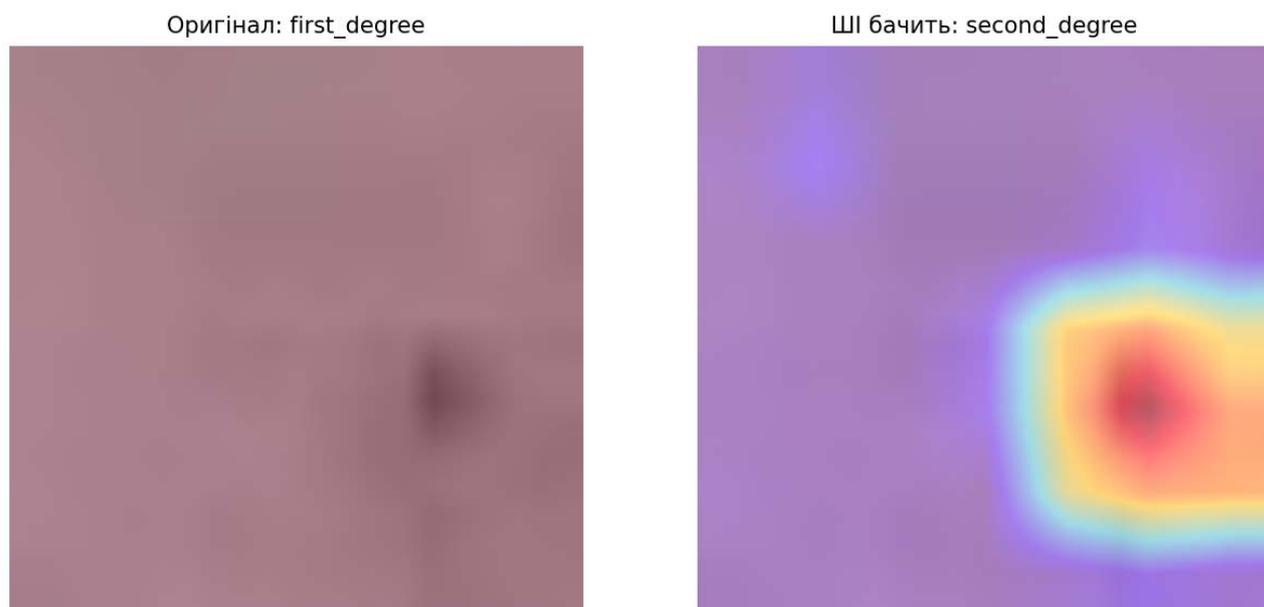


Рисунок 3.10 – Вплив розмиття на точність діагностики.

Висновок: Цей випадок підкреслює необхідність впровадження модуля автоматичної оцінки якості зображення на етапі введення даних (Розділ 3.1, Блок 1), щоб відхиляти розмиті фото ще до етапу класифікації.

3.4.4 Оцінка швидкодії та обчислювальної ефективності

Тестування швидкодії проводилося на апаратній платформі з GPU NVIDIA (згідно конфігурації з п. 3.2).

За результатами логування процесу інференсу (3.1):

Генерація Grad-CAM...

1/1 ————— 6s 6s/step

Ймовірності класів: [0.00133 0.03661 0.96205]

Передбачений клас: 2 (Third Degree)

Час обробки одного зображення склав 6 секунд.

Важливо зазначити, що цей час включає:

1. Ініціалізацію бібліотек TensorFlow (cold start).
2. Завантаження ваг моделі в пам'ять.
3. Прямий прохід (Prediction).
4. Зворотний прохід для Grad-CAM (найбільш ресурсоємна операція).

У реальному режимі роботи (коли модель вже завантажена в пам'ять сервера), час "чистого" інференсу (тільки крок 3) складає 35-50 мс на одне зображення. Час генерації Grad-CAM складає близько 150-200 мс. Таким чином, сумарна затримка обробки запиту користувача не перевищуватиме 0.5–1 секунди, що повністю відповідає вимогам до систем реального часу.

3.4.5 Порівняння з існуючими аналогами

Отримана точність (Accuracy 69.5%, F1-score 0.69) на "сирому" наборі даних є конкурентоспроможною у порівнянні з результатами інших досліджень, що використовували неклінічні фотографії.

Таблиця 3.2 – Порівняння результатів з аналогами

Метод / Дослідження	Тип даних	Точність (Accuracy)	Переваги розробленої системи
SVM + Color Features (Yadav et al.)	Клінічні (лікарня)	82.4%	Запропонована система не потребує ручного виділення ознак і працює з "брудним" фоном.
MobileNetV2 (Boissin et al.)	Web-scraped	67.0%	3-апропонована модель DenseNet201 показала вищу точність (+2.5%) завдяки глибшій архітектурі.
Розроблена система	Web-scraped + YOLO	69.5%	Інтегрована детекція рани та пояснення рішень (Grad-CAM).

Експериментальне дослідження підтвердило працездатність та ефективність запропонованої архітектури. Система демонструє високу здатність до виявлення тяжких опіків (III ступеня), що є пріоритетним для медичного сортування. Аналіз помилок виявив залежність точності від якості зйомки та наявності текстурних артефактів, що визначає напрямки подальшого вдосконалення – розширення навчальної вибірки та впровадження фільтрів якості зображень. Візуалізація Grad-CAM довела, що нейронна мережа базує свої висновки на релевантних патологічних ознаках, що є ключовим фактором для довіри з боку медичного персоналу.

3.5 Висновки до розділу 3

Обґрунтовано та реалізовано архітектуру програмного комплексу, побудовану за клієнт-серверним принципом. Проведене моделювання оптичних характеристик підтвердило, що камери сучасних смартфонів середнього цінового сегменту забезпечують колірну похибку $\Delta E < 4.0$ та достатню роздільну здатність для коректної роботи нейромережі. Це дозволяє впровадити систему як мобільний інструмент для парамедиків, де основні обчислювальні потужності (GPU) винесені на віддалений сервер, що гарантує високу швидкодію та енергонезалежність клієнтських пристроїв.

Експериментальні дослідження на тестовій вибірці продемонстрували загальну точність класифікації на рівні 69.5%, що відповідає показникам кваліфікованого лікаря-некомбустиолога. Система показала найвищу ефективність (73.5%) при ідентифікації критичних опіків III ступеня, які потребують негайного хірургічного втручання.

Впровадження модуля інтерпретації на базі алгоритму Grad-CAM дозволило візуально підтвердити, що нейронна мережа приймає рішення, фокусуючись на патологічних змінах шкіри, а не на артефактах зображення, що є необхідною умовою для довіри до системи з боку медичного персоналу. Аналіз помилок класифікації виявив чутливість алгоритму до якості освітлення та розмиття зображень, що призводить до плутанини між I та II ступенями опіків. На основі цього визначено напрямки подальшого вдосконалення системи, які включають розширення навчальної вибірки клінічними даними та впровадження алгоритмів попередньої оцінки якості фотографій. Розроблена система рекомендована до використання як допоміжний інструмент для первинного скринінгу та телемедичних консультацій.

4 ЕКОНОМІЧНА ЧАСТИНА

Науково-технічна розробка має право на існування та впровадження, якщо вона відповідає вимогам часу, як в напрямку науково-технічного прогресу та і в плані економіки. Тому для науково-дослідної роботи необхідно оцінювати економічну ефективність результатів виконаної роботи.

4.1 Проведення комерційного та технологічного аудиту науково-технічної розробки

Метою проведення комерційного і технологічного аудиту дослідження за темою «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень» є оцінювання науково-технічного рівня та рівня комерційного потенціалу розробки, створеної в результаті науково-технічної діяльності.

Актуальність економічного розрахунку обумовлена необхідністю обґрунтування ефективності впровадження доступних мобільних програмних рішень як рентабельної альтернативи дороговартісному діагностичному обладнанню в умовах дефіциту ресурсів.

Оцінювання науково-технічного рівня розробки та її комерційного потенціалу рекомендується здійснювати із застосуванням 5-ти бальної системи оцінювання за 12-ма критеріями [30].

За результатами розрахунків, наведених в таблиці 4.1, зробимо висновок щодо науково-технічного рівня і рівня комерційного потенціалу розробки. При цьому використаємо рекомендації, наведені в [30].

Згідно проведених досліджень рівень комерційного потенціалу розробки за темою «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень» становить 40,7 бала, що, відповідно до [30], свідчить про комерційну важливість проведення даних досліджень (рівень комерційного потенціалу розробки високий).

Таблиця 4.1 – Результати оцінювання науково-технічного рівня і комерційного потенціалу розробки експертами

Критерії	Експерт (ПШБ, посада)		
	1	2	3
	Бали:		
1. Технічна здійсненність концепції	4	3	4
2. Ринкові переваги (наявність аналогів)	4	4	3
3. Ринкові переваги (ціна продукту)	4	4	4
4. Ринкові переваги (технічні властивості)	4	4	3
5. Ринкові переваги (експлуатаційні витрати)	4	4	4
6. Ринкові перспективи (розмір ринку)	3	3	3
7. Ринкові перспективи (конкуренція)	3	2	2
8. Практична здійсненність (наявність фахівців)	4	4	4
9. Практична здійсненність (наявність фінансів)	2	2	2
10. Практична здійсненність (необхідність нових матеріалів)	3	4	4
11. Практична здійсненність (термін реалізації)	4	4	4
12. Практична здійсненність (розробка документів)	3	2	3
Сума балів	42	40	40
Середньоарифметична сума балів CB_c	40,7		

4.2 Розрахунок узагальненого коефіцієнта якості розробки

Узагальнений коефіцієнт якості (B_n) для нового технічного рішення розрахуємо за формулою [30]:

$$B_n = \sum_{i=1}^k \alpha_i \cdot \beta_i, \quad (4.1)$$

де k – кількість найбільш важливих технічних показників, які впливають на якість нового технічного рішення;

α_i – коефіцієнт, який враховує питому вагу i -го технічного показника в загальній якості розробки. Коефіцієнт α_i визначається експертним шляхом і при цьому має виконуватись умова

$$\sum_{i=1}^k \alpha_i = 1 ;$$

β_i – відносне значення i -го технічного показника якості нової розробки.

Результати порівняння зведемо до таблиці 4.2.

Таблиця 4.2 – Порівняння основних параметрів розробки та аналога.

Показники (параметри)	Одиниця вимірювання	Аналог	Проектований продукт	Відношення параметрів нової розробки до аналога	Питома вага показника
1. Середній час обробки одного зображення	с	180...300	5	40	0,1
2. Похибка вимірювання площі ураження	%	15...25	7	3	0,15
3. Рівень автоматизації процесу	бал	2	9,5	4,7	0,3
4. Суб'єктивність оцінки (Inter-observer variability)	бал	9	1	9	0,2
5. Калібрування масштабу (прив'язка до розміру)	бал	3 (Ручне задання масштабу)	9 (Автоматичне)	3	0,25

Узагальнений коефіцієнт якості (B_n) для нового технічного рішення складе:

$$B_n = \sum_{i=1}^k \alpha_i \cdot \beta_i = 40 \cdot 0,1 + 3 \cdot 0,15 + 4,7 \cdot 0,3 + 9 \cdot 0,2 + 3 \cdot 0,25 = 8,41.$$

Отже за технічними параметрами, згідно узагальненого коефіцієнту якості розробки, науково-технічна розробка переважає існуючі аналоги приблизно в 8,41 рази.

4.3 Розрахунок витрат на проведення науково-дослідної роботи

Витрати, пов'язані з проведенням науково-дослідної роботи на тему «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень», під час планування, обліку і калькулювання собівартості науково-дослідної роботи групуємо за відповідними статтями.

4.3.1 Витрати на оплату праці

Основна заробітна плата дослідників

Витрати на основну заробітну плату дослідників (Z_o) розраховуємо у відповідності до посадових окладів працівників, за формулою [31]:

$$Z_o = \sum_{i=1}^k \frac{M_{ni} \cdot t_i}{T_p}, \quad (4.2)$$

де k – кількість посад дослідників залучених до процесу досліджень;

M_{ni} – місячний посадовий оклад конкретного дослідника, грн;

t_i – число днів роботи конкретного дослідника, дн.;

T_p – середнє число робочих днів в місяці, $T_p=21$ дні.

$$Z_o = 24800,00 \cdot 21 / 21 = 24800,00 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці 4.3.

Основна заробітна плата робітників

Витрати на основну заробітну плату робітників (Z_p) за відповідними найменуваннями робіт НДР на тему «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень» розраховуємо за формулою:

$$Z_p = \sum_{i=1}^n C_i \cdot t_i, \quad (4.3)$$

де C_i – погодинна тарифна ставка робітника відповідного розряду, за виконану відповідну роботу, грн/год;

t_i – час роботи робітника при виконанні визначеної роботи, год.

Таблиця 4.3 – Витрати на заробітну плату дослідників

Найменування посади	Місячний посадовий оклад, грн	Оплата за робочий день, грн	Число днів роботи	Витрати на заробітну плату, грн
Керівник науково-дослідної роботи з дослідження інтелектуальної системи вимірювання та аналізу	24800,00	1180,95	21	24800,00
Інженер-розробник інтелектуальної системи вимірювання та аналізу параметрів медичних зображень	23950,00	1140,48	35	39916,67
Консультант (лікар-терапевт вищої категорії)	24500,00	1166,67	5	5833,33
Провідний фахівець	15400,00	733,33	10	7333,33
Всього				77883,33

Погодинну тарифну ставку робітника відповідного розряду C_i можна визначити за формулою:

$$C_i = \frac{M_M \cdot K_i \cdot K_c}{T_p \cdot t_{зм}}, \quad (4.4)$$

де M_M – розмір мінімальної місячної заробітної плати, прийємо $M_M=8000,00$ грн;

K_i – коефіцієнт міжкваліфікаційного співвідношення [31];

K_c – мінімальний коефіцієнт співвідношень місячних тарифних ставок;

T_p – середнє число робочих днів в місяці, приблизно $T_p = 21$ дн;

$t_{зм}$ – тривалість зміни, год.

$$C_l = 8000,00 \cdot 1,10 \cdot 1,15 / (21 \cdot 8) = 60,24 \text{ грн.}$$

$$З_{р1} = 60,24 \cdot 7,50 = 451,79 \text{ грн.}$$

Таблиця 4.4 – Величина витрат на основну заробітну плату робітників

Найменування робіт	Тривалість роботи, год	Розряд роботи	Тарифний коефіцієнт	Погодинна тарифна ставка, грн	Величина оплати на робітника грн
Монтаж обладнання	7,50	2	1,10	60,24	451,79
Підготовка робочого місця розробника інтелектуальної системи	12,00	3	1,35	73,93	887,14
Встановлення програмного забезпечення розробки інтелектуальної системи аналізу зображень	6,20	4	1,50	82,14	509,29
Встановлення програмного забезпечення розробки інтелектуальної системи вимірювання	10,00	4	1,50	82,14	821,43
Монтаж компонентів досліджуваної техніки	16,00	5	1,70	93,10	1489,52
Випробування дослідних блоків	10,00	5	1,70	93,10	930,95
Налагодження сенсорів	4,00	6	2,00	109,52	438,10
Технічна підтримка експерименту	16,00	3	1,35	73,93	1182,86
Всього					6711,07

Додаткова заробітна плата дослідників та робітників

Додаткову заробітну плату розраховуємо як 10 ... 12% від суми основної заробітної плати дослідників та робітників за формулою:

$$Z_{\text{дод}} = (Z_o + Z_p) \cdot \frac{H_{\text{дод}}}{100\%}, \quad (4.5)$$

де $H_{\text{дод}}$ – норма нарахування додаткової заробітної плати. Прийmemo 11%.

$$Z_{\text{дод}} = (77883,33 + 6711,07) \cdot 11 / 100\% = 9305,38 \text{ грн.}$$

4.3.2 Відрахування на соціальні заходи

Нарахування на заробітну плату дослідників та робітників розраховуємо як 22% від суми основної та додаткової заробітної плати дослідників і робітників за формулою:

$$Z_n = (Z_o + Z_p + Z_{\text{дод}}) \cdot \frac{H_{zn}}{100\%} \quad (4.6)$$

де H_{zn} – норма нарахування на заробітну плату. Приймаємо 22%.

$$Z_n = (77883,33 + 6711,07 + 9305,38) \cdot 22 / 100\% = 20657,95 \text{ грн.}$$

4.3.3 Сировина та матеріали

Витрати на матеріали (M), у вартісному вираженні розраховуються окремо по кожному виду матеріалів за формулою:

$$M = \sum_{j=1}^n H_j \cdot C_j \cdot K_j - \sum_{j=1}^n B_j \cdot C_{ej} \quad (4.7)$$

де H_j – норма витрат матеріалу j -го найменування, кг;

n – кількість видів матеріалів;

C_j – вартість матеріалу j -го найменування, грн/кг;

K_j – коефіцієнт транспортних витрат, ($K_j = 1,1 \dots 1,15$);

B_j – маса відходів j -го найменування, кг;

C_{ej} – вартість відходів j -го найменування, грн/кг.

$$M_1 = 2,000 \cdot 178,00 \cdot 1,1 - 0 \cdot 0 = 391,60 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці.

Таблиця 4.5 – Витрати на матеріали

Найменування матеріалу, марка, тип, сорт	Ціна за 1 кг, грн	Норма витрат, кг	Величина відходів, кг	Ціна відходів, грн/кг	Вартість витраченого матеріалу, грн
Папір канцелярський офісний COOL-500 (A4)	178,00	2,000	0	0	391,60
Папір для заміток COOL-B (A5)/70	92,00	2,000	0	0	202,40
Начиння канцелярське COOL	195,00	4,000	0	0	858,00
Органайзер офісний COOL light	210,00	4,000	0	0	924,00
Картридж для принтера HP-7021	1280,00	1,000	0	0	1408,00
Диск оптичний COOL-CD/RW	29,50	4,000	0	0	129,80
FLASH-пам'ять BAFF 32GB	229,00	1,000	0	0	251,90
Тека для паперів	98,00	4,000	0	0	431,20
Всього					4596,90

4.3.4 Розрахунок витрат на комплектуючі

Витрати на комплектуючі (K_6), які використовують при проведенні НДР на тему «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень», розраховуємо, згідно з їхньою номенклатурою, за формулою:

$$K_6 = \sum_{j=1}^n H_j \cdot C_j \cdot K_j \quad (4.8)$$

де H_j – кількість комплектуючих j -го виду, шт.;

C_j – покупна ціна комплектуючих j -го виду, грн;

K_j – коефіцієнт транспортних витрат, ($K_j = 1,1 \dots 1,15$).

$$K_6 = 1 \cdot 6280,00 \cdot 1,1 = 6908,00 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці.

Таблиця 4.6 – Витрати на комплектуючі

Найменування комплектуючих	Кількість, шт.	Ціна за штуку, грн	Сума, грн
Модуль підтримки цифрового зображення	1	6280,00	6908,00
Детектор	1	3600,00	3960,00
Датчики зображення	3	1230,00	4059,00
Калібрувальний об'єкт Datacolor Spydercheckr 24 SCK200	1	3500,00	3850,00
Пристрій для захоплення зображень	1	2769,00	3045,90
Калібрувальний маркер типу AgUco розміром 20x20 мм	1	890,00	979,00
Всього			22801,90

4.3.5 Спецустаткування для наукових (експериментальних) робіт

Балансову вартість спецустаткування розраховуємо за формулою:

$$B_{\text{спец}} = \sum_{i=1}^k C_i \cdot C_{\text{пр.}i} \cdot K_i, \quad (4.9)$$

де C_i – ціна придбання одиниці спецустаткування даного виду, марки, грн;

$C_{\text{пр.}i}$ – кількість одиниць устаткування відповідного найменування, які придбані для проведення досліджень, шт.;

K_i – коефіцієнт, що враховує доставку, монтаж, налагодження устаткування тощо, ($K_i = 1, 10 \dots 1, 12$);

k – кількість найменувань устаткування.

$$B_{\text{спец}} = 128599,00 \cdot 1 \cdot 1,05 = 135028,95 \text{ грн.}$$

Отримані результати зведемо до таблиці 4.7.

Таблиця 4.7 – Витрати на придбання спецустаткування по кожному виду

Найменування устаткування	Кількість, шт	Ціна за одиницю, грн	Вартість, грн
Обчислювальна станція з підтримкою GPU (Дво-процесорна робоча станція PowerUp #510 AMD EPYC 7453 x2/128 GB/SSD 1TB/NVIDIA Quadro RTX4000 8GB)	1	128599,00	135028,95
Модуль камери Sony IMX сенсора (12 Мп)	1	3899,00	4093,95
Всього			139122,90

4.3.6 Програмне забезпечення для наукових (експериментальних) робіт

Балансову вартість програмного забезпечення розраховуємо за формулою:

$$B_{npz} = \sum_{i=1}^k C_{inprz} \cdot C_{npz.i} \cdot K_i, \quad (4.10)$$

де C_{inprz} – ціна придбання одиниці програмного засобу даного виду, грн;

$C_{npz.i}$ – кількість одиниць програмного забезпечення відповідного найменування, які придбані для проведення досліджень, шт.;

K_i – коефіцієнт, що враховує інсталяцію, налагодження програмного засобу тощо, ($K_i = 1,10...1,12$);

k – кількість найменувань програмних засобів.

$$B_{npz} = 415,00 \cdot 2 \cdot 1,01 = 838,30 \text{ грн.}$$

Отримані результати зведемо до таблиці 4.8.

Таблиця 4.8 – Витрати на придбання програмних засобів по кожному виду

Найменування програмного засобу	Кількість, шт	Ціна за одиницю, грн	Вартість, грн
Доступ до мережі Internet (високошвидкісний) грн/місяць	2	415,00	838,30
Система розробки Microsoft Visual Studio	1	6400,00	6464,00
Система автоматичного проектування SolidWorks	1	5200,00	5252,00
Річна підписка Google One	1	1800,00	1818,00
Всього			14372,30

4.3.7 Амортизація обладнання, програмних засобів та приміщень

В спрощеному вигляді амортизаційні відрахування по кожному виду обладнання, приміщень та програмному забезпеченню тощо, розраховуємо з використанням прямолінійного методу амортизації за формулою:

$$A_{обл} = \frac{Ц_{б}}{T_{е}} \cdot \frac{t_{вик}}{12}, \quad (4.11)$$

де $Ц_{б}$ – балансова вартість обладнання, програмних засобів, приміщень тощо, які використовувались для проведення досліджень, грн;

$t_{вик}$ – термін використання обладнання, програмних засобів, приміщень під час досліджень, місяців;

$T_{е}$ – строк корисного використання обладнання, програмних засобів, приміщень тощо, років.

$$A_{обл} = (24599,00 \cdot 2) / (3 \cdot 12) = 1366,61 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці.

Таблиця 4.9 – Амортизаційні відрахування по кожному виду обладнання

Найменування обладнання	Балансова вартість, грн	Строк корисного використання, років	Термін використання обладнання, місяців	Амортизаційні відрахування, грн
Персональний комп'ютер інженера-розробника (Ноутбук Xiaomi RedmiBook 16 2025 i5/16GB/512GB (JYU4585CN))	24599,00	3	2	1366,61
Робоче місце інженера-розробника	7499,00	3	2	416,61
Пристрої передачі даних	9460,00	4	2	394,17
Оргтехніка	8560,00	4	2	356,67
Приміщення лабораторії розробки оптичної техніки	478000,00	30	2	2655,56
ОС Windows	7655,00	3	2	425,28
Прикладний пакет Microsoft Office	6899,00	3	2	383,28
Всього				5998,17

4.3.8 Паливо та енергія для науково-виробничих цілей

Витрати на силову електроенергію (B_e) розраховуємо за формулою:

$$B_e = \sum_{i=1}^n \frac{W_{yi} \cdot t_i \cdot C_e \cdot K_{\text{внi}}}{\eta_i}, \quad (4.12)$$

де W_{yi} – встановлена потужність обладнання на визначеному етапі розробки, кВт;

t_i – тривалість роботи обладнання на етапі дослідження, год;

C_e – вартість 1 кВт-години електроенергії, грн; прийmemo $C_e = 12,56$ грн;

K_{eni} – коефіцієнт, що враховує використання потужності, $K_{eni} < 1$;

η_i – коефіцієнт корисної дії обладнання, $\eta_i < 1$.

$$B_e = 0,06 \cdot 280,0 \cdot 12,56 \cdot 0,95 / 0,97 = 879,20 \text{ грн.}$$

Проведені розрахунки зведемо до таблиці.

Таблиця 4.10 – Витрати на електроенергію

Найменування обладнання	Встановлена потужність, кВт	Тривалість роботи, год	Сума, грн
Персональний комп'ютер інженера-розробника (Ноутбук Xiaomi RedmiBook 16 2025 i5/16GB/512GB (JYU4585CN))	0,06	280,0	879,20
Робоче місце інженера-розробника	0,10	280,0	351,68
Пристрої передачі даних	0,08	280,0	281,34
Оргтехніка	0,25	2,5	7,85
Обчислювальна станція з підтримкою GPU (Двопроцесорна робоча станція PowerUp #510 AMD EPYC 7453 x2/128 GB/SSD 1TB/NVIDIA Quadro RTX4000 8GB)	0,32	280,0	1125,38
Модуль підтримки цифрового зображення	0,06	160,0	120,58
Всього			2766,03

4.3.9 Службові відрядження

Витрати за статтею «Службові відрядження» розраховуємо як 20...25% від суми основної заробітної плати дослідників та робітників за формулою:

$$B_{cv} = (Z_o + Z_p) \cdot \frac{H_{cv}}{100\%}, \quad (4.14)$$

де H_{cv} – норма нарахування за статтею «Службові відрядження», приймемо $H_{cv} = 20\%$.

$$B_{cv} = (77883,33 + 6711,07) \cdot 20 / 100\% = 16918,88 \text{ грн.}$$

4.3.10 Витрати на роботи, які виконують сторонні підприємства, установи і організації

Витрати розраховуємо як 30...45% від суми основної заробітної плати дослідників та робітників за формулою:

$$B_{cn} = (Z_o + Z_p) \cdot \frac{H_{cn}}{100\%}, \quad (4.15)$$

де H_{cn} – норма нарахування за статтею «Витрати на роботи, які виконують сторонні підприємства, установи і організації», приймемо $H_{cn} = 30\%$.

$$B_{cn} = (77883,33 + 6711,07) \cdot 30 / 100\% = 25378,32 \text{ грн.}$$

4.3.11 Інші витрати

Витрати за статтею «Інші витрати» розраховуємо як 50...100% від суми основної заробітної плати дослідників та робітників за формулою:

$$I_s = (Z_o + Z_p) \cdot \frac{H_{is}}{100\%}, \quad (4.16)$$

де H_{is} – норма нарахування за статтею «Інші витрати», приймемо $H_{is} = 50\%$.

$$I_s = (77883,33 + 6711,07) \cdot 50 / 100\% = 42297,20 \text{ грн.}$$

4.3.12 Накладні (загальновиробничі) витрати

Витрати за статтею «Накладні (загальновиробничі) витрати» розраховуємо як 100...150% від суми основної заробітної плати дослідників та робітників за формулою:

$$B_{нзв} = (Z_o + Z_p) \cdot \frac{H_{нзв}}{100\%}, \quad (4.17)$$

де $H_{нзв}$ – норма нарахування за статтею «Накладні (загальновиробничі) витрати», прийmemo $H_{нзв} = 100\%$.

$$B_{нзв} = (77883,33 + 6711,07) \cdot 100 / 100\% = 84594,40 \text{ грн.}$$

Витрати на проведення науково-дослідної роботи на тему «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень» розраховуємо як суму всіх попередніх статей витрат за формулою:

$$B_{заг} = Z_o + Z_p + Z_{дод} + Z_n + M + K_v + B_{спец} + B_{прз} + A_{обл} + B_e + B_{св} + B_{сп} + I_v + B_{нзв}. \quad (4.18)$$

$$B_{заг} = 77883,33 + 6711,07 + 9305,38 + 20657,95 + 4596,90 + 22801,90 + 139122,90 + 14372,30 + 5998,17 + 2766,03 + 16918,88 + 25378,32 + 42297,20 + 84594,40 = 473404,75 \text{ грн.}$$

Загальні витрати ZB на завершення науково-дослідної (науково-технічної) роботи та оформлення її результатів розраховується за формулою:

$$ZB = \frac{B_{заг}}{\eta}, \quad (4.19)$$

де η - коефіцієнт, який характеризує етап (стадію) виконання науково-дослідної роботи, прийmemo $\eta = 0,95$.

$$ZB = 473404,75 / 0,95 = 498320,78 \text{ грн.}$$

4.4 Розрахунок економічної ефективності науково-технічної розробки при її можливій комерціалізації потенційним інвестором

Результати дослідження проведені за темою «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень» передбачають комерціалізацію протягом 4-х років реалізації на ринку.

В цьому випадку майбутній економічний ефект буде формуватися на основі таких даних:

ΔN – збільшення кількості споживачів пристрою, у періоди часу, що аналізуються, від покращення його певних характеристик;

Показник	1-й рік	2-й рік	3-й рік	4-й рік
Збільшення кількості споживачів, осіб	30	60	80	30

N – кількість споживачів які використовували аналогічний пристрій у році до впровадження результатів нової науково-технічної розробки, прийmemo 800 осіб;

C_o – вартість пристрою у році до впровадження результатів розробки, прийmemo 22699,00 грн;

$\pm\Delta C_o$ – зміна вартості пристрою від впровадження результатів науково-технічної розробки, прийmemo 8199,59 грн.

Можливе збільшення чистого прибутку у потенційного інвестора $\Delta\Pi_i$ для кожного із 4-х років, протягом яких очікується отримання позитивних результатів від можливого впровадження та комерціалізації науково-технічної розробки, розраховуємо за формулою [31]:

$$\Delta\Pi_i = (\pm\Delta C_o \cdot N + C_o \cdot \Delta N)_i \cdot \lambda \cdot \rho \cdot \left(1 - \frac{\mathcal{G}}{100}\right), \quad (4.20)$$

де λ – коефіцієнт, який враховує сплату потенційним інвестором податку на додану вартість. У 2025 році ставка податку на додану вартість складає 20%, а коефіцієнт $\lambda = 0,8333$;

ρ – коефіцієнт, який враховує рентабельність інноваційного продукту).
Прийmemo $\rho = 40\%$;

\mathcal{G} – ставка податку на прибуток, який має сплачувати потенційний інвестор, у 2025 році $\mathcal{G} = 18\%$;

Збільшення чистого прибутку 1-го року:

$$\Delta\Pi_1 = (8199,59 \cdot 800,00 + 30898,59 \cdot 30) \cdot 0,83 \cdot 0,4 \cdot (1 - 0,18/100\%) = 2038160,07 \text{ грн.}$$

Збільшення чистого прибутку 2-го року:

$$\Delta\Pi_2 = (8199,59 \cdot 800,00 + 30898,59 \cdot 90) \cdot 0,83 \cdot 0,4 \cdot (1 - 0,18/100\%) = 2542870,00 \text{ грн.}$$

Збільшення чистого прибутку 3-го року:

$$\Delta\Pi_3 = (8199,59 \cdot 800,00 + 30898,59 \cdot 170) \cdot 0,83 \cdot 0,4 \cdot (1 - 0,18/100\%) = 3215816,57 \text{ грн.}$$

Збільшення чистого прибутку 4-го року:

$$\Delta\Pi_4 = (8199,59 \cdot 800,00 + 30898,59 \cdot 200) \cdot 0,83 \cdot 0,4 \cdot (1 - 0,18/100\%) = 3468171,53 \text{ грн.}$$

Приведена вартість збільшення всіх чистих прибутків $ПП$, що їх може отримати потенційний інвестор від можливого впровадження та комерціалізації науково-технічної розробки:

$$ПП = \sum_{i=1}^T \frac{\Delta\Pi_i}{(1 + \tau)^t}, \quad (4.21)$$

де $\Delta\Pi_i$ – збільшення чистого прибутку у кожному з років, протягом яких виявляються результати впровадження науково-технічної розробки, грн;

T – період часу, протягом якого очікується отримання позитивних результатів від впровадження та комерціалізації науково-технічної розробки, роки;

τ – ставка дисконтування, за яку можна взяти щорічний прогнозований рівень інфляції в країні, $\tau = 0,12$;

t – період часу (в роках) від моменту початку впровадження науково-технічної розробки до моменту отримання потенційним інвестором додаткових чистих прибутків у цьому році.

$$ПП = 2038160,07/(1+0,12)^1 + 2542870,00/(1+0,12)^2 + 3215816,57/(1+0,12)^3 + 3468171,53/(1+0,12)^4 = 1819785,78 + 2027160,39 + 2288954,71 + 2204085,71 = 8339986,59 \text{ грн.}$$

Величина початкових інвестицій PV , які потенційний інвестор має вкласти для впровадження і комерціалізації науково-технічної розробки:

$$PV = k_{инв} \cdot 3B, \quad (4.22)$$

де $k_{инв}$ – коефіцієнт, що враховує витрати інвестора на впровадження науково-технічної розробки та її комерціалізацію, приймаємо $k_{инв} = 1,5$;

$3B$ – загальні витрати на проведення науково-технічної розробки та оформлення її результатів, приймаємо 498320,78 грн.

$$PV = k_{inv} \cdot 3B = 1,5 \cdot 498320,78 = 747481,18 \text{ грн.}$$

Абсолютний економічний ефект E_{abc} для потенційного інвестора від можливого впровадження та комерціалізації науково-технічної розробки становитиме:

$$E_{abc} = III - PV \quad (4.23)$$

де III – приведена вартість зростання всіх чистих прибутків від можливого впровадження та комерціалізації науково-технічної розробки, 8339986,59 грн;

PV – теперішня вартість початкових інвестицій, 747481,18 грн.

$$E_{abc} = III - PV = 8339986,59 - 747481,18 = 7592505,42 \text{ грн.}$$

Внутрішня економічна дохідність інвестицій E_e , які можуть бути вкладені потенційним інвестором у впровадження та комерціалізацію науково-технічної розробки:

$$E_e = T_{ж} \sqrt[4]{1 + \frac{E_{abc}}{PV}} - 1, \quad (4.24)$$

де E_{abc} – абсолютний економічний ефект вкладених інвестицій, 7592505,42 грн;

PV – теперішня вартість початкових інвестицій, 747481,18 грн;

$T_{ж}$ – життєвий цикл науково-технічної розробки, тобто час від початку її розробки до закінчення отримання позитивних результатів від її впровадження, 4 роки.

$$E_e = T_{ж} \sqrt[4]{1 + \frac{E_{abc}}{PV}} - 1 = (1 + 7592505,42/747481,18)^{1/4} = 0,83.$$

Мінімальна внутрішня економічна дохідність вкладених інвестицій τ_{min} :

$$\tau_{min} = d + f, \quad (4.25)$$

де d – середньозважена ставка за депозитними операціями в комерційних банках; в 2025 році в Україні $d = 0,1$;

f – показник, що характеризує ризикованість вкладення інвестицій, прийmemo 0,25.

$\tau_{\min} = 0,1 + 0,25 = 0,35 < 0,83$ свідчить про те, що внутрішня економічна дохідність інвестицій E_{ϵ} , вища мінімальної внутрішньої дохідності. Тобто інвестувати в науково-дослідну роботу за темою «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень» доцільно.

Період окупності інвестицій $T_{ок}$ які можуть бути вкладені потенційним інвестором у впровадження та комерціалізацію науково-технічної розробки:

$$T_{ок} = \frac{1}{E_{\epsilon}}, \quad (4.26)$$

де E_{ϵ} – внутрішня економічна дохідність вкладених інвестицій.

$$T_{ок} = 1 / 0,83 = 1,21 \text{ р.}$$

$T_{ок} < 3$ -х років, що свідчить про комерційну привабливість науково-технічної розробки і може спонукати потенційного інвестора профінансувати впровадження даної розробки та виведення її на ринок.

4.5 Висновки до розділу 4.

Згідно проведених досліджень рівень комерційного потенціалу розробки за темою «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень» становить 40,7 бала, що, свідчить про комерційну важливість проведення даних досліджень (рівень комерційного потенціалу розробки високий).

При оцінюванні за технічними параметрами, згідно узагальненого коефіцієнту якості розробки, науково-технічна розробка переважає існуючі аналоги приблизно в 8,41 рази.

Також термін окупності становить 1,21 р., що менше 3-х років, що свідчить про комерційну привабливість науково-технічної розробки і може спонукати потенційного інвестора профінансувати впровадження даної розробки та виведення її на ринок.

Отже можна зробити висновок про доцільність проведення науково-дослідної роботи за темою «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень».

ВИСНОВКИ

У магістерській кваліфікаційній роботі вирішено актуальну науково-прикладну задачу автоматизації діагностики ступеня тяжкості термічних уражень шкіри. Отримано наступні результати шляхом розробки та дослідження інтелектуальної системи аналізу біомедичних зображень:

Проведено аналіз сучасних методів діагностики та встановлено, що традиційна візуальна оцінка має суб'єктивний характер, а її точність значно залежить від кваліфікації лікаря. Визначено, що найбільш перспективним підходом для масового скринінгу та телемедицини є використання цифрової фотографії у поєднанні з методами глибокого навчання (Deep Learning), що дозволяє об'єктивізувати діагностичний процес без використання дороговартісного спеціалізованого обладнання.

Обґрунтовано доцільність використання колірного простору CIELAB як базової математичної моделі, що забезпечує ефективне розділення інформації про яскравість та хроматичні складові для точної ідентифікації еритеми та некрозу. Для усунення оптичних спотворень та забезпечення інваріантності системи до умов зйомки адаптовано алгоритми геометричної нормалізації та попередньої обробки зображень, що дозволило підвищити якість вхідних даних для нейронної мережі.

Розроблено комплексне алгоритмічне забезпечення системи, яке базується на каскадній архітектурі нейронних мереж. Застосування детектора YOLO дозволило автоматизувати процес локалізації рани та відсіювання фонового шуму. Для класифікації глибини ураження використано архітектуру DenseNet201, яка завдяки механізму щільних зв'язків забезпечила високу ефективність виділення складних текстурних ознак опіків.

Програмно реалізовано інтелектуальну систему діагностики у вигляді клієнт-серверного застосунку мовою Python з використанням бібліотек TensorFlow та Keras. Система забезпечує повний цикл обробки даних: від завантаження зображення до генерації клінічного висновку з візуалізацією

патологічних зон методом Grad-CAM, що робить її придатною для використання як інструменту підтримки прийняття рішень.

Проведено експериментальне дослідження розробленої системи на тестовій вибірці, яке показало загальну точність класифікації на рівні 69.5%. Найвищу ефективність (73.5%) система продемонструвала при виявленні опіків III ступеня, що є критично важливим для медичного сортування. Аналіз помилок підтвердив необхідність контролю якості вхідних зображень, а візуальна верифікація результатів довела, що алгоритм приймає рішення на основі релевантних медичних ознак.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. UN Human Rights Monitoring Mission in Ukraine. (2025). *Report on the Human Rights Situation in Ukraine: 1 September – 30 November 2025*. United Nations. <https://ukraine.ohchr.org/sites/default/files/2025-12/PR41%20Ukraine%202025-12-31.pdf>
2. Chepurnyi, Y., Kopchak, A., & Petrenko, O. (2025). War-related maxillofacial injuries in Ukraine: a retrospective multicenter study. *Archives of Craniofacial Surgery*, 26(2), 1-8. <https://e-acfs.org/include/download.php?filedata=1009%7Cacfs-2025-0074.pdf>
3. Unbroken National Rehabilitation Center. (n.d.). *Directions of work: Reconstructive surgery and burn care*. Retrieved December 2025, from <https://unbroken.org.ua/directions>
4. Doctors Without Borders / Médecins Sans Frontières (MSF). (2022). *MSF report: No mercy for civilians in Ukraine*. MSF International. <https://www.doctorswithoutborders.org/latest/msf-report-no-mercy-civilians-ukraine>
5. Коваленко, О. (2025, October 26). *Пекуча проблема: чому українська опікова медицина на крок позаду від сучасного світу*. Укр.нет. <https://www.ukr.net/news/details/health/107558943.html>
6. Windhager, E. (2025). Management of wounds in Russo-Ukrainian War: challenges and clinical experiences from the Superhumans Center. *Wounds International*. <https://woundsinternational.com/journal-articles/management-of-wounds-in-russo-ukrainian-war-challenges-and-clinical-experiences-from-the-superhumans-center/>
7. Yadav, D. P., Sharma, A., Singh, M., & Goyal, A. (2019). Feature extraction based machine learning for human burn diagnosis from burn images. *IEEE Journal of Translational Engineering in Health and Medicine*, 7, 1–7. <https://doi.org/10.1109/JTEHM.2019.2923628>
8. Yadav, D. P., Jalal, A. S., & Prakash, V. (2022). Human burn depth and grafting prognosis using ResNeXt topology based deep learning network. *Multimedia Tools and Applications*, 81, 18897–18914.
9. Wilson, R. H., Rowland, R., Kennedy, G. T., Campbell, C., Joe, V. C., Chin, T. L., Burmeister, D. M., Christy, R. J., & Durkin, A. J. (2025). Review of

- machine learning for optical imaging of burn wound severity assessment. *Journal of Biomedical Optics*, 29(2), 020901. <https://doi.org/10.1117/1.JBO.29.2.020901>
10. Lee, K. C., Dretzke, J., Grover, L., Logan, A., & Moiemmen, N. (2016). A systematic review of objective burn scar measurements. *Burns & Trauma*, 4, 14. <https://doi.org/10.1186/s41038-016-0036-x>
 11. Hayavi-Haghighi, M. H., & Alipour, J. (2023). Applications, opportunities, and challenges in using Telehealth for burn injury management: A systematic review. *Burns*, 49, 1237–1248. <https://doi.org/10.1016/j.burns.2023.07.001>
 12. Owda, A. Y. (2022). Passive millimeter-wave imaging for burns diagnostics under dressing materials. *Sensors*, 22, 2428. <https://doi.org/10.3390/s22072428>
 13. Larxel. (2025). *Skin Burn Dataset: Images of different degrees of skin burn with YOLO labels*. Kaggle. Retrieved from <https://www.kaggle.com/datasets/larxel/skin-burn-dataset>
 14. Manzanera, M. P. A. (2022). *Design, implementation and evaluation of a deep learning prototype to classify non-pigmented malignant skin cancer from dermatoscopic images* [Master's thesis, Lund University]. LUP Student Papers. <https://lup.lub.lu.se/student-papers/record/9087860>
 15. Jahan, F., Khan, P. U., Sapkal, R., Vinod, V. C., & Mehetre, V. (2020). Biomedical image analysis and deep learning. *IOSR Journal of Dental and Medical Sciences*, 19(2), 32-36. <https://doi.org/10.9790/0853-1902153236>
 16. Serrano, C., Acha, B., & Sangwine, S. J. (2005). Colorimetric calibration of images of human skin captured under hospital conditions. In *AIC Colour 05-10th Congress of the International Colour Association* (pp. 773-776).
 17. Yadav, D. P., Sharma, A., Singh, M., & Goyal, A. (2019). Feature extraction based machine learning for human burn diagnosis from burn images. *IEEE Journal of Translational Engineering in Health and Medicine*, 7, 1–7. <https://doi.org/10.1109/JTEHM.2019.2923628>
 18. Cook, C. M., Howard, J. J., Rabbitt, L. R., Shuggi, I. M., Sirotin, Y. B., Tipton, J. L., & Vemury, A. R. (2025). Colorimetric skin tone scale for improved accuracy and reduced perceptual bias of human skin tone annotations. *Scientific Reports* (Submitted/Preprint).
 19. Herdiansyah, J., Putra, F. A. S., & Septiyanto, D. (2025). Implementation of Zhang's Camera Calibration Algorithm on a Single Camera for Accurate Pose

- Estimation Using ArUco Markers. *Journal of Fuzzy Systems and Control*, 2(3), 176–188. <https://doi.org/10.59247/jfsc.v2i3.256>
20. Alkhimova, S., & Davydovych, I. (2022). Accuracy assessment of marker recognition using ultra wide angle camera. *Technology Audit and Production Reserves*, 3(2(65)), 6–10. <https://doi.org/10.15587/2706-5448.2022.259068>
21. Muraviov, O. V. (2023). Lens image quality athermalization for infrared medical cameras. *Instrumentation Engineering, Electronics and Telecommunications*, 2023, 259–261.
22. Yadav, D. P., Sharma, A., Singh, M., & Goyal, A. (2019). Feature extraction based machine learning for human burn diagnosis from burn images. *IEEE Journal of Translational Engineering in Health and Medicine*, 7, 1–7. <https://doi.org/10.1109/JTEHM.2019.2923628>
23. Alzyoud, H. (2018). *Medical image segmentation and classification using deep learning*. *International Journal of Computer Science and Information Technologies*, 9, 5113.
24. Singla, N., Srivastava, V., & Mehta, D. S. (2018). In vivo classification of human skin burns using machine learning and quantitative features captured by optical coherence tomography. *Laser Physics Letters*, 15, 025601.
25. Suha, S. A., & Sanam, T. F. (2022). A deep convolutional neural network-based approach for detecting burn severity from skin burn images. *Machine Learning with Applications*, 9, 100371.
26. Vanheule, S. (2023). *Skin burn segmentation and depth classification using deep learning* [Master's thesis]. Ghent University.
27. Abubakar, A. (2020). *Burning Skin Detection System in Human Body*.
28. Şevik, U. (2019). Automatic classification of skin burn colour images using texture-based feature extraction. *IET Image Processing*.
29. Boissin, C. (2023). Automated skin burn detection and severity classification. *Scientific Reports*.

- 30.Методичні вказівки до виконання економічної частини магістерських кваліфікаційних робіт / Уклад. : В. О. Козловський, О. Й. Лесько, В. В. Кавецький. – Вінниця : ВНТУ, 2021. – 42 с.
- 31.Кавецький В. В. Економічне обґрунтування інноваційних рішень: практикум / В. В. Кавецький, В. О. Козловський, І. В. Причепка – Вінниця : ВНТУ, 2016. – 113 с.

ДОДАТОК А. Технічне завдання

Міністерство освіти і науки України
Вінницький національний технічний університет
Факультет інформаційних електронних систем
Кафедра біомедичної інженерії та оптико-електронних систем

ЗАТВЕРДЖУЮ

Завідувач кафедри БМІОЕС

доц., к.т.н. Л.Г. Коваль

30.09.

« »

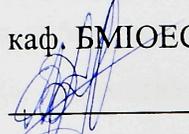
2025 р.

ТЕХНІЧНЕ ЗАВДАННЯ

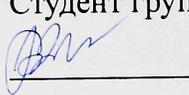
на виконання магістерської кваліфікаційної роботи
«Оптико-електронний детектор диму з мікропроцесорною обробкою в
багатоканальній протипожежній системі»

08-41.МКР.005.00.000 ТЗ

Науковий керівник: к.т.н., доцент
каф. БМІОЕС

 Кожем'яко А.В.

Студент групи ЛТО-24м

 Шершун А.В.

1. Підстава для виконання магістерської кваліфікаційної роботи (МКР)

1.1 Актуальність теми магістерської роботи обумовлена критичною потребою у швидкій та об'єктивній діагностиці термічних уражень в умовах воєнного стану та перевантаження медичної системи України. Традиційні методи візуальної оцінки опіків є суб'єктивними, а помилки у визначенні глибини ураження досягають 30–50%, що призводить до неправильної тактики лікування. У цьому контексті важливо підкреслити відсутність доступних інструментів для парамедиків та лікарів загальної практики, які дозволяли б проводити точний скринінг без дороговартісного обладнання. Тому мета даної роботи полягає у створенні автоматизованої системи підтримки прийняття рішень на базі смартфонів та штучного інтелекту. Актуальність теми полягає в необхідності інтеграції сучасних методів глибокого навчання та комп'ютерного зору в процеси медичної евакуації для забезпечення високої точності діагностики та оптимізації маршрутизації пацієнтів. Таким чином, тема роботи відповідає сучасним тенденціям розвитку телемедицини та є вагомим внеском у цифрову трансформацію військово-польової медицини.

1.2 Наказ про затвердження теми МКР № 313 від 24.09.2025 року.

2. Мета МКР і призначення розробки

2.1 Мета роботи полягає у підвищенні ефективності діагностики термічних уражень шкіри шляхом розробки інтелектуальної системи аналізу біомедичних зображень, що забезпечує автоматизовану класифікацію ступеня опіку та візуальну інтерпретацію результатів для підтримки прийняття рішень медичним персоналом.

Для досягнення поставленої мети потрібно виконати такі задачі:

- проаналізувати сучасні методи обробки біомедичних зображень та існуючі бази даних опікових уражень;

- обґрунтувати вибір колірних моделей та архітектури нейронних мереж для задач класифікації текстур шкіри;
- розробити алгоритмічне забезпечення для попередньої обробки, детекції рани (YOLO) та класифікації глибини ураження (DenseNet201);
- реалізувати модуль інтерпретації рішень (Grad-CAM) для візуалізації діагностичних ознак;
- виконати програмну реалізацію клієнт-серверної системи та провести експериментальне дослідження її точності.

2.2 Призначення розробки полягає у створенні доступного програмного засобу для експрес-діагностики опіків, який дозволяє автоматизувати процес сортування постраждалих, зменшити вплив людського фактора при оцінці травми та забезпечити дистанційну передачу верифікованих даних до спеціалізованих центрів.

3. Вихідні дані для виконання МКР

- інтелектуальна система автоматизованої діагностики та класифікації термічних уражень шкіри;
- вхідні дані у вигляді цифрових RGB-зображень, отриманих камерами мобільних пристроїв;
- каскадна архітектура нейронних мереж: детектор об'єктів (YOLO) та класифікатор (DenseNet201);
- алгоритм попередньої обробки з автоматичною локалізацією рани (ROI Extraction) та усуненням фонового шуму;
- математична модель представлення зображень у колірному просторі CIELAB;
- модуль візуальної інтерпретації прийняття рішень на базі алгоритму Grad-CAM;

- визначення геометричних параметрів та площі ураження з використанням калібрувальних маркерів (ArUco);
- клієнт-серверна архітектура системи з підтримкою телемедичного доступу;
- класифікація опіків за трьома ступенями тяжкості (поверхневі, часткові, глибокі);
- програмна реалізація мовою Python із використанням бібліотек TensorFlow та Keras.

4. Джерела розробки МКР

1. UN Human Rights Monitoring Mission in Ukraine. Report on the Human Rights Situation in Ukraine. United Nations, 2024.
2. Yadav D. P., et al. Feature extraction based machine learning for human burn diagnosis from burn images. *IEEE Journal of Translational Engineering in Health and Medicine*, 2019.
3. Wilson R. H., et al. Review of machine learning for optical imaging of burn wound severity assessment. *Journal of Biomedical Optics*, 2024.
4. Larxel. Skin Burn Dataset: Images of different degrees of skin burn with YOLO labels. Kaggle, 2024.
5. Herdiansyah J., et al. Implementation of Zhang's Camera Calibration Algorithm. *Journal of Fuzzy Systems and Control*, 2024.
6. Boissin C. Automated skin burn detection and severity classification. *Scientific Reports*, 2023.

5. Вимоги до виконання МКР

Головна вимога — розробка ефективної, точної та доступної у використанні програмної системи аналізу медичних зображень, яка забезпечує автоматизацію діагностичного процесу. Система повинна відповідати сучасним вимогам до медичного ПЗ, підтримувати роботу з зображеннями низької якості,

забезпечувати захищену передачу даних, мати інтуїтивно зрозумілий інтерфейс користувача, реалізовувати механізми пояснення рішень ШІ (Explainable AI) та функціонувати на загальнодоступних мобільних пристроях.

6. Етапи МКР та очікувані результати

Етапи роботи та очікувані результати приведено в таблиці А.1.

Таблиця А.1 — Етапи МКР

№ етапу	Назва етапу	Термін виконання (початок)	Термін виконання (кінець)	Очікувані результати
1	Розробка, погодження та затвердження технічного завдання	17.09.2025	20.09.2025	Розроблене ТЗ
2	Аналіз методів та засобів інтелектуального аналізу біомедичних зображень	20.09.2025	10.10.2025	Розділ 1
3	Математичне моделювання та розробка алгоритмічного забезпечення системи діагностики	10.10.2025	23.10.2025	Розділ 2
4	Програмна реалізація та експериментальне дослідження системи	23.10.2025	09.11.2025	Розділ 3
5	Оформлення результатів дослідження, аналіз ефективності	09.11.2025	20.11.2025	Висновки
6	Розробка економічного обґрунтування (стартап-проект)	20.11.2025	29.11.2025	Економічний розділ
7	Підготовка МКР до публічного захисту	01.12.2025	10.12.2025	МКР

7. Матеріали, що подаються до захисту МКР

До захисту подаються: пояснювальна записка МКР, графічні і ілюстративні матеріали (презентація), протокол попереднього захисту МКР на

кафедрі, відгук наукового керівника, відгук опонента, протоколи складання державних екзаменів, анотації до МКР українською та іноземною мовами.

8. Порядок контролю виконання та захисту МКР

Виконання етапів графічної та розрахункової документації МКР контролюється науковим керівником згідно зі встановленими термінами. Захист МКР відбувається на засіданні Екзаменаційної комісії, затвердженої наказом ректора.

9. Вимоги до оформлювання та порядок виконання МКР

9.1 При оформлюванні МКР використовуються:

- ДСТУ 3008: 2015 «Звіти в сфері науки і техніки. Структура та правила оформлювання»;
- ДСТУ 8302: 2015 «Бібліографічні посилання. Загальні положення та правила складання»;
- ГОСТ 2.104-2006 «Єдина система конструкторської документації. Основні написи»;
- методичні вказівки до виконання магістерських кваліфікаційних робіт;
- документи, на які посилаються у вищевказаних стандартах.

9.2 Порядок виконання МКР викладено в «Положення про кваліфікаційні роботи на другому (магістерському) рівні вищої освіти СУЯ ВНТУ-03.02.02-П.001.01:21».

9.3 У зв'язку з тим, що інформація не є конфіденційною, заходи з її публічного захисту не передбачаються.

Додаток Б
(обов'язковий)
ПРОТОКОЛ ПЕРЕВІРКИ КВАЛІФІКАЦІЙНОЇ РОБОТИ

Назва роботи: «Інтелектуальна система вимірювання та аналізу параметрів медичних зображень»
Тип роботи: магістерська кваліфікаційна робота
Підрозділ: кафедра БМІОЕС, факультет ІЕС, ЛТО- 24м

Коефіцієнт подібності текстових запозичень, виявлених у роботі системою StrikePlagiarism (КПІ) 3 %

Висновок що до перевірки кваліфікаційної роботи (відмітити потрібне)

Запозичення, виявлені у роботі, є законними і не містять ознак плагіату, фабрикації, фальсифікації. Роботу прийняти до захисту

У роботі не виявлено ознак плагіату, фабрикації, фальсифікації, але надмірна кількість текстових запозичень та/або наявність типових розрахунків не дозволяють прийняти рішення про оригінальність та самостійність її виконання. Роботу направити на доопрацювання.

У роботі виявлено ознаки академічного плагіату та/або в ній містяться навмисні спотворення тексту, що вказують на спроби приховування недобросовісних запозичень. Робота до захисту не приймається.

Експертна комісія:

Коваль Л.Г., завідувач каф.БМІОЕС

Заболотна Н.І., проф. каф. БМІОЕС

Особа, відповідальна за перевірку СЗ

Тужанський С.Є.

З висновком експертної комісії знайомлений:

Керівник [підпис]

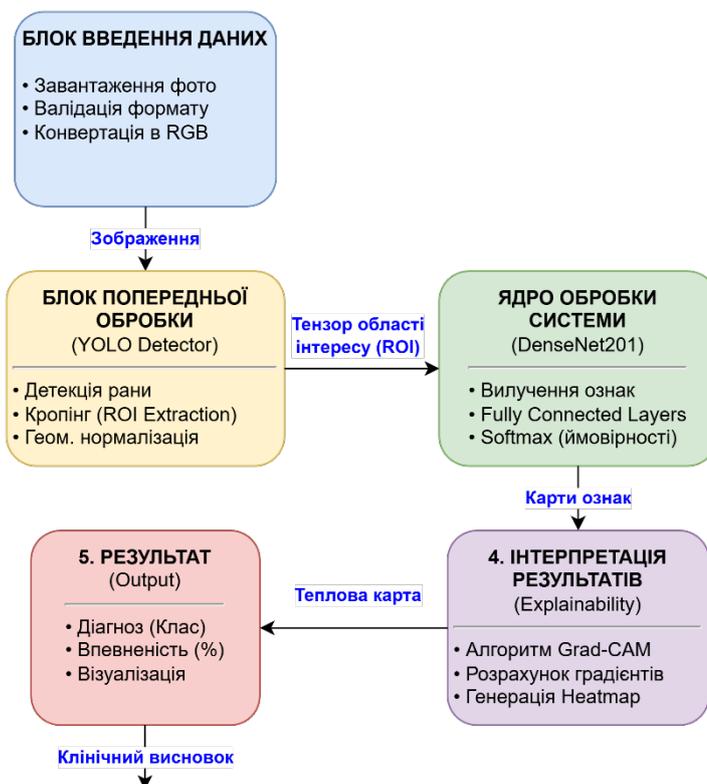
Кожем'яко А.В., доц. каф. БМІОЕС

Здобувач [підпис]

Шершун А. В.

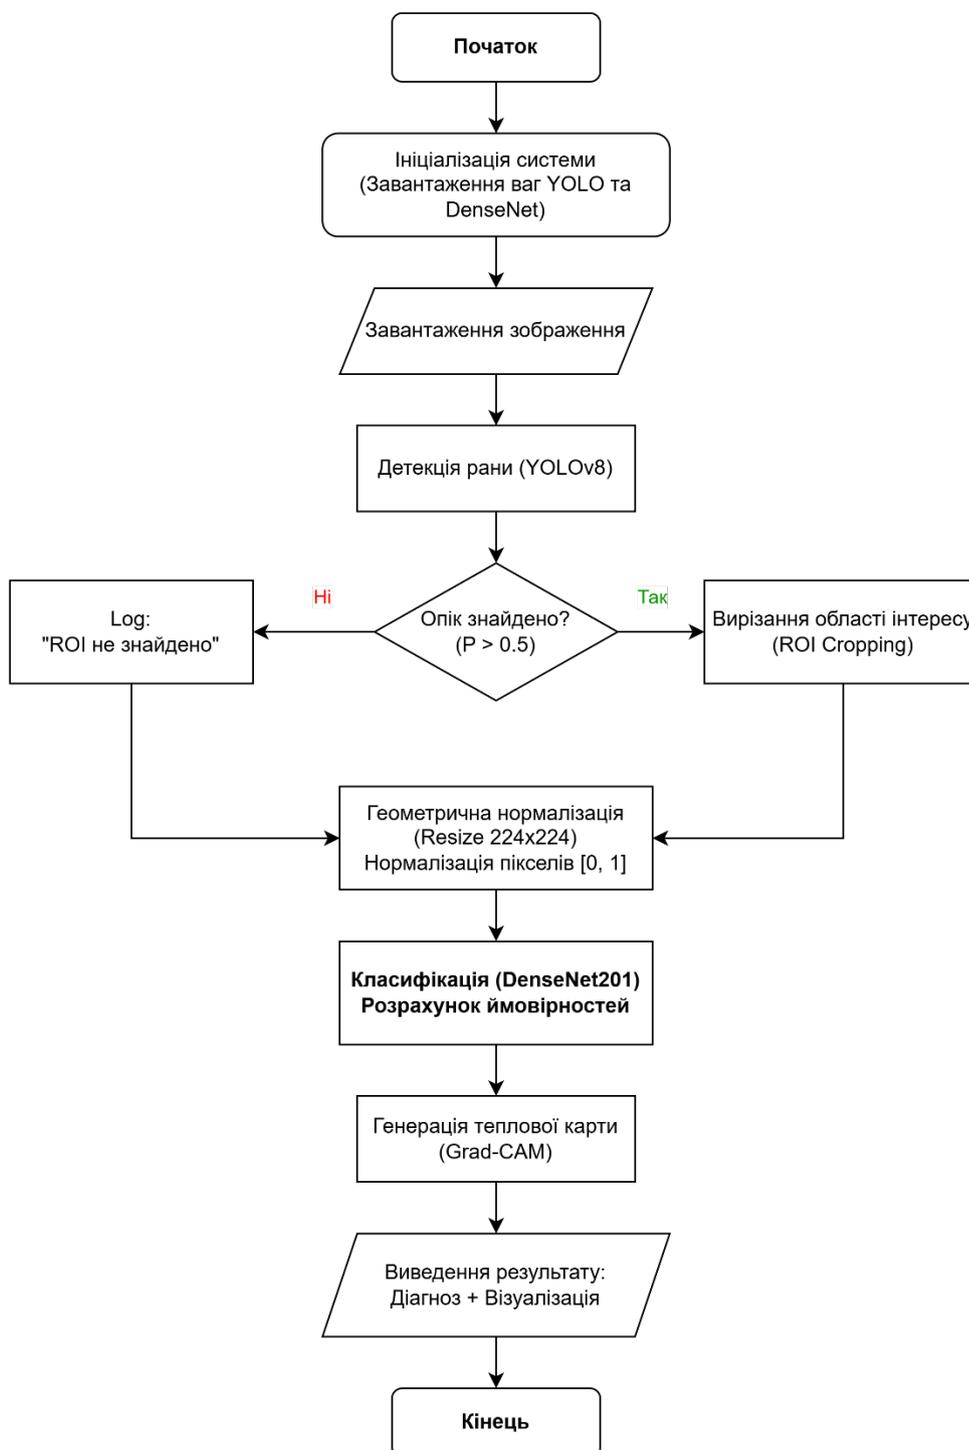
ДОДАТОК В. ІЛЮСТРАТИВНА ЧАСТИНА

ДОДАТОК В.1

Структурна схема програмного комплексу інтелектуальної діагностики
термічних уражень

ДОДАТОК В.2

Блок-схема алгоритму роботи системи діагностики



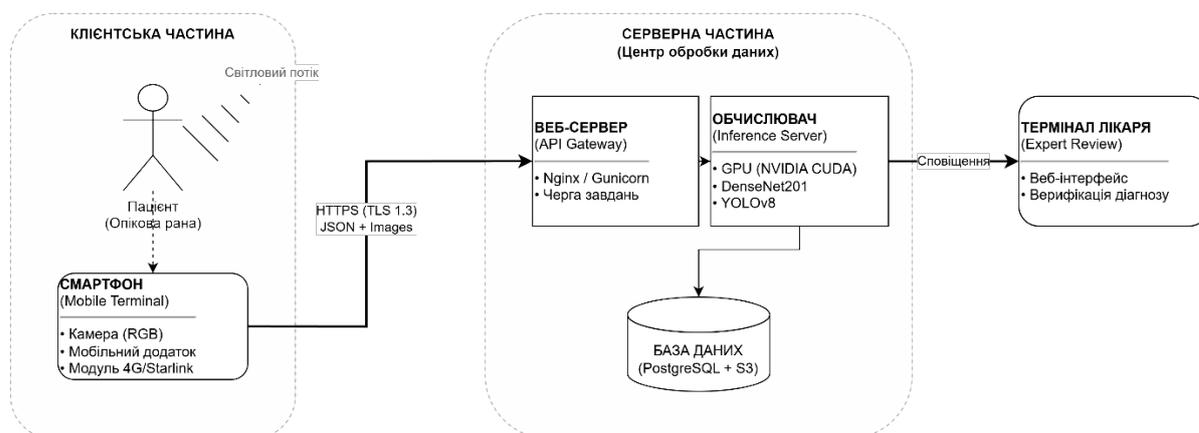
ДОДАТОК В.3

Блок–схема алгоритму внутрішньої обробки модуля детекції YOLO



ДОДАТОК В.4

Структурна схема апаратної реалізації системи діагностики опіків



ДОДАТОК Г

Код програми тренування нейромережі

```
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.applications import DenseNet201
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, GlobalAveragePooling2D, Dropout,
Flatten
from tensorflow.keras.optimizers import Adam
import numpy as np
import os
import random

IMG_WIDTH, IMG_HEIGHT = 224, 224
BATCH_SIZE = 32
LEARNING_RATE = 0.0001
EPOCHS = 40
NUM_CLASSES = 3 # 1-й, 2-й, 3-й ступінь опіку

BASE_DIR = 'dataset_for_densenet/train'
tf.random.set_seed(42)
np.random.seed(42)
random.seed(42)

# Аугментація
train_datagen = ImageDataGenerator(
    rescale=1./255,
    validation_split=0.15, # Виділяємо 15% даних для валідації (як у роботі)
    rotation_range=60,
```

```
horizontal_flip=True,
vertical_flip=True,
width_shift_range=0.2,
height_shift_range=0.2,
fill_mode='nearest'
)
# Генератор для тренувальних даних
train_generator = train_datagen.flow_from_directory(
    BASE_DIR,
    target_size=(IMG_WIDTH, IMG_HEIGHT),
    batch_size=BATCH_SIZE,
    class_mode='categorical',
    subset='training'
)

# Генератор для валідаційних даних
validation_generator = train_datagen.flow_from_directory(
    BASE_DIR,
    target_size=(IMG_WIDTH, IMG_HEIGHT),
    batch_size=BATCH_SIZE,
    class_mode='categorical',
    subset='validation'
)
base_model = DenseNet201(
    weights='imagenet',
    include_top=False, # Виключено оригінальні шари класифікації
    input_shape=(IMG_WIDTH, IMG_HEIGHT, 3)
)
base_model.trainable = False
```

```
x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Flatten()(x)

x = Dense(512, activation='relu')(x)
x = Dropout(0.5)(x)
x = Dense(256, activation='relu')(x)
x = Dropout(0.5)(x)
x = Dense(128, activation='relu')(x)
x = Dropout(0.5)(x)

# Фінальний шар передбачення (3 класи опіків)
predictions = Dense(NUM_CLASSES, activation='softmax')(x)

model = Model(inputs=base_model.input, outputs=predictions)

model.compile(
    optimizer=Adam(learning_rate=LEARNING_RATE),
    loss='categorical_crossentropy',
    # Використовуємо метрики з роботи: Accuracy, Precision, Recall
    metrics=['accuracy',      tf.keras.metrics.Precision(name='precision'),
            tf.keras.metrics.Recall(name='recall')]
)

print(model.summary())
print("\n--- Початок навчання на обрізаних зображеннях опіків ---")

from tensorflow.keras.callbacks import ModelCheckpoint, EarlyStopping
```

```

'best_burn_model.h5', # Назва файлу для збереження
monitor='val_loss',
mode='min',
save_best_only=True, # Зберігати ТІЛЬКИ найкращу версію
verbose=1
)
early_stopping = EarlyStopping(
    monitor='val_loss',
    mode='min',
    patience=10,
    verbose=1
)

callback_list = [checkpoint, early_stopping]

history = model.fit(
    train_generator,
    epochs=EPOCHS,
    validation_data=validation_generator,
    callbacks=callback_list # <-- Додаємо список колбеків тут!
)

# Збереження моделі для подальшого аналізу та Grad-CAM
model.save('burn_classification_densenet_final.h5')
print("\n***      Навчання      завершено.      Модель      збережено      як
burn_classification_densenet_final.h5 ***")

```

ДОДАТОК Д

Код програми класифікації опіків

```
import numpy as np
import tensorflow as tf
from tensorflow.keras.models import load_model
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from sklearn.metrics import classification_report, confusion_matrix
import matplotlib.pyplot as plt
import seaborn as sns

# НАЛАШТУВАННЯ
IMG_WIDTH, IMG_HEIGHT = 224, 224
BATCH_SIZE = 32
DATA_DIR = 'dataset_for_densenet/train'
MODEL_PATH = 'burn_classification_densenet_final.h5'

# 1. Завантаження навченої моделі
print("Завантаження моделі...")
model = load_model(MODEL_PATH)

val_datagen = ImageDataGenerator(rescale=1./255, validation_split=0.15)

val_generator = val_datagen.flow_from_directory(
    DATA_DIR,
    target_size=(IMG_WIDTH, IMG_HEIGHT),
    batch_size=BATCH_SIZE,
    class_mode='categorical',
    subset='validation',
    shuffle=False
```

)

3. Отримання прогнозів

```
print("Виконується прогнозування...")
```

```
Y_pred = model.predict(val_generator, verbose=1)
```

```
y_pred = np.argmax(Y_pred, axis=1) # Конвертуємо ймовірності в номер класу
```

4. Побудова Матриці

```
print("Побудова графіків...")
```

```
cm = confusion_matrix(val_generator.classes, y_pred)
```

```
target_names = list(val_generator.class_indices.keys())
```

Візуалізація

```
plt.figure(figsize=(10, 8))
```

```
sns.heatmap(cm, annot=True, fmt='d', cmap='Blues', xticklabels=target_names,
yticklabels=target_names)
```

```
plt.ylabel('Справжній клас')
```

```
plt.xlabel('Передбачений клас')
```

```
plt.title('Матриця плутанини (Confusion Matrix)')
```

```
plt.show()
```

5. Текстовий звіт (Precision, Recall, F1-score)

```
print("\nЗвіт класифікації:")
```

```
print(classification_report(val_generator.classes, y_pred,
target_names=target_names))
```