


КВАЛІФІКАЦІЙНА РОБОТА

на тему Метод визначення кольоротипу зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу


Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань

Спеціальність 122 – Комп'ютерні науки
Шифр і назва спеціальності

Освітня програма Комп'ютерні науки
Назва освітньої програми

Виконала: студентка групи КН-22-2  Юлія БЕКЕШКО
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

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

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

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

15 червня 2026 р.

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ

Факультет інформаційних технологій

Кафедра комп'ютерних наук

Освітній ступінь бакалавр

Галузь знань 12 – Інформаційні технології

Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ

Завідувач кафедри комп'ютерних наук

(підпис)

д.т.н., професор Олександр БАРМАК

«22» січня 2026 року

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ БАКАЛАВРА**

1. Тема кваліфікаційної роботи бакалавра: «Метод визначення кольоротипу зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу»

2. Завдання видано студентці Юлії Бекешико
(ім'я, прізвище)

3. Керівник роботи доцент кафедри КН Руслан Багрії
(посада, ім'я, прізвище)

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

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

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

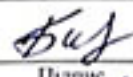
Метою роботи є підвищення точності класифікації сезонного кольоротипу зовнішності людини шляхом розробки нейромережевого методу комп'ютерного зору для генерації персоналізованої рекомендації візуального образу. Досягнення мети передбачає комплексний аналіз предметної області, підготовку наборів даних, проєктування гібридних нейромережевих моделей та їх програмну реалізацію у вигляді експериментального застосування. Працездатність розробленого методу має бути підтверджена результатами експериментального тестування за визначеними метриками оцінювання.

7. Календарний план виконання кваліфікаційної роботи бакалавра:

№	Назва етапів (розділів) кваліфікаційної роботи бакалавра	Термін виконання	Примітка
1	Вибір напрямку дослідження та узгодження теми кваліфікаційної роботи з керівником, складання календарного графіка виконання	січень 2026	виконано
2	Ознайомлення з предметною областю, формулювання мети і задач дослідження, визначення об'єкта та предмета дослідження	лютий 2026	виконано
3	Проектування методу розв'язання задачі, опис архітектурних рішень, розроблення математичних моделей та алгоритмів.	березень 2026	виконано
4	Обґрунтування інструментарію розробки, програмна реалізація розробленого методу, проведення експериментального тестування та оцінювання ефективності.	квітень 2026	виконано
5	Написання тексту кваліфікаційної роботи, урахування зауважень керівника, оформлення згідно з вимогами	травень 2026	виконано
6	Розроблення презентаційних матеріалів та попередній захист кваліфікаційної роботи	травень 2026	виконано
7	Отримання відгуку керівника, рецензії, перевірка тексту кваліфікаційної роботи на плагіат, нормоконтроль	червень 2026	виконано
8	Підготовка до захисту та захист кваліфікаційної роботи	червень 2026	виконано

Виконавець: студентка групи КН-22-2

Група виконавця



Підпис

Юлія БЕКЕШКО

Ім'я, ПРІЗВИЩЕ

Керівник:

к.т.н., доц. каф. КН

Науковий ступінь, посада



Підпис

Руслан БАГРІЙ

Ім'я, ПРІЗВИЩЕ

Анотація

Тема кваліфікаційної роботи бакалавра: «Метод визначення кольоротипу зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу»

Виконавець кваліфікаційної роботи бакалавра: студентка групи КН-22-2 Юлія Бекешко

Керівник кваліфікаційної роботи бакалавра: к.т.н., доцент кафедри КН Руслан Багрії

Кваліфікаційна робота бакалавра містить:

Пояснювальна записка				Кількість додатків
Сторінок	Рисунків	Таблиць	Джерел інформації	
71	25	11	48	3

Метою роботи є підвищення точності класифікації сезонного кольоротипу зовнішності людини шляхом розробки нейромережевого методу комп'ютерного зору для генерації персоналізованої рекомендації візуального образу.

Для досягнення мети запропоновано двохетапний підхід, що поєднує семантичну сегментацію обличчя на базі U-Net, нормалізацію освітлення, екстракцію ознак у просторі CIELAB та мультимодальну класифікацію за допомогою ResNet-18 і MLP з механізмом Gated Attention. Метод програмно реалізовано у вигляді вебзастосунку на базі Streamlit. Практичне значення полягає в автоматизації колористичного аналізу для усунення суб'єктивного фактора людського сприйняття. Система забезпечує генерацію індивідуальних HEX-палітр на основі бази знань JSON. Експериментальне тестування підтвердило ефективність рішення: показник Ассюрасу досяг 91%.

Ключові слова: комп'ютерний зір, кольоротип зовнішності, семантична сегментація, мультимодальний аналіз, гібридні нейромережі, екстракція ознак

Виконавець: студентка групи КН-22-2

Група виконавця


Підпис

Юлія БЕКЕШКО

Ім'я, ПРІЗВИЩЕ

Зміст

Перелік скорочень	4
Вступ.....	6
Розділ 1 Характеристика предметної області: аналіз моделей, методів та реалізацій.....	8
1.1 Аналіз предметної області	8
1.2 Огляд методів та алгоритмів комп'ютерного зору для задач класифікації візуальних ознак зовнішності	9
1.3 Аналіз нейромережових архітектур для задач сегментації та класифікації зображень	14
1.4 Аналіз існуючих програмних засобів	17
1.5 Мета та завдання дослідження	19
Розділ 2 Розробка методу визначення кольоротипу зовнішності людини засобами комп'ютерного зору.....	20
2.1 Загальна концепція та структурна схема методу.....	20
2.2 Проектування нейромережових моделей семантичної сегментації та класифікації	23
2.2.1 Архітектура моделі семантичної сегментації U-Net	23
2.2.2 Архітектура гібридної моделі класифікації на базі ResNet-18 та MLP..	26
2.3 Математична формалізація екстракції та нормалізації колірних ознак	28
2.4 Формування наборів даних для навчання та валідації.....	32
2.4.1 Набір даних для навчання моделі семантичної сегментації.....	32
2.4.2 Спеціалізований набір даних для класифікації кольоротипів.....	35
2.5 Метрики оцінювання якості та точності нейромережових моделей	37
2.6 Висновки до розділу 2	41
Розділ 3 Програмна реалізація та експериментальне дослідження методу	43
3.1 Засоби програмної реалізації та опис застосунку.....	43
3.2 Експериментальне дослідження алгоритмів підготовки даних та навчання моделей.....	46
3.2.1 Алгоритмічна фільтрація навчальної вибірки та усунення аномалій ...	46
3.2.2 Оцінка процесу навчання моделі семантичної сегментації.....	52
3.2.3 Оцінка процесу навчання гібридної моделі класифікації.....	55

3.3 Тестування методу та оцінка результатів класифікації	58
3.4 Генерація персоналізованих рекомендацій візуального образу.....	61
3.5 Висновки до розділу 3	63
Загальні висновки.....	65
Перелік посилань.....	67
Додатки	

Перелік скорочень

Скорочення, термін, позначення	Пояснення
ШІ	Штучний інтелект
RGB	Red, Green, Blue (апаратно-залежна адитивна колірна модель)
HSV	Hue, Saturation, Value (колірна модель, що описує відтінок, насиченість та яскравість)
YCbCr	Колірна модель, де Y – яскравість, а Cb і Cr – синя та червона кольорорізнєві компоненти
SVM	Support Vector Machine (метод опорних векторів, алгоритм машинного навчання)
UCI	University of California, Irvine (міжнародний академічний репозиторій наборів даних для машинного навчання)
ISIC	International Skin Imaging Collaboration (міжнародний архів стандартизованих медичних зображень шкіри)
RGB-YHS	Комбінований ознаковий колірний простір, що поєднує параметри RGB та YHS (яскравість, відтінок, насиченість)
IHLS	Improved Hue, Luminance, and Saturation (вдосконалена колірна модель відтінку, яскравості та насиченості)
CNN	Convolutional Neural Network (згорткова нейронна мережа)
F1-score	F-міра (гармонійне середнє значення між показниками влучності та повноти класифікації)

ResNet	Residual Network (архітектура глибокої згорткової нейронної мережі із залишковими зв'язками)
U-Net	Архітектура згорткової нейронної мережі, орієнтована на задачі прецизійної семантичної сегментації
IoU	Intersection over Union (метрика перетину по об'єднанню для оцінки загальної якості просторової сегментації)
CIELAB (LAB)	Перцептивно рівномірний колірний простір, розроблений Міжнародною комісією з освітлення (CIE Lab*)
MST	Monk Skin Tone (10-бальна шкала відтінків шкіри, розроблена для оцінки алгоритмічного зміщення III)
bIoU	Boundary Intersection over Union (метрика перетину по об'єднанню для оцінки точності меж сегментації)
MLP	Multi-Layer Perceptron (багатошаровий перцептрон, клас штучних нейронних мереж прямого поширення)
HEX	Hexadecimal (шістнадцятковий формат представлення кольору в комп'ютерній графіці)
JSON	JavaScript Object Notation (структурований текстовий формат зберігання та обміну даними)
SMP	Segmentation Models PyTorch (бібліотека високого рівня для побудови моделей сегментації)
OpenCV	Open Source Computer Vision Library (відкрита бібліотека алгоритмів комп'ютерного зору)
ReLU	Rectified Linear Unit (нелінійна функція активації штучних нейронів)

Вступ

Актуальність теми. Стрімкий розвиток інформаційних технологій та впровадження систем штучного інтелекту змінюють підходи до надання послуг в індустрії моди та краси. Дослідження у цій галузі доводять, що гармонія кольорів є ключовим фактором при формуванні індивідуального візуального образу. Основою для такого підбору є визначення кольоротипу зовнішності людини. Сучасна індустрія дедалі більше потребує об'єктивних, математично обґрунтованих методів для автоматизації процесів, які традиційно спиралися виключно на суб'єктивну інтуїцію стилістів та дизайнерів.

Традиційні методи визначення кольоротипу, засновані на ручному візуальному аналізі, є надзвичайно трудомісткими. Крім того, вони критично залежать від суб'єктивного сприйняття експерта, його досвіду та зовнішніх умов, зокрема характеристик освітлення під час оцінки. Водночас наявні на ринку програмні рішення часто не враховують складні взаємозв'язки між відтінками шкіри, волосся та очей, вимагають ручного виділення ознак або працюють з недостатньою точністю класифікації.

Таким чином, виникає чітке протиріччя між зростаючою потребою в об'єктивній класифікації візуальних ознак людини та відсутністю доступних, стійких до зовнішніх факторів автоматизованих засобів для її проведення. З огляду на це, розробка спеціалізованого методу на основі сучасних алгоритмів комп'ютерного зору та глибокого навчання є актуальним завданням, що дозволить усунути вплив людського фактора та підвищити загальну якість персоналізованих рекомендацій.

Об'єкт дослідження – процес автоматизованого визначення кольоротипу зовнішності людини.

Предмет дослідження – методи глибокого навчання та алгоритми комп'ютерного зору для розпізнавання і класифікації візуальних ознак зовнішності.

Мета роботи – підвищення точності класифікації сезонного кольоротипу зовнішності людини шляхом розробки нейромережевого методу комп'ютерного зору для генерації персоналізованої рекомендації візуального образу.

Завдання кваліфікаційної роботи бакалавра:

- провести комплексний аналіз предметної області та сучасного стану технологій комп'ютерного зору для автоматизації колористичного аналізу;
- розробити метод визначення кольоротипу зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу;
- виконати підготовку та попередню обробку наборів даних для забезпечення коректного навчання нейромережевих моделей;
- розробити програмну реалізацію експериментального застосунку запропонованого методу;
- провести експериментальне тестування розробленого методу за визначеними метриками оцінювання.

Практичне значення одержаних результатів полягає у розробці цільового методу та створенні на його основі програмного експериментального застосунку, який здатний автоматизувати процес колористичного аналізу зовнішності.

Запропонований інструментарій дозволяє фахівцям індустрії моди та краси оперативно отримувати об'єктивні дані для генерації індивідуальних колірних палітр та формування персоналізованих рекомендацій візуального образу, виключаючи вплив суб'єктивного людського фактора.

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

1.1 Аналіз предметної області

Предметною областю в рамках дослідження є процес алгоритмізації колористики, що полягає у переведенні абстрактних художніх та естетичних категорій у точні вимірювані параметри цифрових зображень. Основним джерелом вхідних даних для вирішення цієї задачі є растрові зображення обличчя людини. Специфіка роботи з такими даними полягає в тому, що піксельне представлення пігменту шкіри, волосся та очей на фотографії критично залежить від зовнішніх умов. Відповідно, для автоматизації обробки візуальних ознак обличчя необхідна стандартизована теоретична база класифікації.

Теоретичною основою є 4-сезонна система класифікації зовнішності. Незважаючи на популярність в індустрії моди розширених 12-сезонних моделей, деталізація на 12 підтипів створює надмірну візуальну схожість між суміжними класами (наприклад, суміжними м'якими або світлими типами), межі між якими є розмитими та залежать від особистого сприйняття експерта [1, 2]. Натомість базова 4-сезонна система спирається на чіткі, макрохарактеристики зовнішності – домінуючу температуру та рівень контрасту. Тому для переходу від суб'єктивних оцінок до об'єктивних параметрів саме 4-сезонна модель є найбільш надійним стандартом. Ключові особливості цієї системи систематизовано у таблиці 1.1.

Таблиця 1.1 – 4-сезонна система класифікації зовнішності

Цільовий клас	Температура зовнішності	Рівень контрасту	Ключова характеристика
Весна	Тепла	Низький/середній	Чисті, світлі та теплі фарби без різких переходів.
Літо	Холодна	Низький	Приглушеність, м'якість ліній, низька чистота кольору.
Осінь	Тепла	Середній/низький	Глибокі, насичені, але приглушені відтінки.
Зима	Холодна	Високий	Яскравий контраст між шкірою, волоссям та білками очей.

Традиційне ручне визначення кольоротипу має високу похибку через суб'єктивність людського ока та залежність від зовнішнього освітлення.

Температура джерела світла здатна змінити сприйняття підтону шкіри на фотографії, а тіні створюють хибний рівень контрастності [3]. Тому для автоматизації процесу теорію необхідно розглядати як формалізовану задачу багатокласової класифікації з визначеними класами та числовими атрибутами.

Для забезпечення подальшої машинної обробки характеристики трансформуються у вимірювані параметри. Першим ключовим атрибутом є температура підтону, що визначає домінування теплого або холодного колірному простору. Другим параметром виступає світлота, яка обчислюється через канал абсолютної яскравості пікселів. Третім обов'язковим атрибутом є контрастність, що є математичною різницею рівнів яскравості між різними сегментованими зонами обличчя [4, 5]. Опис цільових класів через їхні параметричні значення наведено у таблиці 1.2.

Таблиця 1.2 – Опис цільових класів через колориметричні параметри

Цільовий клас	Температура підтону	Значення світлоти	Рівень контрастності
Весна	Домінування теплого спектра	Високий рівень	Середній
Літо	Домінування холодного спектра	Високий рівень	Низький
Осінь	Домінування теплого спектра	Низький рівень	Низький
Зима	Домінування холодного спектра	Варіативний	Максимальний контраст

Таким чином, досліджувана предметна область спирається на базові естетичні орієнтири і супроводжується значною складністю об'єктивного вилучення ознак із цифрових зображень через оптичні спотворення та вплив освітлення [4, 5]. При розробці методу наведені характеристики вимагають обов'язкової математичної формалізації – трансформації у цифрові діапазони та метричні відстані. Це зумовлює об'єктивну необхідність застосування методів комп'ютерного зору для підвищення точності, усунення суб'єктивного фактора та надійної ідентифікації візуальних ознак обличчя.

1.2 Огляд методів та алгоритмів комп'ютерного зору для задач класифікації візуальних ознак зовнішності

Для автоматизованого визначення кольоротипу та класифікації візуальних ознак людини застосовують алгоритмічні підходи, які доцільно розділити на три логічні групи: евристичні та геометричні методи, класичне машинне навчання та глибоке навчання.

Першими для розв'язання задач колористичного аналізу використовувалися евристичні алгоритми, що базуються на фіксованих математичних правилах. Одним із таких підходів є порогова сегментація пікселів шкіри з використанням колірних просторів RGB, HSV та YCbCr [6]. Алгоритм визначає належність пікселів до шкіри шляхом перевірки їх відповідності заданим діапазнам значень, що дозволяє ефективно відокремлювати обличчя від фону. Приклад результату сегментації наведено на рисунку 1.1.



Рисунок 1.1 – Результати порогової сегментації пікселів шкіри [6].

Незважаючи на простоту та високу швидкість, порогові методи мають суттєві обмеження, зокрема чутливість до змін освітлення, колірної температури та наявності тіней. Для підвищення адаптивності запропоновано використання систем нечіткої логіки, у яких колористичні характеристики описуються через функції належності. Практичне застосування цієї моделі на основі 32 нечітких правил, сформованих за участю експертів, дозволило досягти точності класифікації близько 80% під час тестування на базі даних UCI [7]. Однак необхідність ручного налаштування правил і параметрів значно ускладнює масштабування цього підходу для задач детальної класифікації зовнішності.

Подальший розвиток отримали методи класичного машинного навчання. Зокрема, для виділення домінантних ділянок шкіри та відокремлення обличчя від фону широко застосовується алгоритм просторової кластеризації K-means [8]. У поєднанні з класифікатором SVM підхід досягнув чутливості 95,0% та загальної

точності 97,1% під час тестування на базі даних ISIC. Кластеризація здійснювалася шляхом групування пікселів оригінального зображення у колірному просторі YCbCr [8]. Незважаючи на високу здатність до ізоляції шкіри, алгоритм залишається чутливим до візуального шуму від освітлення, що вимагає застосування медіанних фільтрів для очищення меж і суттєво знижує швидкодію системи.

Для задач класифікації отриманих ознак широко використовується алгоритм опорних векторів. Алгоритм досягнув точності 89,86% під час тестування на наборі даних Schmugge, що включає 846 зображень осіб різного віку, статі та расових груп. Навчання здійснювалося на вибірці з 16564 пікселів із використанням нелінійного гауссового ядра та вектора ознак RGB-YHS, який поєднує параметри кількох колірних просторів [9]. Незважаючи на високу точність, SVM залишається чутливим до складних умов освітлення та викривлень ознак, що знижує його ефективність при роботі з реальними зображеннями.

Іншим підходом є використання ансамблевих методів, зокрема Random Forest. Алгоритм тестувався на вибірці з 8991 зображення у колірному просторі IHLS, де він досяг точності сегментації пікселів шкіри на рівні 87,7% [10].

Приклад результату сегментації наведено на рисунку 1.2.



Рисунок 1.2 – Результат сегментації пікселів шкіри алгоритмом Random Forest: (a) оригінальне зображення, (b) виділені цільові регіони [10].

Перевагою Random Forest є висока здатність до узагальнення та стійкість до перенавчання. Водночас аналіз кожного пікселя окремо без урахування

просторового контексту призводить до появи хибних спрацювань на фонових об'єктах із подібними кольорами, що обмежує точність методу.

Найбільш перспективним напрямом є використання методів глибокого навчання. Згорткові нейронні мережі здатні автоматично вилучати як колірні, так і просторові ознаки безпосередньо із зображень обличчя. Ефективність такого підходу доведено на прикладі архітектури EfficientNetV0, яка використовується для класифікації тону шкіри з метою персоналізованого підбору макіяжу та одягу [11]. Відповідно до умов експерименту, модель навчалася на збалансованому наборі з 1500 зображень облич із застосуванням крос-валідації. Алгоритм досягнув загальної точності на рівні 88,67%, при цьому для світлого типу шкіри показник F1-міри склав 0,94 [11]. Приклад роботи такої рекомендаційної системи наведено на рисунку 1.3.




Рисунок 1.3 – Приклад роботи CNN для класифікації тону шкіри та рекомендації макіяжу [11]

Незважаючи на високу точність класифікації базового тону, стандартні CNN-моделі мають обмеження при задачах точної піксельної сегментації складних зон обличчя, що потребує інтеграції спеціалізованих архітектур.

Більш глибокою та ефективною архітектурою є ResNet, яка забезпечує підвищену якість класифікації завдяки залишковим зв'язкам. Їхня ідея полягає у прямій передачі сигналу до наступних шарів, що запобігає згасанню градієнта та стабілізує навчання глибоких мереж. Завдяки цьому модель ефективно вилучає складні багаторівневі ознаки, зокрема тонкі відмінності у відтінках шкіри та мікrokонтрастах зовнішності. Під час експериментального порівняння на наборі з

3297 зображень ResNet продемонструвала найкращий баланс точності – 91,21% та узагальнювальної здатності [12]. Водночас модель залишається чутливою до шуму та складного фону, що зумовлює необхідність попереднього етапу сегментації для підвищення якості класифікації.

Для точної локалізації об'єктів використовується архітектура U-Net, яка спеціалізується на семантичній сегментації. Її симетрична енкодер-декодерна структура забезпечує поступове вилучення ознак із подальшим відновленням просторової роздільної здатності для формування сегментаційної карти. Ключовою особливістю мережі є пропускні зв'язки між відповідними рівнями енкодера та декодера, що дозволяє зберігати детальну просторову інформацію. Завдяки цьому U-Net забезпечує високу точність виділення меж навіть за умов розмитих контурів чи складного освітлення, досягаючи показника IoU близько 92% [13]. Отримані маски доцільно використовувати як етап попередньої обробки перед класифікацією, що мінімізує вплив фону та підвищує загальну точність системи.

Порівняльну характеристику розглянутих алгоритмів та методів наведено в таблиці 1.3.

Таблиця 1.3 – Порівняльний аналіз методів та алгоритмів класифікації візуальних ознак

Клас методів	Алгоритм / Підхід	Точність	Головні переваги	Ключові недоліки та обмеження
Евристичні методи	Порогова сегментація	Н/Д	Висока швидкість; компенсація недоліків кольорних просторів.	Жорсткі межі; висока вразливість до тіней та температури світла.
	Нечітка логіка	~ 80,0%	Гнучкість прийняття рішень завдяки функціям належності.	Ручне налаштування; низька масштабованість.
Машинне навчання	K-means	Н/Д	Швидке базове відокремлення цільових об'єктів від фону.	Залишковий шум; необхідність складної постобробки.
	SVM	89,86%	Ефективне просторове розділення класів нелінійними ядрами.	Лише піксельний аналіз; вразливість до інтенсивних тіней.
	Random Forest	87,70%	Висока здатність до узагальнення.	Хибні спрацювання на елементах фону.
Глибоке навчання	ResNet	91,21%	Точний аналіз мікροконтрастів.	Зміщення уваги без попередньої сегментації.

	U-Net	IoU ~ 92%	Ідеальна локалізація контурів; стабільність при розмитих межах.	Виконує лише сегментацію.
--	-------	--------------	---	---------------------------

Отже, проведений огляд свідчить, що жоден ізольований алгоритм не забезпечує необхідної точності колористичного аналізу через вразливість до змін освітлення або втрату просторового контексту. Найбільш ефективним рішенням є застосування ансамблевого підходу. Інтеграція мережі U-Net для семантичної сегментації та моделі ResNet для фінальної класифікації відтінків дозволяє взаємно нівелювати їхні недоліки.

1.3 Аналіз неймережевих архітектур для задач сегментації та класифікації зображень

Для розв’язання проблеми високоточної сегментації в умовах візуального шуму перспективним є вдосконалення базових архітектур U-Net та ResNet. Зокрема, для задачі семантичного маскуванню зон обличчя запропоновано гібридну архітектуру SMFD-UNet [14]. Особливістю такої мережі є використання класичної U-подібної структури кодувальника-розкодувальника в поєднанні із щільними залишковими блоками, що відповідає принципам архітектур сімейства ResNet. Модель виконує просторову сегментацію, розподіляючи пікселі на ключові семантичні зони: чисту шкіру, волосся, риси обличчя (очі, ніс, рот), аксесуари та фон. Завдяки механізмам уваги модель здатна адаптивно фокусуватися на морфології обличчя, ефективно ігноруючи сторонні завади. Наочно приклади роботи алгоритму – оригінальні портретні зображення та відповідні їм згенеровані багат шарові маски – продемонстровано на рисунку 1.4.

Експериментальні дослідження на наборі даних CelebAMask-HQ підтверджують високу стійкість підходу: навіть за умови штучного додавання інтенсивного візуального шуму показник точності сегментації за метрикою Dice утримується на рівні 64,84%, а структурна подібність складає 70,81%.



Рисунок 1.4 – Приклади оригінальних зображень та відповідних їм семантичних масок обличчя [14].

Логічним етапом дослідження є аналіз здатності глибоких архітектур до вилучення складних колористичних ознак в умовах змінного освітлення. Для розв'язання задачі оцінки пігментації шкіри під впливом різних джерел світла ефективними визнано згорткові нейромережі, зокрема архітектуру VGG-16. Завдяки адаптації базової моделі до задачі регресії у колірному просторі LAB, алгоритм здатен ідентифікувати тонкі підтони шкіри за сучасною 10-бальною шкалою Monk Skin Tone [15].

Експериментальні дані, отримані на масштабній вибірці з 21375 зображень, підтверджують високу стабільність регресійної моделі: базова оцінка проводилася при дуже жорсткому порозі похибки лише у 0,5 одиниці за шкалою MST. Зі збільшенням допустимої похибки загальна точність алгоритму в умовах різного освітлення сягає в середньому 85,45% та 97,16%. Це доводить здатність таких архітектур ефективно нівелювати вплив колірної температури світла.

Попри ефективність сучасних архітектур семантичної сегментації, існує проблема алгоритмічного зміщення при обробці різних відтінків шкіри. Зокрема, моделі U-Net та гібридні ResU-Net демонструють падіння точності на 15–20% під час аналізу темніших фототипів за шкалою Фітцпатріка порівняно зі світлими [16]. Вирішенням цієї проблеми є використання адаптивних порогів, що динамічно підлаштовуються під індивідуальний тон шкіри. Тестування такого підходу показує різке підвищення якості сегментації найтемніших відтінків: приріст метрики Dice сягає 18–24%, а bIoU – понад 30% [16]. Проте, з огляду на таку вразливість до освітлення та тону, базові сегментатори не підходять для

точного визначення кольоротипу. Тому розроблюваний метод вимагає алгоритмів попередньої обробки, які не лише надійно локалізують обличчя, а й гарантовано зберігають його колористичну специфіку незалежно від фототипу.

Після ізоляції пігменту шкіри наступним критичним кроком є класифікація візуальних ознак обличчя та волосся, для якої еталонним рішенням визнано архітектуру ResNet. Її висока здатність до узагальнення підтверджена дослідженнями на масштабному наборі даних CelebA, що містить понад 200000 анотованих зображень [17]. Алгоритм використовує глибокі залишкові зв'язки для розпізнавання 40 різноманітних візуальних характеристик. Висока стійкість моделі до перенавчання, змін ракурсу та освітлення досягається завдяки використанню оптимізатора AdamW, Dropout-регуляризації, а також застосуванню методів тонкого налаштування й розширеної аугментації даних [17]. За результатами тестування алгоритм досягає середньої точності на рівні 86% та загального показника F1-score 0,81. При цьому модель демонструє особливо високу точність саме при ідентифікації колористичних ознак: наприклад, для атрибутів «чорне волосся» та «світле волосся» показник F1-score сягає 0,82 та 0,86 відповідно.

Для задач класифікації кольоротипу доцільно розглянути підхід до автоматизованого сезонного аналізу на базі набору даних Deep Armoscromia [18]. Для розв'язання цієї задачі автори застосували попередньо виділені маски обличчя та глибокі моделі екстракції ознак. Проте за результатами валідації встановлено, що використання вдосконаленої архітектури ResNeXt50 забезпечує загальну точність лише на рівні 51,3% для базових чотирьох сезонів. При розширеній класифікації на 12 підтипів метрика різко знижується до 28,1%. Отримані показники підтверджують надзвичайну складність комп'ютерної колористики, що зумовлено високою міжкласовою схожістю візуальних ознак.

Отже, застосування стандартних архітектур класифікації, навіть за умови попереднього очищення зображення від фону, не здатне забезпечити прийнятну точність через втрату тонких деталей. Це диктує необхідність переходу до комплексного мультимодального методу: архітектура U-Net забезпечить точну

сегментацію обличчя від фону, а моделі сімейства ResNet – глибокий аналіз найтонших колористичних ознак для надійного визначення кольоротипу.

1.4 Аналіз існуючих програмних засобів

Сучасні програмні рішення для автоматизованого визначення кольоротипу мають архітектурні обмеження, які суттєво знижують точність кінцевої класифікації візуальних ознак.

Першим типом рішень є мобільні застосунки на основі детермінованих алгоритмів обробки сигналів, прикладом яких є «Dressika» [19] (рисунок 1.5). Тестування роботи системи в різних умовах освітлення вказує на відсутність ефективних алгоритмів нормалізації колірної температури. Оскільки застосунок генерує різні результати для одного об'єкта під теплим і холодним світлом, це доводить його нездатність математично відокремити істинну пігментацію шкіри від впливу спектрального складу джерела світла.




Рисунок 1.5 – Вигляд екрану «Dressika» [20]

Другим класом є системи, що базуються на глибокому навчанні, наприклад, «Style DNA» [21], яка представлена на рисунку 1.6. Практичний аналіз результатів розпізнавання виявляє низьку вибірковість механізмів просторової уваги цієї мережі. Через відсутність прецизійної попередньої сегментації обличчя, алгоритм часто помилково інтегрує у вектор ознак домінуючі кольори фону або

одягу замість ізольованого аналізу біометричних характеристик. Додатковим обмеженням є закритість архітектури моделі, що унеможливило верифікацію проміжних етапів обробки зображення.

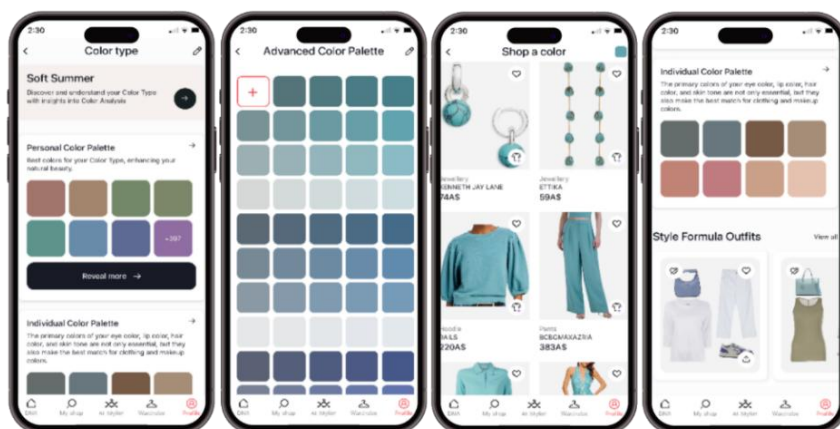


Рисунок 1.6 – Вигляд екрану «Style DNA» [22]

Окрему категорію становлять напівавтоматизовані вебсервіси, зокрема «Colorwise.me» [23]. Робочий процес сервісу (рисунок 1.7) базується на повністю ручному виборі контрольних пікселів користувачем, оскільки алгоритми семантичної сегментації відсутні. Аналіз такого підходу доводить, що він вносить непереконливу суб'єктивну похибку: випадковий вибір користувачем ділянок із мікротінями, почервоніннями або світловими відблисками незворотно спотворює вхідні дані. Це робить подальшу автоматичну класифікацію за детермінованими палітрами математично некоректною.

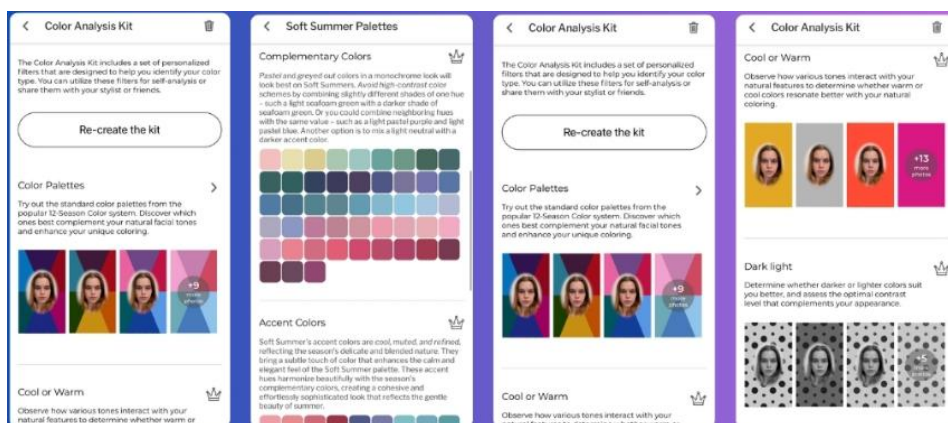


Рисунок 1.7 – Вигляд роботи веб-сервісу «Colorwise.me» [24]

Для систематизації виявлених технічних особливостей та обмежень сформовано порівняльну характеристику існуючих програмних рішень, яка наведена у таблиці 1.4.

Таблиця 1.4 – Порівняльний аналіз існуючих рішень визначення кольоротипу

Критерій порівняння	Dressika	Style DNA	Colorwise.me
Метод вилучення ознак	Автоматизований (комп'ютерний зір)	Автоматизований (нейромережа)	Ручний (під вибіркою користувачем)
Стійкість до дисперсії освітлення	Низька (відсутня нормалізація балансу білого)	Середня (залежить від фону)	Дуже низька (залежить від вибору пікселя)
Алгоритм семантичної сегментації обличчя	Присутній	Присутній	Відсутній
Прозорість моделі	Середня	Низька	Висока

Отже, проведений аналіз існуючих аналогів підтверджує, що головним викликом для сучасних систем колористичного аналізу є розробка методу, який би поєднував прецизійну автоматизовану сегментацію зон інтересу з механізмами стійкості до варіативності освітлення.

1.5 Мета та завдання дослідження

Метою роботи є підвищення точності класифікації сезонного кольоротипу зовнішності людини шляхом розробки нейромережевого методу комп'ютерного зору для генерації персоналізованої рекомендації візуального образу.

Для досягнення поставленої мети необхідно виконати такі завдання:

- провести комплексний аналіз предметної області та сучасного стану технологій комп'ютерного зору для автоматизації колористичного аналізу;
- розробити метод визначення кольоротипу зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу;
- виконати підготовку та попередню обробку наборів даних для забезпечення коректного навчання нейромережевих моделей;
- розробити програмну реалізацію експериментального застосування запропонованого методу;
- провести експериментальне тестування розробленого методу за визначеними метриками оцінювання.

Розділ 2 Розробка методу визначення кольоротипу зовнішності людини засобами комп'ютерного зору

2.1 Загальна концепція та структурна схема методу

Розроблення методу автоматизованого визначення кольоротипу зовнішності базується на концепції послідовної обробки та фільтрації візуальних даних. Суть розробленого підходу полягає у поетапному перетворенні вихідного зображення: від визначення ключових зон (шкіри, волосся, очей) та усунення впливу освітлення до вилучення колірних ознак і їхньої кінцевої нейромережевої класифікації. Запропонований метод інтегрує в собі два послідовні глобальні етапи: високоточну просторову семантичну сегментацію обличчя та мультимодальну класифікацію екстрагованих колірних параметрів. Такий підхід дозволяє нівелювати фоновий шум та оптичні викривлення, забезпечуючи точний перехід від масиву пікселів до одного з чотирьох базових сезонів зовнішності.

Вхідним об'єктом методу є цифрове растрове зображення обличчя, яке математично формалізується як тривимірний масив пікселів у колірному просторі RGB згідно з виразом (2.1):

$$I \in \mathbb{R}^{W \times H \times 3} \quad (2.1)$$

де I – вхідне зображення (масив); W та H – просторова ширина та висота зображення у пікселях відповідно; 3 – кількість колірних каналів (Red, Green, Blue).

Цільовим вихідним простором розроблюваного методу є вектор ймовірностей, що відображає належність об'єкта до одного з чотирьох сезонних макрокласів зовнішності. Цей простір формалізується виразом (2.2):

$$P = \{p_1, p_2, p_3, p_4\}, \quad \sum_{i=1}^4 p_i = 1 \quad (2.2)$$

де P – результуючий вихідний вектор; p_i – передбачена моделлю ймовірність належності до i -го макрокласу (Зима, Весна, Літо, Осінь).

Оскільки пряму обчислювальну трансформацію вхідного тензора I у вихідний вектор Y неможливо виконати з високою точністю за один крок через варіативність умов зйомки, спроектовано загальну структурну схему методу визначення кольоротипу зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу, яку наведено на рисунку 2.1.

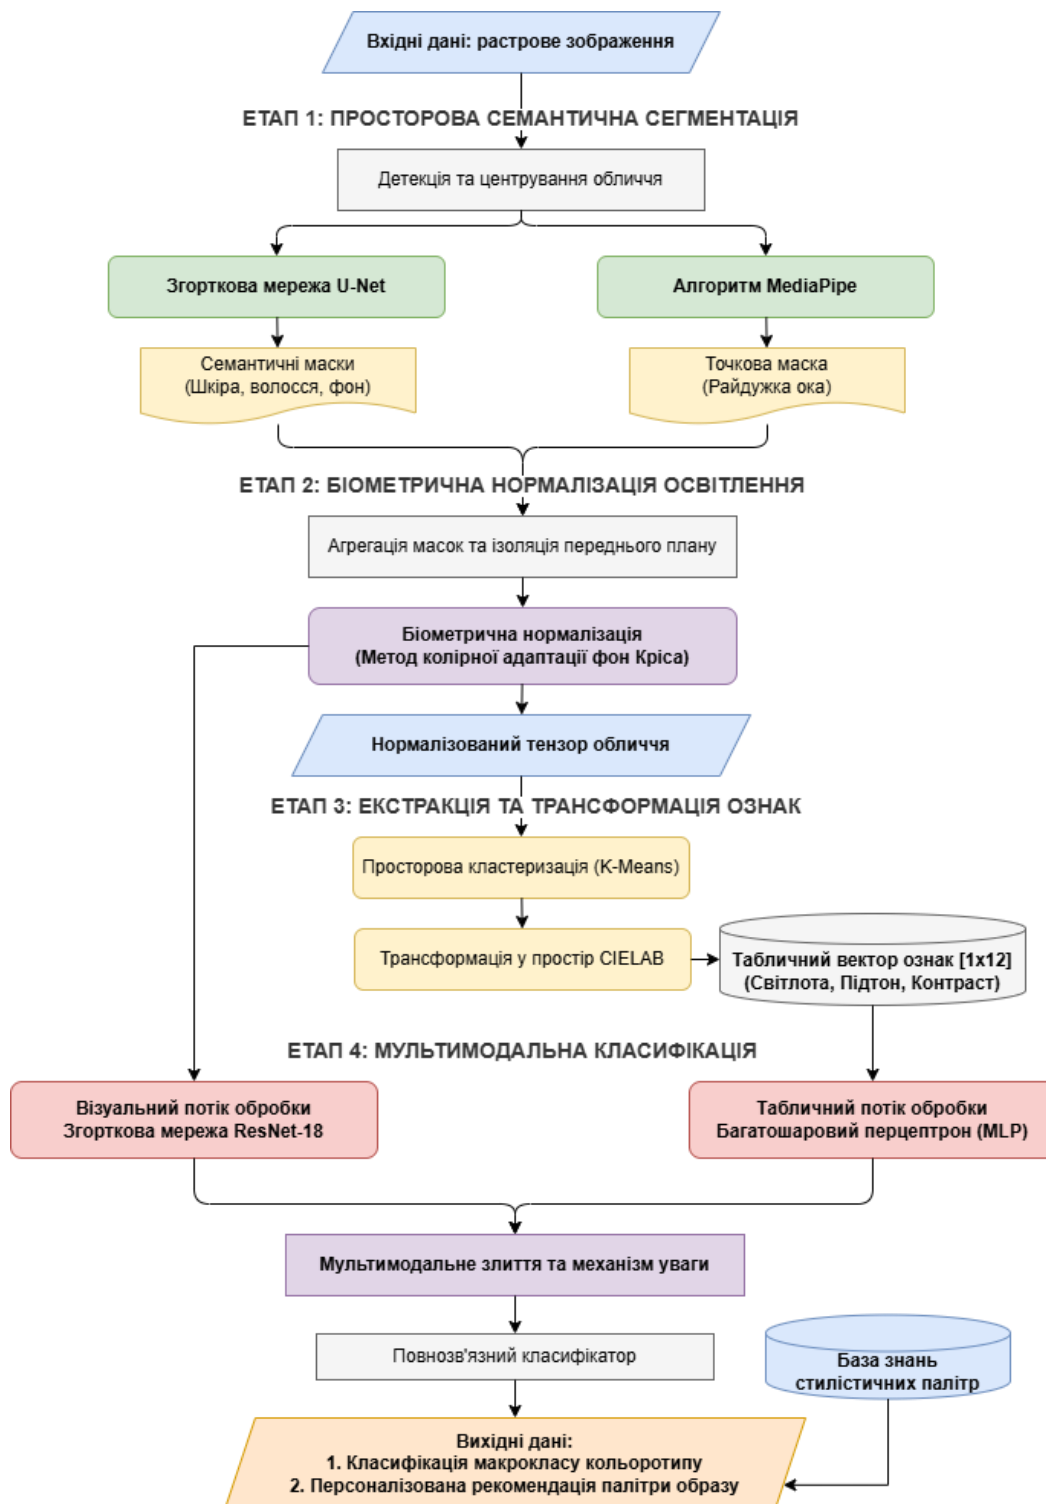


Рисунок 2.1 – Загальна структурна схема методу мультиmodalного аналізу

Відповідно до наведеної схеми, архітектура розробленого методу базується на послідовному виконанні чотирьох ключових етапів.

На першому етапі здійснюється просторова семантична сегментація вхідного зображення. Після попередньої детекції та центрування обличчя потік даних спрямовується до двох паралельних потоків обробки. Перший обчислювальний потік використовує згорткову нейронну мережу архітектури U-Net для виділення макрозон зовнішності, генеруючи високоточні семантичні маски шкіри, волосся та фону. Другий потік застосовує алгоритм MediaPipe Face Mesh для точкової просторової локалізації мікрозон, зокрема для формування маски райдужки ока [25].

Другим етапом є біометрична нормалізація освітлення. Отримані семантичні маски агрегуються для повної ізоляції переднього плану зображення, що дозволяє відсікти нерелевантний фон та елементи одягу. Для усунення спектрального впливу джерела освітлення та компенсації колірної температури застосовується метод колірної адаптації фон Кріса [26]. Цей алгоритм оцінює вектор поточного освітлення та здійснює корекцію пікселів за допомогою матриці масштабування. Результатом цього етапу є нормалізоване зображення обличчя, очищене від спектральних викривлень зовнішнього середовища.

Під час третього етапу відбувається екстракція та трансформація колірних ознак. Нормалізоване зображення обробляється за допомогою алгоритму K-Means для визначення домінуючих пігментів в ізольованих зонах [27]. Визначені RGB-значення трансформуються у перцептивно рівномірний колірний простір CIELAB. На основі цих даних обчислюється набір метрик (показники світлоти, підтону та контрасту), які формують структурований табличний вектор, що складається з дванадцяти ключових ознак.

На завершальному, четвертому етапі виконується мультимодальна класифікація. Процес передбачає паралельну обробку різномірних даних: нормалізоване зображення обличчя подається на вхід згорткової нейронної мережі ResNet-18, тоді як згенерований табличний вектор обробляється MLP [28,

29]. Мультимодальне злиття отриманих масивів даних реалізується через механізм уваги, що дозволяє динамічно зважувати їхню важливість.

Кінцевий результат функціонування методу формалізується у вигляді комплексних вихідних даних. На основі максимізації ймовірностей елементів вектора Y після повнозв'язного класифікатора спочатку забезпечується точна класифікація макрокласу кольоротипу зовнішності. Наступним кроком, використовуючи визначений сезонний тип, алгоритм здійснює автоматичне звернення до бази знань стилістичних палітр. Поєднання розпізнаного біометричного колориту із завантаженими колірними стандартами дозволяє згенерувати фінальну персоналізовану рекомендацію палітри візуального образу для користувача.

2.2 Проектування нейромережових моделей семантичної сегментації та класифікації

2.2.1 Архітектура моделі семантичної сегментації U-Net

Для розв'язання задачі просторової ізоляції цільових зон обличчя у межах розроблюваного методу пропонується застосування архітектури семантичної сегментації U-Net. Вибір даної структури обґрунтований її здатністю до прецизійної локалізації об'єктів та ефективного збереження просторового контексту зображення, що є критичним для коректного вилучення колірних ознак. Процес сегментації формалізується як задача багатокласової класифікації пікселів, де для реалізації сегментаційного модуля та забезпечення його здатності розпізнавати антропометричні зони передбачається використання набору даних CelebAMask-HQ як бази для навчання [30]. Це дозволить спроектованій моделі ідентифікувати 19 семантичних категорій, що є необхідним технологічним етапом для подальшої ізоляції ключових атрибутів зовнішності та проведення їхнього колористичного аналізу.

Вхідні дані методу представлені у вигляді кольорових тензорів у просторі RGB, які на етапі попередньої обробки приводяться до стандарту роздільної

здатності 512x512 пікселів. Центральним елементом спроектованої мережі є кодувальник на базі архітектури ResNet-34. Його структура передбачає проходження сигналу через початковий згортковий шар із ядром 7x7 та кроком 2, що забезпечує первинне вилучення ознак при одночасному зменшенні просторової розмірності [28]. Після шару пакетної нормалізації та функції активації ReLU застосовується шар максимального пулінгу, що готує дані для глибинного аналізу через 4 послідовні стадії залишкових блоків. Кожна стадія містить блоки із двома згортковими шарами 3x3, де кількість фільтрів прогресивно зростає від 64 до 512. Це дозволяє моделі формувати складний ознаковий простір, де початкові рівні відповідають за лінійні контури, а глибинні шари – за специфічні текстурні патерни шкіри та волосся. Для підвищення стабільності навчання пропонується ініціалізація ваг кодувальника за допомогою технології перенесення знань на базі набору даних ImageNet [31]. Деталізована організація цих шарів та загальний шлях проходження тензора даних зображені на структурній схемі (рисунок 2.2).

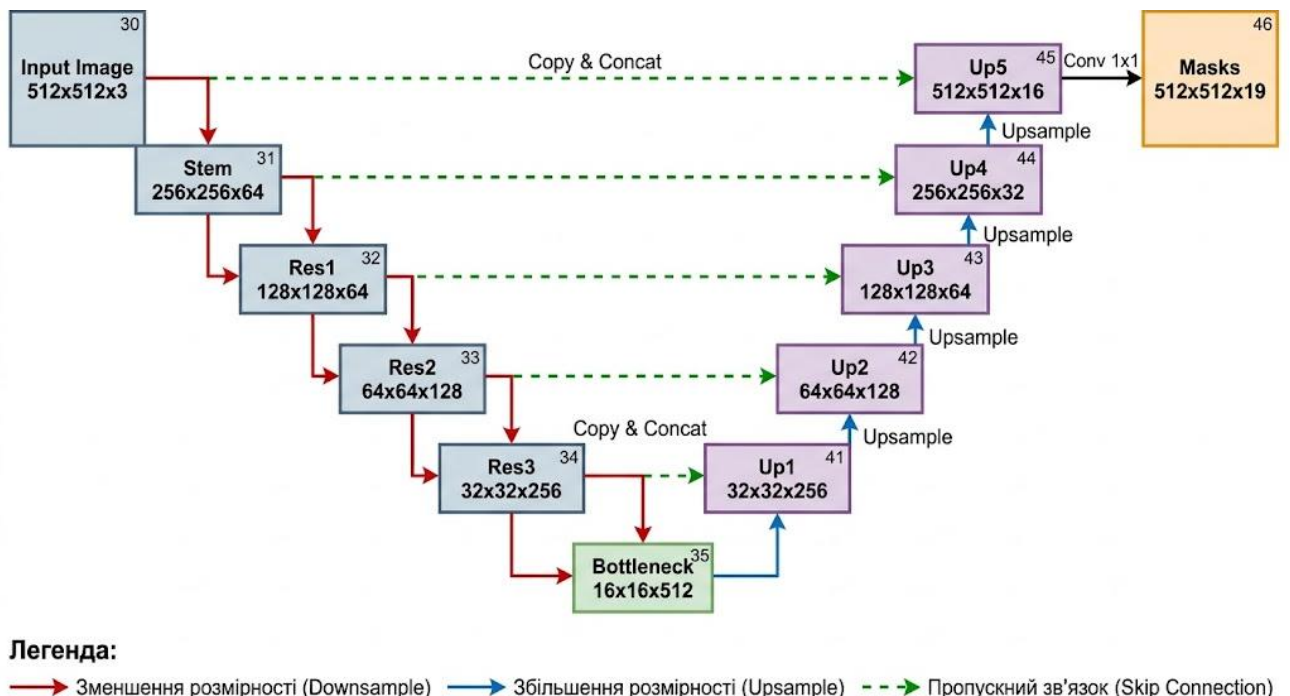


Рисунок 2.2 – Структурна схема нейронної мережі U-Net для багатокласової сегментації зон обличчя

Особливе значення у структурі архітектури мають пропускні зв'язки, що симетрично поєднують рівні кодувальника та розкодувальника, як це показано на наведеній схемі. Передбачається, що карти ознак високої роздільної здатності передаватимуться безпосередньо до відповідних шарів декодера для компенсації втрат просторової інформації, які виникають під час операцій субдискретизації. Таке рішення гарантує формування математично точних меж сегментаційних масок, що є обов'язковою умовою для мінімізації похибки при подальшому обчисленні медіанних значень кольору та показників дисперсії в ізольованих зонах.

Розкодувальник проєктується як послідовність п'яти блоків відновлення розмірності за допомогою операцій зворотної згортки. Кожен такий блок передбачає конкатенацію відновлених ознак із картами високої роздільної здатності, отриманими через пропускні зв'язки, з наступним застосуванням двох згорткових шарів три на три та функції активації ReLU. Вихідний шар мережі реалізується як фінальна згортка з ядром 1×1 , що трансформує ознаковий простір у 19 каналів відповідно до структури навчальної вибірки. Фінальне рішення щодо приналежності пікселя до певного класу пропонується приймати на основі оператора обчислення максимального аргументу, що узгоджується з імовірнісною логікою роботи моделі.

Для налаштування внутрішніх параметрів спроектованої мережі передбачається використання адаптивного алгоритму оптимізації Adam, який забезпечує швидку збіжність за рахунок динамічного коригування швидкості навчання. З огляду на суттєвий дисбаланс площ між цільовими атрибутами у навчальній вибірці, для навчання пропонується застосування гібридної функції втрат. Вона проєктується як лінійна комбінація зваженої багатокласової перехресної ентропії та метрики Dice Loss у ваговій пропорції 0,4 та 0,6 відповідно. Такий підхід забезпечує стабільну ідентифікацію навіть дрібних елементів зовнішності незалежно від їхнього розміру в кадрі, формуючи надійний базис для подальшого визначення кольоротипу.

2.2.2 Архітектура гібридної моделі класифікації на базі ResNet-18 та MLP

Для вирішення задачі класифікації кольоротипу зовнішності у межах розроблюваного методу пропонується використання гібридної нейромережевої архітектури. Незважаючи на те, що на вхід класифікатора подаватимуться зображення, попередньо ізольовані від фону модулем просторової сегментації, використання виключно згорткової мережі є недостатнім. Візуальні ознаки очищеного портрета не завжди здатні алгоритмічно точно передати тонкі колориметричні співвідношення, такі як ледь помітна різниця у підтоні шкіри або математичний контраст між волоссям та очима [32]. Для вирішення цієї проблеми у структурі моделі проєктуються два паралельні потоки даних: візуальний, безпосередньо очищене зображення обличчя, та табличний вектор із 12 попередньо екстрагованих колориметричних ознак.

За обробку візуального потоку відповідатиме згорткова гілка на базі архітектури ResNet-18. Вибір саме 18-шарової модифікації замість більш глибоких аналогів зумовлений порівняно невеликим обсягом цільової навчальної вибірки: легка архітектура дозволяє уникнути швидкого перенавчання моделі та забезпечує високу швидкість обробки даних. Для прискорення збіжності планується використання технології перенесення знань із застосуванням попередньо натренованих ваг ImageNet. У процесі адаптації мережі під специфіку завдання оригінальний класифікаційний шар відсікається, а замість нього проєктується новий повнозв'язний блок. Цей блок містить лінійний шар на 128 нейронів, шар пакетної нормалізації, функцію активації ReLU та шар проріджування Dropout з імовірністю 0,4. Архітектура розробленої гібридної моделі та шляхи проходження мультимодальних даних наведені на структурній схемі (рисунок 2.3).

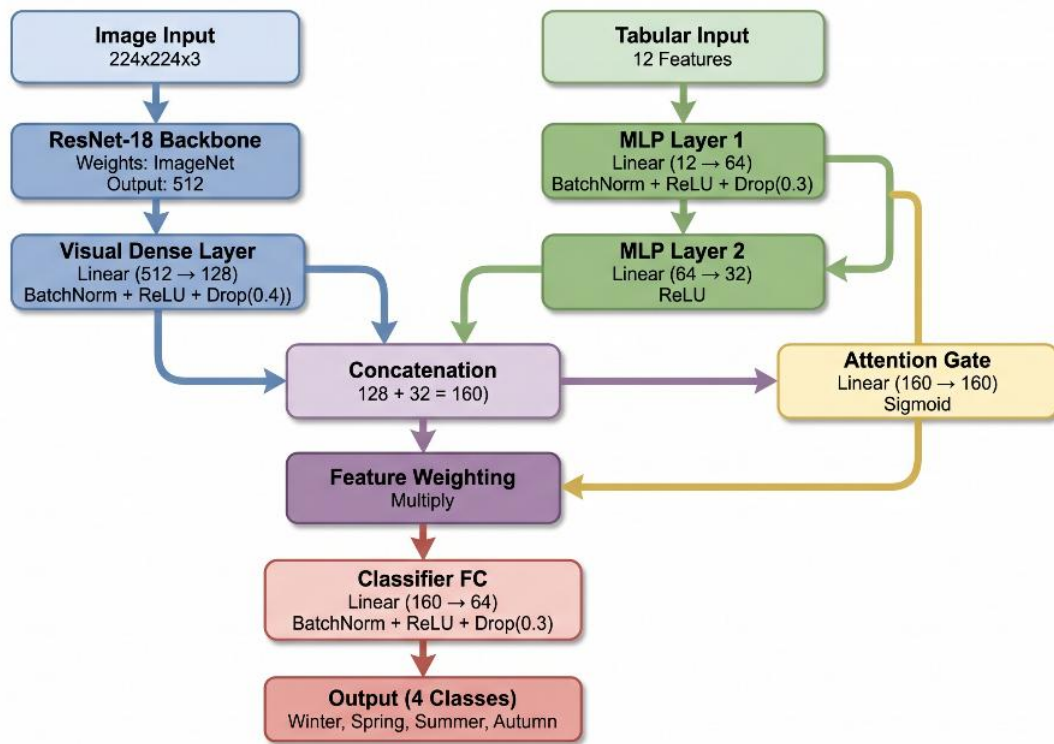


Рисунок 2.3 – Структурна схема гібридної нейронної мережі для класифікації кольоротипу зовнішності

Паралельно з обробкою зображення, табличний потік даних спрямовується до окремого модулі MLP. Цей блок проєктується як міні-мережа, що послідовно пропускає вектор ознак через лінійний шар на 64 нейрони, пакетну нормалізацію, активацію ReLU, шар проріджування з імовірністю 0,3 та фінальний лінійний шар на 32 нейрони. Таке перетворення дозволяє мережі автоматично виявляти приховані математичні закономірності у колірних співвідношеннях. Ключовим елементом архітектури є застосування механізму уваги Gated Attention для злиття обох потоків. Вектор візуальних ознак просторово конкатенується з вектором табличних ознак, після чого об'єднаний масив даних проходить через окремий шар із функцією активації Sigmoid. Цей механізм формує вагові коефіцієнти в діапазоні від 0 до 1, що дозволяє моделі динамічно калібрувати увагу та самостійно визначати, якому джерелу інформації – візуальному контексту чи строгим математичним медіанам кольору – надати більший пріоритет при прийнятті рішення [33].

Відкалібрований об'єднаний вектор ознак передається до фінального класифікаційного модуля, який складається з лінійного шару на 64 нейрони,

пакетної нормалізації, ReLU, шару проріджування та вихідного лінійного шару на 4 нейрони. Вихідні нейрони безпосередньо відповідають чотирьом цільовим сезонам зовнішності. Для забезпечення стабільного та синхронного навчання цієї гібридної структури передбачається використання адаптивного оптимізатора AdamW із застосуванням диференційованої швидкості навчання [34]. Для згорткових блоків ResNet-18 та механізму уваги базова швидкість навчання становитиме $1e-3$, тоді як для табличного блоку MLP параметр буде знижено до $5e-4$. Таке рішення дозволить компенсувати різницю у швидкості збіжності між багатовимірними візуальними та низьковимірними математичними ознаками, забезпечуючи рівномірне та ефективне навчання всієї каскадної архітектури.

2.3 Математична формалізація екстракції та нормалізації кольірних ознак

Для усунення впливу варіативного освітлення та переходу від піксельної матриці до структурованих ознак застосовується специфічний математичний апарат. Прямий аналіз кольорів у просторі RGB є неефективним через його апаратну залежність та спектральні викривлення, що виникають під дією різних джерел світла.

Процес обробки починається з біометричної нормалізації освітлення. Для вирівнювання балансу білого використовується метод кольірної адаптації фон Кріса [35]. Базовий коефіцієнт масштабування для кожного кольорного каналу розраховується за формулою 2.3:

$$S_c = \frac{\max(\mu_R, \mu_G, \mu_B)}{\mu_c} \quad (2.3)$$

де S_c – коефіцієнт корекції для поточного каналу $c \in \{R, G, B\}$; μ_R, μ_G, μ_B – середні значення інтенсивності пікселів у червоному, зеленому та синьому каналах відповідно; μ_c – середнє значення інтенсивності пікселів саме того каналу, для якого обчислюється коефіцієнт.

Оскільки класичне перетворення фон Кріса є агресивним і може призвести до спектральної деградації природного пігменту шкіри та волосся, у розробленому методі запропоновано механізм м'якої нормалізації. Він передбачає встановлення меж відсікання та коефіцієнта згладжування сили корекції, що формалізується за формулою 2.4:

$$S'_c = 1 + (\max(\beta_{min}, \min(\beta_{max}, S_c)) - 1) * \gamma \quad (2.4)$$

де $\beta_{min} = 0.9$ та $\beta_{max} = 1.15$ – граничні значення кліпінгу, а $\gamma = 0.25$ – параметр сили корекції.

Це дозволяє зберегти натуральну базу зовнішності, усуваючи лише екстремальні відхилення колірної температури.

Після нормалізації здійснюється екстракція домінуючого пігменту з семантичних масок. Використання простого середнього арифметичного значення для агрегації пікселів є некоректним через наявність оптичних артефактів, таких як тіні на обличчі чи відблиски на волоссі. Тому для макрозон зовнішності (шкіра, волосся) застосовується алгоритм просторової кластеризації K-Means [36]. Цільова функція мінімізації внутрішньокластерної дисперсії визначається за формулою 2.5:

$$J = \sum_{j=1}^k \sum_{x_i \in C_j} \|x_i - \mu_j\|^2 \quad (2.5)$$

де x_i – вектор кольору пікселя, μ_j – центроїд кластера C_j , а кількість кластерів встановлено емпірично як $k = 3$.

Такий підхід дозволяє ефективно сегрегувати істинний пігмент від тіней та пересвітів, після чого для подальшого аналізу обирається центроїд найбільшого кластера.

Для обробки мікрозон, зокрема маски райдужки ока, застосування кластеризації є математично нестабільним через критично малу розмірність піксельної вибірки. Тому для екстракції пігменту райдужки обчислюється медіанний вектор кольору, що забезпечує стійкість до викидів, за формулою 2.6:

$$\mu_{med} = med(x_1, x_2, \dots, x_n) \quad (2.6)$$

де μ_{med} – результуючий медіанний вектор кольору в обраному просторі; x_1, x_2, \dots, x_n – сукупність колірних векторів усіх пікселів, що входять до семантичної маски райдужки.

Отримані центроїди та медіани у просторі RGB не є перцептивно рівномірними для людського сприйняття, що ускладнює роботу нейромережевого класифікатора. Тому вони трансформуються у колірний простір CIELAB [37]. Після проміжного переведення у простір XYZ, координати L^* , a^* та b^* розраховуються за формулами 2.7, 2.8 та 2.9 відповідно:

$$L^* = 116f(Y/Y_n) - 16 \quad (2.7)$$

$$a^* = 500[f(X/X_n) - f(Y/Y_n)] \quad (2.8)$$

$$b^* = 200[f(Y/Y_n) - f(Z/Z_n)] \quad (2.9)$$

де $f(t)$ – стандартна нелінійна функція кубічного кореня, а X_n, Y_n, Z_n – координати цільового білого ілюмінанта.

На основі екстрагованих координат обчислюються похідні аналітичні ознаки, які допомагають нейромережі знаходити приховані закономірності. Контраст світлоти між шкірою та волоссям розраховується як модуль математичної різниці за формулою 2.10:

$$\Delta L = |L_{skin}^* - L_{hair}^*| \quad (2.10)$$

Загальний агрегований показник теплоти зовнішності визначається як алгебраїчна сума температурних координат осі b^* за формулою 2.11:

$$W = b_{skin}^* + b_{hair}^* + b_{eye}^* \quad (2.11)$$

В результаті виконання усіх описаних математичних перетворень формується єдиний структурований табличний вектор, який подається на вхід

багатошарового перцептрона. Повну структуру та фізичний зміст кожної ознаки екстрагованого вектора наведено у таблиці 2.1.

Таблиця 2.1 – Структура екстрагованого табличного вектора ознак (простір CIELAB)

Індекс	Математичне позначення	Фізичний зміст та опис метрики	Джерело даних
1	L^*_{skin}	Яскравість шкіри	Маска шкіри (K-Means)
2	a^*_{skin}	Рівень еритеми	Маска шкіри (K-Means)
3	b^*_{skin}	Температура	Маска шкіри (K-Means)
4	L^*_{hair}	Яскравість волосся	Маска волосся (K-Means)
5	a^*_{hair}	Наявність червоного пігменту волосся	Маска волосся (K-Means)
6	b^*_{hair}	Температура волосся	Маска волосся (K-Means)
7	L^*_{eye}	Яскравість райдужки ока	Маска очей (Медіана)
8	a^*_{eye}	Зелено-червона вісь райдужки ока	Маска очей (Медіана)
9	b^*_{eye}	Температура райдужки	Маска очей (Медіана)
10	ΔL_{sh}	Контрастність шкіри та волосся	Обчислювальна метрика
11	ΔL_{se}	Контрастність шкіри та очей	Обчислювальна метрика
12	W	Загальна теплота зовнішності	Обчислювальна метрика

Математична формалізація методу завершується етапом відображення розпізнаних ознак на цільовий простір персоналізованих палітр для генерації рекомендацій візуального образу.

Для зв'язку результатів класифікації зі стилістичними рекомендаціями застосовано апарат теорії множин. Нехай $C = \{c_1, c_2, c_3, c_4\}$ – множина сезонних макрокласів зовнішності (де c_1 – зима, c_2 – весна, c_3 – літо, c_4 – осінь). Множина доступних експертних палітр стилістичних рекомендацій визначається як $P = \{p_1, p_2, p_3, p_4\}$. Кожна окрема палітра $p_i \in$ підмножиною шістнадцяткових кодів кольорів у просторі HEX та категоризується за функціональним призначенням згідно з виразом (2.12):

$$p_i = \{H_{base}, H_{accent}, H_{makeup}, H_{taboo}\} \in HEX \quad (2.12)$$

де H_{base} – підмножина базових відтінків гардероба; H_{accent} – підмножина акцентних кольорів; H_{makeup} – підмножина відтінків для макіяжу; H_{taboo} – підмножина відтінків, що не рекомендовані для даного колориту зовнішності.

Перехід від нейромережевого передбачення до конкретної палітри описується функцією відображення f згідно з рівнянням (2.13):

$$f: Y \xrightarrow{\arg \max} C \rightarrow p_i \in P \quad (2.13)$$

де Y – вихідний вектор ймовірностей мультимодального класифікатора; $\arg \max$ – оператор визначення класу з найвищою ймовірністю.

Програмна реалізація цієї інформаційної моделі базується на ієрархічній структурі даних JSON. Після визначення індексу класу за формулою (2.13), алгоритм звертається до відповідного вузла бази знань та вилучає масив HEX -кодів. Отриманий набір даних є кінцевим результатом роботи методу і використовується для генерації персоналізованого візуального образу в інтерфейсі користувача.

2.4 Формування наборів даних для навчання та валідації

2.4.1 Набір даних для навчання моделі семантичної сегментації

Для навчання моделі семантичної сегментації на базі архітектури U-Net доцільним є використання відкритого великомасштабного набору даних CelebAMask-HQ [30]. Цей масив містить 30000 зображень облич високої роздільної здатності. Ключовою перевагою обраного набору є наявність деталізованих анотацій, де кожне кольорове зображення супроводжується відповідними масками просторової сегментації.

Загалом набір даних формалізує 19 класів, серед яких 18 є цільовими атрибутами обличчя, а 1 відповідає за фонову область. До переліку анотованих атрибутів входять шкіра, ніс, ліве та праве око, відповідні брови та вуха, загальна

область рота, верхня та нижня губи, волосся, головний убір, сережки, намисто, шия та елементи одягу. Приклад вхідних зображень та візуалізація відповідних багатокласових масок наведені на рисунку 2.4.

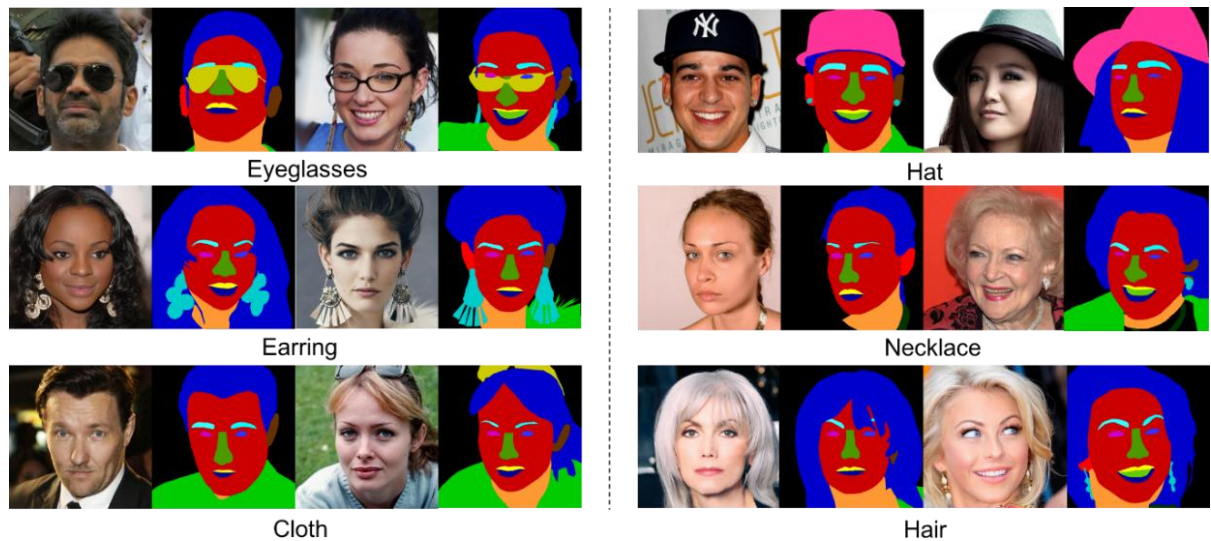


Рисунок 2.4 – Приклад зображень та відповідних цільових масок з набору CelebAMask-HQ [38]

З метою підтвердження репрезентативності обраного набору даних для цільової задачі проведено статистичний аналіз частоти появи кожного з вісімнадцяти атрибутів у загальній вибірці (рисунок 2.5).

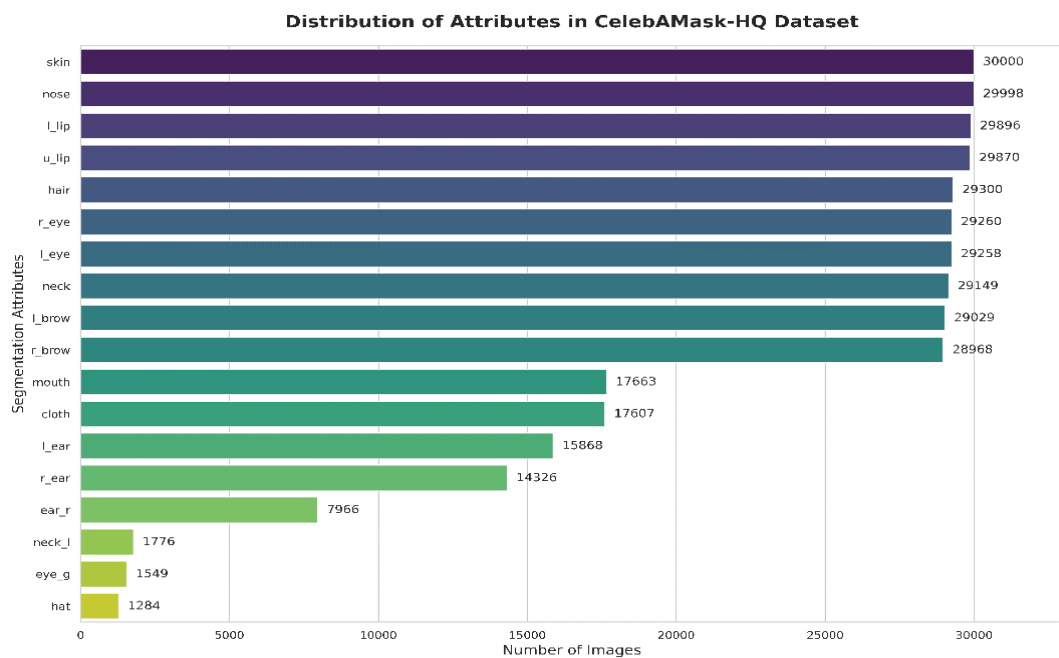


Рисунок 2.5 – Гістограма розподілу цільових атрибутів у наборі даних CelebAMask-HQ

Аналіз наведеного розподілу вказує на те, що вихідний набір даних характеризується суттєвим дисбалансом класів. Цільові для поточного дослідження атрибути, зокрема шкіра та волосся, присутні майже на кожному зображенні. Водночас міноритарні класи, серед яких головні убори або окуляри, становлять менше п'яти відсотків від загального обсягу вибірки.

Збереження такої архітектури даних під час навчання моделі семантичної сегментації неминуче призводить до штучної деградації усереднених статистичних показників точності. Нейронна мережа не отримує достатньої кількості репрезентативних прикладів для виявлення ознак міноритарних класів, що суттєво знижує загальну ефективність її збіжності. Оскільки для розв'язання кінцевої задачі визначення сезонного кольоротипу необхідні виключно колориметричні параметри шкіри, волосся та базових рис обличчя, розроблений метод передбачає ігнорування міноритарних атрибутів. Усі нерелевантні класи агрегуються та переносяться до єдиного масиву фону. Таке структурне рішення дозволяє повністю нівелювати проблему дисбалансу даних, підвищити загальну точність розпізнавання цільових зон моделлю U-Net та оптимізувати процес формування ознакового простору.

Для забезпечення об'єктивної оцінки здатності моделі до узагальнення набір даних розділено на три непересічні підмножини за фіксованим параметром ініціалізації генератора псевдовипадкових чисел. Протокол розподілу передбачає виділення 24 000 зображень (80%) для процесу навчання, 3 000 зображень (10%) для валідації під час оптимізації гіперпараметрів та 3 000 зображень (10%) для фінального тестування моделі. Тестову підмножину ізольовано на етапі первинної конфігурації експерименту, що повністю виключає її участь у процесах обчислення градієнтів та коригування вагових коефіцієнтів. Таке рішення забезпечує отримання неупереджених метрик генералізації алгоритму на незалежних візуальних даних.

Перед подачею на вхід нейронної мережі всі зображення та відповідні їм цільові маски проходять етап попередньої обробки. Цей етап включає

стандартизацію просторового розміру до формату 512x512 пікселів та нормалізацію значень колірної інтенсивності.

2.4.2 Спеціалізований набір даних для класифікації кольоротипів

Аналіз сучасних досліджень у сфері автоматичного визначення кольоротипу зовнішності виявляє критичний дефіцит відкритих та науково верифікованих наборів даних. Більшість існуючих візуальних масивів орієнтовані на суміжні задачі розпізнавання облич і не містять експертної розмітки колориметричних параметрів. З огляду на це, для навчання моделі класифікації найбільш доцільним є використання спеціалізованого набору даних Deep Armoscromia [18]. Зважаючи на відсутність даного масиву у вільному публічному доступі, матеріали для проведення поточного дослідження отримано за відповідним запитом безпосередньо від розробників.

Загалом оригінальний набір даних формалізує 12 класів, які розподілені на 4 базові макрокласи: зима, весна, літо та осінь. Кожен макроклас додатково деталізується на 3 підтипи залежно від домінуючих колориметричних характеристик: яскравий, світлий, м'який, теплий, холодний та глибокий. Зображення у наборі попередньо розмічені відповідно до розширеної теорії сезонних кольоротипів. Приклад вхідних зображень для кожного з дванадцяти сезонних підтипів наведено на рисунку 2.6.

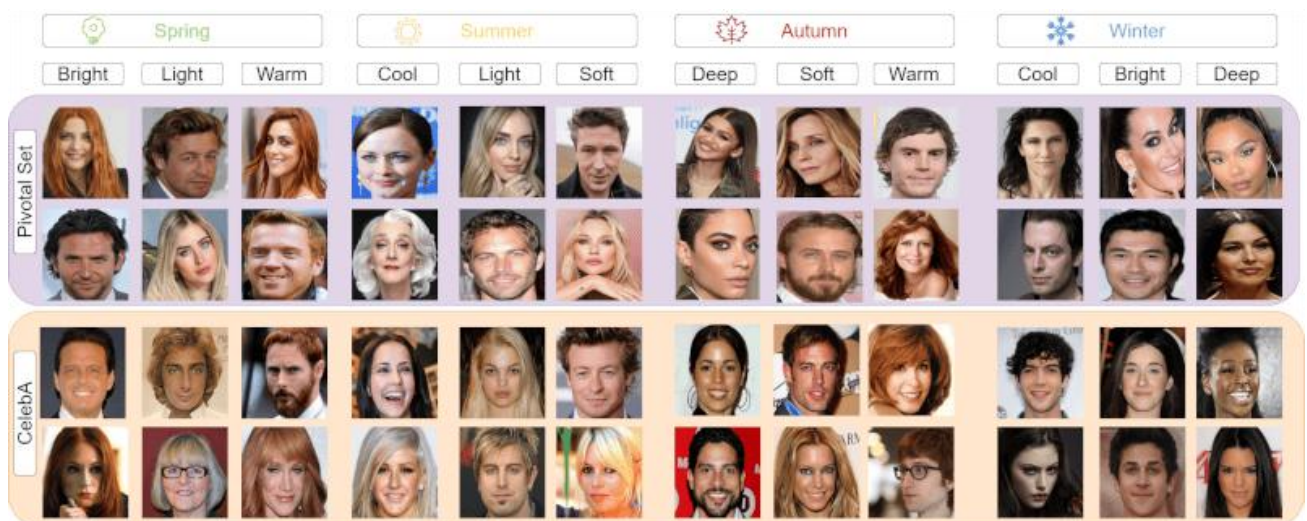


Рисунок 2.6 – Приклад зображень цільових класів з набору Deep Armoscromia [39]

Відповідно до базової системи класифікації, у межах розробленого методу вихідні дванадцять підтипів агрегуються у чотири цільові макрокласи: зима, літо, осінь та весна. З метою підтвердження структурних характеристик отриманого масиву проведено розвідувальний статистичний аналіз частоти появи об'єктів, результати якого наведено на рисунку 2.7.

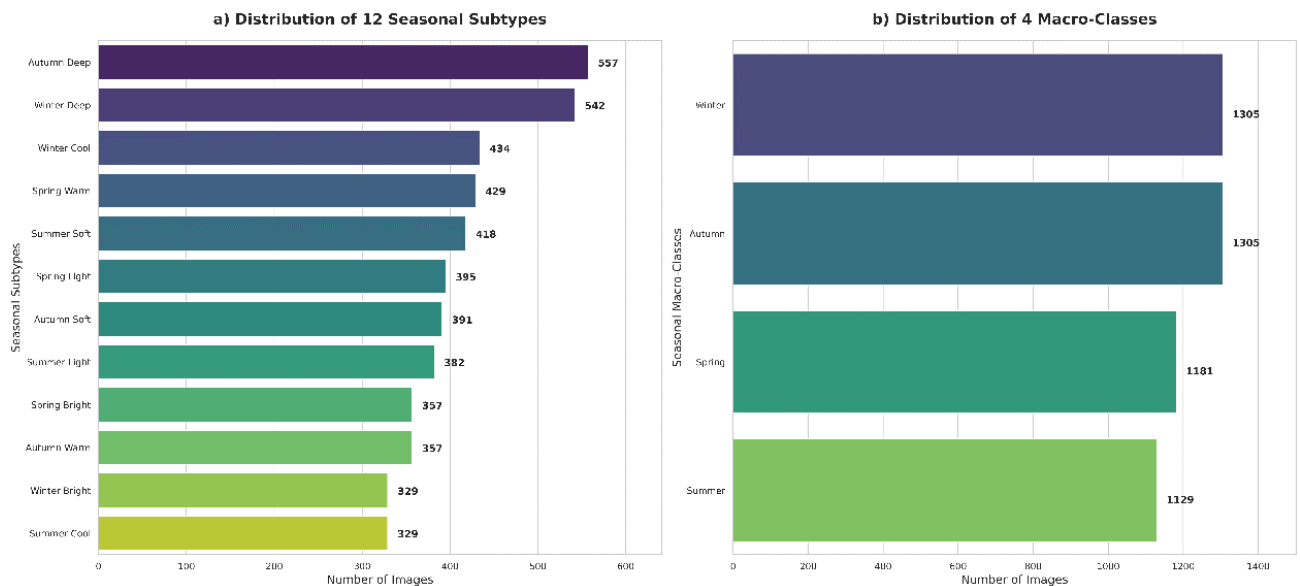


Рисунок 2.7 – Кількісний розподіл вихідного набору даних Deep Atmoscromia: а) за 12 сезонними підтипами; б) за 4 макрокласами

Аналіз наведеного розподілу свідчить про наявність вираженого кількісного дисбалансу між цільовими категоріями. Окрім нерівномірності вибірки, оригінальний масив містить значний обсяг просторового та візуального шуму (різноманітний нерелевантний фон, нестабільні умови зйомки, сторонні елементи одягу), а також суб'єктивні помилки експертної розмітки, де колориметричні параметри окремих об'єктів математично суперечать логіці призначеного їм сезону.

Для усунення зазначених недоліків передбачено поетапну попередню підготовку та математичне очищення вибірки. Після первинної ізоляції зон інтересу засобами моделі U-Net, нормалізації освітлення за методом фон Кріса та екстракції ознак за рівняннями (2.3)–(2.11), заплановано застосування алгоритмічного фільтра на базі дерев рішень з обмеженням максимальної глибини ($max_depth = 3$). Цей підхід дозволить в автоматичному режимі розрахувати

оптимальні фізичні пороги контрастності, світлоти та теплоти для кожного макрокласу, щоб вилучити суперечливі зразки як аномалії розмітки.

З метою забезпечення об'єктивності подальшої оцінки мультимодальної моделі та запобігання ефекту витоку даних, передбачено стратифікацію масиву на тренувальну, валідаційну та тестову підмножини. Тестова вибірка строго ізолюється до початку будь-яких обчислень чи процедур очищення. Вона містить по 100 виключно оригінальних зображень для кожного з чотирьох макрокласів, що гарантує високу точність та об'єктивність фінальної валідації класифікатора. Збалансування та розширення тренувальної підмножини після етапу фільтрації аномалій здійснюватиметься за допомогою спеціалізованого алгоритму мультимодальної аугментації, детальний опис та експериментальні результати якого наведено в третьому розділі роботи.

2.5 Метрики оцінювання якості та точності нейромережевих моделей

Оцінювання якості розробленого методу передбачає комплексний підхід, оскільки запропонована гібридна архітектура послідовно поєднує етапи прецизійної семантичної сегментації зон обличчя та подальшої класифікації отриманих візуальних і колористичних ознак. Для забезпечення об'єктивного аналізу якості функціонування кожного з модулів формалізовано єдиний набір математичних критеріїв та цільових функцій, що дозволяють верифікувати точність екстракції біометричних даних на мікрорівні пікселів та надійність фінального розпізнавання макрокласів на рівні цілісних зображень.

Для оптимізації параметрів сегментаційної моделі на базі архітектури U-Net у структуру методу закладено використання гібридної цільової функції втрат під час її навчання. З огляду на суттєвий дисбаланс площ між фоном та цільовими антропометричними зонами, першою складовою обрано зважену багатокласову перехресну ентропію, яка обчислюється за формулою 2.14:

$$L_{CE_seg} = -\frac{1}{N} \sum_{j=1}^N \sum_{i=1}^C w_i y_{j,i} \log(\hat{y}_{j,i}) \quad (2.14)$$

де N – загальна кількість пікселів у вхідному тензорі зображення; C – загальна кількість цільових семантичних класів сегментації ($C = 19$); w_i – ваговий коефіцієнт i -го класу, призначений для компенсації кількісного дисбалансу вибірки; $y_{j,i}$ – бінарний індикатор, що набуває значення 1, якщо j -й піксель істинно належить до i -го класу, та 0 в іншому випадку; $\hat{y}_{j,i}$ – передбачена моделлю ймовірність приналежності j -го пікселя до i -го класу.

Другою складовою гібридної цільової функції є просторова функція втрат Dice Loss, яка безпосередньо оптимізує геометричне перекриття масок під час тренування мережі та розраховується за формулою 2.15 [40]:

$$L_{Dice} = 1 - \frac{2TP_{pix}}{2TP_{pix} + FP_{pix} + FN_{pix}} \quad (2.15)$$

де TP_{pix} – кількість істинно позитивних пікселів, які модель правильно віднесла до цільового класу; FP_{pix} – кількість хибно позитивних пікселів, помилково віднесених до класу; FN_{pix} – кількість хибно негативних пікселів, які модель не змогла розпізнати.

Загальна функція втрат сегментаційного конвеєра формується як лінійна комбінація цих двох показників за формулою 2.16:

$$L_{total} = \alpha * L_{CE} + \beta * L_{Dice} \quad (2.16)$$

де α та β – вагові коефіцієнти, що визначають внесок кожної складової (у межах розробленого методу встановлено значення $\alpha = 0.4$, $\beta = 0.6$).

Це дозволяє методу однаково ефективно ідентифікувати як великі ділянки шкіри, так і дрібні деталі обличчя, мінімізуючи втрату контурної інформації.

Для верифікації якості сегментації на етапі тестування передбачається побудова матриці помилок розмірністю 19x19 на рівні окремих пікселів. З метою коректної інтерпретації результатів в умовах кількісного дисбалансу мікро- та

макрокласів, у методі реалізовано механізм логарифмічної нормалізації значень матриці за функцією $\log(1 + x)$. Сама матриця дозволяє структурувати результати передбачень та вилучити для кожного класу точні значення базових змінних TP_{pix} , FP_{pix} , FN_{pix} . На основі отриманих з матриці даних розраховується ключовий показник просторової точності – коефіцієнт IoU за формулою 2.17 [41]:

$$IoU = \frac{TP_{pix}}{TP_{pix} + FP_{pix} + FN_{pix}} \quad (2.17)$$

Для уникнення викривлення результатів через різний розмір сегментованих зон, розрахунок IoU здійснюється з використанням макроусереднення, що передбачає незалежне обчислення метрики для кожного класу з подальшим знаходженням їхнього середнього арифметичного. Додатковим критерієм оцінювання виступає коефіцієнт Соренсена-Дайса, який використовується як метрика контурної стабільності на тестових даних та розраховується за формулою 2.18 [41]:

$$Dice = \frac{2TP_{pix}}{2TP_{pix} + FP_{pix} + FN_{pix}} \quad (2.18)$$

На другому етапі роботи методу, що полягає у класифікації кольоротипу за допомогою гібридної моделі ResNet-18 та багатошарового перцептрона MLP, об'єктом оцінювання виступає вже цілісне портретне зображення у поєднанні з вектором екстрагованих колориметричних ознак. Для оптимізації параметрів класифікатора під час навчання застосовується функція багатокласової перехресної ентропії з механізмом згладжування міток. Вона обчислюється для $K = 4$ цільових класів (сезонів зовнішності) за формулою 2.19 [42]:

$$L_{CE_cls} = - \sum_{i=1}^K y_i^{LS} \log(\hat{y}_i) \quad (2.19)$$

де \hat{y}_i – передбачена моделлю ймовірність для i -го сезону, а y_i^{LS} – модифікована згладжена мітка класу, яка розраховується як $y_i^{LS} = (1 - \alpha) + \frac{\alpha}{K}$ при коефіцієнті згладжування $\alpha = 0.1$.

Такий підхід знижує надмірну впевненість класифікатора та запобігає перенавчанню на суміжних типах зовнішності.

Для комплексної оцінки спроектованого класифікатора на тестовій вибірці формується стандартна матриця помилок розмірністю 4x4, яка фіксує розподіл передбачень між чотирма макрокласами зовнішності: Зима, Літо, Осінь та Весна. З отриманої матриці вилучаються значення істинно позитивних TP , хибно позитивних FP та хибно негативних FN класифікацій на рівні зображень. Головним критерієм загальної ефективності системи виступає показник загальної точності, який визначає частку правильно розпізнаних сезонів зовнішності від загальної кількості тестових зразків (формула 2.20):

$$Accuracy = \frac{M_{correct}}{M_{total}} \quad (2.20)$$

де $M_{correct}$ – кількість зображень, для яких кольоротип визначено правильно; M_{total} – загальна кількість зображень у тестовому наборі даних.

З огляду на можливий дисбаланс представників різних сезонів у наборі даних, для детальної оцінки якості диференціації вводяться метрики влучності та повноти, що розраховуються для кожного класу за формулами 2.21 та 2.22:

$$Precision = \frac{TP}{TP + FP} \quad (2.21)$$

$$Recall = \frac{TP}{TP + FN} \quad (2.22)$$

Для прийняття фінального рішення щодо стабільності роботи гібридного класифікатора обчислюється макро-усереднена F1-міра. Базове значення F1-міри для кожного окремого класу є гармонійним середнім між влучністю та повнотою та розраховується за формулою 2.23:

$$F1 = 2 \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.23)$$

Використання наведеного наскрізного комплексу метрик забезпечує математично обґрунтовану верифікацію системи на обох етапах її функціонування.

2.6 Висновки до розділу 2

У розділі спроектовано алгоритмічний метод визначення кольоротипу зовнішності людини засобами комп'ютерного зору, а також математично обґрунтовано та сформовано його інформаційне забезпечення. За результатами етапу проектування формалізовано задачу та розроблено концепцію послідовного мультимодального конвеєра обробки даних. Він охоплює чотири ключові етапи, які включають просторову семантичну сегментацію вхідного растрового зображення обличчя, біометричну нормалізацію освітлення переднього плану, екстракцію та трансформацію цифрових колірних ознак, а також фінальну гібридну класифікацію для визначення сезону зовнішності.

Для практичної реалізації методу розроблено архітектури нейромережових моделей, орієнтовані на роботу з різнорідними даними. Вирішення задачі просторової ізоляції антропометричних зон покладено на сегментаційний модуль, створений на базі архітектури U-Net з кодувальником ResNet-34 та пропускними зв'язками для формування точних геометричних меж масок. Фінальне розпізнавання сезону зовнішності забезпечується гібридною мультимодальною архітектурною схемою, яка паралельно обробляє візуальний потік через згорткову мережу ResNet-18 та табличний потік через багатошаровий перцептрон. Інтеграція та злиття цих потоків реалізовано за допомогою спеціального механізму уваги Gated Attention, що дозволяє динамічно калібрувати пріоритет кожного джерела інформації при прийнятті кінцевого рішення.

На етапі проектування математично обґрунтовано процеси обробки й екстракції ознак, що дозволяє мінімізувати вплив зовнішніх факторів зйомки. Для

усунення спектрального впливу джерел світла інтегровано метод колірної адаптації фон Кріса, доповнений авторським механізмом м'якої нормалізації у вигляді кліпінгу та згладжування, що дозволяє зберегти натуральний пігмент людини. Вилучення домінуючих колірних осей формалізовано через алгоритм просторової кластеризації K-Means для макрозон шкіри та волосся, а також через розрахунок робастного медіанного вектора для мікрозони райдужки ока. Отримані параметри трансформуються у перцептивно рівномірний колірний простір CIELAB, на основі якого обчислюються остаточні аналітичні метрики світлотного контрасту та загальної теплоти зовнішності, що формують структурований табличний вектор ознак.

У межах формування методу визначено та теоретично обґрунтовано базові набори даних для подальшого навчання моделей. Для модуля семантичної сегментації обрано великий масив CelebAMask-HQ, для якого розроблено стратегію структурної адаптації шляхом злиття всіх нецільових деталей зображення з фоном. Для класифікаційного модуля обрано вибірку Deep Arthropodia. За результатами її розвідувального аналізу виявлено критичний рівень візуального шуму, кількісного дисбалансу та колірних аномалій розмітки, що зумовило потребу в розробці авторського конвеєра попередньої підготовки. Для вирішення цих проблем спроектовано алгоритмічний фільтр на базі дерев рішень та закладено логіку синхронної мультимодальної аугментації, які будуть застосовані на етапі експериментального дослідження для створення збалансованого набору даних.

Для комплексної оцінки сегментації обґрунтовано комбінацію багатокласової перехресної ентропії та функції втрат Dice Loss із тестуванням за коефіцієнтами IoU та Соренсена-Дайса. Надійність класифікатора забезпечується перехресною ентропією зі згладжуванням міток, а фінальне розпізнавання перевіряється за показниками загальної точності, влучності, повноти й макросередньої F1-міри. Сформований базис повністю вирішує завдання етапу проектування і створює підґрунтя для експериментального дослідження та програмної реалізації.

Розділ 3 Програмна реалізація та експериментальне дослідження методу

3.1 Засоби програмної реалізації та опис застосунку

Для експериментальної перевірки розробленого методу та автоматизації процесу колористичного аналізу спроектовано та реалізовано інтерактивний програмний застосунок. Базовою мовою програмування обрано Python, що є стандартом для розробки систем штучного інтелекту завдяки високій швидкості прототипування та широкій екосистемі наукових бібліотек.

Для побудови візуального інтерфейсу та клієнт-серверної архітектури застосовано фреймворк Streamlit [43]. Його використання дозволило реалізувати повноцінний веб-застосунок із вбудованим управлінням станом сесії, що забезпечує послідовне проходження етапів аналізу без необхідності розробки складного коду для фронтенду.

Математичне забезпечення нейромережових обчислень реалізовано за допомогою відкритого фреймворку глибокого навчання PyTorch [44]. Цей інструмент гарантує ефективне використання апаратних прискорювачів через механізм тензорних обчислень. Для ініціалізації та конфігурації моделі семантичної сегментації U-Net використано спеціалізовану бібліотеку SMP [45]. Функції попередньої обробки зображень, матричних трансформацій та перетворень колірних просторів реалізовані за допомогою бібліотеки комп'ютерного зору OpenCV [46]. Для прецизійної локалізації антропометричних точок обличчя застосовано фреймворк MediaPipe. Задачі класичного машинного навчання на етапі екстракції ознак вирішуються за допомогою алгоритмів бібліотеки Scikit-learn [47], а фундаментальні математичні операції над масивами пікселів забезпечуються модулем NumPy [48].

Наскрізний алгоритм роботи спроектованого застосунку та логіку ініціалізації процесу інференсу наведено на рисунку 3.1.

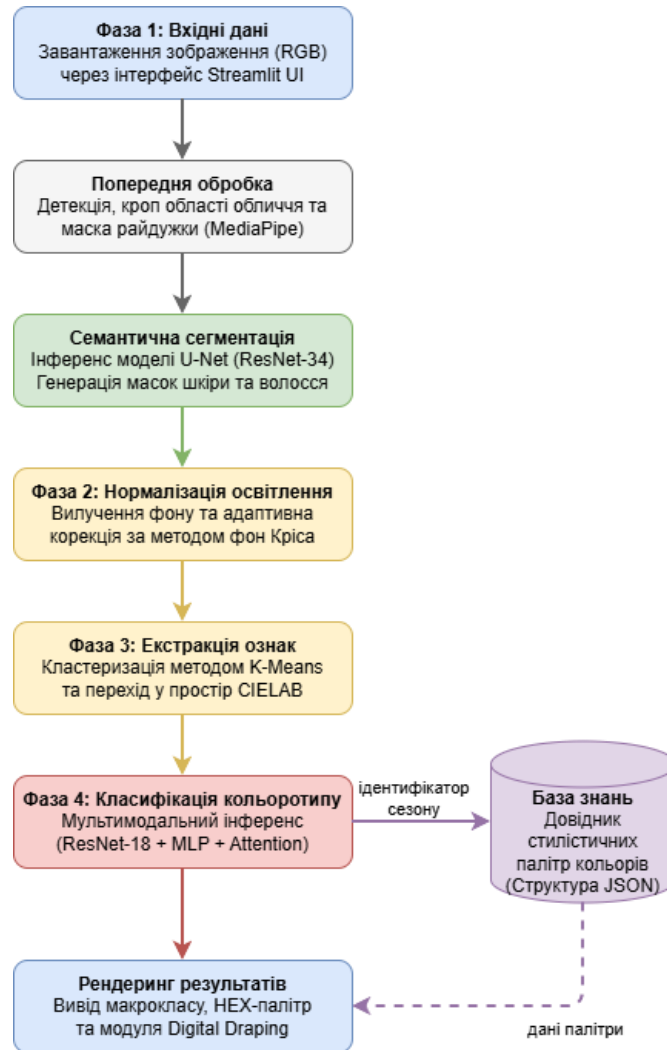


Рисунок 3.1 – Структурна блок-схема алгоритму роботи програмного застосунку

Процес обробки даних ініціюється послідовно через взаємодію користувача з інтерфейсом та складається з декількох логічно пов'язаних етапів. Робота системи розпочинається із завантаження користувачем растрового зображення. Застосунок перетворює вхідний файл у багатовимірний числовий масив, після чого модуль MediaPipe виконує первинну детекцію. На цьому етапі відбувається просторове кадрування та центрування обличчя, що є необхідним для відсікання зайвого фону. Паралельно з цим генерується точкова бінарна маска райдужки ока за ключовими антропометричними координатами. Далі відцентроване зображення масштабується до розміру 512x512 пікселів, трансформується у тензор та передається до моделі U-Net. На основі прямого поширення сигналу мережа генерує 19 шарів ймовірностей, з яких за допомогою

оператора максимального аргументу виокремлюються фінальні семантичні маски шкіри та волосся.

Отримавши загальну маску обличчя, застосунок накладає її на оригінальне зображення, повністю ізолюючи цільовий об'єкт від фонового шуму. Відразу після цього ініціюється функція біометричної нормалізації. Програмний алгоритм аналізує найяскравіші пікселі шкіри (верхні 10% за інтенсивністю) та застосовує адаптивний метод фон Кріса з механізмом м'якого кліпінгу. Це дозволяє вирівняти баланс білого та нівелювати спектральний вплив зовнішніх джерел світла, зберігши при цьому природний пігмент людини.

Наступним кроком є екстракція кольірних ознак. Нормалізоване зображення конвертується за допомогою засобів OpenCV з формату RGB у перцептивний простір CIELAB. Програма накладає семантичні маски шкіри та волосся на цей кольірний простір і запускає кластеризацію K-Means. З метою ігнорування тіней та відблисків система автоматично обирає центроїд найбільшого кластера, тоді як для мікрозони райдужки ока обчислюється робастний медіанний вектор. На основі отриманих даних у пам'яті програми формується фінальний табличний вектор із 12 ключових колориметричних ознак.

Завершальна стадія обробки полягає у виконанні мультимодальної класифікації та рендерингу результатів. Згенерований вектор ознак нормалізується та конвертується у тензор, тоді як нормалізоване зображення обличчя перетворюється у тривимірний масив розмірністю 224x224. Обидва потоки даних паралельно передаються до завантаженої в оперативну пам'ять гібридної моделі класифікатора, що базується на архітектурі ResNet-18 та багатощаровому перцептроні. Після інтеграції ознак через механізм уваги, модель обчислює та видає вектор ймовірностей для чотирьох макрокласів зовнішності.

Отримавши індекс переможного класу, застосунок звертається до локальної бази знань, реалізованої у форматі структурованого JSON-файлу.

Формування самої бази знань здійснювалося на основі оцифрованих експертних стандартів класичної теорії сезонного колориту. Палітри для кожного з чотирьох макрокласів алгоритмічно переведено у шістнадцятковий формат та

згруповано за функціональним призначенням. Для кожного сезону визначено еталонні групи: базові кольори гардероба, акцентні кольори, відтінки для макіяжу та кольори зони ризику. Такий підхід гарантує, що автоматично згенеровані застосунком рекомендації відповідають професійним стилістичним правилам.

Система автоматично вилучає відповідні шістнадцяткові коди базових, акцентних та заборонених відтінків, після чого рендерить їх в інтерфейсі користувача у вигляді інтерактивних палітр. Логічним фіналом роботи конвеєра є ініціалізація модуля цифрового драпінгу. Завдяки розмиттю меж сегментаційної маски цей модуль накладає обличчя користувача на згенеровані колірні фони, наочно демонструючи ефективність розрахованих стилістичних рекомендацій.

3.2 Експериментальне дослідження алгоритмів підготовки даних та навчання моделей

Експериментальне дослідження присвячено практичній реалізації та тестуванню розроблених алгоритмічних рішень. Процес тестування охоплює повний цикл роботи з даними: від первинної фільтрації та усунення аномалій розмітки до мультимодальної аугментації та безпосереднього тренування нейромережових моделей. Основною метою проведених експериментів є верифікація точності запропонованого конвеєра та оцінка динаміки збіжності моделі семантичної сегментації (U-Net) і гібридного класифікатора (ResNet-18 + MLP) у процесі оптимізації їхніх вагових коефіцієнтів.

3.2.1 Алгоритмічна фільтрація навчальної вибірки та усунення аномалій

Практична реалізація розроблених алгоритмів попередньої обробки та фільтрації застосовувалася до спеціалізованого набору даних Deer Armochromia. Відповідно до базової системи класифікації, його вихідні дванадцять підтипів агреговано у чотири цільові макрокласи: зима, літо, осінь та весна. Оскільки

оригінальний масив характеризується наявністю значної кількості візуального шуму та експертних помилок розмітки, його вихідна структура підлягала суттєвій алгоритмічній модифікації для створення якісного еталонного простору ознак.

Для ізоляції цільових атрибутів реалізовано автоматизований конвеєр обробки. Він передбачає просторову нормалізацію кадру шляхом детекції області обличчя з подальшим застосуванням моделі семантичної сегментації U-Net. Для нівелювання варіативності зовнішнього освітлення виконується процедура адаптивної біометричної нормалізації за формулами (2.3)–(2.4). Екстракція домінуючих колірних ознак із макрозон шкіри та волосся здійснюється на основі просторової кластеризації за цільовою функцією (2.5), тоді як для мікрозони райдужки ока розраховується робастний медіанний вектор згідно з виразом (2.6). Наступна колірна трансформація отриманих компонентів у перцептивно рівномірні координати реалізується за рівняннями (2.7)–(2.9), після чого обчислюються остаточні аналітичні метрики світлотного контрасту та загальної теплоти зовнішності за формулами (2.10)–(2.11). На основі згенерованих семантичних масок усі другорядні зони замінено на нейтральний сірий фон зі значенням інтенсивності пікселів $[128, 128, 128]$, що дозволило повністю усунути вплив стороннього колірного шуму.

Після завершення етапу екстракції ознак початковий обсяг вибірки склав 4804 зображення. Для верифікації якості сформованого ознакового простору проведено розвідувальний аналіз. На рисунку 3.2 наведено візуалізацію розподілу зображень у двовимірному просторі ознак за осями загальної теплоти зовнішності та світлотного контрасту.




Рисунок 3.2 – Діаграма розсіювання простору ознак до застосування алгоритмів фільтрації

Аналіз отриманого розподілу виявив суттєвий рівень шуму, хаотичного накладання та взаємного перекриття об'єктів у вихідній експертній розмітці. Значна кількість зображень містила внутрішні математичні суперечності, що унеможливило побудову стійких роздільних поверхонь класифікатора.

Для математичного очищення набору даних застосовано алгоритмічний підхід на основі дерев рішень. Оптимізація критерію неоднорідності дозволила в автоматичному режимі розрахувати оптимальні фізичні пороги контрастності, світлоти волосся та теплоти шкіри для кожного макрокласу (таблиця 3.1).

Таблиця 3.1 – Обчислені фізичні пороги для фільтрації аномалій розмітки

Критерій фільтрації	Математична ознака	Формула	Обчислене значення порогу
Поріг загальної теплоти	Загальна теплота	(2.11)	34.13
Поріг світлотного контрасту	ΔL^* (Контраст)	(2.10)	42.25
Поріг світлоти волосся	L^* волосся	(2.7)	30.49

Поріг теплоти шкіри	b^* шкіри	(2.9)	22.46
---------------------	-------------	-------	-------

Усі зображення, чії екстраговані ознаки порушували виявлені математичні межі, розцінено як аномалії розмітки та повністю вилучено з набору даних. В результаті застосування цих правил фільтрації видалено 2987 суперечливих зразків. Результат просторового розподілу 1817 об'єктів, що залишилися після завершення етапу алгоритмічної фільтрації, наведено на рисунку 3.3.

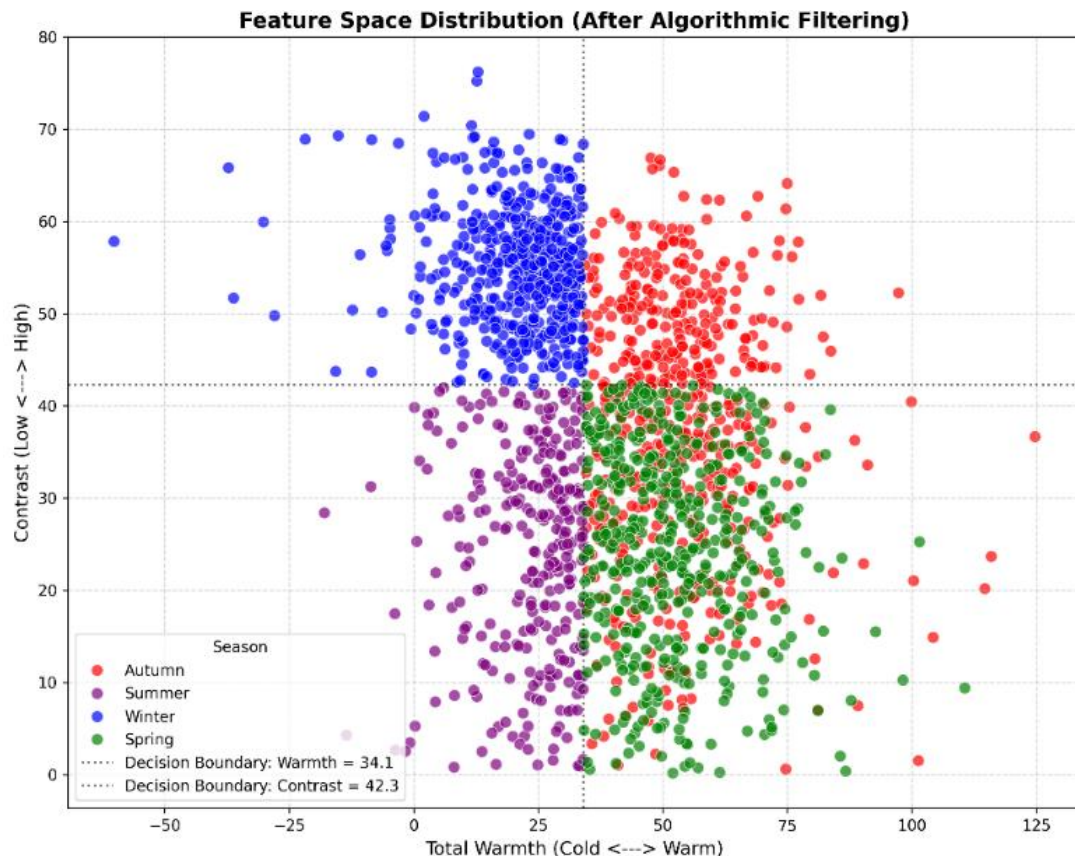


Рисунок 3.3 – Просторовий розподіл макрокласів після застосування алгоритмічної фільтрації на базі дерев рішень

Відсікання колірних аномалій дозволило сформувати еталонний простір ознак із чіткими межами розділення класів. Проте наслідком такого очищення стало виникнення вираженого кількісного дисбалансу між цільовими макрокласами. Розподіл верифікованих об'єктів склав: осінь – 531, зима – 511, весна – 485, літо – 290 зображень (рисунок 3.4).

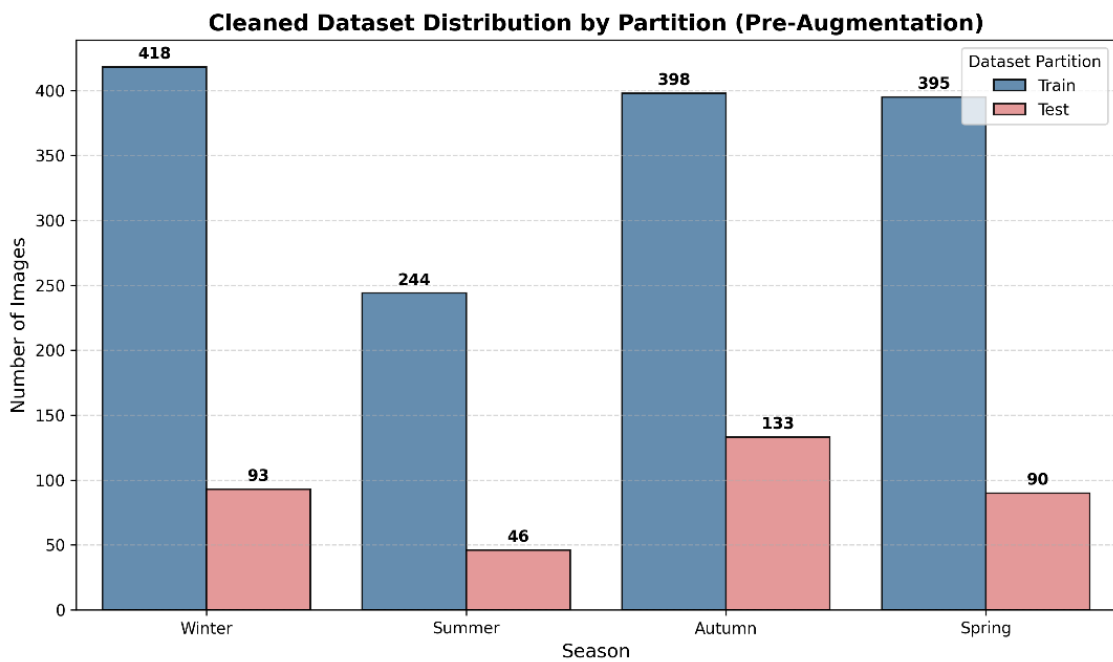


Рисунок 3.4 – Кількісний розподіл очищеного набору даних за класами та вибірками до застосування аугментації

Згідно з методологією, очищений масив стратифіковано на тренувальну та тестову підмножини. Тестова вибірка, яка налічує по 100 оригінальних зображень для кожного з чотирьох макрокласів (загалом 400 об'єктів), суворо ізольована для фінальної перевірки.

Для усунення дисбалансу навчальної вибірки, що складає 1417 об'єктів застосовано розроблений конвеєр мультимодальної аугментації. Його специфіка полягає в одночасній синхронній трансформації обох потоків даних. Для візуального потоку обробки застосовуються випадкові просторові перетворення, зокрема горизонтальне віддзеркалення та геометричний поворот у діапазоні від -10 до +10 градусів. Паралельно з цим, для табличного потоку виконується стохастичне додавання гауссового шуму до компонентів екстрагованого вектора ознак у межах 5% від їхнього стандартного відхилення. Алгоритм генерації здійснював динамічний контроль, блокуючи вихід зашумлених числових ознак за раніше знайдені пороги з таблиці 3.1.

Приклад функціонування мультимодального генератора наведено на рисунку 3.5.

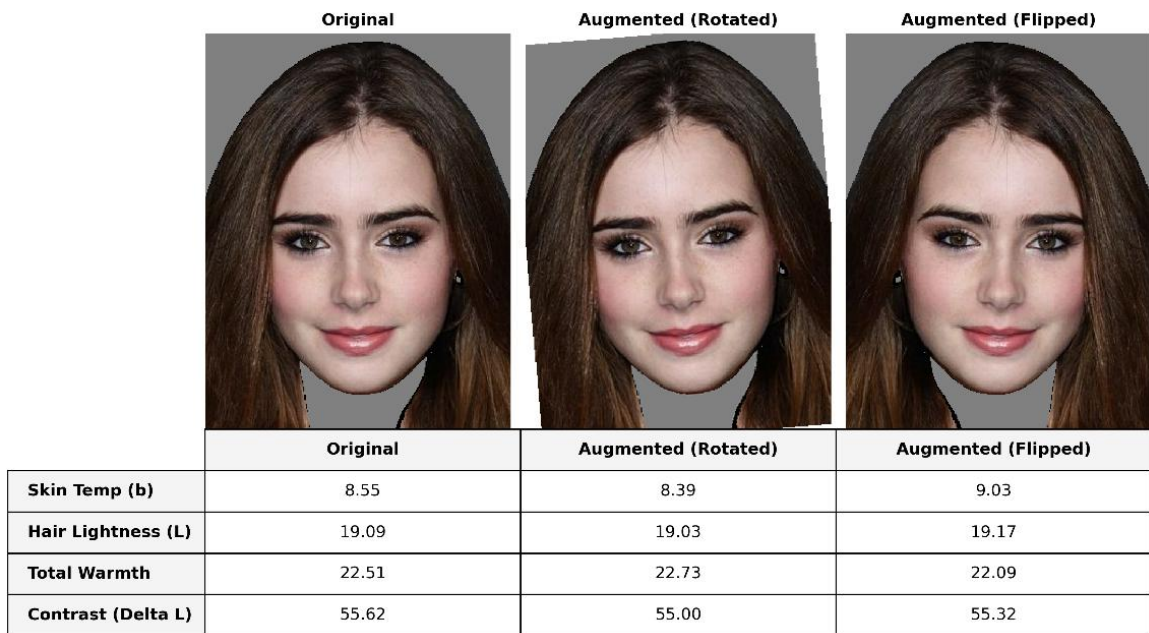


Рисунок 3.5 – Приклад роботи алгоритму мультимодальної аугментації навчальної вибірки

В результаті виконання описаних процедур фільтрації та генерації сформовано остаточний набір даних. Кількісні характеристики ідеально збалансованого масиву, що налічує 2400 репрезентативних об'єктів (по 600 на кожен макроклас), наведено на рисунку 3.6.

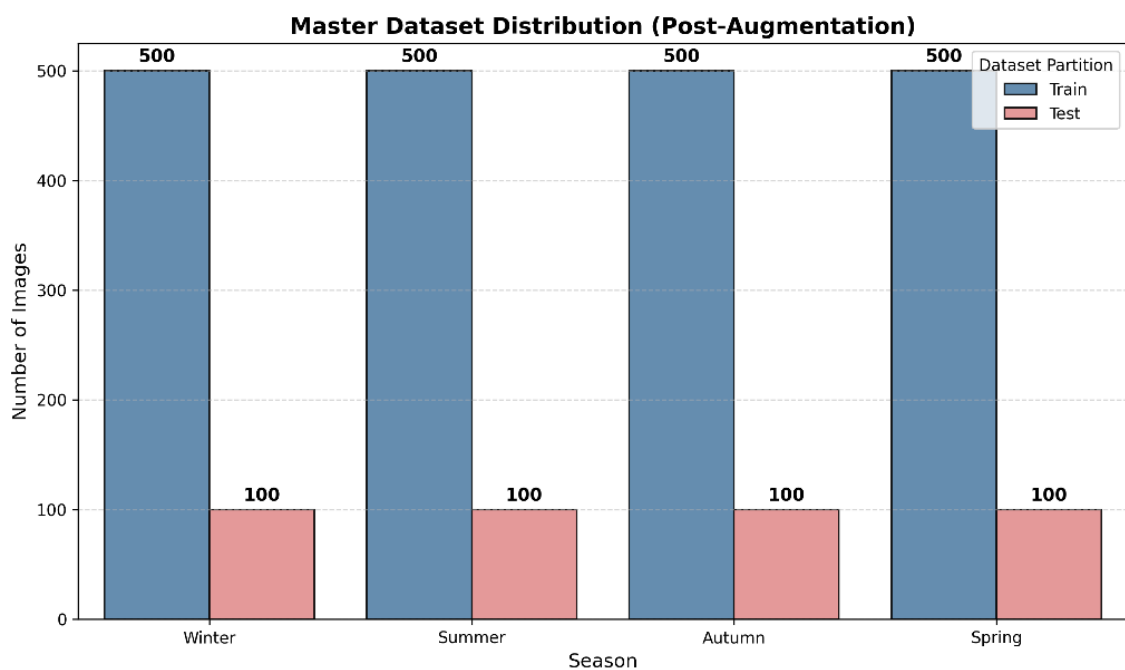


Рисунок 3.6 – Кількісний розподіл остаточного масиву даних після застосування мультимодальної аугментації

Для забезпечення коректного процесу навчання та уникнення витоку даних, збалансований масив навчальної вибірки об'ємом 2000 об'єктів, що містить по 500 зображень для кожного з чотирьох сезонних макрокласів, було додатково розділено на дві підмножини. Протокол розподілу передбачає виділення 1700 зразків (85%) для внутрішньої тренувальної вибірки та 300 об'єктів (15%) для валідації. Завдяки застосуванню алгоритму стратифікації було забезпечено збереження суворої рівномірної пропорції класів: тренувальна підмножина містить по 425 зображень для кожного сезону (Зима, Літо, Осінь, Весна), а валідаційна – по 75 зразків відповідно. Тестова вибірка, яка налічує 400 зразків (по 100 об'єктів для кожного з чотирьох макрокласів), залишалася повністю ізольованою від циклу тренування і використовувалася виключно для об'єктивної оцінки узагальнюючої здатності алгоритму.

Таким чином, сформовано репрезентативний та математично верифікований набір даних, очищений від експертних помилок розмітки та візуального шуму. Застосування алгоритмів фільтрації на базі дерев рішень дозволило стабілізувати простір ознак. Впровадження методу мультимодальної аугментації нівелювало проблему кількісного дисбалансу, створивши надійне підґрунтя для навчання гібридної нейромережевої моделі класифікації.

3.2.2 Оцінка процесу навчання моделі семантичної сегментації

Першим етапом навчання мультимодального конвеєра стала оптимізація ваг моделі семантичної сегментації U-Net. Головним завданням цієї нейромережі є ізоляція цільових біометричних зон від фонового візуального шуму.

В якості магістральної архітектури обрано згорткову мережу ResNet-34 із попередньо ініціалізованими вагами. Для забезпечення відтворюваності експерименту та досягнення максимальної точності сегментації, конфігурацію процесу навчання строго регламентовано. Основні гіперпараметри та архітектурні налаштування моделі наведено у таблиці 3.2.

Таблиця 3.2 – Гіперпараметри та налаштування процесу навчання моделі

Назва параметра	Значення/Алгоритм	Обґрунтування вибору
Алгоритм оптимізації	Adam	Забезпечує адаптивну швидкість навчання для кожного параметра
Швидкість навчання	5×10^{-5}	Знижене значення для плавного оновлення вагових коефіцієнтів та уникнення розбіжності градієнтів.
Функція втрат	Cross-Entropy + Dice Loss	Запобігає ігноруванню моделлю дрібних біометричних зон.
Batch Size	4	Оптимальний максимум, зумовлений апаратними обмеженнями оперативної пам'яті
Аугментація даних	Affine, Blur, CoarseDropout	Збільшує варіативність вибірки, симулюючи складні побутові умови зйомки.

Для моніторингу динаміки навчання на кожній ітерації фіксувалися значення функцій втрат (формула 2.16) та загальної метрики перетину по об'єднанню IoU, що обчислюється згідно з формулою 2.17. Повний журнал навчання наведено у таблиці 3.3.

Таблиця 3.3 – Динаміка метрик у процесі навчання моделі U-Net

Епоха	Тренувальний Loss	Валідаційний Loss	IoU
1	0.2788	0.1822	0.7234
3	0.1574	0.1640	0.7522
6	0.1237	0.1541	0.7641
9	0.1125	0.1908	0.7352

Для наочного аналізу швидкості збіжності моделі та детального моніторингу процесу навчання побудовано відповідні графіки. Візуалізація результатів оптимізації складається з двох взаємопов'язаних діаграм: на лівому графіку відображено динаміку зміни значень функції втрат для тренувальної та валідаційної вибірок упродовж дев'яти епох, тоді як на правому графіку проілюстровано криву зростання цільової метрики перетину по об'єднанню.

Отримані графічні залежності наведено на рисунку 3.7.

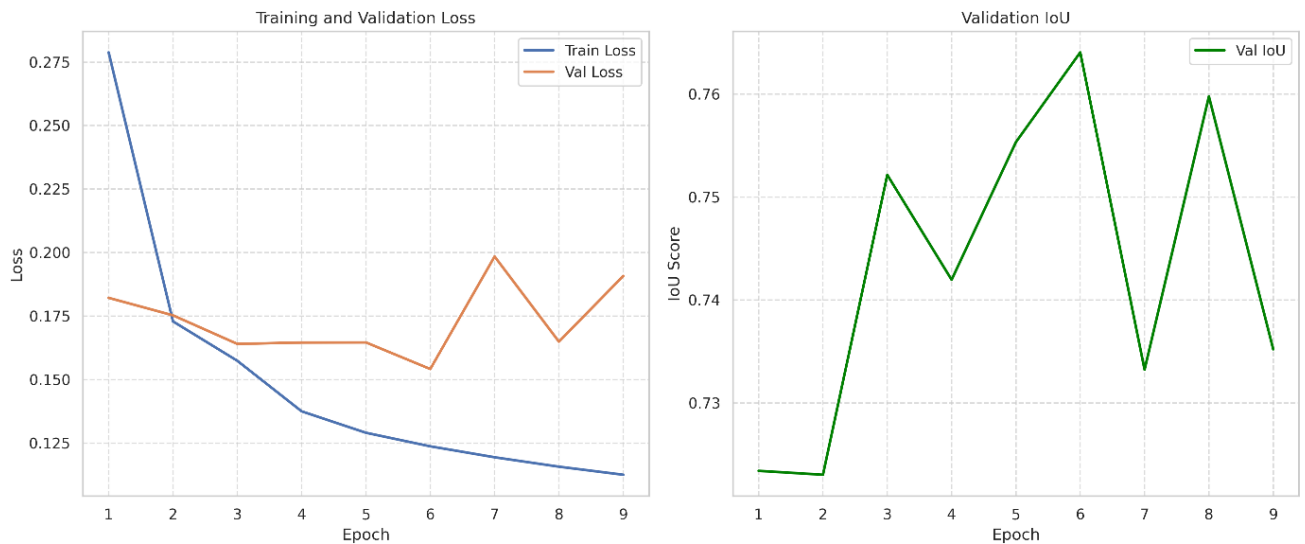


Рисунок 3.7 – Динаміка функцій втрат та метрики IoU під час навчання моделі U-Net

Аналіз лінійного графіка демонструє закономірну оптимізаційну поведінку. Крива тренувальної похибки монотонно спадає, що є прямим свідченням успішної адаптації вагових коефіцієнтів. Валідаційна похибка та загальна метрика демонструють осцилюючу динаміку. Наявність таких локальних коливань пояснюється малим розміром пакету даних та агресивними методами аугментації, які суттєво змінювали візуальний розподіл ознак на кожній ітерації.

Незважаючи на те, що абсолютний математичний максимум загальної метрики зафіксовано на шостій епосі, подальші ітерації (епохи 7-9) продемонстрували різке зростання валідаційної похибки та падіння точності. Таке архітектурне рішення ухвалено на основі додаткового якісного візуального аудиту: саме шоста ітерація продемонструвала найвищу стабільність меж сегментації шкіри та волосся в умовах складного освітлення, успішно ігноруючи похибки оригінальної розмітки навчального датасету. Застосування алгоритму фіксації ваг на цьому етапі дозволило повністю нівелювати ризик перенавчання системи.

Оцінка експортованої моделі на незалежній тестовій вибірці підтвердила її високу ефективність (рисунок 3.8).

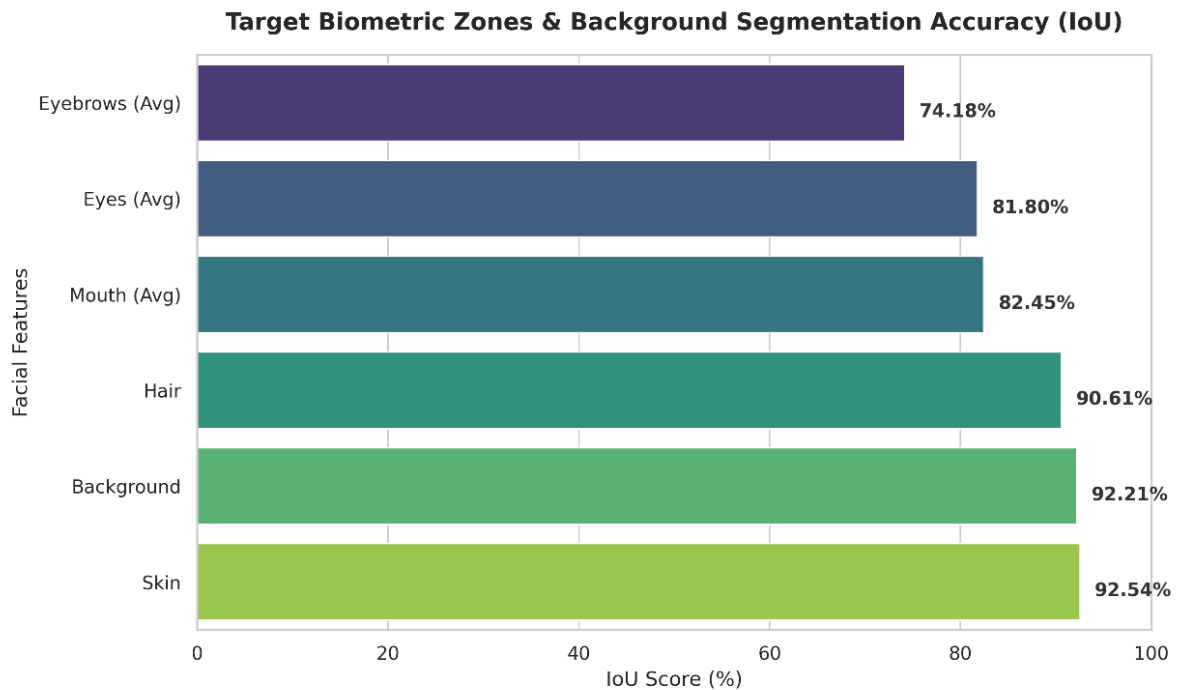


Рисунок 3.8 – Точність сегментації цільових біометричних зон та фону на тестовій вибірці

Під час тестування фокус зміщено виключно на цільові біометричні класи та фон, оскільки допоміжні елементи (одяг, аксесуари) не використовуються у подальшому колористичному аналізі. Цільова макро-усереднена F1-міра склала 0.8536, а Macro IoU досягла позначки 0.8010.

Детальний аналіз стовпчастої діаграми свідчить, що алгоритм демонструє безпрецедентну точність ізоляції ключових макрозон: показники сегментації пікселів фону, шкіри та волосся є найвищими серед усіх метрик (понад 90%). Такі результати повністю задовольняють архітектурні вимоги системи та гарантують відсутність шумових пікселів під час ініціалізації наступного етапу – біометричної нормалізації освітлення.

3.2.3 Оцінка процесу навчання гібридної моделі класифікації

Після завершення етапу попередньої підготовки та мультимодальної аугментації даних ініційовано процес навчання гібридної класифікаційної моделі (ResNet-18 + MLP). Метою цього етапу є оптимізація вагових коефіцієнтів

нейронної мережі для забезпечення максимальної точності розпізнавання чотирьох сезонних макрокласів зовнішності.

Процес навчання конфігуровано з урахуванням складної архітектури моделі та необхідності синхронізації різнорідних потоків даних. Для запобігання деградації градієнтів та забезпечення рівномірної збіжності застосовано стратегію диференційованої швидкості навчання. Повний перелік архітектурних налаштувань та оптимізаційних гіперпараметрів, що використовувалися під час тренування, наведено у таблиці 3.4.

Таблиця 3.4 – Гіперпараметри та налаштування процесу навчання гібридної моделі

Назва параметра	Значення/Алгоритм	Обґрунтування вибору
Алгоритм оптимізації	AdamW	Забезпечує адаптивну швидкість навчання з оптимізованим механізмом регуляризації.
Швидкість навчання (ResNet-18 та Attention)	1×10^{-3}	Базова швидкість для швидкої адаптації повнозв'язних шарів ResNet-18 та механізму Attention Gate.
Швидкість навчання (MLP)	5×10^{-4}	Знижена швидкість для компенсації швидкої збіжності простих табличних ознак відносно складних візуальних.
Функція втрат	Cross Entropy	Оптимальна для багатокласової класифікації.
Label Smoothing	0.1	Знижує надмірну впевненість моделі на суміжних класах, запобігаючи перенавчанню.
Scheduler	ReduceLROnPlateau	Динамічно зменшує швидкість навчання вдвічі, якщо макро-F1 міра не покращується протягом 2 епох.
Batch Size	32	Забезпечує оптимальний баланс між швидкістю навчання та стабільністю градієнтів в оперативній пам'яті.

Для моніторингу динаміки оптимізації на кожній епісі обчислювалися значення функції втрат (2.19) та загальної точності (2.20) як для тренувальної, так і для незалежної валідаційної вибірки. Також фіксувався показник F1-міри для контролю балансу між влучністю та повнотою розпізнавання. Такий підхід дозволив забезпечити безперервний контроль траєкторії оптимізації параметрів та об'єктивно встановити момент досягнення гібридною моделлю стану глобальної збіжності. Витяг із журналу навчання для ключових контрольних точок наведено у таблиці 3.5.

Таблиця 3.5 – Динаміка метрик у процесі навчання гібридної моделі

Епоха	Тренувальний Loss	Валідаційний Loss	Тренувальна точність (%)	Валідаційна точність (%)	Валідаційна F1-міра
1	0.9308	0.7515	69.71	81.33	0.8137
5	0.5476	0.5691	91.41	89.00	0.8886
10	0.5127	0.5257	93.12	90.33	0.9043
14	0.4824	0.5341	94.76	93.00	0.9282
15	0.4957	0.5480	94.35	92.33	0.9219

Для наочного аналізу швидкості збіжності моделі побудовано графіки динаміки функції втрат, які наведено на рисунку 3.9.

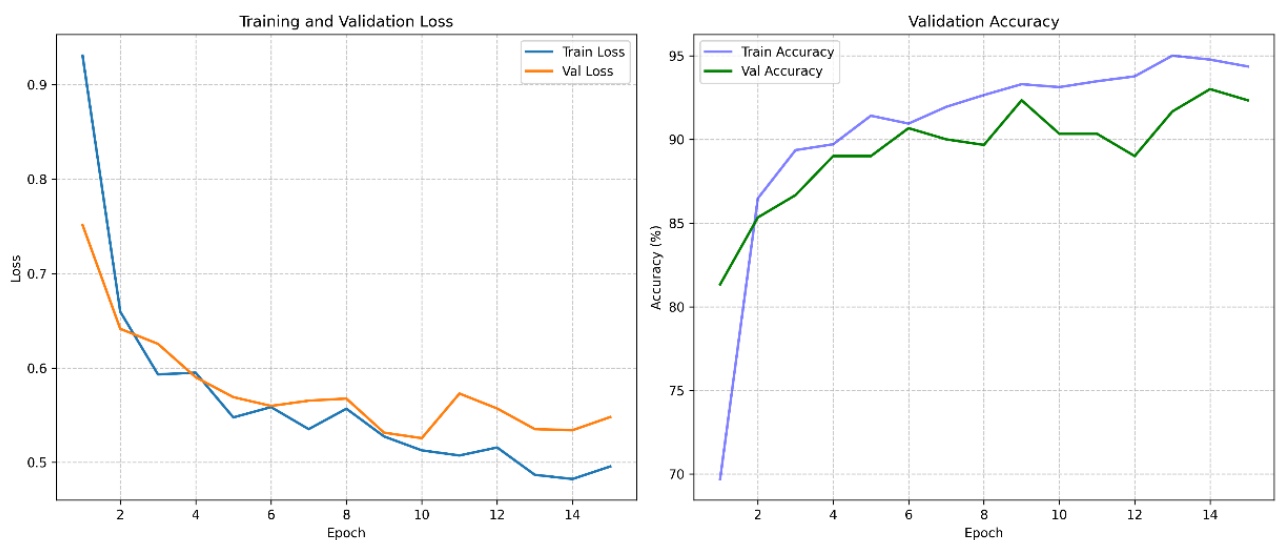


Рисунок 3.9 – Графіки динаміки функцій втрат та точності гібридної моделі

Аналіз отриманих кривих навчання демонструє класичну поведінку глибоких гібридних моделей із високим рівнем регуляризації. Лінія тренувальної похибки стабільно спадає, досягаючи значення 0.4824, що свідчить про успішне вилучення моделлю математичних закономірностей з вектора ознак.

Криві валідаційної похибки та валідаційної точності демонструють немонотонну збіжність. Такі коливання є очікуваними: вони спричинені агресивним використанням шарів проріджування (Dropout з імовірністю 0.3 та 0.4), які навмисно вносять шум у мережу на кожній епосі для запобігання перенавчанню. Крім того, складність синхронізації візуального та табличного потоків через механізм уваги призводить до локальних коливань метрик.

Ключовою точкою оптимізації стала Епоха 14. Саме на цьому етапі модель досягла стану глобальної збіжності: валідаційна точність зафіксувала свій абсолютний максимум на рівні 93.00%, а функція втрат опустилася до локального мінімуму 0.5341. Подальше тренування призвело до початку деградації метрик на незалежній вибірці (зростання Val Loss до 0.5480 та падіння точності до 92.33%), що є індикатором початку процесу перенавчання.

Завдяки реалізованому в алгоритмі механізму збереження контрольних точок, процес деградації проігноровано системою. Фінальними вагами гібридного класифікатора, які були автоматично збережені та експортовані для інтеграції у програмний застосунок, стали параметри Епохи 14 з максимальною F1-мірою 0.9282.

3.3 Тестування методу та оцінка результатів класифікації

Для верифікації загальної точності розробленого алгоритмічного методу проведено тестування на незалежній відкладеній вибірці. Цей масив даних ізольовано на початку дослідження, що гарантує відсутність ефекту перенавчання та об'єктивність отриманих метрик. Тестова вибірка є ідеально збалансованою та містить 400 оригінальних зображень – по 100 об'єктів для кожного з чотирьох макрокласів зовнішності (Зима, Літо, Осінь, Весна).

Під час тестування кожне зображення проходило повний цикл обробки через розроблений мультимодальний конвеєр: від просторової сегментації обличчя та біометричної нормалізації освітлення до екстракції колориметричних ознак та їхнього фінального інференсу гібридною нейромережевою моделлю.

Для детального аналізу розподілу передбачень мережі та виявлення прихованих закономірностей у помилках класифікатора було побудовано матрицю помилок розмірністю 4x4 (рисунок 3.10). Це дозволяє не лише констатувати факт помилки, але й відстежити напрямок хибного зміщення алгоритму між суміжними класами.

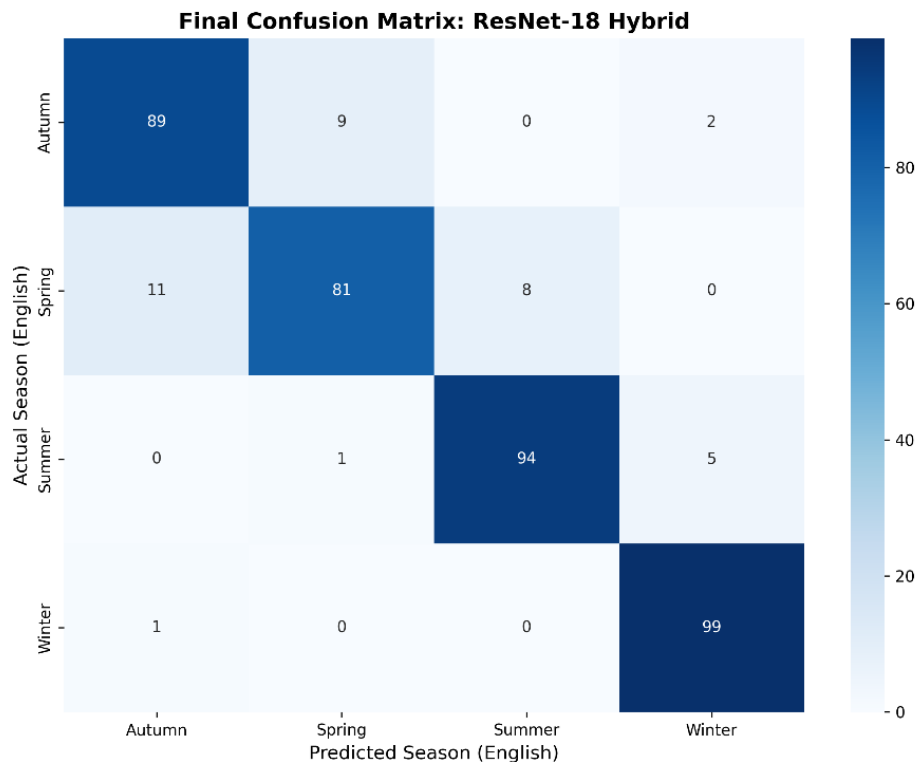


Рисунок 3.10 – Матриця помилок гібридної моделі на тестовій вибірці

Аналіз елементів головної діагоналі матриці підтверджує високу стабільність роботи алгоритмічного комплексу: система безпомилково класифікувала переважну більшість тестових зразків. З метою комплексної математичної оцінки надійності запропонованої моделі, на основі даних матриці помилок розраховано ключові метрики ефективності для кожного макрокласу: Precision, Recall та F1-score, що обчислюються за рівняннями (2.21)-(2.23) відповідно. Зведені результати тестування наведено у таблиці 3.6.

Таблиця 3.6 – Підсумкові метрики ефективності класифікації кольоротипу

Макроклас зовнішності	Precision	Recall	F1-score	Кількість зразків
Зима	0.93	0.99	0.96	100
Літо	0.92	0.94	0.93	100
Осінь	0.88	0.89	0.89	100
Весна	0.89	0.81	0.85	100
Accuracy	-	-	0.91	400

Отримані результати кількісного аналізу свідчать про те, що показник Accuracy розробленого методу становить 91%. Для задачі багатокласової

класифікації візуальних об'єктів зі складними колірними переходами такий рівень точності є високим та підтверджує правильність обраних архітектурних рішень. Детальний аналіз розрахованих метрик у розрізі окремих макрокласів дозволяє глибше зрозуміти специфіку роботи розробленої моделі. Найвищу розпізнавальну здатність гібридний алгоритм демонструє для холодних та контрастних типів зовнішності: макроклас «Зима» класифікується з найвищим показником F1-score на рівні 0.96, а макроклас «Літо» – з показником 0.93. Це закономірно пояснюється чітко вираженими математичними порогами світлотного контрасту та загальної температури шкіри, які успішно екстрагуються алгоритмом просторової кластеризації для цих типів.

Цей тип зовнішності характеризується найвищою оптичною мінливістю, м'якими тепло-холодними переходами та низьким природним контрастом, що робить його візуально спорідненим з іншими суміжними типами. Як наочно видно з розподілу у матриці помилок, найбільша кількість хибних спрацювань алгоритму зафіксована саме для класу «Весна»: 11 випадків було хибно віднесено до макрокласу «Осінь», а 8 випадків – до макрокласу «Літо». Також спостерігається і зворотне змішування ознак, де 9 зразків класу «Осінь» нейромережа розпізнала як «Весна». Такі похибки є прямим наслідком надзвичайної близькості їхніх центроїдів у багатовимірному просторі колірних ознак CIELAB.

Загалом, результати інференсу на повністю відкладеній тестовій вибірці математично доводять високу дієздатність та надійність спроектованого методу. Система здатна стабільно ізолювати ключові біометричні ознаки та класифікувати сезонний тип зовнішності з високим рівнем точності. Це виключає суб'єктивний фактор при визначенні кольоротипу та створює підґрунтя для переходу до фінального етапу – автоматизованої генерації персоналізованих візуальних рекомендацій.

3.4 Генерація персоналізованих рекомендацій візуального образу

Завершальним етапом роботи є практична демонстрація функціонування методу на тестовому зображенні в умовах реального використання. Після успішного навчання ізольованих нейромережових моделей, їх інтегровано в єдиний програмний застосунок для генерації кінцевих колірних рекомендацій. Що забезпечує наскрізне керування потоками даних, автоматизуючи перехід від обробки растрового зображення до формування результируючих HEX-кодів палітри.

Розроблений програмний застосунок виконує роль інтегрованої екосистеми, що автоматизує та керує потоками даних між усіма розробленими алгоритмами. Під час практичного використання достатньо завантажити вхідне портретне зображення, після чого система самостійно ініціює послідовне виконання всього конвеєра. Особливістю даного тестування є використання фотографії зі складним фоном та наявністю виражених тіней. Це дозволяє об'єктивно оцінити стійкість алгоритмів до візуального шуму в умовах, які є характерними для зйомки без застосування спеціалізованого освітлювального обладнання.

Після отримання файлу застосунок активує модуль просторової нормалізації та передає сформований тензор зображення на вхід моделі U-Net. Апаратне відсікання фону на цьому етапі є важливим оскільки наявність сторонніх кольорових елементів (наприклад, яскравих деталей інтер'єру чи неоднорідного освітлення заднього плану) здатна суттєво спотворити результати кластеризації пікселів. Лише після формування точних семантичних масок цільових біометричних зон система переходить до математичної екстракції ознак у просторі CIELAB з подальшою їх передачею до гібридного класифікатора.

Детальний покроковий процес наскрізної обробки зображення та генерації персоналізованої колірної палітри наведено на рисунку 3.11.



Рисунок 3.11 – Етапи обробки вхідного зображення та генерація персоналізованої колірної палітри: а) вхідне зображення; б) сегментація та екстракція ознак; в) генерація візуальних рекомендацій

Як видно з візуалізації проміжних результатів (Частина б), модель семантичної сегментації U-Net успішно ізолює цільові зони (шкіру та волосся), повністю ігноруючи фоновий візуальний шум (елементи інтер'єру), що на оригінальному кадрі (Частина а) міг би призвести до хибної класифікації.

Екстрагований вектор ознак підтверджує високий рівень світлотного контрасту ($\Delta L = 59.61$), що алгоритмічно відповідає фізичним порогам макрокласу «Зима».

Візуальний аудит фінального етапу (Частина в) доводить коректність роботи інтеграційного модуля: на основі передбаченого неймерережею класу система успішно звертається до структурованого JSON-сховища з конфігураціями палітр (використовуючи функцію відображення за рівнянням 2.13) та генерує персоналізовану рекомендацію візуального образу, виводячи на екран користувача валідовану палітру домінуючих та акцентних кольорів. Наведена практична демонстрація повністю підтверджує абсолютну працездатність спроектованого методу, стабільність алгоритмів в умовах оптичних перешкод та готовність системи до експлуатації у формі готового програмного продукту.

3.5 Висновки до розділу 3

Для експериментальної перевірки методу спроектовано та програмно реалізовано повноцінний інтерактивний застосунок. Клієнт-серверну архітектуру та візуальний інтерфейс побудовано на базі мови програмування Python із залученням фреймворку Streamlit, що забезпечило управління станом сесії під час послідовного виконання конвеєра обробки даних. Для реалізації складних матричних обчислень та тензорних трансформацій використано екосистему відкритого фреймворку глибокого навчання PyTorch. Попередню обробку растрових зображень, перетворення колірних просторів та локалізацію антропометричних точок реалізовано за допомогою інтеграції бібліотек комп'ютерного зору OpenCV та MediaPipe.

У ході експериментального дослідження вирішено проблему наявності аномалій розмітки та візуального шуму у вихідному наборі даних Deep Arthroscopia. Застосування алгоритмічного підходу на базі дерев рішень дозволило в автоматичному режимі розрахувати оптимальні фізичні пороги контрастності, світлоти волосся та загальної теплоти шкіри. Це забезпечило математично обґрунтоване видалення 2987 суперечливих зразків та стабілізацію простору ознак. Для подолання виявленого кількісного дисбалансу між цільовими макрокласами розроблено та застосовано метод мультимодальної аугментації. Синхронне застосування просторових перетворень до візуального потоку та стохастичного гауссового шуму до табличного потоку дозволило сформувати ідеально збалансований еталонний масив обсягом 2400 репрезентативних об'єктів (по 600 для кожного із чотирьох сезонних макрокласів).

Підготовка візуального простору ознак забезпечується натренованою нейромережевою моделлю семантичної сегментації U-Net. Процес оптимізації вагових коефіцієнтів моделі здійснювався з використанням алгоритму Adam та комбінованої функції втрат (перехресна ентропія та коефіцієнт Дайса). Встановлено, що модель досягає максимальної стабільності на шостій епісі навчання, демонструючи макро-усереднений F1-score на рівні 0.8536 та показник

Macro IoU на рівні 0.8010. Апаратна ізоляція пікселів шкіри та волосся з точністю понад 90% повністю убезпечує систему від алгоритмічного впливу фонового візуального шуму на подальших етапах екстракції колориметричних ознак у просторі CIELAB.

Оцінка розробленої гібридної моделі класифікації, що базується на архітектурі згорткової мережі ResNet-18 та багатошаровому перцептрону, підтвердила її високу узагальнюючу здатність. Процес навчання супроводжувався застосуванням стратегії диференційованої швидкості оновлення ваг, механізму згладжування міток та шарів проріджування для запобігання перенавчанню. Тестування на незалежній відкладеній вибірці обсягом 400 зображень зафіксувало показник Ассурасу системи на рівні 91%. Математично підтверджено найвищу розпізнавальну здатність алгоритму для контрастних макрокласів зовнішності: макроклас «Зима» класифікується з показником F1-score 0.96, а «Літо» – 0.93. Незначне зниження показника Recall для макрокласу «Весна» (0.81) алгоритмічно пояснюється м'якими колориметричними переходами цього типу, що повністю узгоджується з теоретичними засадами сезонної класифікації.

Працездатність системи доведено в умовах наскрізного тестування на реальних вхідних даних зі складним фоном та нерівномірним освітленням. Підтверджено здатність програмного конвеєра безперервно виконувати цикл обробки: від детекції обличчя та адаптивної біометричної нормалізації до рендерингу результатів. Інтеграційний модуль системи успішно конвертує математичний вивід класифікатора у практичні візуальні рекомендації шляхом звернення до локальної бази знань у форматі JSON, автоматично формуючи шістнадцяткові коди домінуючих палітр та ініціюючи алгоритм цифрового драпінгу. Отримані результати підтверджують ефективність спроектованого методу та його абсолютну готовність до виконання задач автоматизованого колористичного аналізу.

Загальні висновки

Результатом виконання кваліфікаційної роботи бакалавра стало успішне досягнення поставленої мети, а саме підвищення точності класифікації сезонного кольоротипу зовнішності людини шляхом розробки нейромережевого методу комп'ютерного зору для генерації персоналізованої рекомендації візуального образу. Для досягнення мети розроблено метод, що поєднує семантичну сегментацію обличчя, біометричну нормалізацію освітлення, екстракцію кольірних ознак та мультимодальну класифікацію макрокласів зовнішності.

Поставлені завдання кваліфікаційної роботи виконано в повному обсязі. У межах дослідження проведено комплексний аналіз предметної області а сучасного стану технологій комп'ютерного зору для автоматизації колористичного аналізу. Дослідження наявних на ринку програмних аналогів виявило їхню високу вразливість до оптичних викривлень, наявності тіней та варіативності освітлення, що обґрунтувало об'єктивну необхідність розробки нових стійких мультимодальних підходів.

На основі виявлених галузевих обмежень розроблено цільовий метод визначення кольоротипу зовнішності людини. Запропонований підхід об'єднує просторову семантичну сегментацію обличчя на базі архітектури U-Net, адаптивну біометричну нормалізацію освітлення переднього плану за модифікованим методом фон Кріса та екстракцію ознак у кольірному просторі CIELAB. Фінальне розпізнавання сезону зовнішності забезпечується гібридною нейромережевою класифікаційною моделлю (ResNet-18 + MLP), в якій інтеграція різнорідних візуальних та табличних потоків даних реалізована за допомогою механізму уваги Gated Attention.

Важливим етапом дослідження стало виконання підготовки та попередньої обробки набору даних Deer Armoscromia для забезпечення коректного навчання моделі класифікації. Завдяки застосуванню алгоритмічного фільтра на базі дерев рішень успішно вилучено суперечливі кольірні аномалії розмітки, а впровадження розробленого конвеєра синхронної мультимодальної аугментації дозволило

повністю подолати проблему кількісного дисбалансу та сформувати еталонний масив обсягом 2400 репрезентативних об'єктів.

На основі запропонованого математичного та алгоритмічного забезпечення побудовано програмну реалізацію експериментального застосування. Вебсистема, створена мовою Python з використанням фреймворків Streamlit, PyTorch та OpenCV, успішно об'єднує всі етапи обробки в єдиний інтерактивний конвеєр наскрізного інференсу, що забезпечує автоматизовану обробку зображення обличчя, розпізнавання кольоротипу зовнішності та генерацію індивідуальних HEX-палітр на основі бази знань JSON.

Детальне експериментальне тестування розробленого методу підтвердило його високу працездатність та ефективність за визначеними критеріями оцінювання. Зафіксовані показники Macro IoU на рівні 80,10% та F1-score на рівні 85,36% засвідчили надійну просторову локалізацію біометричних зон обличчя моделлю сегментації в умовах візуального шуму. Гібридний мультимодальний класифікатор досяг загального показника Ассигасу на рівні 91% на повністю відкладеній тестовій вибірці, при цьому найвища здатність до диференціації зафіксована для контрастних макрокласів, зокрема показник F1-score для класу «Зима» склав 0,96, а для класу «Літо» – 0,93.

Отримані результати підтверджують, що поставлені мета та завдання кваліфікаційної роботи виконані в повному обсязі. Створений інструментарій довів свою дієздатність та може використовуватися фахівцями індустрії краси для автоматизованого генерування індивідуальних візуальних рекомендацій.

Перелік посилань

1. Cassidy T. D. Personal Colour Analysis, Consumer Colour Preferences and Colour Forecasting for the Fashion and Textile Industries // *Journal of the International Colour Association*. – 2012. – URL: https://www.researchgate.net/publication/228837871_Personal_Colour_Analysis_Consumer_Colour_Preferences_and_Colour_Forecasting_for_the_Fashion_and_Textile_Industries.
2. Armocromy: the science of colours for personal styling [Електронний ресурс] // *IED – Istituto Europeo di Design*. – URL: <https://www.ied.edu/news/armocromy-science-colours-personal-styling>.
3. Krishnapriya K. S., King M. C., Bowyer K. W. Analysis of Manual and Automated Skin Tone Assignments for Face Recognition Applications // *arXiv preprint*. – 2021. – URL: <https://arxiv.org/abs/2104.14685>.
4. Zhu W., Sang P., He Y. Facial skin colour classification using machine learning and hyperspectral imaging data // *IET Image Processing*. – 2022. – URL: https://ietresearch.onlinelibrary.wiley.com/doi/10.1049/ipr2.12366?utm_medium=article&utm_source=researchgate.net.
5. Abbasi M. A., Khan A. A., Laeeq K. AI Based Makeup Recommendation System: A Sustainable AI Solution for Women // *ResearchGate*. – 2026. – URL: https://www.researchgate.net/publication/403250574_AI_Based_Makeup_Recommendation_System_A_Sustainable_AI_Solution_for_Women.
6. Kolkur S., Kalbande D. R., Shimpi P. [та ін.]. Human Skin Detection Using RGB, HSV and YCbCr Color Models // *Proceedings of the International Conference on Communication and Signal Processing 2016 (ICCASP 2016)*. – Atlantis Press, 2016. – Vol. 137. – P. 324–332. – URL: <https://www.atlantis-press.com/proceedings/iccasp-16/25871632>.
7. Neshat M., Sepidname G., Eizi A. [та ін.]. A new skin color detection approach based on fuzzy expert system // *Indian Journal of Science and Technology*. –

2015. – Vol. 8, iss. 21. – URL: <https://indjst.org/articles/a-new-skin-color-detection-approach-based-on-fuzzy-expert-system>.

8. Putra I. K. G. D., Wiastini N. P. A. O., Wibawa K. S. [та ін.]. Identification of Skin Disease Using K-Means Clustering, Discrete Wavelet Transform, Color Moments and Support Vector Machine // *International Journal of Machine Learning and Computing*. – 2020. – Vol. 10, iss. 5. – P. 700–706. – URL: <https://www.ijml.org/index.php?m=content&c=index&a=show&catid=109&id=1167>.

9. Harsha B. K., Indumathi G. Color-Based Feature Extraction Method for Skin Segmentation Based on SVM // *International Journal for Research in Applied Science and Engineering Technology (IJRASET)*. – 2022. – Vol. 10, iss. 1. – P. 66–71. – URL: https://www.researchgate.net/publication/358244173_Color-Based_Feature_Extraction_Method_for_Skin_Segmentation_Based_on_SVM.

10. Khan R., Hanbury A., Stoeftinger J. Skin detection: A random forest approach // *Proceedings of the 17th IEEE International Conference on Image Processing (ICIP)*. – 2010. – URL: <https://ieeexplore.ieee.org/document/5651638>.

11. Nurapipah N., Yuliana S. S. Skin Tone Classification in Digital Images Using CNN For Make-Up and Color Recommendation // *Journal of Intelligent Systems Technology and Informatics (JISTICS)*. – 2025. – Vol. 1, iss. 3. – URL: <https://journal.apatika.org/index.php/jistics/article/view/29>.

12. Liu R., Chen Z., Zhang P. Skin Lesion Classification Based on ResNet-50 Enhanced With Adaptive Spatial Feature Fusion // *arXiv preprint*. – 2025. – URL: <https://arxiv.org/abs/2510.03876>.

13. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // *arXiv preprint*. – 2015. – URL: <https://arxiv.org/abs/1505.04597>.

14. Zami A. SMFD-UNet: Semantic Face Mask Is The Only Thing You Need To Deblur Faces // *arXiv preprint*. – 2026. – URL: <https://arxiv.org/html/2604.07477v1>.

15. Mbatha S. K., Booyesen M. J., Theart R. P. Skin Tone Estimation under Diverse Lighting Conditions // *Journal of Imaging*. – 2024. – Vol. 10, iss. 5. – Art. 109. – URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11122461/>.

16. Stothers D., Xu S., Reeves C. [та ін.]. Fitzpatrick Thresholding for Skin Image Segmentation // *arXiv preprint*. – 2025. – URL: <https://arxiv.org/abs/2510.06655>.
17. Ebis S. K., Muter B. M., Shnan F. H. [та ін.]. Deep Learning for Multi-Label Facial Attribute Classification on Large-Scale Image Datasets (CelebA) // *Journal of Intelligent Systems and Internet of Things*. – 2025. – Vol. 15, iss. 1. – P. 133–143. – URL: <https://doi.org/10.54216/JISIoT.150111> .
18. Stacchio L., Paolanti M., Spigarelli F. [та ін.]. Deep Armocromia: A Novel Dataset for Face Seasonal Color Analysis and Classification // *Computer Vision – ECCV 2024 Workshops*. – Springer, Cham, 2025. – P. 352–367. – URL: https://link.springer.com/chapter/10.1007/978-3-031-91569-7_22.
19. How to use Dressika app // Color Analysis App: Dressika. – 2024. – URL: <https://coloranalysis.app/blog/how-to-use-dressika-app/> .
20. Dressika // *Standy Software*. – URL: <https://standysoftware.com/dressika/>
21. Style DNA: AI Personal Stylist // *Style DNA*. – URL: <https://styledna.ai/>
22. Style DNA Review // *Style Within Grace*. – 2024. – URL: <https://stylewithingrace.com/style-dna-review/> .
23. Discover your best colors // *Colorwise.me*. – URL: <https://colorwise.me/> .
24. Bolonina N. Best Color Analysis Apps to Find Your Color Season // *Natalie Bolonina Blog*. – 2024. – URL: <https://nataliebolonina.com/blog/best-color-analysis-apps>.
25. Grishchenko I., Ablavatski A., Kartynnik Yu. [та ін.]. Attention Mesh: High-fidelity Face Mesh Prediction in Real-time // *arXiv preprint*. – 2020. – URL: <https://arxiv.org/abs/2006.10962>
26. Fairchild M. D. Von Kries 2020: Evolution of degree of chromatic adaptation // *28th Color and Imaging Conference*. – Society for Imaging Science and Technology, 2020. – URL: <https://doi.org/10.2352/issn.2169-2629.2020.28.40>.
27. Blömer J., Lammersen C., Schmidt M. [та ін.]. Theoretical Analysis of the k-Means Algorithm - A Survey // *arXiv preprint*. – 2016. – URL: <https://arxiv.org/abs/1602.08254>.

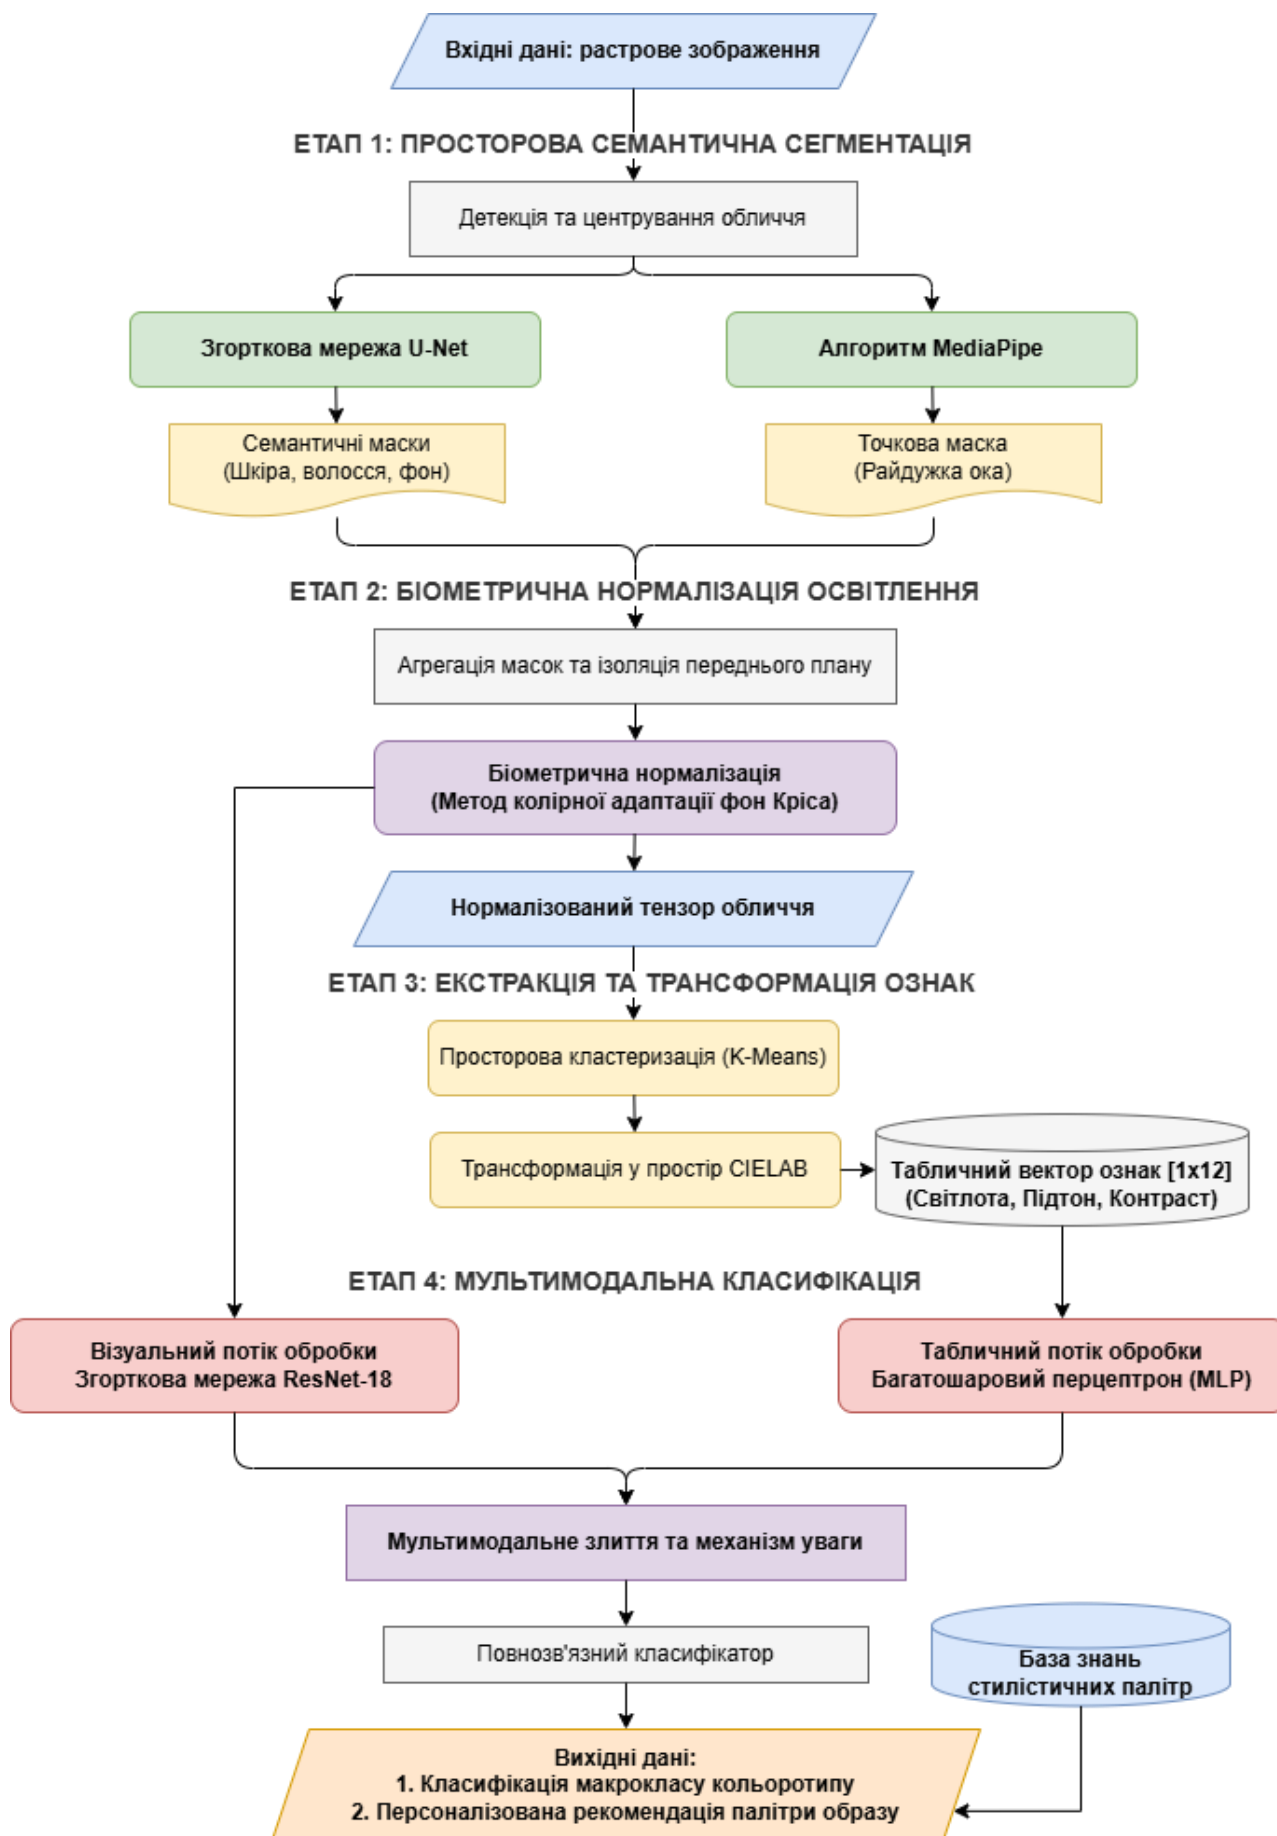
28. He K., Zhang X., Ren S. [та ін.]. Deep Residual Learning for Image Recognition // *arXiv preprint*. – 2015. – URL: <https://arxiv.org/abs/1512.03385>.
29. Tolstikhin I., Houlsby N., Kolesnikov A. [та ін.]. MLP-Mixer: An all-MLP Architecture for Vision // *arXiv preprint*. – 2021. – URL: <https://arxiv.org/abs/2105.01601>.
30. Lee C.-H., Liu Z., Wu L. [та ін.]. MaskGAN: Towards Diverse and Interactive Facial Image Manipulation // *arXiv preprint*. – 2020. – URL: <https://arxiv.org/abs/1907.11922>.
31. Deng J., Dong W., Socher R. [та ін.]. ImageNet: A large-scale hierarchical image database // *2009 IEEE Conference on Computer Vision and Pattern Recognition*. – IEEE, 2009. – P. 248–255. – URL: <https://ieeexplore.ieee.org/document/5206848>.
32. Hamrani A., Leizaola D., Reddy Vedere N. K. [та ін.]. AI Dermatochroma Analytica (AIDA): Smart Technology for Robust Skin Color Classification and Segmentation // *Cosmetics*. – 2024. – Vol. 11, iss. 6. – Art. 218. – URL: <https://www.mdpi.com/2079-9284/11/6/218>
33. Dauphin Y. N., Fan A., Auli M. [та ін.]. Language Modeling with Gated Convolutional Networks // *arXiv preprint*. – 2017. – URL: <https://arxiv.org/abs/1612.08083>.
34. Loshchilov I., Hutter F. Decoupled Weight Decay Regularization // *arXiv preprint*. – 2019. – URL: <https://arxiv.org/abs/1711.05101>.
35. Ramanath R., Drew M. S. von Kries Hypothesis // *Computer Vision*. – Cham : Springer, 2020. – URL: https://doi.org/10.1007/978-3-030-03243-2_455-1.
36. Celebi M. E., Kingravi H. A., Vela P. A. A Comparative Study of Efficient Initialization Methods for the K-Means Clustering Algorithm // *Expert Systems with Applications*. – 2013. – Vol. 40. – P. 200–210. – URL: <https://arxiv.org/abs/1209.1960>.
37. Schanda J. CIE Colorimetry // *Colorimetry* / ed. J. Schanda. – 2007. – URL: <https://doi.org/10.1002/9780470175637.ch3>.
38. CelebAMask-HQ [Електронний ресурс] // *MMLab*. – URL: https://mmlab.ie.cuhk.edu.hk/projects/CelebA/CelebAMask_HQ.html.

39. Stacchio L. Deep-Armocromia [Электронный ресурс] // *GitHub*. – URL: <https://github.com/lorenzo-stacchio/Deep-Armocromia>.
40. Sudre C. H., Li W., Vercauteren T. [та ін.]. Generalised Dice Overlap as a Deep Learning Loss Function for Highly Unbalanced Segmentations // *Deep Learn Med Image Anal Multimodal Learn Clin Decis Support*. – 2017. – P. 240–248. – URL: https://doi.org/10.1007/978-3-319-67558-9_28.
41. Minaee S., Boykov Y., Porikli F. [та ін.]. Image Segmentation Using Deep Learning: A Survey // *arXiv preprint*. – 2020. – URL: <https://arxiv.org/abs/2001.05566>.
42. Müller R., Kornblith S., Hinton G. When Does Label Smoothing Help? // *arXiv preprint*. – 2019. – URL: <https://arxiv.org/abs/1906.02629>.
43. Bayly D., Kruse B., Reidy C. Streamlit App for Cluster Publication Impact Exploration // *PEARC '24: Practice and Experience in Advanced Research Computing*. – New York : ACM, 2024. – URL: <https://doi.org/10.1145/3626203.3670633>.
44. PyTorch Contributors. PyTorch documentation [Электронний ресурс] // *PyTorch*. – URL: <https://docs.pytorch.org/docs/2.12/index.html>
45. Mari J. F. [та ін.]. Getting Started with Semantic Segmentation in PyTorch Using SMP // *38th SIBGRAPI Conference on Graphics, Patterns and Images*. – 2025. – P. 1–6. – URL: <https://doi.org/10.1109/sibgrapi67909.2025.11223385>.
46. OpenCV 5.0 documentation [Электронний ресурс] // *OpenCV*. – URL: <https://docs.opencv.org/5.0/>
47. scikit-learn User Guide [Электронний ресурс] // *scikit-learn*. – URL: https://scikit-learn.org/stable/user_guide.html
48. Harris C. R., Millman K. J., van der Walt S. J. [та ін.]. Array programming with NumPy // *Nature*. – 2020. – Vol. 585, iss. 7825. – P. 357–362. – URL: <https://doi.org/10.1038/s41586-020-2649-2>

ДОДАТКИ

Додаток А

Схема методу



Додаток Б

Програмні коди

Вихідний код, використаний у дослідженні, доступний у репозиторії GitHub: <https://github.com/JuliaBekeshko/color-type-detection-hybrid>

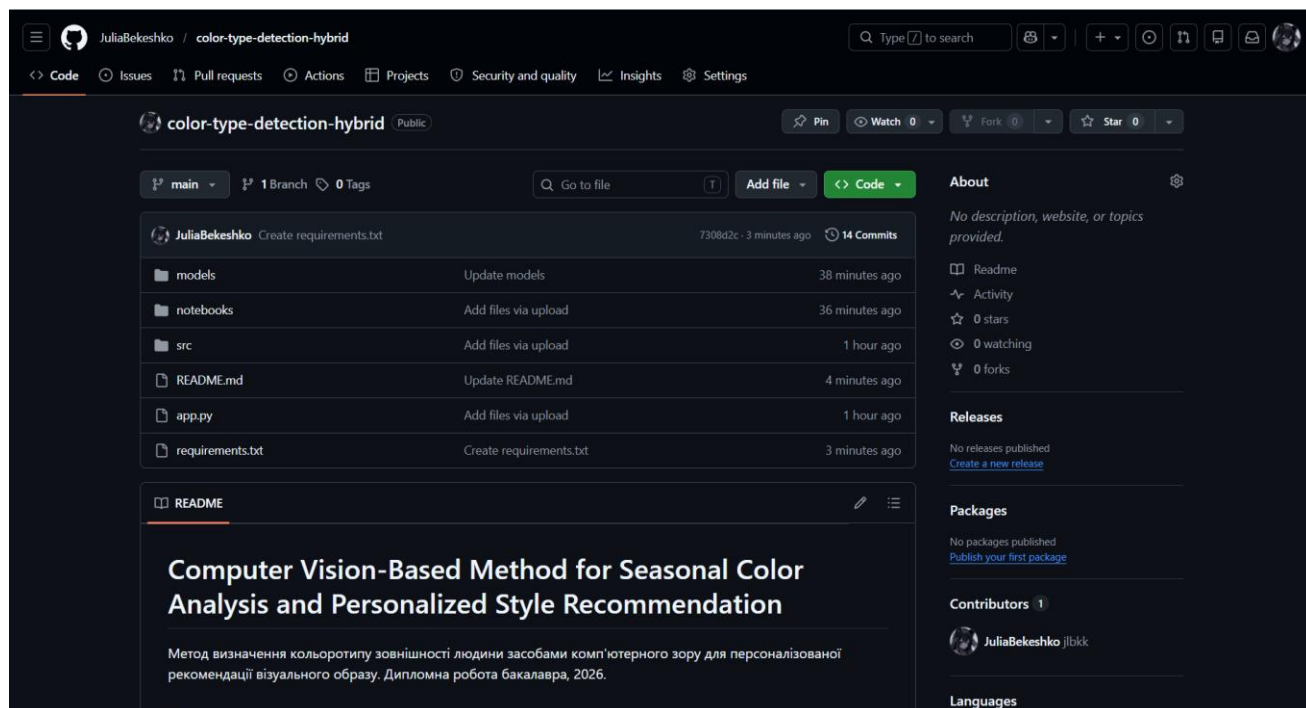


Рисунок Б.1 – Головна сторінка репозиторію

Структура репозиторію наступна:

- Репозиторій складається з кількох основних директорій. Папка `models` містить збережені параметри для масштабування та нормалізації ознак, кодувальник міток, а також посилання на завантаження навчених моделей.
- У папці `notebooks` знаходяться файли Jupyter Notebook для очищення та підготовки наборів даних, а також проведення обчислювальних експериментів із навчання гібридної моделі класифікації та моделі просторової сегментації.
- Папка `src` містить основний вихідний код системи: модулі попередньої обробки зображень, локалізації біометричних зон, вилучення колірних ознак, класифікації зовнішності та генерації персоналізованих рекомендацій.
- Коренева директорія містить скрипт `app.py` для запуску інтерактивного веб-застосунку, файл `README.md` з описом проєкту та інструкціями, а також `requirements.txt` із переліком необхідних бібліотек.

Додаток В

Презентаційний матеріал

КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

На тему: Метод визначення кольоротипу зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу

Виконала:
Студентка 4 курсу, група КН-22-2
Юлія БЕКЕШКО

Керівник:
к.т.н., доц. каф. КН
Руслан БАГРІЙ

АКТУАЛЬНІСТЬ

02

Суб'єктивність

Високий вплив людського фактора під час традиційного колористичного аналізу.

Вразливість

Спотворення оцінки кольоротипу через нестандартне освітлення, наявність сторонніх аксесуарів та візуальний шум на зображеннях.

Алгоритмізація

Необхідність створення автоматизованого інструменту для швидкого та безпомилкового визначення сезонного макрокласу зовнішності без залучення експерта.

МЕТА ТА ЗАДАЧІ РОБОТИ

03

Мета:

Підвищення точності класифікації сезонного кольоротипу зовнішності людини шляхом розробки нейромережевого методу комп'ютерного зору для генерації персоналізованої рекомендації візуального образу.

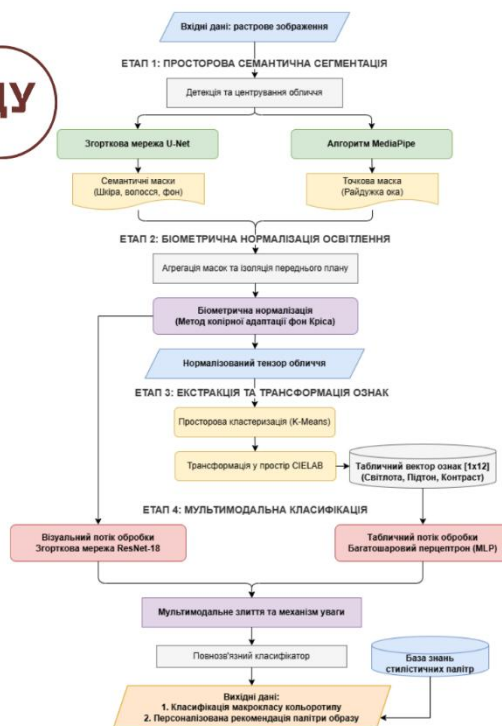
Задачі:

- провести аналіз предметної області;
- розробити метод визначення кольоротипу зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу;
- виконати підготовку та попередню обробку наборів даних;
- розробити програмну реалізацію;
- провести експериментальне тестування.

СХЕМА МЕТОДУ

04

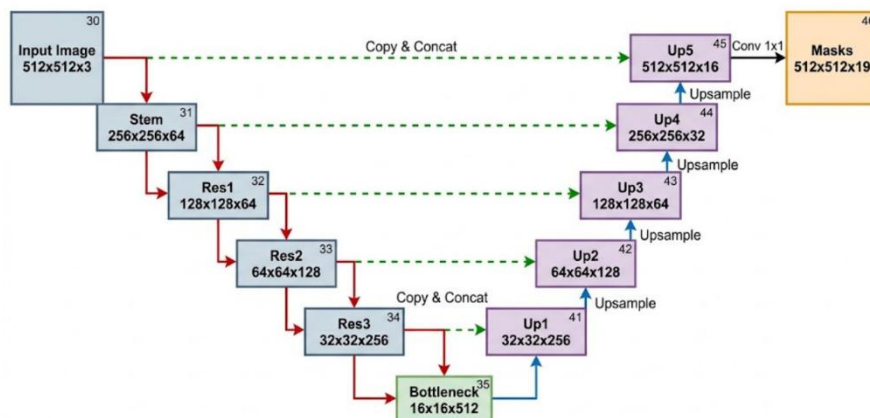
Загальна структурна схема методу мультимодального аналізу



АРХІТЕКТУРА

05

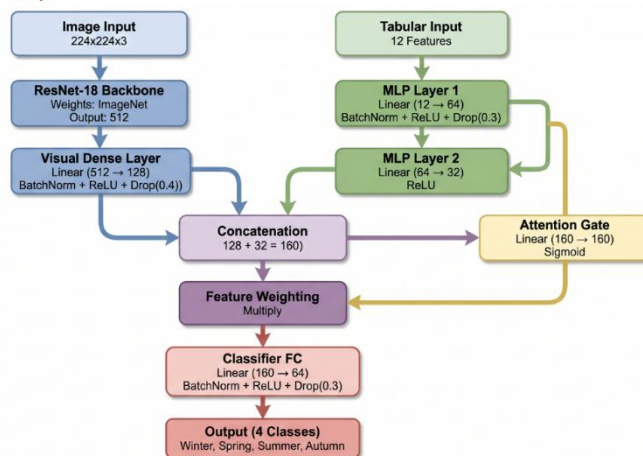
Структурна схема нейронної мережі U-Net для багатокласової сегментації зон обличчя



АРХІТЕКТУРА

06


Структурна схема гібридної нейронної мережі (ResNet-18 та MLP) для класифікації кольоротику зовнішності



НАБОРИ ДАНИХ


CelebAMask-HQ

для семантичної сегментації



Deep Armcromia

для класифікації кольоротипів




ФІЛЬТРАЦІЯ


Фізичні пороги

Загальна теплота	34.13
Контраст	42.25
Світлота волосся	30.49
Теплота шкіри	22.46

До застосування фільтрації



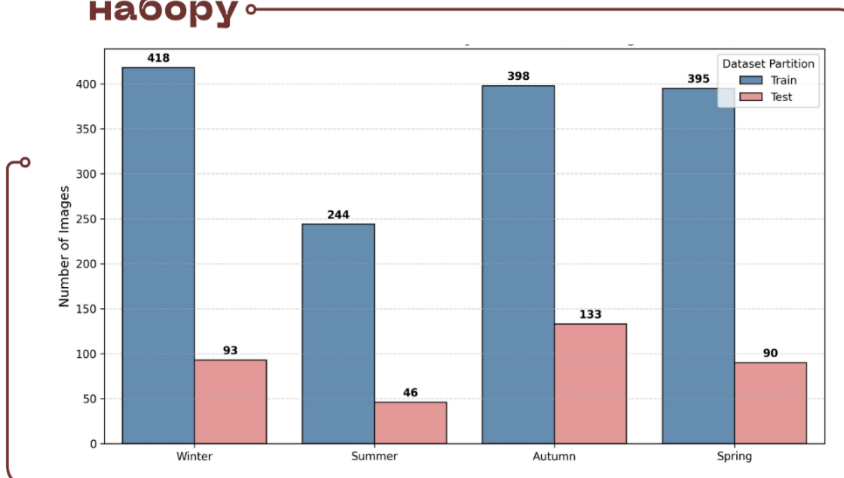
Після застосування фільтрації



ФІЛЬТРАЦІЯ

000 09


Кількісний розподіл очищеного набору



ФІЛЬТРАЦІЯ

000 10

Потік даних	Методи аугментації	Параметри
Візуальний	Horizontal Flip, Rotation	-10 до +10 градусів
Табличний	Gaussian Noise	5% від стандартного відхилення




	Original	Augmented (Rotated)	Augmented (Flipped)
Skin Temp (b)	8.55	8.39	9.03
Hair Lightness (L)	19.09	19.03	19.17
Total Warmth	22.51	22.73	22.09
Contrast (Delta L)	55.62	55.00	55.32

ФІЛЬТРАЦІЯ

o o o

11

Кількісний розподіл остаточного набору



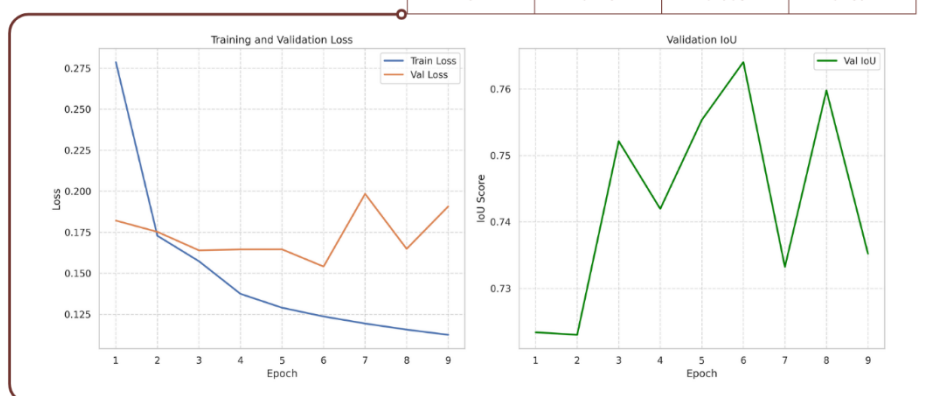
НАВЧАННЯ

o o o

12

Оцінка процесу навчання моделі семантичної сегментації

Епоха	Train Loss	Val Loss	IoU
1	0.2788	0.1822	0.7234
3	0.1574	0.164	0.7522
6	0.1237	0.1541	0.7641
9	0.1125	0.1908	0.7352




НАВЧАННЯ

o o o

13

Оцінка процесу навчання
гібридної моделі класифікації

Епоха	Train Loss	Val Loss	Train Acc	Val Acc	F1-score
1	0.9308	0.7515	69.71	81.33	0.8137
5	0.5476	0.5691	91.41	89.00	0.8886
10	0.5127	0.5257	93.12	90.33	0.9043
14	0.4824	0.5341	94.76	93.00	0.9282



ОЦІНКА


o o o

14

Точність сегментації цільових біометричних
зон та фону на тестовій вибірці

Macro F1-Score 0.8536

Macro IoU 0.8010




ОЦІНКА

15

Матриця помилок гібридної моделі класифікації на тестовій вибірці

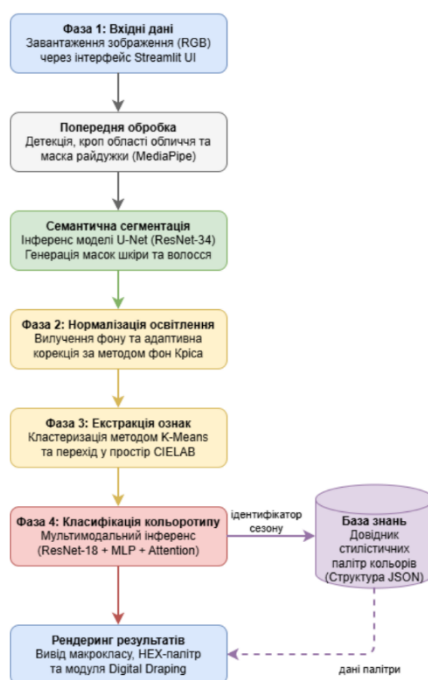
Макроклас	Precision	Recall	F1-score	Кількість зразків
Зима	0.93	0.99	0.96	100
Літо	0.92	0.94	0.93	100
Осінь	0.88	0.89	0.89	100
Весна	0.89	0.81	0.85	100
Accuracy	-	-	0.91	400



СХЕМА

16

Структурна блок-схема алгоритму роботи програмного застосунку



РЕЗУЛЬТАТ

o o o

17

Етапи обробки вхідного зображення та генерація персоналізованої колірної палітри



а) Вхідне зображення



Feature	Lightness (L-)	a- Value	b- Value	Derived Metric	Value
Skin	82.55	11.30	22.78	Lightness Contrast	59.61
Hair	22.93	-0.33	6.80	Eye-Skin Contrast	65.68
Eye	16.86	3.00	10.00	Total Warmth	39.58

б) Сегментація та екстракція ознак



в) Генерація візуальних рекомендацій

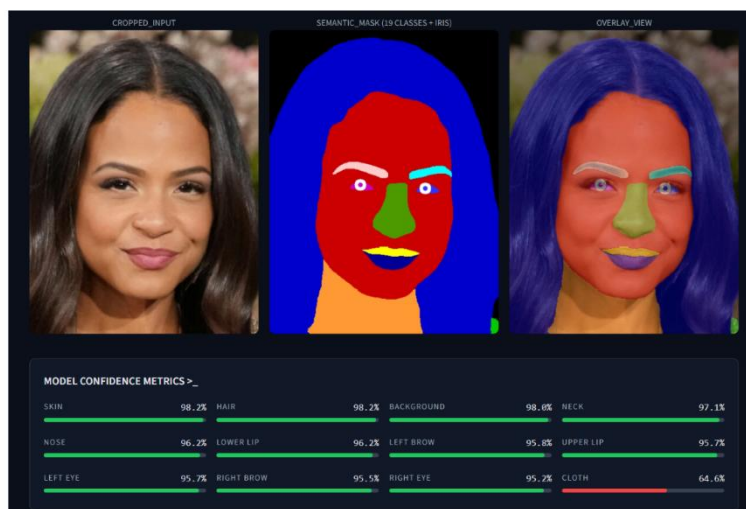
РЕЗУЛЬТАТ

o o o

18

Етап 1. Семантична сегментація обличчя

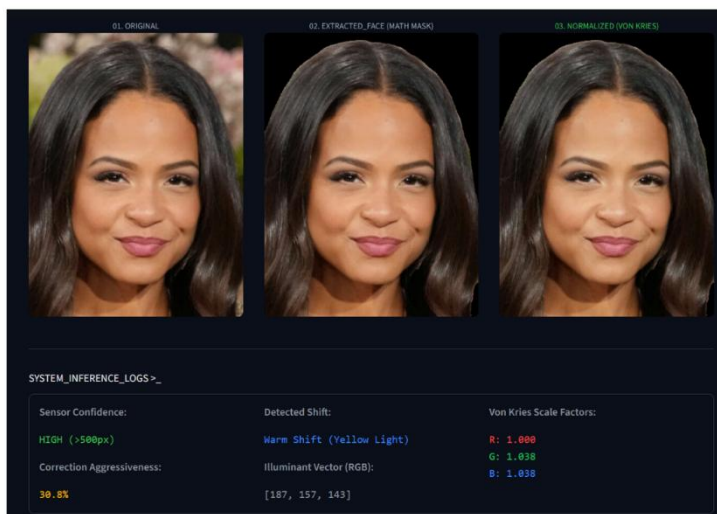
- Ізоляція ключових біометричних зон за допомогою U-Net.
- Візуалізація карти впевненості моделі під час генерації масок.



РЕЗУЛЬТАТ

Етап 2. Біометрична нормалізація

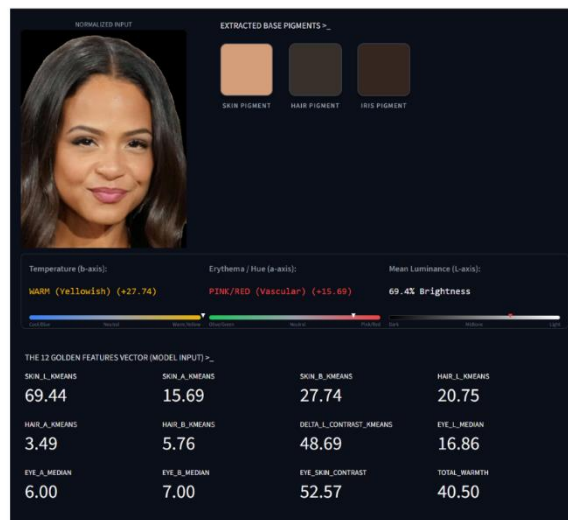
- Успішна локалізація достатньої площі обличчя для виконання якісного аналізу.
- Автоматичне визначення впливу некоректного освітлення на фотографії.
- Розрахунок адаптивних математичних множників для нейтралізації неприродного відтінку.
- Адаптація рівня інтенсивності корекції під кожне конкретне зображення



РЕЗУЛЬТАТ

Етап 3. Екстракція та трансформація ознак

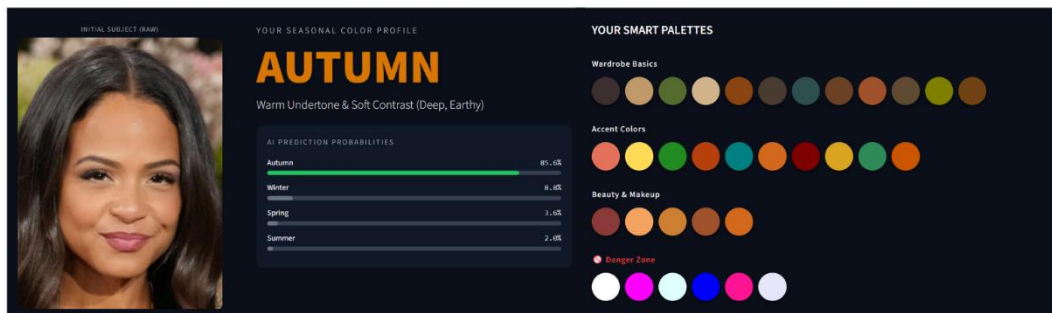
- Просторова кластеризація для виділення домінуючих пігментів шкіри та волосся.
- Розрахунок медіанного вектора кольору райдужки ока.
- Трансформація значень у перцептивно рівномірний колірний простір.
- Формування єдиного вектора ознак для фінальної класифікації



РЕЗУЛЬТАТ

Етап 4. Мультимодальна класифікація та генерація рекомендацій

- Визначення сезонного макрокласу зовнішності на основі обчисленого вектора ймовірностей.
- Формування індивідуальних колірних палітр для базового гардероба акцентів, макіяжу та заборонених відтінків



ВИСНОВКИ

01

Мету кваліфікаційної роботи досягнуто

02

Поставлені завдання виконано в повному обсязі

03

Створено та програмно реалізовано комплексний нейромережевий метод

04

Експериментально підтверджено високу ефективність із загальною точністю розпізнавання 91%

**ДЯКУЮ
ЗА УВАГУ!**



Протокол аналізу звіту подібності науковим керівником

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

Автор: Юлія БЕКЕШКО

Співавтор:

Назва: КВАЛІФІКАЦІЙНА РОБОТА на тему Метод визначення кольоротипу зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу

Науковий керівник: Руслан БАГРІЙ, к.т.н., доцент

Підрозділ: Кафедра комп'ютерних наук

Коефіцієнт подібності 1: 3.62%

Коефіцієнт подібності 2: 1.75%

Мікропробіли: 0

Заміна букв: 12

Інтервали: 0

Білі знаки: 190

Дата створення звіту: 2026-06-12 13:35:15.0

Після аналізу Звіту подібності констатую наступне:

Запозичення, виявлені в роботі є законними і не є плагіатом. Рівень подібності не перевищує допустимої межі. Таким чином робота незалежна і приймається.

Запозичення не є плагіатом, але перевищено граничне значення рівня подібностей. Таким чином робота повертається на доопрацювання.

Виявлено запозичення і плагіат або навмисні текстові спотворення (маніпуляції), як передбачувані спроби укриття плагіату, які роблять роботу невідповідною вимогам законодавства (Ст. 32. ЗУ Про вищу освіту, пункт 3.1, Ст. 42. ЗУ Про освіту) та вимог НАЗЯВО (Критерій 5), а також кодексу етики і процедур. Таким чином робота не приймається.

Обґрунтування:

2026-06-12

Дата

експерт

Петровський С.Р.



Fri Jun 12 18:05:24 EEST 2026, Петровський Сергій Степанович, Хмельницький національний університет, ХНУ

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

Максимальне співпадіння з одним документом 2.0%

Словники перевірки: UA, US, RU. Помилки в документах: 15%

<p>ID: 275028 Назва: КВАЛІФІКАЦІЙНА РОБОТА на тему Метод визначення кольоротипу зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу Додано в БД: 2026-06-12 Автора: Юлія БЕКЕШКО Керівники: Руслан БАГРІЙ Консультанти: Опоненти:</p>	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми		Символи
		104500	842	3740 (4%)

Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

РІШЕННЯ ЕКСПЕРТНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК

ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ

Назва кваліфікаційної роботи Метод визначення кольоротипу зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу

Автор студентка групи КН-22-2 Юлія Бекешко

Освітня програма Комп'ютерні науки

Рівень вищої освіти периний (бакалаврський)

Спеціальність 122 – Комп'ютерні науки

Науковий керівник: к.т.н., доц. каф. комп'ютерних наук Руслан Багрій

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

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

Підтвердження:

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

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

- за системою Anti-Plagiarism: 2%;

- за системою StrikePlagiarism КПІ: 3.62%.

12.06.2026

Завідувач кафедри



Олександр БАРМАК

Гарант освітньої програми



Олександр МАЗУРЕЦЬ

Керівник кваліфікаційної роботи



Руслан БАГРІЙ



ВІДГУК НАУКОВОГО КЕРІВНИКА на кваліфікаційну роботу бакалавра

студентки гр. КН-22-2 Бекешко Юлії Романівни

за темою Метод визначення кольоропиту зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу

1. Актуальність теми

Актуальність теми обґрунтована необхідністю заміни суб'єктивних ручних методів колористичного аналізу на точні, математично обґрунтовані підходи. Особливістю теми є застосування засобів комп'ютерного зору, зокрема моделей семантичної сегментації та гібридних нейронних мереж, для автоматизації визначення сезонного кольоропиту зовнішності й генерації стійких до зовнішніх факторів персоналізованих рекомендацій візуального образу.

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

Тема кваліфікаційної роботи «Метод визначення кольоропиту зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу» відповідає предметній області спеціальності 122 «Комп'ютерні науки» та вимогам до кваліфікаційної роботи бакалавра. Результатом роботи є розробка методу, що базується на інтеграції алгоритмів комп'ютерного зору та гібридних нейронних мереж для автоматизованого колористичного аналізу. При вирішенні поставлених завдань використано методи цифрової обробки зображень, технології глибокого навчання, алгоритми підготовки наборів даних, а також аналіз метрик якості для об'єктивної оцінки ефективності класифікації.

3. Професійні та особистісні якості бакалавра

Бекешко Ю. Р. під час роботи над кваліфікаційною роботою продемонструвала глибоке розуміння теоретичних і практичних аспектів використання алгоритмів комп'ютерного зору та нейронних мереж для обробки візуальних даних, а також здатність до самостійного аналізу та вирішення складних технічних завдань.

4. Ступінь самостійності під час виконання кваліфікаційної роботи

Робота виконана самостійно, академічного плагіату не виявлено, усі записи оформлено з відповідними посиланнями на джерела.

5. Ступінь оволодіння методами дослідження

При реалізації кваліфікаційної роботи студентка проявила високий рівень компетентності та володіння сучасними інструментами, методами й технологіями комп'ютерних наук, зокрема алгоритмами комп'ютерного зору, архітектурами глибокого навчання (для семантичної сегментації та класифікації візуальних даних), а також методами оцінки їхньої ефективності за допомогою спеціалізованих метрик якості.

6. Повнота та якість розкриття теми роботи

Тема роботи повністю розкрита: проведено аналіз актуальності, здійснено огляд сучасних технологій комп'ютерного зору для колористичного аналізу, виконано всі поставлені завдання, а також розроблено концептуальну основу методу, що включає семантичну сегментацію обличчя на базі U-Net, нормалізацію освітлення та мультимодальну класифікацію гібридною мережею ResNet-18 і MLP. Метод підтверджено практичною реалізацією у вигляді вебзастосування на базі Streamlit та оцінкою ефективності, що забезпечує його практичну цінність.

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

Викладення матеріалу логічне, послідовне та аргументоване. Мова і стиль роботи відповідають стандартам наукових текстів, забезпечуючи чіткість і доступність сприйняття. Структура роботи, що включає огляд технологій, проєктування методу та його програмну реалізацію, відповідає вимогам кваліфікаційних робіт.

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

Запропонований метод визначення кольоротипу зовнішності може бути застосований в індустрії моди, краси та електронної комерції, зокрема на вебплатформах для автоматичної генерації персоналізованих стилістичних рекомендацій. Його компоненти, такі як семантична сегментація зображень обличчя та нейромережевий аналіз кольорних ознак, можуть бути адаптовані для інших інформаційних систем, що потребують автоматизації обробки й аналізу візуального контенту.

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

Враховуючи високий рівень виконання, повноту розкриття теми та дотримання всіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка – «відмінно».

Керівник  к.т.н., доц. Руслан Багрий



Кафедра комп'ютерних наук

РЕЦЕНЗІЯ

на кваліфікаційну роботу бакалавра

студентки гр. КН-22-2 Бекешко Юлії Романівни

за темою: Метод визначення кольорошиту зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу

1. Актуальність обраної теми

Розвиток систем штучного інтелекту формуватиме запит на створення точних інструментів для автоматизованого колористичного аналізу. Традиційні методи залежать від суб'єктивного сприйняття спеціаліста та умов освітлення та не здатні забезпечити стабільні результати. Задіяння методів комп'ютерного зору усуває вплив суб'єктивного фактора та дозволяє генерувати персоналізовані рекомендації, що підтверджує своєчасність та високу актуальність роботи.

2. Повнота розкриття мети та завдань роботи

Під час виконання кваліфікаційної роботи бакалавра був реалізований метод визначення кольорошиту зовнішності людини засобами комп'ютерного зору для персоналізованої рекомендації візуального образу, що відповідає меті та завданням кваліфікаційної роботи і розкриває їх повною мірою.

3. Зміст кожного розділу роботи

Перший розділ присвячено огляду предметної області, аналізу сучасних програмних рішень та постановки задачі. Другий розділ містить опис проєктування методу, що включає семантичну сегментацію обличчя, алгоритми нормалізації освітлення та мультимодальну класифікацію. Третій розділ розглядає особливості програмної реалізації методу у вигляді експериментального вебдодатку та результати тестування за визначеними метриками.

4. Оцінка розробленого методу та його практична цінність

Розроблений метод, здатен ефективно та об'єктивно розпізнавати кольорошит зовнішності незалежно від освітлення та генерувати індивідуальні стилістичні HEX-палітри, що становить високу практичну цінність та забезпечує можливість впровадження інструменту на платформах електронної комерції.

5. Якість оформлення кваліфікаційної роботи бакалавра

Записка якісно оформлена відповідно до встановлених вимог, чітко і зрозуміло написана, зі структурованою побудовою розділів та логічною послідовністю викладення матеріалу.

6. Недоліки кваліфікаційної роботи бакалавра

Рекомендовано в подальшому розглянути можливість розширення бази знань та архітектури класифікатора до 12-сезонної системи класифікації.

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

Враховуючи рівень виконання та забезпечення усіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка „Відмінно“

Рецензент Кануєв М.В.

Відмінно
[Підпис]