

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет комп'ютерної інженерії та управління  
(повна назва)

Кафедра електронних обчислювальних машин  
(повна назва)

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

Рівень вищої освіти другий (магістерський)

Модель сегментації зображень з  
використанням алгоритмів кластеризації даних

(тема)

Виконав:

студент II курсу, групи СПМ-22-3  
Зайцев Д.Я.  
(прізвище, ініціали)

Спеціальність 123 «Комп'ютерна інженерія»  
(код і повна назва спеціальності)

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

Освітня програма Системне програмування  
(повна назва освітньої програми)

Керівник: доц. Філімончук Т.В.  
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри ЕОМ

(підпис)

Коваленко А.А.

(прізвище, ініціали)

2024 р.

Харківський національний університет радіоелектроніки

Факультет \_\_\_\_\_ комп'ютерної інженерії та управління \_\_\_\_\_

Кафедра \_\_\_\_\_ електронних обчислювальних машин \_\_\_\_\_

Рівень вищої освіти \_\_\_\_\_ другий (магістерський) \_\_\_\_\_

Спеціальність \_\_\_\_\_ 123 «Комп'ютерна інженерія» \_\_\_\_\_  
(код і повна назва)

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

Освітня програма \_\_\_\_\_ Системне програмування \_\_\_\_\_  
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри \_\_\_\_\_  
(підпис)

“ \_\_\_\_\_ ” \_\_\_\_\_ 20\_\_ р.

**ЗАВДАННЯ**

**НА КВАЛІФІКАЦІЙНУ РОБОТУ**

студенту \_\_\_\_\_ Зайцеву Дмитру Ярославовичу \_\_\_\_\_  
(прізвище, ім'я, по батькові)

1. Тема роботи Модель сегментації зображень з використанням алгоритмів кластеризації даних

затверджена наказом по університету від “ 01 ” квітня 2024 р. № 257 Ст

2. Термін подання студентом роботи до екзаменаційної комісії 15 червня 2024 р.

3. Вхідні дані до роботи 1) несегментоване зображення з дефектами та даними про них;  
2) існуючі методи сегментації; 3) алгоритми обробки зображень;  
4) обчислювальні платформи; 5) алгоритми кластеризації; 6) теорія графів.

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

1) постановка задачі;

2) аналіз існуючих рішень та проблем;

3) вибір інструментів для моделі сегментації зображень;

4) опис запропонованої моделі EBSM;

5) тестування моделі EBSM;

6) порівняльний аналіз роботи моделі.

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (слайдів) \_\_\_\_\_

Слайд-презентація – 13 слайдів \_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

6. Консультанти розділів роботи (заповнюється за наявності консультантів згідно з наказом, зазначеним у п.1 )

Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата

### КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Аналіз методів сегментації зображень	02.04.24-08.04.24	
2	Аналіз методів кластеризації	09.04.24-16.04.24	
3	Вибір інструментальних засобів	17.04.24-22.04.24	
4	Розробка моделі сегментації зображення	23.04.24-06.05.24	
5	Проведення тестування моделі	07.05.24-23.05.24	
6	Оформлення матеріалів кваліфікаційної роботи	24.05.24-03.06.24	
7	Подання кваліфікаційної роботи керівникові та її попередній захист	04.06.24-07.06.24	
8	Подання кваліфікаційної роботи на рецензування	08.06.24-12.06.24	

Дата видачі завдання 01 квітня 2024 р.

Студент \_\_\_\_\_  
(підпис)

Керівник роботи \_\_\_\_\_  
(підпис)

доц. Філімончук Т.В.  
(посада, прізвище, ініціали)

## РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 81 с., 19 рис., 15 джерел.

СЕГМЕНТАЦІЯ, КЛАСТЕРИЗАЦІЯ, K-MEANS, NCUT, C-MEANS, ГАУССІВСЬКЕ РОЗМИТТЯ, ГІСТОГРАМНЕ ВИРІВНЮВАННЯ.

Метою кваліфікаційної роботи є розробка моделі для сегментації зображень на основі комбінованих методів, включно з алгоритмами кластеризації K-Means та Normalized Cut.

У ході виконання кваліфікаційної роботи було досліджено різноманітні методи сегментації зображень, а також розроблено модель Enhanced Boundary Segmentation Model (EBSM). Модель включає модулі стандартизації, попередньої обробки, гібридної сегментації та аналітики. Було проведено тестування моделі на обраному зображенні, що містило шуми, переосвітлення та нечіткі області. Попередня обробка, що включала корекцію освітлення, фільтрацію шуму та підвищення контрасту показала ефективність у покращенні якості зображення.

Результати роботи моделі EBSM підтвердили, що поєднання алгоритмів K-Means та Normalized Cut забезпечує високу точність та детальність сегментації. Попередня обробка значно покращує якість вхідних даних, що позитивно впливає на точність сегментації.

У підсумку, проведена кваліфікаційна робота підтверджує ефективність розробленої моделі для сегментації зображень та вказує на її потенціал для застосування в різних галузях, таких як медична діагностика, дистанційне зондування та автоматичне розпізнавання об'єктів. Модель EBSM має важливе значення у сучасному світі, де обробка візуальних даних стає все більш необхідною у різних сферах.

## ABSTRACT

Master's thesis:: 81 pages, 19 figures, 15 sources.

SEGMENTATION, CLUSTERING, K-MEANS, NCUT, C-MEANS, GAUSSIAN BLUR, HISTOGRAM EQUALIZATION.

The major goal of this thesis is to develop a model for image segmentation based on combined methods, including K-Means and Normalized Cut clustering algorithms.

During the qualification work, various image segmentation methods were researched, and the Enhanced Boundary Segmentation Model (EBSM) was developed. The model includes modules for standardization, preprocessing, hybrid segmentation, and analytics. The model was tested on a selected image containing noise, overexposure, and blurred areas. Preprocessing, including exposure correction, noise filtering, and contrast enhancement, proved effective in improving image quality.

The results of the EBSM model confirmed that the combination of K-Means and Normalized Cut algorithms ensures high accuracy and detail in segmentation. Preprocessing significantly improves the quality of input data, positively affecting segmentation accuracy.

In conclusion, the qualification work confirms the effectiveness of the developed model for image segmentation and highlights its potential for use in various fields, such as medical diagnostics, remote sensing, and automatic object recognition. The EBSM model is of great importance in the modern world, where visual data processing is becoming increasingly necessary in various areas.

## ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ .....	8
ВСТУП .....	9
1 ПОСТАНОВКА ЗАДАЧІ КВАЛІФІКАЦІЙНОЇ РОБОТИ .....	11
2 АНАЛІЗ ІСНУЮЧИХ РІШЕНЬ ТА ПРОБЛЕМ .....	14
2.1 Проблеми у сфері сегментації зображень.....	14
2.2 Фактори зображення, що ускладнюють сегментацію.....	17
2.3 Аналіз існуючих методів сегментації зображень .....	20
2.3.1 Порогова сегментація .....	21
2.3.2 Сегментація на основі глибокого навчання .....	22
2.3.3 Сегментація на основі графів.....	23
2.3.4 Кластеризація .....	23
2.4 Аналіз методів кластеризації .....	24
2.4.1 Кластеризація методом K-means .....	24
2.4.2 Нечітка кластеризація методом C-means.....	27
2.4.3 Ієрархічна кластеризація .....	28
3 ВИБІР ІНСТРУМЕНТІВ ДЛЯ МОДЕЛІ СЕГМЕНТАЦІЇ ЗОБРАЖЕНЬ .....	30
3.1 Стандартизація даних .....	30
3.2 Вибір інструментів.....	31
3.2.1 Попередня обробка зображень .....	32
3.2.1.1 Зміна масштабу .....	32
3.2.1.2 Корекція освітлення.....	33
3.2.1.3 Фільтрація шуму .....	34
3.2.1.4 Підвищення контрасту .....	35
3.2.2 Кластеризація K-Means .....	36
3.2.3 Алгоритм нормалізованого розрізу.....	37
3.2.4 Обчислювальні платформи .....	38

3.3 Метрики порівняння якості сегментації .....	39
4 МОДЕЛЬ СЕГМЕНТАЦІЇ ЗОБРАЖЕНЬ EBSM .....	41
4.1 Огляд існуючої моделі сегментації зображень .....	41
4.2 Опис запропонованої моделі сегментації зображень .....	43
4.2.1 Модуль стандартизації вхідних зображень .....	48
4.2.2 Модуль попередньої обробки .....	49
4.2.2.1 Підмодуль зміни масштабу .....	49
4.2.2.2 Підмодуль корекції освітлення .....	50
4.2.2.3 Підмодуль фільтрації шуму .....	51
4.2.2.4 Підмодуль підвищення контрасту .....	52
4.2.3 Модуль гібридної сегментації .....	52
4.2.3.1 Підмодуль кластеризації K-Means .....	53
4.2.3.2 Підмодуль кластеризації Normalized Cut .....	54
4.2.4 Модуль аналітики .....	55
4.2.4.1 Підмодуль обчислення метрик .....	55
4.2.4.2 Підмодуль аналізу обчислених метрик .....	56
4.3 Тестування моделі EBSM .....	57
4.3.1 Вибір вхідного зображення для тестування .....	58
4.3.2 Попередня обробка зображення .....	60
4.3.2.1 Корекція освітлення .....	60
4.3.2.2 Фільтрація шуму .....	61
4.3.2.3 Підвищення контрасту .....	62
4.3.3 Гібридна сегментація зображення .....	64
4.3.3.1 Сегментація зображення за допомогою K-Means .....	64
4.3.3.2 Сегментація зображення за допомогою Normalized Cut .....	65
4.4 Порівняльний аналіз роботи моделі .....	66
ВИСНОВКИ .....	70
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ .....	72
ДОДАТОК А Графічний матеріал кваліфікаційної роботи .....	74

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

CNN – згорткові нейронні мережі (англ., Convolutional Neural Networks)

Elbow Method – метод визначення оптимальної кількості кластерів у кластеризації шляхом аналізу кривої WCSS

FCN – мережі повного згортання (англ., Fully Convolutional Networks)

Fuzzy C-Means – алгоритм кластеризації, що дозволяє кожному елементу належати до кількох кластерів з різним ступенем належності

Hard C-Means – класичний алгоритм кластеризації, що відносить кожен елемент до одного кластеру

LCE – техніка покращення контрасту зображення шляхом підсилення локальних відмінностей інтенсивності (англ., Local Contrast Enhancement)

Min-Max нормалізація – метод нормалізації даних, що масштабує їх до діапазону  $[0, 1]$

Normalized Cut – алгоритм сегментації графів, що мінімізує кількість відрізаних зв'язків між сегментами

U-Net – архітектура нейронної мережі для сегментації зображень, що використовує симетричні розширюючі та скорочуючі шари

WCSS – міра розсіювання точок усередині кластера (англ., Within-Cluster Sum of Squares)

## ВСТУП

Протягом десятиліть у людства існувала мрія створити такі машини, які б на рівні своїх можливостей могли змагатися з людським розумом, вміючи мислити та вчиняти подібно до людини. Особливо привабливою здавалася перспектива наділити комп'ютери здатністю "бачити" і розуміти оточення так, як це робить людина, перетворюючи візуальну інформацію на аналізований комп'ютером формат. Розвиток у сфері штучного інтелекту, прориви в області глибокого навчання та роботи з нейронними мережами дозволили досягти значних висот у сфері комп'ютерного зору, перевершивши людські здібності у деяких аспектах ідентифікації та класифікації об'єктів. Цей прогрес відкрив шлях до нових викликів та можливостей у сфері візуальної обробки, серед яких сегментація зображень стала ключовим елементом.

Сегментація зображень займає вирішальну роль у сучасному світі обробки зображень та машинного зору, надаючи можливість машинам розуміти зображення на рівні, подібному до людського сприйняття. Цей процес дозволяє виділяти важливі об'єкти на зображенні, роблячи їх значно більш готовими до розпізнавання та аналізу. Застосування сегментації зображень є різноманітним і охоплює такі сфери, як медична візуалізація, автономне водіння, системи спостереження та багато інших. Однак, незважаючи на значний прогрес в цій сфері, сучасні технології все ще стикаються з проблемами, пов'язаними зі швидкістю та точністю сегментації, особливо в умовах складних або мінливих сценаріїв.

Розвиток методів сегментації є критично важливим для подолання цих обмежень, і саме тут алгоритми кластеризації даних відіграють ключову роль. Кластеризація може сприяти підвищенню точності результату шляхом групування схожих пікселів або особливостей зображення, що значно спрощує визначення границь об'єктів. Це також може допомогти у вирішенні проблем швидкодії, оскільки оптимізовані алгоритми кластеризації можуть

ефективно обробляти великі обсяги даних. Однак, для досягнення найкращих результатів, важливо розробити методи, які можуть адаптуватись до різноманітності зображень та їх характеристик.

У контексті кластеризації візуальних даних, існує потенціал для покращення адаптивності алгоритмів до змін у текстурі, освітленні, та інших умов зображення. Це включає розвиток методів, які можуть динамічно налаштовуватись на основі контексту зображення, щоб забезпечити більш точну та ефективну сегментацію. Окрім того, існує потреба в дослідженні та впровадженні більш ефективних обчислювальних стратегій, які могли б сприяти зниженню часу обробки без втрати якості результату.

Метою даної роботи є розробка покращеної моделі сегментації зображень, що базується на алгоритмах кластеризації даних. Основа цієї моделі полягатиме у комбінації декількох існуючих алгоритмів кластеризації, адаптованих та оптимізованих для досягнення високої точності та швидкодії. Ефективність запропонованої моделі буде оцінена через серію експериментів на зображеннях різного типу та складності, що дозволить підкреслити її переваги у порівнянні з існуючими рішеннями.

## 1 ПОСТАНОВКА ЗАДАЧІ КВАЛІФІКАЦІЙНОЇ РОБОТИ

Сьогодні сегментація зображень застосовується в широкому спектрі областей, від медичної діагностики до систем автономного водіння, що постійно розширюється завдяки новим технологічним досягненням. Цей процес, який дозволяє розбити зображення на семантично значущі частини, є критично важливим для розуміння та аналізу візуальної інформації. Він використовується для визначення об'єктів на фотографіях, відео та інших типах зображень, поліпшення систем безпеки через розпізнавання облич, а також в агротехнологіях для моніторингу стану рослинності, допомагаючи фермерам виявляти посухи, захворювання або потребу в добривах.

Попри значний прогрес у цій галузі, існують певні обмеження та виклики, пов'язані з якістю сегментації, зокрема в частині швидкодії та точності обробки різноманітних зображень. Сучасні методи, хоч і ефективні, можуть бути досить складними у використанні та не завжди забезпечують необхідну швидкість обробки або точність у складних умовах. Такі технології як глибоке навчання пропонують значні переваги у точності визначення об'єктів, але вимагають значних обчислювальних ресурсів та великих наборів даних для тренування, що може бути не завжди доступно або практично в певних ситуаціях.

Така ситуація вказує на потребу розробки нових підходів та моделей, здатних ефективно вирішувати ці проблеми. Використання алгоритмів кластеризації для сегментації зображень може пропонувати обнадійливе рішення, оскільки ці алгоритми можуть значно спростити процес сегментації, забезпечуючи водночас високу точність та швидкість обробки. Кластеризація може ефективно виявляти подібності між пікселями або областями зображення, дозволяючи ідентифікувати окремі компоненти без необхідності великої кількості попередньо-анотованих даних, що є великою перевагою у ситуаціях з обмеженими ресурсами.

Оптимальний підхід до сегментації зображень має забезпечити

ідеальний баланс між простотою імплементації, високою ефективністю обробки та здатністю зберігати критично важливу інформацію у зображеннях. Це особливо важливо для задач, де деталі зображення відіграють ключову роль. Розширення можливостей сегментації зображень може також мати значний вплив на розвиток міського планування, дозволяючи точно аналізувати зміни в міському ландшафті, виявляти потреби в інфраструктурі та планувати ефективне розміщення ресурсів.

Важливим аспектом розвитку ефективних систем сегментації є залучення інновацій у процес обробки зображень, таких як розширені алгоритми кластеризації, що адаптуються до специфіки задачі та даних. Такі алгоритми можуть бути оптимізовані для роботи з великими обсягами даних у реальному часі, що відкриває шлях до створення систем, які можуть оперативно реагувати на зміни в оточенні або стані об'єктів.

Інтеграція глибокого навчання з традиційними методами кластеризації, хоча й може здатися ідеальним рішенням для підвищення точності сегментації зображень, на практиці може зіткнутися з певними обмеженнями. По-перше, такий підхід може призвести до створення надмірно складних моделей, що вимагають значних обчислювальних ресурсів для їхньої роботи. Це, у свою чергу, може негативно позначитися на швидкодії системи, роблячи її менш ефективною для застосувань в реальному часі. По-друге, незважаючи на комбінацію методів, для навчання таких складних моделей все ще потрібні великі обсяги анотованих зображень, збір яких може бути трудомістким і дорогим процесом.

Враховуючи ці обмеження, найбільш ефективним підходом може бути розробка систем сегментації, які базуються на комбінації різних методів кластеризації. Такий підхід дозволить досягти високої точності та швидкодії, уникнувши при цьому надмірної складності та великих вимог до обчислювальних ресурсів. Різноманітні алгоритми кластеризації можуть бути оптимізовані для роботи з конкретними типами даних та задач, що дозволить створити адаптивні та ефективні моделі сегментації. Крім того, використання

кластеризації може зменшити залежність від великих наборів анотованих даних, спрощуючи процес навчання та знижуючи загальні витрати на розробку.

Зосередження на розробці легших, але потужних моделей, які використовують різні стратегії кластеризації, дозволить створити гнучкі та масштабовані системи сегментації зображень. Такі системи не тільки будуть відповідати сучасним вимогам до швидкодії та точності, але й матимуть здатність легко адаптуватися до нових задач та умов їхнього виконання, відкриваючи широкі перспективи для інновацій у різних сферах застосування. Зосередження на мінімізації втрати важливої інформації при обробці зображень є критичним. Використання методів машинного навчання та алгоритмів кластеризації може допомогти ідентифікувати та більш детально обробляти ключові області зображення, що мають важливе значення для конкретних застосувань, таких як точна діагностика в медицині або деталізований моніторинг змін в екосистемах.

Створення такої універсальної та високоефективної моделі для сегментації зображень вимагає інтеграції різноманітних підходів, щоб врахувати безліч факторів, які впливають на якість кінцевих результатів. Попри виклики, успішна реалізація такої моделі може значно розширити горизонти застосування сегментації зображень, відкриваючи нові можливості для досліджень, комерційного використання та розвитку технологій у майбутньому. Розробка такої системи дозволить не тільки покращити якість обробки зображень у традиційних областях застосування, але й відкриє шлях до інноваційних рішень у нових сферах, таких як автоматичне визначення та моніторинг біорізноманіття, розробка інтерактивних та іммерсивних віртуальних реальностей, а також покращення автономних систем управління.

## 2 АНАЛІЗ ІСНУЮЧИХ РІШЕНЬ ТА ПРОБЛЕМ

### 2.1 Проблеми у сфері сегментації зображень

Сегментація зображення – це процес поділу цифрового зображення на кілька сегментів або об'єктів (рисунок 2.1). Мета сегментації – змінити подання зображення на щось більш значуще та легше для аналізу. Це важливий крок в обробці зображення, і вона стає майже обов'язковою, якщо є задача проаналізувати, що знаходиться всередині зображення. Наприклад, якщо необхідно визначити, чи є стілець або людина всередині зображення приміщення, то в цьому випадку може знадобитися сегментація зображення, щоб розділити об'єкти та проаналізувати кожен об'єкт окремо, щоб перевірити, що це таке. Сегментація зображення зазвичай виконує функцію попередньої обробки перед розпізнаванням образів, виділенням ознак та стисненням зображення [1].



Рисунок 2.1 – Приклад сегментованого зображення

У міру того, як сфера обробки зображень невпинно розвивалася, здатність комп'ютерів "бачити" та інтерпретувати візуальну інформацію стала відігравати все більш важливу роль у різноманітних областях людської

діяльності. Від автоматичного розпізнавання облич до аналізу медичних зображень – прогрес у цій області відкриває нові можливості для інновацій та досліджень [2]. Разом з тим, цей розвиток також виявив ряд складнощів та обмежень, притаманних сучасним методам сегментації зображень.

Попри значні технічні досягнення та покращення алгоритмів обробки, проблеми, такі як неточності в ідентифікації об'єктів, складнощі із розпізнаванням текстур у різноманітних умовах освітлення, та виклики, пов'язані з обробкою великих обсягів даних, залишаються актуальними. Ці та інші виклики стимулюють наукове співтовариство до пошуку нових підходів та рішень, які б дозволили вдосконалити процес сегментації зображень, підвищити його точність та ефективність.

З усіма досягненнями, які були здійснені в області обробки та аналізу зображень протягом останніх десятиліть, існують певні проблеми, що продовжують викликати труднощі для дослідників та розробників. Актуальність цих викликів підкреслює необхідність постійного інноваційного підходу в дослідженнях та розробці, щоб максимально реалізувати потенціал сегментації зображень для вирішення прикладних задач.

Однією з основних проблем у сфері сегментації зображень є потреба в обробці великих обсягів даних. Це не тільки вимагає значних обчислювальних ресурсів, але й ставить під сумнів ефективність та швидкість обробки. З розвитком технологій та збільшенням доступності високоякісних зображень кількість даних, які потребують аналізу, зростає експоненційно. Це означає, що алгоритми сегментації мають бути не тільки точними, але й достатньо швидкими, щоб впоратися з великим навантаженням, що є великим викликом для сучасних систем.

Досягнення високої точності сегментації є ще однією значною проблемою. Вона включає в себе не тільки відокремлення об'єктів від фону [3], але й правильне визначення границь та категорій цих об'єктів. Різноманітність сцен, в яких можуть знаходитися об'єкти, робить цю задачу

ще складнішою. Наприклад, в медичній сегментації, де точність є критично важливою, тому що невелика помилка може призвести до неправильної діагностики [4]. Точність сегментації залежить не тільки від алгоритмів, але й від якості навчальних даних, що ускладнює процес.

Сфера сегментації зображень охоплює широкий спектр застосувань, кожне з яких має свої унікальні вимоги та виклики. Наприклад, методи сегментації, які працюють добре для зображень зі спутника, можуть бути неефективними для медичних зображень. Ця різноманітність вимагає розробки спеціалізованих алгоритмів, що здатні адаптуватися до конкретних умов та цілей. Розробка універсальних рішень, які могли б ефективно вирішувати різноманітні задачі, є значним викликом.

Швидкодія обробки зображень має вирішальне значення в багатьох застосуваннях, зокрема, в системах автономного водіння або в реальному часі моніторингу. Висока швидкодія сегментації необхідна для того, щоб системи могли оперативнo реагувати на зміни в оточенні та приймати рішення в критичних ситуаціях [5]. Проблема полягає в тому, що збільшення точності алгоритмів часто вимагає більше обчислень, що, в свою чергу, знижує швидкодію. Знаходження оптимального балансу між швидкодією та точністю є ключовим викликом для дослідників та розробників у сфері сегментації зображень.

Багато сучасних методів сегментації зображень, особливо ті, що базуються на глибокому навчанні, вимагають великої кількості анотованих даних для ефективного навчання. Збір та анотація таких даних може бути дорогорартісним та часомістким процесом. Крім того, якість навчальних даних безпосередньо впливає на якість сегментації, що робить цей процес ще складнішим. Виклик полягає не тільки в зборі достатньої кількості даних, але й в забезпеченні їхньої репрезентативності та різноманітності.

Системи сегментації зображень часто розробляються для специфічних задач або умов. Однак, у реальному світі умови можуть швидко змінюватися, що вимагає від системи здатності до адаптації. Масштабування систем для

роботи з різними типами зображень, розмірами датасетів і оперативним навантаженням є складною задачею. Розробка гнучких алгоритмів, здатних адаптуватися до нових викликів без втрати в ефективності, є однією з ключових потреб у цій галузі.

Іншою значною проблемою є забезпечення сумісності розроблених систем сегментації з існуючими технологічними екосистемами. Інтеграція нових рішень в ті програмні та апаратні платформи, які вже використовуються, може виявитися складною задачею, яка вимагає ретельного планування та адаптації. Водночас, ефективна інтеграція є ключем до ширшого прийняття та використання інноваційних технологій сегментації зображень у різноманітних галузях.

Кожна з цих проблем потребує уважного розгляду та індивідуального підходу до їх вирішення. Прогрес у сфері сегментації зображень залежить не тільки від технологічних інновацій, але й від вирішення цих комплексних викликів, що стоять перед дослідниками та розробниками [6].

## 2.2 Фактори зображення, що ускладнюють сегментацію

Окрім загальних проблем, існує цілий ряд специфічних викликів, що пов'язані безпосередньо з характеристиками зображень, які обробляються. Ці проблеми мають вирішальне значення для розуміння обмежень поточних методів сегментації та розробки нових, більш ефективних підходів. Вони включають в себе широкий спектр факторів, від технічної якості до складності візуального контенту, і можуть істотно ускладнити процес ідентифікації, класифікації та відокремлення об'єктів на зображенні. Необхідно розглянути такі питання як низька роздільна здатність, перекриття об'єктів, варіації освітлення, і як ці аспекти можуть викривляти результати сегментації. Також варто мати на увазі інші фактори, наприклад, складність фону та динамічні зміни, що створюють додаткові перешкоди для алгоритмів сегментації.

Низька роздільна здатність зображень (рисунки 2.2 а) є однією з

найпоширеніших проблем, що впливає на точність сегментації. Зображення з низькою роздільною здатністю не містять достатньо деталей, що ускладнює ідентифікацію об'єктів та їх границь. Це особливо критично в ситуаціях, де необхідно розрізнити дрібні елементи або деталі з високою точністю. Для вирішення цієї проблеми часто застосовують методи підвищення роздільної здатності з використанням штучного інтелекту, які дозволяють збільшити кількість деталей на зображенні, поліпшуючи таким чином його якість перед подальшою обробкою.



Рисунок 2.2 – Приклад зображення з низькою роздільною здатністю

Також доволі поширеною проблемою є висока варіативність освітлення на зображеннях, оскільки вона може радикально змінювати як загальний вигляд сцени, так і візуальне сприйняття окремих об'єктів [7]. Непостійність у інтенсивності та напрямку світла не тільки створює тіні або пересвітлені зони, але й може призводити до спотворення кольорів та текстур, роблячи об'єкти важкорозрізнюваними від фону. Це ускладнює процес ідентифікації об'єктів та їх подальшої сегментації, оскільки алгоритми можуть неправильно інтерпретувати границі та характеристики об'єктів.

Для вирішення цієї проблеми вдаються до застосування різноманітних технік нормалізації освітлення та корекції контрасту (рисунок 2.3), які

допомагають стандартизувати умови освітлення по всьому зображенню. Це може включати в себе алгоритми для вирівнювання рівнів освітленості та контрастності, що дозволяє мінімізувати вплив змінних умов освітлення на візуальні характеристики об'єктів. Такі підходи не тільки спрощують виявлення та сегментацію об'єктів, але й підвищують загальну надійність та точність сегментаційних алгоритмів, дозволяючи їм краще адаптуватися до різноманітних сценаріїв застосування. Особливо це важливо в таких областях, як медична візуалізація, аерофотознімання та автоматичне водіння, де точність може мати критичне значення.



Рисунок 2.3 – Приклад переосвітленого зображення:

а) до коригування; б) після коригування

Перекриття об'єктів також є не менш важливою проблемою, яка може істотно ускладнити сегментацію. Коли один об'єкт частково або повністю перекриває інший на зображенні, визначити їх границі стає значно складніше. Це особливо актуально для зображень з високою щільністю об'єктів. В таких ситуаціях застосовують алгоритми глибокого навчання, зокрема, нейронні мережі, які можуть ефективно розпізнавати та відділяти

перекриті об'єкти, враховуючи контекст та інші характеристики зображення.

Комплексність фону є ще одним фактором, що ускладнює сегментацію. Зображення зі складним фоном, який містить багато деталей або шум, може ускладнити визначення границь об'єктів. У таких випадках ефективним рішенням може бути застосування технік передобробки, таких як фільтрація шуму та підсилення країв, що допомагає покращити виділення об'єктів на складному фоні. Додатково, можуть використовуватися методи машинного навчання для класифікації елементів фону та об'єктів, що дозволяє системі ігнорувати несуттєві деталі фону під час сегментації.

Варіативність кольору та текстури об'єктів на зображенні також може створити труднощі для сегментації, особливо в умовах, де об'єкти мають схожі візуальні характеристики з фоном або між собою. Використання кольорових просторів та текстурних аналізаторів може допомогти в розрізненні об'єктів, поліпшуючи загальну точність сегментації. Такі методи дозволяють системі враховувати додаткові властивості об'єктів, що сприяє їх кращій ідентифікації та класифікації.

Загалом, кожна з цих проблем вимагає індивідуального підходу та застосування спеціалізованих технік для їх вирішення. Прогрес у галузі сегментації зображень значною мірою залежить від розвитку технологій обробки зображень та деяким чином від розвитку машинного навчання. Це дало б можливість ефективно адаптуватися та вирішувати вище описані виклики, покращуючи таким чином якість та точність сегментації в різноманітних застосуваннях.

### 2.3 Аналіз існуючих методів сегментації зображень

У світі комп'ютерного зору сегментація зображень відіграє ключову роль, відкриваючи безмежні можливості для аналізу та інтерпретації візуальної інформації. Від простих методів порогової обробки до складних алгоритмів, заснованих на машинному навчанні, спектр існуючих методів сегментації зображень є вражаючим. Кожен з цих методів має свої унікальні

характеристики, адаптовані під конкретні типи задач та умови застосування.

Традиційні методи, такі як порогова обробка та морфологічні операції, часто слугують основою для базової сегментації, пропонуючи простоту використання та низькі вимоги до обчислювальних ресурсів. Ці методи ефективні для зображень з високим контрастом між об'єктами та фоном, але можуть зіткнутися з труднощами у складніших сценаріях.

З іншого боку, алгоритми кластеризації, як-от K-means або алгоритми, засновані на густинах, пропонують більш гнучкі рішення для сегментації зображень, дозволяючи виявляти групи пікселів або об'єктів на основі їх схожості. Використання таких методів може значно покращити якість сегментації, особливо у випадках, коли об'єкти та фон мають складну структуру або коли необхідно виділити декілька об'єктів одночасно.

Методи, засновані на машинному навчанні та глибокому навчанні, представляють собою передовий рівень інструментарію для сегментації зображень, демонструючи вражаючу здатність до вирішення складних візуальних задач. Однак, необхідність у великих обсягах анованих даних для навчання та високі вимоги до обчислювальних потужностей ставлять певні обмеження на їх універсальне застосування, особливо у сценаріях з обмеженими ресурсами або в реальному часі.

Отже, детальний аналіз існуючих методів сегментації зображень є надзвичайно важливим для визначення найефективніших стратегій їх застосування [8]. Він дозволяє не тільки оптимізувати процеси обробки візуальних даних, але й відкриває шлях для підходів, спрямованих на подоланні існуючих обмежень, забезпечуючи більш ефективну сегментацію.

### 2.3.1 Порогова сегментація

Порогова сегментація є одним із найпростіших та найшвидших методів сегментації зображень. Цей метод полягає в виборі певного порогового значення, що розділяє пікселі зображення на дві групи: об'єкти та фон [9]. Пікселі, які перевищують поріг, класифікуються як об'єкти, тоді як решта

пікселів вважаються фоном. Цей метод ефективний для зображень з високим контрастом між об'єктом та фоном і часто використовується у випадках, де необхідно швидко виділити об'єкти з відносно однорідним кольором або інтенсивністю.

Переваги порогової сегментації включають її простоту в реалізації та швидкість обробки. Цей метод не вимагає значних обчислювальних ресурсів, що робить його ідеальним для використання в реальному часі або на пристроях з обмеженою обчислювальною потужністю.

Однак, недоліки порогової сегментації включають її обмежену ефективність у складних умовах освітлення або на зображеннях із низьким контрастом між об'єктами та фоном. Вона також не дуже ефективна для сегментації зображень зі складними або текстурованими фонами, де контраст між об'єктами та фоном не є однозначним.

### 2.3.2 Сегментація на основі глибокого навчання

Методи глибокого навчання, такі як згорткові нейронні мережі (CNN) та мережі повного згортання (FCN), революціонізували підходи до сегментації зображень, пропонуючи високу точність у різноманітних застосуваннях. Однією з найпопулярніших архітектур для сегментації є U-Net, яка була спеціально розроблена для медичної візуалізації та показала чудові результати в ідентифікації медичних зображень.

Переваги сегментації на основі глибокого навчання включають здатність до самонавчання на основі великих наборів даних, що дозволяє системам постійно покращувати свою точність. Ці методи ефективні для роботи зі складними зображеннями та можуть виявляти тонкі особливості та складні взаємозв'язки в даних, які можуть бути неочевидні для традиційних методів.

Однак, недоліки полягають у значних обчислювальних вимогах та потребі в великих наборах анотованих даних для ефективного навчання. Це може стати перешкодою для застосування в областях з обмеженими даними

або в умовах, де швидкість обробки є критичною. Також існує проблема "чорного ящика", пов'язана з труднощами у інтерпретації рішень, прийнятих мережею, що може ускладнити їх використання в деяких чутливих до помилок сферах, як-от медицина.

### 2.3.3 Сегментація на основі графів

Сегментація на основі графів використовує теорію графів для моделювання зображень, де пікселі представляються як вершини графа, а зв'язки між ними як ребра, вага яких відображає схожість між пікселями. Один з популярних методів – це алгоритм нормалізованого різання (Normalized Cuts), який спрямований на мінімізацію вартості розбиття графа на підграфи, таким чином групуючи пікселі в сегменти за їхньою схожістю.

Переваги сегментації на основі графів полягають у її гнучкості та ефективності для обробки зображень із складними структурами та текстурами. Цей метод здатний ефективно виділяти об'єкти, навіть якщо вони мають різну інтенсивність або колір, але схожі за текстурою або структурою.

Однак, недоліки включають в себе високі обчислювальні витрати, особливо для зображень великого розміру, через складність алгоритмів обчислення графів. Також метод може бути складним у налаштуванні та вимагати ретельного вибору параметрів для досягнення оптимальних результатів сегментації.

### 2.3.4 Кластеризація

Кластеризація є потужним методом сегментації, що групує пікселі зображення за подібністю їхніх характеристик, таких як колір, інтенсивність або текстура [11]. Найвідомішим алгоритмом кластеризації є K-means, який визначає k центрів кластерів та призначає кожен піксель до найближчого кластера на основі його властивостей.

Переваги кластеризації полягають в її здатності ефективно обробляти

зображення зі складною структурою, де проста порогова сегментація може бути неефективною. Кластеризація може виявляти приховані взаємозв'язки між пікселями, що дозволяє виділяти об'єкти з подібними характеристиками, навіть якщо вони візуально не відрізняються від фону.

Недоліки методу кластеризації включають в себе вибір кількості кластерів, що може бути нелегким без попереднього аналізу зображення та може вимагати ітеративного підходу для знаходження оптимального рішення. Крім того, кластеризація може бути чутливою до шуму та варіацій у зображеннях, що потребує додаткових методів передобробки для підвищення її ефективності.

## 2.4 Аналіз методів кластеризації

У контексті різноманітності методів сегментації зображень, особливе місце займають алгоритми кластеризації, які виділяються своєю універсальністю та здатністю адаптуватися до складних умов обробки. Використання кластеризації для групування пікселів на основі схожих характеристик дозволяє не лише ефективно виділяти об'єкти на зображенні, але й справлятися з викликами, пов'язаними із змінами освітлення, текстур та іншими аспектами візуальної інформації. Розгляд алгоритмів кластеризації відкриває нові горизонти для підвищення точності та ефективності сегментації, тому, зважаючи на це, варто детальніше оглянути найпопулярніші алгоритми кластеризації з порівнянням їх переваг та недоліків.

### 2.4.1 Кластеризація методом K-means

Кластеризація методом K-means – це алгоритм кластеризації, який відноситься до групи алгоритмів що не потребують навчання, він групує набір даних без міток у різні кластери (рисунок 2.4). Тут  $k$  визначає кількість заздалегідь визначених кластерів, які необхідно створити в процесі,

наприклад, якщо  $k=2$ , буде два кластери, а для  $k=3$  буде три кластери і так далі.

Це дозволяє кластеризувати дані в різні групи та по суті є зручним способом самостійного виявлення категорій груп у немаркованому наборі даних без необхідності навчання.




Рисунок 2.4 – Результат кластеризації за допомогою методу K-Means

Даний алгоритм базується на основі центроїда, де кожен кластер пов'язаний із центроїдом. Основною метою цього алгоритму є мінімізація суми відстаней між точкою даних та відповідними кластерами.

Алгоритм приймає набір даних без міток як вхідні дані, ділить набір даних на  $k$ -кількість кластерів і повторює процес, доки не знайде найкращі кластери. Значення  $k$  має бути заздалегідь визначене в цьому алгоритмі. Метод кластеризації K-means виконує дві задачі:

- визначає найкраще значення для  $k$  центральних точок або центроїдів за допомогою ітераційного процесу;
- призначає кожну точку даних найближчому  $k$ -центру. Ті точки даних, які знаходяться поблизу певного  $k$ -центру, створюють кластер  $d$ .

Таким чином, кожен кластер має точки даних з деякими спільними рисами, і він знаходиться далеко від інших кластерів.

Продуктивність алгоритму кластеризації методом K-means дуже залежить від кластерів, які він формує. Підбір оптимальної кількості

кластерів може стати проблемним. Існують різні способи визначення оптимальної кількості, тобто значення коефіцієнту  $K$ , але найбільш раціональний з них тільки один.

Наведений метод має назву Elbow Method або метод ліктя. Він є одним із найпопулярніших способів знайти оптимальну кількість кластерів і для цього використовує концепція значення WCSS (within-cluster sum of squares). WCSS означає суму квадратів у кластері, що є кількістю загальних варіацій в межах кластера.

Щоб виміряти відстань між точками даних та центроїдом, можна використовувати будь-який відомий користувачеві метод, наприклад, евклідову або манхеттенську відстань.

Для пошуку оптимального значення кластерів метод ліктя виконує наступні дії:

- здійснює кластеризацію K-Means на заданому наборі даних для різних значень  $K$  (діапазони від 1 до 10);
- для кожного значення  $K$  обчислюється значення WCSS;
- далі будується крива між обчисленими значеннями WCSS та кількістю кластерів  $K$ . Гостра точка вигину або точка графіка, що виглядає як плече, вважається найкращим значенням  $K$  (рисунок 2.5).

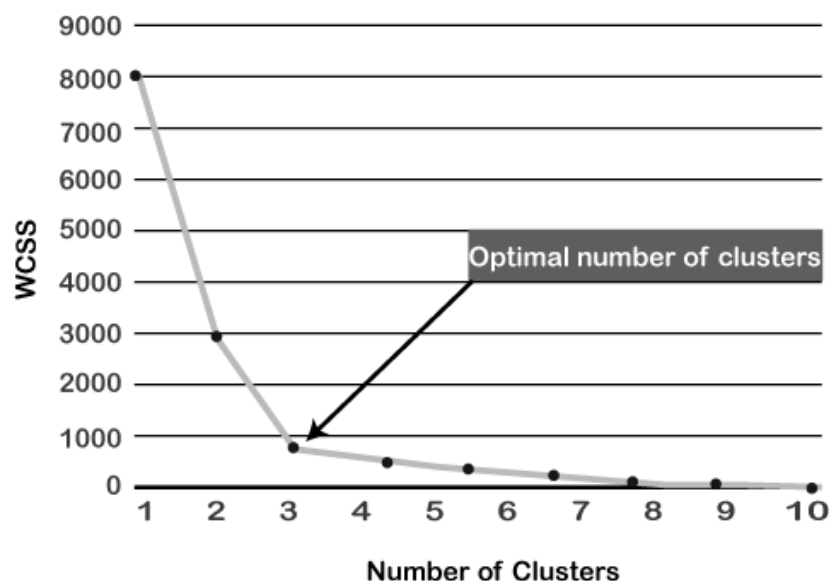


Рисунок 2.5 – Графік залежності значення WCSS від кількості кластерів

## 2.4.2 Нечітка кластеризація методом C-means

Існують алгоритми кластеризації з використанням нечіткої логіки. Тобто, логіки, при якій немає однозначної належності точки конкретному кластеру. Принципи нечіткої логіки можна використовувати для кластеризації багатовимірних даних, призначаючи кожній точці членство в кожному центрі кластера від 0 до 100 відсотків. Це може бути більш ефективно у порівнянні з традиційною кластеризацією з жорстким порогом, де кожній точці призначається чітка, точна мітка.

Алгоритм кластеризації методом C-Means працює шляхом призначення членства кожній точці даних, що відповідає кожному центру кластера, на основі відстані між центром кластера та точкою даних [12]. Чим більше даних знаходиться ближче до центру кластера, тим більше їх приналежність до конкретного центру кластера. Зрозуміло, що сума належності кожної точки даних повинна дорівнювати одиниці.

C-Means – це метод кластеризації, який дозволяє створювати нечіткі розділи з даних. Алгоритм залежить від параметра  $m$ , який відповідає ступеню нечіткості рішення. Великі значення  $m$  призведуть до розмивання меж кластерів, і таким чином всі елементи матимуть тенденцію належати до всіх кластерів. Тобто рішення оптимізаційної задачі залежать від параметра  $m$ : різні вибори  $m$  зазвичай призведуть до різних розділів.

Нечітка кластеризація методом C-means або Fuzzy C-means (FCM), спирається на основну ідею Hard C-means (HCM) кластеризації з тією різницею, що в FCM кожна точка даних належить кластеру на деякому рівні приналежності, а в HCM кожна точка даних або належить до певного кластера, або ні. Таким чином FCM використовує нечітке розділення, тобто кожна точка даних може належати до кількох груп зі своїм ступенем приналежності, визначеним оцінкою між 0 та 1. Однак, FCM все ще використовує доволі затратну функцію, яка має бути мінімізована під час спроби розділення набору даних. Алгоритм працює ітеративно через

попередні дві умови до моменту поки покращення не перестануть спостерігатись.

Порівняємо більш детально алгоритми FCM та K-means, щоб отримати чітке уявлення про те, де підходить описуваний алгоритм C-means.

Перше порівняння стосується віднесення до кластера: у нечіткій кластеризації кожна точка має ймовірність належати до кожного кластера, а не повністю належати лише одному кластеру, як це має місце в традиційному алгоритмі K-means. У FCM кожна точка має вагове значення, пов'язане з певним кластером, тому точка не знаходиться «в кластері» повністю, оскільки вона має слабкий або сильний зв'язок із кластером, який визначається зворотною відстанню до центру кластера.

Друге порівняння стосується швидкості: засоби FCM, як правило, працюватимуть повільніше, ніж засоби K-means, оскільки вони насправді виконують більше роботи. Кожна точка оцінюється з кожним кластером, і в кожній оцінці бере участь більше операцій. Метод K-means потребує обчислення відстані, тоді як нечіткий FCM потребує повного оберненого зважування відстані.

### 2.4.3 Ієрархічна кластеризація

Ієрархічна кластеризація є однією з найпопулярніших та простих для розуміння методів кластеризації. Ця техніка кластеризації поділяється на два види: агломеративний та розділовий.

У техніці агломеративної ієрархічної кластеризації спочатку кожна точка даних розглядається як окремий кластер. На кожній ітерації подібні кластери зливаються з іншими кластерами, поки не буде сформований один або K кластерів.

Базовий алгоритм Agglomerative має наступні кроки:

- обчислення матриці близькості;
- визначення кожної точки даних як кластера;
- поєднання двох найближчих за відстанню кластерів між собою;

– повторення попередніх кроків допоки необхідна кількість кластерів не буде сформована

Візуально алгоритм ієрархічної кластеризації демонструють у вигляді дендрограми (рисунок 2.6).




Рисунок 2.6 – Дендрограма роботи алгоритму ієрархічної кластеризації

Наступним методом для розгляду є розділовий алгоритм ієрархічної кластеризації. Можна сказати, що розділова ієрархічна кластеризація є прямою протилежністю агломеративному підходу ієрархічної кластеризації. У розділовій ієрархічній кластеризації всі точки даних розглядаються як один кластер, і на кожній ітерації точки, які найбільш не схожі, відокремлюються від кластера. Кожна відокремлена точка даних розглядається як окремий кластер. Зрештою, залишиться  $n$  кластерів, кількість яких задаються на початку. Таким чином, оскільки окремі кластери діляться на  $n$  кластерів, це називається розділовою ієрархічною кластеризацією.

## 3 ВИБІР ІНСТРУМЕНТІВ ДЛЯ МОДЕЛІ СЕГМЕНТАЦІЇ ЗОБРАЖЕНЬ

### 3.1 Стандартизація даних

Стандартизація даних відіграє фундаментальну роль у процесі сегментації зображень, оскільки забезпечує необхідну уніформність та якість вхідних даних. Це критично важливо для алгоритмів, які залежать від точності та послідовності даних для ефективної обробки. Належна стандартизація допомагає мінімізувати помилки в сегментації, сприяючи більш точному виявленню та класифікації об'єктів у зображеннях. Передбачається використання різних методів, таких як нормалізація та масштабування для адаптації даних під специфічні умови та вимоги обробки. Розглянемо ключові техніки та процеси, які використовуються для стандартизації зображень, щоб забезпечити оптимальну підготовку даних для подальшої сегментації.

У контексті сегментації зображень, стандартизація включає ряд методів, які забезпечують однорідність та точність в обробці даних. Це починається з визначення якості вхідних зображень та їхнього подальшого відповідного коригування за допомогою нормалізації інтенсивності пікселів. Нормалізація зазвичай виконується шляхом масштабування значень інтенсивності пікселів до стандартного діапазону, наприклад, від 0 до 255 для 8-бітних зображень.

Одним з ефективних методів є використання Min-Max нормалізації. Цей метод регулює інтенсивність пікселів зображення так, що мінімальне значення інтенсивності перетворюється на задане мінімальне значення (наприклад, 0), а максимальне – на максимальне можливе значення (наприклад, 255 для 8-бітних зображень).

Цей метод не тільки забезпечує однорідність даних, але й покращує візуальне сприйняття зображень, роблячи їх більш придатними для подальшої обробки та аналізу.

Також, стандартизація включає уніфікацію форматів зображень, що спрощує їх інтеграцію та обробку у програмному забезпеченні. Кожен із цих етапів підвищує якість вихідних даних, готуючи їх до точної та ефективної сегментації.

### 3.2 Вибір інструментів

Зображення, отримані за допомогою сегментації, є фундаментальною частиною багатьох сучасних досліджень та додатків, від медичної візуалізації до систем безпеки. Як і у випадку з супутниковими знімками, якість цих зображень критично важлива для їх ефективності. Технологічний прогрес збільшує доступність та інформативність цих даних, але також підносить виклики, пов'язані з якістю зображень, які можуть бути викликані різними факторами, такими як шум або різні умови зйомки.

Вибір інструментів та методів для сегментації зображень вимагає ретельного вивчення та знань про специфіку вхідних даних та кінцеві цілі застосування. Ефективні інструменти можуть значно покращити якість сегментації, забезпечуючи більшу точність і надійність у виявленні та класифікації об'єктів на зображеннях. Невірний вибір інструментарію може призвести не тільки до технічних помилок у сегментації, але й до втрати важливої інформації, що може вплинути на всю подальшу роботу з даними.

Опираючись на виклики, пов'язані з якістю зображень, детальний розгляд обраних інструментів та методологій є важливою частиною аналізу в наступних підрозділах. Вони охоплюватимуть методи попередньої обробки, що покращують якість даних перед сегментацією, використання алгоритмів кластеризації для групування пікселів та застосування алгоритмів для детальної визначення границь об'єктів. Аналіз вибору програмного забезпечення та обчислювальних платформ, що підтримують обробку та аналіз зображень допоможе забезпечити не лише технічну точність, а й адаптацію до специфічних потреб застосування, підвищуючи ефективність використання даних.

### 3.2.1 Попередня обробка зображень

Попередня обробка зображень є критичною стадією в процесі сегментації, оскільки вона впливає на якість кінцевих результатів аналізу. Вибір правильних методів для попередньої обробки дозволяє значно покращити візуальну якість зображень, забезпечити більшу точність у виділенні об'єктів та знизити рівень шумів. Методи, які використовуються на цій стадії, включають зміну масштабу, корекцію освітлення, фільтрацію шуму та підвищення контрасту, кожен з яких має свої специфічні цілі та виклики. Важливо обрати методи, що найкраще відповідають вимогам конкретних даних та задач. Це вимагає глибокого розуміння як технічних характеристик зображень, так і особливостей застосувань, для яких вони використовуються. Адекватний вибір методів попередньої обробки допоможе забезпечити, що зображення буде оптимізовано для подальшої точної сегментації, мінімізуючи можливі помилки та підвищуючи ефективність аналітичних алгоритмів.

#### 3.2.1.1 Зміна масштабу

Зміна масштабу дозволяє адаптувати зображення під потрібні розміри та деталізацію, що необхідна для ефективного застосування алгоритмів сегментації. Одним з популярних методів зміни масштабу є білінійна інтерполяція, яка дозволяє плавно змінювати розміри зображення, зберігаючи при цьому його візуальну якість.

Білінійна інтерполяція розраховує значення нових пікселів на основі лінійного зважування чотирьох найближчих пікселів вихідного зображення, що дає змогу згладжувати переходи та уникати ступінчатості, властивої більш простим методам, як-от найближчий сусід. Цей метод ефективно використовується для підготовки зображень, де важливо зберегти деталі та текстуру під час зміни масштабу.


Застосування білінійної інтерполяції покращує подальшу обробку

зображень, особливо при використанні складних алгоритмів сегментації, які вимагають високої точності відображення деталей. Це забезпечує більшу адаптивність моделі до різних умов вхідних даних та підвищує загальну ефективність роботи.

### 3.2.1.2 Корекція освітлення

Корекція освітлення є важливим кроком у попередній обробці зображень, особливо коли метою є покращення якості візуалізації для точнішої сегментації. Одним із найефективніших методів корекції освітлення є гістограмне вирівнювання [13]. Цей метод дозволяє автоматично коригувати контраст зображення, роблячи його більш чітким та покращуючи візуальне сприйняття деталей.

Гістограмне вирівнювання працює шляхом розтягування гистограми інтенсивностей пікселів зображення так, щоб вона рівномірно розподілялася по всьому доступному діапазону (рисунок 3.1). Це підвищує загальний контраст зображень, особливо в областях, які були недостатньо освітлені або пересвітлені. Результатом є зображення, на якому виділено дрібні деталі та поліпшені переходи відтінків, що є критично важливим для алгоритмів сегментації, які покладаються на варіації інтенсивностей для визначення країв і об'єктів.



а)

б)

Рисунок 3.1 – Гістограма зображення:

а) до вирівнювання; б) після вирівнювання

Застосування гістограмного вирівнювання може бути особливо корисним у сценаріях, де зображення мають великі області темряви або

світла, що часто зустрічається в медичних знімках, аерофотозйомці або інших технічних застосуваннях. Метод не лише покращує якість зображень для візуального аналізу людиною, але й підвищує ефективність комп'ютерних алгоритмів сегментації, які вимагають високого рівня розрізнення між об'єктами.

Враховуючи значення точності в сегментації, гістограмне вирівнювання виступає як незамінний інструмент у наборі методів попередньої обробки зображень. Його застосування забезпечує розширення можливостей аналітичних систем та підвищує надійність отриманих результатів сегментації.

### 3.2.1.3 Фільтрація шуму

Фільтрація шуму є важливим етапом, спрямованим на зниження випадкових артефактів, які можуть погіршити якість вихідних даних та сегментації. Гауссівське розмиття – це один із методів, який ефективно зменшує шум, використовуючи математичну функцію для створення ефекту розмиття, що допомагає вирівнювати коливання інтенсивності пікселів на зображенні. Це забезпечує плавніше зображення, знижуючи видимість шуму та покращуючи загальну чистоту візуальних даних.

Гауссівське розмиття використовує функцію ядра для згладжування зображення. Математично це описується виразом 3.1:

$$G(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2}{2\sigma^2}}, \quad (3.1)$$

де  $\sigma$  – це стандартне відхилення гауссівського розподілу, що визначає ширину дії функції.

У контексті обробки зображень, гауссівське розмиття застосовується шляхом конволюції зображення з гауссівським ядром. Це забезпечує плавне згладжування колірних переходів та зменшення візуального шуму, особливо

корисне в умовах слабого освітлення або при високій чутливості датчиків камери.

Процес розмиття впливає на кожен піксель зображення, вираховуючи його нове значення на основі вагових коефіцієнтів від сусідніх пікселів, що підпадають під маску ядра. Це допомагає ізолювати важливі структурні елементи від випадкових варіацій інтенсивності, які можуть бути інтерпретовані як шум (рисунок 3.2).



а)



б)

Рисунок 3.2 – Зашумлене зображення: а) до застосування розмиття;  
б) після застосування розмиття

Впровадження гауссівського розмиття у алгоритм попередньої обробки зображень дозволяє покращити якість вихідних даних для алгоритмів сегментації, зменшуючи ймовірність помилок та забезпечуючи стабільнішу та надійнішу візуалізацію. Таким чином, метод стає незамінним у процесах, де точність розпізнавання деталей є ключовою для успішного аналізу зображень.

#### 3.2.1.4 Підвищення контрасту

Підвищення контрасту є ще одним не менш важливим етапом у попередній обробці зображень, забезпечуючи більшу чіткість та виділення важливих деталей на зображенні. Один із ефективних методів для цього є

локальне контрастне підсилення (Local Contrast Enhancement, LCE). LCE покращує контраст на місцевому рівні, розглядаючи невеликі ділянки зображення та автоматично регулюючи їхній контраст за допомогою алгоритмів, які адаптують інтенсивність кожного пікселя з огляду на його оточення [14].

Цей метод працює шляхом виявлення областей із низьким контрастом та виконання динамічного коригування для збільшення чіткості між сусідніми пікселями. Це не тільки покращує зовнішній вигляд зображення, але й сприяє кращій диференціації об'єктів у складних сценах, що є критично важливим для подальшої точної сегментації.

Локальне підсилення контрасту особливо корисне у медичних застосуваннях для виокремлення тонких структур тканин або у географічних інформаційних системах для підкреслення рельєфу та інших топографічних особливостей. Цей метод також дозволяє зменшити втрату деталей у яскравих або темних регіонах, забезпечуючи більш універсальний підхід до обробки різних типів зображень.

### 3.2.2 Кластеризація K-Means

Кластеризація K-Means є одним із найпопулярніших алгоритмів навчання без вчителя, який широко використовується для сегментації зображень. Алгоритм розділяє зображення на  $k$  кластерів, які представляють собою різні об'єкти або області на зображенні. Основна мета полягає у групуванні пікселів, які мають схожі характеристики, такі як колір або інтенсивність, що забезпечує чіткіше визначення областей на зображенні.

Процес роботи алгоритму починається з випадкового вибору  $k$  центроїдів, які виступають як початкові центри кластерів. На кожній ітерації алгоритм вимірює відстань від кожного пікселя до цих центроїдів та призначає піксель до кластера з найменшою відстанню. Після призначення всіх пікселів, центроїди перераховуються як середнє значення всіх пікселів, призначених до відповідного кластера. Цей процес ітераційно повторюється

до тих пір, поки центроїди не перестануть змінюватися, що означає стабілізацію кластерів.

Застосування K-Means у сегментації зображень важливе завдяки його здатності ефективно виявляти структури на основі схожості кольору або текстури. Цей алгоритм особливо корисний у сценаріях, де потрібно швидко обробляти великі об'єми даних, забезпечуючи добрі результати при відносно низькому обчислювальному навантаженні. Втім, важливо правильно вибрати кількість кластерів  $k$ , оскільки невідповідна кількість може призвести до недостатньої або надмірної сегментації зображення.

### 3.2.3 Алгоритм нормалізованого розрізу

Алгоритм нормалізованого розрізу NCut є вдосконаленим методом для сегментації зображень, який застосовує принципи теорії графів для ефективного поділу зображення на кластери [15]. Алгоритм вирізняється тим, що він оптимізує не тільки когезію внутрішніх елементів кластера, але й мінімізує схожість між різними кластерами, що забезпечує чіткіше відділення об'єктів.

В NCut зображення представляється як ваговий граф (рисунок 3.3), де вузли відповідають пікселям, а ваги ребер між ними відображають ступінь схожості.




Рисунок 3.3 – Приклад графу нормалізованого розрізу для двох кластерів даних

Алгоритм вимагає мінімізації вартості розрізу, яка визначається як сума ваг ребер, що перетинають розріз, поділена на загальну суму ваг всіх

ребер, що виходять з кожного кластера. Такий підход до розрізу дозволяє не тільки зосередитись на локальних особливостях кластерів, але й ураховувати глобальну структуру зображення.

Для практичної реалізації, обчислення нормалізованого розрізу може вимагати значних обчислювальних ресурсів, особливо для великих зображень. Тому важливо оптимізувати алгоритм, забезпечуючи ефективне обчислення матриць схожості та їх подальше використання у процесі мінімізації вартості розрізу.

Інтеграція NCut з K-Means може значно покращити результати сегментації, використовуючи спочатку K-Means для грубої кластеризації, а потім застосовуючи NCut для детального визначення та уточнення границь між кластерами. Це дозволяє комбінувати швидкість k-means з точністю NCut, оптимізуючи загальний процес сегментації.

#### 3.2.4 Обчислювальні платформи

Обчислювальні платформи є необхідними для реалізації та використання алгоритмів сегментації зображень. Вибір правильної платформи впливає на швидкість обробки, ефективність використання ресурсів та масштабованість процесів. Сучасні обчислювальні платформи поділяються на два основних типи: локальні та хмарні рішення.

Локальні платформи забезпечують контроль та безпеку даних, але можуть вимагати значних капіталовкладень у обладнання. Хмарні платформи, такі як AWS, Google Cloud та Microsoft Azure, пропонують масштабованість та гнучкість, дозволяючи користувачам платити тільки за використані ресурси та легко масштабувати обчислювальні потужності відповідно до потреб проекту.

Amazon Web Services (AWS) та Google Cloud є двома провідними платформами, що пропонують розширені можливості для обробки даних. AWS вирізняється своїм широким спектром послуг та налаштуванням безпеки, що робить її ідеальною для проектів з великими даними. Google

Cloud надає високу інтегрованість з машинним навчанням та аналітикою, що є вигідним для сегментації зображень, особливо коли використовуються алгоритми глибокого навчання. Обидві платформи пропонують гнучкі тарифи та масштабованість, що дозволяє оптимізувати витрати та обчислювальні потужності залежно від потреб проекту.

### 3.3 Метрики порівняння якості сегментації

Метрики порівняння якості є необхідними для оцінки ефективності моделей сегментації зображень. Вони дозволяють здійснювати кількісну оцінку точності та здатності алгоритму коректно виділяти об'єкти на зображенні. Використання таких метрик є важливим для порівняння різних методів та алгоритмів сегментації і для обрання оптимального рішення для конкретної задачі аналізу зображень. Серед основних алгоритмів, які найбільш використовуються виділяють наступні метрики:

- точність (Precision): ця метрика визначає, наскільки точно алгоритм ідентифікує позитивні випадки серед усіх пікселів, які він відніс до певного класу. Висока точність свідчить про те, що майже всі позитивні випадки ідентифікувалися правильно. Наприклад, якщо алгоритм виділяє певний клас об'єктів на зображенні, точність показує, яка частка цих виділених областей дійсно відповідає цьому класу;

- повнота (Recall): ця метрика вимірює, наскільки ефективно алгоритм знаходить всі позитивні випадки в датасеті. Висока повнота свідчить про здатність алгоритму правильно ідентифікувати позитивні випадки. Наприклад, якщо на зображенні присутні об'єкти певного класу, повнота показує, яка частка цих об'єктів була ідентифікована алгоритмом;

- F-міра (F-score): це гармонічне середнє між точністю та повнотою, яке використовується для оцінки балансу між ними. Вона дає можливість враховувати обидва аспекти одночасно та дозволяє обирати оптимальну точку компромісу між ними. F-міра штрафує за нерівномірність між точністю та повнотою і дає більш об'єктивну оцінку якості моделі;

– індекс Жаккара (Jaccard Index): ця метрика визначає ступінь схожості між двома множинами шляхом обчислення відношення їхнього перетину до їхнього об'єднання. Вона дає відповідь на питання, наскільки дві множини схожі одна на одну, і часто використовується для порівняння результатів сегментації.

Щодо експертних оглядів, вони зазвичай включають в себе оцінку спеціалістів у відповідних галузях, які аналізують якість сегментації зображень з врахуванням контексту та конкретних потреб додатку. Це дає можливість збирати додаткові відомості про придатність алгоритму до конкретних задач та сценаріїв використання.

## 4 МОДЕЛЬ СЕГМЕНТАЦІЇ ЗОБРАЖЕНЬ EBSM

У розділі розглянуті різноманітні підходи та методики у сфері сегментації зображень. Проведено огляд існуючої моделі сегментації, а також представлена розроблена модель EBSM (Enhanced Boundary Segmentation Model). Модель EBSM поєднує перевірені технології та інноваційні рішення для забезпечення вищої точності та ефективності у виявленні та класифікації об'єктів на зображеннях. Опис моделі поділяється на декілька модулів та підмодулів, кожен з яких викладений у формі кортежів для зручності аналізу.

Також необхідно провести аналіз, як існуючої, так і представленої моделі. Окрім того важливим кроком стане тестування моделі та порівняльний аналіз її ефективності у порівнянні з існуючими рішеннями.

### 4.1 Огляд існуючої моделі сегментації зображень

В загальному сенсі, модель є спрощеним представленням реальності, створеним з метою аналізу чи покращення розуміння певних процесів або явищ. У наукових та інженерних дисциплінах моделі використовуються для імітації складних систем та дозволяють вченим і інженерам експериментувати та висувати гіпотези в контрольованих умовах. Це ключовий інструмент у рішенні задач, де прямі спостереження або експерименти є недоступними, занадто дорогими або небезпечними.

Модель в контексті сегментації зображень визначається як система алгоритмів та методів, призначених для розпізнавання та класифікації об'єктів на зображеннях. Ці моделі складаються з декількох етапів обробки, кожен з яких відповідає за певні функції від попередньої обробки до фінальної сегментації. У цьому випадку, термін "модель" охоплює не лише самі алгоритми, а й структурну організацію процесу обробки зображень, що дозволяє досягти високої точності та ефективності в роботі з візуальними даними.

Сучасні моделі сегментації використовують різні підходи, включно з кластеризацією та іншими методами аналізу зображень, які дозволяють виділяти об'єкти з високим ступенем точності. Ці методи застосовуються у багатьох областях, від медичної візуалізації до систем автоматичного відеоспостереження, де важливо точно ідентифікувати та класифікувати об'єкти на зображеннях.

Перш ніж перейти до опису існуючих моделей та запропонованої моделі EBSM, важливо розуміти базові принципи та компоненти, які лежать в основі процесів сегментації. Це допоможе краще зрозуміти, як нова модель може покращити результати обробки зображень порівняно з існуючими методами. Існуючі моделі сегментації зображень можна поділити на кілька основних категорій в залежності від використовуваних технік та підходів. Починаючи з базових методів на основі порогової обробки, які використовують прості алгоритми для визначення границь об'єктів на зображенні, моделі ускладнювались з розвитком технологій. Еволюція привела до застосування статистичних методів, таких як кластеризація, яка дозволяє групувати піксели за схожими характеристиками без явного зазначення границь об'єктів.

Сучасні моделі сегментації варіюються від простих до складних, адаптуючись до нових технологій та потреб аналізу. Один із узагальнених підходів до цих моделей представлений у вигляді кортежа GSM (General Segmentation Model) (вираз 4.1):

$$\text{GSM} = \{B3, MC, MA\}, \quad (4.1)$$

де B3 – вхідне зображення;

MC – модуль сегментації;

MA – модуль аналітики.

Варто зауважити, що в якості модуля сегментації можуть виступати різноманітні техніки для досягнення більшої точності та ефективності у виділенні об'єктів на зображеннях. Такі методи можуть включати алгоритми

що базуються на використанні машинного навчання, порогову сегментацію, кластеризацію або безліч інших. Ці методи можуть бути застосовані як окремо, так і в комбінації з іншими задля підвищення якості сегментації. Цей підхід буде використано для розробки нової гібридної моделі сегментації, яка інтегрує різноманітні рішення.

#### 4.2 Опис запропонованої моделі сегментації зображень

Модель EBSM (Enhanced Boundary Segmentation Model) представляє собою інноваційний підхід до сегментації зображень, який зосереджується на покращенні точності визначення границь об'єктів. Ця модель розроблена з метою оптимізації процесу сегментації, використовуючи комбінацію класичних методів та новітніх технологій обробки зображень без використання машинного навчання.

EBSM інтегрує в собі декілька модулів та підмодулів. Модель EBSM починається зі стандартизації вхідних зображень, переходячи до попередньої обробки, яка включає зміну масштабу, корекцію освітлення, фільтрацію шуму та підвищення контрасту. Основною інновацією є модуль гібридної сегментації, який використовує алгоритми K-Means та Normalized Cut для точного визначення та вдосконалення границь між сегментами. Така структура дозволяє EBSM забезпечувати високу якість сегментації, адаптуватися до різноманітних умов зйомки та видів зображень, ефективно вирішувати задачі, пов'язані з виділенням об'єктів на складних фонових умовах. Структура моделі подана у вигляді кортежу, який описує компоненти системи та їхні функції (вираз 4.2).

$$\text{EBSM} = \{V3, \text{MC}, \text{МПО}, \text{МГС}, \text{МА}\}, \quad (4.2)$$

де V3 – вхідне зображення. В якості V3 можуть бути зображення, що надходять на обробку з різноманітних джерел та вимагати стандартизації перед подальшим аналізом;

МС – модуль стандартизації, який відповідає за перетворення вхідних даних до формату, придатного для ефективної обробки. Перетворення включає корекцію розміру, кольорового профілю та інших параметрів;

МПО – модуль попередньої обробки, який містить підмодулі для зміни масштабу, корекції освітлення, фільтрації шуму та підвищення контрасту. Кожен із цих кроків підготовки забезпечує оптимальне зображення для сегментації;

МГС – модуль гібридної сегментації, який використовує комбінацію алгоритмів K-Means та Normalized Cut для визначення та уточнення границь між об'єктами;

МА – модуль аналітики, який здійснює оцінку результатів сегментації за допомогою обчислення метрик та аналізу цих метрик для оцінки точності та ефективності моделі.

Наведена структура надає змогу комплексно підходити до сегментації зображень, що забезпечує не тільки високу якість обробки, але й глибокий аналіз та адаптацію до специфічних умов та потреб обробки зображень.

Після стандартизації вхідних даних, наступний крок у моделі EBSM полягає в попередній обробці зображень, що здійснюється в модулі попередньої обробки (МПО) (вираз 4.3). Цей модуль критично важливий для підготовки зображень до фінальної фази сегментації, оскільки правильна підготовка даних може значно покращити якість результатів сегментації. Модуль МПО складається з декількох підмодулів, кожен з яких вирішує специфічні задачі попередньої обробки.

$$\text{МПО} = \{\text{ЗМ}, \text{КО}, \text{ФШ}, \text{ПК}\}, \quad (4.3)$$

де ЗМ – зміна масштабу, метод який адаптує розмір зображення для забезпечення консистентності та оптимального аналізу;

КО – корекція освітлення, метод який вирівнює рівень освітленості на зображенні, мінімізуючи вплив відмінностей освітлення на аналіз;

ФШ – фільтрація шуму, метод який видаляє випадкові шуми та

артефакти, що покращує чистоту зображення;

ПК – підвищення контрасту, метод який покращує візуальну різкість та виділення об'єктів на зображенні.

Кожен з цих підмодулів спрямований на оптимізацію окремих аспектів зображення, що готує платформу для більш точної та ефективної сегментації у подальших модулях моделі EBSM.

Переходячи від модуля попередньої обробки, наступний крок у моделі EBSM – це модуль гібридної сегментації (МГС), який є основою для точного визначення границь об'єктів на зображенні (вираз 4.4). Цей модуль міє два підмодулі які власне відповідають за фактичну сегментацію.

$$\text{МГС}=\{\text{KM}, \text{NC}\}, \quad (4.4)$$

де KM – алгоритм K-Means, який використовується для первинної кластеризації пікселів зображення на основі їхніх характеристик, таких як колір та інтенсивність, що дозволяє грубо відокремити різні об'єкти;

NC – підмодуль Normalized Cut, який використовується для уточнення та визначення більш точних границь між вже ідентифікованими кластерами.

Завдяки комбінації цих алгоритмів модуль гібридної сегментації забезпечує більшу точність у розмежуванні об'єктів та зменшення помилок сегментації, що є важливим для подальших етапів аналізу зображень.

Після завершення сегментації, наступний важливий крок у моделі EBSM – це модуль аналітики (МА), який відіграє ключову роль у вимірюванні та аналізі результатів сегментації. Модуль аналітики складається з двох основних підмодулів (вираз 4.5):

$$\text{МА}=\{\text{OM}, \text{AM}\}, \quad (4.5)$$

де OM – підмодуль обчислення метрик, який займається вимірюванням кількісних показників, таких як точність, повнота, F-міра та індекс Жаккара, що дозволяє оцінити якість сегментації.

AM – підмодуль аналізу метрик, який на основі отриманих метрик проводить детальний аналіз результатів. Він спрямований на виявлення можливих зон для покращення та налаштування моделі, забезпечуючи її оптимізацію для конкретних умов використання.

Завдяки інтеграції цих підмодулів модель EBSM може ефективно оцінювати та вдосконалювати процеси сегментації, що робить її не тільки точною, але й адаптивною до різноманітних аналітичних потреб.

У розробці моделі Enhanced Boundary Segmentation Model (EBSM), ключовим аспектом є детально спланована взаємодія між компонентами системи, що забезпечує не тільки технічну точність, але й адаптивність до різноманітних умов обробки зображень. Інтегровані модулі, такі як стандартизація вхідних даних, попередня обробка, гібридна сегментація та аналітика, виконують послідовні кроки від нормалізації та підготовки до фінальної оцінки результатів. Ця структурована послідовність оптимізує кожен процес обробки, підвищуючи загальну ефективність і точність моделі.

Кожен модуль відповідає за виконання конкретних задач, забезпечуючи, що зображення проходить через всі етапи обробки з максимальною увагою до деталей. Тому є необхідність показати взаємозв'язок всіх компонентів системи у вигляді логічно зв'язного алгоритму (рисунок 4.1).

Перехід до детального опису процесів у моделі EBSM дозволяє глибше зрозуміти її функціональність. Починаючи зі стандартизації вхідних даних до фінальної аналітики результатів, кожен крок моделі розрахований на оптимізацію якості сегментації.

Робота моделі EBSM розпочинається з отримання вхідного зображення, яке потребує ретельної попередньої обробки перед процесом сегментації. Перший крок алгоритму включає стандартизацію вхідних зображень, яка забезпечує їх відповідність до встановлених параметрів. Цей етап важливий для нормалізації розмірів та кольорового балансу, що допомагає уникнути проблем зі сегментацією на наступних етапах.

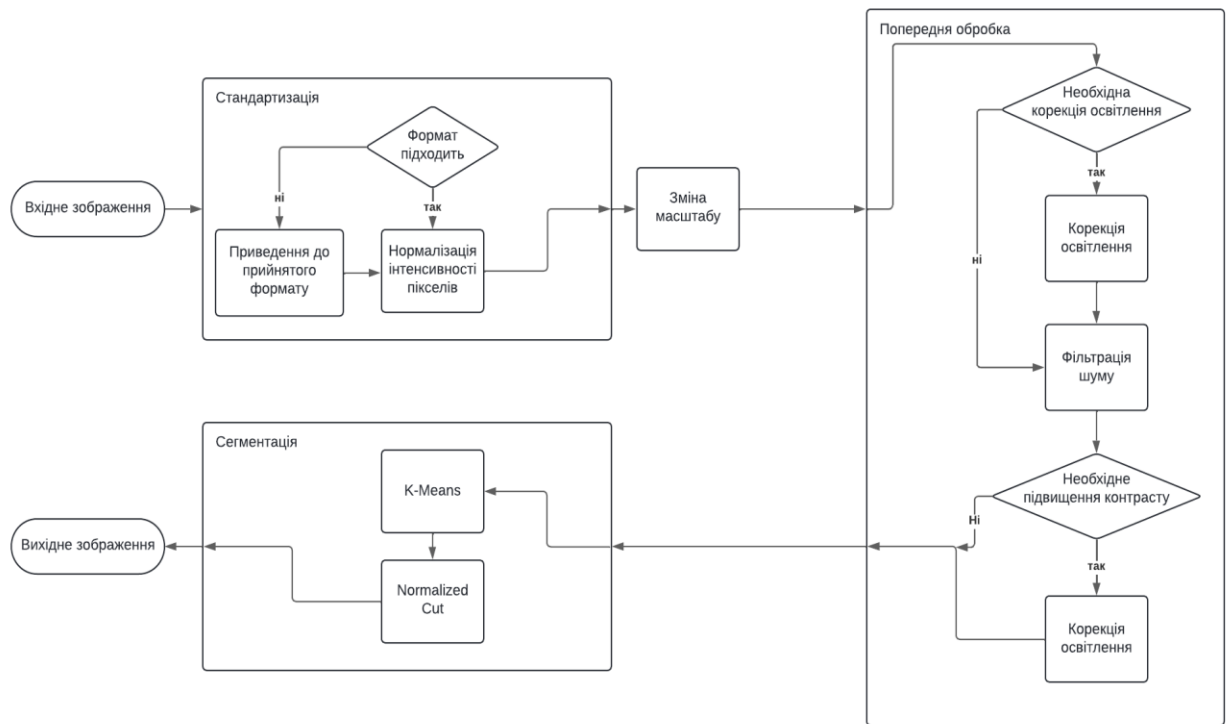


Рисунок 4.1 – Алгоритм роботи моделі EBSM

На другому кроці, в рамках модулю попередньої обробки, зображення проходять через декілька підмодулів: зміна масштабу, корекція освітлення, фільтрація шуму та підвищення контрасту. Зміна масштабу забезпечує однорідність зображень, корекція освітлення вирівнює рівні яскравості та контрастності, фільтрація шуму очищує зображення від випадкових артефактів, а підвищення контрасту покращує видимість деталей та контурів об'єктів.

Після завершення попередньої обробки, зображення переходять до модулю гібридної сегментації, де використовуються два ключові підходи: K-Means та Normalized Cut. Підмодуль K-Means виконує первинну кластеризацію, визначаючи основні групи пікселів за схожими характеристиками, що підготовлює основу для більш точної сегментації. Далі підмодуль Normalized Cut деталізує границі між кластерами, використовуючи графові техніки для оптимізації відділення об'єктів. Цей підхід дозволяє досягнути високої точності в визначенні контурів та зон інтересу на зображенні.

Фінальний етап обробки здійснюється у модулі аналітики, де відбувається оцінка якості сегментації через обчислення різних метрик, таких як точність, повнота, F-міра, та індекс Жаккара. Ці метрики допомагають виміряти ефективність сегментації та виявити потенційні області для покращення, забезпечуючи цінну зворотну інформацію для подальшого покращення алгоритму.

#### 4.2.1 Модуль стандартизації вхідних зображень

Модуль стандартизації вхідних зображень у моделі EBSM забезпечує уніфікацію різних форматів зображень перед їх подальшою обробкою. Основна мета модуля полягає у нормалізації форматів зображень та їх кольорових характеристик, з метою досягнення консистентності та забезпечення ефективної обробки на наступних етапах. Нормалізація допомагає адаптувати зображення, вирівнюючи яскравість та контрастність, а також перетворює зображення до стандартних розмірів, що важливо для забезпечення точності обробки.

Цей етап також включає корекцію колірного балансу, щоб усунути колірні спотворення, які можуть впливати на алгоритми сегментації. Коригування колірного балансу забезпечує, що кольори у зображенні є правдивими до реальності, що критично для застосувань, де колір відіграє ключову роль.

Після корекції колірного балансу, модуль стандартизації також здійснює перетворення зображення до стандартного формату, придатного для машинного аналізу. Це включає конвертацію зображень з різних вихідних форматів до єдиного формату, який використовується в усіх наступних модулях EBSM. Важливим є вирівнювання глибини кольору зображень, щоб уніфікувати спосіб представлення кольорових даних перед їх обробкою. Це забезпечує узгодженість даних та оптимізує їх подальшу обробку, зокрема в модулях попередньої обробки та сегментації, підвищуючи загальну точність та надійність аналізу зображень.

## 4.2.2 Модуль попередньої обробки

Модуль попередньої обробки в моделі EBSM відіграє ключову роль у підготовці зображень до сегментації, забезпечуючи уніфікацію якості та параметрів зображення перед їх детальною обробкою. Цей модуль включає кілька важливих процесів, які допомагають виправити поширені проблеми, такі як нерівномірне освітлення, шум та контрастність, які можуть суттєво вплинути на результати аналізу зображення.

Попередня обробка включає зміну масштабу зображень, що дозволяє адаптувати їх до стандартних розмірів для консистентності обробки. Корекція освітлення, фільтрація шуму та підвищення контрасту кожний з цих параметрів забезпечують покращення візуальних характеристик зображення, що є вирішальним для наступної точної сегментації. Завдяки цим крокам, зображення надходять у модуль сегментації в оптимальному стані, готові до високоефективного виявлення та класифікації об'єктів.

### 4.2.2.1 Підмодуль зміни масштабу

Підмодуль зміни масштабу у моделі EBSM відіграє важливу роль у забезпеченні консистентності вхідних зображень для подальшої обробки. Цей підмодуль задіяний у нормалізації розмірів зображень, що дозволяє стандартизувати процес обробки та сегментації. Розмір зображення впливає на вимоги до обчислювальних ресурсів та може визначати точність аналітичних модулів, тому критично важливо вирівняти ці параметри до початку обробки.

Зміна масштабу включає використання білінійної інтерполяції, що дозволяє зберегти якість зображення при зміні його розміру. Цей метод обраний на основі його здатності зберегти важливі деталі та уникнути спотворень, що є критичним для точності розпізнавання об'єктів на зображенні.

Підмодуль також забезпечує адаптацію зображень до вимог

аналітичних алгоритмів, що часто розроблені для роботи з певними розмірами. Адаптація масштабу сприяє поліпшенню обчислювальної ефективності, оскільки зменшення масштабу зображення може знизити час обробки, в той час як збільшення масштабу може допомогти у виявленні тонких деталей, які в іншому випадку могли б бути втрачені. Коректне налаштування масштабу важливе для оптимізації якості кінцевих результатів сегментації та аналітики, забезпечуючи відповідність між вхідними даними та алгоритмічними вимогами.

#### 4.2.2.2 Підмодуль корекції освітлення

Підмодуль корекції освітлення є важливим компонентом моделі EBSM, що забезпечує рівномірний розподіл світла на зображеннях для покращення якості сегментації. Неоднорідне освітлення може створити тіні та пересвічені області, що ускладнює точне виявлення об'єктів. Використання методів корекції освітлення, таких як гістограмне вирівнювання, допомагає мінімізувати ці проблеми та покращити загальну якість зображення.

Гістограмне вирівнювання є ефективним методом для покращення контрасту зображення. Воно працює шляхом перерозподілу інтенсивностей пікселів, щоб більш рівномірно розподілити яскравість по всьому діапазону, що дозволяє вирівняти освітлення на зображенні, роблячи тіні менш вираженими та усуваючи пересвітлені області.

Застосування гістограмного вирівнювання у підмодулі корекції освітлення моделі EBSM допомагає досягти більш однорідного вигляду зображень, що є особливо важливим для подальших етапів обробки. Це зменшує вплив варіацій освітлення на точність сегментації, дозволяючи алгоритмам краще розпізнавати та класифікувати об'єкти. Завдяки цьому, модель може забезпечити більш точні результати навіть за умов, коли вхідні зображення мають значні варіації в освітленні. Гістограмне вирівнювання підвищує загальну якість зображень, створюючи більш сприятливі умови для точної і надійної сегментації.

#### 4.2.2.3 Підмодуль фільтрації шуму

Підмодуль фільтрації шуму є важливим компонентом попередньої обробки в моделі EBSM, оскільки випадкові артефакти та шум можуть значно впливати на якість сегментації. Шум може походити від різних джерел, таких як цифрові сенсори, умови зйомки або передачі зображень. Видалення цього шуму є критично важливим для підвищення якості зображення та забезпечення більш точного розпізнавання об'єктів.

Основним методом, що використовується для фільтрації шуму в EBSM, є Гауссівське розмиття. Цей метод застосовує Гауссів фільтр, який згладжує зображення, усуваючи дрібні випадкові артефакти, зберігаючи при цьому основні контури та деталі. Гауссівське розмиття є ефективним засобом для зниження рівня шуму завдяки його здатності зменшувати вплив високочастотних компонентів, які найчастіше відповідають за шум.

Гауссівське розмиття працює шляхом застосування Гауссового ядра, яке зважує значення пікселів у відповідності до нормального розподілу, згладжуючи інтенсивності та зменшуючи варіації, що спричинені шумом. Це дозволяє зберігати основні структури зображення, такі як контури та границі об'єктів, при цьому ефективно видаляючи випадкові шумові артефакти.

Інші методи, такі як медіанна фільтрація або двостороннє фільтрування, також можуть використовуватись у випадках, коли необхідно зберегти високу деталізацію. Однак Гауссівське розмиття залишається популярним завдяки своїй простоті та ефективності у багатьох сценаріях.

Завдяки фільтрації шуму, зображення стають більш чіткими та чистими, що дозволяє подальшим алгоритмам сегментації працювати з більшим рівнем точності та надійності. Це особливо важливо у випадках, коли зображення містять дрібні деталі або коли точність сегментації є критично важливою для успішного завершення задачі. Фільтрація шуму допомагає зменшити помилки у сегментації та підвищити загальну якість аналізу зображень.

#### 4.2.2.4 Підмодуль підвищення контрасту

Підмодуль підвищення контрасту у моделі EBSM грає вирішальну роль у забезпеченні чіткості та виразності об'єктів на зображеннях. Основним методом, який використовується для цієї задачі є Local Contrast Enhancement (LCE), який метод дозволяє підвищити видимість деталей, що можуть бути приховані через недостатню контрастність, особливо у випадках зображень, де об'єкти мають схожі відтінки або знаходяться в умовах слабкого освітлення.

Local Contrast Enhancement (LCE) працює шляхом локальної корекції контрасту, акцентуючи увагу на дрібних деталях та забезпечуючи вищу роздільну здатність. Це досягається шляхом аналізу локальних областей зображення та регулювання контрасту в межах кожної з них. Таким чином, навіть найменші зміни в інтенсивності стають більш помітними, що значно покращує здатність до виявлення та класифікації об'єктів.

Використання LCE у підмодулі підвищення контрасту дозволяє не тільки виділити об'єкти, але й покращити їх розпізнавання на наступних етапах обробки. Цей метод особливо ефективний у складних сценах з високою щільністю інформації, де точне визначення об'єктів є критичним. Завдяки підвищенню контрасту, зображення стають більш інформативними, що сприяє більш точному та надійному сегментуванню.

#### 4.2.3 Модуль гібридної сегментації

Модуль гібридної сегментації (МГС) є основою моделі EBSM оскільки він здійснює ключову функцію розділення зображення на окремі об'єкти. МГС поєднує два потужні алгоритми: K-Means та Normalized Cut, що забезпечує високу точність та ефективність процесу сегментації.

Алгоритм K-Means виконує первинну кластеризацію пікселів, групує їх за схожими характеристиками, такими як колір та інтенсивність. Це дозволяє попередньо виділити основні структури та зони на зображенні.

K-Means ефективно обробляє великі обсяги даних і створює початкові кластери, які служать базою для подальшого удосконалення.

Після первинної кластеризації алгоритм Normalized Cut застосовується для більш точного визначення границь між кластерами. Цей алгоритм використовує графову теорію для аналізу зв'язків між пікселями та оптимізації розрізів, що дозволяє виділити чіткі границі між об'єктами. Normalized Cut враховує як локальні, так і глобальні характеристики зображення, забезпечуючи більш детальне та точне розділення.

Поєднання алгоритмів K-Means та Normalized Cut дозволяє модулю гібридної сегментації досягати високої точності в виділенні об'єктів навіть на складних зображеннях з великою кількістю деталей та варіацій. Завдяки цьому, модель EBSM здатна ефективно справлятися з різноманітними задачами сегментації, забезпечуючи високу якість кінцевих результатів.

#### 4.2.3.1 Підмодуль кластеризації K-Means

Підмодуль кластеризації K-Means у моделі EBSM є важливим етапом у процесі сегментації зображень. Алгоритм K-Means застосовується для початкового розділення пікселів на кластери на основі їх схожих характеристик. Цей алгоритм є популярним завдяки своїй простоті та ефективності у виконанні задач кластеризації, особливо коли обсяги даних великі.

Алгоритм K-Means працює шляхом ітеративного процесу, де зображення ділиться на  $k$  кластерів. Спочатку обираються  $k$  випадкових центрів кластерів, після чого кожен піксель зображення призначається до найближчого центру на основі обраної метрики відстані, наприклад, Евклідової відстані. Після цього центри кластерів оновлюються, розраховуючи середні значення координат пікселів, що належать кожному кластеру. Процес повторюється, доки центри кластерів не стабілізуються або не досягнеться задана кількість ітерацій.

Основною перевагою алгоритму K-Means є його здатність швидко та

ефективно обробляти великі обсяги даних, забезпечуючи при цьому достатньо високу точність для багатьох застосувань. Однак, важливо зазначити, що K-Means чутливий до вибору початкових центрів кластерів, що може впливати на кінцеві результати кластеризації.

Застосування K-Means у моделі EBSM дозволяє ефективно виділити основні структури та зони інтересу на зображенні, забезпечуючи базу для подальшого удосконалення границь між кластерами за допомогою алгоритму Normalized Cut. Цей підхід дозволяє моделі виділяти ключові області, які потребують більш детальної обробки. Завдяки первинній кластеризації, можна швидко та ефективно зменшити обсяг даних для обробки, сфокусувавшись на важливих деталях. Це поєднання дозволяє моделі досягати високої точності та ефективності сегментації, навіть у випадках складних та детальних зображень.

#### 4.2.3.2 Підмодуль кластеризації Normalized Cut

Підмодуль кластеризації Normalized Cut у моделі EBSM виконує важливу роль у точному визначенні границь між кластерами, які були попередньо виділені за допомогою алгоритму K-Means. Алгоритм Normalized Cut базується на графовій теорії та використовує концепцію розрізу графа для оптимального розділення зображення на сегменти.

Основна ідея полягає в тому, щоб розглядати зображення як граф, де кожен піксель є вузлом, а ребра між вузлами представляють зв'язки, що відображають схожість між пікселями. Normalized Cut мінімізує вартість розрізу, враховуючи як міцність зв'язків всередині кластерів, так і слабкість зв'язків між різними кластерами. Це дозволяє досягти балансованого розподілу, де сегменти мають високу внутрішню однорідність і чітко відокремлені один від одного.

Використання Normalized Cut забезпечує детальне та точне визначення границь між кластерами, що дозволяє виділити об'єкти навіть у складних сценах з великою кількістю деталей. Процес включає побудову матриці

подібності, яка відображає схожість між усіма парами пікселів, а потім застосування алгоритму розрізу для знаходження оптимального розділення. З цієї причини метод є особливо ефективним для зображень з неоднорідною структурою, де важливо враховувати глобальну інформацію про зображення.

#### 4.2.4 Модуль аналітики

Модуль аналітики (МА) в моделі EBSM є важливим компонентом, який забезпечує оцінку якості та ефективності процесу сегментації. Основна мета цього модуля полягає у вимірюванні та аналізі результатів роботи моделі за допомогою різноманітних метрик та показників.

МА складається з підмодулів обчислення метрик та аналізу метрик. Підмодуль обчислення метрик відповідає за визначення кількісних показників, таких як точність, повнота, F-міра та індекс Жаккара. Ці метрики дозволяють оцінити, наскільки точно та ефективно модель виконує сегментацію, забезпечуючи об'єктивну основу для порівняння та вдосконалення.

Підмодуль аналізу метрик проводить детальний аналіз зібраних даних, що дозволяє виявити сильні та слабкі сторони моделі. Це включає інтерпретацію результатів, ідентифікацію можливих проблем та пропозиції щодо їх вирішення. Завдяки цьому, модуль аналітики сприяє постійному вдосконаленню моделі EBSM, забезпечуючи високий рівень точності та надійності сегментації.

##### 4.2.4.1 Підмодуль обчислення метрик

Підмодуль обчислення метрик у модулі аналітики моделі EBSM відповідальний за вимірювання ефективності та точності сегментації. Основними метриками, які використовуються, є:

– точність (Precision), яка вимірює, наскільки точно модель ідентифікує позитивні випадки серед всіх пікселів, віднесених до певного класу;

- повнота (Recall), яка оцінює, наскільки ефективно модель знаходить всі позитивні випадки в датасеті;
- F-міра (F-score), яка є гармонічним середнім між точністю та повнотою та використовується для оцінки балансу між ними;
- індекс Жаккара (Jaccard Index), який визначає ступінь схожості між двома множинами шляхом обчислення відношення їхнього перетину до їхнього об'єднання.

Ці метрики забезпечують кількісну оцінку роботи моделі, дозволяючи ідентифікувати сильні та слабкі сторони процесу сегментації. Використання всіх метрик одночасно не є обов'язковим, але бажаним для досягнення найбільш точної оцінки.

#### 4.2.4.2 Підмодуль аналізу обчислених метрик

Підмодуль аналізу обчислених метрик у модулі аналітики моделі EBSM забезпечує детальну інтерпретацію та аналіз результатів, отриманих від підмодуля обчислення метрик. Основна мета цього підмодуля полягає в ідентифікації сильних та слабких сторін моделі сегментації, а також виявлення можливостей для її подальшого вдосконалення.

Аналіз обчислених метрик включає порівняння показників точності, повноти, F-міри та індексу Жаккара для різних наборів даних. Це дозволяє визначити, як добре модель працює в різних умовах та з різними типами зображень. Підмодуль також допомагає виявити патерни або тенденції, які можуть свідчити про систематичні помилки або недоліки моделі.

Крім того, підмодуль аналізу метрик може включати візуалізацію результатів у вигляді графіків або діаграм, що полегшує розуміння даних та сприяє більш ефективному прийняттю рішень щодо подальшої оптимізації моделі. Використання цього підмодуля допомагає забезпечити постійний зворотний зв'язок та підвищити точність та надійність моделі EBSM у довгостроковій перспективі.

### 4.3 Тестування моделі EBSM

Тестування є важливим етапом розробки та впровадження будь-якої моделі, включаючи модель EBSM. Воно забезпечує перевірку ефективності та надійності моделі, підтверджуючи її здатність вирішувати поставлені задачі. Тестування дозволяє виявити потенційні слабкі місця та недоліки моделі, що можуть вплинути на результати обробки зображень, і надає можливість їх усунення перед практичним використанням.

У контексті моделі EBSM цей процес має на меті оцінити, наскільки ефективно модуль стандартизації, модуль попередньої обробки, модуль гібридної сегментації та модуль аналітики взаємодіють між собою. Це включає перевірку здатності моделі коректно обробляти вхідні зображення, усувати шуми, коригувати освітлення, підвищувати контрастність та точно сегментувати об'єкти.

Тестування є критично важливим для забезпечення високої точності та надійності моделі. Воно дозволяє підтвердити, що модель EBSM може ефективно працювати з різними типами зображень та умовами зйомки, забезпечуючи стабільні результати. Крім того, тестування допомагає виявити та врахувати специфічні особливості обробки зображень, які можуть виникнути у практичному використанні моделі.

Проведення перевірки роботи моделі EBSM дозволить нам зібрати дані про її продуктивність та якість обробки зображень. Це включає аналіз результатів сегментації, точність виявлення об'єктів, ефективність попередньої обробки та інші ключові показники. Отримані дані можуть бути використані для подальшого вдосконалення моделі та оптимізації її параметрів.

В рамках тестування моделі EBSM слід оберати відповідне зображення, яке має певні недоліки, що потребують усунення під час попередньої обробки. Це зображення пройде через усі етапи моделі: зміну масштабу, попередню обробку, сегментацію та аналітику. На етапі зміни масштабу,

зображення буде адаптовано до необхідних розмірів для подальшої обробки. Попередня обробка включатиме корекцію освітлення, фільтрацію шуму та підвищення контрасту, що забезпечить оптимальні умови для сегментації.

Сегментація здійснюватиметься у два етапи: первинна кластеризація за допомогою K-Means та точне визначення границь за допомогою Normalized Cut. Це дозволить виділити об'єкти та визначити їхні межі з високою точністю. Після цього результати будуть ретельно проаналізовані на якість.

Тестування надасть детальну картину того, як модель EBSM працює з різними типами зображень та умовами зйомки, що дозволить виявити можливі слабкі місця та недоліки, що потребують корекції, а також підтвердити ефективність та надійність моделі в реальних умовах. Завдяки цьому можливо забезпечити високу якість та стабільність результатів сегментації, що є критичним для практичного використання моделі EBSM у різних додатках.

#### 4.3.1 Вибір вхідного зображення для тестування

Для тестування моделі EBSM важливо обрати вхідне зображення, яке дозволить оцінити ефективність усіх етапів обробки, від попередньої обробки до сегментації та аналізу. На цьому етапі було обрано зображення (рисунок 4.2), яке містить ряд характерних недоліків, які модель повинна вирішити, щоб продемонструвати свою ефективність.

Обране зображення містить шум, що ускладнює розпізнавання деталей та об'єктів на зображенні. Наявність шуму є поширеною проблемою у зображеннях, особливо тих, що були зроблені в умовах низької освітленості або з використанням недосконалого обладнання. Модель EBSM повинна бути здатною зменшити або усунути цей шум, використовуючи методи фільтрації шуму, такі як Гауссівське розмиття.

Крім того, зображення має проблеми з переосвітленням, де певні ділянки є занадто яскравими, що приховує деталі та створює труднощі для алгоритмів сегментації. Корекція освітлення за допомогою гістограмного

вирівнювання допоможе вирівняти яскравість по всьому зображенню, покращуючи видимість деталей та створюючи однорідне освітлення.



Рисунок 4.2 – Вхідне зображення для сегментації

Також на зображенні присутні нечіткі області, що ускладнює визначення чітких контурів об'єктів. Нечіткість може бути наслідком руху камери або об'єкта під час зйомки, що потребує використання методів підвищення контрасту для покращення видимості деталей та контурів. Використання методу Local Contrast Enhancement (LCE) дозволить підвищити контрастність зображення та покращити розпізнавання об'єктів.

Обране зображення містить, як явні об'єкти, що добре виділяються, так і об'єкти, які ледь помітні. Це надає можливість перевірити здатність моделі EBСM ефективно сегментувати як легко розпізнавані, так і складні для виявлення об'єкти. Етапи сегментації з використанням алгоритмів K-Means та Normalized Cut повинні забезпечити точне виділення цих об'єктів.

Загалом, обране зображення є підходящим для тестування моделі EBСM, оскільки воно містить широкий спектр проблем, які потрібно вирішити для досягнення високоякісної сегментації. Далі буде здійснено перехід до етапів попередньої обробки та аналізу результатів, що дозволить оцінити ефективність моделі у вирішенні виявлених проблем.

### 4.3.2 Попередня обробка зображення

Попередня обробка зображення є ключовим етапом у моделі EBSM, що забезпечує підготовку вхідних даних до подальшої сегментації. Цей процес включає кілька підмодулів, кожен з яких виконує специфічну функцію для покращення якості зображення. Далі розглянемо роботу кожного з підмодулів попередньої обробки окремо.

#### 4.3.2.1 Корекція освітлення

Корекція освітлення є важливим етапом у процесі попередньої обробки зображення, що дозволяє забезпечити рівномірний розподіл яскравості по всьому зображенню. Обране для тестування зображення містить області з переосвітленням та затемненням, що ускладнює точне розпізнавання об'єктів та деталей. Такі недоліки можуть суттєво вплинути на якість сегментації, оскільки неоднорідне освітлення може приховувати важливі деталі або створювати фальшиві артефакти.

Для корекції освітлення було застосовано метод гістограмного вирівнювання, який дозволяє перерозподілити інтенсивності пікселів, забезпечуючи більш рівномірний розподіл яскравості. Цей метод працює шляхом розтягування гістограми інтенсивностей пікселів, що дозволяє виділити більше деталей в темних та світлих областях зображення. Завдяки цьому процесу, переосвітлені та затемнені області зображення стають більш збалансованими (рисунок 4.3).

На обробленому зображенні видно, що корекція освітлення значно покращила видимість деталей, особливо в областях, які раніше були переосвітленими або затемненими. Це дозволяє краще розпізнавати об'єкти та їх межі, що є важливим для подальших етапів обробки, таких як фільтрація шуму та сегментація.

Результат корекції освітлення показує, що зображення стало більш однорідним у термінах яскравості, що сприяє більш точній сегментації. Це

створює оптимальні умови для подальших етапів обробки зображення, підвищуючи загальну ефективність та точність моделі EBSM.



Рисунок 4.3 – Зображення після корекції освітлення

#### 4.3.2.2 Фільтрація шуму

Фільтрація шуму є важливим етапом попередньої обробки зображення, що дозволяє видалити випадкові артефакти, які можуть погіршити якість подальшої сегментації. На обраному для тестування зображенні присутній значний шум, який утруднює розпізнавання об'єктів та деталей. Шум може походити від різних джерел, таких як сенсори камери, умови зйомки або пост-обробка, і може серйозно вплинути на точність сегментації. Важливо розуміти, що шум знижує контрастність та чіткість зображення, що призводить до втрати важливих деталей та ускладнює подальшу обробку.

Для фільтрації шуму було застосовано Гауссівське розмиття. Цей метод використовує Гауссів фільтр для згладжування інтенсивності пікселів, що допомагає усунути високочастотні компоненти, які відповідають за шум. Гауссівське розмиття ефективно знижує рівень шуму, зберігаючи при цьому основні деталі зображення, такі як контури та структури об'єктів.

Результат фільтрації шуму показує, що зображення стало значно чистішим та чіткішим (рисунок 4.4). Видалення шуму дозволяє покращити якість зображення, роблячи його більш придатним для подальшої сегментації. Це підвищує здатність алгоритмів розпізнавати та виділяти об'єкти на зображенні, забезпечуючи більш точні результати.




Рисунок 4.4 – Вхідне зображення: а) до фільтрації шуму;  
б) після фільтрації шуму

Фільтрація шуму також допомагає уникнути фальшивих спрацьовувань та артефактів, які можуть виникати під час сегментації через наявність шуму. Завдяки цьому, подальші етапи обробки можуть виконуватися з більш високою точністю, що є критично важливим для досягнення якісних результатів у моделі EBSM.

#### 4.3.2.3 Підвищення контрасту

Підвищення контрасту є останнім але не менш важливим етапом попередньої обробки зображення, який сприяє покращенню видимості деталей та забезпечує чіткість об'єктів на зображенні. На обраному для тестування зображенні спостерігається низький рівень контрасту, що

ускладнює розпізнавання об'єктів та деталей. Низький контраст може бути результатом умов зйомки, освітлення або пост-обробки і може серйозно вплинути на точність сегментації.

Для підвищення контрасту було застосовано метод LSE, який спрямований на збільшення контрастності окремих ділянок зображення, що дозволяє краще розпізнавати деталі та структури. LSE працює шляхом локальної корекції контрастності, збільшуючи різницю в інтенсивності між сусідніми пікселями, що дозволяє виділити дрібні деталі та підвищити загальну чіткість зображення.

Результат підвищення контрасту показує, що зображення стало значно чіткішим та виразнішим (рисунок 4.5). Виділення контрастних деталей покращує видимість об'єктів, роблячи їх легше розпізнаваними на зображенні. Це сприяє точнішій сегментації, оскільки алгоритми можуть краще розпізнавати межі та контури об'єктів.




Рисунок 4.5 – Вхідне зображення після підвищення контрасту

Підвищення контрасту також допомагає зменшити вплив залишкового шуму та інших артефактів, що може покращити якість результатів сегментації. Завдяки цьому, подальші етапи обробки можуть виконуватися з

більш високою точністю, що є критично важливим для досягнення якісних результатів у моделі EBSM. Таким чином, підвищення контрасту є ключовим етапом у процесі обробки зображення, що робить його придатним для подальшої обробки та аналізу.

### 4.3.3 Гібридна сегментація зображення

Гібридна сегментація зображення є ключовим етапом моделі EBSM, що включає використання двох алгоритмів сегментації: K-Means та Normalized Cut. Цей підхід дозволяє поєднати переваги обох методів, забезпечуючи високу точність та ефективність сегментації.

#### 4.3.3.1 Сегментація зображення за допомогою K-Means

Сегментація зображення за допомогою алгоритму K-Means є першим етапом гібридної сегментації в моделі EBSM. K-Means дозволяє розділити зображення на кілька кластерів на основі інтенсивності та кольору пікселів, що сприяє початковій класифікації областей на зображенні. Цей алгоритм відомий своєю ефективністю та простотою, що робить його популярним вибором для задач кластеризації.

Під час тестування K-Means на обраному зображенні, алгоритм групує пікселі у кластери, що відображають основні структури зображення. Зокрема видно, що алгоритм виділив різні області з подібними кольорами та інтенсивностями, такі як небо, земля та квіти. Це дає початкове розуміння розподілу об'єктів на зображенні та підготовлює його для більш детальної сегментації.

На зображенні з результатами K-Means видно, що основні компоненти були успішно виділені (рисунок 4.6). Окремі елементи зображення склали окремі кластери, що показує ефективність алгоритму у виявленні основних структур. Хоча цей метод не завжди забезпечує точне розмежування об'єктів, він створює міцну основу для подальшого уточнення меж.



Рисунок 4.6 – Результат кластеризації K-Means

Результати сегментації за допомогою K-Means демонструють якість початкової класифікації, яка значно полегшує роботу наступного етапу, а саме використання алгоритму Normalized Cut.

#### 4.3.3.2 Сегментація зображення за допомогою Normalized Cut

Після початкової класифікації пікселів за допомогою алгоритму K-Means, наступним кроком у процесі гібридної сегментації є використання алгоритму Normalized Cut. Цей метод дозволяє точно визначити границі між кластерами, забезпечуючи детальну та точну сегментацію об'єктів на зображенні. Normalized Cut використовує підхід на основі графів для оптимального розділення зображення на сегменти, враховуючи як внутрішню однорідність кластерів, так і слабкість зв'язків між ними.

Алгоритм Normalized Cut розглядає зображення як граф, де кожен піксель є вузлом, а ребра між вузлами відображають схожість між пікселями. Основна ідея полягає у мінімізації вартості розрізу графа, що дозволяє знайти оптимальні межі між кластерами. Це досягається шляхом побудови матриці подібності, яка відображає схожість між усіма парами пікселів, а потім

застосування алгоритму для знаходження оптимального розділення.

На рисунку 4.7 з результатами сегментації за допомогою Normalized Cut видно, що межі між кластерами стали більш чіткими та точними. Алгоритм успішно виділив окремі об'єкти, такі як квіти, землю та небо.



Рисунок 4.7 – Кінцевий результат сегментації зображення

Використання алгоритму Normalized Cut у поєднанні з K-Means забезпечує комплексний підхід до сегментації, що дозволяє досягти високої точності та ефективності. Завдяки цьому, модель EBSM здатна забезпечити надійну та детальну сегментацію зображень.

#### 4.4 Порівняльний аналіз роботи моделі


Порівняльний аналіз роботи моделі EBSM є важливим етапом, що дозволяє оцінити ефективність та точність запропонованого підходу до сегментації зображень. В цьому розділі будуть розглянуті результати роботи моделі, проведений аналіз роботи сегментації на основі використання алгоритмів K-Means та Normalized Cut. Це дозволить зробити висновки щодо покращення якості зображень та ефективності запропонованої моделі в цілому.

Також варто розглянути попередні кроки, які необхідно було виконати перед сегментацією та проаналізувати отримане зображення після попередньої обробки. Для цього початкове зображення буде порівняне з обробленим зображенням, щоб визначити, наскільки вдалося покращити його якість та підготувати до сегментації.

Початкове зображення мало значні проблеми з шумом, переосвітленням та нечіткістю, що ускладнювало розпізнавання об'єктів. Після попередньої обробки, включаючи корекцію освітлення, фільтрацію шуму та підвищення контрасту, вдалося значно покращити якість зображення (рисунок 4.8). Корекція освітлення дозволила усунути переосвітлені та затемнені області, що забезпечило більш рівномірний розподіл яскравості. Фільтрація шуму знизила рівень випадкових артефактів, зробивши зображення більш чистим та чітким. Підвищення контрасту в свою чергу покращило видимість деталей.



а)



б)

Рисунок 4.8 – Вхідне зображення: а) до попередньої обробки;  
б) після попередньої обробки


Після завершення етапів попередньої обробки, наступним кроком є аналіз роботи сегментації зображення. Першим етапом у процесі гібридної

сегментації є використання алгоритму K-Means, який виконує початкове групування пікселів у кластери.

На рисунку 4.9 видно, що алгоритм виділив основні структури зображення, такі як небо, землю, гори та квіти, формуючи окремі кластери для кожної зони.



а)



б)

Рисунок 4.9 – Вхідне зображення: а) до етапу сегментації;  
б) після етапу сегментації

Алгоритм K-Means показав свою ефективність у початковому розділенні зображення на основні компоненти. Основні області з подібними кольорами та інтенсивностями були виділені, що полегшує подальше уточнення меж об'єктів. Однак, межі між кластерами можуть бути не зовсім чіткими, що вимагає додаткового етапу обробки.

Для оцінки важливості попередньої обробки було проведено порівняння результатів сегментації K-Means із зображенням, яке не пройшло попередньої обробки. На непідготовленому вхідному зображенні видимі значні недоліки, такі як шум, переосвітлення та неоднорідне освітлення. Шум створює випадкові артефакти, які можуть викликати неправильне розпізнавання меж об'єктів. Переосвітлені та затемнені області затруднюють

точне визначення контурів, а неоднорідне освітлення спричиняє нерівномірний розподіл інтенсивностей, що ускладнює кластеризацію пікселів.

Результати сегментації K-Means без попередньої обробки показують, що класифікація пікселів на основі інтенсивності та кольору є менш точною, межі між кластерами стають менш нечіткими. Виявлення структур на зображенні стає складнішим, і загальна якість сегментації значно погіршується (рисунок 4.10).



а)



б)

Рисунок 4.10 – Результат кластеризації: а) обробленого зображення;  
б) необробленого зображення

Також важлива відмінність, що алгоритм навіть не зміг розпізнати різницю між небом та горою у необробленого зображення і як результат вони разом створили один сегмент, чого у свою чергу не сталось з фотографією яка пройшла обробку. Це підтверджує, що попередня обробка є критично важливою для підвищення якості зображення та полегшення процесу сегментації, роблячи його більш точним та ефективним.

## ВИСНОВКИ

Під час виконання кваліфікаційної роботи було приділено значну увагу аспектам сегментації зображень за допомогою комбінованих методів, включно з кластеризацією K-Means та Normalized Cut. Актуальність цього дослідження обумовлена важливістю сегментації зображень для сучасних наукових, медичних та промислових застосувань. Сегментація відіграє вирішальну роль у таких напрямках, як медична діагностика, дистанційне зондування, автоматичне розпізнавання об'єктів та багато інших.

Модель EBSM об'єднує в собі низку технічних рішень для попередньої обробки та сегментації зображень. Вона включає модулі стандартизації, попередньої обробки, гібридної сегментації та аналітики. Така комбінація дозволяє досягти високої точності та ефективності обробки зображень, що було підтверджено під час тестування на обраному зображенні.

Модуль попередньої обробки, який включає корекцію освітлення, фільтрацію шуму та підвищення контрасту, продемонстрував свою ефективність у покращенні якості зображень. Застосування цих методів дозволило значно знизити рівень шуму, вирівняти освітлення та підвищити контрастність, що створило основу для точнішої сегментації.

Модель EBSM продемонструвала значні переваги у порівнянні з традиційними методами сегментації, особливо коли зображення проходять попередню обробку. Використання комбінованого підходу, що включає K-Means та Normalized Cut, дозволило досягти більш чітких та точних меж між сегментами, що є критично важливим для аналізу та інтерпретації зображень у різних галузях.

Проведений аналіз показав, що модель EBSM забезпечує високу якість сегментації навіть для складних та детальних зображень. Результати тестування підтвердили, що попередня обробка значно покращує якість вхідних даних, що позитивно впливає на точність сегментації. Це свідчить про важливість комплексного підходу до обробки зображень, який включає

кілька етапів для досягнення найкращих результатів.

Розроблена модель виконує поставлені задачі та забезпечує високу якість сегментації зображень. Використання сучасних методів обробки та оптимізації дозволяє отримати зображення з високою точністю, що відповідають вимогам спеціалістів у різних сферах.

Запропонована модель має важливе значення у сучасному світі, де обробка візуальних даних стає все більш необхідною у різних галузях. Вона забезпечує інструменти для точного та ефективного аналізу зображень, що є критичним для наукових досліджень, медичної діагностики та безлічі інших важливих застосувань. Використання цієї моделі сприяє покращенню якості візуального аналізу та відповідно прийняттю більш обґрунтованих рішень.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Зайцев Д.Я., Філімончук Т.В., Гук А.С., Майстренко Г.В. Огляд засобів ефективної сегментації зображень з використанням методів кластеризації даних // Системи управління, навігації та зв'язку. Збірник наукових праць. Полтава: ПНТУ, 2024. Випуск 1 (75). С. 77-81. doi:<https://doi.org/10.26906/SUNZ.2024.1.077>.
2. Ониськів П.А., Литвиненко Я.В. Аналіз методів сегментації зображень. Матеріали IV Міжнародної науково-технічної конференції „Теоретичні та прикладні аспекти радіотехніки, приладобудування і комп'ютерних технологій“ присвячена 80-ти річчю з дня народження професора Я.І. Проця, 2019. С. 48-49.
3. Tara S., Reddy B., Ramesh G., Sandeep K. Various Image Segmentation Methods Based On Partial Differential Equation-A Survey. International Conference on Computer & Communication Technologies Vol. 3, 2014. P. 183-186.
4. Dzung L.P., Chenyang Xu., Jerry L.P. Current Methods in Medical Image Segmentation. Annual Review of Biomedical Engineering Vol. 2, 2000. P. 315-337.
5. Гороховський С.С., Мороз А.В. Сегментація зображень із використанням генетичних алгоритмів, 2021. С. 52-55.
6. Волосюк Ю.В. Аналіз алгоритмів кластеризації для задач інтелектуального аналізу даних. Збірник наукових праць Військового інституту Київського національного університету імені Тараса Шевченка, 2014. С. 112-119.
7. Ying Y. Techniques and Challenges of Image Segmentation: A Review, 2023. P. 1199-1224.
8. Jain A.K., Murty M.N., Flynn P.J. Data clustering: a review, 1999. P. 264-323.

9. Греді Л. Random walks of image segmentation, 2006. С. 1768-1783.
10. Peng P., Zhang L. A survey of graph theoretical approaches to image segmentation. Pattern Recognition, 2013. P. 1020-1038.
11. Скаковська А.М., Радивоненко О.С., Шалда К.В. Кластеризація зображень для їх компресії на основі компонентного аналізу. Вісник Сумського державного університету, 2012. С. 32-36.
12. Perez-Ortega J. Hybrid Fuzzy C-Means Clustering Algorithm Oriented to Big Data Realms. Computational and Mathematical Methods in Science and Engineering, 2022. P. 377-385.
13. Піцун О. Й. Адаптивний метод попередньої обробки гістологічних та цитологічних зображень. Тернопільський національний економічний університет, 2016. С. 111-119.
14. Lisani J. Local Contrast Enhancement based on Adaptive Logarithmic Mappings. Image Processing On Line, 2020. P. 43-61.
15. Wang. F. A Variational Image Segmentation Model based on Normalized Cut with Adaptive Similarity and Spatial Regularization. Computer Science - Computer Vision and Pattern Recognition, 2020. P. 651-684.