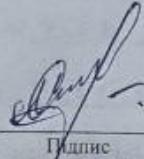
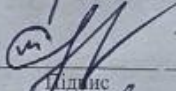


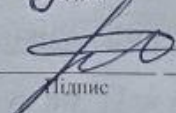
КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

на тему Метод виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості для підвищення достовірності нейромережевої класифікації


Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань
Спеціальність 122 – Комп'ютерні науки
Шифр і назва спеціальності
Освітня програма Комп'ютерні науки
Назва освітньої програми

Виконала: студентка групи КН-22-3  Єлизавета МЕРЕЖКО
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

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

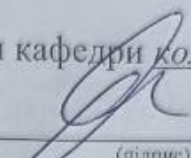
Нормоконтроль: к.т.н., доц. каф. КН  Руслан БАГРІЙ
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

До захисту допускаю:

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

18 серпня 2026 р.

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

ЗАТВЕРДЖУЮ
Завідувач кафедри комп'ютерних наук

(підпис)
д.т.н., професор Олександр БАРМАК
« 21 » січня 2026 року

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ БАКАЛАВРА

1. Тема кваліфікаційної роботи бакалавра: «Метод виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості для підвищення достовірності нейромережевої класифікації»

2. Завдання видано студентці Єлизаветі Мережко
(Ім'я, прізвище)

3. Керівник роботи доцент кафедри КН Олександр Мазурець
(посада, ім'я, прізвище)

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

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

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

Мета роботи – підвищення точності нейромережевої класифікації шляхом розробки методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості. Для досягнення поставленої мети слід виконати такі завдання: провести аналіз предметної області для задачі виявлення надлишкових даних у наборах текстильних зображень; розробити метод виявлення надлишкових текстильних зображень на основі алгоритмів перцептивного хешування та аналізу глибинних векторних представлень; виконати проектування та реалізацію інтелектуальної системи для виявлення надлишкових даних у наборах текстильних зображень та провести експериментальне дослідження запропонованого методу.

7. Календарний план виконання кваліфікаційної роботи бакалавра:

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

Виконавець: студентка групи КН-22-3
Група виконавця


Підпис

Елизавета МЕРЕЖКО
Ім'я, ПРІЗВИЩЕ

Керівник: к.т.н., доц. каф. КН
Науковий ступінь, посада


Підпис

Олександр МАЗУРЕЦЬ
Ім'я, ПРІЗВИЩЕ

Анотація

Тема кваліфікаційної роботи бакалавра: «Метод виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості для підвищення достовірності нейромережевої класифікації»

Виконавець кваліфікаційної роботи бакалавра: студентка групи КН-22-3 Єлизавета Мережко

Керівник кваліфікаційної роботи бакалавра: к.т.н., доцент кафедри КН Олександр Мазурець

Кваліфікаційна робота бакалавра містить:

Пояснювальна записка				Кількість додатків
Сторінок	Рисунків	Таблиць	Джерел інформації	
58	19	7	45	2


Метою кваліфікаційної роботи бакалавра є підвищення точності нейромережевої класифікації шляхом розробки методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості. Для розробки прикладної інтелектуальної системи було використано мову програмування Python, а також спеціалізовані бібліотеки PyTorch, ImageHash та PyQt5 для дедуплікації вибірок, навчання моделей і візуалізації результатів. Розроблена система призначена для автоматизованого аналізу інформаційної надлишковості у графічних датасетах, порівняння ефективності алгоритмів пошуку дублікатів, а також оцінювання впливу процедур очищення вибірок на якість подальшого розпізнавання.

Напрямами практичного використання розробленої системи є автоматизоване виявлення та аналіз надлишкових даних у наборах текстильних зображень.

Ключові слова: перцептивна схожість, текстильні зображення, embedding-представлення, rHash, дедуплікація.

Виконавець: студентка групи КН-22-3

Група виконавця



Відпис

Єлизавета МЕРЕЖКО

Ім'я, ПРІЗВИЩЕ

Зміст

Перелік скорочень.....	3
Вступ.....	4
Розділ 1 Характеристика предметної області: аналіз моделей, методів та реалізацій.....	6
1.1 Аналіз інформаційних моделей.....	6
1.2 Огляд сучасних підходів до виявлення надлишкових даних у наборах текстильних зображень.....	8
1.3 Аналіз існуючих програмних рішень.....	13
1.4 Мета, задачі та вимоги до реалізації інтелектуальної системи.....	17
Розділ 2 Розробка методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості.....	18
2.1 Формалізація задачі виявлення надлишковості текстильних зображень.....	18
2.2 Схема та етапи методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості.....	21
2.3 Архітектури нейромережових засобів для аналізу перцептивної схожості та класифікації текстильних зображень.....	24
2.4 Підготовка робочих вхідних даних для системи.....	28
2.5 Метрики оцінювання точності нейромережових моделей.....	30
2.6 Сценарій експериментів з валідації розробленого методу.....	33
2.7 Висновки до розділу 2.....	35
Розділ 3 Експериментальне дослідження методу виявлення надлишкових даних у наборах текстильних зображень.....	36
3.1 Засоби розробки системи аналізу надлишковості текстильних зображень.....	36
3.2 Опис інтелектуальної системи для дослідження методу.....	37
3.3 Результати досліджень.....	42
3.4 Обмеження та перспективи.....	49
3.5 Висновки до розділу 3.....	51
Загальні висновки.....	53
Перелік посилань.....	54
Додатки	

Перелік скорочень

Скорочення, термін, позначення	Пояснення
КН	Комп'ютерні науки
НМ	Нейронна мережа
ХНУ	Хмельницький національний університет
AI	Artificial Intelligence
aHash	Average Hash
dHash	Difference Hash
pHash	Perceptual Hash
wHash	Wavelet Hash
CNN	Cable News Network
SSIM	Structural Similarity Index
SIFT	Scale-Invariant Feature Transform
ORB	Oriented FAST and Rotated BRIEF
ML	Machine Learning
DL	Deep Learning
SDK	Software Development Kit
HTML	Hyper Text Markup Language
RGB	Red, Green, Blue

Вступ

Кваліфікаційна робота присвячена підвищенню точності нейромережевої класифікації шляхом розробки методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості.

Актуальність. Стрімкий розвиток цифрових технологій та автоматизації виробничих процесів у текстильній промисловості зумовлює потребу у створенні високоточних систем комп'ютерного зору. Сучасні нейромережеві моделі широко використовуються для класифікації тканин, контролю якості та ідентифікації артикулів. Проте ефективність навчання таких моделей критично залежить від якості вхідних даних, що відповідає сучасній концепції Data-Centric AI.

Однією з ключових проблем підготовки наборів даних є наявність великої кількості дубльованих або перцептивно подібних зображень. Надлишковість інформації призводить до надмірних витрат часу та обчислювальних ресурсів під час тренування нейронних мереж. Крім того, накопичення однакових прикладів у вибірці спричиняє перенавчання моделей, що негативно впливає на якість розпізнавання нових об'єктів.

Особливо складною ця задача є для текстильної галузі. Специфіка зображень тканин полягає у наявності повторюваних орнаментів, подібних типів плетіння ниток та однорідної кольорової гами. Через такі особливості стандартні алгоритми часто не можуть відрізнити копії від унікальних зразків, що мають незначні текстурні відмінності. У зв'язку з цим виникає потреба у застосуванні ефективніших підходів до очищення даних, здатних враховувати характерні риси текстильних матеріалів.

Застосування аналізу перцептивної схожості на основі хешування та глибинних векторних представлень дозволяє автоматизувати процес дедуплікації. Це обґрунтовує доцільність розробки спеціалізованого підходу, здатного адаптуватися до особливостей текстильних текстур. Реалізація програмного прототипу на базі запропонованого рішення дозволить експериментально довести його спроможність ефективно усувати надлишковість

даних та підтвердити можливість підвищення достовірності подальшої нейромережевої класифікації.

Об'єкт дослідження – процес підготовки та оптимізації наборів текстильних зображень для підвищення достовірності нейромережевої класифікації.

Предмет дослідження – методи та засоби штучного інтелекту для виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості.

Мета кваліфікаційної роботи бакалавра – підвищення точності нейромережевої класифікації шляхом розробки методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості.

Завдання кваліфікаційної роботи бакалавра – провести аналіз предметної області для задачі виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості; розробити метод виявлення надлишкових текстильних зображень для підвищення достовірності нейромережевої класифікації на основі алгоритмів перцептивного хешування та аналізу глибинних векторних представлень; виконати проектування та реалізацію інтелектуальної системи для виявлення надлишкових даних у наборах текстильних зображень; провести експериментальне дослідження запропонованого методу розробленим програмним забезпеченням.

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

1.1 Аналіз інформаційних моделей

Текстильна промисловість є важливою складовою легкої індустрії, що охоплює виробництво волокон, ниток, тканин та готових виробів, які широко застосовуються у різних сферах діяльності людини – від виготовлення одягу до технічних і спеціалізованих матеріалів [1].

У сучасних умовах галузь активно трансформується під впливом цифрових технологій, впроваджуючи автоматизовані системи контролю, методи комп'ютерного зору та інтелектуальні інформаційні платформи для обробки даних, у яких основним джерелом інформації про матеріали виступають їх цифрові зображення [2]. У таких системах знімок тканини відображає її зовнішній вигляд, текстуру, колірні характеристики та особливості поверхні, що визначає візуальні дані як основний інформаційний ресурс для задач аналізу та автоматизованої класифікації об'єктів дослідження.

Цифрові зображення текстильних матеріалів є специфічним видом візуальних даних, що відрізняються від інших типів своєю багаторівневою ієрархічною будовою та високим ступенем деталізації текстури. Полотно формується шляхом переплетення волокон або ниток у визначеному порядку, створюючи характерний малюнок поверхні [3]. Така організація елементів визначає мікрорельєф тканини та безпосередньо впливає на її фізико-механічні й візуальні властивості. У виробничій практиці виділяють три основні групи матеріалів: ткани, трикотажні та неткані, кожна з яких має свою унікальну внутрішню архітектуру [4]. В межах кожного типу можливі численні варіації, пов'язані зі щільністю ниток, їх товщиною, видом волокон та технологією обробки, що зумовлює різноманіття текстурних характеристик і формування візуально подібних, але структурно відмінних зразків.

Візуальна якість текстильних зображень критично залежить від технічних умов їх реєстрації. Найважливішим чинником вважається освітлення, оскільки

нитки мають об'ємну структуру та різну здатність відбивати світло. Навіть незначна зміна напрямку або інтенсивності променів створює на поверхні тканини складні тіні та відблиски [5]. Це призводить до того, що знімки одного і того ж матеріалу можуть суттєво відрізнятися за кольором та контрастністю. Крім того, на фінальний результат впливають масштаб та ракурс зйомки. Саме від цих параметрів залежить ступінь деталізації полотна, що дозволяє побачити або загальний візерунок, або окремі елементи плетіння [6].

Сукупність розглянутих факторів визначає специфіку формування масивів даних, які слугують фундаментом для навчання інтелектуальних систем. У контексті задач класифікації текстилю такі структури являють собою базу цифрових зразків, розподілених за певними класами відповідно до типу тканини або її характеристик. Побудова ефективних моделей потребує високої репрезентативності даних, яка б охоплювала все реальне різноманіття текстурних варіацій [7].

Проте прагнення забезпечити повноту вибірки часто призводить до іншої проблеми – накопичення критичного обсягу ідентичних або візуально подібних кадрів, що формує явище інформаційної надлишковості [8]. Дослідження показують, що наявність візуально дубльованих або перцептивно подібних зображень у великих датасетах не додає корисної інформації, а навпаки створює ризик інформаційного витоку та завищення метрик за рахунок близьких повторів, коли фактично оцінюється здатність моделі відтворювати вже спостережені зразки, а не узагальнювати нові матеріали [9].

У зв'язку з цим актуальним є підхід, що базується на аналізі перцептивної схожості, тобто оцінці того, наскільки зображення подібні з точки зору їхнього візуального сприйняття. Такий метод дозволяє знаходити дублікати або майже ідентичні зображення навіть за наявності незначних відмінностей, пов'язаних з умовами зйомки. Видалення або групування подібних прикладів дає можливість сформуванню більш впорядкований і збалансований набір даних [10].

Таким чином, специфіка текстилю як об'єкта цифрової реєстрації висуває високі вимоги до якості вхідних даних. Хоча цифровізація галузі сприяє впровадженню інтелектуальних систем, явище надлишковості у масивах зображень

стає суттєвим бар'єром для створення надійних моделей класифікації. Наявність візуальних дублікатів не лише марнує обчислювальні ресурси, а й викривлює оцінку здатності нейромереж до реального узагальнення. У цьому контексті застосування методів аналізу перцептивної схожості для дедуплікації датасетів є критично необхідним етапом. Це дозволяє перейти від кількісного накопичення вибірок до формування якісних репрезентативних баз знань, що забезпечують стабільність роботи комп'ютерного зору в умовах реального виробництва.

1.2 Огляд сучасних підходів до виявлення надлишкових даних у наборах текстильних зображень

Вирішення задачі виявлення надлишковості у масивах зображень базується на методах пошуку візуальної схожості. З огляду на високу повторюваність текстур та варіативність умов зйомки, такі алгоритми повинні забезпечувати стійкість до змін освітлення, масштабу та незначних спотворень. На сьогодні в галузі комп'ютерного зору сформувався декілька основних напрямків ідентифікації дублікатів і подібних графічних елементів, які відрізняються рівнем абстракції ознак, обчислювальною складністю та точністю.

Одним із найбільш поширених рішень для виявлення візуальних дублікатів є перцептивне хешування, зокрема алгоритм рHash. Його принцип полягає у формуванні компактного бінарного коду на основі низькочастотних компонентів цифрового знімка, отриманих за допомогою дискретного косинусного перетворення. Подібність між аналізованими об'єктами визначається за відстанню Геммінга між їхніми хешами, що дозволяє кількісно оцінити ступінь їхньої ідентичності [11]. Завдяки стійкості до незначних змін освітлення, масштабування та стиснення цей метод ефективно застосовується для первинного виявлення дублікатів у великих наборах даних [12].

Специфіка впровадження цієї технології для автоматизованого очищення інформаційних масивів детально описана у статті [13]. Автори досліджують ефективність алгоритмів рHash та dHash для ідентифікації візуально схожих

об'єктів. Особливу увагу приділено визначенню порогових значень відстані Геммінга, які використовуються для оцінювання ступеня близькості між елементами. У роботі доведено, що зависокий поріг може призводити до помилкового видалення унікальних даних, тоді як занижений спричиняє пропуск реальних дублікатів. Результати експериментів підтвердили важливість коректного налаштування threshold-параметрів для надійної автоматизованої фільтрації.

Більш точні результати забезпечують підходи, що базуються на використанні глибоких векторних представлень (embeddings), сформованих за допомогою згорткових нейронних мереж. У цьому випадку вхідні дані проходять через попередньо навчену модель, яка виконує ієрархічне вилучення ознак. На одному з фінальних шарів формується багатовимірне представлення, узагальнюючи ключові візуальні характеристики об'єкта. Оцінювання подібності здійснюється за допомогою косинусної міри або евклідової відстані між отриманими векторами, що забезпечує високу точність навіть за складних змін умов зйомки [14].

Сучасні стратегії дедуплікації все частіше спираються на такі нейромереві моделі для знаходження майже ідентичних кадрів. Зокрема, у дослідженні [15] обґрунтовано переваги рішень на основі глибокого навчання, які демонструють вищу стабільність порівняно з класичними алгоритмами хешування. На основі комплексного порівняльного аналізу встановлено, що використання векторних представлень на основі CNN забезпечує стійкість системи до типових для реальних умов експлуатації проблем, як-от локальні структурні зміни об'єктів або значна варіативність параметрів візуалізації та освітлення.

Серед інших підходів до оцінювання подібності графічних об'єктів застосовується індекс структурної подібності SSIM. Метод порівнює зображення за показниками яскравості, контрасту та локальної структури, наближаючи математичну оцінку до особливостей людського зорового сприйняття. Значення SSIM лежить у діапазоні від 0 до 1, де значення, близьке до одиниці, відповідає високій структурній відповідності [16]. Водночас така технологія демонструє нестабільні результати при незначних геометричних зсувах, поворотах або зміні

ракурсу зйомки, що обмежує її застосування для аналізу текстильних датасетів, де умови реєстрації можуть варіюватися [17].

Аналогічні обмеження мають методи на основі колірних гістограм. Вони дозволяють швидко оцінити колірні характеристики кадру, проте не враховують просторове розташування елементів та особливості текстури. Це може призводити до помилкового об'єднання різних за фактурою матеріалів [18].

Інваріантним до складних геометричних перетворень вважається використання локальних дескрипторів таких як SIFT або ORB. Ці алгоритми виконують пошук ключових точок і описують їхні мікротекстурні характеристики, після чого встановлюють відповідності між знайденими ознаками [19]. Однак ефективність таких підходів критично залежить від стабільності детектування характерних орієнтирів. Це призводить до помилок при аналізі текстилю, оскільки однорідна або циклічна структура тканини не має достатньої кількості унікальних геометричних елементів для побудови коректних зв'язків.

Обмеження розглянутих структурних і текстурних методів підтверджують їхню низьку ефективність під час обробки циклічних візуальних структур тканин. Це обґрунтовує доцільність фокусування уваги саме на алгоритмах перцептивного хешування та глибоких векторних представленнях (embeddings), які є більш стійкими до специфіки таких даних. Водночас у сучасній практиці комп'ютерного зору призначення цих двох інструментів суттєво розширилося: дедуплікація розглядається не просто як механічне видалення ідентичних картинок, а як інструмент інтелектуального відбору найбільш інформативних та корисних зразків для підвищення швидкості та якості узагальнення нейромереж.

Зокрема, у дослідженні [20] розглядається проблема високої інформаційної надлишковості у великих наборах даних та її безпосередній вплив на ефективність навчання нейронних мереж. Авторами запропоновано метод семантичної дедуплікації SemDeDup, який базується на використанні векторних представлень зображень для ідентифікації та видалення візуально схожих об'єктів. Методологія включає кластеризацію ознак за допомогою алгоритму k-means та обчислення

косинусної подібності між embedding-векторами всередині кластерів. Експериментально доведено, що видалення до 50% семантично дубльованих даних дозволяє суттєво прискорити процес навчання нейронних мереж без втрати точності класифікації та покращити здатність моделей до узагальнення.

Питання інформаційної надлишковості також висвітлено у праці [21], спрямованій на оптимізацію навчання штучного інтелекту шляхом селективного відбору даних. Головна мета дослідження полягає в ідентифікації та усуненні не лише прямих копій, а й малоінформативних зразків, які мають низьку цінність для формування чітких класифікаційних меж. Автори пропонують підхід, що ґрунтується на аналізі індивідуального внеску кожного об'єкта в загальну точність моделі. Суть алгоритму полягає у відсіюванні візуально подібних кадрів на користь найбільш репрезентативних прикладів, що дозволяє скоротити обсяг вибірки без втрати її інформативності.

Прагнення поєднати високу швидкість обробки великих потоків даних із точністю глибоких моделей призвело до появи гібридних архітектур. Так, для вирішення проблем обчислювальної ефективності у роботі [22] запропоновано комбінований підхід. Автори об'єднали алгоритми перцептивного хешування, сіамську нейронну мережу та трансформерну модель комп'ютерного зору для виявлення near-duplicate зображень. У такій структурі хешування використовується для швидкої попередньої фільтрації очевидних повторів, тоді як нейромереві моделі забезпечують тонкий аналіз складніших візуальних характеристик. Така каскадна схема є критично важливою для обробки великих графічних масивів, оскільки дозволяє мінімізувати загальне навантаження на обчислювальні блоки глибокого навчання під час аналізу мікротекстур. Результати експериментів продемонстрували високу ефективність запропонованого підходу, зокрема досягнення точності 0.987 та показника ROC-AUC 0.99, що перевищує результати традиційних методів більше ніж на 10%.

Для систематизації результатів проведеного аналізу та порівняння ефективності сучасних підходів до виявлення надлишкових даних у таблиці 1.1 наведено ключові характеристики розглянутих методів.

Таблиця 1.1 – Порівняльний аналіз підходів до дедуплікації та пошуку візуальної схожості зображень

Підхід / метод	Переваги	Недоліки
Перцептивне хешування (pHash)	Висока швидкість роботи, мінімальні вимоги до пам'яті, висока ефективність первинного відбору.	Чутливість результату до вибору числового порогу порівняння (threshold).
Глибокі векторні представлення (CNN-embeddings)	Висока точність пошуку схожих зображень, стійкість до складних візуальних змін.	Високі обчислювальні витрати, потреба у попередньо навчених моделях.
Індекс структурної подібності (SSIM)	Оцінка наближена до сприйняття людського ока.	Нестійкість до зміни ракурсу та геометричних зсувів.
Колірні гістограми	Висока швидкість розрахунку, простота програмної реалізації.	Не враховується просторова структура та текстура об'єктів.
Локальні дескриптори (SIFT, ORB)	Стійкість до геометричних перетворень.	Низька ефективність для однорідних текстур тканини.

Таким чином, огляд сучасних підходів свідчить про високу ефективність методів глибокого навчання та перцептивного хешування для автоматизованої дедуплікації графічних даних. Водночас питання очищення зображень у специфічних прикладних галузях, зокрема в текстильній промисловості, залишається недостатньо вивченим. Це зумовлює актуальність розробки методів, здатних точно ідентифікувати повтори з урахуванням складних текстур і циклічних патернів тканини для ефективного подолання явища доменного зсуву. Реалізація такого підходу дозволить суттєво оптимізувати обсяг навчальних вибірок, знизити ризик перенавчання нейромереж та забезпечити високу точність класифікації матеріалів у реальних умовах виробництва.

1.3 Аналіз існуючих програмних рішень

Зі збільшенням обсягів візуальних даних у галузі комп'ютерного зору зростає потреба у засобах автоматизованого аналізу та оптимізації навчальних вибірок. Одним викликом є виявлення дубльованих і перцептивно подібних зображень, що здатні негативно впливати на процес навчання нейромережевих моделей. Для розв'язання таких задач використовуються спеціалізовані інструменти, орієнтовані на знаходження копій, аналіз структури датасетів та очищення надлишкових елементів.

Серед сучасних засобів інтелектуальної обробки візуальних даних вагоме місце посідає розробка компанії Voxel51 – відкрита платформа FiftyOne [23]. Даний програмний продукт позиціонується як інструментарій для реалізації концепції Data-Centric AI, що фокусується на підвищенні якості вхідних даних для моделей штучного інтелекту. Основним призначенням системи є детальна візуалізація структури вибірок, виявлення невідповідностей у розмітці та пошук дублікатів. Загальну архітектуру взаємодії платформи з користувацькими даними та моделями, а також основні етапи обробки зображень представлено на рисунку 1.1.

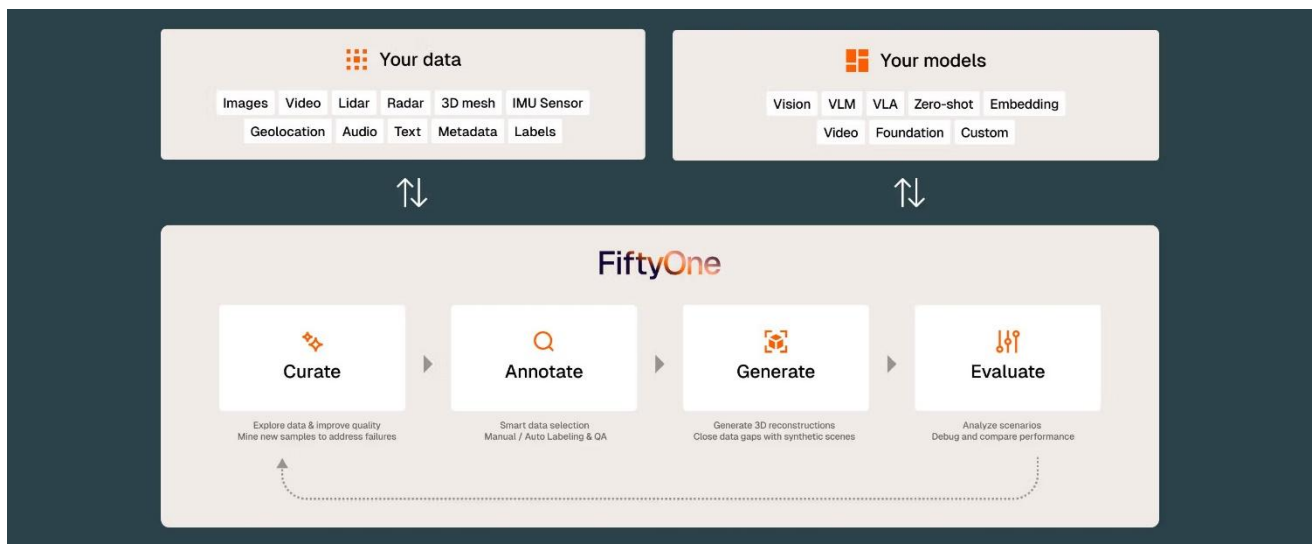


Рисунок 1.1 – Загальна схема функціонування та конвеєр обробки даних на платформі FiftyOne [23]

Після завантаження набору зображень система надає можливість здійснювати інтерактивний аналіз даних через графічний інтерфейс. Однією з ключових функцій FiftyOne є робота з векторизованими представленнями

(embeddings), що формуються за допомогою моделей глибокого навчання. На основі таких ознак алгоритми виконують пошук візуально подібних прикладів та їх групування за ступенем схожості (рисунок 1.2). Це дозволяє автоматично виявляти точні копії або перцептивно близькі зображення у великих масивах даних. Крім пошуку подібних об'єктів, інструмент підтримує гнучку фільтрацію, сортування за метаданими, візуалізацію простору ознак, а також комплексну оцінку результатів роботи НМ моделей.




Рисунок 1.2 – Пошук подібних зображень на платформі FiftyOne [24]

Інтерфейс системи дозволяє наочно переглядати виділені групи повторів, оцінювати загальну щільність датасету та відсіювати надлишкові елементи ще до початку етапу навчання. Завдяки цьому розробник може здійснювати швидкий попередній аудит якості вибірки.




До переваг FiftyOne належать підтримка сучасних методів візуального аналізу, сумісність із популярними ML-фреймворками та здатність ефективно обробляти великі масиви даних. Проте система має відносно високий поріг входження через складність первинного налаштування SDK та вимагає значних обчислювальних ресурсів для розрахунку й порівняння векторів ознак [25]. Крім того, її функціонал обмежений виключно аналізом та очищенням даних без можливості безпосереднього тренування моделей, а відсутність інтегрованих

алгоритмів аналізу мікротекстур обмежує її ефективність під час роботи зі специфічними текстильними патернами.

Ефективною альтернативою важковаговим платформам є спеціалізована бібліотека fastdup [26]. У науковій практиці цей інструмент позиціонується як високоефективне рішення для аналізу візуальних датасетів без вчителя (unsupervised data insights). Головною функцією бібліотеки є швидке виявлення аномалій, помилок маркування та надлишкових елементів для подолання проблеми низької якості реальних наборів даних. Завдяки низькорівневій оптимізації обчислювального ядра мовою C++, алгоритм здатний обробляти мільйони зображень на стандартних процесорах із мінімальним використанням оперативної пам'яті.

Бібліотека автоматично будує граф зв'язків між об'єктами, знаходить точні та часткові дублікати, а також виявляє дефекти вибірки, такі як зашумлені, розмиті або занадто темні кадри. Замість постійного графічного вікна, fastdup генерує за результатами аналізу детальні інтерактивні HTML-звіти. У них користувач може наочно оцінити ступінь схожості об'єктів за розрахованою метрикою відстані, переглянути порівняння оригіналів із накладанням змішаних кадрів, а також ідентифікувати локальні шляхи до дубльованих файлів (рисунк 1.3).

Fastdup Tool - Similarity Report

	Image	Distance	From	To
0		1.0	scene_classification/data/train_set/buildings/9769.jpg	scene_classification/data/train_set/street/7293.jpg
1		1.0	scene_classification/data/train_set/sea/19255.jpg	scene_classification/data/train_set/sea/7872.jpg
2		1.0	scene_classification/data/train_set/street/3492.jpg	scene_classification/data/train_set/street/373.jpg

Рисунк 1.3 – Структура інтерактивного звіту системи fastdup [26]

Додатковою перевагою fastdup є лінійна масштабованість алгоритму, що гарантує стабільність обчислень без ризику переповнення пам'яті при кратному збільшенні вибірки. Проте традиційна архітектура ядра унеможлиблює гнучку кастомізацію метрик схожості під специфічні задачі. Крім того, орієнтація алгоритмів на глобальні геометричні й колірні ознаки обумовлює їхню низьку чутливість до локальних аномалій мікротекстурного рівня.

Поряд із комплексними інструментами дедуплікації використовується простіша бібліотека з відкритим кодом imagededup [27]. Даний засіб орієнтований на виявлення однакових і візуально схожих зображень шляхом порівняння їхніх цифрових представлень. Система підтримує алгоритми перцептивного хешування, серед яких pHash, dHash, wHash та aHash, а також базові методи на основі згорткових нейронних мереж.

Взаємодія з цією бібліотекою відбувається шляхом написання програмного коду, де користувач самостійно визначає метод аналізу та встановлює поріг схожості об'єктів. Результатом виконання скрипту є список подібних зображень із зазначенням кількісних показників їхньої близькості до оригінального файлу (рисунок 1.4).




Рисунок 1.4 – Результат виявлення візуально подібних зображень засобами бібліотеки imagededup [28]

Однією з основних переваг бібліотеки є висока швидкість обробки даних та можливість її інтеграції в наявні системи автоматизації. Водночас суттєвим обмеженням `imagededup` є консольний характер роботи. Відсутність інтегрованих модулів графічного відображення чи генерації звітів змушує користувача розробляти власні програмні рішення для первинної візуальної оцінки та верифікації знайдених дублікатів.

Отже, сучасні системи забезпечують ефективний пошук дублікатів завдяки алгоритмам хешування та нейромережевим моделям. Проте розглянуті інструменти мають вузьку спеціалізацію та не враховують особливості текстильних текстур, що обмежує їхню ефективність у цій галузі. Це обґрунтовує необхідність розробки власного методу виявлення надлишкових даних, здатного врахувати специфіку візуальних ознак тканини для підвищення якості вибірок.

1.4 Мета, задачі та вимоги до реалізації інтелектуальної системи

Метою кваліфікаційної роботи є підвищення точності нейромережевої класифікації шляхом розробки методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості.

Для досягнення поставленої мети потрібно виконати наступні завдання:

- провести аналіз предметної області для задачі виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості;
- розробити метод виявлення надлишкових текстильних зображень для підвищення достовірності нейромережевої класифікації на основі алгоритмів перцептивного хешування та аналізу глибоких векторних представлень;
- виконати проєктування та реалізацію інтелектуальної системи для виявлення надлишкових даних у наборах текстильних зображень;
- провести експериментальне дослідження запропонованого методу розробленим програмним забезпеченням.

Розділ 2 Розробка методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості

2.1 Формалізація задачі виявлення надлишковості текстильних зображень

Задача виявлення надлишковості у наборах текстильних зображень полягає у визначенні елементів, що характеризуються високим рівнем перцептивної схожості та містять повторювану візуальну інформацію. Формалізація такої задачі передбачає подання зображень у вигляді ознакових представлень і визначення кількісних критеріїв оцінювання подібності між ними.

У межах дослідження текстильне зображення розглядається як носій структурно-текстурних характеристик матеріалу, а ступінь близькості між окремими зразками визначається на основі аналізу їхніх візуальних ознак. Особлива увага приділяється ідентифікації мікроструктурних особливостей, таких як напрямок плетіння ниток, циклічність візерунків та локальні деформації тканини, які за умов різного освітлення чи ракурсів зйомки можуть утворювати приховану надлишковість. Основною метою є формування очищеної вибірки, у якій мінімізується кількість дубльованих або перцептивно подібних елементів, здатних спричинити ефект перенавчання НМ. Такий підхід дозволяє зменшити інформаційну надлишковість набору даних, підвищити репрезентативність навчальної вибірки та забезпечити високу інваріантність моделі до незначних геометричних змін зразків.

У роботі розглядається бінарна постановка задачі класифікації, відповідно до якої текстильні матеріали поділяються на два класи: натуральні та синтетичні тканини. Вхідними даними є набір цифрових RGB-зображень, які після попередньої обробки приводяться до єдиного формату та використовуються для аналізу перцептивної подібності й дослідження впливу очищення вибірки на результати нейромережевої класифікації.

Простір вхідних даних X можна подати у вигляді множини:

$$X = \{x_1, x_2, \dots, x_n\}, \quad (2.1)$$

де x_i – окреме зображення текстильного матеріалу, представлене у вигляді тривимірного тензора розмірності $3 \times 224 \times 224$, а n – загальна кількість елементів набору даних.

Для порівняння зображень між собою та виявлення схожих зразків необхідно перетворити їх із багатовимірних матриць пікселів у компактні цифрові представлення. Оскільки в роботі передбачено використання різних підходів до пошуку надлишковості, формування ознак реалізується двома способами.

Перший підхід базується на алгоритмі перцептивного хешування $pHash$, принцип роботи якого полягає у формуванні компактного бінарного опису зображення на основі низькочастотних компонентів дискретного косинусного перетворення. У такому випадку кожному зображенню x_i ставиться у відповідність хеш-представлення:

$$h_i = pHash(x_i), \quad (2.2)$$

де h_i – перцептивний хеш зображення x_i .

Отриманий хеш подається у вигляді бінарного вектора:

$$h_i = \{b_1, b_2, \dots, b_k\}, \quad (2.3)$$

де b_i – окремий елемент хеш-вектора, що може набувати значення 0 або 1, а k – довжина хеш-вектора.

Подібність між двома зображеннями визначається за відстанню Геммінга між їхніми хеш-векторами h_i та h_j :

$$D_H(h_i, h_j) = \sum_{t=1}^k (h_{it} \oplus h_{jt}), \quad (2.4)$$

де \oplus – операція виключного АБО.

Малі значення відстані Геммінга свідчать про високий рівень візуальної близькості між текстильними зразками, унаслідок чого вони можуть розглядатися як потенційно надлишкові. Для автоматизації процесу їх виявлення буде використано порогове значення ε , яке визначає максимально допустиму кількість розбіжностей між хеш-представленнями. Зображення вважаються перцептивно подібними, якщо виконується наступна умова:

$$D_H(h_i, h_j) \leq \varepsilon \quad (2.5)$$

Другий підхід базується на використанні глибинних векторних представлень *embeddings*, сформованих згортковою нейронною мережею. Для вилучення ознак використовується попередньо навчена модель, у якій класифікаційна частина (повнозв'язні шари) відкидається, залишаючи лише згорткову основу для формування векторних представлень. У результаті проходження текстильного зразка через мережу формується *embedding*-вектор, що містить узагальнений опис текстурних і структурних особливостей матеріалу. Кожному зображенню x_i ставиться у відповідність його векторне представлення:

$$e_i = f_{cnn}(x_i), \quad (2.6)$$

де f_{cnn} – функція перетворення вхідного зображення у простір ознак.

Оцінювання ступеня подібності між векторними представленнями e_i та e_j здійснюється за допомогою косинусної міри подібності:

$$S(e_i, e_j) = \frac{e_i \cdot e_j}{\|e_i\| \|e_j\|}, \quad (2.7)$$

де $e_i \cdot e_j$ – скалярний добуток векторних представлень, а $\|e_i\|$ та $\|e_j\|$ – їх евклідові норми. Ця метрика набуває значень у межах $[-1,1]$ та характеризує ступінь близькості між векторами у просторі ознак. Значення, близькі до 1, свідчать про високий рівень схожості між текстильними зразками.

Для прийняття остаточного рішення щодо наявності або відсутності дублікату використовується порогове значення косинусної подібності. Якщо значення метрики перевищує встановлений поріг τ , відповідна пара зображень розглядається як потенційно надлишкова:

$$S(e_i, e_j) \geq \tau \quad (2.8)$$

Незалежно від обраного типу ознакового представлення (*pHash* або *embeddings*), усі пари зображень, які задовольняють критерії подібності відповідної фізичної величин (2.5) або (2.8), об'єднуються у групи перцептивно схожих елементів. На основі аналізу сформованих груп реалізується процедура фільтрації, у межах якої у вибірці залишається лише одне репрезентативне зображення, тоді як інші елементи групи вилучаються як потенційно надлишкові. Схематично процес формування очищеної вибірки представлено на рисунку 2.1.

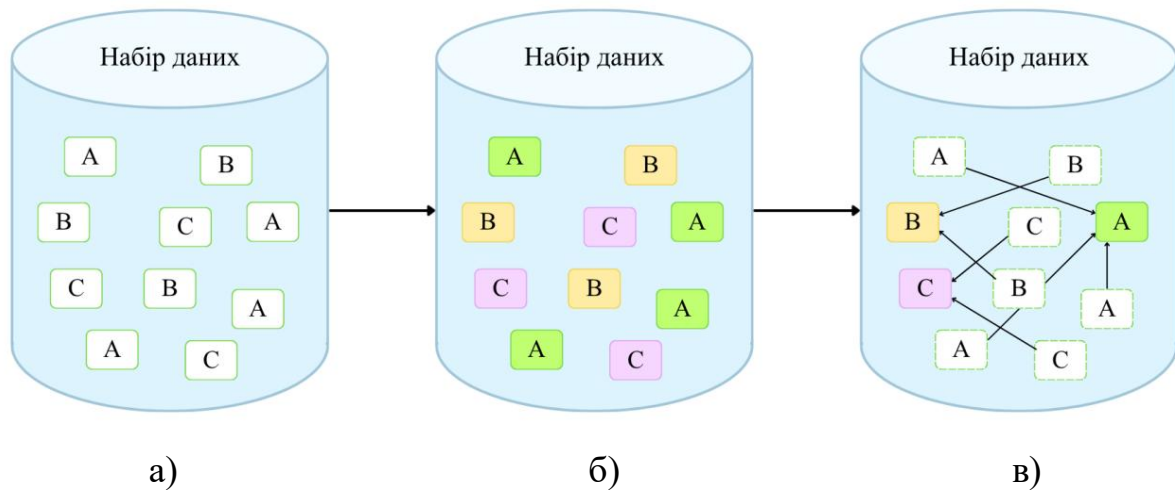


Рисунок 2.1 – Схема процесу виявлення та вилучення надлишкових текстильних зображень: а) формування ознакових представлень; б) виявлення перцептивно схожих зразків; в) вилучення надлишкових елементів

Результатом застосування запропонованого підходу є формування очищеної підмножини даних:

$$X_{clean} \subset X, \quad (2.9)$$

де X_{clean} містить лише унікальні або достатньо відмінні текстильні зразки після вилучення перцептивно подібних елементів. Отримана вибірка використовується для формування навчальних і валідаційних підмножин моделі, що дозволяє зменшити ризик перенавчання та підвищити точність оцінювання класифікації текстильних матеріалів.

2.2 Схема та етапи методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості

Метод виявлення надлишкових текстильних зображень базується на аналізі перцептивної подібності між елементами набору даних та подальшому формуванні очищеної вибірки для підвищення точності нейромережевої класифікації. Методологія організована у вигляді послідовності взаємопов'язаних етапів, що включають попередню обробку зображень, виявлення перцептивно схожих елементів, формування очищеного набору даних та подальше навчання й оцінювання CNN-моделі. На рисунку 2.2 наведено кроки запропонованого методу.

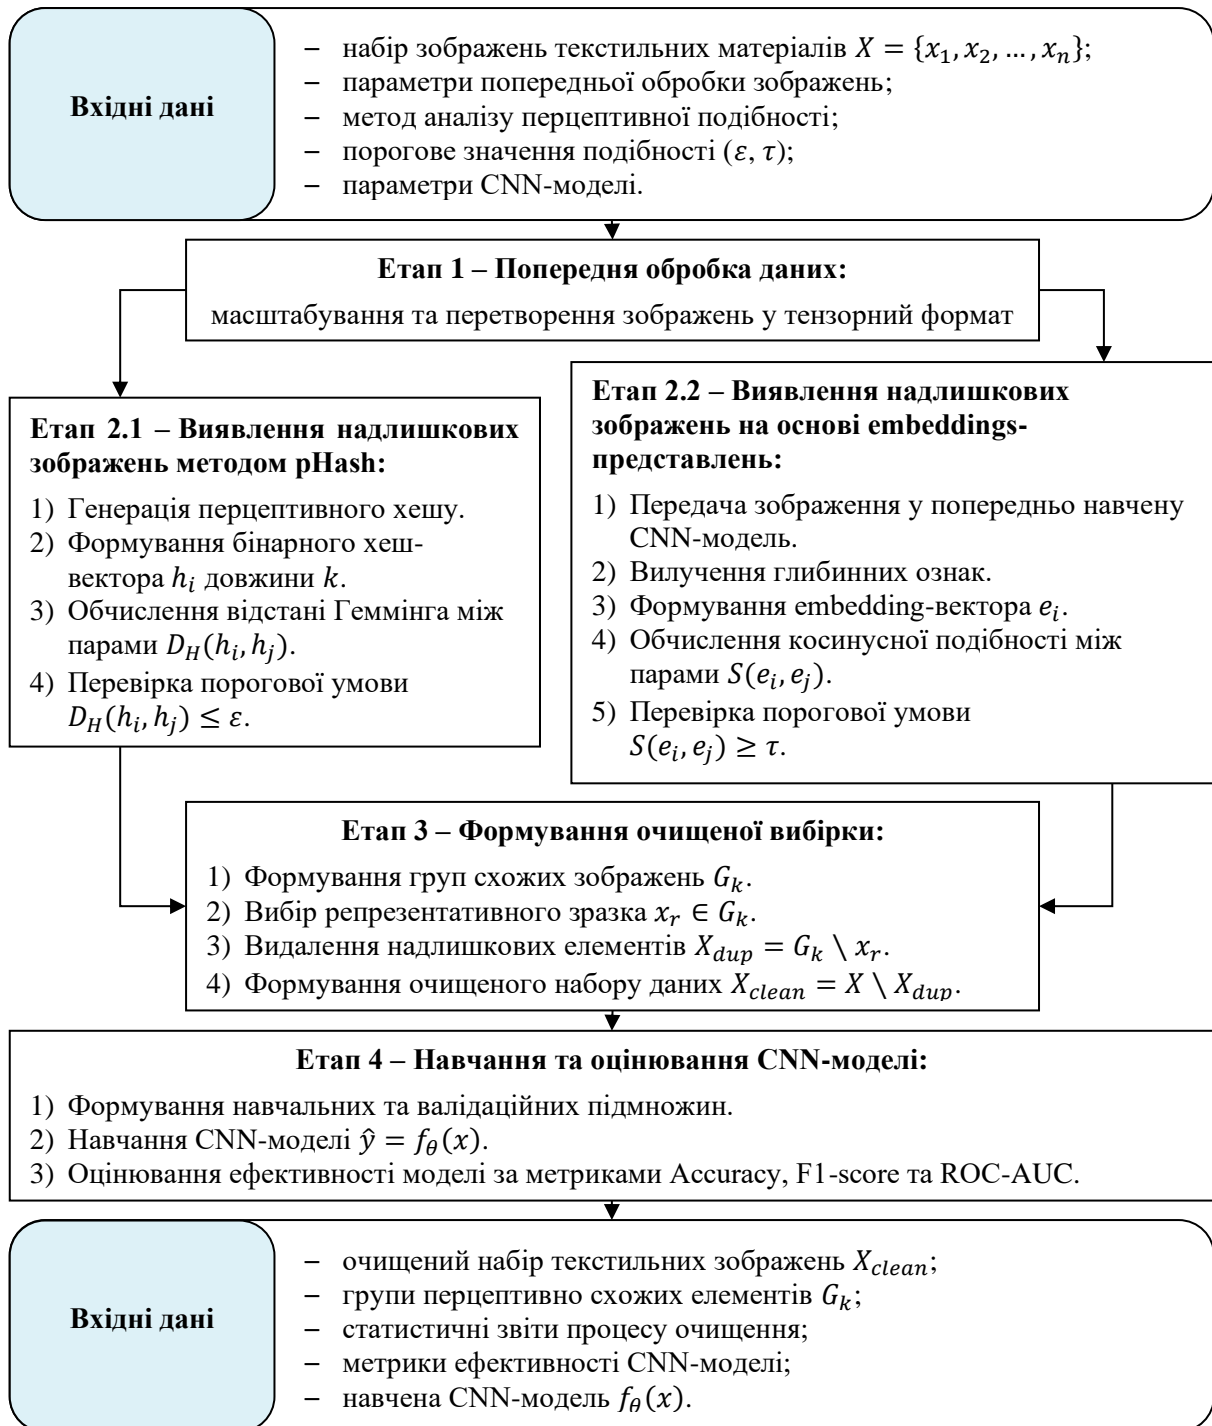


Рисунок 2.2 – Схема та етапи методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості

Етап 1. Попередня обробка даних. На цьому етапі виконується завантаження текстильних зразків із набору даних та перевірка коректності їх зчитування. Оскільки зображення можуть мати різну роздільну здатність, усі файли приводяться до єдиного розміру 224×224 пікселів. Після цього зображення перетворюються у тензорний формат для подальшого аналізу перцептивної подібності між текстильними зразками.

Етап 2. Формування ознакових представлень та оцінювання подібності. Для аналізу використовуються два альтернативні підходи – перцептивне хешування рHash та embeddings-представлення, сформовані згортковою нейронною мережею. У межах цього етапу здійснюється побудова перцептивних хешів і embedding-векторів за поданнями (2.2), (2.3) та (2.6), а також обчислення ступеня подібності між парами зображень за формулами (2.4) і (2.7). Прийняття рішення щодо наявності потенційної надлишковості виконується шляхом перевірки порогових умов за поданнями (2.5) та (2.8).

Етап 3. Формування очищеної вибірки. На цьому етапі на основі аналізу розрахованих раніше значень виявляються перцептивно схожі текстильні зображення. Усі знайдені дублікати автоматично групуються як потенційно надлишкові елементи. З кожної такої групи алгоритм залишає лише одне перше зображення як базовий репрезентативний зразок тканини, а всі інші повторювані копії вилучає з набору даних. Результатом виконання цього етапу є формування очищеної підмножини даних відповідно до подання (2.9), що дозволяє зменшити рівень інформаційної надлишковості вибірки.

Етап 4. Навчання та оцінювання CNN-моделі. На фінальному етапі отриманий очищений набір даних використовується для формування окремих навчальних та валідаційних підмножин. Далі здійснюється безпосереднє тренування класифікатора для розпізнавання сировинного походження текстильних матеріалів. Цей етап завершується розрахунком та оцінюванням ключових метрик ефективності моделі, зокрема Accuracy, F1-score та ROC-AUC, що дозволяє кількісно підтвердити вплив очищення набору даних на результати роботи нейромережевої системи.

У результаті реалізації запропонованого методу забезпечується послідовне виявлення та вилучення перцептивно подібних текстильних зображень із набору даних. Побудований підхід дозволить сформуванню більш репрезентативну вибірку для навчання моделі, зменшити вплив дубльованих зразків на процес класифікації та створити основу для подальшого експериментального дослідження ефективності очищення текстильних датасетів.

2.3 Архітектури нейромережових засобів для аналізу перцептивної схожості та класифікації текстильних зображень

У межах запропонованого методу будуть використовуватись нейромережові засоби двох типів: модель для формування embedding-представлень текстильних зображень та CNN-модель як інструмент оцінювання впливу інформаційної надлишковості набору даних на точність класифікації.

Для побудови embedding-представлень у роботі запропоновано використання попередньо навченої згорткової нейронної мережі ResNet-18. Використання даної архітектури зумовлене її здатністю ефективно формувати узагальнені векторні описи зображень та виявляти складні структурно-текстурні закономірності візуальних даних [29]. Завдяки відносно невеликій кількості параметрів модель забезпечує баланс між точністю аналізу і швидкодією, що є важливим для задач пошуку перцептивно подібних текстильних зразків.

Архітектура ResNet-18 складається з початкового згорткового шару Conv1, шару максимального пулінгу Max Pool та чотирьох послідовних етапів залишкових блоків BasicBlock. У межах мережі використовуються згорткові шари 3×3 , Batch Normalization і функція активації ReLU, а кількість каналів (карт ознак) на кожному етапі поступово збільшується за схемою $64 \rightarrow 128 \rightarrow 256 \rightarrow 512$. Після завершення проходження крізь систему залишкових зв'язків до отриманих карт ознак застосовується шар Global Average Pooling, у результаті чого формується компактне векторне представлення зображення.

Використання моделі як екстрактора ознак передбачає вилучення фінального повнозв'язного класифікаційного шару, щоб на виході мережі утворювався embedding-вектор фіксованої розмірності 512, який використовується для обчислення косинусної міри подібності між текстильними зображеннями та виявлення перцептивно схожих зразків. Архітектуру нейромережі для формування embedding-векторів наведено на рисунку 2.3.

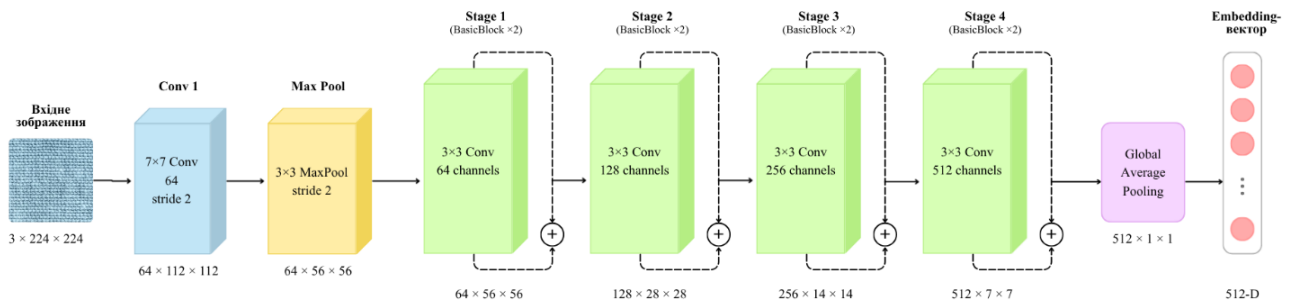


Рисунок 2.3 – Архітектура ResNet-18

Графічна схема відображає загальну структуру архітектури ResNet-18, проте для практичної реалізації процесу формування embedding-представлень необхідно формалізувати послідовність основних обчислювальних операцій. Процес вилучення глибинних ознак виконується ітераційно для всієї множини текстильних зображень та охоплює етапи попередньої обробки даних, прямого поширення через згорткову мережу й нормалізації сформованих векторних представлень. Цикл генерації глибинних представлень наведено в алгоритмі 2.1.

Алгоритм 2.1 – Формування embedding-представлень

Вхідні дані: множина текстильних зображень $X = \{x_1, x_2, \dots, x_n\}$; попередньо навчена модель ResNet-18 без повнозв'язного класифікаційного шару f_{cnn} .

Вихідні дані: Множина сформованих embedding-векторів $E = \{e_1, e_2, \dots, e_n\}$.

1. Ініціалізувати порожню множину embedding-представлень $E = \emptyset$.
2. Для кожного зображення $x_i \in X$ виконувати:
 - Попередню обробку: зміну розміру до 224×224 ; нормалізацію значень пікселів; перетворення у тензор.
 - Передати підготовлене зображення x_i через згорткову основу моделі ResNet-18 згідно з виразом (2.6).
 - Сформувані embedding-вектор: $e_i \in \mathbb{R}^{512}$.
 - Нормалізувати отримане векторне представлення: $e_i = \frac{e_i}{\|e_i\|}$.
 - Додати embedding-вектор e_i до множини E .

3. Кінець циклу.

4. Повернути множину embedding-представлень E .

Для оцінювання впливу надлишковості набору даних на точність розпізнавання у межах запропонованого підходу пропонується використання власної згорткової нейронної мережі. Вибір індивідуального методу замість використання глибоких стандартних моделей зумовлений необхідністю забезпечення високої чутливості до змін якості набору даних. На відміну від складних нейромережевих архітектур із великою кількістю параметрів, спрощена CNN-модель дозволяє більш об'єктивно оцінювати вплив перцептивно схожих зображень на здатність мережі узагальнювати ознаки текстильних матеріалів та коректно виконувати класифікацію нових зразків.

Оскільки у роботі передбачено багаторазове перенавчання моделі для порівняння різних рівнів жорсткості дедуплікації даних, запропонована структура дозволяє мінімізувати витрати часу та обчислювальних ресурсів. Використання даного алгоритму дає змогу зосередити дослідження саме на впливі якості та структури набору даних на результати нейромережевої класифікації. Архітектуру моделі наведено на рисунку 2.4.

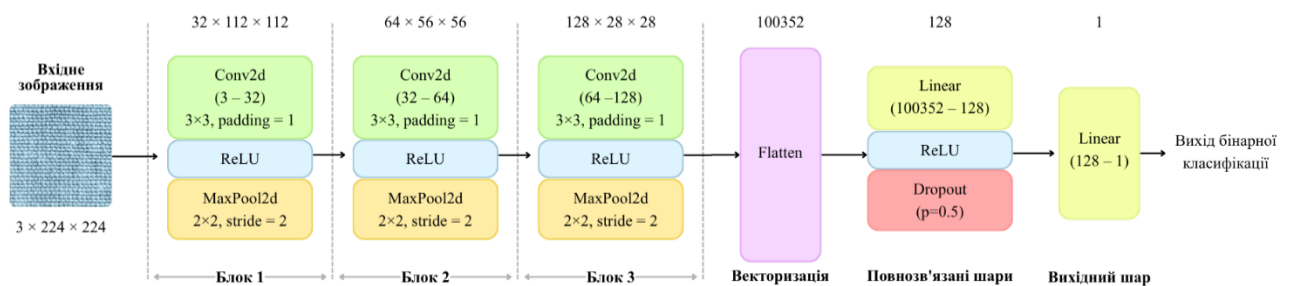


Рисунок 2.4 – Архітектура CNN-моделі

Архітектура складається з трьох послідовних згорткових блоків, кожен із яких містить згортковий шар Conv2D, функцію активації ReLU та шар максимального пулінгу MaxPool2D. Згорткові шари використовуються для автоматичного виділення ознак текстильних зображень, тоді як pooling-шари забезпечують поступове зменшення просторової розмірності карт ознак та зниження обчислювальної складності моделі. Кількість каналів у мережі послідовно збільшується за схемою $32 \rightarrow 64 \rightarrow 128$, що дозволяє формувати ознаки різного рівня складності.

Після завершення згорткової обробки виконується операція Flatten, у результаті якої багатовимірні карти ознак перетворюються у векторне представлення фіксованої розмірності та передається до повнозв'язаного шару Fully Connected із 128 нейронами. Для зменшення ризику перенавчання після першого повнозв'язаного шару застосовується Dropout із коефіцієнтом 0.5. На завершальному етапі використовується вихідний шар із одним нейроном, який формує результат бінарної класифікації текстильних зображень.

Архітектура розробленої CNN-моделі визначає послідовність обробки текстильних зображень під час прямого поширення сигналу через її згорткові та повнозв'язані шари. Для практичної реалізації й автоматизації процесу багаторазового навчання класифікатора на різних варіантах очищених наборів даних сформовано алгоритм 2.2.

Алгоритм 2.2 – Навчання моделі для класифікації текстильних зображень

Вхідні дані: Набір текстильних зображень X ; кількість епох навчання N ; швидкість навчання α ; розмір batch-вибірки B ; CNN-модель f_θ .

Вихідні дані: Навчена модель f_θ ; вагові коефіцієнти моделі W ; метрики класифікації.

1. Виконати попередню обробку набору зображень X : масштабування до розміру 224×224 ; нормалізацію значень пікселів; перетворення у тензор.
2. Розділити набір даних X на $K = 5$ fold-підмножин.
3. Для кожного *fold* F_k виконувати:
 - Сформуванати навчальну X_{train} та валідаційну X_{val} підмножини.
 - Ініціалізувати CNN-модель f_θ .
 - Ініціалізувати оптимізатор Adam з параметром α та функцію втрат $L = BCEWithLogitsLoss$.
 - Для кожної епохи $t = 1 \dots N$:
 - Передати batch-зображення x_i у модель $\hat{y} = f_\theta(x_i)$.
 - Обчислити функцію втрат: $L = BCEWithLogitsLoss(y, \hat{y})$.
 - Виконати зворотне поширення помилки: $\frac{\partial L}{\partial W}$.

- Оновити ваги моделі W за допомогою оптимізатора.
- Кінець циклу епох.
- Оцінити модель на підмножині X_{val} за метриками Accuracy, F1-score та ROC-AUC за умови $p = \text{sigmoid}(z)$.

4. Кінець циклу крос-валідації.

5. Зберегти вагові коефіцієнти моделі W .
6. Повернути навчену CNN-модель f_θ та результати класифікації.

Запропонована схема крос-валідації забезпечує стійкість процесу оптимізації та дозволяє зменшити ризик перенавчання під час роботи з обмеженими або специфічними вибірками текстильних зразків. Такий підхід підвищує об'єктивність і статистичну надійність отриманих результатів та створює умови для коректного порівняльного аналізу узагальненої здатності нейронної моделі за різних рівнів дедуплікації даних.

Таким чином, використання запропонованих нейромережових засобів дозволяє реалізувати один із методів виявлення перцептивно подібних текстильних зображень та виконати дослідження інформаційної надлишковості набору даних на точність класифікації.

2.4 Підготовка робочих вхідних даних для системи

Для дослідження впливу надлишковості текстильних зображень на результати нейромережової класифікації було обрано набір даних «Natural and synthetic fabrics dataset» [30], розміщений на платформі Kaggle [31].

Набір даних містить 3107 мікрозображень, розподілених на матеріали натурального походження (1547) та матеріали синтетичного походження (1560). Зображення отримані з лицьового та зворотного боків тканини, а також в умовах незначних деформацій матеріалу, що забезпечує варіативність вхідної інформації та створює складніші умови для задач автоматичного розпізнавання образів. Приклади мікроструктур досліджуваних зразків наведено на рисунку 2.5.

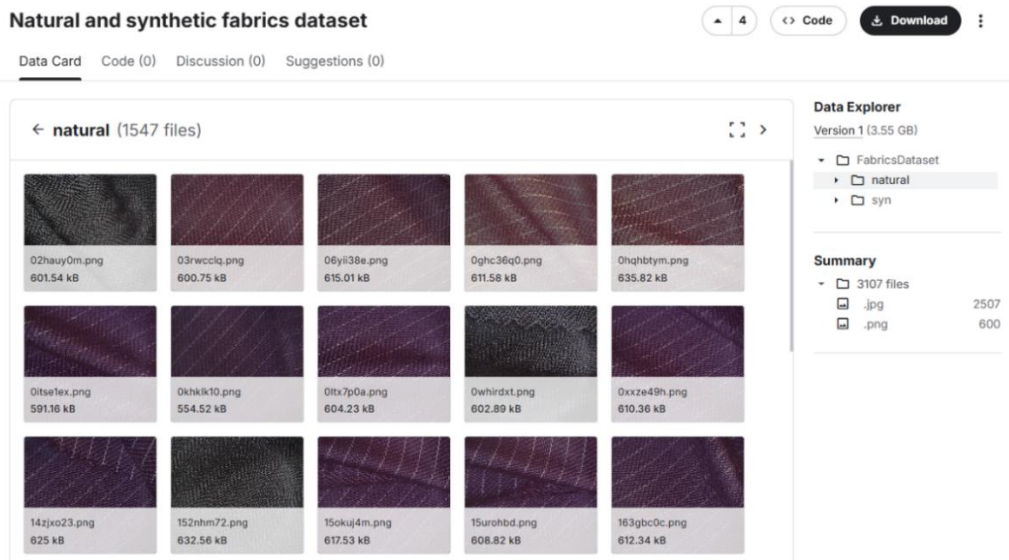


Рисунок 2.5 – Приклад даних набору «Natural and synthetic fabrics dataset» [30]

Важливою характеристикою обраного набору даних є первинна збалансованість його структури. Розподіл зображень між класами є майже рівномірним, що мінімізує ризик зміщення ваг CNN-моделі у бік мажоритарного класу під час навчання та зменшує ймовірність виникнення помилок класифікації.

З метою детального оцінювання геометричних параметрів вхідної інформації було ведено попередній статистичний аналіз структури оригінального датасету. На рисунку 2.6 наведено розроблений аналітичний профіль вибірки, який ілюструє точне співвідношення класів, а також розподіл початкових текстильних зображень за їх просторовою роздільною здатністю до моменту масштабування.

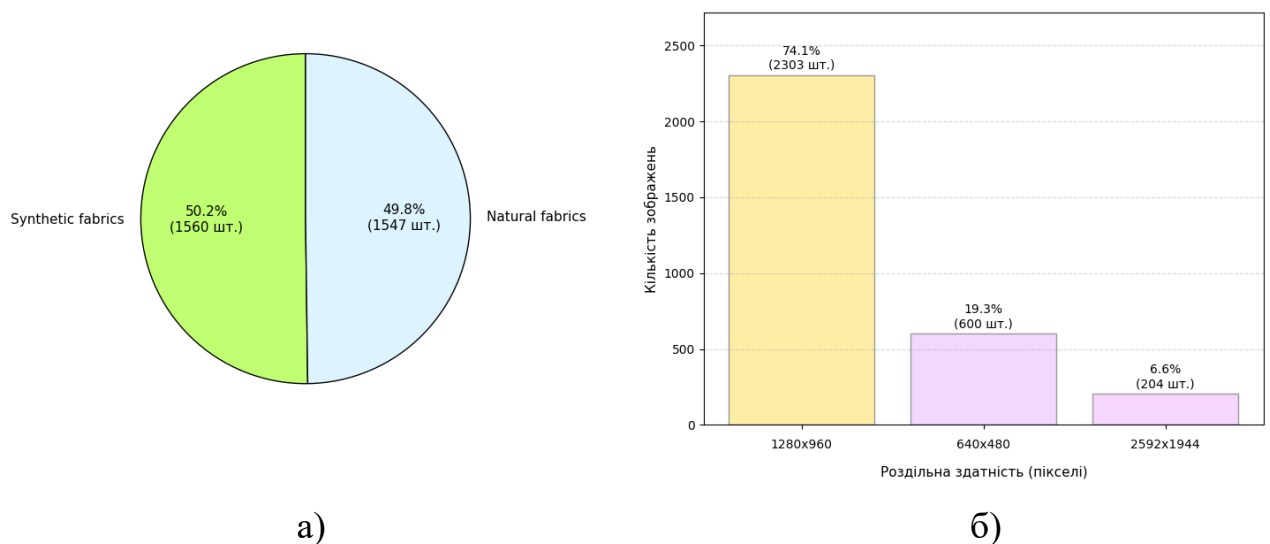


Рисунок 2.6 – Статистичний аналіз: а) співвідношення класів; б) розподіл зображень за їх просторовою роздільною здатністю

Аналіз наведених геометричних параметрів свідчить про те, що початкові знімки мають різну просторову розмірність та співвідношення сторін. З огляду на це, методика підготовки текстильних зображень для забезпечення сумісності з архітектурами нейромереж ResNet-18 (для вилучення ознак) та CNN-моделі (для класифікації) передбачає обов'язкову статичну попередню обробку даних. Ця процедура є однаковою для всіх етапів дослідження та складається з трьох послідовних кроків: масштабування знімків до уніфікованого розміру 224×224 пікселі, нормалізацію та конвертацію у тензорний формат.

Ключовою особливістю цього дослідження є етап теоретичного обґрунтування та подальшої фільтрації інформаційної надлишковості у сформованому масиві даних. На основі базового набору мікрозображень заплановано побудову серії модифікованих підмножин, очищення яких від дублікатів здійснюватиметься ітераційно із застосуванням алгоритмів перцептивного хешування та аналізу глибоких векторних представлень для різних порогів схожості. Отримані таким чином експериментальні вибірки дозволять провести комплексний порівняльний аналіз та оцінити динаміку зміни точності класифікації в умовах мінімізації дублюючої інформації.

Отже, обраний набір даних та запропонований підхід до його попередньої обробки й дедуплікації створюють необхідні умови для дослідження впливу інформаційної надлишковості текстильних зображень на кінцеві результати нейромережевого розпізнавання.

2.5 Метрики оцінювання точності нейромережевих моделей

Для об'єктивного оцінювання якості роботи запропонованих підходів до виявлення надлишковості текстильних зображень та дослідження їх впливу на результати нейромережевої класифікації доцільно використовувати комплексний набір метрик машинного навчання. Оскільки задача розпізнавання текстильних матеріалів є бінарною, базою для розрахунку аналітичних показників виступає матриця помилок (Confusion Matrix), яка враховує такі значення:

– TP (*True Positives*) – кількість правильно визначених позитивних результатів.

– TN (*True Negatives*) – кількість правильно визначених негативних результатів.

– FP (*False Positives*) – кількість хибнопозитивних результатів.

– FN (*False Negatives*) – кількість хибнонегативних результатів.

Головним критерієм для визначення загальної ефективності нейронної мережі виступає *Accuracy* [32]. Дана метрика визначає частку правильно класифікованих зображень серед загальної кількості елементів вибірки:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.10)$$

Оскільки досліджуваний набір даних є збалансованим (частки класів близькі до 50%), метрика *Accuracy* планується до використання як первинний індикатор успішності навчання. У сучасних дослідженнях, присвячених аналізу текстур і автоматизованому розпізнаванню текстильних матеріалів, систему оцінювання доповнюють метриками *Precision* та *Recall* для комплексного визначення ефективності DL-моделей [33].

Метрика *Precision* характеризує частку правильно визначених позитивних результатів серед усіх позитивних прогнозів моделі:

$$Precision = \frac{TP}{TP + FP} \quad (2.11)$$

Метрика *Recall* відображає здатність моделі виявляти елементи позитивного класу та визначає частку правильно знайдених позитивних результатів:

$$Recall = \frac{TP}{TP + FN} \quad (2.12)$$

Покращення одного з наведених показників часто супроводжується погіршенням іншого і тому для отримання збалансованого критерію оцінювання використовують інтегральну метрику *F1-score*. Вона визначається як гармонійне середнє між *Precision* та *Recall*, забезпечуючи об'єктивний аналіз ефективності створених моделей [34]:

$$F1 = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall} \quad (2.13)$$

Для додаткового аналізу якості класифікації використовується метрика ROC-AUC, яка характеризує здатність моделі розділяти класи та оцінювати якість прогнозів. Високе значення ROC-AUC у межах, близьких до 1, свідчитиме про кращу здатність моделі відокремлювати класи текстильних матеріалів та узагальнювати результати на нових даних.

Через використання 5-Fold крос-валідації виникає потреба в оцінюванні стабільності й відтворюваності результатів. З цією метою для базового показника точності передбачено розрахунок математичного очікування (середнього значення) та середнього квадратичного відхилення [35], що записуються у вигляді $Mean \pm Std$.

Середнє значення Mean виступає інтегральним критерієм ефективності архітектури на п'яти різних валідаційних підмножинах і обчислюється за формулою:

$$Mean = \bar{x} = \frac{1}{K} \sum_{i=1}^K x_i, \quad (2.14)$$

де $K = 5$ – кількість фолдів крос-валідації, а x_i – значення метрики Ассурасу, отримане на i -му фолді навчання.

Для оцінювання мінливості результатів та чутливості моделі до випадкового розщеплення даних розраховується середнє квадратичне відхилення Std, яке визначає ступінь розсіювання отриманих значень точності навколо їхнього середнього арифметичного:

$$Std = \sigma = \sqrt{\frac{1}{K} \sum_{i=1}^K (x_i - \bar{x})^2} \quad (2.15)$$

Величина середнього квадратичного відхилення відображає рівень стабільності та відтворюваності результатів навчання. Близькі до нуля значення підтверджують надійність моделі та її незалежність від випадкового розподілу вхідних знімків. Якщо ж після очищення даних від надлишковості цей показник зростає, це сигналізує про нестабільність класифікатора, зумовлену втратою унікальних характеристик текстур або перенавчанням моделі.

Таким чином, сформований комплекс метрик забезпечує об'єктивний аналіз якості розпізнавання текстур та дозволяє математично оцінити, як саме ступінь дедуплікації вхідних зображень впливає на точність і стабільність навчання нейронної мережі.

2.6 Сценарій експериментів з валідації розробленого методу

Для об'єктивного підтвердження ефективності запропонованого методу виявлення надлишкових даних та оцінювання його впливу на точність нейромережевого розпізнавання передбачено проведення комплексної серії валідаційних експериментів. Метою цього етапу є дослідження того, як саме ітераційне вилучення перцептивно схожих текстильних зображень за різних порогових значень критеріїв подібності впливатиме на точність, узагальнювальну здатність та стабільність навчання класифікатора.

Для перевірки гіпотези про те, що видалення прихованої візуальної надлишковості покращує якість класифікації або щонайменше зберігає її на початковому рівні за суттєвого зменшення обсягу вибірки, сценарій передбачає виконання серії порівняльних експериментів. Конфігурацію запланованих досліджень деталізовано у таблиці 2.1.

Для забезпечення коректності порівняння всі експериментальні сценарії виконуватимуться за однакових параметрів функціонування класифікатора. У межах дослідження використовуватиметься одна й та сама архітектура CNN-моделі, а зміна результатів розпізнавання аналізуватиметься виключно як наслідок модифікації структури набору даних після застосування процедур дедуплікації.

Запланована послідовність виконання експериментальних досліджень передбачає поетапне порівняння результатів базового моделювання та мереж, навчених після попереднього очищення масиву даних. На першому етапі виконується навчання класифікатора на початковому наборі даних без застосування процедур дедуплікації (серія E-0), що дозволяє сформувати базову лінію порівняння для подальшого аналізу. Наступним кроком здійснюється послідовне формування модифікованих підмножин даних за допомогою методів rHash (серія E-1) та глибоких векторних представлень (серія E-2). Для кожного експериментального сценарію обов'язково фіксується кількість вилучених зображень та підсумковий ступінь скорочення вибірки.

Таблиця 2.1 – Сценарій порівняльних експериментів

№	Метод фільтрації	Поріг	Цільове призначення
E-0	Без фільтрації	-	Оцінювання базової точності моделі на повному наборі даних.
E-1.1	Алгоритм рHash	$\varepsilon = 6$	Фільтрація зображень із високим ступенем візуальної подібності та вилучення явних дублікатів.
E-1.2	Алгоритм рHash	$\varepsilon = 8$	Помірне проріджування вибірки та видалення стійких структурних повторів мікроструктури.
E-1.3	Алгоритм рHash	$\varepsilon = 10$	Глибоке очищення схожих текстур, аналіз критичної межі збереження корисних ознак.
E-2.1	Глибокі векторні представлення	$\tau = 0.985$	Вилучення дублікатів та семантично близьких зображень у високорозмірному просторі ознак.
E-2.2	Глибокі векторні представлення	$\tau = 0.990$	Високоточна фільтрація графічних даних, ідентифікованих у щільних кластерах представлень.
E-2.3	Глибокі векторні представлення	$\tau = 0.995$	Видалення майже ідентичних залишків і повних візуальних копій тканин.

Після завершення процедури фільтрації кожна сформована підмножина окремо використовується для повторного навчання CNN-моделі зафіксованою кількістю епох. Порівняльний аналіз результатів між експериментальними серіями дозволить оцінити вплив різних рівнів очищення набору даних на точність класифікації та стабільність нейромережових обчислень. Особлива увага приділятиметься аналізу динаміки середніх значень метрик Accuracy, F1-score та ROC-AUC, а також величини стандартного відхилення між фолдами крос-валідації, що безпосередньо характеризує рівень узагальнювальної здатності та стабільності побудованої системи.

Таким чином, запропонований сценарій дозволить отримати математично обґрунтовану доказову базу для оцінювання розробленого методу. Пряме зіставлення отриманих аналітичних метрик у наочній формі продемонструє досягнення встановленої мети дослідження та підтвердить стійкість розпізнавання текстильних матеріалів.

2.7 Висновки до розділу 2

У другому розділі було розроблено метод виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості для підвищення достовірності нейромережевої класифікації. Проведено формалізацію задачі виявлення подібних елементів, де візуальна близькість визначається через відстань Геммінга для рHash та косинусну міру подібності для embedding-представлень. Запропоновано узагальнену схему реалізації методу та математичне представлення процедури дедуплікації набору текстильних зображень.

Обґрунтовано вибір архітектур інтелектуальних засобів системи: модель ResNet-18 адаптовано як екстрактор ознак для генерації embedding-векторів, а для оцінювання впливу очищення даних розроблено власну CNN-модель класифікації текстильних матеріалів. Наведено математичний псевдокод алгоритмів формування embedding-представлень та навчання класифікатора.

Підготовлено робочий набір даних «Natural and synthetic fabrics dataset», визначено етапи попередньої обробки зображень та сформовано підхід до побудови модифікованих підмножин із різними пороговими значеннями критеріїв схожості. Також визначено комплекс метрик Accuracy, F1-score та ROC-AUC для оцінювання ефективності класифікації та розроблено сценарій експериментальної валідації запропонованого методу.

Розділ 3 Експериментальне дослідження методу виявлення надлишкових даних у наборах текстильних зображень

3.1 Засоби розробки системи аналізу надлишковості текстильних зображень

Процес розробки системи аналізу надлишковості візуальних даних потребує застосування сучасних інструментів, що спеціалізуються на цифровій обробці зображень, машинному навчанні та реалізації інтелектуальних алгоритмів. Для досягнення поставленої мети було обрано стек технологій, який забезпечує ефективну обробку великих наборів графічних даних та підтримує реалізацію, навчання та дослідження нейромережевих моделей.

Основною мовою програмування для проектування інтелектуальної системи було обрано Python [36], що зумовлено його широким використанням у сферах машинного навчання та комп'ютерного зору. Мова характеризується високою читабельністю коду, простотою інтеграції компонентів і наявністю спеціалізованих бібліотек для роботи з візуальними даними. Для побудови та тренування нейронних мереж використано фреймворк глибокого навчання PyTorch [37], який базується на концепції динамічних обчислювальних графів, що дозволяє модифікувати архітектуру мережі безпосередньо під час виконання коду, значно спрощує налагодження програмних модулів та забезпечує високу швидкість розробки.

Засоби PyTorch використовувались не лише для фінального розпізнавання текстильних зображень, а й для формування векторних представлень на етапі пошуку візуально схожих структур матеріалу. Поєднання цих інструментів забезпечило можливість наскрізного проектування системи, а саме від вилучення ознак за допомогою ResNet-18 до проведення експериментального дослідження впливу очищення датасетів на кінцеву точність результатів.

Для виконання математичних операцій над багатовимірними масивами та тензорами стек технологій було розширено фундаментальною бібліотекою NumPy [38], а для автоматизації процедури 5-Fold крос-валідації та швидкого

розрахунку валідаційних метрик (зокрема інтегрального показника ROC-AUC) впроваджено інструменти бібліотеки scikit-learn [39].

Окрім основних фреймворків глибокого навчання, для реалізації алгоритмів дедуплікації було використано бібліотеку ImageHash [40] у поєднанні з Pillow [41]. Цей інструментарій дозволив впровадити метод перцептивного хешування для швидкого пошуку візуально схожих зображень за їхніми цифровими відбитками. Для роботи з табличними даними, збереження результатів експериментів і метрик класифікації використано бібліотеку Pandas [42], а для побудови графіків та візуалізації результатів дослідження – Matplotlib [43]. Графічний інтерфейс інформаційно-аналітичного застосунку реалізовано з використанням фреймворку PyQt5 [44], що забезпечує інтерактивний перегляд результатів дедуплікації, аналіз метрик класифікації та порівняння ефективності досліджуваних методів.

Як середовище розробки використовувалося Visual Studio Code [45], яке забезпечує зручну роботу з Python-проєктами, підтримку віртуальних середовищ, встановлення залежностей та налагодження програмного коду.

Таким чином, обраний стек технологій забезпечив реалізацію інтелектуальної системи для дослідження надлишковості текстильних зображень, проведення експериментального аналізу та оцінювання впливу очищення наборів даних на точність нейромережевої класифікації.

3.2 Опис інтелектуальної системи для дослідження методу

Для представлення результатів проведених експериментальних досліджень було реалізовано інтелектуальну систему, призначену для візуалізації процесів дедуплікації текстильних зображень та аналізу впливу інформаційної надлишковості набору даних на результати нейромережевої класифікації. Основною метою системи є забезпечення зручного перегляду результатів експериментів, порівняння ефективності різних методів очищення та відображення отриманих метрик класифікації.

Запуск створеного програмного забезпечення здійснюється шляхом виконання головного файлу застосунку у середовищі Python, після чого користувачеві відкривається стартове вікно графічного інтерфейсу, загальний вигляд якого представлено на рисунку 3.1.

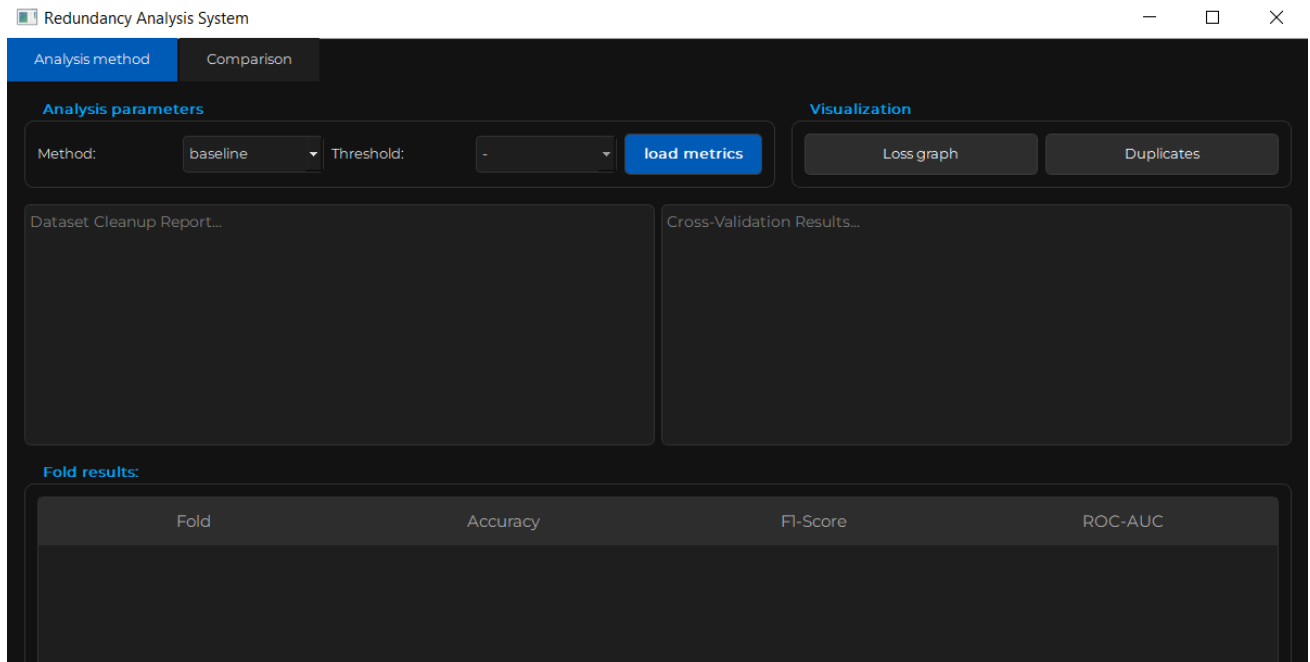


Рисунок 3.1 – Головне вікно системи аналізу надлишковості

Робочий простір інтерфейсу розділено на дві функціональні вкладки:

- Analysis method – для детального аналізу окремого методу очищення.
- Comparison – для глобального порівняння результатів.

За допомогою інтерактивних елементів керування у блоці «Analysis parameters» користувач може обрати метод визначення схожості та встановити відповідний числовий поріг, який визначає критерій віднесення зображень до групи дубльованих. Після активації кнопкою «load metrics» застосунок відображає узагальнені статистичні показники дослідження (рисунок 3.2).

У лівій частині інтерфейсу відображаються основні характеристики процесу очищення набору даних, зокрема загальна кількість зображень у початковій вибірці, число сформованих груп перцептивної схожості, кількість вилучених елементів та підсумкова частка усуненої надлишковості у відсотковому співвідношенні. Додатково система виводить мінімальний, максимальний та середній розмір груп подібності, що дозволяє оцінити характер розподілу дубльованих даних у вибірці.

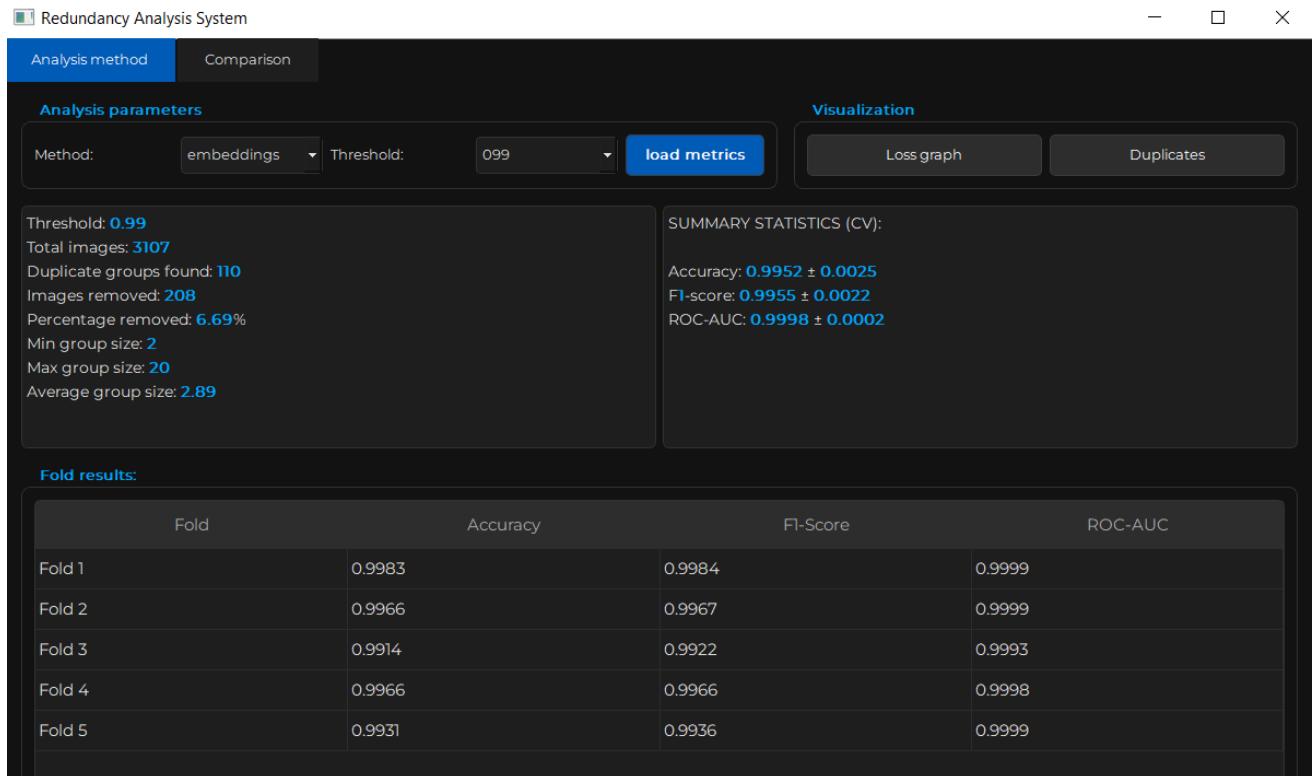


Рисунок 3.2 – Відображення результатів аналізу

У правій частині інтерфейсу розміщено блок узагальненої статистики крос-валідації, який містить середні значення метрик Accuracy, F1-score та ROC-AUC разом із обчисленими інтервалами стандартного відхилення. Нижня область вкладки відведена під таблицю «Fold results», де наведено деталізовані результати оцінювання CNN-моделі окремо для кожного fold у межах процедури 5-Fold крос-валідації.

Для візуального контролю коректності роботи математичних алгоритмів в інтерфейсі передбачено вікно перегляду прикладів груп перцептивно схожих текстильних зображень (рисунок 3.3). З метою забезпечення зручності аналізу та уникнення перевантаження інтерфейсу для кожного досліджуваного методу зберігаються та відображаються перші десять груп дубльованих зображень. Таке рішення дозволяє наочно оцінити характер виявленої схожості та перевірити чутливість алгоритмів до незначних змін освітлення, масштабу чи зміщення ракурсу мікрозйомки, допущених під час формування початкового датасету.




Рисунок 3.3 – Приклад груп перцептивно схожих зображень

Окрема вкладка «Comparison» призначена для порівняльного аналізу результатів усіх експериментальних сценаріїв очищення набору даних (рисунок 3.4). У цьому режимі застосунок автоматично узагальнює та відображає результати базового навчання, а також показники, отримані після застосування різних методів дедуплікації за відповідних порогових значень критеріїв схожості.

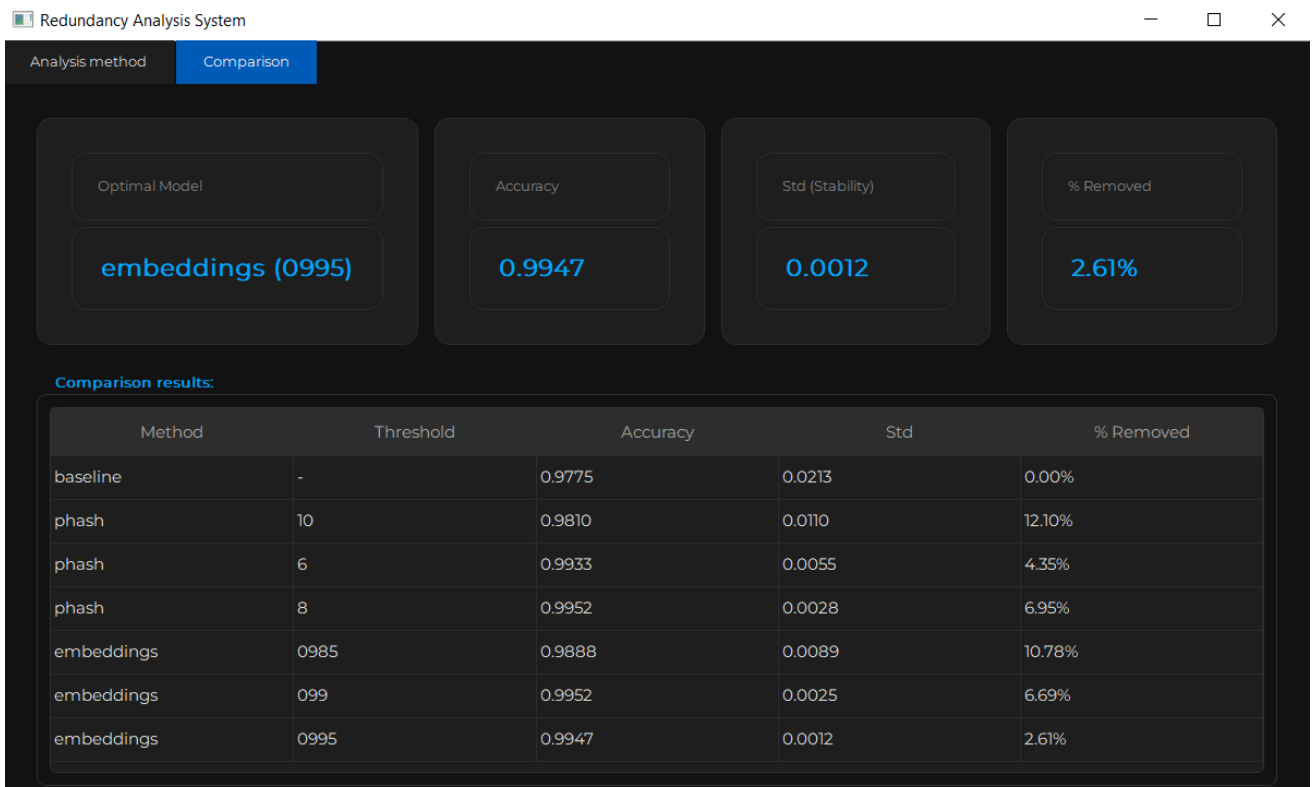


Рисунок 3.4 – Вкладка глобального порівняння результатів

У верхній частині вкладки система в автоматичному режимі ідентифікує та акцентує увагу на оптимальній конфігурації даних, яка продемонструвала найкраще співвідношення узагальнювальної здатності моделі та стабільності результатів на фолдах крос-валідації. У відповідному інформаційному блоці відображаються назва найкращого методу дедуплікації, встановлений для нього поріг схожості, підсумкова середня точність розпізнавання, стандартне відхилення та частка вилучених із вибірки зображень.

Нижня частина вкладки призначена для графічного представлення результатів дослідження (рисунк 3.5).



Рисунок 3.5 – Графічне порівняння результатів для різних методів очищення

Візуалізований графічний модуль формує дві взаємопов'язані аналітичні залежності. Верхня гістограма ілюструє середні значення точності та стабільності класифікації для всіх семи експериментальних сценаріїв, де

вертикальні лінії похибок відповідають стандартному відхиленню на фолдах крос-валідації, а оптимальна конфігурація автоматично маркується червоним кольором. Нижня лінійна залежність відображає зміну метрики точності залежно від відсотка вилучених із вибірки надлишкових зображень для методів перцептивного хешування (синя крива) та векторних представлень (червона крива) відносно контрольної точки baseline.

Таким чином, розроблена інтелектуальна система забезпечує повний функціональний цикл від локального перегляду статистики окремого методу дедуплікації до комплексного порівняння та обґрунтованого вибору оптимальної стратегії фільтрації даних.

3.3 Результати досліджень

Для оцінювання ефективності розробленого методу виявлення надлишковості та визначення його впливу на результати нейромережевої класифікації текстильних матеріалів проведено серію експериментальних досліджень. З урахуванням особливостей структури набору даних основну увагу приділено аналізу впливу перцептивно схожих і дубльованих зображень на узагальнювальну здатність згорткової нейронної мережі. Основною гіпотезою роботи є припущення, що значна кількість візуально подібних прикладів може негативно впливати на здатність моделі коректно класифікувати нові зразки.

Для перевірки цієї гіпотези та формування базової лінії порівняння (Baseline) на першому етапі дослідження було виконано навчання згорткової нейронної мережі на повному наборі даних без попереднього очищення від дублікатів. Отримані результати використовуються як контрольні значення для подальшого аналізу ефективності методів дедуплікації текстильних зображень.

Навчання моделі проводилося із застосуванням 5-кратної перехресної перевірки. Для кожного fold обчислювалися показники Accuracy, F1-score та ROC-AUC, після чого визначалися їхні фінальні середні значення та стандартне відхилення, що відображає рівень дисперсії.

Статистичні характеристики базового навчання наведено в таблиці 3.1.

Таблиця 3.1 – Результати навчання базової моделі

Fold	Accuracy	F1-score	ROC-AUC
1	0.9952	0.9951	0.9992
2	0.9743	0.9746	0.9978
3	0.9984	0.9984	1.0000
4	0.9807	0.9814	1.0000
5	0.9388	0.9352	0.9994
Mean \pm Std	0.9775 \pm 0.0213	0.9769 \pm 0.0226	0.9993 \pm 0.0008

Отримані результати свідчать про високий рівень класифікації вже на базовій вибірці. Середнє значення ROC-AUC наближене до 1, що вказує на хорошу здатність моделі розділяти класи.

Для ілюстрації процесу навчання на рисунку 3.6 наведено динаміку зміни функції втрат для кожного fold у межах 5-кратної крос-валідації.




Рисунок 3.6 – Динаміка зміни функції втрат під час навчання (Baseline)

Аналіз отриманого графіка показує, що впродовж навчання для всіх fold спостерігається стабільне зменшення значення функції втрат. Найбільш інтенсивне зниження loss відбувається на початкових епохах, після чого процес

навчання поступово переходить у стадію збіжності. Разом із цим наявність стандартного відхилення для метрик Accuracy та F1-score свідчить про певну варіативність результатів між окремими fold, що може бути пов'язано з неоднорідністю вибірки та наявністю схожих або надлишкових прикладів, які потенційно впливають на процес узагальнення.

На другому етапі дослідження було оцінено ефективність методу перцептивного хешування rHash для виявлення візуально схожих або дубльованих зображень у наборі даних. У межах експериментів схожість між зразками визначалась на основі відстані Геммінга між їхніми rHash-відбитками. Чим меншим є порогове значення, тим жорсткішим стає критерій відбору, оскільки до однієї групи потрапляють майже ідентичні зображення. Зі збільшенням порогу алгоритм починає враховувати ширший спектр візуально подібних прикладів, включаючи зразки з незначними текстурними або геометричними відмінностями. Для оцінювання того, як саме жорсткість цього критерію впливає на якість моделі, було протестовано три значення порогу: 6, 8 та 10 (таблиця 3.2).

Таблиця 3.2 – Результати дедуплікації набору даних методом rHash

Поріг	Кількість груп	Видалено зображень	Частка видалених, %
6	108	135	4.35%
8	150	216	6.95%
10	190	376	12.10%

Між зростанням числового порогу та кількістю вилючених зображень існує чітка пряма залежність. При мінімальному порозі $\text{threshold} = 6$ відсікаються лише найближчі візуальні копії, що становлять 4.35% від загального обсягу датасету. Розширення радіуса пошуку дублікатів до $\text{threshold} = 10$ призводить до видалення вже 12.10% зображень, що вказує на суттєву зміну щільності розподілу даних у сформованій вибірці.

Після процедури фільтрації для кожної з трьох модифікованих підмножин було проведено повний цикл навчання тієї ж CNN-моделі за аналогічною схемою 5-кратної крос-валідації. Оцінювання ефективності класифікації

проводилося за метриками Accuracy, F1-score та ROC-AUC. Результати навчання після застосування методу pHash наведено у таблиці 3.3.

Таблиця 3.3 – Метрики класифікації після очищення методом pHash

Попіг	Accuracy	F1-score	ROC-AUC	Std
6	0.9933	0.9932	0.9996	± 0.0055
8	0.9952	0.9954	0.9995	± 0.0028
10	0.9810	0.9833	0.9992	± 0.0110

Для кращого розуміння отриманих результатів на рисунку 3.7 наведено узагальнений графік, який відображає, як саме змінюється точність моделі та інтенсивність очищення вибірки залежно від обраного порогу.

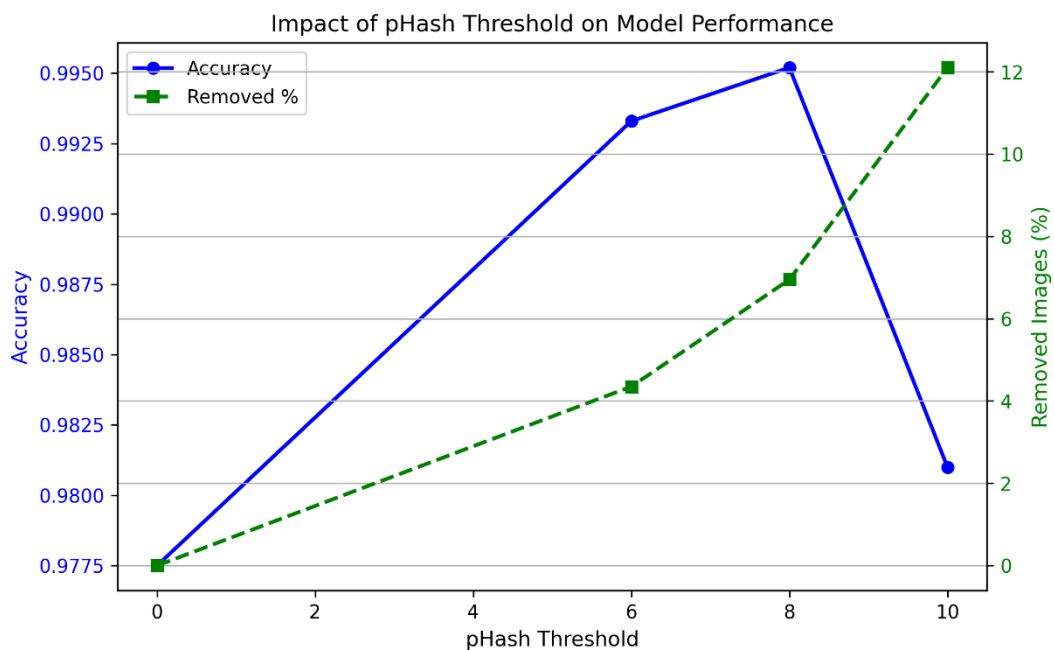


Рисунок 3.7 – Вплив значення порогу pHash на точність моделі та частку видалених зображень

Отриманні результати свідчать про те, що помірне очищення набору даних позитивно впливає на узагальнюючу здатність НМ. При встановленні порогів 6 та 8 спостерігається чітке зростання показників Accuracy та F1-score порівняно з базовим сценарієм. Найкращі аналітичні показники було зафіксовано при пороговому значенні 8, що свідчить про досягнення оптимального балансу між усуненням інформаційної надлишковості та збереженням інформативного різноманіття текстильних зображень.

Водночас подальше підвищення порогу до 10 призводить до помітного зниження Ассигасу та стрімкого зростання похибки. Така тенденція пояснюється надмірною жорсткістю фільтрації, через яку алгоритм rNash починає сприймати унікальні візуальні структури різних тканин як дублікати. Це призводить до значної втрати корисних варіацій текстур необхідних для стабільного узагальнення ознак текстильних матеріалів.

На наступному етапі дослідження було реалізовано альтернативний підхід до виявлення надлишкових зображень, який базується на аналізі глибинних ознак. Ступінь схожості між текстильними зразками визначався за допомогою метрики косинусної подібності. Зображення вважалися дубльованими, якщо значення косинусної подібності між їхніми embeddings перевищувало задану межу. Для оцінювання впливу жорсткості цього підходу було досліджено три значення порогу: 0.985, 0.99 та 0.995.

На відміну від алгоритму перцептивного хешування, у цьому випадку більше значення порогу означає суворіший і точніший критерій схожості. Тобто при порозі 0.995 дублікатами визнаються лише майже ідентичні знімки, тоді як при зниженні порогу до 0.985 до груп копій потрапляють зразки з більш помітними текстурними чи колірними відмінностями. Кількісні параметри очищення вибірки наведено в таблиці 3.4.

Таблиця 3.4 – Результати дедуплікації набору даних методом embedding-представлень

Поріг	Кількість груп	Видалено зображень	Частка видалених, %
0.985	147	335	10.78%
0.99	110	208	6.69%
0.995	65	81	2.61%

З наведених даних видно, що зі зменшенням числового значення порогу кількість виявлених схожих зображень та інтенсивність очищення вибірки зростають. При порозі 0.995 алгоритм діє максимально обережно й видаляє лише 2.61% даних, тоді як зниження порогу до 0.985 активізує процес фільтрації, вилучаючи вже 10.78% зображень.

Після завершення процедури очищення проведено повторне оцінювання CNN-моделі на сформованих підмножинах даних. Якість класифікації визначалася за аналогічними метриками, що використовувалися під час аналізу методу перцептивного хешування. Результати експериментальних досліджень наведено у таблиці 3.5.

Таблиця 3.5 – Метрики класифікації після очищення методом embedding-представлень

Поріг	Accuracy	F1-score	ROC-AUC	Std
0.985	0.9888	0.9898	0.9996	± 0.0089
0.99	0.9952	0.9955	0.9998	± 0.0025
0.995	0.9947	0.9948	0.9995	± 0.0012

Залежність між порогом косинусної подібності, часткою видалених зображень та підсумковою точністю класифікації наочно представлено на рисунку 3.8.

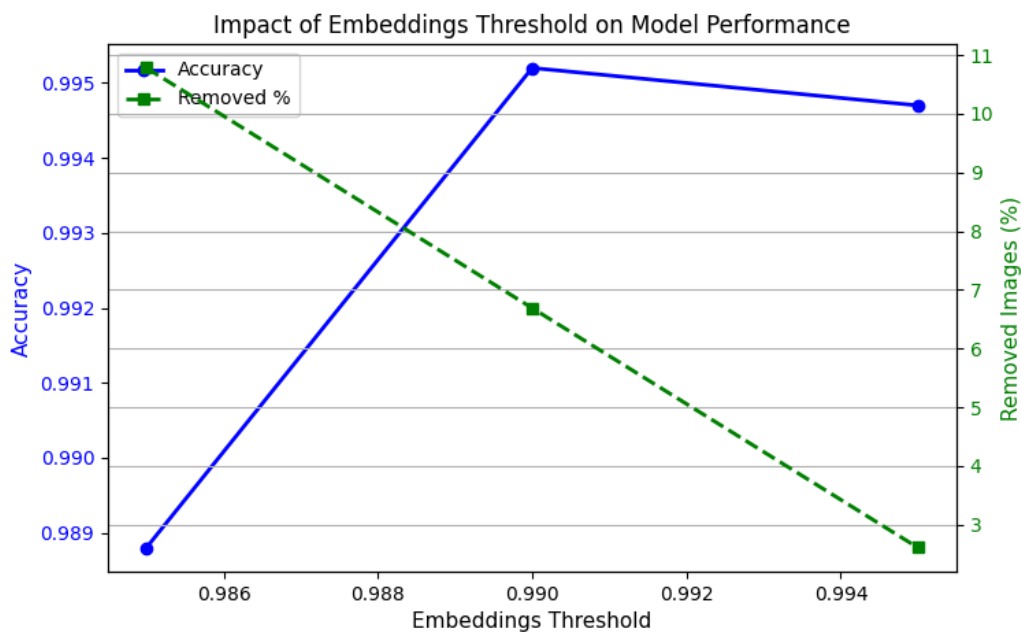


Рисунок 3.8 – Вплив порогу косинусної подібності на якість моделі та частку видалених зображень

Аналогічно до попереднього методу, найкращі показники класифікації досягаються в точці оптимального балансу очищення – при порозі схожості 0.99. У цьому випадку спостерігається підвищення Accuracy порівняно як із базовою

моделлю, так і з більш жорстким або більш м'яким критерієм. При порозі 0.985 видаляється значна частина вибірки, що призводить до певного зниження точності.

Завершальним етапом дослідження стало комплексне порівняння базової моделі та моделей, навчених після попереднього очищення датасету різними методами. Для кожного експериментального сценарію було проаналізовано середні значення показника Accuracy, отримані в результаті 5-кратної перехресної перевірки, а також відповідні стандартні відхилення, що відображають стабільність роботи моделі на різних розбиттях вибірки.

З метою узагальнення та візуалізації отриманих результатів побудовано підсумкову діаграму, приклад якої наведено на рисунку 3.9. На ній представлено порівняльний аналіз середніх значень точності разом із обчисленою величиною інтервалів стандартного відхилення для кожної досліджуваної конфігурації.

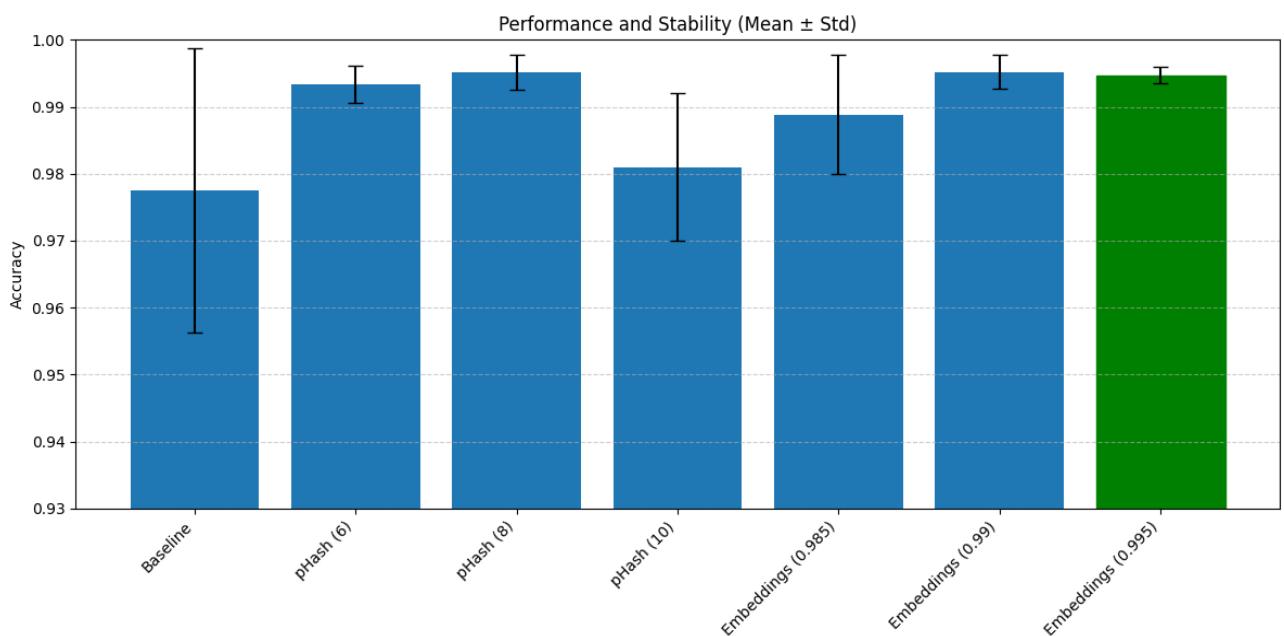


Рисунок 3.9 – Порівняння оцінок точності базової лінії та досліджених методів фільтрації надлишковості

Аналіз підсумкової діаграми підтверджує гіпотезу про те, що попереднє усунення інформаційної надлишковості текстильних зображень позитивно впливає на точність нейромережевої класифікації. Для більшості конфігурацій дедуплікації спостерігається не лише зростання середнього значення Accuracy, а й суттєве зменшення інтервалів дисперсії. Контрольна модель Baseline демонструє найвищу варіативність результатів на фолдах ± 0.0213 , що вказує на її критичну

чутливість до випадкового розподілу дублікатів між навчальною та валідаційною підмножинами під час випадкового розбиття вибірки.

Найбільш збалансовані та математично обґрунтовані результати з точки зору узагальнювальної здатності демонструє модель, навчена після очищення вибірки методом глибинних ознак при порозі косинусної подібності 0.995. Дана конфігурація автоматично виділена на підсумковій діаграмі зеленим кольором як оптимальна за сукупністю критеріїв ефективності.

Необхідно відзначити, що сценарії Embeddings (0.99) та rHash (8) формально демонструють дещо вищий показник середньої точності класифікації (Accuracy = 0.9952), проте характеризуються більшою варіативністю результатів між окремими folds (± 0.0025 та ± 0.0028 відповідно). Водночас модель Embeddings (0.995) показує лише незначне зниження середнього значення Accuracy до рівня 0.9947, однак забезпечує найменше стандартне відхилення серед усіх експериментальних конфігурацій (± 0.0012). Це свідчить про більш стабільну та стійку роботу моделі на різних підвибірках даних, що є важливою характеристикою узагальнювальної здатності нейромережевої системи.

Отже, результати проведених експериментальних досліджень підтверджують ефективність запропонованого підходу до виявлення та усунення інформаційної надлишковості текстильних зображень. Попереднє очищення набору даних від перцептивно схожих елементів сприяє підвищенню стабільності нейромережевого навчання та покращенню узагальнювальної здатності CNN-моделі. Оптимальний вибір методу та порогу дозволяє досягти балансу між скороченням набору даних, збереженням інформативних ознак та стабільністю результатів класифікації.

3.4 Обмеження та перспективи

Проведене дослідження підтвердило ефективність запропонованого підходу до виявлення інформаційної надлишковості текстильних зображень та його позитивний вплив на стабільність нейромережевої класифікації. Водночас

отримані результати свідчать про доцільність подальшого розвитку та розширення функціональних можливостей системи.

У межах роботи експериментальна перевірка виконувалася на наборі текстильних мікрозображень із двома класами матеріалів, що дозволило оцінити вплив процедур дедуплікації на точність і узагальнювальну здатність CNN-моделі. Подальші дослідження можуть бути спрямовані на розширення наборів даних, збільшення кількості класів текстильних матеріалів та аналіз ефективності запропонованого підходу для складніших задач автоматизованої класифікації. Це дозволить оцінити універсальність розробленого методу та його адаптивність до різних типів візуальних даних.

Проведений порівняльний аналіз показав, що метод pHash забезпечує високу швидкодію та ефективно виявляє явні дублікати зображень, однак є менш стійким до складних перцептивних змін. Водночас підхід на основі embedding-представлень дозволяє точніше виявляти приховану візуальну схожість між текстильними зразками, хоча потребує більших обчислювальних ресурсів. Отримані результати підтверджують доцільність вибору методу дедуплікації залежно від вимог до швидкодії, точності та масштабу набору даних.

Перспективним напрямом подальших досліджень є використання сучасних архітектур глибокого навчання для формування більш інформативних ознакових представлень зображень. Зокрема, подальше вдосконалення системи може бути пов'язане із застосуванням трансформерних моделей комп'ютерного зору та методів самонавчання нейромереж, які здатні ефективніше виявляти складні текстурні закономірності та приховану перцептивну схожість між зображеннями. Крім цього, доцільним є дослідження гібридних схем дедуплікації, які поєднуюватимуть швидкість перцептивного хешування та стійкість глибинних ознакових представлень.

Запропонований підхід може бути використаний у системах автоматизованого аналізу текстильних матеріалів, задачах контролю якості виробництва та інтелектуальної обробки великих наборів графічних даних. Окрім текстильної галузі, розроблений метод потенційно може бути адаптований

для медичних систем аналізу зображень, промислового контролю дефектів та інших задач комп'ютерного зору, де важливим є виявлення перцептивно схожих графічних даних та зменшення інформаційної надлишковості набору даних.

3.5 Висновки до розділу 3

У ході проведених експериментальних досліджень було реалізовано та апробовано запропонований метод виявлення інформаційної надлишковості у наборах текстильних зображень, а також комплексно оцінено його вплив на результати нейромережевої класифікації. Для реалізації дослідження обґрунтовано вибір програмних засобів та сформовано стек технологій на базі мови Python та фреймворку PyTorch, який забезпечив ефективну реалізацію алгоритмів дедуплікації, глибокого навчання, статистичного аналізу та візуалізації результатів експериментів.

Було розроблено інтелектуальну систему для представлення результатів дослідження, яка забезпечує інтерактивний перегляд статистики очищення набору даних, аналіз метрик класифікації та порівняння ефективності різних методів дедуплікації текстильних зображень. Реалізований графічний інтерфейс на основі PyQt5 дозволив наочно візуалізувати динаміку функції втрат і результати крос-валідації, структуру сформованих груп перцептивно схожих зображень, а також підсумкові статистичні характеристики експериментальних серій у вигляді аналітичних залежностей та гістограм.

Проведені експериментальні дослідження повністю підтвердили гіпотезу про те, що попереднє усунення інформаційної надлишковості позитивно впливає на стабільність нейромережевого навчання та узагальнювальну здатність CNN-моделі. Контрольна модель Baseline, навчена на неочищених даних, продемонструвала критично високу варіативність результатів на фолдах (± 0.0213), що вказує на її чутливість до випадкового розподілу дублікатів.

У результаті порівняльного аналізу методів pHash та embedding-представлень встановлено, що підхід на основі глибинних ознак, сформованих

моделлю ResNet-18, забезпечує більш стійке виявлення прихованої візуальної схожості текстильних зображень порівняно з перцептивним хешуванням і дозволяє досягти кращого балансу між скороченням обсягу вибірки та збереженням її інформативного різноманіття. Хоча сценарії pHash із порогом 8 та Embeddings із порогом 0.99 забезпечили дещо вищу середню точність, вони продемонстрували вищий рівень дисперсії.

Найбільш ефективною та математично обґрунтованою конфігурацією в межах проведеного дослідження виявився метод embedding-представлень при пороговому значенні косинусної подібності 0.995. Дана конфігурація дозволила вилучити лише 2.61% найбільш критичних перцептивних копій, забезпечивши високу точність розпізнавання (0.9947) при мінімальному рівні варіативності результатів між фолдами крос-валідації (± 0.0012), що доводить високу стійкість процесу оптимізації та захист від ефекту недонавчання.

Отримані результати підтверджують доцільність використання процедур дедуплікації як обов'язкового етапу попередньої підготовки даних у задачах комп'ютерного зору та створюють надійну основу для подальших досліджень у напрямі підвищення якості та репрезентативності навчальних вибірок та розвитку методів автоматизованого аналізу інформаційної надлишковості графічних наборів даних.

Загальні висновки

Метою кваліфікаційної роботи було підвищення точності нейромережевої класифікації шляхом розробки методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості.

Для досягнення поставленої мети виконані наступні завдання:

- проведено аналіз предметної області для задачі виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості;
- розроблено метод виявлення надлишкових текстильних зображень для підвищення достовірності нейромережевої класифікації на основі алгоритмів перцептивного хешування та аналізу глибинних векторних представлень;
- виконано проєктування та реалізацію інтелектуальної системи для виявлення надлишкових даних у наборах текстильних зображень;
- проведено експериментальне дослідження запропонованого методу розробленим програмним забезпеченням.

Проведений порівняльний аналіз отриманих результатів із наявними підходами свідчить про зростання точності моделі класифікації до 0.9952, що перевищує показник базової лінії на неочищених даних на 0.0177. Запропоноване рішення автоматизує процес дедуплікації текстильних зображень та забезпечує візуалізацію сформованих груп перцептивної схожості, що дозволяє користувачеві наочно контролювати якість фільтрації вибірки через графічний інтерфейс інтелектуальної системи. З практичним використанням методу досягається стабілізація нейромережевого навчання завдяки усуненню інформаційного шуму. Метрика Accuracy для оптимальної конфігурації Embeddings (поріг 0.995) склала 0.9947 при мінімальній варіативності між фолдами (лише ± 0.0012), що вказує на відмінну узагальнювальну здатність моделі. Показники є високими з урахуванням роботи з реальними мікротекстурами, де зустрічалися відмінності в освітленні та кутах зйомки. Подальші дослідження спрямовані на масштабування методу для багатокласових задач і впровадження каскадних схем фільтрації.

Перелік посилань

1. Kumar D. T. S., Muthuvelammai S., Jayachandran N. AI in Textiles: A Review of Emerging Trends and Applications. *International Journal for Research in Applied Science and Engineering Technology*. 2024. Т. 12, № 9. С. 1663–1678. URL: <https://doi.org/10.22214/ijraset.2024.64404>.
2. The essence and applications of machine vision inspection for textile industry: a review / C. Xu та ін. *The Journal of The Textile Institute*. 2025. Т. 116, № 10. С. 2286–2310. URL: <https://doi.org/10.1080/00405000.2024.2426257>.
3. Begum M. S., Milašius R. Factors of Weave Estimation and the Effect of Weave Structure on Fabric Properties: A Review. *Fibers*. 2022. Т. 10, № 9. С. 74. URL: <https://doi.org/10.3390/fib10090074>.
4. Overview of different fabric structures / F. Mamdouh та ін. *Journal of Textiles, Coloration and Polymer Science*. 2022. Т. 19, № 2. С. 291–306. URL: <https://doi.org/10.21608/jtcps.2022.152641.1131>.
5. Di L., Long H., Liang J. Fabric Defect Detection Based on Illumination Correction and Visual Salient Features. *Sensors*. 2020. Т. 20, № 18. С. 5147. URL: <https://doi.org/10.3390/s20185147>.
6. Color and Texture Analysis of Textiles Using Image Acquisition and Spectral Analysis in Calibrated Sphere Imaging System-I / N. Rout та ін. *Electronics*. 2022. Т. 11, № 23. С. 3887. URL: <https://doi.org/10.3390/electronics11233887>.
7. A spatial–spectral adaptive learning model for textile defect images recognition with few labeled data / Y. Zhang та ін. *Complex & Intelligent Systems*. 2023. Т. 9, № 6. С. 6359–6371. URL: <https://doi.org/10.1007/s40747-023-01070-y>.
8. Beyond Neural Scaling Laws: Beating Power Law Scaling Via Data Pruning / S. Ganguli та ін. *Advances in Neural Information Processing Systems 35*, м. New Orleans, Louisiana, USA, 28 листоп. – 9 груд. 2022 р. San Diego, California, USA, 2022. С. 19523–19536. URL: <https://doi.org/10.52202/068431-1419>.

9. Kumar K. S., Bai M. R. LSTM based texture classification and defect detection in a fabric. *Measurement: Sensors*. 2023. T. 26. C. 100603. URL: <https://doi.org/10.1016/j.measen.2022.100603>.
10. Khatami A., Mahmoudi-Aznavah A. Deep perceptual similarity and Quality Assessment. *2023 6th International Conference on Pattern Recognition and Image Analysis (IPRIA)*, м. Qom, Iran, Islamic Republic of, 14–16 лют. 2023 р. 2023. URL: <https://doi.org/10.1109/ipria59240.2023.10147170>.
11. Samanta P., Jain S. Analysis of Perceptual Hashing Algorithms in Image Manipulation Detection. *Procedia Computer Science*. 2021. T. 185. C. 203–212. URL: <https://doi.org/10.1016/j.procs.2021.05.021>.
12. Subudhi P., Kumari K. A fast and efficient large-scale near duplicate image retrieval system using double perceptual hashing. *Signal, Image and Video Processing*. 2024. T. 18, № 12. C. 8565–8575. URL: <https://doi.org/10.1007/s11760-024-03490-w>.
13. Detection of NFT Duplications with Image Hash Functions / A. Kotzer та ін. *2024 IEEE International Conference on Blockchain and Cryptocurrency (ICBC)*, м. Dublin, Ireland, 27–31 трав. 2024 р. 2024. C. 1–7. URL: <https://doi.org/10.1109/icbc59979.2024.10634437>.
14. An effective retrieval model for home textile images based on deep feature extraction / Z. Miao та ін. *Multimedia Systems*. 2025. T. 31, № 1. C. 57. URL: <https://doi.org/10.1007/s00530-024-01623-2>.
15. Truong T., Jush F. K., Lenga M. Benchmarking Pretrained Vision Embeddings for Near- and Duplicate Detection in Medical Images. *2024 IEEE International Symposium on Biomedical Imaging (ISBI)*, м. Athens, Greece, 27–30 трав. 2024 р. 2024. C. 1–5. URL: <https://doi.org/10.1109/isbi56570.2024.10635550>.
16. Structural similarity index (SSIM) revisited: A data-driven approach / I. Bakurov та ін. *Expert Systems with Applications*. 2022. T. 189. C. 116087. URL: <https://doi.org/10.1016/j.eswa.2021.116087>.
17. Karnatov S. Analysis of PSNR, SSIM, LPIPS metrics in the context of human perception of visual similarity. *Collection of scientific works of the State University of*

Infrastructure and Technologies series "Transport Systems and Technologies". 2025. № 46. C. 140–150. URL: <https://doi.org/10.32703/2617-9040-2025-46-10>.

18. Content-based Image Retrieval: A Survey on Local and Global Features Selection, Extraction, Representation and Evaluation Parameters / D. Srivastava та ін. *IEEE Access*. 2023. T. 11. C. 95410–95431. URL: <https://doi.org/10.1109/access.2023.3308911>.

19. Similarity Measure of Images using SIFT and ORB Feature Matching / S. Singh та ін. *International Journal for Research in Applied Science and Engineering Technology*. 2022. T. 10, № 6. C. 2354–2359. URL: <https://doi.org/10.22214/ijraset.2022.44319>.

20. SemDeDup: Data-efficient learning at web-scale through semantic deduplication / A. Abbas та ін. *arXiv preprint*. 2023. URL: <https://doi.org/10.48550/arXiv.2303.09540>.

21. Tang Z., Zhang S., Wang X. Exploring Data Redundancy in Real-world Image Classification through Data Selection. 2023. URL: <https://doi.org/10.48550/arXiv.2306.14113>.

22. Jakhar Y., Borah M. D. Effective near-duplicate image detection using perceptual hashing and deep learning. *Information Processing & Management*. 2025. T. 62, № 4. C. 104086. URL: <https://doi.org/10.1016/j.ipm.2025.104086>.

23. FiftyOne. *FiftyOne – FiftyOne 1.16.0 documentation*. URL: <https://docs.voxel51.com/>.

24. Image Deduplication Plugin – FiftyOne 1.16.0 documentation. *FiftyOne – FiftyOne 1.16.0 documentation*. URL: https://docs.voxel51.com/plugins/plugins_ecosystem/image_deduplication.html.

25. Top Computer Vision Tools, Libraries & Frameworks in 2026. *Computer Vision Suite / Lightly*. URL: <https://www.lightly.ai/blog/best-computer-vision-tools>.

26. GitHub - visual-layer/fastdup: fastdup is a powerful, free tool designed to rapidly generate valuable insights from image and video datasets. It helps enhance the quality of both images and labels, while significantly reducing data operation costs, all with unmatched scalability. *GitHub*. URL: <https://github.com/visual-layer/fastdup>.

27. GitHub - idealo/imagededup: Finding duplicate images made easy!. *GitHub*. URL: <https://github.com/idealo/imagededup>.
28. Find Duplicate Images using imagededup. *Lindevs*. URL: <https://lindevs.com/find-duplicate-images-using-imagededup>.
29. Texture classification network integrating adaptive wavelet transform / S. X. Yu та ін. *International Journal of Wavelets, Multiresolution and Information Processing*. 2024. Т. 22, № 05. С. 2450020. URL: <https://doi.org/10.1142/s0219691324500206>.
30. Natural and synthetic fabrics dataset. *Kaggle: The World's AI Proving Ground*. URL: <https://www.kaggle.com/datasets/olyarnncnn/natural-and-synthetic-fabrics-dataset>.
31. Kaggle: The World's AI Proving Ground. *Kaggle: The World's AI Proving Ground*. URL: <https://www.kaggle.com/>.
32. A comprehensive survey of loss functions and metrics in deep learning / J. Terven та ін. *Artificial Intelligence Review*. 2025. Т. 58, № 7. С. 195. URL: <https://doi.org/10.1007/s10462-025-11198-7>.
33. Li X., Zhu Y. A real-time and accurate convolutional neural network for fabric defect detection. *Complex & Intelligent Systems*. 2024. Т. 10, № 3. С. 3371–3387. URL: <https://doi.org/10.1007/s40747-023-01317-8>.
34. Diallo R., Edalo C., Awe O. O. Machine Learning Evaluation of Imbalanced Health Data: A Comparative Analysis of Balanced Accuracy, MCC, and F1 Score. *Practical Statistical Learning and Data Science Methods: Case Studies from LISA 2020 Global Network, USA*. 2024. С. 283–312. URL: https://doi.org/10.1007/978-3-031-72215-8_12.
35. Allgaier J., Pryss R. Cross-Validation Visualized: A Narrative Guide to Advanced Methods. *Machine Learning and Knowledge Extraction*. 2024. Т. 6, № 2. С. 1378–1388. URL: <https://doi.org/10.3390/make6020065>.
36. Welcome to Python.org. *Python.org*. URL: <https://www.python.org/>.
37. Довідник по Machine Learning – PyTorch | База знань ІТ. *База знань ІТ технологій*. URL: <https://itwiki.dev/data-science/ml-reference/ml-glossary/pytorch>.

38. NumPy. *NumPy*. URL: <https://numpy.org/>.
39. scikit-learn: machine learning in Python – scikit-learn 1.9.0 documentation. *scikit-learn: machine learning in Python – scikit-learn 0.16.1 documentation*. URL: <https://scikit-learn.org/stable/>.
40. How to use the Python imagehash library. *PythonHow - Learn Python Through Expert Articles and Practice*. URL: <https://pythonhow.com/what/imagehash-library-tutorial/>.
41. Сімагін Д. Бібліотека Pillow: як обробляти зображення у Python. *Highload.tech - media для розробників*. URL: <https://highload.tech/uk/biblioteka-pillow-obrobka-zobrazhen-u-python/>.
42. Pandas - Python Data Analysis Library. *pandas - Python Data Analysis Library*. URL: <https://pandas.pydata.org/>.
43. Matplotlib – Visualization with Python. *Matplotlib – Visualization with Python*. URL: <https://matplotlib.org/>.
44. Навчальний посібник із PyQt5 із прикладами: проектування графічного інтерфейсу за допомогою PyQt Python. *Guru99*. URL: <https://www.guru99.com/uk/pyqt-tutorial.html>.
45. Microsoft. Visual Studio Code - The open source AI code editor | Your home for multi-agent development. *Visual Studio Code - The open source AI code editor | Your home for multi-agent development*. URL: <https://code.visualstudio.com/>.

ДОДАТКИ

Додаток А

Програмні коди

Вихідний код, використаний у дослідженні, доступний у репозиторії GitHub: <https://github.com/merezhkooo/fabrics-project>.

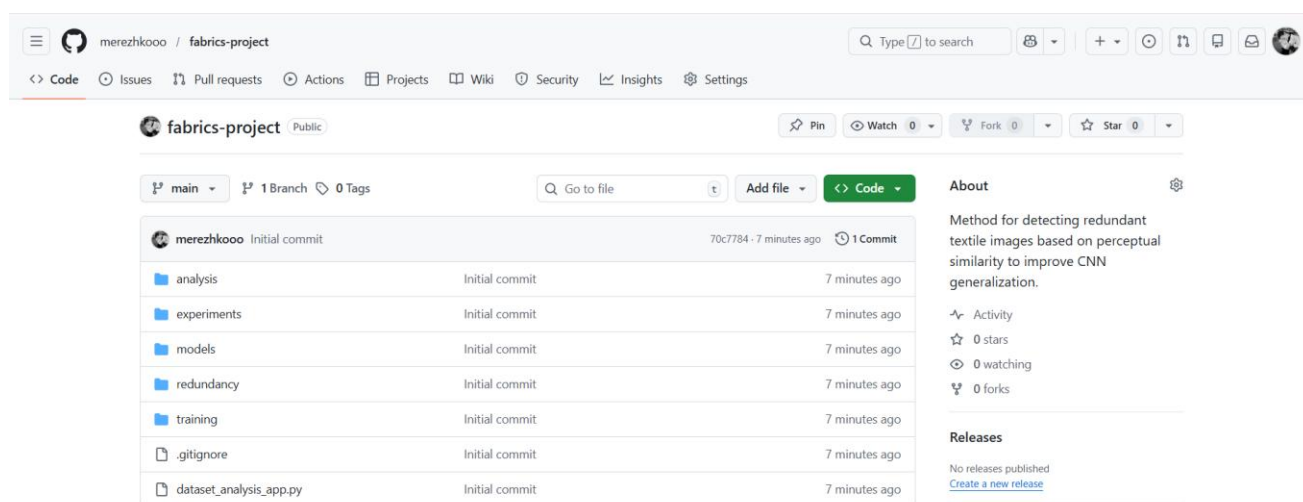


Рисунок А.1 – Головна сторінка репозиторію

Структура репозиторію програмної реалізації методу виявлення надлишкових текстильних зображень організована модульно та включає такі основні компоненти:

- Модулі аналізу та візуалізації результатів (*analysis*). Містить скрипти для побудови графіків, порівняння метрик, аналізу стабільності моделей та оцінювання ефективності різних підходів до виявлення надлишковості. Забезпечує формування підсумкових порівняльних результатів експериментів.

- Модулі проведення експериментів (*experiments*). Містить програмні сценарії навчання моделей за різних порогів перцептивної схожості (для *rHash* та *embedding*-підходів), а також реалізацію базового (*baseline*) експерименту без фільтрації надлишкових даних.

- Модуль архітектури нейромережевої моделі (*models*). Містить реалізацію згорткової нейронної мережі, що використовується для класифікації текстильних зображень.

– Модулі виявлення надлишковості (redundancy). Реалізує алгоритми визначення перцептивної схожості зображень, зокрема метод на основі перцептивного хешування (pHash) та метод на основі порівняння векторних представлень (embeddings).

– Модуль навчання моделі (training). Містить реалізацію тренувального процесу, включаючи обчислення функції втрат, оновлення ваг моделі, крос-валідацію та збереження результатів.

– Модуль запуску програмної реалізації (dataset_analysis_app.py). Є точкою входу до системи та забезпечує запуск основних функціональних компонентів. Реалізує взаємодію користувача з програмою, ініціалізацію аналізу набору зображень та відображення результатів роботи алгоритмів виявлення надлишковості.

Додаток Б

Презентаційний матеріал

КВАЛІФІКАЦІЙНА РОБОТА

Кваліфікаційна робота бакалавра

Метод виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості для підвищення достовірності нейромережевої класифікації

Виконала:
студентка 4 курсу, групи КН-22-3
Єлизавета **Мережко**

Керівник:
к.т.н., доцент кафедри КН
Олександр **Мазурець**

АКТУАЛЬНІСТЬ

Сучасна автоматизація текстильної промисловості зумовлює потребу у впровадженні високоточних систем комп'ютерного зору для класифікації тканин та контролю якості. Проте ефективність навчання нейромережевих моделей критично залежить від якості вхідних даних. Наявність у вибірках великої кількості дубльованих або перцептивно подібних зображень призводить до надмірних обчислювальних витрат та спричиняє перенавчання моделей, що суттєво знижує якість розпізнавання нових об'єктів.

Задача дедуплікації є особливо складною для текстильної галузі через специфіку зображень тканин: наявність повторюваних орнаментів, подібних типів плетіння ниток та однорідної кольорової гами. За таких умов стандартні алгоритми фільтрації часто не здатні відрізнити повні копії від унікальних зразків із дрібними текстурними відмінностями. У зв'язку з цим виникає необхідність створення нових підходів, адаптованих до аналізу складних мікротекстур.

Розроблена система спрямована на підвищення ефективності процесу підготовки даних шляхом автоматичного виявлення та вилучення надлишкових зображень у текстильних датасетах. Це забезпечує оптимізацію обчислювальних витрат на навчання моделей та безпосередньо підвищує достовірність і точність подальшої нейромережевої класифікації в реальних виробничих умовах.

МЕТА ТА ЗАДАЧІ

дослідження

Об'єкт дослідження – процес підготовки та оптимізації наборів текстильних зображень для підвищення достовірності нейромережевої класифікації.

Предмет дослідження – методи та засоби штучного інтелекту для виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості.

Метою дослідження є підвищення точності нейромережевої класифікації шляхом розробки методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості.

Для досягнення поставленої мети потрібно виконати наступні завдання:

провести аналіз предметної області для задачі виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості

розробити метод виявлення надлишкових текстильних зображень для підвищення достовірності нейромережевої класифікації на основі алгоритмів перцептивного хешування та аналізу глибоких векторних представлень

виконати проєктування та реалізацію інтелектуальної системи для виявлення надлишкових даних у наборах текстильних зображень

провести експериментальне дослідження запропонованого методу розробленим програмним забезпеченням

СХЕМА МЕТОДУ

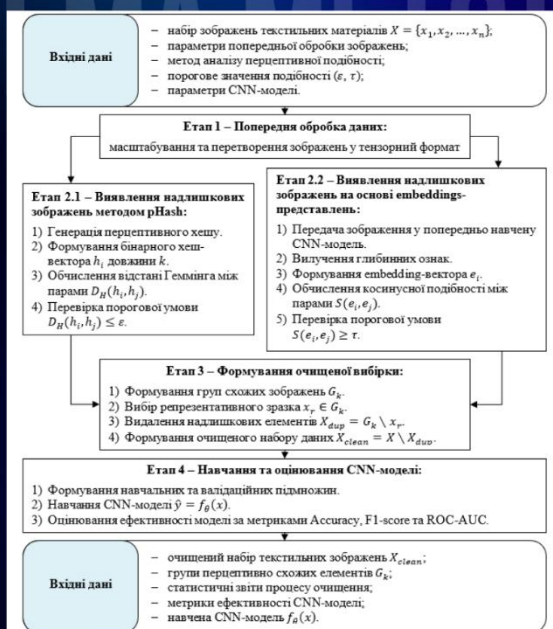


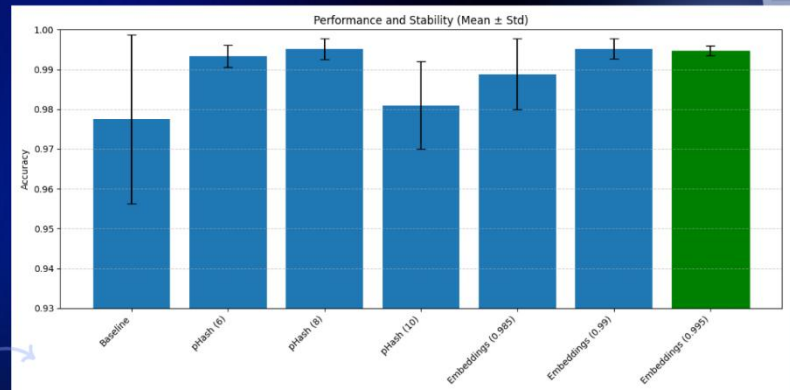
Схема та етапи методу виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості

РЕЗУЛЬТАТИ

експериментальних досліджень

Найменше стандартне відхилення отримано для **Embeddings (0,995)** ($\pm 0,0012$), що свідчить про найвищу стабільність результатів між окремими експериментами.

Збільшення кількості вилучених зображень не завжди призводить до покращення якості класифікації, що підтверджує необхідність вибору оптимального порогу дедуплікації.



Порівняння оцінок точності базової лінії та дослідження методів фільтрації надлишковості

ВИСНОВКИ

Розроблено **метод виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості для підвищення достовірності нейромережевої класифікації**. Реалізація запропонованого підходу дозволяє автоматизувати процес дедуплікації текстильних датасетів і підвищити якість підготовки даних для нейромережевого навчання.

Проведені **експериментальні дослідження** підтвердили ефективність запропонованого методу. Використання процедур дедуплікації забезпечило підвищення точності класифікації з **97,75%** для базової моделі до **99,52%** після очищення набору даних. **Найбільш стабільні результати отримано для методу embedding-представлень** при порозі косинусної подібності 0,995, де досягнуто точності **99,47%** при мінімальному стандартному відхиленні **$\pm 0,0012$** .

Отримані результати підтверджують доцільність використання **методів виявлення надлишковості як етапу попередньої підготовки даних** у задачах комп'ютерного зору. Перспективами подальших досліджень є розширення наборів текстильних даних, використання сучасних архітектур глибокого навчання та розроблення гібридних підходів до дедуплікації зображень.



Thu Jun 18 17:59:08 EEST 2026, Петровський Сергій Степанович, Хмельницький національний університет, ХНУ

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

Максимальне співпадіння з одним документом 3.0%

Словники перевірки: UA, US, RU. **Помилоч в документах: 13%**

ID: 275969 Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості для підвищення достовірності нейромережевої класифікації Додано в БД: 2026-06-18 Автора: Єлизавета МЕРЕЖКО Керівники: Олександр МАЗУРЕЦЬ Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	90059	718	5713 (6%)	69 (10%)

Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

Протокол аналізу звіту подібності науковим керівником

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

Автор: Єлизавета МЕРЕЖКО

Співавтор:

Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості для підвищення достовірності нейромережевої класифікації

Науковий керівник: Олександр МАЗУРЕЦЬ, к.т.н., доцент

Підрозділ: Кафедра комп'ютерних наук

Коефіцієнт подібності 1: 5.69%

Коефіцієнт подібності 2: 2.88%

Мікропробіли: 0

Заміна букв: 7

Інтервали: 0

Білі знаки: 12

Дата створення звіту: 2026-06-17 21:49:24.0

Після аналізу Звіту подібності констатую наступне:

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

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

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

Обґрунтування:

2026-06-18

Дата

експерт

Петровський Р. В.

РІШЕННЯ ЕКСПЕРТНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК

ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ

Назва кваліфікаційної роботи Метод виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості для підвищення достовірності нейромережевої класифікації

Автор студентка групи КН-22-3 Єлизавета МЕРЕЖКО

Освітня програма Комп'ютерні науки

Рівень вищої освіти перший (бакалаврський)

Спеціальність 122 – Комп'ютерні науки

Науковий керівник: к.т.н., доц. каф. КН Олександр МАЗУРЕЦЬ

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

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

Підтвердження:

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

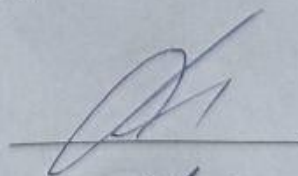
Обсяг запозичень, визначений системами виявлення збігів/ідентичності/схожості:

- за системою Anti-Plagiarism: 3%;

- за системою StrikePlagiarism KPII: 5.69%.

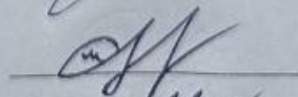
18.06.2026

Завідувач кафедри



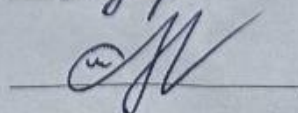
Олександр БАРМАК

Гарант освітньої програми



Олександр МАЗУРЕЦЬ

Керівник кваліфікаційної роботи



Олександр МАЗУРЕЦЬ



**ВІДГУК НАУКОВОГО КЕРІВНИКА
на кваліфікаційну роботу бакалавра**

студентки *гр. КН-22-3 Мережко Єлизавети Олегівни*

за темою Метод виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості для підвищення достовірності нейромережевої класифікації

1. Актуальність теми

Проблематика роботи пов'язана з обробкою великих масивів візуальних даних, зокрема текстильних зображень, у яких необхідно виявляти дублікати та ступінь схожості. Подібні задачі набувають практичного значення у сферах цифрового каталогізування, контролю якості продукції та автоматизації обліку візуальних матеріалів. Актуальність теми зумовлена тим, що сучасні системи комп'ютерного зору все частіше використовуються для аналізу візуальних ознак об'єктів, однак ефективність таких рішень значною мірою залежить від якості даних та коректності методів порівняння. У випадку текстильних зображень додаткову складність створюють варіативність текстур, освітлення та ракурсів зйомки. Таким чином, тема є своєчасною та має прикладну цінність, оскільки поєднує задачі обробки зображень із практичними потребами автоматизації візуального аналізу.

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

Робота відповідає змісту підготовки бакалавра з комп'ютерних наук, оскільки охоплює ключові етапи розв'язання прикладної задачі: формалізацію проблеми, вибір методів аналізу візуальних даних, реалізацію алгоритмічного рішення та оцінювання результатів. У дослідженні використано підходи комп'ютерного зору та методи аналізу ознак зображень, що належать до базового інструментарію спеціальності. Також реалізовано програмну частину, яка забезпечує практичну перевірку запропонованого підходу. У сукупності це підтверджує відповідність роботи вимогам стандарту та типовій структурі підготовки фахівця з комп'ютерних наук.

3. Професійні та особистісні якості бакалавра

Під час виконання роботи здобувачка продемонструвала системність у підході до розв'язання задачі та уважність до деталей на всіх етапах дослідження. Робота

виконувалась послідовно, із поступовим ускладненням технічних рішень та їх уточненням за результатами проміжних експериментів. Позитивно слід відзначити здатність адаптувати методичні рішення до особливостей даних та враховувати зауваження під час доопрацювання роботи.

4. Ступінь самостійності під час виконання кваліфікаційної роботи

Основні результати роботи отримані здобувачкою самостійно. Вона самостійно виконала аналіз предметної області, розробила підхід до виявлення візуальної схожості та реалізувала програмну частину дослідження.

5. Ступінь оволодіння методами дослідження

У роботі продемонстровано належне володіння методами аналізу візуальних даних та підходами комп'ютерного зору. Здобувачка коректно поєднала етапи підготовки даних, виділення ознак, порівняння зображень і оцінювання результатів.

6. Повнота та якість розкриття теми роботи

Тема розкрита у повному обсязі, з урахуванням основних складових дослідження: аналізу проблеми, обґрунтування методів, реалізації алгоритму та оцінювання результатів. Структура роботи є логічною та забезпечує цілісне сприйняття дослідження. Okремо варто відзначити наявність як теоретичного обґрунтування, так і практичної реалізації, що дозволяє оцінити повноту виконаної роботи.

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

Виклад матеріалу є послідовним і логічно структурованим. Перехід від постановки задачі до опису методів і подальшої реалізації є зрозумілим та аргументованим. Термінологія використовується коректно, без суттєвих порушень академічного стилю. Основні положення підкріплені результатами практичної частини, що підсилює загальну переконливість роботи.

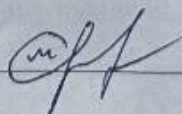
8. Можливість практичного застосування кваліфікаційної роботи бакалавра, окремих її частин

Запропонований підхід має прикладне значення у задачах автоматизованого аналізу та обробки зображень текстилю. Він може бути використаний у системах каталогізації, контролю якості та виявлення дублюючих візуальних даних.

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

Вважаю, що виконана кваліфікаційна робота оцінку заслуговує на оцінку «відмінно».

Керівник



к.т.н., доц. каф. КН Олександр МАЗУРЕЦЬ



РЕЦЕНЗІЯ

на кваліфікаційну роботу бакалавра

студентки *гр. КН-22-3 Мережко Єлизавети Олегівни*

за темою: Метод виявлення надлишкових даних у наборах текстильних зображень на основі перцептивної схожості для підвищення достовірності нейромережевої класифікації

1. Актуальність обраної теми

Тематика роботи відповідає сучасним тенденціям у сфері підготовки та очищення наборів зображень для задач машинного навчання. Автор розглядає проблему, де важливою є не лише точність нейромережевої моделі, а й якість вихідних даних, що безпосередньо впливає на достовірність результатів класифікації. Актуальність визначається не тільки поширенням методів глибокого навчання, а й практичною необхідністю автоматизованого виявлення надлишкових і дубльованих даних у великих візуальних наборах. Робота демонструє розуміння того, що ефективність комп'ютерного зору значною мірою залежить від коректної підготовки даних, правильної постановки експерименту та обґрунтованої інтерпретації результатів.

2. Повнота розкриття мети та завдань роботи

Мета та завдання сформульовані коректно й логічно узгоджені між собою. Студентка послідовно переходить від аналізу предметної області до розроблення методу, не обмежуючись описом програмної реалізації. У роботі чітко простежується зв'язок між поставленими завданнями та отриманими результатами. Теоретична частина природно переходить у практичну, де запропонований метод виявлення надлишкових даних на основі перцептивної схожості реалізовано та перевірено експериментально. Загалом дослідження демонструє цілісність підходу та логічну завершеність виконання поставленої мети.

3. Зміст кожного розділу роботи

Структура роботи є класичною та обґрунтованою. Теоретичний розділ формує базу для подальших рішень, проєктна частина деталізує запропонований метод, а практична демонструє його застосування на реальних даних текстильних зображень з аналізом схожості та виявленням дублікатів. Розділи взаємопов'язані та логічно доповнюють один одного. Теоретичні положення безпосередньо використовуються у практичній реалізації, а експериментальна частина дозволяє оцінити ефективність запропонованого підходу. Такий підхід свідчить про розуміння не лише кінцевого результату, а й методології його отримання.

4. Оцінка розробленої інформаційної системи, її практична цінність

Запропонований підхід має виражений прикладний потенціал, оскільки спрямований на підвищення якості підготовки даних для нейромережевої класифікації. Практична цінність полягає у можливості автоматизованого виявлення надлишкових і дубльованих зображень, що є критично важливим для великих датасетів. Результати роботи можуть

бути використані у системах обробки візуальних даних, зокрема у сфері контролю якості текстильних матеріалів та у суміжних задачах комп'ютерного зору.

5. Якість оформлення кваліфікаційної роботи бакалавра

Оформлення роботи загалом відповідає вимогам до кваліфікаційних робіт. Матеріал викладено структуровано, логічно та послідовно. В окремих фрагментах текст міг би бути більш стислим, однак це не впливає на загальне сприйняття роботи. Термінологія використовується коректно, розділи узгоджені між собою, а висновки відповідають поставленим завданням. Робота сприймається як цілісний науково-прикладний текст, а не як набір окремих технічних описів.

6. Недоліки кваліфікаційної роботи бакалавра

До недоліків слід віднести недостатньо детальне висвітлення обмежень запропонованого методу в окремих сценаріях використання. Крім того, частина експериментальних результатів могла б бути подана з більш розгорнутим аналізом чутливості методу до параметрів. Зазначені недоліки не мають принципового характеру та не впливають на загальну позитивну оцінку роботи, оскільки основні завдання виконано в повному обсязі.

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

Робота демонструє логічну цілісність, коректну методологію та практичну спрямованість результатів. Виявлені недоліки не знижують загальної якості дослідження. Роботу рекомендується допустити до захисту. За сукупністю результатів вона заслуговує на оцінку «визначено».

Рецензент

доцент кафедри КІІС Нітенорук А.О.