

**ДЕРЖАВНИЙ УНІВЕРСИТЕТ
ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ
НАВЧАЛЬНО-НАУКОВИЙ ІНСТИТУТ ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ
КАФЕДРА ІНФОРМАЦІЙНИХ СИСТЕМ ТА ТЕХНОЛОГІЙ**

КВАЛІФІКАЦІЙНА РОБОТА

**на тему: «Інтелектуальна система автоматизованого сортування
твердих побутових відходів на основі вбудованих нейромережевих моделей»**

на здобуття освітнього ступеня бакалавра
зі спеціальності 126 Інформаційні системи та технології
(код, найменування спеціальності)
освітньо-професійної програми Інформаційні системи та технології
(назва)

*Кваліфікаційна робота містить результати власних досліджень.
Використання ідей, результатів і текстів інших авторів мають посилання на
відповідне джерело*

_____ Катерина ХУДОЯРОВА
(підпис) (ім'я, ПРІЗВИЩЕ здобувача)

Виконав: здобувач вищої освіти група ІСД-42
_____ Катерина ХУДОЯРОВА
(ім'я, ПРІЗВИЩЕ)

Керівник _____ Валентина ДАНИЛЬЧЕНКО
PhD (ім'я, ПРІЗВИЩЕ)

Рецензент: _____
(ім'я, ПРІЗВИЩЕ)

Київ 2026

**ДЕРЖАВНИЙ УНІВЕРСИТЕТ
ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ**

Навчально-науковий інститут Інформаційних технологій

Кафедра Інформаційних систем та технологій
Ступінь вищої освіти бакалавр
Спеціальність 126 Інформаційні системи та технології
Освітньо-професійна програма Інформаційні системи та технології

ЗАТВЕРДЖУЮ
Завідувач кафедри ІСТ
Каміла СТОРЧАК
«___» _____ 2026 р.

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ**

Худоярова Катерина Іванівна

(прізвище, ім'я, по батькові здобувача)

1. Тема кваліфікаційної роботи: Інформаційна система автоматизованого сортування твердих побутових відходів на основі вбудованих нейромережових моделей

керівник кваліфікаційної роботи Валентина ДАНИЛЬЧЕНКО, PhD,

(Ім'я, ПРІЗВИЩЕ, науковий ступінь, вчене звання)

затверджені наказом Державного університету інформаційно-комунікаційних технологій
від «20» 02 2026р. № 51

2. Строк подання кваліфікаційної роботи «01» 06 2026р.
3. Вихідні дані до кваліфікаційної роботи: науково-технічна література з питань автоматизованого сортування твердих побутових відходів, комп'ютерного зору, нейромережових моделей, IoT-систем і розумних контейнерів; відкриті набори зображень побутових відходів; документація Python, TensorFlow/Keras та TensorFlow Lite.
4. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити)
1. Дослідити сучасні підходи до розробки розумних систем сортування сміття.
 2. Проаналізувати існуючі моделі та технології автоматичного розпізнавання відходів.

3. Розробити й оцінити ефективність прототипу інтелектуальної системи сортування твердих побутових відходів.

5. Перелік ілюстративного матеріалу: *презентація*

6. Дата видачі завдання «20» 02 2026р.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
1	Підбір науково-технічної літератури	05.03.2026	
2	Дослідження теоретико-методологічних основ розробки та моделювання розумних систем сортування сміття	14.03.2026	
3	Постановка технічного завдання, функціональних та нефункціональних вимог до проєктованої системи	16.03.2026	
4	Підбір і первинна обробка даних для навчання і тестування нейромережових моделей	12.04.2026	
5	Тестування існуючих моделей розпізнавання відходів	22.04.2026	
6	Проектування авторської моделі розпізнавання відходів та тестування програмного рішення	13.05.2026	
7	Розробка демонстраційних матеріалів	15.05.2026	
8	Попередній захист дипломної роботи	19.05.2026	
9	Подання роботи в деканат	01.06.2026	

Здобувач(ка) вищої освіти

(підпис)

Катерина

ХУДОЯРОВА

(Ім'я, ПРІЗВИЩЕ)

Керівник

кваліфікаційної роботи

(підпис)

Валентина

ДАНИЛЬЧЕНКО

(Ім'я, ПРІЗВИЩЕ)

РЕФЕРАТ

Текстова частина кваліфікаційної роботи на здобуття освітнього ступеня бакалавра: 69 стор., 41 рис., 15 джерел.

Мета роботи – розробка та оцінка ефективності інтелектуальної системи автоматизованого сортування твердих побутових відходів на основі вбудованої нейромережевої моделі.

Об'єкт дослідження – процес автоматизованого сортування твердих побутових відходів у розумних контейнерах.

Предмет дослідження – нейромережеві моделі, алгоритми обробки зображень і програмні засоби прийняття рішень для розподілу відходів за цільовими фракціями.

Короткий зміст роботи: У роботі досліджено сучасні підходи до побудови розумних систем сортування сміття, проаналізовано методи автоматичного визначення типу відходів та контролю роботи контейнера. Виконано підготовку набору зображень побутових відходів, проведено порівняльне тестування моделей класифікації та розроблено авторську модель EdgeWasteNet_Lite. Програмний прототип забезпечує класифікацію відходів, оцінювання впевненості прогнозу та формування рішення щодо цільового відсіку контейнера.

КЛЮЧОВІ СЛОВА: ТВЕРДІ ПОБУТОВІ ВІДХОДИ, РОЗУМНИЙ КОНТЕЙНЕР, НЕЙРОМЕРЕЖЕВА МОДЕЛЬ, КОМП'ЮТЕРНИЙ ЗІР, АВТОМАТИЗОВАНЕ СОРТУВАННЯ, EDGEWASTENET_LITE, TENSORFLOW LITE.

ABSTRACT

Textual part of the qualification work for obtaining a bachelor's degree: 69 pages, 41 figs., 15 sources.

The purpose of the work is to develop and evaluate the effectiveness of an intelligent system for automated municipal solid waste sorting based on an embedded neural network model.

The object of research is the process of automated municipal solid waste sorting in smart bins.

The subject of research is neural network models, image processing algorithms and software decision-making tools for distributing waste into target fractions.

Summary of the work: The work investigates modern approaches to the development of smart waste sorting systems, analyzes methods for automatic waste type recognition and bin operation control. A dataset of household waste images was prepared, comparative testing of classification models was performed, and the author's EdgeWasteNet_Lite model was developed. The software prototype provides waste classification, prediction confidence assessment and decision-making regarding the target bin compartment.

KEYWORDS: MUNICIPAL SOLID WASTE, SMART BIN, NEURAL NETWORK MODEL, COMPUTER VISION, AUTOMATED SORTING, EDGEWASTENET_LITE, TENSORFLOW LITE.

ЗМІСТ

ВСТУП.....	9
РОЗДІЛ 1. ТЕОРЕТИКО-МЕТОДОЛОГІЧНІ ОСНОВИ РОЗРОБКИ ТА МОДЕЛЮВАННЯ РОЗУМНИХ СИСТЕМ СОРТУВАННЯ СМІТТЯ.....	13
1.1 Сучасний стан та перспективи сортування побутових відходів в Україні та світі	13
1.2 Архітектурні рішення побудови ефективних систем розумних контейнерів	18
1.3 Методи автоматичного визначення типу сміття.....	22
1.4 Методи автоматичного сортування та контролю роботи контейнера.....	28
РОЗДІЛ 2. АНАЛІТИЧНЕ ДОСЛІДЖЕННЯ НАЯВНИХ МОДЕЛЕЙ РОЗУМНИХ СИСТЕМ СОРТУВАННЯ СМІТТЯ.....	38
2.1 Аналіз існуючих моделей та технологій розумних систем сортування сміття.....	38
2.2 Порівняльний аналіз ефективності моделей автоматичного сортування відходів.....	44
2.3 Переваги, недоліки та обмеження існуючих моделей розумних систем сортування сміття.....	48
РОЗДІЛ 3. РОЗРОБКА ТА ОЦІНКА ЕФЕКТИВНОСТІ ПРОТОТИПУ МОДЕЛІ РОЗУМНОГО КОНТЕЙНЕРА.....	56
3.1 Принцип роботи та архітектура програмного забезпечення моделі	56
3.2 Основні функції програмного забезпечення та алгоритми	62
3.3 Особливості застосування моделі у різних підходах до організації сортування сміття.....	66
3.4 Результати тестування та оцінка ефективності прототипу.....	68
ВИСНОВКИ.....	78
ПЕРЕЛІК ПОСИЛАНЬ	81
ПРЕЗЕНТАЦІЯ.....	83

ВСТУП

Актуальність теми. Проблема поводження з твердими побутовими відходами є однією з важливих екологічних, технічних та організаційних проблем сучасного суспільства. Зростання кількості відходів, ускладнення їхнього складу, недостатній рівень роздільного збирання та високе навантаження на полігони зумовлюють потребу у впровадженні нових технологічних рішень для підвищення івності сортування. Традиційні підходи до розділення сміття значною мірою залежать від дій користувача або ручної праці, тому не завжди забезпечують належну точність, стабільність і швидкість обробки змішаного потоку відходів.

Особливо актуальною є задача автоматичного визначення типу відходу безпосередньо на етапі його потрапляння до контейнера. У разі неправильного первинного сортування придатні до переробки матеріали можуть забруднюватися органічними або залишковими відходами, що знижує їхню подальшу цінність і ускладнює переробку. Тож сучасна система сортування має не лише накопичувати сміття, а й виконувати інтелектуальне розпізнавання об'єкта, приймати рішення щодо відсіку та формувати дані для подальшого контролю роботи контейнера.

Перспективним напрямом вирішення цієї проблеми є використання комп'ютерного зору та нейромережових моделей, здатних класифікувати зображення відходів за візуальними ознаками. Однак для практичного застосування в розумному контейнері недостатньо просто отримати мітку класу. Система повинна бути достатньо легкою для потенційного запуску на вбудованому пристрої, працювати з обмеженою кількістю ресурсів, оцінювати впевненість власного прогнозу та перетворювати результат класифікації на конкретне керуюче рішення. Тому актуальним є розроблення моделі, яка поєднує нейромережеве розпізнавання, рішення та можливість інтеграції у роботу розумного контейнера.

Метою кваліфікаційної роботи є розробка та оцінка ефективності інтелектуальної системи автоматизованого сортування твердих побутових відходів на основі вбудованої нейромережевої моделі, здатної класифікувати зображення

відходів, оцінювати впевненість прогнозу та формувати рішення щодо відповідного відсіку контейнера.

Об'єктом дослідження є процес автоматизованого сортування твердих побутових відходів у розумних контейнерах.

Предметом дослідження є нейромережеві моделі, алгоритми обробки зображень і програмні засоби прийняття рішень для класифікації та автоматизованого розподілу твердих побутових відходів за цільовими фракціями.

Для досягнення поставленої мети у роботі було визначено такі завдання: дослідити сучасний стан і перспективи застосування розумних систем сортування сміття; проаналізувати архітектурні рішення побудови інтелектуальних контейнерів; розглянути методи автоматичного визначення типу відходів та засоби контролю роботи контейнера; підібрати відкриті набори зображень побутових відходів і виконати їхню програмну підготовку для моделювання; провести порівняльний аналіз ефективності базових моделей класифікації відходів; розробити авторську програмну модель EdgeWasteNet_Lite для вбудованої системи сортування; виконати тестування прототипу та оцінити його ефективність за метриками класифікації, матрицями помилок, часом навчання та візуальними прикладами роботи системи.

Методи дослідження включають аналіз науково-технічних джерел щодо інтелектуальних систем сортування відходів, методи комп'ютерного зору, методи попередньої обробки зображень, згорткові нейронні мережі, порівняльне моделювання, статистичну оцінку результатів класифікації, побудову матриць помилок, а також програмну імітацію роботи розумного контейнера. Для реалізації програмної частини використано мову Python та бібліотеки TensorFlow/Keras, NumPy, Pandas, scikit-learn, Matplotlib і Pillow.

Наукова новизна роботи полягає в удосконаленні підходу до автоматизованого сортування твердих побутових відходів шляхом поєднання компактної нейромережевої класифікації з механізмом оцінювання впевненості прогнозу та логікою прийняття рішення для вбудованої системи розумного контейнера. На відміну від звичайної моделі розпізнавання зображень,

запропонований підхід формує не лише клас відходу, а й практичне рішення щодо цільового відсіку, резервного сценарію для невизначених об'єктів та умовної керуючої дії виконавчого механізму.

Практичне значення роботи полягає у створенні програмного прототипу, який може бути використаний як основа для подальшої розробки розумного контейнера або навчально-дослідного стенда для тестування моделей автоматичного сортування відходів. Розроблена система забезпечує підготовку даних, навчання та тестування моделей, порівняння їхньої ефективності, формування візуальних результатів, імітацію заповнення відсіків контейнера та демонстрацію роботи модуля прийняття рішень. Отримані результати можуть бути використані для подальшого вдосконалення системи шляхом розширення датасету, балансування класів, оптимізації порогу впевненості та адаптації моделі до запуску на реальному вбудованому пристрої.

Структура роботи. Кваліфікаційна робота складається зі вступу, трьох розділів, висновків і переліку посилань. У першому розділі досліджено теоретико-методологічні основи розробки та моделювання розумних систем сортування сміття, зокрема сучасний стан проблеми, архітектурні рішення, методи автоматичного визначення типу сміття та методи контролю роботи контейнера. У другому розділі виконано аналітичне дослідження наявних моделей розумних систем сортування, підготовлено набір даних, проведено порівняльне моделювання та визначено переваги й обмеження існуючих моделей. У третьому розділі розроблено авторську програмну модель EdgeWasteNet_Lite, описано її архітектуру, основні функції, алгоритми роботи, особливості застосування та результати тестування прототипу.

Апробація результатів. Основні положення та результати дослідження пройшли апробацію на:

5. III ВСЕУКРАЇНСЬКА НАУКОВО-ТЕХНІЧНА КОНФЕРЕНЦІЯ

«ТЕХНОЛОГІЧНІ ГОРИЗОНТИ: ДОСЛІДЖЕННЯ ТА ЗАСТОСУВАННЯ ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ ДЛЯ ТЕХНОЛОГІЧНОГО ПРОГРЕСУ УКРАЇНИ І СВІТУ» (Київ, ДУІКТ, 18 листопада 2025 р.). Тези доповіді на

тему «Інтеграція автоматизованого сортувального модуля на основі ІОТ у концепію “Розумного будинку” та “Розумного міста”» (стор. 30).

6. ІІІ ВСЕУКРАЇНСЬКА НАУКОВО-ТЕХНІЧНА КОНФЕРЕНЦІЯ
«ТЕХНОЛОГІЧНІ ГОРИЗОНТИ: ДОСЛІДЖЕННЯ ТА ЗАСТОСУВАННЯ
ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ ДЛЯ ТЕХНОЛОГІЧНОГО ПРОГРЕСУ
УКРАЇНИ І СВІТУ» (Київ, ДУІКТ, 18 листопада 2025 р.). Тези доповіді на
тему «Оцінка зниження вуглецевого сліду при управлінні твердими
побутовими відходами шляхом інтеграції ІОТ систем»(стор. 227).

РОЗДІЛ 1. ТЕОРЕТИКО-МЕТОДОЛОГІЧНІ ОСНОВИ РОЗРОБКИ ТА МОДЕЛЮВАННЯ РОЗУМНИХ СИСТЕМ СОРТУВАННЯ СМІТТЯ

1.1 Сучасний стан та перспективи сортування побутових відходів в Україні та світі

В Україні проблема твердих побутових відходів (ТПВ) залишається актуальною не лише в екологічному, а й у технічному та організаційному вимірах. Система надання муніципальних послуг тривалий час функціонувала в умовах хронічного недофінансування, нерівномірного покриття та зношеної інфраструктури. Для сфери поводження з відходами це означало недостатнє охоплення послугами, обмежені можливості для роздільного збирання та низьку готовність до впровадження сучасних рішень. Оцінка стану муніципальних сервісів показує, що охоплення послугами у сфері поводження з ТПВ становило близько 79%, що вказує на наявність суттєвих прогалин у доступності та якості таких послуг. За цих умов сортування відходів виявляється не окремою локальною операцією, а одним із ключових елементів стійності всієї системи міського обслуговування [1]. Просторовий розподіл масштабів пошкодження інфраструктури в Україні наведено на рисунку 1.1.




Рис. 1.1 Просторовий розподіл пошкоджень інфраструктури за регіонами України станом на кінець 2024 року [1]

Технічна складність проблеми визначається насамперед тим, що змішаний потік побутових відходів має негативну ресурсну цінність: при збиранні без попереднього розділення придатні до переробки матеріали забруднюються органічними залишками, втрачають якість і стають менш привабливими для повторного використання. Змішування харчових, пластикових, паперових, металевих і залишкових фракцій ускладнює вилучення вторинної сировини, збільшує собівартість оброблення та підвищує навантаження на полігони. За відсутності якісного сортування навіть потенційно корисні компоненти потоку відходів перетворюються на важко керований масив змішаного сміття, для якого зростають вимоги до транспортування, перевантаження й захоронення. Саме тому технічно ефективна система повинна забезпечувати не лише накопичення відходів, а й їх початкове розділення на рівня джерела утворення або безпосередньо в контейнері.

Звичайне сортування не забезпечує належної ефективності в умовах зростання обсягів відходів і ускладнення їхньої структури. Ручний підхід характеризується низькою продуктивністю, нестабільною точністю класифікації та залежністю від людського чинника, особливо коли відходи мають подібний зовнішній вигляд, забруднену поверхню або багатокomпонентну будову. Окремою проблемою є те, що традиційні схеми обслуговування контейнерів працюють переважно за фіксованими маршрутами й графіками, без урахування фактичного рівня заповнення, складу відходів і поточного санітарного стану. Це призводить або до переповнення контейнерів, або до неефективних виїздів транспорту, а отже – до зайвих витрат ресурсів. У теплішому кліматі додатково зростає значення оперативного відокремлення органічної фракції оскільки харчові відходи потребують частішого вивезення та не повинні змішуватися з сухими придатними до переробки матеріалами.

За таких умов доцільним є використання інтелектуальних автоматизованих систем, здатних поєднувати визначення типу сміття, його сортування, контроль стану контейнера та передачу даних для прийняття подальших рішень. Інженерна перевага таких систем полягає в тому, що вони дають змогу підвищити точність

класифікацій відходів, виконувати обробку даних у режимі, наближеному до реального часу, зменшувати навантаження на персонал та інтегрувати модуль розпізнавання з виконавчими механізмами контейнера. Для цього використовуються датчики, модулі комп'ютерного зору, системи моніторингу рівня заповнення та алгоритми машинного навчання, які можуть працювати як спільно, так і в межах локального вбудованого контуру керування. Саме така архітектура є найбільш доцільною для інтелектуального контейнера, оскільки рішення щодо класифікації та механічного перенаправлення відходу мають прийматися швидко, без істотних затримок і без постійної залежності від зовнішньої обчислювальної інфраструктури.

Особливе значення для подібних систем має використання саме вбудованих нейромережевих моделей. Їх застосування зумовлене обмеженими обчислювальними ресурсами пристрою, потребою локальної обробки даних та необхідністю швидкої реакції системи без постійного звернення до хмарних сервісів. Для розумної системи сортування сміття це критично, оскільки класифікація відходу, визначення стану заповнення та активація виконавчого механізму повинні відбуватися безпосередньо на місці встановлення пристрою. Такий підхід забезпечує автономність, скорочує затримки, підвищує стійкість роботи системи та створює основу для практичного впровадження інтелектуального сортування в реальних умовах експлуатації.

У глобальному вимірі проблема має масштабніший характер. У 2020 році світовий обсяг муніципальних відходів оцінювався приблизно у 2,126 млрд тонн на рік, а за відсутності суттєвих змін до 2050 року він може зрости до 3,782 млрд тонн, тобто приблизно на 56%. Зростання обсягів сміття визначається як економічним так і демографічним чинником: на прогнозоване збільшення впливають і ріст валового продукту, і збільшення населення. При цьому доступ до систем збирання відходів суттєво відрізняється між регіонами: у регіонах із високим рівнем доходу майже всі муніципальні відходи охоплені збиранням, тоді як у країнах з низьким рівнем доходу цей показник є меншим за 40%. Це означає, що у багатьох частинах світу проблема полягає не лише в кількості відходів, а й у недостатній технічній

спроможності систем контролю, сортування та безпечного оброблення [2]. Порівняльні показники утворення муніципальних відходів у різних регіонах світу наведено на рисунку 1.2.




Рис. 1.2 Обсяги утворення муніципальних твердих побутових відходів у регіонах світу та середній показник на одну особу [2]

Світова практика підтверджує, що ефективне сортування є однією з базових умов переходу до циркулярної моделі поводження з відходами. Для економічно та екологічно доцільного управління потоки побутових відходів мають щонайменше розділятися на харчові та садові відходи, сухі чисті придатні до переробки матеріали та залишкову фракцію. Саме така логіка мінімізує забруднення матеріалів, спрощує подальше вилучення вторинної сировини та дає змогу краще узгодити технології збору, транспортування і переробки. Одночасно підкреслюється, що транспорт зазвичай є найдорожчим компонентом будь-якої системи поводження з відходами, тому підвищення ефективності контейнерів і систем їх обслуговування безпосередньо впливає на загальну економіку процесу.

Окрему увагу в глобальному контексті привертає проблема пластикових відходів як одного з найскладніших для сортування потоків. За сценарієм збереження наявних потенційних тенденцій до 2040 року у світі щорічно може

утворюватися близько 119 млн тонн неналежно керованих пластикових відходів. У країнах поза межами Організації економічного співробітництва та розвитку (OECD) частка неналежно керованого пластикового сміття знизилася з 60% у 1990 до 36% у 2023 році, однак в абсолютному вимірі обсяг такого сміття зріс з 12 до 78 млн тонн на рік через швидке зростання споживання та слабкість систем поводження з відходами. Для подолання цієї проблеми у період 2025-2040 років знадобиться понад 2,1 трлн доларів США інвестицій у системи збирання, сортування, переробки та безпечного видалення пластикових відходів. Це свідчить про те, що вдосконалення сортування є не допоміжним, а стратегічним завданням світового рівня [3]. Динаміка міжнародної фінансової підтримки у сфері управління відходами та зменшення пластикового забруднення наведена на рисунку 1.3.




Рис. 1.3 Динаміка міжнародної фінансової підтримки систем управління відходами та скорочення пластикового забруднення у 2010-2022 роках [3]

Отже, як в Україні, так і у світі проблема ТПВ визначається не лише зростання їх обсягів, а й недостатньою ефективністю традиційних схем сортування та обслуговування розумних систем сортування сміття. Для України це поєднується з обмеженнями муніципальної інфраструктури та потребою в її

технологічному оновленні, а на глобальному рівні – з прогнозованим збільшенням муніципальних відходів і високою вартістю їх безпечного оброблення. За таких умов доцільним є використання інтелектуальних автоматизованих систем, здатних виконувати класифікацію відходів, сортування, локальну обробку даних і контроль стану контейнера в єдиному технічному контурі. Саме такий підхід безпосередньо підводить до розгляду архітектурних рішень, методів автоматичного визначення типу сміття та засобів керування роботою інтелектуального контейнера, що становлять зміст наступних підрозділів.

1.2 Архітектурні рішення побудови ефективних систем розумних контейнерів

Сучасні системи управління ТПВ дедалі частіше базуються на інтеграції інтелектуальних технологій, зокрема штучного інтелекту, Інтернету речей та автоматизованих систем сортування. Використання таких технологій дозволяє значно підвищити ефективність збору, сортування та переробки відходів, що є важливою складовою розвитку концепції циркулярної економіки та сталого розвитку міських територій. Як зазначено у дослідженні Olawade та ін., застосування штучного інтелекту у системах управління відходами дозволяє оптимізувати процеси збору, сортування, переробки та моніторингу відходів шляхом аналізу великих обсягів даних та автоматизації прийняття рішень [4].

Архітектура сучасних інтелектуальних систем сортування відходів зазвичай включає кілька взаємопов'язаних рівнів. До них належать рівень збору даних, рівень обробки інформації, рівень прийняття рішень та рівень управління виконавчими механізмами. На рівні збору даних використовуються різноманітні сенсори, камери та інші пристрої моніторингу, які забезпечують отримання інформації про типи відходів, рівень заповнення контейнерів та інші параметри системи. Отримані дані передаються до систем обробки, де за допомогою алгоритмів машинного навчання або нейромережевих моделей здійснюється аналіз

та класифікація відходів. Загальну структуру застосування технологій штучного інтелекту у системах управління відходами наведено на рисунку 1.4.



Рис. 1.4 Основні напрями застосування технологій штучного інтелекту у системах управління відходами [4]

Як показано на рисунку 1.4, технології штучного інтелекту використовуються у кількох напрямках управління відходами, зокрема у процесах сортування, переробки, контролю якості та автоматизації виробничих операцій. Використання алгоритмів комп'ютерного зору дозволяє автоматично ідентифікувати різні типи матеріалів, включаючи пластик, метал, скло та органічні відходи, що значно підвищує точність сортування та зменшує потребу у ручній праці. Крім того, застосування роботизованих систем у поєднанні з алгоритмами машинного навчання дозволяє підвищити продуктивність сортувальних ліній та зменшити кількість помилок при класифікації відходів.

Одним із ключових елементів архітектури інтелектуальних систем сортування відходів є використання алгоритмів глибоко навчання для автоматичного розпізнавання об'єктів. У дослідженні ConvoWaste запропоновано

систему автоматичного сортування відходів на основі згорткових нейронних мереж, яка дозволяє класифікувати різні типи відходів у режимі реального часу. Запропонована система використовує камеру для отримання зображення відходів, після чого отримані дані передаються до модуля обробки, де здійснюється їх аналіз за допомогою алгоритмів глибоко навчання [5].

Архітектура такої системи включає кілька основних компонентів: модуль збору даних, модуль обробки зображень, нейромережевий класифікатор та систему механічного сортування відходів. На першому етапі відходи переміщуються по конвеєрній стрічці, після чого камера здійснює захоплення зображення. Далі зображення передається до обчислювального модуля, де виконується класифікація відходів за допомогою згорткової нейронної мережі. Після визначення типу відходів система керування активує відповідний сервопривід, який переміщує відходи до відповідного контейнера.

Результати експериментального дослідження показали високу ефективність запропонованої архітектури. Зокрема, точність класифікації відходів за допомогою моделі ConvoWaste становила приблизно 98%, що свідчить про високий потенціал використання нейромережевих моделей у системах автоматизованого сортування відходів. Крім того, система здатна класифікувати шість типів відходів, включаючи пластик, метал, скло, органічні відходи, медичні відходи та електронні відходи. Загальну архітектуру системи інтелектуального управління відходами наведено на рисунку 1.5.



Рис. 1.5 Архітектура системи управління відходами на основі технологій штучного інтелекту [5]

Окрім алгоритмів класифікації відходів, важливим компонентом сучасних розумних систем сортування сміття є системи моніторингу рівня заповнення контейнерів. Такі системи базуються на використанні датчиків відстані, ультразвукових сенсорів або сенсорів типу Time-of-Flight. У дослідженні Pires та ін., представлено IoT-систему моніторингу рівня заповнення контейнерів, що використовує сенсор VL53L8CX, мікроконтролер ESP32-S3 та шлюх на базі Raspberry Pi. Отримані дані передаються до хмарної платформи для подальшого аналізу та оптимізації процесу збору відходів [6].

Експериментальна система включала сенсорний модуль, який розміщувався у верхній частині контейнера. Сенсор здійснював вимірювання рівня заповнення контейнера у реальному часі та передавав отримані дані до IoT-шлюзу через бездротове з'єднання Wi-Fi. Загальне енергоспоживання системи становило 153,8 мА-год, що дозволяє використовувати такі пристрої у автономних системах моніторингу відходів.

Використання таких технологій дозволяє оптимізувати процеси збору відходів. Наприклад, система моніторингу рівня заповнення контейнерів дозволяє планувати маршрути сміттєзбиральної техніки лише для тих контейнерів, які

потребують очищення. Це дозволяє значно зменшити витрати на транспорт та знизити рівень викидів парникових газів, пов'язаних із перевезенням відходів.

Таким чином, сучасні архітектурні рішення для побудови ефективних розумних систем сортування сміття базуються на інтеграції технологій штучного інтелекту, машинного навчання та Інтернету речей. Використання сенсорних систем моніторингу, алгоритмів комп'ютерного зору та автоматизованих механізмів сортування дозволяє значно підвищити ефективність управління побутовими відходами, зменшити витрати на їх обробку та забезпечити більш раціональне використання вторинних ресурсів.

1.3 Методи автоматичного визначення типу сміття

Автоматичне визначення типу сміття є одним із ключових етапів побудови інтелектуальних систем сортування ТПВ, оскільки саме точність і швидкість класифікації визначають ефективність подальшого розподілу відходів за категоріями, рівень вилучення вторинної сировини та загальну результативність роботи системи. Сучасні дослідження у цій сфері демонструють кілька основних підходів до автоматичного розпізнавання відходів: методи на основі комп'ютерного зору та згорткових нейронних мереж, полегшені архітектури для вбудовних систем, а також спектральні та багатоспектральні методи, що використовують відбиття світла на різних довжинах хвиль. Узагальнений аналіз сфер застосування штучного інтелекту а управлінні відходами, що охоплює сортування, моніторинг, збирання та переробку, ґрунтується на опрацюванні 246 публікацій за 2021-2023 роки, з яких до фінального огляду було включено 71 дослідження, тобто 28,86% від початкового відібраного масиву. Це свідчить про високу інтенсивність розвитку напряму та про зростання ролі AI-рішень у задачах автоматичної ідентифікації сміття [7, с. 2-4].

На початковому рівні автоматичне визначення типу сміття може розглядатися як частина ширшої інтелектуальної системи поводження з відходами, де розпізнавання матеріалу поєднується з моніторингом контейнерів, планування

маршрутів, динамічним розкладом вивезення та прогнозуванням навантаження на інфраструктуру. Комплексне бачення застосування штучного інтелекту у сфері поводження з відходами передбачає виокремлення чотирьох основних напрямів: smart bin systems, route optimization, dynamic scheduling і demand prediction. У межах такого підходу автоматичне визначення типу сміття виступає не як ізольований процес, а як складова ширшої інтелектуальної архітектури, що забезпечує ефективне функціонування всієї системи. З огляду на це, доцільним є подання узагальненої схеми на початку підрозділу як концептуальної основи для подальшого аналізу конкретних методів класифікації. У сучасних системах управління відходами технології штучного інтелекту застосовуються на різних етапах, починаючи від моніторингу стану контейнерів і завершуючи прогнозуванням навантаження на систему збирання відходів. Такий підхід формує основу для побудови комплексних інтелектуальних рішень, у межах яких модуль автоматичного визначення типу сміття поєднується з іншими функціональними компонентами [7, с. 5-6].




Рис. 1.6 Основні напрями застосування інтелектуальних методів у системах поводження з відходами [7]

Одним із найбільш поширених підходів до автоматичного визначення типу сміття є використання методів комп'ютерного зору в поєднанні зі згортковими нейронними мережами. Перевага цього підходу полягає у можливості класифікації відходів за звичайним RGB-зображенням без застосування складної спектральної

апаратури. У роботі [8] запропоновано полегшену архітектуру Focus-RCNet, орієнтовану на автоматичну класифікацію сміття в умовах обмежених обчислювальних ресурсів, що є особливо важливим для мобільних та вбудованих систем. Для навчання та тестування моделі було використано набір даних TrashNet, що містив 2528 зображень шести класів: paper, glass, plastic, metal, cardboard і trash. Із загального обсягу даних 1768 зображень використовувалися для навчання, а 769 – для валідації. За класами вибірка розподілялася таким чином: 594 зображення паперу, 501 скла, 483 пластику, 410 металу, 403 картону та 137 зображень катерії змішаного сміття. Така структура набору даних дала змогу оцінити ефективність моделі як для масових категорій відходів, так і для менш представлених класів.

Архітектурно модель Focus-RCNet поєднує модуль Focus, sandglass-структуру та механізм уваги SimAM. Вхідне RGB-зображення розміров 380 на 380 проходить послідовну обробку в кількох функціональних блоках, що забезпечують вилучення інформативних ознак із мінімізацією обчислювальних витрат. Загальна обчислювальна складність моделі становить 418,8 MFlops, тоді як teacher-модель EfficientB4 має 17,559 млн параметрів і 4,49 GFlops. Водночас Focus-RCNet містить лише 525,802 тис параметрів, що свідчить про її значно менше ресурсомісткість і придатність для використання у вбудованих системах автоматичного сортування. Наведена архітектура є показовою з погляду реалізації автоматичного визначення типу сміття у вбудованих інтелектуальних системах, оскільки вона демонструє можливість досягнення високої точності класифікації при обмежених апаратних ресурсах.




Рис. 1.7 Архітектура моделі Focus-RCNet для автоматичної класифікації сміття [8]

Експериментальні результати засвідчили високу ефективність запропонованої архітери. Базова версія Focus-RCNet без додаткових удосконалень забезпечила точність 88,07%. Використання Focus-модуля підвищило цей показник до 91,20%, тобто на 3,13 відсоткового пункту. Подальше введення механізму уваги SimAM дало змогу досягти точності 92,20%. Отримані результати свідчать, що навіть відносно компактні архітектурні модифікації можуть забезпечити помітне підвищення якості класифікації без істотного зростання обслуговальної складності. За окремими класами модель продемонструвала такі показники precision/recall/F1-score: cardboard – 0,99/0,96/0,97; glass – 0,91/0,90/0,90; metal – 0,89/0,93/0,91; paper – 0,94/0,97/0,95; plastic – 0,91/0,90/0,90; trash – 0,80/0,74/0,77. Найскладнішим для класифікації виявився клас trash, що може пояснювати його найменшою представленістю у вибірці та значною неоднорідністю візуальних ознак. Макросередні значення precision, recall, F1-score становили 0,91, 0,90 і 0,90 відповідно.

Порівняння з іншими моделями показало, що Focus-RCNet-KD забезпечила точність 92%, тоді як ShuffleNetV1 продемонструвала 86%, MobileNetV1 – 85%, DenseNet121 – 88%, а teacher-модель EfficientB4 – 94%. Це дає підстави стверджувати, що використання knowledge distillation є доцільним підходом для

побудови компактних нейромережевих моделей, здатних забезпечити прийнятний баланс між точністю класифікації та обчислюваною ефективністю.




Рис. 1.8 Схема дистиляції знань у моделі автоматичного визначення типу сміття [8]

Поряд із методами, заснованими на аналізі RGB-зображень, важливе місце посідають спектральні підходи до автоматичного визначення типу сміття. Їхня перевага полягає у можливості ідентифікації матеріалу не лише за зовнішньою формою або кольором, а за його оптичними характеристиками. У роботі [9] запропоновано підхід short-wave infrared optical reflectance, що базується на використанні SWIR-діапазову 1000-2500 нм. У попередньому етапі дослідження ця система, яка включала 10 ретельно підібраних світлодіодів, забезпечила точність класифікації на рівні 98%, що підтверджує високу перспективність спектрального аналізу для задач автоматичного сортування матеріалів. Система працює за принципом послідовного освітлення зразка LED-джерелами, вимірювання відбитого сигналу фотодетектором, його підсилення за допомогою trans-impedance amplifier та подальшої класифікації в середовищі MATLAB. У дослідженні було проаналізовано сім матеріалів: PET, прозорий і білий PP, композит AB400L на основі PLA/PBS, скло, папір і алюміній. Такий підхід є цінним для систем сортування відходів, оскільки дозволяє ідентифікувати матеріал не лише за формою чи кольором, а за його фізико-хімічними оптичними характеристиками.

Ще одним перспективним напрямом є низьковартісне багатоспектральне розпізнавання пластикових відходів, наведене у джерелі [10]. У межах цього

дослідження було сформовано набір із 1200 зразків пластикових відходів, для кожного з яких фіксувалось 18 спектральних каналів у діапазоні 410-910 нм. Розпізнавання виконувалося для шести типів пластиків: PET, HDPE, PVC, LDPE, PP і PS. Для аналізу використовувалися різні алгоритми машинного навчання, включаючи CNN, MLP, decision trees, KNN, LDA, logistic regression, naïve Bayes, random forest і SVM. Найкращі результати в дослідженні продемонструвала CNN-модель після попередньої обробки медотом PCA: accuracy – 72,50%, precision – 72,43%, recall – 72,50%, F1-score – 72,38%. Для тієї ж CNN без зменшення розмірності accuracy становила 72,17%. Багатошаровий перцептрон показав 70,25% після PCA та 70,08% на сирих даних. Отримані результати свідчать, що багатоспектральний підхід є працездатним для ідентифікації полімерних матеріалів, однак задачі розрізнення близьких за властивостями типів пластиків залишаються складними навіть для сучасних алгоритмів машинного навчання.




Рис. 1.9 Порівняння точності методів автоматичного розпізнавання пластикових відходів [10]

Порівняльний аналіз джерел [8], [9] і [10] показує, що методи автоматичного визначення типу сміття можна умовно розділити на дві великі групи. Перша група – це візуальні методи на основі RGB-зображень і нейромереж, які забезпечують високу точність у задачах багатокласової класифікації та є зручним для вбудовування у розумні системи сортування сміття. Прикладом є Focus-RCNet із точністю 92,20% при невеликій кількості параметрів і низькій обчислювальній

складності. Друга група – це спектральні та багатоспектральні методи, які орієнтовані на розпізнавання саме матеріалу, а не лише зовнішньої форми об'єкта. SWIR-підхід показує, що при правильному доборі спектральних каналів можлива дуже висока точність, до 98% у попередніх експериментах, тоді як багатоспектральна система демонструє точність близько 72,5% для класифікації шести типів пластиків. Це означає, що спектральні методи є особливо перспективними для сортування однорізних за зовнішнім виглядом полімерних матеріалів, тоді як RGB-нейромережі краще працюють у змішаних побутових потоках, де є відмінності за формою, текстурою і кольором.

Отже сучасні методи автоматичного визначення сміття базуються на поєднанні технологій комп'ютерного зору, глибокого навчання та спектрального аналізу. Узагальнений підхід до інтелектуалізації систем поводження з відходами формує концептуальне підґрунтя для розуміння місця модуля класифікації у загальній структурі розумних систем. Полегшені згорткові архітектури, такі як Focus-RCNet демонструють високу придатність до використання у вбудованих системах автоматичного сортування. Спектральні методи, зокрема SWIR-підхід, забезпечують високу точність ідентифікації матеріалів, тоді як багатоспектральні low-cost системи відкривають перспективи створення доступних рішень для розпізнавання полімерних відходів. Сукупність цих підходів формує науково-технічну основу для побудови інтелектуальних систем автоматизованого сортування твердих побутових відходів на основі вбудованих нейромережових моделей.

1.4 Методи автоматичного сортування та контролю роботи контейнера

Методи автоматичного сортування та контролю роботи контейнера є невід'ємною складовою сучасних інтелектуальних систем поводження з твердими побутовими відходами, оскільки забезпечують не лише розподіл відходів за типами, а й постійний моніторинг заповнення контейнерів, контроль параметрів середовища, оптимізацію часу вивезення та підвищення загальної ефективності

експлуатації системи. На відміну від традиційних підходів, у яких сортування та обслуговування контейнерів виконується за фіксованими правилами або вручно, сучасні рішення поєднують сенсорні технології, алгоритми машинного навчання, комп'ютерний зар і прогнознi моделі, що дозволяє перейти до адаптивного, даних-орієнтованого управління. У цьому контексті особливий інтерес становлять дослідження, у яких автоматичне сортування розглядається разом із контролем роботи контейнера як єдина інтегрована система.

Одним із найбільш показових підходів до автоматичного сортування є інтеграція сесорної технології та глибокого навчання, запропонована в дослідженні [11]. У цій роботі розглянуто інтелектуальну систему розділення пластикових пакувальних відходів, яку можна застосувати як безпосередньо в smart waste bin, так і в централізованій сортувальній установці. Архітектура системи поєднує два паралельні канали аналізу: сенсорний та візуальний. Сенсорна частина використовує 6 датчиків – near-infrared, humidity, temperature, CO₂, CH₄, laser profile sensor, тоді як візуальний канал базується на RGB-камері та згорткових нейронних мережах. Такий підхід дозволяє враховувати не лише зовнішній вигляд упаковки, а й її матеріальний склад, ступінь забруднення, геометричні розміри та стан поверхні. У межах case study було досліджено 60 об'єктів шести типів відходів, а для навчання моделей створено власну базу 4786 зображень, з яких 902 належали до класу plastic bottles, 750 – plastic bags, 804 – plastic cups, 719 – food packaging, 847 – Tetra Pak cartons і 764 – residual waste. Для класифікації було порівняно чотири попередньо навчені CNN-моделі: ResNet-50, MobileNet-v2, Inception-v3 і DenseNet-201. Найкращий результат показала модель Inception-v3 з загальною точністю 78%, що в умовах багато класового сортування з неоднорідними та частково забрудненими об'єктами є прийнятним результатом для практичних систем початкового рівня. Автори підкреслюють, що камера, яка спирається лише на візуальні ознаки, частіше помиляється у випадках, коли зовнішній вигляд не відображає реальний матеріальний склад, тоді як сенсорний канал краще розпізнає склад матеріалу, але має обмеження для темних об'єктів і при наявності органічних залишків. Саме тому найперспективнішим визначено

комбінований підхід, у якому дані камер і сенсорів використовуються спільно для підвищення чистоти кінцевих фракцій. Додатково у роботі наголошується, що джерельне сортування потенційно здатне підвищити ефективність рециклінгу щонайменше на 15%, а якість вторинного пластику значною мірою залежить від зменшення перехресного забруднення фракцій.




Рис. 1.10 Концептуальна схема інтелектуальної системи сортування пластикових відходів [11]

У роботі важливим є не лише сам факт використання сенсорів і камер, а й методологія прийняття рішень щодо кінцевого розподілу відходів. Для цього було сформульовано задачу оптимізації у вигляді MINLP-моделі, реалізованої в GAMS, де мінімізувалися: кількість об'єктів, що потрапляють до residual waste і dirty bins, та кількість неправильно класифікованих об'єктів. Таким чином, автоматичне сортування розглядалось не як проста класифікація, а як оптимізаційна задача з урахуванням помилок розпізнавання, придатності до переробки та ризику забруднення кінцевих фракцій. Це є важливим методичним положенням для

дипломної роботи, оскільки демонструє, що ефективність розумних систем сортування сміття визначається не лише точність моделі комп'ютерного зору, а й логікою маршрутизації об'єкта до відповідного відсіку, тобто алгоритмом керування роботою контейнера.

Іншу важливу групу методів становлять системи контролю роботи контейнера, орієнтовані на безперервний моніторинг рівня заповнення, прогнозування моменту переповнення та оптимізацію маршрутів вивезення. Саме такий підхід представлено у джерелі [12], де описано AI-enabled smart IoT waste bin monitoring and dynamic collection system. У межах експерименту було розгорнуто 50 розумних контейнерів у трьох типах зон: residential, commercial та public, а польове дослідження тривало 45 днів. Базовим елементом системи є ультразвуковий датчик HC-SR04 з діапазоном вимірювання 2-400 см, що передає дані через MQTT over Wi-Fi до хмарної системи аналізу. Для прогнозування рівня заповнення використовувалися модель LSTM with Reinforcement Learning, навчена на 6 місяцях bin-level data з горизонтом прогнозу 24 години. Навчальна точність моделі становила 96,7% а валідаційна – 93,2%. У результаті застосування прогнозного механізму вдалося знизити кількість emergency collections на 62%, оскільки вивезення почало ґрунтуватися не на реакції на вже переповнений контейнер, а не превентивному спрацюванні за прогнозом.




Рис. 1.11 Порівняння прогнозованого та фактичного рівня заповнення контейнера

[12]

Крім прогнозування, джерело [12] містить переконливі результати щодо власне моніторингу рівня заповнення контейнера. Загальна середня точність контролю fill-level становила 97,6%, а середній рівень false alerts – лише 1,5%. За типами зон показники були такими: residential – 97,2% точності та 1,6% хибних спрацювань, commercial – 96,5% і 2,1%, public spaces – 98,9% і 0,9% відповідною. Отримані результати свідчать, що система демонструє найкращу надійність у публічних просторах, тоді як у комерційних зонах похибка дещо зростає, імовірно через більш нерівномірний та інтенсивний характер накопичення відходів. Для реальної експлуатації це означає, що в розумних системах сортування сміття доцільно передбачити адаптивні пороги спрацювання та корекцію моделей залежно від типу міського середовища.




Рис. 1.12 Точність визначення рівня заповнення контейнерів у різних функціональних зонах [12]

Суттєвим результатом дослідження [12] є також підтвердження ефективності динамічного маршрутування. У порівнянні зі static routing середня щоденна довжина маршруту зменшилась з 110 км до 76 км, тобто приблизно на 31%. Середнє добове споживання пального знизилося з 23,4л на добу до 15,9л, кількість missed pickups скоротилася з 6 до 1 на тиждень, а vehicle idle time зменшився з 80 до 42хв на добу, тобто приблизно на 48%. Середній час реакції системи на зміну стану контейнера становив лише 3,8 секунди, що свідчить про практичну

придатність edge-cloud архітектури для оперативного управління. Додатково встановлено, що середнє енергоспоживання однієї розумної системи сортування сміття не перевищувало 100 ват-годин за день, а sensor failure rate був лише 2%, причому несправності здебільшого компенсувалися вбудованими калібрувальними перевітками. Важливо, що в цій же системі було реалізовано базову функцію source-level separation, де поєднання gas sensors та image processing дало 87% точності класифікації на дві категорії – wet waste та dry waste. Це підтверджує, що контроль роботи контейнера може бути об'єднаний із первинним сортування без значного ускладнення архітектури.




Рис. 1.13 Точність класифікації відходів на вологі та сухі фракції [12]

Якщо джерело [12] демонструє переваги масштабованої IoT-AI системи для міського середовища, то джерело [13] орієнтоване на більш компактну, нозьковартісну багатосенсорну архітектуру, придатну для муніципального та напівмуніципального застосування. У цьому дослідженні запропоновано IoT-based smart waste management system, що поєднує 5 датчиків: HC-SR04 для вимірювання fill-level, HX711 load-cell для контролю маси, DHT22 для температури та вологості, MQ-135 для якості повітря і Ublox NEO-6M GPS для просторового відстеження. Польове випробовування тривало 30 днів і охоплювало 12 муніципальних

контейнерів у Малазії. За підсумками експерименту система досягла 85% точності контролю рівня заповнення, менше 3% MAE для оцінки ваги та 100% виявлення небезпечних умов за температурою більше 40 або відносною вологістю більше 70% RH. Додатково GPS-assisted dynamic routing зібезпечило скорочення truck mileage на 20% і CO₂, emissions на 18% у порівнянні з fixed schedules. На наступному рисунку зображено графік валідації вимірювання рівня сміття оскільки він демонструє узгодженість між ручними вимірами та показами сенсора.




Рис. 1.14 Валідація сенсорного вимірювання рівня заповнення контейнера [13]

Це дослідження є цінним також тим, що демонструє розширення функціоналу розумних систем сортування сміття за межу простого контролю заповнення. Автори обґрунтовують необхідність моніторингу температури й вологості як індикаторів прискореного розкладання органічних фракцій, потенційного поширення запахів та ризику погіршення санітарного стану. Для вибору сенсора fill-level в роботі окремо зазначено, що ультразвуковий модуль був обраний замість інфрачервоних або камерних систем, оскільки забезпечує менше 3% distance error за змінного освітлення та наявності забруднення, при цьому споживає лише 15 mA в активному режимі. Це має практичне значення для розробки енергоефективного контейнера, який може працювати автономно в умовах обмеженого енергоживлення. Таким чином, у порівнянні з [12], де акцент зроблено на AI-прогнозуванні та логістиці, у [13] сильнішою є саме багатосенсорна складова контролю стану контейнера.




Рис. 1.16 Динаміка температури та вологості всередині контейнера в процесі моніторингу [13]

Порівняльний аналіз методів, реалізованих у дослідженнях, показує, що ефективна розумна система сортування сміття повинна поєднувати принаймні три функціональні рівні: автоматичне сортування, контроль стану контейнера та адаптивне управління обслуговуванням. Такий підхід дає змогу не лише розподіляти відходи за відповідними категоріями, а й своєчасно відстежувати зміну стану контейнера, прогнозувати потребу у вивезенні та підвищувати загальну ефективність функціонування системи.

Особливу увагу в сучасних дослідженнях приділено підвищенню якості сортування за рахунок поєднання сенсорних засобів і методів глибокого навчання. Одні підходи орієнтовані насамперед на точніше розпізнавання типів відходів і заміщення змішування різних фракцій, інші – на прогнозування рівня заповнення контейнера та оптимізацію маршрутів його обслуговування, що дає змогу зменшити пробіг транспорту, витрати пального та кількість пропущених вивезень. Окремий напрям становлять багатопараметричні системи контролю, у яких одночасно відстежуються маса відходів, температура, вологість, якість повітря та місцезнаходження контейнера. У сукупності такі рішення демонструють перехід

від окремих технічних засобів до комплексних інтелектуальних систем, у яких контейнер виступає вже не пасивною ємністю для накопичення відходів, а активним елементом міської інфраструктури.

Узагальнюючи результати аналізу, слід зазначити, що автоматичне сортування та контроль роботи системи доцільно оцінювати не лише за окремими показниками точності, а за загальною ефективністю функціонування. Для систем сортування важливими є частота отриманих фракцій, частка помилкових віднесень відходів до іншої категорії та стійкість роботи в умовах неоднорідного і забрудненого потоку сміття. Для систем контролю контейнера визначальними показниками є точність визначення рівня заповнення, швидкість реагування, енергоспоживання та вплив на організацію вивезення відходів. Саме тому найбільш перспективними для практичного застосування є комбінований підхід, у якому камери та нейромережеві алгоритми відповідають за розпізнавання типу сміття, сенсорні засоби – за контроль фізичного стану контейнера, а прогнозні моделі – за прийняття рішень щодо подальшого обслуговування системи. Така архітектура може бути покладена в основу проєктування інтелектуальної системи автоматизованого сортування твердих побутових відходів.

РОЗДІЛ 2. АНАЛІТИЧНЕ ДОСЛІДЖЕННЯ НАЯВНИХ МОДЕЛЕЙ РОЗУМНИХ СИСТЕМ СОРТУВАННЯ СМІТТЯ

2.1 Аналіз існуючих моделей та технологій розумних систем сортування сміття

У межах дослідження інтелектуальної системи автоматизованого сортування твердих побутових відходів було виконано підготовку набору зображень, придатного для подальшого моделювання роботи нейромережевої моделі класифікації. Основною метою цього етапу було не лише зібрати достатню кількість візуальних даних, а й привести їх до єдиної структури, яка може бути безпосередньо використана під час навчання, валідації та тестування моделей комп'ютерного зору. Оскільки система розумного контейнера має працювати з різними типами побутових відходів у реальних умовах, для підготовки даних було використано два відкриті набори зображень із платформи Kaggle: Garbage Classification [14] та Garbage Classification (12 classes) [15]. Перший набір містить класичні категорії побутових відходів, зокрема cardboard, glass, metal, paper, plastic і trash, що відповідає базовій задачі сортування вторинної сировини. Другий набір має ширшу структуру класів і включає додаткові категорії, зокрема biological, battery, clothes, shoes, white-glass, brown-glass, green-glass та інші, що дозволяє розширити вихідний набір даних і зробити його ближчим до реального змішаного потоку побутових відходів.

Використання двох датасетів є доцільним з огляду на те, що окремий набір даних часто має обмеження за кількістю класів, різноманітністю зображень або умовами зйомки. Об'єднання двох джерел дозволило сформувати більш репрезентативну вибірку для оцінки ефективності моделей сортування. При цьому пряме механічне злиття датасетів було б некоректним, оскільки їхні класи мають різний рівень деталізації. Наприклад, у першому наборі скло подано як один клас glass, тоді як у другому воно може бути представлене окремими підкласами brown-glass, green-glass і white-glass. Аналогічно, частина класів другого набору не відповідає основним фракціям контейнерного сортування, але може бути віднесена

до узагальненої категорії залишкових або інших відходів. Тому на етапі підготовки було виконано уніфікацію класів, тобто приведення вихідних назв категорій до єдиної системи цільових класів.

Для автоматизації цього процесу було розроблено програмний алгоритм підготовки даних мовою Python. Загальна логіка алгоритму передбачає послідовне виконання кількох етапів: зчитування архівів із вихідними датасетами, їх розпакування, рекурсивний пошук зображень у вкладених каталогах, визначення вихідного класу за назвою папки, зіставлення цього класу з уніфікованою категорією, перевірку файлів, видалення дублікатів, зміну розміру зображень, розподіл даних на підвибірки та збереження результатів у форматі, придатному для подальшого моделювання. Блок-схему розробленого алгоритму підготовки даних наведено на рис. 2.1.

На першому етапі програма перевіряє наявність ZIP-архівів у вхідному каталозі data/raw. Такий підхід дає змогу не розпаковувати датасети вручну та зменшує ймовірність помилок у структурі папок. Після запуску скрипт автоматично розпаковує архіви Garbage Classification.zip і Garbage Classification (12 classes).zip, після чого виконує пошук файлів із графічними розширеннями. Важливо, що алгоритм не прив'язаний до фіксованого рівня вкладеності каталогів, тому він коректно працює навіть у випадку, коли зображення знаходяться у декількох вкладених папках. Це є практично важливим, оскільки датасети з відкритих джерел часто мають різну внутрішню організацію, а ручне перенесення файлів може призвести до втрати частини даних або порушення відповідності між зображенням і класом.

На другому етапі здійснюється нормалізація класів. Для цього в програмі використано словник відповідності між вихідними назвами папок і цільовими категоріями. У результаті класи cardboard і paper були об'єднані в категорію paper_cardboard, класи plastic – у категорію plastic, класи glass, brown-glass, green-glass і white-glass – у категорію glass, metal – у категорію metal, biological – у категорію organic, а класи battery, clothes, shoes, trash та інші подібні категорії – у клас other. Така схема відповідає логіці роботи розумного контейнера, для якого

важливо не стільки розпізнавати кожен вузький підтип об'єкта, скільки правильно віднести відхід до технологічно значущої фракції.

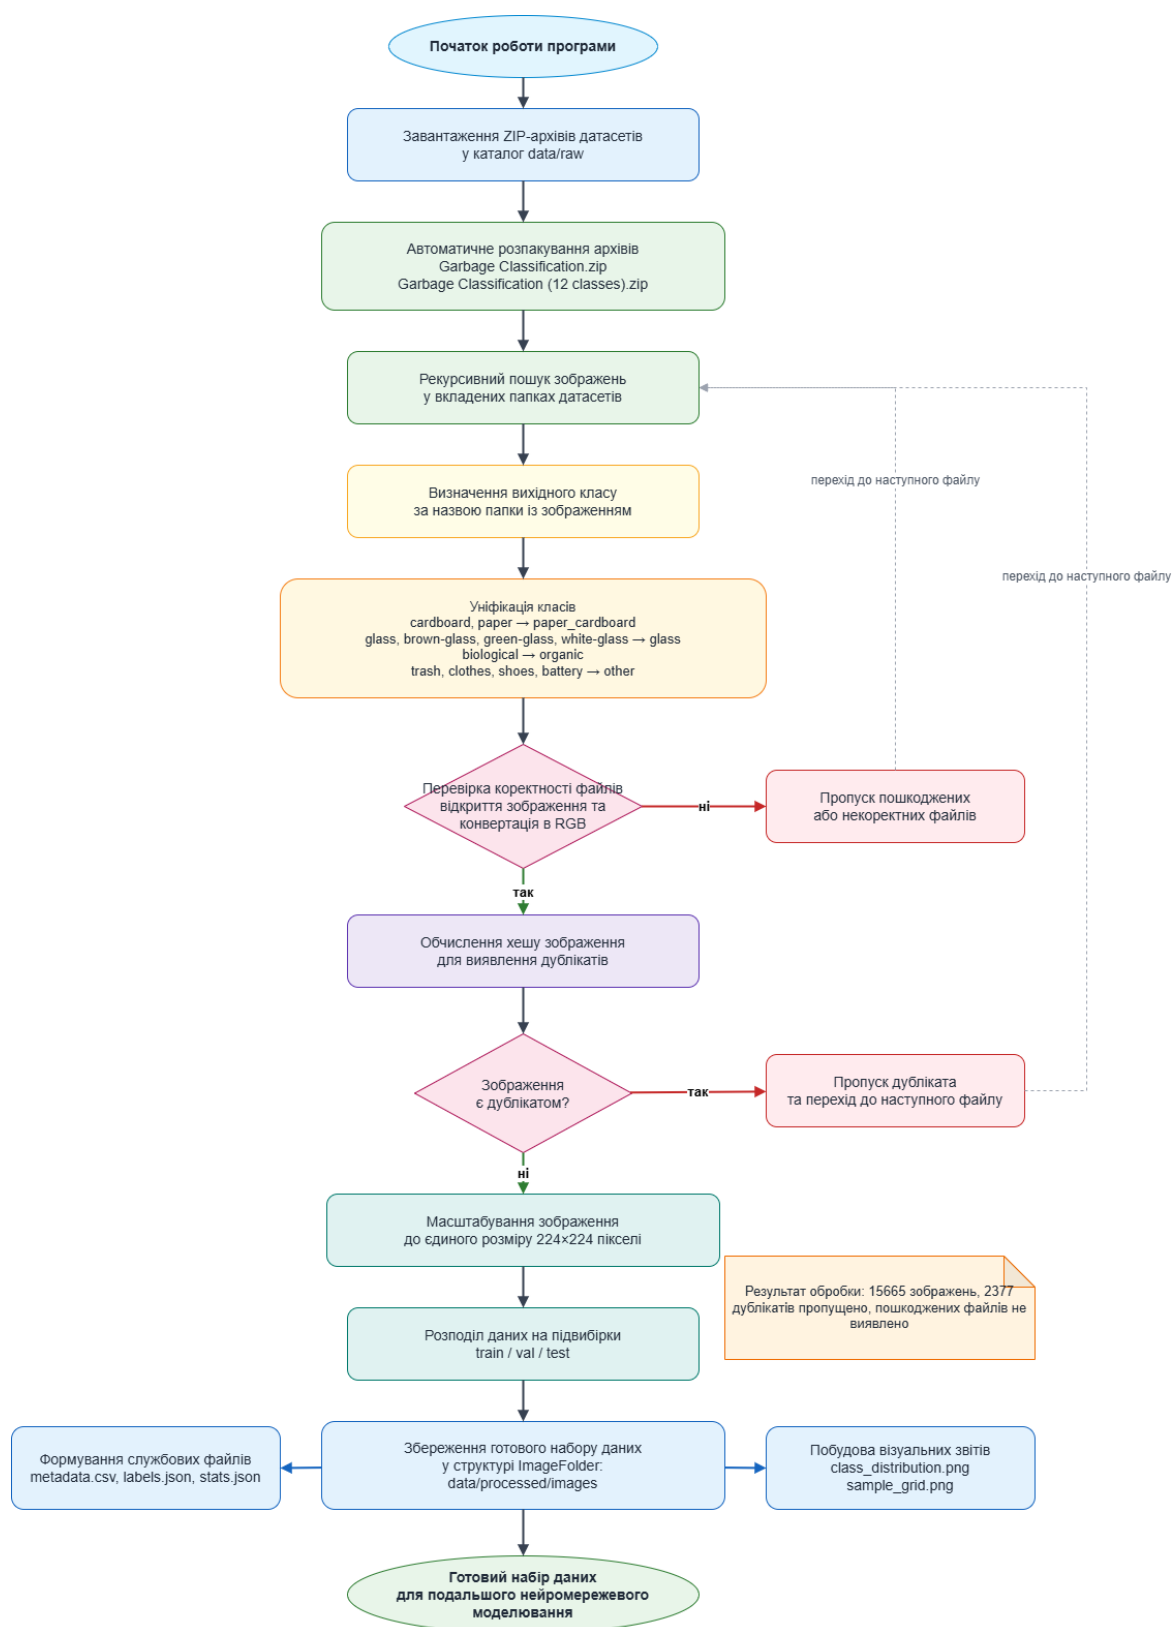


Рис. 2.1 Блок-схема алгоритму автоматизованої підготовки набору даних для моделювання системи сортування твердих побутових відходів

Наприклад, для механізму сортування достатньо визначити, чи потрібно спрямувати об'єкт до відсіку для скла, металу, пластику, паперу, органіки або залишкових відходів.

На третьому етапі програма виконує контроль якості файлів. Кожне зображення відкривається засобами бібліотеки Pillow, переводиться у формат RGB і масштабується до єдиного розміру 224×224 пікселі. Такий розмір обрано тому, що він є типовим для багатьох згорткових нейронних мереж і полегшених моделей комп'ютерного зору, зокрема MobileNet, EfficientNet та інших архітектур, які можуть використовуватися у вбудованих системах. Уніфікація розміру зображень забезпечує однакову форму вхідних даних і спрощує подальше навчання моделі.

Додатково алгоритм перевіряє пошкоджені файли: якщо зображення неможливо відкрити або коректно обробити, воно не потрапляє до підготовленого набору.

Окремим елементом обробки є видалення дублікатів. Для цього для кожного файлу обчислюється хеш, який дозволяє виявляти однакові зображення навіть у тому випадку, якщо вони розміщені в різних папках або походять з різних датасетів. Такий крок є важливим для коректної оцінки ефективності моделі, оскільки дублікати можуть штучно завищувати точність класифікації. Якщо однакове або практично ідентичне зображення потрапить одночасно до навчальної та тестової вибірок, модель фактично буде перевірятися на вже відомих прикладах, що спотворює результати експерименту. У результаті роботи програми було оброблено 15665 зображень, пропущено 2377 дублікатів і не виявлено пошкоджених файлів. Консольний результат виконання програми наведено на рис. 2.2.

```
[INFO] Розпакування: Garbage Classification (12 classes).zip
[INFO] Розпакування: Garbage Classification.zip
[INFO] Оброблено зображень: 15665
[INFO] Пропущено дублікатів: 2377
[INFO] Пропущено пошкоджених файлів: 0

[OK] Підготовку набору даних завершено.
[OK] Готові зображення: data\processed\images
[OK] Метадані: data\processed\metadata.csv
[OK] Мітки класів: data\processed\labels.json
[OK] Статистика: data\processed\stats.json
[OK] Інфографіка: data\processed\reports\class_distribution.png
[OK] Приклади фото: data\processed\reports\sample_grid.png
```

Рис. 2.2 Консольний результат виконання програми автоматизованої обробки та формування набору даних для моделювання

Після очищення й уніфікації дані було розподілено на три підвибірки: навчальну, валідаційну та тестову. Навчальна підвибірка використовується для налаштування ваг нейромережевої моделі, валідаційна – для контролю якості під час навчання та добору параметрів, а тестова – для фінальної оцінки ефективності моделі на даних, які не використовувалися під час навчання. Такий поділ забезпечує методично коректну перевірку здатності моделі узагальнювати ознаки відходів і класифікувати нові зображення. Підготовлені зображення збережено у структурі ImageFolder, де кожна підвибірка має окремі папки за назвами класів. Цей формат є зручним для подальшої роботи з бібліотеками TensorFlow, Keras або PyTorch, оскільки дає змогу без додаткового ручного маркування завантажувати дані у генератори або даталоадери.

У результаті виконання програми було сформовано каталог `data/processed/images`, який містить готові зображення, структуровані за підвибірками та класами. Додатково було автоматично створено файл `metadata.csv`, де для кожного зображення збережено шлях до файлу, цільовий клас, вихідний клас, джерело даних і належність до навчальної, валідаційної або тестової підвибірки. Такий файл є важливим для аналітичного опису набору даних, повторюваності експерименту та можливості подальшого статистичного аналізу. Також сформовано файл `labels.json`, у якому зафіксовано відповідність між назвами класів і числовими мітками, та файл `stats.json`, що містить узагальнену статистику обробки.

Для візуальної перевірки результатів програма додатково формує інфографіку з розподілом зображень за класами та підвибірками, а також сітку прикладів зображень із підготовленого набору. Це дозволяє не лише контролювати технічну коректність обробки, а й наочно продемонструвати зміст сформованого датасету в дипломній роботі. На рис. 2.3 наведено результат візуалізації, який містить розподіл зображень між класами `glass`, `metal`, `organic`, `other`, `paper_cardboard` і `plastic`, а також приклади фото з підготовленого набору.




Рис. 2.3 Візуалізація результатів підготовки набору даних: розподіл зображень за класами та приклади об'єктів із сформованої вибірки

З рисунка видно, що найбільшу кількість прикладів має клас *other*, що пояснюється об'єднанням у ньому кількох вихідних категорій, які не належать до базових фракцій вторинної сировини. Така особливість є очікуваною для реалістичного потоку побутових відходів, де залишкові та змішані категорії можуть бути більш різноманітними за візуальними ознаками, ніж окремі класи скла, металу чи пластику.

Приклади зображень на рис. 2.3 підтверджують, що підготовлений набір містить візуально різноманітні об'єкти: пляшки, металеві упаковки, органічні залишки, елементи одягу, паперові матеріали та пластикові предмети. Це важливо для подальшого моделювання, оскільки нейромережева модель повинна навчитися розпізнавати не лише ідеально сфотографовані об'єкти на однорідному фоні, а й предмети з різними формами, кольорами, текстурами та умовами освітлення. Водночас візуальний аналіз показує, що деякі класи можуть бути складними для класифікації через подібність матеріалів або неоднорідність зображень. Наприклад, частина пластикових і паперових упаковок може мати схожу форму, а клас *other* містить суттєво різні об'єкти, що в подальшому може впливати на точність моделі.

2.2 Порівняльний аналіз ефективності моделей автоматичного сортування відходів

Після формування підготовленого набору даних наступним етапом дослідження стало проведення порівняльного моделювання роботи нейромережових моделей автоматичного сортування відходів. Необхідність цього етапу зумовлена тим, що для інтелектуальної системи сортування твердих побутових відходів важливо не лише забезпечити розпізнавання класів зображень, а й визначити, яка модель є найбільш доцільною для подальшого використання у складі вбудованої системи. У такому випадку оцінюється не одна випадково обрана архітектура, а кілька моделей із різними властивостями: проста базова згорткова мережа, полегшена мобільна модель і більш ефективна сучасна архітектура. Це дає змогу обґрунтовано порівняти їхню придатність для задачі автоматичного сортування відходів за зображеннями.

Моделювання виконувалося на основі підготовленого у підрозділі 2.1 набору даних, який має структуру, зручну для навчання моделей комп'ютерного зору. Вхідні дані розміщено у каталозі `processed/images` і поділено на три підвибірки: `train`, `val` і `test`. Кожна з них містить окремі папки відповідно до цільових класів: `glass`, `metal`, `organic`, `other`, `paper_cardboard` і `plastic`. Така організація відповідає формату `ImageFolder`, який широко використовується у задачах класифікації зображень, оскільки клас об'єкта визначається за назвою папки, у якій розміщено відповідний файл. Це спрощує процес завантаження даних і дає змогу уникнути ручного формування міток для кожного зображення.

Метою моделювання було створення єдиної програмної процедури, яка дозволяє навчати кілька моделей в однакових умовах, оцінювати їх на одній тестовій вибірці та формувати порівняльні матеріали для подальшого аналізу. Саме такий підхід є важливим для коректності експерименту, оскільки порівняння моделей має виконуватися за однаковими правилами: на одному наборі даних, із однаковим розміром вхідних зображень, однаковою кількістю класів, однаковою

логікою навчання та однаковими метриками оцінювання. Загальну схему процесу порівняння моделей автоматичного сортування відходів наведено на рис. 2.4.




Рис. 2.4 Схема процесу порівняльного моделювання моделей автоматичного сортування відходів

Розроблена програма реалізує повний цикл експериментального моделювання. На початку роботи вона перевіряє наявність підготовленого набору даних, зчитує структуру класів і формує навчальний, валідаційний та тестовий потоки зображень. Для цього використовується механізм пакетного завантаження даних, за якого зображення подаються до моделі не по одному, а невеликими групами. Такий підхід зменшує навантаження на оперативну пам'ять і дозволяє працювати з достатньо великим набором зображень навіть на звичайному персональному комп'ютері. Перед подачею до моделі всі зображення приводяться до єдиного розміру 224×224 пікселі, що відповідає типовому вхідному формату багатьох згорткових архітектур.

Для порівняльного аналізу було обрано три моделі: SimpleCNN, MobileNetV2 та EfficientNetB0. Вибір саме такого набору моделей дає змогу порівняти різні підходи до класифікації зображень. SimpleCNN використовується як базова модель, яка будується з кількох згорткових, пулінгових і повнозв'язних шарів. Її роль полягає у створенні контрольного орієнтира: вона показує, якого результату можна досягти за допомогою відносно простої архітектури без складних

попередньо навчених блоків. Така модель є корисною для дипломного дослідження, оскільки дозволяє продемонструвати базовий принцип роботи згорткової нейронної мережі у задачі класифікації відходів.

Модель MobileNetV2 була включена до порівняння через її орієнтацію на мобільні та вбудовані пристрої. Для теми дипломної роботи це має особливе значення, оскільки інтелектуальна система сортування відходів передбачає можливість локальної обробки зображень без постійної залежності від хмарних сервісів. Архітектури типу MobileNet розробляються з урахуванням обмежень за обчислювальними ресурсами, тому вони є придатними для використання на пристроях з обмеженою продуктивністю, наприклад на одноплатних комп'ютерах або вбудованих модулях керування контейнером.

Модель EfficientNetB0 використовується як компактна, але більш ефективна архітектура, яка дає змогу оцінити можливості сучаснішого підходу до побудови нейромережових класифікаторів. Вона є доцільною для порівняння, оскільки поєднує відносно невеликий розмір із високою якістю вилучення візуальних ознак. У межах дослідження ця модель дозволяє перевірити, чи може складніша архітектура забезпечити кращу якість класифікації порівняно з базовою CNN і полегшеною мобільною моделлю.

Технічно програма працює за єдиним сценарієм для кожної моделі. Спочатку створюється відповідна архітектура класифікатора з вихідним шаром, кількість нейронів у якому дорівнює кількості класів підготовленого набору даних. Далі модель компілюється із заданими параметрами навчання, після чого запускається процес тренування на навчальній підвибірці. Валідаційна підвибірка використовується для поточного контролю якості навчання після кожної епохи. Це дозволяє оцінювати, чи модель справді навчається узагальнювати ознаки класів, а не лише запам'ятовує навчальні приклади.

Важливою особливістю розробленої програми є автоматизоване збереження історії навчання. Для кожної моделі фіксуються значення точності та функції втрат на навчальній і валідаційній підвибірках. Такі дані потрібні не лише для підрахунку фінальних метрик, а й для аналізу самого процесу навчання. Наприклад, за

динамікою accuracy та loss можна визначити, чи модель навчається стабільно, чи виникають ознаки перенавчання, чи є потреба у збільшенні кількості епох або зміні параметрів навчання. У цьому підрозділі розглядається саме методика такого моделювання, тоді як кількісні результати порівняння будуть проаналізовані далі.

Після завершення навчання кожна модель перевіряється на тестовій підвибірці. Тестова вибірка не використовується під час навчання, тому вона дає змогу оцінити здатність моделі класифікувати нові зображення. Програма формує прогнозовані класи для тестових зображень, порівнює їх із фактичними мітками та обчислює основні метрики якості класифікації. До таких метрик належать accuracy, precision, recall і F1-score. Їх використання є доцільним, оскільки одна лише загальна точність не завжди достатньо повно характеризує якість моделі, особливо якщо класи представлені нерівномірно. Для задачі сортування відходів важливо розуміти не тільки загальну частку правильних відповідей, а й те, наскільки добре модель розпізнає кожен тип відходів і скільки помилок допускає між близькими категоріями.

Крім числових метрик, програма передбачає побудову матриць помилок. Матриця помилок дає змогу побачити, які саме класи модель плутає між собою. Для задачі автоматичного сортування це має практичне значення, оскільки різні помилки можуть мати різні наслідки. Наприклад, помилка між папером і картоном є менш критичною, якщо вони належать до однієї узагальненої фракції, тоді як змішування органічних відходів із сухою вторинною сировиною може суттєво погіршити якість сортування. Тому включення матриць помилок до програмного модуля дозволяє не лише порівнювати моделі за загальними метриками, а й аналізувати характер їхніх помилок.

2.3 Переваги, недоліки та обмеження існуючих моделей розумних систем сортування сміття

В рамках програмного моделювання було здійснено порівняльний аналіз трьох нейронмережових моделей, які можуть застосовуватися у складі розумних

систем сортування твердих побутових відходів. Для перевірки було використано моделі SimpleCNN, MobileNetV2 та EfficientNetB0. Ці архітектури репрезентують різні підходи до побудови класифікаторів зображень. SimpleCNN є базовою згортковою мережею, яка навчається безпосередньо на сформованому наборі даних. MobileNetV2 орієнтована на використання в мобільних і вбудованих системах, тому теоретично є перспективною для реалізації в розумному контейнері. EfficientNetB0 є більш сучасною компактною архітектурою, яка має забезпечувати кращий баланс між точністю та обчислювальною складністю. Однак результати експерименту показали, що практична ефективність моделі залежить не лише від її архітектурної складності, а й від якості адаптації до конкретного набору даних, способу навчання, збалансованості класів і параметрів попередньої обробки.

Результати навчання базової моделі SimpleCNN наведено на рис. 2.5.

```
[INFO] Навчання моделі: SimpleCNN
WARNING:tensorflow:TensorFlow GPU support is not available on native Windows for
TensorFlow >= 2.11. Even if CUDA/cuDNN are installed, GPU will not be used. Pleas
e use WSL2 or the TensorFlow-DirectML plugin.
Epoch 1/8
343/343 ██████████ 441s 1s/step - accuracy: 0.3187 - loss: 1.5327 - val
_accuracy: 0.5230 - val_loss: 1.3428
Epoch 2/8
343/343 ██████████ 465s 1s/step - accuracy: 0.4661 - loss: 1.3683 - val
_accuracy: 0.5098 - val_loss: 1.3367
Epoch 3/8
343/343 ██████████ 480s 1s/step - accuracy: 0.4788 - loss: 1.3256 - val
_accuracy: 0.5302 - val_loss: 1.2954
Epoch 4/8
343/343 ██████████ 302s 881ms/step - accuracy: 0.4864 - loss: 1.3120 -
val_accuracy: 0.5672 - val_loss: 1.1946
Epoch 5/8
343/343 ██████████ 348s 1s/step - accuracy: 0.5031 - loss: 1.2681 - val
_accuracy: 0.4902 - val_loss: 1.3344
Epoch 6/8
343/343 ██████████ 456s 1s/step - accuracy: 0.5061 - loss: 1.2322 - val
_accuracy: 0.5319 - val_loss: 1.2302
Epoch 7/8
343/343 ██████████ 486s 1s/step - accuracy: 0.5171 - loss: 1.2088 - val
_accuracy: 0.5434 - val_loss: 1.2180
[OK] SimpleCNN: accuracy=0.5762, precision=0.7102, recall=0.5762, f1=0.6136, time
=2977.8s
```

Рис. 2.5 Результат навчання моделі SimpleCNN у командному рядку

У процесі навчання модель поступово підвищувала значення ассураcy на навчальній вибірці та демонструвала зменшення loss, що свідчить про фактичне засвоєння візуальних ознак класів. За підсумком тестування SimpleCNN досягла ассураcy 0,5762, precision 0,7102, recall 0,5762 та F1-score 0,6136. Ці значення не можна вважати дуже високими для промислової системи сортування, однак серед трьох перевірених моделей саме SimpleCNN показала найкращий результат у межах проведеного експерименту. Це означає, що навіть відносно проста згорткова

архітектура може виявитися ефективнішою за складніші попередньо навчені моделі, якщо вона краще узгоджена з підготовленими даними та навчається безпосередньо на них.

Перевагою SimpleCNN є її відносна прозорість і простота реалізації. Така модель складається з базових згорткових, пулінгових і повнозв'язних шарів, тому її легше пояснити, модифікувати та адаптувати до конкретної задачі. Для дипломного дослідження це має суттєве значення, оскільки модель не виступає як «чорна скринька» складної архітектури, а може бути описана як послідовність стандартних операцій вилучення ознак із зображення. Водночас недоліком SimpleCNN є порівняно більший час навчання та потенційна обмеженість здатності до узагальнення на складніших наборах даних. У реальних умовах розумного контейнера, де зображення можуть бути затемненими, частково перекритими, забрудненими або отриманими під різними кутами, проста CNN може потребувати додаткової аугментації даних і донавчання.

Результати навчання MobileNetV2 наведено на рис. 2.6.

```
[INFO] Навчання моделі: MobileNetV2
Epoch 1/8
343/343 ----- 208s 578ms/step - accuracy: 0.0988 - loss: 1.7921 - val_accuracy: 0.1238 - val_loss: 1.7922
Epoch 2/8
343/343 ----- 211s 615ms/step - accuracy: 0.0815 - loss: 1.7920 - val_accuracy: 0.1238 - val_loss: 1.7916
Epoch 3/8
343/343 ----- 271s 638ms/step - accuracy: 0.1327 - loss: 1.7920 - val_accuracy: 0.1238 - val_loss: 1.7911
Epoch 4/8
343/343 ----- 241s 702ms/step - accuracy: 0.1380 - loss: 1.7920 - val_accuracy: 0.1238 - val_loss: 1.7987
Epoch 5/8
343/343 ----- 249s 725ms/step - accuracy: 0.1310 - loss: 1.7920 - val_accuracy: 0.1238 - val_loss: 1.7987
Epoch 6/8
343/343 ----- 224s 651ms/step - accuracy: 0.1301 - loss: 1.7920 - val_accuracy: 0.1238 - val_loss: 1.7987
Epoch 7/8
343/343 ----- 261s 761ms/step - accuracy: 0.1323 - loss: 1.7920 - val_accuracy: 0.1238 - val_loss: 1.7893
Epoch 8/8
343/343 ----- 211s 615ms/step - accuracy: 0.0990 - loss: 1.7920 - val_accuracy: 0.1238 - val_loss: 1.7981
[OK] MobileNetV2: accuracy=0.1238, precision=0.0153, recall=0.1238, f1=0.0273, time=1874.8s
```

Рис. 2.6 Результат навчання моделі MobileNetV2 у командному рядку

Незважаючи на те, що ця архітектура є спеціально орієнтованою на мобільні та вбудовані пристрої, у проведеному експерименті вона не продемонструвала очікуваної якості класифікації. Підсумкові значення становили accuracy 0,1238, precision 0,0153, recall 0,1238 та F1-score 0,0273. Такі результати свідчать про те, що модель фактично не навчилася коректно розрізняти класи в межах поточної конфігурації експерименту. Це не означає, що MobileNetV2 є непридатною для задачі сортування відходів загалом. Навпаки, її архітектура залишається перспективною для вбудованих систем, однак отримані результати показують, що

для її ефективного застосування потрібне коректне налаштування режиму transfer learning, розморожування частини шарів, добір learning rate, збільшення кількості епох або використання більш глибокої адаптації до специфіки зображень побутових відходів.

Аналогічна ситуація спостерігалася для EfficientNetB0, результати навчання якої наведено на рис. 2.7.

```
[INFO] Навчання моделі: EfficientNetB0
Epoch 1/8
343/343 ----- 348s 992ms/step - accuracy: 0.1047 - loss: 1.7920 - val_accuracy: 0.1238 - val_loss: 1.7916
Epoch 2/8
343/343 ----- 381s 1s/step - accuracy: 0.1249 - loss: 1.7919 - val_accuracy: 0.1238 - val_loss: 1.7902
Epoch 3/8
343/343 ----- 306s 888ms/step - accuracy: 0.1237 - loss: 1.7919 - val_accuracy: 0.1238 - val_loss: 1.7897
Epoch 4/8
343/343 ----- 260s 758ms/step - accuracy: 0.1147 - loss: 1.7919 - val_accuracy: 0.1238 - val_loss: 1.7904
Epoch 5/8
343/343 ----- 300s 872ms/step - accuracy: 0.1347 - loss: 1.7918 - val_accuracy: 0.1238 - val_loss: 1.7906
Epoch 6/8
343/343 ----- 232s 676ms/step - accuracy: 0.1463 - loss: 1.7917 - val_accuracy: 0.1962 - val_loss: 1.7904
[OK] EfficientNetB0: accuracy=0.1238, precision=0.0153, recall=0.1238, f1=0.0273, time=1826.0s
```

Рис. 2.7. Результат навчання моделі EfficientNetB0 у командному рядку

Модель показала accuracy 0,1238, precision 0,0153, recall 0,1238 та F1-score 0,0273. Формально EfficientNetB0 є ефективною архітектурою для багатьох задач комп'ютерного зору, проте в межах цього експерименту вона, як і MobileNetV2, не забезпечила якісного розпізнавання класів. Це може бути пов'язано з тим, що попередньо навчені архітектури потребують точнішого узгодження вхідних даних із вимогами моделі, правильного препроцесингу зображень, налаштування верхніх класифікаційних шарів і поступового донавчання. Отже, перевагою EfficientNetB0 є потенційно висока ефективність і компактність, але її недоліком у межах проведеного дослідження стала низька практична результативність без додаткового тонкого налаштування.

Узагальнене порівняння моделей за основними метриками наведено на рис. 2.8.




Рис. 2.8 Порівняння ефективності моделей автоматичного сортування відходів за основними метриками класифікації

На діаграмі видно, що SimpleCNN суттєво перевищує MobileNetV2 та EfficientNetB0 за всіма ключовими показниками. Найбільш показовим є значення weighted F1-score, оскільки воно одночасно враховує precision і recall та є більш інформативним для задачі з нерівномірним розподілом класів. Для SimpleCNN цей показник становить приблизно 0,61, тоді як для MobileNetV2 та EfficientNetB0 він залишається близьким до 0,03. Це означає, що MobileNetV2 і EfficientNetB0 у поточній конфігурації не забезпечили реального розділення класів, тоді як SimpleCNN сформувала хоча б частково працездатний класифікатор. Аналітично це підтверджує, що складніша або відоміша архітектура не гарантує кращого результату без адаптації до конкретного набору даних.

Динаміка навчання моделей за показниками accuracy та loss наведена на рис. 2.9.




Рис. 2.9 Динаміка точності та функції втрат під час навчання моделей класифікації відходів

Графік показує, що SimpleCNN демонструє поступове зростання точності та зменшення функції втрат, тобто її навчання має осмислений характер. Водночас для MobileNetV2 та EfficientNetB0 значення асигуру залишаються майже на одному рівні, а loss практично не змінюється. Така поведінка свідчить про недостатню адаптацію цих моделей до навчальної вибірки. Фактично вони не змогли ефективно змінити внутрішні представлення ознак так, щоб відокремити класи відходів один від одного. Для практичного дослідження це є важливим висновком: якщо модель не демонструє динаміки покращення під час навчання, її використання без зміни параметрів або архітектури є недоцільним.

Матриці помилок, наведені на рис. 2.10, дають змогу глибше оцінити характер класифікації.




Рис. 2.10 Матриці помилок моделей класифікації відходів на тестовій вибірці

Для SimpleCNN видно, що модель правильно розпізнає частину зображень різних класів, зокрема клас other, paper_cardboard, organic, glass, metal і plastic, хоча між класами все ще є значна кількість помилок. Найбільша кількість правильних спрацювань спостерігається для класу other, що частково пояснюється його найбільшою представленістю у тестовій вибірці. Водночас помилки між glass, plastic, metal і paper_cardboard свідчать про складність візуального розмежування деяких типів відходів. Для MobileNetV2 та EfficientNetB0 матриці помилок демонструють критичну проблему: обидві моделі майже всі об'єкти відносять до одного класу paper_cardboard. Це пояснює низькі значення precision і F1-score та підтверджує, що ці моделі в поточній реалізації не сформували повноцінного механізму багатокласової класифікації.

Окремо було проаналізовано час навчання моделей, що наведено на рис. 2.11.




Рис. 2.11 Порівняння часу навчання моделей автоматичного сортування відходів

Найдовше навчалася модель SimpleCNN – приблизно 2977,8 с, тоді як MobileNetV2 потребувала 1874,8 с, а EfficientNetB0 – 1826,0 с. Це показує, що SimpleCNN, попри кращі метрики якості, виявилася повільнішою за дві інші моделі. З погляду практичного впровадження в розумну систему сортування це означає, що вибір моделі не може ґрунтуватися лише на точності. Потрібно враховувати компроміс між якістю класифікації, часом навчання, розміром моделі, швидкістю інференсу та можливістю запуску на вбудованому пристрої.

MobileNetV2 і EfficientNetB0 мають перевагу за швидкістю навчання, однак у цьому експерименті ця перевага не компенсує низьку якість класифікації.

Приклади класифікації тестових зображень наведено на рис. 2.12.




Рис. 2.12 Приклади класифікації зображень тестової вибірки

На них видно як правильні, так і помилкові передбачення. Наприклад, частина зображень одягу коректно віднесена до класу other, пляшка може бути правильно класифікована як plastic, органічний об'єкт – як organic, а скляна пляшка – як glass. Водночас наявні й помилки, зокрема віднесення об'єктів класу other до metal або віднесення пластикової пляшки до plastic із невисокою впевненістю. Це показує, що навіть найкраща з перевірених моделей не завжди демонструє високу впевненість у передбаченнях. Для реальної системи сортування це є обмеженням, оскільки низька впевненість класифікації може призводити до неправильного спрямування відходу у відповідний відсік.

Загалом результати моделювання дозволяють виділити кілька переваг і недоліків розглянутих моделей. SimpleCNN має перевагу у вигляді найкращої фактичної якості класифікації на підготовленому наборі даних, простоти реалізації та зрозумілої структури. Її недоліками є більший час навчання, потреба в подальшому покращенні точності та потенційна чутливість до змін умов зйомки. MobileNetV2 має архітектурну перевагу для вбудованих систем, оскільки створена з урахуванням обмежень мобільних пристроїв. Проте її фактичний недолік у межах експерименту полягає в тому, що без тонкого налаштування вона не забезпечила якісної класифікації. EfficientNetB0 також має перевагу як компактна сучасна модель, але в поточній реалізації її результати виявилися аналогічно низькими, що вказує на потребу в додатковій адаптації.

Основним обмеженням проведеного моделювання є нерівномірність класів у підготовленому наборі даних. Клас other містить багато різномірних об'єктів і має більшу кількість прикладів, що може впливати на навчання моделі та зміщувати її передбачення. Крім того, частина класів має візуально подібні об'єкти: пластикові пляшки, скляні пляшки, металеві банки та паперові упаковки можуть мати схожі контури, кольори або фони. Це ускладнює автоматичне розпізнавання, особливо якщо модель аналізує лише RGB-зображення без додаткових сенсорних ознак. Ще одним обмеженням є те, що зображення з відкритих датасетів не повністю відповідають реальним умовам роботи контейнера, де об'єкти можуть бути забрудненими, частково перекритими, деформованими або сфотографованими під нестандартним кутом.

РОЗДІЛ 3. РОЗРОБКА ТА ОЦІНКА ЕФЕКТИВНОСТІ ПРОТОТИПУ МОДЕЛІ РОЗУМНОГО КОНТЕЙНЕРА

3.1 Принцип роботи та архітектура програмного забезпечення моделі

На основі результатів аналітичного дослідження та підготовленого у попередньому розділі набору даних було розроблено програмний прототип інтелектуальної системи автоматизованого сортування твердих побутових відходів. На відміну від етапу порівняльного моделювання, де основна увага приділялася перевірці окремих нейромережових архітектур, у межах цього розділу розроблено цілісну програмну модель, яка поєднує класифікацію зображення, оцінювання впевненості прогнозу та прийняття рішення щодо подальшого спрямування відходу до відповідного відсіку контейнера. Такий підхід дозволяє розглядати програму не лише як класифікатор зображень, а як прототип керуючого модуля розумного контейнера, орієнтованого на роботу у вбудованому середовищі.

Розроблена система побудована мовою Python із використанням бібліотек TensorFlow/Keras, NumPy, Pandas, scikit-learn, Matplotlib та Pillow. TensorFlow/Keras використовується для побудови, навчання та експорту нейромережової моделі, NumPy і Pandas – для обробки числових даних і збереження результатів експериментів, scikit-learn – для розрахунку метрик класифікації, Matplotlib – для побудови графіків і візуальних звітів, а Pillow – для роботи із зображеннями. Технологічний стек розробленого програмного забезпечення наведено на рис. 3.1.




Рис. 3.1 Технологічний стек програмного забезпечення інтелектуальної системи сортування відходів

Вхідними даними для роботи програми є підготовлений набір зображень, сформований у підрозділі 2.1. Він містить зображення побутових відходів, поділені на навчальну, валідаційну та тестову підвибірки, а також класи glass, metal, organic, other, paper_cardboard і plastic. Така структура дозволяє безпосередньо використовувати дані для навчання моделі без додаткового ручного маркування. На етапі завантаження програма зчитує зображення, приводить їх до єдиного розміру 224×224 пікселі, нормалізує значення пікселів та формує пакети даних для навчання. Формально вхідне зображення можна подати як тензор:

$$X \in R^{224 \times 224 \times 3}, \#(3.1)$$

де 224×224 – просторовий розмір зображення, а 3 – кількість кольорових каналів RGB. Після попередньої обробки зображення подається на вхід нейромережевої моделі, яка формує вектор імовірностей належності об'єкта до кожного з цільових класів.

Основою авторської програмної моделі є легка згортовка нейромережева архітектура EdgeWasteNet_Lite. Її призначення полягає у тому, щоб забезпечити достатню якість розпізнавання зображень при відносно невеликій обчислювальній складності. Це важливо для подальшого використання моделі у вбудованих

пристроях, де ресурси процесора, пам'яті та енергоспоживання є обмеженими. На відміну від великих універсальних моделей комп'ютерного зору, запропонована архітектура орієнтована саме на задачу сортування відходів за обмеженою кількістю практично значущих класів.

Принцип роботи системи полягає в послідовному виконанні кількох етапів. Спочатку камера або файл із тестової вибірки передає зображення відходу до програмного модуля. Далі виконується попередня обробка зображення: масштабування, нормалізація та приведення до формату, сумісного з нейромережею. Після цього модель EdgeWasteNet_Lite виконує класифікацію та формує вектор ймовірностей для всіх класів. Для перетворення вихідних значень нейромережі на ймовірності використовується функція softmax:

$$p_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}, \#(3.2)$$

де p_i – ймовірність належності зображення до i -го класу, z_i – вихідне значення нейромережі для цього класу, K – загальна кількість класів відходів. У межах розробленої системи $K = 6$, оскільки модель працює з шістьма узагальненими категоріями відходів.

Після отримання вектора ймовірностей система визначає клас із найбільшим значенням ймовірності:

$$\hat{y} = \arg \max_i p_i, \#(3.3)$$

Однак особливістю запропонованої програмної моделі є те, що рішення не завершується лише вибором класу. Додатково обчислюється рівень впевненості нейромережі:

$$C = \max_i p_i, \#(3.4)$$

де C – максимальна ймовірність серед усіх класів, тобто рівень довіри системи до власного прогнозу. Саме цей показник використовується у модулі прийняття рішення SmartBinController. Якщо значення C перевищує встановлений поріг довіри τ , система приймає прогноз як достатньо надійний і визначає відповідний відсік контейнера. Якщо ж $C < \tau$, об'єкт може бути позначений як

невизначений або спрямований до резервного відсіку для додаткової перевірки. Логіку прийняття рішення можна записати у вигляді:

$$d = \{B(\hat{y}), \text{якщо } C \geq \tau, B_{unknown}, \text{якщо } C < \tau, \#(3.5)$$

де d – кінцеве рішення системи, $B(\hat{y})$ – відсік контейнера, що відповідає передбаченому класу, $B_{unknown}$ – резервне рішення для невпевненого прогнозу, τ – поріг упевненості. Такий механізм є важливим для практичного застосування, оскільки в реальних умовах система не повинна однаково реагувати на впевнені та сумнівні передбачення. Наявність порогу довіри дозволяє зменшити ризик помилкового сортування, особливо для візуально складних або нестандартних об'єктів.

Загальний принцип роботи розробленої системи наведено на рис. 3.2.

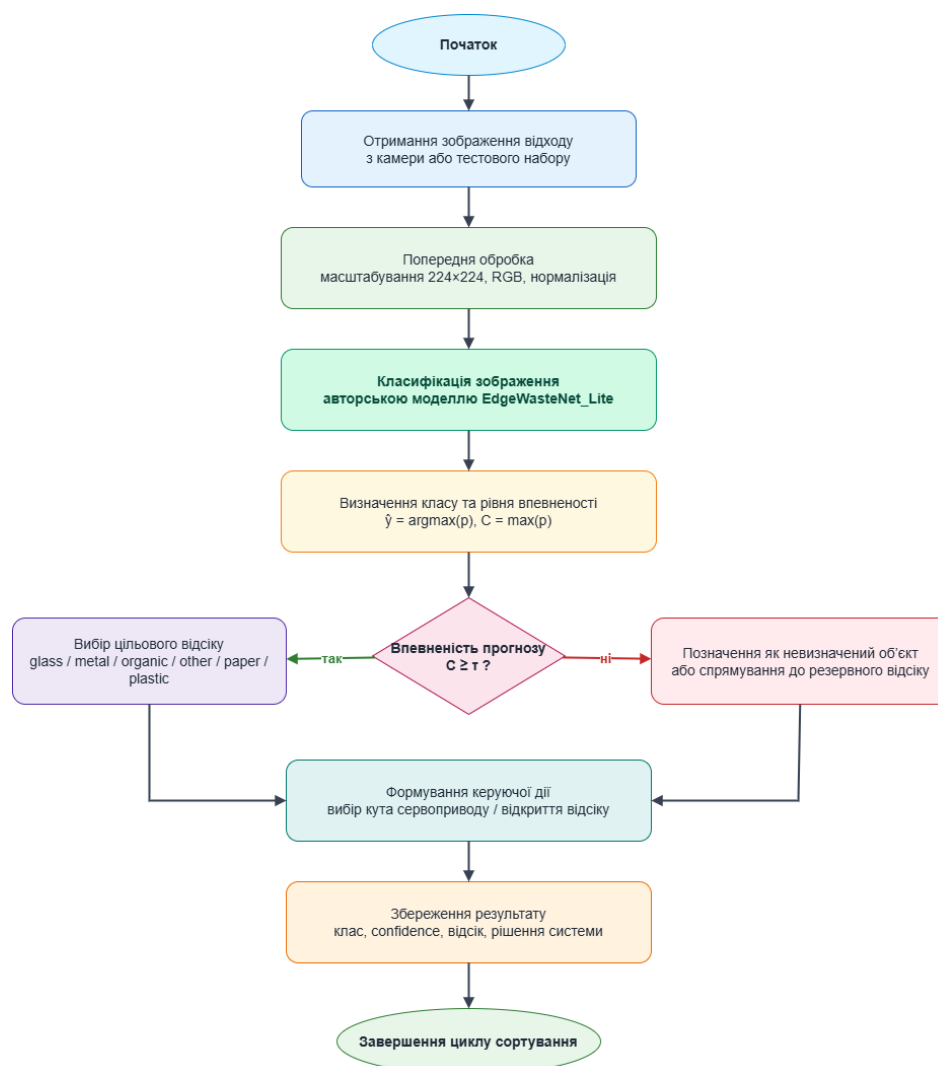


Рис. 3.2 Принцип роботи інтелектуальної системи автоматизованого сортування твердих побутових відходів

Архітектурно програмне забезпечення складається з кількох взаємопов'язаних модулів. Перший модуль відповідає за завантаження та підготовку даних. Він отримує зображення з каталогу підготовленого датасету, формує навчальні й тестові потоки та передає дані до нейромережевої моделі. Другий модуль реалізує архітектуру EdgeWasteNet_Lite, тобто виконує вилучення ознак із зображення та класифікацію об'єкта. Третій модуль відповідає за оцінювання прогнозу: він визначає передбачений клас, рівень упевненості та формує набір службових параметрів для подальшого аналізу. Четвертий модуль SmartBinController реалізує логіку прийняття рішення, тобто зіставляє клас відходу з відповідним відсіком контейнера та умовним кутом повороту сервоприводу. П'ятий модуль забезпечує тестування, формування метрик, побудову графіків і збереження візуальних результатів.

Архітектуру побудованої авторської моделі наведено на рис. 3.3.

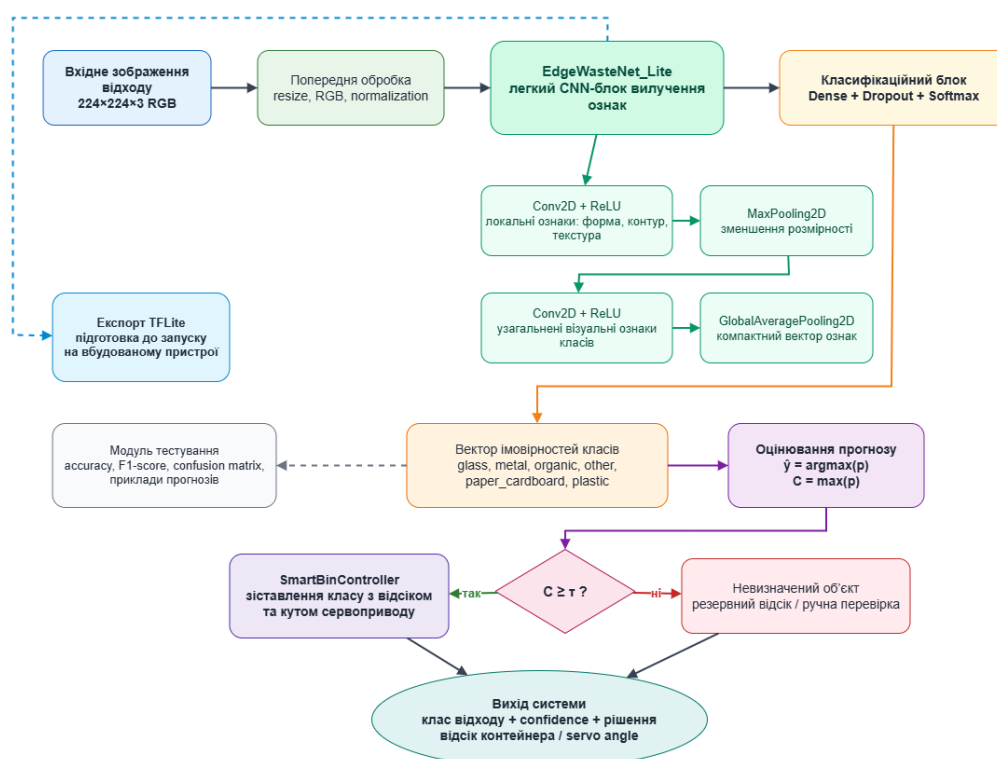


Рис. 3.3 Архітектура авторської програмної моделі EdgeWasteNet_Lite для вбудованої системи сортування відходів

У межах запропонованої архітектури нейромережева частина та логічний модуль керування не існують окремо, а працюють як єдиний контур прийняття

рішення. Це є принципово важливим для розумного контейнера, оскільки в реальному пристрої результатом роботи системи має бути не лише текстова мітка класу, а конкретна дія: відкриття відповідного відсіку, активація механізму перенаправлення або віднесення об'єкта до категорії невизначених. Саме тому програмна модель описує повний шлях від зображення до керуючого рішення.

Для навчання нейромережі використовується функція втрат категоріальної класифікації. Її можна подати у вигляді:

$$L = - \sum_{i=1}^K y_i \log \log (p_i) , \#(3.6)$$

де y_i – істинна мітка класу у форматі one-hot encoding, p_i – передбачена ймовірність для відповідного класу, K – кількість класів. Мінімізація цієї функції під час навчання дозволяє моделі поступово коригувати ваги так, щоб підвищувати ймовірність правильного класу та зменшувати ймовірності помилкових класів.

Окремою частиною програмного забезпечення є модуль експорту моделі у формат TensorFlow Lite. Його використання дозволяє підготувати модель до потенційного запуску на вбудованих або малопотужних пристроях. У контексті теми дипломної роботи це має важливе значення, оскільки система автоматизованого сортування не повинна повністю залежати від зовнішнього сервера або хмарної інфраструктури. Локальна обробка зображення дає змогу скоротити затримку між моментом появи відходу перед камерою та активацією виконавчого механізму контейнера.

3.2 Основні функції програмного забезпечення та алгоритми

Розроблене програмне забезпечення авторської моделі EdgeWasteNet_Lite реалізує повний цикл роботи інтелектуальної системи сортування твердих побутових відходів: від завантаження підготовленого набору даних до навчання нейромережі, перевірки її якості, формування керуючого рішення та створення візуальних результатів тестування. На відміну від окремого класифікатора зображень, програмна розробка має модульну структуру, у якій кожна

функціональна частина виконує окрему задачу, але всі вони працюють як єдиний ланцюг: зображення відходу подається на вхід, модель визначає клас, система оцінює впевненість прогнозу, після чого формується рішення щодо цільового відсіку контейнера.

Для узагальненого подання внутрішньої логіки програми доцільно використати схему взаємодії функціональних модулів, наведену на рис. 3.4

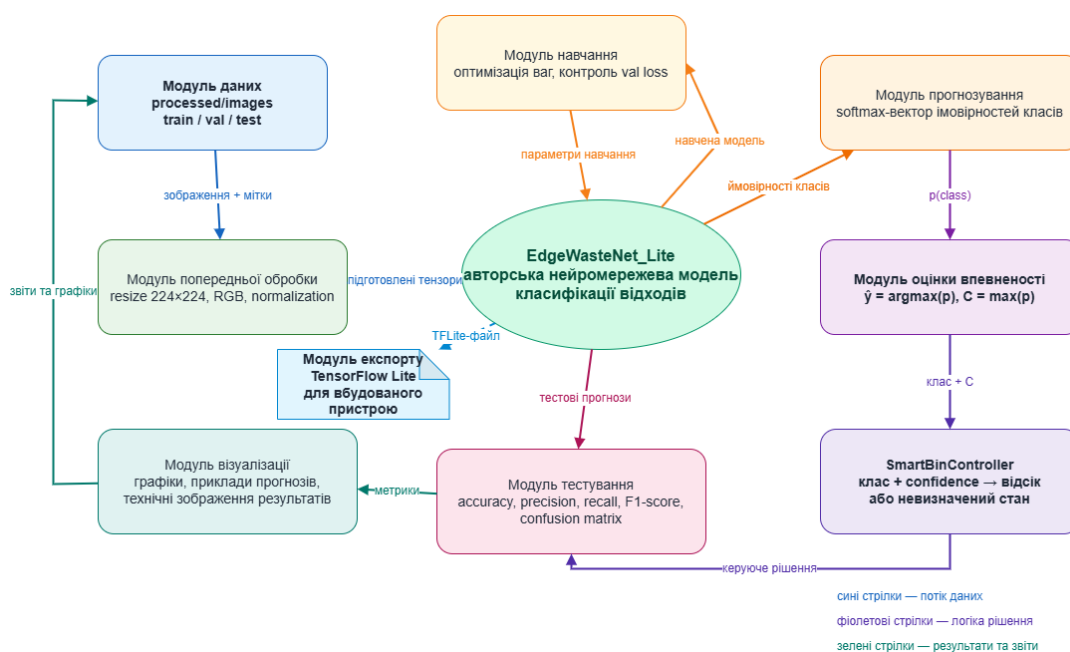


Рис. 3.4 Діаграма взаємодії основних функціональних модулів програмного забезпечення EdgeWasteNet_Lite

Першим функціональним блоком програми є модуль завантаження та підготовки даних. Його призначення полягає у зчитуванні каталогу з підготовленими зображеннями, сформованими у попередньому розділі, та перетворенні їх у формат, придатний для нейромережевого навчання. Програма працює з уже структурованим набором processed/images, у якому дані поділено на навчальну, валідаційну та тестову підвибірки. Такий підхід дозволяє не виконувати повторну ручну розмітку, оскільки назва класу визначається за папкою, у якій розміщене зображення. На цьому етапі зображення масштабуються до розміру 224×224 пікселі, переводяться у формат RGB, нормалізуються та об'єднуються в пакети для подальшої обробки моделлю.

Другим важливим блоком є модуль побудови авторської нейромережевої моделі `EdgeWasteNet_Lite`. Його функція полягає у створенні компактної згорткової архітектури, орієнтованої на класифікацію шести узагальнених категорій відходів: скла, металу, органіки, залишкових відходів, паперу/картону та пластику. На відміну від великих універсальних моделей, запропонована архітектура не перевантажена зайвими шарами, оскільки її призначенням є потенційне використання у вбудованій системі. Вона містить послідовність згорткових блоків для вилучення ознак, операції зменшення розмірності, шар узагальнення ознак і класифікаційний блок із функцією `softmax` на виході.

Третім блоком є модуль навчання. Він відповідає за запуск процесу оптимізації ваг нейромережі на навчальній вибірці та контроль якості за допомогою валідаційної вибірки. У програмі передбачено режим швидкого запуску, який дає змогу перевірити працездатність системи без тривалого навчання. Це важливо з практичного погляду, оскільки на попередніх етапах було встановлено, що тривале навчання кількох моделей може займати значний час. Тому авторська програма орієнтована на баланс між швидкістю експерименту та достатньою якістю отриманих результатів. Для повнішого аналізу користувач може збільшити кількість епох, але базовий режим дозволяє швидко сформувати модель, метрики та візуальні звіти.

Окрему роль відіграє модуль порівняння з базовими моделями. У програмі передбачено можливість зіставлення авторської `EdgeWasteNet_Lite` з іншими архітектурами, зокрема `SimpleCNN`, `MobileNetV2` та `EfficientNetB0`. Це потрібно для того, щоб показати не лише роботу запропонованої моделі, а й її місце серед інших підходів до класифікації відходів. Порівняння виконується за єдиною схемою: моделі навчаються або тестуються на тих самих підготовлених даних, після чого для них обчислюються однакові метрики. Завдяки цьому результати можна використовувати для аргументованої оцінки ефективності авторського рішення.

Наступним блоком є модуль оцінювання результатів. Він формує прогноз для тестової вибірки, порівнює передбачені класи з фактичними мітками та розраховує

основні показники якості: accuracy, precision, recall і F1-score. Також будується матриця помилок, яка дозволяє визначити, які саме класи модель розпізнає краще, а які частіше плутає між собою. Для системи сортування відходів це має практичне значення, оскільки різні помилки можуть мати різну критичність. Наприклад, неправильне віднесення органічних відходів до сухої вторинної сировини є більш небажаним, ніж плутанина між близькими сухими фракціями.

Найважливішою особливістю програмної розробки є модуль SmartBinController. Саме він відрізняє авторську систему від звичайної моделі класифікації зображень. Після того як нейромережа визначає клас відходу, програма додатково аналізує рівень упевненості прогнозу. Якщо confidence перевищує заданий поріг, система приймає прогноз і зіставляє клас із відповідним відсіком контейнера. Якщо ж рівень упевненості недостатній, об'єкт може бути позначений як невизначений або спрямований до резервного відсіку. Такий алгоритм дозволяє зменшити ризик помилкового сортування, оскільки система не змушена автоматично приймати кожне передбачення нейромережі як правильне.

Алгоритм прийняття рішення в модулі SmartBinController можна подати так: спочатку обирається клас із найбільшою ймовірністю, потім перевіряється значення confidence, після чого формується керуюча дія. Якщо прогноз надійний, система визначає цільовий відсік, наприклад для скла, пластику, металу або органіки. Якщо прогноз ненадійний, обирається альтернативна дія: резервний відсік або позначення об'єкта як невизначеного. У програмній моделі це також доповнено умовним кутом сервоприводу, що імітує фізичну дію механізму сортування.

Важливо, що наведені модулі не дублюють один одного, а формують послідовний програмний конвеєр. Спочатку дані перетворюються у стандартизований формат, потім модель навчається розпізнавати класи відходів, після цього якість її роботи перевіряється на тестовій вибірці, а фінальний прогноз передається до логічного блоку керування. Саме на цьому етапі класифікація перетворюється на практичне рішення для розумного контейнера.

Крім основного алгоритму класифікації, програма містить функції генерації візуальних результатів. Вони формують порівняльні графіки метрик, матриці помилок, криві навчання, приклади прогнозів на тестових зображеннях та імітацію стану контейнера. Це має значення не лише для демонстрації роботи програми, а й для аналізу її придатності до практичного використання. Наприклад, за графіками навчання можна оцінити стабільність моделі, за матрицею помилок – визначити проблемні класи, а за прикладами прогнозів – візуально перевірити, наскільки коректно система інтерпретує конкретні об'єкти.

Ще однією функцією програмного забезпечення є експорт навченої моделі у формат TensorFlow Lite. Цей крок потрібний для того, щоб підготувати модель до запуску на пристроях з обмеженими ресурсами. У межах дипломної роботи це підтверджує, що розробка орієнтована не лише на комп'ютерне тестування, а й на потенційне використання у вбудованій системі розумного контейнера. Формат TensorFlow Lite дозволяє зменшити залежність від повноцінного серверного середовища та наблизити модель до локальної обробки даних безпосередньо в місці встановлення контейнера.

3.3 Особливості застосування моделі у різних підходах до організації сортування сміття

Розроблена авторська модель EdgeWasteNet_Lite може застосовуватися у різних підходах до організації сортування твердих побутових відходів, оскільки її робота не обмежується лише визначенням класу об'єкта на зображенні. Програмна система поєднує нейромережеву класифікацію, оцінювання впевненості прогнозу та формування керуючого рішення для вибору відповідного відсіку контейнера. Завдяки цьому модель може бути адаптована як для індивідуального розумного контейнера, так і для ширшої системи первинного сортування на рівні будинку, офісу, навчального закладу або невеликого пункту збору відходів.

У найпростішому варіанті модель може використовуватися в автономному контейнері, де користувач підносить або кладе відхід у зону огляду камери, після

чого система визначає його тип і відкриває відповідний відсік. Для такого сценарію важливою є швидкість прийняття рішення, оскільки користувач очікує майже миттєвої реакції. У цьому випадку перевагою EdgeWasteNet_Lite є орієнтація на локальну обробку даних і можливість подальшого експорту в TensorFlow Lite. Такий формат дає змогу розглядати модель як основу для вбудованого пристрою, що не потребує постійного підключення до хмарного сервера для кожного окремого розпізнавання.

Другий варіант застосування пов'язаний із контейнером для попереднього сортування у громадських місцях. У таких умовах потік відходів є більш різноманітним, а користувачі не завжди правильно визначають категорію сміття самостійно. Тому система може виконувати роль інтелектуального помічника, який зменшує кількість помилок під час первинного розподілу відходів. Особливо важливим тут є модуль оцінювання впевненості прогнозу. Якщо модель достатньо впевнена у класифікації, вона автоматично пропонує або активує відповідний відсік. Якщо ж прогноз є ненадійним, відхід може бути спрямований до резервної категорії або позначений як невизначений. Це дозволяє уникнути ситуації, коли сумнівний об'єкт автоматично потрапляє до неправильної фракції та забруднює інші придатні до переробки матеріали.

Третій підхід передбачає використання моделі як частини навчально-демонстраційної або аналітичної системи. У цьому випадку основною функцією є не фізичне керування контейнером, а пояснення логіки сортування, демонстрація класифікації на прикладах ізбір статистики щодо типів відходів. Програма може показувати зображення об'єкта, передбачений клас, рівень впевненості та рекомендований відсік. Такий режим є корисним для навчальних закладів, лабораторних робіт або тестування нових наборів даних, оскільки дозволяє наочно показати, як нейромережева модель приймає рішення і в яких випадках вона може помилятися.

Для практичного впровадження доцільно розглядати модель як основу системи рекомендацій щодо сортування. У такій системі кожному класу відходів відповідає конкретна дія: скло спрямовується до відсіку для скла, метал – до відсіку

для металевих відходів, пластик – до відсіку для пластикових виробів, органіка – до окремого біологічного відсіку, папір і картон – до сухої паперової фракції, а клас other – до залишкових або змішаних відходів. Якщо рівень упевненості прогнозу нижчий за встановлений поріг, система не приймає остаточне рішення автоматично, а рекомендує резервний відсік або додаткову перевірку.

3.4 Результати тестування та оцінка ефективності прототипу

Для перевірки працездатності розробленого прототипу інтелектуальної системи автоматизованого сортування твердих побутових відходів було проведено тестування авторської моделі EdgeWasteNet_Lite та її порівняння з базовими моделями SimpleCNN, MobileNetV2_baseline та EfficientNetB0_baseline. Метою тестування визначити точність класифікації зображень та перевірити, чи може запропонована модель бути використана як програмна основа для вбудованої системи розумного контейнера. Оцінювання охоплювало декілька аспектів: якість класифікації, характер помилок, швидкість навчання, стабільність навчального процесу та здатність моделі формувати практичне рішення щодо відсіку контейнера.

У межах тестування використовувалися чотири основні метрики: accuracy, weighted precision, weighted recall та weighted F1-score. Accuracy показує загальну частку правильно класифікованих зображень. Precision характеризує, наскільки точними є передбачення моделі для кожного класу, recall показує, яку частку об'єктів відповідного класу модель змогла знайти, а F1-score узагальнює precision і recall в одному показнику. Використання саме зважених метрик є доцільним, оскільки підготовлений набір даних має нерівномірний розподіл класів, зокрема клас other містить значно більше прикладів, ніж окремі фракції на зразок metal або plastic.

Порівняння моделей за основними метриками наведено на рис. 3.5.




Рис. 3.5 Порівняння моделей інтелектуального сортування відходів за метриками класифікації

З рисунка видно, що найвищі та найбільш збалансовані результати показали EfficientNetB0_baseline, EdgeWasteNet_Lite та MobileNetV2_baseline. Для цих моделей значення accuracy, recall і F1-score перебувають приблизно на рівні 0,90–0,93, що свідчить про достатньо високу якість класифікації тестових зображень. Авторська модель EdgeWasteNet_Lite показує результат, близький до EfficientNetB0_baseline, однак її перевага полягає не лише у точності, а в тому, що вона додатково інтегрована з логікою прийняття рішення для розумного контейнера. На відміну від цих моделей, SimpleCNN має суттєво нижчу accuracy – близько 0,56, хоча weighted precision є вищою, приблизно 0,72. Це означає, що SimpleCNN іноді робить точні передбачення, але загалом частіше помиляється і менш стабільно розпізнає різні класи.

Для детальнішого аналізу було побудовано матриці помилок. Вони дозволяють побачити не лише загальний рівень точності, а й те, які саме класи модель плутає між собою. Матриця помилок SimpleCNN наведена на рис. 3.6.

Матриця помилок SimpleCNN показує, що модель частково розпізнає всі класи, однак має значну кількість змішувань між категоріями. Наприклад, для

класу glass правильно визначено 188 зображень, але помітна частина об'єктів помилково віднесена до paper_cardboard та plastic.




Рис. 3.6 Матриця помилок моделі SimpleCNN на тестовій вибірці

Для класу other правильно класифіковано 708 об'єктів, проте значна кількість зображень цього класу була віднесена до paper_cardboard і plastic. Це свідчить, що проста згорткова модель має обмежену здатність відокремлювати візуально схожі або неоднорідні об'єкти. У практичній системі сортування така поведінка є небажаною, оскільки може призводити до забруднення окремих фракцій.

Матриця помилок MobileNetV2_baseline наведена на рис. 3.7.




Рис. 3.7. Матриця помилок моделі MobileNetV2_baseline на тестовій вибірці

Результати MobileNetV2_baseline є значно кращими за SimpleCNN. Модель правильно класифікувала 259 зображень класу glass, 106 зображень класу metal, 146 зображень класу organic, 1264 зображення класу other, 262 зображення класу paper_cardboard і 98 зображень класу plastic. Найбільша кількість правильних спрацювань спостерігається для класу other, що пояснюється його найбільшою представленістю в тестовій вибірці. Водночас залишаються окремі помилки, зокрема частина об'єктів other класифікується як metal, paper_cardboard або plastic. Це показує, що MobileNetV2_baseline добре підходить для задачі сортування, але все ще потребує контролю неоднозначних випадків через поріг упевненості.

Матриця помилок EfficientNetB0_baseline наведена на рис. 3.8.




Рис. 3.8. Матриця помилок моделі EfficientNetB0_baseline на тестовій вибірці

EfficientNetB0_baseline демонструє ще більш стабільний розподіл правильних відповідей. Для класу glass правильно визначено 269 зображень, для metal – 109, для organic – 146, для other – 1256, для paper_cardboard – 278, для plastic – 107. Такий результат підтверджує, що модель добре вилучає візуальні ознаки різних категорій відходів. Основні помилки зосереджені навколо класу other, що є очікуваним, оскільки цей клас об'єднує різні типи залишкових або нестандартних об'єктів. У контексті практичного сортування це означає, що клас other доцільно розглядати як найбільш складний і потенційно потребує додаткової деталізації або окремої логіки обробки.

Матриця помилок авторської моделі EdgeWasteNet_Lite наведена на рис. 3.9.




Рис. 3.9. Матриця помилок авторської моделі EdgeWasteNet_Lite на тестовій вибірці

Авторська модель EdgeWasteNet_Lite показала збалансовані результати класифікації. Вона правильно визначила 261 зображення класу glass, 111 зображень класу metal, 142 зображення класу organic, 1281 зображення класу other, 265 зображень класу paper_cardboard і 103 зображення класу plastic. Особливо важливо, що модель добре розпізнає клас metal і зменшує кількість помилок для окремих малочисельних класів. Найбільше правильних спрацювань знову припадає на клас other, але це пов'язано не лише з кількістю прикладів, а й із тим, що модель навчилася виділяти загальні ознаки залишкової категорії. Порівняно з SimpleCNN авторська модель значно краще відокремлює основні фракції та менше змішує органіку, метал і папір/картон.

Окремо було проаналізовано час навчання моделей, оскільки для практичного застосування важлива не тільки точність, а й ресурсомісткість програмного рішення. Результати порівняння часу навчання наведено на рис. 3.10.




Рис. 3.10. Порівняння часу навчання моделей інтелектуального сортування відходів

З рисунка видно, що найдовше навчалася модель SimpleCNN – понад 2000 с. EfficientNetB0_baseline потребувала приблизно 1100–1150 с, EdgeWasteNet_Lite – близько 800 с, а MobileNetV2_baseline – приблизно 700 с. Отже, авторська модель не є найшвидшою серед усіх, однак вона демонструє суттєво менший час навчання порівняно з SimpleCNN і водночас забезпечує значно кращі метрики якості. Це підтверджує доцільність її використання як компромісного рішення: модель не перевантажена надмірною складністю, але достатньо ефективна для задачі класифікації відходів.

Динаміку навчання моделей наведено на рис. 3.11.




Рис. 3.11. Динаміка ассурасу та loss під час навчання моделей

Графіки accuracy та loss показують, що EdgeWasteNet_Lite швидко досягає високого рівня точності вже на перших епохах навчання. Значення accuracy поступово зростає, а loss зменшується, що свідчить про стабільний процес навчання без різких коливань. Порівняно з SimpleCNN, авторська модель демонструє значно кращу стартову якість і швидше наближається до стабільного результату. SimpleCNN, навпаки, має нижчий рівень accuracy та вищий loss, що свідчить про повільніше й менш ефективне навчання. Для практичного прототипу це важливо, оскільки модель повинна не лише показувати прийнятну точність, а й навчатися за розумний час.

Для імітації роботи розумного контейнера було сформовано графік заповнення відсіків після тестового сортування, наведений на рис. 3.12.




Рис. 3.12. Імітація заповнення відсіків розумного контейнера після тестового сортування

На графіку показано умовний рівень заповнення відсіків GLASS, ORGANIC, METAL, RESIDUAL і PLASTIC. Значення є невеликими й перебувають приблизно в межах 1–3%, оскільки візуалізація відображає демонстраційний фрагмент роботи системи, а не повний цикл експлуатації контейнера. Найбільший рівень заповнення спостерігається для відсіків скла та органіки, дещо менший – для металу, залишкових відходів і пластику. Така імітація показує, що програмний прототип не обмежується класифікацією, а може накопичувати інформацію про розподіл

об'єктів між відсіками. У реальній системі ці дані можуть бути використані для контролю заповнення, формування сервісного попередження або планування вивезення.

Приклади роботи авторської системи на окремих зображеннях наведено на рис. 3.13.




Рис. 3.13. Приклади роботи авторської системи EdgeWasteNet_Lite з визначенням класу, впевненості та цільового відсіку

На рисунку видно, що для кожного об'єкта система формує не лише назву класу, а й додаткові службові параметри: confidence, decision, target bin, servo angle, fill level, service alert і top-3 probabilities. Наприклад, скляна пляшка класифікується як glass із confidence 1,00 та спрямовується до відсіку GLASS, металевий об'єкт визначається як metal із confidence 0,91 або 0,72 та спрямовується до METAL, органічні об'єкти розпізнаються як organic, а взуття – як other із цільовим відсіком RESIDUAL. Такий результат підтверджує, що авторська модель працює як елемент керуючої системи, а не просто як нейромережевий класифікатор. Вона формує рішення, яке можна безпосередньо використати для імітації роботи виконавчого механізму контейнера.

Загалом результати тестування підтвердили працездатність розробленого прототипу. EdgeWasteNet_Lite забезпечила високі значення основних метрик класифікації, наближені до результатів сильніших базових моделей, але при цьому зберегла прикладну спрямованість на вбудоване використання. Найбільш важливою перевагою авторської розробки є інтеграція трьох елементів в одному програмному контурі: нейромережевого розпізнавання, оцінювання впевненості прогнозу та формування рішення для відсіку контейнера. Це дозволяє використовувати модель як основу для подальшого створення інтелектуального контейнера, який здатний не лише визначати тип відходу, а й приймати керуюче рішення щодо його сортування.

ВИСНОВКИ

У кваліфікаційній роботі було вирішено задачу розробки та оцінки ефективності інтелектуальної системи автоматизованого сортування твердих побутових відходів на основі вбудованих нейромережевих моделей. У процесі виконання роботи було проведено теоретичний аналіз предметної області, підготовлено набір даних для моделювання, виконано порівняння моделей класифікації та розроблено авторський програмний прототип EdgeWasteNet_Lite.

У першому розділі було досліджено сучасний стан проблеми сортування побутових відходів в Україні та світі. Встановлено, що традиційні підходи до сортування мають низку обмежень, пов'язаних із залежністю від людського чинника, недостатньою точністю розділення фракцій, забрудненням вторинної сировини та неефективною організацією обслуговування контейнерів. Обґрунтовано доцільність використання інтелектуальних систем, які поєднують комп'ютерний зір, нейромережеві алгоритми, сенсорні засоби та модулі прийняття рішень. Також встановлено, що найбільш перспективними для розумних контейнерів є рішення, здатні виконувати локальну обробку даних і швидко формувати керуючу дію без постійної залежності від хмарної інфраструктури.

У межах аналізу методів автоматичного визначення типу сміття було розглянуто підходи на основі RGB-зображень, згорткових нейронних мереж, полегшених архітектур для вбудованих систем, а також спектральних і багатоспектральних методів. Визначено, що RGB-нейромережі є найбільш придатними для первинного сортування змішаного побутового потоку, оскільки дозволяють працювати зі звичайними зображеннями без складного апаратного забезпечення. Водночас для практичного застосування важливим є не лише сам факт класифікації, а й інтеграція результату розпізнавання з логікою керування контейнером.

У другому розділі було виконано підготовку даних для оцінки ефективності моделей сортування. Для цього використано два відкриті набори зображень побутових відходів, які були об'єднані та приведені до єдиної структури. Було

виконано уніфікацію класів, перевірку коректності файлів, видалення дублікатів, масштабування зображень до розміру 224×224 пікселі та поділ даних на навчальну, валідаційну й тестову підвибірki. У результаті було сформовано структурований набір даних із класами glass, metal, organic, other, paper_cardboard і plastic, придатний для подальшого нейромережевого моделювання.

Також у другому розділі було проведено порівняльний аналіз моделей автоматичного сортування відходів. Було протестовано SimpleCNN, MobileNetV2 та EfficientNetB0. Результати показали, що проста згорткова модель може бути корисною як базовий орієнтир, однак має обмеження за точністю та стабільністю класифікації. Складніші архітектури демонструють потенціал для кращого розпізнавання, проте потребують коректного налаштування, адаптації до конкретного набору даних і контролю помилок між схожими класами. На основі цього було зроблено висновок, що для авторської системи доцільно застосувати компактну модель, орієнтовану не лише на класифікацію, а й на подальше прийняття рішення в межах розумного контейнера.

У третьому розділі було розроблено авторську програмну модель EdgeWasteNet_Lite. Вона побудована як легка згорткова нейромережева архітектура, призначена для класифікації зображень відходів за шістьма узагальненими категоріями. Особливістю розробленого програмного забезпечення є те, що воно не обмежується визначенням класу зображення. Після класифікації система оцінює рівень упевненості прогнозу та передає результат до модуля SmartBinController, який визначає цільовий відсік контейнера або резервне рішення для невизначеного об'єкта. Таким чином, у роботі реалізовано повний програмний ланцюг: зображення відходу – попередня обробка – нейромережева класифікація – оцінювання впевненості – вибір відсіку – імітація керуючої дії.

Розроблене програмне забезпечення включає модулі завантаження даних, попередньої обробки зображень, побудови та навчання EdgeWasteNet_Lite, оцінювання результатів, порівняння з базовими моделями, побудови графіків, матриць помилок, прикладів класифікації та експорту моделі у формат TensorFlow

Lite. Наявність експорту в TensorFlow Lite підтверджує орієнтацію розробки на подальше використання у вбудованих системах або малопотужних пристроях.

Проведене тестування показало, що EdgeWasteNet_Lite забезпечує високі та збалансовані результати класифікації, близькі до сильніших базових моделей. За результатами порівняння, авторська модель продемонструвала значення основних метрик на рівні приблизно 0,90–0,93, що свідчить про достатню якість розпізнавання тестових зображень. При цьому вона показала менший час навчання порівняно з SimpleCNN і зберегла прикладну функціональність, пов'язану з формуванням рішення для відсіку контейнера.

Аналіз матриць помилок підтвердив, що EdgeWasteNet_Lite здатна правильно розпізнавати основні категорії відходів, зокрема скло, метал, органіку, папір/картон, пластик і залишкові об'єкти. Найскладнішим для класифікації залишається клас other, оскільки він об'єднує візуально різноманітні об'єкти. Це вказує на перспективу подальшого вдосконалення моделі шляхом деталізації цього класу, розширення навчальної вибірки та балансування кількості зображень у різних категоріях.

У роботі також було реалізовано імітацію роботи розумного контейнера. Програмний прототип формує не лише передбачений клас, а й confidence, рішення системи, цільовий відсік, умовний кут сервоприводу, рівень заповнення відсіку та службове попередження. Це підтверджує, що розроблена система є не просто моделлю класифікації, а програмним прототипом інтелектуального контейнера, у якому результат нейромережевого розпізнавання перетворюється на практичну керуючу дію.

Практична цінність отриманих результатів полягає в тому, що розроблений прототип може бути використаний як основа для подальшого створення розумного контейнера, навчального стенда або дослідницької платформи для перевірки моделей автоматичного сортування відходів. Система може бути адаптована до різних сценаріїв: автономного контейнера, громадського пункту первинного сортування, демонстраційної системи або модуля підтримки прийняття рішень щодо розподілу відходів.

ПЕРЕЛІК ПОСИЛАНЬ

1. *Documents & Reports - All Documents | The World Bank*. URL: <https://documents1.worldbank.org/curated/en/099022025114040022/pdf/P180174-ca39eccd-ea67-4bd8-b537-ff73a675a0a8.pdf>.
2. Beyond an age of waste Turning rubbish into a resource / Z. Lenkiewicz et al. *Global Waste Management Outlook 2024*. 2024. URL: <https://www.unep.org/resources/global-waste-management-outlook-2024>.
3. OECD. Development co-operation and the elimination of plastic pollution. *OECD*. URL: https://www.oecd.org/en/publications/development-co-operation-and-the-elimination-of-plastic-pollution_96803ffc-en/full-report.html.
4. Smart waste management: A paradigm shift enabled by artificial intelligence / D. B. Olawade et al. *Waste Management Bulletin*. 2024. P. 244–263. URL: <https://doi.org/10.1016/j.wmb.2024.05.001>.
5. ConvoWaste: An Automatic Waste Segregation Machine Using Deep Learning. *org*. URL: <https://arxiv.org/abs/2302.02976>.
6. IoT-Enabled Real-Time Monitoring of Urban Garbage Levels Using Time-of-Flight Sensing Technology. *MDPI*. URL: <http://mdpi.com/1424-8220/25/7/2152>.
7. Smart waste management: A paradigm shift enabled by artificial intelligence / D. B. Olawade et al. *Waste Management Bulletin*. 2024. P. 244–263. URL: <https://doi.org/10.1016/j.wmb.2024.05.001>.
8. Focus-RCNet: a lightweight recyclable waste classification algorithm based on focus and knowledge distillation / D. Zheng et al. *Visual Computing for Industry, Biomedicine, and Art*. 2023. URL: <https://link.springer.com/article/10.1186/s42492-023-00146-3>.
9. Waste Material Classification: A Short-Wave Infrared Discrete-Light-Source Approach Based on Light-Emitting Diodes / A. Manakkakudy et al. *Sensors*. 2024. URL: <https://www.mdpi.com/1424-8220/24/3/809>.
10. Martinez-Hernandez U., West G., Assaf T. Low-Cost Recognition of Plastic Waste Using Deep Learning and a Multi-Spectral Near-Infrared Sensor. *Sensors*. 2024. URL: <https://www.mdpi.com/1424-8220/24/9/2821>.

11. A waste separation system based on sensor technology and deep learning: A simple approach applied to a case study of plastic packaging waste / R. Pucnik et al. *Journal of Cleaner Production*. 2024. URL: <https://www.sciencedirect.com/science/article/pii/S0959652624012101>.
12. AI-Enabled Smart IoT Waste Bin Monitoring and Dynamic Collection System for Sustainable Urban Sanitation / S. U. Gairola et al. 2025. URL: <https://www.scitepress.org/Papers/2025/138673/138673.pdf>.
13. IoT-Based Smart Waste Management System: A Solution for Urban Sustainability / J. Abedalrahim et al. *International Journal of Safety and Security Engineering*. 2025. URL: https://www.researchgate.net/publication/393995489_IoT-Based_Smart_Waste_Management_System_A_Solution_for_Urban_Sustainability.
14. Garbage Classification. *Kaggle*. URL: <https://www.kaggle.com/datasets/asdasdasdasdas/garbage-classification>.
15. Garbage Classification (12 classes). *Kaggle: The World's AI Proving Ground*. URL: <https://www.kaggle.com/datasets/mostafaabla/garbage-classification>.

ПРЕЗЕНТАЦІЯ



ДЕРЖАВНИЙ УНІВЕРСИТЕТ
ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ
ТЕХНОЛОГІЙ

КАФЕДРА ІНФОРМАЦІЙНИХ СИСТЕМ ТА ТЕХНОЛОГІЙ
КИЇВ 2026



ІНТЕЛЕКТУАЛЬНА СИСТЕМА АВТОМАТИЗОВАНОГО СОРТУВАННЯ ТВЕРДИХ ПОБУТОВИХ ВІДХОДІВ НА ОСНОВІ ВБУДОВАНИХ НЕЙРОМЕРЕЖЕВИХ МОДЕЛЕЙ

ПРЕЗЕНТАЦІЯ ДО ЗАХИСТУ БАКАЛАВРСЬКОЇ РОБОТИ

СТУДЕНТКИ ГРУПИ ІСД-42

СПЕЦІАЛЬНОСТІ 126-ІНФОРМАЦІЙНІ СИСТЕМИ ТА ТЕХНОЛОГІЇ

ХУДОЯРОВОЇ КАТЕРИНИ ІВАНІВНИ

2

МЕТА, ОБ'ЄКТ, ПРЕДМЕТ ТА ЗАВДАННЯ ДОСЛІДЖЕННЯ



Мета дослідження

Розробка та оцінка ефективності інтелектуальної системи автоматизованого сортування твердих побутових відходів на основі вбудованої нейромережевої моделі.



Об'єкт дослідження

Процес автоматизованого сортування твердих побутових відходів у розумних контейнерах.



Предмет дослідження

Нейромережеві моделі, алгоритми обробки зображень і програмні засоби прийняття рішень для розподілу відходів за цільовими фракціями.

Основні завдання

- проаналізувати сучасні системи сортування сміття
- підготувати набір зображень побутових відходів
- провести тестування моделей класифікації
- розробити модель EdgeWasteNet_Lite
- оцінити ефективність програмного прототипу

3

Актуальність теми

Актуальність розробки інтелектуальної системи сортування відходів

Проблема поводження з твердими побутовими відходами є однією з важливих екологічних та технічних проблем сучасного суспільства.

Змішування пластику, скла, паперу, металу та органічних відходів ускладнює подальшу переробку і знижує цінність вторинної сировини.

Традиційне сортування значною мірою залежить від дій людини, тому не завжди забезпечує достатню точність і стабільність.

Використання комп'ютерного зору та нейромережових моделей дозволяє автоматизувати визначення типу відходу та підвищити ефективність сортування.



4

Сучасний стан та перспективи сортування побутових відходів

Сортування побутових відходів залишається актуальним через зростання їх кількості та ускладнення складу.


Змішані відходи втрачають ресурсну цінність, оскільки придатні до переробки матеріали забруднюються органічними та залишковими фракціями.

Ефективне сортування є основою переходу до циркулярної моделі поводження з відходами.

Ключова ідея:

первинне сортування має виконуватися максимально точно ще на етапі потрапляння відходу до контейнера.

Figure 2: Municipal solid waste (MSW) generation by region: Total MSW (million tonnes) and MSW per capita (kg/person/day)



5

Архітектурні рішення розумних контейнерів

- Сучасні розумні системи сортування поєднують сенсори, камери, алгоритми машинного навчання та виконавчі механізми.
- Архітектура такої системи включає кілька рівнів: збір даних, обробку інформації, прийняття рішення та керування механізмом сортування.
- Камера або сенсор фіксує об'єкт, нейромережева модель визначає тип відходу, а система керування спрямовує його до відповідного відсіку.



6

Методи автоматичного визначення типу сміття

- Автоматичне визначення типу сміття є ключовим етапом роботи інтелектуальної системи сортування.
- Основними методами є комп'ютерний зір, згорткові нейронні мережі, спектральний аналіз та комбіновані сенсорні підходи.
- Для розумного контейнера найбільш доцільними є компактні нейромережеві моделі, здатні працювати з обмеженими обчислювальними ресурсами.




7

Методи автоматичного сортування та контролю роботи контейнера

✖ Контроль роботи контейнера передбачає не лише сортування відходів, а й моніторинг рівня заповнення, стану середовища та потреби у вивезенні.

✖ Автоматичне сортування поєднує розпізнавання типу відходу з подальшим керуванням виконавчим механізмом.

✖ Найбільш перспективним є комбінований підхід, у якому камера відповідає за розпізнавання, сенсори – за контроль стану контейнера, а алгоритм – за прийняття рішення.




8

Аналіз існуючих моделей та технологій


Для моделювання роботи системи було підготовлено набір зображень побутових відходів.

У роботі використано відкриті набори даних із зображеннями різних категорій сміття.

Дані були приведені до структури, придатної для навчання, валідації та тестування моделей комп'ютерного зору.



✖ Основні класи:
glass, metal, organic, other,
paper/cardboard, plastic.



9


Переваги, недоліки та обмеження існуючих моделей

Існуючі моделі можуть забезпечувати високу точність, але часто потребують значних обчислювальних ресурсів.

Для вбудованої системи важливими є не лише точність, а й швидкодія, компактність та здатність працювати автономно.

Основним обмеженням є складність класифікації схожих або забруднених відходів, а також потреба у якісному та збалансованому наборі даних.

- ! Необхідна компактна модель, орієнтована на практичне використання в розумному контейнері.




10

Принцип роботи та архітектура програмного забезпечення

Програмний прототип реалізує повний цикл автоматизованого сортування відходів.

Зображення подається на вхід моделі, проходить попередню обробку, класифікується нейромережею та перетворюється на рішення щодо цільового відсіку.

Архітектура системи орієнтована на подальшу інтеграцію з вбудованим пристроєм розумного контейнера.



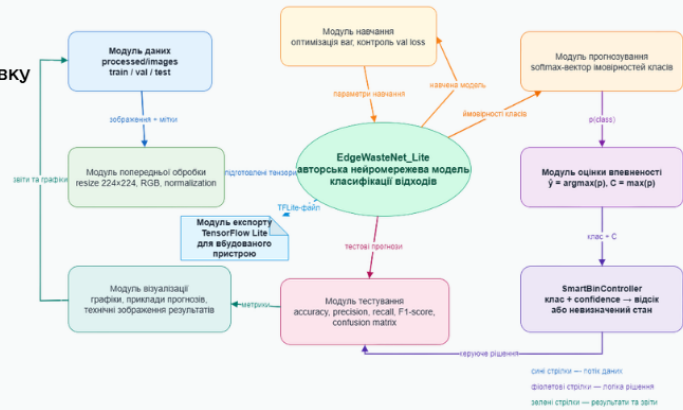
11

Основні функції програмного забезпечення та алгоритми

Програмне забезпечення виконує підготовку зображень, класифікацію відходів, оцінювання впевненості прогнозу та формування рішення.

Алгоритм роботи враховує не лише визначений клас, а й рівень впевненості моделі.

Якщо прогноз є недостатньо надійним, система може перейти до резервного сценарію або рекомендувати додаткову перевірку.



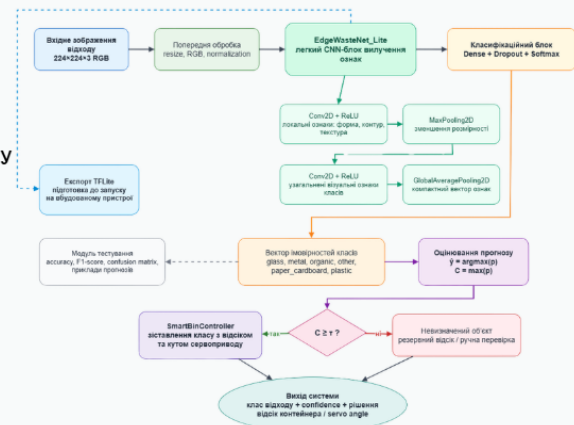
12

Особливості застосування моделі

Модель може застосовуватися як основа для програмного модуля розумного контейнера.

Її можна використовувати у навчально-дослідному стенді, прототипі автоматизованого сортування або системі рекомендацій щодо розподілу відходів.

Особливістю підходу є поєднання класифікації зображення, оцінювання впевненості та формування практичного рішення.





Результати тестування та оцінка ефективності прототипу






Тестування підтвердило працездатність програмного прототипу.

EdgeWasteNet_Lite забезпечила високі значення основних метрик класифікації та показала придатність для вбудованого використання.

Модель поєднує три елементи: нейромережеве розпізнавання, оцінювання впевненості прогнозу та формування рішення для відсіку контейнера.



14



15

Апробація результатів


- ✕ «Інтеграція автоматизованого сортувального модуля на основі IOT у концепцію “Розумного будинку” та “Розумного міста”»(стор. 30).
- ✕ «Оцінка зниження вуглецевого сліду при управлінні твердими побутовими відходами шляхом інтеграції IOT систем»(стор. 227).



16

Висновки

- У роботі досліджено сучасні підходи до автоматизованого сортування твердих побутових відходів.
- Підготовлено набір зображень для навчання та тестування моделей класифікації.
- Розроблено авторську модель EdgeWasteNet_Lite, орієнтовану на використання у вбудованій системі розумного контейнера.



A recycling symbol composed of three interlocking arrows made of crumpled green paper, set against a light green background. The text "ДЯКУЮ ЗА УВАГУ" is centered over the symbol.

ДЯКУЮ ЗА УВАГУ