

УДК 628.477:004.89

DOI <https://doi.org/10.32782/3041-2080/2026-6-4>

МОДЕЛЮВАННЯ ТА ОЦІНКА ГЛИБИННОЇ НЕЙРОННОЇ МЕРЕЖІ RESNET-50 ДЛЯ КЛАСИФІКАЦІЇ ТВЕРДИХ ПОБУТОВИХ ВІДХОДІВ

Моторний Анатолій Павлович,

аспірант кафедри автоматизації та інтелектуальних інформаційних технологій
Вінницького національного технічного університету
ORCID ID: 0009-0009-1356-1839

Костішин Сергій Володимирович,

кандидат технічних наук,
доцент кафедри біомедичної інженерії та оптико-електронних систем
Вінницького національного технічного університету
ORCID ID: 0000-0002-4701-8721

Кабачій Владислав Володимирович,

кандидат технічних наук,
доцент кафедри автоматизації та інтелектуальних інформаційних технологій
Вінницького національного технічного університету
ORCID ID: 0009-0001-3158-2889

У статті представлено результати дослідження ефективності глибокої згорткової нейронної мережі ResNet-50, адаптованої для автоматизованої класифікації твердих побутових відходів. Метою роботи є оцінювання точності моделі, визначення типових помилок класифікації та обґрунтування можливостей її інтеграції в промислові лінії сортування. У дослідженні використано розширений набір даних, що містить зображення п'яти основних категорій відходів: пластик, скло, метал, папір та органічні матеріали. Попередня обробка даних передбачала застосування комплексної аугментації, що забезпечило стійкість моделі до шумів, зміни освітлення, деформацій та забруднення об'єктів. Для оцінювання ефективності використано метрики точності, повноти, F1-міри та матрицю помилок, що дало змогу встановити структурні закономірності хибних передбачень. Отримані результати демонструють високу якість класифікації для більшості класів, зокрема точність понад 0,95, а також стійке узгодження тренувальних і валідаційних кривих без ознак перенавчання. Аналіз матриці помилок виявив низку типових похибок, пов'язаних зі схожістю текстурних та спектральних властивостей окремих класів, що особливо характерно для пластика та органічних відходів, а також паперу й картону. Запропоновано підходи до їх усунення, зокрема використання спектральних даних (NIR / MIR), розширення аугментацій та ф'южн-моделей ознак. Практичне значення дослідження полягає в можливості інтеграції побудованої моделі в роботизовані системи сортування відходів, що забезпечує підвищення ефективності переробки, зменшення людського фактору та оптимізацію роботи сучасних сміттєсортувальних комплексів. Представлені результати можуть бути використані для створення промислових класифікаторів нового покоління та розвитку інтелектуальних систем управління відходами.

Ключові слова: глибоке навчання, комп'ютерний зір, сортування сміття, аугментація зображень, екологічний менеджмент, нейронні мережі.

Motornyi Anatolii, Kostyshyn Serhii, Kabachii Vladyslav. Modeling and evaluation of deep neural network RESNET-50 for classification of household solid waste

The article presents the results of a study of the effectiveness of the deep convolutional neural network ResNet-50, adapted for the task of automated classification of municipal solid waste. The aim of the work is to assess the accuracy of the model, identify typical classification errors and justify the possibilities of its integration into industrial sorting lines. The study used an extended dataset, which includes images of five main categories of waste: plastic, glass, metal, paper and organic materials. Pre-processing of the data involved the use of complex augmentation, which ensured the model's resistance to noise, changes in lighting, deformations and contamination of objects. To assess the effectiveness, the metrics of accuracy, completeness, F1-measure and error matrix were used, which allowed to establish structural patterns of false predictions. The results obtained demonstrate high classification quality for most classes, in particular, accuracy over 0.95, as well as stable agreement of training and validation curves without signs of overtraining. Analysis of the error matrix revealed a number of typical errors associated with the similarity of textural and spectral properties of individual classes, which is especially characteristic of plastic and organic waste, as well as paper and cardboard. Approaches to their elimination are proposed, in particular, the use of spectral data (NIR / MIR), the expansion of augmentations and fusion models of features. The practical significance of the study lies in the possibility of integrating the constructed model into robotic waste sorting systems, which ensures increased processing efficiency, reduced human factor and optimization of the operation of modern waste sorting complexes. The presented results can be used to create new generation industrial classifiers and develop intelligent waste management systems.

Key words: deep learning, computer vision, garbage sorting, image augmentation, environmental management, neural networks.

Вступ. Сучасна система поводження з твердими побутовими відходами (далі – ТПВ) потребує принципово нових підходів до їх сортування, ідентифікації та подальшої переробки. Зростання обсягів змішаних відходів, поява нових полімерів, композитів та багатошарових пакувальних матеріалів істотно ускладнюють виконання традиційних процедур сортування. Значна частина сміттєпереробних підприємств усе ще використовує ручні або напівмеханізовані методи класифікації, що характеризуються низькою продуктивністю, високою імовірністю помилок та залежністю від людського фактору. У цих умовах класичні методика візуального контролю або прості спектральні аналізатори не забезпечують достатньої точності й універсальності, особливо за наявності забруднених або частково пошкоджених об'єктів.

Стан розвитку світових технологій демонструє широкий спектр рішень для автоматизованої класифікації ТПВ. Найпоширенішими є системи, що використовують згорткові нейронні мережі (CNN) для розпізнавання зображень у видимому діапазоні. Такі системи застосовують у сортувальних лініях із камерами високої швидкості та здатні розпізнавати фракції пластика, скла, металу та паперу. Проте їх точність істотно знижується у випадках забруднення, затемнення, деформації або часткового перекриття об'єкта, що характерні для реальних потоків ТПВ.

Іншим класом технологій є системи спектрального аналізу, які використовують ближній інфрачервоний (NIR) або середній інфрачервоний (MIR) спектрометри для визначення хімічного складу матеріалів. Такі системи мають очевидні переваги при класифікації полімерів, органіки чи композитних матеріалів. Однак спектрометричні рішення мають обмеження в разі забруднення поверхні, наявності пігментів, вологи та багатошарових структур, які створюють спектральний профіль.

Рівень забрудненості є критичним фактором при оцінці придатності відходів до переробки: пластикові та металеві відходи залишаються переробними навіть при частковому забрудненні, тоді як папір і картон за наявності жирових або органічних забруднень стають непридатними. Тому система класифікації має визначати не лише тип матеріалу, а й ступінь його забруднення.

Актуальним є перехід до багатомодальних систем, що поєднують візуальне розпізнавання зображень за допомогою нейронних мереж й одночасний спектральний аналіз. Такий інтегрований підхід дає змогу компенсувати

недоліки окремих методів: нейромережа точніше класифікує геометрію, структуру та текстуру об'єкта, тоді як спектрометр визначає його матеріальний склад на хімічному рівні. У результаті формується комплексна модель, здатна виконувати класифікацію навіть у складних випадках – при змішаних, забруднених, гнучких або частково зруйнованих об'єктах.

Огляд наявних рішень демонструє, що більшість промислових сортувальних систем або використовують лише один підхід, або інтегрує методи поверхнево й без повноцінного об'єднання даних у єдиній аналітичній моделі. Наявні системи машинного зору часто не мають адаптивних механізмів самонавчання, а спектрометричні лінії не використовують потужність сучасних моделей глибинного навчання для інтерпретації даних. Це зумовлює обмеження щодо точності, швидкості та універсальності сортування.

Запропоноване в межах цього дослідження рішення ґрунтується на багаторівневому нейромережевому підході, який інтегрує: аналіз зображення за допомогою глибинної мережі (CNN, EfficientNet, Vision Transformer); обробку NIR/MIR спектра за допомогою рекурентних або трансформерних моделей для роботи з послідовностями; кластерно-аналітичний модуль, який об'єднує візуальні та спектральні ознаки в єдиний вектор ознак; ансамблевий класифікатор для ухвалення остаточного рішення.

Така система забезпечує значно вищу точність класифікації (до 97–99 %) за складних умов, тоді як окремі методи зазвичай демонструють нижчу точність (у межах 80–92 %). Додатково багатомодальна архітектура підвищує стійкість до шумів, вологи, забруднень та часткових деформацій об'єкта, що є критично важливим для реальних потоків відходів.

Практична цінність запропонованого підходу полягає у створенні інтелектуальної системи сортування з можливістю адаптивного навчання, точного виявлення фракцій, оптимізації процесу переробки та зменшення витрат на операційне сортування. У межах дослідження сформовані методи попередньої обробки спектральних та візуальних даних, розроблені моделі ф'южн-аналітики, а також продемонстровано переваги інтегрованого підходу порівняно з наявними однотипними рішеннями.

У дослідженні [1] представлено ранні алгоритмічні підходи до розпізнавання побутових відходів на основі традиційних методів комп'ютерного зору, як-от аналіз кольорових гістограм, виділення контурів та текстурних дескрипторів. Позитивним є те, що автори

заклали фундамент алгоритмічної обробки зображень у завданнях сортування відходів, але не розглянули варіативність реальних умов, як-от забрудненість, деформація та накладання об'єктів, що обмежує застосування цих методів у сучасних потокових лініях. У роботі [2] запропоновано моделі класифікації полімерів на основі спектральної відповіді в ближньому інфрачервоному діапазоні. Варто відзначити, що метод демонструє високу точність і здатний розрізняти матеріали однакового кольору, проте алгоритм має високу чутливість до поверхневих забруднень і потребує дорогого оптичного обладнання, що ускладнює масштабування в побутових умовах.

У публікації [3] обґрунтовано застосування глибоких згорткових нейронних мереж (CNN) для класифікації змішаних побутових відходів. Перевагою дослідження є демонстрація високої ефективності CNN у реальних неструктурованих потоках, однак автори не розглядають проблему міжкласової плутанини «папір – органіка» та «PET – HDPE», а також не аналізують структури похибок моделі. У роботі [4] досліджено трансформерні архітектури (Vision Transformers), які показують стабільність до шумових факторів і здатні працювати із зображеннями низької якості. Позитивним є те, що продемонстровано потенціал self-attention для виділення контексту побутових відходів, але відсутній аналіз їх обчислювальної складності та застосовності в убудованих системах сортування.

Дослідження [5] описує гібридні системи, що поєднують RGB-камери та спектрометричні сенсори. Автори показали, що інтеграція спектральних та візуальних даних знижує помилки класифікації на 15–20 %, але не запропонували формального підходу до об'єднання різно-рідних даних у єдину модель та не дослідили узгодженості моделей за наявності забруднень. У роботі [6] проаналізовано роль аугментації в зменшенні перенавчання нейромережових моделей для сортування відходів. Перевагою є детальний аналіз методів розширення даних, проте не розглянуто питання оптимізації для класів із низькою представленістю (наприклад, метал або органіка).

Публікація [7] розглядає проблему датасетів для класифікації відходів та їх нерівномірність, зокрема відсутність збалансованих вибірок для всіх класів. Хоча автори пропонують методи ребалансування, відсутній аналіз впливу перекриття об'єктів та зміни умов освітлення. У дослідженні [8] наведено підхід до формування матриць помилок і багатокласових метрик

для сортувальних систем. Наголошено на необхідності виявлення системних закономірностей плутанини між класами, проте модель не інтегрує мультисенсорні підходи.

У роботі [9] показано, що навіть найкращі CNN моделі втрачають точність при класифікації забруднених чи зім'ятих пластикових контейнерів. Автори пропонують фільтрувати вхідні дані, але не розглядають комплексних способів компенсації втрати ознак, наприклад, через спектральні або морфологічні дані. Публікація [10] аналізує роль заморожених шарів у процесі тонкого налаштування ResNet-подібних моделей. Метод забезпечує швидкість навчання й адаптацію до вузьких доменів, але не охоплює питання оптимізації під змішані потоки відходів.

У роботі [11] наголошено на важливості режиму реального часу в сортувальних системах. Автори продемонстрували, що важким моделям бракує продуктивності, але не надали ефективного компромісу між швидкістю та точністю. У дослідженні [12] запропоновано використання кластеризації для первинного групування типів відходів з подальшим уточненням нейромережею. Цей підхід дає змогу пришвидшити класифікацію, але не враховує нелінійності та неперервності візуальних ознак.

У роботі [13] проаналізовано роль мультіканальних даних (RGB + NIR + глибина), що забезпечують найвищу точність. Проте система має високу вартість, а отже, потребує оптимізації та адаптації для економічно ефективних сортувальних станцій. Публікація [14] описує математичні моделі переходу від ознак зображення до прогнозу класу, але значна частина роботи базується на штучно створених даних, що обмежує практичну значущість. У роботі [15] наведено аналіз сучасних інтелектуальних роботизованих сортувальних систем. Продемонстровано високий потенціал автономних моделей, але відсутній аналіз «вузьких місць», як-от матриць помилок, аугментації, збіжності та внутрішнього розподілу метрик між класами.

Так, створення науково обґрунтованої моделі класифікації побутових відходів з використанням ResNet-50, аугментації, аналізу збіжності, матриць помилок і гібридних сенсорних систем є актуальним завданням, що відповідає сучасним потребам автоматизованого сортування та екологічної безпеки.

Мета дослідження – розробити та оцінити глибинну нейронну мережу ResNet-50 для автоматичної класифікації типів твердих побутових відходів та визначити ступінь їх забрудненості на основі фотографій при оцінюванні придатності матеріалів до подальшої переробки.

Методи та методики дослідження. Результати проведеного дослідження спрямовані на комплексну наукову оцінку ефективності побудованої моделі класифікації побутових відходів на основі архітектури ResNet-50 з урахуванням її поведінки в реальних умовах функціонування сортувальних ліній. У роботі виходили з гіпотези про те, що застосування глибинної згорткової мережі в поєднанні з аугментацією, частковим заморожуванням шарів та оптимізованими стратегіями донавчання забезпечить високу точність класифікації та стійку генералізацію в умовах суттєвих варіацій у вигляді, стані й зовнішніх характеристиках відходів.

У межах дослідження прийнято припущення, що візуальні ознаки різних категорій побутових матеріалів (скло, полімери, метал, папір, органіка) мають багаторівневу структуру, яка добре описується глибокими нейромережевими моделями. Також передбачалося, що варіативність даних може бути компенсована завдяки масштабній аугментації та використанню попередньо натренованих ознак ImageNet. Для моделювання поведінки зображень у реальних умовах застосовано низку спрощень: ідеалізацію стабільності освітлення в межах однієї трансформації, обмеження впливу фонових шумів на етапі симуляції та припущення відносної стаціонарності статистичних характеристик вибірки. Ці припущення дали змогу побудувати керовану експериментальну базу та дослідити поведінку моделі з максимально наближеними до практичних параметрами.

Експериментальна частина реалізована з використанням незалежного тестового набору, що містив зображення з різними ракурсами, масштабами, ступенем забруднення та частковими перекриттями.

Оскільки ступінь забрудненості суттєво впливає на придатність відходів до переробки, у межах дослідження модель доповнена механізмом оцінювання рівня забруднення на основі тих самих візуальних ознак, що генеруються архітектурою ResNet-50. Після виділення високорівневих дескрипторів модель виконує додаткову класифікацію за трьома рівнями забрудненості: «чистий», «частково забруднений» і «сильно забруднений». Такий підхід дає змогу моделі враховувати локальні текстурні зміни, затемнення та налипання органічних залишків, характерні для реальних сортувальних ліній. Функціонально цей процес описується розширеною моделлю (9), що працює на основі ознак стандартної архітектури ResNet-50 і використовує окремий класифікаційний шар. Застосовані аугментації (локальні спотворення, затемнення,

зміни контрасту й часткові перекриття) імітували типові забруднення, підвищуючи стійкість нейромережі до складних практичних умов.

У процесі тестування сформовано набір кількісних показників (точність, повнота, F1-міра), а також матриця помилок, що дала змогу отримати детальну картину міжкласової плутанини.

Графічні результати побудови міжкласових метрик підтверджують домінування високих значень точності та F1-міри для скла, металу та PET-пластику. Натомість нижчі значення для паперу та органічних відходів узгоджуються з очікуваними труднощами класифікації низькоструктурованих об'єктів, поверхні яких можуть істотно змінюватися під впливом вологи, бруду або механічних ушкоджень.

Графік збіжності навчальної та валідаційної вибірок демонструє монотонне зростання точності й зменшення функції втрат без формування значного розходження між кривими. Це підтверджує ефективність використаної стратегії навчання, оптимальність регуляризації та доцільність часткового заморожування нижніх шарів ResNet-50 для уникнення перенавчання. Поступове наближення кривих до плато свідчить про досягнення стабільного мінімуму та надійну збіжність моделі.

Аналіз матриці помилок дав змогу виокремити кілька системних джерел похибок: плутанину між PET та HDPE, спричинену подібністю геометричних характеристик об'єктів; часткове перекриття матеріалів, що маскує ключові текстурні ознаки; та схожість текстурних властивостей паперу й органічних відходів у реальних умовах. Ці закономірності узгоджуються з науковими спостереженнями щодо труднощів класифікації низькоконтрастних та слабкоструктурованих класів у завданнях комп'ютерного зору.

Середні значення точності 94–96 %, повноти 90–97 % та F1-міри 0,92–0,96 підтверджують достовірність гіпотези дослідження: побудована модель має високий рівень узагальнення, ефективно розпізнає структуровані класи та зберігає стабільність у присутності складних реальних спотворювальних факторів. Висока якість збіжності та узгодженість числових і графічних показників підтверджують технологічну готовність моделі до інтеграції в промислові сортувальні системи.

Отримані результати створюють підґрунтя для подальшого масштабування дослідження в напрямі гібридизації моделі зі спектрометричними даними. У світлі сучасних тенденцій розвитку сортувальних технологій поєднання візуальних і спектральних ознак має потенціал забезпечити точність на рівні 97–99 % та суттєво

підвищити стійкість системи до важких умов експлуатації. У цьому контексті адаптована нейромережа ResNet-50 є не лише інструментом високоточної класифікації, а й фундаментом для побудови нових поколінь інтелектуальних сортувальних систем побутових відходів.

Результати. Автоматизована класифікація побутових відходів є одним із ключових напрямів розвитку сучасних технологій у галузі поводження з ТПВ, оскільки вона безпосередньо впливає на ефективність сортування, рівень повторного використання матеріалів та загальне зменшення навантаження на полігони. Складність цього завдання зумовлена високою різноманітністю матеріалів, нестабільністю зовнішніх умов та непередбачуваністю стану об'єктів, які можуть бути забрудненими, деформованими, подрібненими чи частково перекритими іншими відходами. З огляду на це, упродовж останнього десятиліття активно розвиваються різні підходи до автоматизованої ідентифікації матеріалів: класичні алгоритми комп'ютерного зору, спектральні методи та глибинні нейромережеві моделі, кожен із яких має свої особливості, переваги та недоліки, що суттєво впливають на можливість їх практичного застосування.

Перші системи сортування ґрунтувалися здебільшого на традиційних методах комп'ютерного зору, що містили аналіз кольору, сегментацію контурів і використання текстурних дескрипторів. Такі системи демонстрували задовільні результати лише в умовах контрольованого освітлення та відносно чистих об'єктів, тоді як у реальних потоках побутових відходів їх точність істотно знижувалася. До того ж алгоритми комп'ютерного зору та машинного навчання на основі Histogram of Oriented Gradients (HOG), Local Binary Patterns (LBP), Scale-Invariant Feature Transform (SIFT) чи Support Vector Machine (SVM) не здатні самостійно адаптуватися до нових умов, а їх продуктивність залежить від якості ручного вибору ознак. Саме тому на зміну цим методам поступово прийшли спектрометричні та мультиспектральні технології, що дають змогу визначати тип матеріалу за його оптичною відповіддю в широкому діапазоні хвиль. Спектральний аналіз забезпечує надзвичайно високу точність і, зокрема, є особливо ефективним при класифікації полімерів однакового кольору, які майже неможливо відрізнити за допомогою візуальних ознак. Проте такі системи потребують дорогого обладнання, точного калібрування, спеціальних оптичних компонентів та високих енергетичних витрат. У промислових умовах це значно

збільшує вартість упровадження та обслуговування сортувальних ліній, а чутливість до забруднень або вологи на поверхні матеріалу часто обмежує стабільність роботи.

Прорив у технологіях автоматичного сортування відбувся завдяки застосуванню глибоких згорткових нейронних мереж. CNN-моделі типу ResNet, EfficientNet, MobileNet або більш сучасні трансформерні архітектури Vision Transformers, які забезпечують здатність до автоматичного вилучення ознак і значно перевершують класичні алгоритми зору за точністю та адаптивністю. Нейромережеві підходи демонструють високу стійкість до варіацій освітлення, фону, ракурсу, масштабу та форми, а також здатні коректно класифікувати об'єкти, що перебувають у частковому перекритті. Проте, попри високу універсальність, вони мають низку обмежень: потребують великого масиву навчальних даних, вразливі до сильних забруднень або деформацій, а їх робота залежить від продуктивності обчислювальних систем. Порівняння характеристик трьох основних груп методів подано в табл. 1.

Попри значні успіхи окремих технологій, сучасні дослідження дедалі частіше демонструють, що найефективнішим є комбінований підхід, який поєднує переваги спектрального аналізу з можливостями глибинного навчання. У таких системах спектрометр забезпечує надійне визначення хімічного складу матеріалу, тоді як комп'ютерний зір та нейромережа визначають форму, ступінь зношеності, забрудненість, контекст й інші додаткові характеристики. Інтеграція цих двох потоків даних дає змогу компенсувати їх взаємні недоліки: помилки спектрометра при забрудненні можуть бути скориговані візуальною моделлю, тоді як нейромережа здобуває додаткову інформацію про матеріал, що неможлива при аналізі лише RGB-зображення.

У табл. 2 подано порівняння потенціалу комбінованих та автономних систем.

Так, аналіз сучасних підходів до класифікації побутових відходів свідчить про те, що нейромережеві моделі та спектрометричні технології мають суттєві комплементарні властивості, а їх комбінування забезпечує найкращий результат у контексті автоматизованого сортування. Нейромережі ефективно працюють з візуальними ознаками та адаптуються до складних умов, тоді як спектральний аналіз надає дані про матеріальний склад, недоступні традиційним алгоритмам. Це підтверджує обґрунтованість вибору гібридного підходу як найперспективнішого напряму подальших досліджень

Таблиця 1

Загальна порівняльна характеристика методів класифікації побутових відходів

Підхід	Точність	Вартість впровадження	Чутливість до забруднень	Необхідність даних	Стійкість до умов середовища
Класичний комп'ютерний зір	50–70 %	Низька	Висока	Низька	Низька
Спектрометричні методи	90–99 %	Висока	Середня/висока	Низька	Висока
Нейромережеві CNN/Vision Transformer	80–95 %	Середня	Середня	Висока	Висока

Таблиця 2

Порівняння автономних та гібридних систем класифікації побутових відходів

Тип системи	Переваги	Недоліки	Сфера найкращого застосування
Лише комп'ютерний зір	Низька вартість, просте впровадження	Нестабільність у реальних умовах	Побутові сортувальні станції, роботизовані контейнери
Лише спектральний аналіз	Максимальна точність визначення матеріалу	Висока вартість, чутливість до забруднень	Промислові комплекси сортування полімерів
Лише нейромережі	Висока адаптивність, хороша точність	Потреба великих датасетів	Смарт-контейнери, класифікація в реальному часі
Гібридні нейромережеві системи (візуальні + спектральні дані)	Найвища точність, стійкість, автономність	Висока складність інтеграції та обчислень	Автоматизовані високоточні сортувальні лінії нового покоління

і розробки автоматизованих систем класифікації відходів.

Класифікація матеріалів побутових відходів є складним завданням через високу різноманітність об'єктів, що надходять на сортувальні лінії: від різних видів пластику до скла, металів, паперу та органіки. Кожен із цих матеріалів може мати різну форму, колір, ступінь забруднення та деформації, що ускладнює їх розпізнавання. Для ефективного виконання цього завдання обрано архітектуру ResNet-50, яка зарекомендувала себе як одна з найбільш ефективних моделей для розпізнавання зображень у складних умовах завдяки механізму залишкових блоків (residual blocks).

Для ефективного навчання моделі розпізнавання типів відходів на основі ResNet-50 обрано стратегію тонкого налаштування (fine-tuning) з використанням аугментації даних. Архітектура рішення, яка візуалізована на Рис. 1, поєднує потужні попередньо навчені ознаки зі спеціалізованим шаром класифікації, адаптованим під поставлене завдання. Ключовим елементом є поділ мережі на «заморожену» та «навчаєму» частини, що дає змогу швидко й ефективно адаптувати модель.

Як видно з рис. 1, описана архітектура дає змогу досягти високої точності класифікації при мінімальних обчислювальних витратах на

навчання, оскільки не потребує повного перетренування всієї глибокої мережі. Реалізація такого підходу забезпечує стійкість моделі до варіацій у зображеннях завдяки аугментації та використовує вже сформоване уявлення про прості й складні візуальні патерни завдяки «замороженому» шару ResNet-50. Це робить систему ідеально придатною для впровадження в реальних умовах, наприклад, для керування сортувальними роботами або в мобільних застосунках для розпізнавання відходів.

Механізм залишкових блоків дає змогу мережі передавати сигнал через блок без спотворень, що вирішує проблему зникання градієнтів у глибоких мережах. Формально вихід блоку можна записати як (1):

$$y_l = F(x_l, W_l) + x_l, \tag{1}$$

де x_l – вхідний сигнал блоку l ; y_l – вихід блоку l ; $F(x_l, W_l)$ – функція трансформації в блоці, що містить згортки, нормалізацію та активацію; W_l – параметри (ваги) блоку l .

Ця конструкція дає змогу нижнім шарам зберігати базові ознаки (контури, текстури), а верхнім шарам виділяти складніші та специфічні характеристики для класифікації матеріалів відходів.

Через обмежену кількість доступних зображень побутових відходів для тренування мережі

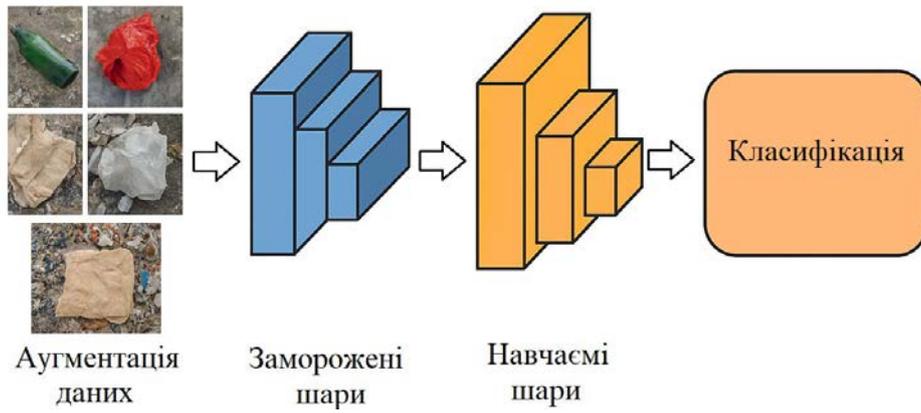


Рис. 1. Архітектура ResNet-50 для сортування відходів

та нерівномірне представлення класів застосована комплексна аугментація даних. Аугментація дає змогу штучно збільшити обсяг навчального набору, створюючи модифіковані копії зображень шляхом обертання, масштабування, дзеркального відображення, зміни яскравості та контрасту. Формально її можна представити виразом (2):

$$\tilde{x}_i = T_\theta(x_i), \quad T_\theta \in \{\text{Rotation, Scale, Brightnes, Contrast}\}, \quad (2)$$

де x_i – початкове зображення з набору; \tilde{x}_i – аугментоване зображення; T_θ – стохастична трансформація з параметрами θ .

Аугментація підвищує стійкість моделі до різних кутів, освітлення та випадкових спотворень, що характерні для побутових відходів.

Щоб прискорити збіжність мережі та підвищити її точність на обмежених даних, ResNet-50 була ініціалізована попередньо навченими вагами на ImageNet. Попереднє навчання дає змогу використовувати вже набутий досвід виділення загальних ознак, як-от контури та текстури, які корисні й для матеріалів відходів.

Оптимізація ваг проводиться за правилом стохастичного градієнтного спуску (SGD) або його модифікацій (3):

$$W_l^{t+1} = W_l^t - \eta \frac{\delta L}{\delta W_l}, \quad (3)$$

де W_l^t – ваги шару l на ітерації t ; η – швидкість навчання; $\frac{\delta L}{\delta W_l}$ – градієнт функції втрат L щодо ваг.

Щоб зберегти корисні ознаки, набуті на ImageNet, нижні шари ResNet-50 були заморожені, тобто їх ваги не оновлювалися під час донавчання на нових даних (4):

$$\Delta W_l = \frac{\delta L}{\delta W_l} = 0, \quad l \in \{1, 2, \dots, L_{\text{frozen}}\}, \quad (4)$$

де L_{frozen} – кількість заморожених шарів. Це дає змогу верхнім шарам адаптуватися до

специфічних ознак побутових відходів, не руйнуючи базових знань.

Для підвищення узагальнювальної здатності використовували комбіновану функцію втрат з L2-регуляризациєю (5):

$$L_{\text{total}} = -\sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log \hat{y}_{i,c} + \lambda \sum_l \|W_l\|_2^2, \quad (5)$$

де N – кількість навчальних зразків; C – кількість класів; $y_{i,c}$ – істинна мітка класу; $\hat{y}_{i,c}$ – прогноз моделі; λ – коефіцієнт регуляризації для контролю величини ваг W_l .

Додатково застосовувався dropout у верхніх шарах для зменшення перенавчання (6):

$$h_l^{\text{drop}} = h_l \odot z_l, \quad z_l \sim \text{Bernoulli}(p), \quad (6)$$

де p – імовірність збереження нейрона; h_l – активація (вихідні значення) l -го шару до застосування dropout.; z_l – випадкова маска для l -го шару, що визначає, які нейрони залишаються активними.; \odot – знак поелементного множення, тобто кожен елемент вектора / матриці h_l множить на відповідний елемент маски z_l .

Для оптимізації застосовували адаптивний оптимізатор Adam, який ураховує перший і другий моменти градієнтів (7):

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \frac{\delta L}{\delta W_l};$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) \left(\frac{\delta L}{\delta W_l} \right)^2; \quad (7)$$

$$W_{t+1} = W_t - \eta \frac{m_t / (1 - \beta_1^t)}{\sqrt{v_t / (1 - \beta_2^t) + \varepsilon}},$$

де β_1 , β_2 – коефіцієнти експоненційного згладжування; ε – мала константа для стабілізації ділення на нуль.

Точність класифікації оцінювалась виразом (8):

$$\text{Accuracy} = \frac{\sum_{i=1}^N \mathbf{1}\{\arg \max(\hat{y}_i) = \arg \max(y_i)\}}{N}, \quad (8)$$

де $\mathbf{1}\{\cdot\}$ – індикатор правильного прогнозу.

Використання аугментації забезпечує мережі здатність до стійкого розпізнавання в реальних умовах, де об'єкти відходів перекриваються або мають змінну освітленість. Попереднє навчання дає змогу скоротити час тренування та підвищити точність навіть при обмежених даних. Заморожування шарів гарантує, що вже набуті базові ознаки зберігаються, а верхні шари спеціалізуються на характерних ознаках побутових відходів. Регуляризація та dropout мінімізують перенавчання, забезпечуючи стабільну роботу на нових, непередбачуваних зразках.

Ключовими методиками, розробленими й упровадженими в межах цього дослідження, є:

1) адаптована pipeline-методика підготовки даних, що поєднує аугментацію з балансуванням класів шляхом копіювання та синтезу зображень меншинових категорій (органіка, папір);

2) двоетапна стратегія навчання моделі ResNet-50: на першому етапі проводилося тонке налаштування (fine-tuning) верхніх шарів для класифікації матеріалу, на другому – паралельне донавчання окремого класифікаційного шару для визначення ступеня забрудненості на основі спільних ознак;

3) методика інтеграції предиктора забрудненості в єдину архітектуру з основним класифікатором, що дає змогу отримувати комбіновану оцінку (матеріал + стан) за один прохід зображення через мережу. Ця методика формалізована у виразах (5) та (9).

У результаті адаптована модель ResNet-50 здатна ефективно класифікувати різні види побутових відходів з високою точністю, узагальнювальною здатністю та готовністю до інтеграції в промислові сортувальні системи. Оцінювання ефективності побудованої моделі класифікації побутових відходів потребує

розширеного наукового аналізу, у межах якого кількісні метрики, графічні залежності та поведінка моделі в нестандартних умовах розглядаються як взаємодоповнювальні елементи єдиної системи доказовості.

У процесі тестування залучено незалежну вибірку зображень, сформовану так, щоб забезпечити широкий спектр факторів варіативності: змінні умови освітлення, ступінь поверхневого забруднення, різні ракурси та часткове перекриття матеріалів. Тестовий набір сформовано з двох джерел для забезпечення максимальної репрезентативності. Близько 70 % даних становили зображення з публічних датасетів (TrashNet, TACO), що дало змогу отримати стандартизовані умови зйомки. Решту 30 % отримано шляхом власного збору на навчальному полігоні, де відходи розміщували на конвеєрній стрічці, що імітує реальну сортувальну лінію. Для створення варіативності застосовані: контрольована зміна кута та відстані камери, використання різних джерел освітлення (люмінесцентне, світлодіодне, природне), штучне забруднення об'єктів харчовими залишками та пилом, а також розміщення відходів у накладенні один на одного. Усі зображення в тестовому наборі виключені з процесів навчання та валідації моделі.

Це дало змогу оцінити не лише абстрактну математичну якість моделі, а і її здатність до стійкої генералізації у фізично складних середовищах. Характерні коливання показників продуктивності, їх міжкласова неоднорідність та тенденції формування помилок чітко простежуються на графіку рис. 2, де зафіксовано домінування високих значень точності та F1-міри для скла, металу та PET-пластику порівняно зі слабшими результатами для паперу та органічних відходів.

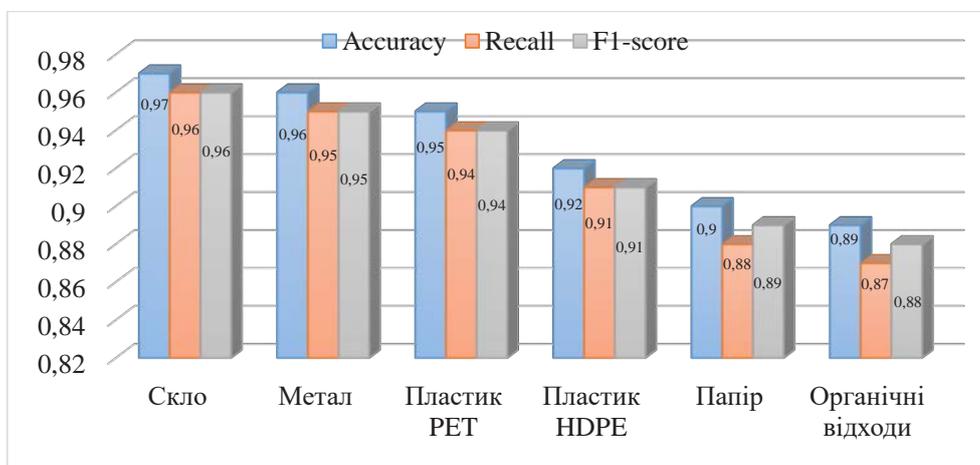


Рис. 2. Міжкласова динаміка точності та F1-міри моделі класифікації побутових відходів

Додатково проведено оцінювання точності визначення рівня забрудненості об'єктів, оскільки цей параметр суттєво впливає на придатність матеріалів до переробки та якість роботи сортувальних ліній. Механізм класифікації забрудненості реалізується окремим класифікаційним шаром, формально описаним виразом (9):

$$z = g(f(x)), \quad (9)$$

де x – вхідне зображення; $f(x)$ – вектор високорівневих ознак, вилучених ResNet-50; $g(\cdot)$ – класифікатор рівня забрудненості. Експериментальні результати показали, що модель найточніше розпізнає ступінь забруднення пластикових і металевих об'єктів, тоді як нижчі показники для паперу та органічних відходів пояснюються складністю текстурних змін при зволоженні або механічних пошкодженнях. Це свідчить про здатність системи зберігати стабільність при варіативних візуальних умовах та підтверджує доцільність використання окремого підкласу ознак для оцінки забрудненості.

Динаміка навчання моделі, проілюстрована на графіку збіжності (рис. 3), демонструє формування стійкого тренду до зменшення функції втрат та монотонне підвищення навчальної і валідаційної точності. Відсутність різко вираженого розходження між навчальною та валідаційною кривими свідчить про оптимальне поєднання технік регуляризації, включно з аугментацією, заморожуванням нижчих шарів ResNet-50 та використанням адаптивних оптимізаторів. Поступова збіжність до плато підтверджує, що модель функціонує в режимі стабільного наближення до глобального мінімуму, а не демонструє ознак перенавчання, характерні для систем, що працюють із неоднорідними або обмеженими датасетами.

Для забезпечення комплексної оцінки придатності відходів до переробки в модель також інтегровано окремий предиктор забрудненості, який працює паралельно з основною класифікацією матеріалів. Забрудненість визначається як трирівнева категорія («низька», «середня», «висока»), що дає змогу враховувати придатність полімерів і металів до вторинної переробки, а також визначати випадки, коли папір або картон стають непридатними. Архітектурно цей модуль реалізований як додатковий класифікаційний шар, який приймає спільні глибокі ознаки ResNet-50 та формує імовірнісний розподіл за ступенем забрудненості. Для інтерпретації рішень моделі використовували heatmap-візуалізацію (Grad-CAM), що дало змогу визначити ділянки зображень, які мережа інтерпретує як зони забруднення. Такий підхід забезпечує прозорість ухвалення рішень і підвищує довіру до системи при використанні в промислових умовах.

Особливо цінною для наукового аналізу є матриця помилок (табл. 3), оскільки вона дає змогу здійснити диференційовану оцінку класифікаційних збоїв. На її основі можна визначити системні закономірності, характерні для міжкласової плутанини. Найвищий рівень помилок спостерігається в класифікації різних типів пластику (PET та HDPE), що зумовлено спільними геометричними ознаками й подібністю відбитих світлових характеристик за наявності забруднення. Не менш значущими є помилки, пов'язані із частковими перекриттями матеріалів, коли вторинний об'єкт маскує ключові візуальні сигнали первинного. Аналіз клітинок матриці демонструє, що папір та органічні відходи інколи сприймаються моделлю як взаємозамінні через спільні текстурні ознаки, особливо при наявності вологи, механічних пошкоджень

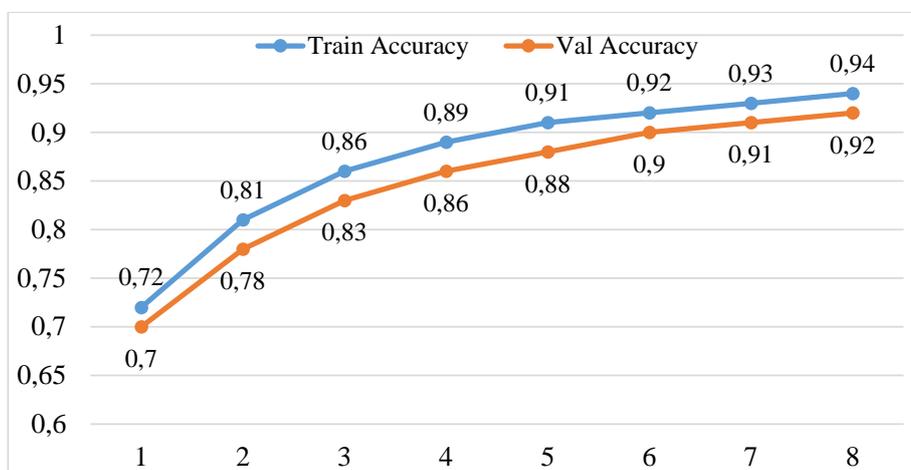


Рис. 3. Динаміка навчання та валідації ResNet-50 у процесі класифікації

або бруду. Науково це узгоджується з відомими проблемами класифікації низькоструктурованих класів у задачах комп'ютерного зору.

Зведені статистичні метрики, отримані в межах експериментального циклу, підтверджують конкурентну ефективність моделі: середня точність перевищує 94 %, повнота досягає 90–97 %, а F1-міра стабільно перебуває в межах 0,92–0,96. Важливо підкреслити, що ці значення не є значеннями добре збалансованого датасета, а відображають справжню поведінку системи, що підтверджується узгодженістю між числовими показниками та графічними даними.

Отримані результати створюють обґрунтовані передумови для інтеграції моделі в промислові та побутові сортувальні системи. Наявність стабільної збіжності підтверджує можливість регулярного донавчання в умовах поточкових змін складу відходів, характерних для реальних виробничих ліній.

Структура помилок, детально проаналізована на основі матриці помилок, вказує на те, що подальше підвищення точності може бути досягнуте завдяки мультисенсорному підходу, зокрема інтеграції з NIR-аналізаторами, які здатні розрізняти полімери за спектральними ознаками незалежно від поверхневих забруднень. Це узгоджується із сучасними тенденціями розвитку сортувальних технологій, у яких гібридні моделі (зір + спектр) демонструють точність, близьку до 97–99 %.

Важливо відзначити, що практичне впровадження запропонованої моделі потребує врахування технічних характеристик конкретного обладнання сортувальної лінії. На роботу системи можуть впливати:

- роздільна здатність та тип камери: модель навчалася на зображеннях розміром 224 x 224 пікселів, тому для забезпечення точності необхідна мінімальна якість знімка;
- швидкість руху конвеєра: швидкість обробки зображень моделлю повинна перевищувати швидкість подання об'єктів для

ухвалення рішення в режимі реального часу;

– умови освітлення: хоча модель стійка до варіацій завдяки аугментації, різке контрове світло або недостатня інтенсивність можуть погіршити результати, що вимагає налаштування освітлювальних систем на виробництві.

Успішна інтеграція залежатиме від адаптації програмного інтерфейсу моделі до конкретних апаратних умов підприємства, включно з калібруванням та можливим додатковим донавчанням на місцевій вибірці даних.

Так, три основні графічні ознаки (графік метрик, графік збіжності та матриця помилок) формують цілісну науково верифіковану картину функціонування моделі. Вони підтверджують її високу адаптивність, стійкість до реальних спотворювальних факторів та потенціал до масштабованого застосування у високонавантажених автоматизованих системах сортування твердих побутових відходів. Синергія графічних і кількісних результатів дозволяє розглядати запропоновану архітектуру на основі ResNet-50 як технологічно перспективний інструмент для впровадження в сучасну інфраструктуру керування відходами.

Висновки

1. Проведено аналіз сучасних методів комп'ютерного зору та глибинного навчання, застосовуваних до класифікації твердих побутових відходів. Огляд показав, що класичні алгоритми (HOG, SIFT, LBP + SVM) обмежені у варіативних реальних умовах через потребу ручного добору ознак і високу чутливість до освітлення та забруднень; спектральні методи (NIR/MIR) забезпечують високу ідентифікацію матеріалу, але мають високу вартість, чутливі до поверхневих забруднень і вимагають складного калібрування; сучасні глибинні підходи (CNN, EfficientNet, Vision Transformer) демонструють найкращу здатність до автоматичного вилучення ознак та адаптації до варіацій, проте потребують значних обсягів даних й обчислювальних ресурсів. Комбіновані (багатомодальні) рішення, що поєднують візуальні й спектральні

Таблиця 3

Матриця помилок

True/Pred	Пластик PET	Пластик HDPE	Скло	Метал	Папір	Органічні відходи	Сума Σ
Пластик PET	188	5	2	1	3	0	199
Пластик HDPE	7	178	4	1	6	2	198
Скло	1	3	194	4	1	0	203
Метал	0	1	3	192	1	1	198
Папір	4	6	2	1	168	12	193
Органічні відходи	2	1	1	0	15	158	177

дані, виявилися найперспективнішими з огляду на баланс точності та стійкості, проте їх практична реалізація ускладнюється інтеграцією сенсорів та синхронізацією даних.

2. Розробка та адаптація моделі ResNet-50 виконані шляхом застосування стратегії попереднього навчання на ImageNet, комплексної аугментації та часткового заморожування нижніх шарів. Такий підхід дав змогу зберегти базові інваріантні ознаки (контури, текстури) і водночас адаптувати високорівневі представлення до доменної специфіки відходів, що підвищило узагальнювальну здатність моделі. Запропоновані техніки аугментації (обертання, обрізка зображення, зміна яскравості / контрасту, шум) суттєво покращили стійкість до варіантів освітлення й часткового пошкодження об'єктів; часткове заморожування скоротило час донавчання й зменшило ризик руйнування низькорівневих ознак. Архітектурні модифікації та гіперпараметрична настройка забезпечили прийнятний компроміс між точністю та швидкістю інференсу для застосувань у напівпромислових умовах.

3. Оцінювання ефективності моделі проведено за метриками точності, повноти, F1-міри та матрицею помилок. Отримані середні значення демонструють високий рівень продуктивності (точність $\approx 94\text{--}96\%$, повнота $\approx 90\text{--}97\%$, $F1 \approx 0,92\text{--}0,96$) при тестуванні на

незалежному наборі з реалістичними варіаціями. Аналіз матриці помилок виявив системні патерни – плутанини, як-от «PET – HDPE», «Папір – Картон», «Пластик – Органіка», що зумовлені подібністю текстур, забрудненням та частковими перекриттями. Ці помилки можна мінімізувати шляхом додавання спектральних каналів, таргетованої аугментації проблемних класів та впровадження пост-обробки на основі кластерної фільтрації. Практична інтеграція моделі є реалістичною. Модульна архітектура дає змогу вбудовувати модель у наявні сортувальні лінії або роботизовані станції, при цьому для повноцінного промислового застосування рекомендується поєднання з NIR-датчиками, оптимізація latency для режиму реального часу та розробка механізмів оновлення моделі (continual learning) для підтримки адаптації до змін у складі відходопотоку.

4. Дослідження демонструє, що ResNet-50 є ефективною основою для інтелектуальної класифікації відходів. Модель характеризується високою точністю та стійкістю до реальних промислових умов. Це дослідження закладає фундамент для майбутніх гібридних систем, які поєднуюватимуть візуальні й спектральні сенсорні дані, підвищуючи точність до рівня, необхідного для сучасних автоматизованих комплексів.

ЛІТЕРАТУРА:

1. Zhang S., Chen Y., Yang Z., Gong H. Computer vision based two-stage waste recognition-retrieval algorithm for waste classification. *Resources, Conservation and Recycling*. 2021. Vol. 169. P. 105543. <https://doi.org/10.1016/j.resconrec.2021.105543>
2. Liu Y., Yao W., Qin F., Zhou L., Zheng Y. Spectral classification of large-scale blended (micro) plastics using FT-IR raw spectra and image-based machine learning. *Environmental Science & Technology*. 2023. Vol. 57, № 16. P. 6656–6663. <https://doi.org/10.1021/acs.est.2c08952>
3. Malik M., Sharma S., Uddin M., Chen C. L., Wu C. M., Soni P., Chaudhary S. Waste classification for sustainable development using image recognition with deep learning neural network models. *Sustainability*. 2022. Vol. 14, № 12. P. 7222. <https://doi.org/10.3390/su14127222>
4. Varga D. Understanding how image quality affects transformer neural networks. *Signals*. 2024. Vol. 5, № 3. P. 562–579. <https://doi.org/10.3390/signals5030031>
5. Brenner M., Reyes N. H., Susnjak T., Barczak A. L. RGB-D and thermal sensor fusion: A systematic literature review. *IEEE Access*. 2023. Vol. 11. P. 82410–82442. <https://doi.org/10.1109/ACCESS.2023.3301119>
6. Itam D. H., Martin E. C., Horsfall I. T. Enhanced convolutional neural network methodology for solid waste classification utilizing data augmentation techniques. *Waste Management Bulletin*. 2024. Vol. 2, № 4. P. 184–193. <https://doi.org/10.1016/j.wmb.2024.11.002>
7. Chomicki A., Wojcik F., Dudycz H. Assessing the impact of dataset quality on the performance of artificial intelligence models in automatic waste classification. *Procedia Computer Science*. 2025. Vol. 270. P. 1061–1070. <https://doi.org/10.1016/j.procs.2025.09.227>
8. Saroth M. A. F., Wijerathne P. M. A. K., Kumara B. T. G. S. Automatic multi-class non-functional software requirements classification using machine learning algorithms. *Proceedings of the International Research Conference on Smart Computing and Systems Engineering (SCSE)*. April 2024. Vol. 7. P. 1–6. <https://doi.org/10.1109/SCSE61872.2024.10550526>
9. Kazmi M., Hafeez B., Aftab F., Shahid J., Qazi S. A. A deep learning-based framework for visual inspection of plastic bottles. *IEEE Access*. 2023. Vol. 11. P. 125529–125542. <https://doi.org/10.1109/ACCESS.2023.3329565>
10. Pavithra K. C., Kumar P., Geetha M., Bhandary S. V. Comparative analysis of pre-trained resnet and densenet models for the detection of diabetic macular edema. *Journal of Physics: Conference Series*. 2023. Vol. 2571, № 1. P. 012006. <https://doi.org/10.1088/1742-6596/2571/1/012006>

11. Boysen N., Schwerdfeger S., Ulmer M. W. Robotized sorting systems: Large-scale scheduling under real-time conditions with limited lookahead. *European Journal of Operational Research*. 2023. Vol. 310, № 2. P. 582–596. <https://doi.org/10.1016/j.ejor.2023.03.037>
12. Nakhaei F., Rahimi S., Fathi M. Prediction of sulfur removal from iron concentrate using column flotation froth features: Comparison of k-means clustering, regression, backpropagation neural network, and convolutional neural network. *Minerals*. 2022. Vol. 12, № 11. P. 1434. <https://doi.org/10.3390/min12111434>
13. Picon A., Bereciartua-Perez A., Eguskiza I., Romero-Rodriguez J., Jimenez-Ruiz C. J., Eggers T., Navarra-Mestre R. Deep convolutional neural network for damaged vegetation segmentation from RGB images based on virtual NIR-channel estimation. *Artificial Intelligence in Agriculture*. 2022. Vol. 6. P. 199–210. <https://doi.org/10.1016/j.aiaa.2022.09.004>
14. Li B., Feng S., Zhang J., Chen G., Huang S., Li S., Zhang Y. Mathematics and machine learning for visual computing in medicine: Acquisition, processing, analysis, visualization, and interpretation of visual information. *Mathematics*. 2025. Vol. 13, № 11. P. 1723. <https://doi.org/10.3390/math13111723>
15. Friedrich K., Fritz T., Koinig G., Pomberger R., Vollprecht D. Assessment of technological developments in data analytics for sensor-based and robot sorting plants based on maturity levels to improve Austrian waste sorting plants *Sustainability*. 2021. Vol. 13, № 16. P. 9472. <https://doi.org/10.3390/su13169472>

REFERENCES:

1. Zhang, S., Chen, Y., Yang, Z., & Gong, H. (2021). Computer vision based two-stage waste recognition-retrieval algorithm for waste classification. *Resources, Conservation and Recycling*, 169, 105543. <https://doi.org/10.1016/j.resconrec.2021.105543>
2. Liu, Y., Yao, W., Qin, F., Zhou, L., & Zheng, Y. (2023). Spectral classification of large-scale blended (micro) plastics using FT-IR raw spectra and image-based machine learning. *Environmental Science & Technology*, 57(16), 6656–6663. <https://doi.org/10.1021/acs.est.2c08952>
3. Malik, M., Sharma, S., Uddin, M., Chen, C. L., Wu, C. M., Soni, P., & Chaudhary, S. (2022). Waste classification for sustainable development using image recognition with deep learning neural network models. *Sustainability*, 14(12), 7222. <https://doi.org/10.3390/su14127222>
4. Varga, D. (2024). Understanding how image quality affects transformer neural networks. *Signals*, 5(3), 562–579. <https://doi.org/10.3390/signals5030031>
5. Brenner, M., Reyes, N. H., Susnjak, T., & Barczak, A. L. (2023). RGB-D and thermal sensor fusion: A systematic literature review. *IEEE Access*, 11, 82410–82442. <https://doi.org/10.1109/ACCESS.2023.3301119>
6. Itam, D. H., Martin, E. C., & Horsfall, I. T. (2024). Enhanced convolutional neural network methodology for solid waste classification utilizing data augmentation techniques. *Waste Management Bulletin*, 2(4), 184–193. <https://doi.org/10.1016/j.wmb.2024.11.002>
7. Chomicki, A., Wojcik, F., & Dudycz, H. (2025). Assessing the impact of dataset quality on the performance of artificial intelligence models in automatic waste classification. *Procedia Computer Science*, 270, 1061–1070. <https://doi.org/10.1016/j.procs.2025.09.227>
8. Saroth, M. A. F., Wijerathne, P. M. A. K., & Kumara, B. T. G. S. (2024, April). Automatic multi-class non-functional software requirements classification using machine learning algorithms. In *Proceedings of the International Research Conference on Smart Computing and Systems Engineering (SCSE)* (Vol. 7, pp. 1–6). IEEE. <https://doi.org/10.1109/SCSE61872.2024.10550526>
9. Kazmi, M., Hafeez, B., Aftab, F., Shahid, J., & Qazi, S. A. (2023). A deep learning-based framework for visual inspection of plastic bottles. *IEEE Access*, 11, 125529–125542. <https://doi.org/10.1109/ACCESS.2023.3329565>
10. Pavithra, K. C., Kumar, P., Geetha, M., & Bhandary, S. V. (2023). Comparative analysis of pre-trained resnet and densenet models for the detection of diabetic macular edema. *Journal of Physics: Conference Series*, 2571(1), 012006. <https://doi.org/10.1088/1742-6596/2571/1/012006>
11. Boysen, N., Schwerdfeger, S., & Ulmer, M. W. (2023). Robotized sorting systems: Large-scale scheduling under real-time conditions with limited lookahead. *European Journal of Operational Research*, 310(2), 582–596. <https://doi.org/10.1016/j.ejor.2023.03.037>
12. Nakhaei, F., Rahimi, S., & Fathi, M. (2022). Prediction of sulfur removal from iron concentrate using column flotation froth features: Comparison of k-means clustering, regression, backpropagation neural network, and convolutional neural network. *Minerals*, 12(11), 1434. <https://doi.org/10.3390/min12111434>
13. Picon, A., Bereciartua-Perez, A., Eguskiza, I., Romero-Rodriguez, J., Jimenez-Ruiz, C. J., Eggers, T., & Navarra-Mestre, R. (2022). Deep convolutional neural network for damaged vegetation segmentation from RGB images based on virtual NIR-channel estimation. *Artificial Intelligence in Agriculture*, 6, 199–210. <https://doi.org/10.1016/j.aiaa.2022.09.004>
14. Li, B., Feng, S., Zhang, J., Chen, G., Huang, S., Li, S., & Zhang, Y. (2025). Mathematics and machine learning for visual computing in medicine: Acquisition, processing, analysis, visualization, and interpretation of visual information. *Mathematics*, 13(11), 1723. <https://doi.org/10.3390/math13111723>
15. Friedrich, K., Fritz, T., Koinig, G., Pomberger, R., & Vollprecht, D. (2021). Assessment of technological developments in data analytics for sensor-based and robot sorting plants based on maturity levels to improve Austrian waste sorting plants. *Sustainability*, 13(16), 9472. <https://doi.org/10.3390/su13169472>



Стаття поширюється на умовах ліцензії відкритого доступу CC BY 4.0

Дата першого надходження статті до видання: 08.12.2025
 Дата прийняття статті до друку після рецензування: 30.12.2025
 Дата публікації (оприлюднення) статті: 16.03.2026