

Юлія Легедза, Ігор Пірко*

¹ НЛТУ України, Львів, Україна, 23lehedza.i@nltu.lviv.ua

² НЛТУ України, Львів, Україна. ORCID: 0009-0008-2378-2929,
pirko@nltu.edu.ua

Розроблення інтелектуальної системи розпізнавання якості фруктів методами глибокого навчання

Анотація. В роботі використано бібліотеки TensorFlow та Keras для побудови та тренування глибокої згорткової нейронної мережі для класифікації фруктів на зображеннях. Завантажені дані піддавалися аугментації для покращення роботи моделі на різних зображеннях. Мережа мала успішні результати на тестовому наборі даних, досягаючи високої точності. Застосована методологія може бути використана для подальших досліджень та розширення на інші завдання класифікації зображень.

Ключові слова – розпізнавання зображень, Python, TensorFlow, Matplotlib.

Класифікація фруктів є важливим аспектом у галузі сільського господарства, машинного навчання та класифікації зображень. Швидка і точна їх класифікація є основною проблемою для підвищення ефективності в сільськогосподарському секторі. Моделі глибокого навчання, які базуються на штучних нейронних мережах, показали прийнятні результати в задачах виявлення та класифікації фруктів. Потенціал та перспективи глибокого навчання були досліджені з використанням архітектури на основі згорткових нейронних мереж. Незважаючи на значні перспективи, основні проблеми, з якими стикаються дослідження ідентифікації фруктів, пов'язані з нерегулярністю форми, розміру та мінливістю кольору.

В роботі використано набір даних FruitNet [1], який містить зображення фруктів разом з рівнями їх якості. В цьому датасеті наявні шість типів фруктів (яблуко, банан, гуава, лайм, апельсин і гранат), для кожного фрукту доступні три типи інформації про його якість (добра, погана та змішана). Набір даних містить 19 500 зображень, що належать до 18 класів. Детальну інформацію про розподіл за класами наведено в табл.1.

Таблиця 1. Розподіл за класами у наборі даних

мітка класу	good	bad	mixed	разом
apple	1149	1141	113	2403
banana	1113	1087	285	2485
guava	1152	1129	148	2429
lime	1094	1085	278	2457
orange	1216	1159	125	2500
pomegranate	5940	1187	125	7252
разом	11664	6788	1074	19526

Зображення в датасеті є з високою роздільною здатністю, за різних умов освітлення та фону. Зразки одних і тих самих фруктів, що належать до різних рівнів якості, містять високий ступінь візуальної схожості, зразки різних фруктів мають схожість за кольором, формою та текстурою. Це робить цей набір даних придатним для навчання інтелектуальних систем, які можуть бути застосовані для вирішення реальних проблем. Було використано набір даних для трьох різних завдань: класифікація фруктів (6 класів), оцінка якості (3 класи) та класифікація фруктів за рівнями якості (18 класів). На рис.1 представлено по одному зразку з кожного з класів набору даних.




Рисунок 1. Зразки зображень з набору даних FruitNet

Опис моделі. Згорткові нейронні мережі вважаються стандартом для вирішення задач класифікації зображень. З'явився інтерес до дослідження різних топологій нейронних мереж та експериментів з різними стратегіями, такими як

розширення ширини або глибини нейронних мереж. Вважається, що глибші мережі загалом працюють краще завдяки їхній більшій здатності до навчання [2].

У згорткових нейронних мережах кожен наступний шар отримує інформацію з усіх попередніх шарів [3]. Ці значення об'єднуються, щоб гарантувати, що жодна інформація не буде втрачена. Ця карта ознак пропускається через композитну функцію, яка містить в собі пакетну нормалізацію, Relu та згортку 3×3 . Потім результат передається на наступний шар і процес повторюється.

У глибокій мережі така конкатенація може призвести до дуже великої кількості параметрів. В результаті вона розбивається на багато блоків, кожен з яких розділений перехідним блоком. У перехідному блоці відбувається пониження вибірки. Перехідний шар складається з шарів пакетної нормалізації, шару згортки 1×1 і шару усередненого об'єднання 2×2 .

Як видно з табл.1, набір даних містить дисбаланс класів, оскільки кількість зразків змішаної якості значно менша порівняно з класами доброї та поганої якості. Глибокі нейронні мережі потребують великої кількості даних для ефективного навчання та пошуку прихованих закономірностей, доповнення даних може бути корисним для забезпечення достатнього обсягу різноманітних прикладів для навчання моделі. Тому замість збільшення/ зменшення вибірок перед фазою навчання було застосовано аугментацію даних.

Щоб відобразити реальні сценарії, використано такі техніки аугментації, як випадкове обертання, зсув по висоті та ширині, випадкові трансформації з різною інтенсивністю. Декілька з цих технік аугментації застосовуються до зразків, що дає змогу представити нову версію перед моделлю кожного разу, коли вона завантажується під час навчання.

Результати та обговорення. Вхідні зображення були змінені до розміру $256 \times 256 \times 3$. Співвідношення розділення було дотримано відповідно до набору даних для навчання, валідації та тестування. Модель навчалася з розміром партії 32, для всіх завдань використовувався оптимізатор Adam. В табл.2 проілюстровано продуктивність по класах, а також кількість зразків окремих класів у тестовому наборі. Хоча точність є відомою метрикою продуктивності, вона та-

кож відома своєю чутливістю до дисбалансу класів. Для більш надійного аналізу розглянуто precision (точність), recall (повнота) та F1-score (F1-міра) для кожного класу. Окрім цього, щоб отримати уявлення про розділення класів у запропонованій моделі, досліджено площу під кривою AUC-ROC. Цей показник використовується для оцінки продуктивності класифікатора, описуючи компроміс між частотою істинно позитивних результатів та хибнопозитивних результатів, використовуючи кілька порогових значень ймовірності. Модель досягла показника AUC-ROC 1 для більшості класів, як показано в табл. 2, оцінки для решти класів досить високі. На рис.2 зображено кілька неправильно класифікованих зразків.

Таблиця 2. Метрики якості моделі по класах

фрукти	якість	precision	recall	F1-score	AUC-ROC
яблуко	bad	1.0000	0.9956	0.9978	1.0000
	good	1.0000	1.0000	1.0000	1.0000
	mixed	1.0000	1.0000	1.0000	1.0000
банан	bad	0.9909	0.9954	0.9931	0.9973
	good	1.0000	1.0000	1.0000	1.0000
	mixed	0.9821	0.9649	0.9735	0.9998
гуава	bad	0.9913	1.0000	0.9956	0.9999
	good	0.9957	1.0000	0.9978	1.0000
	mixed	1.0000	0.9355	0.9667	0.9999
лайм	bad	0.9954	1.0000	0.9977	0.9999
	good	1.0000	1.0000	1.0000	1.0000
	mixed	1.0000	1.0000	1.0000	1.0000
апельсин	bad	0.9830	0.9914	0.9872	0.9999
	good	0.9917	0.9836	0.9877	0.9999
	mixed	1.0000	0.9600	0.9796	1.0000
гранат	bad	1.0000	1.0000	1.0000	1.0000
	good	1.0000	1.0000	1.0000	1.0000
	mixed	1.0000	1.0000	1.0000	1.0000



Рисунок 2. Неправильно класифіковані зразки

Висновок. Автоматизовані системи оцінки якості можуть відігравати важливу роль в обробці сировини, мінімізуючи ручну працю. Запропоновано модель, що використовує згорткові нейронні мережі для оцінки якості фруктів за зображеннями. Надійність моделі була досліджена для трьох різних завдань класифікації фруктів, оцінки їх якості та класифікації фруктів за рівнями якості, вона забезпечила точність близько 99,67 % для всіх завдань. Надано детальний аналіз по класах. У майбутньому ця модель може бути розширена за рахунок застосування моделей сегментації зображень і виявлення об'єктів для точного виявлення областей з неякісними фруктами.

Список використаних літературних джерел

- [1] Meshram, V., & Patil, K. (2022). Fruitnet: Indian fruits image dataset with quality for machine learning applications. *Data in brief*, 40, 107686.
- [2] Siddiqi, R. (2019). Automated apple defect detection using state-of-the-art object detection techniques. *Springer Nature Applied Sciences*, 1(11), 1–12.
- [3] Bhargava, A., & Bansal, A. (2021). Fruits and vegetables quality evaluation using computer vision. *Computer and Information Sciences*, 33 (3), 243–257.

Development of an intelligent fruit quality recognition system using deep learning methods

Yulia Legedza, Igor Pirko

The paper uses TensorFlow and Keras libraries to build and train a deep convolutional neural network for fruit classification in images. The uploaded data was subjected to augmentation to improve the model's performance on different images. The network performed well on the test dataset, achieving high accuracy. The applied methodology can be used for further research and extension to other image classification tasks.