



О. В. Старчак, Т. О. Коротеєва

Національний університет "Львівська політехніка", м. Львів, Україна

## КЛАСИФІКАЦІЯ ЯКОСТІ НАСІННЯ СОНЯШНИКА ЗА ЙОГО ЗОБРАЖЕННЯМИ ІЗ ВИКОРИСТАННЯМ НЕЙРОННИХ МЕРЕЖ

Враховуючи швидкий ріст населення у світі, сільськогосподарська галузь вимушена шукати та розвивати нові способи підвищення ефективності виробництва продуктів харчування. Одним з таких способів є удосконалення процесу відбору насіння ключових культур для посіву. Запропоновано використовувати тип згорткових нейронних і змагальних генеративних мереж для автоматизованого оцінювання якості насіння соняшника. У межах дослідження розроблено та навчено моделі згорткових нейронних мереж на базі ResNet, DenseNet та AlexNet для класифікації якості насіння соняшника за його зображеннями. Сформовано набір даних, що містить 1307 зображень насіння соняшника чотирьох класів: Broken, Deflated, Discolored та Normal. Проаналізовано роботи щодо застосування класичних методів машинного навчання, глибинного навчання та генеративних змагальних мереж для класифікації сортів і якості насіння різних культур зокрема і соняшника. На підставі попередніх досліджень з'ясовано, що застосування згорткових нейронних мереж демонструє високі показники точності класифікації під час навчання на великих обсягах даних. Проте, враховуючи недостатність зображень для ефективного навчання моделі в контексті цього дослідження, вирішено застосувати тип умовних генеративних змагальних мереж для розширення первинного набору даних штучними зображеннями насіння соняшника. Це повинно вдосконалити показники навчання моделей згорткових нейронних мереж. На підставі первинного набору даних створено п'ять додаткових, що були розширені штучним зображенням за допомогою моделі генератора. Проведено експериментальні випробування, під час моделі згорткових нейронних мереж, що навчалися на розширених наборах даних, демонстрували вищі показники точності передбачень класів якості насіння соняшника, ніж на первинному наборі, що підтверджують ефективність запропонованого підходу. Результати дослідження можуть бути корисними для сільськогосподарських виробників, агропромислових компаній і науковців, що працюють у галузі рослинництва.

**Ключові слова:** машинне навчання; згорткові нейронні мережі; генеративні змагальні мережі; глибинне навчання; насіння соняшника.

### Вступ / Introduction

Соняшник (*Helianthus* L.) є однією з найпоширеніших і найважливіших сільськогосподарських культур в Україні. Відповідно до інформації Продовольчої та сільськогосподарської організації ООН, Україна – найбільший виробник насіння соняшника за період від 2011 до 2021 рр. [10]. Середньорічне виробництво за весь цей проміжок часу становить близько 12 млн тонн насіння на рік.

Найбільш простим і традиційним способом визначення якості насіння є візуальне оцінювання та ручне сортування, проте воно не є ефективним через кількість затраченого часу та можливості людської помилки під час перевірки. Найпоширенішим способом перевірки є проведення лабораторної експертизи, яка також передбачає оцінювання насіння із застосуванням хімічних речовин, що дає змогу детально оцінити фізико-хімічні характеристики насіння [1]. Проте, цей підхід визначає тільки загальну якість насіння з партії за рахунок вико-

ристання певної кількості насіння, що надалі робить його непридатним для посіву після взаємодії з хімічними речовинами під час досліджень.

Завдяки стрімкому розвитку технологій комп'ютерного зору та машинному навчанню за останні роки з'явилась можливість автоматизувати цей процес за допомогою візуального оцінювання якості насіння за його зображенням, що допоможе збільшити ефективність відбору насіння. Наявні дослідження в цьому напрямку пропонують застосування методів класичного машинного навчання [3, 5, 15, 17, 20, 28] та згорткових нейронних мереж [4, 16, 19, 27] для вирішення проблеми класифікації та оцінювання якості насіння різних рослин, зокрема і соняшника. Перспективним є використання саме згорткових мереж, проте ключова їхня проблема полягає в недостатності даних для навчання. Для вирішення цієї проблеми можна використати генеративні змагальні мережі [21, 24], що дотепер ще не були застосовані для покращення результатів класифікації зображень саме насіння соняшника.

### Інформація про авторів:

**Старчак Орест Володимирович**, магістр, кафедра програмного забезпечення. Email: [starchak.orest@gmail.com](mailto:starchak.orest@gmail.com);

<https://orcid.org/0009-0003-5924-9011>

**Коротеєва Тетяна Олександрівна**, канд. техн. наук, доцент, кафедра програмного забезпечення.

Email: [tetyana.o.koroteyeva@lpnu.ua](mailto:tetyana.o.koroteyeva@lpnu.ua); <https://orcid.org/0000-0002-6287-5895>

**Цитування за ДСТУ:** Старчак О. В., Коротеєва Т. О. Класифікація якості насіння соняшника за його зображеннями із використанням нейронних мереж. Науковий вісник НЛТУ України. 2023, т. 33, № 6. С. 69–75.

**Citation APA:** Starchak, O. V., & Koroteyeva, T. O. (2023). Sunflower seed quality classification based on its images using neural networks. *Scientific Bulletin of UNFU*, 33(6), 69–75. <https://doi.org/10.36930/40330609>

**Постановка завдання дослідження** – реалізувати та навчити нейронні мережі для класифікації якості насіння соняшника за його виглядом, що дасть змогу автоматизувати процес оцінювання насіння. Створити генеративну змагальну мережу для генерування штучних зображень насіння для розширення наявного набору даних, щоб підвищити ефективність навчання класифікаційних моделей.

**Об'єкт дослідження** – класифікація якості насіння соняшника.

**Предмет дослідження** – методи та алгоритми нейронних мереж для генерування та класифікації зображень класів якості насіння.

**Мета роботи** – удосконалити процедуру класифікації якості насіння соняшника за його зображенням із використанням згорткових нейронних мереж, що дасть змогу здійснити їхній відбір для здорового проростання.

Для досягнення зазначеної мети потрібно вирішити такі **основні завдання дослідження**:

- 1) проаналізувати наявні підходи із використанням нейронних мереж для класифікації якості або сортів насіння інших сільськогосподарських культур;
- 2) сформулювати набір даних із зображень насіння соняшника, визначити основні класи для класифікації;
- 3) розробити та навчити модель умовної генеративної змагальної мережі на підставі наявних даних і доповнити первинний набір штучними зображеннями для підвищення точності передбачення;
- 4) розробити та навчити кілька моделей згорткових нейронних мереж для класифікації якості насіння соняшника на різних типах наборів даних і проаналізувати результати передбачень моделі на первинному та доповнених наборах зображень. Визначити моделі, що показали найкращу точність і приріст відповідно до кількості згенерованих зображень у наборі даних.

**Аналіз останніх досліджень та публікацій.** Автори досліджень у цій галузі використовують методи машинного та глибокого навчання для вирішення завдань класифікації сортів і якості насіння різноманітних рослин.

Серед популярних методів машинного навчання для класифікації, які найчастіше трапляються у дослідженнях, що стосуються розпізнавання сортів насіння, можна виділити: метод опорних векторів (англ. *Support Vector Machines*, SVM) [3, 20, 28], багатошаровий перцептрон (англ. *Multiple Layer Perceptron*, MLP) [17, 28], алгоритм випадкового лісу (англ. *Random Forest Algorithm*, RF) [17, 28], метод *k*-найближчих сусідів (англ. *k-Nearest Neighbor Method*, KNN) [17].

У роботі Мурат Коклу та ін. [17], де досліджують використання машинного навчання для класифікації сортів насіння гарбуза, за допомогою MLP, SVM, RF та KNN досягнуто 88.52, 88.64, 87.56 та 87.64 % точності розпізнавання відповідно. У класифікації насіння соняшника олійних сортів [5] показники точності для методів RF, SVM, and MLP становили 80,16, 79,68 та 78,89 %.

Також у дослідженні Гунасілан Джая Бріндха [15] пропонують використання методу SVM, із подальшою його оптимізацією за допомогою мурашиного алгоритму для класифікації сортів насіння соняшника. Згідно з результатами, метод SVM показав 88,32 % точності, а після оптимізації – 98,82 %.

Незважаючи на високу точність, розглянуті методи машинного навчання мають істотний недолік у потребі проведення виокремлення ознак перед їхнім застосу-

ванням. Для вирішення цієї проблеми можна використувати методи глибокого навчання на підставі глибоких нейронних мереж, оскільки вилучення та вивчення загальних ознак на підставі даних відбувається вже під час процесу навчання.

До прикладу, у дослідженні В. Труонг Хоанга та ін. [27] порівнюють ефективність згорткових нейронних мереж для набору даних з шести класів сортів рису загальною кількістю 8584 зображень. Можна виділити шість типів моделей згорткових нейронних мереж DenseNet, MobileNet, NasNetMobile, VGG, GoogleNet/ Inception та ResNet (англ. *Residual Neural Network*), кожна з яких показала результат, що перевищував 90 % точності класифікації сортів насіння рису.

У роботі Мікеля Барріо-Конде та ін. [4] розглядають застосування глибокої згорткової нейронної мережі на базі архітектури AlexNet для класифікації 6000 фото високоолійних сортів насіння соняшника, де кожному сорту відповідало 1000 зображень. Згідно з отриманими результатами, показники точності створеної класифікаційної моделі становили 100 % при розпізнаванні тільки двох сортів і 89,5 % – для розрізнення шести сортів.

У дослідженні Сяовея Цзіна та ін. [16] можна натрапити на порівняння ефективності застосування кількох типів згорткових нейронних мереж для класифікації класів 6000 зображень насіння соняшника перед застосуванням алгоритму стиснення та після. Для порівняння ефективності моделі на базі архітектури ResNet18 обрано такі моделі: LeNet5, AlexNet та DenseNet121. Передбачення кожної з моделей без процедури стиснення були такими: LeNet5 – 83,61 %, AlexNet – 83,89 %, ResNet18 – 86,94 %, DenseNet121 – 89,72 %.

Ферхат Куртулмуш [19] одним із перших вивчав можливість розпізнавання сортів насіння соняшника за допомогою глибоких нейронних мереж. Для порівняння обрано три поширені архітектури згорткових нейронних мереж: AlexNet, GoogleNet та ResNet. Також під час дослідження використовували два алгоритми оптимізації градієнтного спуску: SGD та AdaDelta. Набір даних становив близько 4800 зображень чотирьох сортів соняшника. Унаслідок цього після навчання, найвищі показники точності розпізнавання продемонстрували моделі на підставі GoogleNet – 97 % незалежно від обраного алгоритму оптимізації.

Основною проблемою під час навчання нейронних мереж для класифікації якості насіння сільськогосподарських культур є недостатня кількість зображень та незбалансованість дефектних класів якості насіння. Натомість для якісного оцінювання згорткові мережі потребують великих наборів даних. Дисбаланс в бік недефектних класів призводить до неефективності моделі при реальному застосуванні. Останні дослідження [24] пропонують тип генеративних змагальних мереж для зменшення дисбалансу класів у наборах даних шляхом генерування додаткових зображень на підставі вже наявних.

Також тип умовних генеративних змагальних мереж пропонують використовувати для вирішення проблеми незбалансованості набору під час навчання нейронної мережі класифікації дефектних насіння кукурудзи [21]. Автори цього дослідження отримали первинний незбалансований набір даних розміром 17 802 зображень, що містив 4 класи якості насіння кукурудзи: зламані насіння, знебарвлені, чисті та інфіковані. Після навчання мо-

делі BigGAN, згенеровані нею зображення були додані до первинного тренувального набору даних. Отже, модель класифікації навчалась уже на збільшеному та збалансованому наборі даних, який становив 29 981 зображень. Згідно з дослідженнями модель Resnet18 демонструвала найвищу точність при валідації на первинному наборі даних – близько 71,02 % успішних передбачень. Отже, при використанні набору даних, що містив близько 20 тис. згенерованих зображень, точність валідації збільшилась на 8,22 %.

Аналізуючи розглянуті вище дослідження, можна зробити висновок, що згорткові нейронні мережі демонструють високі показники точності при розпізнаванні різноманітних дефектів або сортів насіння різних культур, зокрема і насіння соняшника. Тому саме цей тип мереж обрано для визначення якості насіння соняшника у комбінації з методикою трансферного навчання. Також варто відзначити високу ефективність умовних генеративних змагальних мереж для збільшення обсягів початкових даних. Оскільки набір даних із зображень насіння соняшника для цієї роботи є невеликим та формувався з нуля, цей тип мереж використовуватиметься для його розширення, що повинно підвищити ефективність навчання моделі класифікації.

Серед наявних комерційних рішень, що використовуються для відбору та аналізу якості насіння, можна виділити DIGISEED [8], що пропонує компанія KUB-TEC Scientific. Особливість цього рішення полягає у використанні неруйнівного рентгенівського випромінювання для отримання знімку насіння, з його подальшою обробкою за допомогою методів машинного навчання. Такий підхід дає змогу отримати детальні дані про морфологічні та фізичні характеристики кожного насіння, а також визначити пошкодження та вплив зараження шкідниками і хворобами на різні частини насіння. Недоліком такого рішення є необхідність використання дорогого рентгенівського обладнання для агрегації зображень.

Також варто відзначити продукт Envision, який розробила компанія Seed-X [9]. Принцип роботи полягає у скануванні насіння через додатковий пристрій GeNee Detect [7], після чого відбувається навчання пропрієтарного алгоритму із застосуванням методів комп'ютерного зору та глибинного навчання. Програмне забезпечення допомагає аналізувати рівень схожості насіння, придатність паростків, однорідність насіння та генетичну чистоту. Навчання алгоритму поки що відбувається на підставі запропонованих клієнтом зображень насіння у комбінації із приватним накопиченим набором даних. Проте, як заявляють на сайті компанії, після того як їм вдасться накопичити необхідну кількість даних, алгоритм не потребуватиме додаткового навчання. Подібно як і DIGISEED [8], Envision [9] також вимагає додаткового специфічного обладнання для агрегації зображень.

## Результати дослідження та їх обговорення / Research results and their discussion

**Підготовка набору даних.** Першим етапом у формуванні масиву даних став ручний відбір насіння соняшника. Для цього використано непросіяне насіння соняшника сорту "Тео" [26] урожаю 2022 р., зібраного біля села Кам'янка, Черкаської області, Україна. Отже, відібрано 1307 насінин.

Перед отриманням зображень насіння було розміщене на білому фоні у вигляді блоків 3×3 шт., яке було

підсвічено за допомогою двох джерел білого світла (рис. 1). Задля уникнення ефекту тіні на фото використано підставку з прозорого скла. Відібране насіння сфотографовано за допомогою задньої QUAD камери смартфона Samsung Galaxy A23, роздільна здатність якої становить 50,0 MP + 5,0 MP + 2,0 MP + 2,0 MP [25].




Рис. 1. Схема конструкції для отримання зображень насіння /  
Construction scheme for producing seed images

Отже, вдалось отримати 147 фотографій у форматі JPG, кожна з яких містить у собі до 9 насінин, розміром 3060×4080 пікселів. Опісля, фотографія підлягала оброблянню за допомогою скрипта, розробленого мовою програмування Python. Завдяки цьому кожне насіння виокремлене у 9 окремих зображень.

Для розмітки збережених зображень визначено чотири класи вигляду насіння (рис. 2):

- Normal – здорове насіння чорного кольору, з можливим сірими смугами, більш заокругленої форми.
- Discolored – знебарвлене, тобто колір або відтінок відмінний від чорного.
- Broken – зламане та уражене хворобами або комахами насіння, ядро насіння частково або повністю без оболонки.
- Deflated – здуте та тонке за виглядом.



Рис. 2. Приклади класів якості насіння за виглядом / Examples  
of seed classes based on appearance

Розмітка зображень відбувалась у ручний спосіб, шляхом присвоєння нової назви файлу із зображенням. Отже, було отримано 1307 розмічених зображень насіння соняшника розміром 1020×1360.

Після цього сформовано три набори даних (табл. 1):

- Навчальний, що використовується для навчання моделі.
- Валідаційний, який використовується для оцінювання моделі після кожної епохи навчання.
- Тестувальний, котрий використовується на фінальному етапі розроблення моделі, для оцінювання ефективності її роботи на невідомих їй до цього даних. Дані для тестувального набору повинні відображати зображення, з якими модель працюватиме під час реального використання.

Загальна кількість зображень розподілена між навчальним, валідаційним та тестувальними наборами у співвідношенні 79,8, 10,1 та 10,1 % відповідно (табл. 1).

Оскільки не всі зображення в отриманому наборі даних відповідають єдиному стандартному розміру, перед навчанням було проведено процес нормалізації даних. Це включало зміну розміру зображень на менші (256 на 256 пікселів) за допомогою техніки віддзеркалення відступу, яку надає бібліотека FastAI [11]. Зміна розміру




зображень на менші необхідна для зменшення навантаження на обчислювальні потужності під час навчання моделі, а також для виокремлення більш загальних ознак для кожного класу, щоб уникнути перенавчання моделі.

**Табл. 1.** Розподіл зображень для навчання /  
Distribution of images for training

| Тип набору   | Клас насіння | Кількість за класом | Кількість за набором | Частка від сумарної кількості 1307, % |
|--------------|--------------|---------------------|----------------------|---------------------------------------|
| Навчальний   | Broken       | 187                 | 1043                 | 79,8                                  |
|              | Deflated     | 191                 |                      |                                       |
|              | Discolored   | 354                 |                      |                                       |
|              | Normal       | 311                 |                      |                                       |
| Валідаційний | Broken       | 33                  | 132                  | 10,10                                 |
|              | Deflated     | 33                  |                      |                                       |
|              | Discolored   | 33                  |                      |                                       |
|              | Normal       | 33                  |                      |                                       |
| Тестувальний | Broken       | 33                  | 132                  | 10,10                                 |
|              | Deflated     | 33                  |                      |                                       |
|              | Discolored   | 33                  |                      |                                       |
|              | Normal       | 33                  |                      |                                       |

Завдяки техніці віддзеркалення, замість розтягнення зображення при трансформації, пікселі, що знаходяться на краю зображення зеркально дублюються, зберігаючи початкове співвідношення сторін (рис. 3). Отже, зображення максимально зберігає початковий вигляд насіння, для кращого виокремлення ознак під час навчання моделі.



**Рис. 3.** Результати використання техніки віддзеркалення відступу / Results of application of reflection technique

**Генерування штучних зображень насіння.** Для дослідження впливу підвищення збалансованості та розширення обсягу зображень наявного набору даних на навчання моделі класифікації, за рахунок штучних зображень, застосовано тип генеративних змагальних мереж.


Під час реалізації моделі для генерування зображень за допомогою бібліотеки PyTorch, використано архітектуру генеративної змагальної мережі Wasserstein GAN [2]. Враховуючи потребу балансування класів, дана архітектура була удосконалена та перетворена на умовну генеративну мережу шляхом додавання міток класу, як додаткових вхідних даних для моделі генератора. Ця інформація дає змогу створювати тільки певний клас зображень, що водночас використовується для генерування та вирівнювання кількості зображень для кожного класу в наборі даних.

Процес навчання моделі генеративної змагальної мережі передбачає динамічну взаємодію між двома типами нейронних мереж – генератором та дискримінатором. Водночас, як генератор створює нові зображення

на підставі вхідного шуму та вхідних міток, дискримінатор намагається розрізнити реальні та згенеровані дані, використовуючи метод зворотного поширення помилки. Отже, з кожною новою ітерацією генератор вчиться створювати більш реалістичні дані до того моменту коли дискримінатор не зможе відрізнити реальне зображення від згенерованого.

Для побудови моделі дискримінатора було використано сім згорткових шарів Conv2d, після кожного з яких додано функцію активації Leaky ReLU. Натомість генератор складається з семи блоків, кожен з яких містить у собі згортковий шар ConvTranspose2d та функцію активації ReLU, після чого додається ще одна функція активації Tanh. Генератор може створювати, а дискримінатор може приймати на вхід зображення однакового розміру 256×256 пікселів.

Для реалізації та тренування генеративної моделі використано хмарну платформу Google Collaboratory [6], яка надає можливість виконувати Python скрипти за допомогою інтерактивного середовища Jupyter Notebooks [23]. Для обчислень обрано використання графічного процесора NVIDIA A100 [22]. Оскільки ліміт на використання ресурсів Google Collaboratory становить 12 год, гіперпараметри підібрані так, щоб не припиняти навчання моделі до вказаної часової межі. Навчання тривало 100 епох, що зайняло близько 11 годин. Внаслідок цього отримано модель генератора, що може створювати нові синтезовані зображення на підставі введеного класу (рис. 4).



**Рис. 4.** Приклад згенерованих зображень насіння після навчання генератора / Examples of generated seed images after training the generator

**Створення та навчання моделі класифікації.** Для дослідження обрано чотири типи згорткових нейронних мереж: Resnet18 [12], Densenet121 [13], AlexNet [18] та Resnet50 [12]. Під час реалізації та навчання моделей на базі вказаних архітектур використано бібліотеку машинного навчання FastAI [11].

Навчання проводилось у середовищі Google Collaboratory [6] із використанням графічного процесора NVIDIA A100 [22]. Задля отримання кращої точності передбачення для всіх моделей використано методику трансферного навчання. У контексті цього дослідження, для зазначених вище моделей використано параметри, що були отримані внаслідок навчання на різних версіях набору даних ImageNet [14]. Для того, щоб адаптувати дані параметри для вирішення проблеми класифікації насіння соняшника застосовано процес fine-tuning (тонке настроювання), внаслідок якого кінцеві шари попередньо навчених моделей оновлюють свої параметри відповідно до навчання на новому наборі даних.

Для оцінювання моделі на валідаційних даних обрано такі метрики, як error rate – частота помилок та accuracy – точність (відношення правильно передбачених зображень до помилкових), на тестувальних даних – тільки accuracy. Для визначення найкращої кількості епох необхідного для fine-tuning, проведено декілька запусків процесу тренування. Отже, оптимальна кількість циклів навчання становила 4 епохи для всіх мереж, після якого показники метрики error rate для всіх типів мереж почали зростати, що свідчило про початок процесу перетренування моделі.

Перший етап навчання полягав у тренуванні та оцінюванні імплементованих моделей на оригінальному наборі даних, що містив 1307 зображень насіння, з яких 1043 використовувались тільки для навчання. Унаслідок такого навчання точність передбачень моделей після валідації на тестовому наборі даних коливалась в межах 68-72 % (табл. 2).

**Табл. 2.** Результати навчання моделей / Model training output

| Модель       | Точність, % | Розмір тренувального набору даних | Кількість згенерованих зображень | Загальний розмір набору даних |
|--------------|-------------|-----------------------------------|----------------------------------|-------------------------------|
| Res-Net18    | 71,21       | 1043                              | 0                                | 1307                          |
|              | 75          | 2044                              | 1001                             | 2308                          |
|              | 74,24       | 3044                              | 2001                             | 3308                          |
|              | 75          | 4044                              | 3001                             | 4308                          |
|              | 74,24       | 6044                              | 5001                             | 6308                          |
| Dense-Net121 | 72,73       | 11044                             | 10001                            | 11308                         |
|              | 69,7        | 1043                              | 0                                | 1307                          |
|              | 71,21       | 2044                              | 1001                             | 2308                          |
|              | 72,73       | 3044                              | 2001                             | 3308                          |
|              | 72,73       | 4044                              | 3001                             | 4308                          |
| Alex-Net     | 74,24       | 6044                              | 5001                             | 6308                          |
|              | 71,21       | 11044                             | 10001                            | 11308                         |
|              | 71,97       | 1043                              | 0                                | 1307                          |
|              | 73,48       | 2044                              | 1001                             | 2308                          |
|              | 74,24       | 3044                              | 2001                             | 3308                          |
| Res-Net50    | 74,24       | 4044                              | 3001                             | 4308                          |
|              | 74,24       | 6044                              | 5001                             | 6308                          |
|              | 69,7        | 11044                             | 10001                            | 11308                         |
|              | 71,97       | 2044                              | 1001                             | 2308                          |
|              | 71,97       | 3044                              | 2001                             | 3308                          |

Для дослідження впливу згенерованих зображень на навчання моделей класифікації, створено п'ять додаткових наборів даних, кожен з яких доповнений певною кількістю зображень за допомогою натренованого раніше генератора (табл. 2). Генерування зображень прово-

дилась так, щоб досягти однакової кількості зображень для кожного класу.

Нові зображення додавались тільки до навчального набору, з метою уникнення валідації на несправжніх даних. Хоча це могло б покращити результати під час валідації, проте погіршить продуктивність моделі при застосуванні в реальних умовах. Кожна з моделей була навчена на доповнених даних, та провалідована на тестовому наборі даних.

Отже, відповідно до результатів навчання, найкращого результату точності передбачень класів якості насіння соняшника досягнуто з використанням моделі ResNet18, що становить 75 % (табл. 2). Розроблена модель змогла, хоч і неістотно, збільшити показники точності на 3,79 % за рахунок навчання на двох наборах зображень, що містили 1001 та 3001 згенероване зображення відповідно. Найкращий результат решти моделей становив 74,24 % правильних передбачень (табл. 2). Модель ResNet50 змогла досягти найкращого приросту результату точності розміром 5,3 % за рахунок доданого 5001 згенерованого зображення до навчального набору даних. Приріст кількості правильних передбачень для моделей DenseNet121 та Alexnet становив 4,54 % та 2,27 % відповідно. Також варто зауважити, що точність класифікації практично всіх моделей почала падати при навчанні на наборі, який містив 10001 згенероване зображення, за винятком моделі Resnet18, де точність впала на кількості 2001 та 5001.

**Обговорення результатів дослідження.** Для використання згорткових нейронних мереж при класифікації якості насіння соняшника проаналізовано їхню продуктивність у схожих завданнях [4, 16, 19, 27] при класифікації сортів і дефектного насіння для інших рослин, в т.ч. й соняшник. При застосуванні підходу генерування зображень для розширення набору даних зображень насіння вивчено досвід авторів у роботі [21].

Враховуючи те, що результати точності передбачень є меншими, ніж у дослідженнях [4, 16, 19, 27], варто зазначити, що навчання згорткових нейронних мереж в даній роботі проводилось на меншому реальному наборі зображень порівняно з тими, що використовувались в проаналізованих публікаціях. Також вперше було застосовано підхід із використанням генеративної змагальної мережі для збільшення кількості зображень саме насіння рослини соняшника у навчальному наборі даних. Такий підхід допоміг отримати максимальний приріст точності тільки на 5,3 % для моделі ResNet50, хоча очікувалось, що вдасться досягти подібних результатів як у роботі [21]. Проте, це також можна пояснити особливістю вигляду чорної текстури соняшника, у якій, порівняно з кукурудзою [21], важче розрізнити деякі дефектні ознаки, наприклад злегка знебарвлене насіння від нормального та спущеного.

Отже, за результатами виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

*Наукова новизна отриманих результатів дослідження* – розроблено та навчено модель умовної генеративної змагальної мережі з метою збільшення набору зображень насіння соняшника шляхом генерування штучних зображень.

*Практична значущість результатів дослідження* – запропонований підхід для розроблення та навчання

моделей класифікації якості насіння соняшника можна використовувати під час розроблення комерційних систем аналізу якості насіння для агропромислових компаній.

## Висновки/ Conclusions

Отже, розроблено та навчено чотири типи згорткових нейронних мереж для класифікації якості насіння соняшника за його зображенням, а також модель умовної генеративної змагальної мережі для генерування зображень соняшника з метою удосконалення процесу відбору насіння, придатного до здорового проростання. За результатами виконаної роботи зроблено такі висновки:

1. Проаналізовано наукові дослідження у галузі застосування методів машинного навчання, нейронних мереж і глибинного навчання при вирішенні проблем класифікації якості та сортів насіння різноманітних сільськогосподарських культур, зокрема й насіння соняшника. Основними перевагами поширених методів машинного навчання є точність, проте потребу додаткового вилучення ознак перед навчанням. Натомість з'ясовано, що згорткові нейронні мережі також досягають високої точності при подібних проблемах за допомогою автоматичного вилучення ознак під час навчання. Також виявлено, що тип генеративних змагальних мереж може використовуватись для вирішення проблем дисбалансу та недостатньої кількості даних.

2. Ручним способом сформовано набір даних, що складається з 1307 зображень насіння соняшника. Визначено чотири класи зображень соняшника: Broken, Deflated, Discolored та Normal. Кожне зображення позначено міткою класу.

3. Реалізовано модель умовної генеративної мережі Wasserstein GAN, яка в подальшому використовувалась для доповнення та балансування отриманого набору даних синтезованими зображеннями насіння соняшника, що допомогло максимально підвищити точність передбачень моделей класифікації ResNet50, DenseNet121, AlexNet та ResNet50 на 3,79, 4,54, 2,27 та 5,3 % відповідно.

4. Розроблено чотири моделі згорткових нейронних мереж на базі популярних архітектур Resnet, Densenet та AlexNet для класифікації якості насіння соняшника. Дані моделі протестовано на первинному та доповнених наборах даних. У підсумку найкращий результат точності передбачень показала модель ResNet18 – 75 % при навчання на наборі даних із 1001 та 3001 згенерованими зображеннями насіння. Найкращого приросту точності досягла модель ResNet18 – 5,3 % при 5001 штучному зображенні.

## References

1. Agrosep mash. (2023). Determining the quality of sunflower seeds. AGROSEPMASH Ukraine. Expertise. URL: <https://agrosep-mash.ua/uk/viznachennya-yakosti-nasinnya-sonyashniku/>
2. Arjovsky, M., Chintala, S., & Bottou, L. (2017). Wasserstein generative adversarial networks. In Proceedings of the 34th International Conference on Machine Learning, PMLR 70: 214–223 URL: <https://proceedings.mlr.press/v70/arjovsky17a.html>
3. Bantan, R. A. R., Ali, A., Naeem, S., Jamal, F., Elgarhy, M., & Chesneau, C. (2020). Discrimination of sunflower seeds using multispectral and texture dataset in combination with region selection and supervised classification methods. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 30(11), 9–10. <https://doi.org/10.1063/5.0024017>

4. Barrio-Conde, M., Zanella, M. A., Aguiar-Perez, J. M., Ruiz-Gonzalez, R., & Gomez-Gil, J. (2023). A Deep Learning Image System for Classifying High Oleic Sunflower Seed Varieties. *Sensors*, 23(5), 8. <https://doi.org/10.3390/s23052471>
5. Çetin, N., Karaman, K., Beyzi, E., Sağlam, C., & Demirel, B. (2021). Comparative evaluation of some quality characteristics of sunflower oilseeds (*Helianthus Annuus* L.) through machine learning classifiers. *Food Analytical Methods*, 14(8), 11. <https://doi.org/10.1007/s12161-021-02002-7>
6. Colab.google. (2023). Colab.google. URL: <https://colab.google>
7. Detect – Seed-X Technologies. (2023). Seed-X Technologies. URL: <https://www.seed-x.com/product/detect/>
8. DIGISEED – seed analysis. KUBTEC scientific. (2023). KUBTEC Scientific: Home of Cabinet X-ray Imaging. URL: <https://www.kubtecsscientific.com/applications/seed-analysis>
9. Envision – Seed-X Technologies. (2023). Seed-X Technologies. URL: <https://www.seed-x.com/product/envision/>
10. Faostat. (2023). Home. Food and Agriculture Organization of the United Nations. URL: <https://www.fao.org/faostat/en/#data/QCL/visualize>
11. Fastai – Welcome to fastai. (2023). Fastai – Welcome to fastai. URL: <https://docs.fast.ai/>
12. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 27–30. <https://doi.org/10.1109/cvpr.2016.90>
13. Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, 21–26. <https://doi.org/10.1109/cvpr.2017.243>
14. ImageNet. (2023). ImageNet. URL: <https://www.image-net.org/>
15. JayaBrindha, G. & Subbu, E. S. G. (2018). Ant colony technique for optimizing the order of cascaded SVM classifier for sunflower seed classification. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2(1), 6–10. <https://doi.org/10.1109/tetci.2017.2772918>
16. Jin, X., Zhao, Y., Wu, H., & Sun, T. (2022). Sunflower seeds classification based on sparse convolutional neural networks in multi-objective scene. *Scientific Reports*, 12(1), 9–13. <https://doi.org/10.1038/s41598-022-23869-4>
17. Koklu, M., Sarigil, S., & Ozbek, O. (2021). The use of machine learning methods in classification of pumpkin seeds (*Cucurbita Pepo* L.) Genetic Resour. *Crop Evolution*, 68(7), 11. <https://doi.org/10.1007/s10722-021-01226-0>
18. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
19. Kurtulmuş, F. (2020). Identification of sunflower seeds with deep convolutional neural networks. *Journal of Food Measurement and Characterization*, 8–9. <https://doi.org/10.1007/s11694-020-00707-7>
20. Meng, X., Yuan, Y., Teng, G., & Liu, T. (2021). Deep learning for fine-grained classification of jujube fruit in the natural environment. *Journal of Food Measurement and Characterization*, 11–14. <https://doi.org/10.1007/s11694-021-00990-y>
21. Nagar, S., Pani, P., Nair, R., & Varma, G. (2021). Automated Seed Quality Testing System using GAN & Active Learning. *Computer Vision and Pattern Recognition (cs. CV); Hardware Architecture (cs. AR)*, 1–8. <https://doi.org/10.48550/arXiv.2110.00777>
22. NVIDIA A100 gpus power the modern data center. (2023). NVIDIA. URL: <https://www.nvidia.com/en-us/data-center/a100/>
23. Project jupyter. (2023). Project Jupyter. Home. URL: <https://jupyter.org/>
24. Sampath, V., Maurtua, I., Aguilar Martín, J. J., & Gutierrez, A. (2021). A survey on generative adversarial networks for imbalance problems in computer vision tasks. *Journal of Big Data*, 8(1), 48–51. <https://doi.org/10.1186/s40537-021-00414-0>
25. Samsung galaxy A23, camera, battery & specs, Samsung UK. (2023). Samsung uk. URL: <https://www.samsung.com/uk/>



- smartphones/galaxy-a/galaxy-a23-5g-awesome-black-64gb-sm-a236bzkuub/#specs
26. TEO grade (sunflower, annual sunflower). (2023). Agrarians together. Information and analytical system. URL: <https://agrarii-razom.com.ua/culture-variety/teo>
  27. Truong Hoang, V., Van Hoai, D. P., Surinwarangkoon, T., Duong, H.-T., & Meethongjan, K. (2020). A comparative study of rice variety classification based on deep learning and hand-crafted features. *ECTI Transactions on Computer and Information Technology* (ECTI-CIT), 14(1), 5. <https://doi.org/10.37936/ecti-cit.2020141.204170>
  28. Tu, K., et al. (2022). A model for genuineness detection in genetically and phenotypically similar maize variety seeds based on hyperspectral imaging and machine learning. *Plant Methods*, 18(81), 4–15. <https://doi.org/10.1186/s13007-022-00918-7>

**O. V. Starchak, T. O. Koroteyeva**

*Lviv Polytechnic National University, Lviv, Ukraine*

## SUNFLOWER SEED QUALITY CLASSIFICATION BASED ON ITS IMAGES USING NEURAL NETWORKS

The agricultural industry is forced to pursue and develop new approaches for increasing the efficiency of food production due to the rapid growth of the world population. One of the possible methods is to improve the seed selection of key crops. Therefore, the paper introduces the usage of convolutional neural networks (CNN) and generative adversarial networks (GAN) for the automated assessment of sunflower seed quality. In the course of research, convolutional neural network models based on Resnet, Densenet and AlexNet were developed and trained to classify the quality of sunflower seeds based on their images. The formed data set includes 1307 images of four classes of sunflower seeds as follows: Broken, Deflated, Discolored, and Normal. The research also analyzes works related to the application of classical methods of machine learning, deep learning, and generative adversarial networks for the classification of varieties and quality of seeds of various crops, including sunflowers. The application of convolutional neural networks is revealed to demonstrate high classification accuracy rates when learning on large data volumes. However, taking into account the insufficiency of images for effective model training in the context of this research, we decided to apply the type of conditional generative competitive networks to expand the primary dataset with artificial images of sunflower seeds. This solution is to improve the learning performance of convolutional neural network models. Based on the primary data set, five additional models were created, which were augmented with artificial images using a generator model. Experimental tests were conducted as well. During the test, convolutional neural network models trained on extended data sets demonstrated higher accuracy indicators of sunflower seed quality class predictions than on the primary set, confirming the effectiveness of the proposed approach. The research results can be used by agricultural producers, agro-industrial companies, and scientists working in the plant breeding field.

**Keywords:** machine learning; convolutional neural networks; generative adversarial networks; deep learning; sunflower seeds.