

УДК 004.8

Качмарський Олекса Ігорович

асистент кафедри комп'ютерних наук,

Національний університет біоресурсів і природокористування України

ORCID: <https://orcid.org/0009-0001-0241-5678>E-mail: olesprof@gmail.com

ВИЗНАЧЕННЯ СТАДІЙ ЗРІЛОСТІ ПОЛУНИЦІ ЗА ДОПОМОГОЮ МОДЕЛЕЙ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ

***Анотація.** Протягом всієї історії сільського господарства технології вирощування та збору урожаю постійно вдосконалюються, полегшуючи роботу та полі та збільшуючи ефективність збору плодів. Сьогодні у галузь агропромисловості теж проникають сучасні технології, зокрема штучний інтелект. Його використання щороку стає дедалі поширенішим. Ця технологія дозволяє виробникам агропродукції в режимі реального часу отримувати великі обсяги інформації, аналізувати їх та приймати рішення щодо внесення добрив, використання пестицидів, зрошення та визначення зрілості плоду або рослини. Не менш важливим аспектом застосування рішень штучного інтелекту є відслідковування вуглецевого сліду, що дає перевагу при виході на європейські ринки збуту. Поєднання з новітніми розробками безпілотних машин та роботів дозволяє збільшити продуктивність та обсяги виробництва у сільському господарстві.*

Важливою частиною сучасної агропромисловості є комп'ютерний зір — одна з галузей штучного інтелекту, яка зосереджена на створенні інтелектуальних систем, які здатні обробляти та аналізувати візуальну інформацію так, як це робить людська сенсорна система. У рамках даної технології часто використовуються нейронні мережі, що здійснюють як розпізнавання зображень, так і їхню класифікацію.

У статті здійснено порівняльний аналіз різних моделей згорткових нейронних мереж для класифікації стадії дозрівання полуниці, а саме MobileNetV2, MobileNetV3Small та EfficientNetB0. Для оцінки нейромережі враховувалися такі параметри, як точність навчання та валідації, втрати при навчанні та валідації, час навчання. У результаті найкращі показники виявилися у мережі MobileNetV3Small. Результати та методика цього дослідження можуть бути корисними як для науковців, так і для підприємців, що працюють в агропромисловості та впроваджують штучний інтелект у виробничий процес.

***Ключові слова:** штучний інтелект, машинний/комп'ютерний зір, згорткова нейронна мережа (ЗНМ), MobileNet, EfficientNet.*

Вступ. Полуниця є однією з найпоширеніших ягідних культур у світі. Вона походить із Америки, а у Європу її привезли у 18 столітті. Комерційне виробництво полуниці почалося у 19 столітті, і у зв'язку зі щорічним збільшенням попиту зростає. Воно і не дивно, адже вона росте у будь-яких кліматичних умовах, крім полярних місцевостей, а також містить чимало вітамінів, мінералів та інших корисних та поживних елементів для організму людини. У світі вирощують близько 9 мільйонів тон цього плоду. Найбільшим виробником є Китай, який вирощує близько третини світового обсягу полуниці[1], а значну частку ринку займають також США, Туреччина та Мексика.

Завдяки автоматизації агропромислового комплексу, зростає потреба в різноманітних технологічних інноваціях, які можуть замінити традиційні функції, що виконуються людиною. Одним із ключових етапів збору полуниці є визначення ступеня зрілості ягоди. Такими системами обладнані чимало роботів, які здійснюють збірку різних овочів, фруктів, ягід та зернових культур, що дозволяє нівелювати чинник людської помилки, а також оптимізувати сам процес. Пошук оптимальної системи, яка би максимально точно та швидко визначала зрілість плодів, а тому дослідження на таку тему завжди мають потенціал для подальшого використання у промисловості.

На сьогодні існує чимало досліджень, де вивчається питання класифікації стадії зрілості плоду. Для цього використовують чимало способів: від різноманітних класифікаторів, дерев рішень до ЗНМ як з готовою архітектурою, так і з власною. Щоб оцінити ефективність тієї чи іншої технології, окрім точності потрібно також враховувати інші параметри, які дають нам розуміння щодо гнучкості та пристосованості розробленої системи до різних даних чи пристроїв.

Аналіз останніх досліджень та публікацій. На сьогоднішній день згорткові нейронні мережі стали одним з найпоширеніших типів нейронних мереж за рахунок вдалого розпізнавання різноманітних зображень. Їхньою відмінною рисою є наявність математичної операції згортки, і самі згорткові шари є ядром такої мережі. Ефективність цього виду нейромереж зумовлена здатністю до автоматичного виявлення потрібних ознак зображення, а також можливістю обробляти великі масиви даних при навчанні.

Машиинний зір та роль ЗНМ в ньому

Наразі існує чимало готових моделей ЗНМ, таких як VGG, AlexNet, DenseNet, ResNet, Inception, R-CNN, FAST-RCNN тощо. Для кожної з них існує одна чи кілька версій, кожна з яких відрізняється кількістю згорткових шарів(наприклад, у VGG16 16 згорткових шарів, а у VGG19 - відповідно 19). Крім цього, розробник може спроектувати власну згорткову нейромережу, або розробити кілька маленьких нейромереж різних архітектур для розв'язання певної проблеми. Також, в агропромисловості широко використовується алгоритм YOLO різних версій. Його особливість полягає в тому, що на відміну від традиційних нейронних мереж, він розпізнає об'єкти на зображенні в реальному часі, роблячи "прохід" через власну внутрішню нейронну мережу тільки один раз, тобто фактично без навчання.

Варто також і згадати про техніки, що модифікують навчальний набір даних, таких як нарощування даних(data augmentation). Цей метод передбачає збільшення навчального набору даних у кілька разів шляхом обертання зображень під різними кутами, обрізання та інших операцій з ними. Це дозволяє нейромережі бути гнучкішою для виконання поставленої задачі. Крім того, в залежності від ситуації, використовуються різні види зображень, а також кольорових моделей, серед яких: чорно-білі, кольорові(RGB RGB-D), HSV, спектральні та теплові зображення. Кожен вид зображення або кольорова модель має як свої переваги, так і недоліки, і при виборі необхідної картинки потрібно враховувати як саму задачу, так і чимало навколишніх чинників, таких як положення об'єкту в просторі, пору дня, видимість, погодні умови тощо.

Використання ЗНМ в агропромисловості

Науковці із Куньмінського університету науки і технологій здійснили дослідження [2], в ході якого був проведений порівняльний аналіз різних версій алгоритму YOLO у задачі визначення ступеню зрілості полуниці. В ході роботи було використано 1187 зображень ягід полуниці, 949 з яких було використано для навчання нейромережі, і по 119 для валідації та тестування. Навчання відбувалося на 300 епохах. В результаті алгоритм YOLOv8 відпрацював найкраще із точністю розпізнавання в 97.4%.

Часто пошук оптимальної архітектури потребує експериментальної перевірки і вимірювання ефективності та точності різних моделей. Автори такого дослідження розв'язали задачу визначення зрілості чорних та білих ягід шовковиці за їхнім зовнішнім виглядом, а також запропонували модель сортувального пристрою, який би використовував їхню розробку[3]. В ході цього, вони здійснили порівняльний аналіз 5 існуючих різновидів архітектур згорткових нейронних мереж, а саме: AlexNet, DenseNet, ResNet-18, ResNet-50, InceptionV3. Навчання відбувалося на 2000 зображеннях(по 1000 для чорних і білих ягід), 70% з яких були призначені для тренування нейромереж, а решта - для валідації та тестування. Класифікація ягід відбувалася за 4 станами: недозріла, напівнезріла, стигла, перестигла. При виборі найкращої моделі, окрім її точності, враховувався також час розпізнавання, який залежить від кількості шарів у нейромережі, а у 5 вищезгаданих архітектурах ця кількість досить різна.

Попри те, що всі нейромережі показали високу точність, але для білої шовковиці з урахуванням всіх параметрів найкращою виявилася AlexNet з точністю в 98.32% і швидкістю класифікації в 1 хв. Для чорної шовковиці найефективніше себе показала ResNet-18 з точністю в 98.65% та швидкістю класифікації в 1.2 хв. ResNet-18 виявилася найліпшою також і для змішаного набору ягід, уникнувши перенавчання та показавши точність в 98.03% і швидкість розпізнавання в 2.36 хв.

Дослідники із університету Аль-Азхар із Гази розробили нейронну мережу, яка виявляє ступінь зрілості плоду папайї на основі його зовнішнього вигляду [4]. Для цього була вибрана згортоква нейронна мережа з архітектурою VGG16. Набір навчальних даних складався з близько 300 зображень, кожне з яких містило позначення відповідного ступеня зрілості. Класифікація папайї здійснювалася на основі таких ступенів: незріла, напівзріла, зріла. За результатами цієї роботи точність нейронної мережі склала практично 100%, при навчанні нейронної мережі в 1 хв 52 секунди.

Для уникнення перенавчання та підвищення точності нейромережі використовують таку техніку, як регуляризації. У даному дослідженні [5] був проведений порівняльний аналіз різних методів регуляризації для нейронної мережі, що здійснювала виявлення ступеню зрілості манго, томату та яблука. Архітектура нейромережі VGG16 додатково містить багатошаровий перцептрон, який обробляв уже регуляризовані дані. Для збільшення навчального набору було застосоване нарощування даних (data augmentation). Для оцінки нейромережі розглядалися такі показники, як влучність, повнота та f-міра.

Без застосування регуляризації ці параметри склали (80%, 76%, 78%). При застосуванні методу регуляризації виключення (dropout) ці параметри склали (90%, 90%, 90%), для методу пакетної (batch) нормалізації (84%, 84%, 84%), а регуляризації ядра (kernel regularization) – (87%, 78%, 81%). Попри те, що метод виключення виявився найточнішим для цієї нейромережі, кожен спосіб регуляризації покращував влучність, повноту та f-міру.

Метою статті є дослідження ефективності існуючих моделей ЗНМ для класифікації стадії зрілості плоду на прикладі ягід полуниці, здійснення порівняльного аналізу отриманих результатів, визначення найефективнішої нейромережі, а також порівняння із аналогічними системами на предмет точності та швидкості розпізнавання.

Новизна цієї роботи полягає в порівнянні ефективності різних архітектур нейронних мереж на унікальному наборі зображень полуниць, спеціально зібраному для класифікації стадій дозрівання, що має практичне значення агропромислових досліджень у нашій країні. Дослідження також аналізує ефективність легких моделей на зображеннях середньої якості, що важливо для впровадження комп'ютерного зору в умовах обмежених обчислювальних ресурсів, використання моделі на мобільних або вбудованих пристроях для реального агропромислового застосування.

Матеріали і методи дослідження. Програмний код для навчання нейромереж написаний мовою Python з використанням бібліотек ComputerVision та TensorFlow. При навчанні програмно зображення приводяться до розміру 224x224 а також застосовується техніка нарощування даних. Технічні характеристики машини, на якій здійснювалося навчання нейромереж: 32 ГБ ОЗП, RX570 4GB, Intel Xeon E5 - 2670V3 12/24.

Набір даних складений самостійно, в деяких випадках зображення піддалися обробці, кольорова гама – RGB, роздільна здатність – низька. Зображення ягід розподілені за 3 класами: незрілі, наполовину зрілі та повністю зрілі (рис. 1).



Рисунок 1 – Стадії дозрівання полуниці(зліва направо): незріла, наполовину зріла, стигла

Навчальний набір містить 402 зображення, валідаційний – 91 зображення. Валідаційний набір дозволяє оцінювати продуктивність моделі на даних, які вона не застосовувала під час тренування. Навчання нейромереж здійснювалося на 100 епохах.

В контексті досліджуваних метрик розглядається матриця невідповідностей (табл. 1) – таблиця особливого компонування, що дає можливість унаочнювати продуктивність алгоритму класифікації.

Таблиця 1 – Матриця невідповідностей

	Прогнозовано: ТАК	Прогнозовано: НІ
Насправді: ТАК	TP	TN
Насправді: НІ	FP	FN

Розрізняють 4 можливі результати класифікації об’єкту:

- істинно позитивний(true positive, TP): правильно передбачена приналежність до певного класу;
- істинно негативний(true negative, TN): правильно передбачено те, що об’єкт дослідження не належить до певного класу;
- хибно-позитивний(false positive, FP): неправильно передбачена приналежність до певного класу;
- хибно-негативний(false negative, FN): неправильно передбачено те, що об’єкт дослідження не належить до певного класу.

Для оцінки нейромережі вимірювалися такі показники:

- точність(accuracy) – частка правильно прогнозованих результатів
- втрати – є мірою того, наскільки добре або погано нейромережа виконує свої завдання на даних навчального або валідаційного набору. Чим менші втрати, тим модель точніша у своїх передбаченнях.
- влучність(precision) – частка істинно-позитивних передбачень серед усіх позитивних передбачень. Обчислюється за формулою $TP / (TP + FP)$.
- повнота(recall) – частка правильних позитивних передбачень серед усіх істинних позитивів. Обчислюється за формулою $TP / (TP + FN)$.
- міра f1(f1-score) – гармонійне середнє між влучністю та повнотою, яке дозволяє отримати збалансовану оцінку. Обчислюється за формулою:

$$f1 - score = \frac{2 * Precision * Recall}{Precision + Recall}$$

- час навчання – міра того, наскільки оптимально нейромережа буде здійснювати поставлену задачу. Також, він залежить від складності і об’єму моделі, тобто чим більше шарів вона має, тим час навчання буде більший.

Для кожного параметру у кожній нейромережі побудовані відповідні гафіки, а також матриці невідповідностей.

Результати дослідження. Легкі моделі часто показують кращі результати на невеликих наборах даних низької чи середньої якості завдяки меншій кількості параметрів і схильності до меншого перенавчання. Вони ефективніше узагальнюють інформацію, коли даних недостатньо для навчання великих моделей, таких як ResNet чи VGG. Крім того, простіші архітектури краще справляються із шумом і недоліками даних низької якості, тоді як складні моделі можуть «запам’ятовувати» шум, що знижує точність [6].

В ході дослідження було здійснено порівняльний аналіз 3 існуючих різновидів архітектур ЗНМ, а саме MobileNetV2, MobileNetV3Small та EfficientNetB0, які є одними з найлегших моделей згорткових нейронних мереж у наш час.

MobileNet — це сімейство легких згорткових нейронних мереж, оптимізованих для роботи в умовах обмежених ресурсів [6]. Ключовою ідеєю, яка лежить в основі архітектури, є використання згортки з розділенням за глибиною (*Depthwise Separable Convolution*), що дозволяє значно зменшити обчислювальні витрати без значної втрати точності [6]. Це відбувається таким чином: у класичних згортках вхідний тензор розміром $h_i \times w_i \times d_i$ і застосовує згорткове ядро розміром k щоб створити вихідний тензор розміром $h_j \times w_j \times d_j$. Це призводить до обчислювальних витрат, пропорційних формулі: $h_i \times w_i \times d_i \times d_j \times k \times k$. MobileNet замінює це підходом, який розділяє згортку на два окремі етапи:

1) Глибокі згортки (*Depthwise*): кожен фільтр застосовується до одного каналу, а не до всіх.

2) Точкові згортки (*Pointwise*): використовуються згортки для лінійного об'єднання каналів.

Це дає обчислювальні витрати, визначені як: $h_i \times w_i \times d_i \times (d_j + k^2)$, що робить такі згортки ефективнішими.

MobileNetV2, наступна версія сімейства, включає нову концепцію інвертованих залишкових блоків (*Inverted Residuals*), які спрощують передавання градієнтів через мережу, та лінійні вузькі місця (*Linear Bottlenecks*), що покращують якість представлення ознак [7].

У MobileNetV3 архітектура вдосконалена за допомогою автоматичного пошуку архітектур (*Neural Architecture Search, NAS*) і впровадження механізму *Squeeze-and-Excitation (SE)*, який динамічно коригує вагу каналів для покращення точності [8]. Крім того, використання функції активації *Hard-Swish* у MobileNetV3 забезпечує покращення продуктивності без збільшення обчислювальних витрат.

EfficientNet — це сімейство моделей згорткових нейронних мереж, які оптимізовані для досягнення високої продуктивності при мінімальних обчислювальних витратах [9]. Їх головною відмінністю є використання підходу *Compound Scaling* [9]. Цей метод дозволяє одночасно збільшувати глибину, ширину та роздільну здатність вхідних зображень таким чином, щоб зберігати оптимальну архітектуру мережі:

- глибина – кількість шарів мережі, що відповідають за здатність моделі розпізнавати складніші патерни;
- ширина – кількість фільтрів у кожному шарі, що збільшує здатність мережі до паралельної обробки даних;
- роздільна здатність – розмір вхідних зображень, що впливає на деталізацію, яку мережа може навчитися розпізнавати.

Основою сімейства EfficientNet є модель EfficientNetB0 — базова модель у сімействі, яка слугує відправною точкою для масштабування. Вона була автоматично створена за допомогою Neural Architecture Search (NAS) [10]. Модель оптимізована для компромісу між точністю та обчислювальною складністю. Її архітектура включає такі ключові елементи:

- 1) MBConv блоки, які містять згортки з розділенням за глибиною, а також точкові [7], що зменшує обчислювальні витрати.
- 2) Squeeze-and-Excitation. Кожен MBConv блок містить механізм SE, що дозволяє адаптивно зважувати канали [11], підвищуючи важливість найбільш інформативних із них.
- 3) Функція активації Swish замість ReLU, яка покращує передавання градієнтів та сприяє точності моделі [12].
- 4) Початкові гіперпараметри:
 - Глибина: модель має оптимальну кількість шарів, виявлену за допомогою NAS.
 - Ширина: фільтри були обрані так, щоб забезпечити баланс між продуктивністю та ефективністю.

- Роздільна здатність: вхідні зображення мають розмір 224x224 пікселів.
- 5) Оптимізація через Compound Scaling. EfficientNetB0 є базою, яку можна масштабувати для створення інших моделей у сімействі (B1-B7), що забезпечують більшу точність при більшій обчислювальній потужності.

Результати роботи нейромереж

Нейромережа MobileNetV2 показала такі показники при навчанні: точність, влучність, повнота та F1-міра склали 99.46%, втрати 0.0139. При валідації точність, влучність, повнота та F1-міра склали 97.8%, втрати 0.099. Саме навчання нейромережі тривало 14 хв 36 с.

Як видно з графіка на рис. 2, точність навчання стабілізувалися в районі 55 епохи, при цьому точність валідації була висока з перших епох та коливалася в мажах 2-4%.

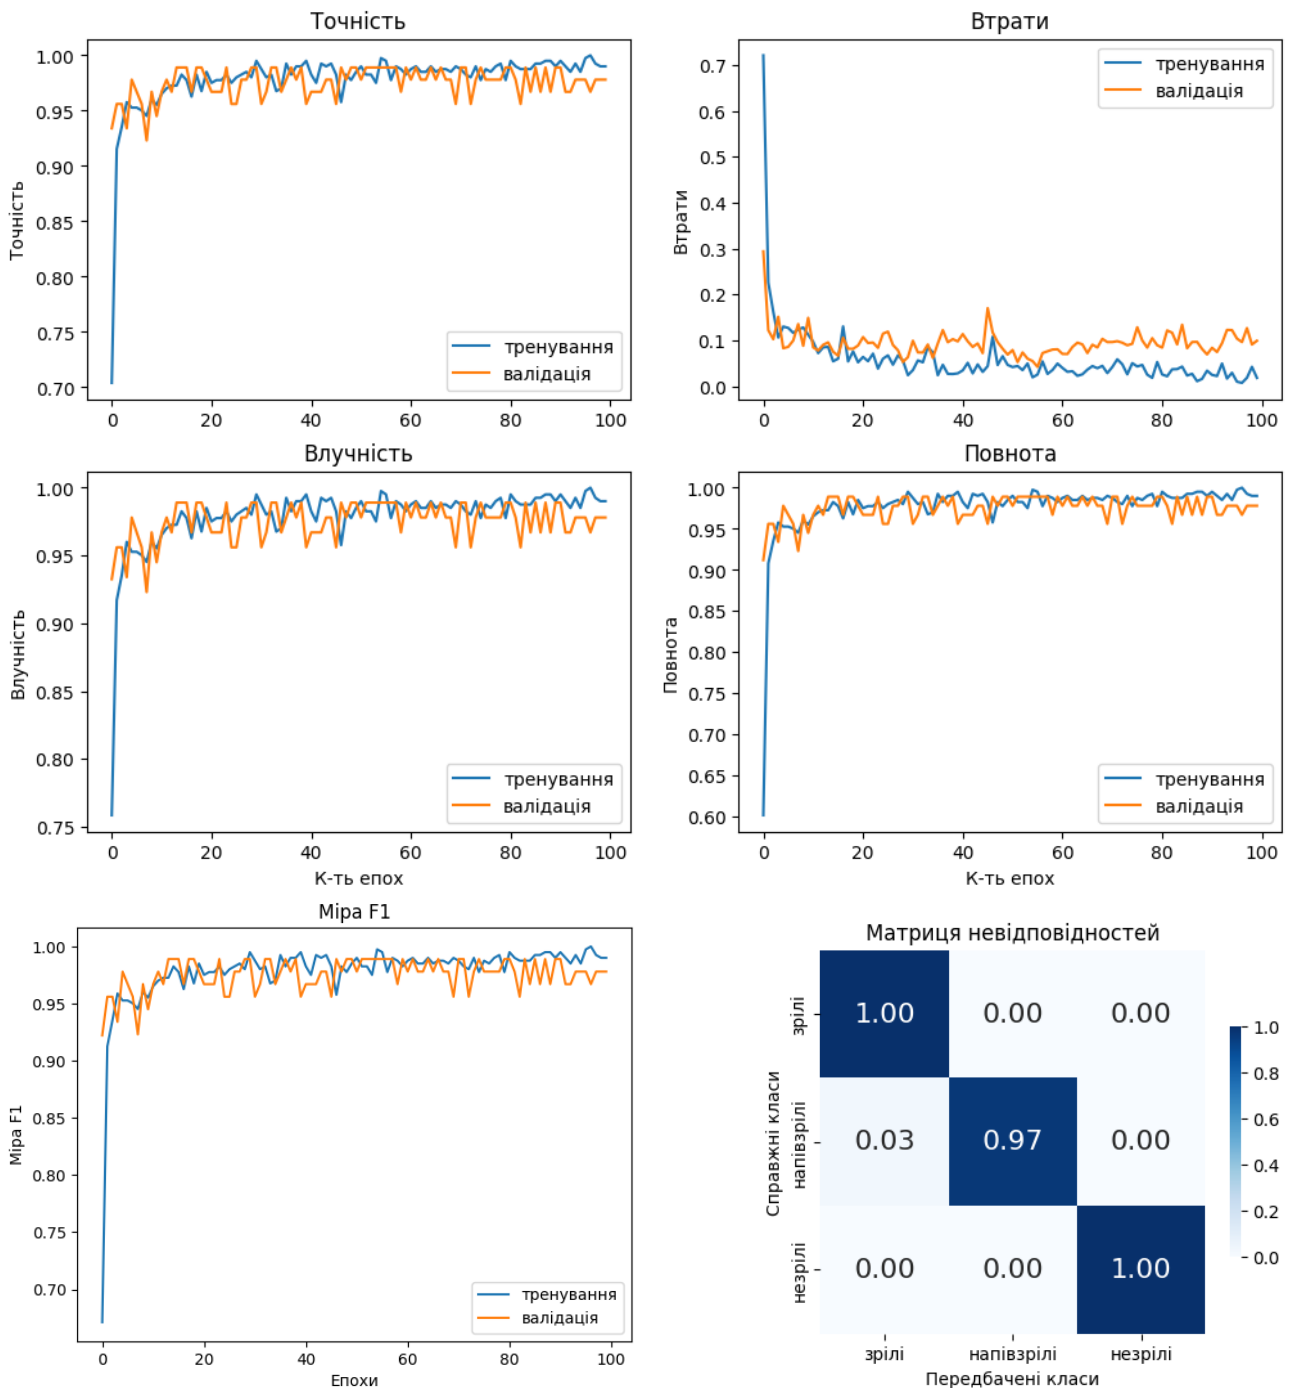


Рисунок 2 – Результати роботи моделі MobileNetV2

Неймережа MobileNetV3Small показала такі показники при навчанні: точність, влучність, повнота та F1-міра склали 98.42%, втрати 0.0288. При валідації точність, влучність, повнота та F1-міра склали 98.9%, втрати 0.0451. Саме навчання неймережі тривало 12 хв.

Як видно з графіків на рис. 3, показники при навчанні стабілізувалися в районі 50 епохи. Показники при валідації стабілізувалися приблизно на 20 епосі із незначними коливаннями в подальшому в межах 1-3%.

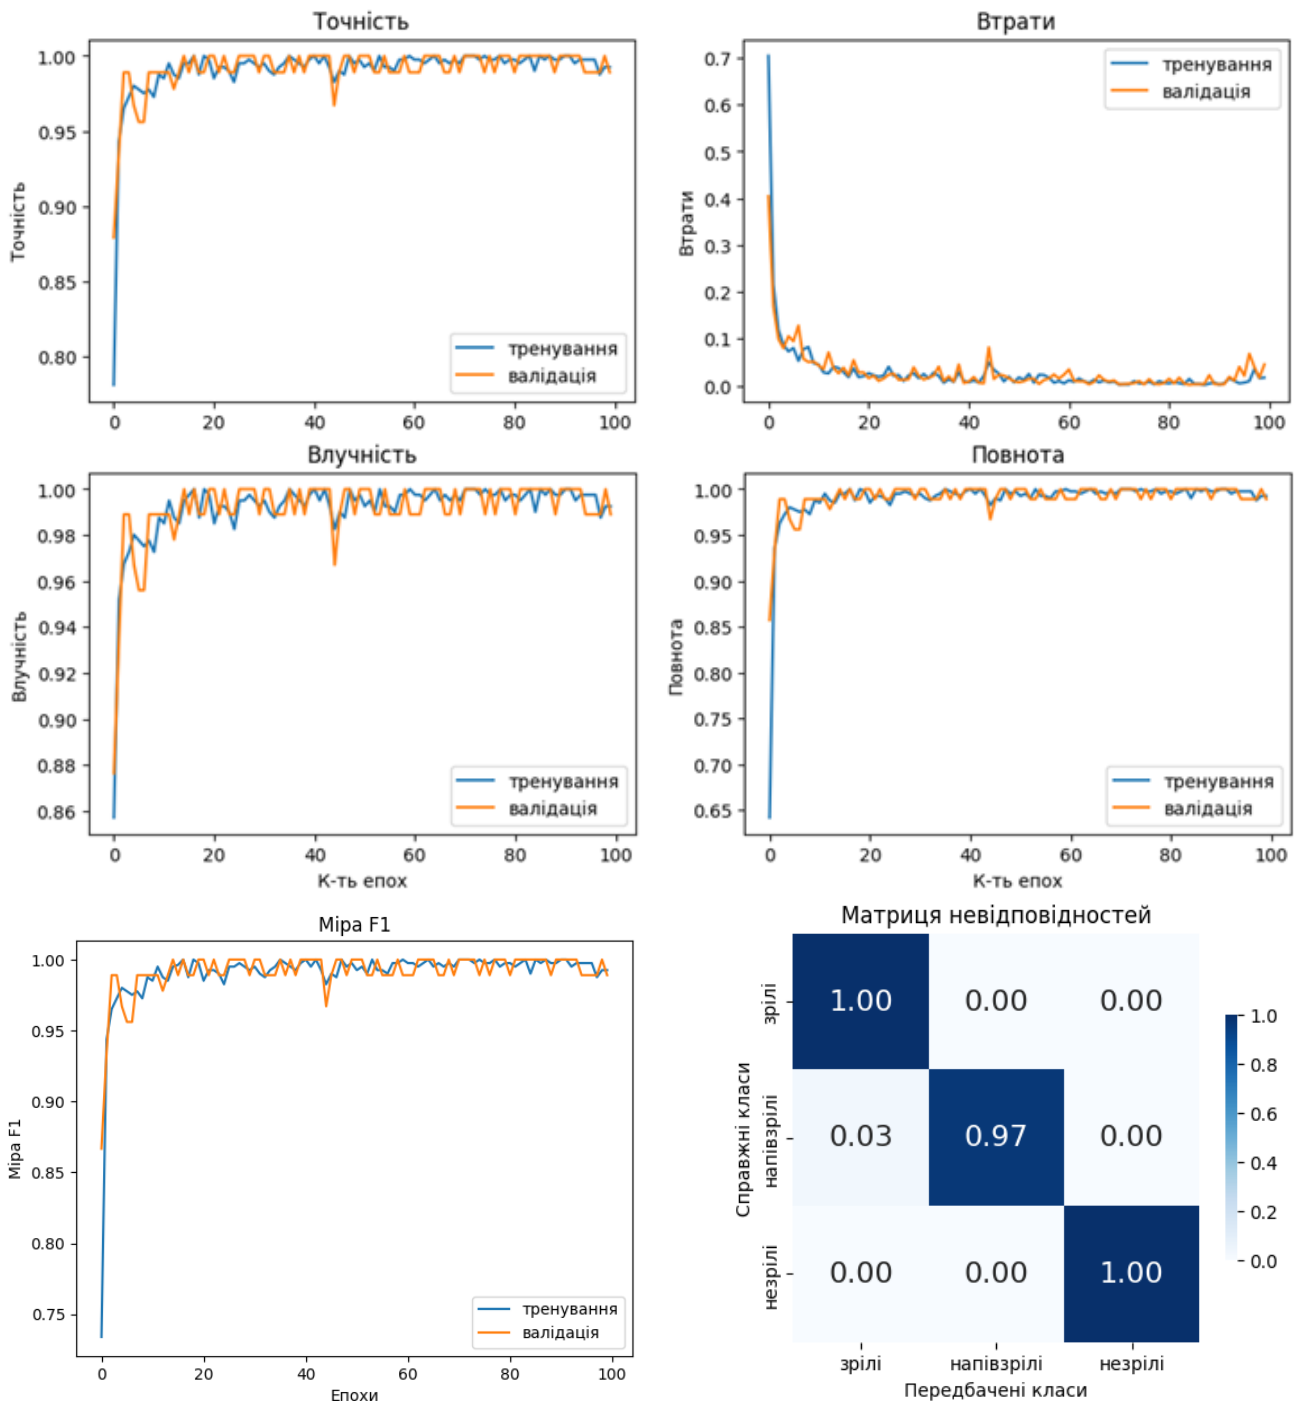


Рисунок 3 – Результати роботи моделі MobileNetV3Small

Неймережа EfficientNetB0 показала такі показники при навчанні: точність 99.33%, втрати 0.033, влучність 99.39%, повнота 99.39%, F1-міра 99.39%. При валідації точність складала 98.61%, втрати 0.04, влучність 98.61%, повнота 98.61%, F1-міра 98.61%. Саме навчання неймережі тривало 16 хв 17 с.

Як видно з графіків на рис. 4, показники при навчанні та валідації стабілізувалися в районі 15 епохи із подальшим коливанням у межах 1-2%.




Рисунок 4 – Результати роботи моделі EfficientNetB0

Висновки. В ході цього дослідження проведений порівняльний аналіз трьох архітектур нейронних мереж для визначення зрілості полуниці. При урахуванні всіх параметрів найефективнішою виявилася нейромережа MobileNetV3Small. Її точність, влучність, повнота та F1-міра при навчанні склали 98.42%, втрати 0.0288. При валідації точність, влучність, повнота та F1-міра склали 98.9%, втрати 0.0451. Навчання нейромережі тривало 12 хв.

Отримана модель має досить високу точність класифікації стадії зрілості полуниці і за своїми параметрами є однією із найоптимальніших при порівнянні із наведеними у статті

дослідженнями. При задіяних обчислювальних спроможностях, нейромережа також показала хороший час навчання за рахунок компактної архітектури та невеликої кількості шарів.

Враховуючи постійне впровадження сучасних технологій у сільське господарство, а також бурхливий розвиток штучного інтелекту, результати цього дослідження можуть стати корисними як для вітчизняних авторів, так і для певних підприємств агропромислового комплексу.

Список використаних джерел

1. Sady i Ogrody. (2024). Co czeka rynek truskawek? Produkcja do przetwórstwa staje się nieopłacalna [What awaits the strawberry market? Production for processing is becoming unprofitable]. https://www.sadyogrody.pl/owoce/101/co_czeka_rynek_truskawek_produkcja_do_przetworstwa_staje_sie_nieoplacalna,39056.html.
2. Wang, C., Wang, H., Han, Q., Zhang, Z., Kong, D., & Zou, X. (2024). Strawberry detection and ripeness classification using YOLOv8+ model and image processing method. *Agriculture*, 14(5), 751. <https://doi.org/10.3390/>.
3. Miraei Ashtiani, S.-H., Javanmardi, S., Jahanbanifard, M., Martynenko, A., & Verbeek, F. J. (2021). Detection of mulberry ripeness stages using deep learning models. *IEEE Access*, 9, 100380–100394. <https://doi.org/10.1109/ACCESS.2021.3096550>.
4. Al-Masawabe, M. M., Samhan, L. F., Al-Farra, A. H., Aslem, Y. E., & Abu-Naser, S. S. (2021). Papaya maturity classifications using deep convolutional neural networks. *International Journal of Academic Engineering Research*, 5(12), 22–29. <http://ijeais.org/wp-content/uploads/2021/12/IJEAIS211207.pdf>.
5. Pardede, J., Sitohang, B., Akbar, S., & Khodra, M. L. (2021). Implementation of transfer learning using VGG16 on fruit ripeness detection. *International Journal of Intelligent Systems and Applications*, 13(2), 34–43. <https://doi.org/10.5815/ijisa.2021.02.04>.
6. Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv*. <https://doi.org/10.48550/arXiv.1704.04861>.
7. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 4510–4520). <https://doi.org/10.1109/CVPR.2018.00474>.
8. Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., Vasudevan, V., Le, Q. V., & Adam, H. (2019). Searching for MobileNetV3. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 1314–1324). <https://doi.org/10.48550/arXiv.1905.02244>.
9. Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. In *Proceedings of the 36th International Conference on Machine Learning* (pp. 6105–6114). PMLR <https://doi.org/10.48550/arXiv.1905.11946>.
10. Zoph, B., & Le, Q. V. (2017). Neural architecture search with reinforcement learning. *arXiv*. <https://doi.org/10.48550/arXiv.1611.01578>.
11. Hu, J., Shen, L., & Sun, G. (2018). Squeeze-and-excitation networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 7132–7141). <https://doi.org/10.48550/arXiv.1709.01507>.
12. Ramachandran, P., Zoph, B., & Le, Q. V. (2017). Searching for activation functions. *arXiv*. <https://doi.org/10.48550/arXiv.1710.05941>.

Kachmarskyi Oleksa

*Assistant at the Department of Computer Science,
National University of Life and Environmental Sciences of Ukraine*

ORCID: <https://orcid.org/0009-0001-0241-5678>

E-mail: olesprof@gmail.com

DETERMINING THE STAGES OF STRAWBERRY MATURITY USING CONVOLUTIONAL NEURAL NETWORK MODELS

Abstract. Throughout the history of agriculture, crop cultivation and harvesting technologies have been constantly improving, easing the work in the field and increasing the efficiency of fruit harvesting. Today, modern technologies, including artificial intelligence, are also penetrating the agro-industrial sector. Its use is becoming increasingly widespread every year. This technology allows agricultural producers to obtain large amounts of data in real-time, analyze them, and make decisions regarding fertilizer application, pesticide use, irrigation, and determining the ripeness of fruits or plants. An equally important aspect of artificial intelligence solutions is the tracking of carbon footprints, which gives an advantage when entering European markets. The combination of the latest developments in unmanned vehicles and robots allows for an increase in productivity and production volumes in agriculture. An important part of modern agro-industry is computer vision — one of the fields of artificial intelligence, focused on creating intelligent systems capable of processing and analyzing visual information in a way similar to the human sensory system. Neural networks are often used in this technology for both image recognition and classification. This article presents a comparative analysis of various convolutional neural network models for classifying the ripeness stage of strawberries, namely MobileNetV2, MobileNetV3Small, and EfficientNetB0. The network was evaluated based on parameters such as training and validation accuracy, training and validation losses, and training time. The best results were found with the MobileNetV3Small network. The results and methodology of this research can be useful for both scientists and entrepreneurs working in the agro-industrial sector and implementing artificial intelligence in the production process.

Keywords: artificial intelligence, machine/computer vision, convolutional neural network (CNN), MobileNet, EfficientNet.