

Роман Гуменюк¹, Іван Попович²

¹ Кафедра систем автоматизованого проектування, Національний університет “Львівська політехніка”, вул. С. Бандери 12, Львів, Україна, E-mail roman.v.humeniuk@lpnu.ua, ORCID 0009-0000-8649-829X

² Кафедра систем автоматизованого проектування, Національний університет “Львівська політехніка”, вул. С. Бандери 12, Львів, Україна, E-mail: popovych.i.p@gmail.com

ДОСЛІДЖЕННЯ МЕТОДІВ ДІАГНОСТИКИ ЗАХВОРЮВАНЬ РОСЛИН ЗА ДОПОМОГОЮ ГЛИБОКОГО НАВЧАННЯ

Отримано: березень 08, 2024 / Переглянуто: квітень 01, 2024 / Прийнято: квітень 05, 2024

© Гуменюк Р., Попович І., 2024

<https://doi.org/>

Анотація. У статті досліджується використання згорткових нейронних мереж (CNN) у процесі діагностики та ідентифікації хвороб та шкідників рослин. Розглянуто різні методи діагностики хвороб рослин, особливості наборів даних, а також проблеми, що існують у даному напрямку досліджень. У статті обговорюється п'ятикрокова методологія для визначення хвороб рослин, включаючи збір даних, попередню обробку, сегментацію, виділення ознак та класифікацію. Досліджуються різні архітектури глибокого навчання, які дозволяють здійснювати швидку та ефективну діагностику хвороб рослин. Виокремлюються інноваційні тенденції та проблеми у даному напрямку, що потребують подальшого дослідження та уваги від наукової спільноти.

Ключові слова: глибоке навчання, ідентифікація рослин, діагностика хвороб рослин, розпізнавання хвороб рослин, згорткові нейронні мережі, CNN, класифікація ознак хвороб рослин.

Вступ

Рослини відіграють важливу роль у підтримці життя на Землі, забезпечуючи кисень, їжу та екологічний баланс, що робить сільське господарство важливим для економічного розвитку. Однак такі фактори, як шкідники та хвороби, створюють загрозу для рослинництва, підкреслюючи необхідність ефективного контролю хвороб [1]. Листя, стебла, коріння, плоди та квіти є ключовими органами рослин, причому листя служать життєво важливими індикаторами здоров'я рослин і часто використовуються для класифікації та ідентифікації [2]. Хвороби рослин, що порушують нормальний ріст, вимагають точної діагностики для ефективного моніторингу систем землеробства.

Постановка проблеми

Традиційні методи розпізнавання захворювань покладаються на візуальні спостереження розпізнають симптоми хвороб рослин традиційними способами, наприклад, спостерігаючи неозброєним оком і звертаючись до інформації в книгах та Інтернеті. Крім того, для класифікації та виявлення різних типів захворювань застосовуються мікроскопи і підходи на основі секвенування ДНК. Однак такі методи вимагають досвідчених експертів у сільському господарстві, і у багатьох фермерів немає змоги використовувати передові інструменти, проте більшість із них мають смартфон для зйомки зображень. Технологічний прогрес пропонує потенційні рішення для автоматизованого виявлення захворювань [3]. Алгоритми обробки зображень і глибокого навчання стали багатообіцяючими інструментами для ефективної та точної ідентифікації захворювань рослин [4]. Глибоке навчання, підгрупа машинного навчання, пропонує складні моделі для виявлення хвороб, і тривають дослідження, зосереджені на покращенні продуктивності розпізнавання різноманітних видів рослин [5]. У цій роботі представлений комплексний огляд існуючої літератури

та методологій глибокого навчання для автоматизованого розпізнавання хвороб рослин, що охоплює збір даних, попередню обробку, сегментацію, вилучення ознак і методи класифікації. Крім того, у ньому обговорюються дослідницькі проблеми в цій галузі, спрямовані на покращення розуміння та інновації в автоматизованій діагностиці хвороб рослин.

Огляд сучасних джерел інформації за тематикою публікації

У сільському господарстві використовується багато підходів для автоматичного розпізнавання хвороб рослин у різних частинах рослин, таких як плід, корінь, стебло та лист. Загальна система виявлення та класифікації хвороб рослин із використанням обробки зображень включає п'ять різних етапів, а саме: збір даних, попередню обробку, сегментацію, виділення ознак і класифікацію [4]. На мал. 1 зображено цю п'ятиетапну процедуру.

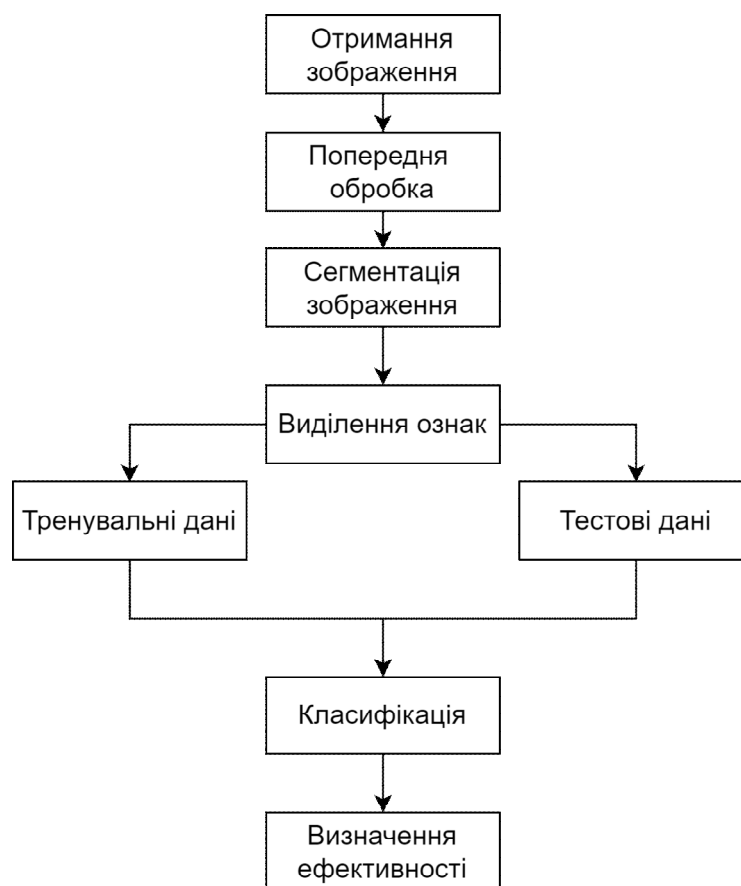


Рис. 1. Блок-схема процесу класифікації

1. Збір даних. Першим кроком у системі класифікації та виявлення захворювань рослин є отримання зображення. Для отримання зображень здорових і хворих рослин можна використовувати різноманітні пристрої, такі як цифрові камери та камери смартфонів.

2. Попередня обробка даних. Етап попередньої обробки в машинному або глибокому навчанні важливий для побудови ефективного набору даних для розвитку узагальнюваності моделі. У глибокому навчанні необхідно зібрати величезну кількість даних з різних джерел, таких як фізичні пристрої, програмне забезпечення, різні веб-сторінки та опитування. Під час збору даних на продуктивність моделі можуть вплинути апаратні збої, проблеми з програмним забезпеченням, шуми на зображеннях, людські помилки тощо. Попередня обробка даних може вирішити такі проблеми, як занадто великі дані, або нестача пам'яті для зберігання. Це також може допомогти візуалізувати та прискорити процес. Попередня обробка даних має важливий вплив на продуктивність керованої моделі машинного навчання. Вона може вирішувати кілька типів

проблем із даними за допомогою перетворення, очищення, нормалізації, вилучення ознак і вибору ознак перед подачею вхідних даних у модель глибокого навчання [6]. Видалення фонових шумів та придушення небажаних спотворень покращує деякі функції зображення та робить вхідні дані придатними для подальшої обробки [7]. Наприклад, щоб підвищити надійність своєї моделі, проводиться попередня обробка вхідних зображень, обрізаючи їх вручну, таким чином виділяючи цікаву область, створюючи квадрат навколо листа [8]. В іншому дослідженні змінено розмір зображення з 5760×3840 на зображення RGB 512×512 , щоб зменшити час виконання та розмір навчальних даних [10]. В іншій роботі попередньо обробили вхідні зображення, змінивши їх розмір до 128×128 пікселів, нормалізувавши значення пікселів до діапазону $[0,1]$ і збалансувавши різні класи [11]. У [12] інструменти Photoshop були використані для обробки зображень у модель RGB для обчислень, а потім розмір цих зображень зменшили до розміру 224×224 пікселів. У таблиці 1 наведено різні дослідження з використанням різних підходів до попередньої обробки зображень

Таблиця 1

Дослідження методів попередньої обробки, які застосовуються для ідентифікації рослин

Автори	Методи попередньої обробки
Amara, Bouaziz and Algergawy, 2017 [3]	Зображення змінено та перетворено в градації сірого
Lu, et al., 2017 [10]	Розмір зображень було зменшено, щоб зменшити час обробки та розміри моделі
Sladojevic, et al., 2016 [8]	Обрізування зображень вручну та виділення квадратом області навколо листа
Ashqar, Abu-Nasser and Abu-Naser, 2019 [11]	Зміна розміру, нормалізація та балансування різних класів зображень
Chen, et al., 2020 [12]	Використання Photoshop для однакової обробки зображень і зміни розміру
Nagashubramanian, et al., 2019 [9]	RGB зображення, перетворені на HSV

3. Сегментація даних. Методи комп'ютерного зору та розпізнавання образів потребують інтелектуальної сегментації для розпізнавання вмісту зображення та полегшення аналізу зображення. Процес сегментації зображення ділить візуальний вхід на фрагменти, які позначаються як сутності або частини сутностей і містять набір пікселів. Сегментація аналізує дані зображення, щоб визначити межі в зображеннях, спростити ілюстрації зображення та витягти значущу інформацію для подальшої обробки. Вона відіграє важливу роль у розпізнаванні та класифікації різних хвороб рослин. Моделі глибокого навчання зазвичай можна застосовувати безпосередньо до зображень, щоб усунути процес сегментації. Було проведено кілька досліджень автоматичної сегментації з використанням різних методів. Наприклад, Барбеде зрозумів, що сегментація зображення може бути корисною для виділення регіону, де розташовані симптоми. Було встановлено, що точність, отримана згортковою нейронною мережею (CNN), навченою з локалізованими областями ураження симптомів (87%), вища, ніж вихідне зображення (76%) [14]. Крім того, порогову метрику сегментації можна використовувати для діапазонів хвиль RGB гіперспектрального зображення стебла ураженого попелястою гниллю [9]. Автори [13] сегментували зображення на окремі плями та ураження, що збільшило кількість зображень і різноманітність даних, а також зробило можливим розпізнати численні захворювання на одному листі, де розглядалися окремі симптоми. Було досягнуто приблизно 12% точності, що більше, ніж у випадку використання необроблених зображень. У іншому дослідженні було сегментовано листя, щоб видалити непотрібну інформацію [15]. Вони обрали метод, заснований на наборі масок, створених шляхом вивчення кольорів, складових насиченості та освітленості серії частин зображення. Вони показали, що сегментовані зображення працюють краще, ніж зображення у градаціях сірого, але гірше, ніж кольорові. Таблиця II підсумовує різні процеси сегментації.

Узагальнення різних процесів сегментації та переваги

Автори	Процес сегментації	Переваги
Nagasubramanian, et al., 2019 [9]	Порогова метрика сегментації, що використовується для діапазонів хвиль RGB	Використовується для хвиль RGB гіперспектрального зображення стебла ураженого попелястою гниллю
Barbedo, 2018 [14]	Сегментація симптомів, яка використовується для локалізації області симптомів	Точність, отримана з локалізованими областями ураження симптомів, вища, ніж оригінальне зображення
Arnal Barbedo, 2019 [13]	Окремі плями та пошкодження були сегментовані на зображеннях	Збільшується кількість зображень і різноманітність даних, і стає можливим розпізнавання численних захворювань на одному листку
Mohanty, Hughes and Salathé, 2016 [15]	Уся додаткова фонові інформація видаляється з листя на основі набору масок, створених шляхом вивчення компонентів кольору, насиченості та освітленості.	Краща продуктивність, ніж використання зображень у відтінках сірого, і меншу, ніж кольорові зображення

4. Виділення ознак. У розпізнаванні образів особливу роль відіграють ознаки зображення, які є частиною об'єкта на зображенні для його ідентифікації. Ознаки описують різні властивості зображення, такі як кути, краї, області точок та гребені. Для розпізнавання хвороб рослин колір, форма та текстура використовується як характерні ознаки для розрізнення рослини (передній план) та інших непов'язаних об'єктів (фон). Ознака текстури зображення визначає, як розміщені кольори на зображенні. Ознака кольору зображення використовується, щоб відрізнити одне захворювання від іншого. Крім того, для розрізнення хвороб можна використовувати особливості проявів захворювань: таких як площа, вісь чи кут [4]. Зазвичай набори даних машинного навчання включають дуже великі або багатовимірні дані, які можуть містити корельовані функції, які можуть вводити в оману або бути надлишковими, що збільшує розмір простору та ускладнює обробку даних. Зменшення розмірності – це техніка, яка може зменшити розмірність набору ознак. Застосування зменшення розмірності може представити дані за допомогою зменшеної групи ознак [16]. У той час як традиційні підходи до розпізнавання образів використовують вручну створені ознаки, глибоке навчання автоматично адаптує ознаки з кращим та сучасним способом з великого набору даних [17]. Методи глибокого навчання класифікуються як група алгоритмів машинного навчання, де вхідні шари в відображаються на вихідні [15]. Такі методи включають різні шари нелінійних блоків обробки для вилучення та адаптації ознак. Усі послідовні шари використовують вихідні дані попереднього шару як вхід [5]. У згорткових нейронних мережах процес зменшення розмірності та процес класифікації об'єднані в одній моделі. Згорткові нейронні мережі використовують кілька етапів видобування ознак та уникнуть складної процедури видобування ознак, щоб навчитися специфічним для задачі ознакам більш ефективно. Методи зменшення розмірності можна загалом розділити на два типи, а саме: видобування ознак та відбір ознак [17]. У машинному навчанні вилучення ознак є важливою технікою для перетворення вхідного зображення в набір ознак [16] і для зменшення розмірності простору [17]. Вилучення ознак може зменшити кількість ознак, необхідних для визначення величезного вхідного набору даних [16] і видалення менш значущих даних. Це впливає на точність алгоритму навчання для обробки даних за найменший [17].

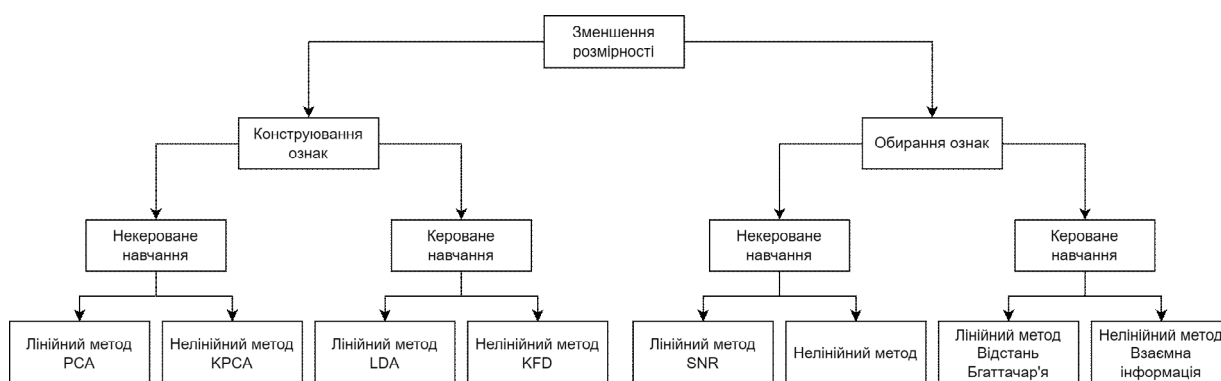


Рис. 2. Методи зниження розмірності

Другий тип техніки зменшення розмірності – це відбір ознак, який спрямований на пошук найкращих ознак серед усіх отриманих ознак. Він обирає найважливіші та найбажаніші ознаки серед усіх ознак зі стартового набору даних. Ці ознаки можуть надавати релевантну інформацію про дані та дозволяти точну передбачуваність на етапі виведення [16]. CNN – це набір функцій нелінійного перетворення, який може автоматично вивчати представлення з даних, щоб використовувати численні кроки вилучення ознак [18]. Це особливий тип прямої нейронної мережі (інформація передається від шару до шару без реверсування) [19] і який брав за основу біологічні процеси, які відбуваються в органах зору живих істот. У 1980-х роках CNN спочатку були запропоновані для розпізнавання цифр [20]. Нещодавно архітектури глибокого навчання на основі CNN дозволили виконувати масштабні завдання розпізнавання об'єктів. CNN здатні виділяти характеристики ієрархічно та класифікувати їх [18]. CNN має кілька рівнів, які ієрархічно обчислюють характеристики із зображень як вхідних даних. Глибокі згорткові нейронні мережі вперше були використані для класифікації великомасштабних зображень і продемонстрували надзвичайну ефективність. Архітектура CNN складається із шарів згортки, шару пулінгу, шару активації функцій, шарів випадкового вибору та повністю з'єданого шару в кінці. Згортковий шар і шар пулінгу рівні діють як екстрактори ознак [3]. Згортковий рівень зберігає результати згортки фільтрів або ядер попереднього шару [21]. Ці фільтри або ядра, що підлягають навчанню, містять ваги та зсуви; всі фільтри обмежені просторово, але розширюються зі збільшенням глибини вхідного обсягу [16]. Крім того, шари згортки створюють карту ознак, витягуючи особливості вхідного зображення за допомогою фільтра або ядра [22]. Ядро (вікно) ковзає по всьому зображенню крок за кроком. Результат береться з підсумовування по всьому зображенню [19]. Різні карти ознак створюються на основі кількох згорткових шарів і різних фільтрів, щоб забезпечити повне виділення різноманітних об'єктів. Функція активації відіграє значну роль у процесі навчання, і, таким чином, вибір належної функції активації вплине на динаміку навчання та виконання завдань [23]. Різні функції активації використовувалися для впровадження нелінійної комбінації функцій і для збільшення нелінійності мережі. Найбільш часто використовуваною функцією є ReLU, яка є кусково-лінійною функцією, у якій усі негативні значення пікселів замінюються нулем, тоді як позитивні значення пікселів зберігаються [24]. Шар пулінгу працює незалежно по всій глибині вхідного обсягу для масштабування його. Отже, матриця ознак зменшується [16]. Шар пулінгу має велике значення після функції активації для отримання потужної ознаки проти шуму та спотворення [25]. Він використовується для зменшення кількості зв'язків між згортковими шарами, зменшення розміру вибірки та зменшення розмірності відображення ознак [22], зменшення розміру нейрона та зменшення перенавчання [21]. До популярних методів пулінгу входять максимальний, середній, змішаний та стохастичний пулінг. Шари випадкового вибору використовуються для уникнення перенавчання, яке випадково вимикає нейрони в мережі [21].

5. Класифікація. Як правило, класифікація виконується за допомогою повністю з'єданого шару з функцією активації softmax, у якій комп'ютерна програма використовує вивчені ознаки з вхідних даних, щоб класифікувати їх у попередньо визначені класи [3] і використовує різні колекції ознак [16]. У галузі сільського господарства для дослідження хвороб рослин використовується багато методів класифікації. Традиційні методи машинного навчання широко застосовуються в сільськогосподарській сфері. Крім того, методи DCNN були застосовані для ідентифікації об'єктів і категоризації хвороб рослин і продемонстрували значний розвиток за останні роки. У поточні роки глибоке навчання широко розглядалося для завдань комп'ютерного зору, і таким чином було розроблено величезну кількість пов'язаних методів. Хоча доведено, що він ефективний у різних проблемах класифікації та виявлення, виділити невідомі об'єкти дуже складно через різну форму та положення об'єктів [26]. Наприклад, модель LeNet як CNN використовувалася в [3] для класифікації двох хвороб бананового листа, а саме, бананової плями та сигатоки. Також була розроблена нова глибока архітектура CNN для точної класифікації чотирьох різних типів хвороб яблунь, таких як мозаїка, іржа, бура плямистість і альтернативна плямистість листа [27]. Вони використали набір даних із 13 689 зображень нездорового листа яблуні та отримали загальну точність 97,62%. Автори розробили інноваційний метод ідентифікації на основі CNN для класифікації десяти поширених хвороб рису. Використовуючи цю модель, вони досягли точності 95,48% на наборі даних, що включає 500 зображень нездорових і здорових листків і стебел рису [10]. Автори [11] вибрали підхід CNN (на основі ConvNet) для класифікації саджанців рослин із набором даних, що містить приблизно 5000 зображень, що належать до 12 різних видів. Трансферне навчання – це процес повторного використання попередньо навченої моделі для розв'язання нової проблеми, яка відрізняється від початкової, що передбачає вивчення або навчання даних із базових. Наприклад, автори [12] вивчали перенесення навчання глибокого CNN для класифікації хворого листа. Вони обрали VGGNet і початкові моделі для покращення здатності до навчання невеликих ознак ураження. Автори дослідження [13] використовували попередньо підготовлену CNN, яка використовувала архітектуру GoogLeNet для вивчення використання окремих плям і уражень замість використання цілих листків і класифікації різних інфекцій рослин. Вони дійшли до висновку, що точність, досягнута з окремих уражень і плям, становить 94%. У іншому дослідженні [15] автори зосередилися на двох відомих глибоких моделях CNN, а саме AlexNet і GoogLeNet, навчених з нуля та перенавчання на зображеннях нездорових та здорових листків, щоб класифікувати 14 класів культур і 26 хвороб. Вони відзначили, що GoogLeNet надійно виконує кращу класифікацію на основі тренувального перенесення навчання на зображеннях нездорових і здорових листків і досягла точності 99,35. Крім того, у іншому дослідженні було вдосконалено техніку під назвою контрольований 3D-CNN для вивчення спектральної та просторової інформації гіперспектральних зображень здорового листа та прикладів категоризації хвороб вугільної гнилі в стеблах сої. Вони пояснили значення конкретних гіперспектральних довжин хвиль у категоризації за допомогою техніки візуалізації на основі карти помітності та отримали точність класифікації 95,73% [9]. Найсучасніша модель CNN із нуля, запропонована в [28] для діагностики здорового листка та п'яти хвороб листа огірка. Було проведено порівняльні експерименти на основі застосування попередньо навчених моделей (AlexNet, Inception-V3 і ResNet-50), щоб підтвердити автентичність запропонованого CNN.

Загалом класифікації хвороб рослин присвячено більшість досліджень у наявній літературі. Однак ідентифікація хвороб рослин (як локалізація, так і класифікація) є складним завданням. Деякі методи глибокого навчання були розроблені саме для виявлення хвороб рослин. Метаархітектури глибокого навчання, такі як Faster Region-based CNN (Faster R-CNN), Region-based Fully Convolutional Network (R-FCN) і Single Shot Multibox Detector (SSD), використовувалися як детектор для категоризації та локалізації хвороби листа рослин [2], і вони були використані в [32] для виявлення хвороб і шкідників томатів з відповідною ефективністю. В іншому дослідженні [21] використовувалися моделі AlexNet і SqueezeNet для виявлення хвороб помідорів із зображень листа і виявилось, що перша дає точніші результати, ніж друга. В іншому дослідженні було використано

Дослідження методів діагностики захворювань рослин за допомогою...

інноваційну техніку на основі глибокої CNN для автоматичного виявлення хвороб рослин і класифіковано 13 різних видів хвороб рослин із зображень здорового листа за допомогою архітектури CaffeNet CNN. Автори досягли середньої точності 96,3% [8]. Крім того, у іншому дослідженні було запропоновано метод виявлення захворювань рослин на основі ймовірнісного програмування з використанням байєсівських процедур глибокого навчання [29]. У іншій статті було використано п'ять моделей CNN, а саме AlexNet, AlexNetOWTBn, GoogLeNet, Overfeat і VGG для виявлення захворювань рослин за допомогою зображень здорових і нездорових листків. Результатом було те, що VGG є успішною моделлю з показником успішності 99,53% на тестовому наборі даних, що містить 17 548 зображень [30]. В іншому дослідженні [31] було застосоване перенесення навчання для навчання глибокого CNN Inception v3 для виявлення трьох хвороб маніоки та двох видів пошкодження шкідниками.

Таблиця 3

Узагальнення різних досліджень з класифікації хвороб рослин

Автори	Методи	Набір даних	Точність
Saleem, et al., 2020 [2]	Faster R-CNN, R-FCN with ResNet , and SSD with Inception	PlantVillage	73.07%
Amara, Bouaziz and Algergawy, 2017 [3]	LeNet	PlantVillage (2 види захворювань бананів)	97.57%
Lu, et al., 2017 [10]	CNN	Хвороби рису (10 поширених хвороб)	95.48%
Sladojevic, et al., 2016 [8]	CNN (CaffeNet)	PlantVillage (13 різних хвороб)	96.3%
Ashqar, Abu-Nasser and Abu-Naser, 2019 [11]	CNN (ConvNet)	Набір для висадки рослин	99.48%
Chen, et al., 2020 [12]	VGGNet and Inception	Зображення рису	92.00%
Nagasubramanian, et al., 2019 [9]	Supervised 3D-CNN	Із зразків стебла сої відібрано 4 генотипи	95.73%
Barbedo, 2018 [14]	CNN (GoogLeNet)	Загальнодоступний набір фото з 50 тис. рослин	94%. від окремих пошкоджень і плям
Mohanty, Hughes and Salathé, 2016 [15]	AlexNet and GoogLeNet	PlantVillage	99.35% з GoogLeNet
Durmus, Gunes and Kirci, 2017 [21]	AlexNet and SqueezeNet	PlantVillage (фото листя помідорів)	95.65% з AlexNet
Liu, et al., 2017 [27]	CNN (Goo- gLeNet)	Фото яблунь (4 поширені типи хвороб яблунь)	97.62%
Fuentes, et al., 2017 [32]	Faster R-CNN, R-FCN, and SSD with ResNet	PlantVillage (фото листя помідорів)	88.20% від RFCN з ResNet 50
Ferentinos, 2018 [30]	AlexNet, Overfeat, AlexNetOWTBn, GoogLeNet, and VGG	Загальнодоступний набір фото з 87 тис. рослин	99.53% з VGG

6. Набори даних. У попередніх дослідженнях для класифікації хвороб рослин і завдань виявлення використовувалися різні набори даних. Деякі з цих наборів даних – це набір даних PlantVillage, який містить здорові та хворі зображення п'яти культур, а саме яблуні [27], кукурудзи, винограду, картоплі та помідорів [24]. Крім того, автори дослідження [31] використовували набір даних про хворобу маніоки, тоді як автори дослідження [2] використовували набір даних ImageNet. Автори дослідження [3] використовували реальний набір даних про хворобу бананів, в якому вони

були отримані з набору даних PlantVillage. Для реалізації алгоритмів глибокого навчання [2], потрібно кілька кроків, які починаються від збору даних до відображення візуалізації. З цього розділу ми можемо зробити висновок, що, незважаючи на те, що деякі моделі глибокого навчання були розроблені для класифікації зображень у застосуванні діагностики та виявлення хвороб рослин, це все ще є плідною областю досліджень і має призвести до покращень для кращого розпізнавання хвороб рослин у різні ситуації, наприклад різні умови освітлення та врахування реального фону. Було також зроблено висновок, що лист є найбільш часто використовуваною частиною рослини для класифікації хвороб рослин, оскільки його зображення можна легко зібрати, він зелений і гладкий протягом більшості пір року. Інший висновок полягає в тому, що він показує, що набір даних PlantVillage використовувався в більшості досліджень. Він включає простий фон та кілька фотографій різних видів рослин з їх хворобами. Проте для реалістичного сценарію потрібно врахувати фактичне середовище. Таблиця 3 підсумовує, що для класифікації хвороб листя рослин було використано кілька алгоритмів і наборів даних.

Цілі та проблеми дослідження

У сучасний час моделі глибокого навчання досягають високої продуктивності та обіцяючих результатів у різних галузях, таких як класифікація та виявлення зображень, розпізнавання мови та виявлення об'єктів. Такі моделі достатньо розвинені, щоб впоратися з складними завданнями. Останнім часом в глибокому навчанні були використані різні архітектурні моделі для отримання значної продуктивності та ефективності. Незважаючи на розвиток та вдосконалення, які були застосовані до моделей глибокого навчання в різних дослідженнях, особливо в класифікації та виявленні хвороб рослин, перед впровадженням різних архітектур глибокого навчання для визначення хвороб рослин все ще існують численні значні наукові прогалини та виклики, які потрібно вирішити. Наукові проблеми та виклики, які були визначені у цій статті, включають налаштування гіперпараметрів, перенавчання моделей, органи рослин, недоступність наборів даних хвороб рослин та різноманітність хвороб рослин.

1. Налаштування гіперпараметрів. Сучасні моделі автоматично вивчають особливості із зображень і класифікують на основі цих вивчених ознак. З іншого боку, традиційні моделі машинного навчання вручну виділяють ознаки і налаштовують їх, що може займати багато часу. Протягом тренування та тестування моделі використовується набір параметрів для процесу навчання, відомих як гіперпараметри. В різних архітектурах глибокого навчання використовується великий набір гіперпараметрів [33]. У кожному наборі даних налаштування гіперпараметрів має значний вплив на навчання моделі для отримання хорошої продуктивності [34]. Гіперпараметри включають параметри регуляризації, архітектури мережі, такі як кількість шарів та типи функцій переносу сигналу, кількість вибірок та швидкості навчання, попередню обробку, таку як зменшення розмірності та нормалізацію, та параметри ініціалізації ваги. Теоретично було розглянуто кілька методів, які використовують гіперприори та вручну використовують оптимізаційні техніки. Математична обробка деяких гіперпараметрів може бути великою проблемою [33]. У таких випадках налаштування гіперпараметрів архітектури глибокого навчання є проблемою, яку необхідно вирішити на основі емпіричних даних, використовуючи вдосконалення теоретичної бази та оцінки продуктивності мережі [35]. Наприклад, спрощена система або вдосконалена техніка вимагатиме менше гіперпараметрів. З іншого боку, складну систему можна автоматично налаштувати за допомогою алгоритмів оптимізації гіперпараметрів у певній програмі для досягнення оптимальної продуктивності [33]. Було запропоновано байєсівську техніку оптимізації гіперпараметрів для покращення продуктивності моделі, де оптимізуються всі значення гіперпараметрів [35].

2. Перенавчання моделі. Перенавчання – це проблема, з якою стикаються алгоритми машинного навчання, особливо моделі глибокого навчання, у яких помилки або випадковий шум виникають замість описаного в моделі основного взаємозв'язку [27]. Було показано, що перенавчання негативно впливає на надійну продуктивність навчального набору в кількох наборах

даних, таких як ImageNet, CIFAR-10, CIFAR-100 і SVHN [36]. Для уникнення перенавчання використовувалися операції розширення набору даних, такі як відображення відносно осей, обертання зображень, випадкові зміни PCA та коригування яскравості, щоб збільшити різноманітність тренувальних зображень та покращити загальність їх моделі [27]. У іншому дослідженні [36] вивчено методи збільшення та регуляризації даних, для усунення перенавчання. Їх експериментальне тестування показало, що методи регуляризації не обов'язково запобігають перенавчанню та мають тенденцію робити модель надмірно регуляризованою. Крім того, в іншому дослідженні [37] використовувалися два різні алгоритми аргументації, щоб запобігти перенавчанню, а саме традиційні методи збільшення, такі як попиксельні зміни або обертання, і навчання за допомогою генеративної змагальної мережі. Вони використовували локальну нормалізацію, отриману за допомогою шарів нормалізації відповіді, і використовували шари згортки замість деяких повністю пов'язаних шарів [27]. Крім того, іншим способом уникнення перенавчання за допомогою передачі навчання є виправлення останніх кількох шарів та заморожування першого шару [14]. У іншому дослідженні [15] було змінено співвідношення даних тренувальних і тестових наборів. Для зменшення перенавчання використовувалися два різні методи, такі як тренування мережевої моделі з використанням більшої кількості прикладів та зміна складності мережі, така як зміна структури та параметрів мережі [38]. У нейронній мережі відпадання означає тимчасове видалення одиниць із мережі разом із вихідними та вхідними з'єднаннями під час процесу навчання.

3. Частини рослин. Рослини мають різні частини, які використовувалися як характеристика для вивчення дослідниками в різних галузях, особливо для завдання розпізнавання та виявлення хвороб. Як було описано вище, більшість дослідників використовують саме зображення листків, з метою класифікації та виявлення хвороб рослин. Іноді замість цілого листка використовували окремі плями та пошкодження. Однак багато захворювань краще класифікувати за допомогою інших частин рослин, таких як стебло наприклад. Отже, необхідно створити повний набір даних зображень рослин, щоб включити зображення інших частин і краще класифікувати їх хвороби.

4. Проблеми, пов'язані зі створенням великих наборів даних. У глибокому навчанні потрібен великий набір різноманітних даних. Однак побудова такого набору даних включає в себе виклики. Види рослин, різноманіття хвороб, умови зйомки зображень та кількість зразків у кожному класі набору даних впливають на можливість розпізнавання та унеможливають більш широке застосування моделей глибокого навчання на практиці. Дослідники використовували різні набори даних у своїх дослідженнях для навчання моделей глибокого навчання. Наприклад, загальнодоступний набір даних PlantVillage часто використовується для оцінки точності та продуктивності, який містить багато різних зображень здорових та хворих рослин з простим фоном. Однак більшість дослідників використовували схожий архітектурний дизайн і отримували досить схожі результати своїх експериментів на цьому наборі даних. Хоча вони використовували кілька аспектів моделі для навчання та тестування системи для розпізнавання хвороб рослин, їм все ще не вдалося отримати достатньо нової інформації. Таким чином, нові тести слід розглядати разом з додатковими наборами даних. Деякі дослідники також створювали синтетичний набір даних. Однак ще багато проблем потрібно вирішити. Взагалі в галузі сільського господарства недостатньо наявних наборів даних для дослідників. З цією метою дослідники повинні вдосконалити та створити новий набір даних, який включає різні органи рослин та різні хвороби листя.

5. Проблеми хвороб рослин. Боротьба з хворобами та патологіями рослин стикаються з постійно зростаючими викликами. З одного боку, сільськогосподарська продуктивність зменшується через вичерпання природних ресурсів та зменшення обробних земель. З іншого боку, у зв'язку зі зростанням глобальної популяції зросли вимоги до високоякісної та різноманітної їжі. Крім того, еволюція та епідемії хвороб рослин в останні роки зросли в глобальному масштабі через інтенсифікацію та використання ресурсів, таких як вода, добрива та пестициди. Хвороби рослин та шкідники є головною причиною значних економічних збитків та зниження врожайності. У сфері технологічних досягнень теорії діагностики хвороб та шкідників рослин, такі як виявлення та

класифікація, розвивалися на основі симптомів та ознак хвороб. У майбутньому плани боротьби хворобами рослин, такі як точне визначення хвороб, є важливими і повинні бути наділені більшою увагою для соціального розвитку, забезпечення продовольства, глобалізації, зміни клімату та профілактики хвороб. У сфері розвитку патології рослин було розроблено деякі нові шляхи для специфічних і чутливих процедур діагностики рослин, які поєднуються з молекулярною біологією, біоінформатикою та біотехнологіями.

Висновки

У сільському господарстві хвороби та шкідники рослин впливають на втрати продуктивності харчового виробництва, якщо їм не приділяти достатньо уваги. Тому автоматизована система діагностики хвороб та виявлення шкідників рослин є необхідною, оскільки вона має багато переваг для людей у галузі сільського господарства, фармацевтичної промисловості тощо. Автоматизовані системи діагностики хвороб рослин поєднують знання експертів з фітопатології з можливістю вилучення симптоматичних ознак за допомогою алгоритмів CNN для ідентифікації та класифікації хвороб та шкідників рослин. Ця стаття є оглядом і узагальненням технік діагностики та виявлення хвороб рослин на основі глибокого CNN. Вона також висвітлює деякі проблеми та виклики, що стосуються класифікації хвороб, виявлення та характеристики наборів даних, через різноманітність проблем і специфічність реальних сценаріїв, які ускладнюють семантичну каталогізацію даних в репрезентативних наборах даних. Крім того, у цьому огляді досліджено деякі архітектури глибокого навчання, це все ще плідна область досліджень для дослідників з метою вирішення прогалин у різних сільськогосподарських галузях шляхом інтеграції обробки зображень та машинного навчання, особливо підходів на основі CNN.

Перелік використаних джерел

- [1] F. Fina, P. Birch, R. Young, J. Obu, B. Faithpraise, and C. Chatwin, "Automatic plant pest detection and recognition using k-means clustering algorithm and correspondence filters," *International Journal of Advanced Biotechnology and Research*, vol. 4, pp. 189-199, 2013.
- [2] M. H. Saleem, S. Khanchi, P. Potgieter, and K. M. Arif, "Image-based plant disease identification by deep learning meta-architectures," *Plants*, vol. 9, no. 11, pp. 1451, 2020. <https://doi.org/10.3390/plants9111451>
- [3] J. Amara, B. Bouaziz, and A. Algergawy, "A Deep Learning-based Approach for Banana Leaf Diseases Classification," 2017. Available at: <https://dl.gi.de/handle/20.500.12116/944>
- [4] K. P. Panigrahi, H. Das, A. K. Sahoo, and S. C. Moharana, "Maize leaf disease detection and classification using machine learning algorithms," in *Advances in Intelligent Systems and Computing*, Springer, Germany, 2020, pp. 659-669. https://doi.org/10.1007/978-981-15-2414-1_66
- [5] B. B. Benuwa, Y. Zhan, B. Ghansah, D. K. Wornyo, and F. B. Kataka, "A review of deep machine learning," *International Journal of Engineering Research in Africa*, vol. 24, pp. 124-136, 2016. <https://doi.org/10.4028/www.scientific.net/JERA.24.124>
- [6] S. B. Kotsiantis, D. Kanellopoulos, and P. E. Pintelas, "Data preprocessing for supervised learning," *International Journal of Computer Science*, vol. 1, pp. 111-117, 2006.
- [7] U. Shruthi, V. Nagaveni, and B. K. Raghavendra, "A Review on Machine Learning Classification Techniques for Plant Disease Detection," in *2019 5th International Conference on Advanced Computing and Communication Systems, ICACCS 2019*, Institute of Electrical and Electronics Engineers Inc., United States, 2019, pp. 281-284. <https://doi.org/10.1109/ICACCS.2019.8728415>
- [8] S. Sladojevic, M. Arsenovic, A. Anderla, D. Culibrk, and D. Stefanovic, "Deep neural networks based recognition of plant diseases by leaf image classification," *Computational Intelligence and Neuroscience*, vol. 2016, p. 3289801, 2016. <https://doi.org/10.1155/2016/3289801>
- [9] Nagasubramanian, K., Jones, S., Singh, A.K. et al. Plant disease identification using explainable 3D deep learning on hyperspectral images. *Plant Methods* 15, 98 (2019). <https://doi.org/10.1186/s13007-019-0479-8>
- [10] Y. Lu, S. Yi, N. Zeng, Y. Liu, and Y. Zhang, "Identification of rice diseases using deep convolutional neural networks," *Neurocomputing*, vol. 267, pp. 378-384, 2017. <https://doi.org/10.1016/j.neucom.2017.06.023>
- [11] B. A. M. Ashqar, B. S. Abu-Nasser, and S. S. Abu-Naser, "Plant Seedlings Classification Using Deep Learning," 2019.

- [12] J. Chen, J. Chen, D. Zhang, Y. Sun, and Y. A. Nanekarana, "Using deep transfer learning for image-based plant disease identification," *Computers and Electronics in Agriculture*, vol. 173, p. 105393, 2020. <https://doi.org/10.1016/j.compag.2020.105393>
- [13] J. G. Arnal Barbedo, "Plant disease identification from individual lesions and spots using deep learning," *Biosystems Engineering*, vol. 180, pp. 96-107, 2019. <https://doi.org/10.1016/j.biosystemseng.2019.02.002>
- [14] J. G. A. Barbedo, "Factors influencing the use of deep learning for plant disease recognition," *Biosystems Engineering*, vol. 172, pp. 84-91, 2018. <https://doi.org/10.1016/j.biosystemseng.2018.05.013>
- [15] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *Frontiers in Plant Science*, vol. 7, p. 1419, 2016. <https://doi.org/10.3389/fpls.2016.01419>
- [16] S. Dara and P. Tumma, "Feature Extraction by Using Deep Learning: A Survey," in *Proceedings of the 2nd International Conference on Electronics, Communication and Aerospace Technology, ICECA 2018*, Institute of Electrical and Electronics Engineers Inc., United States, 2018, pp. 1795-1801.
- [17] K. Karthikayani and A. R. Arunachalam, "A survey on deep learning feature extraction techniques," in *AIP Conference Proceedings*, American Institute of Physics Inc., College Park, Maryland, 2020. <https://doi.org/10.1063/5.0028564>
- [18] A. Khan, A. Sohail, U. Zahoor, and A. S. Qureshi, "A survey of the recent architectures of deep convolutional neural networks," *Artificial Intelligence Review*, vol. 53, no. 8, pp. 5455-5516, 2020. <https://doi.org/10.1007/s10462-020-09825-6>
- [19] A. Zbakh, Z. A. Mdaghri, A. Benyoussef, A. El Kenz, M. El Yadari, et al., "Spectral classification of a set of hyperspectral images using the convolutional neural network, in a single training," *International Journal of Advanced Computer Science and Applications (IJACSA)*, vol. 10, no. 6, 2019. <https://hal.science/hal-02172017> <https://doi.org/10.14569/IJACSA.2019.0100634>
- [20] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, and L. D. Jackel, "Backpropagation applied to handwritten zip code recognition," *Neural Computation*, vol. 1, no. 4, pp. 541-551, 1989. <https://doi.org/10.1162/neco.1989.1.4.541>
- [21] H. Durmus, E. O. Gunes, and M. Kirci, "Disease Detection on the Leaves of the Tomato Plants by Using Deep Learning," in *2017 6th International Conference on Agro-Geoinformatics, Agro-Geoinformatics 2017*, Institute of Electrical and Electronics Engineers Inc., United States, 2017. <https://doi.org/10.1109/Agro-Geoinformatics.2017.8047016>
- [22] Z. Ibrahim, N. Sabri, and D. Isa, "Multi-maxpooling Convolutional Neural Network for Medicinal Herb Leaf Recognition," in *Proceedings of the 6th IIAE International Conference on Intelligent Systems and Image Processing 2018*, The Institute of Industrial Applications Engineers, Japan, 2018. <https://doi.org/10.12792/icisip2018.060>
- [23] P. Ramachandran, B. Zoph, and Q. V. Le, "Searching for Activation Functions," in *6th International Conference on Learning Representations, ICLR 2018-Workshop Track Proceedings*, 2017. <http://arxiv.org/abs/1710.05941>
- [24] N. Fatihah Sahidan, A. K. Juha, N. Mohammad, and Z. Ibrahim, "Flower and leaf recognition for plant identification using convolutional neural network," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 16, no. 2, pp. 737-743, 2019. <https://doi.org/10.11591/ijeecs.v16.i2.pp737-743>
- [25] M. M. Saufi, M. A. Zamanhuri, N. Mohammad, and Z. Ibrahim, "Deep learning for roman handwritten character recognition," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 12, no. 2, pp. 455-460, 2018. <https://doi.org/10.11591/ijeecs.v12.i2.pp455-460>
- [26] D. Jiang, G. Li, Y. Sun, J. Hu, J. Yun, and Y. Liu, "Manipulator grabbing position detection with information fusion of color image and depth image using deep learning," *Journal of Ambient Intelligence and Humanized Computing*, vol. 12, no. 12, pp. 10809-10822, 2021. <https://doi.org/10.1007/s12652-020-02843-w>
- [27] B. Liu, Y. Zhang, D. He, and Y. Li, "Identification of apple leaf diseases based on deep convolutional neural networks," *Symmetry*, vol. 10, p. 11, 2017. <https://doi.org/10.3390/sym10010011>
- [28] S. M. Omer, K. Z. Ghafoor, and S. K. Askar, "An intelligent system for cucumber leaf disease diagnosis based on the tuned convolutional neural network algorithm," *Mobile Information Systems*, vol. 2022, p. 8909121, 2022. <https://doi.org/10.1155/2022/8909121>
- [29] S. Hernández and J. L. López, "Uncertainty quantification for plant disease detection using Bayesian deep learning," *Applied Soft Computing Journal*, vol. 96, p. 106597, 2020. <https://doi.org/10.1016/j.asoc.2020.106597>
- [30] K. P. Ferentinos, "Deep learning models for plant disease detection and diagnosis," *Computers and Electronics in Agriculture*, vol. 145, pp. 311-318, 2018. <https://doi.org/10.1016/j.compag.2018.01.009>
- [31] A. Ramcharan, K. Baranowski, P. McCloskey, B. Ahmed, J. Legg, and D. P. Hughes, "Deep learning for image-based cassava disease detection," *Frontiers in Plant Science*, vol. 8, p. 1852, 2017. <https://doi.org/10.3389/fpls.2017.01852>

- [32] A. Fuentes, S. Yoon, S. C. Kim, and D. S. Park, "A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition," *Sensors (Switzerland)*, vol. 17, no. 9, p. 2022, 2017. <https://doi.org/10.3390/s17092022>
- [33] F. Hutter, J. Lücke, and L. Schmidt-Thieme, "Beyond manual tuning of hyperparameters," *KI-Kunstliche Intelligenz*, vol. 29, no. 4, pp. 329-337, 2015. <https://doi.org/10.1007/s13218-015-0381-0>
- [34] A. H. Victoria and G. Maragatham, "Automatic tuning of hyperparameters using Bayesian optimization," *Evolving Systems*, vol. 12, no. 1, pp. 217-223, 2021. <https://doi.org/10.1007/s12530-020-09345-2>
- [35] P. Angelov and A. Sperduti, "Challenges in Deep Learning," 2016. Available from: <https://eprints.lancs.ac.uk/id/eprint/134273>
- [36] L. Rice, E. Wong, and J. Z. Kolter, "Overfitting in Adversarially Robust Deep Learning," in *Proceedings of Machine Learning Research*, 2020.
- [37] M. Arsenovic, M. Karanovic, S. Sladojevic, A. Anderla, and D. Stefanovic, "Solving current limitations of deep learning based approaches for plant disease detection," *Symmetry*, vol. 11, no. 7, p. 939, 2019.
- [38] J. Brownlee, "Better Deep Learning: Train Faster, Reduce Overfitting, and Make Better Predictions," 2018. <https://doi.org/10.3390/sym11070939>

Roman Humeniuk¹, Ivan Popovych²

¹Computer Aided Design Department, Lviv Polytechnic National University, Ukraine, Lviv, S. Bandery street 12, E-mail: roman.v.humeniuk@lpnu.ua, ORCID 0009-0000-8649-829X

²Computer Aided Design Department, Lviv Polytechnic National University, Ukraine, Lviv, S. Bandery street 12, E-mail: popovych.i.p@gmail.com

RESEARCH OF PLANT DISEASE DIAGNOSTIC METHODS USING DEEP LEARNING

Received: March 08, 2024 / Revised: April 01, 2024 / Accepted: April 05, 2024

© Humeniuk R., Popovych I., 2024

Abstract. The article explores the use of convolutional neural networks (CNNs) in the diagnosis and identification of plant diseases and pests. Various methods of plant disease diagnosis, features of datasets, and challenges in this research direction are considered. The article discusses a five-step methodology for determining plant diseases, including data collection, preprocessing, segmentation, feature extraction, and classification. Different deep learning architectures enabling fast and efficient plant disease diagnosis are investigated. Innovative trends and issues in this field requiring further research and attention from the scientific community are highlighted

Keywords: deep learning, plant identification, plant disease diagnosis, plant disease recognition, convolutional neural networks, CNN, plant disease symptom classification.