

Афонін А. О., Кундік К. В.

ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ У РОЗПІЗНАВАННІ ХВОРОБ РОСЛИН

У статті описано розроблену модель нейронної мережі, що дає змогу розпізнавати хвороби рослин за зображенням їхнього листа. Модель має високу точність і швидкий час передбачення. Детально висвітлено проведені дослідження сучасних архітектур моделей глибокого навчання з акцентом на досягнення найвищої точності та найменшої помилки при вирішенні задачі класифікації зображень. Продемонстровано ефективність запропонованих рішень на прикладі створення автоматизованої системи розпізнавання хвороб сільськогосподарських рослин.

Ключові слова: машинне навчання, класифікація зображень, комп'ютерний зір, глибоке навчання, Tensorflow, хвороби сільськогосподарських рослин.

Вступ

Глибоке навчання розв'язує центральну проблему в репрезентативному навчанні шляхом введення особливостей, які виражаються в термінах інших, простіших особливостей. Глибоке навчання дає змогу комп'ютеру будувати складні концепції, поєднуючи більш прості поняття, такі як кути, тіні та контури, які, своєю чергою, визначаються з точки зору різних країв.

Основним прикладом моделі глибокого навчання є глибока мережа прямого пересилання, або багат шаровий перцептрон (MLP). Багат шаровий перцептрон – це просто математична функція, що відображає деякий набір вхідних значень у вихідні. Функція формується шляхом складання багатьох простих функцій. Можна вважати, що кожне застосування різних математичних функцій – це нове представлення вхідних даних.

Ідея вивчення правильного подання даних дає один погляд на глибоке навчання. Інший погляд на глибоке навчання полягає в тому, що глибина дає комп'ютеру змогу вивчати багаторівневу комп'ютерну програму. Кожен шар представлення можна сприймати як стан пам'яті комп'ютера після паралельного виконання іншого набору інструкцій. Мережі з більшою глибиною можуть виконувати більше інструкцій послідовно. Послідовні інструкції надають велику потужність, оскільки пізніші інструкції можуть посилалися на результати попередніх. Згідно з цим поглядом на глибоке навчання, не вся інформація в активаціях шару обов'язково кодує фактори варіації, що пояснюють вхідні дані. Представлення також зберігає інформацію про

стан, яка допомагає виконати програму, що може зрозуміти введені дані. Ця інформація про стан може бути аналогом лічильника або покажчика в традиційній комп'ютерній програмі. Це не має нічого спільного із змістом введення, зокрема, але допомагає моделі організувати його оброблення.

Згідно з дослідженнями Продовольчої та сільськогосподарської організації ООН (ФАО), кожного року близько 40 % світового врожаю хворіє та гине, а вже до 2050 р. для того, щоб прогодувати населення Землі, фермерам необхідно збільшити виробництво їжі на 70 % порівняно з теперішнім обсягом. Хвороби рослин різко знижують якість і кількість врожаю, що зменшує потенційні переваги сільського господарства. Зменшення випадків загибелі рослин через такі хвороби дасть змогу фермерам підвищити ефективність власних підприємств, що відповідно збільшить якість та кількість виробленої їжі. На цей момент господарникам доводиться самостійно перевіряти стан сільськогосподарських культур, аналізувати майже кожну рослину, при цьому іноді залучати кваліфікованих ботаніків. Такі накладні витрати ускладнюють процес вирощування рослин та роблять його дуже трудомістким.

Ми спробуємо автоматизувати цей процес.

Сервіс для автоматичного розпізнавання хвороб сільськогосподарських рослин

Опис датасету для навчання

Для навчання було використано датасет компанії PlantVillage, яка займається розробками у

сферах штучного інтелекту. Датасет від початку створено компанією для проведення хакатону щодо розроблення моделі для визначення хвороб сільськогосподарських рослин. Він містить 38 класів для більш ніж 15 видів рослин, що є найбільш популярними агрокультурами серед фермерів Південної Африки та Північної Америки (кукурудза, томати, картопля, фруктові культури та ягоди тощо). Датасет містить майже 65 тисяч уже розмічених зображень, що дає змогу відразу переходити до його оброблення і безпосередньої роботи з ним.



Рис. 1. Приклад зображень класу Tomato Bacterial Spot (листя помідорів, що мають ознаки бактеріальних хвороб), що містяться в датасеті

Спершу було прийнято рішення збалансувати класи датасету, де значно не вистачає представників, а для цього – штучно генерувати нові зображення завдяки різним афінним перетворенням, змінам контрастності, яскравості тощо.

Після розширення і класового балансування датасету було проведено нормалізацію зображень: зчитано зображення та змінено їх розмір відповідно до вхідного шару моделей (під час

навчання моделей було визначено розмір 220 на 220 пікселів, який давав змогу помістити одну партію зображень в оперативну пам'ять для виконання одного кроку навчання моделі); нормалізовано значення пікселів зображень до розподілу в межах від 0 до 1.

Проектування нейронної мережі

Для проектування та навчання моделей ми обрали сучасний і популярний фреймворк для машинного навчання tensorflow і його розширення keras.

За допомогою фреймворку створено власну модель та спеціальний програмний інтерфейс, що допомагає легко інтегрувати нові архітектури моделей для навчання, створення звітів після їх навчання, роботи з оцінками моделей та їх подальшого використання для передбачень.

Програмний інтерфейс зорієнтовано для виділення основних функцій навчання та роботи з моделями. Його можна використовувати у двох режимах: навчання та передбачення зі вже навченою моделлю.

Для навчання було виокремлено функції нормалізації даних, розширення датасету, ініціалізації моделей (ініціалізація шарів та інших допоміжних функцій), вибір оптимізатора (за замовчуванням використовується один із найпопулярніших оптимізаторів машинного навчання Adam), визначення функції помилки та метрики навчання (за замовчуванням для функції помилки використовується Binary cross entropy loss function, а для метрики навчання – точність), сам процес навчання з виводом інформації щодо поточного кроку та епохи навчання, створення графіків навчання і підсумкових результатів та збереження натренованих параметрів моделі. Для передбачення було створено функції завантаження параметрів моделей, їх перевірки та валідації і функції для роботи з передбаченнями.



Рис. 2. Приклад зображень після нормалізації




Рис. 3. Візуалізація розробленої архітектури моделі нейронної мережі

Використання архітектури займає приблизно 150 хвилин для навчання та видає максимально 83,3 % точності на тренувальних даних і максимально 81,5 % на тестових даних для оцінюваної моделі.

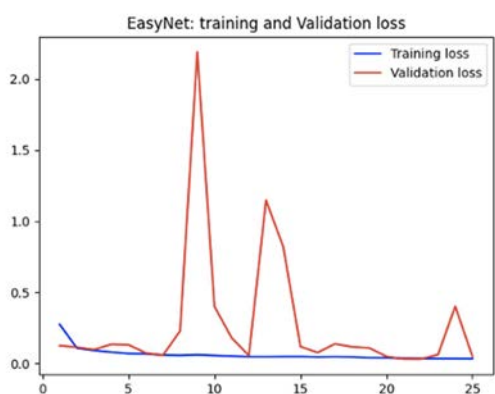


Рис. 4. Зображення графіків функції помилки на тренувальних і тестових даних під час навчання. Ось абсцис містить значення кількості епох тренуваної моделі, а ординат – значення функції помилки




Рис. 5. Зображення графіків функції метрики (точності) на тренувальних і тестових даних під час навчання. Ось абсцис містить значення кількості епох тренуваної моделі, а ординат – значення функції метрики (точності)

Навчання наявних архітектур нейронних мереж

Для навчання вже наявних архітектур нейронних мереж було використано розроблений і описаний вище програмний інтерфейс, у який легко було інтегрувати моделі. Ми обрали такі архітектури: AlexNet, DenseNet121, LeNet, VggNet16, XceptionNet.

Із натренованих моделей найкращу точність мала XceptionNet: 99,3 % на тренувальних даних і 93,4 % на тестових. Найгіршими виявились LeNet та VggNet16. LeNet мала низьку точність – 65,6 % на тренувальних даних і 72,1 % на тестових, через свою достатньо просту та застарілу архітектуру. VggNet16 взагалі не підійшла під цю проблему та мала найнижчу точність – менше ніж 4 % на тренувальних та тестових даних. Через це вони точно не підходять для вирішення нашого завдання.

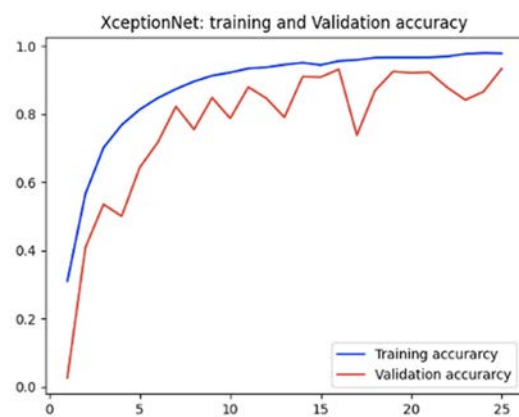


Рис. 6. Зображення графіків функції метрики (точності) на тренувальних і тестових даних під час навчання. Ось абсцис містить значення кількості епох тренуваної моделі, а ординат – значення функції метрики (точності). Для XceptionNet

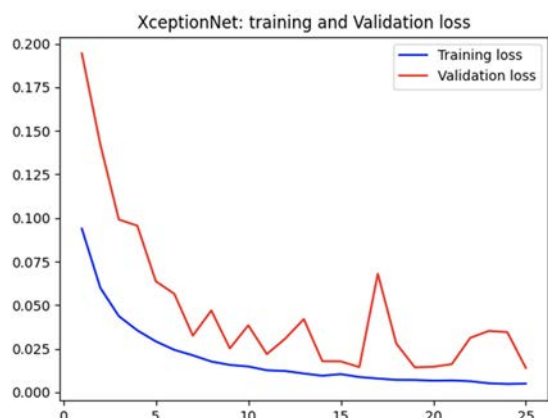


Рис. 7. Зображення графіків функції помилки на тренувальних і тестових даних під час навчання. Ось абсцис містить значення кількості епох тренуваної моделі, а ординат – значення функції помилки. Для XceptionNet

Наступними етапами для вдосконалення точностей моделей та покращення їхньої якості на реальних прикладах може бути: розширення датасету та/або його заміна на більш новий і такий, що міститиме більшу кількість класів для класифікації; підбирання гіперпараметрів моделей для досягнення максимальної точності кожної з моделей; використання інших функцій помилки та оцінки; використання інших моделей глибинного навчання.

Реалізація сервісу для кінцевих користувачів

Головними критеріями додатка, що використовуватиме натреновані моделі і буде доступ-

ним для будь-якого користувача, були зручність використання сервісу та швидкість його розроблення і подальшого доповнення. Ми вирішили створити спеціальний телеграм-бот, який звертається до моделей машинного навчання та видає користувачу результат відпрацювання моделей із додатковими інформаціями щодо хвороб рослин.

Для розроблення застосовували Python фреймворк aiogram із використанням стандартної бібліотеки асинхронного програмування asyncio. Оскільки час передбачення моделей на реальних прикладах може бути достатньо великим (до 250–300 мс, що є досить багато в сучасних реаліях), ми мінімізували час на всі інші операції, скориставшись: оптимізованою бібліотекою ujson для роботи з форматами JSON; бібліотекою uvloop, що дає можливість використовувати більш оптимізований цикл подій для асинхронних операцій та інші прискорювачі асинхронного коду, які орієнтовані на пришвидшення роботи з мережею.

Висновки

За допомогою розробленої моделі нейронної мережі здійснено спробу полегшити виявлення та класифікацію хвороб сільськогосподарських рослин. Досліджено наявні популярні моделі глибинного навчання для застосування у вирішенні поставленої задачі. Результат навчання моделі XceptionNet як наявної архітектури має точність 93,4 % на валідаційному дата-

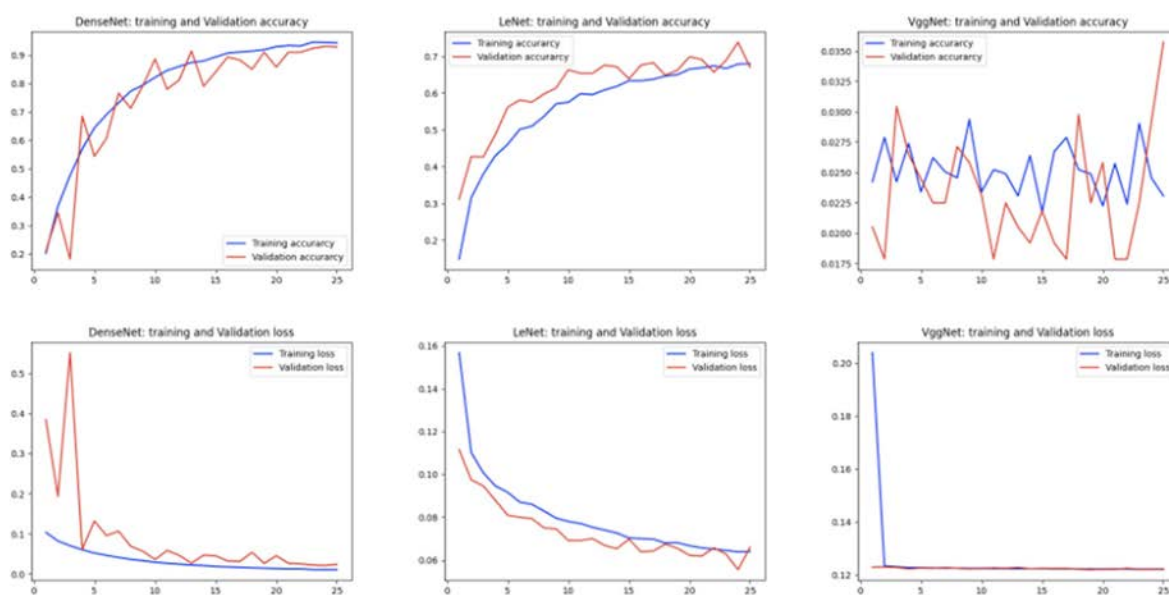


Рис. 8. Зображення графіків функції метрики (точності) та функції помилки на тренувальних і тестових даних під час навчання. Ось абсцис містить значення кількості епох тренуваної моделі, а ординат – значення функцій. Для моделей (зліва–направо) DenseNet121, LeNet, VggNet16

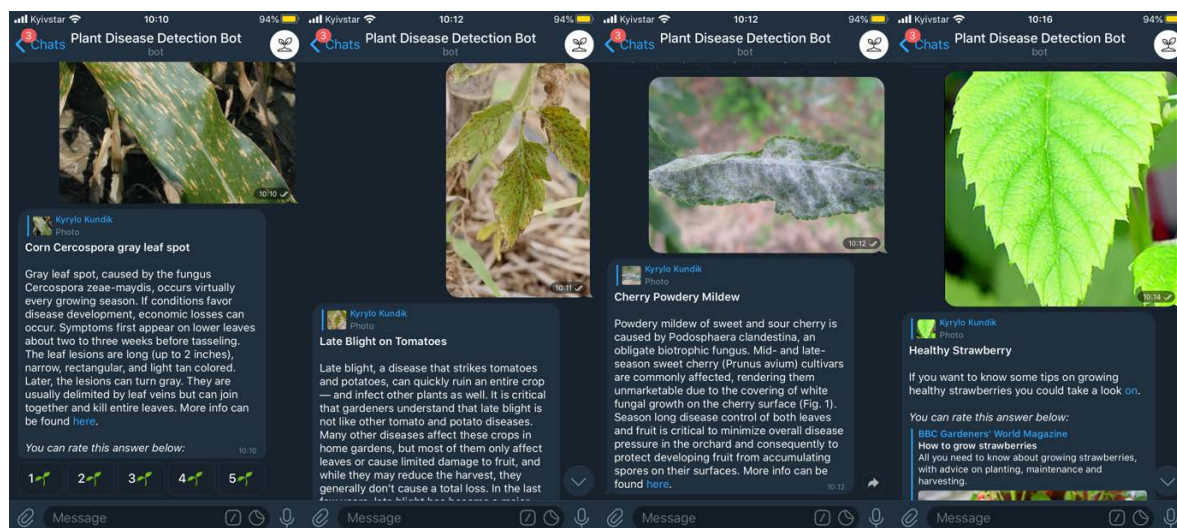


Рис. 9. Зображення результатів використання сервісу розпізнавання хвороб на реальних зображеннях хворих і здорових рослин

сеті, модель власної архітектури має 81,5 % точності.

Створений телеграм-бот покладається лише на асинхронний код задля зменшення затримок мережі й взаємодії з моделями та швидкого реагування на повідомлення користувачів.

Автоматизація виявлення хвороб є корисною, оскільки це зменшує об'ємну роботу спостереження за сільськогосподарськими культурами. Варіації симптомів, які вказують на хвороби рослини, можуть бути неправильно діагностова-

ні через труднощі їх визначення. Автоматизована система, розроблена для виявлення хвороб рослин за зовнішнім виглядом та візуальними симптомами, може бути корисною як для любителів-садівників, так і фахівців як система перевірки в діагностиці хвороб.

Досягнення у галузі комп'ютерного зору дають можливість розширити та вдосконалити практику захисту рослин та розширити ринок програм комп'ютерного зору в галузі землеробства.

Список літератури

1. Chollet F. Xception: Deep Learning with Depthwise Separable Convolutions [Electronic resource] / Francois Chollet. – 2017. – Mode of access: https://openaccess.thecvf.com/content_cvpr_2017/papers/Chollet_Xception_Deep_Learning_CVPR_2017_paper.pdf.
2. Dettmers T. Deep Learning in a Nutshell: Core Concepts [Electronic resources] / Tim Dettmers. – 2015. – Mode of access: developer.nvidia.com/blog/deep-learning-nutshell-core-concepts/.
3. Geron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, 2nd Edition [Electronic resource] / Aurelien Geron. – 2019. – Mode of access: <https://www.oreilly.com/library/view/hands-on-machine-learning/9781492032632/>.
4. Goodfellow I. Deep Learning [Electronic resource] / I. Goodfellow, Y. Bengio, A. Courville. – 2016. – Mode of access: www.deeplearningbook.org/.
5. Zhu L. Towards Image Classification with Machine Learning Methodologies for Smartphones [Electronic resource] / L. Zhu, P. Spachos. – 2019. <https://doi.org/10.3390/make1040059>

References

- Chollet, F. (2017). *Xception: Deep Learning with Depthwise Separable Convolutions*, Google, Inc. Retrieved from https://openaccess.thecvf.com/content_cvpr_2017/papers/Chollet_Xception_Deep_Learning_CVPR_2017_paper.pdf.
- Dettmers, T. (2015). *Deep Learning in a Nutshell: Core Concepts*. Retrieved from developer.nvidia.com/blog/deep-learning-nutshell-core-concepts/.
- Geron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. 2nd Edition. O'Reilly Media, Inc. Retrieved from <https://www.oreilly.com/library/view/hands-on-machine-learning/9781492032632/>.
- Goodfellow, I., et al. (2016). *Deep Learning*, MIT Press. Retrieved from www.deeplearningbook.org/.
- Zhu, L., & Spachos, P. (2019). *Towards Image Classification with Machine Learning Methodologies for Smartphones*. <https://doi.org/10.3390/make1040059>

A. Afonin, K. Kundik

AUTOMATIC DETERMINATION OF AGRICULTURAL PLANT DISEASES

Machine learning technologies have developed rapidly in recent years, and people are now able to use them in various spheres of life, making their lives easier and better. The agro-industry is not lagging behind, and every year more and more problems in this area are solved with the help of machine learning algorithms. However, among the problems that have not yet been solved is the problem of identifying diseases of agricultural plants. According to the UN research, about 40% of the world's harvest dies each year from various diseases, most of which could be avoided through timely intervention and treatment.

To solve this problem, we offer an easy, accessible service for everyone, which will allow one to predict by the image of the plant leaves whether it is sick or healthy, or whether it needs any help or intrusion. This service will be indispensable for small farms engaged in growing crops. Thus, it will allow employees of such enterprises to immediately detect diseases and receive recommendations for the care of plants important to them.

Therefore, it was decided to develop a neural network architecture that will solve this problem: the prediction of a plant disease by the image of its leaves. This neural network model is lightweight, does not take much time to learn, and has high accuracy on our dataset. It was also investigated which popular architectures (e.g. XceptionNet, DenseNet, etc.) of deep neural networks can have great accuracy in solving this problem. To realize the possibility of using the model by end users, i.e. farmers, it was decided to develop a special web service in the form of a telegram bot. With this bot, anyone can upload images of the leaves of agricultural plants and check whether this plant is healthy or free of any diseases. This bot is also trained to give appropriate advice to gardeners on the treatment of diseases or the proper cultivation of healthy plants.

This solution fully solves the problem and has every chance to become an indispensable helper in preserving the world harvest.

Keywords: machine learning, image classification, computer vision, deep learning, Tensorflow, agricultural plant diseases.

Матеріал надійшов 14.06.2021



Creative Commons Attribution 4.0 International License (CC BY 4.0)