

Б. П. Книш¹
Я. А. Кулик¹

КЛАСИФІКАЦІЯ СОНЯШНИКА ЗА ДОПОМОГОЮ ЗГОРТКОВО-КАПСУЛЬНОЇ МОДЕЛІ НЕЙРОННОЇ МЕРЕЖІ CNN-CAPSNET

¹Вінницький національний технічний університет

Запропоновано класифікацію соняшника за допомогою згортково-капсульної моделі нейронної мережі CNN-CapsNet з удосконаленою архітектурою, яка поєднує згорткову нейронну мережу CNN та капсульну нейронну мережу CapsNet та дозволяє використати переваги цих обох архітектур. На основі проведеного літературного огляду встановлено, що перевагою згорткової нейронної мережі CNN є коротший час навчання, а капсульної нейронної мережі CapsNet — більша точність, надійність та можливість ефективно працювати зі складними задачами. Поєднання згорткової нейронної мережі CNN та капсульної нейронної мережі CapsNet та вдосконалення архітектури CNN-CapsNet проводилося шляхом внесення змін в CapsNet. Ці зміни полягають в тому, що у динамічній маршрутизації процес зворотного зв'язку додає підтримку для капсули, яка найбільше відповідає вихідному сигналу. Також застосовуються функції активації для апроксимації нелінійних з'єднань у глибоких мережах. Вони реалізовані як базові математичні функції, зазвичай для скалярних величин. Згорткові шари використовуються для отримання початкових карт функцій, які потім завантажуються в модель CapsNet для виконання остаточної класифікації. На основі цього розроблено дві окремі моделі. Одна модель виконує класифікацію на основі двох класів: «незрілий соняшник» та «стиглий соняшник». Друга модель виконує класифікацію на основі трьох класів: «незрілий соняшник», «стиглий соняшник» та «хворий соняшник». Основними показниками ефективності нейронної мережі CNN-CapsNet вибрано такі характеристики як точність класифікації, чутливість та F-оцінка на основі помилок I і II роду. Для аналізу цих показників побудовано матриці помилок і графіки точності та похибок цих моделей. Здійснене порівняння запропонованих моделей нейронної мережі CNN-CapsNet з подібними продемонструвало найбільшу точність саме запропонованих моделей.

Ключові слова: класифікація, соняшник, згортково-капсульна модель, нейронна мережа, точність.

Вступ

Ключовою галуззю економіки України є сільське господарство, оскільки сприятливі кліматичні умови та наявність родючих ґрунтів дають змогу отримувати високі врожаї культур. Вже багато років в Україні найбільші посівні площі використовують під три культури — соняшник (5,3 млн га), пшениця (4,4 млн га), кукурудза (3,9 млн га) [1]. При цьому найбільша рентабельність спостерігається саме для соняшника (63 %), тоді як для кукурудзи вона становить 45 %, а для пшениці — ще менше [2]. Тому Україна сьогодні є найбільшим експортером не лише зерна, а й соняшникової олії [3].

Крім того, однією з причин цього є широке впровадження точного землеробства. Це сукупність технологій, які ґрунтуються на результатах агромоніторингу, а саме на точних даних, та їхньої обробки. Дані забезпечуються знімками супутників, системами технічного зору, робототехнічними комплексами, безпілотними літальними апаратами, системами відеоспостереження, веб-сервісами та мобільними додатками для ідентифікації та пошуку [4]. Обробка цих даних забезпечується різноманітними моделями розпізнавання, які базуються на нейронних мережах [5], [6].

Використання таких моделей розпізнавання підвищує автоматизацію та оптимізацію процесів вирощування соняшника шляхом його класифікації, що дозволяє здійснювати контроль якості цієї сільськогосподарської культури. Це надає такі переваги як моніторинг стану посівів, виявлення хвороб та шкідників, оптимізація використання ресурсів, підвищення врожайності та підвищення якості продукції.

Для точного землеробства, зокрема для класифікації сояшника, використовують згорткові нейронні мережі (CNN) та капсульні нейронні мережі (CapsNets). Кожна з них має свої переваги та недоліки. CNN демонструють ефективність у виявленні різних аспектів, пов'язаних з посівами, включно з ідентифікацією хвороб, оцінюванням здоров'я посівів тощо, але нездатні розпізнавати спотворення текстури, розрізняти пози та форми цілих об'єктів або їхніх частин на зображеннях [7], [8]. CapsNets придатні для вирішення складних проблем, де традиційні мережі мають проблеми через експоненціальне зростання вимог до навчання, є точнішими та надійнішими [9], але вимагають довшого часу навчання порівняно з CNN, що може бути помітним недоліком у практичних застосуваннях, де час навчання є критичним фактором [10].

Таким чином, ефективність цих моделей визначається багатьма показниками, основним з яких є точність класифікації сояшника, для оцінки якої необхідні експериментальні дослідження.

Огляд моделей згорткових нейронних мереж CNN

Моделі CNN можуть бути використані для аналізу посівів сояшника, контролю їхньої вегетації та дозрівання. Так в роботі [7] запропоновано модель глибокого навчання з використанням CNN для класифікації позакоренових захворювань сояшнику, які можуть завдати значної економічної шкоди.

В дослідженні [8] використано гібридну модель, яка поєднувала перехідне навчання для вилучення ознак з невеликого набору даних про захворювання сояшнику з моделлю CNN для класифікації.

Відомі дослідження демонструють ефективність таких згорткових нейронних мереж у виявленні різних аспектів, пов'язаних з посівами сояшника, включно з ідентифікацією хвороб, оцінюванням здоров'я посівів і встановленням фази дозрівання. Але моделі CNN мають проблеми з обробкою варіацій зовнішнього вигляду сояшника, пов'язаних зі зміною освітлення, кутів камери або умов навколишнього середовища, що може вплинути на продуктивність моделі та знизити ефективність класифікації сояшника.

Одним з можливих методів усунення цих обмежень є поєднання моделей CNN з іншими моделями, до прикладу, CapsNet.

Огляд моделей капсульних нейронних мереж CapsNets

На відміну від CNN капсульні нейронні мережі CapsNets використовують механізми динамічної маршрутизації та матриці перетворення для вивчення просторових зв'язків, через що вони ефективніші під час оброблення просторових змін і трансформації кута огляду на об'єкт дослідження. Ці моделі краще виявляють сояшник, долаючи обмеження CNN, пов'язані з обробкою аномалій, поліпшуючи інтерпретацію та можливості узагальнення.

Моделі CapsNets продемонстрували різну точність порівняно з іншими архітектурами нейронних мереж на основі різних досліджень. Дослідження [11] порівнювало класифікацію зображень за допомогою CapsNet з традиційними моделями, які працюють з наборами зображень. Результати показали, що CapsNet перевершив Fisherface на наборі зображень MIT, але потребував значно більше часу для навчання.

У роботі [12] запропоновано модель, основу на ResNet, яка подібна до CapsNet, для класифікації сояшнику. Проводилося порівняння з іншими архітектурами, зокрема CNN, і результати показали, що запропонована модель точніша і має більшу швидкодію. Модель на основі ResNet досягла точності 87,5 % після використання глобального скорочення, що є значним поліпшенням порівняно з методом стиснення з використанням пошарового скорочення. Також модель продемонструвала зменшення кількості параметрів на 92 % зі збереженням продуктивності, близької до оригінальної моделі, демонструючи її ефективність у зниженні обчислювальних ресурсів і витрат.

Незважаючи на очевидні переваги CapsNets, особливо в порівнянні з CNN, основними факторами, які впливають на ефективність класифікації сояшника за допомогою CapsNets, є час навчання (витрачається більше часу на навчання, що може вплинути на виконання задач, чутливих до часу класифікації), складність набору зображень (точність може знизитися на багатокласових наборах), попередня обробка даних (може вплинути на продуктивність).

Поєднання згорткових нейронних мереж CNN та капсульних нейронних мереж CapsNets

Поєднання декількох нейронних мереж в одну дозволяє поліпшити її загальні характеристики та зменшити або нівелювати недоліки, характерні для архітектур, елементи яких входять до складу цієї гібридної моделі.

Гібридна модель DenseNet 121, що поєднує CapsNet з DenseNet і зворотну регресію, запропонована для ідентифікації хвороб листя кави [13], продемонструвала переваги над наявними моделями класифікації хвороб рослин. Моделі CapsNet досліджено для класифікації хвороб інших культур, таких як картопля, арахіс і болгарський перець, та показали перспективні результати. DenseNet121 працювала добре навіть з невеликим набором навчальних даних, що свідчить про схильність до перенавчання. Це може бути обмеженням, якщо модель не в змозі добре узагальнити різні види рослин і типи хвороб без значного розширення даних.

У роботі [14] запропоновано гібридну модель VGG19+CNN, яка поєднує навчання з перенесенням і згорткову нейронну мережу для виявлення хвороб соняшника з невеликого набору даних. Ефективність моделі може бути обмежена її нездатністю диференціювати певні види захворювання. До того ж, набір даних, який використовується у дослідженні, може не повністю відображати різноманітний спектр проявів захворювань у соняшнику, що може обмежити можливість узагальнення моделі.

Всі ці результати досліджень дають підстави стверджувати про перспективність поєднання архітектур подібних до CNN та CapsNet, зокрема для розв'язання задач класифікації соняшника, а саме пов'язаних з виявленням стресу у рослин та ідентифікацією хвороб. Це можна досягти за рахунок об'єднання унікальної властивості CapsNets, а саме еквіваріантності, що дозволяє краще працювати з динамічними об'єктами або сценами, та коротшого часу навчання, що властиво для CNN. Більше того, експериментування з більшими навчальними наборами та меншою кількістю епох може допомогти уникнути перенавчання та підвищити точність [15].

Таким чином, поєднання CNN та CapsNets відкриває можливості для підвищення ефективності, а саме точності класифікації соняшника. При цьому складність набору зображень, час навчання та методи попередньої обробки, відіграють вирішальну роль у визначенні загальної продуктивності таких гібридних архітектур як CNN-CapsNet.

Тому *метою статті* є підвищення ефективності класифікації соняшника шляхом розробки моделі нейронної мережі CNN-CapsNet з удосконаленою архітектурою, яка поєднує відповідні архітектури нейронних мереж та дозволяє використати переваги обох архітектур.

Створення та вдосконалення архітектури CNN-CapsNet проводиться шляхом внесення змін в CapsNet, оскільки вищенаведені моделі показали підвищення точності саме у випадку вдосконалення архітектури CapsNet. Ці зміни полягають в тому, що у динамічній маршрутизації процес зворотного зв'язку додає підтримку для капсули, яка найбільше відповідає вихідному сигналу. Також застосовуються функції активації для апроксимації нелінійних з'єднань у глибоких мережах. Зазвичай вони реалізовані як базові математичні функції для скалярних величин. Згорткові шари використовуються для отримання початкових карт функцій. Потім карти функцій завантажуються в модель CapsNet для виконання остаточної класифікації. Архітектуру CNN-CapsNet сформовано на основі чотирьох згорткових шарів. Кожен згортковий рівень використовує 64×64 та 128×128 ядер, відповідно, а шари — 3×3 . Для всіх шарів використовується функція активації ReLU. Після другого шару згортки розташовується шар проміжного з'єднання.

Такий підхід може забезпечити вищу продуктивність навчання, ніж операції, засновані на максимальному об'єднанні, утвореному маршрутизацією.

Показники ефективності нейронної мережі CNN-CapsNet

Основними показниками ефективності нейронної мережі CNN-CapsNet, що визначалися в процесі дослідження, вибрано такі характеристики [16]:

$$\text{– точність} \quad \textit{precision} = \frac{T^P}{T^P + F^P}; \quad (1)$$

$$\text{– чутливість} \quad \textit{recall} = \frac{T^P}{T^P + F^N}; \quad (2)$$

$$\text{– } F\text{-оцінка} \quad F\text{-score} = \frac{2 \times \textit{recall} \times \textit{precision}}{\textit{recall} + \textit{precision}}, \quad (3)$$

де F^P — хибно позитивне значення, тобто помилка I роду, коли запропонована модель спрогнозувала істину, але фактичне значення хибне; T^P — позитивне значення, коли запропонована модель

спрогнозувала істинну і фактичне значення позитивне; F^N — хибнонегативне значення, тобто помилка II роду, коли фактичне значення позитивне, а запропонована модель спрогнозувала хибне.

Дослідження моделей нейронної мережі CNN-CapsNet для класифікації соняшника

Запропоновано дві окремі моделі. Одна виконує класифікацію на основі двох класів: «незрілий соняшник» та «стиглий соняшник». Друга модель виконує класифікацію на основі трьох класів: «незрілий соняшник», «стиглий соняшник» та «хворий соняшник». Для навчання цих моделей використовується оптимізатор Адама. Функція граничних похибок використовується для визначення характеристик класу.

$$L_k = T_k \max(0, m^+ - \|v_k\|)^2 + \alpha(1 - T_k) \max(0, m^+ - \|v_k\| - m^-)^2, \quad (4)$$

де T_k — показник класу, причому $T_k = 1$, якщо ознака класу k існує; α — розмір початкового кроку; m^+ — розрахована першочергова оцінка з виправленням лівого зміщення; m^- — розрахована першочергова оцінка з виправленням правого зміщення; v_k — розрахована оцінка другого вихідного моменту з виправленням зміщення [16].

Обидві моделі навчалися не більше 30 епох. Для їхнього навчання використовувався набір зображень 512×512 , а саме Sun Flower Fruits and Leaves dataset for Sunflower Disease Classification through Machine Learning and Deep Learning [17], який містить 1668 зображень стиглих та незрілих соняшників, а також зображення соняшників, уражених різноманітними хворобами. Також вони використовувалися для розрахунку показників ефективності. Навчання завершувалося методом ранньої зупинки, щоб уникнути наслідків перенавчання. Якщо перевірка завершувалася подальшим поліпшенням, механізм ранньої зупинки припиняв навчання. У цьому випадку функція граничних похибок обчислювалась після кожної епохи на тестовому наборі. Навчання припинялося, коли похибка моделі збільшувалась, тобто коли спостерігалися великі відмінності між значеннями точності класифікації під час навчання та перевірки. Це є ознакою перенавчання. Скасування кроку навчання залежить від параметра допуску, який відповідає кількості епох очікування на зменшення значення похибки. Для обох моделей параметр допуску дорівнює 10.

На рис. 1 показано графіки зміни точності класифікації під час навчання та перевірки двокласової та трикласової моделей нейронної мережі CNN-CapsNet.




Рис. 1. Графік зміни: ● — точності класифікації під час навчання; ■ — перевірки моделей нейронної мережі CNN-CapsNet: *a* — двокласової; *б* — трикласової

Як видно з рисунку, для двокласової та трикласової моделей нейронної мережі CNN-CapsNet точність класифікації під час навчання та перевірки росте, але значення під час перевірки дещо нижчі. Різниця значень знаходиться в допустимому діапазоні, що показує ефективність моделей та відсутність перенавчання. На пізніх етапах навчання ця різниця менша. Після завершення навчання точність класифікації моделей під час перевірки перевищує 0,9, що є хорошим показником.

На рис. 2 показано графіки зміни похибок класифікації під час навчання та перевірки двокласової та трикласової моделей нейронної мережі CNN-CapsNet.




Рис. 2. Графік зміни: — похибок класифікації під час навчання; — перевірки моделей нейронної мережі CNN-CapsNet: *a* — двокласової; *б* — трикласової

Як випливає з рис. 2, для двокласової та трикласової моделей нейронної мережі CNN-CapsNet похибки класифікації під час навчання постійно зменшуються. Під час перевірки похибки класифікації також зменшуються, але спостерігається коливання значень. Їхнє постійне зниження дозволяє стверджувати про відсутність перенавчання. Після завершення навчання похибки класифікації моделей під час перевірки становлять менше 0,1, що є хорошим показником.

Для аналізу показників ефективності запропонованих моделей, а саме (1)—(3), проведено тестове розпізнавання зображень з набору Sunflower_detection [18], який містить 600 зображень 640×640. На основі результатів розпізнавання побудовано матриці помилок, за допомогою яких можна порівняти прогнозовані та фактичні значення класів сояшника. Це дозволяє розрахувати помилки I та II роду, на основі яких, відповідно до (1)—(3), можна обчислити точність, чутливість та *F*-оцінку. Матриці помилок для двокласової та трикласової моделей нейронної мережі CNN-CapsNet показано на рис. 3.



Рис. 3. Матриці помилок для моделей нейронної мережі CNN-CapsNet: *a* — двокласової; *б* — трикласової

Для двокласової моделі проведено тестове розпізнавання 100 зображень, які розділено на 50 зображень незрілого сояшника та 50 зображень стиглого сояшника. Для трикласової моделі проведено тестове розпізнавання 150 зображень, які розділено на 50 зображень незрілого сояшника, 50 зображень стиглого сояшника та 50 зображень хворого сояшника.

В табл. 1 подано показники ефективності двокласової та трикласової моделей нейронної мережі CNN-CapsNet сформовані на основі результатів дослідження.

Таблиця 1

Показники ефективності двокласової та трикласової моделей нейромережі CNN-CapsNet

Моделі CNN-CapsNet	Клас	Показники ефективності		
		точність	чутливість	<i>F</i> -оцінка
Двокласова	Стиглий сояшник	0,95	0,85	0,89
	Незрілий сояшник	0,87	0,90	0,81

Моделі CNN-CapsNet	Клас	Показники ефективності		
		точність	чутливість	F -оцінка
Трикласова	Стиглий соняшник	0,95	0,86	0,83
	Незрілий соняшник	0,87	0,85	0,82
	Хворий соняшник	0,90	0,82	0,81

Як видно з табл. 1, значення точності, чутливості та F -оцінки є досить значними, що вказує на високу ефективність запропонованих моделей нейронної мережі CNN-CapsNet.

Порівняння запропонованих моделей нейронної мережі CNN-CapsNet з подібними

Для перевірки запропонованих моделей нейронної мережі CNN-CapsNet виконано порівняння з іншими моделями за ефективністю, а саме за точністю класифікації. Такими моделями з подібною архітектурою, яка поєднують архітектури CNN та CapsNet вибрано CNN-SVM [19], ResNext101 [12], VGG19+CNN [14], MCCNE [20]. Для перевірки моделей використано зображення з набору Sunflower labeled image dataset [21], який містить 282 зображення 256×256 . Приклад застосування двокласової моделі нейронної мережі CNN-CapsNet для цього набору показано на рис. 4, трикласової моделі — на рис. 5.



Рис. 4. Точність класифікації соняшника за допомогою двокласової моделі нейронної мережі CNN-CapsNet: *a* — стиглий соняшник (95 %), *б* — незрілий соняшник (93 %)



Рис. 5. Точність класифікації соняшника за допомогою трикласової моделі нейронної мережі CNN-CapsNet: *a* — стиглий соняшник (94 %); *б* — незрілий соняшник (87 %); *в* — хворий соняшник (85 %)

Загальні результати точності класифікації запропонованих моделей та подібних зведено в табл. 2.

Таблиця 2

Загальні результати точності класифікації моделей нейронних мереж

Модель	CNN-SVM	ResNext101	VGG19+CNN	MCCNE	CNN-CapsNet
Точність	86	84	88	84	90

З цієї таблиці видно, що найбільшу точність, а саме 90 %, демонструють запропоновані моделі нейронної мережі CNN-CapsNet. Це свідчить про високу ефективності класифікації соняшника саме цими моделями.

Висновки

В роботі запропоновано класифікацію соняшника за допомогою згортково-капсульної моделі нейронної мережі CNN-CapsNet з удосконаленою архітектурою, яка поєднує згорткову нейронну мережу CNN та капсульну нейронну мережу CapsNet та дозволяє використати переваги цих обох архітектур. На основі цього розроблено дві окремі моделі. Одна модель виконує класифікацію на основі двох класів: «незрілий соняшник» та «стиглий соняшник». Друга модель виконує класифікацію на основі трьох класів: «незрілий соняшник», «стиглий соняшник» та «хворий соняшник». Основними показниками ефективності нейронної мережі CNN-CapsNet вибрано такі характеристики як точність класифікації, чутливість та F -оцінка на основі помилок I і II роду. Для аналізу цих показників побудовано матриці помилок. Значення точності мають високі показники, проте хибні класифікації трапляються, хоча й не часто. Графіки точності та похибок моделей показали хороші значення на перевіірчній вибірці. Точність класифікації моделей під час перевірки перевищує 0,9, тоді як похибки класифікації становлять менше 0,1. Характер графіків свідчить, що значного перенавчання вдалось уникнути. Здійснено порівняння запропонованих моделей нейронної мережі CNN-CapsNet з подібними, що продемонструвало найбільшу точність (90 %) саме запропонованих моделей.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

- [1] Названо топ-3 культури, посівні площі під якими змінилися найбільше. [Електронний ресурс]. Режим доступу: https://agroportal.ua/news/eksklyuzivny/nazvano-top-3-kulturi-posivni-ploshchi-pid-yakimi-zminilisya-naybilshhe_. Дата звернення 09.07.2024.
- [2] Що вигідно вирощувати фермеру в Україні? [Електронний ресурс]. Режим доступу: <https://veles-agro.com/news/chtovugodno-vyrashhivat-fermeru-v-ukraine>. Дата звернення 09.07.2024.
- [3] Найбільш популярні сільськогосподарські культури в Україні [Електронний ресурс]. Режим доступу: <https://gora.in.ua/news/najbilsh-populjarni-silskogospodarski-kulturi-v-ukraini>. Дата звернення 09.07.2024.
- [4] А. Б. Ачасов, А. О. Седов, і А. О. Ачасова, «Оцінка забур'яненості посівів соняшника за допомогою безпілотних літальних апаратів,» *Людина та довкілля. Проблеми неоекології*, № 3-4 (26), с. 69-74, 2016.
- [5] В. Knysh, and Y. Kulyk, "Development of an image segmentation model based on a convolutional neural network," *Eastern-European Journal of Enterprise Technologies*, no. 2 (110), pp. 6-15, 2021. <https://doi.org/10.15587/1729-4061.2021.228644>.
- [6] В. Knysh, and Y. Kulyk, "Improving a model of object recognition in images based on a convolutional neural network," *Eastern-European Journal of Enterprise Technologies*, no. 3 (111), pp. 40-50, 2021. <https://doi.org/10.15587/1729-4061.2021.233786>.
- [7] Y. Unal, and M. N. Dudak, "Deep Learning Approaches for Sunflower Disease Classification: A Study of Convolutional Neural Networks with Squeeze and Excitation Attention Blocks," *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, vol 13 (1), pp. 247-258, 2024. <https://doi.org/10.17798/bitlisfen.1380995>.
- [8] A. Sirohi, and A. Malik, "A Hybrid Model for the Classification of Sunflower Diseases Using Deep Learning," in *2nd International Conference on Intelligent Engineering and Management (ICIEM)*, 2021, no. 2, pp. 58-62. <https://doi.org/10.1109/ICIEM51511.2021.9445342>.
- [9] G. E. Hinton, A. Krizhevsky, and S. D. Wang, "Transforming autoencoders," in *International Conference on Artificial Neural Networks*, 2011, pp. 44-51.
- [10] J. Xuefeng, W. Yikun, L. Wenbo, L. Shuying, and L. Junrui, "CapsNet, CNN, FCN: Comparative Performance Evaluation for Image Classification," *International Journal of Machine Learning and Computing*, vol. 9, no. 6, pp. 840-848, 2019. <https://doi.org/10.18178/ijmlc.2019.9.6.881>.
- [11] R. Mukhometzianov, and J. Carrillo, "CapsNet comparative performance evaluation for image classification," *Computer Vision and Pattern Recognition*, vol. 1, pp. 1-14, 2018. <https://arxiv.org/ftp/arxiv/papers/1805/1805.11195.pdf>.
- [12] D. Rodica, and D. Ciprian, "ResNet interpretation methods applied to the classification of foliar diseases in sunflower," *Journal of Agriculture and Food Research*, vol. 9, no. 100323, pp. 1-12, 2022. <https://doi.org/10.1016/j.jafr.2022.100323>.
- [13] M. Bakr, S. Abdel-Gaber, M. Nasr, and M. Hazman, "DenseNet Based Model for Plant Diseases Diagnosis," *European Journal of Electrical Engineering and Computer Science*, vol. 6, pp. 1-9, 2022. <https://doi.org/10.24018/ejece.2022.6.5.458>.
- [14] Gh. Promila, A. K. Mondal, S. Chatterjee, M. Masud, H. Meshref, and A. K. Bairagi, "Recognition of Sunflower Diseases Using Hybrid Deep Learning and Its Explainability with AI," *Mathematics*, vol. 11, no. 10, pp. 1-24, 2023. https://doi.org/10.3390/math11102241_.
- [15] M. U. Haq, M. A. J. Sethi, and A. U. Rehman, "Capsule Network with Its Limitation, Modification, and Applications – A Survey," *Machine Learning and Knowledge Extraction*, vol. 5(3), pp. 891-921, 2023. https://doi.org/10.3390/make5030047_

- [16] B. Juba, and H. S. Le, "Precision-recall versus accuracy and the role of large data sets," in *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, vol. 33, pp. 4039-4048.
- [17] Sun Flower Fruits and Leaves dataset for Sunflower Disease Classification through Machine Learning and Deep Learning. [Electronic resource]. Available: <https://data.mendeley.com/datasets/b83hmrzth8/1> . Accessed: 09.07.2024.
- [18] Sunflower_detection Computer Vision Project [Electronic resource]. Available: https://universe.roboflow.com/khaing/sunflower_detection_. Accessed: 09.07.2024.
- [19] G. Rana, R. Singh, A. Pal, and R. Gupta, "Enhancing Sunflower Disease Identification with CNN-SVM Integration," in *3rd International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON)*, 2023, pp. 1-6. <https://doi.org/10.1109/SMARTGENCON60755.2023.10442779> .
- [20] M. Peker, "Multi-channel capsule network ensemble for plant disease detection," *SN Applied Sciences*, vol. 3, pp. 1-10, 2021. <https://doi.org/10.1007/s42452-021-04694-2> .
- [21] 282 Sunflower labeled image dataset [Electronic resource]. Available: https://images.cv/download/sunflower/282_. Accessed 09.07.2024.

Рекомендована кафедрою автоматизації та інтелектуальних інформаційних технологій ВНТУ

Стаття надійшла до редакції 10.10.2024

Книш Богдан Петрович — канд. техн. наук, доцент кафедри загальної фізики, e-mail: tutmos-3@i.ua;
Кулик Ярослав Анатолійович — канд. техн. наук, доцент кафедри автоматизації та інтелектуальних інформаційних технологій, e-mail: Yaroslav_Kulik@i.ua.
 Вінницький національний технічний університет, Вінниця

B. P. Knysh¹
Ya. A. Kulyk¹

Classification of Sunflowers by the Means of Convolutional-Capsular Model of Neural Network CNN-Capsnet

¹Vinnitsia National Technical University

Sunflower classification using convolutional- capsular model of neural network CNN-CapsNet of improved architecture, which combines the convolutional neural network CNN and the capsular neural network CapsNet and enables to use the advantages of these two architectures is suggested in the paper. The conducted review of the literature sources allows to conclude that the advantage of convolutional neural network CNN is a shorter training time and the advantages of capsular neural network CapsNet include greater precision, reliability and the ability to work effectively with the complex tasks. Combination of convolutional neural network CNN and capsular neural network CapsNet as well as improvement of CNN-CapsNet architecture were conducted by means of making changes to CapsNet. These changes are that in dynamic routing, the feedback process adds support for the capsule that most closely matches the original signal. Activation functions are also applied to approximate nonlinear connections in deep networks. They are implemented as basic mathematical functions, usually for scalar quantities. Convolutional layers are used to get initial feature maps, which are then loaded into the CapsNet model to perform the final classification. Based on this approach, two separate model have been developed. One model provides classification, based on two classes: "unripe sunflower" and "ripe sunflower". The second model provides classification based on three classes: "unripe sunflower", "ripe sunflower" and "sick sunflower". Main indicators of the effectiveness of the CNN-CapsNet neural network were selected such characteristics as accuracy, sensitivity and F-score based on type I and II errors. To analyze these indicators, error matrices and graphs of accuracy and errors of these models were constructed. The comparison of the proposed models of the CNN-CapsNet neural network with similar ones was made, the highest accuracy was demonstrated by the proposed models.

Keywords: classification, sunflower, convolution-capsule model, neural network, accuracy.

Knysh Bogdan P. — Cand. Sc. (Eng.), Associate Professor of the Chair of General Physics, e-mail: tutmos-3@i.ua ;
Kulyk Yaroslav A. — Cand. Sc. (Eng.), Associate Professor of the Chair of Automation and Intelligent Information Technologies, e-mail: Yaroslav_Kulik@i.ua