

УДК 004.9

DOI <https://doi.org/10.32782/IT/2024-3-6>

### **Віта КАШТАН**

кандидат технічних наук, доцент, доцент кафедри інформаційних технологій та комп'ютерної інженерії, Національний технічний університет «Дніпровська політехніка», просп. Дмитра Яворницького 19, Дніпро, Україна, 49005

ORCID: 0000-0002-0395-5895

Scopus-AuthorID: 57201902879

### **Володимир ГНАТУШЕНКО**

доктор технічних наук, професор, завідувач кафедри інформаційних технологій та комп'ютерної інженерії, Національний технічний університет «Дніпровська політехніка», просп. Дмитра Яворницького, 19, м. Дніпро, Україна, 49005

ORCID: 0000-0003-3140-3788

Scopus Author ID: 6505609275

### **Іван ЛАКТИОНОВ**

доктор технічних наук, доцент, професор кафедри програмного забезпечення комп'ютерних систем, Національний технічний університет «Дніпровська політехніка», просп. Дмитра Яворницького, 19, м. Дніпро, Україна, 49005

ORCID: 0000-0001-7857-6382

Scopus Author ID: 57194557735

### **Григорій ДЯЧЕНКО**

кандидат технічних наук, доцент кафедри електропривода, Національний технічний університет «Дніпровська політехніка», просп. Дмитра Яворницького, 19, м. Дніпро, Україна, 49005

ORCID: 0000-0001-9105-1951

Scopus Author ID: 57201252081

**Бібліографічний опис статті:** Каштан, В., Гнатушенко, В., Лактіонов, І., Дяченко, Г. (2024). Геоінформаційна технологія нейромережевої сегментації для картографування земного покриття. *Information Technology: Computer Science, Software Engineering and Cyber Security*, 3, 51–62, doi: <https://doi.org/10.32782/IT/2024-3-6>

## **ГЕОІНФОРМАЦІЙНА ТЕХНОЛОГІЯ НЕЙРОМЕРЕЖЕВОЇ СЕГМЕНТАЦІЇ ДЛЯ КАРТОГРАФУВАННЯ ЗЕМНОГО ПОКРИВУ**

Актуальність розвитку сучасних технологій для сегментації земельного покриття зростає у зв'язку з підвищеними вимогами до точного моніторингу та управління земельними ресурсами, в тому числі, сільськогосподарського призначення. Традиційні методи сегментації часто не забезпечують достатню точність у класифікації складних класів, таких як сільськогосподарські культури, дерева, будівлі та дороги. **Мета роботи** полягає в розробці геоінформаційної технології для виділення множинних ознак із супутникових знімків Sentinel-2 та їх використання для сегментації земного покриття за допомогою нейронної мережі ResNet.

**Методологія.** У цьому дослідженні використовуються знімки Sentinel-2 для аналізу земного покриття. Спочатку зображення проходять попередню обробку, яка включає атмосферну корекцію, геометричне та радіометричне калібрування. Потім дані нормалізуються для підвищення стабільності навчання нейронної мережі. На наступному етапі зображення обробляються для виділення спектральних, морфологічних і текстурних ознак, які є вхідними даними для моделі ResNet. Модель застосовує конволюційні шари і функцію активації ReLU для автоматичного виділення ознак. Для класифікації використовується повнозв'язний шар з функціями Softmax та Cross-Entropy. Після навчання модель класифікує кожен піксель, створюючи сегментоване зображення, яке відображає різні класи земного покриття, зокрема сільськогосподарські угіддя, будівлі, дерева та дороги.

**Наукова новизна** дослідження полягає в розробці новітньої методології обробки супутникових зображень Sentinel-2, що включає інтеграцію комплексної попередньої обробки, нормалізацію даних, мульти-модальне виділення ознак та використання глибоких нейронних мереж для автоматичного виділення

та класифікації ознак. Впровадження нових підходів до атмосферної, геометричної та радіометричної корекції, а також застосування ResNet з функціями активації ReLU та повнозв'язних шарів з функціями Softmax і Cross-Entropy, забезпечує підвищення точності класифікації та деталізації сегментації земного покриття.

**Висновки.** Дослідження показало, що запропонована технологія забезпечує суттєве покращення точності і якості класифікації в порівнянні з традиційними методами, такими як IsoData, K-means, SVM, Minimum Distance, Maximum Likelihood та Parallelepiped. Результати демонструють, що технологія на основі ResNet досягає високої точності в сегментації основних класів земного покриття: сільськогосподарські культури, дерева, будівлі та дороги, що є важливим для ефективного моніторингу та управління земельними ресурсами.

**Ключові слова:** нейромережева сегментація, глибоке навчання, матриця неточностей, матриця помилок, оптичні супутникові знімки, модель ResNet.

### **Vita KASHTAN**

Candidate of Technical Science, Associate Professor, Associate Professor at the Information Technology and Computer Engineering Department, Dnipro University of Technology, 19, Dmytra Yavornytskoho Ave., Dnipro, Ukraine, 49005, kashtan.v.yu@nmu.one

**ORCID:** 0000-0002-0395-5895

**Scopus-AuthorID:** 57201902879

### **Volodymyr HNATUSHENKO**

Doctor of Technical Science, Professor, Head of the Information Technology and Computer Engineering Department, Dnipro University of Technology, 19, Dmytra Yavornytskoho Ave., Dnipro, Ukraine, 49005, hnatushenko.v.v@nmu.one

**ORCID:** 0000-0003-3140-3788

**Scopus Author ID:** 6505609275

### **Ivan LAKTIONOV**

Doctor of Technical Science, Associate Professor, Professor at the Department of Software Engineering, Dnipro University of Technology, 19, Dmytra Yavornytskoho ave., Dnipro, Ukraine, 49005, laktionov.i.s@nmu.one

**ORCID:** 0000-0001-7857-6382

**Scopus Author ID:** 57194557735

### **Grygorii DIACHENKO**

Ph.D, Associate Professor at the Department of Electric Drive, Dnipro University of Technology, 19, Dmytra Yavornytskoho Ave., Dnipro, Ukraine, 49005, diachenko.g@nmu.one

**ORCID:** 0000-0001-9105-1951

**Scopus Author ID:** 57201252081

**To cite this article:** Kashtan, V., Hnatushenko, V., Laktionov, I., Diachenko, G. (2024). Heoinformatsiina tekhnolohiia neiromerezhevoi sehmentatsii dlia kartohrafuvannia zemnoho pokryvu [Geoinformation technology neural network segmentation for land cover mapping]. *Information Technology: Computer Science, Software Engineering and Cyber Security*, 3, 51–62, doi: <https://doi.org/10.32782/IT/2024-3-6>

## **GEOINFORMATION TECHNOLOGY NEURAL NETWORK SEGMENTATION FOR LAND COVER MAPPING**

The relevance of developing modern technologies for land cover segmentation is growing due to increased requirements for accurate monitoring and management of land resources including for agricultural purposes. Traditional segmentation methods often lack accuracy in classifying complex classes such as crops, trees, buildings, and roads. **The work aims** to develop geographic information technology for extracting multiple features from Sentinel-2 satellite images and using them to segment the land cover using the ResNet neural network.

**Methodology.** This study uses Sentinel-2 images for land cover analysis. First, the images undergo pre-processing, which includes atmospheric correction and geometric and radiometric calibration. Then, data is normalized to improve the stability of the neural network training. At the next stage, the images are processed to extract spectral, morphological, and textural features, which are the input to the ResNet model. The model uses convolutional layers and the ReLU activation function to extract features automatically. A fully connected layer with Softmax and Cross-Entropy functions is used for classification. After training, the model classifies each pixel, creating a segmented image that shows different classes of land cover, including farmland, buildings, trees, and roads.

**The scientific novelty** of the research is the development of the latest methodology for processing Sentinel-2 satellite images, including integration of complex pre-processing, data normalization, multimodal feature extraction, and the use of deep neural networks for automatic feature extraction and classification. The new approaches to atmospheric, geometric, and radiometric correction, as well as the use of ResNet with ReLU activation and fully connected layers with Softmax and Cross-Entropy functions, improve the accuracy of classification and detail of land cover segmentation.

**Conclusions.** The study showed that the proposed technology provides a significant improvement in classification accuracy and quality compared to traditional methods such as IsoData, K-means, SVM, Minimum Distance, Maximum Likelihood, and Parallelepiped. The results demonstrate that the ResNet-based technology demonstrates high precision in segmenting the main land cover classes—crops, trees, buildings, and roads—which is crucial for effective land monitoring and management.

**Key words:** network segmentation, deep learning, confusion matrix, error matrix, optical satellite images, ResNet model.

**Вступ.** Точне та своєчасне володіння інформацією про сільськогосподарські землі, зокрема за допомогою створення карт земного покриття, є надзвичайно важливим для розвитку сучасного сільського господарства. Визначення площі та територіальне розміщення посівів є важливим для отримання необхідної аграрної інформації (Solórzano J.V., 2021). Традиційні методи сегментації земного покриття за допомогою польових вимірювань, досліджень та статистичних аналізів потребують значних людських та фінансових ресурсів (Zhang H., 2021). Завдяки стрімкому розвитку технологій дистанційного зондування Землі (ДЗЗ), зокрема підвищенню просторової та часової роздільної здатності зображень, багатоспектральні дані дистанційного зондування стали широко застосовуватися в аграрних дослідженнях (Peng X., 2021). Багатоспектральні дані відіграють важливу роль у моніторингу стану посівів, оцінці врожайності сільськогосподарських культур та моніторингу шкідників (Lianze T., Vincent G.). Однак, незважаючи на значний прогрес у космічних технологіях та збільшення кількості датчиків супутників спостереження Землі, створення детальних карт ґрунтового покриття залишається складним, трудомістким та тривалим процесом (Rakhlin A., 2018). Карти земного покриття зазвичай мають обмежену часову роздільну здатність, що ускладнює постійний моніторинг змін. Наприклад, продукти наземного покриття EU Corine (Bossard M., 2000) доступні лише для певних років, а останні продукти Європейського космічного агентства (ESA) WorldCover (Zanaga D., 2021) охоплюють лише 2020 та 2021 роки. Отже, існує необхідність у створенні машинних моделей, які можуть точно створювати карти земного покриття на основі супутникових даних, що дозволить покращити моніторинг змін та управління сільськогосподарськими ресурсами.

**Літературний огляд.** Традиційні методи сегментації поділяються на два основні типи: некерована та керована класифікація

(Makantasis K., 2015). Прикладом некерованої класифікації є методи, такі як K-середнє (K-means) та максимізація очікуваного значення (Expectation Maximization), які дозволяють створювати категорії для обробки даних, однак атрибути результатів класифікації залишаються невизначеними. Алгоритм IsoData, який є вдосконаленою версією K-means, дозволяє адаптивно змінювати кількість кластерів під час ітераційного процесу класифікації.

До методів керованої класифікації відносяться метод опорних векторів (SVM), дерева рішень, класифікація за максимальною правдоподібністю (Maximum Likelihood), метод мінімальної відстані (Minimum Distance) і паралелепіпедний метод (Parallelepiped). У цих методах параметри дискримінантної функції визначаються на основі відомих даних про елементи зображення. Після цього дискримінантна функція застосовується для класифікації невідомих елементів зображення, що забезпечує точність класифікації на основі навчальних даних.

Традиційні методи сегментації відзначаються високою повторюваністю та оперативністю порівняно з візуальною інтерпретацією даних. Але їх точність значно знижується при зміні даних або області дослідження (Xie C., 2022).

На відміну від класичних алгоритмів машинного навчання, глибинне навчання (ГН) демонструє унікальні переваги в класифікації зображень. Тоді як традиційні алгоритми машинного навчання вимагають ручної розробки ознак для завдань класифікації, глибинне навчання усуває необхідність у цьому; алгоритми на основі ГН автоматично навчаються і вилучають ознаки, що мають відношення до цільового завдання. Ця властивість автоматичного вилучення ознак забезпечує високу надійність моделей глибинного навчання та спрощує їх адаптацію до різних наборів даних (Kamilaris A., 2018). Крім того, алгоритми глибинного навчання можуть обробляти великі масиви даних, виявляючи

потенційні шаблони та закономірності, що сприяє підвищенню точності та ефективності класифікації земного покриву. Але незважаючи на переваги, які надає глибинне навчання, класифікація зображень у галузі дистанційного зондування часто обмежується через відсутність надійно маркованих наборів даних.

Один з найбільш досліджених і широко використовуваних наборів даних для класифікації зображень дистанційного зондування – це набір землекористування UC Merced (UCM), представлений в роботі (Yang Y., 2010). Набір даних містить 21 клас землекористування та земного покриву, з 100 зображеннями для кожного класу розміром 256x256 пікселів і з просторовою роздільною здатністю близько 30 см на піксель. Всі зображення мають колірний простір RGB і були отримані з колекції знімків міських територій Національної карти США, отриманих з літальних апаратів. Але, невелика кількість зображень на клас є значним обмеженням для використання цього набору даних у задачах класифікації.

Для покращення ситуації з набором даних, різні дослідження використовували комерційні зображення Google Earth для створення нових наборів даних (Zhao L., 2016). Наприклад, набори даних PatternNet (Zhou W., 2018) і NWPU-RESISC45 (Cheng G, 2017) базуються на зображеннях з дуже високою роздільною здатністю до 30 см на піксель. Однак, через складність і трудомісткість процесу створення маркованих наборів даних, ці набори даних також мають обмежену кількість зображень на клас, що варіюється від кількох сотень до кількох тисяч.

Одним з найбільших доступних наборів даних є набір аерофотознімків (Aerial Image Dataset, AID), який включає 30 класів, кожен з яких містить від 200 до 400 зображень розміром 600x600 пікселів, отриманих з Google Earth. Незважаючи на розширене покриття класів, використання комерційних і попередньо оброблених зображень обмежує їхню придатність для реальних програм спостереження Землі, таких як Sentinel-2.

Також, набір даних SAT-6, представлений в (Basu S., 2015) базується на аерофотознімках з просторовою роздільною здатністю 1 метр на піксель. Набір даних SAT-6 отримано з зображень Національної програми сільськогосподарських знімків (NAIP) і включає 6 класів: неродючі землі, дерева, луки, дороги, будівлі та водні об'єкти. Патчі зображень мають розмір 28x28 пікселів і представлені в червоному, зеленому, синьому та ближньому інфрачервоному діапазонах.

Порівняно з наборами даних, згаданими вище, розроблено новий набір даних, який використовує супутникові зображення з роздільною здатністю 10 метрів на піксель, що робить його більш відповідним для реальних програм спостереження Землі. Наш набір даних базується на знімках супутника Sentinel-2, що дозволяє включати значно більшу площу покриття.

**Мета дослідження:** розробка геоінформаційної технології для виділення множинних ознак із супутникових знімків Sentinel-2 та їх використання для сегментації земного покриття за допомогою нейронної мережі ResNet. Це дозволить підвищити точність та деталізацію класифікації різних типів земного покриття, таких як сільськогосподарські культури, дерева, об'єкти забудови та дороги, що в свою чергу сприяє поліпшенню моніторингу та управління земельними ресурсами.

**Виклад основного матеріалу.** У рамках дослідження було виконано наступні кроки: попередня обробка даних, вилучення спектральних, морфологічних і текстурних ознак з супутникових знімків, навчання глибокої нейронної мережі ResNet і сегментація зображень земного покриття. Алгоритм, що ілюструє роботу геоінформаційної технології, представлено на рисунку 1.

Знімки Sentinel-2 з 12 каналами після завантаження проходять етап попередньої обробки, який включає атмосферну корекцію, геометричне та радіометричне калібрування (Каштан В.Ю., 2024). Після цього дані приводяться до однакового масштабу для підвищення стабільності навчання нейронної мережі.

Наступним етапом є виділення множинних ознак: спектральних (містять інформацію про різні типи земного покриття), морфологічних (дозволяють виділяти структури та форми об'єктів на зображенні) та текстурних ознак (дозволяють визначати характеристики поверхні земного покриття), які служать входними даними для подальшої обробки в нейронній мережі. Це дозволяє моделі навчатися різноманітним зразкам, характерним для різних типів земного покриття. Ці етапи обробки виконуються як для попередньо оброблених, так і для первинних даних Sentinel-2.

Для навчання моделі підготовлено навчальні вибірки первинних даних супутника Sentinel-2 Дніпропетровщини до та після попередньої обробки. Вибірка містила класи: AnnualCrop (сільськогосподарські угіддя), Trees (дерева), Buildings (об'єкти забудови) та Roads (дороги). Кожне зображення мало розмір 64x64 пікселів,

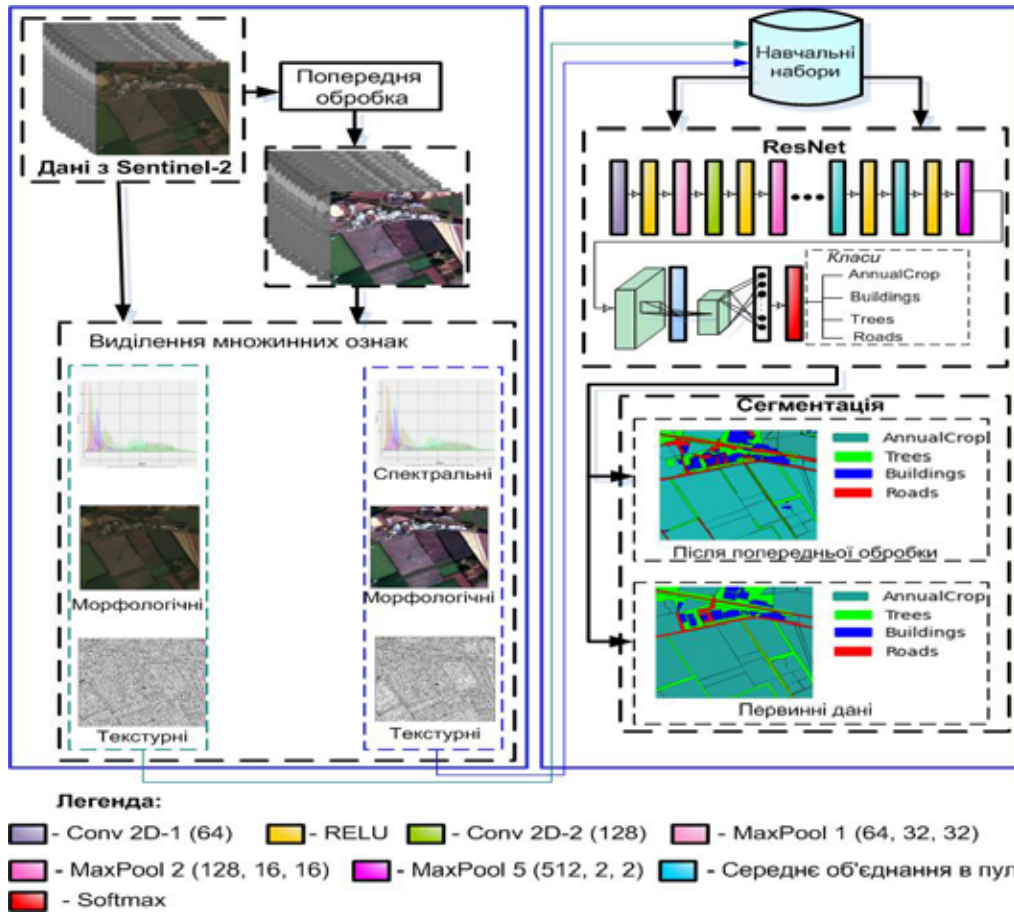


Рис. 1. Схема запропонованої геінформаційної технології

що дозволило забезпечити високу деталізацію та точність моделі.

Під час навчання виділені спектральні, морфологічні та текстурні ознаки подаються на вхід ResNet. Ця глибока нейронна мережа використовує послідовність конволюційних шарів для автоматичного виділення високорівневих ознак із вхідних зображень (Selmi L., 2022)

$$Y_{i,j} = \sum_{m=1}^M \sum_{n=1}^N x_{i+m-1,j+n-1} \cdot k_{m,n}, \quad (1)$$

де  $x$  – вхідне зображення,  $k$  – ядро конволюції,  $y$  – вихідне зображення.

Функція активації ReLU:

$$f(x) = \max(0, x) \quad (2)$$

На етапі класифікації виділені ознаки подаються на вхід повнозв'язного шару нейронної мережі. Повнозв'язний шар, або fully connected layer, здійснює кінцеву класифікацію на основі отриманих ознак, що дозволяє визначити належність кожного пікселя до одного з чотирьох класів: сільськогосподарські угіддя (AnnualCrop), будівлі (Buildings), дерева (Trees) та дороги (Roads). Функція втрат

для класифікації (Softmax та Cross-Entropy) (Selmi L., 2022):

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_j e^{z_j}} \quad (3)$$

$$\text{Cross-EntropyLoss} = -\sum_{i \in C} y_i \log(\hat{y}_i), \quad (4)$$

де  $y_i$  – істинна ймовірність класу,  $\hat{y}_i$  – передбачена ймовірність класу;  $C$  – множина всіх класів.

Адаптивне середнє пудлінгування (Selmi L., 2022):

$$y_{ij} = \frac{1}{|R|} \sum_{(m,n) \in R} x_{m,n}, \quad (5)$$

де  $y_{ij}$  – значення пікселя у вихідному зображенні після пулінгування;  $R$  – область усереднення, тобто область вхідного зображення, значення пікселів якої усереднюються;  $|R|$  – кількість елементів (пікселів) в області  $R$ ;  $x_{m,n}$  – значення пікселя у вхідному зображенні.

Модель навчається на підготовлених вибірках, оптимізуючи параметри за допомогою зворотного поширення помилки. Це дозволяє моделі адаптуватися до різноманітних варіацій

у даних та забезпечувати точну класифікацію типів земного покриття.

На основі результатів класифікації створюється сегментоване зображення, де кожному пікселю присвоюється клас. Це дозволяє візуально відобразити результати аналізу супутникових даних та забезпечити точну сегментацію земного покриття.

**Експерименти.** В роботі використано супутникові знімки Sentinel-2 Дніпропетровщини (рис. 2). На рисунку 3 наведено результати сегментації земного покриття, отримані за допомогою розробленої технології.

За результатами візуального аналізу можна зробити висновок, що класифікація земного покриття після попередньої обробки знімка та застосування нейронної мережі ResNet є значно чіткішою та точнішою у порівнянні з класифікацією на первинних даних супутникових знімків Sentinel-2.

У цьому дослідженні проведено порівняння різних методів сегментації, включаючи IsoData, K-means, SVM, Minimum Distance, Maximum Likelihood, Parallelepiped і запропонований метод на основі нейронної мережі. На рисунку 4 наведено результат сегментації класичними методами (IsoData, K-means, SVM, Minimum Distance, Maximum Likelihood, Parallelepiped) та запропонований метод (рис. 3 г) на основі нейронної мережі ResNet.

**Результати.** За результатами візуального аналізу, метод IsoData (рис. 4а) показує здатність розпізнавати основні ділянки з культурами

та деревами. Але, значні труднощі виникають при сегментації будівель та доріг, що призводить до змішування класів та знижує загальну точність методу. Метод K-means (рис. 4б) демонструє дещо вищу точність порівняно з IsoData. Культури та дерева класифікуються успішніше, але проблеми з розрізненням будівель та доріг все ще залишаються. Деякі області будівель і доріг змішані з іншими класами, що впливає на точність сегментації. Метод SVM (рис. 4в) демонструє вищу точність сегментації культур та дерев в порівнянні з IsoData та K-means. Метод Minimum-Distance (рис. 4г) демонструє нижчу точність порівняно з методами IsoData, K-means та SVM. Великі області пікселів були помилково класифіковані, особливо у класі доріг, що робить цей метод менш ефективним для задач сегментації. Метод Maximum-Likelihood (рис. 4г) показує кращі результати, ніж Minimum Distance, але все ще виникають значні проблеми з сегментацією доріг. Культури та дерева класифікуються успішно, а будівлі – з певними труднощами. Метод Parallelepiped (рис. 4д) стикається з значними труднощами при класифікації всіх класів. Велика частина пікселів була помилково класифікована, що знижує загальну ефективність методу. Запропонована технологія (рис. 3г) демонструє значно кращі результати порівняно з класичними підходами. Класи такі, як дерева, дороги, будівлі та культури, були чітко ідентифіковані, що свідчить про ефективність методів сегментації для супутникових знімків Sentinel-2.



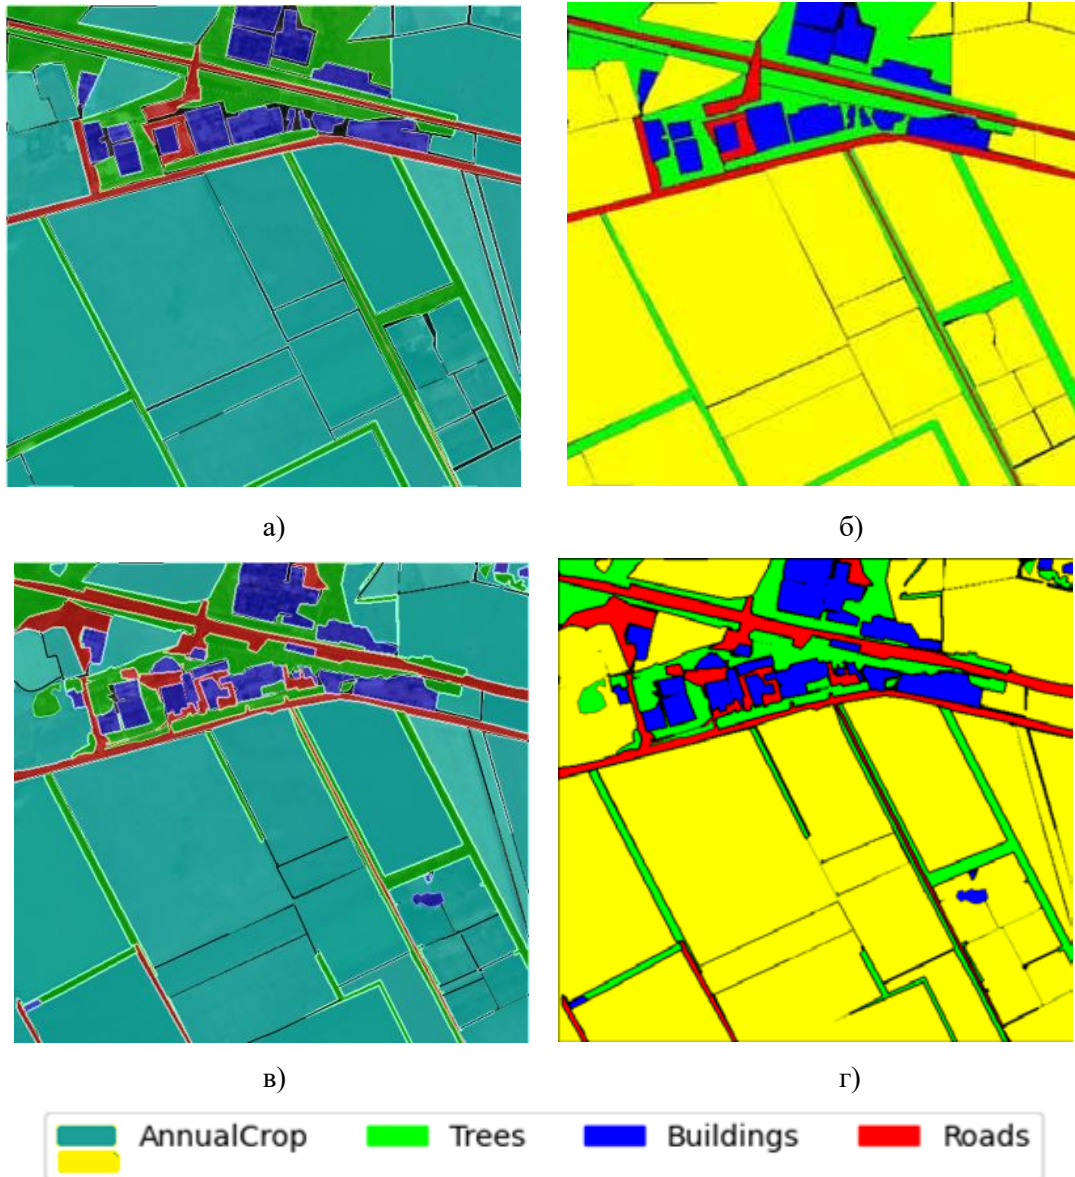
а)



б)

**Рис. 2.** Супутникові знімки космічного апарату Sentinel-2 синтезовані у R-G-B канали: а) первинний; б) після попередньої обробки



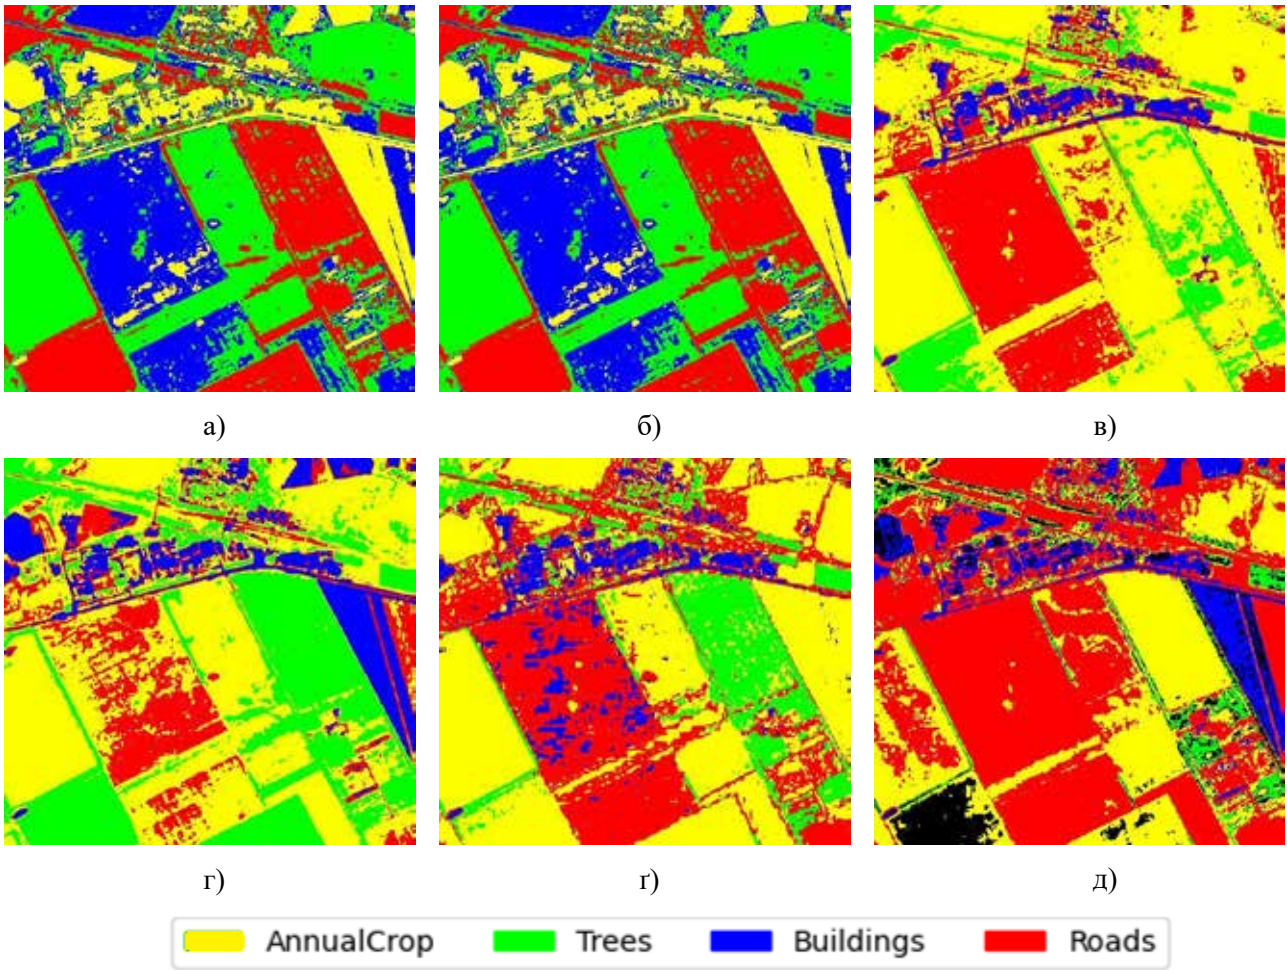


**Рис. 3. Результати сегментації земного покриву за даними Sentinel-2:**  
**а) первинний знімок; б) тематична карта для первинного знімку; в) знімок після обробки; г) тематична карта для знімку після застосування запропонованої технології**


На рисунку 5 представлено графіки динаміки зміни втрат (Loss) та точності (Accuracy) для тренувального і тестового наборів даних протягом 30 епох навчання нейронної мережі. Значне зниження втрат під час навчання (рис. 5а) спостерігається вже на перших епохах. З 0.5 на початку, втрати швидко зменшуються до приблизно 0.15 вже на 5-й епосі. Потім зниження продовжується повільнішими темпами, досягаючи 0.008 до кінця 30 епохи. Це свідчить про те, що модель добре навчається на навчальних даних. Точність під час навчання (рис. 5б) значно збільшується з 88% до приблизно 94% вже на перших епохах. Потім зростання продовжується більш поступово, досягаючи близько 99.9% до кінця 30-ї епохи. Це демонструє, що

модель успішно навчається на навчальних даних і здатна досягти високої точності.

Для кількісного аналізу побудовано матрицю невідповідностей (confusion matrix) (Rakhlin A., 2018), яка дозволила оцінити точність класифікації пікселів за чотирма класами: AnnualCrop, Trees, Buildings, і Roads (рис. 6). Матриця невідповідностей дозволяють детально оцінити точність сегментації різними методами. Для методу IsoData (рис. 6а) спостерігаються значні помилки при класифікації доріг (Roads), де більшість пікселів (74223) були неправильно класифіковані як AnnualCrop. Це свідчить про низьку точність для класу доріг (Roads). Метод K-means (рис. 6б) також показав помилки при класифікації доріг, але краща



**Рис. 4. Сегментація земного покриття для Sentinel-2: а) IsoData; б) K-means; в) SVM; г) Minimum Distance; г) Maximum Likelihood; д) Parallelepiped**



**Рис. 5. Графік динаміки зміни втрат та точності: а) тренувального набору; б) тестового набору**

точність у порівнянні з методом IsoData. SVM (рис. 6в) має найбільше помилок при класифікації доріг, але суттєво менше помилок для інших класів в порівнянні з методами K-means та IsoData. Метод Minimum Distance (рис. 6г) показав вищу точність при класифікації будівель (Buildings) і дерев (Trees), але все ще

мав значні помилки при класифікації доріг (69487 пікселів).

Для методу Maximum Likelihood (рис. 6г) спостерігається вища точність при класифікації доріг (37849 пікселів) у порівнянні з методами IsoData, K-means, SVM та Minimum Distance, але все ще залишається значна кількість



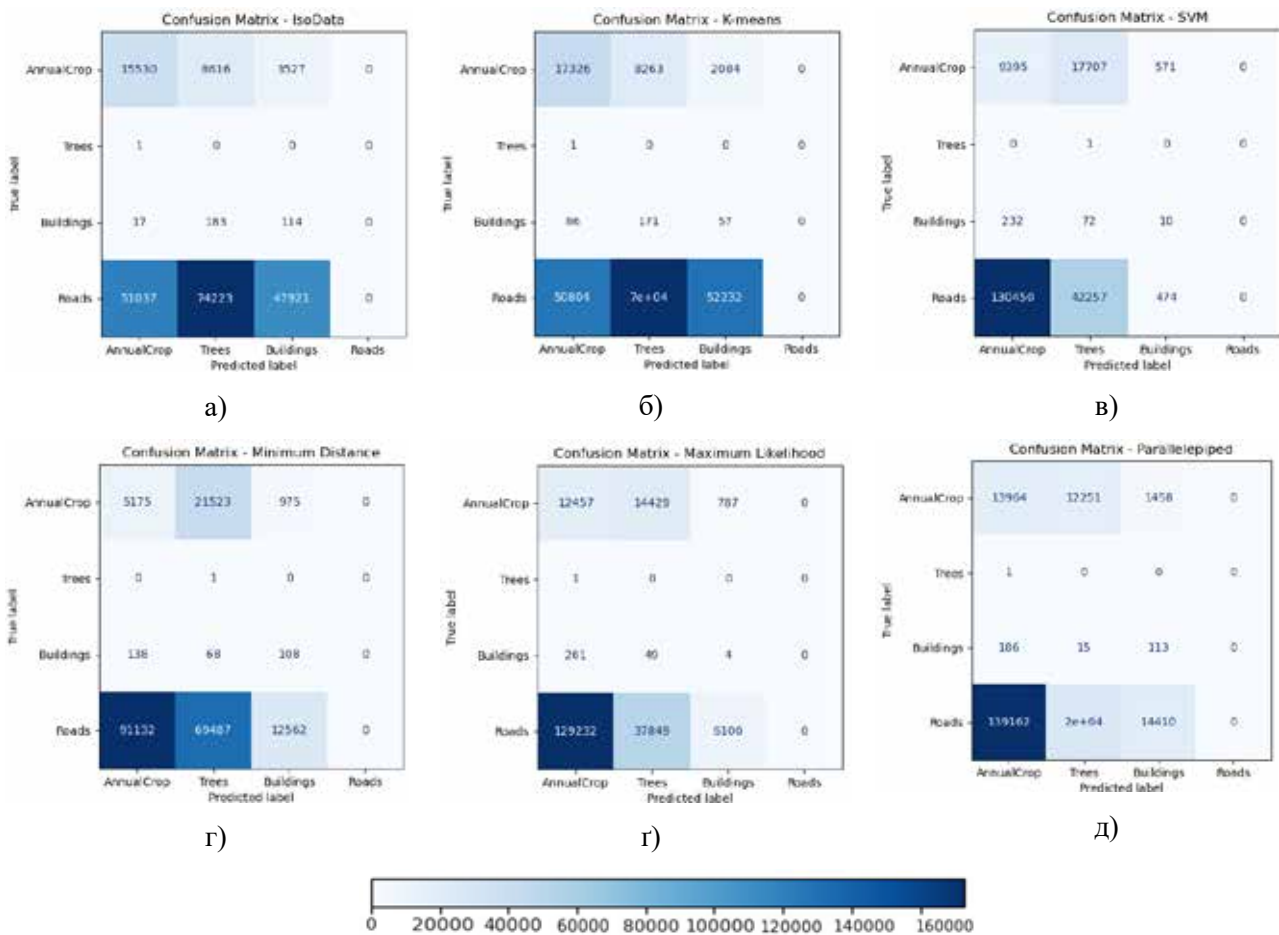


Рис. 6. Матриця невідповідностей для: а) IsoData; б) K-means; в) SVM; г) Minimum Distance; ґ) Maximum Likelihood; д) Parallelepiped

помилки при класифікації інших класів. Метод Parallelepiped (рис. 6д) показує найгірші результати серед класичних методів, з найбільшими помилками для всіх класів, зокрема для доріг (19609 пікселів). Запропонована технологія на основі нейронної мережі (рис. 7а) продемонструвала найкращі результати з мінімальними помилками для всіх класів. Всі пікселі були правильно класифіковані (AnnualCrop: 25831, Trees: 1, Buildings: 314, Roads: 172964), що вказує на високу точність технології.

Аналіз матриць помилок дозволяє виявити, які класи були неправильно класифіковані і в які інші класи вони були помилково віднесені (рис. 8). Метод IsoData (рис. 8а) показав значні помилки, зокрема для класу доріг (74223 пікселів), які були неправильно класифіковані як AnnualCrop. Метод K-means (рис. 8б) демонструє помилки, схожі на ті, що спостерігаються у методі IsoData, але з дещо покращеною точністю; кількість помилок для класифікації доріг становила 70145 пікселів. Метод SVM (рис. 8в) має найбільші помилки для класу доріг (130450 пікселів), але значно покращив точність для інших класів.

Minimum Distance (рис. 8г) демонструє кращі результати для класифікації будівель (68 пікселів) і дерев (0 пікселів), але зберігаються значні помилки для класу доріг (69487 пікселів). Метод Maximum Likelihood (рис. 8ґ) має кращі результати для класифікації доріг порівняно з іншими методами, але все ще спостерігається значна кількість помилок, зокрема для класу дерев (Trees). Метод Parallelepiped (рис. 8д) відзначився найбільшими помилками серед усіх методів, зокрема для класифікації доріг, де було виявлено 19609 помилкових пікселів. Запропонована технологія на основі нейронної мережі (рис. 7б) продемонструвала найкращі результати з мінімальними помилками для всіх класів. Це вказує на високу точність і ефективність у порівнянні з класичними методами.

**Висновки.** Розроблено геоінформаційну технологію нейромережевої сегментації для картографування земного покриву. В роботі досліджено класи земного покриву, зокрема сільськогосподарські культури (AnnualCrop), дерева (Trees), будівлі (Buildings) та дороги (Roads). Для реалізації технології було

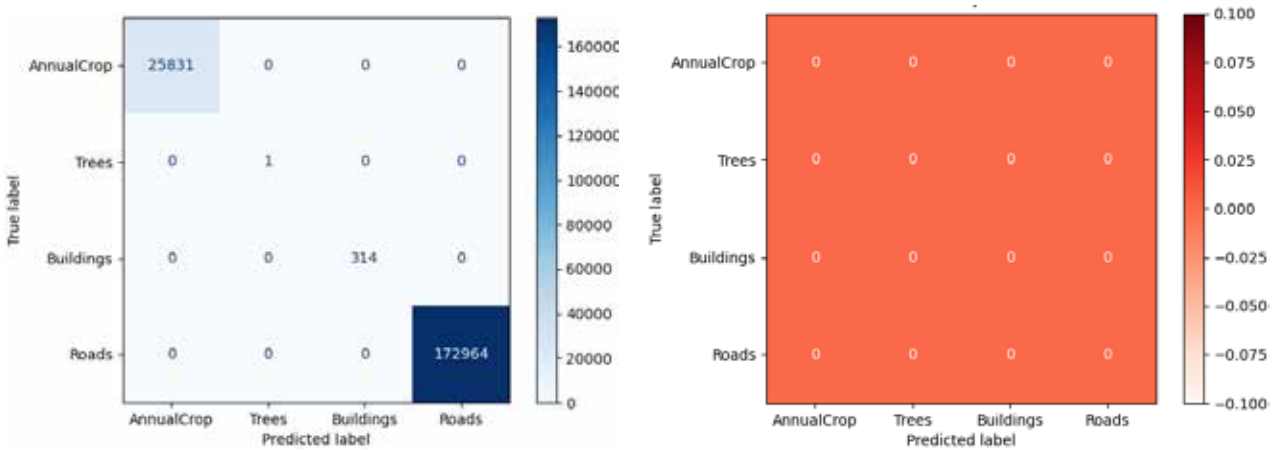


Рис. 7. Кількісні показники запропонованої технології:  
а) матриця невідповідностей; б) матриця помилок

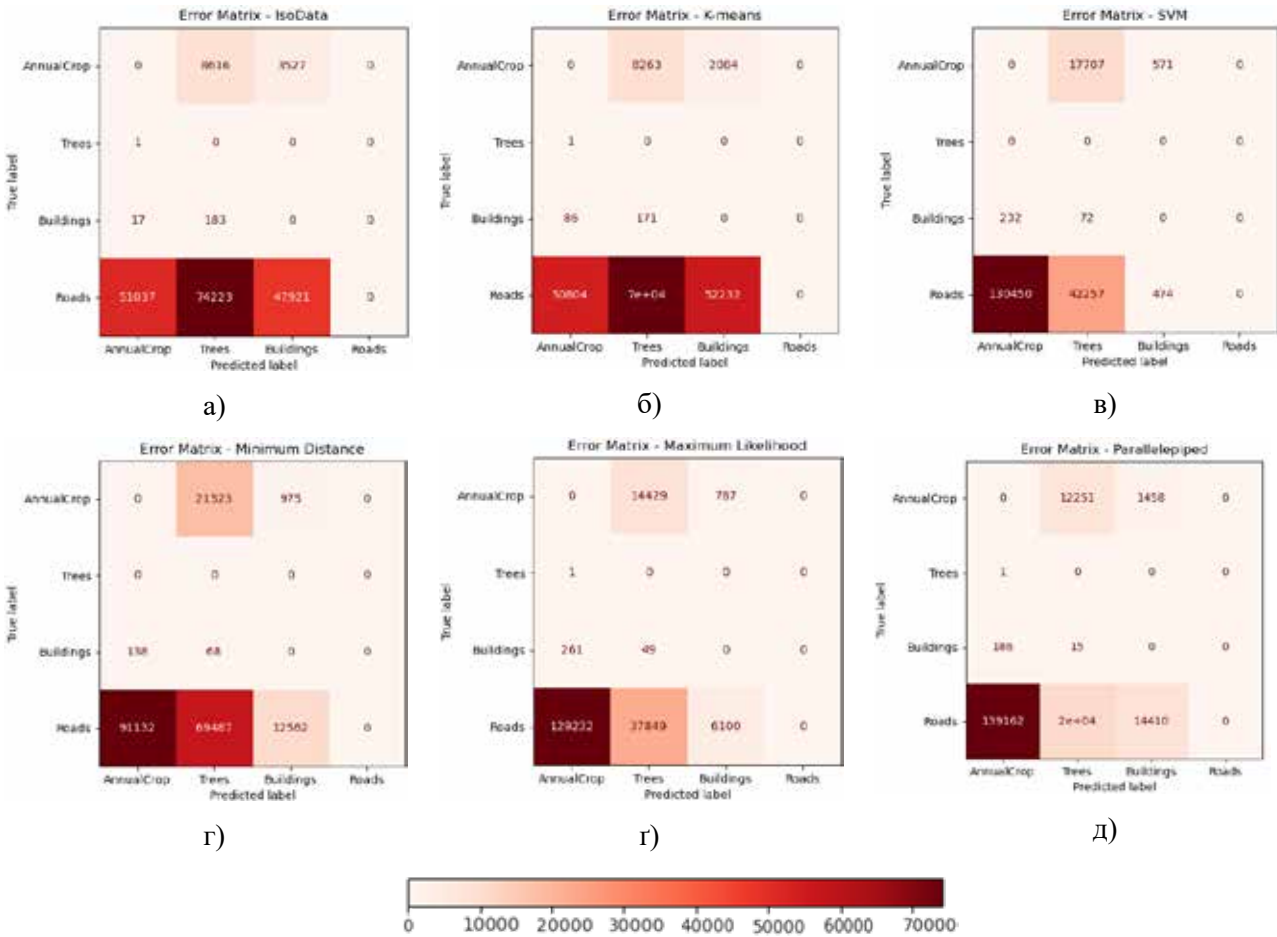


Рис. 8. Матриця помилок для: а) IsoData; б) K-means; в) SVM; г) Minimum Distance; г) Maximum Likelihood; д) Parallelepiped

використано модель ResNet, яка була навчена на даних супутника Sentinel-2 для Дніпропетровщини, що включають ці класи, з метою забезпечення точності їх класифікації.

Дослідження показало, що технологія на основі нейронної мережі ResNet

значно перевищує традиційні методи сегментації за точністю та якістю класифікації. Традиційні методи, такі як IsoData, K-means, SVM, Minimum Distance, Maximum Likelihood та Parallelepiped мають суттєві обмеження, зокрема при сегментації доріг,

сільськогосподарських культур, що підтверджено аналізом матриць невідповідностей і помилок.

Якість та точність сегментації значно залежать як від первинних даних, так і від їх попередньої обробки. Попередня обробка даних, включаючи атмосферну корекцію, геометричне та радіометричне калібрування, а також нормалізація масштабів, має важливе значення для досягнення високої точності сегментації. Запропонована технологія демонструє високий рівень точності та ефективності у сегментації всіх класів земного покриву: сільськогосподарські культури (25831 піксель), дерева (1 піксель), будівлі (314 пікселів), дороги (172964

пікселі). Це свідчить про високу точність і ефективність сегментації.

Таким чином, використання моделі ResNet в поєднанні з виконаною попередньою обробкою первинних даних оптичного супутника Sentinel-2 демонструє суттєве покращення результатів сегментації зображень, підтверджуючи переваги сучасних нейронних мереж у порівнянні з традиційними методами.

Дослідження статті виконані в рамках науково-дослідної теми «Розвиток програмно-апаратного забезпечення інтелектуальних технологій для сталого вирощування сільськогосподарських культур у воєнний та повоєнний час» (номер держреєстрації 0124U000289).

#### ЛІТЕРАТУРА:

1. Solórzano J. V., Mas J. F., Gao Y., Gallardo-Cruz J. A. Land Use Land Cover Classification with U-Net: Advantages of Combining Sentinel-1 and Sentinel-2 Imagery. *Remote Sens.* 2021, 13, 3600
2. Zhang H., Wang L., Tian T., Yin J. A Review of Unmanned Aerial Vehicle Low-Altitude Remote Sensing (UAV-LARS) Use in Agricultural Monitoring in China. *Remote Sens.* 2021, 13, 1221.
3. Peng X., Han W., Ao J., Wang Y. Assimilation of LAI Derived from UAV Multispectral Data into the SAFY Model to Estimate Maize Yield. *Remote Sens.* 2021, 13, 1094.
4. Lianze T., Yong L., Hongji Z., Sijia L. Summary of UAV Remote Sensing Application Research in Agricultural Monitoring. *Sci. Technol. Inf.* 2018, 16, 122–124.
5. Vincent G., Antin C., Laurans M., Heurtebize J., Durrieu S., Lavalley C., Dautat J. Mapping plant area index of tropical evergreen forest by airborne laser scanning. A cross-validation study using LAI2200 optical sensor. *Remote. Sens. Environ.* 2017, 198, 254–266.
6. Rakhlin A., Davydov A., Nikolenko S. Land cover classification from satellite imagery with u-net and lovasz-softmax loss. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Salt Lake City, UT, USA, 18–22 June 2018, 262–266.
7. Bossard M., Feranec J., Otahel J. CORINE Land Cover Technical Guide: Addendum; European Environment Agency: Copenhagen, Denmark, 2000; Volume 40.
8. Zanaga D., Van De Kerchove R., De Keersmaecker W., Souverijns N., Brockmann C., Quast R., Wevers J., Grosu A., Paccini A., Vergnaud S., et al. ESA WorldCover 10 m 2020 v100; OpenAIRE: Los Angeles, CA, USA, 2021.
9. Makantasis K., Karantzalos K., Doulamis A., Doulamis N. Deep supervised learning for hyperspectral data classification through convolutional neural networks. In *Proceedings of the 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Milan, Italy, 2015, 4959–4962
10. Xie C., Zhu H., Fei Y. Deep coordinate attention network for single image super-resolution. *IET Image Process.* 2022, 16, 273–284.
11. Kamilaris A., Prenafeta-Boldú F.X. Deep learning in agriculture: A survey. *Comput. Electron. Agric.* 2018, 147, 70–90.
12. Yang Y., Newsam S. Bag-of-visual-words and spatial extensions for land-use classification. In *Proceedings of the 18th SIGSPATIAL international conference on advances in geographic information systems*, ACM, 2010, 270–279.
13. Zhao L., Tang P., Huo L. Feature significance-based multibag-of-visual-words model for remote sensing image scene classification. *Journal of Applied Remote Sensing*, 10(3):035004–035004, 2016.
14. Zhou W., Newsam S., Li C., Shao Z. Patternnet: a benchmark dataset for performance evaluation of remote sensing image retrieval. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018.
15. Cheng G., Han J.i, and Lu X. Remote sensing image scene classification: benchmark and state of the art. *Proceedings of the IEEE*, 105(10):1865–1883, 2017.
16. Basu S., Ganguly S., Mukhopadhyay S., DiBiano R., Karki M., Nemani R. DeepSAT: a learning framework for satellite imagery. In *Proceedings of the 23rd SIGSPATIAL International Conference on Advances in Geographic Information Systems*, ACM, 2015, 37.

17. Каштан В. Ю., Шевцова О. С. Інформаційна технологія попередньої обробки супутникових зображень з використанням згорткової нейронної мережі. *Системні технології. Регіональний міжвузівський збірник наукових робіт*. – Випуск 1 (150). Дніпро, 2024. С. 36–50. DOI: 10.34185/1562-9945-1-150-2024-04.
18. Selmi L. Land Use and Land Cover Classification using a ResNet Deep Learning Architecture, 2022.

#### REFERENCES:

1. Solórzano, J. V., Mas, J. F., Gao, Y., Gallardo-Cruz, J. A. (2021). Land Use Land Cover Classification with U-Net: Advantages of Combining Sentinel-1 and Sentinel-2 Imagery. *Remote Sens*, 13, 3600
2. Zhang, H., Wang, L., Tian, T., Yin, J. (2021). A Review of Unmanned Aerial Vehicle Low-Altitude Remote Sensing (UAV-LARS) Use in Agricultural Monitoring in China. *Remote Sens*, 13, 1221.
3. Peng, X., Han, W., Ao, J., Wang, Y. (2021). Assimilation of LAI Derived from UAV Multispectral Data into the SAFY Model to Estimate Maize Yield. *Remote Sens*, 13, 1094.
4. Lianze, T., Yong, L., Hongji, Z., Sijia, L. (2018). Summary of UAV Remote Sensing Application Research in Agricultural Monitoring. *Sci. Technol*, 16, 122–124.
5. Vincent, G., Antin, C., Laurans, M., Heurtebize, J., Durrieu, S., Lavalley, C., Dauzat, J. (2017). Mapping plant area index of tropical evergreen forest by airborne laser scanning. A cross-validation study using LAI2200 optical sensor. *Remote. Sens. Environ*, 198, 254–266.
6. Rakhlin, A., Davydow, A., Nikolenko, S. (2018). Land cover classification from satellite imagery with u-net and lovász-softmax loss. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, Salt Lake City, UT, USA, 262–266.
7. Bossard, M., Feranec, J., Otahel, J. (2000). CORINE Land Cover Technical Guide: Addendum; European Environment Agency: Copenhagen, Denmark, Volume 40.
8. Zanaga, D., Van De Kerchove, R., De Keersmaecker, W., Souverijns, N., Brockmann, C., Quast, R., Wevers, J., Grosu, A., Paccini, A., Vergnaud, S., et al. (2021). ESA WorldCover 10 m 2020 v100; OpenAIRE: Los Angeles, CA, USA.
9. Makantasis, K., Karantzalos, K., Doulamis, A., Doulamis, N. (2015). Deep supervised learning for hyperspectral data classification through convolutional neural networks. In Proceedings of the 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Milan, Italy, 4959–4962
10. Xie, C., Zhu, H., Fei, Y. (2022). Deep coordinate attention network for single image super-resolution. *IET Image Process*, 16, 273–284.
11. Kamilaris, A., Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Comput. Electron. Agric*, 147, 70–90.
12. Yang, Y., Newsam, S. (2010). Bag-of-visual-words and spatial extensions for land-use classification. In Proceedings of the 18th SIGSPATIAL international conference on advances in geographic information systems, ACM, 270–279.
13. Zhao, L., Tang, P., Huo, L. (2016). Feature significance-based multibag-ofvisual-words model for remote sensing image scene classification. *Journal of Applied Remote Sensing*, 10(3):035004–035004.
14. Zhou, W., Newsam, S., Li, C., Shao, Z. (2018). Patternnet: a benchmark dataset for performance evaluation of remote sensing image retrieval. *ISPRS Journal of Photogrammetry and Remote Sensing*.
15. Cheng, G., Han, J. i, & Lu, X. (2017). Remote sensing image scene classification: benchmark and state of the art. Proceedings of the IEEE, 105(10):1865–1883.
16. Basu, S., Ganguly, S., Mukhopadhyay, S., DiBiano, R., Karki, M., Nemani, R. (2015). DeepSAT: a learning framework for satellite imagery. In Proceedings of the 23rd SIGSPATIAL International Conference on Advances in Geographic Information Systems, ACM, 37.
17. Kashtan, V. Yu., Shevtsova, O. S. (2024). Інформаційна технологія попередньої обробки супутникових зображень з використанням згорткової нейронної мережі. *Системні технології. Регіональний міжвузівський збірник наукових робіт*. – Випуск 1 (150), 36 – 50. DOI: 10.34185/1562-9945-1-150-2024-04. [in Ukrainian].
18. Selmi, L. (2022). Land Use and Land Cover Classification using a ResNet Deep Learning Architecture.