

Царинюк О. В.

## ЗАСТОСУВАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ КЛАСИФІКАЦІЇ СУПУТНИКОВИХ ЗОБРАЖЕНЬ: ОГЛЯД ЛІТЕРАТУРИ ТА КЛЮЧОВИХ ФРЕЙМВОРКІВ

*У розвитку цифрових технологій і космічної галузі значущу роль відведено ефективному аналізу супутникових зображень. У цій статті докладно розглянуто методи машинного навчання, які застосовують для класифікації таких зображень, а також для вивчення ключових інструментів і фреймворків, які активно використовують у цьому напрямі. В основі дослідження — аналіз сучасних підходів до класифікації, зокрема за допомогою глибоких нейронних мереж. Окремий розділ присвячено популярним фреймворкам, як-от PyTorch, TensorFlow тощо, їхнім особливостям під час роботи з геоданими. Для об'єктивності подано літературний огляд відомих досліджень і робіт, що вплинули на розвиток цієї галузі.*

**Ключові слова:** машинне навчання, класифікація зображень, супутникові знімки, глибоке навчання, згорткові нейронні мережі, PyTorch, TensorFlow, ГІС.

### Вступ

В епоху цифрової трансформації актуальність і точність геоданих стають вирішальними для безлічі сфер, від містобудування до екологічного моніторингу. Цифрові карти, які використовують у найрізноманітніших галузях, потрібно постійно оновлювати й уточнювати. Географічні інформаційні системи (ГІС) є ключовим інструментом у цьому процесі, а швидкість та якість оброблення геоданих визначають їхню конкурентоспроможність.

Розвиток космічних технологій і методів дистанційного зондування надає можливість отримувати дедалі більше високодеталізованих супутникових зображень Землі, що стають основою для формування геоданих і створення цифрових карт. Проте перетворення цих супутникових зображень на векторизовані геодані залишається трудомістким завданням, що потребує значних ресурсів.

Машинне навчання відкриває нові горизонти для автоматизації процесів розпізнавання та векторизації супутникових зображень. Застосування сучасних алгоритмів і фреймворків машинного навчання може в разі зменшити витрати часу та людських ресурсів на виробництво геоданих, а також забезпечити більшу точність і масштабованість оброблення.

У цій статті проведено комплексний огляд методів машинного навчання, які застосовують для розпізнавання супутникових зображень,

а також проаналізовано основні фреймворки, що використовують у цій галузі.

### Методи машинного навчання

Класифікація об'єктів на супутникових зображеннях за допомогою методів машинного навчання — це комплексний процес, який складається з кількох етапів: навчання класифікатора та власне класифікації зображення. Ці етапи відіграють важливу роль у розпізнаванні об'єктів і можуть бути реалізовані різними методами.

Класифікація полягає у наданні кожному пікселю растрового зображення певної категорії або класу на основі його спектральних характеристик.

Нижче розглянуто основні підходи з використанням технологій машинного навчання.

*Histogram of Oriented Gradients* (HOG, гістограма орієнтованих градієнтів) — це техніка визначення ознак (features extraction) на зображеннях, яку часто використовують у завданнях комп'ютерного зору.

Основна ідея HOG полягає в отриманні інформації про градієнти (напрямок зміни інтенсивності) в різних частинах зображення. Надалі інформація компонується у формі гістограми.

HOG є дуже ефективним для виявлення об'єктів, наприклад людських облич або пішохідів. Першу пропозицію щодо використання ознаки HOG як методу розпізнавання об'єктів зробили Dalal і Triggs у 2005 р. [4, р. 886].

Цю методику часто використовують у поєднанні з класифікаторами, як-от SVM (машини опорних векторів), для виявлення об'єктів на зображеннях.

*Support Vector Machine* (SVM, машина опорних векторів) — це лінійний бінарний класифікатор, який може бути також використаний для регресії та виявлення змін класів. Основна ідея SVM — знаходження «оптимальної гіперплощини», яка найкраще розділяє два класи даних. Цей метод було запропоновано у статті «An Overview of Statistical Learning Theory» [14, p. 988], зараз його широко використовують для виявлення доріг [5, p. 3906; 6, p. 1977; 12, p. 1365].

*Artificial Neural Network* (ANN, штучна нейронна мережа) було запропоновано на початку 1980-х рр. Вона має здатність розпізнавати патерни, складність яких робить їх важкими для аналізу за допомогою інших звичайних підходів [2, p. 11].

Деякі типові архітектури нейронних мереж, наприклад згорткові нейронні мережі (Convolutional Neural Network, CNN) [7, p. 1422], з успіхом використовують у багатьох додатках дистанційного зондування, зокрема для виявлення доріг [10, p. 32; 15, p. 3144].

### Згорткові нейронні мережі

Великі обсяги супутникових даних потребують ефективних методів оброблення, щоб перетворити ці дані на корисну інформацію. Згорткові нейронні мережі (ЗНМ) демонструють високу ефективність у низці завдань зорового розпізнавання і, як показали дослідження, можуть бути особливо корисними для розпізнавання растрових зображень. На сьогодні існує велика кількість наукових публікацій, у яких досліджено й підтверджено ефективність згорткових нейронних мереж для задач розпізнавання супутникових знімків.

У статті «Imagenet classification with deep convolutional neural networks» [8, p. 84] було представлено архітектуру AlexNet, яка суттєво випередила інші методи на конкурсі ImageNet у 2012 р. й стала однією з основних робіт, що популяризувала використання ЗНМ для задач розпізнавання зображень.

У статті «Remote Sensing Image Scene Classification: Benchmark and State of the Art» зроблено огляд методів класифікації сцен супутникових знімків, з акцентом на глибокі методи навчання, зокрема ЗНМ [3, p. 1865].

Однією з найбільш упізнаваних архітектур у контексті семантичної сегментації є U-net [11, p. 1]. Початково розроблена для задач мікроско-

пії клітин, ця архітектура показала свою ефективність у вирішенні завдань, у яких потрібно виконувати високоточну локалізацію. Специфіка архітектури U-net, що містить етапи стиснення та розширення, робить її особливо придатною для задач, де важлива просторова інформація, що є характерним для супутникових знімків.

Серед прикладів успішного використання U-net для розпізнавання супутникових зображень можна згадати такі публікації. У статті «M-UNet: Modified U-Net Segmentation Framework with Satellite Imagery» [13, p. 47] було запропоновано модифіковану архітектуру U-Net, яка використовує отримання контекстної інформації з супутникових зображень. У статті «Deep learning for classification of hyperspectral data: A comparative review» [1, p. 159] подано огляд глибокого навчання для класифікації гіперспектральних даних з акцентом на архітектури, наприклад U-net. У статті «Application of UNet Fully Convolutional Neural Network to Impervious Surface Segmentation in Urban Environment from High Resolution Satellite Imagery» [9, p. 3915] описано застосування архітектури U-Net для автоматичного розпізнавання різних типів поверхонь на супутникових знімках високої роздільної здатності.

Високу ефективність ЗНМ у розв'язанні задач розпізнавання і класифікації супутникових знімків зумовлено такими факторами:

- *ієрархічне представлення даних*: ЗНМ автоматично навчаються ієрархічним способом, виявляючи низькорівневі ознаки (як-от краї або текстури) в початкових шарах і складніші абстракції в глибших шарах;
- *локальність і неперервність*: завдяки операції згортки ЗНМ здатні концентруватися на локальних ознаках зображення, що є особливо корисним для аналізу супутникових знімків, де об'єкти можуть мати різний розмір та орієнтацію;
- *масштабованість*: ЗНМ можуть ефективно обробляти великі зображення, які часто трапляються в супутникових знімках;
- *Transfer Learning*: ЗНМ дають змогу використовувати попередньо навчені моделі на великих наборах даних (наприклад, ImageNet) для специфічних задач супутникового розпізнавання з меншою кількістю даних.

Однак твердження, що ЗНМ — це найефективніший метод для всіх задач розпізнавання супутникових знімків, може бути занадто загальним. Залежно від конкретної задачі, роздільної здатності зображення, доступних даних для

навчання та інших факторів, інші методи машинного навчання або комбінації методів можуть бути також доречними.

### Огляд фреймворків для машинного навчання

Для сучасного моделювання та реалізації алгоритмів машинного навчання дослідники та розробники мають використовувати продуктивні й адаптивні інструменти. У цьому розділі розглянуто провідні фреймворки у сфері машинного навчання.

*PyTorch* — це відкрита платформа для глибокого навчання, розроблена командою Facebook's AI Research (FAIR). Вона надає динамічний граф обчислень, що робить його дуже корисним для дослідження.

Особливості:

- динамічний граф обчислень;
- інтуїтивний API для створення та навчання моделей;
- ефективна інтеграція з CUDA для прискореного обчислення на GPU;
- широкий спектр вбудованих функцій для глибокого навчання.

*TensorFlow* — це відкритий фреймворк для машинного навчання, розроблений командою Google Brain. Його можна використовувати для різних задач, від класичних алгоритмів машинного навчання до глибокого навчання.

Особливості:

- статичний граф обчислень, хоча з інтродукцією TensorFlow 2.x було додано підтримку динамічних графів за допомогою tf.eager;
- розширена інтеграція з TensorBoard для візуалізації та моніторингу;
- підтримка для розподілених обчислень і робота на мобільних пристроях.

*Keras* — високорівневий інтерфейс для створення моделей глибокого навчання, який можна виконувати на основі TensorFlow, Theano або CNTK.

*Caffe* — відкритий фреймворк, який в основному використовують для задач, пов'язаних із зображеннями. Розроблений у Каліфорнійському університеті в Берклі.

*MXNet* — гнучкий фреймворк для глибокого навчання, що підтримує різні мови програмування.

*Theano* — один із перших фреймворків для глибокого навчання, нині не дуже активно розробляється, але відіграв важливу роль у становленні екосистеми глибокого навчання.

З-поміж численних доступних фреймворків машинного навчання вибір оптимального інструменту часто визначається специфічними потребами та вимогами до вашого проекту. Попри велике різноманіття опцій, PyTorch і TensorFlow залишаються на вершині популярності. Це можна пояснити їхньою гнучкістю, високою продуктивністю та активними спільнотами розробників і користувачів.

Розглядаючи питання вибору фреймворку з погляду оброблення геоданих, PyTorch вирізняється завдяки інтеграції з системою ArcGIS. Така комбінація надає дослідникам і фахівцям можливість використовувати єдину платформу для всього процесу: від оброблення геоданих до тренування та впровадження моделей. Особливо важливо зазначити, що ArcGIS надає засоби для роботи з просторовими зображеннями у відповідних координатах, у TensorFlow такої можливості немає.

### Висновки

Процес оброблення супутникових знімків завжди супроводжується викликами, зумовленими великою кількістю даних, неоднорідністю ландшафту та змінами у земних покриттях. Традиційні методи часто виявляються часомісткими й потребують великої кількості ручної роботи. З появою та розвитком методів машинного навчання, зокрема глибокого навчання, стало можливим значно автоматизувати процеси розпізнавання та класифікації.

Аналіз, представлений у цій статті, демонструє, що сучасні алгоритми, як-от ANN і ЗНМ, можуть значно підвищити ефективність оброблення зображень. Однак, як і у всіх інших галузях, важливо вибрати правильний інструмент для конкретної задачі.

PyTorch, завдяки своїй інтеграції з ArcGIS, є відмінним інструментом для роботи з геоданими. Однак TensorFlow і інші фреймворки також можуть виявитися корисними залежно від специфіки задачі та вимог.

Враховуючи швидкий розвиток технологій і постійні наукові дослідження у сфері машинного навчання, можна очікувати появи нових, ще більш удосконалених методів і технік у найближчому майбутньому. Незалежно від вибраного методу або фреймворку, головною метою залишається покращення якості та швидкості аналізу геоданих для різноманітних застосувань, від моніторингу навколишнього середовища до міського планування.

## Список літератури

1. Audebert Nicolas. Deep Learning for Classification of Hyperspectral Data: A Comparative Review / Nicolas Audebert, Bertrand Le Saux, Sebastien Lefevre // *IEEE Geoscience and Remote Sensing Magazine*. — 2019. — Vol. 7 (2). — Pp. 159–173.
2. Cheng Gong. A Survey on Object Detection in Optical Remote Sensing Images / Gong Cheng, Junwei Han // *ISPRS Journal of Photogrammetry and Remote Sensing: Official Publication of the International Society for Photogrammetry and Remote Sensing*. — 2016. — Vol. 117 (July). — Pp. 11–28.
3. Cheng Gong. Remote Sensing Image Scene Classification: Benchmark and State of the Art / Gong Cheng, Han Junwei, Xiaoqiang Lu // *Proceedings of the IEEE*. — 2017. — Vol. 105 (10). — Pp. 1865–1883.
4. Dalal N. Histograms of Oriented Gradients for Human Detection / N. Dalal, B. Triggs // *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. — 2005. — Vol. 1. — Pp. 886–893.
5. Das Sukhendu. Use of Salient Features for the Design of a Multistage Framework to Extract Roads From High-Resolution Multispectral Satellite Images / Sukhendu Das, T. T. Mirmalinee, Koshy Varghese // *IEEE Transactions on Geoscience and Remote Sensing: A Publication of the IEEE Geoscience and Remote Sensing Society*. — 2011. — Vol. 49 (10). — Pp. 3906–3931.
6. Huang Xin. Road Centreline Extraction from High-resolution Imagery Based on Multiscale Structural Features and Support Vector Machines / Xin Huang, Liangpei Zhang // *International Journal of Remote Sensing*. — 2009. — Vol. 30 (8). — Pp. 1977–1987.
7. Jin Xiaoying. Vehicle Detection from High-Resolution Satellite Imagery Using Morphological Shared-Weight Neural Networks / Xiaoying Jin, Curt H. Davis // *Image and Vision Computing*. — 2007. — Vol. 25 (9). — Pp. 1422–1431.
8. Krizhevsky Alex. Imagenet Classification with Deep Convolutional Neural Networks [Electronic resource] / Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton // *Advances in Neural Information Processing Systems*. — 2012. — Vol. 25. — Mode of access: <https://proceedings.neurips.cc/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html>.
9. McGlinchy. Application of UNet Fully Convolutional Neural Network to Impervious Surface Segmentation in Urban Environment from High Resolution Satellite Imagery / Joe McGlinchy, Brian Johnson, Brian Muller, Maxwell Joseph, Jeremy Diaz // *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*. — IEEE, 2019. — Pp. 3915–3918.
10. Mokhtarzade M. Road Detection from High-Resolution Satellite Images Using Artificial Neural Networks / M. Mokhtarzade, M. J. Valadan Zojj // *International Journal of Applied Earth Observation and Geoinformation*. — 2007. — Vol. 9 (1). — Pp. 32–40.
11. Ronneberger Olaf. U-Net: Convolutional Networks for Biomedical Image Segmentation [Electronic resource] / Olaf Ronneberger, Philipp Fischer, Thomas Brox // *arXiv [cs.CV]*. 2015. — Mode of access: <http://arxiv.org/abs/1505.04597>.
12. Song Ming Jun. Road Extraction Using SVM and Image Segmentation / Ming Jun Song, Daniel Civco. — *Photogrammetric Engineering & Remote Sensing*. — 2004. — No. 12. — Pp. 1365–1371.
13. Soni Ashish. M-Net: Modified U-Net Segmentation Framework with Satellite Imagery / Ashish Soni, Radhakanta Koner, Vasant Govind Kumar Villuri // *Proceedings of the Global AI Congress 2019*. — Springer Singapore, 2020. — Pp. 47–59.
14. Vapnik V. N. An Overview of Statistical Learning Theory / V. N. Vapnik // *IEEE Transactions on Neural Networks*. — 1999. — Vol. 10 (5). — Pp. 988–999.
15. Wang Jun. Road Network Extraction: A Neural-Dynamic Framework Based on Deep Learning and a Finite State Machine / Jun Wang, Jingwei Song, Mingquan Chen, Zhi Yang // *International Journal of Remote Sensing*. — 2015. — Vol. 36 (12). — Pp. 3144–3169.

## References

- Audebert, N., Le Saux, B., & Lefevre, S. (2019). Deep Learning for Classification of Hyperspectral Data: A Comparative Review. *IEEE Geoscience and Remote Sensing Magazine*, 7 (2), 159–173.
- Cheng, G., & Han, J. (2016). A survey on object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing: Official Publication of the International Society for Photogrammetry and Remote Sensing*, 117, 11–28.
- Cheng, G., Han, J., & Lu, X. (2017). Remote Sensing Image Scene Classification: Benchmark and State of the Art. *Proceedings of the IEEE*, 105 (10), 1865–1883.
- Dalal, N., & Triggs, B. (2005). Histograms of oriented gradients for human detection. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, 1, 886–893.
- Das, S., Mirmalinee, T. T., & Varghese, K. (2011). Use of Salient Features for the Design of a Multistage Framework to Extract Roads From High-Resolution Multispectral Satellite Images. *IEEE Transactions on Geoscience and Remote Sensing: A Publication of the IEEE Geoscience and Remote Sensing Society*, 49 (10), 3906–3931.
- Huang, X., & Zhang, L. (2009). Road centreline extraction from high-resolution imagery based on multiscale structural features and support vector machines. *International Journal of Remote Sensing*, 30 (8), 1977–1987.
- Jin, X., & Davis, C. H. (2007). Vehicle detection from high-resolution satellite imagery using morphological shared-weight neural networks. *Image and Vision Computing*, 25 (9), 1422–1431.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25. <https://proceedings.neurips.cc/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html>.
- McGlinchy, J., Johnson, B., Muller, B., Joseph, M., & Diaz, J. (2019). Application of UNet Fully Convolutional Neural Network to Impervious Surface Segmentation in Urban Environment from High Resolution Satellite Imagery. *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, 3915–3918.
- Mokhtarzade, M., & Zojj, M. J. V. (2007). Road detection from high-resolution satellite images using artificial neural networks. *International Journal of Applied Earth Observation and Geoinformation*, 9 (1), 32–40.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In *arXiv [cs.CV]*. arXiv. <http://arxiv.org/abs/1505.04597>.
- Song, M. J., & Civco, D. (2004). Road Extraction Using SVM and Image Segmentation. *Photogrammetric Engineering & Remote Sensing*, 12, 1365–1371.
- Soni, A., Koner, R., & Villuri, V. G. K. (2020). M-UNet: Modified U-Net Segmentation Framework with Satellite Imagery. *Proceedings of the Global AI Congress 2019*, 47–59.
- Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE Transactions on Neural Networks / a Publication of the IEEE Neural Networks Council*, 10 (5), 988–999.
- Wang, J., Song, J., Chen, M., & Yang, Z. (2015). Road network extraction: a neural-dynamic framework based on deep learning and a finite state machine. *International Journal of Remote Sensing*, 36 (12), 3144–3169.

O. Tsaryniuk

## APPLICATION OF MACHINE LEARNING METHODS FOR SATELLITE IMAGE CLASSIFICATION: A LITERATURE REVIEW AND OVERVIEW OF KEY FRAMEWORKS

*In the era of digital technology and space exploration, efficient analysis of satellite imagery has become increasingly crucial. This article provides a comprehensive examination of machine learning methods applied to the classification of satellite images, alongside an exploration of key tools and frameworks utilized in this field. Central to this research is the analysis of contemporary classification approaches, particularly through the use of deep neural networks.*

*The article delves into the significance of satellite imagery in various applications, ranging from urban planning and environmental monitoring to agricultural and disaster management. It emphasizes the challenges posed by the vast volume and high resolution of satellite data, underscoring the necessity for sophisticated analytical tools.*

*A substantial focus is placed on convolutional neural networks (CNNs), renowned for their efficacy in image recognition tasks. The article reviews the evolution of CNNs and their pivotal role in advancing satellite image analysis, highlighted by case studies and successful applications.*

*Additionally, this study offers a look at PyTorch and TensorFlow, two of the most prominent machine learning frameworks. Their integration, features, and suitability for geospatial data analysis are critically evaluated. The article discusses PyTorch's notable integration with ArcGIS, providing a unique advantage for geospatial applications. TensorFlow's extensive ecosystem and its adaptability for various computational environments are also examined.*

*To ensure a balanced perspective, the article includes a literature review of seminal studies and papers that have shaped the domain of satellite imagery analysis. This includes an overview of groundbreaking works and recent advancements, providing readers with a contextual understanding of the field's evolution.*

*In conclusion, the article not only serves as a guide to current methodologies and tools in satellite image analysis but also as a window into the potential future developments in this rapidly evolving field.*

**Keywords:** machine learning, image classification, satellite imagery, deep learning, convolutional neural networks, PyTorch, TensorFlow, GIS.

*Матеріал надійшов 15.11.2023*



Creative Commons Attribution 4.0 International License (CC BY 4.0)