

УДК 004.93

DOI <https://doi.org/10.32782/IT/2024-4-16>

### **Павло КУНДЕНКО**

аспірант кафедри інформаційних технологій і систем, Український державний університет науки і технологій, вул. Лазаряна, 2, Дніпро, Україна, 49010

ORCID: 0009-0000-9388-2783

### **Олександр СОКОЛ**

аспірант кафедри інформаційних технологій і систем, Український державний університет науки і технологій, вул. Лазаряна, 2, Дніпро, Україна, 49010

ORCID: 0009-0002-8851-2045

### **Наталія КАЛІНІНА**

кандидат технічних наук, доцент, доцент кафедри інформаційних технологій і систем, Український державний університет науки і технологій, вул. Лазаряна, 2, Дніпро, Україна, 49010

ORCID: 0009-0001-6416-4907

### **Вікторія ГНАТУШЕНКО**

доктор технічних наук, професор, завідувач кафедри інформаційних технологій і систем, Український державний університет науки і технологій, вул. Лазаряна, 2, Дніпро, Україна, 49010

ORCID: 0000-0001-5304-4144

Scopus-Author ID: 57218682553

**Бібліографічний опис статті:** Кунденко, П., Сокол, О., Калініна, Н., Гнатушенко, В. (2024). Нейромережевий підхід виявлення водних об'єктів на мультиспектральних зображеннях. *Information Technology: Computer Science, Software Engineering and Cyber Security*, 4, 132–143, doi: <https://doi.org/10.32782/IT/2024-4-16>

## **НЕЙРОМЕРЕЖЕВИЙ ПІДХІД ВІЯВЛЕННЯ ВОДНИХ ОБ'ЄКТІВ НА МУЛЬТИСПЕКТРАЛЬНИХ ЗОБРАЖЕННЯХ**

**Мета роботи.** Метою даного дослідження є створення та впровадження ефективного нейромережевого підходу на основі моделі U-Net для детектування структурних елементів водного середовища України шляхом аналізу мультиспектральних зображень із супутника Sentinel-2. Це передбачає підвищення точності та швидкості виявлення змін у водних масах та елементах екомережі, що сприятиме оперативному реагуванню на екологічні виклики.

**Методологія.** Для підготовки даних застосовується автоматичний підхід до формування навчально-го набору з використанням нормалізованого різнищевого водного індексу (NDWI). На супутникових знімках Sentinel-2 (зелений та ближній інфрачервоний канали) генеруються бінарні маски води на основі порогового значення, що дає змогу створювати великий набір даних для навчання без ручної анотації. Модель базується на глибокій нейронній мережі U-Net: енкодер виокремлює високорівневі ознаки, а декодер відновлює просторову роздільну здатність і формує сегментаційну карту. Під час навчання застосовується комбінована функція втрат, яка поєднує бінарну крос-ентропію та коефіцієнт Дайса. Оцінка моделі здійснюється за метриками F1-міри, точності, повноти й індексу Жаккара (IoU). Модель тестується на повнорозмірних знімках різних ділянок, демонструючи високий рівень узагальнення.

**Наукова новизна.** Запропоновано підхід, що полягає в об'єднанні автоматичного формування масок водних об'єктів (за допомогою NDWI) та нейромережі U-Net, адаптованої до задач бінарної сегментації великих супутникових зображень. Така інтеграція уникає ручної розмітки та забезпечує точні результати виявлення води. Використання комбінованої функції втрат покращує чутливість моделі до тонких водних структур, а стійкість до варіативності спектральних характеристик і атмосферних перешкод підтверджується експериментами в різних умовах зйомки.

**Висновки.** Розроблено ефективну модель для сегментації водних об'єктів на супутникових знімках Sentinel-2 з використанням глибокої нейронної мережі архітектури U-Net. Процес включав підготовку даних, де автоматично генерувалися маски водних об'єктів на основі індексу NDWI, та детальне навчання моделі з комбінованою функцією втрат, що поєднує бінарну крос-ентропію та коефіцієнт Дайса.

Модель досягла високих показників точності, підтверджених метриками F1-міри (0.8897), точності (0.8721), повноти (0.9080) та IoU (0.8013), що свідчить про її здатність до точного виявлення водних

об'єктів різних розмірів і форм. Перевагами використаних підходів є поєднання глибокого навчання з попередньою підготовкою даних, що дозволило автоматизувати процес виявлення водних об'єктів та забезпечити високу точність сегментації. Модель демонструє гнучкість, масштабованість та обчислювальну ефективність, що робить її придатною для практичного застосування в моніторингу водних ресурсів і екологічних дослідженнях. Майбутні напрямки дослідження направлені на експерименти з іншими архітектурами нейронних мереж, використання альтернативних методів створення масок та врахування просторово-часової інформації, що дасть змогу підвищити ефективність і універсальність моделі.

**Ключові слова:** згорткові нейронні мережі, семантична сегментація, супутникові знімки, водні ресурси, екологічний моніторинг.

### **Pavlo KUNDENKO**

Postgraduate Student at the Department of Information Technology and Systems, Ukrainian State University of Science and Technologies, 2, Lazariana Str., Dnipro, Ukraine, 49010, pavel.kundenko@gmail.com

**ORCID:** 0009-0000-9388-2783

### **Oleksander SOKOL**

Postgraduate Student at the Department of Information Technology and Systems, Ukrainian State University of Science and Technologies, 2, Lazariana Str., Dnipro, Ukraine, 49010, wawjuu4ok@gmail.com

**ORCID:** 0009-0002-8851-2045

### **Nataliia KALININA**

Candidate of Technical Science, Associate Professor, Associate Professor at the Department of Information Technology and Systems, Ukrainian State University of Science and Technologies, 2, Lazariana Str., Dnipro, Ukraine, 49010, natalyku13@gmail.com

**ORCID:** 0009-0001-6416-4907

### **Viktoriiia HNATUSHENKO**

Doctor of Technical Science, Professor, Head of Department of Information Technology and Systems, Ukrainian State University of Science and Technologies, 2, Lazariana Str., Dnipro, Ukraine, 49010, vik.v.hnatushenko@ust.edu.ua

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

**Scopus-AuthorID:** 57218682553

**To cite this article:** Kundenko, P., Sokol, O., Kalinina, N., Hnatushenko, V. (2024). Neiromerezhevyi pidkhid vyavlennia vodnykh ob'ektiv na multispektralnykh zobrazhenniakh [Neural network approach to detecting water objects in multispectral images]. *Information Technology: Computer Science, Software Engineering and Cyber Security*, 4, 132–143, doi: <https://doi.org/10.32782/IT/2024-4-16>

## **NEURAL NETWORK APPROACH TO DETECTING WATER OBJECTS IN MULTISPECTRAL IMAGES**

**Aim of the Study.** The goal of this research is to develop and implement an effective neural network approach based on the U-Net model for detecting structural elements of Ukraine's aquatic environment through the analysis of multispectral images from the Sentinel-2 satellite. This entails enhancing both accuracy and speed in identifying changes in water bodies and ecological network components, thereby enabling prompt responses to environmental challenges.

**Methodology.** An automatic approach to forming the training set is utilized, relying on the Normalized Difference Water Index (NDWI). Binary water masks are generated based on a threshold value applied to the Sentinel-2 green and near-infrared channels, enabling the creation of a large training dataset without manual labeling. The model is built around the U-Net architecture: the encoder extracts high-level features, while the decoder restores spatial resolution and produces the segmentation map. During training, a combined loss function that merges binary cross-entropy with the Dice coefficient is applied. Model evaluation uses F1 score, precision, recall, and Intersection over Union (IoU). Testing the model on full-resolution images of different areas demonstrates a high degree of generalization.

**Scientific Novelty.** The proposed approach integrates automatic generation of water body masks (via NDWI) with a U-Net-based architecture tailored for binary segmentation of large satellite images. This integration eliminates the need for manual labeling and ensures accurate water detection results. The use of a combined loss function improves the model's sensitivity to fine water structures, while experiments under various imaging conditions confirm its robustness against spectral and atmospheric variability.

**Conclusions.** An effective model has been developed for the segmentation of water bodies in Sentinel-2 satellite images using a deep neural network with a U-Net architecture. The process involved data preparation, wherein

*water masks were automatically generated based on the NDWI index, followed by thorough training of the model with a combined loss function that merges binary cross-entropy and the Dice coefficient. The model achieved high accuracy metrics, confirmed by an F1 score of 0.8897, precision of 0.8721, recall of 0.9080, and an IoU of 0.8013, demonstrating its capability for accurately detecting water bodies of various sizes and shapes. The advantages of the chosen approaches stem from combining deep learning with prior data processing, which automated the detection of water bodies and ensured high segmentation accuracy. The model exhibits flexibility, scalability, and computational efficiency, making it suitable for practical applications in water resource monitoring and environmental studies. Future research directions include experimenting with different neural network architectures, employing alternative methods for mask generation, and incorporating spatiotemporal information to further enhance the model's effectiveness and versatility.*

**Key words:** *convolutional neural networks, semantic segmentation, satellite imagery, water resources, environmental monitoring.*

**Постановка проблеми.** Моніторинг змін у структурних елементах водного середовища є критично важливим для збереження біорізноманіття та стійкого розвитку екосистем. Актуальність цього питання зростає в контексті глобальної зміни клімату (Climatechange, 2021), яка призводить до підвищення температури води, зміни рівня моря та збільшення частоти екстремальних погодних явищ. Висхідні екологічні виклики, спричинені також антропогенними факторами та військовими конфліктами, погіршують якість водних ресурсів через забруднення та руйнування екосистем (UNEP, 2021). Постійний розвиток сфери нейронних мереж відкриває нові можливості для аналізу мультиспектральних зображень, що використовуються для моніторингу водного середовища (LiW., 2019). Сучасні нейронні мережі, зокрема глибокі згорткові нейронні мережі, здатні обробляти великі обсяги даних з високою точністю, дозволяючи виявляти навіть незначні зміни у структурі водних об'єктів (MaL., 2019). Проте, попри значний прогрес, існує простір для покращення методів обробки та аналізу даних, зокрема в контексті підвищення точності, швидкості та інтерпретованості результатів (ZhangC., 2020). З огляду на зазначене, дослідження, спрямовані на розробку ефективних нейромережових підходів до моніторингу водного середовища та виявленню його елементів на мультиспектральних зображеннях, є актуальними та мають значний науковий і практичний інтерес.

#### **Аналіз останніх досліджень і публікацій.**

Останніми роками спостерігається значний прогрес у застосуванні штучного інтелекту (ШІ) та глибокого навчання для моніторингу водних мас та елементів екомережі. Це зумовлено необхідністю оперативного реагування на екологічні виклики та можливістю обробки великих обсягів даних дистанційного зондування (Dobrovolska, 2024; Hnatushenko V.V., 2019). Одним із ключових напрямків є використання згорткових нейронних мереж (CNN) для класифікації та сегментації водних об'єктів на мультиспектральних

зображеннях. Наприклад, Li та інші розробили метод для виявлення нафтових розливів на основі поляриметричних SAR-даних, використовуючи глибоке навчання. Їхня модель досягла високої точності виявлення, що сприяє швидкому реагуванню на екологічні аварії (Li, 2019).

Інші дослідження зосереджуються на виявленні цвітіння водоростей, яке може мати негативний вплив на водні екосистеми. Gao та співавтори успішно застосували CNN для виявлення цвітіння водоростей у прибережних зонах, аналізуючи дані з супутникових зображень (Gao, 2020). У сфері аналізу наземних екосистем глибоке навчання також демонструє високий потенціал. Zhang та інші використали глибокі нейронні мережі для класифікації типів наземного покриття, що дозволяє відстежувати зміни в біорізноманітті та стані екосистем (Zhang, 2021). Це сприяє більш ефективному управлінню природними ресурсами та збереженню екологічного балансу. Комбінація мультиспектральних зображень із можливостями глибокого навчання дозволяє отримувати більш детальну інформацію про стан водних та наземних екосистем. Chen та інші досліджували застосування глибоких нейронних мереж для покращення роздільної здатності супутникових зображень, що забезпечує більш точний аналіз структурних елементів екомережі (Chen, 2021, p.5899-5921). Попри значний прогрес, існують виклики, пов'язані з необхідністю великих обсягів якісних навчальних даних та забезпеченням інтерпретованості моделей ШІ. Подальші дослідження спрямовані на розвиток методів трансферного навчання та удосконалення алгоритмів, щоб підвищити точність і надійність моделей для практичного застосування в екологічному моніторингу.

**Мета дослідження.** Метою даного дослідження є створення та впровадження ефективного нейромережового підходу на основі моделі U-Net для детектування структурних елементів водного середовища України шляхом аналізу мультиспектральних зображень із супутника

Sentinel-2. Це передбачає підвищення точності та швидкості виявлення змін у водних масах та елементах екомережі, що сприятиме оперативному реагуванню на екологічні виклики.

**Основна частина.** В дослідженні використовувалися супутникові знімки Sentinel-2, надані Європейським космічним агентством (ЄКА). Sentinel-2 надає мультиспектральні зображення високої роздільної здатності з просторовим розрізненням 10 м у видимому та ближньому інфрачервоному (NIR) діапазонах, що робить їх придатними для моніторингу водного середовища. Для тренування і валідації був обраний знімок з ідентифікатором «S2B\_MSIL2A\_20240501T085559\_N0510\_R007\_T36UUA\_20240501T114536.SAFE».

Для аналізу були обрані три основні спектральні канали: канал B3 (зелений, 10 м), який є чутливим до рослинності та використовується в обчисленні індексів, пов'язаних з водою; канал B8 (ближній інфрачервоний, NIR, 10 м), що допомагає виявляти водні об'єкти завдяки своїй реакції на вологість; та канал TCI (TrueColorImage), істинно-кольорове зображення для візуалізації та загального аналізу.

Зображення завантажувалися та нормалізувалися шляхом масштабування значень пікселів до діапазону [0, 1], що сприяло стабільності та ефективності навчання нейронної мережі (SanturkarS., 2018, р. 2483–2493). Це забезпечувало стандартизацію даних

і покращувало збіжність алгоритму під час тренування.

Для автоматичного генерування масок водних об'єктів використовувався нормалізований різницевий водний індекс (NDWI), який ефективно виявляє водні поверхні, базуючись на різниці відбиття між зеленим та ближнім інфрачервоним каналами (DuanW., 2019). Формула NDWI має вигляд:

$$NDWI = \frac{B3 - B8}{B3 + B8},$$

де B3 – відбиття у зеленому каналі, а B8 – відбиття у ближньому інфрачервоному каналі.

Процес створення масок складався з кількох етапів. Спочатку завантажувалися спектральні канали B3 та B8 і перетворювалися до відповідного числового формату. Якщо роздільна здатність каналів не співпадала, здійснювалося масштабування одного з них для вирівнювання розмірів зображень. Це було важливим для коректного обчислення NDWI та забезпечення точності подальшого аналізу. Далі для кожного пікселя зображення розраховувався NDWI. Щоб уникнути ділення на нуль та некоректних значень, застосовувалися відповідні методи обробки даних, такі як додавання малих констант або фільтрація пікселів з нульовою сумою каналів. Після обчислення NDWI встановлювалося порогове значення -0.015; пікселі з NDWI вище цього порогу вважалися водними



Рис. 1. Зображення, використане в навчанні моделі

об'єктами. Це значення було визначене емпірично на основі аналізу гістограм NDWI та може бути адаптоване залежно від специфічних умов зйомки та характеристик регіону дослідження.

На основі порогового значення генерувалася бінарна маска, де водні пікселі позначалися як 1, а всі інші – як 0. Маска зберігалася для подальшого використання в процесі навчання моделі. Це дозволило автоматизувати процес створення навчальних даних та зменшити потребу в ручній розмітці, що є трудомістким завданням.

Через високу роздільну здатність супутникових зображень Sentinel-2 було прийнято рішення розбивати їх на менші фрагменти (патчі) розміром 512×512 пікселів. Це дозволило зменшити обчислювальні вимоги, оскільки робота з меншими зображеннями знижує потреби в оперативній пам'яті та підвищує швидкість обробки даних. Крім того, такий підхід покращив навчання моделі, оскільки вона ефективніше навчається на локальних особливостях зображення, що сприяє точнішій сегментації водних об'єктів. Розбиття здійснювалося рівномірно по всьому зображенню, забезпечуючи відповідність між патчами зображень та відповідними масками. Патчі зберігалися у зручному для подальшої обробки форматі, що дозволяло швидко завантажувати їх під час тренування та забезпечувало ефективний потік даних.

Для тренування моделі були відібрані найбільш інформативні патчі, які містили значну кількість водних пікселів. Такий підхід забезпечив збалансованість даних: модель отримувала достатню кількість прикладів з водними

об'єктами, що покращувало її здатність до їх коректного виявлення. Це також підвищило ефективність тренування, оскільки фокусування на інформативних патчах зменшувало час навчання без компромісу щодо якості моделі. Валідаційний набір даних формувався з патчів, які не використовувалися під час тренування. Це забезпечувало об'єктивну оцінку продуктивності моделі та її здатності до узагальнення на невідомих даних. Такий підхід є стандартною практикою в машинному навчанні і дозволяє уникнути перенавчання моделі на тренувальних даних.

**Архітектура нейронної мережі.** Для задачі сегментації водних об'єктів була обрана модель U-Net, яка є одним із провідних підходів для семантичної сегментації зображень, особливо в галузі дистанційного зондування та медичної візуалізації (ZhouZ., 2019, p. 1856-1867). U-Net поєднує в собі симетричну архітектуру, що складається з шляху стиснення (енкодера) та шляху розширення (декодера). Така структура дозволяє моделі враховувати як локальні, так і глобальні контексти зображення, що є критичним для точного виявлення водних об'єктів.

Енкодер моделі складається з послідовності згорткових шарів, які поступово зменшують просторові розміри вхідного зображення та збільшують кількість каналів. Це дозволяє моделі захоплювати високорівневі особливості та контекстну інформацію. Зокрема, енкодер містить чотири блоки, кожен з яких має два послідовних згорткових шари з активаційною функцією та нормалізацією. Після кожного блоку застосовується операція максимального пулінгу,



Рис. 2. Розмітка цільових даних знімку

яка зменшує розміри зображення та підвищує ефективність навчання.

Перший блок енкодера приймає вхідне зображення розміром  $H \times W \times 3$  (три кольорні канали) і містить згорткові шари з кількістю каналів 64. Кожен наступний блок подвоює кількість каналів (128, 256, 512), що дозволяє моделі вловлювати більш складні та абстрактні особливості зображення. Максимальний пулінг з розміром ядра  $2 \times 2$  зменшує просторові розміри, забезпечуючи збереження важливої інформації. У центрі моделі знаходиться боттлнек, який відповідає за максимально глибоке представлення вхідного зображення. Він складається з двох згорткових шарів з кількістю каналів 1024, активаційними функціями та нормалізацією. Це дозволяє моделі навчитися розпізнавати найбільш високорівневі особливості, що є важливими для сегментації.

Декодер моделі відповідає за відновлення просторових розмірів зображення та зменшення кількості каналів. Він також складається з чотирьох блоків, симетричних до енкодера. Кожен блок декодера включає транспоновану згортку (апсемплінг), яка збільшує розміри зображення, та два згорткових шари з активацією та нормалізацією. Кількість каналів на кожному рівні декодера зменшується відповідно до енкодера (512, 256, 128, 64).

Ключовою особливістю U-Net є використання пропускових з'єднань між відповідними рівнями енкодера та декодера. Це дозволяє моделі поєднувати контекстну інформацію з глибоких шарів з просторовою інформацією високої роздільної здатності з нижчих рівнів. Математично це можна виразити формулою:

$$y_i = \text{Conv}(\text{Up}(y_{i+1}) \oplus x_i), \quad (1)$$

де  $x_i$  – вихід енкодера на рівні  $i$ ,  $y_i$  – вихід декодера на рівні  $i$ ,  $\text{Up}(y_{i+1})$  – результат апсемплінгу з наступного рівня декодера,  $\oplus$  – операція конкатенації по каналах, а  $\text{Conv}$  – згортковий блок.

Для активації після кожного згорткового шару використовується функція ReLU (RectifiedLinearUnit), яка вводить нелінійність та запобігає проблемам зникаючих градієнтів (RamachandranP., 2018). Нормалізація після згорткових шарів стабілізує процес навчання та сприяє швидшій збіжності моделі (IoffeS., 2015, p. 448-456). Ці елементи критично важливі для ефективного навчання глибоких нейронних мереж.

Вихідний шар моделі складається зі згорткового шару з фільтром розміру  $1 \times 1$  та кількістю каналів 1, що підходить для задачі бінарної сегментації. На цьому шарі використовується сигмоїдна активаційна функція, яка переводить

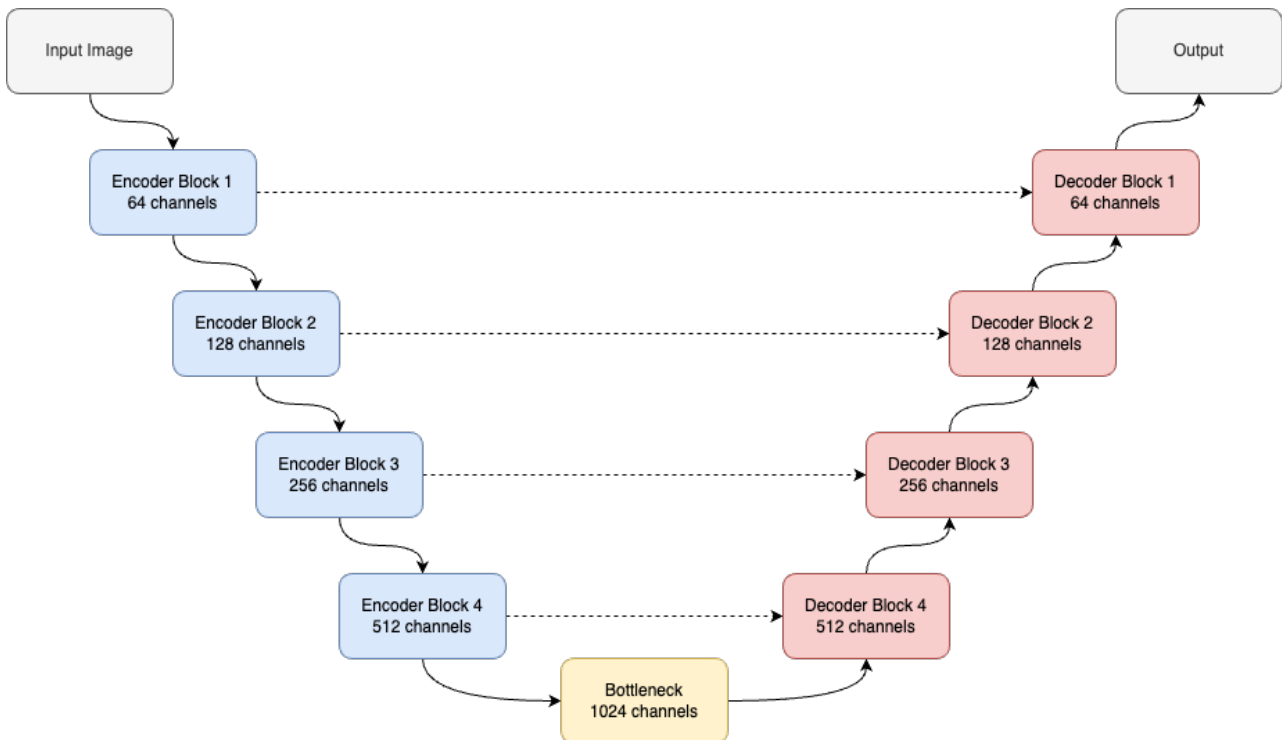


Рис. 3. Архітектура моделі U-net

вихідні значення в діапазон  $[0, 1]$ , інтерпретуючи їх як ймовірність належності пікселя до класу «вода».

Параметри моделі були обрані з метою забезпечення балансу між точністю та обчислювальною ефективністю. Розмір фільтрів встановлено на  $3 \times 3$  для всіх згорткових шарів, що дозволяє моделі вловлювати локальні патерни та текстури. Кількість фільтрів подвоюється на кожному рівні енкодера, досягаючи максимуму в бутлнеку, і відповідно зменшується в декодері. Використання паддінгу гарантує збереження розмірів зображення після згортки, а страйд встановлений на 1 для згорткових шарів та 2 для операцій максимального пулінгу та апсемплінгу.

Операція згортки для вхідного тензора  $I$  та ядра  $K$  визначається як:

$$(I * K)(i, j) = \sum_{m=-k}^k \sum_{n=-k}^k I(i+m, j+n) \cdot K(m, n), \quad (2)$$

де  $k$  – радіус ядра згортки. Транспонована згортка (апсемплінг) використовується для збільшення просторових розмірів вхідного тензора, що дозволяє відновити роздільну здатність зображення:

$$Up(I)(i, j) = \sum_{m=-k}^k \sum_{n=-k}^k I\left(\frac{i-m}{s}, \frac{j-n}{s}\right) \cdot K(m, n), \quad (3)$$

де  $s$  – страйд апсемплінгу.

Обґрунтування вибору архітектури полягає в її здатності ефективно вирішувати задачі семантичної сегментації з високою точністю навіть при обмеженій кількості навчальних даних (ZhouZ., 2019, р. 1856-1867). Пропускні з'єднання дозволяють моделі поєднувати високорівневі контекстуальні ознаки з низькорівневими просторовими деталями, що є особливо важливим для точного виявлення водних об'єктів різних розмірів та форм. Симетрична структура U-Net полегшує процес навчання та забезпечує збалансоване представлення характеристик на різних масштабах, що сприяє покращенню якості сегментації. Використання цієї архітектури в нашому дослідженні дозволило досягти високої точності виявлення водних об'єктів на супутникових знімках. Модель показала високу ефективність та гнучкість, що підтверджується отриманими результатами та метриками оцінки. Це свідчить про доцільність застосування U-Net у задачах моніторингу навколишнього середовища та підкреслює її потенціал для подальшого розвитку та вдосконалення.

**Навчання та оцінка моделі.** Після підготовки даних та побудови архітектури моделі було проведено навчання глибокої нейронної

мережі для задачі семантичної сегментації водних об'єктів на супутникових знімках. Основні аспекти процесу навчання включали вибір функції втрат, оптимізатора, гіперпараметрів та стратегії навчання.

Для задачі бінарної сегментації використовувалася комбінована функція втрат, яка поєднує бінарну крос-ентропію (BinaryCross-Entropy, BCE) та коефіцієнт Дайса (DiceLoss). Формула бінарної крос-ентропії:

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)]. \quad (4)$$

Формула коефіцієнта Дайса має вигляд:

$$L_{Dice} = 1 - \frac{2 \sum_{i=1}^N y_i p_i + \epsilon}{\sum_{i=1}^N y_i + \sum_{i=1}^N p_i + \epsilon}, \quad (5)$$

де  $y_i$  – істинне значення пікселя (0 або 1),  $p_i$  – передбачена ймовірність належності пікселя до класу «вода»,  $\epsilon$  – мале число для уникнення ділення на нуль.

Комбінована функція втрат визначається як:

$$L_{total} = \alpha \cdot L_{BCE} + \beta \cdot L_{Dice}, \quad (6)$$

де  $\alpha$  та  $\beta$  – вагові коефіцієнти, що визначають внесок кожної складової функції втрат.

Комбінування цих двох функцій втрат дозволяє враховувати як піксельну точність (через BCE), так і загальну форму та перекриття передбаченої та істинної масок (через DiceLoss) (YeungM., 2021; LiX., 2018, р. 2663-2674).

Для оптимізації ваг моделі використовувався метод адаптивної оптимізації зі швидкістю навчання  $\eta = 1 \times 10^{-4}$ , що забезпечує стабільну збіжність та поступове оновлення ваг (LuoL., 2019). Розмір батчу був встановлений на рівні 16, що дозволило збалансувати використання пам'яті та статистичну стабільність градієнтів. Навчання моделі проводилося протягом 50 епох, після чого спостерігалася стабілізація функції втрат на валідаційному наборі даних.

Стратегія навчання передбачала розбиття даних на навчальний та валідаційний набори в пропорції 80% та 20%, що відповідає рекомендаціям сучасних досліджень (BudaM., 2018, р. 249-259). Патчі даних перемішувалися перед кожною епохою, щоб уникнути впливу порядку даних на процес навчання.

Для запобігання перенавчанню та покращення збіжності використовувалися наступні методи:

- Рання зупинка (EarlyStopping): навчання припинялося, якщо функція втрат на валідаційному наборі переставала зменшуватися протягом 5 епох (PrecheltL., 2012, р. 53-67).

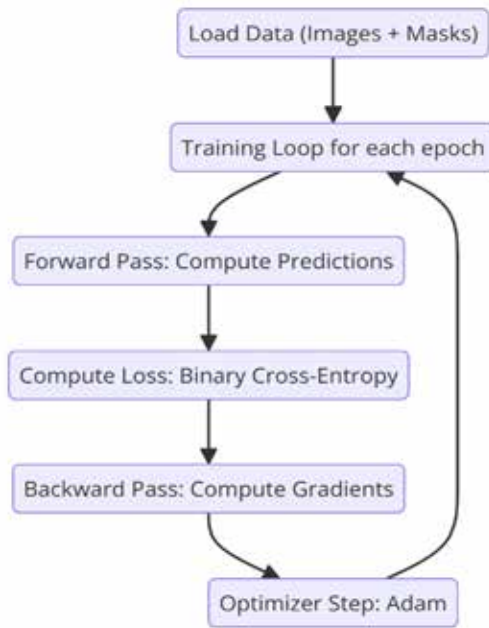


Рис. 4. Схема навчання моделі

- Зменшення швидкості навчання на плато: Швидкість навчання зменшувалася на фактор 0.1, якщо функція втрат на валідаційному наборі не покращувалася протягом 3 епох (SmithL.N., 2018).

Для оцінки продуктивності моделі були обрані наступні метрики:

1. F1-міра (F1 Score): враховує як точність, так і повноту, що особливо важливо в умовах незбалансованих класів, характерних для даної задачі (YangP., 2020).

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}, \quad (7)$$

2. Точність (Precision): відсоток правильно передбачених позитивних прикладів серед всіх передбачених позитивних.

$$Precision = \frac{TP}{TP + FP}, \quad (8)$$

3. Повнота (Recall): відсоток правильно передбачених позитивних прикладів серед всіх реальних позитивних.

$$Recall = \frac{TP}{TP + FN}, \quad (9)$$

4. Індекс Жаккара (IntersectionoverUnion, IoU): відношення площі перетину передбаченої та істинної масок до площі їх об'єднання. Широко використовується в задачах сегментації та дає інтуїтивне розуміння перекриття між передбаченою та істинною масками (RahmanM.A., 2016, p. 234-244).

$$IoU = \frac{TP}{TP + FP + FN}, \quad (10)$$

де TP (TruePositives) – кількість правильно передбачених пікселів води, FP (FalsePositives) – кількість пікселів, неправильно передбачених як вода, FN (FalseNegatives) – кількість пікселів води, які не були виявлені.

Оцінка моделі проводилася на валідаційному наборі даних після кожної епохи навчання. Передбачені ймовірності переводилися в бінарні значення з використанням порогу 0.5, що є стандартною практикою в задачах бінарної класифікації (LiuX., 2019). На основі передбачених та істинних масок обчислювалися зазначені вище метрики. Результати метрик використовувалися для моніторингу продуктивності моделі та прийняття рішень щодо коригування гіперпараметрів або стратегії навчання.

Після завершення навчання модель показала високі результати на валідаційному наборі даних. Отримані метрики:

Метрика	Значення
F1-міра (F1 Score)	0.8897
Точність (Precision)	0.8721
Повнота (Recall)	0.9080
Індекс Жаккара (IoU)	0.8013

Ці показники свідчать про те, що модель досягла високої точності та повноти у виявленні водних об'єктів. Високе значення F1-міри вказує на збалансованість між точністю та повнотою, а значення IoU понад 0.8 свідчить про значне перекриття між передбаченими та істинними масками. Модель демонструвала стійкість до перенавчання завдяки застосуванню методів регуляризації та контролю за функцією втрат на валідаційному наборі. Використання комбінованої функції втрат сприяло більш точному виявленню як дрібних деталей, так і загальних контурів водних об'єктів.

**Застосування моделі та її переваги.** Після успішного навчання та оцінки модель була протестована на нових супутникових знімках для перевірки її здатності до узагальнення та практичного застосування. Для ефективного прогнозування на повнорозмірних зображеннях використовувався метод розбиття зображення на менші фрагменти (патчі). Це було необхідно, оскільки безпосередня обробка великих зображень є обчислювально складною та вимагає значних ресурсів пам'яті. Вихідне зображення розміром  $H \times W$  пікселів ділилося на патчі розміром  $P \times P$  пікселів із певним кроком  $S$ . Використання перекриття між патчами ( $S < P$ ) дозволяло зменшити артефакти на межах патчів і покращити якість сегментації. Кожен патч передавався через модель для отримання



передбаченої маски. Оскільки модель була навчена на патчах того ж розміру, прогнозування було ефективним та точним. Після обробки всі передбачені маски патчів об'єднувалися в одне повнорозмірне зображення з урахуванням можливих перекриттів. При перекритті пікселів використовувалося середнє або максимальне значення для остаточного рішення, що забезпечувало цілісність передбаченої маски та підвищувало загальну якість сегментації. Приклад передбачень моделі на повнорозмірних знімках Sentinel-2 (ідентифікатор знімку-«S2A\_MSIL2A\_20240430T083601\_N0510\_R064\_T36UXU\_20240430T120153.SAFE»):

Обраний підхід має кілька важливих переваг. По-перше, він забезпечує обчислювальну ефективність. Розбиття на патчі зменшує вимоги до оперативної пам'яті, дозволяючи виконувати прогнозування на звичайному обладнанні без необхідності використання високопродуктивних обчислювальних систем. Крім того, можлива паралельна обробка патчів, що прискорює процес прогнозування.

По-друге, метод характеризується гнучкістю та масштабованістю. Модель легко застосовується до зображень будь-якого розміру, оскільки процес розбиття та збирання не залежить від розмірів вхідного зображення. Це особливо важливо для обробки зображень з високою роздільною здатністю, що необхідно для детального аналізу територій.

По-третє, відбувається покращення якості прогнозування. Обробка патчів дозволяє моделі фокусуватися на локальних особливостях зображення, що сприяє більш точному

виявленню дрібних водних об'єктів. Перекриття патчів і об'єднання прогнозів зменшують артефакти на межах, підвищуючи загальну якість сегментації.

**Потенційні покращення.** Для підвищення ефективності моделі можна розглянути альтернативні підходи до створення масок водних об'єктів. Замість використання фіксованого порогу на основі NDWI, доцільно застосувати методи кластеризації або глибокого навчання для автоматичного виявлення води з більшою точністю (LiB., 2020). Об'єднання декількох спектральних індексів, таких як MNDWI чи AWEI, також може покращити результати в умовах змінної освітленості та атмосферних впливів (DuanW., 2019).

Експериментування з іншими архітектурами нейронних мереж, такими як U-Net++ (ZhouZ., 2018), Attention U-Net (OktayO., 2018) або DeepLabv3+ (ChenL.C., 2018), може сприяти покращенню сегментації завдяки кращому врахуванню багаторівневих особливостей та механізмів уваги. Впровадження цих підходів дозволить моделі збільшити точність ідентифікування складних структур водних об'єктів та підвищити загальну продуктивність системи.

**Висновок.** У даній роботі було розроблено ефективну модель для сегментації водних об'єктів на супутникових знімках Sentinel-2 з використанням глибокої нейронної мережі архітектури U-Net. Процес включав підготовку даних, де автоматично генерувалися маски водних об'єктів на основі індексу NDWI, та детальне навчання моделі з комбінованою функцією втрат, що поєднує бінарну крос-ентропію




Рис. 5. Результат передбачення моделі

та коефіцієнт Дайса. Модель досягла високих показників точності, підтверджених метриками F1-міри, точності, повноти та індексу Жаккара, що свідчить про її здатність до точного виявлення водних об'єктів різних розмірів і форм. Перевагами використаних підходів є поєднання глибинного навчання з попередньою підготовкою даних, що дозволило автоматизувати процес виявлення водних об'єктів та забезпечити високу точність сегментації. Модель демонструє

гнучкість, масштабованість та обчислювальну ефективність, що робить її придатною для практичного застосування в моніторингу водних ресурсів і екологічних дослідженнях. Майбутні напрямки дослідження направлені на експерименти з іншими архітектурами нейронних мереж, використання альтернативних методів створення масок та врахування просторово-часової інформації, що дасть змогу підвищити ефективність і універсальність моделі.

#### ЛІТЕРАТУРА:

1. IPCC. *Climate Change 2021: The Physical Science Basis*. URL: <https://www.ipcc.ch/report/ar6/wg1/>
2. United Nations Environment Programme (UNEP). *Environmental Issues Emerging from Conflict and Disaster*. 2021. URL: <https://www.unep.org/explore-topics/disasters-conflicts>
3. Li W., Fu H., Yu L., Cracknell A. Deep learning based oil spill detection from polarimetric SAR data. *Remote Sensing of Environment*, 2019. 233, 111368. URL: <https://www.sciencedirect.com/science/article/pii/S0034425719304563>
4. Ma L., Liu Y., Zhang X., Ye Y., Yin G., Johnson B. A. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019. 152, 166–177. URL: <https://www.sciencedirect.com/science/article/pii/S0924271618303333>
5. Zhang C., Liu F., & Li W. A review of remote sensing image classification techniques: the role of spatio-contextual information. *European Journal of Remote Sensing*, (2020). 53(1), 176–197. URL: <https://www.tandfonline.com/doi/full/10.1080/22797254.2020.1727854>
6. Li W., Fu H., Yu L., Cracknell A. Deep learning based oil spill detection from polarimetric SAR data. *Remote Sensing of Environment*, 2019. 233, 111368. <https://doi.org/10.1016/j.rse.2019.111368>
7. Gao B., Huang J., Li J., Chen Z. Detecting algal blooms in coastal waters using deep learning and satellite imagery. *Remote Sensing*, 2020. 12(7), 1135. <https://doi.org/10.3390/rs12071135>
8. Zhang C., Li W., Travis D. Gaps fill of land cover classification with deep learning. *Remote Sensing of Environment*, 2021. 267, 112716. <https://doi.org/10.1016/j.rse.2021.112716>
9. Chen Y., Jiang H., Li C., Jia X., Ghamisi P. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 2021. 59(7), 5899–5921. <https://doi.org/10.1109/TGRS.2020.3028704>
10. Santurkar S., Tsipras D., Ilyas A., Madry A. How Does Batch Normalization Help Optimization? *Advances in Neural Information Processing Systems*, 2018. 31, 2483–2493. URL: <https://proceedings.neurips.cc/paper/2018/file/905056c1f1abf51a8521faa9756a31d8-Paper.pdf>
11. Duan W., He B., Nover D., Yang G., Chen W., Meng H., Liu C. Water bodies' mapping from Sentinel-2 imagery with modified normalized difference water index at 10-m spatial resolution produced by sharpening the SWIR band. *Remote Sensing*, 2019. 11(23), 2779. <https://doi.org/10.3390/rs11232779>
12. Zhou Z., Siddiquee M.M.R., Tajbakhsh N., Liang J. UNet++: Redesigning skip connections to exploit multiscale features in image segmentation. *IEEE Transactions on Medical Imaging*, 2019. 39(6), 1856–1867. <https://doi.org/10.1109/TMI.2019.2959609>
13. Ramachandran P., Zoph B., Le Q. V. Searching for activation functions. *arXiv preprint arXiv:1710.05941*. 2018. URL: <https://arxiv.org/abs/1710.05941>
14. Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *Proceedings of the 32nd International Conference on Machine Learning*, 2015. 37, 448–456. <http://proceedings.mlr.press/v37/loff15.html>
15. Yeung M., Sala E., Schönlieb C. B., Rundo, L. Unified focal loss: Generalising Dice and cross entropy-based losses to handle class imbalanced medical image segmentation. *Computerized Medical Imaging and Graphics*, 2021. 89, 101885. <https://doi.org/10.1016/j.compmedimag.2021.101885>
16. Li X., Chen H., Qi X., Dou Q., Fu C. W., Heng P. A. H-DenseUNet: Hybrid Densely Connected UNet for Liver and Tumor Segmentation From CT Volumes. *IEEE Transactions on Medical Imaging*, 2018. 37(12), 2663–2674. <https://doi.org/10.1109/TMI.2018.2845918>
17. Luo L., Xiong Y., Liu Y., Sun X. Adaptive gradient methods with dynamic bound of learning rate. *Proceedings of the 7th International Conference on Learning Representations (ICLR)*. 2019. URL: <https://arxiv.org/abs/1902.09843>

18. Buda M., Maki A., Mazurowski M. A. A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks*, 2018. 106, 249–259. <https://doi.org/10.1016/j.neunet.2018.07.011>
19. Prechelt L. Early stopping – but when?. In *Neural Networks: Tricks of the Trade* (2012). (pp. 53–67). Springer. [https://doi.org/10.1007/978-3-642-35289-8\\_5](https://doi.org/10.1007/978-3-642-35289-8_5)
20. Smith L. N. A disciplined approach to neural network hyper-parameters: Part 1 – learning rate, batch size, momentum, and weight decay. *arXiv preprint arXiv:1803.09820*. 2018. URL: <https://arxiv.org/abs/1803.09820>
21. Yang P., Zhang L., Zhao W., Xie X. Retinal vessel segmentation using a U-Net based convolutional neural network. *Symmetry*, 2020. 12(4), 611. <https://doi.org/10.3390/sym12040611>
22. Rahman M. A., Wang Y. Optimizing intersection-over-union in deep neural networks for image segmentation. In *International Symposium on Visual Computing* (2016). (pp. 234–244). Springer. [https://doi.org/10.1007/978-3-319-50835-1\\_22](https://doi.org/10.1007/978-3-319-50835-1_22)
23. Liu X., Song L., Liu S., Zhang Y. A review of deep-learning-based medical image segmentation methods. *Sustainability*, 2019. 11(7), 1897. <https://doi.org/10.3390/su11071897>
24. Li B., Liu Y., Wang Y., Li M., Liu Y. A comparison of clustering algorithms for water body extraction from remote sensing images. *Remote Sensing*, 2020. 12(10), 1590. <https://doi.org/10.3390/rs12101590>
25. Duan W., He B., Nover D., Yang G., Chen W., Meng H., Liu C. Water bodies' mapping from Sentinel-2 imagery with modified normalized difference water index at 10-m spatial resolution produced by sharpening the SWIR band. *Remote Sensing*, 2019. 11(23), 2779. <https://doi.org/10.3390/rs11232779>
26. Zhou Z., Siddiquee M.M.R., Tajbakhsh N., Liang J. UNet++: A Nested U-Net Architecture for Medical Image Segmentation. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support 2018*. (pp. 3–11). Springer. [https://doi.org/10.1007/978-3-030-00889-5\\_1](https://doi.org/10.1007/978-3-030-00889-5_1)
27. Oktay O., Schlemper J., Le Folgoc L., Lee M., Heinrich M., Misawa K., ... Rueckert D. Attention U-Net: Learning Where to Look for the Pancreas. *arXiv preprint arXiv:1804.03999*. 2018. URL: <https://arxiv.org/abs/1804.03999>
28. Chen L. C., Zhu Y., Papandreou G., Schroff F., Adam H. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. In *Proceedings of the European Conference on Computer Vision (ECCV) 2018*. (pp. 801–818). [https://doi.org/10.1007/978-3-030-01234-2\\_49](https://doi.org/10.1007/978-3-030-01234-2_49)
29. Olena Dobrovolska, Knut Schmidtke, Viktoriia Hnatushenko, Svitlana Sytnyk and Iryna Dmytriieva Relationship between economic development, forest resources, and forest fires: European context. *Environmental Economics*, 2024. 15(2), 77–92. doi:10.21511/ee.15(2).2024.06.
30. Hnatushenko V. V., Mozgovoy D. K., Hnatushenko Vik. V., Spiritsev V. V., Udovik I. M. All-weather monitoring of oil and gas production areas using satellite data // Scientific bulletin of National Mining University. *State Higher Educational Institution "National Mining University"*, Dnipro, 2019. № 6 (158). С. 99–105.

#### REFERENCES:

1. IPCC. *Climate Change 2021: The Physical Science Basis*. Retrieved from: <https://www.ipcc.ch/report/ar6/wg1/>
2. United Nations Environment Programme (UNEP). *Environmental Issues Emerging from Conflict and Disaster*. 2021. Retrieved from: <https://www.unep.org/explore-topics/disasters-conflicts>
3. Li, W., Fu, H., Yu, L., & Cracknell, A. (2019). Deep learning based oil spill detection from polarimetric SAR data. *Remote Sensing of Environment*, 233, 111368. Retrieved from: <https://www.sciencedirect.com/science/article/pii/S0034425719304563>
4. Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166–177. Retrieved from: <https://www.sciencedirect.com/science/article/pii/S0924271618303333>
5. Zhang, C., Liu, F., & Li, W. (2020). A review of remote sensing image classification techniques: the role of spatio-contextual information. *European Journal of Remote Sensing*, 53(1), 176–197. Retrieved from: <https://www.tandfonline.com/doi/full/10.1080/22797254.2020.1727854>
6. Li, W., Fu, H., Yu, L., & Cracknell, A. (2019). Deep learning based oil spill detection from polarimetric SAR data. *Remote Sensing of Environment*, 233, 111368. <https://doi.org/10.1016/j.rse.2019.111368>
7. Gao, B., Huang, J., Li, J., & Chen, Z. (2020). Detecting algal blooms in coastal waters using deep learning and satellite imagery. *Remote Sensing*, 12(7), 1135. <https://doi.org/10.3390/rs12071135>
8. Zhang, C., Li, W., & Travis, D. (2021). Gaps fill of land cover classification with deep learning. *Remote Sensing of Environment*, 267, 112716. <https://doi.org/10.1016/j.rse.2021.112716>
9. Chen, Y., Jiang, H., Li, C., Jia, X., & Ghamisi, P. (2021). Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 59(7), 5899–5921. <https://doi.org/10.1109/TGRS.2020.3028704>

10. Santurkar, S., Tsipras, D., Ilyas, A., & Madry, A. (2018). How Does Batch Normalization Help Optimization? *Advances in Neural Information Processing Systems*, 31, 2483–2493. <https://proceedings.neurips.cc/paper/2018/file/905056c1f1abf51a8521faa9756a31d8-Paper.pdf>
11. Duan, W., He, B., Nover, D., Yang, G., Chen, W., Meng, H., & Liu, C. (2019). Water bodies' mapping from Sentinel-2 imagery with modified normalized difference water index at 10-m spatial resolution produced by sharpening the SWIR band. *Remote Sensing*, 11(23), 2779. <https://doi.org/10.3390/rs11232779>
12. Zhou, Z., Siddiquee, M.M.R., Tajbakhsh, N., & Liang, J. (2019). UNet++: Redesigning skip connections to exploit multiscale features in image segmentation. *IEEE Transactions on Medical Imaging*, 39(6), 1856–1867. <https://doi.org/10.1109/TMI.2019.2959609>
13. Ramachandran, P., Zoph, B., & Le, Q.V. (2018). Searching for activation functions. *arXiv preprint arXiv:1710.05941*. Retrieved from: <https://arxiv.org/abs/1710.05941>
14. Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *Proceedings of the 32nd International Conference on Machine Learning*, 37, 448–456. <http://proceedings.mlr.press/v37/loff15.html>
15. Yeung, M., Sala, E., Schönlieb, C.B., & Rundo, L. (2021). Unified focal loss: Generalising Dice and cross entropy-based losses to handle class imbalanced medical image segmentation. *Computerized Medical Imaging and Graphics*, 89, 101885. <https://doi.org/10.1016/j.compmedimag.2021.101885>
16. Li, X., Chen, H., Qi, X., Dou, Q., Fu, C.W., & Heng, P.A. (2018). H-DenseUNet: Hybrid Densely Connected UNet for Liver and Tumor Segmentation From CT Volumes. *IEEE Transactions on Medical Imaging*, 37(12), 2663–2674. <https://doi.org/10.1109/TMI.2018.2845918>
17. Luo, L., Xiong, Y., Liu, Y., & Sun, X. (2019). Adaptive gradient methods with dynamic bound of learning rate. *Proceedings of the 7th International Conference on Learning Representations (ICLR)*. Retrieved from: <https://arxiv.org/abs/1902.09843>
18. Buda, M., Maki, A., & Mazurowski, M. A. (2018). A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks*, 106, 249–259. <https://doi.org/10.1016/j.neunet.2018.07.011>
19. Prechelt, L. (2012). Early stopping – but when?. In *Neural Networks: Tricks of the Trade* (pp. 5–67). Springer. [https://doi.org/10.1007/978-3-642-35289-8\\_5](https://doi.org/10.1007/978-3-642-35289-8_5)
20. Smith, L. N. (2018). A disciplined approach to neural network hyper-parameters: Part 1 – learning rate, batch size, momentum, and weight decay. *arXiv preprint arXiv:1803.09820*. Retrieved from: <https://arxiv.org/abs/1803.09820>
21. Yang, P., Zhang, L., Zhao, W., & Xie, X. (2020). Retinal vessel segmentation using a U-Net based convolutional neural network. *Symmetry*, 12(4), 611. <https://doi.org/10.3390/sym12040611>
22. Rahman, M. A., & Wang, Y. (2016). Optimizing intersection-over-union in deep neural networks for image segmentation. In *International Symposium on Visual Computing* (pp. 234–244). Springer. [https://doi.org/10.1007/978-3-319-50835-1\\_22](https://doi.org/10.1007/978-3-319-50835-1_22)
23. Liu, X., Song, L., Liu, S., & Zhang, Y. (2019). A review of deep-learning-based medical image segmentation methods. *Sustainability*, 11(7), 1897. <https://doi.org/10.3390/su11071897>
24. Li, B., Liu, Y., Wang, Y., Li, M., & Liu, Y. (2020). A comparison of clustering algorithms for water body extraction from remote sensing images. *Remote Sensing*, 12(10), 1590. <https://doi.org/10.3390/rs12101590>
25. Duan, W., He, B., Nover, D., Yang, G., Chen, W., Meng, H., & Liu, C. (2019). Water bodies' mapping from Sentinel-2 imagery with modified normalized difference water index at 10-m spatial resolution produced by sharpening the SWIR band. *Remote Sensing*, 11(23), 2779. <https://doi.org/10.3390/rs11232779>
26. Zhou, Z., Siddiquee, M.M.R., Tajbakhsh, N., & Liang, J. (2018). UNet++: A Nested U-Net Architecture for Medical Image Segmentation. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support* (pp. 3–11). Springer. [https://doi.org/10.1007/978-3-030-00889-5\\_1](https://doi.org/10.1007/978-3-030-00889-5_1)
27. Oktay, O., Schlemper, J., Le Folgoc, L., Lee, M., Heinrich, M., Misawa, K., ... & Rueckert, D. (2018). Attention U-Net: Learning Where to Look for the Pancreas. *arXiv preprint arXiv:1804.03999*. Retrieved from: <https://arxiv.org/abs/1804.03999>
28. Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. In *Proceedings of the European Conference on Computer Vision (ECCV)* (pp. 801–818). [https://doi.org/10.1007/978-3-030-01234-2\\_49](https://doi.org/10.1007/978-3-030-01234-2_49)
29. Olena Dobrovolska, Knut Schmidtke, Viktoriia Hnatushenko, Svitlana Sytnyk & Iryna Dmytriieva (2024). Relationship between economic development, forest resources, and forest fires: European context. *Environmental Economics*, 15(2), 77–92. doi:10.21511/ee.15(2).2024.06.
30. Hnatushenko, V. V., Mozgovoy, D. K., Hnatushenko, V. V., Spiritsev, V. V., Udovych, I. M. (2019). All-weather monitoring of oil and gas production areas using satellite data // Scientific bulletin of National Mining University. *State Higher Educational Institution "National Mining University"*, Dnipro, № 6 (158). C. 99–105.