УДК 004.8:336.76

МЕТОДИ МАШИННОГО НАВЧАННЯ ДЛЯ РОЗПІЗНАВАННЯ НАФТОВИХ ПЛЯМ ЗА ДОПОМОГОЮ СУПУТНИКОВИХ ЗНІМКІВ

М. Л. Нагорський[1,a], Г. О. Яйлимова[1]

[1] Навчально-науковий Фізико-технічний інститут

Анотація

Стаття присвячена аналізу та обробці супутникових одноканальних знімків для виявлення нафтових розливів. Метою роботи є розробка та порівняння ефективності різних нейронних моделей у задачі сегментації зображень. Для досягнення поставленої мети було виконано попередню обробку даних. Важливою частиною дослідження стало навчання моделей на одній географічній області та їх подальше застосування у іншій, що дозволило оцінити універсальність моделей.

Ключові слова: супутники, SAR, нафтові плями, SegNet, FCN, U-Net

Вступ

У світі, де довкілля все частіше потерпає від екологічних викликів, нафтові розливи є особливою проблемою. Вони залишають після себе тривалі наслідки на природі, завдають удару по економіці прибережних місць і створюють ризики для здоров'я людей.

Тому виявлення нафтових плям якомога раніше і точний аналіз їх розташування та розмірів може суттєво допомогти у зменшенні їх негативного впливу.

Роботу виконано в рамках проєкту європейської комісії HORIZON Europe project iMERMAID «Інноваційні рішення для відновлення середземноморської екосистеми шляхом моніторингу та деактивації від хімічного забруднення», («Innovative solutions for Mediterranean Ecosystem Remediation via Monitoring and Decontamination from Chemical Pollution», контракт номер 101112824) [1].

1. Теорія

1.1. U-Net

Модель U-Net – це архітектура нейронної мережі, спеціально розроблена для завдань сегментації зображень (рис. 1). Основна особливість U-Net полягає у її структурі, яка має форму букви U і складається з двох шляхів: стискаючого (кодувального) та розширювального (декодувального).

Стискаючий шлях працює як типова згорткова нейронна мережа, зменшуючи просторові розміри зображення і збільшуючи кількість ознакових каналів. Цей етап допомагає аналізувати та класифікувати зображення. Розширювальний шлях реконструює зображення з набраних ознак, поступово збільшуючи його розміри та зменшуючи кількість ознакових каналів. Це дозволяє досягти деталізованої сегментації з високою точністю. При цьому важливою особливістю є використання зв'язків пропускання (skip connections), які передають інформацію зі стискаючого шляху в розширювальний, це дозволяє поєднувати контекст з високорівневою інформацією для більш точної сегментації.

U-Net широко застосовується у медичній сегментації зображень, але також виявилася ефективною для сегментації в інших галузях, наприклад, у виявленні нафтових плям на супутникових знімках. Завдяки своїй архітектурі, U-Net може працювати з обмеженою кількістю навчальних даних, але все ще забезпечує високу точність сегментації [2].

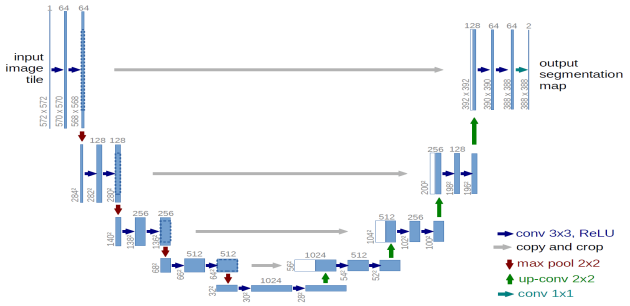

Рис. 1. U-Net [3]

1.2. SegNet

Модель SegNet – це конволюційна нейронна мережа, яка використовується для семантичної сегментації зображень (рис. 2). Ця модель була розроблена для точного піксельного прогнозування, яке необхідне у багатьох застосуваннях, таких як розпізнавання дорожніх сцен, аналіз медичних зображень та обробка супутникових знімків [4].

Основна особливість SegNet полягає в її архітектурі, яка складається з енкодерної (кодувальної) і

[a] nahorskyi.max@lll.kpi.ua

декодерної (розкодувальної) частин. Енкодерна частина зазвичай базується на згортковій нейронній мережі і використовується для аналізу та видобування ознак із вхідних зображень. Декодерна частина мережі використовує ці ознаки для генерації сегментаційних мап, які показують, до якого класу належить кожен піксель вихідного зображення.

Однією з ключових особливостей SegNet є використання індексів максимальних значень під час операцій пулінгу в енкодері, які зберігаються і використовуються в декодері для більш точного відновлення розміщення пікселів. Це дозволяє SegNet ефективно відновлювати детальну інформацію про межі об'єктів у зображенні, що є важливим для багатьох застосувань.

SegNet особливо ефективна для обробки зображень, де потрібно зрозуміти контекст на рівні пікселів, таких як виявлення нафтових плям на супутникових знімках. Вона дозволяє точно ідентифікувати і класифікувати різні об'єкти на знімках завдяки своїй здатності аналізувати великі обсяги даних і виділяти характеристики на різних рівнях глибини.

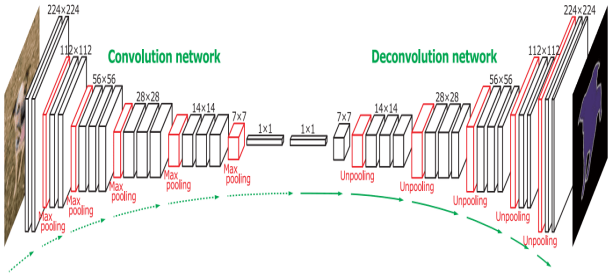

Рис. 2. SegNet [4]

1.3. FCN

Модель повнозв'язної конволюційної мережі (FCN, Fully Convolutional Network) – це тип нейронної мережі, який широко використовується для задач семантичної сегментації (рис. 3). FCN модель була вперше представлена у дослідженні Джонатана Лонга та його колег у 2015 році.

Основною особливістю FCN є те, що вона замінює повнозв'язні шари, які зазвичай використовуються в класичних конволюційних мережах, на конволюційні шари. Це дозволяє мережі приймати зображення будь-якого розміру та ефективніше обробляти великі зображення, такі як супутникові знімки. Ключові компоненти FCN:

Конволюційні шари, призначені для виявлення особливостей на зображеннях. З їх допомогою мережа аналізує зображення та виділяє важливі характеристики.

Після того, як зображення проходить через конволюційні шари, воно зазвичай має менший розмір через пулінг. Шари зсуву (upsampling layers) дозволяють відновити оригінальний розмір зображення шляхом упорядкування характеристик, отриманих на попередніх етапах.

Перехресні шари (skip connections) використовуються для комбінування глибоких, семантично багатих інформаційних шарів з менш глибокими шарами, що мають більшу просторову точність. Це допомагає покращити точність сегментації на краях об'єктів.

Модель FCN дозволяє точно виділити нафтові плями на великих знімках, автоматизувати процес виявлення та забезпечити оперативне реагування на екологічні катастрофи [5].

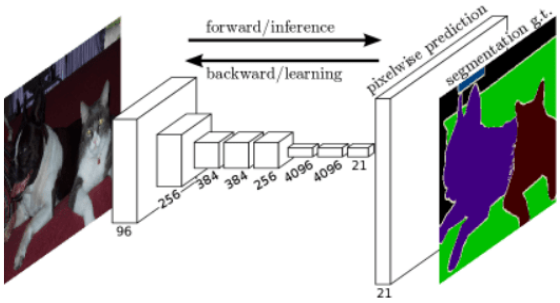

Рис. 3. FCN [5]

2. Вирішення проблеми розпізнавання нафтових плям

2.1. Постановка задачі

Метою цієї роботи є реалізація та порівняння методів для виявлення нафтових плям у морському середовищі з використанням супутникових зображень. Завдання полягає в ідентифікації нафтових плям на основі даних дистанційного зондування, а саме аналіз зображень SAR супутників.

План роботи:

1. Проведення детального аналізу даних, отриманих від супутників синтетичної апертурної радіолокації, для оцінки їхньої ефективності в виявленні нафтових плям.
2. Аналіз та обробка супутникових знімків.
3. Вдосконалення алгоритмів нейронних моделей.
4. Навчання моделей на певній області.
5. Порівняння моделей на тестових данних.

2.2. Створення датасету

В роботі використані канали з поляризацією VV радарних даних супутника Sentinel-1, оскільки вони є найбільш інформативними для визначення нафтових плям [6]. Супутникові дані розташовані на сході та півдні США та були розділені на тестові та навчальні (рис. 4), значення яких представляли середнє за певний період і відповідні маски містили значення, де 0 – це вода, а 1 – нафтова пляма. Першим кроком знімки було поділено на сегменти розміром 256x256 пікселів, в результаті чого було отримано 2387 знімків. Ці знімки були перетворені в матриці. На наступному етапі було проведено фільтрацію: були видалені знімки, що не містили жодного значення нафти, залишилося 160 знімків. З цих знімків були вибрані ті, в яких було понад 5000 пікселів з

нафтовими плямами, кількість яких склала 80. Ці зображення було дубльовано шляхом віддзеркалення по вертикалі та горизонталі та поворотів на 90, 180, 270 градусів, збільшивши кількість навчальних знімків до 800. Знімки, що містили значення Nan, були видалені, а решта була нормалізована (формула 1), в результаті чого було отримано 781 знімків для навчання.

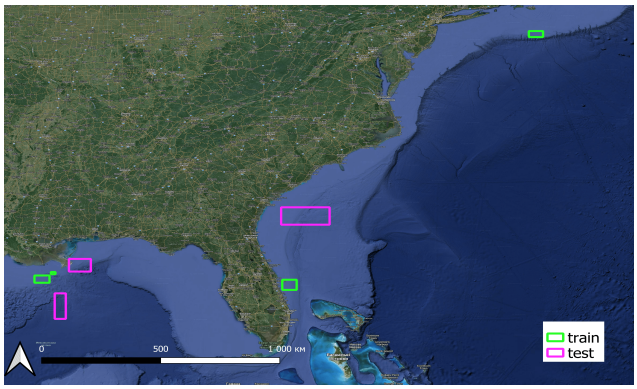

Рис. 4. Навчальні та тестові області знімків

$$A_{\text{norm}} = \frac{A - \min(A)}{\max(A) - \min(A)}, \tag{1}$$

- A – початкова матриця значень;
- $\min(A)$ – мінімальне значення в матриці A;
- $\max(A)$ – максимальне значення в матриці A;
- A_{norm} – результат нормалізації матриці A, де всі значення будуть масштабовані до діапазону від 0 до 1.

2.3. Результати моделей

Intersection over Union (IoU) є метрикою, яка вимірює ступінь перекриття між прогнозованою сегментацією та істинною сегментацією об'єктів у задачі комп'ютерного зору. IoU розраховується за формулою:

$$\text{IoU}(A, B) = \frac{|A \cap B|}{|A \cup B|}, \tag{2}$$

- A – множина пікселів прогнозованої сегментації,
- B – множина пікселів істинної сегментації.

Метрика F1-score є гармонійним середнім між точністю та повнотою, що дозволяє оцінити баланс між цими двома аспектами при класифікації. F1-score розраховується за формулою:

$$\text{F1-score} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}, \tag{3}$$

- Precision – це відношення кількості істинно позитивних результатів до загальної кількості позитивних результатів, передбачених моделлю.
- Recall – це відношення кількості істинно позитивних результатів до кількості позитивних результатів у даних.

В таблиці 1 наведені результати метрик, отриманих на тестових даних, для задачі класифікації нафтових плям за допомогою алгоритмів SegNet, FCN та U-Net.

(а) Результати моделі FCN

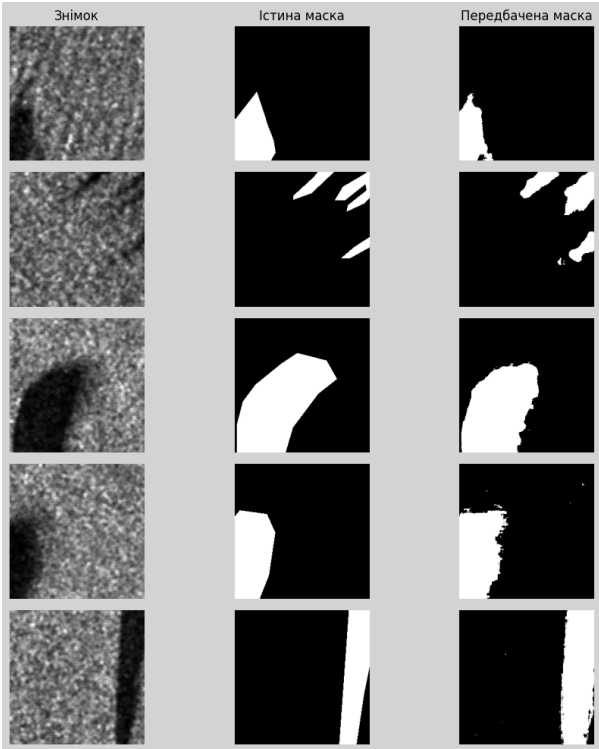

(б) Результати моделі SegNet

Рис. 5. Результати моделі FCN, SegNet

Таблиця 1. Порівняння ефективності моделей

Модель	Точність	F1	IoU
SegNet	0.97	0.72	0.1876
FCN	0.95	0.63	0.2258
U-Net	0.90	0.47	0.1408

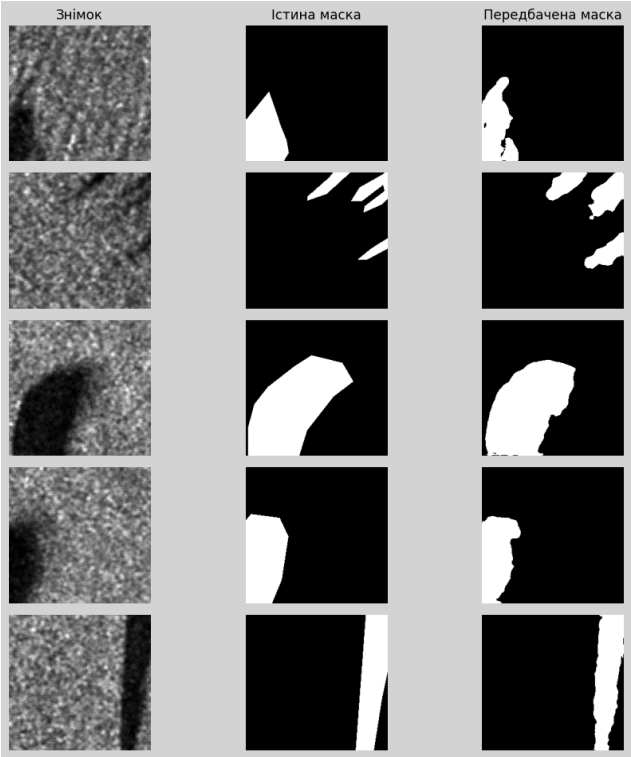

Рис. 6. Результати моделі U-Net

Висновки

У рамках даної роботи було виконано порівняльний аналіз трьох різних моделей нейронних мереж: SegNet, FCN та U-Net, для вирішення задачі розпізнавання нафтових плям на супутникових знімках. Основна мета полягала у визначенні найбільш ефективної моделі за такими критеріями, як точність, F1-міра та IoU. На рисунках 5(а), 5(б), 6 було показано результати моделей FCN, SegNet та U-Net.

За результатами дослідження, модель SegNet продемонструвала найвищу точність (0.97) та показники F1-міри (0.72), що робить її оптимальним вибором для завдань, де критично важлива висока точність розпізнавання. Водночас, FCN та U-Net мають дещо нижчі показники, але також можуть бути застосовані в залежності від специфічних потреб та умов задачі.

Таким чином, розглянувши всі аспекти дослідження, SegNet виявилася найкращою моделлю для використання у проєктах, пов'язаних з ідентифікацією та моніторингом нафтових забруднень на морських просторах. Це дозволяє рекомендувати SegNet для подальших розробок та впровадження в практику дистанційного зондування землі.

Перелік використаних джерел

1. URL: https://imermaid.eu/.
2. U-Net and Its Variants for Medical Image Segmentation: A Review of Theory and Applications / S. Nahian, P. Sidike, E. C. P., D. Vijay // IEEE Access. — 2021. — T. 9. — C. 82031—82057. — DOI: 10.1109/ACCESS.2021.3086020.
3. *Olaf R.*, *Philipp F.*, *Thomas B.* U-Net: Convolutional Networks for Biomedical Image Segmentation // CoRR. — 2015. — T. abs/1505.04597. — arXiv: 1505.04597 [cs.CV]. — URL: http://arxiv.org/abs/1505.04597.
4. *Hyeonwoo N.*, *Seunghoon H.*, *Bohyung H.* Learning Deconvolution Network for Semantic Segmentation // CoRR. — 2015. — T. abs/1505.04366. — arXiv: 1505.04366. — URL: http://arxiv.org/abs/1505.04366.
5. *Jonathan L.*, *Evan S.*, *Trevor D.* Fully Convolutional Networks for Semantic Segmentation // CoRR. — 2015. — T. abs/1411.4038. — arXiv: 1411.4038 [cs.CV]. — URL: http://arxiv.org/abs/1411.4038.
6. *Niyazi A.* Assessment of oil spills using Sentinel 1 C-band SAR and Landsat 8 multispectral sensors // Environmental Monitoring and Assessment. — 2018. — T. 190, № 11. — C. 637. — DOI: 10.1007/s10661-018-7017-4.