

ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ АПРОКСИМАЦІЇ РОЗМІРІВ НАЗЕМНИХ ОБ'ЄКТІВ

Анотація. Терабайти даних супутникових зображень надвисокої роздільної здатності надсилаються на наземні станції щохвилини, із них використовується лише 5% для вирішення задач різного спектру, що підвищує значущість автоматизацію як методу прискорення процедур обробки зображень. Семантична сегментація мап є одним із популярних способів для вирішення широкого кола проблем, таких як спостереження, моніторинг рослинності, виявлення змін в забудові тощо. Сьогодні підходи до обробки зображень на базі глибокого навчання пропонують дуже гнучкі інструменти для різних потреб включаючи семантичну сегментацію. За допомогою глибокого навчання можна отримати унікальні знання з даних та адаптувати моделі та алгоритми для конкретних даних для досягнення найкращих результатів. У роботі пропонується комплексна автоматизована технологія розрахунку розмірів наземних об'єктів. Пропонована технологія застосовує переваги глибокого навчання для семантичної сегментації в комбінації з класичними методами обробки зображень та лінійної алгебри.

Ключові слова: дистанційне зондування, зображення, глибоке навчання, семантична сегментація, маски, апроксимація.

Постановка проблеми. Незважаючи на стрімкий розвиток інструментів та засобів обробки великих даних (Big data), на сьогодні, проблема автоматизованої або, навіть, автоматичної обробки залишається майже не вирішеною, зокрема в області дистанційного зондування Землі (ДЗЗ). Більшість існуючих рішень обробки графічних даних розроблені для вилучення інформації із трьохканальних зображень що кодують значення відбиття видимого спектру світла.

Специфіка ж зображень ДЗЗ полягає у більш складній структурі зображення, що часто містить 16 та більше каналів видимого та невидимого спектрів. Часто такі зображення також містять неграфічні метаданні які мають певну користь при побудові ознак для алгоритмів машинного навчання. Навіть враховуючи, що низка рішень в області машинного та глибокого навчання націлені

саме на дані ДЗЗ, зазначені особливості графічних даних ДЗЗ часто ігноруються при вирішенні задач інструментами машинного навчання.

Ще одною, але не менш важливою проблемою є швидкість обробки даних аби вони втрачали якомога менше свою актуальність. Будь-яка місцевість, що вивчається постійно змінюється, а час отримання результатів часто вимірюється в днях або навіть тижнях. Для вирішення цього кластеру проблем часто застосовують масштабовані засоби, що пропонують хмарні технології. Задля ефективного використання хмарних або наземних (on-premise) ресурсів є запит на підходи до автоматизації процесів обробки даних.

Аналіз останніх досліджень. Останні роки семантична сегментація наземних об'єктів все більше використовується у програмах та системах ДЗЗ. Сегментовані карти інтенсивно застосовуються у різних сферах, таких як містобудування, сільськогосподарські програми, оцінка руху та моніторинг як на суші, так і на воді тощо. Зазвичай розглядаються дві категорії підходів при вирішенні проблем семантичної сегментації - чіткі алгоритми, засновані на визначених вручну характеристиках, або стохастичні підходи, зокрема ті, що базуються на глибокому навчанні, які в значній мірі покладаються на властивості глибоких нейронних мереж згортки [1].

Беручи до уваги той факт, що на основі функціональних чітких алгоритмів та інших підходів до машинного навчання без використання нейронних мереж можна успішно застосовувати для вирішення певних проблем обробки супутникових зображень, глибоке навчання все ще залишається більш доцільним у довгостроковій перспективі [2]. Розвитком нейронних мереж глибокого вивчення прямого поширення стало чергування згорткових та шарів пулінгу максимального значення [3], вдосконалених декількома повнозв'язними або слабозв'язними шарами, і, відповідно, наступним верхнім шаром класифікації.

Більшість рішень для глибокого навчання використовують нейромережеві структури, засновані на згорткових нейронних мережах. Деякі нейронні мережі більше підходять для різних завдань - ДЗЗ не є виключенням. Однією з проблем, яка існує навіть сьогодні для обробки зображень з ДЗЗ, є те, що її часто потрібно обробляти по частинах або тайлами, оскільки більшість нейромереж обробляють 3-канальні зображення набагато меншої роздільної здатності, коли більшість зображень ДЗЗ можуть досягти роздільної здатності близько кілька сот мільйонів пікселів. Повнозгорткова нейронна мережа (Fully convolutional network) була винайдена для вирішення згаданої проблеми [4]. Використовуючи цей тип нейронної мережі, можна сформулювати сегмен-

товану карту будь-якого розміру. Іншим популярним підходом для семантичної сегментації є архітектура кодувальника-декодувальника, в результаті якої формується семантична карта тієї ж роздільної здатності та розмірів, що і вихідне зображення.

У більшості випадків результати рішень для глибокого навчання для ДЗЗ успішно застосовуються лише до певного типу зображень, з якими він був впроваджений і протестований. Однак існують винятки, коли належне поєднання архітектур нейронних мереж та параметрів вирішило проблему семантичної сегментації для подібних зображень з різних супутникових апаратів. Ці проблеми та рішення детально описані в [5].

У поточній роботі модифікована пропонується Unet-подібна архітектура сімества автокодувальників для обробки даних гіперспектральних зображень із високою роздільною здатністю WorldView-3. В даній роботі зображення WorldView-3 використовуються для розробки набору даних для навчання пропонуваної архітектури нейронної мережі. Додаткові шари розроблені і додані на виході архітектури нейронної мережі, щоб відокремити екземпляри виявлених наземних об'єктів та виконати алгоритм вимірювання фізичних параметрів щільності наземних об'єктів.

Метою даної роботи є розробка автоматизованої end-to-end технології для розпізнавання і високоточної апроксимації наземних об'єктів на знімках надвисокої роздільної здатності (VHR).

Викладення основного матеріалу. Алгоритм дій по розробці рішення складається з двох частин:

- Розробка нейромережі
- Післяобробка результатів

Архітектура нейронної мережі. Протягом останніх років архітектура Unet є популярним вибором у багатьох областях досліджень, де потрібна семантична сегментація. Спочатку Unet був розроблений для біомедичної сегментації зображень [6]. Однак сьогодні Unet успішно застосовується в інших галузях знань, включаючи ДЗЗ [3].

Основним напрямком цього дослідження є подальша обробка результатів сегментації Unet, тому була зроблена додаткове тонке налаштування нейронної мережі, яка використовується в поточній роботі, щоб оптимізувати алгоритм розділення цілої маски на окремі екземпляри та вимірювань фізичних параметрів наземних об'єктів.

Пропонована нейронна мережа складається з:

- Вхідний шар розміром $512 \times 512 \times 3$
- 5 блоків кодувальника (рис. 1)
- 1 стандартний блок згортки (рис. 1)
- 1 додатковий блок згортки (рис. 1)
- 5 блоків декодувальника (рис. 1)
- Вихідний шар розміром $512 \times 512 \times 3$ із сигмоїдною функцією активації.

На відміну від більшості Unet-подібних архітектурних застосувань, відсівання значень вагів не використовується в поточній роботі - у проведених експериментах різні комбінації шарів відсіювання, не показали жодних поліпшень для алгоритму апроксимації.




Рисунок 1 - Магістральні блоки пропонованої архітектури неймережі

Навчання проводилось на 4255 навчальних та 759 зразках перевірки. Випадковий відтінок, горизонтальне перевертання та зміщення по ширині, по висоті застосовуються як методи аугментації набору навчальних даних. Вибрано значення дельти відтинку - 0,1. Останнє - не застосовується до набору даних перевірки.

Існують метрики, спеціально розроблені для адекватного вимірювання ефективності рішень на базі глибокого навчання. Спеціальні метрики та функції втрат були розроблені в поточній роботі для кращого представлення ефективності нейронної мережі та ефективності алгоритму післяобробки.

Оскільки однію з цілей роботи було досягти задовільних результатів сегментації екземплярів, було вирішено застосувати модифікований коефіцієнт Дайса (міра F1)

$$F1 = \frac{1}{N} \sum_{i=0}^n \frac{2 * p(y_i) * y_i + 1}{p(y_i) + y_i + 1} \quad (1)$$

де $p(y_i)$ – розпізнані пікселі і y_i – істинні значення пікселів, доступні з навчальних даних.

Він був успішно використаний в [7] для представлення якості результатів сегментації екземплярів. Оригінальний коефіцієнт Дайса модифікується додаванням одиниці для частин перетину та об'єднання в рівнянні, щоб запобігти діленню на нуль. Крім того, для тренування використовується функція втрати із застосуванням (1)

із застосуванням (1)

$$loss_{F1} = 1 - F1, \quad (2)$$

де $F1$ визначено в (1). Функція втрат Дайса - це метрика для вимірювання перекриття істинних значень пікселів та сегментованих пікселів (масок). Метрика втрат Дайса дуже гнучка і може бути додатково оптимізована, що може покращити результати [8], але в поточній роботі така оптимізація не досліджується.

На жаль, використання архітектури нейронної мережі з (2) призвело до повного сходження функції втрат. Для подолання цієї проблеми було впроваджено вдосконалення функції втрат, що допомогло в іншій проблемі з використанням подібної моделі нейронної мережі [9]. Рішення полягає у визначенні більш комплексної функції втрат

$$loss = loss_{F1} + loss_{bce}, \quad (3)$$

де $loss_{bce}$ - функція бінарної перехресної ентропії або логарифмічної функції втрат, яка визначається як

$$loss_{bce} = -\frac{1}{N} \sum_{i=0}^n y_i * \log(p(y_i)) + (1 - y_i) * \log(1 - p(y_i)), \quad (4)$$

де $p(y_i)$ є сегментована маска і y_i є анотована істинна маска, доступна з навчальних даних.

Техніку змішаної точності було застосовано для того, щоб покращити швидкість тренування відносно великої моделі (10 мільйонів параметрів) в обмеженому навчальному середовищі (Google Collaboratory). Техніка змішаної точності докладно описана в [10].

Кінцеві результати навчання наведені в таблиці 1.

Таблиця 1

Результати тренування пропонованої нейромережі

Метрика	Значення
Точність (Accuracy)	0,9834
Точність (Precision)	0,9217
Повнота (Recall)	0,7641
Міра F1	0,8355

Отримані результати порівняні з такими що в аналогічних роботах [3], які мають більш кращий показник повноти результатів і таку саму точність із точністю до сотих.

Попереднє дослідження показало, що більша кількість епох тренування і очищення наборів даних є головним фактором кращого значення повноти.

Алгоритм апроксимації розмірів. Головною метою поточної статті є післяобробка результатів сегментації, яка реалізована як верхні шари для Unet-подібної магістральної архітектури. Ця подальша обробка може виконує кілька послідовних кроків:

- Поділ на окремі об'єкти цільної маски.
- Семантичне маркування.
- Об'єднання масок за комплексною розрахованою ознакою близькості граничних пікселів.
- Вилучення наддрібних пікселів на кількісною ознакою.
- Розрахунок фізичних розмірів із використанням утворених окремих масок і спектральних характеристик пікселя.
- Розрахунок щільності забудови.

Вихідні дані Unet - це піксельні значення відтінків сірого в діапазоні 0..1, які представляють ступінь належності пікселя до певного класу. Для того, щоб правильно відрізнити виявлені маски від фону, необхідно застосувати певне порогове значення, щоб кожен піксель можна було розділити за цим значенням.

Більшість досліджень використовують середнє значення 0,5. Однак для запропонованого підходу інше значення дало точніші результати. Це значення отримується шляхом застосування методу Оцу [11] до результатів сегментації для розрахунку порогового значення, що використовується для класифікації

всіх пікселів на два класи - передній план та фон, що виливається у бінаризоване зображення. Згідно з методом Оцу, оптимальний поріг для бінаризації досягає мінімізації зваженої суми дисперсій у кожному кластері або, з іншого боку, максимальної суми дисперсій між класами.

Додатковий семантичний пошук виконується після розділення для отримання координат та розмірів усіх знайдених об'єктів. Ці координати та розміри використовуються для розрахунків фізичних параметрів та щільності.

Ця частина післяобробки вважається найпростішою з точки зору складності обчислень. Він базується на знанні структури супутникових знімків. Відомо, що довжина і ширина одного пікселя становлять 31 см, що дає можливість розрахувати фізичні параметри виявлених об'єктів.

Для одного об'єкта обчислюється прямокутник мінімальної площі, що повністю описує полігональну маску об'єкта. Цей прямокутник побудований із знайденими найбільшими вертикальним та горизонтальним діаметрами.

З використанням розрахункового діаметра наземних об'єктів приймаються фізичні параметри - периметр (5), квадратна площа (6).

$$P = 2 * v_{max} + 2 * h_{max}, \quad 5)$$

де h_{max} - максимальний горизонтальний діаметр, прийнятий з мінімального прилягаючого прямокутника, v_{max} - вертикальний.

$$S = v_{max} * h_{max}, \quad 6)$$

де h_{max} та v_{max} - це максимальні горизонтальний та вертикальний діаметри відповідно.

Щільність забудови обчислюється за допомогою (7) як відсоток усіх пікселів, визначених як наземні об'єкти, до загальної кількості пікселів зображення. Хоча ці розрахунки передбачають лише фізичні розміри земельного об'єкта, оскільки система ШІ не може бути 100% точною, формула також враховує корекцію, використовуючи значення точності та відкликання як фактор.

$$ШЗ = \frac{\text{точність}}{\text{повнота}} * \frac{\sum_{i=0}^m p(y_i)}{\sum_{j=0}^n x_j}, \quad 7)$$

де m - кількість сегментованих пікселів, n - загальна кількість пікселів зображення, $p(y_i)$ - прогнозований піксель та x_j - піксель зображення. Точність та Повнота - це відповідні метрики нейронної мережі, отримані під час перевірки етапу навчання.

Експерименти проводились кількома різними способами – модульним та інтеграційним: для нейронної мережі, алгоритмів апроксимації та для всієї системи. Необхідність таких умов обґрунтовується модульністю та порівняльністю кожної частини з подібними підходами для попередньої обробки, обробки нейронною мережею та післяобробки.

Для вимірювання ефективності нейронної мережі обчислюється точність, відкликання та оцінку F1 та порівнюється із іншими сучасними Unet-подібними рішеннями нейронної мережі для семантичної сегментації зображень ДЗЗ надвисокої роздільної здатності. Запропонована архітектура порівнюється з оригінальною Unet, HSFA-Unet, Refined Unet [3], Stacked Unets [12].

Усі згадані нейронні мережі працюють на наборі даних, який використовується для розробки та тестування в поточній роботі [13]. Результат тестування нейронних мереж наведено в таблиці 2.

Оригінальна Unet дещо краща з точки зору загальної ефективності, але запропонована Unet-подібна архітектура є кращою з огляду на застосування процедури постобробки через значно більшу точність, ніж у оригінальній Unet архітектурі.

У поточному дослідженні пропонується підхід до автоматизованої технології із застосуванням штучного інтелекту та класичних алгоритмів обробки зображень та лінійної алгебри, що включає попередню обробку даних і розробку набору даних для нейромережі, моделювання нейронної мережі та модуль розрахунку фізичних розмірів наземних об'єктів.

Таблиця 2

Порівняння ефективності нейронних мереж із запропонованою

Нейронна мережа	Точність	Повнота	Mira F1
SA	0.9437	0.7532	0.837757
Unet	0.9116	0.8023	0.853465
HSFA-Unet	0.8135	0.7422	0.776216
Refined Unet	0.8915	0.7211	0.797297
Stacked Unets	0.8327	0.6678	0.741189

Етап попередньої обробки значною мірою покладається на результати попередньої роботи [13]. Ці результати пропонують повний підхід до розробки набору даних для вирішення проблем ДЗЗ, який використовується в поточному дослідженні із мінімальними змінами, що включають додаткові методи збіль-

шення набору даних та покращення зображення для підвищення ефективності обробки нейронної мережі та алгоритму апроксимації фізичних розмірів наземних об'єктів.

Друга частина рішення підкреслює актуальність Unet для задач ДЗЗ, пропонуючи інший підхід до налаштування цієї архітектури для вирішення багатьох різноманітних проблем та викликів, включаючи сегментацію окремих екземплярів та вимірювання наземних об'єктів, для яких вона спочатку не призначена. Розроблені спеціальні метрики та функції втрат, які доповнюють подальшу обробку результатів семантичної сегментації та можуть бути застосовані при вирішенні завдань вимірювання наземних об'єктів, в таких галузях як містобудування тощо. Стаття пропонує всю необхідну інформацію для успішного проведення описаного експерименту.

Післяобробка у вигляді алгоритму апроксимації є основною частиною дослідження. Усі попередні роботи, що стосуються конфігурації нейронної мережі та розробки користувацьких метрик, виконуються для доповнення, оптимізації та тестування алгоритму апроксимації вимірювань. Пропоноване рішення вирішує дуже прикладне завдання повністю автоматизовано - взаємодія з іншими системами або оператором абсолютно не потрібна.

Усі результати в даний час застосовуються до єдиного класу об'єктів - будівлі. Інші класи об'єктів планується додати до набору даних у майбутньому. Оскільки джерело, якщо дані залишаються незмінними - зображення WorldView-3, розроблений підхід продемонструє однакову ефективність для нових класів об'єктів, якими можуть бути дерева, транспортні засоби тощо.

Висновки. Доведено, що запропонований комплексний підхід дає багатообіцяючі результати при обробці багатьох типів даних супутникових зображень дуже високої роздільної здатності. Поточне дослідження демонструє задовільну якість обробки зображень WorldView-3. Отримані результати дозволяють зробити висновок, що методи, запропоновані в цій дослідницькій роботі, придатні для мульти- та гіперспектральних зображень дуже високої роздільної здатності, таких як дані супутникових зображень. Незважаючи на те, що підхід та методи застосовуються до даних зображень WorldView-3 у поточній роботі, він не обмежений штучно і може бути використаний у подібних супутникових знімках для іншого супутникового апарату, такого як Landsat або Sentinel.

Застосування запропонованих методів до різних зображень ДЗЗ можливо завдяки гнучкості інструментів глибокого навчання, а всі аспекти адаптації та

оптимізації для використання з різними зображеннями висвітлюються в попередніх розділах.

Іншим важливим аспектом роботи є те, що вона демонструє застосування інструментів глибокого навчання на не популярних зображеннях ДЗЗ, що є у відкритому доступі (таких як Landsat 8, GeoEye-1 або Sentinel- 2), а комерційних - WorldView-3, що на сьогодні надають максимально можливу роздільну здатність, якість та найменш охоплені дослідженнями дані у порівнянні із державними супутникових апаратами переліченими вище. Крім того, краща роздільна здатність, якість та інформаційний вміст зображень WorldView-3 можуть впливати на рішення, що використовують глибоке навчання, різними способами. Через специфіку нейронних мереж цей вплив може як покращити так і погіршити результат, що потребуватиме додаткових досліджень. Останнє, підвищує важливість висвітлення досліджень "непопулярних" комерційних супутникових знімків. Комерційні знімки ДЗЗ дуже важливі з точки зору застосування їх в різних галузях знань завдяки своїй, зазвичай, кращій технічній якості, ніж супутники загального користування. Також, комерційні знімки забезпечують краще покриття Землі через частоту реєстрації, що може мати вирішальне значення для виявлення змін та реагування на гуманітарної кризи будь-яких видів.

ЛІТЕРАТУРА

1. Дмитро Мозговий, Володимир Гнатушенко та Володимир Васильєв "Оцінка точності автоматизованого розпізнавання об'єктів за допомогою мультиспектральних аерозображень та нейронної мережі", Зб. SPIE 10806, десята міжнародна конференція з цифрової обробки зображень (ICDIP 2018), 108060H (9 серпня 2018 р.); <https://doi.org/10.1117/12.2502905>.
2. Юань, Цянцян та ін. "Поглиблене вивчення дистанційного зондування навколишнього середовища: досягнення та проблеми". Дистанційне зондування довкілля 241 (2020): 111716.
3. Він Нанджун, Леюан Фанг та Антоніо Плаза. "Гібрид Unet першого та другого порядку уваги для побудови сегментації у зображеннях дистанційного зондування." Science China Information Sciences 63.4 (2020): 1-12.
4. Юань, Цянцян, Х. Шень, Т. Лі, Чжи-Вей Лі, Шувен Лі, Юнь Цзян, Хунчжан Сю, В. Тан, К. Ян, Цзівен Ван, Цзяньхао Гао і Лянгпей Чжан. "Поглиблене вивчення дистанційного зондування навколишнього середовища: досягнення та проблеми". Дистанційне зондування довкілля 241 (2020): 111716.

5. МОЙ Сайфі, Дж. Сінгла, Микіта. Основи глибокого навчання для семантичної сегментації супутникових зображень. 2020 Четверта міжнародна конференція з обчислювальних методологій та зв'язку (ICCMC). doi: 10.1109 / iccmc48092.2020.iccmc-00069
6. Т. Шоттнер, (2019, 16 травня). Чому дані слід нормалізувати перед навчанням нейронної мережі. Середній. URL: <https://towardsdatascience.com/why-data-should-be-normalized-before-training-a-neural-network-c626b7f66c7d> .
7. Олаф Роннебергер, Філіп Фішер та Томас Брокс. "U-net: згорткові мережі для біомедичної сегментації зображень." Міжнародна конференція з обчислень медичних зображень та комп'ютерного втручання. Спрінгер, Чам, 2015.
8. Володимир Гнатушенко та Вадим Жерновий. "Метод вдосконалення сегментації екземплярів для зображень дистанційного зондування дуже високої роздільної здатності за допомогою глибокого навчання" . У: Бабічев С., Пелешко Д., Винокурова О. (ред.) . Видобування та обробка потоку даних. DSMP 2020. Комунікації в комп'ютерній та інформаційній науці, вип. 1158. Спрінгер, Чам. https://doi.org/10.1007/978-3-030-61656-4_21.
9. Міллетарі Фаусто, Насір Наваб та Сейєд-Ахмад Ахмаді. "V-net: повністю згорнуті нейронні мережі для об'ємної сегментації медичних зображень." 2016 четверта міжнародна конференція з питань 3D зору (3DV). IEEE, 2016.
10. Виклик маскування зображень Carvana Каггл. (2015). URL: Kaggle. <https://www.kaggle.com/c/carvana-image-masking-challenge/discussion/40199>
11. П. Мічікевічус, С. Наранг, Дж. Альбен, Г. Діамос, Е. Ельсен, Д. Гарсія, & Х. Ву. Змішана точність навчання. препринт arXiv arXiv: 1710.03740, 2017.
12. Нобуюкі Оцу. Msgstr "Метод вибору порогу з гістограм рівня сірого". Транзакції IEEE щодо систем, людини та кібернетики, вип. 9, № 1, с. 62-66, січень 1979 р., Doi: 10.1109 / TSMC.1979.4310076.
13. А. Гош, М. Ерліх, С. Шах, Л. Девіс та Р. Челлаппа. Складені U-мережі для сегментації наземного матеріалу на знімках з дистанційним зондуванням. 2018 Конференція IEEE / CVF з питань комп'ютерного зору та розпізнавання зразків (CVPRW), с.252-256. doi: 10.1109 / cvprw.2018.00047 .

REFERENCES

1. Dmytro Mozghovyi, Volodymyr Hnatushenko та Volodymyr Vasyliiev "Otsinka tochnosti avtomatyzovanoho rozpiznavannia ob'ektiv za dopomohoiu multispektralnykh aerezobrazhen ta neironnoi merezhi", Zb. SPIE 10806, desiata

mizhnarodna konferentsiia z tsyfrovoy obrobky zobrazen (ICDIP 2018), 108060H (9 serpnia 2018 r.); <https://doi.org/10.1117/12.2502905>.

2. Iuan, Tsiansian ta in. "Pohlyblene vyvchennia dystantsiinoho zonduvannia navkolyshnoho seredovyscha: dosiahnennia ta problemy". Dystantsiine zonduvannia dovkillia 241 (2020): 111716.

3. Vin Nandzhun, Leiuan Fanh ta Antonio Plaza. "Hibryd Unet pershoho ta druhoho poriadku uvahy dlia pobudovy sehmentatsii u zobrazhenniakh dystantsiinoho zonduvannia." Science China Information Sciences 63.4 (2020): 1-12.

4. Iuan, Tsiansian, Kh. Shen, T. Li, Chzhyy-Vei Li, Shuven Li, Yun Tszian, Khunchzhan Siu, V. Tan, K. Yan, Tsziven Van, Tsziankhao Hao i Lianhpei Chzhan. "Pohlyblene vyvchennia dystantsiinoho zonduvannia navkolyshnoho seredovyscha: dosiahnennia ta problemy". Dystantsiine zonduvannia dovkillia 241 (2020): 111716.

5. MOI Saifi, Dzh. Sinhla, Mykita. Osnovy hlybokoho navchannia dlia semantychnoi sehmentatsii suputnykovykh zobrazen. 2020 Chetverta mizhnarodna konferentsiia z obchysliuvalnykh metodolohii ta zviazku (ICCMC). doi: 10.1109 / iccmc48092.2020.iccmc-00069

6. T. Shottner, (2019, 16 travnia). Chomu dani slid normalizuvaty pered navchanniam neironnoi merezhi. Serednii.

URL: <https://towardsdatascience.com/why-data-should-be-normalized-before-training-a-neural-network-c626b7f66c7d>.

7. Olaf Ronneberher, Filip Fisher ta Tomas Broks. "U-net: zghortkovi merezhi dlia biomedychnoi sehmentatsii zobrazen." Mizhnarodna konferentsiia z obchyslen medychnykh zobrazen ta kompiuternoho vtruchannia. Sprinher, Cham, 2015.

8. Volodymyr Hnatushenko ta Vadym Zhernovyi. "Metod vdoskonalennia sehmentatsii ekzempiariv dlia zobrazen dystantsiinoho zonduvannia duzhe vysokoi rozdilnoi zdatnosti za dopomohoiu hlybokoho navchannia". U: Babichev S., Peleshko D., Vynokurova O. (red.). Vydobuvannia ta obrobka potoku danykh. DSMP 2020. Komunikatsii v kompiuternii ta informatsiinii nautsi, vyp . 1158. Sprinher, Cham. https://doi.org/10.1007/978-3-030-61656-4_21.

9. Milletari Fausto, Nasir Navab ta Seied-Akhmad Akhmadi. "V-net: povnistiu zghornuti neironni merezhi dlia obiemnoi sehmentatsii medychnykh zobrazen." 2016 chetverta mizhnarodna konferentsiia z pytan 3D zoru (3DV). IEEE, 2016.

10. Vykyk maskuvannia zobrazen Carvana | Kahhl. (2015). URL: Kaggle. <https://www.kaggle.com/c/carvana-image-masking-challenge/discussion/40199>

11. P. Michikevichus, S. Naranh, Dzh. Alben, H. Diamos, E. Elsen, D. Harsiia, ... & Kh. Vu. Zmishana tochnist navchannia. preprynt arXiv arXiv: 1710.03740, 2017.

12. Nobuiuki Otsu. Msgstr "Metod vyboru porohu z histohram rivnia siroho" . Tranzaktsii IEEE shchodo system, liudyny ta kibernetiky, vyp. 9, № 1, s. 62-66, sichen 1979 r., Doi: 10.1109 / TSMC.1979.4310076.
13. A. Hosh, M. Erlikh, S. Shakh, L. Devis ta R. Chellappa. Skladeni U-merezhi dlia sehmentatsii nazemnoho materialu na znimkakh z dystantsiinym zonduvanniam. 2018 Konferentsiia IEEE / CVF z pytan kompiuternoho zoru ta rozpoznavannia zrazkiv (CVPRW), s.252-256. doi: 10.1109 / cvprw.2018.00047 .

Received 28.12.2021.

Accepted 10.01.2022.

Land objects size approximation informational technology

Despite rapid development of Big Data and data processing technologies, it is still quite a challenge to implement efficient pipelines for obtaining reliable and reasonable results. In remote sensing, thousands of gigabytes of data is acquired by satellite and aircraft vehicles, but only the modest amount of data is processed. Among the data processed, even less results remains reliable overtime due to the nature of satellite imagery. Nowadays, machine learning area affects nearly every domain of knowledge including remote sensing. A toolset of machine learning suggests ways to automate data processing which makes data pipelines constructure much more effective. Deep neural networks demonstrate the best results so far in image processing field. However, applying deep learning achievements in Remote Sensing still remain challenging in regard to multi channel satellite imagery of a very high resolution. Despite astonishing results deep learning field demonstrates in remote sensing competitions such as Open Street Map, these are applicable on regular RGB images of popular image formats such JPEG and similar. In current paper, a technology is suggested to apply deep neural network toolset in multispectral images of a very high resolution acquired from a commercial WorldView 3 satellite vehicle. The suggested approach covers topics of dataset preparation to fully replicate the results of the suggested neural network training. The proposed neural network solution output are segmentation maps. In addition to replicatable neural network structure, a particular use case is considered in detail which implements a fully automated technology of highly precise approximation of physical sizes of the land objects. The neural network performance is measured and compared to modern similar neural network solutions.

Жерновий Вадим Вікторович – аспірант кафедри комп'ютерних наук Дніпровського національного університету імені О. Гончара (м. Дніпро).

Zhernovyi Vadym – postgraduate student of the Department of Computer Science, Oles Honchar Dnipro National University, Ukraine.