

М.С. Міщенко, Вік. В. Гнатушенко, А.В. Сінгер

КЛАСИФІКАЦІЯ ЕКООБ'ЄКТІВ НА СУПУТНИКОВИХ ЗОБРАЖЕННЯХ ЗА ДОПОМОГОЮ PYTORCH

Анотація. У статті наведена практична реалізація алгоритму класифікації екооб'єктів на супутникових зображеннях з використанням бібліотеки глибокого навчання PyTorch. Метою дослідження є підвищення якості класифікації об'єктів на цифрових зображеннях завдяки розробці та використанню моделі нейронної мережі.

Запропонований підхід дозволяє класифікувати воду, піски, хмари та зелену місцевість на супутникових знімках, полегшуючи аналіз великих обсягів даних та отримано середню точність 95%. Його було протестовано на супутникових знімках Sentinel 2, отриманих з березня по серпень 2023 року для деяких частин Херсонської та Миколаївської областей, Україна. Для навчання моделі використовується попередньо натренована архітектура ResNet.

Представлене дослідження демонструє практичне використання сучасних методів глибокого навчання, зокрема бібліотеки PyTorch, для вирішення актуальних завдань аналізу та класифікації об'єктів на супутникових знімках.

Ключові слова: нейронна мережа, супутникове зображення, розпізнавання, глибоке навчання, PyTorch.

Вступ. Аналіз і класифікація супутникових зображень є важливою задачею в таких галузях, як дистанційне зондування Землі, моніторинг навколишнього середовища, картографія та розвідка [1, 2]. З розвитком супутникових систем та збільшенням обсягів зібраних даних постає нагальна потреба в ефективних інструментах для автоматизованої обробки та інтерпретації цих величезних масивів візуальних даних [3].

Завдяки стрімкому прогресу в галузі машинного навчання та нейронних мереж, методи глибокого навчання продемонстрували видатні результати в різноманітних задачах комп'ютерного зору, включно з класифікацією зображень. Зокрема, бібліотеки глибокого навчання, такі як PyTorch, значно спрощують розробку та впровадження потужних моделей класифікації для обробки супутникових зображень.

У цій статті ми розглядаємо практичну реалізацію задачі класифікації супутникових зображень на чотири класи: вода, піски, хмари та зелена місцевість. Представлено процес підготовки даних та навчання моделі нейронної мережі з використанням бібліотеки PyTorch. Особливу увагу приділено аналізу продуктивності моделі для кожного окремого класу, що дозволяє виявити можливі проблеми та шляхи для подальшого вдосконалення.

Постановка проблеми. Зі зростаючим обсягом зібраних супутникових даних постає нагальна потреба в ефективних методах автоматизованої класифікації та інтерпретації супутникових знімків. Розробка точних і надійних моделей класифікації зображень на основі глибинного навчання є актуальною проблемою, яка дозволить спростити аналіз величезних масивів супутникових даних.

Аналіз останніх досліджень. У останні роки методи глибинного навчання, зокрема згорткові нейронні мережі (CNN), довели свою ефективність у задачах класифікації зображень різного походження. Дослідники активно застосовують ці підходи для аналізу аерокосмічних знімків, отриманих з безпілотних літальних апаратів, супутників та інших джерел дистанційного зондування.

Низка досліджень була присвячена класифікації різних типів земного покриву, таких як водойми, міські території, ліси та сільськогосподарські угіддя. Зокрема, у роботі “Deep learning based roof type classification using very high resolution aerial imagery” [4] автори досягли високої точності класифікації за допомогою архітектури VGGNet, попередньо натренованої на наборі ImageNet. В іншому дослідженні “Land-cover classification with high-resolution remote sensing images using transferable deep models” [5] використовувалася модель ResNet з трансферним навчанням для картографування земного покриву на основі супутникових знімків високої роздільної здатності.

Варто відзначити, що більшість існуючих досліджень зосереджені на класифікації зображень окремих регіонів чи територій. Питання створення універсальних моделей, здатних обробляти супутникові знімки з різних джерел та з різними умовами зйомки, залишається відкритим і потребує подальших досліджень.

Викладення основного матеріалу. Класифікація супутникових зображень є важливим завданням у галузі дистанційного зондування Землі та аналізу супутникових даних. Воно полягає у визначенні типу земного покриву (вода, пустеля, ліси, міські території тощо) на основі знімків, отриманих з космосу.

Точна класифікація дозволяє отримувати цінну інформацію про навколишнє середовище, сільськогосподарські угіддя, лісові масиви, міську інфраструктуру та багато іншого, що має практичне значення у картографії, моніторингу змін клімату, плануванні територій, розвідці та інших сферах.

PyTorch - це популярна open-source бібліотека машинного навчання, орієнтована на розробку та тренування моделей глибокого навчання, включаючи згорткові нейронні мережі. Вона забезпечує зручний та гнучкий інструментарій для використання нейронних мереж, навчання моделей на наборах даних, оптимізації параметрів та виведення результатів [6].

Завдяки потужності та ефективності бібліотеки PyTorch, вона успішно використовується для вирішення задач класифікації супутникових знімків. Основні переваги PyTorch у цьому контексті:

- Побудова складних згорткових нейронних мереж, здатних ефективно виявляти та розпізнавати патерни на супутникових зображеннях.
- Використання трансферного навчання, коли попередньо натреновані на великих наборах даних моделі можуть бути адаптовані до специфічної задачі класифікації земного покриву.
- Гнучке визначення функцій втрат, метрик точності та оптимізаторів для ефективного навчання моделей.
- Навчання на GPU, використовуючи CUDA Toolkit від NVIDIA, для пришвидшення процесу.
- Широкий вибір вбудованих інструментів для передобробки даних, аугментації зображень та візуалізації результатів.
- Інтеграція з бібліотеками обробки зображень.

Таким чином, PyTorch є потужним інструментом для розробки систем глибокого навчання для аналізу та класифікації супутникових зображень, що може мати широке практичне застосування в різноманітних галузях.

Класифікація супутникових зображень за допомогою PyTorch. Для вирішення поставленої задачі класифікації супутникових знімків, використовувалась бібліотека глибокого навчання PyTorch. На вхід моделі подавався набір зображень, розділених на чотири класи: вода, піски, хмари та зелена місцевість. Мета - навчити модель класифікувати зображення відповідно до цих категорій з максимальною ймовірністю.

Підготовка даних – це один з ключових етапів. На вхід нейронної мережі завантажувалось по 500 зображень для кожного класу. Для навчальних даних було застосовано різноманітні трансформації та аугментації, такі як зміна ро-

змірів, обертання, відбиття та додавання гаусового шуму [7, 1]. Це дозволило збільшити різноманітність даних і покращити здатність моделі розпізнавати. Для валідаційних даних, застосовувалось лише зміна розмірів зображень.

```
train_transform = transforms.Compose([
    transforms.Resize(224),
    transforms.RandomHorizontalFlip(p=0.5),
    transforms.RandomVerticalFlip(p=0.5),
    transforms.GaussianBlur(kernel_size=(5, 9), sigma=(0.1,
5)),
    transforms.RandomRotation(degrees=(30, 70)),
    transforms.ToTensor(),
    transforms.Normalize(
        mean=[0.485, 0.456, 0.406],
        std=[0.229, 0.224, 0.225]
    )
])

valid_transform = transforms.Compose([
    transforms.Resize((224, 224)),
    transforms.ToTensor(),
    transforms.Normalize(
        mean=[0.485, 0.456, 0.406],
        std=[0.229, 0.224, 0.225]
    )
])
```

Лістинг 1 – Трансформування даних для навчання та валідації

В якості архітектури нейронної мережі, для експерименту, обрано попередньо натреновану на ImageNet модель ResNet. Останній класифікаційний шар моделі змінено відповідно до кількості класів, у нашій задачі до чотирьох. Такий підхід навчання дозволяє ефективно використовувати ваги, отримані на великих наборах даних, і адаптувати модель до специфічних задач.

```
import torch
import argparse
import torch.nn as nn
import torch.optim as optim

from model import build_model
from utils import save_model, save_plots
from datasets import train_loader, valid_loader, dataset
from tqdm.auto import tqdm
```

```
parser = argparse.ArgumentParser()

parser.add_argument('-e', '--epochs', type=int, default=50,
                    help='number of epochs to train our network')
args = vars(parser.parse_args())
```

Лістинг 2 – Скрипт тренування моделі

Для процесу навчання достатньо 50-100 епох з використанням оптимізатора Adam та функції втрат Cross Entropy. Після кожної епохи було обчислено метрики точності та втрат як для навчальних, так і для валідаційних даних. Окремо була розрахована точність класифікації для кожного класу, що дозволило виявити проблеми з розпізнаванням певних типів земного покриття.

```
optimizer = optim.Adam(model.parameters(), lr=lr)
criterion = nn.CrossEntropyLoss()
```

Лістинг 3 – використання оптимізатора Adam та функції Cross Entropy у скрипті тренування train.py

При вищевказаних налаштуваннях, тестові результати навчання продемонстрували високу загальну точність моделі - близько 95% на валідаційному наборі даних. Проте, можна очікувати, що точність класифікації для класів "зелена місцевість" та "вода" буде дещо нижчою, ніж для "піски" та "хмар". Це може бути пов'язано з меншою кількістю навчальних зразків для цих класів, а також з більшою схожістю зображень зелених територій та водойм.

```
Accuracy of class clouds: 95.63536177491962
Accuracy of class desert: 96.8609865470852
Accuracy of class green_area: 89.43661971830986
Accuracy of class water: 94.48051948051948
```

Лістинг 4 – Виведення даних про точність

Висновки. У статті наведено підхід до реалізації задачі класифікації супутникових зображень з використанням бібліотеки глибокого навчання PyTorch. Запропонована модель, побудована на основі попередньо натренованої архітектури ResNet, яка досягає високої загальної точності у розпізнаванні чотирьох категорій земного покриття: води – 94.48%, пісків – 96.86%, хмарного покриття – 95.63% та зелених зон – 89.43%.

Ключовими факторами, що роблять цей підхід ефективним, є: ретельна підготовка навчальних даних із застосуванням різноманітних трансформацій та використання сучасних методів оптимізації під час тренування моделі. Завдяки можливостям PyTorch зручно реалізовано всі необхідні компоненти від завантаження даних до визначення архітектури нейронної мережі.

Подальші напрямки вдосконалення можуть включати збільшення та диверсифікацію навчального набору даних, експерименти з іншими архітектурами нейронних мереж, застосування додаткових методів оптимізації. Крім того, інтеграція з додатковими джерелами даних, такими як метадані зйомки чи інформація про висоту, може потенційно покращити точність класифікації.

Отримані результати демонструють потужність та потенціал застосування бібліотеки PyTorch у поєднанні з методами глибинного навчання для вирішення складних завдань класифікації супутникових зображень. Такий підхід може знайти широке застосування у різноманітних галузях картографії, моніторингу навколишнього середовища та розвідки.

ЛІТЕРАТУРА

1. Hnatushenko, Vi., Hnatushenko, Vo., Soldatenko, D., Heipke, C. (2023): Enhancing the quality of CNN-based burned area detection in satellite imagery through data augmentation. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLVIII-1/W2-2023, 1749–1755. doi.org/10.5194/isprs-archives-XLVIII-1-W2-2023-1749-2023.
2. Ortega, M. X., Wittich, D., Rottensteiner, F., Heipke, C., Feitosa, R. Q., 2023. Using time series image data to improve the generalization capabilities of a CNN - The example of deforestation detection with Sentinel-2. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences X-1/W1-2023*, pp. 961–970. doi.org/10.5194/isprs-annals-X-1-W1-2023-961-2023
3. KAPLAN, G. &AVDAN, U., 2018: Sentinel-1 and Sentinel-2 Data fusion for wetlands mapping: Balikdami, Turkey. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. XLII-3. 729-734. 10.5194/isprs-archives-XLII-3-729-2018.
4. Buyukdemircioglu, M., R. Can, and S. Kocaman. "Deep learning based roof type classification using very high resolution aerial imagery." *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 43 (2021): 55-60.
5. Tong, Xin-Yi, et al. "Land-cover classification with high-resolution remote sensing images using transferable deep models." *Remote Sensing of Environment* 237 (2020): 111322.

6. Zhou, Yue, et al. "Mmrotate: A rotated object detection benchmark using pytorch." Proceedings of the 30th ACM International Conference on Multimedia. 2022.

7. Wu, Sen, et al. "On the generalization effects of linear transformations in data augmentation." International Conference on Machine Learning. PMLR, 2020.

REFERENCES

1. Hnatushenko, Vi., Hnatushenko, Vo., Soldatenko, D., Heipke, C. (2023): Enhancing the quality of CNN-based burned area detection in satellite imagery through data augmentation. Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci., XLVIII-1/W2-2023, 1749–1755. doi.org/10.5194/isprs-archives-XLVIII-1-W2-2023-1749-2023.

2. Ortega, M. X., Wittich, D., Rottensteiner, F. , Heipke, C., Feitosa, R. Q., 2023. Using time series image data to improve the generalization capabilities of a CNN - The example of deforestation detection with Sentinel-2. In: ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences X-1/W1-2023, pp. 961–970. doi.org/10.5194/isprs-annals-X-1-W1-2023-961-2023

3. KAPLAN, G. &AVDAN, U., 2018: Sentinel-1 and Sentinel-2 Data fusion for wetlands mapping: Balikdami, Turkey. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. XLII-3. 729-734. 10.5194/isprs-archives-XLII-3-729-2018.

4. Buyukdemircioglu, M., R. Can, and S. Kocaman. "Deep learning based roof type classification using very high resolution aerial imagery." The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 43 (2021): 55-60.

5. Tong, Xin-Yi, et al. "Land-cover classification with high-resolution remote sensing images using transferable deep models." Remote Sensing of Environment 237 (2020): 111322.

6. Zhou, Yue, et al. "Mmrotate: A rotated object detection benchmark using pytorch." Proceedings of the 30th ACM International Conference on Multimedia. 2022.

7. Wu, Sen, et al. "On the generalization effects of linear transformations in data augmentation." International Conference on Machine Learning. PMLR, 2020.

Received 09.05.2024.

Accepted 13.05.2024.

Implementation of satellite image classification using PyTorch

This article presents a practical implementation of the satellite image classification task using the PyTorch deep learning library. The aim of the work is to develop a neural network model capable of classifying satellite images into four classes: water, sands, clouds, and greenery.

The model is trained using the pre-trained ResNet architecture.

The proposed approach allows for automatic classification of satellite images, facilitating the analysis of large amounts of data, and has been tested on Sentinel-2 satellite images acquired from March to August 2023 for parts of Kherson and Mykolaiv regions, Ukraine, and achieved an average accuracy of 95%.

The presented research demonstrates the practical use of modern deep learning methods, in particular the PyTorch library, to solve actual problems of satellite image analysis and classification.

Міщенко Максим Станіславович - аспірант кафедри інформаційних технологій і систем Українського державного університету науки і технологій.

Гнатушенко Вікторія Володимирівна - д.т.н., професор, завідувача кафедрою інформаційних технологій і систем, Український державний університет науки і технологій.

Сінгер Анастасія-Джей Володимирівна - студентка кафедри інформаційних технологій і систем Українського державного університету науки і технологій.

Mishchenko Maksym - Postgraduate Student, Department of Information Technologies and Systems, Ukrainian State University of Science and Technology.

Hnatushenko Viktoriia - Doctor of Engineering's Sciences, Professor, Head of Department of information technology and systems of the Ukrainian state University of science and technologies.

Sinher Anastasiia-Dzhei - Student, Department of Information Technologies and Systems, Ukrainian State University of Science and Technology.