

**ДИСТАНЦІЙНИЙ МОНІТОРИНГ СІЛЬСЬКОГОСПОДАРСЬКИХ ПОЛІВ З
ВОРОНКАМИ ВІД ВИБУХОВИХ ПРИСТРОЇВ ДЛЯ ВІДНОВЛЕННЯ ЇХ
ВИКОРИСТАННЯ ДЛЯ РОСЛИННИЦЬКИХ ПРАКТИК**

А. О. Дудник, кандидат технічних наук, доцент

О. О. Опришко, кандидат технічних наук, доцент

М. О. Кіктєв, кандидат технічних наук, доцент

Ю. Л. Цицюрський, інженер

Д. Є. Жук, аспірант

Національний університет біоресурсів і природокористування України

E-mail: ozon.kiev@gmail.com

Анотація. *Стаття присвячена дослідженню застосування нейронних мереж для розпізнавання кратерів, які утворюються в результаті вибухів на сільськогосподарських полях за супутниковими або БПЛА знімками.*

Метою дослідження є оцінка стану руйнування на основі даних про реальний стан полів, отриманих у результаті дистанційного моніторингу, з використанням засобів машинного навчання.

Моніторингу в відомих роботах здійснювався з використанням супутникових даних високої роздільної здатності 0,3 - 0,5 м/піксел, проте починаючи з 2022 року такий продукт Google Earth Pro припинив поширювати для території України. Альтернативою при отриманні таких даних можуть бути БПЛА, які при використанні літакових платформ можуть обстежувати до 10 000 гектарів на добу.

Встановлено, що розпізнавання кратерів від вибухів на зображеннях з роздільною здатністю 0,5 м/піксель можливо за допомогою нейронних мереж. У ході дослідження були вивчені круглі кратери, але під час військових дій можливі й інші форми, які потребують додаткового вивчення. У подальших дослідженнях доцільно ввести додатковий параметр – індекс форми кратера. Отримані результати свідчать про перспективність впровадження цього підходу в післявоєнне відновлення земель сільськогосподарського призначення в Україні.

Ключові слова: *нейронна мережа, сільськогосподарські угіддя, розпізнавання зображень, вибухові кратери, навчання, база даних*

Актуальність. Ринок продовольства в світі перебуває в нестабільному стані. За результатами дослідницької роботи F. Trajković (2023) в [1] щодо Європейського ринку продовольства в останні роки спостерігаються серйозні аномалії щодо

ціноутворення. Однією з важливих причин цього явища є масштабні бойові дії в Європі, починаючи з 2022 року, і відповідно вивід з обороту великих обсягів сільськогосподарських угідь. Ситуація із пошкодженням полів має тривалий характер, так за даними Dries Claeys (2019) в [2] воронки на полях від артилерійських снарядів на полях Західної Європи збереглися з часів першої світової війни. З урахуванням значно підсиленої вибухової сили снарядів та появи балістичних, крилатих ракет та потужних авіабомб ситуація з пошкодженням полів у сучасних війнах принципово погіршується. По оцінках приведеним в роботі Deepak Rawtani (2022) в [3] війна в Україні є самим масштабним збройним конфліктом в Європі з часів другої світової війни за отриманими руйнуваннями та пошкодженнями інфраструктури. Для забезпечення стабільності продовольчого ринку необхідно оперативно вводити до обігу поля постраждали від військових дій. З урахуванням обмежених людських та матеріальних ресурсів в аграріїв необхідно враховувати вартість відновлення, оцінювати стан руйнувань та розраховувати оптимальні маршрути, як показано в роботах V.Mezhuyev (2020) в [4], S.Lienkov (2022) в [5]. Такі заходи можливі лише за наявності даних про реальний стан полів які можна отримати за результатами дистанційного моніторингу,.

Аналіз останніх досліджень і публікацій. Фізичні порушення ґрунту за даними Giacomo Certini (2013) в [6] включають ущільнення через будівництво оборонних інфраструктур, копання траншей або тунелів, ущільнення рухом техніки та військ або утворення вирв від бомб тощо. Місця де були розміщені укріпрайони можуть мати фортифікаційні споруди: протитанкові надовби, рви тощо. Розташування укріпрайонів з військових міркувань має розміщуватись з урахуванням рельєфу місцевості та наявної дорожньої інфраструктури і, як правило, не безпосередньо на полях, відповідно в цій роботі увагу було зосереджено саме на воронках. Дослідженням саме щодо воронок присвячено роботу Nataliia Kussul (2023) в [7] завдяки безкоштовним супутниковим даним Sentinel-2 по змінам динаміки вегетаційних індексів було визначено постраждалі поля. Аналогічні дослідження з подібним інструментарієм проводились і в роботі Maksym Solokha (2023) в [8]. В обох випадках було отримано аналогічні результати, проте фактично

визначається загальна площа воронок, що в певній мірі може бути корисним з огляду на юридичний та економічний аспект проблеми, проте погано пристосовані для розрахунків по відновленню ґрунтів. При використанні вегетаційних індексів для оцінки стану посівів слід враховувати і методику їх отримання з притаманними ним обмеженням. Так, к роботі N.A.Pasichnyk (2021) в [9] приведено результати, згідно яким вплив атмосферної корекції на визначення вегетаційних індексів є дуже істотним, а можливість традиційної корекції даних за наземними дослідженнями на місцях недавніх бойових дій є сумнівною. Також невідомо і склад рослинності та їх стан органогенезу, які можна визначити лише приблизно, а за даним N. Pasichnyk (2023) в [10] не врахування цих показників також впливатиме на точність та взагалі придатність даних.

Краща ідентифікація воронок за результатами супутникового моніторингу показано в роботі Erik S. Duncan (2023) в [11], але за приведеними результатами створена модель краще визначає наявність кратерів, а не їх форму та габарити. Відповідно надійно ідентифікуються кратери площею більш ніж 60 м², що доцільно знати для потреб хімічної дезактивації, але знешкодження таких воронок є сумнівно доцільним з огляду на рослинницькі практики. Так, на рис. 1 наведено фотознімки з мережі інтернет щодо воронок різних вибухових пристроїв.



Рис.1 Воронки від вибухових пристроїв. Воронка від найпоширенішого фугасного снаряду калібру 155 мм (ліворуч) та від БПЛА Шахид-136 (з права)

Якщо воронку від 155 мм фугасного снаряду можливо відносно легко ліквідувати з використанням наявних ресурсів фермерських господарств, то з воронкою від балістичної ракети глибиною в кілька метрів це відносно складно

реалізувати. Відповідно, внаслідок вибухів на полі можуть бути як такі кратери, які можна та потрібно вирівняти бульдозером, так і такі, які за рахунок габаритів є небезпечними для такого обладнання. Отже, необхідно розраховувати траєкторії у випадку можливих конфліктних ситуацій, як показано в N.Pasichnyk (2023) в [12] та при наявності обмежень, як показано в S. A.Shvorov (2019) в [13].

Моніторинг в представлених вище роботах здійснювався з використанням супутникових даних високої роздільної здатності 0,3 - 0,5 м/піксел, проте починаючи з 2022 року такий продукт Google Earth Pro припинив поширювати для території України. Альтернативою при отриманні таких даних можуть бути БПЛА, які при використанні літакових платформ можуть обстежувати до 10 000 гектарів на добу. Досвід використання БПЛА щодо моніторингу для потреб гуманітарного розмінування представлено в роботі N. Kiktev (2023) в [14], де з використанням тепловізійного знаряддя пропонувалося виявляти розкладені на поверхні землі протитанкові міни. При досліджах автори встановили, що воронки від вибухових пристроїв добре ідентифікуються, проте вибіркковість низька за рахунок наявності сторонніх об'єктів, таких як автомобільні скати, частини обладнання тощо. Відповідно було використано підхід щодо використання нейронних мереж для відслідковування наявності характерного для мінних загороджень розташування об'єктів.

Попри можливості БПЛА для моніторингу, в тому числі і наслідків дій, вони відносно мало використовуються, проте такий досвід присутній зокрема при дослідженні вулканічної активності, як показано в роботах Ruli Andaru (2021) в [15] та A. Román (2022) в [16]. Для вулканів БПЛА використовуються, оскільки саме вони дозволяють працювати оперативно та під шаром хмар чи диму при виверженні. Отже навіть при обмеженості доступності супутникових даних існують доступні технічні засоби для отримання візуальної інформації.

Отже, можна зробити висновки про:

- можливість ідентифікації кратерів обумовлених бойовими діями на знімках високої роздільної здатності;

- кратери від вибухів зберігаються на полях впродовж десятиліть і сильно обмежують рослинницькі практики на полях;
- розпізнавання можна зробити за формою характерною саме для таких кратерів;
- необхідно визначати розміри кратерів хоча б в горизонтальній проекції, оскільки не всі кратери можуть бути виправлені ресурсами господарств і їх потрібно враховувати при плануванні маршрутів.

Мета дослідження - оцінка стану руйнувань за даними про реальний стан полів, отриманих за результатами дистанційного моніторингу з використанням інструментів машинного навчання.

Матеріали і методи дослідження. Оскільки боєві дії високої інтенсивності відбувалися на території України з 2014 року, тому для роботи було використано архівні дані супутникової зйомки, отримані від сервісу Google Earth Pro за 2013-2017 роки (рис. 2- 4). Досліджуватися поля із координатами 47.927794, 38.746100.




Рис. 2. Вихідне поле без впливу бойових дій (08,2013)



Рис. 3 Поле із кратерами від вибухових пристроїв різною потужності, менші зверху на зеленому полі та потужніші знизу на темному полі (07.2014).



Рис. 4. Поле із кратерами із коліями наземного обладнання при спробах знешкодити кратери (08.2014)

Результати досліджень та їх обговорення. Для обробки графічних даних було прийнято рішення згенерувати нейронну мережі на мові Python. Нижче наведено опис та фрагменти коду програмного забезпечення.

На рис.5 представлено фрагмент коду завантаження даних з зображеннями.

3. Load Data

```
In [8]: import numpy as np
        from matplotlib import pyplot as plt

In [9]: data = tf.keras.utils.image_dataset_from_directory('data')

Found 305 files belonging to 2 classes.

In [10]: data_iterator = data.as_numpy_iterator()

In [11]: batch = data_iterator.next()

In [12]: fig, ax = plt.subplots(ncols=4, figsize=(20,20))
        for idx, img in enumerate(batch[0][:4]):
            ax[idx].imshow(img.astype(int))
            ax[idx].title.set_text(batch[1][idx])
```

Рис. 5 Скріншот коду, який завантажує дані з зображеннями, конвертує їх у формат масиву NumPy

Завантаження даних:

Використовується `tf.keras.utils.image_dataset_from_directory` для завантаження набору даних з директорії `data`, що містить масив файлів, розділених на 2 класи.

Конвертація в ітератор NumPy:

Дані конвертуються в ітератор масивів NumPy за допомогою `data.as_numpy_iterator()`.

Отримання першої порції даних:

Перший набір даних отримується з ітератора за допомогою `data_iterator.next()`.

Візуалізація зображень:

Використовується `plt.subplots` для створення підсюжетів (4 стовпці, розмір фігури `20×20`). За допомогою циклу `for` та `enumerate` відображаються перші 4 зображення з набору даних.

4. Scale Data

```
In [13]: data = data.map(lambda x,y: (x/255, y))
```

```
In [ ]: data.as_numpy_iterator().next()
```

5. Split Data

```
In [15]: train_size = int(len(data)*.7)
          val_size = int(len(data)*.2)
          test_size = int(len(data)*.1)
```

```
In [16]: train_size
```

```
Out[16]: 7
```

```
In [17]: train = data.take(train_size)
          val = data.skip(train_size).take(val_size)
          test = data.skip(train_size+val_size).take(test_size)
```

Рис. 6. Скрін коду програмного забезпечення щодо організації машинного навчання: масштабування та розподіл даних

4. Масштабування даних. Масштабування зображень:

На цьому етапі відбувається нормалізація зображень, тобто значення кожного пікселя діляться на 255. Це робиться для того, щоб значення пікселів знаходилися в діапазоні від 0 до 1, що допомагає моделі швидше і краще навчатися. Після масштабування зображення зберігаються в форматі, який зручний для обробки (масиви NumPy).

5. Розподіл даних. Розподіл на частини:

Далі дані розподіляються на три частини: навчальну, валідаційну та тестову множини. Навчальна множина (70 % даних) використовується для навчання моделі. Валідаційна множина (20 % даних) використовується для налаштування моделі і перевірки її точності під час навчання. Тестова множина (10 % даних) використовується для остаточної перевірки точності моделі після завершення навчання.

Процес розподілу. Спочатку обчислюються розміри кожної з цих частин (скільки зображень буде в кожній частині). Потім дані фактично розподіляються: спочатку беруться дані для навчальної множини, далі для валідаційної і, нарешті, для тестової. Цей підхід допомагає створити надійну модель, яка може добре працювати на нових, невідомих даних.

6. Побудова моделі глибокого навчання

Огляд навчальних даних представлено на рис. 7.

У верхньому рядку показано, що використовуються навчальні дані, які представляють собою набір зображень розміром 256x256 пікселів.

Наступні рядки показують імпорт основних компонентів для створення моделі, зокрема бібліотеки для побудови різних шарів нейронної мережі.

Створення послідовної моделі. В рядку `model = Sequential()` створюється структура моделі, яка дозволяє додавати шари один за одним.

Додавання шарів до моделі:

Перший шар – це конволюційний шар, який виділяє важливі особливості зображень.

Макспулінг: зменшує розмірність зображень, що допомагає зменшити обсяг обчислень і запобігти перенавчанню.

Другий і третій шари: знову конволюційні шари та макспулінг, що допомагає виділяти ще більш складні особливості зображень.

Шар згладжування: переводить двовимірні дані в одновимірні, щоб їх можна було передати в щільні шари.

Щільні шари: включають нейрони, що з'єднують усі попередні особливості і приймають рішення про те, до якого класу належить зображення.

6. Build Deep Learning Model

```
In [18]: train

Out[18]: <TakeDataset element_spec=(TensorSpec(shape=(None, 256, 256, 3), dtype=tf.float32, name=None), TensorSpec(shape=(None, ), dtype=tf.int32, name=None))>

In [19]: from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Dense, Flatten, Dropout

In [20]: model = Sequential()

In [21]: model.add(Conv2D(16, (3,3), 1, activation='relu', input_shape=(256,256,3)))
model.add(MaxPooling2D())
model.add(Conv2D(32, (3,3), 1, activation='relu'))
model.add(MaxPooling2D())
model.add(Conv2D(16, (3,3), 1, activation='relu'))
model.add(MaxPooling2D())
model.add(Flatten())
model.add(Dense(256, activation='relu'))
model.add(Dense(1, activation='sigmoid'))

In [22]: model.compile('adam', loss=tf.losses.BinaryCrossentropy(), metrics=['accuracy'])
```

Рис. 7. Реалізація коду щодо створення моделі глибокого навчання для розпізнавання зображень, використовуючи бібліотеку TensorFlow.

Компільована модель: На останньому етапі модель компілюється, використовуючи оптимізатор adam та функцію втрат BinaryCrossentropy, що підходить для двокласової класифікації. Модель також буде оцінюватися за точністю. Цей процес дозволяє створити нейронну мережу, яка може навчатися на зображеннях і використовувати свої знання для класифікації нових зображень. На рис.8 наведено зведену таблицю, яка допомагає зрозуміти структуру моделі, кількість параметрів у кожному шарі та їх форму, що є важливим для перевірки коректності побудови моделі та її оцінки.

```
In [23]: model.summary()

Model: "sequential"

```

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 254, 254, 16)	448
max_pooling2d (MaxPooling2D)	(None, 127, 127, 16)	0
conv2d_1 (Conv2D)	(None, 125, 125, 32)	4640
max_pooling2d_1 (MaxPooling2D)	(None, 62, 62, 32)	0
conv2d_2 (Conv2D)	(None, 60, 60, 16)	4624
max_pooling2d_2 (MaxPooling2D)	(None, 30, 30, 16)	0
flatten (Flatten)	(None, 14400)	0
dense (Dense)	(None, 256)	368656
dense_1 (Dense)	(None, 1)	257

```

Total params: 3,696,625
Trainable params: 3,696,625
Non-trainable params: 0

```

Рис. 8 Код програми щодо моделі глибокого навчання

Опис моделі:

- Тип моделі: sequential (послідовна модель)
- Структура моделі
- Шари моделі: conv2d (Conv2D):
- Вихідна форма: (None, 254, 254, 16)
- Кількість параметрів: 448

Це конволюційний шар, який виділяє основні риси зображення.

max_pooling2d (MaxPooling2D):

- Вихідна форма: (None, 127, 127, 16)
- Кількість параметрів: 0

Це шар зменшення розмірів, який зменшує просторові розміри виділених на рисункую

- conv2d_1 (Conv2D):
- Вихідна форма: (None, 125, 125, 32)
- Кількість параметрів: 4640

Ще один конволюційний шар для більш глибокого виділення рисунку.

- max_pooling2d_1 (MaxPooling2D):
- Вихідна форма: (None, 62, 62, 32)
- Кількість параметрів: 0

Шар зменшення розмірів.

- conv2d_2 (Conv2D):
- Вихідна форма: (None, 60, 60, 16)
- Кількість параметрів: 4624

Третій конволюційний шар.

- max_pooling2d_2 (MaxPooling2D):
- Вихідна форма: (None, 30, 30, 16)
- Кількість параметрів: 0

Ще один шар зменшення розмірів.

- flatten (Flatten):
- Вихідна форма: (None, 14400)
- Кількість параметрів: 0

Цей шар переводить багатовимірні дані в одновимірний вектор.

- dense (Dense):
- Вихідна форма: (None, 256)
- Кількість параметрів: 3,686,656

Щільний (fully connected) шар, що обробляє згладжені дані.

- dense_1 (Dense):
- Вихідна форма: (None, 1)
- Кількість параметрів: 257

Останній шар, який видає остаточний результат класифікації.

- Загальна інформація
- Загальна кількість параметрів: 3,696,625
- Кількість параметрів, які навчаються: 3,696,625
- Кількість ненавчаємих параметрів: 0

7. Відображення результатів.

На рис. 9 показано графічне відображення результатів навчання моделі глибокого навчання, зокрема, зміни втрат (loss) та точності (accuracy) під час навчання і валідації.

Графік втрат (Loss):

У першому коді створюється графік втрат під час навчання (loss) та валідаційних втрат (val_loss).

Графік показує, як ці показники змінюються з кожною епохою (ітерацією навчання).

На графіку видно, що обидві криві зменшуються, що свідчить про те, що модель поступово навчається і покращується.

Графік точності (Accuracy):


У другому коді створюється графік точності під час навчання (accuracy) та валідаційної точності (val_accuracy).

Графік демонструє, як змінюється точність моделі з кожною епохою.

Криві на графіку показують зростання, що означає, що модель стає більш точною в своїх прогнозах.

8. Plot Performance

```
In [27]: fig = plt.figure()
plt.plot(hist.history['loss'], color='teal', label='loss')
plt.plot(hist.history['val_loss'], color='orange', label='val_loss')
fig.suptitle('Loss', fontsize=20)
plt.legend(loc="upper left")
plt.show()
```



```
In [28]: fig = plt.figure()
plt.plot(hist.history['accuracy'], color='teal', label='accuracy')
plt.plot(hist.history['val_accuracy'], color='orange', label='val_accuracy')
fig.suptitle('Accuracy', fontsize=20)
plt.legend(loc="upper left")
plt.show()
```




Рис. 9. Графічне відображення результатів навчання моделі глибокого навчання, зокрема, зміни втрат (loss) та точності (ассурасу) під час навчання і валідації

Виходячи з приведених на графіках результатів видно, що як навчальні, так і валідаційні втрати зменшуються, що свідчить про те, що модель вчиться і покращується з кожною епохою.

Щодо точності можна засвідчити, що обидві криві точності збільшуються, що свідчить про поліпшення здатності моделі робити правильні прогнози. Ці графіки є важливими інструментами для оцінки ефективності навчання моделі і допомагають зрозуміти, чи модель продовжує покращуватися, чи вже досягла свого максимуму.

Процес тестування здійснюється за таким алгоритмом:

- Імпорт та зчитування зображення:
- Імпортується бібліотека cv2.
- Зчитується зображення 154006829.jpg за допомогою cv2.imread і відображається за допомогою plt.imshow.
- Зміна розміру зображення:
- Зображення змінюється до розміру 256x256 пікселів, що відповідає розміру, який використовувався під час навчання моделі.
- Змінене зображення відображається знову.
- Прогнозування класу:
- Модель використовує змінене зображення для прогнозування класу (model.predict).

Результат прогнозу (yhat) порівнюється з пороговим значенням 0.5:

- Якщо результат більше 0.5, зображення класифікується як "Sad".
- Інакше, зображення класифікується як "Happy".

Безпосередньо проблема ідентифікація на знімках воронок від снарядів раніше майже не розглядалася, оскільки практично після Другої світової війни в Європі не відбувалися бойові дії високої інтенсивності із витратою снарядів калібру ≥ 152 мм більш ніж 5000 в день.

Апробація роботи та подяки. Робота доповідалась на міжнародній науковій конференції 2023 CAM Dynamical System Modeling and Stability Investigation (DSMSI-2023), (Nikolay Kiktev, Oleksiy Opryshko, Alla Dudnyk, Volodymyr Reshetiuk. "Machine Learning for Remote Monitoring of Agricultural Fields with Explosive Tunnels" Dynamical System Modeling and Stability Investigation (DSMSI-2023), December 19-21, 2023, Kyiv, Ukraine, pp. 74 - 84, https://ceur-ws.org/Vol-3746/Paper_8.pdf).

Висловлюємо щирю вдячність Володимиру Михайловичу Решетюку за допомогу щодо організації проведення досліджень.

Висновки і перспективи.

Встановлено що розпізнавання воронок на знімках з роздільною здатністю від 0,5 м/піксел можливе з використанням нейронних мереж. При попередніх дослідження вдалося отримати високу точність, проте знімки від сервісу google earth надають лише дані, отримані при найбільш сприятливих умовах супутникової зйомки, що ймовірно в звичайних умовах може вплинути на отримані результати.

При дослідженнях досліджувалися кратери круглої форми, проте при бойових діях можливі і інші форми воронок, що необхідно додатково досліджувати.

У подальших дослідженнях доцільним є введення додаткового параметру - індексу форми кратеру.

References

1. F. Trajkovikj et al. (2023). "A comprehensive study of food prices and food fraud in the European Union," 2023 IEEE International Conference on Big Data (BigData), Sorrento, Italy, 2023, 4557-4566, doi: 10.1109/BigData59044.2023.10386666.
2. Dries Claeys, Celina Van Dyck, Gert Verstraeten, Yves Segers (2019). "The importance of the Great War compared to long-term developments in restructuring the rural landscape in Flanders (Belgium)" *Applied Geography*, 111, 102063, doi: 10.1016/j.apgeog.2019.102063.
3. Deepak Rawtani, Gunjan Gupta, Nitasha Khatri, Piyush K. Rao, Chaudhery Mustansar Hussain (2022). "Environmental damages due to war in Ukraine: A perspective" *Science of The Total Environment*, 850, 157932, doi: 10.1016/j.scitotenv.2022.157932.
4. Mezhuiev, V., Gunchenko, Y., Shvovov. S., Chyrchenko. D. (2020). "A method for planning the routes of harvesting equipment using unmanned aerial vehicles". *Intelligent Automation and Soft Computing*, 26 (1), 121 - 132, doi: 10.31209/2019.100000133.
5. Lienkov. S., Shvovov. S., Sieliukov. O., Tolok. I., Lytvynenko. N., Davydenko. T. (2022). *Learning of Neural Networks Using Genetic Algorithms. CEUR Workshop Proceedings*, 3312, 155 – 164
6. Giacomo Certini, Riccardo Scalenghe, William I. Woods (2013). "The impact of warfare on the soil environment, *Earth-Science Reviews*", 127, 1-15, doi: 10.1016/j.earscirev.2013.08.009.
7. Nataliia Kussul, Sofiia Drozd, Hanna Yailymova, Andrii Shelestov, Guido Lemoine, Klaus Deininger, (2023). "Assessing damage to agricultural fields from military actions in Ukraine: An integrated approach using statistical indicators and machine learning". *International Journal of Applied Earth Observation and Geoinformation*, 125, 103562, doi: 10.1016/j.jag.2023.103562.

8. Maksym Solokha, Paulo Pereira, Lyudmyla Symochko, Nadiya Vynokurova, Olena Demyanyuk, Kateryna Sementsova, Miguel Inacio, Damia Barcelo (2023). "Russian-Ukrainian war impacts on the environment. Evidence from the field on soil properties and remote sensing " Science of The Total Environment, 902, 166122, doi: 10.1016/j.scitotenv.2023.166122.
9. Pasichnyk N., Komarchuk D., Opryshko O., Shvorov S., Kiktev N. (2021). "Methodology for Software Assessment of the Conformity of Atmospheric Correction from the UAV's Zenith Sensor," 2021 IEEE 6th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD), Kyiv, Ukraine, 2021, 1-5, doi: 10.1109/APUAVD53804.2021.9615177.
10. Pasichnyk, N., Opryshko, O., Shvorov, S., Dudnyk, A., Teplyuk, V. (2023). "Remote field monitoring results feasibility assessment for energy crops yield management" (2023). Machinery and Energetics, 14 (2), 46 - 59, doi: 10.31548/machinery/2.2023.46
11. Erik C. Duncan, Sergii Skakun, Ankit Kariryaa, Alexander V. (2023). Prishchepov "Detection and mapping of artillery craters with very high spatial resolution satellite imagery and deep learning" Science of Remote Sensing, 7, 100092, doi: 10.1016/j.srs.2023.100092.
12. D.S. Komarchuk, Y.A. Gunchenko, N.A. Pasichnyk, O.A. Opryshko, S.A. Shvorov and V.M. Reshetiuk (2021). "Use of Drones in Industrial Greenhouses," 2021 IEEE 6th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD), Kyiv, Ukraine, 2021, 184-187, doi: 10.1109/APUAVD53804.2021.9615418
13. S.A. Shvorov, N.A. Pasichnyk, S.D. Kuznichenko, I.V. Tolok, S.V. Lienkov, L.A. Komarova (2019). "Using UAV During Planned Harvesting by Unmanned Combines," 2019 IEEE 5th International Conference Actual Problems of Unmanned Aerial Vehicles Developments (APUAVD), Kiev, Ukraine, 252-257, doi: 10.1109/APUAVD47061.2019.8943842.
14. Kiktev, N., Opryshko, O., Pasichnyk, N., Dudnyk, A., Komarchuk, D. (2023). "Remote Monitoring of Mines in Fields with Using Neural Networks". CEUR Workshop Proceedings, 3624, 239 – 249.
15. Ruli Andaru, Jiann-Yeou Rau, Devy Kamil Syahbana, Ardy Setya Prayoga, Heruningtyas Desi Purnamasari (2021). "The use of UAV remote sensing for observing lava dome emplacement and areas of potential lahar hazards: An example from the 2017–2019 eruption crisis at Mount Agung in Bali", Journal of Volcanology and Geothermal Research, 415, 107255, doi: 10.1016/j.jvolgeores.2021.107255.
16. A. Román, A. Tovar-Sánchez, D. Roque-Atienza, I.E. Huertas, I. Caballero, E. Fraile-Nuez, G. Navarro (2022). "Unmanned aerial vehicles (UAVs) as a tool for hazard assessment: The 2021 eruption of Cumbre Vieja volcano, La Palma Island (Spain)", Science of The Total Environment, 843, 157092, doi: 10.1016/j.scitotenv.2022.157092.

MACHINE LEARNING FOR REMOTE MONITORING OF AGRICULTURAL FIELDS WITH EXPLOSIVE TUNNELS

A. Dudnyk, O. Opryshko, N. Kiktev, Y. Tsitsyurskii, D. Zhuk.

Abstract *The article is devoted to the study of the application of neural networks for recognizing craters resulting from explosions in agricultural fields using satellite or UAV images.*

The aim of the study is to assess the state of destruction based on data on the real state of fields obtained as a result of remote monitoring, using machine learning tools.

Monitoring in known works was carried out using satellite data with a high resolution of 0.3 - 0.5 m/pixel, but starting from 2022, such a Google Earth Pro product stopped being distributed for the territory of Ukraine. An alternative to obtaining such data can be UAVs, which, when using aircraft platforms, can survey up to 10,000 hectares per day.

It has been established that recognition of craters from explosions in images with a resolution of 0.5 m/ pixel is possible using neural networks. In the course of the study, round craters were studied, but during military operations other shapes are also possible, which require further study. In further studies, it is advisable to introduce an additional parameter - the crater shape index. The results obtained indicate the prospects for introducing this approach in the post-war restoration of agricultural lands in Ukraine.

Key words: *neural network, agricultural land, image recognition, blast craters, training, dataset*