

РОЗПІЗНАВАННЯ ОРГАНІЧНОГО КАМУФЛЯЖУ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ

А. О. Дудник, кандидат технічних наук, доцент

С. А. Шворов, доктор технічних наук, професор

О. О. Опришко, кандидат технічних наук, доцент

Н. А. Пасічник, кандидат сільськогосподарських наук, доцент

О. О. Кисляк, аспірантка

Національний університет біоресурсів і природокористування України

E-mail: kislyak.olya1999@gmail.com

Анотація. *Безпілотні літальні апарати (БПЛА) стають все більш важливими для військових операцій, включаючи розвідку, надання підтримки на полі бою та виконання різноманітних місій. Можливість атаки цілей з використанням групи БПЛА підсилює актуальність заходів щодо захисту, зокрема, маскуванню. У літературному огляді висвітлено досвід використання БПЛА в військових сферах діяльності та їх високу ефективність у розвідці та підтримці на полі бою. В умовах дії засобів радіоелектронної боротьби в якості пріоритетного напрямку навігації БПЛА розглянуто візуальну орієнтацію на місцевості з використанням високої роздільної здатності зображень. На основі гібридних згорткових нейронних мереж серійно випускається апаратне забезпечення для роботи з платформою БПЛА. Пропонується використання ліан для маскуванню стаціонарних об'єктів у зв'язку з їх швидким ростом і відповідним співвідношенням якості/вартості. Метою роботи є перевірка ефективності маскуванню невеликих об'єктів з використанням трав'янистих та витких рослин щодо перспектив їх ідентифікації оптичними засобами. Дослідження проводились з використанням власних даних, отриманих від БПЛА у видимому діапазоні на дослідних полях і ботанічному саду НУБіП України та на знімках споруд з мережі інтернет. Експериментально встановлено, що різноманітність форм, розмірів та структур рослинних насаджень ускладнює процес розпізнавання для згорткових нейронних мереж. Вигляд рослин може значно змінюватися залежно від кута зйомки, освітлення та стану мінерального живлення. Органічний камуфляж у вигляді трав та ліан може повністю або частково приховувати будівлі та структури, змінюючи їх яскравість та контур. Це може призвести до затемнення деталей та збільшити ризик помилкового розпізнавання об'єктів. Наприклад, споруди, вкриті ліанами *Aristolochia manshuriensis* Kom., були правильно розпізнані лише у 27 % випадків із використанням нейронної мережі. Згорткові нейронні мережі потребують значної кількості даних для навчання, якщо метою є досягнення високої точності. Проте, якщо дані з об'єктами, вкритими ліанами, обмежені або недоступні, процес*

навчання може бути недостатнім, що може вплинути на здатність мережі до точного розпізнавання таких об'єктів.

Ключові слова: *органічний камуфляж, БАЛА, згорткові нейронні мережі, ліани*

Актуальність. У сучасному світі безпілотні літальні апарати (БПЛА) займають все більш важливе місце у військових сферах діяльності. Вони швидко стають незамінними знаряддями для розвідки, надання підтримки на полі бою та виконання різноманітних місій. БПЛА відіграють важливу роль у військових операціях шляхом забезпечення покращеної розвідки та нагляду. Вони здатні проникати в небезпечні зони, і збирати розвідувальну інформацію без ризику для особового складу. Вартість БПЛА здатного нести засоби ураження становить від кількох сотень доларів, при тому що зборка апарату з готових компонентів наявних у вільному доступі може бути виконана буквально в домашніх умовах, робить це знаряддя зручним устаткуванням не тільки для держав, а і для терористів. Завдяки передовим технологіям, БПЛА можуть бути оснащені різноманітними датчиками, включаючи пристрої технічного зору високої роздільної здатності, і радары та лідари, що дозволяє збирати важливі дані для прийняття рішень як на стратегічному, так і на тактичному рівнях. Можливість атаки цілі одночасно зграєю БПЛА робить актуальною впровадження новітніх підходів щодо захисту від цієї загрози і передусім маскуванню.

Перший досвід використання показав високу перспективність такого знаряддя і був реалізований при безпосередньому дистанційному керуванні, що показано в роботі [1]. Такі системи показали високу ефективність при зіткненнях супротивників на принципово різному технологічному рівні, коли супротивник не має засобів радіоелектронної боротьби. Розуміючи потенційну небезпеку такого озброєння, було розроблено комплекс знаряддя для протидії ним, а саме поставка перешкод по ідентифікованому каналу зв'язку, як показано в роботах [2, 3]. У якості протидії розроблялись спеціальні протоколи, такі як ALOHA, описане в [4] для керування радіоканалами, а також [5] для вибору вільних каналів керування, що особливо актуально для зграй БПЛА. Для цивільного сегменту, зокрема поліції та

рятувальників, вдалось розробити рішення щодо протидії зловмисникам, які показані в роботі [6], проте вважалось, що зловмисники фізично не здатні генерувати спотворений сигнал із високою потужністю. Для військових таких обмежень немає і відповідно такий захист може бути неефективним.

У разі протидії БПЛА окрім суто захисних заходів щодо генерації електромагнітних перешкод розроблялись і засоби для ідентифікації операторів, яка розглядалась як пріоритетні цілі для засобів ураження артилеристів та мінометників. Для забезпечення безпеки операторів потрібно було віддалити їх від лінії бойового зіткнення, для чого пропонувалось створювати мережі спеціалізованих БПЛА ретрансляторів, показаних у [7]. Проте такі проміжні пристрої затримують сигнал і ускладнюють керування БПЛА при враженні, особливо для рухомих об'єктів. Для враження стаціонарних об'єктів можливим рішенням при використанні ударних БПЛА є засоби високоточного позиціонування, зокрема військовий сегмент GPS. Такі БПЛА можуть програмуватися, заздалегідь використовуючи дані від розвідувальної авіації чи супутників, проте для боротьби з ними можливим є не глушіння, а спотворення сигналів навігаційної системи (Spoofing Attack). У роботах [8-10] описані перспективні рішення щодо ідентифікації такого впливу на систему, що ефективно може діяти зокрема для розвідувальних апаратів, але незрозуміло або вистачить часу на корекцію в ударних БПЛА особливо в умовах протидії ППО. Завдяки практиці Spoofing Attack досягти похибки навігації в кілька десятків метрів є цілком реальним, що для БПЛА класу «міні» із притаманним їм корисним навантаженням вибухового пристрою вагою до кількох сотень грам робить її неефективною.

Альтернативним рішенням щодо навігації БПЛА в умовах радіоелектронної боротьби є візуальна орієнтація на місцевості, описана зокрема в роботах [11-12]. Візуальна орієнтація реалізується на базі зображень місцевості, які отримуються на базі знімків високої роздільної здатності від супутників чи розвідувальних БПЛА. Програмно реалізація орієнтації здійснюється з використанням HCNNs (hybrid convolutional neural networks), огляд яких описано в роботі [13]. Досвід щодо використання для ідентифікації транспортних засобів за допомогою БПЛА та саме

ансамблю гібридних згорткових нейронних мереж показано в [14] та щодо ідентифікації транспортних засобів в аеропорту в роботі [15]. Окрім видимого діапазону спектру за цією технологією використовуються й інші, зокрема тепловий, показаний у цьому контексті щодо ідентифікації об'єктів в роботі [16]. Для серійних виробів під використання згорткових нейронних мереж при роботі з платформи БПЛА розроблене апаратне забезпечення NVIDIA Jetson TX2, показане в роботах [17-18].

Отже, найбільш перспективними і захищеними від засобів радіоелектронної боротьби є технології візуальної ідентифікації, що реалізуються на гібридних згорткових нейронних мережах. З урахуванням можливості роботи у різних спектральних діапазонах було висунуто гіпотезу щодо доцільності маскування саме стаціонарних об'єктів з використанням рослинних насаджень, зокрема ліан. З урахуванням того, що деякі ліани можуть приростати в довжину на 2,5–5 м на рік їхнього використання для маскування стаціонарних об'єктів може бути виправданим за співвідношенням якості/вартість.

Мета дослідження – перевірка ефективності маскування невеликих об'єктів з використанням трав'янистих та витких рослин щодо перспектив їх ідентифікації оптичними засобами.

Матеріали та методи дослідження. Для маскування інфраструктурних об'єктів можуть бути оперативно задіяні різноманітні трави, які можуть виконуватись у вигляді рулонного покриття, та швидкорослі ліани. Вони можуть використовуватись як разом, так і незалежно один від одного. Відповідно з розрахунку на можливість орієнтації БПЛА за спектральними показниками та геометрією об'єкту досліджувались:

- залежність спектральних показників трав'янистих рослин, зокрема пшениці озимої, від стану освітлення;
- зручність ідентифікації технологічної споруди, вкритої ліанами, з використанням згорткових нейронних мереж.

Дослідження щодо пшениці озимої здійснювали на дослідницькому стаціонарі щодо вивчення системи застосування добрив НУБіП України (рис. 1).



Рис 1. Стационарний дослід кафедри агрохімії і якості продукції рослинництва НУБіП України. Доза мінеральних добрив збільшується починаючи від дороги

Досліджувались ділянки посівів без внесення мінеральних добрив та із полуторною дозою NPK. Рослини перебували в стадії вегетації «вихід в трубку». Додатково розглядали ділянку ґрунтової дороги, що перебувала в повітряно-сухому стані. Позиціонування здійснювали по опорним точкам на поверхні землі. Дослідження проводились в безхмарну погоду, починаючи з 17 по 20 годину. Зйомки здійснювали з використанням БПЛА DJI Phantom 2+ (камера видимого діапазону FC200). Методика проведення досліджень та обробки результатів описані в [19-20].

В якості ліан для органічного камуфляжу було вибрано вид *Aristolochia manshuriensis* Kom. Ці рослини районовані для клімату України і можуть приростати більш, ніж на 5 м упродовж вегетації, що корисно з огляду на маскування габаритних споруд. Дослідження проводились у ботанічному саду НУБіП та в приватному секторі, де озеленення здійснювали з допомогою цієї рослини (рис. 2), також використовувались цифрові фотознімки, отримані з мережі інтернет.

Для розпізнавання зображень були використані згорткові нейронні мережі. Навчання таких мереж передбачає використання зображень, які можуть бути отримані із супутника чи з БПЛА [21]. У якості тренувальних даних використано знімки передмістя Нью-Йорка, де роздільна здатність відповідає знімкам з БПЛА на висоті 400 м. Це зображення містить ділянки із лісом (паркова зона, де на частині

дерев були ліани) та будівлями різного розміру та типу. З метою навчання нейронної мережі зображення було розбито на частини рівного розміру, котрі містили рослини та споруди різного типу.



Рис 2. Зразки ліани *Aristolochia manshuriensis* Kom. навесні, влітку та восени відповідно

Для створення та навчання згорткової нейронної мережі було використано популярну структуру глибокого навчання TensorFlow разом із Keras API. Послідовність виконання підготовки, навчання й тестування мережі наступна:

1. Data Collection: Gather a dataset containing images of green plants and images of objects created by people from a height of 400 meters.
2. Data Preprocessing: Resize and normalize the images to prepare them for training.
3. Model Definition: Design the CNN architecture.
4. Model Training: Train the CNN on the prepared dataset.
5. Evaluation: Evaluate the model's performance.
6. Predictions: Make predictions on new images using the trained model.

Перший етап полягав у розбитті зображень на дві категорії: будівлі (рис. 3) та зелень (рис. 4). На основі даних зображень відбувався процес навчання мережі.



Рис 3. Зображення, які було віднесено до типу «Будівлі» при навчанні CNN




Рис 4. Зображення, які було віднесено до типу «Рослинність» при навчанні CNN

CNN складається з двох повторюваних блоків Convolution і Max Pooling, за якими йдуть два повністю підключених шари. Шари згортки та максимального об'єднання відповідають за вивчення просторових характеристик класів (наприклад, визначення прямокутної форми будівель), тоді як повністю підключені рівні вчать робити прогнози, використовуючи ці просторові характеристики [22].

Результати досліджень та їх обговорення. При орієнтації БПЛА, виходячи з зображення місцевості, забарвлення об'єктів є важливим параметром щодо їх ідентифікації. Оскільки показники інтенсивності кольору для адитивної моделі кольороутворення RGB залежать від стану освітлення, його потрібно враховувати. Для цього можуть використовуватись як додаткові сенсори (зенітні спрямовані вгору) чи оптичні шаблони із відомими спектральними показниками, зокрема ґрунтові дороги, як правило, наявні на полях. Виходячи з цього було досліджено залежність інтенсивності складових кольору пшениці у порівнянні з ґрунтовою дорогою (рис. 5).

Виходячи з отриманих даних, коефіцієнт кореляції між показниками пшениці і утрамбованого ґрунту становить до 0,2, і відповідно показники можна вважати стабільними, проте різниця між мінімальним та максимальним значенням становить до 12 одиниць, що є великим, виходячи зі шкали вимірювання в 256 одиниць. Можливим поясненням цього є особливості будови рослинних насаджень, коли при різному куті освітлення фіксувалися в різних пропорціях частини рослин. Це є принциповою відмінністю від традиційного камуфляжного забарвлення поверхні об'єктів. Цікавим фактом є те, що вдень інтенсивність складових кольору рослин без

добрив були більшими, ніж у підживлених рослин, а ввечері в сутінки ситуація стала протилежною.




Рис 5. Залежність інтенсивності відповідної складової кольору пшениці без добрив (0) та з полуторною дозою (5) від кольору дороги в поверхнево сухому стані

Результати, отримані при використанні експонетру, (виходячи зі службових даних фотоапарату визначали значення світла LV) наведені на рис. 6.




Рис 6. Залежність інтенсивності відповідної складової кольору пшениці без добрив (0) та з полуторною дозою (5) від значення світла (LV)

При використанні експонометра в якості сенсора освітлення ситуація не змінилась і коефіцієнт кореляції для рослинних насаджень складає до 0,21. Для ущільненого ґрунту в повітряно сухому стані найбільш стабільним виявився синій вимірювальний канал, що доцільно враховувати при організації калібрування щодо освітлення.

Навчання згорткових нейронних мереж включає в себе два основних процеси: пряме поширення (forward propagation) та зворотнє поширення помилки (backpropagation). Ці процеси допомагають мережі вивчати оптимальні ваги та параметри для вирішення конкретного завдання.

Процес прямого поширення відбувається від вхідних даних до вихідного шару мережі. Дані проходять через послідовні шари, які включають в себе згорткові шари, функції активації та можливо, пулінг шари. У кожному згортковому шарі ядро здійснює згортку з вхідними даними, що вивчає різні особливості в даних.

Після прямого поширення вихід мережі порівнюється з бажаними результатами, і виникає фаза зворотного поширення помилки. Основна ідея полягає в тому, щоб оцінити, наскільки сильно ваги і параметри впливають на помилку, і потім коригувати їх, щоб поменшити цю помилку.

Зворотнє поширення помилки базується на градієнтному спуску, де вираховується градієнт втрат (функції, яка вимірює різницю між прогнозованими і фактичними результатами) відносно ваг і параметрів мережі. Цей градієнт показує, як потрібно змінити ваги та параметри, щоб зменшити помилку.

Після вирахування градієнту мережа застосовує алгоритм оптимізації (наприклад, метод стохастичного градієнтного спуску), щоб внести коригуючі зміни в ваги та параметри. Цей процес повторюється для багатьох пакетів даних (mini-batches) протягом декількох епох навчання.

Важливою складовою навчання згорткових нейронних мереж є використання функції втрати, яка вимірює величину помилки між прогнозованими та фактичними результатами.

Узагальнюючи, навчання згорткових нейронних мереж включає в себе пропускання даних через мережу, вирахування помилки, обчислення градієнту та коригування ваг та параметрів з метою мінімізації помилки під час навчання.

Фрагменти коду для навчання нейронних мереж приведені на рисунках 7 та 8.

```
train_dir = "dataset/train"
validation_dir = "dataset/validation"

# Step 2: Data Preprocessing
image_size = (150, 150)
batch_size = 32

train_datagen = ImageDataGenerator(rescale=1.0/255.0)
train_generator = train_datagen.flow_from_directory(
    train_dir,
    target_size=image_size,
    batch_size=batch_size,
    class_mode="binary"
)
```

Рис 7. Фрагмент коду програми на Python для створення мережі

```
# Step 4: Model Training
epochs = 10

model.fit(train_generator,
          steps_per_epoch=train_generator.n // batch_size,
          epochs=epochs,
          validation_data=validation_generator,
          validation_steps=validation_generator.n // batch_size)

# Step 5: Evaluation
loss, accuracy = model.evaluate(validation_generator)
print(f"Validation Loss: {loss:.4f}, Validation Accuracy: {accuracy:.4f}")

# Step 6: Predictions on New Images
def predict_single_image(image_path):
    image = load_img(image_path, target_size=image_size)
    image_array = img_to_array(image)
    image_array = np.expand_dims(image_array, axis=0)
    image_array /= 255.0
    prediction = model.predict(image_array)
    if prediction[0][0] < 0.5:
        return "Green Plant"
    else:
        return "People Object"
```

Рис 8. Фрагмент коду програми для навчання CNN

Тестування нейронної мережі включало в себе подачу вхідних даних на навчену модель для отримання вихідних значень та оцінки її продуктивності на нових, раніше не бачених даних. Основна мета тестування - перевірити, наскільки

добре навчена модель здатна генералізувати на нових даних, тобто наскільки добре вона працює на реальних вхідних даних, а не просто на даних, на яких вона була навчена.

Цикл тестування повторювався декілька разів для різних тестових наборів даних з метою отримання кращих результатів та забезпечення надійної оцінки продуктивності моделі.

Успішність розпізнавання зображень за допомогою нейронної мережі було оцінене за допомогою основної метрики, а саме Точність (Accuracy). Це основна метрика, яка визначає відсоток правильно класифікованих зображень у всьому тестовому наборі.

У першому випадку мережа продемонструвала високу точність розпізнавання зображень, зокрема здатність розрізнити будівлі та насадження (рис. 9).

```
score = model.evaluate_generator(test_set, steps=100)

for idx, metric in enumerate(model.metrics_names):
    print("{}: {}".format(metric, score[idx]))

loss: 0.475635891854763
acc: 0.80375
```

Рис 9. Результати тестування мережі при використанні зображень, де чітко видно будівлі та насадження

Неуспішне розпізнавання зображень можна визначити за допомогою різних методів та оцінюваних показників. Ось декілька способів:

Низька точність (Accuracy): Низька точність моделі на тестових даних може свідчити про її неуспішність у розпізнаванні зображень. Чим менше точність, тим більше помилок моделі.

Помилкові випадки: Аналіз помилкових випадків, коли модель неправильно класифікує зображення, може також допомогти визначити неуспішне розпізнавання

зображень. Виявлення шаблонів або тенденцій у помилкових випадках може вказати на проблеми з розпізнаванням певних типів зображень.

У випадку використання зображень, де нечітко видно будівлі, які знаходяться під деревами або в тіні дерев, мережа дала низьку точність розпізнавання (рис. 10).

```
score = model.evaluate_generator(test_set, steps=100)

for idx, metric in enumerate(model.metrics_names):
    print("{}: {}".format(metric, score[idx]))

    loss: 0.8915886721653
acc: 0.3157
```

Рис 10. Результати тестування мережі при використанні зображень, де нечітко видно будівлі та насадження

З наведених результатів простежуємо кореляцію між точністю розпізнавання зображень мережею та наявністю на цих зображеннях будівель, насаджень та будівель вкритих насадженнями. При розпізнаванні зображень споруд вкритих ліанами (м. Київ) будови у літній та осінній період було ідентифіковано лише в 27 %. Навчання для періоду без листя не проводилось, виходячи з малої кількості доступних даних.

Фактично, більш ніж в чверті випадків, ідентифікація будівель відбулась, що враховуючи вартість і відповідно кількість доступних ударних БПЛА можна вважати чималою. Проте, навчання нейронної мережі відбувалося на візуальних даних, отриманих в ідеальних умовах. За даними [23] ідентифікація об'єктів, коли камера спостерігає об'єкт під гострим кутом, що є основним режимом роботи для сучасних ударних камікадзе БПЛА, ідентифікація принципово ускладнюється. До того ж ліани, на відміну від маскувальних сіток, можуть ефективно використовуватися як у горизонтальній, так і у вертикальних проекціях. Така особливість ліан є особливо корисною, враховуючи можливості використання в уданих БПЛА рухомих камер, для яких можливість розпізнавання з урахуванням змін меж області ідентифікації, як показано в роботі [24]. До того ж суттєвою проблемою стосовно застосування ударних БПЛА, що орієнтуються завдяки засобам

машинного зору, є нестабільність траєкторії польоту, що за даними [25], навіть на прикладі наземного транспорту, призводить до суттєвих помилок щодо ідентифікації відстані і відповідно габаритів до ідентифікованих цілей ураження.

Ідентифікація інфраструктурних об'єктів, таких як електричні підстанції за даними [26] здійснюється за рахунок сегментації і ідентифікації окремих складових. Отримані авторами результати підтвердили дані [26], згідно яким ідентифікація навіть з високою роздільною здатністю була вкрай ускладнена завдяки фоновим поміхам такими, як випадкові об'єкти (будови, транспорт, рослини) тощо. Відповідно вважаємо, що точність ідентифікації замаскованих об'єктів у 27 % є позитивним результатом.

Висновки і перспективи. Рослинні насадження можуть мати велику варіативність форми, розміру та структури, що ускладнює завдання розпізнавання для мережі. Вони можуть виглядати дуже різними на зображеннях, залежно від кута зйомки, освітлення, стану мінерального живлення тощо.

Органічний камуфляж у вигляді трав та ліан може частково або повністю закривати будівлі або структури, що змінює яскравість та контур об'єктів. Це може призвести до затемнення інформації про об'єкти та збільшити шанс помилкового розпізнавання. Так, споруди вкриті ліанами *Aristolochia manshuriensis* Kom. були розпізнані нейронною мережею лише в 27 %.

Згорткові нейронні мережі вимагають великих обсягів даних для навчання, щоб досягти високої точності. Якщо дані з об'єктами, вкритими ліанами, обмежені або недоступні, навчання може бути недостатнім, що може взагалі вплинути на здатність мережі до точного розпізнавання таких об'єктів.

References

1. G. Raja, Y. Baskar, P. Dhanasekaran, R. Nawaz and K. Yu. (2021). An Efficient Formation Control mechanism for Multi-UAV Navigation in Remote Surveillance. 2021 IEEE Globecom Workshops (GC Wkshps), Madrid, Spain. pp. 1-6, doi: 10.1109/GCWkshps52748.2021.9682094.
2. K. Pärilä, T. Riihonen and M. Turunen. (2019). Sweep Jamming Mitigation Using Adaptive Filtering for Detecting Frequency Agile Systems. 2019 International Conference on Military Communications and Information Systems (ICMCIS), Budva, Montenegro, pp. 1-6. doi: 10.1109/ICMCIS.2019.8842761.

3. P. Kozak, V. Platenka and M. Richterova. (2019). Radio Communication Channel Analysis of UAV. 2019 International Conference on Military Technologies (ICMT), Brno, Czech Republic, pp. 1-4. doi: 10.1109/MILTECHS.2019.8870137.
4. H.-H. Choi, J. Oh, K.-M. Kang and H. Lee. (2023). Idle-less Slotted ALOHA Protocol for Drone Swarm Identification. IEEE Transactions on Vehicular Technology. doi: 10.1109/TVT.2023.3261104.
5. Z. Xu, I. Petrunin, A. Tsourdos and S. Ayub. (2019). Learning Based Spectrum Hole Detection for Cognitive Radio Communication. 2019 IEEE/AIAA 38th Digital Avionics Systems Conference (DASC), San Diego, CA, USA, pp. 1-7. doi: 10.1109/DASC43569.2019.9081799.
6. J. Viana et al. (2022). A Convolutional Attention Based Deep Learning Solution for 5G UAV Network Attack Recognition over Fading Channels and Interference, pp. 1-5. doi: 10.1109/VTC2022-Fall57202.2022.10012726.
7. H. Jee, K. Lee and J. Lim. (2017). Autonomous maneuvering of relay UAV for battlefields using TDOA localization. MILCOM 2017 - 2017 IEEE Military Communications Conference (MILCOM), Baltimore, MD, USA, pp. 453-458. doi: 10.1109/MILCOM.2017.8170765.
8. Z. Wang, J. Guo, Z. Chen, L. Yu, Y. Wang and H. Rao. (2022). Robust secure UAV relay-assisted cognitive communications with resource allocation and cooperative jamming. Journal of Communications and Networks, 24(2): 139-153. doi: 10.23919/JCN.2021.000044.
9. S. Wang, J. Wang, C. Su and X. Ma. (2020). Intelligent Detection Algorithm Against UAVs' GPS Spoofing Attack. 2020 IEEE 26th International Conference on Parallel and Distributed Systems (ICPADS), Hong Kong, pp. 382-389. doi: 10.1109/ICPADS51040.2020.00058.
10. C. Titouna and F. Naït-Abdesselam. (2021). A Lightweight Security Technique For Unmanned Aerial Vehicles Against GPS Spoofing Attack. 2021 International Wireless Communications and Mobile Computing (IWCMC), Harbin City, China, pp. 819-824. doi: 10.1109/IWCMC51323.2021.9498734.
11. S. Shvorov et al. (2020). The method of determining the amount of yield based on the results of remote sensing obtained using UAV on the example of wheat. 2020 IEEE 15th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET), Lviv-Slavske, Ukraine, pp. 245-248. doi: 10.1109/TCSET49122.2020.235432.
12. M. G. Lutsky, V. M. Sineglazov and V. S. Ishchenko. (2021). Suppression of Noise in Visual Navigation Systems. 2021 IEEE 6th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD), Kyiv, Ukraine, pp. 7-10. doi: 10.1109/APUAVD53804.2021.9615405.
13. V. Sineglazov, A. Kot. (2021). Design of Hybrid Neural Networks of the Ensemble Structure. Eastern-European Journal of Enterprise Technologies, 109(4): 31-45. doi: 10.2139/ssrn.3807474.
14. A. Bouguettaya, H. Zarzour, A. Kechida and A. M. Taberkit. (2022). Vehicle Detection From UAV Imagery With Deep Learning: A Review. IEEE Transactions on Neural Networks and Learning Systems, vol. 33, no. 11, pp. 6047-6067, Nov. 2022, doi: 10.1109/TNNLS.2021.3080276.

15. S. Liu, R. Wu, J. Qu and Y. Li. (2022). HDA-Net: Hybrid Convolutional Neural Networks for Small Objects Recognition at Airports. *IEEE Transactions on Instrumentation and Measurement*, Vol. 71, pp. 1-14. doi: 10.1109/TIM.2022.3219500.
16. J. Dong, K. Ota and M. Dong. (2020). Real-Time Survivor Detection in UAV Thermal Imagery Based on Deep Learning. 2020 16th International Conference on Mobility, Sensing and Networking (MSN), Tokyo, Japan, pp. 352-359. doi: 10.1109/MSN50589.2020.00065.
17. Z. Zhang, L. Tang, Y. Tian and Y. Pan. (2019). A Real-time Visual UAV Detection Algorithm on Jetson TX2. 2019 IEEE International Conference on Signal, Information and Data Processing (ICSIDP), Chongqing, China, pp. 1-4. doi: 10.1109/ICSIDP47821.2019.9173005.
18. J. Jeon, S. Jung, E. Lee, D. Choi and H. Myung. (2021). Run Your Visual-Inertial Odometry on NVIDIA Jetson: Benchmark Tests on a Micro Aerial Vehicle. *IEEE Robotics and Automation Letters*, 6(3) : 5332-5339. doi: 10.1109/LRA.2021.3075141.
19. N.A. Pasichnyk, O.A. Opryshko, D.S. Komarchuk, N.A. Yasinska, R.S. Rakhmedov and N.A. Kiktev. (2022). Data engineering for the automation of non-contact foliar diagnostics of plants based on the HSL model of color formation. 2022 IEEE 17th International Conference on Computer Sciences and Information Technologies (CSIT), Lviv, Ukraine, pp. 226-229. doi: 10.1109/CSIT56902.2022.10000464.
20. S.A. Shvorov, N.A. Pasichnyk, S.D. Kuznichenko, I.V. Tolok, S.V. Lienkov and 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, pp. 252-257. doi: 10.1109/APUAVD47061.2019.8943842.
21. Mingxia Yang, Yuling Mou, Shan Liu, Yanrong Meng, Zelin Liu, Peng Li, Wenhua Xiang, Xiaolu Zhou, Changhui Peng. (2022). Detecting and mapping tree crowns based on convolutional neural network and Google Earth images. *International Journal of Applied Earth Observation and Geoinformation*, 108. doi: 10.1016/j.jag.2022.102764.
22. James Loy. (2019). *Neural Network Projects with Python*. Packt Publishing Ltd. Birmingham, B3 2PB, UK.
23. Y. Wu, Y. Sun, Y. Jia and F. Liao. (2022). Parking-Lot Vehicles Detection from a Low-Angle Camera Perspective Based on Improved Mask R-CNN. 2022 Asia Conference on Algorithms, Computing and Machine Learning (CACML), Hangzhou, China, pp. 571-575. doi: 10.1109/CACML55074.2022.00102.
24. M. Zins, G. Simon and M.-O. Berger. (2020). 3D-Aware Ellipse Prediction for Object-Based Camera Pose Estimation. 2020 International Conference on 3D Vision (3DV), Fukuoka, Japan, pp. 281-290, doi: 10.1109/3DV50981.2020.00038.
25. J. Strosahl, J. Sichermann, M. Jesch and D. Spieler. (2022). Perspective-Corrected Extraction of Trajectories from Urban Traffic Camera Using CNN. 2022 International Conference on Connected Vehicle and Expo (ICCVE), Lakeland, FL, USA, pp. 1-7. doi: 10.1109/ICCVE52871.2022.9742966.
26. N. Yan, T. Zhou, C. Gu, A. Jiang and W. Lu. (2020). Instance Segmentation Model for Substation Equipment Based on Mask R-CNN. 2020 International Conference on Electrical Engineering and Control Technologies (CEECT), Melbourne, VIC, Australia, pp. 1-7. doi: 10.1109/CEECT50755.2020.9298600.

27. N.A. Pasichnyk, S.A. Shvorov, O.A. Opryshko, A. Dudnyk, B. Oksana and D.S. Komarchuk. (2023). Prospective of Camouflage Ground Objects to Counter UAVs. 2023 IEEE 7th International Conference on Methods and Systems of Navigation and Motion Control (MSNMC), Kyiv, Ukraine, pp. 1-6. doi: 10.1109/MSNMC61017.2023.10328960.

RECOGNITION OF ORGANIC CAMOUFLAGE USING NEURAL NETWORKS

A. Dudnyk, S. Shvorov, O. Opryshko, N. Pasichnyk, O. Kysliak,

Abstract. *Unmanned aerial vehicles (UAVs) are becoming increasingly important for military operations, including reconnaissance, providing battlefield support, and performing a variety of missions. The possibility of attacking targets using a group of UAVs increases the relevance of protection measures, in particular, camouflage. The literature review highlights the experience of using UAVs in military spheres of activity and their high efficiency in reconnaissance and support on the battlefield. Visual orientation on the terrain using high-resolution images was considered as a priority direction of UAV navigation in the conditions of the operation of electronic warfare tools. On the basis of hybrid convolutional neural networks, hardware for working with the UAV platform is serially produced. It is suggested to use vines for masking stationary objects due to their rapid growth and the corresponding quality/cost ratio. The purpose of the work is to check the effectiveness of masking small objects using herbaceous and spindly plants in relation to the prospects of their identification by optical means. The research was conducted using our own data obtained from UAVs in the visible range on experimental fields and the botanical garden of NUBiP of Ukraine and on pictures of buildings from the Internet. It has been experimentally established that the variety of shapes, sizes and structures of vegetation complicates the recognition process for convolutional neural networks. The appearance of plants can change significantly depending on the angle of photography, lighting and the state of mineral nutrition. Organic camouflage in the form of grasses and vines can completely or partially hide buildings and structures, changing their brightness and contour. This can obscure details and increase the risk of false object recognition. For example, structures covered with *Aristolochia manshuriensis* Kom. vines were correctly recognized only 27% of the time using a neural network. Convolutional neural networks require a large amount of data to train if the goal is to achieve high accuracy. However, if data with vine-covered objects is limited or unavailable, the training process may be insufficient, which may affect the network's ability to accurately recognize such objects.*

Key words: *organic camouflage, BALA, convolutional neural networks, vines*