

УДК 005:623

DOI: [https://doi.org/10.34169/2414-0651.2023.4\(40\).105-114](https://doi.org/10.34169/2414-0651.2023.4(40).105-114)

**В. І. СЛЮСАР**, доктор технічних наук, професор  
<https://orcid.org/0000-0002-2912-3149>

**Н. С. БІГУН**

<https://orcid.org/0000-0003-3327-5521>

(Центральний науково-дослідний інститут озброєння та військової техніки Збройних Сил України, м. Київ)

## МЕТОД БЕЗДРОТОВОЇ ПЕРЕДАЧІ ЗОБРАЖЕНЬ З ВИКОРИСТАННЯМ НЕЙРОМЕРЕЖ

Стаття присвячена оптимізації передачі зображень з безпілотних літальних апаратів за допомогою сучасних методів обробки зображень та машинного навчання. Автори представляють новаторський підхід, який базується на використанні розділених автоенкодерів. Ці автоенкодери, що працюють між безпілотними літальними апаратами та приймачем, дозволяють стискати зображення без втрати якості, що в свою чергу допомагає зекономити енергію та збільшити пропускну здатність при передачі даних. Однак, щоб запобігти можливим втратам якості від стиснення, автори застосовують методи надвисокої роздільної здатності на приймальній стороні. Такий комбінований підхід не тільки підвищує ефективність передачі зображень, але й відкриває нові можливості для програм дистанційного зондування та моніторингу на основі безпілотних літальних апаратів. Стаття буде корисною для фахівців у галузі бездротових мереж, спеціалістів з обробки зображень та дослідників, які працюють над розробкою та вдосконаленням безпілотних літальних апаратів.

**Ключові слова:** безпілотні літальні апарати, бездротові мережі, автоенкодер, кодер, декодер, згорток-ві нейронні мережі.

### ВСТУП

Безпілотні літальні апарати (БПЛА), широко відомі як дрони, все частіше знаходять застосування у багатьох сферах – від комерційного використання, як-от доставка продуктів і аерофотозйомка, до більш важливих завдань, як-от спостереження, ліквідація наслідків стихійних лих і моніторинг навколишнього середовища. Їх універсальність і маневреність відкрили нові можливості для збору даних, особливо візуальних, які можуть надати цінну інформацію про різні явища.

Типове завдання БПЛА передбачає зйомку візуальних даних високої роздільної здатності, їх обробку та передачу на приймальну станцію для подальшого аналізу (рис. 1). Однак цей процес становить значний виклик – зображення або відео високої роздільної здатності становлять великі обсяги даних, які, враховуючи обмежену

пропускну здатність та енергетичні ресурси БПЛА, може бути складно і неефективно передавати [1].




Рис. 1. Узагальнена система управління БПЛА

Попередні методи розв'язання цієї проблеми були зосереджені на звичайному стисненні, яке мінімізувало навантаження на канал передачі даних, гарантуючи при цьому, що якість відновлених зображень не погіршиться.

Отже, виникає потреба в ефективних і результативних методах стиснення і передачі даних без значної втрати якості переданих зображень. Нейронні мережі, нарізний камінь сучасного машинного навчання, пропонують перспективні розв'язання цієї проблеми. Зокрема, автоенкодери, особливий тип нейронних мереж, мають високу здатність до стиснення даних, що робить їх особливо придатними для нашого контексту. З усім тим, ці методи не позбавлені проблем та обмежень.

### ОГЛЯД СИСТЕМИ УПРАВЛІННЯ БПЛА

Еволюція безпілотних літальних апаратів перевизначила горизонти бездротового управління, запровадивши нові парадигми, які вимагають ефективних і надійних систем передачі даних. Система управління БПЛА – це складна мережа, в якій БПЛА діє як динамічний вузол. Вона охоплює ряд складних процесів, таких як збір, обробка, кодування, передача, приймання і декодування даних. Для забезпечення ефективного управління всі ці операції повинні бути безперешкодно інтегровані та досконало організовані.

Одним з основних аспектів, який відрізняє управління БПЛА від типового наземного бездротового управління, є просторовий і тривимірний характер управління БПЛА. Системи управління БПЛА можна умовно поділити на системи прямої видимості (LOS) і системи за межами прямої видимості (BLOS). Системи LOS простіші й, як правило, передбачають пряме радіоуправління між БПЛА та наземною станцією (рис. 1). Однак їхній радіус дії обмежений кривизною Землі та будь-якими перешкодами. Системи BLOS (рис. 2), з іншого боку, використовують супутники або ретрансляційні БПЛА для розширення робочого діапазону та забезпечення глобального покриття [2].

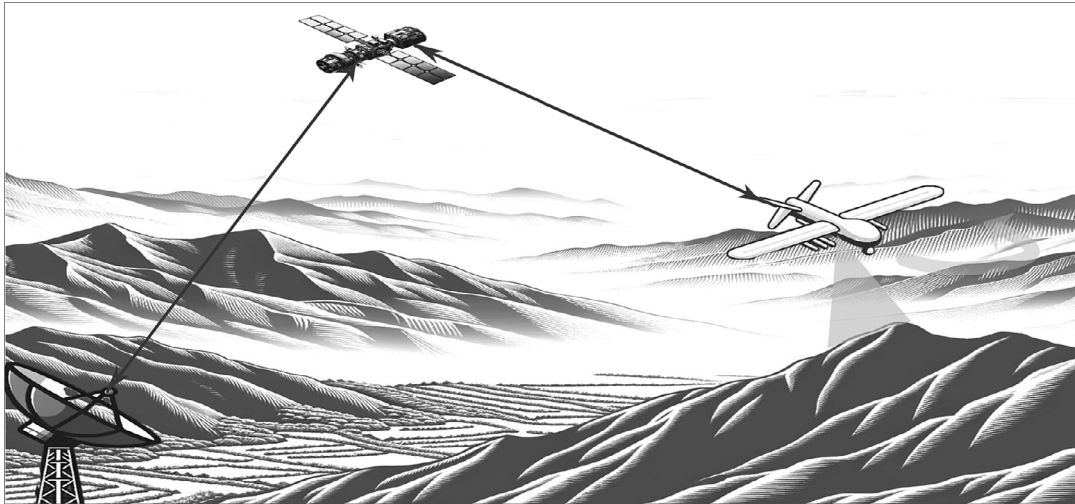


Рис. 2. Системи за межами прямої видимості (BLOS) [3]

Попри успіхи, досягнуті в розробці систем управління для БПЛА, деякі проблеми залишаються невирішеними. До них відносяться проблеми, пов'язані з обмеженою пропускну здатністю, перешкодами сигналу та потенційними вразливими місцями в системі безпеки. Крім того, ці проблеми стають все більш актуальними зі зростанням попиту на вищі швидкості передачі даних для підтримки складних додатків, таких як потокове відео високої роздільної здатності в реальному часі [1]. Однією з конкретних проблем є ефективна передача зображень або відеопотоків високої роздільної здатності з БПЛА на наземну станцію. Цей процес вимагає великої пропускну здатності, і на нього можуть серйозно впливати обмеженість смуги пропускання і шум. Наявні методи включають алгоритми стиснення даних і протоколи передачі, які спрямовані на оптимізацію використання доступної смуги пропускання. Однак ці методи часто призводять до компромісу між якістю зображення та ефективністю передачі.

У цьому контексті ключовим напрямком досліджень є застосування штучного інтелекту (ШІ) та методів машинного навчання для оптимізації передачі даних. Нейронні мережі, автоенкодера та методи надвисокої роздільної здатності були визначені як потенційні інструменти, що можуть значно підвищити якість та ефективність передачі зображень і відеоданих у системах управління БПЛА.

### МЕТОДОЛОГІЯ

В основі запропонованої системи лежить застосування розщепленого автоенкодера – варіанту штучної нейронної мережі, який широко використовується для кодування даних. Автоенкодера в стандартному вигляді складаються з двох основних компонентів: кодера та декодера, які працюють в тандемі для стиснення та подальшого відновлення вхідних даних [4]. Унікальність цієї методології полягає в «розділеній» роботі цього автоенкодера, де кодер і декодер стратегічно розміщені на передавальному та приймальному кінцях відповідно.

Зокрема, на борту БПЛА встановлюється компонент автоенкодера – кодер. Він є нейронною мережею, яка розроблена та навчена перетворювати високорозмірні дані зображення в компактне, низькорозмірне представ-

лення латентного простору, що часто називають «шифруванням». Наприклад, якщо БПЛА знімає 12-мегапиксельне зображення, що відповідає приблизно 36 мільйонам точок у колірному просторі RGB, кодер може стиснути ці дані до представлення, яке складається лише з кількох тисяч точок. Таке значне зменшення розмірності призводить до значного стиснення оригінального зображення, яке потім формує суть даних, що передаються.

Для ілюстрації процесу для 12-мегапиксельного зображення, розміри якого можуть бути близько 4000x3000 пікселів, було використано згорткові нейронні мережі [5] (CNN) з Keras (рис. 3). Цей приклад коду створює модель кодера, що здатна значно зменшити розмірність вхідного зображення.

```
from keras.layers import Input, Conv2D, MaxPooling2D
from keras.models import Model

# Assuming a 12-megapixel image in RGB color space (4000 x 3000 x 3)
input_img = Input(shape=(4000, 3000, 3))

Encoder network
x= Conv2D(128, (3, 3), activation='relu', padding='same')(input_img)
x= MaxPooling2D((2, 2), padding='same')(x)
x= Conv2D(64, (3, 3), activation='relu', padding='same')(x)
x= MaxPooling2D((2, 2), padding='same')(x)
x= Conv2D(32, (3, 3), activation='relu', padding='same')(x)
x= MaxPooling2D((2, 2), padding='same')(x)
x= Conv2D(16, (3, 3), activation='relu', padding='same')(x)
encoded = MaxPooling2D((2, 2), padding='same')(x)

# Create the Encoder Model
encoder = Model(input_img, encoded)

# Print summary of the Encoder model
encoder.summary()
```

Рис. 3. Спрощений приклад моделі кодера

Цей скрипт будує модель кодера, використовуючи шари Conv2D і MaxPooling2D, ефективно зменшуючи розмірність вхідного зображення. Кодований результат матиме значно меншу розмірність, ніж вихідне зображення. На рис. 3 наведено спрощений ілюстративний приклад, тому на практиці вибір архітектури буде залежати від конкретних вимог використання.

Крім того, перш ніж модель зможе ефективно стискати дані зображення, її потрібно навчити на відповідних навчальних даних. Це пов'язано з тим, що кодер розроб-

лений таким чином, щоб зберегти найважливіші риси оригінального зображення в цьому низьковимірному представленні, відкидаючи те, що, на його думку, є надлишковою або менш важливою інформацією. Цей аспект «навчання», що зберігати, а що відкидати, є результатом етапу навчання кодера, де він тренується на тисячах прикладів, щоб зрозуміти та зафіксувати основні закономірності та структури в даних.

Суттєве зменшення обсягу даних, досягнуте за допомогою цього процесу кодування, призводить до значної економії енергії та пропускної здатності. Наприклад, якщо розглянути сценарій бездротової передачі, де пропускна здатність може бути обмежена кількома сотнями кілобайт на секунду, вищезгадане стиснення може уможливити передачу зображень у реальному часі або майже в реальному часі, що в іншому випадку було б практично неможливо. Після успішної передачі даних стисненого зображення приймальна сторона ініціює процес декодування. Цією фазою роботи керує другий компонент розділеного автоенкодера – декодер.

Роль декодера в системі полягає в тому, щоб повернути назад операцію, яку виконує кодер. Декодер бере отримане низькорозмірне представлення, яке ми називаємо «розкодуванням», і починає процес реконструкції вихідних високорозмірних даних зображення. По суті, він намагається «декодувати» інформацію, яку кодер раніше «закодував» у більш низькорозмірний формат (рис. 4). Декодер, як і кодер, також є нейронною мережею. Вона розроблена і навчена для вивчення зворотної функції кодера. Маючи компактне, низьковимірне представлення зображення, він прагне реконструювати оригінальне зображення шляхом екстраполяції з цього зменшеного представлення. Декодер поступово збільшує розмірність вхідних даних, шар за шаром, намагаючись відновити деталі оригінального зображення на кожному кроці.

```

from keras.layers import Input, Conv2D, MaxPooling2D, UpSampling2D
from keras.models import Model

# Decoder network
x = Conv2D(16, (3, 3), activation='relu', padding='same')(encoded)
x = UpSampling2D((2, 2))(x)
x = Conv2D(32, (3, 3), activation='relu', padding='same')(x)
x = UpSampling2D((2, 2))(x)
x = Conv2D(64, (3, 3), activation='relu', padding='same')(x)
x = UpSampling2D((2, 2))(x)
x = Conv2D(128, (3, 3), activation='relu', padding='same')(x)
x = UpSampling2D((2, 2))(x)
decoded = Conv2D(3, (3, 3),
                 activation='sigmoid', padding='same')(x)

# Create the Autoencoder Model
autoencoder = Model(input_img, decoded)

# Print summary of the Autoencoder model
autoencoder.summary()

```

Рис. 4. Спрощений приклад моделі декодера

Під час початкової фази навчання автоенкодера, його сегменти кодер і декодер навчаються разом як єдина модель, причому цей процес виконується без урахування наявності бездротового зв'язку між ними. Ця оптимізація необхідна для спільної синхронізації, оскільки після завершення навчання автоенкодер розділяється, а кодер і декодер розгортаються окремо.

Важливо зазначити, що цей процес реконструкції не дає ідеальної копії оригінального зображення. Процес стиснення на етапі кодування неминуче призводить до втрати деяких даних, зокрема, менш значущих або надлишкових аспектів даних зображення, визначених навчанням автоенкодера. В результаті, декомпресоване зображення, отримане декодером, буде дещо погіршеною версією оригінального зображення, де бракуватиме деяких деталей або якості. Ступінь цієї деградації залежить від ступеня стиснення та складності оригінального зображення.

Наприклад, у крайньому випадку, якщо багатоколірне зображення з високою деталізацією стискається до дуже малого кодування, декодер може відновити лише розмите або монохромне наближення оригінального зображення. З іншого боку, якщо стиснення відносно слабке, а зображення просте, декодер може відновити зображення, яке майже не відрізнити від оригіналу для людського ока.

По суті, хоча декодерний компонент розділеного автоенкодера відіграє вирішальну роль у відновленні даних зображення з переданого кодування, цей процес за своєю природою схильний до певного рівня втрати якості через компроміс, досягнутий під час циклу стиснення-розпакування. Для боротьби з погіршенням якості, спричиненим циклом стиснення-розпакування автоенкодера, ми включили в нашу методологію додатковий крок – застосування методів надвисокої роздільної здатності. Після того, як стиснуті дані зображення отримані та розпаковані декодером, вони обробляються за допомогою алгоритму надвисокої роздільної здатності для подальшого підвищення якості реконструйованого зображення. Алгоритми надвисокої роздільної здатності привернули значну увагу в галузі комп'ютерного зору та обробки зображень завдяки своїй здатності збільшувати роздільну здатність зображень, ефективно «заповнюючи» відсутні деталі, які не присутні у версії з нижчою роздільною здатністю. Ці методи використовують алгоритми машинного навчання для прогнозування та реконструкції високочастотних деталей, які зазвичай втрачаються під час стиснення зображень [6].

У цьому контексті під «високочастотними» маються на увазі аспекти зображення, які швидко змінюються на невеликих просторових ділянках, такі як краї об'єктів і дрібні текстури. Ці деталі мають вирішальне значення для сприйняття якості зображення людиною, але часто першими відкидаються під час стиснення через високу вагу даних. Одним із прикладів такого методу надвисокої роздільної здатності є використання CNN. У методі, відомому як «Single Image Super Resolution» (SISR), CNN навчається на парах зображень з низькою та високою роздільною здатністю [7]. Цей процес дозволяє CNNs навчатися і відтворювати перетворення з низької роздільної здатності у високу, ефективно додаючи відсутні деталі до зображення. SISR на основі глибокого навчання, проілюстрована на рис. 5, є визначною технікою для покращення якості зображень [8].

Іншою відомою технікою надвисокої роздільної здатності є підхід «Генеративна змагальна мережа» (GAN). Вона містить дві нейронні мережі, генератор і дискримінатор, які конкурують між собою. Генератор намага-

```

from keras.layers import Input, Conv2D
from keras.models import Model

# The output from the decoder network, as you described above
decoder_output = decoded

# Assuming that the decoder output is a 4000x3000 RGB image
super_resolution_input = Input(shape=(4000, 3000, 3))

# Super-resolution network
x = Conv2D(64, (9, 9), activation='relu', padding='same')(
    super_resolution_input)

x = Conv2D(32, (1, 1), activation='relu', padding='same')(x)
super_resolved = Conv2D(3, (5, 5), activation='linear',
padding='same')(x)

# Create the Super Resolution Model
super_resolution = Model(super_resolution_input, super_resolved)

# Print summary of the Super Resolution model
super_resolution.summary()

```

Рис. 5. Спрощений приклад моделі SISR на основі глибокого навчання

ється створити зображення високої роздільної здатності з вхідних даних низької роздільної здатності, в той час, як дискримінатор намагається відрізнити ці створені зображення від реальних зображень високої роздільної здатності. Цей змагальний процес призводить до того, що генератор створює все більш реалістичні зображення з високою роздільною здатністю [9].

Завдяки цим методам зображення, отримані з декодера, ще більше покращуються, відновлюючи деякі втрачені високочастотні деталі й, таким чином, досягаючи якості, наближеної до оригінальних попередньо стиснутих зображень. Інтегруючи цей етап надвисокої роздільної здатності в нашу методологію, ми можемо значно покращити стандартний автоенкодерний підхід до стиснення

та передачі зображень, отримуючи якісніші зображення після передачі. Ця нова комбінація розділеного автоенкодера для ефективного стиснення зображень і методів надвисокої роздільної здатності для покращення якості лежить в основі цього підходу до оптимізації передачі зображень з БПЛА. На рис. 6 показано узагальнений вигляд алгоритму описаних вище процесів.

### ПЕРСПЕКТИВИ МЕТОДУ АНАЛІЗУ ТА ПЕРЕДАЧІ ЗОБРАЖЕНЬ БПЛА

Згорткові нейронні мережі (CNNs) призвели до зміни парадигми виявлення об'єктів і виявилися особливо ефективними в обробці даних зображень [10]. Вони використовують операції багатопарової згортки та об'єднання для вивчення ієрархічного представлення вхідних даних. У контексті виявлення об'єктів ці ієрархічні ознаки використовуються для визначення наявності та розташування об'єктів на зображенні [11, 12].

Раніше методи виявлення об'єктів використовували ручні ознаки та класифікатори, такі як машини опорних векторів (SVM) або AdaBoost. Однак, поява CNNs відкрила нову еру наскрізного навчання, коли модель здатна навчатися як вилученню ознак, так і класифікації. Використання CNNs для виявлення об'єктів почалося з розробки архітектури R-CNN (Regions with CNN features), де селективний пошук використовувався для того, щоб запропонувати регіони, які потім класифікувалися за допомогою CNNs. За цим з'явилися архітектури Fast R-CNN і Faster R-CNN, які значно підвищили продуктивність і ефективність задач виявлення об'єктів. Ці методи поклалися на концепцію регіональних пропозицій, яка була дорогою в обчислювальному плані. Такі архітектури, як You Only Look Once (YOLO) та Single Shot

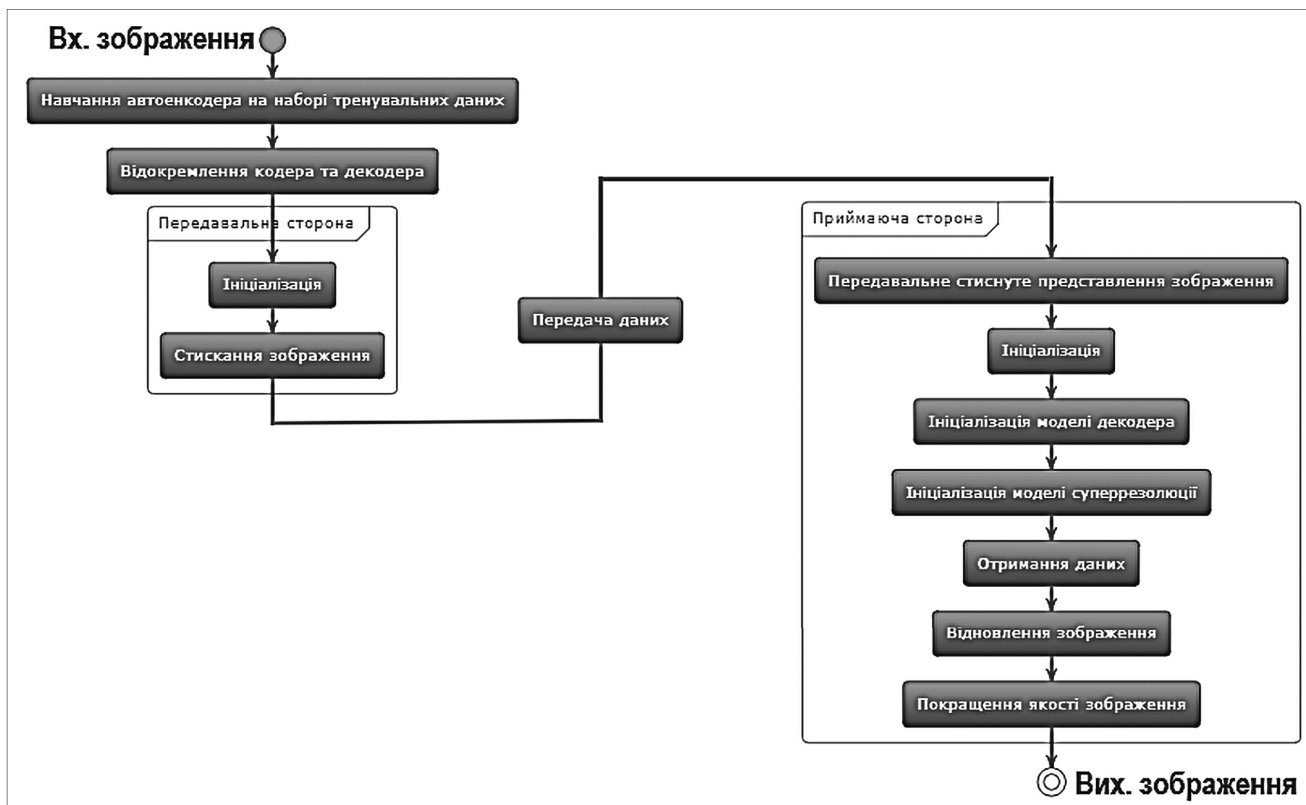


Рис. 6. Блок-схема методу бездротової передачі зображення з використанням нейронних мереж

MultiBox Detector пропонували інший підхід, де задача виявлення об'єктів розглядалася як задача регресії до просторово розділених обмежувальних областей та пов'язаних з ними ймовірностей класів [13].

У сфері візуалізації за допомогою БПЛА отримання всебічного просторового розуміння має вирішальне значення для багатьох застосувань, включаючи картографування місцевості, інспекцію інфраструктури та спостереження. У цьому розділі ми розглянемо методи формування 3D-зображень, сегментації контурів і виявлення об'єктів за допомогою CNN, які є невіднятними частинами запропонованої нами стратегії оптимізації передачі зображень з БПЛА. Для БПЛА виявлення об'єктів відіграє вирішальну роль у ряді застосувань, таких як спостереження, пошук і порятунк, сільське господарство та інспекція інфраструктури [14]. Наприклад, у сценарії пошуку та порятунку система виявлення об'єктів може бути використана для визначення місцеперебування людей, які потребують допомоги. У сільському господарстві система може бути використана для ідентифікації та визначення місця посівів або ділянок, які потребують уваги.

Наступна технологія, яка може спростити процес обробки зображень з БПЛА, – це контурна сегментація. Сегментація в обробці зображень означає процес розбиття зображення на декілька сегментів або наборів пікселів, часто на основі певного критерію, такого як колір, інтенсивність або текстура. У контексті нашого дослідження [15] контурна сегментація передбачає виділення меж об'єктів на зображенні, що може бути особливо корисним для таких застосувань, як виявлення або відстеження об'єктів.

Нещодавні досягнення в галузі глибокого навчання значно покращили ефективність контурної сегментації,

CNNs продемонстрували свій потенціал у цій галузі. CNNs здатні автоматично навчатися та виокремлювати ієрархічні ознаки з вхідних зображень, покращуючи таким чином задачі сегментації. Крім того, ці моделі можна навчити добре узагальнювати невидимі дані, що забезпечує надійну роботу в широкому діапазоні середовищ. Однією з найефективніших архітектур для задач контурної сегментації є архітектура U-Net (рис. 7) [16]. U-Net – це тип повністю згорткової мережі (FCN), яка була спеціально розроблена для сегментації біомедичних зображень, хоча з того часу її було поширено на широкий спектр інших застосувань. Архітектура U-Net включає серію згорткових і об'єднувальних шарів для виділення ознак, за якими слідує серія підсилювальних і згорткових шарів для попиксельної класифікації.

У контексті операцій БПЛА сегментація контурів може відігравати важливу роль у багатьох додатках, таких як виявлення об'єктів, навігація та розуміння сцени. Наприклад, БПЛА можуть використовувати сегментацію контурів для виявлення та уникнення перешкод у реальному часі, що підвищує їхню безпеку та надійність [15].

Не менш важливою є концепція перетворення 2D-зображень у тривимірну форму, відома як 3D-реконструкція. 3D-зображення додають глибину до двовимірних (2D) зображень, пропонуючи спостерігачеві реальну перспективу. Це має величезне значення для багатьох застосувань в системах БПЛА, від картографування місцевості до виявлення та уникнення перешкод. Здатність БПЛА будувати 3D-моделі наземних об'єктів і ландшафтів забезпечує безпрецедентну деталізацію і просторове розуміння [17].

У БПЛА створення 3D-зображень зазвичай передбачає збір декількох двовимірних (2D) зображень сцени або об'єкта з різних точок зору. Процес збору зображень




Рис. 7. Архітектура U-Net

здійснюється за допомогою бортових датчиків, як правило, стереокамер або LiDAR-технології, які встановлюються на БПЛА. Після отримання зображень, 3D-реконструкція сцени досягається шляхом застосування принципів комп'ютерного зору і фотограмметрії, які в основному базуються на триангуляції. Розбіжність або позиційна різниця точки, що спостерігається з двох різних точок зору (тобто двох різних 2D-зображень), використовується для визначення глибини цієї точки в сцені, в результаті чого створюється 3D-зображення (рис. 8) [18, 19].

Такі методи, як Structure from Motion (SfM) і Multi-View Stereo (MVS) широко використовуються для великомасштабної 3D-реконструкції. У той час як SfM може працювати з некаліброваними зображеннями та оцінювати положення камери для створення розріджених 3D-хмар точок, MVS вимагає каліброваних зображень і пропонує щільну 3D-реконструкцію.

Ще однією важливою вимогою при експлуатації БПЛА є забезпечення надійного управління, що в цьому випадку передбачає роботу в умовах обмеженої пропускної здатності й перешкод, які можуть серйозно вплинути на якість переданої інформації, в тому числі зображень. Величезний обсяг даних, особливо зображень і відео високої роздільної здатності, які необхідно передавати в реальному часі або близькому до нього, призводить до обмеженої пропускної здатності каналів передачі даних. З іншого боку, шуми в каналі передачі даних, які можуть

бути викликані такими факторами, як атмосферні умови, рельєф місцевості та інші електромагнітні перешкоди, можуть погіршити якість переданих сигналів, що призводить до потенційної втрати або неправильної інтерпретації інформації.

Для зменшення цих проблем пропонується використувати схему цифрового квадратурного фільтра (DSQF) з двокаскадною синфазною та квадратурною (I/Q) технологією демодуляції (рис. 9), що сприятиме оптимізації використання смуги пропускання та підвищенню завадостійкості лінії управління. Ця технологія забезпечує кількісну оцінку якості цифрового сигналу, інтегруючи DSQF-вимірювання в процес передачі, і дозволяє динамічно адаптувати рівень стиснення даних зображення на основі поточної якості сигналу [20].




Рис. 9. Схема DSQF з двоступеневою I/Q демодуляцією

З іншого боку, двокаскадна технологія I/Q демодуляції покращує завадостійкість системи. I/Q демодуляція – це

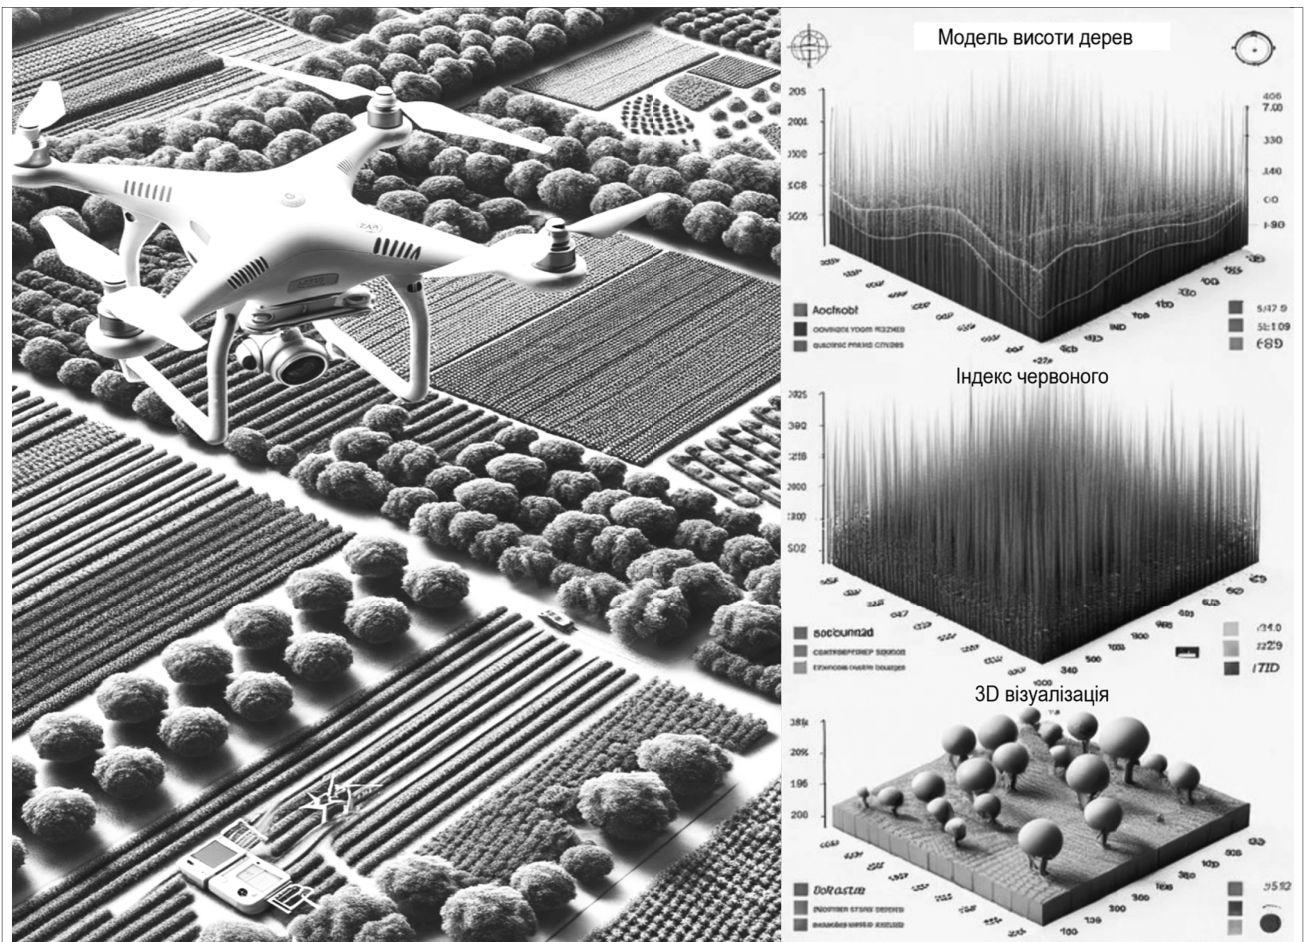


Рис. 8. Приклад 3D-моделі, створеної з 2D-зображень, отриманих БПЛА

метод, який використовується в системах зв'язку для розділення синфазних і несинхронних компонентів сигналу. Двоступенева реалізація цього методу забезпечує вищий рівень завадостійкості, гарантуючи, що якість отриманих зображень не погіршиться через шуми та перешкоди в каналі передачі даних. Процес двокаскадної I/Q демодуляції розбивається на два етапи. Ця двоетапна процедура забезпечує більший контроль над обробкою сигналу, дозволяючи більш точне налаштування та коригування на кожному етапі.

На першому етапі сигнал потрапляє в систему і розділяється на дві частини: синфазну (I) і квадратурну (Q) складові. Ці дві складові представляють один і той самий сигнал, але знаходяться в протифазі на 90 градусів одна від одної. Такий поділ на I і Q-компоненти корисний, оскільки дозволяє обробляти амплітудну і фазову інформацію окремо, мінімізуючи спотворення і втрату інформації. Саме тут відфільтровується більшість шумів і завад, оскільки певні типи шуму придушуються під час процесу модуляції.

Роль другого етапу полягає в подальшому покращенні I- та Q-компонентів, які вже були вилучені та первинно оброблені. Цей етап включає ще один раунд демодуляції, подальше придушення залишкового шуму та точне налаштування сигналу. На цьому етапі для покращення якості сигналу можуть бути застосовані вдосконалені алгоритми обробки сигналу. Це можуть бути такі завдання, як адаптивна фільтрація, корекція помилок або інші форми оптимізації сигналу.

Розділивши ці процеси на два окремі етапи, кожен з них можна оптимізувати для певної мети: перший – для ефективного розділення I/Q і початкового шумопридушення, а другий – для точного налаштування і додаткового шумопридушення. Такий структурований двоетапний підхід може значно покращити якість сигналу в кінці процесу, забезпечуючи цілісність даних зображень, що передаються з БПЛА.

Завадостійкість покращується, оскільки будь-який шум, внесений під час передачі, впливає на амплітуду та фазу радіочастотного сигналу. Оскільки I/Q демодуляція працює безпосередньо з цими параметрами, вона пропонує більш надійний метод вилучення вихідної інформації навіть у присутності шуму.

## ВИСНОВКИ

У цій статті представлено інноваційне рішення для оптимізації передачі зображень з БПЛА через бездротовий канал управління. Використовуючи комбінацію нейромережових архітектур, даний підхід ефективно зменшує розмір даних зображень без значного погіршення якості зображення.

Запропонована система в першу чергу використовує розділений автоенкодер, з кодером, встановленим на борту БПЛА, і декодером, розташованим на приймальному кінці. Кодер значно зменшує розмір високорозмірних даних зображення шляхом перетворення в компактне, більш низькорозмірне представлення латентного простору, або «шифрування». В експериментах 12-мегапіксельні зображення (що відповідає приблизно 36 мільйонам точок даних у колірному просторі RGB) були успішно

стиснуті до представлень, що складаються лише з кількох тисяч точок, що призвело до значної економії при передачі даних.

Однак стиснені зображення при відновленні декодером страждали від певних втрат якості. Для розв'язання цієї проблеми пропонується використовувати методи надвисокої роздільної здатності, такі як SISR та GAN, ця система дозволяє ефективно додавати втрачені деталі до реконструйованих зображень. По суті, вона зіставляє зображення з низькою роздільною здатністю з їхніми аналогами з високою роздільною здатністю.

На додаток, БПЛА може «вчитися» на вхідних і вихідних зображеннях, що в кінцевому підсумку призведе до кращого кодування автоенкодером і меншої втрати якості. Це свідчить про те, що з більшою кількістю даних і навчанням система може постійно вдосконалюватися.

Отже, це дослідження продемонструвало, що завдяки поєднанню розділеного автоенкодера для стиснення і методів надвисокої роздільної здатності для покращення якості, можна ефективно передавати високоякісні зображення з БПЛА бездротовим каналом передачі даних. Це дослідження є цінним внеском у сферу передачі зображень і може мати суттєві наслідки для повітряного спостереження в реальному часі, дистанційного зондування та багатьох інших застосувань.

## СПИСОК ПОСИЛАНЬ

1. Слюсар В.И. Методы передачи изображений сверхвысокой четкости. Первая миля. Last mile (Приложение к журналу «Электроника: наука, технология, бизнес»). 2019. № 2. С. 46–61. <https://doi.org/10.22184/2070-8963.2019.79.2.46.61>.
2. Davies, L. (2018). Review of unmanned aircraft system technologies to enable beyond visual line of sight (BVLOS) operations. X 537 Intern. Conf. on electrical power drive systems (ICEPDS). <https://doi.org/10.1109/ICEPDS.2018.8571665>.
3. Human Factors In UAS Research. Available at: <http://uasblogger.blogspot.com/>.
4. Bourtsoulatz, E., Burth Kurka, D. & Gunduz, D. (2019). Deep Joint Source-Channel Coding for Wireless Image Transmission. IEEE Transactions on Cognitive Communications and Networking. Vol. 5(3). Pp. 567–579. <https://doi.org/10.1109/TCCN.2019.2919300>.
5. Deng, H., Zhang, Y., Li, R., Hu, C., Feng, Z. & Li, H. (2022). Combining residual attention mechanisms and generative adversarial networks for hippocampus segmentation. Tsinghua Science and Technology. Vol. 27(1). Pp. 68–78. <https://doi.org/10.26599/tst.2020.9010056>.
6. Arun, P., Herrmann, I., Budhiraju, K.M. & Karnieli, A. (2019). Convolutional network architectures for super-resolution/sub-pixel mapping of drone-derived images. Pattern recognition. Vol. 88(12). Pp. 431–446. <https://doi.org/10.1016/j.patcog.2018.11.033>.
7. Park, S.C., Park, M.K. & Kang, M.G. (2003). Super-resolution image reconstruction: A technical overview. IEEE Signal Processing Magazine. Vol. 20(3). Pp. 21–36. <https://doi.org/10.1109/MSP.2003.1203207>.
8. Chang, H., Yeung, D. & Xiong, Y. (2004). Super-resolution through Neighbor embedding. IEEE Computer Society

- Conf. on Computer Vision and Pattern Recognition. P. II. <https://doi.org/10.1109/CVPR.2004.1315043>.
9. Goodfellow, Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. & Bengio, Y. (2020). Generative adversarial networks. *Commun. ACM*. Vol. 63(11). <https://doi.org/10.1145/3422622>.
  10. Slyusar, V., Protsenko, M., Chernukha, A., Gornostal, S., Rudakov, S., Shevchenko, S., Chernikov, O., Kolpachenko, N., Timofeyev, V. & Artiukh, R. (2021). Construction of an advanced method for recognizing monitored objects by a convolutional neural network using a discrete wavelet transform. *Eastern-European J. of Enterprise Technologies*. Vol. 4/9(112). Pp. 65–77. <https://doi.org/10.15587/1729-4061.2021.238601>.
  11. Slyusar, V., Protsenko, M., Chernukha, A., Kovalov, P., Borodych, P., Shevchenko, S., Chernikov, O., Vazhynskyi, S., Bogatov, O. & Khrustalev, K. (2021). Improvement of the object recognition model on aerophotos using deep conventional neural network. *Eastern-European J. of Enterprise Technologies*. Vol. 5/2(113). Pp. 6–21. <https://doi.org/10.15587/1729-4061.2021.243094/>.
  12. Slyusar, V., Protsenko, M., Chernukha, A., Melkin, V., Biloborodov, O., Samoilenko, M., Kravchenko, O., Kalinichenko, G., Rohovyi, A. & Soloshchuk, M. (2022). Improvement of the model for detecting objects on aerial photos and video in unmanned aerial systems. *Eastern-European J. of Enterprise Technologies*. Vol. 1/9(115). Pp. 24–34. <https://doi.org/10.15587/1729-4061.2022.252876>.
  13. Redmon, J. (2016). You Only Look Once: Unified, Real-Time Object Detection. *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR-2016)*. <https://doi.org/10.1109/cvpr.2016.91>.
  14. Badrinarayanan, V., Kendall, A. & Cipolla, R. (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol. 39(12). Pp. 2481–2495. <https://doi.org/10.1109/TPAMI.2016.2644615>.
  15. Slyusar, V. (2021). Improving a neural network model for semantic segmentation of images of monitored objects in aerial photographs. *Eastern-European J. of Enterprise Technologies*. Vol. 6/2 (114). Pp. 86–95. <https://doi.org/10.15587/1729-4061.2021.248390>.
  16. Применение нейронной сети на основе архитектуры U-NET с целью детектирования искомым объектов на изображениях на примере детектирования активных элементов на фотографиях печатных плат. [Электронный ресурс]. – Режим доступа: <https://codeby.school/blog/informacionnaya-bezopasnost/primenenie-neyronnoy-seti-na-osnove-arhitektury-u-net-s-celyu-detektirovaniya-iskomyh-obektov-na-izobragheniyah-na-primere-detektirovaniya-aktivnyh-elementov-na-fotografyah-pechatnyh-plat>.
  17. Yu, C., Han, R., Song, M., Liu, C. & Chang, C.I. (2020). A Simplified 2D-3D CNN Architecture for Hyperspectral Image Classification Based on Spatial-Spectral Fusion. *IEEE J. of Selected Topics in Applied Earth Observations and Remote Sensing*. Vol. 13. Pp. 2485–2501. <https://doi.org/10.1109/JSTARS.2020.2983224>.
  18. Asadpour, M., Giustiniano, D., Hummel, K.A. & Egli, S. UAV networks in rescue missions. The 8<sup>th</sup> ACM Intern. Workshop on Wireless Network Testbeds, Experimental Evaluation & Characterization – WiNTECH 13. <https://doi.org/10.1145/2505469.2506491>.
  19. Sangjan, W., McGee, R.J. & Sankaran, S. (2022). Optimization of UAV-Based Imaging and Image Processing Orthomosaic and Point Cloud Approaches for Estimating Biomass in a Forage Crop. *Remote Sensing*. Vol. 14(10). P. 2396. <https://doi.org/10.3390/rs14102396>.
  20. Slyusar, V. & Bihun, N. (2022). The Method of Increasing the Immunity of Data Transmission in Communication Channels. *IEEE 9<sup>th</sup> Intern. Conf. on Problems of Infocommunications. Science and Technology (PIC S&T)*. Kharkiv. Pp. 301–305. <https://doi.org/10.1109/PICST57299.2022.10238546>.

### REFERENCES

1. Slusar, V. (2019). “Metody peredachi izobrazhenii sverkhvysokoi chetkosti” [Methods of transferring images of ultra-high definition], *Last mile (Addition of J. «Electronics: Science, Technology, Business»)*. Vol. 2. Pp. 46–61. <https://doi.org/10.22184/2070-8963.2019.79.2.46.61>.
2. Davies, L. (2018). Review of unmanned aircraft system technologies to enable beyond visual line of sight (BVLOS) operations. *X 537 Intern. Conf. on electrical power drive systems (ICEPDS)*. <https://doi.org/10.1109/ICEPDS.2018.8571665>.
3. Human Factors In UAS Research. Available at: <http://uasblogger.blogspot.com/>.
4. Bourtsoulatze, E., Burth Kurka, D. & Gunduz, D. (2019). Deep Joint Source-Channel Coding for Wireless Image Transmission. *IEEE Transactions on Cognitive Communications and Networking*. Vol. 5(3). Pp. 567–579. <https://doi.org/10.1109/TCCN.2019.2919300>.
5. Deng, H., Zhang, Y., Li, R., Hu, C., Feng, Z. & Li, H. (2022). Combining residual attention mechanisms and generative adversarial networks for hippocampus segmentation. *Tsinghua Science and Technology*. Vol. 27(1). Pp. 68–78. <https://doi.org/10.26599/tst.2020.9010056>.
6. Arun, P., Herrmann, I., Budhiraju, K.M. & Karnieli, A. (2019). Convolutional network architectures for super-resolution/sub-pixel mapping of drone-derived images. *Pattern recognition*. Vol. 88(12). Pp. 431–446. <https://doi.org/10.1016/j.patcog.2018.11.033>.
7. Park, S.C., Park, M.K. & Kang, M.G. (2003). Super-resolution image reconstruction: a technical overview. *IEEE Signal Processing Magazine*. Vol. 20(3). Pp. 21–36. <https://doi.org/10.1109/MSP.2003.1203207>.
8. Chang, H., Yeung, D. & Xiong, Y. (2004). Super-resolution through Neighbor embedding. *IEEE Computer Society Conf. on Computer Vision and Pattern Recognition*. P. II. <https://doi.org/10.1109/CVPR.2004.1315043>.
9. Goodfellow, Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. & Bengio, Y. (2020). Generative adversarial networks. *Commun. ACM*. Vol. 63(11). <https://doi.org/10.1145/3422622>.
10. Slyusar, V., Protsenko, M., Chernukha, A., Gornostal, S., Rudakov, S., Shevchenko, S., Chernikov, O., Kolpachenko, N., Timofeyev, V. & Artiukh, R. (2021). Construction of an advanced method for recognizing



- monitored objects by a convolutional neural network using a discrete wavelet transform. *Eastern-European J. of Enterprise Technologies*. Vol. 4/9(112). Pp. 65–77. <https://doi.org/10.15587/1729-4061.2021.238601>.
11. Slyusar, V., Protsenko, M., Chernukha, A., Kovalov, P., Borodych, P., Shevchenko, S., Chernikov, O., Vazhynskiy, S., Bogatov, O. & Khrustalev, K. (2021). Improvement of the object recognition model on aerophotos using deep conventional neural network. *Eastern-European J. of Enterprise Technologies*. Vol. 5/2(113). Pp. 6–21. <https://doi.org/10.15587/1729-4061.2021.243094/>.
  12. Slyusar, V., Protsenko, M., Chernukha, A., Melkin, V., Biloborodov, O., Samoilenko, M., Kravchenko, O., Kalinichenko, G., Rohovyi, A. & Soloshchuk, M. (2022). Improvement of the model for detecting objects on aerial photos and video in unmanned aerial systems. *Eastern-European J. of Enterprise Technologies*. Vol. 1/9(115). Pp. 24–34. <https://doi.org/10.15587/1729-4061.2022.252876>.
  13. Redmon, J. (2016). You Only Look Once: Unified, Real-Time Object Detection. *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR-2016)*. <https://doi.org/10.1109/cvpr.2016.91>.
  14. Badrinarayanan, V., Kendall, A. & Cipolla, R. (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol. 39(12). Pp. 2481–2495. <https://doi.org/10.1109/TPAMI.2016.2644615>.
  15. Slyusar, V. (2021). Improving a neural network model for semantic segmentation of images of monitored objects in aerial photographs. *Eastern-European J. of Enterprise Technologies*. Vol. 6/2 (114). Pp. 86–95. <https://doi.org/10.15587/1729-4061.2021.248390>.
  16. “Primenenie neironnoi seti na osnove arkhitektury U-NET s tseliu detektirovaniia iskomykh obektov na izobrazheniiakh na primere detektirovaniia aktivnykh elementov na fotografiakh pechatnykh plat” [Application of a neural network based on the U-NET architecture for the purpose of detecting the desired objects in images using the example of detecting active elements in photographs of printed circuit boards]. Available at: <https://codeby.school/blog/informacionnaya-bezopasnost/primenenie-neyronnoy-seti-na-osnove-arhitektury-u-net-s-celyu-detektirovaniya-iskomykh-obektov-na-izobragheniyah-na-primere-detektirovaniya-aktivnykh-elementov-na-fotografiyah-pechatnyh-plat>.
  17. Yu, C., Han, R., Song, M., Liu, C. & Chang, C.I. (2020). A Simplified 2D-3D CNN Architecture for Hyperspectral Image Classification Based on Spatial-Spectral Fusion. *IEEE J. of Selected Topics in Applied Earth Observations and Remote Sensing*. Vol. 13. Pp. 2485–2501. <https://doi.org/10.1109/JSTARS.2020.2983224>.
  18. Asadpour, M., Giustiniano, D., Hummel, K.A. & Egli, S. UAV networks in rescue missions. *The 8<sup>th</sup> ACM Intern. Workshop on Wireless Network Testbeds, Experimental Evaluation & Characterization – WiNTECH 13*. <https://doi.org/10.1145/2505469.2506491>.
  19. Sangjan, W., McGee, R.J. & Sankaran, S. (2022). Optimization of UAV-Based Imaging and Image Processing Orthomosaic and Point Cloud Approaches for Estimating Biomass in a Forage Crop. *Remote Sensing*. Vol. 14(10). P. 2396. <https://doi.org/10.3390/rs14102396>.
  20. Slyusar, V. & Bihun, N. (2022). The Method of Increasing the Immunity of Data Transmission in Communication Channels. *IEEE 9<sup>th</sup> Intern. Conf. on Problems of Infocommunications. Science and Technology (PIC S&T)*. Kharkiv. Pp. 301–305. <https://doi.org/10.1109/PICST57299.2022.10238546>.

**Slyusar V.I., Bihun N.S.**

#### **METHOD OF WIRELESS IMAGE TRANSMISSION USING NEURAL NETWORKS**

*The research article addresses the problem of improving the efficiency of image transmission from unmanned aerial vehicles by using state-of-the-art image processing techniques along with advanced machine learning algorithms. The research introduces a new methodology that involves the use of split autoencoders to facilitate the compression of images transmitted from UAVs to ground receivers. These sophisticated autoencoders work in tandem with the transmission systems to provide efficient image compression, thereby reducing bandwidth usage and saving energy without degrading the visual information content of the images.*

*The authors' innovative approach is that they counteract the potential reduction in image quality typically associated with compression by implementing advanced ultra-high resolution technologies at the receiving end of the transmission. As a result, end users receive images that not only closely match the original, but also feature exceptional clarity and an increased level of detail, which is critical for accurate interpretation and analysis.*

*The findings of this research are particularly relevant to professionals in the field of wireless network engineering, experts specializing in image processing, and the broader research community that is engaged in the continuous development and improvement of unmanned aerial vehicle technology. The article not only outlines the technical aspects of the proposed methods, but also provides insight into practical applications, thereby serving as a resource for those who intend to explore the limits of UAV capabilities and optimize data transfer protocols.*

**Keywords:** UAV, wireless networks, autoencoder, coder, decoder, CNN.