

<https://doi.org/10.31891/2307-5732-2025-359-25>
УДК 004.8:004.932

ЖИЛЯКОВ ВЛАДИСЛАВ

Національний університет «Львівська Політехніка»
<https://orcid.org/0009-0007-4747-8019>
e-mail: vladyslav.zhyliakov.mknssh.2024@lpnu.ua

ГОРУН ПАВЛО

Національний університет «Львівська Політехніка»
<https://orcid.org/0009-0008-4296-5560>
e-mail: pavlo.p.horun@lpnu.ua

ІДЕНТИФІКАЦІЯ ЛЮДЕЙ У ПОШУКОВО-РЯТУВАЛЬНИХ ОПЕРАЦІЯХ ЗА ДОПОМОГОЮ КОНВОЛЮЦІЙНИХ НЕЙРОННИХ МЕРЕЖ

З метою підвищення точності ідентифікації людей на зображеннях під час пошуково-рятувальних операцій в роботі запропоновано удосконалений підхід з використанням конволюційних нейронних мереж. Розроблено глибинну конволюційну мережу з каскадним розташуванням конволюційних і пулінгових шарів. Проведено експериментальні дослідження з різними оптимізаторами навчання, зокрема Nadam, RMSprop, Adam, SGD, Adamax та Adagrad.

Експерименти з розмірами ядер конволюції показали, що збільшення розміру з 3×3 до 5×5 покращує точність моделі, тоді як зменшення до 2×2 призводить до погіршення результатів. Досліджено вплив кількості фільтрів у конволюційних шарах: збільшення їх кількості вдвічі (64, 128, 256, 512 відповідно) підвищило ефективність, а зменшення (16, 32, 64, 128 відповідно) знизило точність моделі.

Найкращі результати досягнуто з оптимізатором Nadam, розміром ядра 5×5 та збільшеною кількістю фільтрів. При цьому, F1-score – 0.91, точність – 0.92. Додовнення (аугментація) вхідних даних (відображення, трансформації зсуву, повороти, збільшення) дозволило підвищити стійкість моделі до перенавчання та покращити її точність.

Ключові слова: конволюційні нейронні мережі, ідентифікація людей, пошуково-рятувальні операції, комп'ютерний зір, машинне навчання.

ZHYLIAKOV VLADYSLAV

HORUN PAVLO

Lviv Polytechnic National University

NEURAL NETWORKS FOR HUMAN IDENTIFICATION IN SEARCH AND RESCUE OPERATIONS

The paper proposes an approach to improving a human identification system on the images for application in search and rescue operations by using convolutional neural networks. A deep convolutional neural network with cascaded arrangement of convolutional and pooling layers has been developed. Experimental studies were conducted with various training optimizers, including Nadam, RMSprop, Adam, SGD, Adamax, and Adagrad.

Experiments with the different convolution kernel size showed that increasing the size from 3×3 to 5×5 improves model accuracy, while reducing to 2×2 leads to the accuracy degradation. The influence of the number of filters in convolutional layers was investigated: doubling the filters (64, 128, 256, 512 accordingly) increased efficiency, while their reduction (16, 32, 64, 128 accordingly) decreased model accuracy.

The best results were achieved by using Nadam optimizer, kernel size 5×5 , and increased number of filters: F1-score – 0.91 and accuracy – 0.92. The application of data augmentation techniques (reflection, translation transformation, rotation, magnification) enhanced the robustness of the proposed model against overfitting and improved model's accuracy.

The developed model can be integrated into systems with limited computing resources. This allows to reduce the response time to emergency situations and increase the safety of rescuers by automating the process of detecting people. Despite the achieved results, the model is inferior to the latest architectures YOLO and EfficientDET in terms of absolute accuracy. In addition, the study was based on a single dataset, which may limit the generalizability of the conclusions to other types of SAR scenarios.

Possible directions for further research: integration of generative modeling methods (GAN, diffusion models) to improve data quality in complex conditions; use of ensemble approaches to increase the robustness of the model; testing the model on real video streams from drones in different weather and lighting conditions.

Keywords: convolutional neural networks, human identification, search and rescue operations, computer vision, machine learning.

Стаття надійшла до редакції / Received 25.09.2025

Прийнята до друку / Accepted 15.11.2025

Постановка проблеми у загальному вигляді

та її зв'язок із важливими науковими чи практичними завданнями

У сучасному світі, де надзвичайні ситуації стають дедалі поширенішими, особливо в контексті техногенних катастроф, значна увага приділяється пошуково-рятувальним операціям. Однією з ключових задач у таких випадках є швидка ідентифікація людей, які можуть потребувати допомоги. Традиційні методи пошуку зазвичай вимагають значних людських ресурсів і можуть бути неефективними в умовах обмеженого часу та небезпечних ситуацій. З появою технологій комп'ютерного зору та машинного навчання відбувається зміна парадигми в цих процесах, що відкриває нові можливості для автоматизації задач і підвищення їх ефективності.

Ця робота присвячена розробці моделі на основі конволюційних нейронних мереж (CNN) для ідентифікації людей у контексті пошуково-рятувальних операцій на воді. Основна мета полягає у розробці технології, що дозволяє зменшити час реагування на надзвичайні ситуації та підвищити точність виявлення людей.

У цій роботі розглядається система, що використовує різні підходи до обробки зображень, включаючи сучасні алгоритми глибокого навчання, з метою досягнення високої точності. Крім того, проведено експерименти з різними конфігураціями і гіперпараметрами моделей, щоб знайти оптимальне рішення для вирішення поставленої задачі.

Аналіз досліджень та публікацій

Дослідження, представлене у статті [1], зосереджено на використанні конволюційних нейронних мереж (CNN) для виявлення людей за допомогою БПЛА в умовах пошуково-рятувальних операцій. Точність виявлення перевищила 80%, що підтверджує ефективність CNN у пошуково-рятувальних місіях.

Дослідження, описані у статті [2], є оглядом сучасних методів виявлення людей за допомогою БПЛА у пошуково-рятувальних місіях. У дослідженні розглянуто використання YOLOv3, YOLOv4, EfficientDET і ансамблевих алгоритмів для підвищення точності. Одним із ключових результатів стало досягнення точності 94,73% YOLOv3 при ідентифікації плавців у відкритій воді. Ця точність доповнюється швидкістю 6,8 FPS, що забезпечує модель високою ефективністю у сценаріях реального часу. У статті також описано успішне застосування EfficientDET, яка показала найкращі результати на наборі даних HERIDAL. Інноваційний ансамблевий підхід дозволив поєднати кілька моделей глибокого навчання для підвищення точності ідентифікації людей.

У роботі [3] основна увага приділяється покращенню якості зображень у затоплених регіонах за допомогою сучасних методів глибокого навчання, таких як автоенкодери, GAN і механізми уваги. Основною моделлю виявлення обрано YOLOv8, яка була оптимізована для роботи в складних умовах. GAN використовували для покращення видимості зображень, що знімалися у сценаріях зі слабким освітленням або високим рівнем шуму. Результати показали, що така комбінація методів дозволяє значно підвищити точність ідентифікації людей, а також якість зображень у складних умовах.

Дослідження [4] було спрямоване на підвищення стійкості моделей виявлення людей у пошуково-рятувальних операціях на воді за допомогою моделювання реальних погодних умов і освітлення. Основна увага приділялася використанню моделей YOLOv5l і YOLOv10l, які були натреновані на збільшених наборах даних. Збільшення даних включало синтетичне моделювання погодних умов, таких як туман, дощ і змінне освітлення. Результати показали значні покращення в показниках точності та відновлення. Зокрема, YOLOv5l досягла рівня точності до 91%, що є вищим, ніж у моделей, які не використовували аугментацію даних. Також моделі показали високу стійкість до варіацій властивостей зображень, що дозволяє ефективно виявляти об'єкти навіть у складних умовах. Важливо відзначити, що додаткові F1-оцінки підтвердили збалансованість між точністю та повнотою, де YOLOv5l досягла найкращого показника - 0,94.

У статті [5] основна увага приділяється ансамблевому навчанню на основі EfficientDET для виявлення людей на аерофотознімках. Використання ансамблевих моделей дозволило досягти високої точності 95,11%, що перевершує результати окремих архітектур, таких як BiFPN та FC-FPN. Найкращі результати були досягнуті при використанні роздільної здатності зображення 512 пікселів, тоді як вищі роздільні здатності (640 і 1024) демонстрували трохи нижчі показники точності (92,63% і 90,06% відповідно). Ансамблеве навчання забезпечило перевагу за рахунок комбінування кількох моделей і покращення їхніх індивідуальних сильних сторін. Це дозволило значно знизити кількість хибно позитивних передбачень і підвищити надійність системи виявлення. Дослідження також акцентує увагу на важливості правильної оптимізації параметрів, що має суттєвий вплив на продуктивність моделі.

Стаття [6] ілюструє значні досягнення у застосуванні синтетичних даних згенерованих за допомогою ігрового рушія Unreal Engine 4 для машинного навчання в контексті морських пошуково-рятувальних операцій. Інноваційність підходу полягає не лише у створенні синтетичних даних, але й у їх адаптації до моделювання різноманітних реалістичних умов (наприклад, впливу різних погодних явищ), що підвищує стійкість моделей до змін домену. Інтеграція синтетичних даних дозволяє тренувати моделі з використанням значно меншої кількості реальних даних — до 95% менше — без втрати продуктивності, відкриваючи можливості для створення ресурсоефективних моделей, які мають практичне застосування у сценаріях з обмеженою доступністю даних.

Стисле порівняння кожного дослідження наведено у таблиці 1.

Аналіз літературних джерел демонструє, що для ідентифікації людей у пошуково-рятувальних операціях найбільш ефективними є сучасні моделі комп'ютерного зору, такі як CNN, YOLO різних версій (v3, v4, v5l, v8, v10), EfficientDET та ансамблеві методи. Висока точність виявлення (понад 90% у більшості досліджень) досягається завдяки використанню методів аугментації даних, таких як моделювання реальних погодних умов, та оптимізації моделей під специфічні завдання.

Зокрема, CNN продемонстрував хорошу швидкість обробки зображень, а YOLOv3 і EfficientDET досягли найкращих результатів у виявленні людей на відкритих територіях і в морських умовах. Використання інноваційних підходів, таких як GAN для покращення якості зображень, та ансамблеве навчання дозволило підвищити ефективність систем, зменшити кількість хибних передбачень і збалансувати продуктивність.

Попри високі результати точності сучасних архітектур (YOLO різних версій, EfficientDET, ансамблеві методи), аналіз літературних джерел показує наявність кількох прогалин. Більшість моделей із найвищою точністю (94–95%) потребують значних обчислювальних ресурсів, спеціалізованого обладнання та великих наборів даних для навчання. Це ускладнює їх використання у реальних пошуково-рятувальних місіях, де доступні обчислювальні потужності обмежені. Таким чином, постає завдання пошуку компромісу між точністю, стійкістю та ресурсними витратами.

Таблиця порівняння досліджень

Джерело	Вхідні дані	Метод дослідження	Сильні сторони	Недоліки
CNN-based Human Detection for UAVs in Search and Rescue [1]	Зображення з БПЛА	CNN	Непогана точність (понад 80%), швидкість обробки 3 кадри/сек, ефективно виявлення частково видимих людей.	Нижча точність, порівняно з новішими моделями.
Human Detection from UAVs for SAR Missions: State-of-the-Art [2]	Зображення з БПЛА	YOLOv3, YOLOv4, EfficientDET, ансамблеве навчання	Висока точність виявлення (94,73%), успішне застосування моделей для різних умов, значний внесок у SAR місії.	Потребує спеціалізованого обладнання, складність збору якісних даних.
Object Detection in SAR: Deep Learning Strategies [3]	Зображення у затоплених регіонах	Autoencoders, GAN, механізми уваги	Оптимізація YOLOv8, покращення точності виявлення в затоплених умовах.	Обмеження ресурсів для обробки в реальному часі, складність застосування у динамічних умовах затоплення.
Enhancing Robustness of Human Detection Algorithms [4]	Збільшені аерознімки	YOLOv5l, YOLOv10l, збільшені набори даних	Підвищення ефективності моделей у SAR місіях, F1-score до 0,94, покращення за допомогою збільшення наборів даних.	Складність збільшення наборів даних, адаптація до реальних умов.
Detecting Humans in SAR Using Ensemble Learning [5]	HERIDAL dataset	Ансамблеве навчання на базі EfficientDET	Точність 95,11% на роздільній здатності 512, перевищення результатів попередніх методів, ефективність на аерофотознімках.	Складність відтворення через оптимізацію параметрів і керування часом навчання.
Unreal Engine 4 для SAR [6]	Синтетичні дані, згенеровані в Unreal Engine 4	Інтеграція синтетичних даних, моделювання реалістичних умов (погода, зміна домену)	Зменшення потреби в реальних даних до 95% без втрати продуктивності, тренування моделей для SAR у складних умовах, підвищення стійкості до змін домену.	Залежність від якості синтетичних даних, обмеження адаптації до реальних сценаріїв.

У цьому контексті застосування CNN є виправданим і раціональним рішенням. Хоча CNN поступаються новітнім моделям за абсолютними показниками точності, вони забезпечують достатній рівень розпізнавання (понад 80%) при значно менших апаратних вимогах. Це забезпечує достатній баланс між точністю та обчислювальними витратами, що робить CNN придатними для інтеграції в системах з обмеженими ресурсами. Це, у свою чергу, підвищує доцільність та практичність їх використання у реальних пошуково-рятувальних операціях, зокрема із використанням БПЛА.

Формулювання цілей статті

Метою даної роботи є розробка моделі на основі конволюційних нейронних мереж для вирішення завдання ідентифікації людей у контексті пошуково-рятувальних операцій. Конволюційні мережі обрано через їхню здатність забезпечувати високу ефективність при значно меншій вимозі до обчислювальних ресурсів порівняно з моделями типу YOLO, що є важливим у реальних умовах з обмеженими ресурсами. Робота також включає проведення експериментів з різними типами архітектур таких мереж і аналіз результатів, отриманих під час тестування моделей.

Опис набору даних

Для реалізації задачі було обрано Human Detection Dataset [7], що містить велику кількість зображень людей у різних позах. Зображення приведені до розміру 256×256 пікселів, додаткова зміна розміру зображень

не застосовувалася. Для розширення та урізноманітнення даних виконано аугментацію: горизонтальне й вертикальне відображення, зсуви, повороти, масштабування. У результаті для кожного зображення сформовано 9 варіантів (оригінал і 8 аугментованих копій). Приклади аугментації наведено на рис. 1.

Підготовлений набір забезпечує достатню різноманітність для ефективного навчання CNN без ризику перенавчання.




Рис. 1. Приклад оригінального зображення і його 8 аугментованих копій

Виклад основного матеріалу

У процесі дослідження було розроблено та протестовано кілька архітектур конволюційних нейронних мереж (CNN) для задачі класифікації зображень, спрямованої на пошук людей у складних умовах. Розробка включала як формальну постановку задачі, так і проведення експериментів із різними архітектурними параметрами та оптимізаторами з метою вибору найбільш ефективної конфігурації.

Архітектура моделі

Загальна архітектура моделі реалізує збалансований підхід до вилучення ознак. На початкових етапах модель вивчає прості ознаки, поступово переходячи до складніших. Комбінація шарів MaxPooling і AveragePooling сприяє оптимальному вилученню ключових характеристик із даних. Функція активації ReLU у прихованих шарах дозволяє уникнути проблеми затухаючих градієнтів, що сприяє більш стабільному та швидкому навчанню.

Фінальний шар із функцією активації sigmoid забезпечує відповідний вихід для задач бінарної класифікації, перетворюючи результати в діапазон $[0, 1]$, що дозволяє інтерпретувати їх як ймовірності належності до певного класу. Для оцінки якості навчання використовувалася функція втрат Binary Cross-Entropy:

$$L = -\frac{1}{N} \sum_{i=1}^N (y_i \cdot \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i))$$

де $y_i \in \{0,1\}$ – справжня мітка класу, $\hat{y}_i \in [0,1]$ – прогнозована ймовірність, N – загальна кількість екземплярів.

Якість класифікації додатково оцінювалася за метриками Precision, Recall та F1-score, які визначаються наступним чином:

$$Precision = \frac{TP}{TP+FP}, \quad Recall = \frac{TP}{TP+FN}, \quad F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision+Recall},$$

де TP – кількість правильно ідентифікованих позитивних значень, FP – кількість хибнопозитивних значень, FN – кількість хибнонегативних значень.

Вибір гіперпараметрів (кількість фільтрів, розмір ядра, оптимізатор) здійснювався на основі експериментів (див. таблицю 2).

Межі гіперпараметрів

Гіперпараметр	Діапазон значень
Оптимізатор	RMSprop, Adam, Nadam, Adamax, SGD, Adagrad
Розмір ядра згортки	2×2, 3×3, 5×5
Кількість фільтрів	(16, 32, 64, 128), (32, 64, 128, 256), (64, 128, 256, 512)

На рис.2. зображено архітектуру базової моделі.




Рис.2. Архітектура базової моделі

Незважаючи на те, що розроблена модель показала хороші результати, зокрема досягнення значення F1-Score - 0.83, існує потенціал для подальшого покращення через підбір найкращих параметрів моделі. Цей підбір описується далі через експерименти з оптимізаторами, розміром ядра і кількістю фільтрів. Експерименти проводилися у середовищі Google Colab із використанням CPU, 12 GB оперативної пам'яті та фреймворку TensorFlow.

Експерименти з оптимізаторами

Було перевірено шість оптимізаторів: RMSprop, Adam, Nadam, Adamax, SGD, Adagrad. Найкращі результати модель показала з оптимізатором Nadam – 0.86 F1-Score і 0.84 Precision, що демонструє його ефективність для даної архітектури. Також добре себе зарекомендували RMSProp і Adam, які показали результати F1 Score 0.83. На рис.3. зображений графік результатів F-1 Score для шести оптимізаторів.

Оптимізатор Adamax досяг F1 Score 0.81, що є порівняно хорошим результатом, але поступається Adam і RMSProp. Найменш ефективними виявилися оптимізатори SGD та Adagrad, значення F1-Score яких склали 0.78 і 0.54 відповідно. Особливо слабкий результат Adagrad можна пояснити повільною швидкістю збіжності та меншою здатністю до адаптації в задачах класифікації.





Рис.3. Значення F1-Score для різних оптимізаторів


Подальші експерименти проводилися із використанням оптимізаторів Nadam, Adam і RMSProp, оскільки вони показали найкращі результати.

Експерименти з розміром ядра згортки

Розмір ядра згортки змінювався між 2×2, 3×3 та 5×5. Найкращий результат зафіксовано при розмірі ядра 5×5 з оптимізатором Nadam: F1-Score = 0.88, Precision = 0.89. При зменшенні до розміру ядра 2×2 з тим же оптимізатором показники впали: F1-Score = 0.82, Precision = 0.81. Це вказує на те, що занадто мале ядро не здатне якісно захоплювати просторові залежності, а 5×5 забезпечує оптимальний баланс. На рис. 4-5 зображені графіки результатів F1-Score та тренувальних і валідаційних втрат при різних оптимізаторах для ядер 5×5 і 2×2 відповідно.



а) б)
Рис.4. Значення F1-Score : а) розмір ядра 5×5; б) розмір ядра 2×2




а) б)
Рис.5. Значення Train/Validation loss : а) розмір ядра 5×5; б) розмір ядра 2×2

Експерименти з кількістю фільтрів

Для перевірки впливу глибини мережі тестувалися варіанти:

- Базова кількість (32, 64, 128, 256);
- Збільшена вдвічі (64, 128, 256, 512);
- Зменшена вдвічі (16, 32, 64, 128).

Збільшення кількості фільтрів підвищило якість навчання: Так, за рахунок використання оптимізатора Nadam вдалося досягти точності 0.92, F1-Score = 0.91. Зменшення кількості фільтрів суттєво погіршило результати: F1-Score = 0.81. На рис. 6-7 зображені графіки значень F1-Score та тренувальних і валідаційних втрат при різних оптимізаторах для різної кількості фільтрів – (64, 128, 256, 512) і (16, 32, 64, 128) відповідно.



а) б)
Рис.6. Значення F1-Score : а) кількість фільтрів – (64, 128, 256, 512); б) кількість фільтрів – (16, 32, 64, 128)




Рис.7. Значення Train/Validation loss : а) кількість фільтрів – (64, 128, 256, 512); б) кількість фільтрів – (16, 32, 64, 128)

Отримані результати з кожного експерименту наведено в таблиці 3.

Таблиця 3

Зведена таблиця результатів

Ядро згортки	Фільтри (по блоках)	Оптимізатор	Точність	F1-Score
2×2	32,64,128,256	Nadam	0.81	0.82
		RMSprop	0.74	0.75
		Adam	0.76	0.76
3×3	32,64,128,256	RMSprop	0.81	0.83
		Adamax	0.82	0.81
		Nadam	0.84	0.86
		Adam	0.84	0.83
		SGD	0.77	0.78
		Adagrad	0.56	0.54
5×5	16,32,64,128	Nadam	0.8	0.81
		RMSprop	0.77	0.76
		Adam	0.76	0.77
	32,64,128,256	Nadam	0.89	0.88
		RMSprop	0.84	0.85
		Adam	0.85	0.85
	64,128,256,512	Nadam	0.92	0.91
		RMSprop	0.9	0.9
		Adam	0.89	0.9

Висновки та перспективи подальших досліджень у даному напрямі

У роботі було розроблено та протестовано кілька архітектур конволюційних нейронних мереж (CNN) для задачі ідентифікації людей у пошуково-рятувальних операціях. Експерименти показали, що оптимізатор Nadam у поєднанні з ядром 5×5 та збільшеною кількістю фільтрів (64, 128, 256, 512) забезпечує найкращий результат, а саме Precision - 0.92 та F1-Score - 0.91, що перевищує базові конфігурації CNN, а саме F1-Score 0.83. Це підтверджує доцільність підбору гіперпараметрів під специфічні умови.

У дослідженні було систематично проаналізовано вплив трьох ключових параметрів - розміру ядра згортки, кількості фільтрів і вибору оптимізатора. Такий комплексний підхід дозволив показати, що: збільшення розміру ядра до 5×5 суттєво покращує якість виявлення людей у складних умовах; використання більшої кількості фільтрів підвищує робастність моделі; оптимізатор Nadam є найбільш придатним для досягнення стабільної збіжності.

Розроблена модель може бути інтегрована у системи з обмеженими обчислювальними ресурсами. Це дозволяє зменшити час реагування на надзвичайні ситуації та підвищити безпеку рятувальників завдяки автоматизації процесу виявлення людей.

Попри досягнуті результати, модель поступається новітнім архітектурам YOLOv8 та EfficientDET за абсолютними показниками точності. Крім того, дослідження базувалося на одному наборі даних, що може

обмежувати узагальненість висновків для інших типів SAR-сценаріїв.

Можливі напрямки подальших досліджень: інтеграція методів генеративного моделювання (GAN, diffusion models) для покращення якості даних у складних умовах; використання ансамблевих підходів для підвищення стійкості моделі; тестування моделі на реальних відеопотоках із дронів у різних погодних і світлових умовах.

Література

1. Mesvan N. CNN-based Human Detection for UAVs in Search and Rescue. 2021. [Електронний ресурс]. arXiv:2110.01930. DOI: 10.48550/arXiv.2110.01930.
2. Bany Abdelnabi A.A., Rabadi G. Human Detection From Unmanned Aerial Vehicles' Images for Search and Rescue Missions: A State-of-the-Art Review. IEEE Access. 2024. Vol. 12. P. 152009–152035. DOI: 10.1109/ACCESS.2024.3479988.
3. Object Detection and Classification in Human Rescue Operations: Deep Learning Strategies for Flooded Environments | IIETA. [Електронний ресурс]. Date accessed: 15, November 2024. Available from: <https://iieta.org/journals/ijss/paper/10.18280/ijss.140226>.
4. Tjia M., Kim A., Wijaya E.W., Tefara H., Zhu K. Enhancing Robustness of Human Detection Algorithms in Maritime SAR through Augmented Aerial Images to Simulate Weather Conditions. 2024, August. [Електронний ресурс]. arXiv:2408.13766. DOI: 10.48550/arXiv.2408.13766.
5. Detecting Humans in Search and Rescue Operations Based on Ensemble Learning. ResearchGate. 2024, October. DOI: 10.1109/ACCESS.2022.3156903.
6. Martinez-Esteso J.P., Castellanos F.J., Rosello A., Calvo-Zaragoza J., Gallego A.J. On the use of synthetic data for body detection in maritime search and rescue operations. Eng. Appl. Artif. Intell. 2025, Vol. 139. P. 109586. DOI: 10.1016/j.engappai.2024.109586.
7. Verner K. Human Detection Dataset. 2021, October 11. [Електронний ресурс]. Available from: <https://www.kaggle.com/datasets/constantinwerner/human-detection-dataset/data>

References

1. Mesvan N. CNN-based Human Detection for UAVs in Search and Rescue. 2021. [Elektronnyi resurs]. arXiv:2110.01930. DOI: 10.48550/arXiv.2110.01930.
2. Bany Abdelnabi A.A., Rabadi G. Human Detection From Unmanned Aerial Vehicles Images for Search and Rescue Missions: A State-of-the-Art Review. IEEE Access. 2024. Vol. 12. P. 152009–152035. DOI: 10.1109/ACCESS.2024.3479988.
3. Object Detection and Classification in Human Rescue Operations: Deep Learning Strategies for Flooded Environments | IIETA. [Elektronnyi resurs]. Date accessed: 15, November 2024. Available from: <https://iieta.org/journals/ijss/paper/10.18280/ijss.140226>.
4. Tjia M., Kim A., Wijaya E.W., Tefara H., Zhu K. Enhancing Robustness of Human Detection Algorithms in Maritime SAR through Augmented Aerial Images to Simulate Weather Conditions. 2024, August. [Elektronnyi resurs]. arXiv:2408.13766. DOI: 10.48550/arXiv.2408.13766.
5. Detecting Humans in Search and Rescue Operations Based on Ensemble Learning. ResearchGate. 2024, October. DOI: 10.1109/ACCESS.2022.3156903.
6. Martinez-Esteso J.P., Castellanos F.J., Rosello A., Calvo-Zaragoza J., Gallego A.J. On the use of synthetic data for body detection in maritime search and rescue operations. Eng. Appl. Artif. Intell. 2025, Vol. 139. P. 109586. DOI: 10.1016/j.engappai.2024.109586.
7. Verner K. Human Detection Dataset. 2021, October 11. [Elektronnyi resurs]. Available from: <https://www.kaggle.com/datasets/constantinwerner/human-detection-dataset/data>.