



С. І. Глод, А. В. Дорошенко

Національний університет "Львівська політехніка", м. Львів, Україна

ВИБІР ЕФЕКТИВНОЇ МОДЕЛІ ДЛЯ РОЗПІЗНАВАННЯ ВІЙСЬКОВИХ ОБ'ЄКТІВ У РЕЖИМІ РЕАЛЬНОГО ЧАСУ НА СПЕЦІАЛІЗОВАНИХ НАБОРАХ ДАНИХ

Розпізнавання об'єктів у режимі реального часу є ключовим елементом сучасного комп'ютерного зору, особливо в складних сценаріях їх отримання, таких як військові операції, де швидкість і точність виявлення цільових об'єктів є критично важливими для успішної навігації в динамічних і непередбачуваних умовах поля бою. У цьому дослідженні проаналізовано проблему виявлення та класифікації військових об'єктів у режимі реального часу. Навчено та налаштовано три моделі для виявлення військових об'єктів: Faster R-CNN (англ. *Region-based Convolutional Neural Networks*), SSD (англ. *Single Shot MultiBox Detector*) та YOLO (англ. *You Look Only Once*). Досліджено продуктивність двоетапних і одноетапних алгоритмів й оцінено придатність моделей для оперативного розгортання в динамічних середовищах. Розроблено спеціалізований набір даних, що містить різноманітні зображення бронетехніки (танків, бойових машин піхоти та бронетранспортерів) та адаптований набір для навчання, валідації та тестування моделей для виявлення військових об'єктів у реальних умовах. Оцінено продуктивність навчених моделей для виявлення військових об'єктів за ключовими показниками: точність, влучність, F1-міра, середня точність та частота кадрів. Застосовано платформу NVIDIA Jetson для тестування продуктивності моделей за умов обмежених обчислювальних ресурсів. Встановлено, що модель YOLOv8n є найефективнішою, досягнувши найвищих значень mAP (91,8 %) та FPS (55), що підтверджує її придатність для вирішення завдань розпізнавання зображень у режимі реального часу. Водночас, модель Faster R-CNN разом із залишковою нейронною мережею ResNet50 (англ. *Residual Neural Network*) забезпечила належну точність (mAP – 89,2 %, F1-Score – 89,4 %), однак її низька швидкість оброблення вхідних кадрів (FPS – 7) значно обмежує використання в оперативних сценаріях. Модель SSD разом з легкою згортовою нейронною мережею MobileNetV3 продемонструвала збалансовані результати (mAP – 81 %, F1-Score – 83,4 %, FPS – 36), пропонуючи компроміс між точністю та швидкістю, проте поступається за загальною ефективністю через випадки хибної класифікації або пропуску цільових об'єктів. Вказано на практичну значущість вибору та адаптації моделей відповідно до конкретних оперативних потреб, зокрема у військовій сфері. Отримані результати слугують основою для подальших досліджень, спрямованих на вдосконалення одноетапних алгоритмів розпізнавання військових об'єктів у режимі реального часу, розширення набору даних, удосконалення сучасних методів підвищення продуктивності периферійних пристроїв у складних і динамічних середовищах.

Ключові слова: виявлення військових об'єктів у режимі реального часу; периферійний пристрій; одноетапні детектори; двоетапні детектори; модель YOLO; модель SSD; модель Faster R-CNN; спеціалізований набір даних; платформа NVIDIA Jetson.

Вступ / Introduction

Виявлення цілей у системах розпізнавання військових об'єктів в реальному часі є однією з найважливіших проблем комп'ютерного зору та предметом досліджень у світовій науковій літературі. Однією з основних проблем є досягнення належної точності розпізнавання цільових об'єктів при збереженні низької затримки, особливо за умов наявності обмежених наданих ресурсів, вимагаючи балансу між швидкістю, точністю та обчислювальною ефективністю [3]. Традиційні двоетапні детектори, такі як Faster R-CNN, забезпечують належну точність, але часто потребують значних обчислювальних витрат, що робить їх менш придатними для застосування в реальному часі. На противагу цьому, одноступене-

ві моделі, такі як YOLO і SSD, надають перевагу швидкості оброблення вхідних даних, але в складних сценаріях можуть жертвувати точністю [18, 21]. Іншими проблемами є робота з різними розмірами об'єктів, розміттям при русі, мінливістю навколишнього середовища, а наявність високоякісних навчальних наборів даних з точними анотаціями мають вирішальне значення для моделей для виявлення військових об'єктів у режимі реального часу [6, 16]. Синтетична генерація даних, напівкероване навчання, активне навчання, мережі пірамід ознак, безопорне виявлення (англ. *Anchor-Free Detection*) є сучасними передовими методами для вирішення подібних проблем, проте проблеми з наборами даних, екстремально насиченими середовищами або несприятливими погодними умовами залишаються ключовими зав-

Інформація про авторів:

Глод Сергій Ігорович, аспірант, кафедра автоматизованих систем управління. Email: hlodserhiy@gmail.com;
<https://orcid.org/0009-0008-4252-0510>

Дорошенко Анастасія Володимирівна, канд. техн. наук, доцент, кафедра автоматизованих систем управління.
Email: anaastasiia.v.doroshenko@lpnu.ua; <https://orcid.org/0000-0002-7214-5108>

Цитування за ДСТУ: Глод С. І., Дорошенко А. В. Вибір ефективної моделі для розпізнавання військових об'єктів у режимі реального часу на спеціалізованих наборах даних. Науковий вісник НЛТУ України. 2025, т. 35, № 1. С. 137–148.

Citation APA: Hlod, S. I., & Doroshenko, A. V. (2025). Selection of an effective model for real-time military objects recognition on specialized datasets. *Scientific Bulletin of UNFU*, 35(1), 137–148. <https://doi.org/10.36930/40350117>

даннями для вирішення завдань з розпізнавання військових об'єктів у режимі реального часу.

У світовій науковій літературі розпізнавання військових об'єктів є також однією із основних проблем систем розпізнавання зображень у режимі реального часу. Сучасні дослідження демонструють різноманітні методології для підвищення ефективності виявлення військових об'єктів у військових сценаріях. Наприклад, модифікація карти ознак (англ. *Feature Map*) для виявлення малих об'єктів [16]; дослідження ієрархічного наведення ознак і вдосконалених методів локалізації для розпізнавання військових транспортних засобів за рахунок покращення вилучення ознак і точності [15] або дослідження з використанням БПЛА, оснащених радарми із синтезованою апертурою (SAR) для інтеграції передових моделей виявлення для класифікації об'єктів у повітряній розвідці [8]. Наявні дослідження переважно зосереджені на вдосконаленні сучасних алгоритмів для розпізнавання військових об'єктів, з обмеженою увагою до практичного розгортання та операційної експлуатації в реальних військових умовах.

Актуальність дослідження полягає у потребі розроблення ефективних алгоритмів виявлення військових об'єктів, здатних працювати в реальному часі у складних і динамічних умовах. Забезпечення належної точності та значної швидкості роботи таких моделей є критично важливим для оперативного прийняття рішень у військових сценаріях.

Незважаючи на значні успіхи в цій галузі, низка питань залишаються невирішеними, що вказує на актуальність цього дослідження. Існують проблеми із забезпеченням належної точності виявлення військових об'єктів при збереженні продуктивності в реальному часі, особливо на периферійних пристроях з обмеженими обчислювальними ресурсами. Для усунення цих прогалин потрібні моделі, які не тільки досягають належної точності та значної швидкості оброблення, але й ефективно працюють в обмежених умовах, роблячи процедуру виявлення військових об'єктів в реальному часі надійною та придатною для розгортання у критичних військових сценаріях. Запропонований у цій роботі підхід забезпечує вибір найефективнішої моделі для виявлення об'єктів у військових сценаріях у режимі реального часу [4]. Швидка і точна ідентифікація військових об'єктів має вирішальне значення як для оборонних, так і наступальних операцій. Здатність автоматично розпізнавати і класифікувати потенційно небезпечні об'єкти, такі як транспортні засоби, безпілотники, військову техніку, зброю або боєприпаси – може значно покращити процес прийняття рішень у режимі реального часу. Проте розпізнавання військових об'єктів в динамічних умовах пов'язане з унікальними викликами:

- 1) *Обмеження в режимі реального часу.* Військові операції вимагають миттєвого виявлення військових об'єктів і реагування на них. Значна швидкість виявлення військових об'єктів є ключовою вимогою для будь-якої розгорнутої системи.
- 2) *Різнноманітне та складне середовище.* Система повинна адаптуватися до динамічних і непередбачуваних умов бойових дій – від міських вулиць до сільської місцевості, враховуючи зміну освітлення, фізичні перешкоди та різну орієнтацію об'єктів.
- 3) *Баланс між точністю та швидкістю.* Хибні спрацювання або пропуск реальних загроз можуть мати катастрофічні наслідки. Адаптоване рішення повинно

поєднувати належну точність із можливістю роботи в реальному часі.

- 4) *Придатність алгоритмів.* Двоетапні алгоритми, як-от Faster R-CNN, забезпечують належну точність, але поступаются швидкістю. Одноетапні, такі як YOLO і SSD, працюють швидше, але можуть втрачати точність у складних сценах.

Основним напрямом дослідження є розроблення вдосконалених моделей для виявлення військових об'єктів, здатних працювати в реальному часі на відповідних периферійних пристроях. Особливу увагу приділяють балансу між точністю та швидкістю, що є однією з основних вимог для військових застосувань у динамічних і непередбачуваних умовах.

Об'єкт дослідження – розпізнавання військових об'єктів у режимі реального часу.

Предмет дослідження – методи, моделі та засоби розпізнавання об'єктів у режимі реального часу, застосованих у військових сценаріях, що дасть змогу оцінити продуктивність та потенціал розгортання одноетапних і двоетапних алгоритмів.

Мета роботи – проаналізувати та оцінити ефективність роботи сучасних моделей для розпізнавання військових об'єктів у режимі реального часу з використанням спеціалізованих наборів даних, що дасть можливість визначити підходи до їх розгортання, враховуючи обчислювальні обмеження, точність виявлення військових об'єктів і швидкість прийняття обґрунтованих рішень.

Для досягнення зазначеної мети визначено такі основні завдання дослідження:

- розробити спеціалізований користувацький набір даних, пристосований для військових застосувань, який враховуватиме різні класи військових об'єктів, таких як танки, БМП і БТР, захоплених у реальних умовах поля бою;
- вибрати репрезентативні варіанти одноетапних і двоетапних алгоритмів, виконати їхнє налагодження на власному наборі даних, що дасть змогу оцінити їхню ефективність за ключовими показниками;
- змодельовати процедуру розгортання моделей на периферійних пристроях, що дасть можливість оцінити їхню практичну застосовність до умов обмежених обчислювальних ресурсів;
- порівняти ефективність роботи моделей за різними показниками, що дасть змогу визначити найефективніший алгоритм для розпізнавання військових об'єктів у режимі реального часу;
- проаналізувати експлуатаційні виклики обраних моделей за різних умов навколишнього середовища для оцінювання їхньої адаптивності, стійкості до змінних факторів і ефективності роботи в умовах реального часу.

Аналіз останніх досліджень та публікацій. Сучасні алгоритми комп'ютерного зору здатні обробляти величезні обсяги візуальних даних зі значною швидкістю та точністю, що дає можливість комп'ютерним системам ефективно ідентифікувати й відстежувати об'єкти в різних умовах навколишнього середовища. Проте цей процес потребує значних обсягів даних і багаторазового аналізу візуальних шаблонів, просторових зв'язків і особливостей об'єктів для точного виявлення відмінностей і класифікації об'єктів. У контексті виявлення військових об'єктів це завдання охоплює визначення об'єктів на зображенні, їх точну локалізацію за допомогою обмежувальних рамок та класифікацію за відповідними категоріями, враховуючи виклики, пов'язані з масштабом, складністю сцени та умовами навколишнього середовища. Вирішення цих проблем потре-

бує удосконалення як алгоритмів, так і адаптації наборів даних, що дасть змогу підвищити точність і надійність виявлення військових об'єктів у динамічних умовах поля бою.

Наприклад, у роботі [15] запропоновано систему виявлення військових об'єктів, яка використовує ієрархічне вилучення ознак та вдосконалені методи локалізації. Інтеграція різномасштабної контекстної інформації дає можливість покращити наведення ознак, підвищуючи точність ідентифікації військової техніки в різних умовах. На відміну від стандартних моделей, цей підхід зменшує кількість хибних спрацьовувань і пропущених цільових об'єктів, покращуючи точність локалізації. Однак дослідження не враховує обмеження роботи в реальному часі, що ускладнює його практичну реалізацію на пристроях із обмеженими обчислювальними ресурсами. Водночас, дослідження [21] зосереджене на покращенні вилучення ознак для розпізнавання військових об'єктів у складних умовах, зокрема при їхньому частковому накладанні та наявності фонового шуму, що є поширеними викликами у військових застосуваннях. Запропонований підхід підвищує надійність виявлення військових об'єктів там, де традиційні моделі мають обмежену ефективність. Хоча дослідження демонструє належні показники частоти кадрів (англ. *Frames per Second, FPS*), вони були досягнуті на високопродуктивному графічному процесорі, що порушує питання щодо його придатності для роботи в реальному часі на периферійних пристроях.

Робота [16] розширює дискусію про виявлення об'єктів у режимі реального часу в складних умовах їхнього перебування. Автори вдосконалили архітектуру моделі YOLOv5 за допомогою різних модифікацій, таких як доповнення даних, специфічних для розмитих або прихованих об'єктів і вдосконалення опорних рамок для підвищення ефективності виявлення невеликих об'єктів у завданнях повітряного спостереження. Автори перевірили свій підхід на власному наборі даних, спеціально розробленому для виявлення військових об'єктів. Хоча результати демонструють істотне підвищення точності, дослідження зосереджене переважно на вдосконаленні моделі, без урахування обмежень розгортання на периферійних пристроях. Окрім цього, використання штучно змодельованого набору даних створює потенційні обмеження для реального застосування, оскільки подібні дані не враховують реальних непередбачуваних чинників, які виникають під час завдань із розпізнавання військових об'єктів у режимі реального часу. Це дослідження зробило значний внесок у сферу розпізнавання військових об'єктів, оскільки висвітлює ключові виклики, характерні для подібних завдань. Водночас, запропонованому підходу бракує тестування на реальних даних і оцінювання продуктивності при розгортанні на периферійних пристроях, що є критично важливим для його практичного застосування.

У роботі [9] наведено підхід до виявлення об'єктів у морському середовищі з використанням мереж 6G для передачі даних у режимі реального часу. Запропонований підхід на підставі алгоритму SSD разом з легкою згортовою нейронною мережею MobileNetV3 було удосконалено для периферійних обчислень, однак не було повідомлено конкретної тестової платформи. Отримані результати справді демонструють ефективність у контрольованих умовах, але потрібно відзначити об-

меження такого підходу у роботі зі складнішими сценаріями, де показник точності може знижуватися, а кількість хибних або пропущених спрацювань може збільшуватися. Попри цінність отриманих результатів, які дають зрозуміти процес розгортання подібних моделей на периферійних пристроях, дослідження сфокусовано на морських умовах, що відрізняються від військових сценаріїв. Окрім цього, проблеми SSD-моделей з виявленням малих або частково прихованих об'єктів [2] вказують на потребу альтернативних рішень, які можуть забезпечити кращу ефективність розпізнавання військових об'єктів разом з кращою продуктивністю у режимі реального часу.

У роботі [22] наведено комплексний підхід до інтеграції виявлення об'єктів у військові системи прийняття рішень. Автори розробили модель, яка використовує передові методи аналізу зображень для класифікації та ідентифікації широкого спектра військових об'єктів, спираючись на набір даних із численними класами. Підхід спрямований на покращення ситуаційної обізнаності шляхом автоматизованого виявлення військових об'єктів на полі бою, що сприяє ефективнішому прийняттю рішень на підставі даних. Попри належну точність класифікації об'єктів, дослідження не оцінює продуктивність роботи YOLOv5-моделі в реальному часі на периферійних пристроях, що є критичним фактором для практичного розгортання в динамічних умовах. Реалізація процедури виявлення військових об'єктів у режимі реального часу потребує ефективних обчислювальних рішень, здатних працювати за умов наявності обмежених наданих ресурсів. Хоча дослідження висвітлює досягнення в алгоритмах виявлення військових об'єктів, їхня практична застосовність у реальних умовах залишається невизначеною без відповідного тестування на реальних даних. Це свідчить про розрив між теоретичними результатами та операційною доцільністю, що залишається ключовим викликом для військових застосувань III.

Проведений аналіз досліджень вказує на актуальність виявлення військових об'єктів у режимі реального часу для військових застосувань. Проаналізовані роботи охоплюють ключові виклики, зокрема складність наборів даних, варіативність умов навколишнього середовища та адаптивність моделей. Хоча кожен підхід удосконалює традиційні методи, більшість досліджень зосереджені на статичному розпізнаванні зображень, без належного врахування процедури їхнього оброблення в реальному часі. Окрім цього, значним обмеженням є відсутність процедури тестування моделей на периферійних пристроях, що має вирішальне значення для практичного розгортання в операційних сценаріях. Це дослідження заповнює зазначену прогалину, оцінюючи моделі виявлення військових об'єктів не тільки за належною точністю, а й за її продуктивністю в реальному часі на пристроях з обмеженими обчислювальними ресурсами. Отримані результати підтверджують потребу проведення подальшого дослідження для розроблення ефективних і адаптивних моделей, придатних для їх розгортання у складному й динамічному військовому середовищі.

Матеріали та методи дослідження. Для досягнення поставлених цілей у дослідженні використано кілька ключових методів, інструментів і архітектур глибокого навчання моделей. Було навчено та оцінено три моделі виявлення військових об'єктів, зокрема:

- 1) Faster R-CNN з ResNet50-FPNv2 – представник двоетапних алгоритмів розпізнавання об'єктів, який працює у два етапи: спочатку генерує регіони пропозицій, а потім класифікує та уточнює їх координати.
- 2) SSD з MobileNetV3 – представник одноетапних алгоритмів розпізнавання об'єктів, який за допомогою багаторівневих карт ознак та попередньо визначених обмежувальних рамок виконує передбачення координат і класів об'єктів за один прохід через мережу розпізнавання.
- 3) YOLOv8n – найшвидший представник одноетапних алгоритмів розпізнавання об'єктів сімейства YOLOv8, який одночасно передбачає координати об'єктів та визначає приналежність об'єктів до відповідного класу завдяки архітектурі вихідного рівня, який поділяє завдання класифікації та регресії, при цьому збільшуючи швидкість роботи алгоритму.

Для їхнього навчання та тестування використано спеціалізований набір даних, розроблений із використанням різноманітних військових об'єктів у динамічних умовах навколишнього середовища їхнього перебування/функціонування. Набір даних піддавався попередньому обробленню та анотації для забезпечення отримання високоякісних вхідних даних для моделей під час розпізнавання військових об'єктів. Оцінювання продуктивності моделей здійснювалося на платформі NVIDIA Jetson, що дало змогу імітувати їхнє розгортання на периферійних пристроях з обмеженими обчислювальними ресурсами. Для вимірювання точності виявлення військових об'єктів і обчислювальної ефективності навчених моделей використано такі ключові метрики їхнього оцінювання, як точність (англ. *Precision*), влучність (англ. *Recall*), F1-міра (англ. *F1-Score*), середня точність (англ. *Mean Average Precision, mAP*) та кількість кадрів за секунду (FPS). Такий послідовний підхід дає змогу всебічно оцінити придатність кожної моделі для вирішення завдань розпізнавання військових об'єктів у режимі реального часу.

Результати дослідження та їх обговорення / Research results and their discussion

Підготовка спеціалізованого набору даних. Розроблений набір даних призначений для навчання моделей, здатних ідентифікувати ключові загрози на сучасних полях бою, таких як танки, БМП (бойова машина піхоти) і БТР (бронетранспортер). Для врахування реалій бойових умов, враховуючи змінне освітлення, різноманітну орієнтацію об'єктів і їхнє масштабування, до набору даних внесено різноманітні та високоякісні зображення з різних джерел. Такий підхід забезпечує адаптацію моделей до динамічного середовища, підвищуючи їхню ефективність у підтримці прийняття рішень у критичних ситуаціях, де кожна секунда має вирішальне значення. Для створення унікального набору даних використано структурований підхід (рис. 1), що враховує специфіку поставленого завдання та реальні умови його використання, зокрема [11]:

- 1) *Варіативність середовища.* Набір даних містить зображення військових об'єктів, отриманих у різних погодних умовах (туман, дощ, сонячне світло) та за різного рівня освітлення (день, ніч, сутінки).
- 2) *Різні кути огляду та різноманітність розмірів об'єктів.* Дані містять військові об'єкти, зняті з різних ракурсів і об'єкти різних розмірів, що забезпечить стійкість моделей до зміни масштабу.
- 3) *Наявність перешкод.* Об'єкти можуть бути частково приховані іншими елементами сцени (рослинність,

складність місцевості, задимлення), що імітує реальні бойові умови.

- 4) *Реалістичне подання класів.* Набір даних враховує співвідношення військових об'єктів у реальному середовищі, зокрема присутність військової техніки серед природного чи міського ландшафтів, наземне чи повітряне подання об'єктів.



Рис. 1. Блок-схема розроблення набору даних для виявлення військових об'єктів / Flowchart of creating a dataset for detecting military objects

На етапі попереднього оброблення даних всі зображення було змінено до стандартної роздільної здатності 1280×720 пікселів, що дало змогу зберегти їхню якість та оригінальне співвідношення сторін. Наступним ключовим етапом підготовки набору даних стало маркування. Набір даних класифіковано на три основні категорії: танк, БМП і БТР, що відповідають основним типам бронетехніки, досліджуваним у межах цієї роботи. Після маркування вибірку було поділено на три підмножини: 70 % для навчання, 20 % для валідації та 10 % для тестування. Усі три класи були рівномірно розподілені між підмножинами, щоб забезпечити збалансованість і достовірність моделі під час навчання та її оцінювання.

Для підвищення варіативності набору даних і покращення узагальнення моделей застосовано методи аугментації за допомогою фреймворку Albumentations. Нагадаємо, аугментація – це процедура, яку проводять для підвищення об'єму або розміру вхідного набору даних. Було використано вертикальне перевертання для моделювання різних точок зору, випадкові повороти у діапазоні 45°-90° для адаптації до змінних ракурсів, а також регулювання яскравості та контрастності з ймовірністю 50 %, що імітує різні умови освітлення. Такі перетворення (трансформації) розширили набір даних, покращивши здатність моделі адаптуватися до невідомих сценаріїв. Ретельне попереднє оброблення забезпечило ефективне навчання, що зробило модель придат-

ною для застосування в реальному часі у складних експлуатаційних умовах. Розроблений набір даних (рис. 2) містить близько 7700 зображень, що забезпечує різ-



Рис. 2. Візуалізація маркованих зразків із набору даних, враховуючи приклади кожного класу / Visualization of labeled samples from the dataset, including examples of each class

Для акцентування уваги на тому, що зображення із набору даних здебільшого містять малі об'єкти, що ускладнює завдання розпізнавання військових об'єктів, але водночас точно відтворює реальні умови середовища, було здійснено розподіл розмірів об'єктів для трьох основних класів за п'ятьма категоріями (рис. 3). Ці категорії наведено у вигляді частки співвідношення площі об'єкта до загальної площі зображення: 0-1 %, 1-3 %, 3-6 %, 6-9 % та 9-100 %. На рис. 3 вісь у вказує на відношення об'єктів до загальної кількості об'єктів у всіх класах.




Рис. 3. Розподіл об'єктів за їхнім розміром / Distribution of objects according to size

На рис. 3 показано, що значна частина об'єктів перебувають у діапазоні розмірів 0-1 %, що свідчить про присутність малих і віддалених об'єктів у наборі даних. Це вказує на важливість використання алгоритму, здатного ефективно розпізнавати дрібні об'єкти, що є особливо складним завданням у реальних умовах. Різноманітний розподіл розмірів об'єктів у наборі даних забезпечує для моделей можливість працювати з цілями різного масштабу та розташування, що сприяє її здатності адаптуватися до широкого спектра реальних сценаріїв. Наявність менших об'єктів акцентує потребу модифікації алгоритмів для виявлення дрібних, малопо-

номанітну колекцію сцен і варіацій середовища знаходження військових об'єктів для ефективного навчання, валідації та тестування моделей.

мітних цілей, тоді як більші об'єкти підвищують надійність розпізнавання ближчих і більш помітних цілей.

Процес навчання моделей. Навчання моделей проводилося з використанням графічного процесора GeForce RTX 3060 Ti в парі з процесором AMD Ryzen 7 7700X і MacBook з чіпом M3 Pro для виконання додаткових завдань і адаптації моделей. Тестування проводилося на NVIDIA Jetson Orin Nano для перевірки розгортання моделей у реальних сценаріях, що дало змогу оцінити їхню продуктивність за умов наявності обмежених обчислювальних ресурсів і реальних експлуатаційних вимог.

Характеристика моделі Faster R-CNN-ResNet50-FPNv2. Для цього дослідження було обрано основну мережу (англ. *Backbone Network*) ResNet50, інтегровану з мережею пірамід ознак (FPNv2). Основна мережа ResNet50 забезпечує ефективне вилучення ознак завдяки своїй глибині та міжшаровим зв'язкам, що робить її збалансованим вибором для вирішення завдань із розпізнавання військових об'єктів [7]. Водночас, мережа пірамід ознак FPNv2 покращує здатність мережі розпізнавати об'єкти різного масштабу, використовуючи карти ознак, отримані на різних рівнях основної мережі [2, 14].

Початковий етап навчання моделі Faster R-CNN містив застосування попередньо навчених ваг, отриманих із моделі, навченої на наборі даних COCO. Для досягнення оптимальної продуктивності при роботі з трьома класами об'єктів були ретельно налаштовані гіперпараметри, такі як розмір партії, швидкість навчання, порогові значення для пропозицій регіонів тощо. Ці налаштування були ретельно підібрані з урахуванням різноманітності розмірів об'єктів і варіативності сцен у наборі даних, забезпечуючи надійність та адаптивність моделі до різних умов.

Результати навчання моделі Faster R-CNN продемонстрували значний рівень продуктивності, ефективно засвоюючи користувацький набір даних і зберігаючи при

цьому здатність до узагальнення на небачених даних. Модель досягла мінімальної втрати під час навчання у 0,2551 та втрати при валідації у 0,4423 (рис. 4, а). Зменшення втрат при навчанні свідчить про належну здатність моделі адаптуватися до набору даних, тоді як зниження втрат при валідації демонструє її ефективність у роботі з новими прикладами. Аналогічно, криві точності на рис. 4, б ілюструють стійке покращення, досягаючи пікових значень точності у 93,7 % для навчання та 90,7 % для валідації. Постійне вирівнювання кри-




Рис. 4. Оцінювання процесів навчання та валідації моделі Faster R-CNN / Evaluation of training and validation processes of the Faster R-CNN model: (a) втрати від навчання та валідації впродовж ітерацій / training and validation loss over epochs; (b) точність навчання та валідації впродовж ітерацій / training and validation accuracy over epochs



Рис. 5. Результат тестування навченої моделі Faster R-CNN / Trained Faster R-CNN model testing output


Ці результати підтверджують ефективність Faster R-CNN з ResNet50 і FPNv2, демонструючи її надійність і придатність для завдань виявлення військових об'єктів на зображеннях зі складними і динамічними середовищами.

Характеристика моделі SSD-MobileNetV3. Для цього дослідження було обрано основну мережу MobileNetV3 [2] через її компактну конструкцію та придатність для роботи в реальному часі, особливо на периферійних пристроях. Ця модель містить вдосконалення, такі як hardswish-активація та оптимізована архітектура, що забезпечують підвищену точність за збереження низьких обчислювальних витрат. Завдяки цим характеристикам MobileNetV3 є ідеальним вибором для сценаріїв, де потрібне швидке й ефективне виявлення військових об'єктів із належною продуктивністю [10, 12].

Навчання розпочалося з ретельного налаштування гіперпараметрів для підвищення продуктивності моделі. Процес містив 100 ітерацій навчання з використанням оптимізатора AdamW за швидкості навчання 0,001. Планувальник ReduceLROnPlateau динамічно регулював швидкість навчання для досягнення стабільного та ефективного процесу навчання. Окрім цього, для врахування різних розмірів об'єктів у наборі даних було застосовано поріг NMS у 0,5 та масштабовані розміри опорних рамок, що забезпечило надійне виявлення вій-

ськових об'єктів і стабільну продуктивність у різноманітних умовах.

Результати тестування моделі (рис. 5) демонструють її здатність точно виявляти і локалізувати об'єкти в складних сценах. Обмежувальні рамки з відповідними оцінками достовірності вказують на успішну ідентифікацію танків (синій колір), бойових машин (зелений) і бронетранспортерів (червоний) у різних сценаріях, враховуючи повітряні і наземні наведення, різний рельєф і складні умови, такі як задимленість і перешкоди.



ськових об'єктів і стабільну продуктивність у різноманітних умовах.

Продуктивність моделі SSD, як показано на рис. 6,, свідчить про те, що модель потребує подальшого їх вдосконалення. Точність навчання у 89 % і точність валідації у 81 % демонструють помітну межу між навчальним та валідаційним наборами даних, що свідчить про те, що модель бореться із узагальненням небачених даних (див. рис. 6,а). Це також підтверджується навчальними втратами у 0,3559 та валідаційними втратами у 0,5935, де вищі показники валідації вказують на проблеми, пов'язані зі складністю набору даних. Криві втрат на рис. 6,б показують, що показники втрат при валідації знижуються повільніше і демонструють коливання на пізніх етапах навчання, що може вказувати на труднощі з адаптацією моделі до набору даних для валідації. Ці труднощі, ймовірно, зумовлені складністю та різноманітністю даних у валідаційному наборі або обмеженнями основної мережі MobileNetV3 у вилученні ознак для складних сценаріїв.

Як показано на рис. 7, модель SSD демонструє як свої сильні сторони, так і обмеження: вона успішно ідентифікує деякі об'єкти, проте стикається з труднощами у складніших сценаріях їх отримання. Модель змогла точно виявити декілька об'єктів із помірним рівнем достовірності, але пропустила менші об'єкти або ті, що пе-

ребувають у складних умовах, що вказує на проблеми з узагальненням і вилученням ознак. Покращення архітектури, наприклад, додавання додаткових функціона-

льних шарів і модифікації конфігурації опорних рамок, може підвищити здатність моделі ефективно працювати на різних масштабах.




Рис. 6. Оцінювання процесів навчання та валідації моделі SSD-MobileNetV3 / Evaluation of training and validation processes of the SSD model: (a) втрати від навчання та валідації впродовж ітерацій / training and validation accuracy over epochs; (b) точність навчання та валідації впродовж ітерацій / training and validation loss over epochs



Рис. 7. Результат тестування навченої моделі SSD-MobileNetV3 / Trained SSD-MobileNetV3 model testing output

У своїй поточній конфігурації навчена модель SSD демонструє значний потенціал для роботи в режимі реального часу, однак має певні обмеження під час оброблення складних і різноманітних даних. Для досягнення оптимальної продуктивності, особливо при розгортанні на периферійних пристроях, модель потребує подальшого удосконалення, зокрема вдосконалення її архітектури та адаптації до широкого спектра використовуваних сценаріїв.

Характеристика моделі YOLOv8n. Базова архітектура моделі YOLOv8 [20] містить три основні компоненти: основну мережу, проміжний рівень (англ. *Neck*) та вихідний рівень (англ. *Head*), кожен з яких спрямований на підвищення ефективності виявлення військових об'єктів. Модель YOLOv8 використовує основну мережу CSPDarknet53 з модулем C2 f, яка оптимізує градієнтний потік і покращує процес навчання, забезпечуючи надійне розпізнавання об'єктів різного розміру. Для кращого розуміння структури та обчислювального потоку навченої моделі YOLOv8n за допомогою інструментарію *TensorBoard* було згенеровано графічне подання її архітектури (рис. 8). Ця візуалізація вказує на ієрархічну організацію згорткових шарів, механізмів злиття ознак і головного механізму виявлення військових об'єктів, демонструючи, як модель обробляє вхідні дані за допомогою послідовних перетворень.

Окрім компонент архітектури, важливими нововведеннями є голова виявлення військових об'єктів без прив'язки до опорних точок (англ. *Anchor-Free Detection*

Head), яка усуває залежність від попередньо визначених опорних рамок та архітектура розділеного вихідного рівня (англ. *Decoupled Head*), що поділяє завдання класифікації та регресії для зменшення помилок прогнозування та покращення загальної продуктивності [20].

Модель YOLOv8n, як найлегша і найшвидша у серії YOLOv8, забезпечує значну ефективність при компактному розмірі – близько 2 МБ у форматі INT8 та 3,8 МБ у форматі FP32. Завдяки оптимізованим згортковим шарам і зменшеній кількості параметрів, ця модель є чудовим вибором для розгортання на периферійних пристроях у середовищах, де критично важливі енергоефективність і швидкість дії.

Процес навчання моделі YOLOv8n був адаптований для підвищення її точності, функції втрат та обчислювальної ефективності для виявлення військових об'єктів у режимі реального часу. Модель навчалася протягом 100 ітерацій, оптимізуючи точність виявлення військових об'єктів шляхом мінімізації помилок у локалізації, класифікації та оцінюванні достовірності. Функція втрат моделі YOLOv8 збалансовує ці особливості, забезпечуючи точне та ефективне навчання. Загальні втрати L_{total} визначають як суму трьох ключових компонент [20]:

$$L_{total} = \lambda_{box} \cdot L_{box} + \lambda_{cls} \cdot L_{cls} + \lambda_{dfl} \cdot L_{dfl}, \quad (1)$$

де: L_{box} – втрата регресії обмежувальної рамки; L_{cls} – втрата класифікації; L_{dfl} – розподільна фокусна втрата, яка прийшла на зміну втраті достовірності з попередніх моделей YOLO; λ_{box} , λ_{cls} , λ_{dfl} – гіперпараметри для балансування кожного компонента втрат.




Рис. 8. Графічне подання архітектури навченої моделі YOLOv8n / Graphical representation of the architecture of the trained YOLOv8n model

Втрата регресії відповідає за уточнення локалізації об'єкта, мінімізуючи похибку між прогнозованими та істинними координатами. Втрата класифікації відповідає за точні прогнози міток класифікації. Її обчислюють за допомогою бінарної перехресної ентропії (*BCE*), яка оцінює різницю між прогнозованою та фактичною ймовірністю класу. Розподільна фокусна втрата (англ. *Distribution Focal Loss, DFL*) покращує точність локалізації за рахунок вдосконалення прогнозів обмежувальної області. Розподільна фокусна втрата замінила втрату достовірності, а завдяки точній регресії обмежувальної області удосконалює точність локалізації, особливо для невеликих об'єктів [20].

Під час навчання модель ітеративно уточнює цю функцію втрат для підвищення власної продуктивності. Функція втрат забезпечує баланс між точністю та ефективністю, що робить модель добре придатною для застосування в реальному часі в динамічних середовищах.

Отримані результати навчання та валідації моделі YOLOv8n подано у вигляді графіків на рис. 9. Наведені метрики оцінювання свідчать про стабільне покращення продуктивності моделі протягом навчання. Втрати під час навчання плавно зменшуються, що підтверджує ефективність навчального процесу. Втрати під час валідації також знижуються, хоч і повільніше, демонструючи здатність моделі узагальнювати нові дані.




Рис. 9. Результати оцінювання процесів навчання та валідації навченої моделі YOLOv8n (вісь x – кількість ітерацій, вісь y – відповідні значення втрат та точності) / Graphs for evaluation of training and validation of the trained YOLOv8n model (the x-axis represents the number of epochs, while the y-axis denotes the respective values for loss and accuracy)

Показники точності та влучності стабільно зростають, підтверджуючи підвищення якості розпізнавання та класифікації об'єктів. Показник $mAP@50$ досягає високих значень, що свідчить про ефективне розпізнавання військових об'єктів, тоді як показник $mAP@50-95$ демонструє здатність моделі точно локалізувати об'єкти різного розміру. Отримані результати підтверджують надійність моделі YOLOv8n у роботі із запропонованим набором даних, проте для подальшого вдосконалення моделі необхідно збільшити кількість ітерацій навчання та застосувати модифікації, спрямовані на вдосконалення архітектури обраної моделі, що дасть змогу ще більше підвищити продуктивність моделі.

Матриця невідповідностей, наведена на рис. 10, демонструє ефективність роботи моделі YOLOv8n у чотирьох категоріях: БМП, БТР, танк і фон. Модель успішно розпізнає БТР, зафіксувавши 225 правильних прогнозів з мінімальною кількістю помилкових класифікацій. Хоча БМП і танки також досягли належних показників точності, спостерігалися випадки помилкової класифікації, особливо для фонових об'єктів.

Візуалізовані результати на рис. 11 ілюструють можливості моделі YOLOv8n у виявленні та класифікації об'єктів у різноманітних складних умовах. Модель успішно ідентифікує танки, БМП і БТР із достовірністю понад 80 % у більшості випадків, демонструючи свою здатність адаптуватися до варіацій розміру, орієнтації та складності фону об'єктів.

	БМП	БТР	Танк	Фон
БМП	190	5	3	11
БТР	1	225	1	18
Танк	7		194	10
Фон	13	27	33	
	БМП	БТР	Танк	Фон

Рис. 10. Матриця невідповідностей навченої моделі YOLOv8n / Confusion Matrix of trained YOLOv8n model

Однак, окремі кадри демонструють помилкові виявлення військових об'єктів, наприклад, будівля була помилково ідентифікована як танк із достовірністю близько 41 %, що вказує на періодичні труднощі роботи моделі в складних умовах, таких як задимленість або низька видимість. Незважаючи на ці недоліки, результати роботи моделі вказують на її придатність для виявлення військових об'єктів у режимі реального часу в динамічному середовищі.



Рис. 11. Результат тестування навченої моделі YOLOv8n / Trained YOLOv8n model testing output

Результати тестування. Тестування та перевірка моделей проводилися на платформі NVIDIA Jetson Orin Nano, що забезпечило можливість оцінювання їхньої сумісності та ефективності для сценаріїв розгортання в реальному часі.

Під час реалізації спостережень в межах проведеного експерименту було навчено моделі розпізнавання військових об'єктів, що використовували комплексний набір метрик, які охоплюють ключові особливості забезпечення продуктивності моделей. Точність роботи моделі вказує на частку правильно ідентифікованих об'єктів серед усіх прогнозів, а влучність – оцінює здатність моделі виявляти всі релевантні об'єкти в наборі даних. F1-міра об'єднує точність і влучність у єдине значення, забезпечуючи збалансоване оцінювання ефективності. Середня точність агрегує точність для всіх категорій об'єктів, відображаючи загальну ефективність роботи моделі. Кількість кадрів на секунду

визначає швидкість виведення результатів розпізнавання військових об'єктів внаслідок опрацювання вхідних кадрів, що є критично важливим параметром для застосування моделі в реальному часі. Разом ці метрики дають змогу провести детальний аналіз продуктивності моделей, порівнюючи їхню ефективність роботи та придатність для різних умов експлуатації.

Таблиця. Порівняльна характеристика навчених моделей для завдань розпізнавання військових об'єктів у режимі реального часу / Comparison of the trained object recognition models for real-time tasks

Назва моделі із використанням військового набору даних	Precision, %	Recall, %	F-1 Score, %	mAP, %	FPS
Faster R-CNN ResNet50-FPNv2	88,7	90,1	89,4	89,2	7
SSD-MobileNetV3	83,5	82,6	83,4	81,0	36
YOLOv8n	91,4	84,8	87,97	91,8	55

Порівняльні результати моделей наведено в таблиці, яка наочно демонструє їхню ефективність за ключовими показниками. Модель Faster R-CNN досягла значень показників mAP – 89,2 % та F1-Score – 89,4 %, що свідчить про належну точність і влучність моделі. Однак її продуктивність значно обмежує низький FPS – 7, що ускладнює використання в реальних сценаріях. Незважаючи на точність виявлення об'єктів на різних зображеннях, модель не задовольняє вимоги застосунків у режимі реального часу через повільну швидкість оброблення вхідних кадрів. Модель SSD-MobileNetV3 показала збалансовані результати mAP – 81 %, F1-Score – 83,4 % та FPS – 36. Ця модель забезпечує гарний компроміс між точністю та швидкістю, проте поступається у загальній точності виявлення військових об'єктів порівняно з іншими моделями. Це проявляється у випадках хибної класифікації або пропуску об'єктів, особливо за складних умов. Найкращі результати продемонструвала модель YOLOv8n, яка досягла найвищих показників точності, mAP – 91,8 % та FPS – 55. Швидкість обчислень і точність отриманих результатів роблять цю модель найбільш придатною для її застосування в реальному часі, особливо за умов наявності обмежених наданих ресурсів, таких як сучасні поля бою, військові місії або розвідка за допомогою БПЛА.

Отже, проведено детальне оцінювання алгоритмів розпізнавання об'єктів для військових застосувань із зосередженням уваги на їхню продуктивність у режимі реального часу. Отримані результати висвітлюють можливість та обмеження моделей Faster R-CNN з ResNet50-FPNv2, SSD-MobileNetV3 та YOLOv8n (див. таблицю) під час оброблення складних наборів даних, надаючи важливу інформацію щодо їхньої придатності та надійності в динамічних умовах.

Дослідження підтверджує ефективність роботи моделі YOLOv8n, яка перевершує інші моделі за показниками точності, mAP та FPS, демонструючи унікальну здатність збалансувати швидкість обчислень і точність отриманих результатів у специфічних військових сценаріях. На відміну від попередніх робіт, орієнтованих на набори даних загального призначення, наше дослідження використовує спеціалізований набір даних, що відображає реальні умови поля бою. Це дає можливість запропонувати новий внесок у галузь, оцінюючи алгоритми в більш специфічному та практично орієнтованому контексті.

Перспективи подальших досліджень передбачають розширення набору даних для внесення нових класів об'єктів і різноманітних умов, а також інтеграцію передових методів аугментації даних для підвищення продуктивності у складних сценаріях їх отримання, таких як туман, розмитість або тепловізійні зображення. З появою моделей наступної модифікації, таких як YOLOv10 і YOLOv11, відкриваються нові можливості для вдосконалення точності розпізнавання військових об'єктів та адаптації до складних умов. Центральним напрямом цих зусиль стане дослідження більш ефективних архітектур, що забезпечить подальше підвищення продуктивності моделей. Наступним кроком буде впровадження цих удосконалень для покращення здатності моделі працювати в динамічних і вимогливих середовищах.

Обговорення результатів дослідження. Дослідження [11] вивчає виявлення танків на розвідувальних

знімках БПЛА з використанням покращеної моделі YOLOv5 та спеціалізованого набору даних – UAVT-3. Хоча їхня робота зосереджувалась на вдосконаленні доповнення даних, специфічних для розмиття та модифікації конфігурації опорних рамок, наше дослідження ставить акцент на розгортанні моделей у реальних сценаріях. Ми зосереджуємо увагу на оцінюванні їхньої продуктивності на периферійних пристроях, таких як NVIDIA Jetson Orin Nano, для середовищ з обмеженими обчислювальними ресурсами.

У роботі [16] наведено застосування модифікованої моделі YOLOv5 для виявлення об'єктів у режимі реального часу, зосереджуючись на ідентифікації загроз, пов'язаних із солдатами та зброєю. Дослідження демонструє значні покращення у виявленні та класифікації демаскованих загроз, спрямовані на зменшення людської помилки у завданнях розпізнавання потенційних загроз. Порівняно з нашим підходом, це дослідження сфокусовано на об'єктах, пов'язаних з піхотою, тоді як наше дослідження розглядає ширший спектр військових транспортних засобів в умовах поля бою.

Дослідження [1] демонструє застосування методів виявлення об'єктів у режимі реального часу для точної ідентифікації військових танків. Використовуючи вдосконалену модель YOLOv5, дослідження досягає належної точності та достовірності розпізнавання військових об'єктів, проте наше дослідження розширює перелік потенційних об'єктів, пропонуючи спеціалізований набір даних і безпосереднє його тестування на периферійних пристроях.

Робота [17] вказує на вебзастосунок з інтеграцією глибинної моделі SOTA та алгоритму YOLOv8, розроблений для військового повітряного спостереження. Система призначена для покращення ідентифікації об'єктів і моніторингу на аерофотознімках, що справді є цінним інструментом для розвідувальних місій у режимі реального часу. Водночас, результати виявлення військових об'єктів перебувають на помірному рівні, що може свідчити про складність набору даних або недоопрацювання можливостей розробленої моделі розпізнавання військових об'єктів.

У дослідженні [5] описують архітектуру багаторівневих капсульних мереж для розпізнавання військових об'єктів на невеликих наборах даних. Автори використовують 10-рівневе перехресне затвердження (англ. *10-fold cross validation*), що сприяло значному покращенню результатів порівняно з іншими протестованими моделями. Однак ефективність цього підходу щодо використання сучасних алгоритмів виявлення військових об'єктів, а також його практична придатність для реального розгортання залишаються невизначеними, що ставить під сумнів доцільність використання капсульних мереж у цьому контексті.

У роботі [13] запропоновано вбудовану систему з використанням динамічних давачів зору для виявлення швидкісних безпілотників. Такий підхід забезпечує висновки в реальному часі за низького енергоспоживання, що вказує на його потенціал для військових застосувань. На відміну від нашої роботи, яка зосереджена на військових наземних транспортних засобах, це дослідження розглядає повітряні загрози, використовуючи для їхнього виявлення інший тип сенсорних технологій. Використання сенсорів і різних способів візуалізації, таких як тепловізійні давачі і давачі динаміч-

ного зору, відіграє вирішальну роль у виявленні військових об'єктів, покращуючи видимість в умовах низької освітленості та в несприятливих умовах. Проте більш повне наведення їхньої системи розпізнавання об'єктів дало б уявлення про застосовність і відтворюваність результатів дослідження.

Ключові відмінності нашого дослідження вказують на практичний підхід, що забезпечує оперативне застосування розглянутих моделей для розпізнавання військових об'єктів у режимі реального часу та динамічних умовах ведення бою. Комплексне оцінювання результатів нашого дослідження дає уявлення про компроміси між точністю отриманих результатів і обчислювальною ефективністю використовуваних моделей, сприяючи удосконаленню моделей виявлення об'єктів для розгортання за умов наявності обмежених наданих ресурсів у військовому середовищі. Також наш підхід можна вдосконалити додаванням більшої кількості необроблених зображень, використанням розширених метрик оцінки, таких як енергоефективність, а також тестуванням на ширшому спектрі периферійних пристроїв. Це дало змогу б знайти економічно ефективніші рішення для різних військових і цивільних застосувань.

Отже, внаслідок виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

Наукова новизна отриманих результатів дослідження – розроблено унікальний набір даних військових об'єктів, що описує різноманітні сценарії перебігу бойових дій та умов навколишнього середовища, що дало змогу вдосконалити сучасні моделі для розпізнавання таких об'єктів у режимі реального часу.

Практична значущість результатів дослідження – результати використано для оцінювання можливостей розгортання сучасних моделей на периферійних пристроях для виявлення військових об'єктів у режимі реального часу, а запропонований підхід можна застосувати для розроблення інтелектуальних систем спостереження, автономних дронів і військових аналітичних платформ, що вимагають належної точності та значної швидкості отримання результатів за умов наявності обмежених обчислювальних ресурсів.

Висновки / Conclusions

Проаналізовано та оцінено ефективність роботи сучасних моделей під час розпізнавання військових об'єктів у режимі реального часу з використанням спеціалізованих наборів даних, що дало можливість визначити підходи до їх розгортання, враховуючи обчислювальні обмеження, точність виявлення військових об'єктів і швидкість прийняття обґрунтованих рішень. За результатами проведеного дослідження можна зробити такі основні висновки.

1. Розроблено та систематизовано спеціалізований набір даних для відображення реальних умов поля бою, що охоплює різні класи військових об'єктів (танк, БМП і БТР) і складні сценарії, такі як різноманітне освітлення, розмиття, перешкоди, затінення та складність навколишнього середовища.
2. Проаналізовано результати навчання моделей для виявлення військових об'єктів, зокрема Faster R-CNN-ResNet50-FPNv2, SSD-MobileNetV3 та YOLOv8n, на підставі ключових показників ефективності, таких як точність, влучність, F1-Score, mAP та FPS, що дало змогу визначити переваги та недоліки кожної моделі та оцінити їхню придатність для роботи в реальному часі.

3. З'ясовано, що розгортання та тестування моделей під час розпізнавання військових об'єктів на платформі NVIDIA Jetson Orin Nano дало змогу оцінити їхню придатність для роботи за умов наявності обмежених обчислювальних ресурсів, визначивши, які з моделей забезпечують необхідний рівень ефективності для військових і безпекових застосувань, а які мають обмеження щодо практичного їх використання.
4. За результатами практичних тестувань та розгортання на платформі NVIDIA Jetson встановлено, що модель YOLOv8n є найбільш ефективною, яка досягнула найвищих показників mAP (91,8 %) і FPS (55), що підтверджує її придатність для застосування у режимі реального часу за умов наявності обмежених обчислювальних ресурсів.
5. Визначено практичне значення адаптації моделей для виявлення військових об'єктів з зосередженням уваги на потребі досягнення оптимального співвідношення між обчислювальною ефективністю та точністю розпізнавання об'єктів, оскільки цей баланс є критичним фактором для оперативного розгортання моделей в бойових умовах, де швидкість і точність виявлення військових об'єктів безпосередньо впливають на ситуаційну обізнаність та ухвалення тактичних рішень.

References

1. Ali, S., Abdullah, Athar, A., Ali, M., Hussain, A., & Kim, H.-C. (2023). Computer Vision-Based Military Tank Recognition Using Object Detection Technique: An application of the YOLO Framework. 2023 1st International Conference on Advanced Innovations in Smart Cities (ICAISC), Jeddah, Saudi Arabia, 1–6. <https://doi.org/10.1109/ICAISC56366.2023.10085552>
2. Aman, Dalmia. (2019). Real-time Object Detection: Understanding SSD. *Medium; Inveterate Learner*. URL: <https://medium.com/inveterate-learner/real-time-object-detection-part-1-understanding-ssd-65797a5e675b>
3. Arani, E., Gowda, S., Mukherjee, R., Magdy, O., Kathiresan, S., & Zonooz, B. (2022). A Comprehensive Study of Real-Time Object Detection Networks Across Multiple Domains: A Survey. *Published in Transactions on Machine Learning Research*, 08, 1–48. <https://doi.org/10.48550/arXiv.2208.10895>
4. Azarov, I., Gnatyuk, S., Aleksander, M., Azarov, I., & Mukasheva, A. (2023). Real-time ML Algorithms for The Detection of Dangerous Objects in Critical Infrastructures. *IntelITSIS'2023: 4th International Workshop on Intelligent Information Technologies and Systems of Information Security*, 3373, Mar. 22-24, 2023. URL: <https://ceur-ws.org/Vol-3373/paper11.pdf>
5. Bonam, J., G Kalyani, A. Karuna, Prasad, N., & Krishna, M. (2021). RETRACTED ARTICLE: Military object detection in defense using multi-level capsule networks. *Published in Soft Computing*, 27, 1045–1059. <https://doi.org/10.1007/s00500-021-05912-0>
6. Diwan, T., Anirudh, G., & Tembhurne., J. V. (2022). Object detection using YOLO: challenges, architectural successors, datasets and applications. *Published in Multimedia Tools and Applications*, 82, 9243–9275. <https://doi.org/10.1007/s11042-022-13644-y>
7. Du, L., Zhang, R., & Wang, X. (2020). Overview of two-stage object detection algorithms. *Published in Journal of Physics: Conference Series*, 1544, article ID 012033. <https://doi.org/10.1088/1742-6596/1544/1/012033>
8. Gromada, K., Siemiątkowska, B., Stecz, W., Plochocki, K., & Woźniak, K. (2022). Real-Time Object Detection and Classification by UAV Equipped With SAR. *Published in Sensors*, 22(5), article ID 2068. <https://doi.org/10.3390/s22052068>
9. Li, H., Yang, S., Liu, J., Yang, Y., Kadoch, M., & Liu, T. (2022). A Framework and Method for Surface Floating Object Detection Based on 6G Networks. *Published in Electronics*, 11(18), 2939–2939. <https://doi.org/10.3390/electronics11182939>
10. Lin, T.-Y., Goyal, P., Girshick, R., He, K., & Dollar, P. (2017). Focal Loss for Dense Object Detection. 2017 *IEEE International*

- Conference on Computer Vision (ICCV), Venice, Italy, 2999–3007. <https://doi.org/10.1109/iccv.2017.324>
11. Liu, H., Yu, Y., Liu, S., & Wang, W. (2022). A Military Object Detection Model of UAV Reconnaissance Image and Feature Visualization. *Published in Applied Sciences*, 12(23), article ID 12236. <https://doi.org/10.3390/app122312236>
 12. Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016). SSD: Single Shot Multibox Detector. *Computer Vision – ECCV 2016*, 9905, 21–37. https://doi.org/10.1007/978-3-319-46448-0_2
 13. Mandula, J., Kühne, J., Pascarella, L., & Magno, M. (2024). Towards Real-Time Fast Unmanned Aerial Vehicle Detection Using Dynamic Vision Sensors. 2024 *IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, 1–6, Glasgow, Scotland. <https://doi.org/10.1109/i2mtc60896.2024.10561168>
 14. Mohan, V. S., Vinayakumar, R., Sowmya, V., & Soman, K. P. (2019). Deep Rectified System for high-speed Tracking in Images. *Published in Journal of Intelligent & Fuzzy Systems*, 36(3), 1957–1965. <https://doi.org/10.3233/jifs-169907>
 15. Ouyang, Y., Wang, X., Hu, R., Xu, H., & Shao, F. (2022). Military Vehicle Object Detection Based on Hierarchical Feature Representation and Refined Localization. *Published in IEEE Access*, 10, 99897–99908. <https://doi.org/10.1109/ACCESS.2022.3207153>
 16. Parcell, K., Choi, B., & Starling, J. (2024). Optimizing Performance of Real-time Detection and Classification for Military Personnel and Weapons. *Published in The ITEA Journal of Test and Evaluation*, 45(3). <https://doi.org/10.61278/itea.45.3.1005>
 17. Patil, A. N., Mohanty, S. N., & Khan, T. (2024). SkyViewSentinel: A Deep Learning-Driven Military Object Detection Application for Remote-Sensing Satellite Images. *Published in Recent Advances in Computer Science and Communications*, 18(5), <https://doi.org/10.2174/0126662558333174241009112642>
 18. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 779–788. <https://doi.org/10.1109/cvpr.2016.91>
 19. Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *Neural Information Processing Systems; Curran Associates, Inc.* URL: https://papers.nips.cc/paper_files/paper/2015/hash/14bfa6bb14875e45bba028a21ed38046-Abstract.html
 20. Sohan, M., Thotakura, Sai Ram., & Ch. (2024). A Review on YOLOv8 and Its Advancements. *Published in Algorithms for Intelligent Systems*, 529–545. https://doi.org/10.1007/978-981-99-7962-2_39
 21. Syed, Muhammad Aamir, Ma, H., Ali, K. M. A., & Muhammad, Aaqib. (2021). Real-Time Object Detection in Occluded Environment with Background Cluttering Effects Using Deep Learning. *The 7th International Workshop on Advanced Computational Intelligence and Intelligent Informatics (IWACIII2021)*, Beijing, China, Oct. 31 – Nov. 3, 1–6. <https://doi.org/10.48550/arXiv.2401.00986>
 22. Žigulić, N., Glučina, M., Lorencin, I., & Matika, D. (2023). Military Decision-Making Process Enhanced by Image Detection. *Published in Information*, 15(1), 11–21. <https://doi.org/10.3390/info15010011>

S. I. Hlod, A. V. Doroshenko

Lviv Polytechnic National University, Lviv, Ukraine

SELECTION OF AN EFFECTIVE MODEL FOR REAL-TIME MILITARY OBJECTS RECOGNITION ON SPECIALIZED DATASETS

Real-time object recognition is a fundamental component of modern computer vision, especially in complex scenarios such as military operations, where the speed and accuracy of targeted object detection are critical for effective decision-making in dynamic and unpredictable battlefield environments. This study examines the problem of real-time detection and classification of military objects, focusing on the comparative analysis of different object detection methodologies. As part of this research, three following object detection models were trained and fine-tuned: Faster R-CNN, SSD (Single Shot MultiBox Detector), and YOLO (You Only Look Once). The study investigates the performance of both two-stage and one-stage detection algorithms and the suitability of the models for rapid deployment in operational conditions. To ensure realistic testing scenarios, a specialized dataset was compiled and adapted for training, validation, and testing, consisting of diverse images of armored vehicles, including tanks, infantry fighting vehicles (BMP), and armored personnel carriers (BTR). Model performance was evaluated using key metrics, including Precision, Recall, F1-Score, Mean Average Precision (mAP), and Frames per Second (FPS). The NVIDIA Jetson platform was used to test the model inference to simulate real-time deployment in resource-constrained environments. The results indicate that the trained YOLOv8n model demonstrates the highest efficiency, achieving a mAP of 91.8 % and an FPS of 55, confirming its suitability for real-time recognition tasks. Faster R-CNN with ResNet50 exhibited quite high accuracy (mAP – 89.2 %, F1-Score – 89.4 %) but was constrained by its low inference speed (FPS – 7), significantly limiting its practical deployment in time-sensitive operational environments. SSD with MobileNetV3 provided balanced results (mAP – 81 %, F1-Score – 83.4 %, FPS – 36), offering a trade-off between accuracy and speed; however, its overall performance was affected by occasional misclassification and missed detections. The findings emphasize the practical significance of selecting and adapting object detection models to specific operational requirements, particularly in the military domain. The results of this study establish a foundation for further research aimed at enhancing one-stage detection algorithms, expanding dataset diversity, and refining state-of-the-art methods to improve the performance of edge computing devices in complex and dynamic environments.

Keywords: real-time military objects detection; peripheral device; one-stage detectors; two-stage detectors; YOLO model; SSD model; Faster R-CNN; specialized dataset; NVIDIA Jetson platform.