

УДК 004.93:004.8

Процюк Ю. О. ORCID: 0000-0001-5193-3669 (ВІТІ ім. Героїв Крут)
Драглюк О. В. ORCID: 0000-0001-8572-7257 (ВІТІ ім. Героїв Крут)
Паламарчук Н. А. ORCID: 0000-0001-8818-7794 (ВІТІ ім. Героїв Крут)
Куцаєв П. В. ORCID: 0000-0002-3235-3316 (ВІТІ ім. Героїв Крут)
канд. техн. наук Овсянніков В. В. ORCID: 0000-0003-0186-6220 (ВІТІ ім. Героїв Крут)

ПІДХОДИ ДО ФОРМУВАННЯ БАЗИ ДАНИХ ЗОБРАЖЕНЬ В СИСТЕМІ ІДЕНТИФІКАЦІЇ ВИБУХОНЕБЕЗПЕЧНИХ ПРЕДМЕТІВ ДЛЯ ПОДАЛЬШОГО НАВЧАННЯ НЕЙРОННОЇ МЕРЕЖІ

Використання безпілотних літальних апаратів для виявлення вибухонебезпечних предметів є перспективним напрямком у галузі розмінування. Наразі значна роль при ідентифікації виявлених предметів залишається за оператором (людиною). Для вирішення задач з ідентифікації зображень вибухонебезпечних предметів, безпілотні літальні апарати або інші роботизовані системи доцільно обладнувати відповідними програмно-технічними засобами із вбудованими елементами штучного інтелекту, які б дозволили з певною ймовірністю розпізнавати виявлені об'єкти за їхніми характерними локальними ознаками (формою/зображенням, матеріалом виготовлення корпусу, температурою корпусу) та класифікувати їх без участі оператора.

Розпізнавання полягає в обчисленні міри релевантності між описами об'єкта та еталона, образи яких задані у вигляді множин векторів-дескрипторів та оптимізації значень цієї міри для бази еталонів.

У статті розглянуто основні алгоритми (методи) ідентифікації зображень та обрано ті, які мають вищу швидкість та побудовані за бінарним типом, що спрощує процес обчислення та знижує затрати. В цілому, комбінування дескрипторів ORB та BRISK дає кращі результати, оскільки враховується спотворення кольору, погане освітлення, наявність шумів, різних проєкцій.

У статті запропоновано підходи до формування бази даних зображень вибухонебезпечних предметів, яка в подальшому виступатиме вхідним шаром для навчання нейронної мережі для ідентифікації вибухонебезпечних предметів. У процесі роботи був написаний програмний код, який надає можливість перевірити працездатність комбінованих методів (алгоритмів) ідентифікації зображень щодо формування бази даних, її збереження та тестування.

Ключові слова: безпілотні літальні апарати, вибухонебезпечні предмети, дескриптор, ідентифікація зображення, нейронні мережі, розмінування, штучний інтелект.

Y. Protsiuk, O. Draglyuk, N. Palamarchuk, P. Kutsaiev, V. Ovsyannikov. Approaches to the formation of an image database in the explosive ordnance identification system for further training of a neural network

The use of unmanned aerial vehicles to detect explosive objects is a promising area of demining. Currently, a significant role in identifying detected objects remains with the operator (human). To solve the problem of identifying images of explosive objects, it is advisable to equip unmanned aerial vehicles or other robotic systems with appropriate software and hardware with built-in elements of artificial intelligence that would allow to recognize detected objects with a certain probability by their characteristic local features (shape/image, body material, body temperature) and classify them without operator participation.

Recognition consists in calculating the relevance measure between the descriptions of the object and the reference, whose images are given as sets of descriptor vectors, and optimizing the values of this measure for the reference database.

The article discusses the main algorithms (methods) for image identification and selects those that have higher performance and are built according to the binary type, which simplifies the calculation process and reduces costs. In general, the combination of ORB and BRISK descriptors gives better results, since it takes into account color distortion, poor lighting, noise, and different projections.

The paper proposes approaches to forming a database of explosive ordnance images, which will further serve as an input layer for training a neural network to identify explosive ordnance. In the course of the work, a program code was written that makes it possible to test the performance of combined methods (algorithms) of image identification in terms of database formation, storage and testing.

Keywords: unmanned aerial vehicles, explosive ordnance, descriptor, image identification, neural networks, demining, artificial intelligence.

Постановка завдання. За період ведення бойових дій в Україні забрудненою вибухонебезпечними предметами (далі – ВВП) вважається вся територія, де йшли бої, не враховуючи території, де нині проходять бойові дії. За оцінками Асоціації саперів, перевірки на ВВП потребує п'ята частина території країни, що становить приблизно 139 тис. кв. км, і за оцінками деяких експертів на розмінування потрібно приблизно 750 років. Для порівняння, під час виконання робіт з очищення території України представниками ДСНС України з 2014 року по 2023 рік знешкоджено 1 262 134 од. ВВП, площа очищеної території склала 3 082 кв. км [1–3].

На сьогодні розробляються та використовуються новітні технології розмінування, такі як механізоване розмінування, роботизовані системи (комплекси), безпілотні літальні апарати (далі – БпЛА) з датчиками різних типів для виявлення та знешкодження ВВП [4]. Всі ці технології дозволяють віддалене управління засобами розмінування та убезпечують операторів від випадкового спарцювання ВВП, але не виключають їхньої присутності у роботі цих систем. Для вирішення задач з ідентифікації зображень ВВП, БпЛА або інші роботизовані системи доцільно обладнувати відповідними пристроями на кшталт камери з високою роздільною здатністю, тепловізора, автоматизованої системи зйомки тощо, із вбудованими елементами штучного інтелекту, які б дозволили з певною ймовірністю розпізнавати виявлені об'єкти за їхніми характерними локальними ознаками (формою/зображенням, матеріалом виготовлення корпусу, температурою корпусу) та класифікувати їх без участі оператора (людини). Тому, для проведення ідентифікації ВВП по їхньому зображенню в автоматизованому режимі необхідно розробити методику формування бази даних зображень для подальшого навчання нейронної мережі.

Аналіз останніх досліджень і публікацій. Дослідження, що проводяться в області розпізнавання предметів, зводяться до створення та впровадження сучасних засобів робототехніки з широким використанням елементів штучного інтелекту. Так, у [5–7] був проведений аналіз актуальних, сучасних та перспективних технологій робототехніки, зокрема БпЛА, їх застосування за допомогою штучного інтелекту, які без втручання людини можуть визначати наявність небезпеки шляхом дослідження результатів обстеження територій БпЛА та управління якістю розмінування. У [9] проведено навчання регіонально-згорткової нейронної мережі (Faster R-CNN) щодо ідентифікації ВВП за допомогою мультиспектральних і теплових даних, зібраних автоматизованою системою зйомки з БпЛА.

У [8; 10; 12; 13] авторами проведена робота з розробки та тестування методів обробки даних багатоканального дистанційного зондування на основі нейронних мереж, досліджена тема розпізнавання візуальних об'єктів із використанням класифікації дескрипторів особливих (ключових, контрольних) точок зображення на основі навчання нейронної мережі з описом методів SIFT, SURF, ORB та BRISK.

У [4] запропоновано синтез системи виявлення ВВП на базі БпЛА зі встановленим на ньому тепловізором, в поєднанні з металошукачем та маніпулятором із вибухівкою для дистанційного розмінування. Хоча значного прогресу в цій галузі вже досягнуто, залишається багато нерозв'язаних задач, у тому числі ідентифікація зображень ВВП в автоматизованому режимі. Тому пошук шляхів підвищення ефективності при виявленні та ідентифікації зображень ВВП за допомогою нейронних мереж є актуальним.

Метою статті є розробка підходів до формування бази даних зображень в системі ідентифікації вибухонебезпечних предметів для подальшого навчання нейронної мережі.

Виклад основного матеріалу. Постійний розвиток нових технологій напряму сприяє розвитку основних військових функцій. Технологічні зміни завжди впливали на військові дії та є суттєвим чинником результату військових конфліктів. Наукові розробки у США та країнах Європи спрямовані на використання цифрових технологій для аналізу даних за допомогою штучного інтелекту. До основних напрямків розвитку штучного інтелекту

відносять: глибинне навчання (Deep Learning), машинне навчання (Machine Learning), комп'ютерне бачення, автономні системи, робототехніку тощо.

Одним з найбільш розвинених алгоритмів для глибинного навчання з ідентифікацією зображень та відео є згорткові нейронні мережі (CNN – Convolutional Neural Network), які адаптовані для обробки зображень і спроектовані з припущенням, що на вхід подається еталонне зображення. На відміну від стандартних нейронних мереж, шари у згорткових нейронних мережах є тривимірними, а нейрони одного шару зв'язані тільки з певною областю наступного шару. Це дозволяє вибудувати певні характеристики в архітектуру, спрямовану на поліпшення класифікації зображень.

Структурні методи розпізнавання об'єктів, що засновані на локальних ознаках зображення, набули популярності та широко застосовуються в сучасних системах комп'ютерного зору. Вони базуються на визначенні множини особливих (контрольних) точок (далі – контрольні точки) та їхньому описові у вигляді числового чи бінарного вектора – дескриптора, який відображає властивості зображення для локальних околиць цих точок. Зазначене дає можливість програмі працювати із візуальними образами подібно людині. Значення дескриптора є незмінним стосовно зміщення, повороту, масштабування об'єктів на зображенні, при цьому кількість утворених дескрипторів, що формують опис, повинна бути достатньою для прийняття рішення відносно ідентифікації. Розпізнавання полягає в обчисленні міри релевантності між описами об'єкта та еталона, образи яких задані у вигляді множин дескрипторів та оптимізації значень цієї міри для бази еталонних зображень.

Ідентифікація (розпізнавання) ВВП, як і будь-яких інших об'єктів, здійснюється за їхніми характерними ознаками. Так, аналіз ВВП показав [4], що найбільш розповсюдженими на поверхні є протипіхотні фугасні міни (ПФМ-1, міна-метелик), міни-пастки, протитанкові міни фугасної дії, протипіхотні міни осколкової дії, протитанкові міни дистанційного мінування. Для фугасних мін характерне використання пластмас, для мін осколкової дії – металу, відповідно основними характерними ознаками для виявлення та ідентифікації ВВП можуть бути їхні форма/зображення (висота, радіус, довжина, ширина), матеріал виготовлення корпусу (пластмаса, поліетилен, сталь, чавун), температура корпусу. За своєю специфікою ВВП можуть бути розкидані в різній місцевості (середовищі) – трава, пісок, сніг, листя та в різних проєкціях, що в подальшому впливатиме на обробку зображень. Ці характерні ознаки є визначальними при виборі способу (засобу) виявлення ВВП, кожний із яких має переваги та недоліки.

Пошук металевих (металовмісних) ВВП здійснюється за допомогою металошукача (під землею або на поверхні землі), пошук пластикових ВВП, що знаходяться на поверхні землі – за допомогою візуального аналізу зображення та за допомогою спеціального програмного забезпечення із залученням тепловізійної чи оптичної камери. Основною функцією металошукача є виявлення металу у міні, а оскільки багато років використовуються міни в неметалевих корпусах, то це значно ускладнює роботу. Також уповільнює процес виявлення наявність великої кількості хибних сигналів від осколків ВВП та інших металів, якими перенасичений ґрунт внаслідок ведення бойових дій [4].

Тепловізійний моніторинг, згідно з [14], найбільш ефективний лише у сонячні дні, в хмарну погоду є недоцільним, а встановлені в тіні зразки не ідентифікуються, як і закопані в ґрунт на глибину 2–5 см. Хоча при тепловізійному моніторингу наявність забруднення металевими частками, на відміну від класичних металошукачів, не становить проблеми. При цьому значна роль при ідентифікації виявлених предметів залишається за оператором (людиною).

Одним із варіантів ідентифікації ВВП, які знаходяться на поверхні землі, може бути їх розпізнавання в автоматизованому режимі з використанням алгоритмів обробки зображень та нейронної мережі. В цій роботі пропонується підхід до розробки методики формування бази

даних зображень ВВП на прикладі протипіхотної фугасної міни (ПФМ-1, міна-метелик) з подальшим використанням її для навчання нейронної мережі. ПФМ-1 обрано для дослідження, оскільки вони є найпоширенішими в Україні, встановлюються методом дистанційного мінування (на поверхні), що дозволяє отримати їхнє зображення, а також можуть маскуватися під місцевість (пісок, листя та ін.), що матиме певні особливості при обробці зображень. Проблема при виявленні цих мін полягає в тому, що вони мають малий розмір, маскуються та зроблені переважно з пластику, відповідно їх досить важко знайти за допомогою металодетекторів, а ефективність використання тепловізорів пов'язана із зазначеними обмеженнями та значною мірою залежить від погодних умов [4; 14].

Запропонована методика містить ряд кроків: від створення відповідного набору даних зображень (на прикладі ПФМ-1), їх попередньої обробки та ін., до тестування сформованої бази даних (рис. 1).



Рис. 1. Методика формування Dataset ВВП

Для якісного навчання нейронної мережі, необхідно на вхідний шар мережі подати сформовану базу даних зображень, еталонів ВВП. База даних зображень (далі – Dataset) повинна бути репрезентативною для всіх можливих варіантів, зображення повинні бути стійкі до спотворення кольору, поганого освітлення, наявності шумів, різних проєкцій, тобто, повинні відповідати вимогам до класифікації зображень.

Розглянемо детальніше кожний із наведених кроків методики. На першому кроці здійснюється підготовка бази зображень ВВП на прикладі ПФМ-1. Для наповнення Dataset можливо використовувати як спеціальне програмне забезпечення для колекціонування зображення з різних ресурсів мережі Інтернет (готові бази даних з різних платформ), так і створити власноруч із зображень, які були отримані за допомогою різних пристроїв – камер, сенсорів, супутників, БПЛА тощо. Для формування Dataset було завантажено 78 зображень ПФМ-1 з різних джерел в мережі Інтернет. На цих зображеннях ПФМ-1 зображені при різному освітленні (штучному та природному), зроблені у різний час доби (вдень та вночі), в різних ракурсах, кутах та позиціях (зверху, знизу та з боку), середовищах та шумах. Далі, на другому кроці, ці зображення були попередньо оброблені з використанням платформи Depositphotos, а саме проведено затирання фону та виділено об'єкти, які обробляються, що дозволило отримати еталонні зображення ПФМ-1 (рис. 2) для формування Dataset.

З метою класифікації зображення (після попередньої обробки) визначаються його локальні особливості, тобто контрольні точки. Контрольна точка – точка на зображенні, що задовольняє ряд властивостей [15]:

визначеність – властивість точки виділятися на фоні серед інших сусідніх точок;

стійкість – властивість, при якій зміна яскравості, контрастності та кольорової гами не повинні здійснювати вплив на місце контрольної точки;

інваріантність – властивість точки бути стійкою до повороту, масштабу, зміни ракурсу;

стабільність – властивість, при якій наявність шумів (сніг, листя тощо) не повинна впливати на роботу детектора;

інтерпретованість – представлення точки в прийнятному для роботи форматі;

кількість – необхідна кількість точок, яка допоможе провести зіставлення зображення.



Рис. 2. Приклад обробки зображень з використанням платформи Depositphotos:
а – зображення ПФМ-1 на місцевості; б – еталонне зображення ПФМ-1 (після обробки)

Для обробки зображень з метою їх ідентифікації використовують ряд алгоритмів (методів), які базуються на комп'ютерному баченні. До основних з них належать [13; 15]:

1. SIFT (Scale Invariant Feature Transform) – алгоритм застосовується для аналізу зображень з подальшим виявленням, описуванням та зіставленням локальних ознак (точок) у зображеннях та створенні дескриптора. Для побудови простору зображень метод SIFT використовує фільтр Гауса, де обчислюється різниця Гауса, а саме попіксельне віднімання зображень в одній октаві. Октаву формують зображення одного масштабу, розмиті фільтром Гауса з різним радіусом розмиття. На цьому етапі забезпечується інваріантність до масштабування, далі визначаються екстремуми, які записуються в список потенційних контрольних точок.

Переваги: інваріантність щодо рівномірного масштабування спрямування та зміни освітлення; часткова інваріантність щодо афінного спотворення. Недоліки: вимогливість до обчислювальної потужності та ліцензійність.

2. SURF (Speeded up Robust Features) – подібний до алгоритму SIFT, але працює за допомогою матриці Гессе, яка досягає свого екстремуму в точках максимальної зміни градієнту яскравості. Градієнт яскравості обчислюється за допомогою фільтрів Хаара. Метод добре виявляє плями, кути, краї, але не інваріантний відносно масштабу. Після знаходження контрольних точок формуються дескриптори.

Переваги: інваріантність відносно повороту та масштабування, різниці яскравості; можливість виявлення багатьох об'єктів на заданому зображенні. Недоліки: складність реалізації та не дуже швидка робота.

3. FAST (Features from Accelerated Segment Test) – алгоритм детектування контрольних точок на зображеннях, заснований на швидкому алгоритмі перевірки великої кількості пікселів навколо потенційної контрольної точки. Визначає потенційні контрольні точки, шукаючи точки, у яких інтенсивність значно вища або нижча від інтенсивності центрального

пікселя. Після вибору центрального пікселя, алгоритм перевіряє інтенсивності пікселів навколо центрального пікселя в чотирьох напрямках. Якщо знайдено стійкий або більше швидких переходів із темного до світлого або зі світлого до темного, центральний піксель вважається контрольною точкою.

Переваги алгоритму: швидкість детектування контрольних точок; ефективність виявлення контрольних точок на складних зображеннях з великою кількістю деталей; простота реалізації. Недоліки: чутливість до шуму та текстур, до орієнтації; не є інваріантним до масштабу; відсутність можливості генерації дескрипторів.

4. BRIEF (Binary Robust Independent Elementary Features) – алгоритм створення локальних дескрипторів для обробки зображень, який використовується для виявлення та опису контрольних точок на зображеннях. Основна ідея методу полягає в тому, щоб створити короткі, бінарні дескриптори, які можуть швидко порівнюватися для відповідності між зображеннями.

Переваги: швидкість порівняння зображень через використання бінарних дескрипторів та прості порівняння пікселів; ефективність в обробці великих обсягів даних; простота реалізації; малий обсяг пам'яті, що дозволяє ефективно зберігати та обробляти багато дескрипторів одночасно. Недолік: низька робучість; низька точність збігу; чутливість до шуму.

5. ORB (Oriented FAST and Rotated BRIEF) – алгоритм, який обчислює орієнтацію ключової точки зображення та бінарне узгодження з вже отриманих орієнтацій. Є ефективним варіантом SIFT та SURF, який забезпечує порівняну ефективність та швидкість. ORB розроблений на базі детектора контрольних точок і дескриптора.

6. BRISK (Binary Robust Invariant Scalable Keypoints) – продовження алгоритмів SIFT і SURF, але з подальшим удосконаленням складових FAST. BRISK складає дескриптор шляхом об'єднання результатів порівняльних тестів яскравості, враховуючи зазначений масштаб та розташування кожної контрольної точки, щоб забезпечити інваріантність до обертання та одержати адаптовано нормалізовані дескриптори. Дескриптор BRIEF забезпечує ідентифікацію однакових ділянок зображення, отриманих з різних точок зору.

Переваги: вища швидкодія, завдяки спрощенню процесу оброблення та побудови і використання дескриптора бінарного типу; можливість виявлення якісно вищих контрольних точок на зображенні та досягнення стійкості до геометричних перетворень.

Порівняльний аналіз характеристик зазначених алгоритмів наведено в таблиці 1.

Таблиця 1

Порівняльний аналіз характеристик зазначених алгоритмів

Найменування алгоритму \ Характеристика	FIST	SURF	FAST	BRIEF	ORB	BRISK
Швидкість	висока	висока	висока	висока	середня	середня
Інваріантність до масштабу	відсутня	відсутня	відсутня	відсутня	наявна	наявна
Інваріантність до обертання	відсутня	відсутня	відсутня	відсутня	наявна	наявна
Витримка до шуму	висока	висока	низька	середня	висока	висока
Діапазон освітленості	середній	широкий	високий	середній	високий	високий
Діапазон детектованого кута	великий	широкий	середній	середній	великий	великий
Робоча пам'ять	середня	висока	низька	низька	середня	середня
Навчальна складність	висока	висока	низька	середня	середня	середня
Простота реалізації	середня	середня	висока	висока	середня	середня
Ресурсоемність	низька	висока	низька	низька	середня	середня
Відносна надійність	висока	висока	висока	середня	висока	висока
Популярність у використанні	середня	висока	висока	середня	висока	висока

Проаналізувавши зазначені типи алгоритмів та результати їх використання при ідентифікації зображень, автори дійшли висновку, що у подальшій роботі для ідентифікації ВНП доцільно використовувати комбінування ORB та BRISK (третій крок методики), оскільки вони мають вищу швидкість, побудовані по бінарному типу, що спрощує процес обчислення та знижує затрати. В цілому, їх комбінування дає кращі результати, оскільки враховується спотворення кольору, погане освітлення, наявність шумів та різних проєкцій зображень.

Розглянемо математичне представлення застосування ORB та BRISK для класифікації зображень ВНП [16]. Припустимо, що у нас є певна множина $Z = \{Z^j\}_{j=1}^J$ ознак бази зображень, яку складають еталони (Z^j – еталон, J – число класів). Під час попередньої обробки множину Z поділяємо на певну кількість k кластерів $M = \{M_i\}_{i=1}^k$, так що $M_i \cap M_d = \emptyset$, $Z = \cup M_i$, $M = Z$. Кожний з кластерів M_i має свій центр m_i .

Кластерування полягає у відображенні еталонного набору контрольних точок в себе $Z \rightarrow Z$, де кожна контрольна точка належить до одного з кластерів.

Створена навчальна множина даних $W = \{x | x \in R^n\}$, $W \subseteq R^n$, яка складається з набору контрольних точок дескрипторів. Після цього можемо збудувати кортеж k опорних векторів $M = \{m_i\}_{i=1}^k$, $m_i \in R^n$, $i = 1, \dots, k$.

Для сформованого набору M апроксимація довільного вектора $x \in W$ конкурентним способом означає визначення номера v найближчого до нього (у метриці $\rho(x, m_i)$) вектора $m_v \in M$ у просторі модельних векторів відповідно до виразу (1):

$$v = \arg \min_{i=1, \dots, k} \rho(x, m_i). \quad (1)$$

Для традиційного варіанта онлайн-навчання, якщо дескриптори контрольних точок $x[t] \in W$ поступають по черзі, центр m_v кластера, який став переможцем в (1), на кроці $t = 1, 2, \dots, s$ навчання коригується відповідно до виразу (2):

$$m_v[t + 1] = m_v[t] + \alpha[t](x[t] - m_v[t]), \quad (2)$$

де $s = \text{card}W$ – загальне число контрольних точок бази зображень навчальної вибірки, $\alpha[t]$ швидкість навчання, яка задається, водночас $\alpha[t] \rightarrow 0$ при $t \rightarrow s$.

Критерій похибки оцінюється якістю кластерування – усередненої суми квадратів відхилень від центрів сформованих кластерів відповідно до виразу (3):

$$E = \frac{1}{2} \sum_{i=1}^k \sum_{v=1}^{s(i)} \rho^2(x_v, m_i), \quad (3)$$

де $s(i)$ – потужність i -го кластера [3].

У випадку, коли число k кластерів дорівнює числу еталонів бази зображень, кластерування виконує класифікацію на k класів у просторі W . Множина дескрипторів контрольних точок, що описує довільний візуальний об'єкт, може бути класифікована як один із еталонів зображення.

Наряду з класифікацією, на підставі мережі Кохонена, розглянемо евристичний підхід бінарного аналізу, суть якого полягає в наступному.

1. На підставі логічного правила визначимо вектор m_i центра класу для кожного з еталонів множини Z_i дескриптора BRISK, який має бінарний вид відповідно до виразу (4):

$$m_i(b) = \begin{cases} 1, & \text{при } \sum_{d=1}^{s(i)} x_d(b) \geq s(i)/2, \\ 0, & \text{при } \sum_{d=1}^{s(i)} x_d(b) < s(i)/2, \end{cases} \quad (4)$$

$x_d \in Z^i \quad b = \overline{1,12},$

де $x_d(b)$ – біт з номером b для дескриптора з номером d в описі еталону зображення.

Таким чином, значення центрів для кожного з бітів m_i для i -го класу визначається переважно більшістю значень відповідних бітів всіх дескрипторів контрольних точок, які належать еталону Z^i .

2. Аналізуємо елементи $x \in Z$ спільного вмісту структурних описів бази еталонів (навчальна вибірка) шляхом віднесення їх до відповідного класу з використанням конкурентного способу (1). Тут у якості $\rho(x, m_i)$ застосуємо метрику Хемінга, що визначає кількість розбіжних бітів для двох двійкових послідовностей однакової довжини (детекторів контрольних точок) відповідно до виразу (5):

$$\rho(x, m_i) = \sum_{b=1}^{512} |x(b) - m_i(b)|, \quad (5)$$

У результаті оброблення для кожного еталону отримуємо його кластерне подання $H[Z^i] = (h_1^i, \dots, h_j^i)$, де h_a^i – цілі числа, які відповідають розподілу елементів множини Z^i за класами еталонів.

Етап попередньої обробки, що ґрунтується на бінарному аналізі, можна розглядати як альтернативний метод хешування для набору дескрипторів контрольних точок еталону. Для аналізу множини дескрипторів ORB можна використати аналогічну обробку. В якості прикладу, на рисунку 3 відображено формування контрольних точок алгоритмами ORB та BRISK для ПФМ-1.




Рис. 3. Приклад формування контрольних точок для ПФМ-1:
а – еталон ПФМ-1; б – дескриптор ORB; в – дескриптор BRISK

Алгоритм ORB обробляє зображення швидше за BRISK, що дає перевагу під час використання в реальному часі. Проте BRISK формує значно більше контрольних точок та аналізує зображення детальніше, що дозволяє забезпечувати більш точні розпізнавання об'єктів. Відповідно, в процесі комбінування цих методів можливо співставляти контрольні точки ORB та BRISK, що дозволяє забезпечити створення продуктивного методу ідентифікації зображення на основі бітового оброблення та побудову класифікаційних рішень щодо відповідності зображення еталону.

Четвертий крок. В якості програмного середовища для формування Dataset (як зазначалося, бази даних еталонних зображень для ПФМ-1) з використанням зазначених методів ідентифікації ВНП, обрано онлайн-платформу Google Colab, яка дозволяє писати та запускати програмний код мовою Python у хмарі, використовуючи лише браузер. Для цього, імпортуємо необхідні бібліотеки в середовище Google Colab, такі як: OpenCV (для обробки зображень), NumPy (для роботи з масивами даних), Pandas (для роботи з даними у вигляді таблиць) та Matplotlib (для візуалізації даних).

На п'ятому кроці даємо команду на створення об'єктів алгоритмами ORB та BRISK для їх ініціалізації та формування «нульового» Dataset в Google Colab. З метою наповнення Dataset завантажується частина попередньо оброблених зображень (перший та другий крок). Після їх завантаження, об'єкти ORB та BRISK проводять ініціалізацію зображень, позначають на зображеннях контрольні точки та формують дескриптори (у форматі CSV файлу), які і є наповненим Dataset. Якщо Dataset сформовано та збережено коректно, отримуємо повідомлення «Datasets saved successfully», в іншому випадку – код видаватиме помилку з вказівкою місця хибної роботи (рис. 4).

```
def extract_keypoints_and_descriptors(image, detector):
    gray = cv2.cvtColor(image, cv2.COLOR_BGR2GRAY)
    keypoints, descriptors = detector.detectAndCompute(gray, None)
    return keypoints, descriptors

def save_dataset_to_csv(dataset, csv_filename):
    with open(csv_filename, mode='w', newline='') as file:
        writer = csv.writer(file)
        writer.writerow(['Image Path', 'Keypoints', 'Descriptors'])
        for data in dataset:
            keypoints = [keypoint.pt for keypoint in data['keypoints']]
            descriptors = data['descriptors']
            writer.writerow([data['image_path'], keypoints, descriptors])

# Ініціалізація детекторів ORB та BRISK
orb = cv2.ORB_create()
brisk = cv2.BRISK_create()

# Формування датасету для ORB та BRISK
orb_dataset = []
brisk_dataset = []

# Завантаження зображень
uploaded = files.upload()

# Збереження датасету в CSV
save_dataset_to_csv(orb_dataset, 'orb_dataset.csv')
save_dataset_to_csv(brisk_dataset, 'brisk_dataset.csv')

print("Datasets saved successfully.")
```

Рис. 4. Фрагмент програмного коду для ініціалізації детекторів та формування «нульового» Dataset

Для тестування (на шостому кроці) завантажуються вибіркові контрольні зображення (частина зображень, які вже збережені в Dataset та інші, які були попередньо оброблені, але не завантажувалися на попередньому кроці), які порівнюються зі збереженими даними Dataset. Якщо результат ідентифікації зображень є позитивним, виводиться ідентифіковане зображення (за допомогою функції cv2.imshow в середовищі Google Colab) та повідомлення, що зображення є «True». Якщо зображення не ідентифікується, то виводиться повідомлення

«False». Отримані результати підтверджують, що сформований Dataset пройшов тестування успішно та може бути використаний як вхідний шар для навчання нейронної мережі.

Висновки. В статті було розглянуто характерні локальні ознаки ВНП, за якими їх можна ідентифікувати. Аналіз методів ідентифікації зображень показав, що доцільно комбінувати методи ORB та BRISK, це дає більш високу точність при класифікації зображень, оскільки враховується спотворення кольору, погане освітлення, наявність шумів та різних проєкцій.

Запропонована методика містить кроки щодо формування Dataset на прикладі ПФМ-1, починаючи з пошуку, вибору алгоритмів ідентифікації зображень до розроблення програмного коду та тестування сформованого Dataset.

За допомогою платформи Google Colab реалізовано коректну роботу алгоритмів ідентифікації зображень, формування та тестування зазначеного Dataset. Сформований Dataset може бути використаний як вхідний шар для навчання нейронної мережі для ідентифікації ВНП. Подальшим напрямком досліджень є розширення даних Dataset завдяки збільшенню кількості зображень в різних середовищах (з використанням різного програмного забезпечення та порівняння отриманих результатів) та навчання нейромережі для ідентифікації більшої кількості зображень ВНП.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Мірошниченко Б. Десятки років та мільярди доларів. Коли розмінують українські поля та міста? // Економічна правда. 2023. URL: <https://www.epravda.com.ua/publications/2023/03/7/697737/>.
2. Аналіз виконання робіт щодо очищення території України від вибухонебезпечних предметів по роках // Державна служба України з надзвичайних ситуацій. 2023. URL: <https://dsns.gov.ua/protiminna-diyalnist/gumanitarne-rozminuvannya/analiz-vikonannya-robot-schodo-ochischennya-teritoriyi-ukrayini-vid-vibuhonebezpechnih-predmetiv-po-rokah>.
3. Собенко Н. Повне розмінування України може зайняти понад 750 років – WP // Суспільні Новини. 2023. URL: <https://suspilne.media/534815-povne-rozminuvanna-ukraini-moze-zajnati-ponad-750-rokiv-wp/>.
4. Чередниченко О. Ю., Паламарчук Н. А., Шемендюк О. В., Мартинюк В. В. Синтез системи виявлення вибухонебезпечних предметів на базі безпілотного літального апарата // Системи і технології зв'язку, інформатизації та кібербезпеки. Випуск 3, 2023. С. 163–170. ISSN 2786-6610. DOI: 10.58254/viti.3.2023.
5. Невлюдов І. Ш., Янушкевич Д. А., Толкунов І. О., Попов І. І., Іванець Г. В. Обґрунтування необхідності створення робототехнічних комплексів для гуманітарного розмінування. Problems of Emergency Situations (Проблеми надзвичайних ситуацій). Серія: Civil Security. Вип. 2 (38). С. 17–38. DOI: 10.52363/2524-0226-2023-38-2.
6. Рибалка А. В., Скорлупін О. В., Подорожняк А. О. Аналіз можливості застосування технологій штучного інтелекту для виявлення вибухонебезпечних предметів та подальшого гуманітарного розмінування // Тези доповідей. Інформаційна безпека та інформаційні технології: VI Всеукраїнська науково-практична конференція молодих учених, студентів і курсантів, 30 листопада 2023 року. Львів, ЛДУ БЖД, 2023. С. 404–406.
7. Янушкевич Д. А., Іванов Л. С., Толкунов І. О. Креативні підходи управління якістю у сфері гуманітарного розмінування із застосуванням робототехнічних систем // Тези доповідей. Збірник матеріалів V форуму «Автоматизація, електроніка та робототехніка. Стратегії розвитку та інноваційні технології», АЕРТ-2023. Х.: ХНУРЕ, каф. МТС, 29–30 листопада 2023 р. 149 с. С. 55–58.
8. Єремеев О., Васильєва І., Макарічев В., Рубель О., Лі Ф., Чернова Г., Коваленко Б., Ворзель Б., Лукін В. Деякі аспекти обробки багатоканальних даних дистанційного зондування з використанням нейромереж // Prospective global scientific trends: Informatics, Architecture, Innovative technology, Ecology: Monographic series «European Science». 2023. Book 19. Part 2. С. 7–60. DOI: 10.30890/2709-2313.2023-19-02-001.

9. Jasper Baur, Gabriel Steinberg, Alex Nikulin, Kenneth Chiu, Timothy S. de Smet. Applying Deep Learning to Automate UAV-Based Detection of Scatterable Landmines // Remote sensing. 2020. URL: <https://www.mdpi.com/2072-4292/12/5/859#>.
10. Szeliski R. Computer vision: algorithms and applications. Springer Science & Business Media. 2010.
11. Shnain, Noor Abdalrazak; Hussain, Zahir M.; LU, Song Feng. A feature-based structural measure: an image similarity measure for face recognition. Applied Sciences, 2017, 7.8: 786.
12. Gorokhovatskyi, Volodymyr; Tvoroshenko, Iryna. Image classification based on the Kohonen network and the data space modification. 2020.
13. Leutenegger, Stefan; Chli, Margarita; Siegwart, Roland Y. BRISK: Binary robust invariant scalable keypoints. In: 2011 International conference on computer vision. Ieee, 2011. P. 2548–2555.
14. Опришко О. О., Пасічник Н. О., Шворов С. А., Кіктев М. О., Дудник А. О., Сович В. І. Дослідження перспектив дистанційного моніторингу мін на полях з використанням тепловізійного знаряддя // Енергетика і автоматика. 2023. № 6. С. 74–89. DOI: [http://dx.doi.org/10.31548/energiya6\(70\).2023.074](http://dx.doi.org/10.31548/energiya6(70).2023.074).
15. Тимчишин Р. М., Волков О. Є., Господарчук О. Ю., Богачук Ю. П. Сучасні підходи до розв'язання задач комп'ютерного зору // Управляющие системы и машины. 2018. № 6. С. 46–73. Бібліогр.: 48 назв. – укр.
16. Gorokhovatsky V. O. Аналіз властивостей, характеристик та результатів застосування новітніх детекторів для визначення особливих точок зображення / V. O. Gorokhovatsky, D. V. Pupchenko, K. G. Solodchenko // Системи управління, навігації та зв'язку. Збірник наукових праць. Полтава: ПНТУ, 2018. Т. 1 (47). С. 93–98. DOI: <https://doi.org/10.26906/SUNZ.2018.1.093>.