

Zastosowanie algorytmów rozpoznawania obrazu w Bezzałogowych Statkach Powietrznych

Streszczenie. W pracy zaprezentowano przykłady użycia sztucznej inteligencji (SI) w zastosowaniach rozpoznawania obrazu dla Bezzałogowych Statków Powietrznych (BSP). Omówiono autorski projekt BSP amunicji krążącej wykorzystujący algorytmy analizy obrazu. Przedstawiono zasadę działania, elementy systemu oraz zaprezentowano wyniki nauczania sieci neuronowej.

Abstract. This paper presents examples of the use of artificial intelligence (AI) in image recognition applications for unmanned aerial vehicles (UAVs). The author's design of a loitering munitions UAV using image analysis algorithms is discussed. The principle of operation, system components and neural network learning results are presented. (**Application of image recognition algorithms in unmanned aerial vehicles**).

Słowa kluczowe: Bezzałogowe Statki Powietrzne, Sztuczna Inteligencja, Sztuczna Inteligencja w BSP .

Keywords: Unmanned Aerial Systems, Artificial Intelligence, Artificial Intelligence in UAV.

Wstęp


Historia sztucznej inteligencji sięga połowy XX wieku, obejmując rozwój od pierwszych modeli sztucznych sieci neuronowych w latach 40 do najnowocześniejszych dużych modeli językowych takich jak LaMDA (*Language Model for Dialogue Applications*), LLaMA (*Low Latency Machine-learning Architecture*) czy GPT-4 (*Generative Pre-trained Transformer 4*) [1]. Sztuczna inteligencja znalazła zastosowanie w różnych dziedzinach, w tym w handlu elektronicznym, gdzie algorytmy personalizują rekomendacje produktów na podstawie historii wyszukiwania i poprzednich zakupów użytkownika. Ponadto, znaczącą rolę odgrywa w zachowaniu bezpieczeństwa, gdzie pomaga wspierać walkę z cyberatakami i innymi zagrożeniami komputerowymi [2]. Zaawansowane zastosowania AI (*Artificial Intelligence*) obejmują także stosowanie konwolucyjnych (CNN – *Convolutional Neural Network*) i rekurencyjnych (RNN – *Recurrent Neural Network*) sieci neuronowych w nowoczesnych zaporach sprzętowych typu "next-generation", co zrewolucjonizowało podejście do bezpieczeństwa w cyberprzestrzeni [3, 4].

Rozwój AI obejmuje wykorzystanie różnorodnych algorytmów oraz bibliotek programistycznych, takich jak Keras, TensorFlow i PyTorch w języku Python, które umożliwiają kreowanie zaawansowanych aplikacji używających sieci neuronowych. Keras, działający jako interfejs programistyczny, wspomaga tworzenie wysokopoziomowych konstrukcji sieci neuronowych, a także ich implementację z wykorzystaniem niskopoziomowych struktur stworzonych za pomocą JAX czy PyTorch [5].

Historia bezzałogowych statków powietrznych (BSP), która rozpoczęła się ponad sto lat temu, ewoluowała od pierwszych brytyjskich pocisków kierowanych radiowo do zaawansowanych, które wspierały samoloty MQ-25 Stingray [6, 7]. Współczesne BSP pełnią wiele funkcji w środowisku militarnym - od jednostek rozpoznawczo-obszernych, przez jednostki amunicji krążącej (tzw. *drony kamikaze*), po jednostki wsparcia. Algorytmy rozpoznawania obrazu wykorzystywane w każdej z tych kategorii BSP umożliwiają identyfikację wrogów, klasyfikację pojazdów przeciwnika, wykrywanie osób w ukryciu, a także określanie lokalizacji i kierunków ruchu

jednostek, korzystając wyłącznie z danych z pokładowej kamery [8]. Obserwując aktualne wydarzenia na arenie międzynarodowej, jak konflikt rosyjsko-ukraiński, można zauważyć znaczący wzrost wykorzystania BSP w najniższych szczeblach wojskowych, gdzie obie strony konfliktu intensyfikują użycie BSP, w tym amunicji krążącej, mocując ładunki wybuchowe do dronów FPV dla przeprowadzania ataków suicydalnych [8]. Implementacja zaawansowanych algorytmów rozpoznawania obrazu mogłaby znacząco podnieść skuteczność bojową wzmiankowanych wyżej systemów (Rys. 1).

Przełom XX i XXI wieku przyniósł także transformację w zastosowaniach bezzałogowych systemów powietrznych, które zaczęły być wykorzystywane nie tylko w działaniach militarnych, ale również stały się obiektem zainteresowania przemysłu cywilnego i entuzjastów [9]. Branża fotograficzna i turystyczna zaczęła wykorzystywać BSP klasy mini, a drony znalazły zastosowanie w badaniach naukowych i logistyce jako kurierzy lub narzędzia transportujące aparaturę pomiarową. Wprowadzenie regulacji dotyczących użytkowania BSP, takich jak ograniczenia dotyczące maksymalnej wysokości lotu, wagi, a także wymogi certyfikacyjne, takie jak BVLOS NSTS-05 oraz VLOS NSTS-01, stanowi odpowiedź na rosnące zainteresowanie tą technologią [10].



Rys. 1. Przykład systemu do rozpoznania oraz eliminacji celu przez BSP. Źródło: Opracowanie własne.


Zastosowanie analizy obrazu w BSP typu amunicja krążąca

Doświadczenia z bieżącego konfliktu ukraińsko-rosyjskiego ujawniają, że dominującym typem amunicji krążącej jest ta, która powstaje poprzez integrację komercyjnych bezzałogowych statków powietrznych (BSP) z adaptowanymi pociskami do granatników ręcznych RPG-7 (Rys. 2). Obsługa tego rodzaju systemu wymaga zaawansowanych umiejętności w pilotażu dronów FPV, a ze względu na ograniczenia zasięgu, pilot musi znajdować się w pobliżu strefy działań bojowych, co często oznacza ekspozycję na zagrożenia.



Rys.2. Dron typu amunicja krążąca [11].

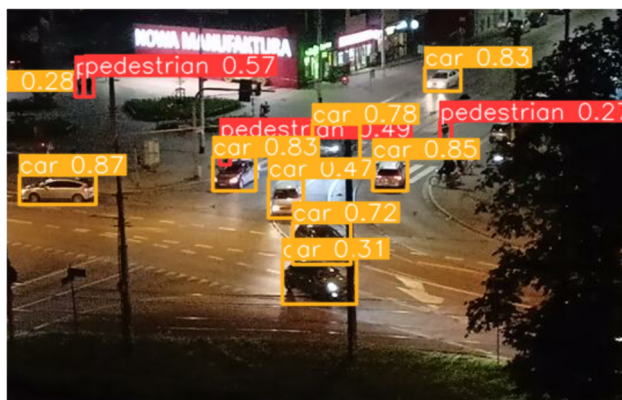
Wykorzystanie algorytmów rozpoznawania obrazu w połączeniu z automatycznym systemem naprowadzania pozwala na precyzyjne identyfikowanie i eliminowanie celów, takich jak pojazdy lub grupy żołnierzy wroga. Automatyzacja tego procesu umożliwia nawet mniej doświadczonym operatorom skuteczne neutralizowanie celów. Bezzałogowe Statki Powietrzne (BSP) wyposażone w te technologie mogą działać autonomicznie (Rys. 3), co minimalizuje ryzyko strat po stronie sojuszników i obniża zużycie amunicji. System może również korzystać ze statycznych kamer umieszczonych w strategicznych lokalizacjach, co ułatwia naprowadzanie na cel i jego weryfikację, zmniejszając potrzebę intensywnego szkolenia personelu.



Rys.3. Schemat algorytmu działania BSP typu amunicja krążąca. Źródło: Opracowanie własne.

System detekcji i naprowadzania oparty na dwuwarstwowej sztucznej inteligencji jest zaawansowanym rozwiązaniem w dziedzinie precyzyjnych uderzeń. Pierwsza warstwa tego systemu, której wyniki przedstawione są na rysunku 4, jest odpowiedzialna za identyfikację celu. Druga warstwa, opierając się na zbiorze uczącym składającym się z kluczowych elementów wcześniej wykrytego celu, umożliwia przeprowadzanie precyzyjnych ataków na strategiczne komponenty pojazdu przeciwnika. Taka

konfiguracja prowadzi do redukcji zużycia efektorów systemu oraz umożliwia skrócenie czasu potrzebnego na szkolenie personelu, eliminując wymóg znajomości technicznej specyfikacji pojazdów wroga. Dzięki temu, system nie tylko zwiększa efektywność operacji, ale również wpływa na ograniczenie kosztów i zasobów niezbędnych do realizacji misji.



Rys.4. Przykład wykrycia pojazdu przez sztuczną inteligencję. Źródło: Opracowanie własne.

Zastosowanie analizy obrazu w BSP rozpoznania

Od lat 70. XX wieku badano potencjał wykorzystania dronów w roli urządzeń zwiadowczych, co doprowadziło do rozwoju Bezzałogowych Systemów Powietrznych (BSP) rozpoznawczych. Jako przykład wczesnych badań można wskazać IAI Scout, który był wykorzystywany do zwiadu taktycznego [12]. Z uwagi na ograniczenia technologiczne tamtych czasów nie możliwa była implementacja algorytmów sztucznej inteligencji. Wraz z postępem technologicznym, możliwa stała się wykorzystanie SI w Bezzałogowych Systemach Powietrznych rozpoznania. Współczesne BSP korzystają z zaawansowanych systemów do analizy obrazu, znacząco zwiększając świadomość sytuacyjną operatorów. Obrazy z kamer BSP są transmitowane do stacji naziemnej (Ground Station Control, GSC), gdzie są analizowane przy użyciu sztucznej inteligencji. Na przykład, wykorzystując model YOLOv8, możliwa jest identyfikacja różnych klas obiektów, takich jak pojazdy, personel cywilny lub wojskowy (Rys. 5) [13]. Implementacja takiego rozwiązania możliwa jest dzięki mikrokomputerom typu Raspberry PI 4, Raspberry PI 5 lub LattePanda które umożliwiają użycie algorytmów SI, przy małym zużyciu energii.




Rys. 5. Przykład użycia biblioteki YOLOv7 z perspektywy BSP. Źródło: Opracowanie własne.

Jednym z przykładów komercyjnego bezzałogowego statku powietrznego (BSP), który wykorzystuje algorytm rozpoznawania obrazu, jest INI Trojan. Jest on głównie używany w misjach zwiadowczo-rozpoznawczych, wykorzystując sztuczną inteligencję (SI) do detekcji twarzy [14].

Sterowanie BSP w sytuacji zakłóceń


Jedną z popularnych metod niekinetycznego zwalczania bezzałogowych statków powietrznych (BSP) jest zagłuszanie, które dąży do uniemożliwienia komunikacji między operatorem drona a BSP. Mogą one również zakłócać sygnał GPS, utrudniając automatyczną nawigację. Takie zakłócenia mogą skutkować przejściem dronów przez wroga i utrudniać ich operowanie w strefie zagłuszenia. Aby zachować funkcjonalność BSP po utracie sygnału GPS, stosuje się systemy sterowania oparte na danych inercyjnych i wizualnych [15]. Sieć neuronowa zaimplementowana w układzie sterownia BSP, dokonuje rozpoznania i klasyfikacji charakterystycznych obiektów i na podstawie ich zmian w czasie (Rys. 6) (przemieszczenie, rozmiar) dokonuje oszacowania zmian aktualnej pozycji geograficznej. Obecnie wykorzystywane sposoby sterowania w pełni zagłuszonym dronem nie są w stanie zapewnić wysokiej precyzji estymacji pozycji, powodując często kilkudziesięciometrowe dryfy na kilometr przebytej drogi [16].



Rys.6. Przykład aktualnie wykorzystywanych systemów wizualnej odometrii w Bezzałogowych Systemach Powietrznych [17].

Automatyczne unikanie przeszkód i lądowanie

Większość bezzałogowych systemów powietrznych (BSP), zarówno komercyjnych jak i amatorskich, posiada możliwość automatycznego lotu po zaplanowanej ścieżce (ang. *path*) i wykonuje podstawowe zadania, takie jak obserwacja czy międzylądowania. Manewrowanie w dynamicznie zmieniającym się środowisku może jednak zwiększać ryzyko kolizji. W celu mitygacji ryzyka opracowano systemy detekcji i unikania przeszkód, które w czasie rzeczywistym identyfikują i klasyfikują przeszkody na trasie, umożliwiając korektę trasy lotu. Sieć neuronowa dokonując analizy obrazu otrzymywanego z kamery pokładowej, wykrywa i klasyfikuje znajdujące się na trasie przelotu potencjalne przeszkody następnie koryguje zaplanowaną trasę przelotu celem uniknięcia zderzenia (Rys. 7).



Rys. 7. Schemat wykrycia przeszkody przez BSP. Źródło: Opracowanie Własne.

Analogicznie, analiza obrazu jest stosowana do autonomicznej procedury lądowania bezzałogowych statków powietrznych (BSP). W komercyjnych zastosowaniach popularne są systemy typu "Drone in the box", gdzie dron współpracuje z bezstykową stacją lądującą. Drony te wykorzystują do lądowania kod ArUco

nadrukowany na stacji lądującej, umożliwiając precyzyjne pozycjonowanie [18]. Zastosowanie analizy obrazu do identyfikacji i wyboru miejsc lądowania w terenie, z uwzględnieniem takich czynników jak budynki, drogi, roślinność, nachylenie gruntu może zapobiegać uszkodzeniom BSP w przypadku awaryjnego lądowania po utracie łączności z operatorem.

Śledzenie celu

Jedną z głównych funkcji wykonywanych przez sieci neuronowe w analizie obrazu jest śledzenie obiektów. Proces ten rozpoczyna się od identyfikacji celu, po której następuje jego utrzymanie w polu widzenia kamery przy zachowaniu odpowiedniej odległości od obiektu. Do rozpoznawania obiektów używane są zaawansowane konwolucyjne modele sztucznej inteligencji, które charakteryzują szybkość przetwarzania i wysoka dokładność. Po zlokalizowaniu celu, dron obserwacyjny przełącza się w tryb śledzenia, nakładając na obiekt strefę wyznaczenia (ang. *bounding box*) definiującą jego kontury i utrzymując go w centrum pola kamery. System kontynuuje analizę zmian pozycji i rozmiaru tego okna niezależnie od ruchów BSP, co umożliwia oszacowanie trajektorii celu i generowanie komend sterujących dla jednostki kontrolującej lot. Dla poprawy funkcjonalności systemu śledzenia, niezbędna jest kamera stabilizowana, zdolna do samodzielnych ruchów względem BSP, co pozwala na ciągłe i precyzyjne monitorowanie celu.

Projekt amunicji krążącej z zaimplementowanym algorytmem rozpoznawania obrazu Swój-Wróg.

Koncepcji ta dotyczy budowy Bezzałogowego Statku Powietrznego (BSP) zdolnego do automatycznej identyfikacji i neutralizacji wybranych celów w wyznaczonym obszarze. System ten posiada możliwość wykonywania zadań bez nadzoru operatora, skutkuje to minimalizacją ryzyka dla niego poprzez odsunięcie jego od strefy zagrożenia. System ten blokuje ruch nieprzyjacielskich jednostek przez strategiczne punkty, takie jak mosty czy tunele, oferując bezpieczną alternatywę dla tradycyjnych pól minowych. Zaawansowany algorytm rozpoznawania obrazu umożliwia identyfikację przyjaciół i wrogów (FFI - *Friend-Foe Identification*). Efektorami tego systemu są niewielkie samobójcze BSP, tzw. kamikadze (jap. 神風, kamikaze) (Rys. 8), które mogą przenosić ładunki do 2 kg, co zapewnia efektywną neutralizację celów. Działa w pełni automatycznie, monitorując obszar za pomocą kamer, które mogą pochodzić z systemu lub innych źródeł. Uzyskany obraz poddawany jest analizie z wykorzystaniem sieci neuronowej, której zadaniem jest detekcja i identyfikacja celu. Zaimplementowana sieć przeznaczona jest do rozpoznania pojazdów, pozwalając dokonać klasyfikacji FF (Friend/Foe).



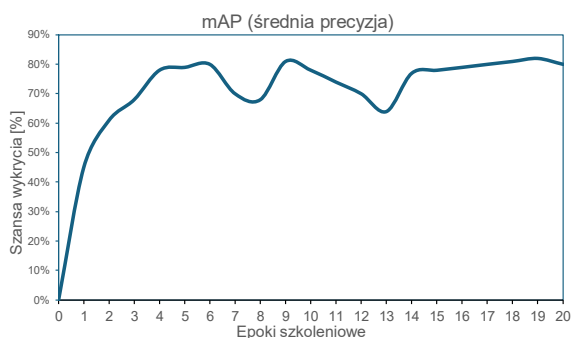
Rys. 8. Efektor systemu. Źródło: Opracowanie własne.

Identyfikacji celu wymusza przełączenie systemu w tryb śledzenia, w którym widok obiektu utrzymywany jest w centrum pola widzenia kamery, co umożliwi ciągłą obserwację i skuteczne namierzanie. Kamera wyposażona jest we wbudowany sensor pola magnetycznego (*kompas*) oraz dalmierz, które umożliwiają na dokładne określenie pozycji celu, a informacje o pozycji celu są przekazywane do BSP kamikadze, który wykonuje powierzone mu zadanie. Po zakończeniu zadania, system zostaje przywrócony do trybu obserwacyjnego, przygotowując się do kolejnych działań.



Rys. 9. Kamera systemu. Źródło: Opracowanie własne.

W systemie zaimplementowana została sztuczna inteligencja której zadaniem jest analiza obrazu, wykrycie oznaczeń pojazdów nieprzyjaciela oraz wskazanie ich w graficznym interfejsie użytkownika. SI wykorzystane w tym projekcie posiada zbiór danych treningowych składający się z 210 unikalnych obrazów, zestaw danych walidacyjnych składający się z 60 unikalnych obrazów oraz zestaw testowy składający się z 30. Obrazy poddane zostały procesowi obróbki wstępnej (ang. *preprocessing*) obejmującemu: auto orientacja obrazu oraz ustandaryzowane skalowanie rozdzielczości do 1920x1080px. Następnie zwiększono liczbę zbioru treningowego za pomocą rotacji o kąt $\pm 5^\circ$ zdjęć która umożliwiła rozszerzenie zbioru danych treningowych do 695 obrazów. SI została poddana nauczaniu przez dwadzieścia epok szkoleniowych w których dla zestawu danych walidacyjnych osiągnęła wyniki sięgające 80% szansy poprawnego wykrycia oznaczenia pojazdu (Rys.10).



Rys. 10. Wykres średniej precyzji SI. Źródło: Opracowanie własne.

Wnioski

W artykule przedstawiono przykłady implementacji sztucznej inteligencji w projektowaniu, budowie i eksploatacji Bezzałogowych Statków Powietrznych. Zaprezentowano systemy SI aktualnie wykorzystywane w produktach komercyjnych oraz w platformach o przeznaczeniu militarnym. Opisane zastosowania sieci

neuronowych prezentują szeroki zakres przypadków użycia i wskazują na tendencję rozwojową. Rozważa się implementację algorytmów sztucznej inteligencji w nowych dziedzinach m.in. badania uszkodzeń strukturalnych budynków wielopiętrowych czy detekcji oraz oznaczania potencjalnych lokalizacji pól minowych. Z uwagi na unikalne połączenie rozmiarów i zdolności nośnych BSP pozwalających na przenoszenie wszystkich wymaganych elementów podsystemów sztucznej inteligencji możliwe jest wykorzystywanie jej w zastosowaniach wcześniej niedostępnych.

Autorzy: inż. Jakub Grzesiak, dr inż. Krzysztof Górski, inż. Sebastian Szymański, mgr inż. Korneliusz Sierpowski, inż. Igor Mielczarek, Alan Kaspercak Akademia Wojsk Lądowych, Katedra Informatyki, ul. Czajkowskiego 109, 51-147 Wrocław, E-mail: jakub.grzesiak@awl.edu.pl, krzysztof.gorski@awl.edu.pl, sebastian.szysmański@awl.edu.pl, korneliusz.sierpowski@awl.edu.pl, igor.mielczarek@awl.edu.pl, s10044@edukacja.awl.edu.pl .

LITERATURA

- [1] Strona: <https://www.britannica.com/technology/artificial-intelligence/The-Turing-test> (z dn. 14.04.2023r.)
- [2] Strona: Sztuczna inteligencja: co to jest i jakie ma zastosowania? | Aktualności | Parlament Europejski (europa.eu) (z dn. 14.04.2023 r.)
- [3] Sarker I. H., Furhad M. H., Nowrozy R., AI-driven cybersecurity: an overview, security intelligence modeling and research directions, SN Computer Science, 2 (2021), 1-18.
- [4] Imanbayev, S. Tynymbayev, R. Odarchenko, S. Gnatyuk, R. Berdibayev, A. Baikenov, and N. Kaniyeva, Research of machine learning algorithms for the development of intrusion detection systems in 5G mobile networks and beyond, Sensors, 22 (2022), nr. 24, 9957.
- [5] Dokumentacja biblioteki <https://keras.io/about/> (z dn. 12.04.2024r.)
- [6] Palik M., Nagy M.: *A brief history of UAV development*, Repüléstudományi Közlemények 31(1) (2019), 155-166,
- [7] Blom, J. D. *Unmanned Aerial Systems: A Historical Perspective, Occasional Paper 37*, (2010).
- [8] Chávez, K. *Learning on the fly: Drones in the Russian-Ukrainian war*, Arms Control Today, 53(1) (2023), 6-11.
- [9] Sullivan, J. M. Evolution or revolution? The rise of UAVs. IEEE Technology and Society Magazine, 25(3), (2006), 43-49.
- [10] Rozporządzenie wykonawcze komisji (UE) 2019/947 w sprawie przepisów i procedur dotyczących eksploatacji bezzałogowych statków powietrznych.
- [11] Wpis użytkownika <https://twitter.com/Osinttechnical/status/1775336644637339829/photo/1> (z dn. 11.04.2024 r.)
- [12] Prisacariu V., A BRIEF HISTORY OF UAVs IN THE 1970s, Scientific Research & Education in the Air Force-AFASES, 2022
- [13] Chien-Yao W., Bochkovskiy A., Hong-Yuan M. L. *YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors*. (2022)
- [14] Strona producenta: <https://aeronautics-sys.com/systems/trojan/> (z dn. 25.04.2023 r.)
- [15] Krajník, T., Nitsche, M., Pedre, S., Přeučil, L., & Mejail, M. E., A simple visual navigation system for an UAV, (2012), In International Multi-Conference on Systems, Signals & Devices, IEEE, (pp. 1-6)
- [16] Jiang R., Klette R., Shigang W., Modeling of Unbounded Long-Range Drift in Visual Odometry, (2010).
- [17] Krul S., Pantos C., Frangulea M., Valente J. Visual SLAM for Indoor Livestock and Farming Using a Small Drone with a Monocular Camera: A Feasibility Study, (2021).
- [18] Khazetdinov A., Zakiev A., Tsoy T., Svinin M., Magid E., Embedded ArUco: a novel approach for high precision UAV landing, International Siberian Conference on Control and Communications (SIBCON), (2021).