

System detekcji i pozycjonowania bezzałogowych statków powietrznych

Streszczenie. W pracy przedstawiono projekt systemu służącego do detekcji i pozycjonowania bezzałogowych statków powietrznych na podstawie analizy próbek dźwiękowych z wykorzystaniem sztucznej inteligencji. Zaprezentowano przykładowy prototyp systemu działającego na polu walki, obrazującego na mapie wykryte źródła dźwięku.

Abstract. This paper presents the design of a system for the detection and positioning of UAVs based on the analysis of sound samples using artificial intelligence. An example prototype of the system operating on the battlefield, depicting detected sound sources on a map, is presented.. (Unmanned aircraft detection and positioning system).

Słowa kluczowe: Sieć neuronowa, zbieranie danych taktycznych, analiza dźwięku, bezzałogowe statki powietrzne
Keywords: Neural network, tactical data gathering, sound analysis, unmanned aerial vehicles

Wstęp

Mówi się, że wojna nigdy się nie zmienia, lecz metody jej prowadzenia podlegają ciągłej ewolucji. Nieustanny wyścig zbrojeń między sposobami walki a metodami obrony jest źródłem dynamicznego rozwoju technologicznego. Obserwując i analizując aktualne konflikty zbrojne, w szczególności trwającą wojnę ukraińsko-rosyjską, uwagę zwraca masowe wykorzystywanie bezzałogowych statków powietrznych (BSP) [1], na wszystkich szczeblach dowodzenia, od niewielkich dronów zwiadowczych, po ogromne maszyny zdolne do operowania na odległościach setek kilometrów. Zdominowały one niebo nad terenami objętymi działaniami zbrojnymi [2].

W odpowiedzi pojawiły się środki mające na celu przeciwdziałanie tej dominacji.

Analiza problemu i jego rozwiązania

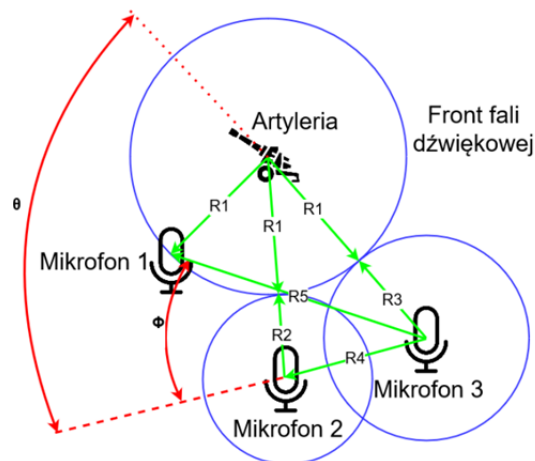
Konflikt za naszą wschodnią granicą spowodował wypracowanie metod użycia BSP w charakterze krótko zasięgowych bombowców taktycznych. Brak odpowiedniego sprzętu obrony przeciwlotniczej wraz z niewielkimi wymiarami jednostek latających sprawia, że przeciwdziałanie a nawet wykrycie takich ataków jest niezwykle trudne. Dostrzegając konieczność istnienia systemów wczesnego ostrzegania wzięto sobie za cel opracowanie i przetestowanie systemu pasywnego wykrycia obiektu latającego. W założeniu system ten nie powinien być skomplikowany w obsłudze a jednocześnie tani w produkcji i utrzymaniu. W wyniku własnych doświadczeń z zakresu projektowania i budowy bezzałogowych statków powietrznych, powstała koncepcja Systemu Wykrywania i Lokalizacji Dronów, wykorzystujący sieci neuronowe do analizy sygnałów dźwiękowych.

Podstawa teoretyczna i wstępne założenia

Na szerszą skalę dźwiękową lokalizację obiektów na polu bitwy zaczęto wykorzystywać w czasie pierwszej Wojny Światowej do wykrywania stanowisk wrogiej artylerii. Wtedy to zrodziła się koncepcja detekcji wykorzystująca system odpowiednio rozmieszczonych mikrofonów oraz uproszczone (na potrzeby szybkości działań) obliczenia matematyczne (rys.1) [3].

W trakcie obecnych konfliktów zbrojnych z uwagi na zwiększony zasięg artylerii i szybkość jej relokacji opisany sposób lokalizacji stał się nieużyteczny. Wykorzystać go można w zmodernizowanej formie, do wykrywania innego


typu obiektów emitujących charakterystyczne dźwięki np. BSP. Związane jest to ze znacznie mniejszymi odległościami, często poniżej 500 metrów, komparatywnie niskimi, w stosunku do prędkości dźwięku, szybkościami przelotowymi BSP jak i ich zwiększonej głośności przy przelotach [4]. W opracowanym systemie zastosowano uproszczony model ludzkiego słuchu w procesie analizy i przetwarzania sygnału dźwiękowego. Nie jest to rozwiązanie optymalne, uznano je jednak za wystarczające z uwagi na ogromną różnorodność dostępnych, fabrycznych oraz wyrabianych własnoręcznie, modeli BSP charakteryzujących się drastycznie różnymi cechami charakterystycznymi produkowanych dźwięków. W procesie analizy obrazu zastosowano konwulcyjną sieć neuronową, szeroko stosowaną w zadaniach klasyfikacyjnych [5].



Rys. 1. Schemat pozycjonowania artylerii wykorzystujący zestaw mikrofonów.


Schemat i zasada działania

Przedstawiony na rysunku 2 system pomiarowy powinien składać się z zestawu co najmniej trzech mikrofonów o charakterystyce oraz dobrej jakości rejestrowanego dźwięku, jednostki przetwarzającej dane w postaci systemu komputerowego zdolnego do analizy danych w czasie rzeczywistym oraz niezależnego źródła zasilania. Rejestratory rozmieszczone są w pięciometrowej odległości od siebie na stelażu o wysokości 2 m.



Rys. 2. Schemat rozmieszczenia rejestratorów dźwięku.

Aktualna iteracja systemu ma dwufazowy charakter działania według grafu przedstawionego na rysunku 3.

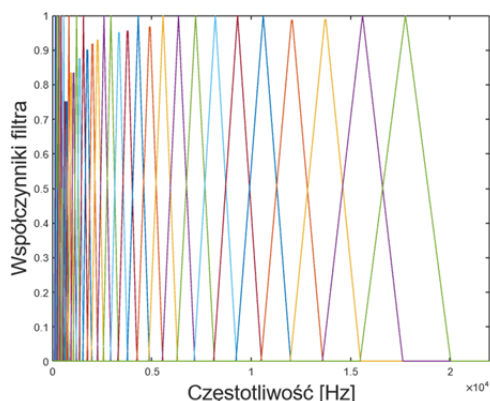


Rys. 3. Ogólny schemat działania systemu detekcji i pozycjonowania.

Pierwszy etap – detekcja – polega na analizie napływających próbek dźwiękowych celem wykrycia charakterystycznego dźwięku wytwarzanego przez obrót wirników w BSP. Do badania z wykorzystaniem sieci neuronowych przeznaczonych do analizy obrazów konieczne jest uzyskanie parametrów mel-cepstralnych (MFCC). W tym celu otrzymywany sygnał poddawany jest procesowi filtracji formującej osłabiającej dźwięki o niskich częstotliwościach i wzmacniającej te o wysokich. Odfiltrowany strumień poddawany jest ramkowaniu tj. podziałowi na krótkie poddane. Zastosowano proces nakładania się próbek (overlapping) celem poprawy jakości detekcji. Ramki okienkowane są z wykorzystaniem okna Hamminga (1) [6].

$$(1) Ham(N) = 0,54 - 0,46 \cdot \cos\left(2\pi \cdot \frac{n-1}{N-1}\right)$$

Gdzie: N - długość ramki, n = 1, 2, ... N



Rys. 4. Przykład filtra mel-cepstralnego

W kolejnym etapie wykorzystano szybką transformację Fouriera (FFT) dla uzyskania widma mocy i widma

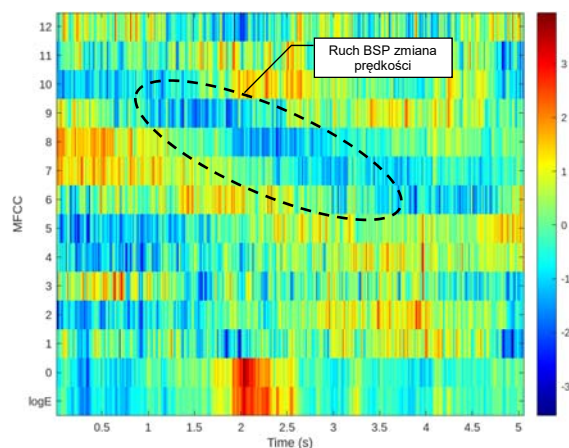
częstotliwościowego, które z kolei poddawane są działaniu zestawu filtrów w skali melowej (H_m). Zastosowano popularne filtry trójkątne o równomiernie rozmieszczonych środkach w danym zakresie częstotliwości (rys 4) [7].

Na wyjściu uzyskano energię pasma którą poddano działaniu logarytmu energii celem redukcji wrażliwości filtrów na bardzo głośne i bardzo ciche dźwięki, wymodelowaniu nieliniowej wrażliwości ucha ludzkiego oraz poprawę jakości rozpoznania. Ostatecznie zastosowano dyskretną transformatę cosinusową (DCT), pozwalającą na obliczenie wartości współczynników MFCC według poniższego wzoru (2) [8]:

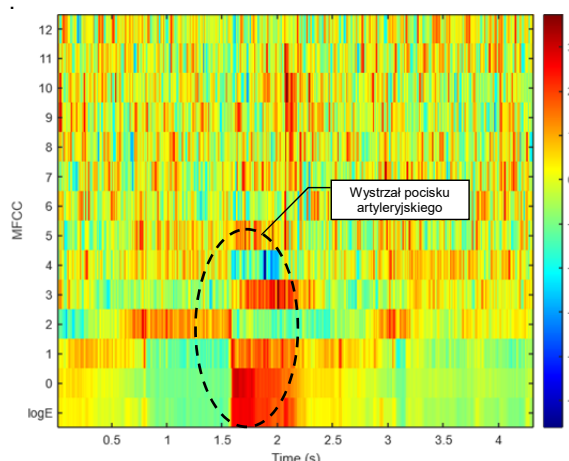
$$(2) c_i = \sqrt{\frac{2}{M}} \sum_{m=1}^M \log(S_m) \cdot \cos\left(\frac{\pi \cdot i}{M} (m - 0,5)\right)$$

Gdzie: i – numer współczynnika, M – liczba zastosowanych filtrów, S_m – energia pasma

Uzyskane w ten sposób spektrogramy MFCC przedstawione na rysunku 5 i rysunku 6, poddawane są analizie na wyuczonej, konwolucyjnej sieci neuronowej pozwalającej na określenie prawdopodobieństwa klasyfikacji danej próbki dźwiękowej jako zawierającej dowody obecności BSP.



Rys. 5. Parametry MFCC w domenie czasowo-częstotliwościowej, przyspieszenie BSP



Rys. 6. Parametry MFCC w domenie czasowo-częstotliwościowej, wystrzał pocisku artyleryjskiego

Kolejnym etapem działania systemu jest pozycjonowanie. Znając parametry rozmieszczeń mikrofonów (odległości i kąty między nimi) oraz różnicę w czasie odbioru ramek zawierających charakterystyczne momenty detekcji BSP (pierwsza detekcja, zmiany

prędkości) możemy obliczyć przybliżoną pozycję BSP, korzystając z równań trygonometrycznych. Przy wyznaczaniu należy pamiętać o zmiennej charakterystyce rozchodzenia się fal w zależności od warunków atmosferycznych, ciśnienia, temperatury i obecności przeszkód terenowych [9].

Realizacja praktyczna, analiza wyników

Proces praktycznej realizacji wykonania prototypu omawianego systemu rozpoczął się od utworzenia bazy uczącej dla sieci neuronowej. Z uwagi na utrudnienia w dostępności do rzeczywistych platform latających, konieczność zebrania znacznych ilości danych oraz zapewnienia szerokiej gamy symulowanych statków powietrznych, warunków pogodowych oraz terenowych postanowiono skorzystać z symulatora pola bitwy, opartego na elementach systemu VBS (Virtual Battle Simulator). Rozwiązanie to, w tym przypadku konieczne, jest dalekim od realistycznego oddania istotnych elementów świata rzeczywistego, takich jak chociażby modele propagacyjne fal dźwiękowych oraz wpływu środowiska na nie. Z tej przyczyny uzyskane wyniki powinny być traktowane jako pogładowe, pokazujące słuszność lub brak proponowanej idei. Do zbioru uczącego pozyskano próbki dźwiękowe o łącznym czasie trwania 241 minut, na które składały się nagrania zawierające dźwięki przelotów przy różnych warunkach pogodowych (75 minut), nagrania dźwięków tła (56 minut), nagrania dźwięków BSP w obecności źródeł zagłuszenia (64 minuty) oraz dźwięków źródeł zagłuszenia takich jak wybuchy, praca silników pojazdów mechanicznych (46 minut). Dodatkowo zebrano materiał do zbioru testowego o łącznym czasie trwania 31 minut. Uzyskane nagrania podzielone zostały na pięciosekundowe fragmenty które przeszły następnie proces konieczny do uzyskania parametrów mel-cepstralnych. Wyznaczenie odbyło się z użyciem oprogramowania MATLAB firmy Mathworks [10]. Zgromadzone dane zostały wykorzystane do nauczania konwolucyjnej sieci neuronowej opartej na bibliotece Tensorflow języka Python [11]. W wyniku testów uzyskano następujące rezultaty prawdopodobieństwa wykrycia, które przedstawiono w tabeli 1:

Tabela 1. Prawdopodobieństwo wykrycia BSP.

Szumy i zakłócenia	BSP	Prawdopodobieństwo wykrycia
Zakłócenia	Zawis	0,274
	Ruch	0,466
Bez zakłóceń	Zawis	0,682
	Ruch	0,873

Analizując uzyskane wyniki możemy wyciągnąć następujące wnioski. Konieczne jest zastosowanie lepszego filtrowania w procesie obróbki danych celem minimalizacji wpływu zakłóceń na próbkę. Ruch BSP, pociągający za sobą zmianę parametrów dźwięku, ułatwia detekcję poprzez izolację go od ogólnego szumu otoczenia i zakłóceń z innych źródeł dźwięku.

Badanie etapu pozycjonowania odbywało się z wykorzystaniem danych o najwyższym prawdopodobieństwie wykrycia. Uzyskane dane wykazały znaczące różnice w dokładności lokalizacji, zależnie od prędkości BSP, wysokości przelotu i odległości do systemu detekcyjnego. Uśrednione wyniki różnicy między położeniem rzeczywistym a wyliczonym przedstawiono w tabeli 2.

Tabela 2. Średnia różnica między pozycją rzeczywistą a wyliczoną.

Prędkość	Wysokość przelotu	Odległość od systemu		
		<50m	50-200m	>200m
< 80 km/h	<25m	2,4m	6,8m	23,9m
	25-50m	3,7m	9,9m	29,8m
	>100m	6,8m	14,5m	39,3m
> 80 km/h	<25m	1,7m	5,9m	18,7m
	25-50m	2,8m	8,2m	26,2m
	>100m	4,2m	10,9m	32,5m

Z uwagi na przyjętą metodę zbierania i analizy dźwięku oraz obliczania odległości uzyskujemy jedynie informację o azymucie i odległości do celu, nie uwzględniając elewacji. Prowadzi to do powstania przekłamań związanych z różnicą między odległością rzeczywistą w linii prostej a odległością między pozycjami geograficznymi. Prędkość lotu ma niewielki wpływ na dokładność lokalizacji, różnicę mogą wynikać z możliwości lepszego wyznaczenia porównawczego znacznika czasowego dla dźwięków o wyższej głośności. Największy wpływ na precyzję lokalizacji ma odległość od systemu badawczego. Efekt rozmycia fali dźwiękowej wraz z jej rozchodzeniem się w przestrzeni oraz wpływ przeszkód terenowych utrudnia precyzyjne określenie różnicy w czasie między sygnałami odbieranymi przez system mikrofonów (rys. 2).

Możliwe zastosowania systemu

Postępująca popularyzacja BSP, zarówno w przestrzeni cywilnej [12] jak i militarnej [13], stwarza konieczność implementacji metod ich neutralizacji. Proponowany system może znaleźć zastosowanie jako element omawianych rozwiązań w systemach wczesnego ostrzegania funkcjonujących w strefie działań wojennych. Wykrycie pojawienia się w przestrzeni powietrznej nieprzyjacielskiego statku powietrznego pozwoli wykorzystać odpowiednie środki zaradcze, obejmujące eliminację BSP, maskowanie obecności i zajęcie pozycji w schronach. Jest to szczególnie istotne w warunkach nadmiernego rozproszenia środków obrony przeciwlotniczej jakie możemy zaobserwować na przykładzie wojny ukraińsko-rosyjskiej. Popularyzacja BSP przyczyniła się do wykorzystania ich w charakterze środków przemytu nielegalnych towarów przez granicę. Szereg zestawów proponowanego systemu pozwoli na kontrolę przestrzeni powietrznej na niskim pułapie w niewralgicznych punktach granicy państwowej. Analogiczne działanie ochronne może zostać wdrożone w przypadku obiektów infrastruktury krytycznej, mogącej być celem działań rozpoznawczych prowadzonych przez osoby powiązane z nieprzyjawnymi rządami i instytucjami.

Autorzy: dr inż. Krzysztof Górski, Akademia Wojsk Lądowych, Katedra Zarządzania Innowacyjnymi Projektami, ul. Czajkowskiego 109, 51-147 Wrocław, E-mail: krzysztof.gorski@awl.edu.pl., Sebastian Szymański, Jakub Grzesiak, Akademia Wojsk Lądowych, Koło Naukowe Łączności i Elektroniki, E-mail: s9229@edukacja.awl.edu.pl, s9208@edukacja.awl.edu.pl

LITERATURA

- [1] Bellamy, C., *The evolution of modern land warfare: theory and practice*, (2015), Routledge.
- [2] D. Kunertova., *The war in Ukraine shows the game-changing effect of drones depend on the game*, 95-102, Infoma UK Limited.
- [3] Bateman H., *Mathematical theory of sound ranging*, Monthly Weather Review., 46(1), (1918), 4-11.
- [4] Biswas D., Su H., Wang C., Stevanovic A., *Speed estimation of multiple moving objects from a moving UAV platform*. ISPRS International Journal of Geo-Information, 8(6), (2019), 259.

- [5] Sultana F., Sufian A., Dutta P., *Advancements in image classification using convolutional neural network*. In 2018 Fourth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN), (2018, November), 122-129.
- [6] Sahidullah M., Saha G., *A Novel Windowing Technique for Efficient Computation of MFCC for Speaker Recognition*, IEEE Signal Processing Letters, vol. 20, no. 2, (2013 February), 149-152.
- [7] Paseddula C., Gangashetty S. V., *DNN based Acoustic Scene Classification using Score Fusion of MFCC and Inverse MFCC*, 2018 IEEE 13th International Conference on Industrial and Information Systems (ICIIS), (2018), Rupnagar, India, 18-21.
- [8] Hossan M. A., Memon S., Gregory, M. A., *A novel approach for MFCC feature extraction*. 2010 4th International Conference on Signal Processing and Communication Systems. (2010, December), 1-5.
- [9] Carrera E. V., Mena E., Arciniega P., Padilla A., Paredes M., *Analysis and Evaluation of Sound-based Positioning Techniques for Short Distances*, 2020 IEEE ANDESCON, (2020), Quito, Ecuador, 1-6.
- [10] Strona producenta: <https://www.mathworks.com/help/audio/ref/mfcc.html> [Dostęp z dnia 27.04.2023]
- [11] Raschka S., Mirjalili V., *Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2*, (2019), Packt Publishing Ltd.
- [12] Koldaev A. V. *Non-military UAV applications*. Aero India International Seminar-2007 Edition. (2007, February), Bangalore.
- [13] Muchiri G. N., Kimathi S., *A review of applications and potential applications of UAV*. Proceedings of the Sustainable Research and Innovation Conference. (2022, April), 280-283.