

Model systemu detekcji przeszkód i mapowania środowiska dla autonomicznych pojazdów podwodnych

Rafał Kot, Paweł Piskur, Norbert Sigiel

Akademia Marynarki Wojennej, Śmidowicza 69, 81-127 Gdynia, Polska

Streszczenie: W artykule przedstawiono model systemu detekcji przeszkód i mapowania środowiska, bazujący na przetwarzaniu obrazowym w czasie rzeczywistym, przeznaczony dla autonomicznego pojazdu podwodnego. Model został zrealizowany w oparciu o parametry pracy rzeczywistego sonaru z mechanicznym przestawianiem wiązki Tritech Micron Sonar. Działanie systemu detekcji zostało zweryfikowane z wykorzystaniem matematycznego modelu autonomicznego pojazdu podwodnego poruszającego się w środowisku podwodnym wyrażonym mapą testową przygotowaną na bazie rzeczywistych pomiarów zrealizowanych za pomocą ww. sonaru. Model systemu pozwala wykrywać i zapisywać w postaci mapy, przeszkody znajdujące się w polu widzenia sonaru w czasie rzeczywistym.

Słowa kluczowe: detekcja przeszkód, akwizycja danych, przetwarzanie zobrażeń sonarowych, autonomiczny pojazd podwodny, sonar

1. Wprowadzenie

W ostatnich latach obserwuje się wzrost wysiłków badawczych w zakresie uzyskania wysokiego poziomu autonomiczności pojazdów. Największe zainteresowanie wzbudzają technologie i systemy, które mogą być wykorzystane w motoryzacji. Z tego względu duża liczba dostępnej literatury z zakresu detekcji przeszkód dotyczy autonomicznych pojazdów naziemnych AGV (ang. *Autonomous Ground Vehicles*). Wysoki poziom autonomiczności wymagany jest również w bezzałogowych pojazdach powietrznych, tzw. dronach UAV (ang. *Unmanned Aerial Vehicles*). W przypadku projektów przeznaczonych dla pojazdów poruszających się w środowisku podwodnym, niewielka ich liczba związana jest z uzyskaniem pełnej autonomiczności działania w zakresie detekcji i unikania przeszkód. Środowisko podwodne charakteryzuje się specyficznymi parametrami, które powodują ograniczenia w zastosowaniu niektórych technologii wykorzystywanych z powodzeniem w środowisku naziemnym oraz powietrznym. Są to m.in. silne tłumienie sygnałów elektromagnetycznych oraz światła, co powoduje brak możliwości korzystania z rozwiązań radarowych, brak dostępu do systemu GPS oraz ograniczony zakres wykorzystania kamery w celu detekcji środowiska.

Mimo iż w literaturze można znaleźć przykłady rozwiązań systemów detekcji środowiska podwodnego opartych na systemach wizyjnych [1–4], to zasięg detekcji jest uzależniony od warunków środowiska (głębokość, zanieczyszczenie wody itp.) i wynosi maksymalnie kilkanaście metrów. W niektórych akwenach, do których można zaliczyć akwen Morza Bałtyckiego, zasięg detekcji wizyjnej ogranicza się do wartości nie większych niż 2–5 m. Dlatego w systemach detekcji przeszkód podwodnych najczęściej wykorzystuje się rozwiązania sonarowe [5], co zapewnia relatywnie duży zasięg (kilkadziesiąt-kilkaset metrów), dużą dokładność detekcji oraz odporność na zakłócenia. Tego typu rozwiązania mają jednak swoje ograniczenia związane z występowaniem zjawiska refrakcji fali akustycznej w akwenach płytkowodnych. Prawidłowa interpretacja zobrażeń sonarowych wymaga doświadczenia [6] oraz zastosowania odpowiednich metod przetwarzania obrazu. Z tego względu realizacja efektywnie działającego systemu detekcji przeszkód wymaga dogłębnej analizy w zakresie zastosowania czujnika percepcji środowiska oraz systemu akwizycji danych. Odpowiednie zestawienie tych dwóch elementów zapewnia skuteczne przygotowanie danych do dalszego przetwarzania w celu wykorzystania ich w systemach unikania kolizji, planowania trasy [7] oraz śledzenia trajektorii [8]. Dane otrzymane w wyniku detekcji oraz przetwarzania obrazowego mogą zostać wykorzystane również w celu wykrywania niewybuchów [9], min podwodnych [10] oraz uszkodzeń różnego rodzaju instalacji znajdujących się na dnie badanego zbiornika wodnego. W zastosowaniach militarnych od autonomicznych pojazdów podwodnych wymagane jest wykrywanie przeszkód i ich skuteczne omijanie. Z tego względu system detekcji przeszkód ma kluczowe znaczenie dla realizacji zaplanowanych misji podwodnych oraz wydajnego działania autonomicznego pojazdu w środowisku o zróżnicowanym stopniu komplikacji.

Autor korespondujący:

Rafał Kot, r.kot@amw.gdynia.pl

Artykuł recenzowany

nadesłany 24.08.2022 r., przyjęty do druku 11.10.2023 r.



Zezwala się na korzystanie z artykułu na warunkach licencji Creative Commons Uznanie autorstwa 3.0

Istnieją również pasywne rozwiązania do systemów wykrywania przeszkód [11–14]. Jednak mimo zalet hydrofonów, takich jak niskie zużycie energii i długi czas pracy, systemy takie dostarczają jedynie informacji o obecności przeszkody i kierunku nadejścia sygnału. W przypadku przeszkód, które nie emitują żadnych sygnałów, wykrycie obiektu jest niemożliwe. Ponadto tego typu metody są bardzo podatne na zakłócenia. Jeżeli AUV (ang. *Autonomous Underwater Vehicle*) porusza się w złożonym środowisku, takie metody mają ograniczone możliwości i mogą być stosowane tylko jako systemy pomocnicze lub systemy pasywnego rozpoznania (np. w zastosowaniach militarnych).

W artykule przedstawiono model systemu detekcji przeszkód i mapowania środowiska, bazujący na przetwarzaniu obrazowym, przeznaczony dla autonomicznego pojazdu podwodnego działający w czasie rzeczywistym. Model został zrealizowany w oparciu o parametry pracy rzeczywistego sonaru z mechanicznym przestawianiem wiązki Tritech Micron Sonar [16]. Działanie systemu detekcji zostało zweryfikowane z wykorzystaniem matematycznego modelu autonomicznego pojazdu podwodnego [15] poruszającego się w środowisku podwodnym, wyrażonym za pomocą mapy testowej, przygotowanej na bazie rzeczywistych pomiarów ww. sonarem.

Struktura artykułu jest następująca. Rozdział 2 zawiera opis koncepcji systemu detekcji przeszkód dla autonomicznych pojazdów podwodnych z wykorzystaniem sonaru. W rozdziale 3 zawarto opis modelu systemu detekcji przeszkód i mapowania otoczenia. W rozdziale 4 przedstawiono wyniki działania systemu. Końcowe wnioski zostały omówione w rozdziale 5.


2. Koncepcja systemu detekcji przeszkód

System detekcji przeszkód jest jednym z kluczowych elementów wyposażenia autonomicznych pojazdów podwodnych. Efektywność jego działania determinuje skuteczne i szybkie poruszanie się AUV w nieznanym środowisku, w obecności przeszkód. Pozyskiwanie i przetwarzanie danych w systemach detekcji przeszkód składa się z kilku etapów takich jak:

- Skanowanie środowiska,
- Wstępne przetwarzanie danych,
- Segmentacja,
- Ekstrakcja cech wykrytych obiektów.


Na etapie skanowania środowiska z wykorzystaniem sonaru bardzo istotny jest dobór odpowiednich parametrów detekcji takich jak rozdzielczość kątowna, rozdzielczość odległości, zasięg (determinowany częstotliwością pracy sonaru), próg detekcji oraz sektor pomiaru. Zbyt duża rozdzielczość zobrazowania sonarowego powoduje wydłużenie procesu przetwarzania danych, co ma bezpośredni wpływ na szybkość podejmowania decyzji przez AUV. Ustawienie zbyt niskiej rozdzielczości pomiaru może doprowadzić do sytuacji, w której mimo istnienia przeszkody nie zostanie ona wykryta ze względu na zbyt dużą odległość między sąsiednimi próbkami. Odpowiednio dobrany zasięg pomiarowy sonaru pozwala uniknąć odbić od powierzchni wody oraz od dna zbiornika wodnego, co może spowodować fałszywą detekcję obiektów. Dodatkowo odpowiednio dobrany próg wykrywania przeszkód pozwala uniknąć szumów powstających w procesie detekcji nie tracąc informacji o przeszkodach. Sektor pomiaru determinuje pole widzenia AUV w czasie poruszania się w środowisku podwodnym. Zobrazowanie sonarowe uzyskane w procesie detekcji jest zazwyczaj 8-bitową macierzą intensywności odbicia sygnału sondującego w funkcji odległości od nadajnika dla ustawionego sektora pomiarowego (Rys. 1).

Takie zobrazowanie w procesie wstępnego przetwarzania danych poddawane jest procesom filtracji w celu redukcji szumów powstałych w procesie detekcji. Najczęściej stosowana jest filtracja medianowa, uśredniająca albo z wykorzystaniem histogramu w określonym oknie danych, np. 5×5 pikseli (Rys. 2).




Rys. 1. Przykładowe zobrazowanie danych uzyskanych podczas pomiaru przeszkody w kształcie walca o średnicy 0,5 m i wysokości 0,5 m, dla zasięgu sonaru 10 m

Fig. 1. An example of data obtained measuring a cylindrical obstacle with a diameter of 0.5 m and a height of 0.5 m for a sonar range of 10 m




Rys. 2. Przykładowe zobrazowanie otrzymane po zastosowaniu filtracji uśredniającej w oknie 5×5 pikseli

Fig. 2. An example image obtained after applying averaging filtering in a 5×5 pixels window



Rys. 3. Przykładowe zobrazowanie otrzymane po zastosowaniu filtracji uśredniającej w oknie 5×5 pikseli oraz segmentacji progowej

Fig. 3. An example image obtained after applying averaging filtering in a 5×5 pixels window and threshold segmentation



Rys. 4. Przykładowe zobrazowanie otrzymane po zastosowaniu filtracji uśredniającej w oknie 5×5 pikseli, segmentacji progowej oraz algorytmu wyznaczania krawędzi


Fig. 4. An example image obtained after applying averaging filtering in a 5×5 pixels window, threshold segmentation and the edge determination algorithm

Algorytmy zastosowane na etapie wstępnego przetwarzania danych determinują efektywność działania operacji segmentacji. Odpowiednio przetworzone zobrazowanie poddawane jest operacji grupowania poszczególnych pikseli w zależności od zastosowanych algorytmów. Najczęściej w procesie segmentacji wykorzystuje się grupowanie pikseli na podstawie porównania ich wartości z ustawioną wartością progową. Jeśli intensywność analizowanego piksela jest mniejsza od wartości progowej, to jego wartość zmieniana jest na 0 (Rys. 3). Innym sposobem segmentacji może być tzw. klasteryzacja polegająca na grupowaniu pikseli na podstawie podobieństwa.

Kolejnym etapem jest ekstrakcja cech obiektów na podstawie zobrazowania uzyskanego w procesie segmentacji. W tym kroku wyodrębniane są cechy obiektów takie jak krawędzie (Rys. 4), kontury lub zajmowany obszar (Rys. 5).

Z punktu widzenia systemu detekcji przeszkód, współdziałającego z systemami unikania kolizji, najbardziej istotne będzie pozyskanie informacji o zajmowanym przez przeszkodę obszarze, co po dodaniu dodatkowej strefy bezpieczeństwa wokół niej powinno uniemożliwić kolizję. Zazwyczaj jest to realizowane za pomocą różnych operacji morfologii matematycznej, polegających na modyfikacji obrazu (wyrażonego np. w sposób binarny lub w skali szarości) w celu wydobycia cech obiektów lub zmiany ich kształtu i wielkości w zależności od zastosowanych wyrażeń matematycznych z wykorzystaniem elementów strukturalnych.

Podstawowe operacje morfologii matematycznej to dylatacja i erozja polegające odpowiednio na powiększaniu obiektów na obrazie przez wypełnienie pustych obszarów między pojedynczymi pikselami oraz zmniejszaniu obiektów w wyniku eliminacji pojedynczych pikseli lub małych grup. Inną często stosowaną operacją morfologii matematycznej jest otwieranie, które jest połączeniem erozji i dylatacji. Przeciwym procesem jest operacja zamykania, w której obraz początkowo poddawany jest dylatacji a następnie erozji. Przykład takiego sposobu przetwarzania obrazowego zobrazowań sonarowych został przedstawiony na Rys. 5. Tak przetworzone dane są następnie przekazywane do systemów sterowania autonomicznym pojazdem podwodnym w celu wyznaczenia trasy oraz wykonania manewrów unikania kolizji. Duża dokładność wyodrębniania cech obiektów w procesie przetwarzania obrazowego zapewnia możliwość wyznaczenia optymalnej trasy przemieszczania się AUV w nieznanym środowisku. Ze względu na to, że więk-



Rys. 5. Przykładowe zobrazowanie otrzymane po zastosowaniu filtracji uśredniającej w oknie 5×5 pikseli, segmentacji progowej oraz operacji dylatacji i zamykania

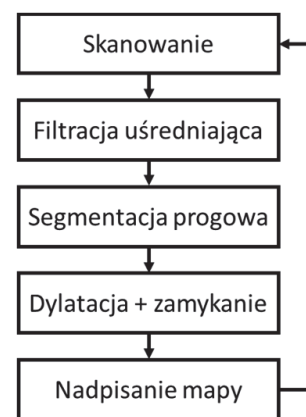
Fig. 5. An example image obtained after applying averaging filtering in a 5×5 pixels window, threshold segmentation and dilation and closure operations

szość technik wymaga sprawdzenia wartości każdego z pikseli i poddania ich operacjom matematycznym lub statystycznym, przetwarzanie obrazowe często wymaga dużej mocy obliczeń. Im bardziej złożona metoda tym większy czas przetwarzania. Aby działanie zaimplementowanych metod przetwarzania było odpowiednio dostosowane do warunków środowiskowych, niezbędne jest doświadczenie autora prezentowanego rozwiązania w analizie i interpretacji zobrazowań sonarowych.

3. Model systemu detekcji przeszkód i mapowania środowiska oparty na sonarze Tritech Micron Sonar

Ogólny schemat blokowy opracowanego systemu detekcji przeszkód i mapowania otoczenia został przedstawiony na Rys. 6. Kolejne etapy są realizowane w sposób iteracyjny.

Proces skanowania został opracowany z uwzględnieniem rzeczywistych parametrów sonaru Tritech Micron Sonar (Rys. 7) [16], przedstawionych w Tab. 1 oraz pomiarów w rzeczywistym zbiorniku wodnym realizowanych z wykorzystaniem ww. sonaru dla różnych konfiguracji parametrów.



Rys. 6. Schemat blokowy opracowanego systemu detekcji przeszkód i mapowania środowiska

Fig. 6. Block diagram of the developed obstacle detection and environmental mapping system

Sonary stosowane w autonomicznych pojazdach podwodnych do detekcji przestrzeni znajdującej się przed pojazdem FLS (ang. *Forward Looking Sonar*) najczęściej generują dużą liczbę wąskich wiązek pomiarowych (od kilkudziesięciu do kilku-set) w określonych odstępach kątowych, rejestrując dane zapewniające szerokie pole widzenia. Innym rozwiązaniem są sonary

z mechanicznym przesuwaniem generowanej wiązki w zależności od ustawionej rozdzielczości kątowej oraz sektora pomiarowego [16]. Ze względu na to, iż model systemu detekcji przeszkód i mapowania przestrzeni został opracowany dla jednego typu sonaru, a cały system został zintegrowany z modelem symulacyjnym autonomicznego pojazdu podwodnego [8], należało wziąć pod uwagę czas pojedynczego skanowania w zadanym sektorze, który determinowałby czas odświeżania przestrzeni przed pojazdem oraz czas dodawania kolejnych fragmentów przestrzeni do mapy budowanej na bieżąco w trakcie symulacji przemieszczania się autonomicznego pojazdu podwodnego zgodnie z zadaną trajektorią. W tym celu zrealizowano pomiary czasu skanowania sonaru Tritech Micron Sonar dla różnych konfiguracji parametrów, takich jak rozdzielczość kątowa, zasięg oraz sektor skanowania.

Tab. 1. Wybrane parametry sonaru Tritech Micron Sonar

Tab. 1. Tritech Micron Sonar specifications

Częstotliwość pracy	średkowa 700 kHz (chirp)
Szerokość wiązki	35° pionowo, 3° poziomo
Maksymalny zasięg	75 m
Minimalny zasięg	0,3 m
Rozdzielczość kątowa	0,45°, 0,9°, 1,8°, 3,6°
Sektor skanowania	regulowany do 360°
Zasilanie	12–48 V DC, 4 VA
Protokoły komunikacji	RS-485, RS-232
Głębokość pracy	750 m
Masa w powietrzu	0,32 kg
Masa w wodzie	0,18 kg
Temperatura pracy	-10 °C do 35 °C



Rys. 7. Tritech Micron Sonar
Fig. 7. Tritech Micron Sonar

Tab. 2. Wyniki pomiarów czasu pojedynczego skanowania w zależności od parametrów konfiguracyjnych sonaru Tritech Micron Sonar

Tab. 2. Single scan time measurement results depending on the Tritech Micron Sonar configuration parameters


Rozdzielczość kątowa: L = 3,6°, M = 1,8° H = 0,9°, U = 0,45°	Zasięg [m]	Sektor [°]	Przedział czasu skanowania [s]	
			min	max
L	5–60	40	0,98	1,35
L	5–60	60	1,41	1,83
L	5–60	80	1,93	2,52
L	5–60	100	2,37	3,00
M	5–60	40	1,71	2,50
M	5–60	60	2,48	3,32
M	5–60	80	3,23	4,31
M	5–60	100	4,08	5,51
H	5–60	40	3,49	4,56
H	5–60	60	5,29	7,73
H	5–60	80	7,32	10,00
H	5–60	100	9,09	13,65
U	5–60	40	5,92	8,74
U	5–60	60	8,97	13,58
U	5–60	80	12,50	19,11
U	5–60	100	16,01	24,57

W pierwszym etapie wykonano po 15 skanowań dla różnych wartości rozdzielczości kątowej ($3,6^\circ$, $1,8^\circ$, $0,9^\circ$, $0,45^\circ$), zasięgu (5 m, 10 m, 20 m, 30 m, 40 m, 50 m, 60 m) i sektora skanowania (40° , 60° , 80° , 100°), a następnie obliczono średnią wartość czasu skanowania. Na podstawie otrzymanych wyników (Tab. 2) określono rozdzielczość oraz sektor skanowania dla systemu detekcji przeszkód odpowiednio $3,6^\circ$ oraz 40° . W dalszej części doboru parametrów zdecydowano się ustawić zasięg detekcji na 20 m, co pozwalało na wykonanie pojedynczego skanowania w czasie 1,07 s. Dlatego w modelu symulacyjnym przyjęto, że zobrazowanie przestrzeni znajdującej się przed pojazdem będzie generowane co 1 s.

Na bazie przeprowadzonej analizy przyjęto, iż skanowanie otoczenia wokół AUV zostanie przeprowadzone zgodnie z poniższymi parametrami:

- rozdzielczość kątowa: $3,6^\circ$,
- sektor skanowania: $\pm 20^\circ$,
- zasięg: 20 m.

Każdy skan poddawany był procesowi filtracji uśredniającej w oknie 5×5 pikseli oraz segmentacji progowej na poziomie jasności pikseli 100 (wyrażonej w skali od 0 do 255, co odpowiada rzeczywistemu poziomowi ciśnienia akustycznego równemu $31,37 \text{ dB re } 1 \mu\text{Pa}$) w celu eliminacji zakłóceń oraz odbić od powierzchni i dna zbiornika wodnego. Następnie pojedyncze skanowanie poddawane było operacjom morfologii matematycznej, takim jak dylatacja oraz zamykanie z elementem strukturalnym w kształcie kwadratu o wymiarach 5×5 pikseli. Po wykonaniu pojedynczego skanowania (Rys. 8a) system otrzymuje fragment mapy, który po uwzględnieniu przetworzenia obrazowego zapisywany jest w pamięci. Kolejne fragmenty w odstępach 1 s są nadpisywane, tworząc mapę zawierającą zbiór lokalnych skanowań wokół pojazdu w obszarze, w którym przemieszczał się AUV (Rys. 8b).




Rys. 8. Przykład działania systemu mapowania przestrzeni: a) pojedynczy sonogram, b) zbiór wielu sonogramów

Fig. 8. An example of how mapping system works: a) a single sonogram, b) a set of many sonograms

4. Wyniki symulacji

W celu weryfikacji działania modelu systemu detekcji przeszkód i mapowania środowiska zbudowano mapę na podstawie pomiarów w rzeczywistym zbiorniku wodnym sonarem Tritech Micron Sonar (Rys. 9).

Sprawdzenie poprawności działania systemu detekcji przeszkód i mapowania przestrzeni zostało zrealizowane z wykorzystaniem matematycznego, nieliniowego, nieholonomicznego modelu symulacyjnego autonomicznego pojazdu podwodnego o kształcie torpedopodobnym wyposażonym w system śledzenia zadanej trajektorii w oparciu o regulator PID [8]. Rysunki 10 a-d przedstawiają kolejne etapy przetwarzania obrazowego realizowanego przez system detekcji przeszkód i mapowania otoczenia. W przeprowadzonej symulacji zamodelowany pojazd śledzi zadaną trajektorię z jednoczesnym skanowaniem i mapowaniem środowiska. Należy zaznaczyć, że cały proces przetwarzania obrazowego realizowany jest w czasie rzeczywistym podczas przemieszczania się pojazdu dla każdego pojedynczego skanowania.



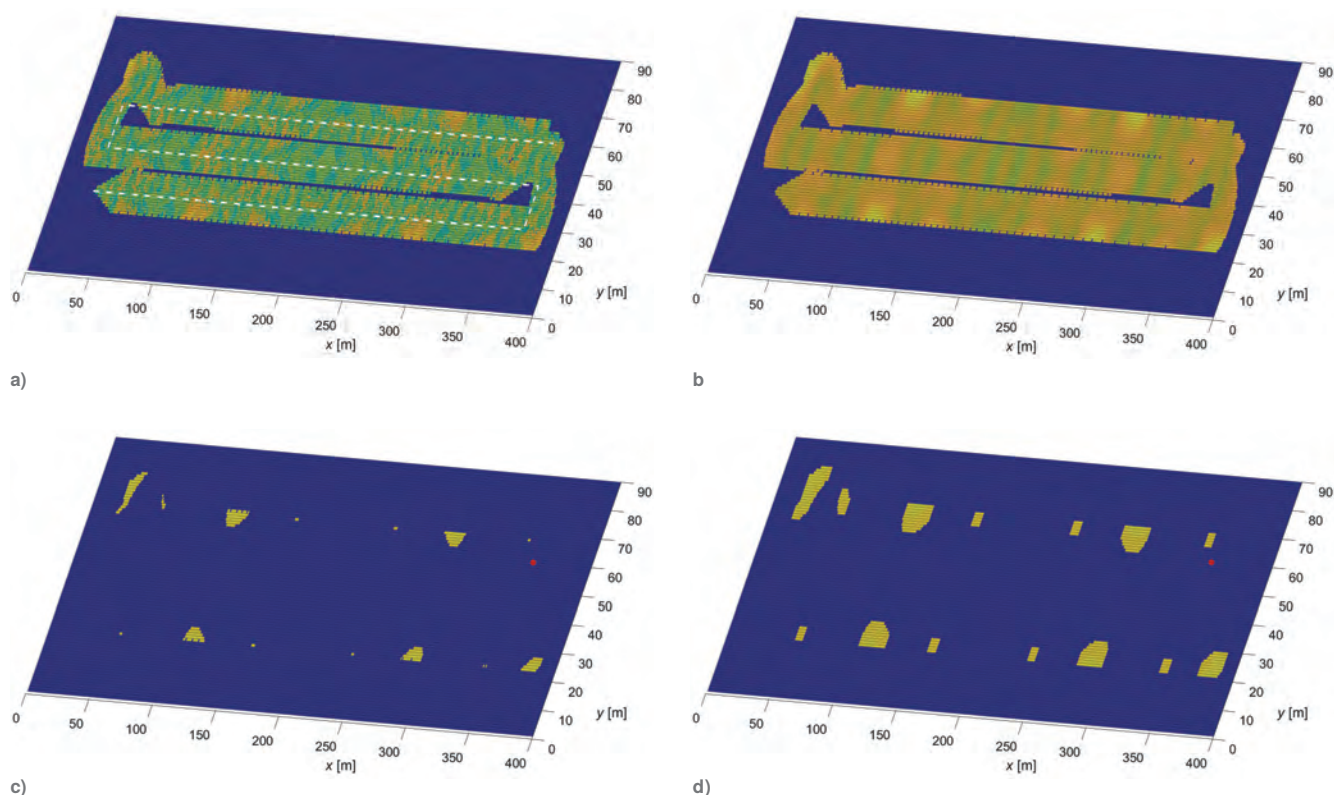
Rys. 9. Zobrazowanie mapy testowej oraz zadana trajektoria dla przemieszczającego się pojazdu (biała przerywana linia)

Fig. 9. Image of the test map and the given trajectory for the moving vehicle (white dashed line)

Czas obliczeń obejmujący przetwarzanie obrazowe oraz zapisanie wynikowego skanu w układzie współrzędnych tworzących mapę nie przekracza 0,01 s (Intel Core i5 10 gen, 1,60 GHz, 8 GB RAM, Win11 Home) co pozwala na działanie przedstawionego systemu detekcji przeszkód i mapowania środowiska czasie rzeczywistym. Przedstawiona na Rys. 10d mapa środowiska, otrzymana w wyniku działania systemu detekcji przeszkód i mapowania środowiska, potwierdza zdolność systemu do wyodrębniania przeszkód w środowisku podwodnym. Zobrazowanie uzyskane w wyniku zastosowanego przetwarzania obrazowego jest przystępne pod względem dalszego przetwarzania w systemach unikania kolizji, ponieważ nie zawiera pojedynczych pikseli oraz małych grup powodujących powstawanie lokalnego minimum w pobliżu przeszkody.

5. Wnioski

Opracowany model systemu detekcji przeszkód i mapowania środowiska pozwala wyodrębnić obszary, w których mogą znajdować się przeszkody, bazując na wartości sygnału odbitego od przeszkody. W wyniku przetwarzania obrazowego system wyznacza mapę przeszkód z uwzględnieniem dodatkowej strefy bezpieczeństwa. W przypadku gdy mapa uzyskana w wyniku działania systemu przekazywana jest do systemu unikania kolizji, dodatkowa strefa wokół przeszkód zapewnia wyznaczenie bezpiecznej trasy pozwalającej na bezkolizyjne manewrowanie w pobliżu przeszkód w przypadku wystąpienia np. prądów morskich. Ze względu na niewielki czas obliczeń niezbędny do wykonania operacji przetwarzania obrazowego model systemu



Rys. 10. Poszczególne etapy przetwarzania obrazowego dla środowiska wyrażonego mapą testową a) dane otrzymane w wyniku detekcji sonarem, b) obrazowanie uzyskane w wyniku zastosowania filtracji uśredniającej 5×5 pikseli, c) obrazowanie uzyskane w wyniku zastosowania segmentacji progowej (próg 31,37 dB re $1 \mu\text{Pa}$) obrazu poddanego filtracji uśredniającej, d) obrazowanie uzyskane w wyniku zastosowania dylatacji i zamykania dla obrazu powstałego w poprzednich etapach przetwarzania obrazowego

Fig. 10. Successive stages of image processing for the environment expressed by the test map a) image of the data obtained as a result of sonar detection, b) image obtained as a result of applying 5×5 px averaging filtering, c) image obtained as a result of applying threshold segmentation (threshold of 31.37 dB) of the image subjected to averaging filtering, d) image obtained as a result of applying dilation and closure to the image created in the previous stages of image processing

zapewnia detekcję obiektów w czasie rzeczywistym. Jednakże prawidłowe działanie systemu w dużej mierze zależy od zastosowanego progu segmentacji. W zależności od akwenu, w jakim porusza się AUV, próg segmentacji może wymagać wcześniejszego dostrajania lub zastosowania algorytmów realizujących dostrajanie progu segmentacji w sposób automatyczny. Z uwagi na powszechność wykorzystania sonaru Tritech Micron Sonar w systemach podwodnych eksploatowanych komercyjnie, jak i w działaniach militarnych, istnieje duży potencjał do implementacji wyników zaprezentowanych prac.

Podziękowania

Praca została sfinansowana przez firmę SR Robotics w ramach projektu z Programu Operacyjnego Inteligentny Rozwój 2014–2020, tzw. „Szybkiej Ścieżki” pt. „Opracowanie innowacyjnej metodyki badania środowiska wodnego z wykorzystaniem formacji autonomicznych pojazdów podwodnych oraz sztucznej inteligencji do identyfikacji i klasyfikacji ferromagnetycznych obiektów niebezpiecznych” nr POIR.01.01.01-00-1088/20. Praca realizowana była w Ośrodku Technologii Morskich Akademii Marynarki Wojennej w latach 2021–2022 w ramach umowy między firmą SR Robotics a Akademią Marynarki Wojennej.

Bibliografia

1. Szymak P., Piskur P., Naus K., *The Effectiveness of Using a Pretrained Deep Learning Neural Networks for Object Classification in Underwater Video*, “Remote Sensing”, Vol. 12, No. 18, 2020, DOI: 10.3390/rs12183020.
2. Hożyń S., Żak B., *Stereo Vision System for Vision-Based Control of Inspection-Class ROVs*, “Remote Sensing”, Vol. 13, No. 24, 2021, DOI: 10.3390/rs13245075.
3. Xanthidis M., Karapetyan N., Damron H., Rahman S., Johnson J., O’Connell A., O’Kane J.M., Rekleitis I., *Navigation in the Presence of Obstacles for an Agile Autonomous Underwater Vehicle*, 2020 IEEE International Conference on Robotics and Automation (ICRA), Paris, France, 2020, 892–899, DOI: 10.1109/ICRA40945.2020.9197558.
4. An R., Guo S., Zheng L., Hirata H., Gu S., *Uncertain moving obstacles avoiding method in 3D arbitrary path planning for a spherical underwater robot*, “Robotics and Autonomous Systems”, Vol. 151, 2022, DOI: 10.1016/j.robot.2021.104011.
5. Kot R., *Review of Obstacle Detection Systems for Collision Avoidance of Autonomous Underwater Vehicles Tested in a Real Environment*, “Electronics”, Vol. 11, No. 21, 2022, DOI: 10.3390/electronics11213615.
6. Zieja M., Wawrzyński W., Tomaszewska J., Sigiel N., *A Method for the Interpretation of Sonar Data Recorded during Autonomous Underwater Vehicle Missions*, “Polish

- Maritime Research”, Vol. 29, No. 3, 2022, 176–186, DOI: 10.2478/pomr-2022-0038.
7. Kot R., *Review of Collision Avoidance and Path Planning Algorithms Used in Autonomous Underwater Vehicles*, “Electronics”, Vol. 11, No. 15, 2022, DOI: 10.3390/electronics11152301.
 8. Szymak P., Kot R., *Trajectory Tracking Control of Autonomous Underwater Vehicle Called PAST*, “Pomiary Automatyka Robotyka”, Vol. 26, No. 3, 2022, 17–22, DOI: 10.14313/PAR_245/17.
 9. Wawrzyński W., Zieja M., Żokowski M., Sigiel N., *Optimization of autonomous underwater vehicle mission planning process*, „Bulletin of the Polish Academy of Sciences: Technical Sciences Bulletin of the Polish Academy of Sciences: Technical Sciences”, Vol. 70, No. 2, 2022, DOI: 10.24425/BPASTS.2022.140371.
 10. Hożyń S., *A Review of Underwater Mine Detection and Classification in Sonar Imagery*, “Electronics”, Vol. 10, No. 23, 2021, DOI: 10.3390/electronics10232943.
 11. Piskur P., Gąsiorowski M., *Digital Signal Processing for Hydroacoustic System in Biomimetic Underwater Vehicle*, “Nase More”, Vol. 67, No. 1, 2020, 14–18, DOI: 10.17818/nm/2020/1.3.
 12. Szymak P., Piskur P., *Measurement system of biomimetic underwater vehicle for passive obstacles detection*, Proceedings of the 18th International Conference on Transport Science, ICTS, 2018.
 13. Piskur P., Szymak P., *Algorithms for passive detection of moving vessels in marine environment*, “Journal of Marine Engineering & Technology”, Vol. 16, No. 4, 2017, 377–385, DOI: 10.1080/20464177.2017.1398483.
 14. Piskur P., Szymak P., Jaskólski K., Flis L., Gąsiorowski M., *Hydroacoustic system in a biomimetic underwater vehicle to avoid collision with vessels with low-speed propellers in a controlled environment*, “Sensors”, Vol. 20, No. 4, 2020, DOI: 10.3390/s20040968.
 15. Szymak P., *Zorientowany na sterowanie model ruchu oraz neuro-ewolucyjno-rozmyta metoda sterowania bezzalogowymi jednostkami pływającymi*. Politechnika Krakowska, 2015.

Inne źródła

16. Tritech Ltd., *Micron Sonar – Product Manual*, No. 04, [www.tritech.co.uk/files/Manuals/Hardware-Manuals/0650-SOM-00003-04a-Micron-Sonar-Manual.pdf].

Simulation Model of Obstacle Detection and Mapping System for AUVs

Abstract: This article presents a real-time model of an obstacle detection and environmental mapping system based on image processing for an autonomous underwater vehicle (AUV). The model was based on Tritech Micron Sonar operating parameters with mechanical beam adjustment. The operation of the detection system was verified using a mathematical model of an autonomous underwater vehicle moving in the underwater environment, expressed by a test map prepared based on actual measurements of the above-mentioned sonar. The system model allows for detecting and mapping obstacles in the sonar’s field of view in real-time.

Keywords: obstacle detection, data acquisition, sonar image processing, autonomous underwater vehicle, AUV

kpt. mar. mgr inż. Rafał Kot

r.kot@amw.gdynia.pl

ORCID: 0000-0002-9273-353X

Absolwent Wojskowej Akademii Technicznej w Warszawie. W 2016 r. uzyskał tytuł magistra na kierunku Elektronika i Telekomunikacja. Przez prawie 6 lat pracował w Bazie Lotnictwa Marynarki Wojennej, gdzie zdobywał doświadczenie w obsłudze i serwisie statków powietrznych w obszarze awioniki. Od 2022 r. pracuje w Akademii Marynarki Wojennej. Jego główne obszary zainteresowań obejmują systemy detekcji przeszkód, algorytmy planowania trasy oraz systemy unikania kolizji dla autonomicznych pojazdów podwodnych.



kmr ppor. dr inż. Paweł Piskur

p.piskur@amw.gdynia.pl

ORCID: 0000-0002-8823-4316

Ukończył Wojskową Akademię Techniczną w Warszawie w 2004 r. uzyskując tytuł magistra inżyniera na Wydziale Mechatroniki, profil dyplomowania osprzęt samolotów i śmigłowców. Następnie pracował w Bazie Lotniczej Marynarki Wojennej. W 2010 r. uzyskał stopień doktora inżyniera na Politechnice Koszalińskiej. Od 2017 r. pracuje w Akademii Marynarki Wojennej. Jego obszar badawczy jest ściśle związany z bezałogowymi pojazdami podwodnymi, zwłaszcza biomimetycznymi układami napędowymi.



kpt. mar. dr inż. Norbert Sigiel

n.sigiel@amw.gdynia.pl

ORCID: 0000-0001-6184-1063

W 2014 r. ukończył studia na kierunku nawigacja w Akademii Marynarki Wojennej. Służąc na okrętach przeciwminowych proj. 206FM, 207M, 207P, 258-Kormoran, wielokrotnie uczestniczył w operacjach rozminowania wód Bałtyku oraz Morza Północnego, w tym w ramach działań Stałego Zespołu Sił Odpowiedzi NATO (SNMCMG1). Od 2016 r. uczestniczył w procesie wdrażania do służby okrętów proj. 258-Kormoran, m.in. systemów autonomicznych oraz zdalnie sterowanych przeznaczonych do działań przeciwninowych. W 2021 r. uzyskał stopień naukowy doktora w Instytucie Technicznym Wojsk Lotniczych. Od 2023 r. pracuje w Akademii Marynarki Wojennej. Jego obszar badawczy jest ściśle związany z wykorzystaniem systemów autonomicznych oraz zdalnie sterowanych do detekcji, klasyfikacji, identyfikacji i niszczenia podwodnych obiektów niebezpiecznych UXO (ang. Unexploded Ordnance).

