

Mariusz Matejski, Mariusz Dramski

dr inż. Mariusz Matejski
Politechnika Szczecińska, Katedra Maszyn Ciepłych i Siłowni Okrętowych
71 – 065 Szczecin al. Piastów 41
tel.: +91 449-41-63
e-mail: matmar@ps.pl

dr inż. Mariusz Dramski
Uniwersytet Kazimierza Wielkiego w Bydgoszczy
Wydział Matematyki, Fizyki i Techniki
Instytut Techniki
85-064 Bydgoszcz ul. Chodkiewicza 30
tel. 052 3419331
e-mail: mdramski@ukw.edu.pl (instytutowy - insttech@ukw.edu.pl)

**MODELOWANIE RUCHU POJAZDU TYPU ROV
W PŁASZCZYŹNIE PIONOWEJ Z WYKORZYSTANIEM SIECI
NEURONOWYCH**

Modelowanie ruchu bezzałogowych pojazdów podwodnych może być efektywnie realizowane z użyciem sieci neuronowych zdolnych do zilustrowania tego procesu. W tym artykule przedstawiono sposób budowania sieci neuronowych oraz proces ich nauczania. Wszystkie eksperymenty przeprowadzono na WTM/PS na pojeździe podwodnym typu ROV - KRAB.

Słowa kluczowe: modelowanie ruchu bezzałogowych pojazdów podwodnych, sieci neuronowe

**MODELLING OF THE MOVEMENT OF ROV VEHICLE IN
VERTICAL PLANE USING NEURAL NETWORKS**

Modeling of the move of unmanned underwater vehicles can effectively be realized with use of neural networks capable to illustrate the modeled process. In this paper a method of a construction of neural networks and a learning process is presented. All experiments were carried out at the Faculty of Maritime Technologies of Szczecin University of Technology on the underwater vehicle ROV type - KRAB.

Keywords: modeling of the move of unmanned underwater vehicles, neural networks

WSTĘP

Na Wydziale Techniki Morskiej Politechniki Szczecińskiej prowadzone są badania dotyczące sterowania ruchem zdalnie sterowanych pojazdów podwodnych typu ROV (Remote Operated Vehicles).

Ich pierwszy etap obejmował próby basenowe, w trakcie których zbierane i rejestrowane były dane dotyczące położenia pojazdu w toni wodnej w trakcie ruchu po realizowanej trajektorii przy jednoczesnej rejestracji sygnałów sterujących dla poszczególnych pędników pojazdu i wskazań czujnika głębokości. Zostały one wykorzystane do stworzenia neuronowych modeli ruchu pojazdu za pomocą sieci neuronowych.

Obiektem badań był zdalnie sterowany pojazd podwodny KRAB wchodzący w skład systemu SWOT (System Wykrywania Obiektów Technicznych). Badania przeprowadzono w basenie technologicznym WTM o wymiarach 20 x 6 x 5m [5].

1. CHARAKTERYSTYKA TECHNICZNA OBIEKTU BADAŃ, JAKIM JEST SYSTEM SWOT (SYSTEM WYKRYWANIA OBIEKTÓW TECHNICZNYCH)

System SWOT został zbudowany w latach 1991-92 i w latach późniejszych przeszedł wiele modernizacji. Był również obiektem badań związanych z teorią ruchu bezzałogowych zdalnie sterowanych pojazdów podwodnych, zagadnieniami monitoringu środowiska i wielu innych.[1]

W skład Systemu SWOT wchodzi dwa obiekty:

- Podwodny nośnik aparatury KRAB
- Mobilne Stanowisko Sterowniczo-Badawcze.


1.1. PODWODNY NOŚNIK APARATURY

Nośnik podwodny KRAB (typu ROV) zbudowany jest z anodyzowanych rur aluminiowych stanowiących przestrzenną konstrukcję ramową. Wyposażenie jest umieszczone w pojemnikach ciśnieniowych. Podobne pojemniki zostały zastosowane jako moduły wypornościowe.

Ze względu na ograniczenie obszaru penetracji wód Bałtyku do jego strefy przybrzeżnej głębokość robocza nośnika wynosi 150m. Prędkość postępową wynoszącą 1,5 m/s zapewniają dwa pędniki wzdłużne generujące siłę 135,97 N. Nośnik posiada również dwa pędniki poprzeczne generujące sumarycznie siłę na prawą burtę 92,21 N, na lewą burtę 42,46 N. Silniki te zapewniają również obrót nośnika wynoszący 30°/s. Pędnik pionowy usytuowany centralnie generuje siłę 40,42N (przy zanurzaniu) oraz 21,73N (przy wynurzeniu) i zapewnia maksymalną prędkość zanurzania wynoszącą 0,2235 m/s i prędkość wynurzenia 0,205m/s [1].

1.2. DANE TECHNICZNE POJAZDU „KRAB”

głębokość operacyjna	150 m
prędkość pojazdu (wzdłużna)	1,5 m/s
prędkość obrotu	30 °/s
pływalność kabloliny	około 0 N/m
długość kabloliny	150m
ilość pędników	5
poziome wzdłużne	2
poziome poprzeczne	2
pionowy	1
zasilanie	220 V/50Hz
wymiary	1200 x 760 x 600mm
ciężar w powietrzu	70 kG



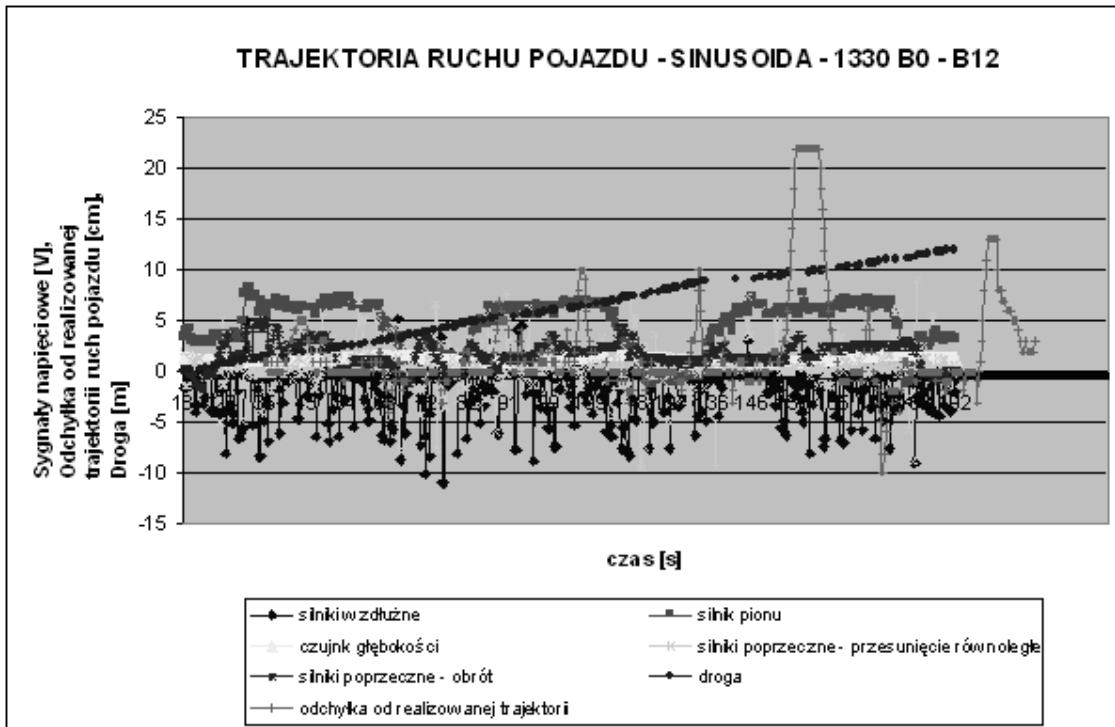
Fot.1 Pojazd podwodny KRAB przed wodowaniem oraz jego widok w basenie technologicznym WTM

2. MODEL NEURONOWY RUCHU POJAZDU „KRAB” W PŁASZCZYŹNIE PIONOWEJ

2.1 OKREŚLENIE ZBIORÓW DANYCH UCZĄCYCH I TESTUJĄCYCH

W artykule, (ze względu na objętość) przedstawiono przykładowy model neuronowy ruchu pojazdu KRAB w płaszczyźnie pionowej po sinusoidzie.

Jako sekwencje treningowe posłużyły dane pomiarowe uzyskane w wyniku przeprowadzonych eksperymentów przedstawione na wykresie 1. Częstotliwość próbkowania pozwalała na zarejestrowanie ok. 4 próbek na sekundę. Wykres przedstawia sygnały zarejestrowane od 18 sekundy, to jest od momentu gdy pojazd znalazł się na odcinku pomiarowym. Z wykresu wynika, że odchyłki od zadanej trajektorii ruchu były stosunkowo niewielkie i maksymalnie osiągnęły w przypadku prezentowanego przebiegu wartość 10cm. Można jednak stwierdzić, że dokładność odwzorowania trajektorii ruchu realizowana przez operatora była dobra.



Wykres 1. Przebieg zmian napięcia: sterującego pędnikami pojazdu KRAB i generowanego przez czujnik głębokości oraz odchyłka od realizowanej trajektorii ruchu w funkcji czasu podczas ruchu pojazdu po sinusoidzie. Długość odcinka pomiarowego 12m.

W celu przeprowadzenia poprawnego procesu uczenia sieci dokonano wyboru danych uczących i testujących. Z 10 zbiorów danych pomiarowych uzyskanych w trakcie realizacji analizowanej trajektorii ruchu na basenie technologicznym WTM wybrano 7 zbiorów i podzielono na zbiory uczące i testujące w stosunku 4:3 (przeciętnie w lit.[2] przyjmuje się podział 7:3). Przy wyborze kierowano się prawidłowością odwzorowania trajektorii ruchu i kompletnością danych. Wybierano przy tym przebiegi, które w możliwie pełnym stopniu odwzorowywały badane zjawisko, czyli trajektorię ruchu.

Przebiegi realizowane były przez tego samego operatora – eksperta, który wcześniej realizował podobne zadania.

2.2 OKREŚLENIE STRUKTURY SIECI

Kolejnym krokiem pozwalającym na stworzenie modelu neuronowego ruchu w płaszczyźnie pionowej po sinusoidzie było określenie struktury sieci. Na dzień dzisiejszy nie ma żadnych jednoznacznych reguł takiego postępowania [1],[3],[5]. Można więc stwierdzić, że dobór struktury sieci i jej wewnętrznych połączeń wymaga odpowiedniego doświadczenia i intuicji [3][5]. Istnieje jednak kilka zasad, które nie są wprawdzie udowodnione naukowo, jednakże doświadczenie i dotychczasowe rezultaty badań nad sieciami neuronowymi pozwoliły na uzyskanie pewnych reguł.

Do rozwiązania opisanego problemu wybrano sieć perceptronową z jedną warstwą ukrytą. Liczba warstw ukrytych może być różna, ale nadmierna ich ilość może prowadzić do poważnego skomplikowania obliczeń i przeuczenia sieci. Nawet jeśli sieć zostanie nauczona prawidłowo to i tak efekt ten nie będzie warty poniesionych nakładów. Jak dotąd większość rozwiązań opartych na sieci perceptronowej działa


znakomicie przy zastosowaniu jednej bądź dwóch warstw ukrytych. Bardzo rzadko można znaleźć w literaturze rozwiązania z większą liczbą warstw ukrytych.

Liczba neuronów w warstwie wejściowej jest zawsze równa liczbie wejść badanego systemu. Analogicznie ma się sytuacja w warstwie wyjściowej. Inaczej natomiast szacuje się liczbę neuronów w warstwie ukrytej. Przyjęto się dwie metody postępowania – progresywną i regresywną. W pierwszej z nich zaczyna się od bardzo małej liczby neuronów, a następnie dodaje się kolejne. Proces powtarza się dopóki nie uzyska się satysfakcjonujących odpowiedzi sieci. Metoda regresywna zaś, oznacza dokładnie odwrotne postępowanie [6].

Wskutek eksperymentów wielu badaczy oszacowano jednak, że liczba neuronów w warstwie ukrytej zwykle stanowi średnią geometryczną liczby wejść i wyjść systemu. Czasem dokonuje się niewielkiej korekty poprzez dodanie lub odjęcie jednego lub kilku neuronów.

Do eksperymentów wybrano zatem sieć perceptronową z jedną warstwą ukrytą.

Podstawą może być stwierdzenie spotykane w literaturze [3], [6], że perceptron wielowarstwowy o trzech warstwach (warstwa wejściowa, warstwa ukryta i warstwa wyjściowa) realizuje odwzorowanie dowolnej przestrzeni X w dowolną przestrzeń Y w postaci $X \rightarrow Y$. Tak skonfigurowaną sieć, która będzie podstawą tworzenia modeli ruchu pojazdu w płaszczyźnie pionowej, przedstawia schemat 1.




Schemat 1. Schemat sieci neuronowej z neuronami sigmoidalnymi i neuronem liniowym w warstwie wyjściowej .

Przeprowadzono eksperymenty z różną ilością neuronów (rozpoczynając od 30). Uzyskane wyniki ulegały stopniowej poprawie. Przy 20 neuronach uzyskano wyniki technicznie akceptowalne.

Do budowy sieci neuronowej wykorzystano równanie różnicowe wyprowadzone z modelu liniowego ruchu pojazdu w płaszczyźnie pionowej za pomocą metody dyskretyzacji ZOH. [4]

W modelu tym brane są pod uwagę sygnały napięciowe z czujnika głębokości, wartości przebytej przez pojazd drogi, sygnały sterujące silnikiem głębokości oraz silnikami napędu wzdłużnego. Sieć neuronową zbudowaną w oparciu o przedstawione założenia przedstawiono na schemacie 2.




Schemat 2. Schemat blokowy sieci neuronowej reprezentującej neuronowy model ruchu pojazdu KRAB po sinusoidzie gdzie:

- $p(k-1)$ – napięcie sterujące pędnika głębokości w kroku **k-1**
- $p(k-2)$ – napięcie sterujące pędnika głębokości w kroku **k-2**
- $z(k-1)$ – napięcie z czujnika głębokości w kroku **k-1**
- $z(k-2)$ – napięcie z czujnika głębokości w kroku **k-2**
- $z(k)$ – napięcie z czujnika głębokości w kroku **k**
- $r(k-1)$ – napięcie sterujące pędników wzdłużnych w kroku **k-1**
- $r(k-2)$ – napięcie sterujące pędników wzdłużnych w kroku **k-2**
- $s(k-1)$ – wielkość przebytej drogi w kroku **k-1**
- $s(k-2)$ – wielkość przebytej drogi w kroku **k-2**
- $s(k)$ – wielkość przebytej drogi w kroku **k**

Wartości napięcia sterującego pędników wzdłużnych i pędnika pionu zarejestrowano w trakcie przeprowadzonych eksperymentów na basenie technologicznym WTM. Wielkość przebytej drogi określono na podstawie obrazu zarejestrowanego na magnetowidzie za pośrednictwem kamery wizyjnej. Pomocnym w tym przypadku było zsynchronizowanie kamery ze znacznikiem laserowym, którego plamka w sposób jednoznaczny określała położenie pojazdu w stosunku do siatki pomiarowej naniesionej na ścianie basenu. Odpowiednia konwersja tych danych pomiarowych szeregująca je według kroków k , $k-1$, $k-2$, została przeprowadzona w oparciu o program komputerowy.

Jak ze schematu blokowego wynika, na wejściu sieci wprowadzane są dane umieszczone w macierzy ośmiowierszowej i stąd warstwa wejściowa składa się z ośmiu wejść i ośmiu neuronów. W warstwie wyjściowej, ze względu na wartość liczbową sygnału wyjściowego umieszczono dwa neurony liniowe obsługujące macierz dwuwierszową. Warstwa ukryta składa się z dziesięciu neuronów. Sieć zaprojektowano w programie MATLAB. Struktura sieci przedstawiona została na schemacie blokowym 2.

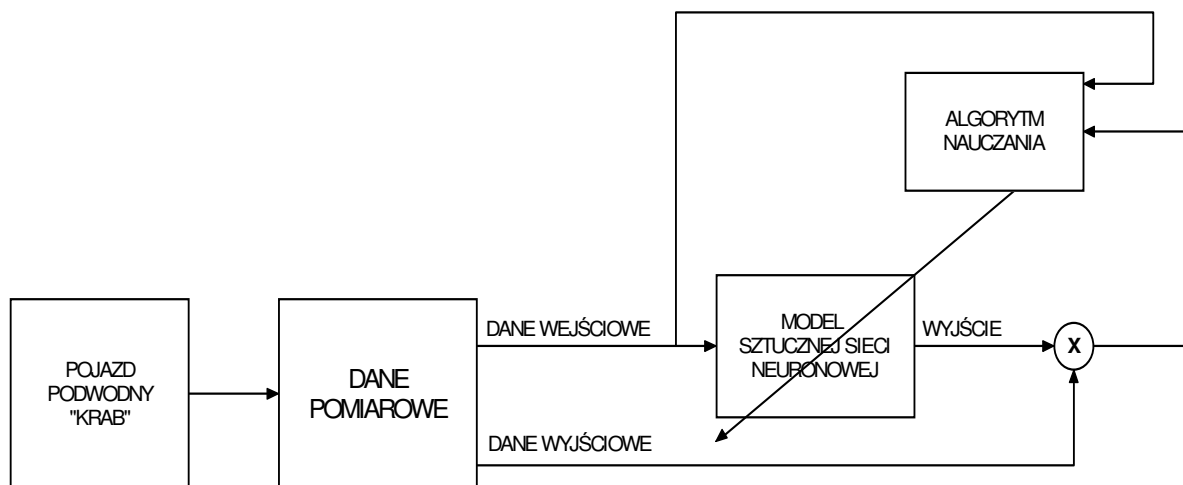


Schemat 3. Schemat blokowy struktury sieci neuronowej (Sieć 1S_3C) – model pionowego ruchu sinusoidy pojazdu KRAB .

2.3 PROCES UCZENIA SIECI

Pliki danych uzyskane w wyniku przeprowadzonych eksperymentów na basenie technologicznym WTM wprowadzono do środowiska MATLAB, a konkretnie do pakietu Neural Networks Tool, za pośrednictwem programu, przeprowadzającego odpowiednią konwersję tych plików. Wprowadzono również dane dotyczące zaprojektowanej sieci.

Uczenie sieci neuronowej przeprowadzono z użyciem algorytmu wstecznej propagacji błędów. Nauczanie jest procesem ciągłym, zmieniającym parametry obiektu trenowanego na podstawie wzorców uczących i testujących. Uczenie sieci neuronowej polega na prezentacji wzorców uczących tak długo aż uzyskamy pożądaną odpowiedź sieci. Realizowana sieć to przykład nauczania z nauczycielem tzn. trenowana sieć otrzymuje informację jaka powinna być poprawna odpowiedź dla danego przykładu wejściowego. Jeżeli jest właściwa, to nie następują żadne zmiany, a jeśli niewłaściwa, to następuje taka korekta wag połączeń w sieci, aby różnice między poprawną a rzeczywistą odpowiedzią były jak najmniejsze. Proces nauczania modelu neuronowego przedstawiono na schemacie nr 3.



Schemat nr 4. Schemat przebiegu procesu nauczania modelu neuronowego.

Na podstawie wielokrotnych prób, określono strukturę sieci neuronowej, a następnie przeprowadzono proces nauczania wykorzystując dane pomiarowe uzyskane w trakcie przeprowadzonych eksperymentów.

Przeprowadzono symulacje z sieciami dwu- i trzywarstwowymi, z różną liczbą neuronów w warstwie ukrytej uzyskując mniej lub bardziej akceptowalne wyniki.

3. PODSUMOWANIE

W przypadku realizowanego przebiegu (sinusoidy) na wyjściu z sieci analizowane były dwie wielkości: głębokość (określana na podstawie wskazań głębokościomierza – sygnał napięciowy [V]) i droga (określana na podstawie obrazu wizyjnego – wyrażona w [m]). Wartość średnia błędów bezwzględnych głębokości, w przypadku przebiegów testujących była symetryczna i osiągnęła w zakresie dodatnich oraz ujemnych wartości błędów wartość $\pm 0,0168V$, co w przeliczeniu na miarę długości odpowiadało odchyłkom $\pm 0,033m$ od realizowanej trajektorii ruchu.

Średnia wartość błędów względnych głębokości wyrażonego w procentach dla przebiegów testujących wyniosła 1,67%.

Dla przebiegów uczących wykorzystanych dla sprawdzenia funkcjonowania sieci jako testujące średnia wartość błędu bezwzględnego głębokości była symetryczna i wynosiła dla zakresu dodatnich i ujemnych wartości tego błędu +/- 0,0185V, co w przeliczeniu na miarę długości odpowiadało odchyłkom +/-0,037m od realizowanej trajektorii ruchu, a średnia wartość błędu względnego głębokości wyrażonego w procentach dla tych przebiegów uczących wykorzystanych jako testujące wyniosła 1,83%.

Średni błąd bezwzględny drogi dla przebiegów testujących był również symetryczny i wynosił +/- 0,01m. Wartość średnia błędu względnego drogi dla przebiegów testujących wynosiła 0,083%, a dla przebiegów uczących 0,316%. Jednak, ze względu na wielkość modułu siatki pomiarowej, przyjęto jego wielkość na poziomie 1%.

Biorąc pod uwagę wielkość błędu bezwzględnego i względnego określonych w trakcie testowania neuronowego modelu pojazdu KRAB nauczonego w III lub IV krokach nauczania można stwierdzić, że z wystarczającą dokładnością aproksymuje warunki rzeczywiste w postaci przebiegów testujących i uczących. Można, więc stwierdzić, że przedstawione w artykule przesłanki doboru struktury sieci pozwalają na uzyskanie pełnowartościowych neuronowych modeli ruchu pojazdu podwodnego typu ROV.

LITERATURA

1. Matejski M, Graczyk T.: "Creating of models of the ROV movement in limited experimental conditions applying fuzzy logic technique". Seventh International Conference BLACK SEA 2004r., Varna, Bulgaria. (jęz. konf. Angielski)
2. Piegat A. „Modelowanie i sterowanie rozmyte”. pp. 165-169, 267-323, 349-367 Akademicka Oficyna Wydawnicza EXIT , Warszawa 1999r.
3. Świętnicki Z., Wantoch-Rekowski R. „Sieci neuronowe w zastosowaniach wojskowych”, Dom Wydawniczy BELLONA, Warszawa 1998r.
4. Graczyk T. "Application of fuzzy logic technique in the ROV movements modeling", Polish Hyperbaric Research nr 1, 2007r.
5. Żurada J., Barski M., Jędruch W., „Sztuczne sieci neuronowe”. Warszawa, Wydawnictwo Naukowe PWN 1996r.
6. Korbicz J., Obuchowicz A., Uciński D. „Sztuczne sieci neuronowe. Podstawy i zastosowanie.” pp.151-162. Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994r.

Autorzy:

dr inż. Mariusz Matejski pracuje w Katedrze Maszyn Ciepłych i Siłowni Okrętowych Wydziału Techniki Morskiej Politechniki Szczecińskiej. Oprócz zagadnień dotyczących budowy i eksploatacji siłowni okrętowych zajmuje się zagadnieniami związanymi z jakością oraz transportem paliw płynnych i gazowych. Dodatkową dziedziną działalności jest projektowanie, budowa i eksploatacja pojazdów podwodnych typu ROV, łącznie z zagadnieniami dotyczącymi sterowania ruchem tych pojazdów z wykorzystaniem logiki rozmytej. Zagadnienia te były tematem obronionej w 2006 roku rozprawy doktorskiej.

dr inż. Mariusz Dramski doktor nauk technicznych z dyscypliny informatyka. Zainteresowania naukowe - sztuczna inteligencja, teoria sterowania. Aktualnie adiunkt w Zakładzie Informatyki na Uniwersytecie Kazimierza Wielkiego w Bydgoszczy.