

Mirosław ŁĄCKI<sup>1</sup>

### **WYZNACZANIE PUNKTÓW TRASY W NEUROEWOLUCYJNYM STEROWANIU STATKIEM**

*W artykule tym autor przedstawia system wspomagania decyzji sternika podczas manewrowania statkiem na ograniczonym obszarze. Podstawą systemu są ewolucyjne sztuczne sieci neuronowe, których struktura i parametry, odpowiednio zakodowane w kodzie genetycznym, rozwijają się w czasie symulacji, dostosowując całą populację do wyznaczonego zadania jakim jest bezpieczne przejście statku od pozycji startowej do celu. W celu usprawnienia procesu uczenia sieci neuronowej autor proponuje algorytm wyznaczania punktów trasy będących dodatkowym użytecznym zestawem informacji podczas obliczania wychylenia steru.*

### **SETTING WAYPOINTS IN NEUROEVOLUTIONARY SHIP HANDLING**

*In this article the author presents a decision support system for the helmsman maneuvering the vessel in a restricted area. The system is based on evolutionary artificial neural networks, whose structure and parameters, encoded in the genetic code, develop during the simulation by adjusting the entire population to an assignment which is safe passage of the ship from starting point to designated goal. To improve the learning process the author proposes an algorithm of setting waypoints for additional useful data set when calculating the angle of the rudder.*

## **1. WSTĘP**

Neuroewolucyjne sterowanie statkiem jest to system wspomagania decyzji podejmowanych przez sternika podczas manewrowania statkiem na ograniczonym obszarze. W symulowanym modelu statkiem steruje sztuczna sieć neuronowa. Na jej wejściu znajdują się sygnały zakodowane z informacji dotyczących aktualnego stanu środowiska w którym znajduje się statek oraz sternik, np.: aktualny kurs, prędkość nad dnem, prędkość kątowna. Na wyjściu sieci znajdują się kąty wychylenia steru.

W aspekcie ewolucyjnym taka sieć neuronowa jest traktowana jako osobnik w populacji sieci konkurujących między sobą o miano sieci najlepiej przystosowanej do badanego problemu [1] czyli bezpiecznego sterowania statkiem na zadanym ograniczonym obszarze wodnym. Droga odpowiedniej selekcji podczas obserwacji bieżących dokonań sterników, system wybiera najlepszego sternika i poprzez operacje genetyczne tworzy w następnym pokoleniu nowe osobniki. W podejściu neuroewolucyjnym sieć neuronowa posiada swój

---

<sup>1</sup> Akademia Morska w Gdyni, Wydział Nawigacyjny, Katedra Nawigacji, 81-225 Gdynia, ul. Morska 81-87, tel. +48 58 69 01 574, e-mail: lacki@am.gdynia.pl

genotyp, w którym zawarte są informacje o strukturze sieci, czyli ilości wejść, wyjść oraz neuronów a także informacje o połączeniach między poszczególnymi elementami sieci neuronowej. Wszystkie te informacje są zakodowane w genach w taki sposób by możliwe były operacje genetyczne przekazujące pożądane cechy rodziców do genotypów następných pokoleń [2, 3].


W dotychczasowych badaniach inteligentnych systemów wspomagania decyzji manewrowych [1, 3, 4] widać wyraźną zależność między złożonością modelu środowiska a zdolnością sztucznej sieci neuronowej do nauczenia się bezpiecznego manewrowania statkiem. Proces uczenia sternika w środowiskach o niewielkiej dynamice zmian może być realizowany klasycznymi metodami jak Uczenie się Ze Wzmocnieniem (ang. *Reinforcement Learning*) [5, 6, 7] lub przy użyciu sztucznych sieci neuronowych z ustaloną strukturą. W przypadku środowisk dynamicznych z dużą przestrzenią stanów mnogość ważnych dla sternika informacji, które sieć musi przeliczyć by prawidłowo wspomóc decyzję o wychyleniu kąta steru sprawia, że trudne staje się zaprojektowanie optymalnej klasycznej struktury sieci, czyli takiej w której określona, stała ilość wejść, neuronów i wyjść oraz połączeń między nimi efektywnie i prawidłowo wylicza wartość kąta wychylenia steru w sytuacjach manewrowych o różnym stopniu złożoności [8].

Zaproponowany i przetestowany przez autora system wyznaczania punktów trasy znacznie usprawnia proces uczenia się sternika w złożonych sytuacjach manewrowych.

## 2. EWOLUCYJNA SIEĆ NEURONOWA

### 2.1 Budowa neuronu

W ewolucyjnych sieciach neuronowych struktura neuronu (rys. 1) jest taka sama jak w klasycznej sztucznej sieci neuronowej [9]. Jego cechy, czyli numery połączeń (informacja o tym z którym wejściem, neuronem lub wyjściem sieci jest połączony dany neuron), wartości wag oraz wartości współczynnika przesunięcia  $\theta_j$  (ang. *bias*) wartości funkcji aktywacji są zapisane w genotypie danej sieci neuronowej [10].




Rys.1. Budowa neuronu w sztucznej sieci neuronowej

Funkcja aktywacji neuronu [11] jest ciągła o charakterze sigmoidalnym unipolarnym (rys. 2) przyjmującej wartości wg wzoru (1) z zakresu  $f(x)=(0,1)$ .

$$o_j = \frac{1}{1 + e^{-(S_j\beta + \theta_j)}} \quad (1)$$

gdzie:  $o_j$  – wartość wyjściowa neuronu  
 $S_j$  – suma iloczynów wartości wejściowych  $x_i$  i wag  $w_{ij}$   
 $\beta$  – współczynnik nachylenia funkcji  
 $\theta_j$  – współczynnik przesunięcia wartości funkcji



Rys. 2. Funkcja aktywacji neuronu z zaznaczonym zakresem wartości wyjściowych zależnych od współczynnika przesunięcia  $\theta_j$

Przesunięcie wpływa na moment pobudzenia neuronu [12]: im większa wartość współczynnika przesunięcia tym łatwiej pobudzić neuron, nawet dla niewielkich wartości sygnałów wejściowych.

Wartości graniczne  $\langle -6..6 \rangle$  współczynnika przesunięcia funkcji aktywacji neuronu zostały wyznaczone eksperymentalnie.


W ewolucyjnym modelu obliczeniowym sieć neuronowa jest trenowana bez nauczyciela [13, 14]. Posiada ona globalną wartość przystosowania obliczaną za pomocą sygnałów wzmocnień, pozytywnych bądź negatywnych, których wartości zależą od decyzji podejmowanych przez sternika oraz od ogólnej jakości całej populacji.

## 2.2 Sygnały wejściowe sztucznej sieci neuronowej

W symulowanym środowisku sygnały wejściowe o charakterze ciągłym zostały zakodowane do postaci binarnej. System też umożliwia wykorzystanie informacji o charakterze rozmytym lub wielokryterialnym [15]. W wersji podstawowej opracowanego przez autora systemu rozpatrywane były następujące sygnały wejściowe (rys. 3):

- aktualny kurs statku  $\psi$ ,
- prędkość kątowna  $r$ ,
- czy kurs jest kolizyjny (wartość binarna),
- odległość do przeszkody na kursie  $d$ ,
- czy niebezpieczeństwo wzrosło (wartość binarna),
- czy niebezpieczeństwo zmalało (wartość binarna),

- statek zbliża się do celu (wartość binarna),
- cel jest widoczny (wartość binarna),
- kąt wychylenia steru  $\delta$ .



Rys. 3. Podstawowe sygnały wejściowe sieci neuronowej


Do podstawowych sygnałów wejściowych zostały także dodane sygnały związane z punktami trasy, tj.: odległość i kąt do najbliższego oraz następnego punktu trasy. Koncepcja dodania punktów trasy narodziła się z obserwacji wyników symulacji złożonych sytuacji manewrowych, tj. tras przejścia o dużej złożoności wymagającej często przeciwnych wychyleń steru na obie burty. Symulacje bez punktów trasy wykazały dużą stochastyczność otrzymywanych wyników wynikającą z dużej przestrzeni stanów, którą sieć neuronowa eksploruje podczas poszukiwania wartościowych rozwiązań.

### 2.3 Wyznaczanie punktów trasy

Trasą w projektowanym środowisku symulacyjnym jest uporządkowany zbiór punktów do startu do celu. Między sąsiednimi punktami trasy nie znajduje się przeszkoda w linii prostej. Dzięki informacji o współrzędnych punktów trasy sztuczna sieć neuronowa sterująca wychyleniem steru jest w stanie sprawniej wyliczyć prawidłowy kąt pletwy sterowej aby zminimalizować ryzyko wplynięcia na przeszkodę lub wypłynięcia poza obszar wodny.

Punkty trasy oblicza się na początku symulacji metodami geometrycznymi biorąc pod uwagę ilość krawędzi obszarów zabronionych przecinających odcinek A łączący pozycję startową statku z celem (rys. 4). Współrzędne punktu trasy wyznaczone są w środku odcinka przecinającego kanał wodny pomiędzy punktami obszarów zabronionych lub granicą obszaru symulacji.

W algorytmie porządkowania punktów trasy uwzględnia się również przeszkody o kształcie wielokątów wklęsłych. W takim przypadku, jeśli punkt 1 jest niewidoczny z pozycji startowej, wyznacza się za pomocą odcinka B punkty 5 i 6.



Rys.4. Wyznaczanie punktów trasy przejścia na ograniczonym obszarze

Ostatecznie uporządkowana zalecana trasa w prezentowanym przykładzie będzie składać się z kolejnych punktów {5,6,1,2,4,3}. Trasa ta może ulec modyfikacji ze względu na punkty trasy znajdujące się blisko siebie. Dopuszczalne najkrótsze warianty to {5,1,3} lub {6,2,3}.

Z przeprowadzonych symulacji wynika, że minimalizacja ilości punktów trasy nie zwiększa wydajności systemu. Ma to związek z faktem, że wyliczone punkty nie są punktami optymalnej trasy, jedynie wskazówką dla sternika w którą stronę prowadzić statek z punktu w którym aktualnie się znajduje.

#### 2.4 Sygnały wyjściowe

W modelowanym systemie wspomaganie decyzji bazującym na sieci neuronowej ważne jest określenie ilości wyjść sieci czyli ilości kątów wychylenia steru. Większa ilość wyjść sieci oznacza większą złożoność sieci, ale też lepsze odwzorowanie symulowanego modelu. Zbyt duża ilość wyjść może jednak znacznie zmniejszyć szybkość uczenia się sternika i obniżyć jego zdolność przystosowywania się do nowych sytuacji nawigacyjnych.

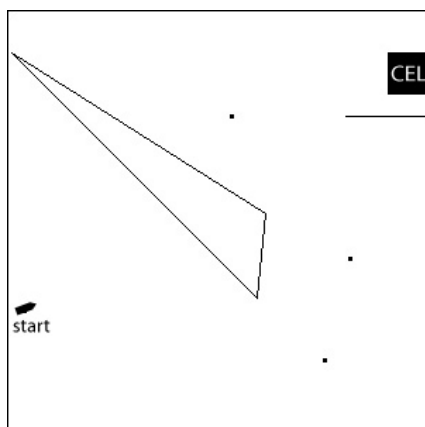
Zakładając przedział kąta wychylenia steru od  $-35^{\circ}$  do  $+35^{\circ}$  w symulacji zastosowano 11 sygnałów wyjściowych o skoku wychylenia steru co  $7^{\circ}$ :  $-35^{\circ}$ ;  $-28^{\circ}$ ;  $-21^{\circ}$ ;  $-14^{\circ}$ ;  $-7^{\circ}$ ;  $0^{\circ}$ ;  $7^{\circ}$ ;  $14^{\circ}$ ;  $21^{\circ}$ ;  $28^{\circ}$ ;  $35^{\circ}$ .

### 3. SYMULACJA

Symulacja została przeprowadzona przy użyciu aplikacji stworzonej do tego celu przez autora i uruchomionej na komputerze klasy PC z procesorem dwurdzeniowym.

Dane symulacji:

- symulacja manewrowania statkiem na ograniczonym obszarze z dwiema przeszkodami statycznymi w dwóch przypadkach: bez punktów trasy i z trzema punktami trasy (rys. 5),



Rys.5. Środowisko symulacyjne manewrowania statkiem na ograniczonym obszarze z wyznaczonymi trzema punktami trasy

- przeprowadzenie symulacji 12 razy dla każdego z dwóch ww. przypadków,
- populacja 80 osobników,
- dla uproszczenia obliczeń prędkość statku jest stała,
- brak innych obiektów ruchomych,
- 200 cykli pomiarowych pomiędzy operacjami ewolucyjnymi,
- dynamiczne parametry mutacji parametrów sieci,
- dynamiczne wartości wzmocnień wartości przystosowania osobnika, zależne od chwilowej wydajności całej populacji,
- dynamiczne kryteria selekcji osobników,
- pomiar czasu pomiędzy startem symulacji a wytrenowaniem co najmniej 20% populacji.

Tab. 1. Porównanie czasów symulacji

Rodzaj symulacji	Czas min. [gg:mm:ss]	Czas średni [gg:mm:ss]	Czas maks. [gg:mm:ss]	Odch. stand. [gg:mm:ss]
Bez punktów trasy	00:04:14	00:24:34	00:58:58	00:20:14
Z trzema punktami trasy	00:01:22	00:09:44	00:28:44	00:07:50

#### 4. WNIOSKI

Z przedstawionych wyników symulacji wynika, że zastosowanie punktów trasy w zestawie sygnałów wejściowych znacznie przyspiesza proces uczenia się sztucznej sieci neuronowej. W przykładowym środowisku symulacyjnym czas średni dla symulacji z punktami trasy był ponad dwukrotnie krótszy od czasu średniego symulacji bez punktów trasy.

Dodatkowo należy odnotować fakt, iż symulacja z użyciem punktów trasy wymaga wykonania dodatkowych obliczeń związanych zakodowaniem na wejścia sieci neuronowej informacji o odległości i kątach do punktów trasy. Pomimo tych dodatkowych obliczeń symulacja taka jest bardziej efektywna. Wynika to z tego, że dodatkowe informacje w znacznym stopniu zmniejszają przestrzeń wartościowych stanów środowiska eksplorowanych przez sieć neuronową podczas poszukiwania prawidłowych rozwiązań.

#### 5. BIBLIOGRAFIA

- [1] Łącki M.: *Ewolucyjne sieci NEAT w sterowaniu statkiem*, Inżynieria Wiedzy i Systemy Ekspertowe, Akademicka Oficyna Wydawnicza EXIT, Warszawa, str. 535-544, 2009
- [2] Kenneth O.S., Miikkulainen R.: *Efficient reinforcement learning through evolving neural network topologies*, Proceedings of the Genetic and Evolutionary Computation Conference (GECCO-2002), San Francisco, CA, Morgan Kaufmann, 2002
- [3] Łącki M.: *Neuroevolutionary approach towards ship handling*, Proceedings of TST Conference, Katowice - Ustroń, WKL, 2008
- [4] Łącki M.: *Speciation of population in neuroevolutionary ship handling*, Marine Navigation and Safety of Sea Transportation, redakcja: Adam Weintrit, CRC Press/Balkema, Taylor & Francis Group, Boca Raton – London - New York - Leiden, str. 541-545, 2009
- [5] Tesauro G.: *Temporal Difference Learning and TD-Gammon*, Communications of the Association for Computing Machinery, vol. 38, No. 3., 1995
- [6] Sutton R., Barto A.: *Reinforcement Learning: An Introduction*, MIT Press, 1998
- [7] Sutton R.: *Generalization in Reinforcement Learning: Successful Examples Using Sparse Coarse Coding*, Neural Information Processing Systems 8, 1996
- [8] Łącki M.: *Machine Learning Algorithms in Decision Making Support in Ship Handling*, Proceedings of TST Conference, Katowice - Ustron, WKL, 2007
- [9] Touretzky D., Mozer M., Hasselmo M.: *Neural Information Processing Systems*, MIT Press, 1996
- [10] Kenneth O.S., Miikkulainen R.: *Efficient Evolution of Neural Network Topologies*, Proceedings of the 2002 Congress on Evolutionary Computation, Piscataway, 2002
- [11] Braun H., Weisbrod, J.: *Evolving feed-forward neural networks*, Proceedings of ANNGA93, International Conference on Artificial Neural Networks and Genetic Algorithms, Berlin: Springer, 1993
- [12] Beyer H. G., Schwefel P. H.: *Evolution strategies A comprehensive introduction*, Natural Computing, 1(1):352, 2002
- [13] Kenneth O.S., Miikkulainen R.: *Real-Time Neuroevolution in the NERO Video Game*, Proceedings of the IEEE 2005 Symposium on Computational Intelligence and Games, Piscataway, 2005

- 
- [14] Kenneth O.S., Miikkulainen R.: *Real-Time Neuroevolution in the NERO Video Game*, Proceedings of the IEEE 2005 Symposium on Computational Intelligence and Games, Piscataway, 2005
  - [15] Filipowicz W., Łacki M., Szłapczyńska J.: *Multicriteria decision support for vessels routing*, Proceedings of ESREL05 Conference, Gdańsk, 2005