

**ZESZYTY NAUKOWE NR 3(75)
AKADEMII MORSKIEJ
SZCZECIN 2004**

PRACE WYDZIAŁU NAWIGACYJNEGO

Maciej Nowakowski

**Pozycjonowanie metodami porównawczymi
na przykładzie odcinka toru Świnoujście – Szczecin
z wykorzystaniem sztucznych sieci neuronowych**

Słowa kluczowe: nawigacja porównawcza, neuronowe metody dopasowania obrazów radarowych, wyznaczanie pozycji

Istotą nawigacji porównawczej jest porównanie dynamicznie zarejestrowanego obrazu ze wzorcem i na tej podstawie wyznaczenie pozycji statku. W artykule wykorzystano rzeczywiste obrazy radarowe z przejścia statku torem po Zalewie Szczecińskim. Przebadano odpowiedzi różnych rodzajów sztucznych sieci neuronowych wraz z analizą błędów.

**Comparative Position Plotting on the Świnoujście – Szczecin
Fairway Using Artificial Neural Networks**

Keywords: comparative navigation, neural methods for radar image matching, position plotting


The essence of comparative navigation is to match a dynamically registered image with the pattern and to plot the position on that basis. Radar images used in the research were registered on the Świnoujście – Szczecin fairway. Responses from different kinds of artificial neural network were examined together with error analysis.

Wstęp

Konwencja SOLAS nakłada na armatorów obowiązek wyposażenia statku w system nawigacyjny pozwalający w sposób ciągły i automatyczny wyznaczać pozycję jednostki. W ostatnich czasach obowiązek ten jest realizowany prawie wyłącznie przez systemy satelitarne. Uzależnienie się od jednego systemu jest zawsze niebezpieczne, tym bardziej że systemy satelitarne mogą ulegać zakłóceniom, celowym wyłączeniom czy awariom. Alternatywnym i, co ważniejsze, autonomicznym systemem wyznaczania pozycji może być system wykorzystujący metody porównawcze [2, 3, 4, 5]. Wszystko, czego taki system potrzebuje to radarowy obraz obszaru wokół statku, który następnie jest porównywany ze wzorcem. Wzorce mogą być generowane sztucznie na podstawie modelu terenu tworząc tzw. mapę radarową lub być rzeczywistymi obrazami radarowymi pochodzącymi z rejestracji. W artykule przeprowadzono badania z obrazami rzeczywistymi zarejestrowanymi na torze wodnym ze Świnoujścia do Szczecina. Metody porównawcze mają oczywiście zastosowanie tylko w sąsiedztwie brzegów lub innych stałych obiektów dających echa radarowe. Kolejnym ograniczeniem jest brak możliwości pozycjonowania przy braku cech charakterystycznych wyróżniających dany obraz spośród innych – np. przy idealnie prostej linii brzegowej. Pozycjonowanie metodami porównawczymi jest wtedy bardzo utrudnione, a czasem wręcz niemożliwe. W procesie obróbki a następnie porównywania obrazów wykorzystywać można zarówno tradycyjne metody analityczne, jak również metody sztucznej inteligencji, takie jak np. sztuczne sieci neuronowe [3, 4, 5, 6, 7]. Cechy sztucznych sieci neuronowych, takie jak zdolność uogólniania wiedzy, odporność na zakłócenia, szybkość przetwarzania informacji, zdolność rozwiązywania nawet bardzo złożonych problemów są do tego zadania predestynowane [8, 9].

1. Przygotowanie danych

Do badań wykorzystano obrazy radarowe udostępnione przez prof. dr hab. A. Statecznego i pochodzące z przejścia statku m/s Nawigator XXI torem wodnym ze Świnoujścia do Szczecina. Obrazy zostały zarejestrowane rejestratorem Maris i mają postać sekwencji video. Na zakresie 6 Mm dokonano zrzutów obrazu (rys. 1) z odcinka od główek kanału Piastowskiego do 3. bramy torowej co ok. 5 s. Otrzymano w ten sposób 410 bitmap w rozdzielczości 780 x 780 punktów w 16mln kolorów. Porównywanie obrazów w takiej postaci jest ze względu na ilość informacji bardzo utrudnione [3, 5] i zachodzi potrzeba skompresowania ich do rozmiarów, w których mogłyby być podane na wejście sztucznej sieci neuronowej.




Rys. 1. Przykład obrazu radarowego z rejestratora
 Fig. 1. An example of registered radar image

Zaproponowano następujące kroki w celu przetworzenia obrazu do mniej-szej postaci:

1. Redukcja obrazu kolorowego do monochromatycznego, gdzie każdy punkt obrazu opisany jest jednym bitem – wartość binarna 1 oznacza echo, wartość binarna 0 brak echa. Za punkty echa radarowego uznano takie, których jasność w obrazie kolorowym była większa od 0,5. Wynik takiego odcięcia na poziomie jasności 0,5 to m.in. brak w obrazie wynikowym poświaty.
2. Redukcja wielkości obrazu o połowę poprzez zapis co drugiego i wiersza i co drugiej kolumny. Działanie takie spowodowało utratę informacji o echach o wielkości pojedynczego punktu. Tak małe echa to w większości zakłócenia lub echa od jednostek pływających. Echa o wymiarach 2x1 i większe przejdą do obrazu wynikowego więc nie zostaną w tym procesie utracone.

Na rysunku 2 przedstawiono efekty dotychczasowych przekształceń. Zauważalne jest pogorszenie rozdzielczości obrazu i jednoczesna redukcja części zakłóceń. Zniknęły też kręgi odległości. Pozostałe zakłócenia nie będą dalej usuwane, ponieważ zarówno w procesie uczenia jak i późniejszej eksploatacji sztucznej sieci neuronowej będziemy na jej wejście podawać tak samo wstępnie przetworzone obrazy, co związane jest z możliwościami adaptacyjnymi sieci neuronowych [5].



Rys. 2. Fragment obrazu radarowego przed i po konwersji
Fig. 2. Radar image before and after conversion

Teraz każdy obraz opisany jest macierzą 0-1 o wymiarach 390*390 lub inaczej rzecz ujmując wektorem o długości 152100 elementów. Trudno sobie oczywiście wyobrazić sztuczną sieć neuronową o takiej ilości wejść. Ilość danych opisujących jeden obraz należy jeszcze bardziej zredukować. Można posłużyć się jednym z wielu algorytmów kompresji obrazów. Jednak większość z nich nastawiona jest na maksymalizację stosunku sygnał/szum. Tutaj zadanie jest całkowicie odmienne. Celem jest takie zakodowanie informacji o obrazie w możliwie małej postaci, aby zachować cechy obrazu umożliwiające wyznaczenie pozycji jednostki z możliwie dużą dokładnością. W literaturze [4] znajdziemy kilka odpowiednich metod. W artykule posłużono się jedną z najprostszych, tj. rzutowaniem na osie. Metoda polega na zsumowaniu wartości w wierszach i kolumnach w rezultacie czego otrzymamy wektor długości $N+M$, gdzie N to szerokość obrazu, a M – wysokość. Współczynnik kompresji w tej metodzie wynosi:

$$k = \frac{M + N}{M * N} \quad (1)$$

Wszystkie dotychczasowe operacje przetwarzania obrazu radarowego pozwoliły zapisać pojedynczy obraz w postaci wektora o 780 elementach.

2. Ocena dokładności pozycji

Za kryterium oceny każdej sieci neuronowej przyjęto błędy w pozycji określone poprzez $dRMS^1$ [1]. Parametr ten jest bardzo często podawany przy ocenie jakości pozycji z systemów nawigacyjnych. Wyznaczona pozycja znajdzie się

¹ distance root mean square

wewnątrz koła o promieniu 2^*dRMS na poziomie ufności 95%, przy czym środek koła znajduje się w pozycji wzorcowej.

sd_E – odchylenie standardowe pomiarów współrzędnej wschodniej:

$$sd_E = \sqrt{\frac{1}{n-1} \left(\sum_{i=1}^n (E_o - E_i)^2 \right)} \quad [\text{m}] \quad (2)$$

gdzie:

E_o – współrzędna wschodnia pozycji wzorcowej,

E_i – współrzędna wschodnia i -tej pozycji,

n – liczebność próby

sd_N – odchylenie standardowe pomiarów współrzędnej północnej:

$$sd_N = \sqrt{\frac{1}{n-1} \left(\sum_{i=1}^n (N_o - N_i)^2 \right)} \quad [\text{m}] \quad (3)$$

gdzie:

N_o – współrzędna północna pozycji wzorcowej,

N_i – współrzędna północna i -tej pozycji,

$dRMS$ – średni błąd kwadratowy pozycji poziomej (2D) z próby pomiarowej (poziom ufności 68%):

$$dRMS = \sqrt{(sd_N^2 + sd_{Ei}^2)} \quad [\text{m}] \quad (4)$$

Ze względu na rodzaj akwenu, na którym wykonano obliczenia, celowa wydaje się także ocena metod pod względem dokładności względem osi toru. Dla każdej z wyznaczonych pozycji obliczono odległość do osi toru jako odległość punktu od prostej wg wzoru:

$$d = \frac{|Ax_o + By_o + C|}{\sqrt{A^2 + B^2}} \quad [\text{m}] \quad (5)$$

gdzie:

A, B, C – parametry opisujące prostą,

x_o, y_o – współrzędne punktu.

3. Eksperyment


Zebrane i wstępnie przetworzone dane stanowią 410 par wektorów, przy czym w każdej parze znajduje się:

- wektor opisujący obraz radarowy,
- wektor pozycji powiązanej z obrazem $[\varphi, \lambda]$.

Na wejście sieci podawano wektor po standaryzacji do przedziału $(0,1)$. Przebadano następujące typy sztucznych sieci neuronowych:

- liniowa (LIN),
- radialna (RBF),
- regresji ogólnej (GRNN),
- perceptron wielowarstwowy (MLP).

Zaproponowano 2 modele sieci. W modelu pierwszym sieć podaje na wyjściu tylko jedną współrzędną geograficzną (φ lub λ) w drugim natomiast na wyjściu sieci pojawia się para współrzędnych $[\varphi, \lambda]$. W literaturze [4, 5] spotkać można jedynie informacje o pierwszym przypadku.



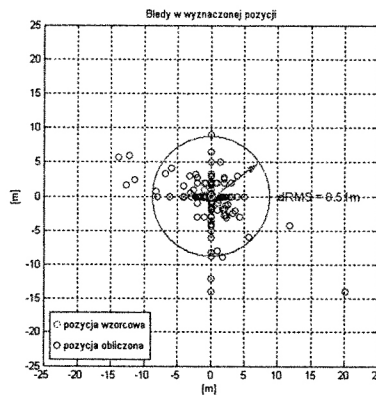
Rys. 3. Sieci GRNN o jednym i o dwóch wyjściach
Fig. 3. GRNN networks with single output and two outputs

Zdecydowanie najlepsze okazały się być do tego zastosowania sieci GRNN, których odpowiedzi obarczone były najmniejszymi błędami. Wyniki obliczeń dla poszczególnych rodzajów sieci przedstawia tabela 1.

Przeprowadzone badania dowodzą, że rozkład błędów zależy od modelu zastosowanej sieci. Na rysunku 4 przedstawiono wyniki dla sieci GRNN o jednym wyjściu. Widać, że błędy rozkładają się równomiernie we wszystkich sektorach, większe skupiska występują wzdłuż osi OX i OY.

Porównanie błędów różnych rodzajów sieci
Comparison of errors from different neural networks

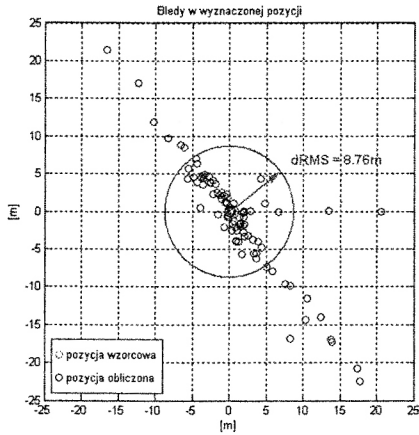
Typ sieci	Błąd na poziomie ufności 95% [m]	Ilość neuronów w warstwach ukrytych	Algorytm uczący
GRNN	8.76	[350 3]	regresji ogólnej
RBF	92.73	[25]	K-średnich
LIN	153.47	–	pseudo-inverse
MLP	3173.60	[43 43]	propagacja wsteczna



Rys. 4. Rozkład błędów dla sieci GRNN z jednym wyjściem
Fig. 4. Error distribution for GRNN with single output


Rozkład błędów wzdłuż osi układu wynika z faktu wyznaczenia jednej współrzędnej z bardzo dużą dokładnością (błąd bliski 0) podczas, gdy druga współrzędna jest obciążona błędem.

Rysunek 5 prezentuje odpowiedzi sieci neuronowej o dwóch wyjściach, w której po podaniu na wejście zakodowanego obrazu, na wyjściu otrzymujemy wektor $[\varphi, \lambda]$. Wyraźnie widać, że błędy rozkładają się wzdłuż pewnego kierunku. Okazuje się, że jest to kierunek toru na jakim zostały zarejestrowane obrazy. Można stwierdzić, że sieć popełnia błędy dużo większe na kierunku wzdłuż toru natomiast mniejsze w kierunku poprzecznym. Jest to zjawisko na badanym akwenie pozytywne, ponieważ odejście od osi toru w prawo lub lewo jest zazwyczaj bardziej niebezpieczne, podczas gdy przemieszczenie się wzdłuż toru już niebezpieczne najczęściej nie jest. Zmienne φ i λ są ze sobą skorelowane – współczynnik korelacji wynosi 0,8. Parametr dRMS jest dla obu sieci bardzo zbliżony i mieści się w przedziale 8,5 – 9 m.



Rys. 5. Rozkład błędów dla sieci GRNN z dwoma wyjściami
 Fig. 5. Error distribution for GRNN with two outputs

Obliczone wartości odległości wyznaczonej pozycji od osi toru potwierdzają wcześniejsze przypuszczenia. Sieć o dwóch wyjściach wyznaczająca jednocześnie parę współrzędnych φ , λ jest zdecydowanie lepsza jeżeli chodzi o pozycjonowanie w kierunku poprzecznym do toru (rys. 6). Odchylenie standardowe zejścia z osi toru wynosi przy tej sieci 2,31 m, podczas gdy dla sieci o jednym wyjściu jest to 4,97 m.



Rys. 6. Odległości wyznaczonej pozycji od osi toru w zależności o modelu sieci
 Fig. 6. Plotted position distances from the center line of the fairway depending on NN model used

Wnioski

Porównawcze metody pozycjonowania mogą być alternatywą dla systemów satelitarnych, ponieważ pozwalają wyznaczyć pozycję jednostki w sposób automatyczny. Mają dodatkowo jedną niepodważalną zaletę – są całkowicie autonomiczne. Porównawcze wyznaczanie pozycji jest szeroko stosowane, zwłaszcza w wojsku oraz do nawigowania pojazdami bezzałogowymi. W artykule potwierdzono skuteczność tych metod również w zastosowaniach morskich. Na badanym akwenu osiągnięto $dRMS = 8,5$ m co oznacza, że wyznaczona pozycja znajdzie się wewnątrz koła o takim promieniu na poziomie ufności 95%. Zaobserwowano także silną zależność błędu od modelu zastosowanej sieci tj. w sieci o dwóch wyjściach współrzędne φ i λ są wyraźnie ze sobą skorelowane. Błędy w takiej sieci układają się wzdłuż toru co jest zjawiskiem korzystnym, bo ważniejsze jest położenie jednostki w stosunku do osi toru wodnego. Położenie statku wzdłuż osi toru jest natomiast w większości przypadków mniej istotne.

Literatura

1. Clarke B., *Aviator's Guide to GPS*, McGraw-Hill, Inc., 1994.
2. Pietrzykowski Z., *Pozycjonowanie statku na podstawie obrazu radarowego w wykorzystaniu sieci neuronowej o logice rozmytej*, *Explo-Ship*, Szczecin 2002.
3. Stateczny A., *Nawigacja porównawcza*, GTN, Gdańsk 2001.
4. Stateczny A., *Metody nawigacji porównawczej*, GTN, Gdańsk 2004 (w druku).
5. Stateczny A., Praczyk T., *Artificial Neural Networks in Radar Image Compression*, IRS, Hamburg 2003.
6. Stateczny A., Praczyk T., *Sztuczne sieci neuronowe w rozpoznawaniu obiektów morskich*, GTN, Gdynia 2002.
7. Stateczny A., Duda J., *Koncepcja porównawczego wyznaczania pozycji jednostki pływającej na podstawie obrazów sonarowych*, *Explo-Ship*, Szczecin 2004.
8. Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa 1993.
9. Tadeusiewicz R., *Wprowadzenie do sieci neuronowych*, Statsoft, Kraków, 2001.
10. Wąż M., *Metoda wyznaczania pozycji okrętu za pomocą porównania obrazu radarowego z mapą morską*, rozprawa doktorska, AMW, Gdynia 2000.

Recenzent

dr hab. inż. Roman Śmierchalski, prof. AM Gdynia

Adres Autora

mgr inż. Maciej Nowakowski

Akademia Morska w Szczecinie

Instytut Nawigacji Morskiej

ul. Wały Chrobrego 1/2

70-500 Szczecin