

## ZASTOSOWANIE SIECI NEURONOWEJ DO STEROWANIA PRACĄ WCIĄGARKI

Paweł FAŁAT\*

\*Wydział Zarządzania i Informatyki, Akademia Techniczno – Humanistyczna, ul Willowa 9, 43-309 Bielsko – Biała

[fałat@ath.bielsko.pl](mailto:fałat@ath.bielsko.pl)

**Streszczenie:** Często spotykanym zadaniem stawianym przed żurawiami typu offshore jest utrzymanie ładunku na zadanej głębokości pomimo ruchów bazy żurawia wywołanych falowaniem morza. W niniejszym artykule przedstawiono zastosowanie sieci neuronowej do wyznaczania funkcji napędowej wciągarki zapewniającej stabilizację pionową ładunku. Analizy przeprowadzono dla żurawia typu A-rama. Opracowano jego model matematyczny, przy czym korzystając z wcześniejszych doświadczeń autora, przyjęto, że jedynym elementem podatnym w układzie jest lina. W poprzednich pracach autor proponował użycie metod optymalizacji do wyznaczenia poszukiwanej funkcji napędowej. Optymalizacja dynamiczna jest jednak na tyle czasochłonna obliczeniowo, że jej zastosowanie w czasie rzeczywistym nie jest możliwe. Stąd podjęto próbę wykorzystania do rozwiązania tego problemu sieci neuronowej. Optymalizację zastosowano natomiast do przygotowania odpowiedniego zbioru uczącego dla sieci neuronowej.

### 1. WSTĘP

Współcześnie konstruowanym urządzeniom *offshore*, to znaczy urządzeniom pracującym na pokładach statków lub platform morskich, stawiane są coraz większe wymagania. Względy ekonomiczne powodują, że dąży się do stworzenia możliwości ich pracy w coraz trudniejszych warunkach pogodowych. Chodzi tu głównie o wysokość falowania morza. Dlatego, obok prac konstrukcyjnych, prowadzone są prace badawczo-rozwojowe, których jednym z celów jest poszukiwanie strategii sterowania napędami urządzeń offshore zapewniających ich poprawną, a przede wszystkim bezpieczną pracę, w coraz bardziej ekstremalnych warunkach. Pojawia się więc potrzeba dokładnej symulacji i analizy pracy takich konstrukcji podczas falowania (Fałat, 2004; Maczyński, 2005). Następnie można przystąpić do definiowania algorytmów sterujących ruchami roboczymi urządzenia. Często stosowaną metodą poszukiwania odpowiednich funkcji napędowych jest optymalizacja. Zazwyczaj jednak obliczenia optymalizacyjne, wymagające wielokrotnego całkowania równań ruchu układu, są zbyt czasochłonne aby możliwa była ich implementacja w czasie rzeczywistym (Fałat i inni, 2009). Dlatego coraz powszechniej proponuje się rozwiązania bazujące na sztucznej inteligencji, na przykład sterowanie rozmyte lub sztuczne sieci neuronowe. Warto zauważyć, że metody te często wspomagane są przez typową optymalizację, bądź to na etapie opracowywania (np. tworzenie zbioru uczącego dla sieci neuronowej) bądź na etapie jej testowania (obliczenia porównawcze).

Prezentowany artykuł przedstawia takie właśnie podejście. Klasyczna metoda optymalizacji wykorzystana została do przygotowania zbioru uczącego dla sieci neuronowej, oraz do sprawdzenia jakości otrzymanych z niej rozwiązań.


### 2. ISTOTA ZAGADNIENIA

Szereg prac wykonywanych z użyciem żurawi offshore wymaga stabilizacji (utrzymania) ładunku na zadanej głębokości pomimo ruchów bazy (jednostki pływającej, platformy) wywołanych falowaniem morza. Niezbędne jest to w przypadku niektórych prac montażowych, pracy sonaru czy na pewnych etapach wodowania batyskafów lub podwodnych pojazdów. Utrzymanie ładunku na zadanej głębokości można uzyskać poprzez odpowiednie sterowanie pracą wciągarki żurawia. Jednak prace podwodne są prowadzone często przy znacznych długościach liny, dochodzących zwykle do kilkuset, a w skrajnych przypadkach nawet do dwóch, trzech tysięcy metrów). Powoduje to, że podczas wyznaczania funkcji napędowych wciągarki należy uwzględnić podatność układu linowego.

Zagadnienie poszukiwania funkcji napędowej wciągarki, zapewniającej stabilizację ładunku na zadanej głębokości, klasyczną metodą optymalizacji (pełzającego sympleksu) było przedmiotem szeregu wcześniejszych prac autora i zostało dokładnie przedstawione w pracy (Fałat, Wojciech 2003). Jak już wspomniano klasyczne metody optymalizacji charakteryzują się znaczną czasochłonnością obliczeń. Dlatego też podjęto próbę wykorzystania do rozwiązania przedstawionego zadania sztucznej sieci neuronowej (Tadeusiewicz, 1993). Taka sieć mogłaby sterować pracą wciągarki w czasie rzeczywistym na podstawie pomiarów ruchu bazy żurawia. Oczywiście wymaga ona przeprowadzenia wcześniej procesu uczenia na podstawie odpowiednio przygotowanego zbioru uczącego. W niniejszej pracy zaproponowano opracowanie takiego zbioru uczącego przy zastosowaniu wspomnianej wcześniej optymalizacji dynamicznej.

### 3. MODEL MATEMATYCZNY A-RAMY I ZADANIE OPTIMALIZACJI

Prezentowane w dalszej części pracy analizy przeprowadzono dla żurawia offshore typu A-Rama (Rys. 1). Głównymi jego elementami są: rama, układ siłowników wychylających ramę, wciągarka i układ linowy.




Rys. 1. Żuraw typu A-rama

Jednym z podstawowych założeń, przyjętych na etapie budowy modelu matematycznego A-ramy, było potraktowanie konstrukcji nośnej żurawia jako sztywnej. W szczególności chodzi tu o samą ramę oraz siłowniki hydrauliczne. W swoich wcześniejszych pracach (między innymi w Fałat 2004), autor badał wpływ podatności konstrukcji na dynamikę A-ramy podczas jej pracy w warunkach falowania morskiego. Podatność tę modelowano przy użyciu metody sztywnych elementów skończonych (Kruszewski i inni, 1999). W wyniku przeprowadzonych analiz stwierdzono, że w zadaniu optymalizacji (to znaczy w zadaniu poszukiwania funkcji napędowej wciągarki stabilizującej położenie ładunku na zadanej głębokości) podatność konstrukcji może być pominięta. Założenie takie radykalnie ogranicza liczbę stopni swobody układu dzięki czemu wyraźnie wzrasta efektywność obliczeniowa procesu optymalizacji. Nie można natomiast pominąć podatności układu linowego, szczególnie wówczas, gdy prace podwodne prowadzone są przy znacznych długościach liny. Wówczas jej podatność może być o kilka rzędów większa niż podatność samej konstrukcji żurawia.

Przyjęto ponadto, że znany jest ruch statku bazy (Rys. 2), na którym znajduje się urządzenie i opisany jest on współrzędnymi będącymi funkcjami czasu (1). W wielu publikacjach dotyczących dynamiki urządzeń offshore przyjmuje się, że funkcje te są funkcjami harmonicznymi (Paszkievicz i inni, 1999; Fossen, 1994; Mosoud, 2000).

$$\begin{cases} x_C = x_C(t) = A_{x_C} \sin(\omega_{x_C} t + \phi_{x_C}) \\ y_C = y_C(t) = A_{y_C} \sin(\omega_{y_C} t + \phi_{y_C}) \\ z_C = z_C(t) = A_{z_C} \sin(\omega_{z_C} t + \phi_{z_C}) \\ \varphi_x = \varphi_x(t) = A_{\varphi_x} \sin(\omega_{\varphi_x} t + \phi_{\varphi_x}) \\ \varphi_y = \varphi_y(t) = A_{\varphi_y} \sin(\omega_{\varphi_y} t + \phi_{\varphi_y}) \\ \varphi_z = \varphi_z(t) = A_{\varphi_z} \sin(\omega_{\varphi_z} t + \phi_{\varphi_z}) \end{cases} \quad (1)$$



Rys. 2. Schemat modelu

Równania ruchu ładunku traktowanego jako masa skupiona mają postać:

$$\begin{cases} m_N x_N + C_l \cdot \frac{\Delta l}{|BN|} (x_N - a_x - lb_x) = 0 \\ m_N y_N + C_l \cdot \frac{\Delta l}{|BN|} (y_N - a_y - lb_y) = 0 \\ m_N z_N + C_l \cdot \frac{\Delta l}{|BN|} (z_N - a_z - lb_z) + m_N g - F_w = 0, \end{cases} \quad (2)$$

gdzie:  $m_N$  – masa ładunku,  $[x_N, y_N, z_N]^T$  – wektor współrzędnych ładunku,  $l$  – długość odcinka AB,  $g$  – przyspieszenie ziemskie,  $C_l$  – sztywność liny,  $\varphi_D$  – kąt obrotu bębna wciągarki,  $R_D$  – promień bębna wciągarki,  $\Delta l = |DB| + |BN| - l_0 + \varphi_D \cdot R_D$ ,  $l_0$  – długość liny bez obciążenia,  $|DB|$  – długość liny na odcinku bęben wciągarki – krążek zamontowany na A-ramie,

$|BN|$  – długość liny na odcinku krążek–ładunek,

$F_w$  – siła wyporu działająca na ładunek.

Wektory  $\mathbf{a}$  i  $\mathbf{b}$  są zdefiniowane następująco:

$$\mathbf{a} = \begin{bmatrix} x'_A - \varphi_z y'_A + \varphi_y z'_A + x_C \\ \varphi_z x'_A + y'_A - \varphi_x z'_A + y_C \\ -\varphi_y x'_A + \varphi_x y'_A + z'_A + z_C \\ 1 \end{bmatrix},$$

$$\mathbf{b} = \begin{bmatrix} -C_\beta S_\alpha - \varphi_z C_\beta S_\alpha + \varphi_y S_\alpha \\ -\varphi_z C_\beta S_\alpha + C_\beta S_\alpha - \varphi_x S_\alpha \\ \varphi_y C_\beta S_\alpha + \varphi_x C_\beta S_\alpha + S_\alpha \\ 1 \end{bmatrix},$$

$[x'_A, y'_A, z'_A]^T$  – wektor współrzędnych punktu A w układzie pokładu

$C_\beta = \cos(\beta)$ ,

$S_\alpha = \sin(\alpha)$ .

Zadanie optymalizacji zostało sformułowane następująco: *znaleźć funkcję napędową określającą przebieg czasowy kąta obrotu bębna wciągarki dla znanych funkcji:*

$$\begin{matrix} x_C(t) & \varphi_x(t) \\ y_C(t) & \varphi_y(t) \\ z_C(t) & \varphi_z(t) \end{matrix} \quad (3)$$

opisujących ruch statku bazy, tak by zminimalizować funkcjonal  $F$  opisany równaniem:

$$F = \int_0^{t_k} [z_N - h]^2 \rightarrow \min \quad (4)$$

gdzie:  $t_k$  – czas obserwacji,  $h$  – zadane położenie ładunku.

W każdym kroku optymalizacji całkowane są równania ruchu (2).

Do rozwiązania zadania optymalizacji wykorzystany został algorytm Nelder’a-Mead’a (pełzającego sympleksu) w połączeniu z metodą Powella do znajdowania minimum kierunkowego (Chapra i Canale, 2002). Dokładny opis modelu matematycznego A-rama oraz rozwiązanie zadania optymalizacji zostały przedstawione w pracy (Fałat, Wojciech 2003).

#### 4. SZTUCZNA SIEĆ NEURONOWA

Ponieważ zaprezentowana w poprzednim rozdziale metoda znajdowania stosownej funkcji napędowej stabilizującej ładunek na zadanej głębokości na drodze optymalizacji jest zbyt czasochłonna aby mogła zostać zastosowana w czasie rzeczywistym, postanowiono podjąć próbę wykorzystania sztucznej sieci neuronowej.

##### 4.1. Budowa sieci

Obliczenia związane ze sztuczną siecią neuronową przeprowadzono przy wykorzystaniu autorskiego programu napisanego w języku C#. W odróżnieniu od typowych implementacji komercyjnych, program napisany w języku C# wykorzystuje programowanie obiektowe również do konstrukcji sieci. Istota takiego rozwiązania została przedstawiona w (Fałat i inni. 2000). We wspomnianym programie, do nauki sieci wykorzystywana jest metoda wstecznej propagacji błędów. Dobór konfiguracji sieci przeprowadzono metodą prób i błędów. Także testowanie sieci przeprowadzane jest „ręcznie” poprzez przeliczenie konkretnych przypadków.


W wyniku szeregu testów zdecydowano się na zastosowanie, sieci składającej się z 4 wejść, 3 warstw ukrytych i 9 wyjść (Rys. 3).

Dane na wejściach sieci stanowią wybrane parametry opisujące ruch statku. Są to:

- amplituda ruchu statku wzdłuż osi z;
- częstość ruchu statku wzdłuż osi z;
- amplituda obrotów wokół osi y;
- częstość obrotów wokół osi y.

Jak wskazują wcześniejsze doświadczenia autora, parametry te mają największy wpływ na ruch ładunku

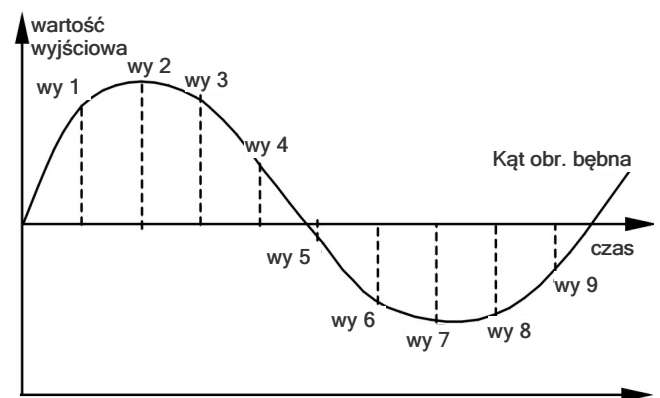
w kierunku pionowym, a więc są najistotniejsze ze względu na stabilizację jego głębokości w przypadku gdy A-rama umiejscowiona jest na burcie statku. Ograniczono zatem ruchy statku do dwóch spośród 6 funkcji (1). Uproszczenie takie zdecydowanie ułatwia proces uczenia, co nie jest bez znaczenia na wstępnym etapie analiz.



Rys. 3. Budowa sieci

W neuronach, z których zbudowana została sieć, zaimplementowano funkcję aktywacji w postaci funkcji sigmoidalnej i połączono z obiektem typu bias (Tadeusiewicz, 1993).

Wielkościami wyjściowymi z sieci są kolejne wartości definiujące funkcję napędową (Rys. 4), to znaczy wartości kąta obrotu bębna wciągarki dla dyskretnych, zdefiniowanych wcześniej, chwil czasu. Ciągła postać tej funkcji jest następnie wyznaczana przy zastosowaniu interpolacji funkcjami sklejanymi.



Rys. 4. Funkcja napędowa wciągarki

Ponieważ zarówno w procesie optymalizacji jak w budowie sieci neuronowej przyjmowano jednakową liczbę równo odległych punktów wewnętrznych w przedziale  $\langle 0, t_k \rangle$  łatwo można wyznaczyć błąd na wyjściu sieci neuronowej jako:

$$\varepsilon_i = wy_{iPS} - wy_{iN} \quad (5)$$

gdzie:  $wy_{iPS}$  – wartość na wyjściu  $i$  w pojedynczym zadaniu optymalizacji,  $wy_{iN}$  – wartość na wyjściu  $i$  sieci neuronowej.

## 4.2. Proces uczenie sieci

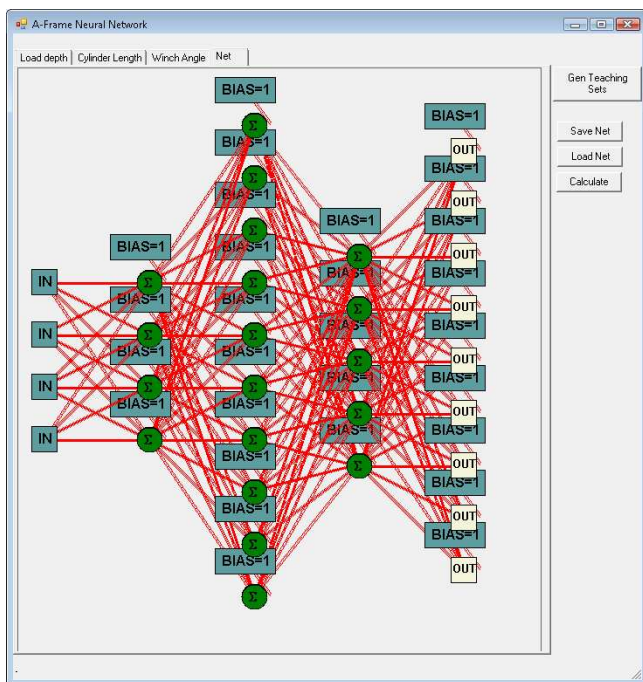
Ze względu na skuteczność i poprawność działania sztucznej sieci neuronowej bardzo istotny jest proces jej uczenia. Ważna jest przy tym zarówno liczba danych uczących jak i ich charakter. W omawianym przypadku, wykorzystując „klasyczną” metodę optymalizacji (pełzający sympleks), przygotowano 1440 zbiorów uczących uwzględniających zmiany parametrów wejściowych. Zakres zmian tych parametrów przedstawia tabela 1:

**Tab. 1.** Zakres zmian parametrów

Parametr		Wartość początkowa	Wartość końcowa	Krok
Amplituda Z [m]	Z	0.5	3	0.5
Omega Z [rad/s]	Z	0,261799388	0,523598776	0,087266463
Amplituda $\varphi_y$ [rad]	$\varphi_y$	0,008726646	0,130899694	0,008726646
Omega $\varphi_y$ [rad/s]	$\varphi_y$	0,261799388	0,523598776	0,087266463

Do uczenia zastosowano algorytm wstecznej propagacji błędów (Tadeusiewicz 1993) będący jedną z podstawowych metod uczenia sztucznych sieci neuronowych.

## 4.3. Pakiet komputerowy



**Rys. 5.** Przykładowy ekran pakietu komputerowego

Jak już wspomniano pakiet komputerowy wykonano z wykorzystaniem języka C#. Składa się z dwóch modułów (programów): Pierwszy służył do wyznaczania wartości funkcji napędowej wciągarki jako rozwiązania pojedynczego zadania optymalizacji. Drugi umożliwiał stworzenie i nauczanie sieci neuronowej. Część zawierająca algorytm

optymalizacyjny była wykorzystana w pierwszym etapie do przygotowania zbiorów uczących. Wykonano symulacje, zmieniając wybrane parametry (Tab. 1). Wyuczona sieć była następnie zapisywana do pliku z wykorzystaniem mechanizmu serializacji (Duffy J. 2007). Mechanizm ten zastosowano z uwagi na obiektowe podejście do tworzenia sieci neuronowej. Taki sposób umożliwia bowiem dokonanie operacji zapisu szeregu powiązanych ze sobą obiektów.

Otrzymana sieć mogła być następnie wczytywana do pierwszego programu, zmodyfikowanego tak, że potrafił wykonać zarówno klasyczną optymalizację jak i porównać jej wyniki z wynikami otrzymanymi z sieci neuronowej.

## 5. WYNIKI OBLICZEŃ

Po fazie nauki, uzyskaną sztuczną sieć neuronową wczytano do programu umożliwiającego symulację dynamiki modelu A-ramy. Następnie przeprowadzono szereg obliczeń porównawczych. Analizowano zachowanie się ładunku i funkcje napędowe uzyskane przy zastosowaniu metody optymalizacji oraz z sieci neuronowej. Czas obliczeń nie był parametrem porównywanym. Ze swojej istoty sztuczna sieć neuronowa jest bowiem wielokrotnie szybsza niż algorytmy optymalizacyjne. Poniżej zaprezentowane zostaną wyniki dla trzech przypadków (Tab. 2) danych wejściowych, pokazujące zarówno poprawne działanie sieci neuronowej jak i jej niezadawalającą odpowiedź. Przypadki A i B ilustrują poprawne działanie sieci neuronowej. Przypadek C obrazuje niewłaściwe zachowanie sieci, nie zapewniające stabilizacji ładunku na zadanej głębokości.

**Tab. 2.** Dane testowe

Parametr	Przypadek A	Przypadek B	Przypadek C
Amplituda Z [m]	2.25	2.5	2.6
Omega Z [rad/s]	0.52359	0.52359	0.50614
Amplituda $\varphi_y$ [rad]	0.05934	0.12915	0.12915
Omega $\varphi_y$ [rad/s]	0.366519	0.52359	0.52359

Kolejne rysunki przedstawiają wyniki obliczeń, przy czym rozważano przypadki:

- bez optymalizacji (to znaczy przy nieruchomym bębnie wciągarki);
- z optymalizacją (funkcja napędowa bębna wciągarki wyznaczona metodą pełzającego sympleksu);
- z siecią neuronową (funkcja napędowa bębna wciągarki wyliczona poprzez sieć).

Rys. 6 i Rys. 7 prezentuje wyniki dla Przypadku A z (Tab. 2), Rys. 8 i Rys. 9 to wyniki w Przypadku B, natomiast Rys. 10 i Rys. 11 dotyczą Przypadku C.




Fig. 6. Przypadek A: Zmiana położenia ładunku w kierunku pionowym




Fig. 9. Przypadek B: Kąt obrotu bębna wciągarki




Fig. 7. Przypadek A: Kąt obrotu bębna wciągarki

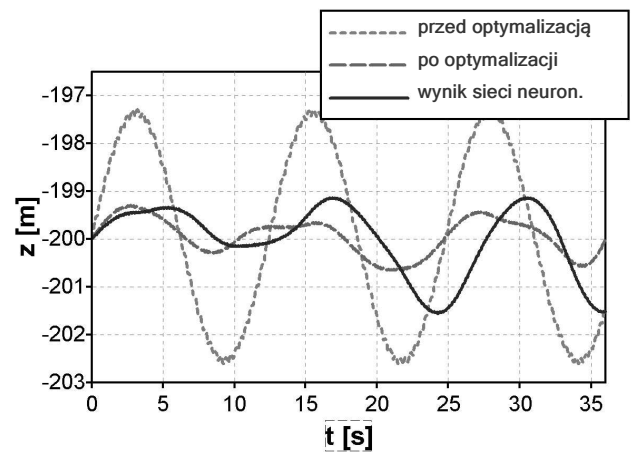


Fig. 10. Przypadek C: Zmiana położenia ładunku w kierunku pionowym

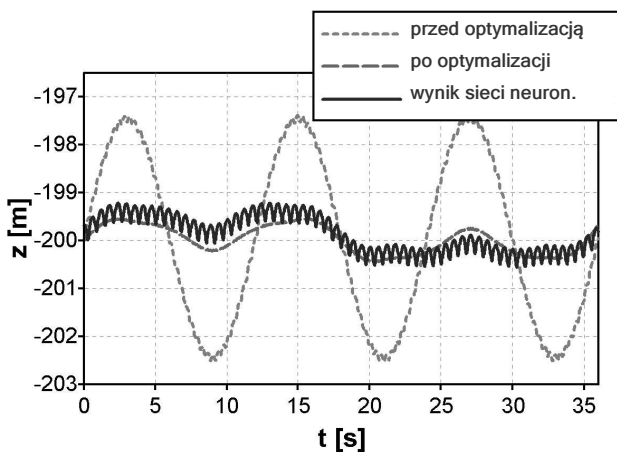


Fig. 8. Przypadek B: Zmiana położenia ładunku w kierunku pionowym




Fig. 11. Przypadek C: Kąt obrotu bębna wciągarki

Warto zwrócić uwagę, że w przypadku C wszystkie parametry były bliskie maksymalnym. Poprzez poszerzenie zakresu obliczeń dotyczących określenia zbioru uczącego możliwe byłoby uzyskanie stabilizacji i w tym przypadku

## 6. PODSUMOWANIE

Niniejszy artykuł przedstawia wyniki wstępnych prac autora związanych z zagadnieniem poszukiwania funkcji napędowej wciągarki żurawia offshore, zapewniającej stabilizację położenia ładunku na zadanej głębokości, za pomocą sieci neuronowych. Uzyskane wyniki potwierdzają możliwość stosowania takiej metody.

Jakość wyników można by znacznie poprawić poprzez poszerzenie zbioru uczącego (zwiększenie wartości w Tab. 1), lub poprzez zbudowanie sieci o innej strukturze (fizycznej i z innymi funkcjami aktywacji). Mimo, że poszukiwanie innej struktury sieci jest procesem bardzo pracochłonnym, wymagającym wielu obliczeń, to obiektowa budowa sieci, jaką zastosowano w programie komputerowym, umożliwia łatwą implementację takich zmian, w tym budowę sieci o różnych strukturach (niekoniecznie standardowych). Również implementacja innych algorytmów uczenia jest w podejściu obiektowym łatwa do realizacji.

Innym czynnikiem, który wydaje się że może pozytywnie wpłynąć na uzyskiwane rozwiązania, jest zmiana funkcji wyjściowej w zadaniu optymalizacji (klasycznej i siecią neuronową). Ponieważ przyjęte wymuszenia ruchu bazy żurawia są funkcjami harmonicznymi, więc celowa wydaje się próba wykorzystania do opisu ruchu wciągarki funkcji w postaci:

$$\varphi_D = A \sin(\omega t + \varphi_0), \quad (6)$$

zamiast stosowanych dotychczas funkcji sklepanych (Rys. 4). W takim przypadku sieć neuronowa szukałaby tylko parametrów  $A$ ,  $\omega$ ,  $\varphi_0$ , co znacznie uprościłoby zadanie, skróciło czas niezbędny na przygotowanie sieci neuronowej oraz, być może, pozwoliłoby na uzyskanie lepszych wyników. Powyższe uwagi wskazują na kierunki dalszych prac.

## LITERATURA

1. **Adamiec-Wójcik I., Fałat P., Gancarczyk T.** (2003), Computer Analysis of static loads of an A-Frame, *Zeszyty Naukowe Akademii Techniczno – Humanistycznej w Bielsku – Białej*, Zeszyt nr 6, 7-25.
2. **Duffy J.** (2007), *.NET Framework 2.0*, Zaawansowane programowanie, Helion.
3. **Chapra S.C., Canale R.P.** (2002), *Numerical methods for engineers*, McGraw-Hill Higher Education, New York.
4. **Fałat P.** (2004), *Analiza dynamiczna żurawia okrętowego typu A-rama*, rozprawa doktorska, ATH Bielsko-Biała.
5. **Fałat P., Wojciech S.** (2003), Application of non-linear optimisation methods to stabilise motion of a sea probe, *Zeszyty Naukowe Akademii Techniczno – Humanistycznej w Bielsku – Białej*, Zeszyt nr 6, pp. 29-40.
6. **Fałat P., Brzozowska L., Brzozowski K.** (2000), Application of object oriented neural network to control motion of the load of a sea crane, *International Scientific Journal of Computing*.
7. **Fałat P. Maczyński A. Wojciech S.** (2009), Optymalizacja w planowaniu ruchu urządzeń dźwigowych - część II, *Pomiary Automatyka Kontrola*, Nr 6/2009.
8. **FOSSON T.I.** (1994), *Guidance and Control of ocean vehicles*, John Wiley and sons Chichester England.

9. **Kruszewski J., Sawiak S., Wittbrodt E.** (1999), *Metoda sztywnych elementów skończonych w dynamice konstrukcji*, WNT – Warszawa.
10. **Maczyński A.** (2005), *Pozycjonowanie i stabilizacja położenia ładunku żurawia wysięgnikowych*, Wydawnictwo Akademii Techniczno – Humanistycznej.
11. **Mosoud Z.N.** (2000), *A control system for the reduction of cargo pendulation of ship mounted cranes*, Virginia Polytechnic Institute and State University, Doctoral Thesis, Blacksburg, Virginia USA.
12. **Paszkiewicz T., Osiński M., Wojciech S.** (1999), Dynamic Analysis of an Offshore Crane on Offshore Installations, *The 4th International Offshore Cranes Conference Stavanger*, Norway.
13. **Tadeusiewicz, R.** (1993), *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa.

## APPLICATION OF NEURAL NETWORK TO DEFINE WINCH DRIVE FUNCTION

**Abstract:** The paper presents the application of the neural network to controlling of the drive function of a sea crane winch. The function ensures the load stabilization on a proper depth. The base ship movements, caused by the sea waves, are taken into consideration. The author applied the neural network and the object oriented programming techniques which have been used to create own software applications.