

Krzysztof BRZOZOWSKI¹
Andrzej MACZYŃSKI²

SZTUCZNA SIEĆ NEURONOWA A POZYCJONOWANIE ŁADUNKU ŻURAWIA W RUCHU OBROTOWYM DLA RÓŻNYCH WYSIĘGÓW

Z punktu widzenia bezpieczeństwa i efektywności prac wykonywanych przy zastosowaniu żurawi obrotowych istotne jest końcowe pozycjonowanie ładunku w ruchu obrotowym nadwozia. W niniejszej pracy zaproponowano do rozwiązania tego zagadnienia zastosowanie sztucznej sieci neuronowej. Zbiór uczący uzyskano bazując na optymalizacji dynamicznej. Zaprezentowano przykładowe wyniki symulacji numerycznych dla określonego kąta obrotu i różnych wysięgów żurawia.

AN ARTIFICIAL NEURAL NETWORK AND CRANE'S LOAD POSITIONING IN SLEWING MOTION FOR DIFFERENT RADIUSSES

From the point of view of safety and efficiency of works performed with the use of a rotary crane the final positioning of a load in the slewing motion of the upper structure is very important. In the paper an artificial neural network is proposed to solve this problem. Training set was obtained based on dynamic optimization. The exemplary results of numerical simulations for a given angle of slew and different crane radiusses are presented.

1. WSTĘP

Od szeregu lat, w różnych ośrodkach naukowych, prowadzone są prace związane ze sterowaniem ruchem obrotowym żurawi [1], [3-4], [14]. Zazwyczaj poszukuje się funkcji napędowych zapewniających końcowe pozycjonowanie ładunku dla określonego kąta obrotu [6], [7], [13], choć oczywiście stosowane są także inne kryteria. We swoich wcześniejszych pracach autorzy poszukiwali przebiegu czasowego funkcji napędowej obrotu nadwozia, zapewniającej końcowe pozycjonowanie ładunku, na drodze optymalizacji [7], [10]. Zadanie to realizowane było dla uproszczonego, efektywnego numerycznie, modelu żurawia. Pomimo to metoda jest na tyle czasochłonna, że nie może być stosowana w czasie rzeczywistym. Stąd też autorzy poszukują innych dróg,

¹ Akademia Techniczno-Humanistyczna, Katedra Informatyki Stosowanej; 43-309 Bielsko-Biała; ul. Willowa 2, e-mail: kbrzozowski@ath.eu

² Akademia Techniczno-Humanistyczna, Katedra Informatyki Stosowanej; 43-309 Bielsko-Biała; ul. Willowa 2, e-mail: amaczyński@ath.eu

pozwalających na szybkie otrzymanie rozwiązania. Jedną z nich może być zastosowanie sztucznej sieci neuronowej. Próby takie podejmują także inni badacze [11].

Podstawowe parametry określające ruch obrotowy nadwozia żurawia to: kąt i czas obrotu, masa ładunku oraz wysięg. O wartości kąta obrotu i wysięgu decyduje oczywiście operator, natomiast przyjęto, że czas obrotu będzie określony przez układ sterujący. Wcześniejsze badania autorów wskazują, że poszukiwania stosownej funkcji napędowej mogą być przeprowadzane dla jednej masy ładunku, odpowiadającej maksymalnemu udźwigowi żurawia dla danego wysięgu [8]. Zmniejszenie masy ładunku powoduje bowiem poprawę jego końcowego pozycjonowania. Zadaniem układu sterującego bazującego na sztucznej sieci neuronowej jest zatem określenie czasu obrotu oraz wygenerowanie przebiegu funkcji napędowej dla podanego przez operatora żądanego kąta i wysięgu.

Sztuczna sieć neuronowa musi być podana procesowi uczenia na podstawie odpowiednio dobranego zbioru uczącego. Zbiór danych uczących tworzą w tym przypadku funkcje napędowe zapewniające końcowe pozycjonowanie ładunku, zdefiniowane dla konkretnych, wybranych a priori parametrów. Do wyznaczenia tych funkcji zaproponowano zastosowanie opracowanej uprzednio metody bazującej na optymalizacji dynamicznej. W niniejszym artykule przedstawione zostaną wyniki symulacji numerycznych związanych z poszukiwaniem funkcji napędowych dla przypadku gdy kąt obrotu jest stały, zmienny jest natomiast wysięg żurawia. Przypadek stałego wysięgu i zmiennego kąta obrotu był przedmiotem publikacji [5].

Przeprowadzenie omawianych analiz wymagało wykonania następujących kroków:

1. opracowanie uproszczonego modelu żurawia stosowanego następnie w zadaniu optymalizacji,
2. zdefiniowanie i rozwiązanie zadania optymalizacji pozwalającego wyznaczyć funkcje napędowe obrotu nadwozia żurawia zapewniające, końcowe pozycjonowanie ładunku dla określonych parametrów obrotu,
3. przygotowanie zbioru uczącego dla sieci neuronowej przy wykorzystaniu narzędzi opracowanych w krokach 1 i 2,
4. zaproponowanie schematu architektury sieci neuronowej i przeprowadzenie procesu uczenia sieci,
5. wykonanie symulacji numerycznych pozwalających na ocenę przydatności opracowanej metody końcowego pozycjonowania ładunku; etap ten przeprowadzono bazując na modelu matematycznym, w którym uwzględniono podatność i tłumienie w wybranych podukładach żurawia.

2. UPROSZCZONY MODEL ŻURAWIA STOSOWANY W ZADANIU OPTYMALIZACJI

Ze względu na konieczność wielokrotnego powtarzania obliczeń, rozwiązywanie zadania optymalizacji powinno bazować na efektywnym numerycznie modelu matematycznym. Założono zatem całkowitą sztywność układu nośnego żurawia, dzięki czemu uzyskano model o trzech stopniach swobody (rys.1). Wówczas równania ruchu ładunku mogą być przedstawione w postaci:

$$m_L \ddot{x}_L = S \frac{x_G - x_L}{l}, \quad (1a)$$


$$m_L \ddot{y}_L = S \frac{y_G - y_L}{l}, \quad (1b)$$

$$m_L \ddot{z}_L = S \frac{z_G - z_L}{l} - m_L g, \quad (1c)$$

gdzie: m_L – masa ładunku,

S – siła w linie,

l – długość liny, długość odcinka GL.



Rys.1. Schemat modelu żurawia stosowanego w zadaniu optymalizacji

Równania (1), w których występują 4 niewiadome x_L , y_L , z_L , S należy uzupełnić o równanie więzów postaci:

$$|GL|^2 = [x_G - x_L]^2 + [y_G - y_L]^2 + [z_G - z_L]^2 = const \quad (2)$$

oznaczające, że długość odcinka GL liny (wahadła sferycznego) jest stała. Po dwukrotnym zróżniczkowaniu równania (2) otrzymano następującą zależność:

$$\begin{aligned} (x_G - x_L)\ddot{x}_L + (y_G - y_L)\ddot{y}_L + (z_G - z_L)\ddot{z}_L = \\ = (\dot{x}_G - \dot{x}_L)^2 + (\dot{y}_G - \dot{y}_L)^2 + (\dot{z}_G - \dot{z}_L)^2 + \ddot{x}_G(x_G - x_L) + \ddot{y}_G(y_G - y_L) + \ddot{z}_G(z_G - z_L) \end{aligned} \quad (3)$$

Mnożąc równania (1) odpowiednio przez $(x_G - x_L)$, $(y_G - y_L)$, $(z_G - z_L)$ i dodając je, uzyskuje się:

$$(x_G - x_L)\ddot{x}_L + (y_G - y_L)\ddot{y}_L + (z_G - z_L)\ddot{z}_L = S \frac{l}{m_L} - g(z_G - z_L). \quad (4)$$

Porównując (3) i (4) otrzymano wzór na siłę S :

$$S = \frac{m_L}{l} [g(z_G - z_L) + (\dot{x}_G - \dot{x}_L)^2 + (\dot{y}_G - \dot{y}_L)^2 + (\dot{z}_G - \dot{z}_L)^2 + \ddot{x}_G(x_G - x_L) + \ddot{y}_G(y_G - y_L) + \ddot{z}_G(z_G - z_L)] \quad (5)$$

Tak wyznaczoną siłę S można podstawić do równań ruchu ładunku (1). Wielkości $x_G, y_G, z_G, \dot{x}_G, \dot{y}_G, \dot{z}_G, \ddot{x}_G, \ddot{y}_G, \ddot{z}_G$ zależą od kąta obrotu żurawia φ . Zgodnie z rys.1 zachodzi:

$$\begin{cases} x_G = d \cos \psi \cos \varphi = d' \cos \varphi \\ y_G = d \cos \psi \sin \varphi = d' \sin \varphi; \\ z_G = d \sin \psi = \text{const} \end{cases} \quad \begin{cases} \dot{x}_G = -\dot{\varphi} \cdot d' \sin \varphi \\ \dot{y}_G = \dot{\varphi} \cdot d' \cos \varphi; \\ \dot{z}_G = 0 \end{cases} \quad \begin{cases} \ddot{x}_G = -\ddot{\varphi} \cdot d' \sin \varphi - \dot{\varphi}^2 \cdot d' \cos \varphi \\ \ddot{y}_G = \ddot{\varphi} \cdot d' \cos \varphi - \dot{\varphi}^2 \cdot d' \sin \varphi \\ \ddot{z}_G = 0 \end{cases}, \quad (6)$$

gdzie $d' = d \cos \psi$.

3. SFORMUŁOWANIE ZADANIA OPTYMALIZACJI

Zadanie optymalizacji dynamicznej, do których należy rozpatrywany problem doboru funkcji napędowej obrotu żurawia, można sformułować następująco:

– znaleźć minimum funkcjonału:

$$F = F(w, \dot{w}, x), \quad (7)$$

gdzie: w, \dot{w} – wektory współrzędnych i prędkości uogólnionych,

x – wektor zmiennych decyzyjnych określających optymalizowaną funkcję napędową,

– zapewniając spełnienie ograniczeń:

$$q_j(w, \dot{w}, x) \leq 0 \quad j=1, \dots, n_g, \quad (8.1)$$

$$h_j(w, \dot{w}, x) = 0 \quad j=1, \dots, n_h, \quad (8.2)$$

podczas gdy wektory w, \dot{w}, x powiązane są równaniami ruchu postaci:


$$M\ddot{w} = P(w, \dot{w}, \dot{x}) \quad \text{dla } t \in \langle t_0, t_k \rangle. \quad (9)$$

W dalszych rozważaniach przyjęto, że dla $t \in \langle 0, T \rangle$ (T oznacza czas obrotu) funkcja $\varphi_w(t)$, określająca wymuszenie kinematyczne obrotu żurawia, przybliżona jest funkcjami sklejonymi trzeciego stopnia (rys.2). Można wówczas zdefiniować funkcje $S_i(t)$:

$$S_i(t) = \varphi_w(t)|_{t \in (t_{i-1}, t_i)} = a_i(t - t_{i-1})^3 + b_i(t - t_{i-1})^2 + c_i(t - t_{i-1}) + d_i, \quad (10)$$

gdzie: $t_i = \frac{T}{n} \cdot i$, $i=0,1,\dots,n_d$,

a_i, b_i, c_i, d_i – współczynniki.



Rys.2. Przybliżenie funkcji $\varphi_w(t)$ za pomocą funkcji sklejanych

Jeśli znane są wartości $\varphi_{w,i} = \varphi_w(t_i)$ dla $i=0,1,\dots,n_d$ to wyznaczenie współczynników a_i, b_i, c_i, d_i sprowadza się do rozwiązania następującego układu $4n_d$ równań o $4n_d$ niewiadomych ($a_1, b_1, c_1, d_1, \dots, a_{n_d}, b_{n_d}, c_{n_d}, d_{n_d}$):

$$\left. \begin{array}{l} S_1(t_0) = \varphi_{w,0} \\ S_1'(t_0) = 0 \\ \vdots \\ S_i(t_i) = S_{i+1}(t_i) = \varphi_{w,i} \\ S_i'(t_i) = S_{i+1}'(t_i) \\ S_i''(t_i) = S_{i+1}''(t_i) \\ \vdots \\ S_{n_d}(t_0) = \varphi_{w,n_d} \\ S_{n_d}'(t_0) = 0 \end{array} \right\} i=1,2,\dots,n_d-1. \quad (11)$$

Jako zmienne decyzyjne w zadaniu optymalizacji przyjęto składowe wektora:

$$\mathbf{X} = [\varphi_{w,1}, \varphi_{w,2}, \dots, \varphi_{w,n_d-1}]^T. \quad (12)$$

Funkcjonał F występujący w (7) zdefiniowano następująco:

$$F = C_1 \cdot \frac{1}{2} m_L \cdot v_{LT}^2 + C_2 \cdot \|r_{LT} - r_{LF}\|^2, \quad (13)$$

gdzie: $r_{LT} = r_L|_{t=T}$; $v_{LT} = v_L|_{t=T}$,

r_{LF} – wektor oczekiwanych współrzędnych ładunku w chwili $t=T$,

v_L – prędkość ładunku,

C_1, C_2 – współczynniki (wagi).

Tak sformułowana funkcja celu oznacza, że oczekuje się, aby po zakończeniu obrotu ładunek znalazł się w określonym punkcie przestrzeni, a ponadto aby jego energia kinetyczna była minimalna. Współczynniki C_1 i C_2 dobrano poprzez eksperymenty numeryczne.

Sformułowane szczegółowe zadanie optymalizacji dynamicznej jest więc następujące: znaleźć minimum funkcjonału F określonego zależnością (13), poprzez dobór wartości $\varphi_{w,1}, \dots, \varphi_{w,n_d-1}$ będących składowymi wektora \mathbf{X} z (12). W celu określenia wartości funkcjonału F z (13) należy całkować równania ruchu (1), podczas gdy siła S określona jest wzorem (5), a związek pomiędzy funkcją φ oraz współrzędnymi punktu G określony jest w (6). Zadanie to jest zadaniem bez ograniczeń. Do jego rozwiązania zastosowano metodę pełzającego simpleksu.

Tak jak większość metod optymalizacyjnych, również metoda pełzającego simpleksu jest wrażliwa na wybór przybliżenia początkowego. W niniejszej pracy przyjęto, że początkowe przybliżenie wektora \mathbf{X} :

$$\mathbf{X}_0 = [\varphi_{w,1,0}, \dots, \varphi_{w,n_d-1,0}]^T, \quad (14)$$

otrzymuje się ze wzoru:

$$\varphi_{w,i,0} = \varphi_w(t_i) = \begin{cases} \frac{8\varphi_{w,\max}}{T^4} t^3 (-t + T) & \text{gdy } t \leq \frac{T}{2} \\ \frac{8\varphi_{w,\max}}{T^4} (t - T)^3 \cdot t + \varphi_{w,\max} & \text{gdy } t > \frac{T}{2} \end{cases}. \quad (15)$$

4. SZTUCZNA SIEĆ NEURONOWA

Jak wspomniano wcześniej, analizy prezentowane w niniejszej pracy dotyczą obrotu nadwozia o określony kąt. Dowolnie natomiast przyjmowany może być wysięg, określony pochylem wysięgnika. Wykorzystując metodę optymalizacji przedstawioną w rozdziale 3 przygotowano zbiór uczący wykorzystany do ustalenia architektury oraz wag sieci neuronowej. Zadaniem układu sterującego obrotem żurawia, opartego na sztucznej sieci neuronowej, jest wyznaczenie funkcji napędowej dla danego kąta obrotu i dowolnego kąta pochylem wysięgnika. W tym celu zaproponowano zastosowanie jednokierunkowej sztucznej sieci neuronowej o sigmoidalnej funkcji aktywacji neuronów, postaci:

$$f(\mathbf{w}^T \mathbf{z}) = \left[1 + e^{-\mathbf{w}^T \mathbf{z}} \right]^{-1}, \quad (16)$$


gdzie: \mathbf{w} – wektor wag połączeń wejściowych neuronu,
 \mathbf{z} – wektor sygnałów wejściowych do neuronu.

W niniejszej pracy, dla ustalonych a priori wartości $\varphi_{w,\max}$ oraz $n_d = 7$ przyjęto, że zbiór uczący stanowić będzie $k = 1, \dots, N$ par wektorów $\{\mathbf{I}, \mathbf{X}\}$, przy czym wektor sygnałów wejściowych do sieci ma postać:

$$\mathbf{I} = [\psi, t_1, \dots, t_i, \dots, t_7]^T, \quad (17)$$

gdzie $t_7 = T$.

Oznacza to, że na wejście sieci podawane jest równocześnie osiem sygnałów a na wyjściu oczekiwanych jest 7 wartości $\varphi_{w,i}$. Proces uczenia sieci neuronowej rozpoczęto od sieci z pojedynczą warstwą ukrytą oraz stałym sygnałem równym -1 podawanym na każdy z neuronów. Początkowe wartości wag połączeń pomiędzy poszczególnymi neuronami przyjęto losowo. Schemat zastosowanej sieci przedstawiono schematycznie na rys. 3.



Rys.3. Schemat architektury wykorzystanej sieci neuronowej

W pierwszym podejściu założono pięć neuronów na warstwie ukrytej i przeprowadzono proces doboru wartości wag połączeń poszczególnych neuronów z wykorzystaniem metody momentu z przyrostowym uaktualnianiem wag. Algorytm uaktualnienia wektora wag można zapisać w $n+1$ kroku uczenia sieci w postaci [12, 15]:

$$\mathbf{w}^{(n+1)} = \mathbf{w}^{(n)} - \eta^{(n)} \nabla E(\mathbf{w}^{(n)}) + \alpha (\mathbf{w}^{(n)} - \mathbf{w}^{(n-1)}) \quad (18)$$

gdzie: η – współczynnik uczenia,
 E – błąd odpowiedzi sieci,
 α – współczynnik momentu o wartości 0,9.

W każdym kroku algorytmu w wyniku podania sygnału wejściowego w postaci wektora \mathbf{I} , jako odpowiedź sieci otrzymuje się sygnał wyjściowy postaci:

$$\mathbf{O} = [\bar{\varphi}_{w,1}, \bar{\varphi}_{w,2}, \dots, \bar{\varphi}_{w,n_d-1}]^T, \quad (19)$$

a następnie obliczany jest średniokwadratowy błąd odpowiedzi sieci E dla wszystkich N wektorów uczących:

$$E = \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^{n_d-1} (\varphi_{w,i}^{(k)} - \bar{\varphi}_{w,i}^{(k)})^2 \quad (20)$$

gdzie $\varphi_{w,i}^{(k)}, \bar{\varphi}_{w,i}^{(k)}$ są odpowiednio i -tymi elementami wektorów $\mathbf{X}^{(k)}$ i $\mathbf{O}^{(k)}$.

Po wykorzystaniu do uczenia wszystkich N par wektorów $\{\mathbf{I}, \mathbf{X}\}$ weryfikowano zdolność sieci do poprawnej predykcji kątów obrotu $\varphi_{w,i}$ dla M elementowego zbioru par wektorów $\{\mathbf{I}, \mathbf{X}\}$ innych od tych wykorzystywanych w procesie uczenia. Przyjęto, że sieć jest poprawnie zdefiniowana i można ją wykorzystać w zadaniu sterowania jeżeli średni błąd względny odpowiedzi sieci zdefiniowany jako:

$$E_w = \frac{1}{M(n_d-1)} \sum_{j=1}^M \sum_{i=1}^{n_d-1} \frac{|\varphi_{w,i}^{(j)} - \bar{\varphi}_{w,i}^{(j)}|}{\varphi_{w,i}^{(j)}} 100\% \quad (21)$$


będzie dla danych ze zbioru weryfikującego równy lub mniejszy niż 5%.

Jeżeli kryterium weryfikacyjne $E_w \leq 5\%$ nie było spełnione, proces uczenia sieci kontynuowano ponownie zaczynając od losowego doboru początkowych wartości wag. W przypadku, gdy ponawiany wielokrotnie proces uczenia nie doprowadził do spełnienia kryterium weryfikacyjnego zwiększano liczbę neuronów na warstwie ukrytej. W przypadku rozważanego w pracy zadania dopiero sieć z dziewięcioma neuronami na warstwie ukrytej umożliwiła spełnienie przyjętego kryterium. Sieć tą zastosowano w zadaniu pozycjonowania ładunku.


5. SYMULACJE NUMERYCZNE

W prezentowanych symulacjach dane geometryczno-masowe modelu odpowiadały teleskopowemu, samojezdnemu żurawiovi klasy 30 MG. Długość wysięgnika wynosiła 10,5 m, a początkowa wysokość ładunku nad podłożem 2 m. Masa ładunku była zmienna i odpowiadała maksymalnemu udźwigowi żurawia dla danego wysięgu. Zbiór uczący dla sieci neuronowej bazował na funkcjach wyznaczonych dla obrotu o kąt 90° realizowanego w ciągu 15 s oraz następujących kątów pochylenia wysięgnika: $20^\circ, 22^\circ, 24^\circ, \dots, 80^\circ$. Obliczenia przeprowadzono dla modelu żurawia uwzględniającego podatność układu nośnego, w tym układu podporowego, wysięgnika i liny nośnej, oraz tłumienie w wybranych podukładach teleskopowego. Dokładne omówienie tego modelu wykracza

poza ramy niniejszej pracy. Był on przedstawiony między innymi w [2], a jego weryfikacja pośrednia w [9].



Rys.4. Funkcje napędowe wg zależności (14) i jako odpowiedź z sieci neuronowej dla kątów pochylenia wysięgnika 35° i 75°



Rys.5. Fragmenty trajektorii ładunku dla kątów pochylenia wysięgnika 35° i 75°

Prezentowane wykresy otrzymano przy założeniu, że kąt pochylenia wysięgnika wynosi 35° oraz 75° , czyli jest spoza zbioru uczącego. Porównano przebiegi funkcji napędowych określonych zależnością (14) tj. początkowe rozwiązanie przyjmowane w zadaniu optymalizacji z funkcjami uzyskanymi jako odpowiedź sieci neuronowej, oraz odpowiadające im końcowe fragmenty rzutu trajektorii ładunku na płaszczyznę XY.

6. WNIOSKI

Przedstawione wyniki symulacji numerycznych potwierdzają przydatność zaproponowanej metody wyznaczania funkcji napędowych obrotu żurawia zapewniających końcowe pozycjonowanie ładunku. Pozwala ona uzyskać wyraźne zmniejszenie amplitudy wahań ładunku po zakończeniu obrotu nadwozia. Niewątpliwą jej zaletą jest możliwość sterowania obrotem w czasie rzeczywistym. Operator lub układ sterujący określa parametry obrotu, a sztuczna sieć neuronowa w ciągu kilku milisekund wyznacza przebieg czasowy funkcji napędowej.

Warto także zauważyć, że przyjęcie jednego czasu obrotu dla różnych wysięgów powoduje, że przy mniejszym pochyleniu wysięgnika, już dla początkowego przybliżenia funkcji napędowej, uzyskuje się stosunkowo niewielkie amplitudy końcowych wahań

ładunku. Celowe więc wydaje się przeprowadzenie w przyszłości analiz dotyczących możliwości zwiększenia prędkości obrotu przy większych wysięgach żurawia, lub takiego zdefiniowania zadania optymalizacji, aby układ sam określał czas obrotu, oczywiście przy założeniu, że końcowe wahania ładunku nie mogą przekroczyć określonej wartości granicznej.

7. BIBLIOGRAFIA

- [1] Abdel-Rahman E. M., Nayfeh A. H.: *Pendulation Reduction in Boom Cranes Using Cable Length Manipulation*, *Nonlinear Dynamics*, 27 (3), 255-269, 2002
- [2] Adamiec-Wójcik I., Maczyński A., Wojciech S.: *Zastosowanie metody przekształceń jednorodnych w modelowaniu dynamiki urządzeń offshore*, Warszawa, WKŁ, 2008
- [3] Balachandran B., Li YY., Fang CC.: *A mechanical filter concept for control of non-linear crane-load oscillations*: *Journal of Sound & Vibrations*, 228, 651-682, 1999
- [4] Bednarski S., Cink J., Tomczyk J.: *Pozycjonowanie ładunku w ruchu roboczym żurawia portowego*, X Konferencja Problemy Rozwoju Maszyn Roboczych, Zakopane, Zeszyt I, 25-32, 1997
- [5] Brzozowski K. Maczyński A.: *The application of an artificial neural network to load positioning in slewing motion of a crane*, *International Journal of Applied Mechanics and Engineering*, vol. 13, No.3, 413-421, 2010
- [6] Kłosiński J.: *Sterowanie ruchami roboczymi żurawi samojezdnych zapewniające pozycjonowanie przenoszonego ładunku*: *Zeszyty Naukowe Politechniki Łódzkiej Filii w Bielsku-Białej, Rozprawy naukowe, Z. 35, nr 55, Bielsko-Biała, 2000*
- [7] Maczyński A.: *Load positioning and minimization of load oscillations for rotary cranes*, *Journal of Theoretical and Applied Mechanics*, Vol. 41, No. 4, 873-885, 2003
- [8] Maczyński A.: *Determination of drive functions of slewing of a mobile crane which minimize load oscillations*, *The Archive of Mechanical Engineering*, Vol. L, No 2, 167-199, 2003
- [9] Maczyński A., Szczotka M.: *Comparison of models for dynamic analysis of a mobile telescopic crane*, *Journal of Theoretical and Applied Mechanics*, Vol 40, No. 4, 1051-1074, 2002
- [10] Maczyński A., Wojciech S.: *Dynamics of a Mobile Crane and Optimisation of the Slewing Motion of its Upper Structure*: *Nonlinear Dynamics*, 32, 259-290, 2003
- [11] Nakazono K., Ohnishi K., Kinjo H., Yamamoto T.: *Vibration control of load for rotary crane system using neural network with GA-based training*, *Artif Life Robotics*, 13, 98-101, 2008
- [12] Osowski S.: *Sieci neuronowe w ujęciu algorytmicznym*, Warszawa, WNT, 1996
- [13] Parker G. G., Groom K., Hurtado J. E., Feddema J., Robinett R. D., Leban F.: *Experimental verification of a command shaping boom crane control system*: *American Control Conference, San Diego, California, June, 86-90, 1999*
- [14] Sakawa Y., Shindo Y., Hashimoto Y.: *Optimal control of a rotary crane*, *Journal of Optimization Theory and Applications*, Vol. 35, No. 4, 535-557, 1981
- [15] Żurada J., Barski M., Jędruch W.: *Sztuczne sieci neuronowe*, Warszawa, PWN, 1996