

dr Maria Meler-Kapcia
Politechnika Gdańska

ZASTOSOWANIE SIECI NEURONOWEJ DO WSPOMAGANIA PROJEKTOWANIA WSTĘPNEGO STATKU

W referacie zaprezentowano strukturę oraz algorytm uczenia sieci neuronowej ze wsteczną propagacją błędów do wspomagania projektowania wstępnego dla doboru mocy silnika głównego statku na podstawie jego parametrów ogólnych. Algorytm zaimplementowany został w języku Visual Basic w systemie Access i może być zastosowany dla dowolnej liczby parametrów, którymi mogą być pola bazy danych statków zbudowanych. Uzyskane wyniki mogą służyć do weryfikacji projektu wstępnego, w którym nie wykorzystuje się podobieństwa statków.

ON APPLICATION OF NEURAL NETWORK FOR AIDED CONCEPTUAL SHIP DESIGN

In the paper the structure and error back-propagation neural network algorithm was presented to aid conceptual design for choosing of power output of ship's main engine (ME) based on the general ship's parameters (mainly its dimensions). This algorithm was elaborated in Visual Basic language and may be used for every parameters number as ship's constructed database fields. Obtained results may be used for project's verification in which similarity of ships is not used.

1. WSTĘP

W literaturze znaleźć można przykłady zastosowania sztucznej inteligencji, w tym sieci neuronowych, do wspomagania projektowania statków [1, 2, 9] zwłaszcza na etapie wstępnym, w którym na podstawie szczegółowych wymagań armatora określa się główne parametry statku. Dla zapewnienia optymalnych wymiarów głównych statku w jego projekcie często stosuje się podejście oparte na znajdowaniu statków o podobnych charakterystykach i ewentualnym dokonaniu modyfikacji zastosowanych rozwiązań projektowych.

Wykorzystanie informacji dotyczących wcześniej wykonanych podobnych projektów umożliwiając zarówno systemy ekspertowe za pomocą metody wnioskowania na podstawie przypadków [9], co ułatwia zaprojektowanie statku o wysokiej efektywności w możliwie krótkim czasie, jak i sieci neuronowe [11, 14], które można uczyć w oparciu o reprezentatywne przykłady oraz wyniki uzyskane z innych źródeł (np. podczas eksploatacji statku). W ten sposób przetwarzanie charakterystyczne dla tradycyjnych systemów ekspertowych jest komplementarne względem rozproszonego przetwarzania równoległego, jakim odznaczają się sieci neuronowe.

Oba te klasyczne narzędzia sztucznej inteligencji wraz z relacyjną bazą danych zostały zastosowane do wspomagania projektowania wstępnego statku w zakresie doboru mocy silnika głównego (SG) na podstawie parametrów wejściowych: nośności, długości całkowitej, szerokości, zanurzenia oraz prędkości przy użyciu metod obliczania podobieństwa w aplikacji bazy danych (z funkcją trapezową, Gaussa, trójkątną oraz z dolną granicą). Oceny skuteczności i prawidłowości tych metod dokonano poprzez ich analizę porównawczą w zestawieniu z wynikami uzyskanymi z sieci neuronowej.

Wartości parametrów statków o zbyt małym stopniu podobieństwa mogą być weryfikowane przez sieć neuronową, ze wsteczną propagacją błędów, która zaimplementowana została

w języku Visual Basic i może być zastosowana dla dowolnej liczby parametrów wejściowych i wyjściowych w postaci pól tabeli bazy danych statków zbudowanych.

Ma to miejsce wówczas, gdy nie znaleziono statku podobnego, a w tworzonym projekcie występują elementy projektów pochodzące z różnych statków lub został on utworzony samodzielnie przez projektanta (bez korzystania z podobieństwa statków).

2. SIEĆ NEURONOWA DLA DOBORU MOCY SILNIKA GŁÓWNEGO STATKU

W zastosowaniach sieci neuronowych wymagane jest posiadanie możliwie liczego zbioru uczącego. Obliczenia przeprowadzono na wybranych parametrach kilkuset statków zbudowanych w polskich stoczniach. W przeprowadzonych badaniach poszukiwano zależności mocy silnika głównego od parametrów wejściowych takich jak: nośność (DWT [t]), długość całkowita (LOA [m]) i szerokość statku (B [m]), jego zanurzenie (D [m]) oraz prędkość (V [w]).

Fragment bazy danych tych statków przedstawiono w tab. 1.


Tab. 1. Przykładowy fragment bazy danych statków zbudowanych

Lp.	DWT [t]	LOA [m]	B [m]	D [m]	V [w]	Moc SG [kW]
2	15300	148.9	23	8.5	14	6800
4	15300	148.9	23	8.5	14	6800
6	7200	169.9	28	12.3	20.5	8600
8	41600	206.5	30	11.5	14.3	11330
9	41450	205	30	11.48	14.6	8338
10	16500	149	23	8.5	18	7230
11	550	60.21	10.5	3.15	11	1200
12	210	30.25	10.2	4.72	5	600
13	1480	90.63	15.02	5.4	15	3600
15	1564	88.88	15.22	5.4	16	3600
17	18500	141.35	22.5	9.47	13	6650
18	2209	102.6	17.07	5.7	16.5	5200

W obliczeniach zastosowano sieć dwuwarstwową z ciągłą unipolarną funkcją aktywacji i klasyczny algorytm propagacji wstecznej błędu zmiany wag. Zbiór statków podzielono na dwa podzbiory: uczący i testujący. Do zbioru testującego wylosowano 25 % statków. Jako fragment zbioru uczącego wykorzystano dane z tab. 1. Wszystkie parametry statków przed rozpoczęciem obliczeń zostały znormalizowane do wartości z zakresu [0, 1].

W tym przypadku jeden cykl obliczeniowy składał się z wprowadzenia na wejście sieci kolejno parametrów wszystkich statków ze zbioru uczącego. Zakończenie uczenia sieci następowało wtedy, gdy średni błąd kwadratowy e_c w cyklu przyjmował wartość mniejszą od zadanej. Błąd ten dotyczył różnicy pomiędzy rzeczywistą mocą SG a mocą wyliczoną przez sieć dla tego samego statku.

Zbieżność procesu uczenia wyrażoną zależnością e_c od liczby cykli obliczeniowych l_c przedstawiono na rys. 1. Dane te uzyskano dla sieci o następujących cechach: pięć wejść (DWT, LOA, B, D, V), 25 neuronów w warstwie ukrytej, jeden neuron wyjściowy, współczynnik uczenia $\eta_l = 0,5$, parametr funkcji aktywacji $\beta = 1,5$.



Rys. 1. Zbieżność procesu uczenia sieci neuronowej

Po zakończeniu uczenia sieci na zbiorze uczącym statków, przeprowadzono obliczenia (z uzyskanymi wagami sieci) wykorzystując parametry statków ze zbioru testującego.

W obliczeniach testujących określono także średni błąd względny w procentach wyrażony wzorem:

$$e = \sum_{i=1}^n \frac{|M_{ri} - M_{oi}|}{M_{ri}} \cdot 100 \quad (1)$$

gdzie: M_r i M_o odpowiednio moc rzeczywista i moc obliczona przez sieć, n – liczba statków, i – numer statku.

Uzyskano następującą wartość tego błędu: $e = 23,13$ %, która w przypadku zastosowania metody regresji [14], dla tych samych danych, wyniosła 25,61 %.

Wnioski ogólne dotyczące zastosowanej metody uczenia sieci neuronowej można sformułować następująco:

- zbieżność procesu uczenia za pomocą algorytmu propagacji wstecznej błędów i ze stałym współczynnikiem uczenia jest stosunkowo słaba
- znaczna rozbieżność wyników dla zbioru testującego (duże wartości błędu) wynika z dużej różnorodności rozpatrywanych statków
- gradientowy algorytm uczenia ze stałym współczynnikiem uczenia η_1 charakteryzuje się szybką zbieżnością w fazie początkowej i słabszą zbieżnością w dalszej części obliczeń.

3. ALGORYTM UCZENIA SIECI NEURONOWEJ DLA DOBORU MOCY SG

Opracowany algorytm uczenia sieci neuronowej ze wsteczną propagacją błędów, zastosowany dla doboru mocy SG zaimplementowany został w języku Visual Basic i może być zastosowany dla dowolnej liczby parametrów wejściowych i wyjściowych w postaci pól tabeli bazy danych statków zbudowanych.

W algorytmie tym wymagane jest wskazanie bazy danych, a następnie tabeli, z której pochodzą pola przyjęte jako parametry dla sieci, w wyniku czego następuje przywołanie odpowiednich danych do wglądu. Po określeniu liczby cykli oraz wstępnej wartości błędu, jak również współczynników uczenia η_1 i korekcji wag η_2 uruchamiany jest proces uczenia sieci. Uzyskane wyniki z sieci neuronowej zapisywane są w osobnym polu „Oblicz” tabeli źródłowej.

Wartości wszystkich parametrów algorytmu uczenia sieci wprowadzane są za pośrednictwem formularza przedstawionego na rys. 2.

The screenshot shows a software interface for configuring a neural network. It includes a database selection area, a table of input/output nodes, a table of network parameters, and a 'Ucz sieć' button.

Wybór pól

Lp	Nazwa	Typ	Wej	Wyj	Obl.
1	Lp	Liczba całkc			
2	Dwt	Liczba całkc	1		
3	LQA		5	2	
4	B		5	3	
5	D		5	4	
6	V		5	5	
7	Moc	Single			1
8	Moc obl	Single			0

Wybór tabeli

Lp	Dwt	LQA	B	D	V	Moc	Oblicz.
1	22800,0000	200,0000	32,2600	9,5000	20,2000	22240,0000	25215,470
2	8700,0000	195,0000	25,2000	7,7000	22,0000	39890,0000	27645,990
3	8700,0000	195,0000	25,2000	7,7000	22,0000	39890,0000	29550,360
4	9415,0000	162,5000	25,2000	6,5000	18,0000	13380,0000	22746,110
5	9415,0000	162,5000	25,2000	6,5000	18,0000	13380,0000	21148,770
6	21400,0000	199,9000	32,2500	10,0000	20,1000	19460,0000	24573,900
7	21400,0000	199,9000	32,2500	10,0000	20,1000	19460,0000	23528,540
8	11900,0000	185,0000	25,5000	8,5000	24,0000	3400,0000	26707,940
9	11900,0000	185,0000	25,5000	8,5000	24,0000	3400,0000	22481,190
10	23630,0000	200,0000	30,4000	9,2000	20,0000	24160,0000	16097,620
11	23630,0000	200,0000	30,4000	9,2000	20,0000	24160,0000	18032,480
12	8800,0000	154,5000	22,7000	6,9500	20,0000	21200,0000	14261,800
13	8800,0000	154,5000	22,7000	6,9500	20,0000	21200,0000	15689,420
14	8800,0000	154,5000	22,7000	6,9500	20,0000	21200,0000	16789,080
15	8800,0000	154,5000	22,7000	6,9500	20,0000	21200,0000	17647,500
16	29800,0000	200,0000	32,2600	9,5000	20,2000	22240,0000	27645,990

Ucz sieć

Liczba cykli: 1000
 Błąd średni: 0,0562
 Współcz. uczenia pocz.: 0,1 konc.: 0,9
 Współcz. korekcji wag pocz.: 0,1 konc.: 0,6

Rys. 2. Formularz do wprowadzania wartości parametrów sieci neuronowej

W procesie uczenia sieci należy uwzględnić następujące problemy:

1. dobór zbioru uczącego o odpowiedniej wielkości
2. określenie wartości współczynników η_1 jako współczynnika uczenia oraz η_2 jako współczynnika korekcji wag
3. zdefiniowanie czasu uczenia.

Istotną rzeczą jest umiejętny wybór współczynnika uczenia η_1 , który ma ogromny wpływ na stabilność i szybkość całego procesu. Współczynnik η_1 jest mnożony przez propagowany wstecz błąd i odpowiada za szybkość uczenia. Zbyt mała wartość tego parametru powoduje, iż uczenie i zbieżność sieci jest bardzo wolne, przy zbyt dużej jego wartości proces poszukiwania optymalnego wektora wag jest rozbieżny i algorytm może stać się niestabilny [5]. Współczynnik η_2 mnożony jest przez wielkość zmiany wag w poprzednim kroku, „wygładzając” zbyt gwałtowne skoki wag połączeń.

Wartości współczynnika η_2 należy dobierać na zasadzie pewnego kompromisu, tak aby kolejne przyrosty wag stanowiły małą część ich aktualnych wartości (np. kilkuprocentową).

W literaturze [12] proponowana wartość współczynnika η_1 zawiera się w przedziale [0,05, 0,25]. Inni autorzy [13] podają jako wartości „klasyczne” tych współczynników: odpowiednio $\eta_1 = 0,9$, a $\eta_2 = 0,6$, przy czym zaznacza się, że w przypadku dużych sieci należy przyjmować wartości mniejsze, lecz o podobnych proporcjach względem siebie. Podczas uczenia wartości te powinny być zmniejszane, lecz proponowane jest również rozpoczynanie procesu uczenia sieci prawie od zerowych wartości współczynników η_1 i η_2 oraz stopniowe ich zwiększanie aż do osiągnięcia pewnej ustalonej wartości. Badania rozpoczęto od pewnych małych wartości współczynników, stopniowo je zwiększając. Czas uczenia określa się za pomocą liczby cykli prezentacji zbioru uczącego.

Wybrane przykłady zastosowania opracowanego algorytmu sieci neuronowej w zakresie doboru mocy SG, na podstawie wymiarów, nośności i prędkości statku, a następnie doboru mocy SG na podstawie jednego parametru wejściowego tj. prędkości statku, przedstawiono w tab. 2.

Badania w zakresie doboru mocy SG na podstawie innych parametrów projektowych, głównie wymiarów statku przeprowadzono dla przykładowej liczby cykli w zakresie

100-50000, przy wartościach współczynników η_1 i η_2 równych odpowiednio 0,9 i 0,6 oraz wartościach w zakresie 3-0,1 i 1-1.


W większości przypadków przyjęto rozwiązanie polegające na zmniejszaniu wartości współczynników uczenia, co spowodowało uzyskanie błędu średniego w granicach: 0,034 – 0,06.

W innych przypadkach, zastosowano te same wartości współczynników, co przyczyniło się do wzrostu błędu średniego, przy małej liczbie cykli nawet do wartości równej 0,1. W jednym przypadku zastosowano zwiększanie wartości współczynników, a uzyskany błąd średni nie odbiega od poprzednich wartości.

Tab. 2. Wyniki zastosowania opracowanego algorytmu sieci neuronowej


Parametry wyjściowe	Liczba cykli	Liczba param. we.	Wartości współczynników		Czas uczenia [min]	Błąd średni
			η_1	η_2		
Moc SG	1000	5	0,9	0,6	1	0,06
	10000	5	0,9	0,6	7	0,04
	30000	5	0,9	0,6	13	0,037
	50000	5	0,9	0,6	20	0,034
	1000	5	0,1	0,1	0,5	0,1
	2000	5	1	0,1	1	0,05
	4000	5	0,1	0,1	2	0,05
	4000	5	1	0,1	2	0,048
	4000	5	0,1	1	2	0,05
	4000	5	1	1	2	0,046
	4000	5	2	0,1	2	0,045
	4000	5	2	0,5	2	0,043
	4000	5	3	0,1	2	0,046
	10000	5	0,1	0,1	7	0,07
	1000	1	0,9	0,6	0,3	0,06
	10000	1	0,9	0,6	0,5	0,05
	30000	1	0,9	0,6	12	0,056

Wyniki dotyczące uczenia sieci dla liczby cykli równej 100, a następnie 1000 przedstawiono na wykresie (rys. 3).



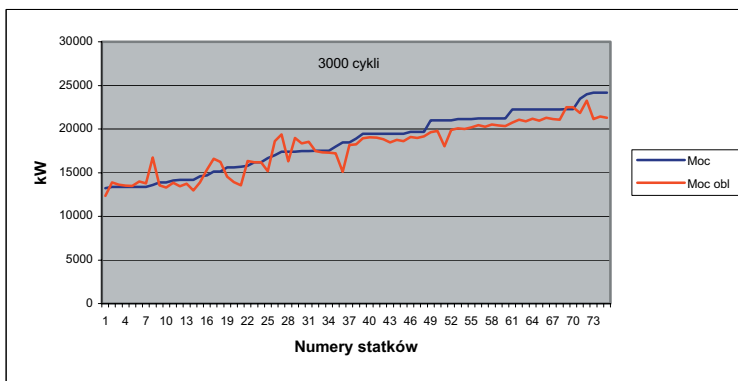
Rys. 3. Zależności mocy SG od parametrów: DWT, LOA, D, G, V

Wyniki uczenia sieci dla liczby cykli równej 50000 cykli (przy tych samych pozostałych parametrach) przedstawiono na rys. 4.



Rys. 4. Wyniki uczenia sieci dla liczby cykli równej 50000


Dla porównania tych wyników przeprowadzono test uczenia sieci dla doboru mocy SG na podstawie jednego parametru wejściowego tj. prędkości statku, co przedstawiono na rys. 5. Test wykonano na zbiorze statków o mocy SG >13000 kW i <25000 kW.



Rys. 5. Zależność mocy SG od prędkości statku dla wybranego zbioru statków

Zbieżność procesu uczenia dla doboru mocy SG na podstawie jednego parametru np. prędkości statku jest nieco lepsza, aniżeli na podstawie wielu parametrów projektowych.

Podobny test (na zbiorze statków o mocy SG >13000 kW i <25000 kW) wykonano dla wielu parametrów projektowych (DWT, LOA, B, D) dla η_1 i η_2 , = odpowiednio 3 i 0,1, którego wyniki przedstawiono na rys. 6.



Rys. 6. Zależność mocy SG od wielu parametrów projektowych dla wybranego zbioru statków - 3000 cykli

W oparciu o wyniki przedstawionych przykładowych badań można sformułować następujące szczegółowe wnioski:

1. błąd średni maleje ze wzrostem liczby cykli obliczeń
2. zwiększanie wartości współczynników uczenia nie daje lepszych rezultatów, aniżeli ich zmniejszanie (w drugim przypadku wzrost błędu średniego o 0,03)
3. zbieżność procesu uczenia prowadzonego na wyselekcjonowanym zbiorze statków dla jednego parametru np. prędkości statku jest nieco lepsza, aniżeli zbieżność na podstawie wielu parametrów projektowych
4. zwiększanie liczby cykli powyżej pewnej granicy (30000 dla analizowanych przykładów) nie daje znaczącej poprawy uzyskanych efektów.

4. ZASTOSOWANIE SIECI NEURONOWEJ DO PROJEKTOWANIA WSTĘPNEGO STATKU DLA DOBORU MOCY SILNIKA GŁÓWNEGO

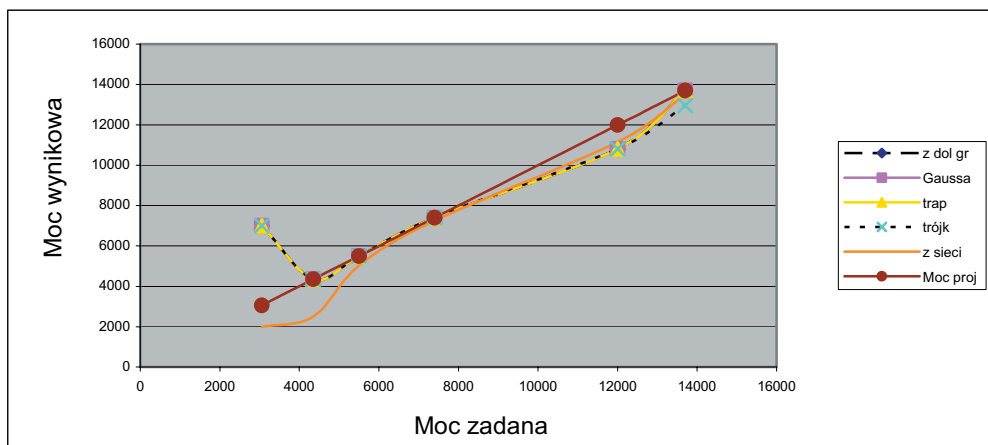
Opracowany algorytm sieci neuronowej zastosowano do wspomagania projektowania wstępnego statku dla doboru mocy silnika głównego obok metod obliczania podobieństwa statków [7]. Wyniki tych metod zestawione zostały w tabeli 3.

W przypadku, gdy wyszukane z bazy danych wartości mocy SG statków według poszczególnych funkcji obliczania podobieństwa są identyczne z projektowanymi (przypadek: 2, 3, 4, 6) – tab. 3, wyniki uzyskane z sieci neuronowej są gorsze. Nie ma zatem potrzeby dokonania ich weryfikacji za pomocą sieci, która ma zastosowanie w przypadku, gdy nie znaleziono wystarczająco podobnych statków za pomocą metod obliczania podobieństwa w aplikacji bazy danych (przypadki: 1 i 5) – tab. 3. Wówczas ma miejsce proces weryfikacji tych wyników za pomocą sieci neuronowej.

Tab. 3. Wartości mocy silnika głównego statków podobnych uzyskane przy użyciu różnych funkcji obliczania podobieństwa oraz z sieci neuronowej

Moc SG statku projektowanego	Moc SG statku podobnego [kW]				
	Metodą z dolną granicą	Metodą z funkcją Gaussa	Metodą z funkcją trapezową	Metodą z funkcją trójkątną	Z sieci neuronowej
3057	7000	7000	7000	7000	1991
4350	4350	4350	4350	4350	2503
5500	5500	5500	5500	5500	5043
7400	7400	7400 </td <td>7400</td> <td>7400</td> <td>7250</td>	7400	7400	7250
12000	10800	10800	10800	10800	11153
13700	13700	13700	13700	12960	13500

Porównanie uzyskanych przykładowych wyników dotyczących statków zbudowanych w polskich stoczniach (wartości mocy SG statków o największym podobieństwie zawarte w tab. 3) przedstawiono na wykresie (rys. 7).

**Rys. 7. Graficzne porównanie mocy SG statków podobnych zbudowanych w polskich stoczniach według poszczególnych metod obliczania podobieństwa**

Z zaprezentowanych przykładów wynika, iż uzyskane poszczególnymi metodami obliczania podobieństwa wartości mocy statków najbardziej podobnych nie zawsze są zbliżone do mocy zadanej statku projektowanego. Wynika to z faktu, iż statki podobne wyszukiwane są na podstawie podobieństw sumarycznych wszystkich parametrów wejściowych. Istotną rolę odgrywa tu właściwe ustalenie wartości wag parametrów, jak również wartości granic badanych zakresów i ich odchyień. Analizę podobieństwa przeprowadzono na podstawie statków różnych typów, zbudowanych w polskich stoczniach. Analizie poddano również wyniki w zakresie doboru mocy SG uzyskane z sieci neuronowej. Różnice podobieństw uzyskanych przy zastosowaniu różnych funkcji wynikać mogą z następujących powodów:

- mocno zróżnicowana struktura badanego zbioru statków w bazie danych (różne typy, gabaryty, przeznaczenie)
- zbyt mała liczba statków poddanych analizie
- zbyt mały zbiór statków w bazie danych, co rzutuje na wyniki uzyskane z sieci neuronowej.

5. PODSUMOWANIE

W opracowanym systemie wspomagania projektowania wstępnego statku zastosowano sieć neuronową dla doboru mocy oraz prędkości obrotowej silnika głównego, na podstawie parametrów ogólnych statku m.in. jego wymiarów do wytypowania rozwiązania w przypadku, gdy znalezione w bazie danych statki podobne nie spełniają oczekiwań projektanta (nie są wystarczająco podobne). Uzyskane wyniki z sieci neuronowej porównano z wartościami wynikowymi znalezionych statków podobnych w bazie danych.

Sieć neuronowa, wyuczona na podstawie wcześniejszych rozwiązań na statkach zbudowanych, w oparciu o ogólne dane projektowe statku może zatem służyć do uzupełnienia (weryfikacji) metod określania podobieństwa w aplikacji bazy danych lub systemie ekspertowym w przypadku braku rozwiązań podobnych.

LITERATURA:

1. CEPOWSKI T., SZELANGIEWICZ T.: Sztuczne sieci neuronowe w badaniu właściwości morskich okrętu, *Budownictwo Okrętowe* 2002 nr 5.
2. CLAUSEN H.B., LUTZEN M., FRIIS-HANSEN A., BJORNEBOE N.: Bayesian and neural networks for preliminary ship design, *Marine Technology* 2001, No. 4.
3. HEIAT A.: Comparison of artificial neural network and regression models for estimating software development effort, *Information and software Technology*, vol. 44, 2002, 911-922.
4. HSIAO S.W., HUANG H.C.: A neural network based approach for product form design, *Design Studies* 2002, No. 23.
5. KORBICZ J., OBUCHOWICZ A., UCIŃSKI D.: Sztuczne sieci neuronowe, Podstawy i zastosowania, Akademska Oficyna Wydawnicza, Warszawa 1994.
6. KOWALSKI Z., MELER-KAPCIA M., ZIELIŃSKI S.: Dobór funkcji podobieństwa w systemie eksperckim dla projektowania automatyki statków. Konferencja NT Automatykacja – Nowości i Perspektywy AUTOMATION 2002.
7. KOWALSKI Z., ZIELIŃSKI S., MELER-KAPCIA M.: Problemy sztucznej inteligencji w projektowaniu statków, Konferencja NT Automatykacja – Nowości i Perspektywy AUTOMATION'2003, Warszawa 2003.
8. KOWALSKI Z., MELER-KAPCIA M., ZIELIŃSKI S., DREWKA M.: CBR methodology application in an expert system for aided design ship's engine room automation, *Expert Systems with Applications* 29, 2005, 256-263.
9. LEE D., LEE K. H.: An approach to case-based system for conceptual ship design assistant. *Expert Systems with Applications*, 1999, Vol. 16, No. 2, 97-104.
10. MELER-KAPCIA M., ZIELIŃSKI S., KOWALSKI Z.: On application of some artificial intelligence methods in ship design. *Polish Maritime Research* 2005 no 1.
11. REICH Y., BARAI S.V.: A methodology for building neural networks models from empirical engineering data, *Engineering Applications of Artificial Intelligence*, vol. 13, 2000, 685-694.
12. RUTKOWSKA D., PILIŃSKI M., RUTKOWSKI L. Sieci neuronowe, algorytmy genetyczne i systemy rozmyte, WNT, Warszawa 1999.
13. TADEUSIEWICZ R.: Sieci neuronowe. Akademska Oficyna Wydawnicza, Warszawa 1993.
14. ZAKARIAN V. L., KAISER M. J.: An embedded hybrid neural network and expert system in a computer- aided design system. *Expert Systems with Applications*, vol. 16, 1999.
15. ŻURADA J., BARSKI M., JĘDRUCH W.: Sztuczne sieci neuronowe. Wydawnictwo Naukowe PWN, Warszawa 1996.