

Prof. dr hab. Zbigniew Kowalski
dr inż. Stefan Zieliński
mgr Maria Meler-Kapcia
Politechnika Gdańska

ZASTOSOWANIA SZTUCZNEJ INTELIGENCJI W PROJEKTOWANIU STATKÓW

W referacie zaprezentowano metodologię zastosowania sztucznej inteligencji w postaci sieci neuronowej oraz wnioskowania na podstawie przypadków w systemach wspomagania do projektowania statków. Prezentowane metody zostały zrealizowane w systemie ekspertowym wspomagania projektowania automatyki okrętowej.

ARTIFICIAL INTELLIGENCE APPLICATIONS IN SHIP'S DESIGN

The paper presents methods used of artificial intelligence in the form of neural network and case based reasoning used in an aided ship's design. The methods were implemented in an expert system for aided design of ship's automation.

1. WSTĘP

Projektowanie statku jest wieloetapowym, złożonym procesem. Ostra konkurencja w okrętownictwie zmusza projektantów do maksymalnego skracania czasu projektowania, a jednocześnie do uzyskania projektu o należytej jakości [5]. Współczesne projektowanie wymaga efektywnych działań poprzez stosowanie najnowszych technik informatycznych. Ważnym etapem w tym procesie jest etap początkowy obejmujący projekt koncepcyjny i kontraktowy, w którym określa się główne parametry statku, a także jego cenę. Niedoskonałości i błędy popełnione w tym etapie mogą mieć poważne skutki techniczne i ekonomiczne zarówno w budowie, jak i eksploatacji statku. Z tego względu przy projektowaniu nowego statku ważne jest wykorzystanie informacji dotyczących projektów podobnych, wcześniej wykonanych. Umożliwiają to zarówno systemy ekspertowe za pomocą metody wnioskowania na podstawie przypadków (ang. case-based reasoning – CBR), jak i sieci neuronowe, które można uczyć w oparciu o reprezentatywne przykłady. Ponadto sieć może być douczona w oparciu o wyniki uzyskane z innych źródeł (np. podczas eksploatacji statku).

Zaprojektowany system wspomagania projektowania statku, jako system hybrydowy, oparty został na zastosowaniu obu tych klasycznych narzędzi sztucznej inteligencji oraz relacyjnej bazy danych. W ten sposób przetwarzanie charakterystyczne dla tradycyjnych systemów ekspertowych jest komplementarne względem rozproszonego przetwarzania równoległego, jakim odznaczają się sieci neuronowe.

Opracowany system wspomagania projektowania wstępnego i automatyki statku stanowi oryginalne i nowatorskie rozwiązanie aplikacyjne z uwagi na zintegrowanie meto-

logii i narzędzi wspomagających projektowanie, a także szeroki, nie stosowany dotąd, zakres prac objęty systemem

Sieć neuronowa, wyuczona na podstawie wcześniejszych rozwiązań na statkach zbudowanych, w oparciu o ogólne dane projektowe statku dokonuje doboru mocy silnika głównego jako projektowanego obiektu, przekazując wyniki do systemu ekspertowego, dla dokonania ich interpretacji i adaptacji, za pomocą metod określania podobieństwa statków.

2. PRZEGLĄD ZASTOSOWAŃ SIECI NEURONOWYCH W OKRĘTOWNICTWIE

2.1. Sieć neuronowa do projektowania wstępnego [3]

W literaturze znaleźć można liczne przykłady zastosowania sztucznej inteligencji do projektowania statków zwłaszcza na etapie wstępnym, w którym na podstawie szczególnych wymagań armatora określa się główne parametry statku. Dla zapewnienia optymalnych wymiarów głównych statku w jego projekcie często stosuje się podejście oparte na znajdowaniu statków z podobnymi charakterystykami i ewentualnym dokonaniu modyfikacji zastosowanych rozwiązań projektowych. Innym podejściem jest określenie parametrów początkowych projektowanego statku na podstawie zależności empirycznych uzyskanych metodą regresji z danych statystycznych. Proste wyrażenia empiryczne jednakże określają tylko relacje między dwoma parametrami. Metodą znajdowania równoczesnych zależności między wieloma parametrami są sieci neuronowe.

Analizie poddano statki kontenerowe zbudowane w ciągu ostatnich trzydziestu lat na podstawie bazy danych zawierającej charakterystyki statków floty światowej pochodzących z morskich informacji serwisowych Lloyd'a. Jako parametry projektowe wytypowano: wyporność statku, długość, szerokość, wysokość, zanurzenie, prędkość. Analizie poddano 812 statków.

Dane zostały znormalizowane do wartości w zakresie (-1, 1).

Do analizy zastosowano sieć neuronową składającą się z dwu warstw. Jest to sieć z wektorem wejściowym, jedną warstwą ukrytą, warstwą wyjściową i wektorem wyjściowym. Każda z dwu warstw składa się z S^x neuronów (wyjść), gdzie x odnosi się do numeru warstwy. Wektor wejściowy dla każdej warstwy jest powiązany z neuronami poprzez macierz wag W^x . To ważone wejście jest sumowane ze stałą (ang. bias b^x) do obliczenia wejścia n^x i funkcji aktywacji F^x , która jest funkcją sigmoidalną:

$$F^1(n) = \frac{1}{1 + e^{-n}} \quad (1)$$

Warstwa wyjściowa stosuje liniową funkcję aktywacji:

$$F^2(n) = n \quad (2)$$

Sieć jest trenowana za pomocą regularyzacji Bayesa. Jest to metoda wstecznej propagacji, która aktualizuje wartości wag zgodnie z optymalizacją Levenberga-Marquardta. Wartości te znajdują się w fazie uczenia, gdzie dla danych wejść i wyjść procedura w Matlabie minimalizuje błąd wyjściowy.

W modelu regresji relacja między parametrami projektowymi jest wyrażana w postaci potęgowej funkcji ciągłych. Parametry tych funkcji określone są metodą najmniejszych kwadratów.

Dla większości parametrów projektowych sieć neuronowa, w porównaniu z metodą regresji, zapewnia najmniejszy błąd średni, który wynika głównie z jej elastyczności.

Wybór modelu zależy jednak nie tylko od najniższej miary błędu, ale też od zastosowania. Funkcje potęgowe są prostsze do implementacji, lecz nie obejmują właściwości np. statków Panmax, co jest możliwe w przypadku sieci neuronowych, Sieci neuronowe są również proste w implementacji i zapewniają mniejszy błąd oszacowania, lecz dla każdej kombinacji wejść muszą być uczone oddzielnie.

2.2. Sieć neuronowa do badania właściwości morskich okrętu [2]

Jednym z zastosowań sieci neuronowych w okrętownictwie jest metoda prognozowania właściwości morskich okrętu na etapie projektu wstępnego. Metoda ta wykorzystuje algorytmy oparte na sztucznej inteligencji w postaci sieci neuronowych. Sieć neuronowa uczona jest na podstawie parametrów projektowych statku, wyników uzyskanych z dowolnej metody prognozowania właściwości morskich takich jak kołysania statku. Ponadto sieć może być douczana w oparciu o wyniki uzyskane z innych źródeł.

Przybliżone funkcje aproksymujące kołysania są zwykle opracowywane na podstawie analiz statystycznych właściwości morskich statków podobnych. Na podstawie bazy danych dotyczących kołysań statków podobnych określa się współczynniki interpolacji i ekstrapolacji, z których z kolei oblicza się kołysania nowego statku.

Zbiorem danych wejściowych sieci neuronowej jest zbiór parametrów projektowych statku (X_1, X_2, \dots, X_n), natomiast wzorcem tj. zbiorem uczącym funkcje przenoszenia kołysań obliczone numerycznie lub zmierzone doświadczalnie. Wszystkie wejścia zostały znormalizowane do przedziału $\langle -1, 1 \rangle$. Parametry projektowe X_1, X_2, \dots, X_n powinny być ustalone w takich przedziałach, aby można było objąć nimi dużą grupę wielkości statków, a także aby w takich przedziałach mieściły się inne kryteria projektowe (np. nośność, sterowność, moc napędu, koszt budowy i eksploatacji statku).

Wytrenowana sieć może służyć jako symulator do generowania charakterystyk częstotliwościowych kołysań na podstawie parametrów projektowych nowego statku. Przyjęto, iż na kołysania statku decydujący wpływ mają następujące parametry: długość statku między pionami, wysokość boczna, objętość podwodzia, współczynnik pełnotliwości kadłuba, a także prędkość statku i kierunek fali.

Sieci neuronowe zaprojektowano i przetestowano za pomocą programu komputerowego Tlearn V.1.0.3 przeznaczonego do projektowania sieci neuronowych ze wsteczną propagacją błędów.

2.3. Badanie możliwości sieci neuronowych na zbiorze statków zbudowanych w polskich stocznicach

W zastosowaniach sieci neuronowych wymagane jest posiadanie możliwie licznej bazy uczonego. Przedstawione poniżej wyniki badań bazują na zbiorze 222 statków zbudowanych w polskich stocznicach. Zbiór ten zawiera bardzo zróżnicowane statki. Każdy statek scharakteryzowany był następującymi parametrami: Dwt – nośność, L – długość całkowita, B – szerokość, D – zanurzenie i moc – moc napędu głównego.

W przeprowadzonych badaniach poszukiwano zależności mocy od pozostałych parametrów. 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. Przykładowy fragment zbioru uczącego zamieszczono w tabeli 1. Statki o brakujących liczbach porządkowych w kolumnie Lp. zostały zaliczone do zbioru testującego.

Tablica 1


Przykładowy fragment zbioru uczącego statków

Lp.	Dwt [t]	L [m]	B [m]	D [m]	V [kn]	Moc SG [KM]
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


Wszystkie parametry statków przed rozpoczęciem obliczeń zostały znormalizowane do wartości z zakresu $[0,1]$.

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 w cyklu (Esr) przyjmował wartość mniejszą od zadanej. Błąd ten dotyczył różnicy pomiędzy rzeczywistą mocą statku i mocą wyliczona przez sieć dla tego samego statku. Zbieżność procesu uczenia wyrażoną zależnością Esr od liczby cykli obliczeniowych (Lco) przedstawiono na rysunku 1. Dane te uzyskano dla sieci o następujących cechach: sześć wejść, 25 neuronów w warstwie ukrytej, jeden neuron wyjściowy, współczynnik uczenia $\eta = 0.5$, parametr funkcji aktywacji $\beta = 1.5$.

Po zakończeniu uczenia sieci na zbiorze uczącym statków przeprowadzono obliczenia (z uzyskanymi wagami sieci) wykorzystując parametry statków ze zbioru testującego. Porównanie otrzymanych, w tych obliczeniach, mocy z mocami rzeczywistymi przedstawiono na rysunku 2. Na rysunku tym zamieszczono także wyniki uzyskane metodą regresji wielowymiarowej z zastosowaniem modelu wielomianowego trzeciego stopnia.



Rys.1. Zbieżność procesu uczenia sieci neuronowej



Rys.2. Wyniki porównawcze uzyskane dla zbioru testującego statków

W obliczeniach tych określono także średni błąd bezwzględny w procentach określony wzorem [4]:

$$e = \frac{|M_r - M_o|}{M_r \cdot n} 100 \quad (1)$$

gdzie:

M_r - moc rzeczywista,

M_o - moc obliczona przez sieć,

N - liczba statków w zbiorze testującym.

Uzyskano następujące wartości tego błędu: $e_1=25.61$ dla metody regresji i $e_2=23.13$ dla sieci.

W oparciu o wyniki przedstawionych badań można sformułować następujące wnioski:

- zbieżność procesu uczenia za pomocą algorytmu propagacji wstecznej błędu i ze stałym współczynnikiem uczenia η jest bardzo słaba (rys. 1);
- wyniki uzyskane z sieci neuronowej i z metody regresji są zbliżone;
- znaczna rozbieżność wyników dla zbioru testującego (małe wartości błędu e) wynika z dużej różnorodności rozpatrywanych statków.

3. PRZEGLĄD ZASTOSOWAŃ WNIOSKOWANIA NA PODSTAWIE PRZYPADKÓW W SYSTEMACH EKSPERTOWYCH

3.1. Projektowanie koncepcyjne statku

Aby zaprojektować statek o wysokiej efektywności i w możliwie krótkim czasie celowe jest wykorzystanie projektów podobnych za pomocą metody wnioskowania na podstawie przypadków.

Metoda wnioskowania na podstawie przypadków stanowi stosunkowo nowy sposób rozwiązywania problemów dotyczących baz danych i baz wiedzy, który polega na generowaniu rozwiązań nowych problemów przez zaadoptowanie rozwiązań zastosowanych w przeszłości w podobnych sytuacjach. Zasadniczym etapem tej metody jest wyszukiwanie w bazie danych przypadków rozwiązań zrealizowanych podobnych do przypadku rozwiązywanego. Wykorzystuje się tu miarę podobieństwa tych przypadków, którą najczęściej przyjmuje się jako funkcję określoną na wartościach wytypowanych atrybutów (cech) charakteryzujących rozpatrywane przypadki.

Funkcja podobieństwa dla każdego nowego przypadku może przyjmować wartości: prawda/fałsz, 0/1 lub zbiór wartości z jakiegoś przedziału. Stopień podobieństwa określany jest za pomocą algorytmu dopasowania, który może być: numeryczny, heurystyczny lub mieszany. Po wyszukaniu przypadku z bazy można zastosować go wprost lub po adaptacji do nowego problemu.

Do tej pory powstało wiele komercyjnych systemów tego typu (także w dziedzinie okrętownictwa) jak np. system dla projektowania koncepcyjnego statku BASCON IV, opracowany przez Koreański Instytut Badawczy Okrętownictwa i Oceanotechniki [6].

Obejmuje on:

- bazę przypadków,
- moduł rozwiązania problemu (wyszukujący i wnioskujący).

Moduł wyszukujący przypadku z bazy stosuje funkcję podobieństwa między nowym i każdym przechowywanym przypadkiem w oparciu o ważoną sumę cech.

Stopień podobieństwa określony jest za pomocą algorytmu "najbliższego sąsiada". Ogólna miara podobieństwa reprezentowana jest jako sumaryczny stopień dopasowania każdej cechy. Typ cechy może być: logiczny, tekstowy, numeryczny oraz w postaci listy. Dla cechy typu liczbowego stosowany jest algorytm, w którym stopień dopasowania określony jest przez: maksymalną dopuszczalną wartość, minimalną dopuszczalną wartość, odchylenie dopasowania i minimalny zakres błędu.

Ogólna miara podobieństwa obliczana jest następująco:

$$\sum_{i=1}^p S_i - \sum_{j=1}^q M_j - \sum_{k=1}^r A_k \quad (2)$$

gdzie:

- S - wartość ważona dla cechy dopasowanej,
- M - wartość ważona dla cechy niedopasowanej,
- A - wartość ważona dla cechy nieokreślonej,
- p - liczba cech dopasowanych,
- q - liczba cech niedopasowanych,
- r - liczba cech nieokreślonych.

Główne parametry statków wcześniej zaprojektowanych (i ewentualnie zbudowanych) przechowywane są w bazie danych. Do wyboru, z tej bazy, statku najbardziej podobnego do statku projektowanego wykorzystuje się algorytm uczący. Natomiast dla adaptacji wybranego statku do aktualnych wymagań opracowano, w oparciu o doświadczenie projektantów, specjalny system ekspercki. Cały system działa na zasadzie interakcji z użytkownikiem.

Do najważniejszych parametrów statków przechowywanych w bazie danych należą: nazwa i typ statku, nośność, rodzaj ładunku, wymiary, urządzenia przeładunkowe i stocznia, która wybudowała statek. Każdy z tych parametrów ma przypisany współczynnik określający wagę wpływu tego parametru na ogólną miarę podobieństwa.

3.2. Projektowanie automatyki statku

Zaprojektowany system jest aplikacją wspomagającą w znacznym stopniu proces projektowania monitoringu i automatyki siłowni statku na etapie projektu ofertowego oraz technicznego.

Aplikacja stworzona została przy zastosowaniu systemu zarządzania bazą danych ACCESS 2000. i przewidziana jest do współpracy z systemem eksperckim Exsys oraz programem AutoCAD; może jednak stanowić również niezależne narzędzie

Opracowany system wspomagania projektowania automatyki siłowni może być użytkowany w dwojaki sposób:

- interaktywnie w przypadku samodzielnej pracy projektanta przez udzielanie odpowiedzi na pytania systemu eksperckiego
- na podstawie informacji o statkach zbudowanych przechowywanych w bazie danych

Baza danych zawiera informacje dotyczące zarówno automatyzowanych obiektów (urządzeń) i systemów aktualnie projektowanego statku jak i statków zbudowanych wcześniej. W przypadku braku odpowiednich rozwiązań na statkach zbudowanych udostępniany jest tryb „projektowania samodzielnego”.

Przyjęty tryb wspomagania projektowania obowiązuje zarówno na etapie projektu ofertowego dając możliwość tworzenia opisów technicznych na podstawie opisów statków podobnych jak i na etapie projektu technicznego przy doborze elementów automatyki (głównie czujników) korzystając z rozwiązań na zbudowanych już jednostkach. Odbywa się to poprzez dołączanie zapisów dotyczących poszczególnych systemów automatyki lub obiektów pochodzących z różnych statków i ich aktualizacji. Dobór elementów automatyki do obiektów dokonywany jest w obrębie systemów okrętowych, wśród których wyróżnia się: system sterowania i zabezpieczeń SG, system paliwa, system oleju smarnego, system wody słodkiej, system wody morskiej, system sprężonego powietrza, kotły i system pary, system zęzowy, system elektroenergetyczny, system balastowy, inne.

W projektowaniu automatyki statku przypadek utożsamiany jest z projektem automatyki i obejmuje: dane ogólne statku i jego automatyki, opisu techniczny automatyki, zestawienie punktów kontrolno-pomiarowych statku oraz schematy blokowo-funkcyjne systemów (instalacji). Wszystkie elementy przypadku identyfikowane są poprzez symbol statku zbudowanego, który wykazuje największe podobieństwo sumaryczne na podstawie wartości wytypowanych parametrów projektowych.

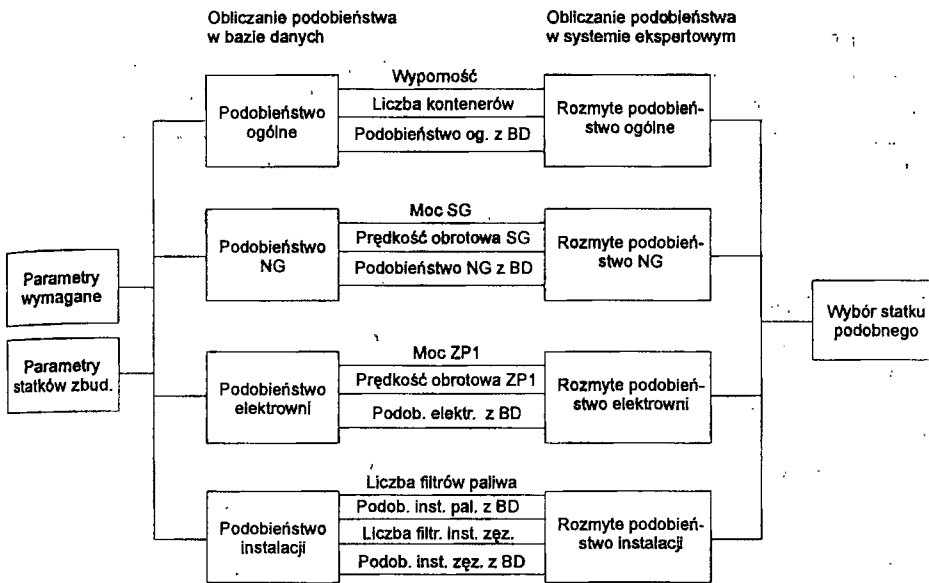
Przyjęta metodologia w zakresie obliczania stopnia podobieństwa oparta została na:

- badaniu identyczności parametrów tekstowych z uwzględnieniem ich wag (test identyczności),
- użyciu funkcji symetrycznego podobieństwa z dolną granicą dla parametrów liczbowych,
- zastosowaniu logiki rozmytej w odniesieniu do wybranych parametrów liczbowych.
- innych funkcjach podobieństwa takich jak: trapezowa, trójkątna, Gaussa

W początkowym etapie w bazie danych obliczane jest podobieństwo pojedynczych parametrów, z uwzględnieniem wag pól. Na ich podstawie obliczane są podobieństwa cząstkowe: danych ogólnych, napędu głównego (NG, SG - silnik główny), elektrowni (ZP1, ZP2 - zespoły prądotwórcze), wybranych (systemów) instalacji oraz podobieństwo całego statku jako suma ważona podobieństw cząstkowych. Obliczone podobieństwa w systemie bazy danych przekazywane są do systemu ekspertowego Exsys, gdzie poddawane są rozmyciu wraz z parametrami, których podobieństwo obliczane jest bezpośrednio przy zastosowaniu logiki rozmytej. Z systemu Exsys do bazy danych przekazywane są wynikowe maksymalne podobieństwa cząstkowe wraz z identyfikatorami odpowiadających im statków oraz maksymalne podobieństwo sumaryczne statku jako suma podobieństw cząstkowych. Na tej podstawie system bazy danych wyszukuje dane tego statku jako statku podobnego. Schemat poszukiwania statku podobnego przedstawiony został na rysunku 3.

Projekt automatyki statku zbudowanego może zostać przyjęty bez żadnych zmian lub podlegać adaptacji zgodnie z wymaganiami projektanta automatyki. Adaptacja projektu statku zbudowanego może być realizowana dwojako:

- na podstawie innych projektów statków zbudowanych,
- w oparciu o model dziedzinowy [10]



Rys. 3. Schemat poszukiwania statku podobnego

Projekt automatyki statku podobnego może zostać zweryfikowany na podstawie projektów innych statków. Ma to miejsce wówczas, gdy podobieństwa cząstkowe poszczególnych systemów statku podobnego (o największym podobieństwie sumarycznym) są mniejsze od podobieństw pojedynczych systemów innych statków.

Adaptacja w oparciu o model dziedziny ma miejsce wówczas, gdy w bazie danych nie znaleziono statku wystarczająco podobnego lub znaleziony statek wykazuje stosunkowo małe podobieństwo sumaryczne i projektant rezygnuje z dopasowywania istniejącego projektu na rzecz projektowania samodzielnego.

4. PODSUMOWANIE

W projektowaniu statków często stosuje się wykorzystanie informacji dotyczących projektów podobnych, wcześniej wykonanych. Umożliwia to metoda wnioskowania na podstawie przypadków. Do tej pory powstało wiele komercyjnych systemów tego typu (także w dziedzinie okrętownictwa) jak np. system dla projektowania koncepcyjnego statku BASCON IV, opracowany przez Koreański Instytut Badawczy Okrętownictwa i Oceanotechniki [6] lub norweski, eksperymentalny system nadzoru wieży wiertniczej [10]

W opracowanym systemie wspomaganie projektowania automatyki statku metodologia ta zrealizowana została przy użyciu elementów sztucznej inteligencji takich jak: sieć neuronowa, system ekspertowy z logiką rozmytą oraz relacyjna baza danych Access z inteligentnym interfejsem zapewniającym współpracę z systemem ekspertowym.

W pracy dokonano przeglądu zastosowań sieci neuronowych oraz systemów ekspertowych w okrętownictwie. Dokonano też analizy funkcji służących do określania podobieństwa

bieństwa przypadków w systemie ekspertowym (logika rozmyta) oraz bazie danych (oprócz znanych z literatury opracowano własne funkcje podobieństwa).

Zaprezentowane przykłady zastosowania wybranych metod sztucznej inteligencji takich jak: sieć neuronowa oraz system ekspertowy z wnioskowaniem na podstawie przypadków do określonych zadań projektowych w okrętownictwie potwierdzają ich dużą skuteczność i efektywność. Złożoność projektowanych obiektów - statków wymaga jednak dalszych prac w tym zakresie.

LITERATURA:

- [1] Aamodt A., Plaza E.: Case-Based Reasoning, Foundation issues, methodological variations, and system approaches. *Artificial Intelligence Communications*, 1994, Vol. 7, No. 1, 39-59.
- [2] Cepowski T., Szelangiewicz T.: Sztuczne sieci neuronowe w badaniu właściwości morskich okrętu, *Budownictwo okrętowe* 2002 nr 5.
- [3] Clausen H.B., Lutzen M., Friis-Hansen A., Bjerneboe N.: Bayesian and neural networks for preliminary ship design, *Marine Technology* 2001, No. 4.
- [4] Heiat a.: Comparison of artificial neural network and regression models for estimating software development effort. *Information and software Technology*, vol. 44, 2002, 911-922.
- [5] Kowalski Z., Arendt R., Meler-Kapcia M., Zieliński S.: An expert system for aided design of ship systems automation, *Expert Systems with Applications*, 2001, Vol. 20, No. 3, 261-266.
- [6] Lee D., Lee K. H.: An approach to case-based system for conceptual ship design assistent. *Expert Systems with Applications*, 1999, Vol. 16, No. 2, 97-104.
- [7] Mulawka J.: Systemy ekspertowe. WN-T, Warszawa 1996.
- [8] 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.
- [9] Rutkowska D., Piliński M., Rutkowski L.: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. WN-T, Warszawa 1999.
- [10] Skalle P., Sveen J., Aamodt A.: Improved Efficiency of Oil Well Drilling through Case Base Reasoning, Proc. Of PRICAI 2000, The Sixth Pacific Rim International Conference on Artificial Intelligence, Melbourne August-September 2000. Lecture Notes in Artificial Intelligence, Springer Verlag, 2000, pp. 713-723.
- [11] Żurada J., Barski M., Jędruch W.: Sztuczne sieci neuronowe. Wydawnictwo Naukowe PWN, Warszawa 1996.
- [12] Yager R. R., Filev D. P.: Podstawy modelowania i sterowania rozmytego. Warszawa, WNT, 1999.