

ZASTOSOWANIE SIECI NEURONOWYCH W BADANIACH EKSPERTOWYCH NIEZAWODNOŚCI SYSTEMU NAPĘDOWEGO STATKU

W artykule przedstawiono metodę oszacowania liczby uszkodzeń systemu napędowego statku. Do badań wykorzystano sztuczne sieci neuronowe. Praca stanowi fragment szerszych badań niezawodności tych systemów. Dane do oszacowania uzyskano od ekspertów, którzy formułowali swoje opinie częściowo w formie rozmytej. W artykule oceniono wpływ przetwarzania tych danych oraz postaci parametrów wejściowych i wyjściowych na adekwatność modeli neuronowych.

WSTĘP

Utrata funkcji napędu przez statek jest zdarzeniem niebezpiecznym, które w określonych warunkach może zagrażać jego istnieniu. Uszkodzenie systemu napędowego (PS) wiąże się z utratą przezeń zdolności do realizacji przypisanej mu funkcji, czyli wytwarzania siły naporu określonej co do wartości i kierunku. Występuje ono jako skutek uszkodzenia katastroficznego¹ układu PS. Przyczyną tego zdarzenia może być uszkodzenie systemu napędowego i/lub błędy operatorów w jego użytkowaniu. W procesie eksploatacji statku istotna jest wiedza o aktualnym poziomie niezawodności tego systemu, traktowanego jako obiekt antropotechniczny i obejmującego wszystkie składniki siłowni mające wpływ na tę niezawodność. W rozważanym przypadku odpowiednie wydają się modele wykorzystujące narzędzia, jakim są sztuczne sieci neuronowe. Stwarzają one możliwość oszacowania liczb uszkodzeń systemu napędowego na podstawie subiektywnych ocen stanu niezawodnościowego składników systemu PS. Są proste w modelowaniu i pozwalają na wykorzystanie praktycznej wiedzy oficerów mechaników. Ten ostatni aspekt jest szczególnie istotny, gdyż informacje z baz danych nie nadają się do bieżącego wyznaczania stanu urządzeń okrętowych, a przy tym są bardzo kosztowne.

¹ „Uszkodzenie katastroficzne” definiuje się jako utratę przez obiekt zdolności do realizacji przypisanej mu funkcji.

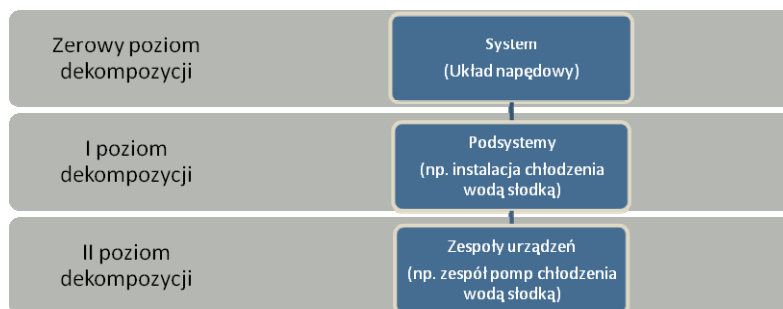
Aby znaleźć najlepszą postać modelu neuronowego estymacji liczb uszkodzeń systemu PS, konieczna jest ocena wpływu postaci parametrów wejściowych i wyjściowych tego obiektu na dokładność modelu. W artykule przedstawiono wyniki poszukiwań tych postaci.

1. MODEL OSZACOWANIA LICZBY USZKODZEŃ SYSTEMU NAPĘDOWEGO

Wielkościami wejściowymi modelu są roczne liczby uszkodzeń katastroficznych zespołów urządzeń N_{zu} systemu PS, natomiast wyjściową jest roczna liczba uszkodzeń tego systemu N_{PS} wyrażona w formie numerycznej lub lingwistycznej.

Modele zbudowano opierając się na danych subiektywnych uzyskiwanych od ekspertów w zakresie eksploatacji systemów statków morskich.

PS poddano dekompozycji. Model każdego poziomu realizowany jest przez osobną sieć neuronową. Następnie sieci połączono kaskadowo zgodnie z modelem blokowym systemu napędowego.



Rys. 1. Poziomy dekompozycji systemu napędowego

Ze względu na podobny charakter modeli obu poziomów dekompozycji badania przeprowadzono dla modelu realizującego I jej poziom. Odpowiednia postać parametrów wejściowych i wyjściowych tego modelu będzie również właściwa dla modeli II poziomu.

2. DOBÓR POSTACI PARAMETRÓW MODELU OSZACOWANIA LICZBY USZKODZEŃ SYSTEMU NAPĘDOWEGO

Procedura ujawnienia sądów ekspertów oraz przetwarzania tych sądów w celu uzyskania danych do modelowania została opisana w pracy [1]. Ekspertami byli oficerowie mechanicy okrętowi o długoletnich stażach (50 osób, z czego 3 odrzucono ze względu na wyskakujące wartości ujawnionych danych). Przygotowano dla nich specjalne ankiety zawierające definicję badanego obiektu, schematy podsystemów i zespołów, ściśle sformułowane pytania oraz tablice do wprowadzania odpowiedzi. W ankiecie napisano wyraźnie, że uszkodzenie typu ICF² może powstać na skutek uszkodzenia urządzeń lub w wyniku działania załogi. Ekspertów proszono o traktowanie obiektów ich sądów jako systemów antropotechnicznych, czyli złożonych elementów technicznych i antropijnych (funkcje operatorów).

Postać parametrów wejściowych i wyjściowych ma znaczący wpływ na jakość modelu neuronowego [3]. W związku z tym przebadano sieć na następujących postaciach danych:

- otrzymanych bezpośrednio z ankiet eksperckich bez przetwarzania,
- numerycznych po przetworzeniu danych eksperckich metodą porównania parami AHP (*Analytic Hierarchy Process*),
- rozmytych.

W ostatnim przypadku wyniki uzyskane z porównania parami przekształcono na wartości lingwistyczne. Do fuzyfikacji, czyli zamiany wartości o postaci deterministycznej na postać rozmytą, przyjęto pięć lub siedem zmiennych lingwistycznych rocznej liczby uszkodzeń podsystemów SS i PS o prostokątnych funkcjach przynależności. Nośniki wartości zmiennych lingwistycznych rozłożono równomiernie w ich przestrzeniach rozważań lub wyznaczono, opierając się na wartościach kwantyli zbioru 47 numerycznych wypowiedzi ekspertów po przetworzeniu ich metodą AHP. Wyjście z modelu oszacowania liczb uszkodzeń PS musi mieć postać numeryczną. Dla modeli klasyfikacyjnych, których wyjście ma postać lingwistyczna, konieczna była **defuzyfikacja**, czyli przekształcenie rozmytej postaci liczby uszkodzeń na deterministyczną postać numeryczną. Do tego celu wykorzystano właściwość sieci klasyfikacyjnej. Ten rodzaj sieci w warstwie wyjściowej ma tyle neuronów, ile grup klasyfikacyjnych (wartości zmiennych lingwistycznych liczby uszkodzeń). Sieć, na podstawie wartości wejściowych, generuje na wyjściu wartości poziomu aktywacji (PA) każdego neuronu wyjściowego. Neuron wyjściowy, którego poziom aktywacji jest największy, „wygrywa” i odpowiedź zostaje przypisana do klasy odpowiadającej temu neuronowi. Aby uzyskać wartość numeryczną, należy zastosować następującą formułę:

$$N_{num} = \sum_l \sum_i S_l P A_{il} , \quad (1)$$

² ICF jest to uszkodzenie powodujące natychmiastową utratę funkcji napędu przez statek.

gdzie:

PA_{il} – wartość poziomu aktywacji i -tego neuronu l -tego podsystemu,

S_l – wartość nośnika zmiennej lingwistycznej l -tego podsystemu.

Model 1

Model 1 został oparty na danych z ankiet eksperckich bez przetwarzania. Eksperti w ankietach byli pytani o wartości numeryczne jedynie odnośnie do rocznych liczb uszkodzeń PS oraz udział czasu pobytu statku w morzu podczas obserwacji przez eksperta. Opinie na temat uszkodzeń podsystemów i zespołów PS podawali w postaci lingwistycznej. Wartościami wejściowymi modelu neuronowego były więc sądy ekspertów bezpośrednio z ankiet w postaci lingwistycznej dotyczące danego zespołu urządzeń jako przyczyny uszkodzeń PS. Wyjściem była liczba rocznych uszkodzeń odpowiadająca tym wejściom.

Dysponowano bazą danych 47 ekspertów. Wypowiedzi każdego eksperta posłużyły jako osobny wektor uczący, czyli dysponowano 47 wektorami danych uczących.

Model zbudowany w ten sposób nie przyniósł pozytywnych rezultatów. Nie potrafił on znaleźć poprawnych zależności pomiędzy wejściami a wyjściem. Wyniki nie nadawały się do dalszych badań. Konieczna była kalibracja wypowiedzi ekspertów do postaci umożliwiającej sieci neuronowej znalezienie zależności panujących w badanym obiekcie.

Model 2

W modelu 2 zastosowano metodę *bootstrap* [1, 2] do rozmnażania danych wykorzystanych w modelu 1 w celu poprawy jego jakości.

Strojenie sieci neuronowej polega na ekspozycji kompletów danych uczących, które składają się z wektora wartości wejściowych i odpowiadającej im wartości wyjściowej. Od liczby kompletów danych uczących zależy dokładność uzyskanego modelu. W literaturze przedmiotu można wyczytać, że w zależności od modelowanego obiektu powinno się dysponować przypadkami uczącymi w liczbie od kilkudziesięciu do kilku tysięcy. W związku z tym, że parametry modelu wyznaczono na podstawie danych subiektywnych, ujawnionych przez ekspertów, liczba zbiorów uczących była równa liczbie ankiet eksperckich. Ze względu na specyfikę badanego zagadnienia, ograniczonej liczby ekspertów oraz ograniczonego czasu badań niemożliwe było zebranie odpowiedniej liczby zbiorów danych uczących.

Według autorów [1, 2] do rozmnożenia danych statystycznych można zaadoptować metodę *bootstrap*. W skrócie polega ona na losowaniu ze zbioru istniejących danych takiej liczby przypadków, jaka potrzebna jest do badań. Losowanie oparte jest na rozkładzie równomiernym.

Metoda ta wydawała się właściwa do powielenia danych uczących. Jednakże umożliwia ona jedynie powielenie istniejących przypadków. Badania wykazały, że sieci neuronowe uczone na pierwotnym zbiorze uczącym miały takie same właściwości jak modele zbudowane na podstawie danych rozmnożonych metodą *bootstrap*.

Model 3

Wartości wejściowe i wyjściowe miały postać lingwistyczną po przetworzeniu metodą AHP oraz po fuzyfikacji na 5 wartości zmiennych lingwistycznych (A1 – bardzo mała, B1 – mała, C1 – średnia, D1 – duża, E1 – bardzo duża). Nośniki zmiennych lingwistycznych wyznaczono, przyjmując pięć charakterystycznych parametrów, takich jak: minimum, kwantyl 0,25, mediana, kwantyl 0,75 oraz maksimum ze zbioru 47 numerycznych wypowiedzi ekspertów na temat rocznych liczb uszkodzeń PS oraz podsystemów.

W modelu tym wykorzystano sieci klasyfikacyjne. Zadaniem ich było zaklasyfikowanie, na podstawie wartości wejściowych w postaci lingwistycznej, odpowiedzi do odpowiedniej wartości lingwistycznej.

W tabeli 1 przedstawiono uzyskane wartości. Jest to model I poziomu dekompozycji. Wartościami wejściowymi są roczne liczby uszkodzeń podsystemów (instalacji) w postaci lingwistycznej. Odpowiedzią jest roczna liczba uszkodzeń systemu napędowego również w postaci lingwistycznej. Sieć została przetestowana na 10 danych testowych wyodrębnionych losowo ze zbioru uczącego, nieeksponowanych podczas procesu strojenia.

Tabela 1

Wyniki estymacji rocznej liczby uszkodzeń PS uzyskane za pomocą modelu 3

Model neuronowy	Błąd klasyfikacji [%]	Średni błąd względny po defuzyfikacji [%]
1. MLP	20	10,5
2. MLP	20	11,1
3. MLP	30	16,8
4. RBF	30	26,1
5. RBF	40	28,2
6. RBF	40	31,2

Wyniki nie są idealne, ale na tym etapie badań są zadowalające. Widać wpływ obróbki danych eksperckich metodą AHP na wyniki uzyskane modelem. Sieć jest w stanie odnaleźć zależności panujące w modelowanym obiekcie. W przypadkach błędnych klasyfikacji wartości różnią się tylko o jedną wielkość zmiennej lingwi-

stycznej (tab. 1) od wartości poprawnej. Jest to dowód na to, że mimo niepoprawnej odpowiedzi wielkość ta nie jest przypadkowa. Można przypuszczać, że dalsze badania nad modelem pozwolą polepszyć jego jakość.

Model 4a

Wartości wejściowe mają postać numeryczną po przetworzeniu metodą AHP, natomiast wyjściowe – postać rozmytą o 5 wartościach zmiennych lingwistycznych (A1 – bardzo mała, B1 – mała, C1 – średnia, D1 – duża, E1 – bardzo duża). Nośniki zmiennych lingwistycznych wyznaczono w ten sam sposób jak w modelu poprzednim. Model został zweryfikowany na zbiorze testowym, który składał się z 5 zestawów wyodrębnionych ze zbioru uczącego. Nie był on prezentowany podczas procesu uczenia sieci. Ten sam zbiór testowy wykorzystywano do weryfikacji kolejnych modeli. W tabeli 2 przedstawiono wyniki uzyskane za pomocą modelu 4a.

Tabela 2

Wyniki estymacji rocznej liczby uszkodzeń PS uzyskane za pomocą modelu 4a

Model neuronowy	Błąd klasyfikacji [%]	Średni błąd względny po defuzyfikacji [%]
1. MLP 11-11-5	14	8,75
2. MLP 11-5-5	0	6,87
3. MLP 11-17-5	14	8,17
4. RBF 11-7-7	14	26,74
5. RBF 11-7-5	29	30,52
6. RBF 11-15-5	29	29,92

Model 4b

Wartości wejściowe miały postać numeryczną po przetworzeniu metodą AHP, natomiast wyjściowe – postać rozmytą o 7 wartościach zmiennych lingwistycznych (A1 – minimalna, B1 – bardzo mała, C1 – mała, D1 – średnia, E1 – duża, F1 – bardzo duża, G1 – ekstremalnie duża). Wartości nośników zmiennych lingwistycznych wyznaczono poprzez określenie wartości: minimum, kwantyl 0,167, kwantyl 0,33, mediany, kwantyl 0,67, kwantyl 0,83 oraz maksimum z 47 wypowiedzi ekspertów na temat rocznych liczb uszkodzeń PS oraz podsystemów.

Tabela 3

Wyniki estymacji rocznej liczby uszkodzeń PS uzyskane za pomocą modelu 4b

Model neuronowy	Błąd klasyfikacji [%]	Średni błąd względny po defuzyfikacji [%]
1. MLP 7-4-7	0	3,2
2. MLP 11-7-7	14	4,3
3. RBF 11-9-7	29	12,2

PODSUMOWANIE

Korzystanie z narzędzia, jakim są sztuczne sieci neuronowe, w odróżnieniu od konwencjonalnych metod pozwala na stosunkowo proste oraz szybkie modelowanie bez konieczności budowania modelu formalnego, przy dysponowaniu tylko wektorami danych wejściowych i wyjściowych. Jednakże konieczne jest, aby dane odzwierciedlały prawidłowe zależności panujące w badanym obiekcie. Dlatego też bardzo istotna jest prawidłowa akwizycja danych eksperckich oraz przetworzenie ich w taki sposób, aby zachować odpowiednie korelacje występujące pomiędzy danymi wejściowymi i wyjściowymi.

Opisana w części poświęconej modelowi 2 metoda powielania danych eksperckich *bootstrap* nie przyniosła zamierzonych rezultatów. Dane uzyskane tą metodą były kopią danych już istniejących. Nie poprawiło to jakości modeli.

Rozpatrując wyniki modeli 4a i 4b, można zauważyć, że znaczący wpływ na jakość modeli ma liczność zmiennych lingwistycznych. Porównując średnie błędy względne tych modeli, można zauważyć, że zmniejszają się one wraz z liczbą tych wartości. Jednakże, ze względu na percepcję operatora, liczba ta nie powinna być większa niż 9 [5]. Ze względu na możliwości potencjalnych operatorów zdecydowano, że najkorzystniejsze będzie zastosowanie 7 zmiennych lingwistycznych. Rozmiar nośników wartości zmiennych lingwistycznych nie miał większego wpływu na jakość modelu.

Rezultaty uzyskane w badaniach pozwalają stwierdzić, że odpowiednia akwizycja i przetworzenie danych eksperckich oraz dobór postaci danych uczących pozwalają na wykorzystanie sztucznych sieci jako narzędzia do modelowania opinii eksperckich dotyczących liczb uszkodzeń systemu PS.

Głównym problemem badań była ograniczona liczba danych uczących. Pochodziły one z sądów uzyskanych od ekspertów. Ze względu na określony czas badań oraz specyfikę badanego zagadnienia bardzo trudne było zgromadzenie odpowiedniej liczby ekspertów w tej dziedzinie. Odpowiednio większa liczba danych uczących z pewnością poprawiłaby jakość uzyskanych modeli.

LITERATURA

1. Brandowski A., Frąckowiak W., Mielewczyk A., *Subjective reliability estimation of the seagoing ship systems*, Proceedings of ESREL07 Conference, Stavanger 2007.
2. Efron B. Tibshirani R.J., *An introduction to the Bootstrap*, Chapman & Hall, New York, London 1993.
3. Lula P., Tadeusiewicz R., *Wprowadzenie do sieci neuronowych*, StatSoft&C.H. Beck, Kraków 2001.
4. Modarres M., Kaminskiy M., Krivtsov., *Reliability Engineering and Risk Analysis*, Marcel Dekker Inc., New York, Basel 1999.
5. Piegat A., *Modelowanie i sterowanie rozmyte*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 1999.
6. Saaty T.L., *The Analytic Hierarchy Process*, McGraw-Hill, New York et al. 1980.
7. STATISTICA. Sieci neuronowe (program komputerowy).

APPLICATION OF NEURAL NETWORKS IN SHIPS PROPULSION SYSTEM RELIABILITY ESTIMATION BASED ON EXPERT JUDGMENTS

Summary

Presented is a method of ships propulsion system number of failures estimation. Neural networks were adopted. This is a fragment of propulsion system reliability research. The estimation is based on the expert judgments. Experts elicited their judgments partly in a linguistic form. Data's processing and form of input and output parameters assessment were made.