

WIELOSYPOTOMOWA PROGNOZA STANU I CZASU DO AWARII Z WYKORZYSTANIEM SIECI NEURONOWYCH

Maciej TABASZEWSKI

Politechnika Poznańska, Instytut Mechaniki Stosowanej
Ul. Piotrowo 3, 60-965 Poznań, Maciej.Tabaszewski@put.poznan.pl

Streszczenie

Praca zawiera próbę rozwiązania problemu prognozy wielosymptomowej dla złożonych obiektów technicznych. Zaproponowano kilka możliwości realizacji prognozy wielosymptomowej stanu i czasu do awarii kładąc szczególny nacisk na możliwość zastosowania sieci neuronowej. Przedstawiono przykład zastosowania sieci neuronowej w prognozie czasu resztkowego do awarii łożyska tocznego 608. Wskazano na silną zależność jakości otrzymywanych prognoz od przyjętej struktury sieci.

Słowa kluczowe: prognozowanie czasu resztkowego, sieci neuronowe,
diagnostyka wielosymptomowa, diagnostyka łożysk tocznych.

MULTI-SYMPOTM FORECASTING OF CONDITION AND RESIDUAL TIME BY MEANS OF NEURAL NETWORKS

Summary

The work concerns an idea of multi-symptom forecasting for complex technical objects. Some of possibilities of realization of multi-symptom forecasting of machine condition and time to breakdown were proposed, especially realization based on neural networks. Some example of prediction of residual time to breakdown of ball bearing 608 was presented. The strong relationship between quality of forecasts and assumed structure of artificial neural network was shown.

Keywords: forecasting of residual time, neural networks, multidimensional condition monitoring,
ball bearing condition monitoring.

1.WPROWADZENIE

Problem prognozowania dla potrzeb diagnostyki technicznej poruszany jest przez wielu autorów. Można tutaj wymienić choćby niektóre, przykładowe prace [1], [2], [3], [4]. Także zastosowanie sieci neuronowych czy też systemów neuronowo- rozmytych do prognozy w diagnostyce było tematem wielu opracowań (przykładowo [5], [6], [7], [8]). W wielu przypadkach diagnostyki złożonych obiektów technicznych może wystąpić konieczność prognozowania czasu resztkowego do awarii jaki i prognozy stanu w oparciu o wiele miar sygnału diagnostycznego wypracowywanych jednocześnie. Konieczność stosowania podejścia wielosymptomowego akcentuje wielu autorów (patrz choćby [9]). Takie spojrzenie na obiekt diagnozowany ma szczególne znaczenie w przypadkach gdy istnieje możliwość niezależnego rozwijania się wielu uszkodzeń. Podstawą obserwacji w diagnostyce wielosymptomowej jest symptomowa macierz obserwacji (SOM). Macierz tę tworzą wierszowe wektory obserwacji $[S_t] = [S_{1t}, S_{2t}, \dots, S_{Nt}]$, które są określane w każdym cyklu pomiarowym, w równo odległych odstępach miary eksploatacji $d\Theta$ podczas całego cyklu życia Θ obiektu $0 \leq \Theta \leq \Theta_b$ [16], [17]. W ten sposób

otrzymuje się macierz obserwacji, której kolumny odzwierciedlają obserwowane symptomy, a wiersze kolejne realizacje obserwacji.

Istnieje kilka możliwości rozwiązania przedstawionego problemu bazującego na zbiorze N miar sygnału diagnostycznego. W niektórych metodach zakłada się, że prócz obserwowanych wartości miary sygnału diagnostycznego posiadamy poprawnie wyznaczoną wartość graniczną tej miary. Pozwala to zbadać relację prognozowanych wartości miary sygnału ze wspomnianą wartością graniczną. Taką relację można badać dla każdego symptomu S_i niezależnie, a następnie zastosować nadrzędny algorytm decyzyjny pozwalający na wypracowanie ostatecznej prognozy w oparciu o wypracowany zbiór niezależnych prognoz. Takie podejście można nazwać jednosymptomowym gdyż sam proces prognozy odnosi się do każdego symptomu osobno. W najprostszym przypadku rozróżniania tylko dwu klas stanu można zapisać:

$$\begin{aligned} \hat{S}_i(\Theta) \leq S_i^l & - \text{stan zdalny} \\ \hat{S}_i(\Theta) > S_i^l & - \text{stan niezdatny} \end{aligned} \quad (1)$$

gdzie: $\hat{S}_i(\Theta)$ - i - ta, prognozowana, miara sygnału diagnostycznego zorientowana zużyciowo (wartość

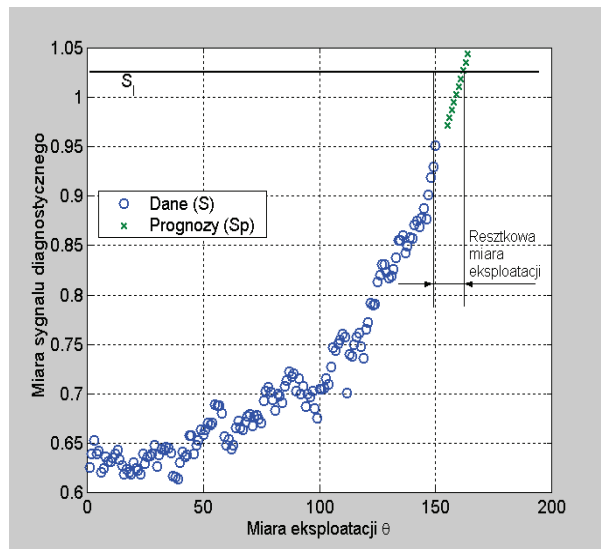
symptomu), S_i^l - wartość graniczna symptomu, Θ - miara eksploatacji (np. czas), $i=1,2 \dots N$,

Ideę prognozy resztkowego czasu do awarii jak i prognozy stanu przy wspomnianych wcześniej założeniach ilustruje rys. 1.

Aby dokonać oszacowania czasu resztkowego należy określić chwilę czasową, w której następuje osiągnięcie przyjętej wartości granicznej, a dalej formalnie:

$$\Delta\hat{\Theta}_i = \hat{\Theta}_i^b - \Theta_n \quad (2)$$

gdzie: $\Delta\hat{\Theta}_i$ - prognozowana wartość czasu resztkowego na podstawie i -tej miary sygnału diagnostycznego, $\hat{\Theta}_i^b$ - prognozowana chwila czasowa w której wystąpi awaria, Θ_n - chwila czasowa, w której dokonuje się prognozy.



Rys. 1. Idea prognozy resztkowej miary eksploatacji (czasu resztkowego) oraz stanu w przypadku diagnostyki jednosymptomowej

W przypadku prognozy złożonych obiektów i diagnostyki wielosymptomowej można zastosować ideę „najsłabszego ogniwa”. U podstaw tej metody stoi założenie, że wiele rozpatrywanych miar sygnału diagnostycznego może być ukierunkowane na detekcję poszczególnych rozwijających się uszkodzeń (np. dzięki zastosowaniu selekcji częstotliwościowej [10]). Dodatkowo wspomniane miary mogą różnić się wrażliwością na zmiany cech stanu. Przy takim założeniu o stanie całości powinno zdecydować zaawansowanie „najszybciej rozwijającego” się uszkodzenia (lub najintensywniej zużywającego się elementu) czyli zdecydować powinna prognoza oparta o najkrótszą krzywą życia. Oznacza to najbardziej pesymistyczne oszacowanie zarówno czasu do awarii jak i najbardziej pesymistyczne określenie stanu w zakładanym horyzoncie prognozy.

Prognoza czasu resztkowego ma wtedy postać:

$$\Delta\hat{\Theta} = \min(\Delta\hat{\Theta}_i) \quad (3)$$

Inną możliwością prognozy stanu i czasu resztkowego w przypadku prognozy wielosymptomowej może być znalezienie kumulant [10] lub uogólnionych symptomów zastępczych (np. w oparciu o rozkład SVD [11], [12]), które mogłyby opisywać ogólny stan techniczny obiektu jako całości. Niestety pojawia się wtedy problem określenia wartości granicznej dla tego typu symptomów uogólnionych, które w zasadzie można wyznaczyć doświadczalnie tylko w oparciu o wielokrotny eksperyment czynno-biorny lub czynny, lub do pewnego stopnia estymować wykorzystując niezawodność symptomową budowaną w oparciu eksperyment biorny i regułę Neymana - Pearsona [13], [14].

Wiele innych metod dotyczących diagnostyki wielosymptomowej można znaleźć choćby w [9].

Jednym z podejść proponowanym przez autora jest zastosowanie zasady, że na etapie formułowania prognozy bierzemy pod uwagę najbardziej optymistyczną jak i pesymistyczną prognozę, a więc otrzymujemy pewien przedział w którym mieści się nasza prognoza. Ponieważ jednak potrzebujemy raczej konkretnych prognozowanych wartości np. resztkowego czasu do awarii, można zastosować reguły decyzyjne analogiczne do reguły Hurwicza [15] z teorii decyzji:

$$\Delta\hat{\Theta} = \alpha \max(\Delta\hat{\Theta}_i) + (1 - \alpha) \min(\Delta\hat{\Theta}_i), \quad (4)$$

gdzie: $0 \leq \alpha \leq 1$ może pełnić rolę wskaźnika optymizmu podczas podejmowania decyzji, $\Delta\hat{\Theta}$ - jest ostateczną prognozą czasu resztkowego.

Jeżeli $\alpha = 0$ podejmujemy decyzję co do przyjęcia resztkowego czasu eksploatacji na podstawie otrzymanej minimalnej (po symptomach) prognozy tego czasu – prognoza pesymistyczna. W przypadku $\alpha = 1$ prognoza jest skrajnie optymistyczna. W przypadku gdy potrafimy arbitralnie wyrazić swój stopień optymizmu co do przyszłości szacowany czas resztkowy będzie w przedziale od $\min(\Delta\hat{\Theta}_i)$ do $\max(\Delta\hat{\Theta}_i)$.

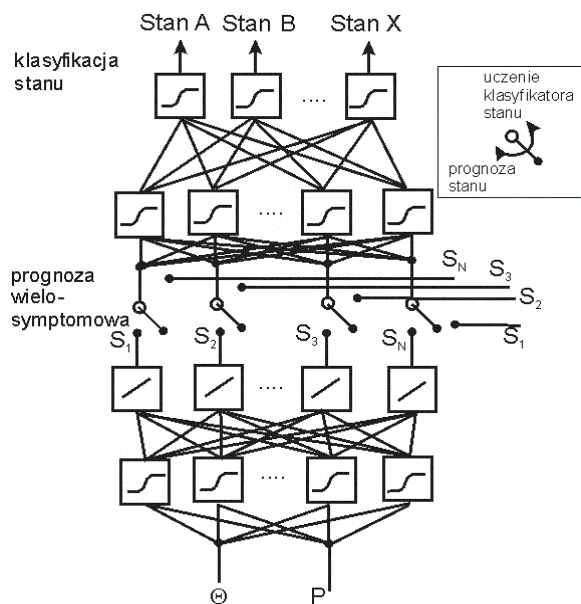
Kolejnym podejściem, szerzej tutaj omówionym, będzie zastosowanie jednokierunkowych sieci neuronów sigmoidalnych i liniowych do prognozy stanu i czasu resztkowego do awarii. W pracy zastosowano nieskomplikowaną strukturalnie sieć do rozwiązania problemu prognozowania wielosymptomowego czasu awarii łożyska tocznego uzyskując zachęcające wyniki. Zaprezentowano także ideę połączenia sieci realizującej prognozę z klasyfikatorem neuronowym pozwalającą na spójną implementację w systemie diagnostycznym.

2. ZASTOSOWANIE SIECI NEURONOWEJ W PROGNOZIE WIELOSYPHTOMOWEJ

Idea prognozy wielosymptomowej może zostać zrealizowana w oparciu o perceptron

wielowarstwowy [22]. W przypadku prognozy stanu idea ta może być przedstawiona jak na rys. 2.

Proponowane podejście wymaga dwóch niezależnie uczonych i optymalizowanych sieci neuronowych. W pierwszym etapie uczenia sieci realizującej prognozę wartości symptomów następuje trenowanie tak aby uzyskać zależność każdego S_{it} (i-ty symptom w danej chwili czasowej t) od miary eksploatacji Θ_t . Jest to więc typowy problem aproksymacji rozpatrywany dla każdego symptomu S_i . W przypadku zmiennych parametrów sterowania P_{it} (np. parametrów determinujących prędkość obrotową, obciążenie itp.) mających wpływ na obserwowane miary sygnałów diagnostycznych konieczne będzie uwzględnienie tych parametrów na wejściu sieci (na rysunku oznaczenie P). W następnym kroku uczy się niezależnie klasyfikator stanu. Na wejścia perceptronu wielowarstwowego podawane są obserwowane wartości symptomów S_{it} (jeśli to konieczne także parametry sterowania) oczekując na wyjściu właściwej klasyfikacji stanu na podstawie przykładów uczących.



Rys. 2. Idea prognozowania wielosymptomowego za pomocą sieci i prognoza stanu za pomocą klasyfikatora neuronowego

Na etapie prognozy na wejście pierwszej sieci podajemy iteracyjnie miarę eksploatacji Θ_T (gdzie $T > n$, oraz n – numer ostatniej dostępnej obserwacji, Θ_T – wartość miary eksploatacji, dla której sporządza się prognozę) i otrzymujemy przewidywane wartości symptomów $\hat{S}_i(\Theta_T) = \hat{S}_{iT}$. Kolejny etap prognozy polegać będzie na wprowadzeniu prognozowanych wartości symptomów na wejście klasyfikatora stanu uzyskując prognozę stanu w zadanym horyzoncie prognozy. W przypadku zmiennych parametrów


sterowania procedurę należy powtórzyć dla przewidywanych wartości tych parametrów z jakimi może pracować obiekt.

Można zaproponować także pewną odmianę tej metody poprzez zastosowanie w procesie prognozy symptomu wielu sieci neuronowych zamiast jednej. W tym rozwiązaniu każda z sieci będzie prognozować wartości określonego symptomu niezależnie od innych. Tak jak w omawianym wcześniej rozwiązaniu odbywałoby się to w oparciu o wartości miary eksploatacji Θ oraz wartości parametrów sterowania P. Takie podejście, choć wydaje się pewną komplikacją, jednak pozwala na dobranie struktury sieci indywidualnie do każdej krzywej życia. Natomiast przy współczesnych środkach obliczeniowych i niezbyt skomplikowanych i rozbudowanych strukturach sieci w omawianym problemie, zastosowanie omawianej odmiany metody wielosymptomowego prognozowania stanu nie rodzi specjalnych trudności. Zresztą tego typu podejście, które nazywane jest bankiem wyspecjalizowanych modeli w zakresie rozwiązywania problemu klasyfikacji jest powszechnie (patrz np. [9]).

Bezpośrednia prognoza czasu do awarii może być zrealizowana zdecydowanie prościej. W przypadku prognozy stanu przewidujemy klasę tego stanu dla zadanej wartości miary eksploatacji. W przypadku prognozy czasu resztkowego lub chwili w której nastąpi awaria, sytuacja jest odwrotna, czyli na wejściu sieci podajemy bezpośrednio wartości symptomów (najświeższe dostępne obserwacje) oraz oczekujemy odpowiedzi ile czasu do awarii jeszcze pozostało. Odpowiedni schemat sieci ilustruje rys. 3. Jak wynika z rysunku 3 na wejście sieci (warstwa I) podaje się wartości wielu symptomów S_i gdzie $i=1,2 \dots N$ (mogą być także podane wartości parametrów sterowania lub nawet aktualna miara eksploatacji). Niestety takie podejście może nie pozwolić sieci na odkrycie właściwych relacji ze względu na fluktuacje losowe symptomu. Stąd konieczność uwzględniania nie tylko ostatniej znanej obserwacji i - tego symptomu S_{in} ale także m wcześniejszych jego realizacji $S_{in-1}, S_{in-2}, \dots, S_{in-m}$. W warstwie ukrytej sieci (warstwa II) należy zastosować neurony sigmoidalne [20], [21] natomiast na wyjściu (warstwa III) neuron liniowy.

Otrzymane wyniki zależą od wielu czynników. Jednym z nich jest wartość m , która na dodatek dla każdego symptomu może być różna. Ogólnie dla symptomów o gwałtownych zmianach charakteru w tendencji rozwojowej i zakłóceniach tej tendencji (np. tendencje wzrostowe i spadkowe w różnych fazach krzywej życia, istotne fluktuacje losowe) wartość m powinna być większa. Inaczej w monotonicznych krzywych życia. Zbyt duża wartość m może doprowadzić do wypracowania zbyt uśrednionej zależności pomiędzy wartościami symptomów, a czasem resztkowym co może

doprowadzić do niewystarczająco dokładnych prognoz. Innym czynnikiem wpływającym na jakość prognozy może być liczba neuronów w warstwie ukrytej. Zbyt duża ich liczba spowoduje brak zdolności uogólniania co w przypadku danych nie prezentowanych wcześniej sieci będzie powodem dużych błędów prognozy. Zbyt mała liczba neuronów może doprowadzić do sytuacji, że sieć nie będzie mogła się nauczyć odwzorowywać wartości symptomów w resztkowy czas do awarii.




Rys. 3. Koncepcja struktury sieci neuronowej dla wielosymptomowej prognozy czasu resztkowego

Należy wspomnieć, że przypadku sieci neuronowej i prognozowania czasu resztkowego wypracowywanego w oparciu o wiele symptomów możliwe jest również zastosowanie metody pośredniej. Metoda ta opiera się na podobnej idei jak przedstawiona na rys. 2. W pierwszym etapie budujemy sieć neuronową pozwalającą na przewidywanie wartości miar sygnałów diagnostycznych w zależności od wartości miary eksploatacji oraz parametrów sterowania, a w drugim etapie wykorzystujemy uzyskane prognozy wartości wielu symptomów do przewidzenia czasu awarii. Jednak takie podejście, choć teoretycznie możliwe, wymaga budowania, optymalizacji i trenowania dwóch sieci i wydaje się niepotrzebną komplikacją problemu. Ewentualnie można zastosować taką strukturę w przypadku implementacji systemu prognostycznego realizującego zarówno prognozy stanu jak i prognozy czasu resztkowego gdyż początkowo wykorzystujemy tę samą sieć. W przypadku jednak prognozy stanu prognozowane wartości symptomu stanowią wejście klasyfikatora (nie koniecznie neuronowego) [9], [18], [19], a w przypadku prognozy czasu resztkowego stanowią wejście sieci prognozującej czas resztkowy.

3. PRZYKŁAD ZASTOSOWANIA

Aby sprawdzić możliwość wykorzystania jednej z omawianych koncepcji dotyczącej bezpośredniej prognozy czasu resztkowego (patrz rys. 3) wykorzystano dane pomiarowe ze stanowiska przyspieszonego zużycia małowabarytowych łożysk tocznych typu 608. Pole zjawiskowe w tym eksperymencie obejmowało: przyspieszenia drgań, emisje akustyczną, moc pobieraną przez silnik oraz temperaturę łożyska. Dodatkowo podczas eksperymentu zmieniano obciążenie łożyska. Dla niektórych ze składowych tego pola wyznaczono wiele miar punktowych sygnałów diagnostycznych (symptomów) w funkcji czasu eksperymentu w różnych pasmach częstotliwości. W wyniku przeprowadzonego eksperymentu dla 10-ciu łożysk tocznych otrzymano ok. 70 symptomowych krzywych życia dla każdego z badanych łożysk. W każdym z przypadków łożysko doprowadzono do awarii w postaci zmęczeniowego pęknięcia pierścienia zewnętrznego łożyska.

Na rys. 4 zaprezentowano rozmieszczenie czujników w głowicy pomiarowej, w której mocowano badane łożysko.

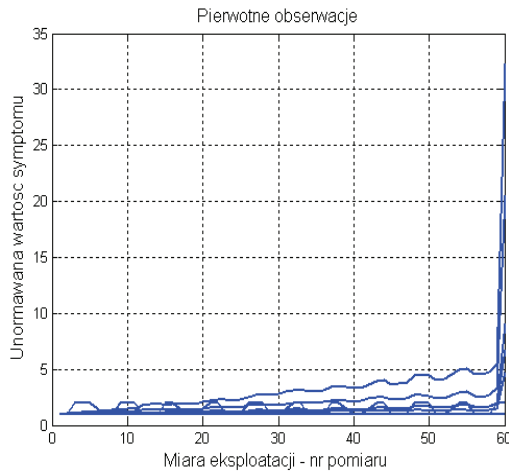


Rys. 4. Widok ogólny głowicy pomiarowej: część górna – ramię (a), część dolna – wkładka dociskowa (docisk obciążający) (b), kołki ustalające (c), śruby dociskowe (d), badane łożysko (e), przetwornik emisji akustycznej (f), przetwornik temperatury (g), przetwornik przyspieszeń drgań (h)

W opisywanym eksperymencie ograniczono się do prognozy czasu resztkowego zgodnie z siecią z rys. 3. Niestety ogrom informacji podany na wejście sieci nie dał oczekiwanych rezultatów nie dając sensownych prognoz. W kolejnym podejściu na wejście sieci podano tylko te symptomy (istotnie uśrednione), które charakteryzowały się tendencją wzrostową. Odrzucono więc te miary sygnału diagnostycznego, które z powodu bądź to niewłaściwej selekcji częstotliwościowej, bądź samej definicji miary nie niosły informacji o procesie zużycia zachodzącym w łożysku. W ten sposób wybrano tylko sześć miar subiektywnie

oceniając ich przydatność. Przykładowo wybrane symptomy wraz z informacją o skokowej zmianie obciążenia przedstawiono na rys. 5.

Ostatecznie do dalszych analiz wybrano wartości skuteczne, i szczytowe przyspieszeń drgań w dwóch pasmach częstotliwości, tempo emisji akustycznej, oraz wartość kurtozy w paśmie.



Rys. 5. Wybrane miary sygnału diagnostycznego, których wartości stanowią wejście sieci przedstawionej na rys. 3

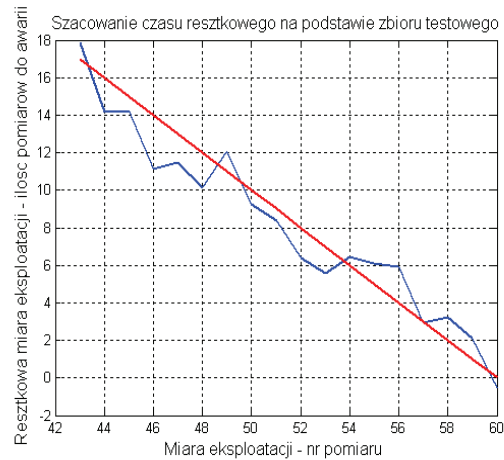
Rys. 6 przedstawia oszacowania czasu resztkowego w funkcji miary eksploatacji uzyskane za pomocą sieci neuronowej dla $m=3$ oraz $N=6$ (patrz rys. 3) oraz rzeczywiste odwzorowanie w postaci funkcji linowej. Dla rozpatrywanego przypadku stanowisko wyłączono po 60 cyklach pomiarowych, po których stwierdzono pęknięcie pierścienia zewnętrznego. Ostatni pomiar odpowiada chwili, w której zanotowano efekt akustyczny związany ze wspomnianym uszkodzeniem. Wyniki dotyczą fragmentu krzywej życia traktowanej jako zbiór testowy (nie prezentowany sieci w trakcie uczenia ale o znanych wartościach, które sieć powinna uzyskać na wyjściu). Należy jednak pamiętać, że sieć nie ma informacji o mierze eksploatacji, a jedynie o ostatnich wartościach symptomów.

Podczas analiz przyjęto następujące oznaczenie modeli sieci neuronowych: $SN(x,m,N)$ przedstawia model o liczbie x neuronów w warstwie ukrytej, m – parametr opóźnienia zgodnie z rys. 3 (przyjęto m równe dla każdej miary), oraz N – liczba uwzględnionych symptomów.


Kolejny rys. 7 prezentuje przykładowy wynik dla modelu $SN(15,3,6)$. Widać wyraźnie pogorszenie jakości prognozy. Przykład ten ilustruje jak metoda jest wrażliwa na właściwy dobór parametrów modelu. Stanowi to istotną niedogodność przedstawianej metody.

Kolejną niedogodnością jest istotna zależność otrzymywanych wyników od przyjętego błędu uczenia. Zbyt duży błąd dopuszczalny powoduje istotne błędy prognozy. Niestety podczas pracy sieci (a nie testowania jak w omawianych przypadkach)

nie ma możliwości porównania otrzymanych wyników z właściwymi i takiego ostatecznego doboru błędu uczenia aby oszacowania resztkowej miary eksploatacji były niewielkie.



Rys. 6. Uzyskane prognozy resztkowej miary eksploatacji w funkcji miary eksploatacji (model $SN(10,3,6)$), na tle prawdziwej, liniowej zależności



Rys. 7. Oszacowany, za pomocą modelu $SN(15,3,6)$, resztkowy czas do awarii w funkcji miary eksploatacji wraz z nałożoną prawdziwą zależnością w postaci funkcji liniowej

4. PODSUMOWANIE I WNIOSKI

Prognoza czasu resztkowego do awarii ma istotne znaczenie z punktu widzenia eksploatacji uwarunkowanej stanem technicznym, pozwalając na planowanie określonych zabiegów i optymalizację podejmowanych decyzji [1]. Przejście z prognozy jedno do wielosymptomowej wydaje się konieczne biorąc pod uwagę złożoność niektórych obiektów technicznych oraz wielość procesów zużycia, które mogą występować jednocześnie [9].

W pracy zaproponowano kilka możliwości rozwiązania problemu prognozy wielosymptomowej. Wartościowa wydaje się idea oparta o sieci neuronowe [5]. Przedstawione tutaj wyniki są obiecujące choć dopiero rozpoczęto fazę weryfikacji metody. Ogólnie wydaje się, że aby

metoda dawała się zastosować praktycznie, konieczny jest mechanizm starannego doboru miar sygnałów diagnostycznych i rozpatrywanie tylko tych dla, których występuje pewna tendencja rozwojowa. Istotną zaletą metody jest uzależnienie decyzji diagnostycznych od wartości wielu symptomów, a nie tylko jednego. Wydaje się więc, że jest to metoda pozwalająca na obiektywne i kompleksowe spojrzenie na obiekt diagnostyki. Dodatkowo w łatwy sposób można uwzględnić tutaj parametry sterowania.

LITERATURA

- [1] Batko W.: *Metody syntezy diagnoz predykcyjnych w diagnostyce technicznej*. Rozprawa habilitacyjna, AGH, Kraków 1984.
- [2] Kaźmierczak J.: *Zastosowanie liniowych modeli procesów losowych do prognozowania w diagnostyce maszyn*. Rozprawa habilitacyjna, Politechnika Śląska, Gliwice 1989.
- [3] Tylicki H.: *Optymalizacja procesu prognozowania stanu technicznego pojazdów mechanicznych*. Rozprawa habilitacyjna, ATR, Bydgoszcz 1998.
- [4] Cempel C., Bossak J., Żółtowski B.: *Proste modele prognozowania stanu maszyn*. Zagadnienia Eksploatacji Maszyn, nr 3/1989, Kraków 1989.
- [5] Batko W., Gibiec M.: *Analiza przydatności sieci neuronowych w procesie prognozowania stanu maszyn*. III Krajowa Konferencja Naukowo-techniczna Diagnostyka Procesów Przemysłowych, Jurata 1998, s.325-330.
- [6] Tabaszewski M.: *Prognozowanie resztkowej miary eksploatacji młyna wentylatorowego z wykorzystaniem sieci neuronowych*. Diagnostyka, vol. 3/(39), Polskie Towarzystwo Diagnostyki Technicznej, Warszawa 2006, str. 149-154.
- [7] Wang Q., i inni: *Prognosis of machine health condition using neuro-fuzzy systems*. Mechanical Systems and Signal Processing, Vol. 18 (2004), 813-831.
- [8] Baranow S., Kurawski L.: *Acoustic Vibrations – modeling, optimisation and diagnostics*. Rozdz. 4. Russian Aviation Company, Moskwa 2006.
- [9] Korbicz J., i inni: *Diagnostyka Procesów – Modele, Metody sztucznej inteligencji*. Rozdz. 2, 9, 14 WNT Warszawa 2002.
- [10] Cempel C.: *Podstawy wibroakustycznej diagnostyki maszyn*. WNT, Warszawa 1982.
- [11] Cempel C.: *Multi-Symptom Condition Monitoring of a Critical Mechanical Systems to design Condition Inference Agent*. Intern. Journ. COMADEM, 2005, Vol. 8, No 2 pp. 5-10.
- [12] Cempel C.: *Implementing Multidimensional Inference Capability in Vibration Condition Monitoring*. Diagnostyka Vol. 34, 2005, pp. 7-14.
- [13] Cempel C.: *Condition Evolution of Machinery and its Assessment from Passive Diagnostic Experiment*. Mechanical Systems and Signal Processing No 5(4), 1991, str. 317-326.
- [14] Cempel C.: *Passive Diagnostic Experiment, Symptom Reliability and Their Applications in Vibration Condition Monitoring*. Zagadnienia eksploatacji maszyn, Zeszyt 2-3 (82-83), 1990.
- [15] Blanchard B.S., Fabrycky W.J.: *Systems Engineering and Analysis*. Prentice Hall, new Jersey, 1990.
- [16] Cempel C.: *Multi Dimensional Condition Monitoring of Mechanical Systems in Operation*. XIX Sympozjum Diagnostyka Maszyn, Węgierska Górka, 2002, s. 109-118.
- [17] Cempel C, Tabaszewski M. Krakowiak M.: *Metody Ekstrakcji Wielowymiarowej Informacji Diagnostycznej*, 2003, Węgierska Górka.
- [18] Kornacki J, Ćwik J.: *Statystyczne systemy uczące się*. WNT, Warszawa, 2005.
- [19] Therrien Ch.W.: *Decision Estimation and Classification*, Jon Wiley & Sons, New York, 1989.
- [20] Tadeusiewicz R.: *Sieci neuronowe*. AOW RM, Warszawa 1993.
- [21] Markowska-Kaczmar U., Kwaśnicka H.: *Sieci neuronowe w zastosowaniach*. Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2005.
- [22] Osowski S.: *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.

Dr inż. **Maciej TABASZEWSKI** – informacja o autorze zamieszczona jest na stronie 18.