

## PROGNOZOWANIE RESZTKOWEJ MIARY EKSPLOATACJI MŁYNA WENTYLATOROWEGO Z WYKORZYSTANIEM SIECI NEURONOWYCH

Maciej TABASZEWSKI

Politechnika Poznańska, Instytut Mechaniki Stosowanej  
Ul. Piotrowo 3, 60-965 Poznań, [Maciej.Tabaszewski@put.poznan.pl](mailto:Maciej.Tabaszewski@put.poznan.pl)

### Streszczenie

Praca zawiera opis metodologii prognozowania czasu resztkowego (czasu do awarii) dla młyna wentylatorowego MWk-16. Ze względu na krótki czas pracy młyna wentylatorowego pomiędzy naprawami (krótkie krzywe życia) oraz duży rozrzut długości tych krzywych, prognoza przewidywanego czasu do awarii w oparciu o zebrane dane stanowi bardzo istotną przesłankę do podejmowania decyzji eksploatacyjnych. W celu rozwiązania przedstawionego problemu w pracy rozpatrzono dwie koncepcje struktur sieci neuronowych.

Słowa kluczowe: prognozowanie czasu resztkowego, sieci neuronowe.

### FORECASTING OF RESIDUAL TIME OF MILLING FANS BY MEANS OF NEURAL NETWORKS

#### Summary

The paper concerns methodology of forecasting of residual time (time to breakdown) of milling fan MWk-16. As the time between breakdowns of the fan is very short (short live curves) and variable, forecasting of life time based on collected data gives very important information which can be used in making decisions concerning machine operation. In order to solve the problem two structures of neural networks were considered.

Keywords: forecasting of residual time, neural networks.

## 1. WPROWADZENIE

Młyny wentylatorowe są urządzeniami przemiałowymi samowentylującymi, które bez oddzielnego wentylatora zasysają czynnik suszący i transportują mieszanę pyłowo-powietrzną do palników kotła energetycznego [1]. Rozdrobnienie oraz suszenie węgla prowadzone jest w celu zapewnienia właściwego spalania mieszanki pyłowo-powietrznej w kotle. Elementem roboczym młyna jest koło bijakowe, które zbudowane jest z dwóch tarcz, do których zamocowane są płyty rozbijające węgiel (bijaki). Jedna z tarcz osadzona jest na piaście wału, druga ma kształt pierścienia, dzięki czemu możliwe jest osiowe zasysanie medium. Koło bijakowe młyna wentylatorowego pełni zatem dodatkowo rolę koła wentylatorowego wytwarzającego jednocześnie podciśnienie i naciśnienie. Dzięki takiemu rozwiązaniu podciśnienie powoduje zasysanie medium suszącego, a naciśnienie wydmuchiwanie mieszanki pyłowo-powietrznej przez palniki szczelinowe do paleniska. Do suszenia węgla stosowane jest gorące powietrze, spaliny lub mieszanina spalin i powietrza.

Podstawową przyczyną przerw w eksploatacji młynów wentylatorowych jest zużycie cierne elementów zespołu mielącego. W wyniku procesu kruszenia i mielenia węgla następuje ścieranie elementów mielących. Stopniowemu ścieraniu

ulegają zarówno płyty koła bijakowego jak i płyty opancerzenia korpusu (płyty progowe i obwodowe). Najintensywniej zużywają się płyty bijakowe. Wynika to z dużej prędkości obwodowej bijaka, dynamicznego charakteru oddziaływań płyty z węglem oraz podwyższonej temperatury panującej w komorze młyna – ok. 150 °C [1]. Czynnikiem niekorzystnie wpływającym na poprawną eksploatację młyna i ograniczającym trwałość pozostałych jego podzespołów jest nierównomierność zużywania się płyt bijakowych. Dochodzi niekiedy do dużych różnic w ubytku masy pomiędzy poszczególnymi płytami (na skutek ścierania jak i w wyniku pęknięć i wykruszania się fragmentów płyt). Asymetria rozkładu masy prowadzi do niewyważenia wirnika. Konsekwencją niekorzystnych oddziaływań dynamicznych może być obniżenie trwałości węzłów łożyskowych. Niewyważenie może także powodować zmęczenie materiału całej struktury młyna w szczególności zaś wału, co w skrajnym przypadku może prowadzić do jego pęknięcia.

W tablicy 1 zamieszczono zakresy trwałości elementów kruszących młynów wentylatorowych. Duże rozpiętości trwałości płyt w głównej mierze zależą od jakości węgla.

Tablica 1. Zakresy trwałości elementów zespołu mielącego młynów wentylatorowych [2]

Element	trwałość minimalna [h]	trwałość maksymalna [h]
plyty bijakowe	500	900
plyty progowe	700	1200
plyty obwodowe	2000	7000

Ze względu na duży rozrzut trwałości płyt bijakowych ( patrz tabela 1), oraz małe jej wartości (najczęstsza przyczyna postojów), prognoza czasu resztkowego do awarii staje się bardzo istotną przesłanką do podejmowania optymalnych decyzji eksploatacyjnych.


Drugim elementem ulegającym zużyciu choć w innym przedziale czasu eksploatacji są łożyska toczne układu łożyskowania wału koła bijakowego [1]. Trwałość łożysk szacowana jest na kilka tysięcy godzin. Zatem teoretycznie ich wymiana przypada na kilka cykli wymiany elementów zespołu mielącego. W rzeczywistości trwałość węzłów w dużej mierze zależy od oddziaływań dynamicznych związanych nie tylko z procesem mielenia, ale jak wcześniej wspomniano z niewyważeniem koła bijakowego oraz poprawnością osiowania wałów silnika i wirnika młyna.

Omawiany typ młyna stosowany jest w jednej z elektrociepłowni w Polsce. Zainstalowany tam system diagnostyczny obejmuje ciągłym dozorem on-line sześć młynów wentylatorowych wspomnianego typu. System diagnostyczny dokonuje rejestracji wartości skutecznej prędkości drgań w paśmie normowym 10-1000Hz oraz nastawionych przez obsługę wartości: pierwszego alarmu i wartości granicznej symptomu. Pomiaru dotyczą trzech punktów rozmieszczonych w węzłach łożyskowych (dwa na młynie, radialnie (Ł1) i osiowo (Ł2A), jeden na silniku – Ł3). Dotychczasowa praca systemu pozwoliła na zbudowanie bazy danych zawierającej ok. 30 pełnych krzywych życia co stanowi podstawę do opracowania metody wyznaczania czasu resztkowego do awarii. Wspomniane krzywe życia dotyczą tylko punktów pomiarowych związanych z młynem (patrz rys. 1).

## 2. WYZNACZENIE RESZTKOWEJ MIARY EKSPLOATACJI W OPARCIU O SIECI NEURONOWE

Wczesne wykrywanie uszkodzeń może zapobiec zatrzymaniu pracy systemu, uszkodzeniu podzespołów, a nawet nagłej awarii pociągającej za sobą wysokie straty materialne [5]. Znajomość resztkowego czasu do awarii w momencie narastania

uszkodzeń niewątpliwie może zostać wykorzystana do racjonalnego podejmowania decyzji dotyczących terminu niezbędnych prac obsługowych [6].



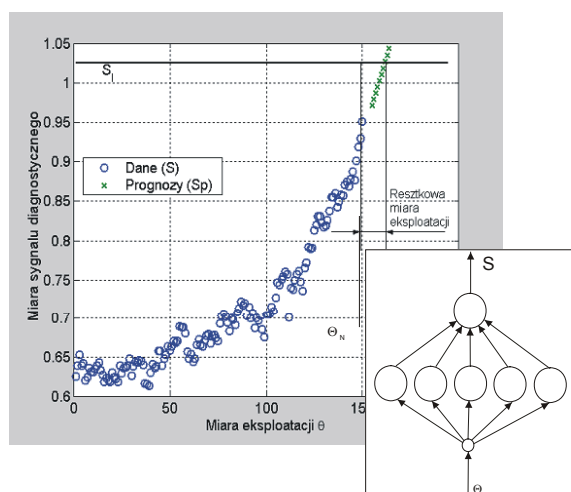
Rys. 1. Rozmieszczenie punktów pomiarowych w węzłach łożyskowych młyna MWk 16 [4]

Metody bezpośredniego szacowania czasu resztkowego w oparciu modele niezawodności symptomowej zaproponował Cempel (patrz np. [3]). Proponowane modele niezawodności symptomowej zostały zbudowane na bazie procesora energii, który matematycznie opisywany jest funkcjami rosnącymi asymptotycznie, o gwałtownym narastaniu wartości symptomu w miarę zbliżania się do awarii. W obserwowanych trendach krzywych życia młynów wentylatorowych raczej nie udało się zaobserwować takich zachowań. Rejestrowane krzywe życia wykazują raczej charakter trendu wielomianowego, wykładniczego lub kwadratowo-wykładniczego (patrz [7]). Stąd zrezygnowano z zastosowania tej metody w tym przypadku.

W celu rozwiązania problemu prognozowania czasu resztkowego do awarii w oparciu o dane zbierane przez wspomniany system nadzoru młyna wentylatorowego można stosować podejście oparte o aproksymację danych pomiarowych składających się na krzywą życia za pomocą wybranego modelu matematycznego (np. modelu regresyjnego, wyrównywania wykładniczego, trendu pelzającego itp.) i jednostronną ekstrapolację w przyszłość poza przedział obserwacji. Jeżeli na podstawie przyjętego modelu nie można bezpośrednio oszacować czasu resztkowego, to można przynajmniej stwierdzić, czy w danym horyzoncie prognozy wystąpi przekroczenie wartości granicznej czy nie. Można więc odpowiedzieć na pytanie czy czas resztkowy jest mniejszy od danego horyzontu prognozy, a jeżeli jest, to iteracyjnie znaleźć jego wartość badając dla jakich wartości miary eksploatacji nastąpi przekroczenie wartości granicznej. Niestety takie podejście może wymagać zastosowania modeli adaptacyjnych prognozowania lub metod śledzenia błędów prognozy ze względu na fakt, że przyjęty początkowo model może stać się nieadekwatny w miarę napływu nowych danych pomiarowych [8].

Kolejną możliwością zaproponowaną tutaj stanowi zastosowanie sieci neuronowych do procesu prognozowania czasu resztkowego. Możliwe są co najmniej dwa podejścia. Pierwsze z nich, podobnie jak poprzednio, opiera się na zasadzie aproksymacji

dostępnego zbioru danych odpowiednim modelem sieci neuronowej, a następnie ekstrapolacji poza obszar obserwacji. Taka sieć z neuronami sigmoidalnymi w warstwie ukrytej oraz neuronem liniowym w warstwie wyjściowej, ma odwzorowywać wejście w postaci miary eksploatacji  $\Theta$  w wyjście w postaci obserwowanego symptomu. W ten sposób można sieć nauczyć aproksymować krzywą życia. Mając model w postaci wytrenowanej sieci można zasymulować wartości symptomu dla różnych wartości miar eksploatacji  $\Theta$ . Wartości symptomu można z kolei porównać z jego wartością graniczną. Tak więc w metodzie tej oszacowanie resztkowej miary eksploatacji  $\Delta\Theta_N$  na podstawie danych zgromadzonych do chwili  $\Theta_N$  odbywa się poprzez iteracyjne poszukiwanie wartości tej miary  $\Theta > \Theta_N$ , dla której następuje przekroczenie założonej wartości symptomu  $S_l$  (patrz rys. 2).




Rys.2. Schemat zastosowanej sieci neuronowej i idea szacowania resztkowej miary eksploatacji na podstawie pomiarów zgromadzonych do chwili  $\Theta_N$  oraz przyjętej wartości granicznej  $S_l$  (metoda 1)

Niestety sieć taką należy uczyć indywidualnie dla każdej krzywej choćby ze względu na duży rozrzut trwania okresów od naprawy do naprawy (długości krzywych życia). Wykorzystanie sieci neuronowych ma tę zasadniczą zaletę, że w miarę napływu nowych danych pomiarowych sieć można „dotrenować” co przy odpowiedniej elastyczności sieci zapobiega w pewnym stopniu dezaktualizacji modelu prognostycznego [4]. Dotrenowanie jest tu rozumiane jako uruchomienie procesu trenowania z wartościami wag uzyskanymi z poprzedniego trenowania, a nie uzyskiwanymi np. w sposób losowy. Oczywiście stoi za tym założenie, że nowo napływające dane nie zmieniają charakteru w sposób bardzo gwałtowny. Z badań autora w przypadku aproksymacji krzywych życia takie podejście sprawdza się (patrz np. [4]).

Innym podejściem jest zastosowanie sieci do bezpośredniego określania wartości czasu

resztkowego na podstawie kilku wartości symptomu zaobserwowanych ostatnio (rys. 3).



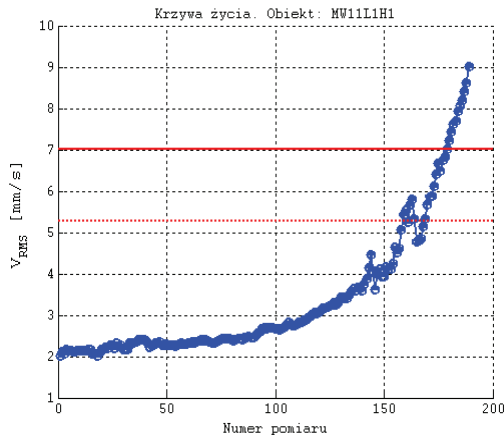
Rys. 3. Schemat sieci neuronowej pozwalającej na odtwarzanie resztkowej miary eksploatacji  $\Delta\Theta_N$  w zależności od wartości obserwowanego symptomu  $S$  w chwili  $\Theta_N$  i  $n$  poprzednich chwilach (metoda 2)

Liczba uwzględnionych wartości symptomu determinuje ilość neuronów w warstwie wejściowej i jest sprawą arbitralną. Ogólnie większa liczba wartości pozwala na eliminację wpływu chwilowych fluktuacji wartości symptomu, natomiast zbyt duża liczba tych wartości może powodować pogorszenie właściwości uogólniających sieci. Tutaj również zastosowano sieć z sigmoidalną warstwą ukrytą i wyjściem liniowym. Sieć uczono natomiast na podstawie kilkunastu krzywych życia oraz testowano zdolność uogólniania na podstawie nieprezentowanych danych. Prognoza sprowadza się do podania na wejście sieci najaktualniejszych wartości symptomu.

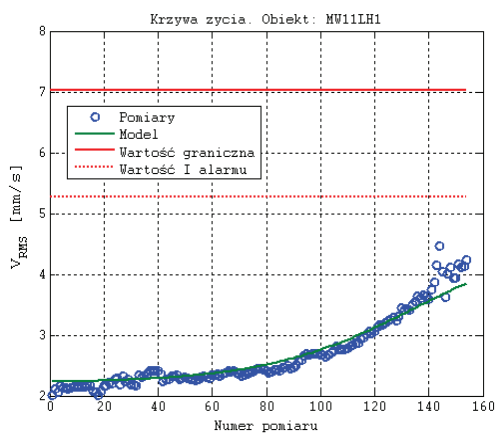
### 3. ANALIZA UZYSKANYCH WYNIKÓW

Na rys. 4a przedstawiono przykładową krzywą życia młyna wentylatorowego dla punktu Ł1 wraz z naniesionymi wartościami pierwszego alarmu i wartością graniczną symptomu ( $V_{RMS} \approx 7\text{mm/s}$ ) ustalonymi przez obsługę. Widać zresztą, że moment wyłączenia obiektu został zignorowany lub też wartość graniczną ustalono na zbyt niskim poziomie. Nie ma to jednak żadnego znaczenia w przyjętej tutaj metodologii. Kolejne rys. 4b i 4c przedstawiają modele aproksymacyjne uzyskane za pomocą wspomnianej wcześniej sieci neuronowej (metoda 1) na tle dostępnych w danym momencie danych pomiarowych.

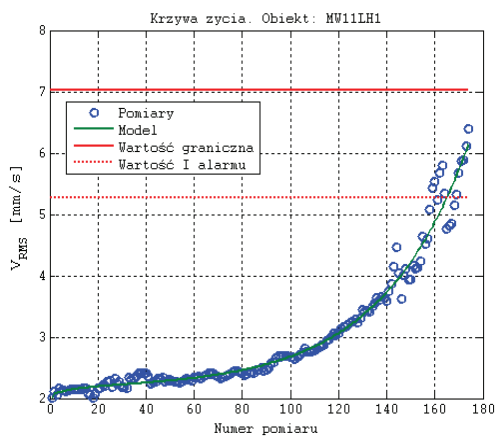
a)



b)

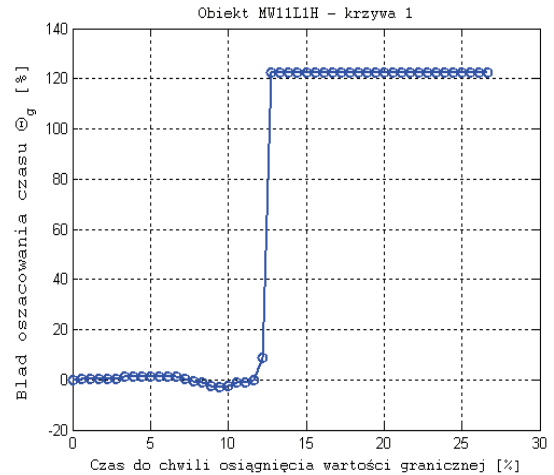


c)



Rys. 4. Przykładowa krzywa życia (a) i wybrane aproksymacje (b,c) uzyskane za pomocą sieci neuronowej z rysunku 2 (metoda 1)

Wyraźny staje się tutaj problem z jakim spotkać się można wykorzystując tę metodę. W początkowej fazie (rys. 4b) nie sposób trafnie przewidzieć ostatecznego charakteru zachowania symptomu, co powoduje błędne prognozy czasu przekroczenia wartości granicznej symptomu. Widać to zresztą wyraźnie na rys. 5, który ukazuje błąd prognozy *ex-post* wartości miary eksploatacji odpowiadającej chwili przekroczenia wartości granicznej symptomu.



Rys. 5. Błąd prognozy dla krzywej życia z rys. 4a uzyskany za pomocą sieci neuronowej (metoda 1)

Błąd ten zdefiniowano następująco:

$$\varepsilon = 100 \frac{\Theta'_g - \Theta_g}{\Theta_g} [\%], \quad (1)$$

natomiast względną wartość miary eksploatacji, dla której buduje się prognozy (oś odciętych na rys. 5) jako:

$$\tau = 100 \frac{\Theta_g - \Theta_N}{\Theta_g} [\%], \quad (2)$$

gdzie:  $\Theta_g$  – wartość miary eksploatacji dla której następuje przekroczenie wartości granicznej,  $\Theta'_g$  – oszacowanie tej miary uzyskane za pomocą sieci,  $\Theta_N$  – wartość miary eksploatacji w chwili sporządzania prognozy.

Na rys. 5 widać, że prognozy stają się sensowne dopiero od pewnej chwili gdy następuje faza przyspieszonego zużycia i wartość symptomu zaczyna wyraźnie rosnać. Dla prezentowanego przykładu zaczyna się to od ok. ostatnich 12% długości krzywej życia. Od tego momentu prognoza jest dość precyzyjna i dla wartości mniejszych niż wspomniane 12% błąd prognozy wartości  $\Theta_g$  nie przekracza 3%. Wartość stała błędu na poziomie 120% widoczna na rys. 5 przed tym momentem wynika z przyjętego algorytmu i założenia pewnego ograniczenia wartości szacowanego czasu  $\Theta_g$ . Wskazuje ona ogólnie na zupełnie chybione prognozy.

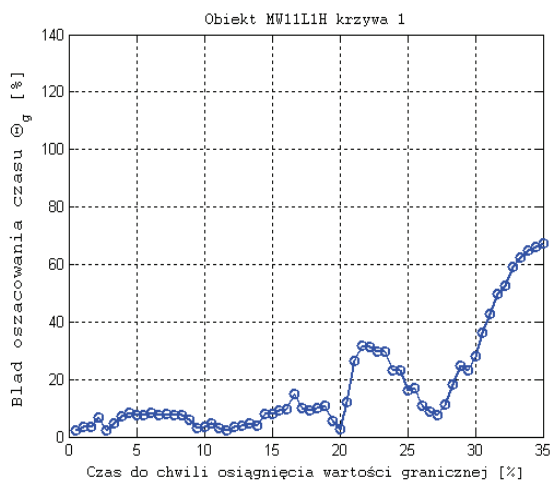
Formalnie, prognozowaną wartość resztkowej miary eksploatacji formułowaną w chwili  $\Theta_N$  wyznaczyć można na podstawie prostego przeliczenia:

$$\Delta\Theta'_N = \Theta'_g - \Theta_N, \quad (3)$$

gdzie:  $\Theta'_g$  – prognozowana wartość miary eksploatacji dla, której stwierdzono przekroczenie wartości granicznej symptomu, oraz  $\Theta_N$  wartość miary eksploatacji, dla której formułuje się prognozę.

Należy zaznaczyć, że istotny wpływ ma tutaj założony, dopuszczalny błąd uczenia sieci. Ogólnie lepiej dopasowany model pozwala na uzyskanie mniejszych błędów oszacowania czasu do awarii. Należy także rozsądnie dobierać liczbę neuronów w warstwie ukrytej sieci. Zbyt duża liczba neuronów spowoduje zanik zdolności uogólniania i zbyt dosłowne odwzorowanie chwilowych fluktuacji symptomu, a to bardzo mocno odbija się na jakości prognozy czasu resztkowego omawianą metodą.

Przykładowe wyniki uzyskane na podstawie danych przeznaczonych do testowania (nie prezentowanych sieci podczas uczenia) i dotyczące drugiej z omawianych metod zaprezentowano na rys. 6.



Rys. 6. Błąd oszacowania czasu do osiągnięcia wartości granicznej symptomu uzyskany siecią z rys. 3 (metoda 2). Rysunek sporządzono z podobną rozpiętością skali co rys. 5 w celu możliwości ich porównania

Z rys. 6 wynika, że metoda ta daje wcześniej, niż poprzednio omawiana, sensowne oszacowania czasu  $\Theta_g$ . Niestety nawet w przedziale 5% czasu przed  $\Theta_g$  zdarzają się prognozy z błędami większymi niż 5%, a więc takie które można uważać za bezużyteczne. To że prognozy takie są bezużyteczne wynika z faktu, że w tych przypadkach czas pozostały do awarii jest krótszy niż ten wynikający z prognozy. Dodatkowo w odróżnieniu od metody 1, prognoza nie dostarcza w miarę stałego oszacowania  $\Theta_g$  w miarę zbliżania się do awarii. Przyczyną może być problem zbioru trenującego zawierający

dość różniące się pod względem dynamiki wzrostu symptomu i długości krzywe życia.

Ostatecznie więc nasuwa się pewne rozwiązanie będące kombinacją obu metod. Początkowo należałoby wykorzystywać obie metody równolegle i póki metoda pierwsza nie powala na oszacowanie czasu  $\Theta_g$  (czyli nie ma jeszcze przyspieszonej fazy narastania symptomu) można w przybliżeniu szacować ten czas metodą drugą. W momencie pojawienia się stabilnych oszacowań  $\Theta_g$  uzyskanych pierwszą metodą można zacząć opierać się na nich.

#### 4. PODSUMOWANIE

Przedstawione metody wyznaczania resztkowej wartości miary eksploatacji uzupełniają się wzajemnie i pozwalają na planowanie odpowiednich napraw młynów wentylatorowych, co ma istotne znaczenie praktyczne. Z dotychczasowych badań można wywnioskować, że w granicach ok. 10% czasu do wystąpienia przekroczenia wartości granicznej można osiągnąć błędy oszacowania tego czasu mniejsze niż 5%, co w przypadku braku dodatkowych założeń uważa się za prognozę dobrej jakości. Dodatkowo, co jest niezmiernie ważne, oszacowania czasu resztkowego stają się stabilne co do wartości. W wielu przypadkach osiągnięto dużo lepsze rezultaty. Dotyczy to szczególnie pierwszej z omawianych metod. Drugą należy potraktować jako uzupełnienie dla wypracowania wcześniejszej, bardziej przybliżonej prognozy. W przypadku metody drugiej istotny może się okazać dobór zbioru uczącego. Metoda ta bazuje na trenowaniu sieci w oparciu o cały zbiór krzywych życia. Należy więc zapewnić taki zbiór krzywych aby sieć zdobyła możliwości uogólniania. Z kolei pewną wadą metody pierwszej jest konieczność uczenia sieci indywidualnie dla każdej krzywej życia.

Należy zwrócić uwagę, że przedstawione metody nie zawsze da się zastosować dla innego typu obiektów i wnioski nie mają charakteru ogólnego. Młyny wentylatorowe są obiektami nie podlegającymi zmianom parametrów roboczych podczas pracy. Dodatkowo, w zasadzie, podlegają jednemu typowi zużycia, które uwidacznia się w rejestrowanym symptomie (praktycznie we wszystkich krzywych życia symptom nie zawiera informacji o innych). Symptom ten charakteryzuje się ponadto w miarę monotonicznym wzrostem związanym z narastaniem niewyrównowazenia. Ogólnie jest to sytuacja nieczęsto spotykana w praktyce. Stąd przedstawiona analiza może być ograniczona jedynie do omawianych obiektów.

---

**LITERATURA**

1. Paczkowski Z.: *Diagnostyczne badania identyfikacyjne młyna wentylatorowego MWk-16*, Praca Magisterska Politechnika Poznańska, WBMiZ - Poznań 1999.
2. Kilarski J., Jura. S., Studnicki A., Suchoń J., *Możliwość zwiększenia trwałości elementów mielących w młynach MWK*, Zeszyty naukowe Politechniki Opolskiej, Politechnika Opolska, Opole 1998.
3. Cempel C., Natke H. G, Yao J. P. T.: *Symptom - Based Reliability for Critical Operating Systems, Intern, Workshop on Damage Assessment, Pescara - Italy, May 1995.*
4. Tabaszewski M. i inni: *Metodologia prognozowania dla potrzeb automatycznych systemów diagnostycznych w przemyśle*, sprawozdanie z projektu badawczego 5T07 B03924, Politechnika Poznańska, Instytut Mechaniki Stosowanej, 2006
5. Korbicz J. i inni: *Diagnostyka procesów, Modele sztucznej inteligencji*, Zastosowania, WNT, Warszawa 2002, rozdz. 9.
6. Zóltowski B.: *Podstawy diagnostyki maszyn*, Wydawnictwo Uczelniane ATR, Bydgoszcz 1996, rozdz. 10.3
7. Cempel C.: *Podstawy wibroakustycznej diagnostyki maszyn*, WNT, Warszawa, 1982, 50-56, rozdz. 4.5.
8. Tabaszewski M.: *Metody doboru modeli prognostycznych w automatycznych systemach diagnostycznych*, Diagnostyka, PTDT Warszawa 2004, vol. 30/2 125-128.



Dr inż. **Maciej TABASZEWSKI** jest adiunktem w Instytucie Mechaniki Stosowanej Politechniki Poznańskiej. Jego zainteresowania dotyczą metod prognozowania stanu maszyn w tym także wykorzystania metod sztucznej inteligencji w procesie prognozowania, modelowania miar sygnałów diagnostycznych, pomiarów wielkości mechanicznych, programowania obiektowego dla potrzeb narzędzi cyfrowej analizy sygnałów.