

PEWNOŚĆ DIAGNOZY STANU MASZYN W PODEJŚCIU JEDNO I WIELOWYMIAROWYM

Magdalena KRAKOWIAK, Czesław CEMPEL
Politechnika Poznańska, Instytut Mechaniki Stosowanej, Zakład Wibroakustyki i Bio Dynamiki Systemów
email: magdalena.krakowiak@put.poznan.pl

Streszczenie

W pracy przedstawiono problematykę związaną z badaniami możliwości wielowymiarowej diagnostyki stanu maszyn. Zaprezentowano przejście od macierzy obserwacji diagnostycznej obiektu i wykorzystanie dostępnych narzędzi wnioskowania diagnostycznego w środowisku Matlab. Pokazano między innymi wyznaczenie wartości granicznych symptomu i prognozy. W pracy porównano rezultaty uzyskane po zastosowaniu prognozy najpierw jedno a następnie wielowymiarowej, aby w końcowej fazie ocenić zysk wielowymiarowości w diagnostyce wybranych obiektów.

Słowa kluczowe: wielowymiarowość, macierz obserwacji, symptom, czas resztkowy, niezawodność symptomowa, dekompozycja SVD.

RELIABILITY OF CONDITION ASSESSMENT IN A SINGLE AND MULTI DIMENSIONAL APPROACH

Summary

The paper presents introductory consideration of the reliability of condition assessment, when using one symptom approach against the symptom observation matrix in the multidimensional condition monitoring. The comparison was made by using some software for condition assessment and forecasting prepared in the MATLAB environment, and basing on real symptoms used in vibration condition monitoring of the railroad diesel engines. The residual system life time was used as the quantity of comparison in a single and multi dimensional case. It was found in a given case, that multidimensionality can give us more reliability of assessment of the engine residual life.

Keywords: Symptoms of condition, observation matrix, singular value decomposition, symptom reliability, residual life.

1. WSTĘP

Celem diagnostyki technicznej powstałej na potrzeby użytkowników coraz bardziej skomplikowanych obiektów technicznych jest podwyższenie trwałości, niezawodności oraz efektywności ich działania. Znajomość stanu technicznego urządzenia niezbędna jest do podejmowania decyzji w każdej fazie życia maszyny tzn. w fazach jej konstruowania, wytwarzania i eksploatacji. Diagnostyka jako pojęcie została przedstawiona przez Pszczółkowskiego[1] a dostosowana do potrzeb oceny stanu maszyn jako wyodrębnienie i określenie trzech podstawowych bloków tematycznych:

- Diagnostyka - określenie bieżącego stanu technicznego,
- Geneza - określenie przyczyn zaistniałego stanu,
- Prognoza - określenie horyzontu czasowego przyszłej zmiany stanu technicznego.

Od strony wykonawczej diagnostyka eksploatacyjna sprowadza się do pomiarów

dostępnych dla **obserwacji symptomów**¹ stanu technicznego i wnioskowania na podstawie uzyskanego zbioru danych o rozpatrywanym obiekcie.

W diagnostyce maszyn zainteresowani jesteśmy ewolucją stanu konkretnego obiektu, która zachodzi w cyklu życia θ urządzenia ($0 \leq \theta \leq \theta_b$). Wiadomo jednak, że w pracujących maszynach rozwija się wiele uszkodzeń, tzn. ich przestrzeń uszkodzeń jest wielowymiarowa. Zatem mając możliwość wielowymiarowej obserwacji stanu obiektu należy to wykorzystać do uchwycenia i diagnozowania zużyciowej wielowymiarowości obiektów. Należy przejść, zatem do diagnostyki wielu uszkodzeniowej obiektów.

Celem niniejszej pracy jest pokazanie zysku wielowymiarowości przy wykorzystaniu wyników obserwacji diagnostycznej z badanych diagnostycznie obiektów: silników spalinowych. Dla wykazania tego przetworzymy ich macierze obserwacji w specjalnych programach obliczeniowych takich jak, **pcainfo.m**, **diaginfo.m**

¹ Symptomem nazywamy wielkość dostępną pomiarowo i proporcjonalną do poszukiwanego stanu technicznego.

dem8.m, opracowanych w zespole ZWBDS. Analizie poddane zostaną symptomy z krzywych życia obiektów potrzebne do uzyskania informacji o zużyciu obiektu. Symptomy te poddane zostaną zarówno jedno jak i wielowymiarowym przetworzeniom tak, by następnie dokonać ich prognozy i oceny stanu jedno i wielowymiarowej. Szczególnie istotną informacją będzie czas pojawienia się **stanu alarmowego** i oszacowany **resztkowy czas życia** potrzebny do stałej obserwacji obiektu i zaplanowania odnowy.

2. WIELOWYMIAROWA OBSERWACJA DIAGNOSTYCZNA

Wcześniej już (DAMAS 99 w Dublinie) zdefiniowano pojęcie symptomowej macierzy obserwacji obiektu [2]. Tworząca tą macierz obserwacja wierszowego wektora symptomów stanu technicznego polega na wykonaniu kilkudziesięciu równo odległych o $\Delta\theta$ odczytów wartości wektora w kolejnych chwilach cyklu życia θ obiektu $0 \leq \theta \leq \theta_b$. [2] W ten sposób otrzymuje się macierz obserwacji, której kolumny (**r**) odzwierciedlają obserwowane symptomy, a wiersze (**p**) łączną liczbę kolejnych realizacji obserwacji. Wiadomo także [8], że maksimum informacji diagnostycznej uzyskujemy z symptomowej macierzy obserwacji, jeśli wycentrujemy i znormalizujemy wszystkie odczyty do wartości początkowej danego symptomu. $S_m(0) = S_{0m}$; $[S_m] = [S_1, \dots, S_r]$. Do uzyskanej w ten sposób bezwymiarowej macierzy obserwacji stosuje się procedurę rozkładu względem wartości szczególnych (SVD), [4] uzyskując,

$$O_{pr} = U_{pp} * \Sigma_{pr} * V_{rr}^T, \quad T\text{-transpozycja}, \quad (1)$$

gdzie U_{pp} to p wymiarowa ortogonalna macierz lewostronnych wektorów szczególnych, a V_{rr} r wymiarowa ortogonalna macierz prawostronnych wektorów szczególnych, oraz diagonalna macierz wartości szczególnych Σ_{pr} o własnościach jak niżej: $\Sigma_{pr} = \text{diag}(\sigma_1, \dots, \sigma_l)$, oraz $\sigma_1 > \sigma_2 > \dots > \sigma_u > 0$, $\sigma_{u+1} = \dots = \sigma_l = 0$, $l = \max(p, r)$, $u = \min(p, r)$.

Rozkład SVD można prowadzić po wykonaniu każdej obserwacji; $n=1, \dots, p$, i śledzić w ten sposób ewolucję uszkodzeń o domniemanych intensywnościach $F_t(\theta)$, $t=1, 2, \dots, u$ w obiekcie. Oznacza to, że z pośród r mierzonych symptomów możemy uzyskać tylko $u < r$ niezależnych informacji o rozwijających się uszkodzeniach F_t . Zakładamy, bowiem, że podczas życia obiektu mogą się równoległe rozwijać niezależne uszkodzenia w obiekcie $F_t(\theta_n)$, $t=1, 2, \dots$.

Postulujemy, zatem, że po wykonaniu rozkładu macierzy uszkodzenie F_t opisuje para wielkości; **SD_t** -to uogólniony symptom uszkodzenia t, oraz **σ_t** – to wartość szczególna określająca intensywność uszkodzenia. Uogólniony symptom uszkodzenia można otrzymać jako iloczyn prawostronny macierzy obserwacji i wektora v_t [2].

$$SD_t = O_{pr} * v_t = u_t * \sigma_t, \quad (3)$$

O_{pr} - macierz obserwacji diagnostycznej.

Dla danego czasu życia θ zaawansowanie zużycia uszkodzenia $F_t(\theta_n)$, może być odzwierciedlone przez wartość szczególną $\sigma_t(\theta_n)$, natomiast jego chwilowa ewolucja przez SD_t . Postulujemy zatem równoważność w całym czasie życia obiektu

$$SD_t(\theta) \sim F_t(\theta). \quad (4)$$

Wiadomo, że proces zużywania się obiektu nie jest jednowymiarowy, ponieważ w czasie życia maszyny rozwija się wiele uszkodzeń z różną intensywnością. Zarysowana wyżej możliwość wielowymiarowej obserwacji stanu obiektu pozwala wykorzystać ją do uchwycenia i diagnozowania zużyciowej wielowymiarowości obiektów.

Diagnoza stanu obiektu to jak wspomniane zostało wcześniej: ocena stanu, określenie przyczyn tego stanu, a także określenie prognozy zmian tego stanu [3]. Do uzyskania informacji o zużyciu obiektu w pracy wykorzystano, dane z obserwacji drganiowej silników Diesla². W wybranym jednym punkcie wykonywano, co 10 tyś. km pomiary kilkunastu symptomów drganiowych. Mierzonymi wielkościami drganiowymi były amplitudy przyspieszenia, prędkości, przemieszczeń drgań i częstości Rice'a odpowiednich procesów. Badania takie wykonywane były w całym cyklu życia silnika $0 \leq \theta \leq \theta_b$, od uruchomienia poremontowego $\theta = 0$, aż do uszkodzenia po kolejnej naprawie θ_b . Dla tych danych będziemy oceniać stan przez bliskość wartości alarmowej i oceniać prognozę resztkowego czasu życia.

3. DOSTĘPNE NARZĘDZIA WNIOSKOWANIA DIAGNOSTYCZNEGO

Diagnostyka eksploatacyjna wymaga umiejętności prognozowania przyszłej zmiany stanu, a mając dane symptomowe stanu obiektu można przejść do wykonania jego diagnozy tzn. określić przyczynę stanu oraz określić czas, przy którym nastąpi zmiana tego stanu i jej przyczyny. Podczas wieloletnich prac nad diagnostyką maszyn opracowano w zespole ZWBDS wiele programów informatycznych napisanych w systemie MATLAB między innymi: **dem8.m**, **diaginfo.m** i **pcainfo.m**, które przetwarzają pojedynczy symptom i macierz obserwacji diagnostycznej. W naszej pracy jednowymiarowy program **dem8.m** przetwarza wybraną kolumnę (symptom) macierzy obserwacji, natomiast programy: **diaginfo.m** i **pcainfo.m** przetwarzają całą macierz obserwacji, a więc już wykorzystują wielowymiarowość. W macierzy tej (w kolumnach znajdują się obserwowane symptomy a w wierszach realizacje kolejnych obserwacji).

² Serdeczne podziękowania dla prof. F.

Tomaszewskiego za użyczenie wyników jego dawnych badań w postaci symptomowych macierzy obserwacji.

W naszych rozważaniach uwzględnimy macierze wybranych obiektów silników np. (sil54d2).

3.1. Wyznaczanie wartości granicznych symptomu

Wyznaczenie jednowymiarowej prognozy stanu obiektu na podstawie 5 uzyskanych pojedynczych krzywych życia możliwe jest poprzez zastosowanie programu dem8.m. Na podstawie uzyskanych histogramów wyodrębnionych dla każdego z symptomów można przetworzyć wybraną pojedynczą kolumnę macierzy obserwacji. Kategorią wyboru jest w tym programie najlepszy symptom, poddany zostaje on następnie „działaniu” odpowiednich funkcji rozkładu prawdopodobieństwa symptomu, odpowiadającym rozkładom powszechnie stosowanym w statystyce a zwłaszcza w teorii niezawodności.

W eksploatacji maszyn pojęcie **niezawodności czasowej** $R(\theta)$ definiuje się jako prawdopodobieństwo poprawnej pracy w zadanych warunkach do określonej chwili czasu życia θ . W dziedzinie symptomu Cempel w swoich pracach definiuje niezawodność symptomową jako [5]

$$R(S) = \int_s^{\infty} p(S(\Theta)) dS = P(S(\Theta) \geq S), \quad (5)$$

gdzie $p(S(\theta))$ jest gęstością prawdopodobieństwa mierzonego symptomu obserwowanego na populacji obiektów w stanie zdatności, S - symptom, dla którego określane jest $R(S)$. Konieczne jest tutaj wyjaśnienie przejścia w dziedzinę symptomu i zdefiniowania pojęcia **niezawodności symptomowej**.

Jeśli znana jest monotonicznie rosnąca funkcja $S(\Theta)$ a symptom S i miarę eksploatacji Θ potraktujemy jako dwie zmienne losowe to można zapisać następującą relację [10]:

$$p(S) ds = p(\Theta) d\Theta. \quad (6)$$

Ważnym czynnikiem jest przyjęcie postaci funkcji rozkładu $p(\Theta)$. Przyjmuje się w pierwszym podejściu równomierny odstęp pomiarów, co w efekcie daje $p(\Theta) = \frac{1}{\Theta_b}$ dla przedziału czasu

$\langle 0, \Theta_b \rangle$, oraz 0 poza nim. Poprzez scałkowanie tego ostatniego wyrażenia w podanych granicach można sprawdzić, że spełnia ono definicję gęstości prawdopodobieństwa. Aby wyznaczyć odpowiednie prawdopodobieństwa $p(s)$ trzeba z równania:

$$\frac{S(D)}{S_0} = -\ln(1 - D)^{\frac{1}{\gamma}}, \text{ modelu typu Weibulla,}$$

$(D = \frac{\Theta}{\Theta_b})$ - bezwymiarowy unormowany czas życia.)

wyznaczyć $\Theta(S)$ i obliczyć pochodną $\frac{d\Theta(S)}{dS}$.

Otrzymuje się w ten sposób odpowiednie funkcje rozkładów prawdopodobieństwa symptomu $p(S)$.

O odpowiadające rozkładom stosowanym w statystyce i teorii niezawodności.

Na podstawie założenia o równomiernym rozkładzie czasu obserwacji można uzyskać relację wiążącą $R(S)$ z czasem granicznym, a znając bezwymiarowy czas resztkowy w danej chwili i ostatnią wartość symptomu można wyznaczyć prognozowane wartości symptomu S w wyznaczonym horyzoncie prognozy [9]. Wykorzystując regułę Neymana- Pearsona i zadane modele $R(S)$ oszacować można wartości graniczne symptomu przy założonym prawdopodobieństwie błędnej decyzji diagnostycznej [6].

$$G \int_{S_g}^{\infty} p(S) dS = GR(S_g) = A, \quad (7)$$

gdzie G - żądana gotowość grupy maszyn, S_g - wartość graniczna symptomu, A -przyjęte dopuszczalne prawdopodobieństwo zbędnych remontów, $p(S)$ -gęstość prawdopodobieństwa rozkładu symptomu.

Modele niezawodności symptomowej dotyczące rozkładów symptomów, które teoretycznie mogą opisywać doświadczalny rozkład są przedstawione w [6]. Dla jednoparametrowego rozkładu Weibulla mamy:

$$R(S) = e^{-\left(\frac{S}{S_0}\right)^{\gamma}} \quad (8)$$

gdzie: $S_0 = S(\Theta=0)$,

γ -współczynnik kształtu rozkładu wyznaczany w każdym konkretnym przypadku.

Dla rozkładów typu Pareto, Frechet'a definicje niezawodności symptomowej oraz wyznaczanie wartości granicznej przedstawione zostały w pracy [11]. W tej pracy skupimy się tylko na przykładzie rozkładu symptomów Weibulla, gdyż jest on najczęściej występującym w rozpatrywanych przykładach analizowanych obiektów.

Wychodząc z pojęcia niezawodności symptomowej wprowadzić można także wielkość nazwaną resztkowym **czasem do awarii** ΔD_n wyrażonym zależnością uzyskaną z (6):

$$\int_S^{\infty} p(S) ds = \int_{\theta}^{\theta_b} \frac{d\theta}{\theta_b} = R(S) = 1 - D_n = \Delta D_n$$

$$\Delta D_n = 1 - D_n. \quad (9)$$

Wykorzystując powyższą relację i znając estymowany współczynnik γ można, wiążąc czas życia z $R(S)$ wyrazić go w funkcji mierzonego symptomu. Dla rozkładu Weibulla przedstawia się on następująco:

$$D_n = 1 - e^{-\left(\frac{S(D)}{S_0}\right)^{\gamma}} \quad (10)$$

W powiązaniu z szacowaną wartością graniczną symptomu (7) zależność ta przyjmie postać (w przypadku rozkładu Weibulla):

$$\frac{Sg}{S_0} = \left[-\ln\left(\frac{A}{G}\right) \right]^{\frac{1}{\gamma}}. \quad (11)$$

Wspomnieć należy, że wartość graniczną powinno się uważać za wartość nieprzekraczalną dla danego symptomu. Wyróżnić można jeszcze wartość alarmową, S_a , której przekroczenie jest sygnałem, że maszyna jest bliska awarii i konieczna jest jej ciągła obserwacja. Wartość alarmową otrzymamy zakładając, że $R(S_a)$, jest pewną wielokrotnością wartości niezawodności dla symptomu granicznego:

$$R(S_a) = cR(Sg), \quad (12)$$

Wartość c przyjmuje się z zakresu od 2 do 5[9]. Potrzebne jeszcze oszacowania **gotowości G** można dokonać za pomocą wzoru [7]

$$G = \frac{T_z}{T_z + T_n}, \quad (13)$$

T_z - średni czas poprawnej pracy maszyny, T_n średni czas koniecznych napraw.

Wartość A ze wzoru (7) można także oszacować za pomocą zależności:

$$A = \mu(1-G). \quad (14)$$

Współczynnik bezpieczeństwa μ można przyjąć jako: $\mu=1\div 3$ dla mało odpowiedzialnych maszyn i $\mu=3\div 10$ dla maszyn odpowiedzialnych [9]. W tej pracy do celów obliczeniowych przyjęto gotowość grupy obiektów $G=0.9$ oraz procent zbędnych remontów $A=0.01$.

3.2. Narzędzia diagnozowania wielowymiarowego

Obserwacja stanu obiektu pozwala diagnozować jego proces zużywania się w stopniu wielowymiarowym, przechodząc do diagnostyki wielouszkodzeniowej. Do pokazania zysku wielowymiarowości przetworzone zostaną macierze obserwacji danych obiektów za pomocą programów informatycznych przeznaczonych do tego celu takich jak: `diaginfo.m` i `pcainfo.m`.

Program `diaginfo.m` wykorzystuje się do przetworzenia macierzy obserwacji diagnostycznej i zastosowaniu procedury SVD (Singular Value Decomposition) dla danej macierzy obserwacji. W przypadku tej pracy danych silnika spalinowego `sil54d2`, skrót ten oznacza, że jest to silnik `sil54`, a `d2` jest punktem pomiarowym Program powala na obserwację całej „rodziny” krzywych symptomowych, ich % udział w zawartości informacji diagnostycznych o niezależnych uszkodzeniach w macierzy obserwacji. Obecnie zawartość tego programu została zaimplementowana do nowszej wersji, jaką jest program **`pcainfo.m`**. Pozwala on również na wykrycie niezależnych dyskryminant SD_i i ich miar zaawansowania σ_i . Dyskryminanty SD_i oraz wartości szczególne σ_i

mogą obrazować całościowe zaawansowanie zużycia w obiekcie, jak niżej. Postulujemy, zatem, że:

Zaawansowanie pojedynczego uogólnionego uszkodzenia będzie opisywane przez symptom uogólniony:

$$SD_i(\theta) \sim F_i(\theta). \quad (15)$$

Zaawansowanie całości procesów zużyciowych zaś przez sumę symptomów uogólnionych:

$$SD(\theta) = \sum_{i=1}^{\bar{z}} |SD_i(\theta)| = \sum_{i=1}^{\bar{z}} |\sigma_i(\theta) \cdot u_i(\theta)| \sim \sum_{i=1}^{\bar{z}} |F_i(\theta)| = P(\theta) \quad (16)$$

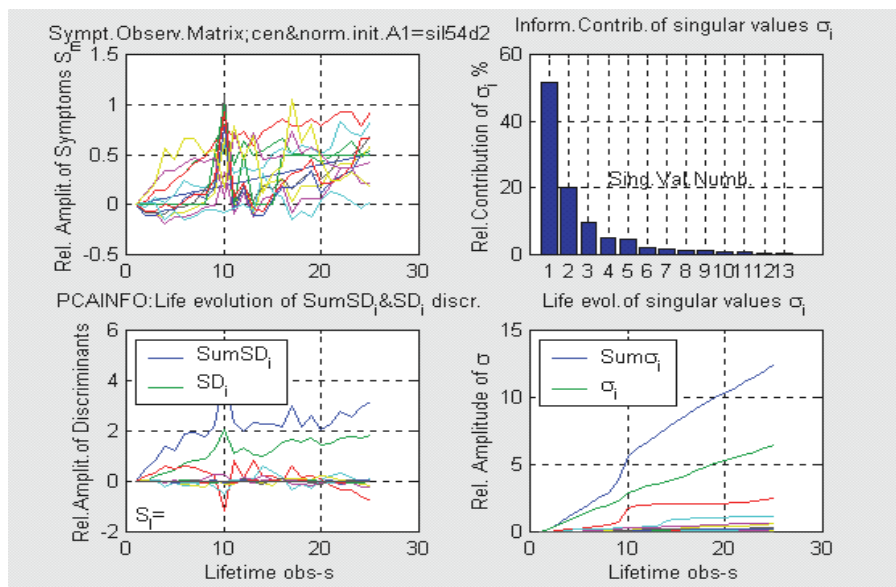
Czas życia jest wartościowany dyskretnie, z odczytami monitorowania dla kolejnych θ_n .

Do celów obliczeniowych w tej pracy wykorzystane zostaną dane symptomów najbardziej charakterystycznych pod względem zawartości informacji diagnostycznych. Będą to dwa symptomy tzn. symptomy wartości średniej przyspieszeń drgań i skutecznej (A_{sr} , A_{sk}).

Program **`pcainfo.m`** służy do ekstrakcji informacji diagnostycznych z macierzy obserwacji. Skrót `pca` w nazwie programu oznacza Principal Component Analysis, czyli rozkład macierzy według składowych głównych. Program ten służący do prognozy wielowymiarowej na podstawie przetworzenia całej macierzy obserwacji przedstawia symptomy w postaci uogólnionej. Oznacza to, że po wycentrowaniu i znormalizowaniu symptomów do wartości początkowej obserwuje się uszkodzenie lub uszkodzenia symptomu uogólnionego w postaci krzywej życia.

3.3. Rezultaty uzyskane po zastosowaniu programów `pcainfo.m` i `diaginfo.m`

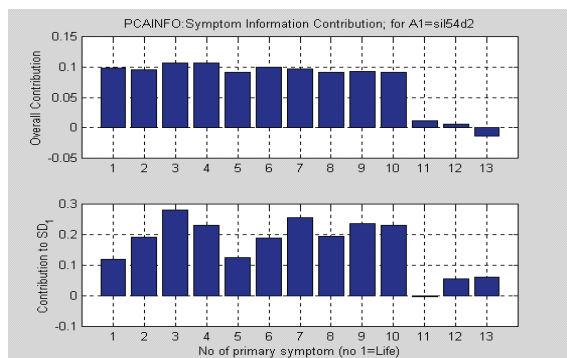
Program **`pcainfo.m`** jest nowszą wersją programu `diaginfo.m` uzyskujemy na jego podstawie dane symptomów w postaci uogólnionej i symptomy sumaryczne. Zastosowanie programu pozwala między innymi na uzyskanie informacji o dominujących symptomach uszkodzeniowych. Przykład obrazuje rys.1. Jak widać 12 mierzonych symptomów tworzy gęstwinę informacji (obrazek lewy górny), która po zastosowaniu SVD (Singular Value Decomposition) jest dekodowana na dwa główne rodzaje uszkodzeń, ponieważ σ_1 i σ_2 to kolejno 50% i 20% ogółu informacji diagnostycznej w macierzy obserwacji (rysunki prawe, górny i dolny). Uszkodzenie SD_1 rośnie prawie monotonicznie, drugie natomiast jest niezbyt stabilne i zaczyna rosnąć po pomiarze dwudziestym (200 tys. km) obrazuje to wykres (lewy dolny) na rys.1.



Rys. 1. Zawartość informacji diagnostycznej o niezależnych uszkodzeniach w symptomowej macierzy obserwacji silnika Diesla sil54d2

W badaniach diagnostycznych skupimy się na najbardziej rozwiniętym uogólnionym uszkodzeniu SD_1 , ponieważ symptom $sumSD_i$ jest tu bardzo podobny. Interesujące jest pytanie, jakie mierzone pierwotnie symptomy tworzą SD_1 i czy można w inny sposób oceniać wkład informacyjny symptomów.

Odpowiedź na to pytanie przedstawia rys.2 uzyskany z programu **pcainfo.m**.



Rys. 2. Wkład pierwotnych symptomów w pierwszą dyskryminantę SD_1 oraz w ogólne informacje diagnostyczne silnika sil54d2

Z rysunku 2 (obrazek górny) zauważyć można, że symptom 1 to czas życia, symptomy 2,3,4 to kolejno przyspieszenia $A_{Sr.}$, $A_{sk.}$, $A_{szcz.}$, symptomy prędkości 5,6,7 to $V_{Sr.}$, $V_{sk.}$, $V_{szcz.}$, symptomy o numerach 8,9,10, to przemieszczenia $X_{Sr.}$, $X_{sk.}$, $X_{szcz.}$. Symptomy o numerach 11,12,13 (to częstość Rice'a przyspieszeń, prędkości i przemieszczeń drgań). Jak widać te ostatnie, czyli nr 11,12,13 można pominąć, ponieważ nie wnoszą liczącego się zasobu informacji w diagnozowanie

uogólnionego uszkodzenia pierwszego SD_1 , gdyż ich kowariancja z SD_1 i suma kowariancji jest mała.

Przydatność dekompozycji SVD do wielowymiarowej diagnostyki obiektów potwierdzają przykłady z rysunków 1 i 2. Na podstawie programów oceniać można także zaawansowanie innych uszkodzeń, a również redukować nadwymiarowość obserwacji, jak w tym przypadku symptomy 11,12,13.

4. METODA OCENY ZYSKU WIELOWYMIAROWOŚCI W DIAGNOSTYCE WYBRANYCH OBIEKTÓW

4.1. Prognozy jednowymiarowe

Do wykonania prognozy jednowymiarowej pod uwagę brane są dane symptomowe silnika sil54d2. Najpierw po zastosowaniu programu **diaginfo.m** wybrany zostanie najlepszy symptom lub symptomy tzn. taki lub takie, które wnoszą znaczącą ilość informacji o dominującym uszkodzeniu w obiekcie. Następnie wybrany symptom uszkodzenia zostanie przetworzony za pomocą programu **dem.8**, tak, aby wydobyc informację o zbliżającym się stanie alarmowym i szacowanej liczbie obserwacji, jaka jeszcze została przed awarią.

Kolejnym krokiem będzie zastosowanie programu **dem.8** po to, aby przeprowadzić prognozę prowadzącą do wykrycia stanu przed alarmowego.

Prognoza przyszłej wartości symptomu, może odbywać się w dwu wymiarach. Pierwszy to prognoza symptomu w najbliższej przyszłości od ostatniego pomiaru.[9]. Przeprowadzana będzie ona w celu określenia czy w najbliższym czasie nie wystąpi przekroczenie wartości dopuszczalnych. Drugim aspektem prognozy może być prognoza

czasu, w którym takie przekroczenie nastąpi. W tej pracy interesuje nas bezwymiarowy czas życia obliczony na podstawie równań [9]:

$$\text{- model Pareto } D_n = 1 - \left(\frac{S(D_n)}{S_0} \right)^{-\gamma}, \quad (17)$$

gdzie D_n -szacowany bezwymiarowy czas życia maszyny na podstawie n-tej obserwacji $S(D_n)$,

$$\text{- model Weibulla } D_n = 1 - e^{-\left(\frac{S(D_n)}{S_0} \right)^{-\gamma}}, \quad (18)$$

$$\text{- model Frecheta } D_n = e^{-\left(\frac{S(D_n)}{S_0} \right)^{-\gamma}}, \quad (19)$$

gdzie γ jest oszacowane na bieżąco w programie.

Można stąd określić resztkowy bezwymiarowy czas życia ΔD_n , ($\Delta D_n = 1 - D_n$), tzn. zaprognozować czas awarii. Wcześniej należy dopasować do eksperymentalnego rozkładu, któryś z modelowych rozkładów, wybrać najlepiej dopasowany i zidentyfikować współczynniki modelu. Znając bezwymiarowy czas życia w danej chwili i ostatnią

wartość symptomu można wyznaczyć prognozowane wartości dla każdego z modeli.

Do analizy wybrane zostały wartości symptomów z kolumn 2 i 3. W przypadku jednowymiarowej diagnozy i prognozy kolumny 2 i 3 to (numery symptomów przyspieszeń) A_{sr} , A_{sk} , zaś n oznacza kolejny punkt obserwacji symptomowej krzywej życia. Stan alarmowy dla danych oryginalnych (silnika sil54d2) pojawia się dla symptomu przyspieszenia A_{sr} przy rozkładzie logarytmicznym dla punktu obserwacji symptomowej krzywej życia $n=14$. Dla danych tego samego silnika, ale w przypadku diagnozy i prognozy wielosymptomowej tzn. po przetworzeniu przez dem8 stan alarmowy dla symptomu SumSDi pojawia się także przy rozkładzie logarytmicznym w punkcie obserwacji krzywej życia $n=16$. Dla symptomu SD1 stan alarmowy występuje przy rozkładach Pareto i logarytmicznym, ale także przy punkcie obserwacji nr.16 Wartości te zestawiono w tabeli 1.

Tabela.1 Detekcja stanów alarmowych w diagnozowaniu jedno i wielowymiarowym silnika sil54d2.

Jednowymiarowa diagnoza i prognoza wg. najlepszego symptomu.						Diagnoza i prognoza wielosymptomowa z pełną macierzą obserwacji					
k	N	Weibull	Frechet	Pareto	Logarithm.	K	N	Weibull	Frechet	Pareto	Logarith.
2	14				37.5	2	16	3.4	3.5	4.1	3.7
	15	39.1	39.8	41.8	39.1		18	3.4	3.5	4.0	3.5
	17	36.0	36.5	36.3	36.3		21	3.4	3.5	4.1	3.6
	21	35.0	35.4	35.9	35.3		23	3.8	3.9	4.8	3.9
	23	39.2	39.6	40.6	38.9		25	4.6	4.8	5.7	4.6
	25	36.3	36.7	37.3	36.5						
3						3	16	2.8	2.9	3.3	2.8
	15	59.0	57.0	58.5	56.0		18	2.8	2.9	3.3	2.8
	17	55.6	56.4	57.7	57.5		21	2.6	2.7	3.0	2.6
	21	57.6	58.2	59.4	57.1		23	3.0	3.1	3.5	3.0
	23	60.2	60.4	61.7	59.2		25	3.1	3.2	3.6	3.0
	25	59.9	60.0	61.3	58.9						

Współczynniki determinizmu R%						Współczynniki determinizmu R%					
k	N	Weibull	Frechet	Pareto	Logarit	K	n	Weibull	Frechet	Pareto	Logarith
2	25	95.4%	83.2%	72.7%	87.7%	2	25	95%	82.8%	74.0%	84.6%
3	25	93.3%	80.1%	64.2%	84.1%	3	25	96.3%	80.3%	65.4%	88.7%

k- numer symptomu,

n- kolejny punkt obserwacji na symptomowej krzywej życia.

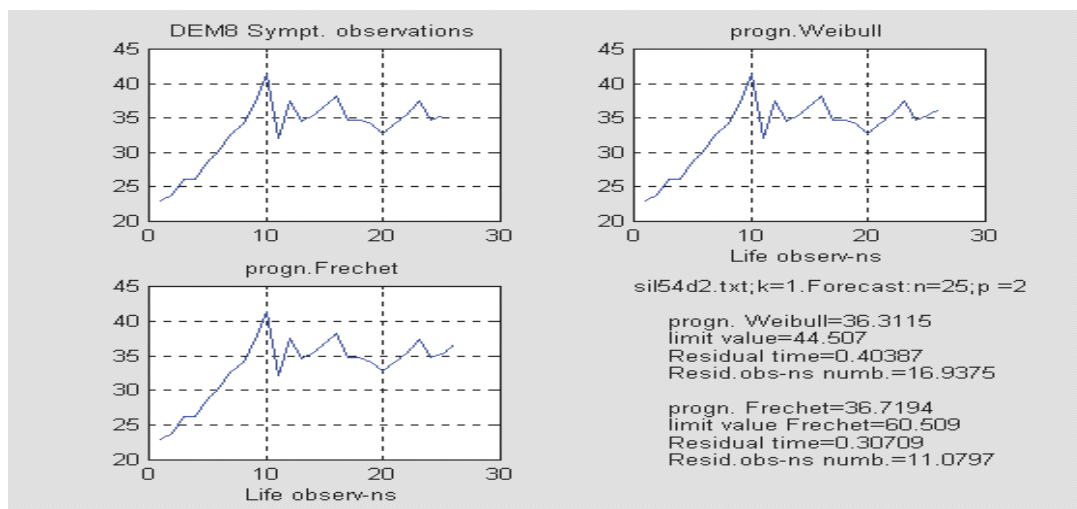
Przykład z tabeli 1 ukazuje dla jednowymiarowej diagnozy i prognozy symptomu z punktu obserwacji 21 przy prognozie Weibulla dla symptomu przyspieszenia A_{sr} ; przewidywana wartość w jednostkach bezwzględnych wynosi 39.1 w jednostkach przyspieszenia m/s^2 , a podczas zastosowania diagnozy wielowymiarowej dla tego samego punktu obserwacji przewidywana wartość prognozy Weibulla startuje z wartości względnej

3.40, by ostatecznie dojść do wartości 4.6 w jednostkach bezwymiarowych.

Kolejną miarą pewności diagnozy jest współczynnik determinizmu R% przedstawiony w tej samej tabeli. Dla przykładu dla symptomu 3 (symptom przyspieszeń A_{sk}) punkt obserwacji na symptomowej krzywej życia 25 prognozy Weibulla podczas diagnozowania i prognozowania jednowymiarowego wynosi 93.3%, a po

zastosowaniu diagnozy i prognozy wielowymiarowej współczynnik ten wzrósł do wartości 96.3%. Rysunek 3 przedstawia prognozę stanu dla silnika sil54d2 przy ostatnim punkcie czasu życia $n=25$ i symptomu przyspieszeń A_{sr} .

Z rysunku wynika, że pozostały bezwymiarowy czas resztkowy, przy wartości współczynnika gotowości $G=0.9$ i procencie zbędnych remontów $A=0.01$ plasuje się na poziomie równym 0.40387.



Rys.3. Prognoza dla silnika sil54d2 wg.symptomu A_{sr} . tuż przed awarią dla $n=25$

4.2. Prognozy wielowymiarowe


Do wykonania prognozy wielowymiarowej konieczne jest uzyskanie z programu pcainfo.m uogólnionych symptomów SDi i SumSDi tak, aby ich wartości zaimplementować do programu dem8. Rozpatrujemy w dalszym ciągu dane z silnika sil54d2

Rysunki 4 i 5 przedstawiają symptomy SDi silnika sil54d2. Rysunek 4 przedstawia symptom SD1 dla symptomu 1 dla porównania bezwymiarowy resztkowy czas obserwacji wynosi 7.1621, a przy prognozie jednowymiarowej dla tego

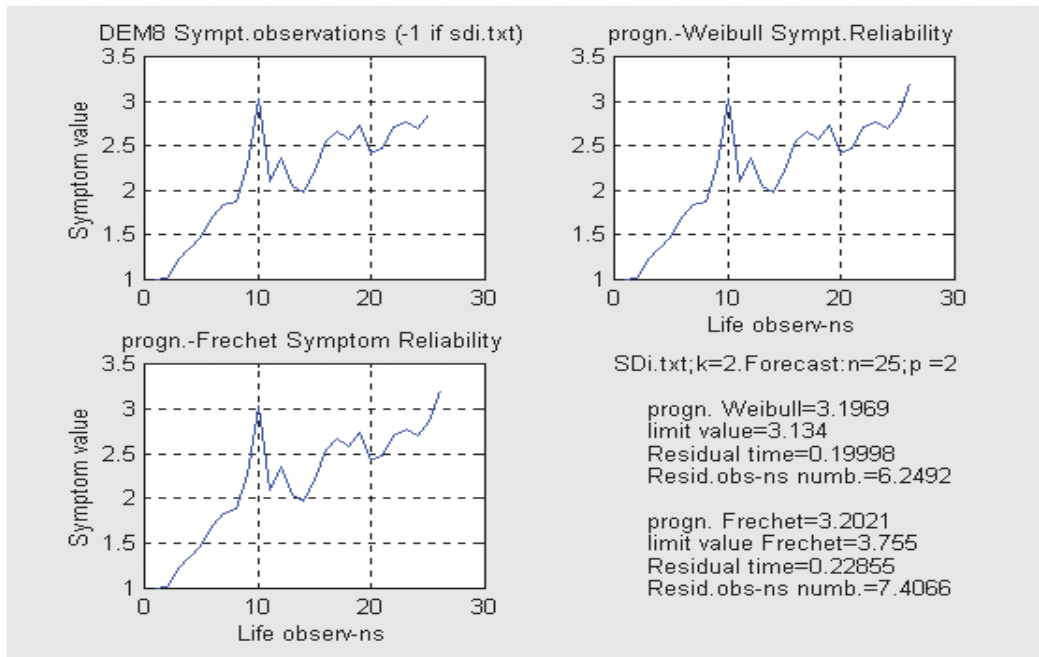
samemu symptomu bezwymiarowy resztkowy czas obserwacji wynosił 16.9 dla prognozy Weibulla.

Rysunek 5 przedstawia także wartość symptomu SDi silnika sil54d2, lecz dla symptomu uogólnionego 2 z resztkowym czasem obserwacji 6.24.

Szersze porównanie wartości czasów resztkowych i resztkowych obserwacji do wystąpienia awarii dla prognozy jedno i wielowymiarowej przedstawione zostały w tabeli 2 (silnik sil54d2).



Rys. 4. Uogólniony symptom SDi silnika sil54d2 (k=1)

Rys. 5. Uogólniony symptom SD_1 silnika sil54d2(k=2),przetworzony programem dem8

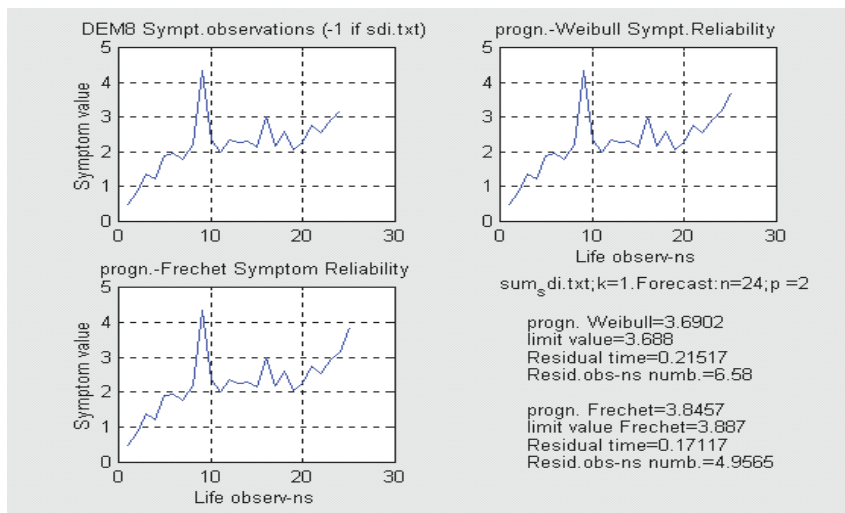
Tab.2. Porównanie wartości symptomów uogólnionych dla prognoz Weibulla i Frechet dla silnika sil54d2 przy prognozie jedno i wielowymiarowej

		Prognoza jednowymiarowa		P. wielowymiarowa	
Symptom	Kolejny p.obser.		Prognoza	Symptom	Prognoza
Sil54d2	25	Prog.Weibulla	36.3115	SD1	4.686
		Limit value	44.507		4.753
		Residual time	0.4038	<i>-Spadek-</i>	0.222
		Resid.obs-ns	16.937		7.162
		Prog.Frechet	36.719		4.838
		Limit value	60.509		5.022
		Residual time	0.307	<i>-Spadek</i>	0.179
		Resid.obs-ns	11.079		5.565
Sil54d2	25	Prog.Weibulla	59.916	SumSdi	3.690
		Limit value	62.120		3.688
		Residual time	0.252	<i>-Spadek</i>	0.215
		Resid.obs-ns	8.464		6.581
		Prog.Frechet	60.087		3.845
		Limit value	76.232		3.887
		Residual time	0.302	<i>-Spadek</i>	0.171
		Resid.obs-ns	10.839		4.956

Przyglądając się wartościom z tabeli 2 dla czasów resztkowych i resztkowych obserwacji do wystąpienia awarii zauważyć można, że po zastosowaniu prognozy wielowymiarowej dla tych samych symptomów poszczególne wartości wykazują tendencję spadkową. Na przykład dla silnika sil54d2 przy prognozie jednowymiarowej dla Weibulla czas resztkowy wynosił **0,4038**, a po zastosowaniu prognozy wielowymiarowej wartość ta

wyniosła **0,222**. Zatem, wnioskować można, że w prognozie wielowymiarowej decyzja jest bardziej dokładna.

Rysunek 6 obrazuje wartości dla silnika sil54d2 symptomu SumSdi bezwymiarowy resztkowy czas obserwacji wynosi w tym przypadku 0,215 dla prognozy Weibulla, a dla prognozy Frechet'a wg rozkładu tylko 0,1711.



Rys. 6. Prognoza życia dla uogólnionego symptomu SumSdi silnika sil54d2.

Dla danych z innych podobnych obiektów wyliczone zostały także współczynniki determinizmu R%, w procentach dopasowania do konkretnego rozkładu. Dominującym rozkładem był rozkład Weibulla, aż na 40 rozpatrywanych przypadków (dla danych oryginalnych) 29 danych to właśnie wspomniany powyżej rozkład.

W odniesieniu do danych, które zostały przetworzone przez pcainfo.m a następnie za pomocą dem8.m rozkład ten występuje w przeważającym stopniu tzn. na 40 przypadków 32 to rozkłady wg. Weibulla.

Wyniki obliczeń zostały zestawione w tabeli 3.

Tabela 3. Skojarzone współczynniki determinizmu R% dla danych obiektów w prognozie jedno/i wielowymiarowej

Uwaga; Współczynnik determinizmu R% dla danych wyjściowych z obiektów (symptomy oryginalne po przetworzeniu przez dem8.m) / Współczynniki determinizmu R% dla obiektów poddanych prognozie wielowymiarowej (symptomy przetworzone przez pcainfo.m i dem8.m). Szare tło sygnalizuje zwiększenie tego współczynnika

Obiekt	Symptom	Weibull	Frechet	Pareto	Uniform
Sil54d2	1	95.4 % / 95.0%			
	2	93.2% / 96.3%			
Sier1	1	95.4% / 98.4%			
	2	96.1% / 99.1%			
Sier2	1	80.2% / 97.9%		88.1%	
	2	97.5% / 97.2%			
S24Vsk	1	97.7% / 94.9%			
	2	92.5% / 98.8%	94.7%		
Sil24d2	1	99.1% / 97.2%			
	2	98.0% / 97.8%			
Sild6	1	96.2% / 96.8%			
	2	95.8% / 98.7%			
S24Asz	1	97.7% / 98.6%			
	2	96.9% / 97.6%			
Sild1	1	96.7% / 95.7%			97.3%
	2	98.9% / 98.8%			
Sild2	1	99% / 95.9%			
	2	97.1% / 99.1%			97.8%
Sild3	1	97% / 95.5%			97.8%
	2	98.6% / 99.3%			
Sild9	1	95.8% / 92.5%			
	2	93.9% / 99.3%			

W tabeli 3 porównane zostały wartości współczynnika determinizmu R% po zastosowaniu do danych wyjściowych obiektów, czyli danych oryginalnych i wartości tego współczynnika

obliczonego dla tych samych obiektów, lecz dla symptomów przetworzonych przez program pcainfo.m a następnie przez program dem8.m. Wartości te zostały przedstawione dla rozkładu

Weibulla, gdyż to właśnie ten rozkład jest najczęściej występującym. Szare tło przy prognozie Weibulla sygnalizuje zwiększenie wartości współczynnika determinizmu po przetworzeniu programami **pcainfo.m** i **dem8.m**.

Zatem zaobserwować można, że po przetworzeniu danych przez programy **pcainfo.m** i **dem8** współczynnik determinizmu $R\%$ wzrasta, prawie we wszystkich przypadkach.

Dla przykładu weźmy pod uwagę rozpatrywany w pracy silnik sil54d2 dla symptomu 2 (A_{sk}) z danych wyjściowych $R\%=93.2\%$ a po przetworzeniu $R\% = 96.3\%$ co oznacza, że zastosowanie prognozy i wnioskowanie wielowymiarowe może być znacznie dokładniejsze.

5. PODSUMOWANIE

W pracy starano się wykazać, że macierze obserwacji symptomów z obiektów poddane przetworzeniu przez programy (**dem8.m**, **pcainfo.m**, **diaginfo.m**), dają możliwości „wyłonienia” symptomów uogólnionych, takich, które zawierają istotne informacje opisujące występujące uszkodzenia. Prognozy wykonane dla poszczególnych symptomów dają obraz tego, w którym momencie (biorąc pod uwagę krzywe życia obiektu) wystąpi informacja o **alarmie**, oraz ile bezwymiarowego czasu obserwacji zostało do zaistnienia stanu alarmowego.

Detekcja stanów alarmowych w diagnozowaniu jedno i wielowymiarowym obiektu pozwala nie tylko na uzyskanie informacji o zbliżającym się alarmie, lecz także podaje wartości resztkowych czasów obserwacji dla dominujących rozkładów prawdopodobieństwa (Weibulla, Frechet, Pareto). Porównano wartości symptomów z prognozy jednowymiarowej danych oryginalnych oraz wartości tych symptomów po przetworzeniu na potrzeby prognozy wielowymiarowej. Wykazano, że rozkładem przeważającym jest prognoza Weibulla, czego najlepszym przykładem są obliczone współczynniki determinizmu $R\%$. Bardziej słuszne jest także stosowanie diagnozy w ujęciu

wielowymiarowym, jest ona metodą bardziej dokładną niż prognoza jednowymiarowa. Daje ona, bowiem możliwość szybszego wykrycia stanu alarmowego obiektu, co przedkłada się na pewniejszą decyzję o ewentualnym wyłączeniu maszyny w celu jej odnowy.

LITERATURA

1. Pszczołkowski T., *Mala encyklopedia prakseologii*, Ossolineum, Wrocław 1978, str.48.
2. Cempel C, Tabaszewski M, Krakowiak M., *Metody Ekstrakcji Wielowymiarowej Informacji Diagnostycznej*, 2003, Węgierska Górka.
3. Cempel C., *Diagnostyka Wibroakustyczna Maszyn*, P.P Poznań 1985
4. Kielbasiński A., Schwetlick H., 1992, *Linear Numerical Algebra*, WNT, Warsaw, chapt.1, p.502.
5. Cempel C., *Pareto Law of Damage Evolution in Application to Vibration, Condition Monitoring*. Bulletin of the Polish Academy of Sciences, vol.39, No4, 1991, str.573-588.
6. Cempel C., *Pre-Breakdown Symptom Value for Vibration Condition Monitoring*, Bulletin of the Polish Academy of Sciences, Technical Sciences Vol.37, NO 7-12, 1989.
7. Tomaszewski F., Cempel C., *An Attempt to Diagnose a Locomotive Combustion Engine by utilizing Vibroacoustic Process*. The Archives of Transport, No1, 1991.
8. Cempel C., *Multi Dimensional Condition Monitoring of Mechanical Systems in Operation*, XXI Conf. On Machine Diagnostics Węgierska Górka, March 2002.
9. Raport z projektu badawczego: „*Teoria degradacji maszyn i urządzeń jako ewolucyjnych systemów otwartych z ograniczoną dyssypacją*.” Poznań, wrzesień 1996r.
10. Bobrowski D., *Elementy teorii prawdopodobieństwa*, skrypt uczelniany Politechniki Poznańskiej, Poznań 1971, rozdz.3.1.



Mgr inż. Magdalena KRAKOWIAK jest doktorantem w Instytucie Mechaniki Stosowanej Politechniki Poznańskiej i zamierza zrealizować rozprawę doktorską z przedstawionej tematyki w artykule.



Czesław CEMPEL - Profesor dr hab. Jest kierownikiem Zakładu Wibroakustyki i Bio-Dynamiki Systemów Wydziału Budowy Maszyn i Zarządzania Politechniki Poznańskiej, dr h.c. Politechniki Szczecińskiej, członek korespondent Polskiej Akademii Nauk, członek Komitetu Badań Naukowych w trzeciej kadencji. Jest członkiem wielu organizacji naukowych krajowych i zagranicznych np.: IMEKO, EUROSCIENCE, GAMM. Jeden z założycieli PTDT w 1990 r. Obecnie jest honorowym przewodniczącym PTDT. Zajmuje się wibroakustyką i diagnostyką maszyn, inżynierią systemów, ekologią. Autor ponad 350 opublikowanych prac, 12 skryptów i książek.