

OPTYMALIZACJA ZBIORU CECH SYGNAŁÓW DIAGNOSTYCZNYCH MASZYNY WIRNIKOWEJ

Damian SŁAWIK

Politechnika Śląska, Katedra Podstaw Konstrukcji Maszyn
ul. Konarskiego 18a, 44 - 100 Gliwice
e-mail: damian.slawik@polsl.pl

Streszczenie

W referacie opisano wyniki testów modeli diagnostycznych zidentyfikowanych na podstawie wartości cech sygnałów oraz informacji o stanie obiektu. Rozpatrzone dwa przypadki. W pierwszym do celów optymalizacji zbioru cech skorzystano z miar wrażliwości. W drugim przypadku uwzględniano wszystkie cechy sygnałów. Prowadząc badania, do określenia zbioru uczącego oraz testującego, skorzystano z metody *leave one out*.

Zaproponowana w referacie metoda optymalizacji zbioru cech sygnałów znajduje zastosowanie w wyborze cech sygnałów zawierających najwięcej istotnych informacji o stanie lub klasie stanu badanego obiektu. Wybierane za jej pomocą cechy mogą służyć do budowy prostszych, sprawniejszych i wydajniejszych systemów diagnostycznych.

Słowa kluczowe: selekcja cech, analiza wrażliwości, diagnostyka maszyn, model diagnostyczny

OPTIMIZATION OF SET OF DIAGNOSTIC SIGNAL FEATURES OF ROTATING MACHINE

Summary

The results of tests of diagnostics models are described in the paper. Those models are identified based on value signal feature and information of object state. Two cases were considered. The measures of sensitivities to optimization of signal features were used in the first case and all the signals features were considered in the second one. The 'leave one out' method was applied to the both cases.

Sensitivity analysis can be used in selection of signal features. Such the signal features contain the most important information about state or state class of researched object. Selected signal features may be used to design and perform simpler and more efficient diagnostic systems.

Keywords: features selection, sensitivity analysis, machinery diagnostics, diagnostics model

1. WSTĘP

Projektując różnego rodzaju maszyny dużą uwagę skupia się zarówno na ich niezawodności jak i na minimalizacji kosztów eksploatacji. Są one ściśle ze sobą związane. Chcąc zwiększyć niezawodność należy częściej przeprowadzać przeglądy i/lub remonty, co wiąże się z większymi wydatkami. Sposobem na rozwiązanie tego problemu, może być system diagnostyczny monitorujący stan maszyny. Dysponując systemem diagnostycznym można z pewnym wyprzedzeniem przewidzieć awarię oraz przeprowadzić remont. Można także uniknąć sytuacji, w których maszyna jest wyłączana z ruchu i poddawana przedwczesnemu, niepotrzebnemu przeglądowi. Rozwiązanie takie jest stosowane w przypadku, gdy zyski wynikające z działania takiego systemu są większe od kosztów jego wdrożenia oraz utrzymania.

Redukując do minimum liczbę wchodzących w skład systemu diagnostycznego czujników będących źródłem sygnałów

diagnostycznych można obniżyć koszt samego systemu. Przykładem może być hipotetyczny system autodiagnostyki wentylatora składający się z jednego akcelerometra oraz układu elektronicznego realizującego zadania związane z przetwarzaniem sygnału oraz klasyfikacją stanu.

Uproszczenie systemu diagnostycznego niestety może pociągać za sobą pogorszenie jakości klasyfikacji stanu diagnozowanego obiektu. Chcąc zaradzić temu zaproponowana została metoda selekcji wrażliwych cech sygnałów optymalizująca zbiór dostępnych cech.

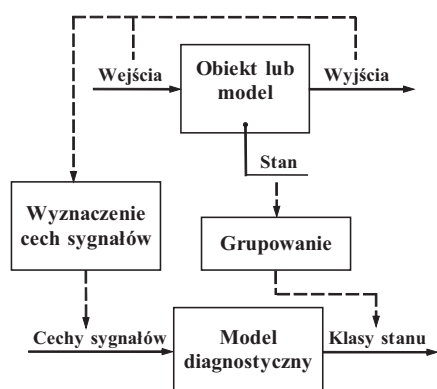
2. MODEL DIAGNOSTYCZNY

Założmy, że chcemy zbudować prosty system diagnostyczny. Będzie się on składał z jednego lub kilku czujników, dostarczających informacje o stanie badanego obiektu za pośrednictwem sygnałów diagnostycznych. Chcąc wydobyć tę informację o stanie obiektu z sygnałów wyznaczamy wartości cech sygnałów. Postępowanie takie jest uzasadnione, ponieważ cechy sygnałów często będąc

¹ Opracowano częściowo w ramach grantu promotorskiego KBN 8 T07B 030 27 pod kierunkiem W. Cholewy

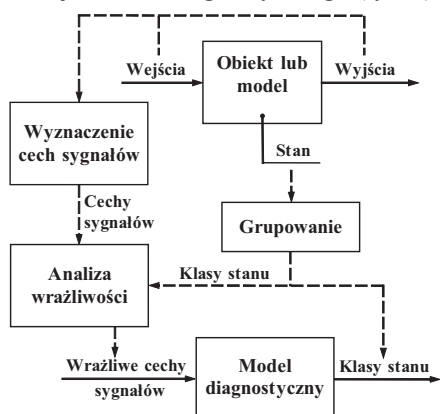
estymatorami nieobciążonymi, minimalizują wpływ wszelkiego rodzaju zakłóceń i zwiększają stosunek sygnału do szumu. Dodatkowo wyznaczenie większej liczby cech sygnałów, przy obecnych możliwościach obliczeniowych, jest tańsze, niż zwiększenie liczby mierzonych sygnałów diagnostycznych.

Mając do dyspozycji wartości cech sygnałów i posiadając wiedzę na temat związanych z nimi stanów identyfikujemy model diagnostyczny (rys.1). Może on być zarówno zestawem prostych reguł, zestawem reguł przybliżonych, jak i wyuczoną siecią neuronalną. Tak otrzymany model diagnostyczny będący integralną częścią systemu diagnostycznego dostarcza informacji o stanie na podstawie przesyłanych do niego wartości cech sygnałów.



Rys. 1. Identyfikacja modelu diagnostycznego

Pamiętając, że naszym celem jest zbudowanie prostego systemu diagnostycznego, oraz przyglądając się rysunkowi (rys. 1), można przypuszczać, iż jest to możliwe poprzez zmniejszenie do minimum liczby cech na wejściu modelu diagnostycznego. Ograniczając, zgodnie z tą sugestią zbiór cech sygnałów nasuwa się jednak pytanie: Co się stanie, jeżeli rozpatrywane cechy, zamiast w sposób przypadkowy lub intuicyjny, będą wybierane na podstawie miar wrażliwości cech sygnałów na zmiany stanu? Aby na nie odpowiedzieć postanowiono uwzględnić analizę wrażliwości przy identyfikacji modelu diagnostycznego (rys. 2).



Rys. 2. Identyfikacja modelu diagnostycznego z przeprowadzaną optymalizacją zbioru cech

3. BADANY OBIEKT TECHNICZNY

Do badań wybrany został obiekt należący do klasy maszyn wirnikowych ułożyskowanych ślizgowo. Jest nim stanowisko Rotor Kit firmy Bentley Nevada [1]. Stanowisko to służy do badań drgań wałów i znajduje się laboratorium Katedry Podstaw Konstrukcji Maszyn Politechniki Śląskiej w Gliwicach. Podstawowymi jego elementami są: wał; dwie tarcze umożliwiające wprowadzenie niewyważ; dwa usadowione w podporach łożyska ślizgowe; silnik elektryczny przekazujący moc na wał poprzez sprzęgło podatne oraz układ pomiarowy służący do akwizycji sygnałów przemieszczeń względnych wału.

4. KLASY STANU

W wyniku przeprowadzonych przez A. Klimka oraz B. Wysogłada pomiarów [7] otrzymano dane zawierające przebiegi sygnałów diagnostycznych oraz informacje o odpowiadających im stanach obiektu. Badania były prowadzone z uwzględnieniem 166-ciu stanów technicznych, a rejestrację sygnałów wykonywano dla trzech różnych prędkości obrotowych wału, z czego optymalizacja cech zostanie przeprowadzona jedynie dla prędkości obrotowej $n = 5500 [obr/min]$.

Poszczególne stany techniczne można rozróżnić za pomocą takich cech stanu jak:

- umiejscowienie wprowadzanych do badanego obiektu niewyważ: tarcza nr 1; tarcza nr 2 lub obie tarcze jednocześnie;
- masa wprowadzanej niewyważi:
 $m = \{0; 0.6; 0.8; 1; 1.2; 1.4; 1.6\} [g]$;
- położenie kątowe niewyważi na tarczy:
 $\alpha = \{0; 22.5; 45; \dots; 337.5\} [deg]$.

Korzystając z tych informacji utworzono 3 klasy stanu:

- B1** masa niewyważi na tarczy nr 1: $\{0; 0.6\} [g]$;
- B2** masa niewyważi na tarczy nr 1: $\{0.8; 1; 1.2\} [g]$;
- B3** masa niewyważi na tarczy nr 1: $\{1.4; 1.6\} [g]$.

Każda z powyższych klas stanu B_i ; $i = 1, 2, 3$ reprezentowana jest przez stany związane z charakterystyczną dla każdej klasy, masą niewyważi na tarczy nr 1, którą mocowano w stałej odległości od środka tarczy. Ponadto w jednej klasie znajdują się stany związane z: różnymi wartościami położenia kąтового niewyważi na tarczy nr 1 i nr 2 oraz różnymi wartościami niewyważi na tarczy nr 2.

5. CECHY SYGNAŁÓW

Dane otrzymane z badań stanowiska Rotor Kit obejmują sygnały przemieszczeń względnych wału mierzone w dwóch płaszczyznach pomiarowych zlokalizowanych w pobliżu dwóch podpór łożyskowych. Są to: sygnały przemieszczeń względnych wału mierzone w kierunku poziomym oraz w kierunku pionowym.

Mając na celu optymalizację zbioru cech sygnału wyznaczone zostały 75 cechy dla każdej płaszczyzny pomiarowej. Tworzą one zbiór 150-ciu cech sygnałów: $c = \{c_1, c_2, \dots, c_m\}$.

6. DEFINICJA WRAŻLIWOŚCI

Chcąc optymalizować zbiór cech sygnałów należy określić, które cechy zawierają najwięcej informacji o interesującej nas klasie stanu. Można do tego celu posłużyć się miarą wrażliwości, której definicje przedstawiono poniżej:

„Wrażliwością s_i^j , wartości cech sygnałów W^j , na zmianę klasy stanu z B_i na inną, nazywamy względną zmianę wartości cech sygnałów W^j wynikającą ze zmiany tej klasy stanu.”

Można ją także przedstawić w postaci równania:

$$s_i^j = \frac{V(W^j | B_i)}{V(W^j | B)}; \quad B = \{B_1, B_2, \dots\}, \quad (1)$$

gdzie: B – zbiór klas stanu; B_i – rozpatrywana klasa stanu do której może należeć jeden lub więcej stanów; W^j – zbiór wartości j -tej cechy sygnału; $V(W^j | B)$ – wartość miary zmienności V uwzględniająca cechy sygnału W^j wyznaczone dla wszystkich stanów; $V(W^j | B_i)$ – wartość miary zmienności V cechy sygnału W^j wynikająca ze zmiany klasy stanu z B_i na inną klasę stanu.

7. WSTĘPNA SELEKCJA CECH SYGNAŁÓW

Przed przystąpieniem do wyznaczania wartości wrażliwości przeprowadzono analizę zmienności wartości cech sygnałów. Pozwala ona stwierdzić, czy zmiany wartości cech sygnałów zależą, chociaż w niewielkim stopniu, od klas stanu, dla których cechy te wyznaczone. Powszechnie do tego celu stosowanym narzędziem jest analiza wariancji. Jej przeprowadzenie wymaga jednak spełnienia podstawowego założenia, zgodnie z którym, rozkład wartości cech wyznaczonych dla poszczególnych klas stanu musi być normalny, z taką samą wariancją. Do celów diagnostyki, gdy nie chcemy zakładać postaci rozkładów statystycznych analizowanych wartości cech sygnału, znajdują zastosowanie metody rangowe. Metodą najbardziej odpowiednią do tego celu wydaje się nieparametryczny test Kruskalla-Wallisa. Test Kruskalla-Wallisa przeprowadzono niezależnie dla każdej cechy sygnału $nam(c_j)$; $j = 1, 2, \dots, m$ rozpoczynając każdorazowo od umieszczenia wartości rozpatrywanej cechy w tabeli, której kolumny odpowiadały kolejnym, rozpatrywanym klasom stanu. Traktując poszczególne kolumny tabeli jak grupy, wyznaczono rangi, statystykę testową T oraz przeprowadzono weryfikację hipotezy zerowej o równości grup [3] dla założonego poziomu istotności.

Odrzucenie hipotezy zerowej oznacza, iż rozpatrywana cecha sygnału $nam(c_j)$ zawiera informację pozwalającą odróżnić od siebie stany

należące do przynajmniej dwóch, spośród wszystkich klas stanu. Oznacza to także, że informacja taka może być niewystarczająca do poprawnego zaklasyfikowania dowolnego, rozpatrywanego stanu. Przyjęcie hipotezy zerowej oznacza małą przydatność rozpatrywanej cechy do celów diagnostycznych. Cechę taką można pominąć, ponieważ nie wnosi ona żadnych istotnych informacji o stanie badanego obiektu.

8. PRZEDZIAŁY UFNOŚCI

Drugim etapem poszukiwania optymalnego zbioru cech sygnałów są porównania wielokrotne rozkładów wartości cech poszczególnych par grup za pomocą testów Kruskalla-Wallisa lub za pomocą rangowego odpowiednika testu F Friedmana [3]. Wynikiem porównań wielokrotnych jest informacja o tym, czy różnice pomiędzy poszczególnymi parami grup (zbiorami wartości cech sygnałów) są na tyle duże, że można stwierdzić, iż grupy te są rozdzielne. Informacja ta jest zawarta w przedziałach ufności określanych niezależnie dla każdej pary grup (klas stanu):

$$\left\langle \Delta w_{i,k}^{-j}, \Delta w_{i,k}^{+j} \right\rangle; \quad i, k = 0, 1, \dots, 7; \quad j = 1, 2, \dots, 525. \quad (2)$$

Wyznaczanie przedziałów ufności podobnie jak przeprowadzenie testów statystycznych na równość grup wymaga przyjęcia odpowiedniego poziomu istotności.

9. MIARY WRAŻLIWOŚCI

Dysponując informacjami o przedziałach ufności oraz korzystając z przedstawionej definicji wrażliwości wyznaczamy wartości wrażliwości cząstkowej:

$$s_{i,k}^j = \begin{cases} 1 & \text{jeżeli: } \text{sign}(\Delta w_{i,k}^{-j}) = \text{sign}(\Delta w_{i,k}^{+j}) = 1; \\ -1 & \text{jeżeli: } \text{sign}(\Delta w_{i,k}^{-j}) = \text{sign}(\Delta w_{i,k}^{+j}) = -1; \\ \frac{\Delta w_{i,k}^{-j} + \Delta w_{i,k}^{+j}}{|\Delta w_{i,k}^{-j}| + |\Delta w_{i,k}^{+j}|} & \text{jeżeli: } \text{sign}(\Delta w_{i,k}^{-j}) \neq \text{sign}(\Delta w_{i,k}^{+j}); \end{cases} \quad (3)$$

$$i = 1, 2; \quad k = i + 1, i + 2, 3; \quad j = 1, 2, \dots, m.$$

Wpisujemy je w macierz o zerowych wartościach diagonalnych:

$$S_{cz}^j = [s_{i,k}^j]_{3 \times 3}; \quad s_{k,i}^j = -s_{i,k}^j; \quad s_{i,i}^j = 0. \quad (4)$$

Oprócz wrażliwości cząstkowej dla każdej cechy wyznaczamy wartości wrażliwości grupowej:

$$s_i^j = \frac{\sum_k |s_{k,i}^j|}{2}; \quad i, k = 1, 2, 3; \quad j = 1, 2, \dots, m; \quad (5)$$

$$S_{gr}^j = [s_i^j]_{1 \times 3}; \quad (6)$$

oraz wrażliwość główną:

$$S^j = s^j = \frac{\sum_i |s_i^j|}{3}; \quad i = 1, 2, 3; \quad j = 1, 2, \dots, m. \quad (7)$$

Cechy charakteryzujące się największą wrażliwością (główną) niosą najwięcej informacji

pozwalającej prawidłowo rozpoznać klasę stanu badanego obiektu. Cechy charakteryzujące się największą wrażliwością grupową pozwalają odróżnić związaną z mini klasę stanu od pozostałych klas. Korzystając, zatem z wartości wrażliwości możemy wyodrębnić optymalny zestaw cech, których uwzględnienie jako wejść systemu wnioskującego może być wystarczające do celów poprawnego określenia stanu diagnozowanego obiektu.

10. OPTIMALIZACJA ZBIORU CECH

Korzystając z wyznaczonych wartościach wrażliwości można wybrać optymalny, ze względu na jakość klasyfikacji stanu badanego obiektu, zbiór cech sygnałów. W przypadku prowadzonych badań był to zbiór 6-ciu cech charakteryzujących się największą wartością wrażliwości grupową (dwie cechy najbardziej wrażliwe w każdej grupie).

11. PRZEBIEG BADAŃ

Mając na celu określenie wpływu optymalizacji zbioru cech sygnałów na jakość budowanych modeli diagnostycznych porównano ze sobą dwa przypadki: **A1**: przeprowadzana była optymalizacja rozpatrywanego zbioru cech sygnałów; **A2**: uwzględniane były wszystkie cechy z rozpatrywanego zbioru cech sygnałów. Rozpatrywane zbiory cech **C4** oraz **C5** są 28-mio oraz 14-to elementowymi podzbiórmi zbioru wszystkich 150-ciu wyznaczanych cech.

Prowadząc badania, do określenia zbioru uczącego oraz testującego, skorzystano z metody *leave one out*.

Model diagnostyczny, który następnie testowano, był identyfikowany na podstawie zbioru danych uczących. W zbiorze tym wyróżniono dane związane z wejściami (cechami sygnałów) oraz dane związane z jednym wyjściem (numerem klasy stanu). Do budowy modelu diagnostycznego wybrano narzędzia bazujące na rozmytych sieciach neuronalnych, a jego opracowanie przebiegało kilkietapowo:

- najpierw określono optymalną liczbę grup dla poszczególnych cech sygnałów; narzędziem do tego zastosowanym był algorytm substryktywnej klasteryzacji [2];
- na podstawie informacji o liczbie grup budowane były reguły rozmyte [5];
- na podstawie wyprowadzonych reguł określona została struktura rozmytej sieci neuronalnej [4];
- po określeniu struktury, sieć poddawana była uczeniu; do celów uczenia sieci, a tym samym określenia parametrów reguł rozmytych skorzystano z narzędzia ANFIS (od ang. Adaptive Neuro-Fuzzy Inference System) [6];
- wyuczony model diagnostyczny (rozmytą sieć neuronalną) przetestowano stosując dane testujące.

12. WYNIKI BADAŃ ORAZ WNIOSKI

Wyniki przeprowadzonych badań zamieszczono w tabeli 1 oraz tabeli 2.

Tab. 1. Wyniki klasyfikacji otrzymane dla 14-tu oraz 6-ciu z 14-tu wybranych za pomocą analizy wrażliwości cech

Brak selekcji cech			Selekcja cech		
Test	O ₁	O ₂	Test	O ₁	O ₂
A2C5R0.4	43,4%	66,0%	A1C5R0.4	52,4%	74,1%
A2C5R0.5	49,4%	71,4%	A1C5R0.5	50,6%	73,8%
A2C5R0.6	45,8%	70,2%	A1C5R0.6	53,6%	75,0%
A2C5R0.7	50,0%	73,5%	A1C5R0.7	54,2%	75,3%
A2C5R0.8	51,8%	74,1%	A1C5R0.8	50,0%	73,2%

Tab. 2. Wyniki klasyfikacji otrzymane dla 28-miu oraz 6-ciu z 28-miu wybranych za pomocą analizy wrażliwości cech

Brak selekcji cech			Selekcja cech		
Test	O ₁	O ₂	Test	O ₁	O ₂
A2C4R0.4	45,8%	68,1%	A1C4R0.4	47,0%	71,1%
A2C4R0.5	42,8%	64,8%	A1C4R0.5	50,0%	72,0%
A2C4R0.6	50,6%	71,1%	A1C4R0.6	50,6%	73,5%
A2C4R0.7	53,0%	73,2%	A1C4R0.7	55,4%	76,8%
A2C4R0.8	48,8%	71,4%	A1C4R0.8	50,6%	74,4%

13. WNIOSKI

Oceny O₁ oraz O₂ uzyskane w przypadku stosowania selekcji cech są lepsze lub niewiele gorsze od ocen uzyskanych w przypadku, gdy ta selekcja nie była prowadzona. Pozwala to stwierdzić, że model diagnostyczny zbudowany na podstawie 6-ciu wrażliwych cech sygnałów, wybranych ze zbioru 14-tu lub 28-ciu cech może być lepszy od modelu zbudowanego na podstawie wszystkich 14 lub 28 cech. Oznacza to, że stosowanie optymalizacji zbioru cech pozwala nie tylko na uproszczenie modelu diagnostycznego, ale także poprawia jakość klasyfikacji stanu.

LITERATURA

- [1] Bently Nevada Corporation. *Rotor Kit*. Mindem USA, 1994.
- [2] Davé R.N., Krishnapuram R. *Robust clustering methods: a unified view*. IEEE Trans. Fuzzy Systems, (5):270–293, 1997.
- [3] Koronacki J., Mielniczuk J. *Statystyka dla studentów kierunków technicznych i przyrodniczych*. Wydawnictwo Naukowo-Techniczne, Warszawa, 2001.
- [4] Lin C.T. *A neural fuzzy control scheme with structure and parameter learning*. Fuzzy Sets and Systems, (70):183–212, 1995.
- [5] Paiva R., Dourado A. *Interpretability and learning in neuro-fuzzy systems*. Fuzzy Sets and Systems, (147):17–38, 2004.
- [6] The MathWorks, Inc. *Fuzzy logic toolbox user's guide*, 2004.

- [7] Wysogład B. *Mikrostanowisko do badań drgań wałów. Zbiór wyników pomiarów drgań w warunkach stacjonarnych*. Katedra Podstaw Konstrukcji Maszyn, Gliwice, 1997.
-



Magister inżynier Damian Sławik jest absolwentem Wydziału Mechanicznego Technologicznego Politechniki Śląskiej w Gliwicach. W roku 2000 rozpoczął studia doktoranckie w Katedrze Podstaw Konstrukcji Maszyn tejże uczelni.

Swoje zainteresowania skupia głównie na metodach komputerowego wspomaganego projektowania i eksploatacji maszyn, modelowania obiektów diagnostycznych, metodach sztucznej inteligencji oraz metodach diagnostyki technicznej. Jest on laureatem Stypendium Promocyjnego koncernu Fiat dla najlepszych prac dyplomowych magisterskich i doktorskich (nagroda zbiorowa wspólnie z Jackiem Wojtusikiem i Dominikiem Wachlą).