

Jarosław BEDNARZ, Tomasz BARSZCZ, Tadeusz UHL

AKADEMIA GÓRNICZO-HUTNICZA, WYDZIAŁ INŻYNIERII MECHANICZNEJ I ROBOTYKI, KATEDRA ROBOTYKI I MECHATRONIKI

Zastosowanie metody OMAX i modeli NARX do diagnostyki maszyn wirnikowych

Mgr inż. Jarosław BEDNARZ

Jest doktorantem w Katedrze Robotyki i Mechatroniki Akademii Górniczo-Hutniczej w Krakowie. Jego zainteresowania skupiają się na zastosowaniu analizy modalnej oraz modeli nieliniowych NARX w diagnostyce maszyn. Jest współautorem kilku prac z tego zakresu.



e-mail: jaroslaw.bednarz@agh.edu.pl

Dr inż. Tomasz BARSZCZ

Jest adiunktem w Katedrze Robotyki i Mechatroniki Akademii Górniczo-Hutniczej w Krakowie. Obszarem jego zainteresowania jest konstrukcja i zastosowania układów monitorowania stanu maszyn. Posiada znaczący dorobek naukowy w zakresie diagnostyki maszyn i układów regulacji. Jest autorem wielu artykułów o charakterze naukowym jak również wielu praktycznych wdrożeń w przemyśle.



e-mail: tbarszcz@uci.agh.edu.pl

Streszczenie

W artykule przedstawiono porównanie algorytmów detekcji uszkodzeń w oparciu o metodę OMAX oraz modele NARX. Zaprezentowano również stanowisko laboratoryjne znajdujące się w Katedrze Robotyki i Mechatroniki (KRiM) AGH służące do testowania powyższych metod.

Application of OMAX method and NARX models in diagnostics of rotating machinery

Abstract

The article discusses possibility of use OMAX method and NARX model in rotating machinery diagnostics. The idea of diagnostics algorithms based on this two methods is presented. The AGH laboratory test rig used for validate these methods is also presented.

1. Wstęp

Coraz większą rolę w diagnostyce maszyn i urządzeń odgrywa podejście wykorzystujące model monitorowanego obiektu lub model sygnału drganiowego pochodzącego z monitorowanego obiektu. Takie podejście umożliwia bardziej dokładną identyfikację uszkodzenia, daje także możliwość jego lokalizacji. W ramach projektu prowadzonego w Katedrze Robotyki i Mechatroniki (KRiM) AGH testowane są metody diagnostyczne wykorzystujące model modalny układu mechanicznego zbudowany z wykorzystaniem Eksploatacyjnej Analizy Modalnej z Mierzalnymi Wejściami (OMAX – z ang. Operational Modal Analysis with eXogenous Inputs) oraz model sygnałów zbudowany w oparciu o nieliniowy model ARX (NARX – Nonlinear AutoRegressive with eXogenous Inputs). W artykule zostaną zaprezentowane podstawy diagnostyki z wykorzystaniem tych metod, wyniki ich testowania oraz zaprezentowane zostanie stanowisko badawcze służące do ich testowania.

2. Opis metody OMAX [4, 8, 9]

Eksploatacyjna Analiza Modalna z Mierzalnymi Wejściami (OMAX) zakłada, że drgania każdego obiektu wymuszone są zarówno przez siły mierzalne jak i niemierzalne.

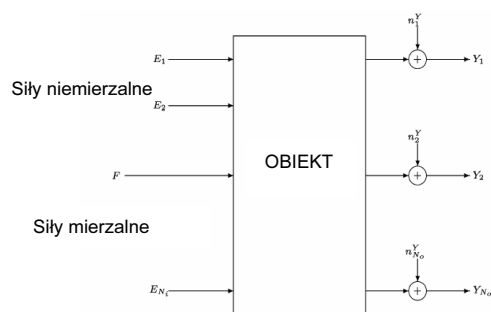
Prof. dr hab. inż. Tadeusz UHL

Jest kierownikiem Katedry Robotyki i Mechatroniki Akademii Górniczo-Hutniczej w Krakowie. W swoich pracach zajmuje się zagadnieniami dynamiki konstrukcji, a zwłaszcza analizą modalną. Jego zainteresowania obejmują także układy aktywnej redukcji drgań, układy sterowania i szeroko pojętą mechatronikę. Jest autorem 15 książek i kilkuset artykułów dotyczących wspomnianych zagadnień.



e-mail: tuhl@agh.edu.pl

Dlatego też w tej metodzie odpowiedź układu jest rozpatrywana jako złożenie dwóch komponentów: deterministycznego wymuszanego przez siły mierzalne oraz stochastycznego wymuszanego przez siły niemierzalne (rys. 1).



Rys. 1. Schemat obiektu z przyłożonymi siłami mierzalnymi i niemierzalnymi

W celu wyznaczenia odpowiedzi takiego układu równania w postaci dyskretnej mogą zostać wykorzystane:

$$\begin{aligned} z_k X_k &= AX_k + BF_k + W_k \\ Y_k &= CX_k + DF_k + V_k \end{aligned} \quad (1)$$

gdzie:

X_k, Y_k, F_k – wektor stanu, wejścia i wyjścia,
 A, B, C, D – macierz stanu, wejścia, wyjścia oraz sterowań,
 W_k, V_k – biały szum (wymuszenie eksploatacyjne).

Dla równania (1) relacja wejście – wyjście może zostać napisana w następującej postaci:

$$Y_k = [C(Iz_k - A)^{-1}B + D]F_k + C(Iz_k - A)^{-1}W_k + V_k \quad (2)$$

Pierwszy wyraz równania (2) opisuje wpływ deterministycznego wymuszenia na odpowiedź układu natomiast drugi – wpływ stochastycznego wymuszenia. W rezultacie zarówno deterministyczna jak i stochastyczna część zawiera informacje o dynamice systemu (wyrażenie $(Iz_k - A)$). Na tej podstawie sformułowane zostało kilka metod identyfikacji w oparciu o metodę OMAX [3, 4, 5]. W celu wyznaczenia parametrów modalnych w metodzie OMAX następujące podstawowe równanie może być wykorzystane [4]:

$$\left[H^m(\omega_k) \quad S_{yy}^+(\omega_k) \right] = \sum_{r=1}^m \left(\frac{\varphi_r Q_r^T}{1 - \lambda_r z_k} + \frac{\varphi_r^* Q_r^{*T}}{1 - \lambda_r^* z_k} \right) \quad (3)$$

Jeżeli siły mierzalne (deterministyczna część metody OMAX)

oraz całkowita odpowiedź układu są znane równanie (2) można przekształcić do następującej postaci:

$$Y_{o,b}(\omega_k) = \frac{B_{oi}(z_k)}{A(z_k)} F_b(\omega_k) + \frac{T_{o,b}(z_k)}{A(z_k)} + \frac{C_o(z_k)}{A(z_k)} E_{o,b}(\omega_k) \quad (4)$$

Gdzie $Y_{o,b}$ i F_b są widmami DFT sygnałów wejściowych oraz wyjściowych, $E_{o,b}$ jest nieznanym białym szumem (wymuszeniem eksploatacyjnym), B_{oi} jest licznikiem wielomianu, $A(z_k)$ jest wielomianem wspólnego mianownika, $T_{o,b}$ jest wielomianem procesów przejściowych wyjścia o . Można łatwo zauważyć, że każda część równania (4) zawiera wielomian $A(z_k)$, który opisuje dynamikę systemu, alew praktyce wyznaczone z tego równania bieguny układy (pierwiastki równania charakterystycznego $A(z_k) = 0$ wymuszane są w różny sposób. W celu wyznaczenia parametrów modelu błąd predykcji powinny być minimalizowane, co prowadzi do zastosowania następującej funkcji (podejście CLSF):

$$J_{IO}^{CLSF}(\Theta) = \sum_{o=1}^{N_o} \sum_{b=1}^{N_b} \sum_{k=1}^{N_f} |E_{o,b}(\omega_k)|^2 \quad (5)$$

gdzie:

$$E_{o,b}(\omega_k) = \frac{B_{oi}(z_k)F_b(\omega_k) - A(z_k)Y_{o,b}(\omega_k) - T_{o,b}(z_k)}{C_o(z_k)}$$

W trakcie estymacji parametrów modalnych stabilność numeryczna powinna być bardzo dokładnie sprawdzana (problem z miejscami zerowymi wielomianu $C_o(z_k)$) [2, 3]. Dla systemów zmiennych w czasie równanie (4) można przekształcić do następującej postaci:

$$Y_{o,b}(\omega_k, i) = \frac{B_{oi}(z_k, i)}{A(z_k, i)} F_b(\omega_k, i) + \frac{T_{o,b}(z_k, i)}{A(z_k, i)} + \frac{C_o(z_k, i)}{A(z_k, i)} E_{o,b}(\omega_k, i) \quad (6)$$

gdzie: i – dyskretny indeks czasu.

W celu identyfikacji systemu z równia (6) można zastosować metodę rekurencyjną [1] i na tej podstawie wyznaczyć częstotliwości drgań własnych oraz współczynniki tłumienia modalnego obiektu.

3. Opis modeli NARX [10]


Najbardziej podstawowymi strukturami modeli typu „czarna skrzynka” są modele neuronowe wejścia – wyjścia. Zalecane jest, aby przed rozpoczęciem procesu modelowania obiektów posiadać wiedzę a priori na temat ich struktury oraz nieliniowości. Sieć neuronowa jest zbiorem parametrów zwanych wagami oraz bias. Do tej pory zdefiniowano wiele rodzajów struktur sieci neuronowych [6]. Najczęściej wykorzystywaną architekturą sieci neuronowych jest struktura oparta o wielowarstwowy perceptron (MLP – z ang. multi-layer perceptron). Przykład sieci złożonej z dwóch warstw MLP przedstawia rysunek 2.

W ogólnym przypadku architektura sieci neuronowej może być opisana następującym równaniem [7]:

$$\hat{y}(t) = g[\varphi, \theta] = F_i \left[\sum_{j=1}^{nH} W_{i,j} f_j \left(\sum_{l=1}^{nI} w_{j,l} \varphi_l + w_{j,0} \right) + W_{i,0} \right] \quad (7)$$

Predyktor $\hat{y}(t) = g[\varphi, \theta]$ zawiera w sobie poprzednie wyjścia i /lub poprzednie wejścia oraz przewidywane wyjście $\hat{y}(t)$ gdzie θ oznacza wektor parametrów, który zawiera wszystkie dobrane parametry sieci. Zazwyczaj wykorzystuje się sigmoidalne/tangens hiperboliczne funkcje aktywacyjne w warstwie ukrytej sieci,

w warstwie wyjściowej wykorzystuje się natomiast funkcje liniowe. W trakcie badań rozważono sieć opisaną równaniem (7).



Rys. 2. Struktura dwuwarstwowej sieci MLP

Wagi sieci (θ , w oraz W) zostały dobrane na podstawie procesu treningu sieci z wykorzystaniem zestawu danych wejściowych i wyjściowych zebranych w zbiór uczący. Jako kryterium uczące przyjęto najmniejszy błąd średniokwadratowy pomiędzy zadaniem a przewidzianym wyjściem systemu. Błąd predykcji opisany jest następującym równaniem:

$$BP = \frac{1}{2N} \sum_{r=1}^N \left[y(t) - \hat{y}(t|\theta) \right]^T \left[y(t) - \hat{y}(t|\theta) \right] \quad (8)$$

Wagi sieci zostały ustalone na podstawie algorytmu uczącego. Jednym z podstawowych algorytmów uczących jest algorytm oparty na wstecznej propagacji. Szczegółowy opis tego algorytmu można znaleźć np. w [6].

Wielowarstwowy perceptron może być stosowany do identyfikacji lub modelowania nieliniowych systemów dynamicznych [7]. Struktura, która została wybrana do zaprezentowania w artykule jest znana jako nieliniowy ARX (NARX). Dla takiej struktury można zdefiniować wektor regresji (9) oraz predyktor (10) jako:

$$\varphi(t) = [y(t-1) \dots y(t-n_a) u(t-n_k) \dots u(t-n_b - n_k + 1)]^T \quad (9)$$

$$\hat{y}(t|\theta) = \hat{y}(t-1, \theta) = g(\varphi(t), \theta) \quad (10)$$


Po poprawnie przeprowadzonym procesie uczenia sieć neuronowa jest zdolna zamodelować rozpatrywany system.

4. Stanowisko laboratoryjne

Stanowisko laboratoryjne (rys. 3) zostało zaprojektowane i wykonane w KRiM AGH. Stanowisko wykorzystywane jest głównie do badania niesprawności maszyn wirnikowych. Ponadto wykorzystywane jest ono w badaniach dotyczących operacyjnej analizy modalnej, diagnostyki opartej na modelach NARX oraz służy również do testowania układów automatycznego wyważania.

Układ łożyska/wirnik jest zamontowany na ciężkiej płycie stalowej. Wirnik jest napędzany silnikiem prądu przemiennego, który umożliwia osiągnięcie prędkości obrotowej wałka do 3000 [obr/min]. Silnik zasilany jest poprzez falownik, który umożliwia sterowanie prędkością obrotową oraz szybkością rozbiegu i wybiegu maszyny. Jeden ze stojaków łożyskowy ma możliwość wprowadzenia regulowanego rozosowania układu. Na wirniku można osadzić do czterech tarcz, w których można wprowadzać

niewyważenie, zarówno statyczne, jak i dynamiczne. Dodatkowo na stanowisku zamontowany jest drugi silnik asynchroniczny prądu przemiennego połączony z grzejnikiem elektrycznym. Układ ten umożliwia trójstopniową zmianę obciążenia. Zmiana obciążenia wykorzystywana jest do symulacji momentu synchronizacji, który może zostać wykorzystany jako zewnętrzne wymuszenie w metodzie OMAX.



Rys. 3. Stanowisko laboratoryjne zaprojektowane w KRiM AGH

Uzupełnieniem części mechanicznej jest specjalizowany układ pomiarowy oparty na komponentach firmy National Instruments. Istnieje również możliwość wzbudzenia drgań stanowiska za pomocą zewnętrznego wymuszenia (wzbudnika elektrodynamicznego lub młotka modalnego), co umożliwia testowanie eksperymentalnej analizy modalnej oraz metody OMAX.

5. Wyniki badań

W trakcie badań prowadzonych nad zastosowaniem analizy modalnej oraz modeli NARX do diagnostyki maszyn wirnikowych skupiono się głównie na wykrywaniu uszkodzeń w postaci luzów posadowienia łożysk. Dodatkowo przebadano również możliwość zastosowania modeli NARX do detekcji niewyważenia oraz nieosiowości maszyn wirnikowych.

5.1. Algorytm oparty na metodzie OMAX

W celu przetestowania możliwości zastosowania metody OMAX do diagnostyki maszyn wirnikowych przeprowadzono serię pomiarów na stanowisku laboratoryjnym. W trakcie pomiarów przeprowadzono symulację uszkodzeń łożysk polegającą na wprowadzeniu luzów posadowienia ich obudów od strony czynnej i biernej. Pomiary wykonano z wykorzystaniem akcelerometrów piezoelektrycznych umieszczonych na łożyskach. Jako zewnętrzne mierzalne wymuszenie zastosowano zmianę obciążenia układu (symulacja momentu synchronizacji turbogeneratora z siecią). Na podstawie pomiarów wyznaczono parametry modalne układu. Analizy przeprowadzono dla trzech stanów dynamicznych obiektu:

- obiekt sprawny,
- obiekt z luzem posadowienia łożyska po stronie czynnej,
- obiekt z luzem posadowienia łożyska po stronie biernej.

Wyniki przeprowadzonych analiz dla trzech różnych stanów dynamicznych stanowiska przedstawiono w tabelach 1, 2 oraz 3.

Tab. 1. Wyznaczone bieguny układu sprawnego

Lp.	Częstotliwość własna [Hz]	Tłumienie modalne [%]
1	22.24	6.24
2	39.93	0.02
3	57.77	3.61
4	73.96	4.79
5	79.91	0.07
6	144.23	0.73
7	144.07	0.71
8	147.52	2.03
9	159.89	0.03
10	183.76	0.55

Tab. 2. Wyznaczone bieguny układu z wprowadzonymi luzami posadowienia łożysk od strony czynnej

Lp.	Częstotliwość własna [Hz]	Tłumienie modalne [%]
1	22.89	7.30
2	39.97	0.02
3	39.95	0.01
4	57.52	4.46
5	59.50	1.96
6	73.79	4.24
7	80.05	0.07
8	108.36	2.45
9	143.40	0.74
10	143.68	0.64
11	159.91	0.04
12	185.03	0.81

Tab. 3. Wyznaczone bieguny układu z wprowadzonymi luzami posadowienia łożysk od strony biernej

Lp.	Częstotliwość własna [Hz]	Tłumienie modalne [%]
1	22.92	7.22
2	39.92	0.02
3	57.93	4.22
4	59.91	1.60
5	73.52	4.55
6	79.95	0.01
7	108.37	2.45
8	143.54	0.71
9	143.54	0.74
10	147.47	1.41
11	159.86	0.01
12	185.03	0.82

Przeprowadzone analizy pokazują, że metoda OMAX umożliwia wykrycie uszkodzenia występującego w badanym układzie. Można łatwo zauważyć, że wprowadzona niesprawność układu zmienia zarówno częstotliwości drgań własnych jak i współczynnik tłumienia modalnego układu. Ponadto można zauważyć, że w układzie pojawiają się nowe postacie drgań własnych. Różnice można zauważyć nie tylko pomiędzy stanem poprawnym maszyny i układem z niesprawnością, ale także pomiędzy układami z wprowadzonymi różnymi uszkodzeniami. Występowanie takich różnic można zauważyć nie tylko w przypadku różnych uszkodzeń, ale także w przypadku tego samego typu uszkodzenia różniącego się miejscem wystąpienia (tabela 2 i 3). Dotychczasowe prace prowadzone nad metodą OMAX pokazują, że metoda ta umożliwia nie tylko wykrycie niesprawności układu, ale także miejsce jego wystąpienia. Cecha ta umożliwia szybszą naprawę uszkodzenia, co ma znaczny wpływ na koszty eksploatacji maszyn – daje możliwość skrócenia czasu remontu.

5.2. Algorytm oparty na modelu NARX

W trakcie badań nad wykorzystaniem modeli NARX do diagnostyki wykorzystano do analizy sygnałów jeden z przyborników narzędziowych Matlab – Neural Network Based System Identification [11]. Zmierzone na obiekcie dane zostały podzielone na osobne zbiory, z których każdy zawierał 1000 próbek. Takie zbiory zostały przygotowane dla każdego z mierzonych stanów: sprawnego, rozosiowienia, niewyważenia oraz dwóch rodzajów luzów posadowienia łożysk (dla strony czynnej – DE oraz biernej – NDE). Jako wejście do sieci neuronowej wykorzystano sygnał znacznika fazy. W trakcie badań przeanalizowano kilka rodzajów sieci neuronowych różniących się ilością i typem neuronów. Analizę rozpoczęto dla sieci z 10 wejściami i wyjściami oraz 10 neuronami w warstwie ukrytej. Wszystkie neurony w warstwie ukrytej posiadają funkcję aktywacji typu tangens hiperboliczny, pojedynczy neuron w warstwie wyjściowej ma liniową funkcję aktywacji. Po przeprowadzonym procesie optymalizacji ostatecznie przyjęta struktura sieci składa się z 3 wejść i wyjść oraz zawiera 5 neuronów w warstwie ukrytej. Po przeprowadzonym procesie optymalizacji przystąpiono do uczenia trzech sieci dla trzech

różnych stanów obiektu – sprawnego oraz dwóch typów luzów posadowienia łożysk. Te sieci zostały następnie wykorzystane jako sieci referencyjne. Celem prowadzonych badań było sprawdzenie czy istnieje możliwość sklasyfikowania stanu monitorowanego obiektu na podstawie danych przekazywanych do sieci neuronowej. W tym celu przygotowano trzy zbiory testowe dla danych z obiektu sprawnego oraz z luzami łożyskowymi i wprowadzono je kolejno do każdej z sieci referencyjnych. Wyniki tych analiz przedstawiono w tabeli 4.

Tab. 4. Błędy predykcji referencyjnej sieci neuronowej dla trzech różnych pakietów danych testowych

Sieć referencyjna	Dane z obiektu sprawnego	Dane z obiektu z luznym łożyskiem DE	Dane z obiektu z luznym łożyskiem NDE
Dla obiektu sprawnego	1.32	3.52	1.77
Dla obiektu z luznym łożyskiem DE	5.12	2.29	2.87
Dla obiektu z luznym łożyskiem NDE	1.75	3.05	1.5

Jak można łatwo zauważyć istnieją różnice pomiędzy wynikami uzyskanymi na podstawie danych z takiego stanu obiektu, dla którego sieć była uczona i danych z obiektu w innym stanie. Umożliwia to wykrycie uszkodzenia i jego ocenę – im większa wartość błędu predykcji tym układ znajduje się w gorszym stanie. Problem, który można tutaj zauważyć występuje z danymi z obiektu z luznym łożyskiem NDE. Różnica w błędzie predykcji dla sieci nauczonej dla danych z obiektu sprawnego wskazują, że luz wprowadzony do układu był niewielki, przez co istnieje możliwość jego niewykrycia przez sieć. Problem pojawia się również dla sieci uczoney dla danych z obiektu z luznym łożyskiem DE. W przypadku wprowadzenia danych z obiektu z luznym łożyskiem NDE sieć osiąga podobny błąd predykcji jak dla danych uczących. Może to prowadzić to błędnej interpretacji wyników analiz.

Po przeprowadzonych testach zdecydowano się wykorzystać referencyjną sieć neuronową dla danych z obiektu sprawnego do sprawdzenia czy istnieje możliwość wykrycia za jej pomocą niewyważenia i nieosiowości występujących w badanym obiekcie. Wyniki tych analiz przedstawiono w tabeli 5.

Tab. 5. Błędy predykcji referencyjnej sieci neuronowej (dla obiektu sprawnego) dla trzech różnych pakietów danych testowych

Typ danych	Wartość błędu predykcji
Dane z obiektu sprawnego	1.44
Dane z obiektu z nieosiowością	7.86
Dane z obiektu z niewyważeniem	8200

Wyniki pokazują, że również w przypadku nieosiowości i niewyważenia można zastosować model NARX do ich wykrycia. Bardzo duża wartość błędu predykcji dla niewyważonego układu ma związek ze zmianą charakteru sygnału drganiowego (w sygnale pochodzącym z obiektu wyważonego jest wiele równorzędnych składowych a charakterze losowym, w sygnale pochodzącym z układu niewyważonego dominuje jedna składowa harmoniczna związana z prędkością obrotową wału).

6. Wnioski końcowe

Przeprowadzone badania pokazały, że zarówno metoda OMAX jak i modele NARX mogą być wykorzystywane w diagnostyce maszyn wirnikowych. Wykorzystanie tych metod daje możliwość monitorowania stanu maszyn w trybie on-line. W takim wypadku jako wymuszenie w metodzie OMAX można zastosować np. moment zmiany obciążenia lub w przypadku układów turbina – generator moment synchronizacji z siecią energetyczną.

W proponowanym w artykule podejściu diagnostycznym z wykorzystaniem modelu NARX dla każdego typu uszkodzenia należy stworzyć osobną sieć neuronową. Następnie, kiedy zostaną zebrane nowe dane należy dla nich obliczyć błędy predykcji. Powoduje to spore zapotrzebowanie na moc obliczeniową. Prowadzone badania wykazały jednak, że współczesne komputery mogą bez problemu poradzić sobie z taką ilością danych w trybie on-line – analizy prowadzone były na gigahercowym procesorze i nie pojawiały się żadne problemy.

Niewątpliwą zaletą modeli NARX jest możliwość łatwej klasyfikacji rodzaju uszkodzenia. Dodatkowo baza systemu monitorującego wykorzystującego takie podejście może być w łatwa sposób uzupełniana o nowe typy uszkodzeń – jeżeli dany typ uszkodzenia nie daje się przypisać do żadnej grupy diagnosta powinien przeprowadzić dokładną analizę systemu, sklasyfikować uszkodzenie (nadać mu nazwę), a następnie stworzyć sieć neuronową umożliwiającą detekcję uszkodzenia tego typu w przyszłości.

Kolejną zaletą modeli NARX jest możliwość wykorzystania ich do planowania remontów. Wartość błędu predykcji wzrasta wraz ze wzrostem poziomu uszkodzenia, co daje możliwość oszacowania dopuszczalnego czasu pracy danego urządzenia.

Wyniki prowadzonych prac wskazują na celowość ich dalszego kontynuowania. W kolejnych etapach prac zostanie podjęta próba zastosowania metody OMAX dla nieliniowości. W przypadku modeli NARX planowane jest wykorzystanie sieci neuronowych, do których wprowadzane będą dane ze wszystkich kanałów drganiowych, a nie tylko z jednego wybranego na podstawie subiektywnej oceny operatora systemu diagnostycznego.

Proponowane podejście do diagnostyki urządzeń znacznie zmniejsza koszt ich eksploatacji – daje możliwość wykonania eksperymentu diagnostycznego bez konieczności zatrzymywania obiektu (w przypadku metody OMAX) oraz umożliwia planowanie remontów na podstawie rzeczywistego stanu obiektu (monitorowanie stanu maszyny on-line z wykorzystaniem modeli NARX).

7. Literatura

- [1] Uhl T., Bogacz M.: Real time modal analysis and its application for damage detection, Proc. of ISMA2004, str.1066-1076, Leuven, 2004.
- [2] Pintelon R., Schoukens J.: System Identification; A frequency domain approach, IEEE Press, 2001.
- [3] Cauberghe B., Guillaume P., Verboven P., Parloo E.: Modal Analysis in presence of unmeasured forces and transient effects. JSV, vol. 265 str. 609-625, 2003.
- [4] Cauberghe B.: Applied frequency – domain system identification in the field of experimental and operational modal analysis. Praca doktorska, VUB, Brussel, 2004.
- [5] Iwaniec J., Uhl T.: Application of the nonlinear LSCF method to the estimation of modal model parameters, Machine Dynamic Problems, vol. 27, nr.2, str. 37-54, 2003.
- [6] Korbicz, J., Obuchowicz, A., Uciński, D.: Sztuczne sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa, 1994.
- [7] Norgaard M., Ravn O., Poulsen N.K., Hansen L.K.: Neural network for modeling and control of dynamic systems. Springer-Verlag, Londyn, 2000.
- [8] Bednarz J., Uhl T.: Metoda OMAX w identyfikacji układów mechanicznych. Wybrane zagadnienia analizy modalnej konstrukcji mechanicznych (red. Uhl T.), str. 15-20, Wydawnictwo ITE, Kraków 2005.
- [9] Uhl T., Barszcz T., Bednarz.: Model Based SHM – Rotating Machinery Application. Trans Tech Publications, Proceedings of the 6th Conference on Damage Assessment of Structures, str. 459-466, Gdańsk, 2005.
- [10] Barszcz T., Uhl T., Bednarz J.: Nonlinear System Identification in Diagnostics of Rotating Machinery., 7th IFToMM-Conference on Rotor Dynamics, Vienna, Austria, 25-28 September 2006, w druku.
- [11] Norgaard M: Neural Network Based System Identification Toolbox, Tech. Report. 00-E-891, Department of Automation, Technical University of Denmark, 2000.