

XI OGÓLNOPOLSKA KONFERENCJA TEORII MASZYN
I MECHANIZMÓW11th POLISH CONFERENCE ON THE THEORY OF MACHINES
AND MECHANISMS

27—30. 04. 1987 ZAKOPANE

Jan KAZMIERCZAK

Instytut Mechaniki i Podstaw Konstrukcji Maszyn
Politechnika ŚląskaMODELOWANIE WIBROAKUSTYCZNEGO SYGNAŁU DIAGNOSTYCZNEGO
DLA POTRZEB PROGNOZOWANIA

Streszczenie: W referacie przedstawiono problem opisu szczególnych procesów losowych, jakimi są sygnały wibroakustyczne związane z działaniem maszyn, przy zastosowaniu modeli liniowych typu "mieszany proces autoregresji i ruchomej średniej" (ARMA). Ze względu na występowanie w sygnałach diagnostycznych składowych systematycznych (trendów) zaproponowano wykorzystanie dla opisu takich sygnałów modeli zmodyfikowanych typu ARIMA, co pozwala na analizowanie również procesów losowych niestacjonarnych. Celem zastosowanie omawianego sposobu postępowania jest prognozowanie elementów szeregów czasowych, reprezentujących przebiegi w czasie ocen sygnałów diagnostycznych, co z kolei stanowi punkt wyjścia dla wnioskowania prognostycznego o stanie obiektu badań. W referacie zawarto krótki opis algorytmu proponowanej metody, ponadto omówiono pewne szczególne aspekty prognozowania w diagnostyce środków technicznych, wreszcie pokazano przykłady wyników zastosowania dyskutowanej metody dla wybranych sygnałów diagnostycznych.

1. Wprowadzenie

Mówiąc o badaniach środków technicznych nie sposób pominąć omówienia celu prowadzenia takich badań. Cel ten może być dwójaki i jest w pewnym stopniu przypisany do fazy procesu zaspokajania potrzeb, w której jest prowadzony konkretny eksperyment. I tak zarówno w badaniach symulacyjnych, prowadzonych na etapie konstruowania środka technicznego oraz w badaniach prototypów głównym celem jest weryfikacja konstrukcji ze względu na określone kryteria. Cel taki występuje również w obszarze badań eksploatacyjnych maszyn, jednakże podstawowym zadaniem takich badań ze względu na po-

trzeby użytkowników maszyn jest identyfikacja zespołu cech badanego obiektu, pozwalającego określić jego stan techniczny.

Problem stanu maszyny w procesie jej użytkowania ma podstawowe znaczenie z wielu względów, dlatego też intensywnie rozwijane są środki i sposoby pozyskiwania informacji o działających maszynach. Powstała nawet odrębna gałąź wiedzy, zajmująca się problemami badania maszyn i wnioskowania o ich stanie na podstawie wyników eksperymentów - nazywana diagnostyką maszyn (lub diagnostyką stanu maszyn).

Punktem wyjścia w diagnostyce maszyn jest założenie, że istnieje pewna relacja (lub zbiór relacji) pomiędzy działaniem maszyny a sygnałem diagnostycznym.

Jako sygnał diagnostyczny może być traktowane dowolne oddziaływanie fizyczne pomiędzy maszyną i otoczeniem, które da się zmierzyć bezpośrednio lub oszacować w sposób co najmniej jakościowy, a w miarę możliwości - również ilościowy. Możemy powiedzieć, że stan środka technicznego (maszyny) jest reprezentowany przez zbiór własności, natomiast sygnał diagnostyczny jest podzbiorem w zbiorze właściwości maszyny.

W opracowaniu tym pokazano możliwość zastosowania do opisu losowych procesów wibroakustycznych, związanych z działaniem maszyn i wykorzystanych w tzw. diagnostyce wibroakustycznej, klasy modeli liniowych, oznaczanych potocznie symbolem ARIMA (ang. autoregressive integrated moving average - scałkowany mieszany proces autoregresji i "ruchomej średniej").

W modelu takim [1] rozpatrujemy pewien układ dynamiczny, wzbudzany losowym procesem "białego szumu" (A_T). Odpowiedzią układu jest proces losowy (Y_T). Dla potrzeb analizy numerycznej przyjmuje się zazwyczaj, że procesy (A_T) i (Y_T) są reprezentowane przez realizacje, dane w postaci dyskretnej (w postaci tzw. szeregów czasowych, czyli uporządkowanych w czasie ciągów dyskretnych wartości zmiennych losowych " a_t " i " y_t "). Poprzez odpowiedni dobór funkcji przejścia rozpatrywanego układu dynamicznego możemy wpływać na postać losowego procesu wyjściowego (Y_T).

W szczególności proces (Y_T) może być traktowany jako przybliżenie (model) losowego sygnału diagnostycznego, stacjonarnego lub niestacjonarnego.

W modelu ARIMA element y_t szeregu czasowego Y_T , reprezentującego proces (Y_T), jest ważoną sumą skończonej liczby "p" elementów szeregu Y_T poprzednich w czasie względem chwili "t" oraz skończonej liczby "q" poprzednich elementów szeregu czasowego A_T , reprezentującego realizację procesu "białego szumu" (A_T), co opisuje zależność:

$$\tilde{y}_t = \varphi_1 \tilde{y}_{t-1} + \dots + \varphi_p \tilde{y}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (1)$$

lub w uproszczonym zapisie

$$\tilde{y}_t = \varphi^{-1}(B) \Theta(B) a_t \quad (2)$$

gdzie:

$$\tilde{y}_t = y_t - \bar{y} \quad , \quad \bar{y} = E[y_T]$$

$\varphi(\varphi_1, \varphi_2, \dots, \varphi_p)$ - zbiór wag (współczynników) "autoregresji"

$\theta(\theta_1, \theta_2, \dots, \theta_q)$ - zbiór współczynników "ruchomej średniej"

B - operator przesunięcia wstecz [1].

Ponieważ modele typu ARIMA są generowane dla dyskretnych reprezentacji procesów losowych, punktem wyjścia dla [] analizy sygnału diagnostycznego z zastosowaniem omawianej metody jest dyskretyzacja tego sygnału.

Jeżeli badany sygnał ma charakter niestacjonarny, to kolejnym krokiem w jego analizie jest wydzielenie z szeregu czasowego, reprezentującego ten sygnał, składowej systematycznej. W metodzie IARIMA operacja taka polega na przekształceniu wyjściowego szeregu czasowego Y_T na szereg Z_T z wykorzystaniem tzw. operatora różnicowego [1], definiowanego następująco:

$$z_t = \nabla y_t = y_t - y_{t-1} = (1-B)y_t \quad (3)$$

$$z_t = \nabla^d y_t = \nabla^{d-1} y_t - \nabla^{d-1} y_{t-1} = (1-B)^d y_t \quad (4)$$

Zastosowany w analizie danego szeregu czasowego stopień "d" operatora różnicowego stanowi wspólnie ze zdefiniowanymi powyżej wielkościami "p" (parametr autoregresji) i "q" (parametr "ruchomej średniej") zbiór parametrów modelu ARIMA. W kodowym identyfikatorze modelu parametry te są zapisywane wg notacji ARIMA (p, d, q).

Ekstrakcja składowej systematycznej ($d \neq 0$) wprowadza do symbolicznego oznaczenia modelu literą I (= integrated). Model procesu/sygnału stacjonarnego, a więc nie zawierającego składowej systematycznej, nie obejmuje tego elementu i jest opisywany symbolem ARMA (p, q).

Ponieważ model procesu losowego stanowi pewną formalizację mechanizmów, generujących ten proces, to ekstrapolacja estymowanych wartości ocen tego procesu (elementów szeregu czasowego) stanowi narzędzie dla wnioskowania typu prognostycznego. Dotyczy to w szczególności procesów losowych, generowanych przez zjawiska zachodzące z upływem czasu.

Analizie prognostycznej z zastosowaniem przedstawionej powyżej metody może być poddany również szczególny proces losowy, jakim jest sygnał diagnostyczny, odwzorowujący działanie środka technicznego (maszyny).

Możliwość rozwiązywania zadań prognostycznych dla potrzeb diagnostyki stanu maszyn była podstawową przyczyną podjęcia prób wykorzystania modeli ARIMA w analizie sygnałów diagnostycznych.

Należy tu podkreślić fakt, że metoda ARIMA zawiera oprócz możliwości budowy modeli prognostycznych także inne elementy, które mogą znaleźć zastosowanie w obszarze diagnostyki maszyn. W szczególności metoda umożli-

liniowa modelowanie funkcji przenoszenia ([1], [2]), układów, wzbudzanych procesem losowym, gdy odpowiedzia układu jest również proces losowy. Stanowi to może jedną z dróg wyeliminowania z zadań diagnostycznych założenia o "czarnej skrzynce", przekształcającej proces zachodzący w maszynie na proces, traktowany w badaniach jako nośnik informacji (sygnał).

Możliwość przewidywania przyszłych zdarzeń w obserwowanej maszynie jest szczególnie ważna w przypadku nadzoru diagnostycznego maszyn lub układów maszynowych, stanowiących niewrażliwe punkty linii technologicznych i zakładów przemysłowych. Element wnioskowania prognostycznego w analizie informacji diagnostycznej w istotny sposób zwiększa możliwość zapobiegania awariom nadzorowanych obiektów.

Niniejszy referat pomyślany został jako szkicowy opis problemów aplikacji wybranej metody w określonym obszarze prac badawczych. W rozdziale 2 pokazano w skrócie algorytm budowy modelu prognostycznego ARIMA, natomiast w rozdziale 3 omówiono pewne szczególne aspekty stosowania modeli prognostycznych w analizie danych diagnostycznych. Z kolei w rozdziale 4 przedstawiono wyniki zastosowania omawianej metody dla analizy wybranych sygnałów diagnostycznych.

2. Krótki opis metody modeli ARIMA procesów losowych

Tek postępowania, zmierzający do utworzenia modelu liniowego typu ARIMA dla badanego szeregu czasowego, stanowiącego dyskretną reprezentację realizacji procesu losowego, rozdzielić można na trzy podstawowe etapy.

W poszczególnych etapach przeprowadzane są następujące czynności:

- 1) identyfikacja modelu - określenie wartości parametrów modelu, tzn. wartości "p" (parametr autoregresji), "q" (parametr ruchomej średniej) oraz "d" (stopień operatora różnicowego);
- 2) estymacja współczynników - wyznaczenie wartości wag, tzn. wartości $\varphi_i, i=1, \dots, p$ oraz $\theta_j, j=1, \dots, q$;
- 3) sprawdzenie adekwatności modelu względem zadanego szeregu czasowego, tzn. kontrola zgodności wartości modelowanych z wartościami szeregu, szczególnie poza odcinkiem "uciecznym", czyli podzbiorem elementów szeregu czasowego wykorzystanym w dwóch pierwszych krokach algorytmu.

Algorytmy obliczeniowe, zastosowane dla realizacji poszczególnych kroków metody w badaniach, omawianych w tym referacie, są szczegółowo przedstawione w pracach [1]-[6].

Dla identyfikacji modelu wykorzystano techniki analizy funkcji autokorelacyjnych, zaproponowaną przez Boxa i Jenkinsa [1]. Uzyskane wyniki są opublikowane w pracy [3]. Wartości współczynników modeli były estymowane metodą najmniejszych kwadratów z zastosowaniem algorytmu Marquardta [4].

Przeprowadzono również próby wykorzystania dla przeprowadzenia identyfikacji oraz estymacji modeli ARIMA szeregów czasowych cech sygnałów wibroakustycznych "efektywnej metody", zaproponowanej przez Cadzowa [5].

Sprawdzenie diagnostyczne utworzonych modeli było wykonywane wg zaleceń Boxa i Jenkinsa [1], tzn. na drodze analizy autokorelacji reszt prognoz z wykorzystaniem zmodyfikowanej statystyki "Chi-kwadrat" [6].

Dysponując modelem ARIMA szeregu czasowego, utworzonym w podany powyżej sposób, możemy wykorzystać ten model do obliczenia "przyszłych" względem zadanej chwili (chwili aktualnej) wartości elementów szeregu czasowego. Innymi słowy, model umożliwi prognozowanie elementów szeregu czasowego.

Jeżeli zależność (1), opisująca model ARIMA, zastosujemy dla chwili $T = t + l_a$, gdzie: t - chwila bieżąca oraz l_a - zadane wyprzedzenie czasowe prognozy, oraz podstawimy:

$\tilde{z}_{t+1}, \tilde{z}_{t+2}, \dots, \tilde{z}_{t+l_a-1}$ - obliczone w kolejnych krokach iteracji oraz

$a_{t+1}, a_{t+2}, \dots, a_{t+l_a-1} = 0$,

możemy obliczyć prognozę elementu \tilde{z}_{t+l_a} szeregu Z_T .

Próbę wykorzystania właśnie modelu typu ARIMA dla opisu sygnałów wibroakustycznych, wykorzystywanych jako nośniki informacji o stanie obiektu badań w diagnostyce, podjęto ze względu na następujące cechy tej metody:

- duża zdolność dopasowania takich modeli do danych eksperymentalnych,
- możliwość modelowania również niestacjonarnych procesów losowych (sygnałów),
- istnienie bogatego zbioru efektywnych algorytmów obliczeniowych, umożliwiających generowanie modeli omawianego typu.

3. Wnioskowanie prognostyczne a specyficzne cechy diagnostyki stanu maszyn

W badaniach, zmierzających do określenia możliwości stosowania dyskretnych modeli liniowych dla prognozowania procesów, obserwowanych w diagnostyce stanu maszyn, napotkano na szereg trudności przy próbach bezpośredniego przenoszenia metod prognostycznych, opracowanych dla zagadnień z odmiennych dziedzin, na teren diagnostyki.

Pojawiła się tu potrzeba modyfikacji metod wnioskowania prognostycznego w kierunku, który uwzględniałby specyfikę sygnałów diagnostycznych, związanych z działaniem maszyn. Koncepcja takiej modyfikacji obejmuje trzy grupy zagadnień.

Pierwszą z nich wiąże się z uwarunkowaniem zjawisk, obserwowanych w różnych realizacjach sygnałów diagnostycznych, pewnymi wspólnymi cechami w klasach obiektów badań (np. wspólna konstrukcja lub podobny proces technologiczny, realizowany w różnych obiektach). W toku dotychczasowych badań [7] potwierdzono wstępnie możliwość wykorzystania w analizie prognostycznej sygnałów diagnostycznych takich modeli, które zostały zbudowane dla "uczających" realizacji sygnałów diagnostycznych, odwzorowujących procesy podobne w poprzednio wskazanym sensie. Możliwość taka oznacza, że prognozowanie w zadaniach diagnostycznych nie musi być poprzedzone dla każdego analizowanego zbioru danych (szeregu czasowego) etapem budowy modelu. Wynika z tego również, że obserwowany w badaniach diagnostycznych danego obiektu przedział czasowy nie musi być ograniczony ze względu na konieczność przeznaczenia pewnego podzbioru elementów szeregu czasowego na budowę i kontrolę modelu. Innymi słowy, [prognozowanie w obserwowanym procesie mogłoby być prowadzone praktycznie od chwili "0", tzn. od momentu rozpoczęcia obserwacji.

Druga grupa zagadnień, charakterystycznych dla prognozowania w diagnostyce stanu maszyn, wiąże się z trendami, występującymi w procesach/sygnałach diagnostycznych. Zazwyczaj trendy takie odwzorowują złożenie się wpływu pewnych czynników "obiektywnych", związanych z procesami technologicznymi oraz zużyciowymi w badanej maszynie z czynnikami "subiektywnymi", decydującymi niejednokrotnie o przebiegu badanych zjawisk. Takimi "subiektywnymi" czynnikami, współkształtującymi procesy zachodzące w maszynach i układach maszynowych są zarówno nadzorujący dany obiekt człowiek-operator, jak i powiązania obiektu z nadrzędną strukturą organizacyjną i techniczną megaukładu, którego elementem jest przedmiot badań diagnostycznych.

Ten obszar problemów jest źródłem podstawowych, utrudnień w stosowaniu formalnych modeli dla opisu działania środków technicznych. W obecnym stanie wiedzy problemy takie są zazwyczaj eliminowane poprzez wybór dla celów badań obiektów o mało złożonych cyklach działania i wymagających minimum czynności obsługowych (np. [8]).

Ponieważ jednak zadania typu prognostycznego powinny być realizowane dla dowolnych obiektów, autor niniejszego opracowania proponuje następujący tok postępowania dla przypadku, gdy formalny model prognostyczny ma być utworzony dla procesu, zawierającego trend nieregularny, w szczególności - losowy.

Punktem wyjścia jest zbiór realizacji badanego sygnału, umożliwiajający określenie "przeciętnej" postaci trendów w tym sygnale. Dla potrzeb prognozowania każda kolejno obserwowana realizacja jest wstępnie przekształcana do postaci sumy "przeciętnego" trendu i składnika losowego, przy czym przedmiotem opisu z zastosowaniem modelu prognostycznego jest drugi z elementów takiej sumy (składowa losowa). Tak więc prognozowane są nie wartości bezwzględne ocen sygnału, lecz ich odchylenia od pewnego wzorca.

Trzecia grupa charakterystycznych własności zadań diagnostycznych, mogących wpływać na metody formułowania prognoz w takich zadaniach, wiąże się z konieczną liczbą wymiarów przestrzeni sygnałów diagnostycznych, w której odwzorowywany jest proces zachodzący w badanym obiekcie. W pracach z zakresu diagnostyki stanu maszyn podejmowany jest dość często problem optymalizacji przestrzeni cech sygnału ze względu na kryterium maksymalnej zdolności odwzorowania zdarzeń w badanej maszynie (np. [9]). Niezmiernie rzadko zdarza się jednak, że wynikiem takiej optymalizacji jest przestrzeń jednowymiarowa. Oznacza to, że również wnioskowanie typu prognostycznego powinno być prowadzone w przestrzeni, która w przypadku ogólnym jest wielowymiarowa.

Stosowane dotychczas w zadaniach diagnostycznych metody prognozowania (np. [8], [10]), umożliwiły w zasadzie rozwiązywanie zadań jednowymiarowych, tzn. prognozowanie wartości jednowymiarowych szeregów czasowych. Ograniczenia takiego nie narzuca metoda ARMA/ARIMA, która wprowadza również modele wielowymiarowych procesów losowych.

Wydaje się jednak, że przy swojej dość dużej złożoności obliczeniowej modele takie nie muszą być stosowane w analizie wielowymiarowych procesów/sygnałów diagnostycznych, przynajmniej w początkowej fazie prac badawczych.

Wynika to z faktu, że - z jednej strony - typowe procesy (np. procesy użytkowe) obserwowane w diagnostyce stanu maszyn zawierają z reguły trendy wolnozmiennie w czasie i zmienność poszczególnych ocen sygnałów diagnostycznych, tworzących zbiór wymiarów przestrzeni sygnałów, może być analizowana kolejno (z zastosowaniem modeli jednowymiarowych). Oznacza to wydłużenie czasu analizy, ale znaczne uproszczenie układu analizującego.

Z drugiej strony - w zadaniach prognostycznych w diagnostyce interesuje badacza zazwyczaj nie tyle przyszłe wartości ocen sygnału, co informacja o tym, kiedy obserwowany obiekt znajdzie się w stanie uznanym wstępnie za kryterialny (np. stan przedawaryjny, zakończenie cyklu technologicznego itp.). Stan kryterialny może tu być określony na szereg sposobów, np. jako stan graniczny wg Cz. Cempla [11].

Zdaniem autora tego opracowania, w większości zadań diagnostycznych pojawia się również potrzeba utworzenia modelu prognozy dla szczególnego, jednowymiarowego procesu losowego, jaki tworzą zmiennie w czasie wartości podobieństwa aktualnego zbioru ocen procesu/sygnału o dowolnej liczbie takich ocen do zbioru wartości takich ocen, odpowiadającego stanowi kryterialnemu (w podanym wyżej sensie).

Podobieństwo elementów przestrzeni sygnałów może być mierzone z zastosowaniem metod, znanych z takich dziedzin jak rozpoznawanie obrazów lub selekcja informacji (np. [12]).

Dla konkretnego przypadku badań decyzja, dotycząca wyboru miary podobieństwa zdarzeń w analizowanym procesie stanowi oddzielny problem badawczy, którego rozwiązanie warunkuje możliwość budowy modelu prognozy "od-

dalenia" aktualnego stanu obiektu od stanu kryterialnego. Przeprowadzone badania wykazują, że miary podobieństwa mogą być stosowane z powodzeniem w analizie informacji diagnostycznej [13].

4. Zastosowanie modeli ARIMA dla prognozowania wybranych sygnałów wibroakustycznych, emitowanych przez działające maszyny

W pierwszym etapie badań, zmierzających do określenia przydatności modeli typu ARIMA dla realizacji zadań prognostycznych w diagnostyce stanu maszyn, podjęto próbę modelowania szeregów czasowych cech sygnału akustycznego, emitowanego przez elektrostalownicze piece łukowe. Badania tego sygnału, traktowanego jako nośnik informacji o zjawiskach, zachodzących w piecu łukowym omówiono szczegółowo (m.in. w [13]).

Przedmiotem analizy były szeregi czasowe zmienności w czasie roztopiania wsadu w piecu łukowym następujących ocen sygnału:

- bezwzględnej wartości szczytowej amplitudy ciśnienia akustycznego,
- współczynnika kurtozy badanego sygnału,
- współczynników kształtu, szczytu i impulsowości amplitudy.

W badaniach dysponowano zbiorem kilkunastu realizacji sygnału, odpowiadających różnym realizacjom tego samego cyklu technologicznego (roztopianie wsadu metalowego), przeprowadzanego na tym samym obiekcie. Przyjęte że mogą one być traktowane jako realizacje tego samego procesu losowego. Uzyskane w tym etapie badań wyniki pokazano bardziej szczegółowo w [7].

Przykładowo dla szeregu wartości współczynnika kurtozy zbudowano model ARIMA (1, 0, 2), o postaci:

$$y_t = 3,57 - 0,893y_{t-1} + 0,426a_{t-1} - 0,030a_{t-2} \quad (5)$$

W tablicy 1 pokazano wybrane wyniki wykorzystania tego modelu, potraktowanego jako zbudowany na uczącym zbiorze danych, dla prognozowania wartości szeregów czasowych, reprezentujących inne realizacje danego procesu.

Uzyskane wyniki stanowią swego rodzaju potwierdzenie tezy, że w sygnałach diagnostycznym można odnaleźć odwzorowanie pewnych ogólnych cech środka technicznego, np. uwarunkowanych jego konstrukcją i w związku z tym wspólnych dla całej klasy obiektów, wytworzonych wg tej samej konstrukcji.

Kolejnym obiektem badań diagnostycznych, dla którego podjęto próbę utworzenia modelu prognostycznego, była grupa sprężarek wirnikowych, eksploatowanych w przemyśle chemicznym [14]. Analizowano szeregi czasowe wartości bezwzględnych przemieszczeń drgań, mierzonych w wybranych punktach na korpusie sprężarki.

Tablica 1

Identyfikator szeregu czasowego	Wyprzedzenie czasowe prognozy "la"	Wartość przeciętna reszt progn.	Wariancja reszt (*100)	Odchylenie standardowe reszt
	[krok czasu]			
T900/3	1	0,01	5,76	0,24
T900/3	30	-0,03	7,85	0,28
T902/3	1	0,01	3,62	0,19
T902/3	30	0,01	4,40	0,21
T904/3	1	0,01	4,45	0,21
T904/3	30	-0,01	8,52	0,29

Istotnym elementem takiego wyboru obiektu badań był fakt, że dysponowano bogatym zbiorem wyników pomiarów. Uporządkowany zbiór wyników, zawierający dodatkowo dane o przebiegu eksploatacji obserwowanych maszyn, obejmował pomiary przemieszczeń drgań w 12 punktach na korpusach dwóch sprężarek śrubowych. Pomiary takie były prowadzone względnie regularnie w okresie ponad 4 lat.

W wyniku badań stwierdzono, że dla opisu zmienności amplitudy przemieszczeń drgań sprężarki w wybranych punktach pomiarowych najlepiej nadają się modele typu ARIMA (p, 1, q). Sygnalizuje to obecność trendu w analizowanych szeregach czasowych, a więc w pewnym sensie potwierdza tezę o istnieniu związków pomiędzy czasową historią obserwowanego sygnału diagnostycznego a "krzywą życia" obiektu badań.

5. Podsumowanie

Przedstawione w tym opracowaniu wyniki badań mają charakter wstępnych prób zastosowania wybranej metody dla prognozowania w zadaniach z zakresu diagnostyki stanu maszyn. Tym niemniej już na tym etapie możliwe jest sformułowanie pewnych wniosków z zastrzeżeniem, że do momentu empirycznego potwierdzenia ich prawdziwości powinny one być traktowane jako hipotezy oraz jako wskazanie kierunku dalszych prac badawczych:

- modele typu ARMA/ARIMA mogą być stosowane jako narzędzie dla formułowania wniosków prognostycznych w obszarze badań diagnostycznych maszyn metodami wibroakustycznymi;
- w pewnych wypadkach możliwe jest wykorzystywanie modeli prognoz, utworzonych dla "uczących" zbiorów danych, do analizy prognostycznej różnych realizacji losowych sygnałów diagnostycznych, warunkowanych wspólną konstrukcją obiektów badanych lub podobnym cyklem operacji technologicznych;

- formułowania wniosków prognostycznych w diagnostyce stanu maszyn wymaga uwzględnienia w metodzie prognozowania specyficznych cech analizowanych zbiorów danych.

Porównując modele prognostyczne, uzyskiwane metoda ARIMA z modelami innych typów (np. models wygładzania wykładniczego [7], [10]) należy stwierdzić, że modele ARIMA dają lepszą dokładność prognozy oraz umożliwiają określenie charakteru trendów w modelowanych procesach losowych. Z drugiej jednak strony modele takie nie mogą być stosowane dla analizy zbiorów danych o małej liczebności. Dlatego też w dalszym rozwoju prac w zakresie prognozowania w diagnostyce stanu maszyn celowe wydaje się wyodrębnienie dwóch kierunków badań:

- a) proste modele prognoz dla krótkich serii danych (np. [8]);
- b) modele, np. typu ARMA/ARIMA, dostosowane do potrzeb i możliwości rozbudowanych systemów nadzoru diagnostycznego maszyn i układów maszynowych, w tym - tzw. "systemów rzeczoznawczych" (ang. expert systems).

LITERATURA

- [1] G.E.P. BOX, G.M. JENKINS: Analiza szeregów czasowych: prognozowanie i sterowanie, PWN, Warszawa 1983.
- [2] J. KAŹMIERCZAK: Identyfikacja funkcji przenoszenia środka technicznego z wykorzystaniem techniki ARIMA, Materiały XII Sympozjonu PKM, Lublin-Kazimierz, październik 1985, s. 163-164.
- [3] J. KAŹMIERCZAK: Metoda wyznaczania stopnia modeli ARIMA dla potrzeb prognozowania procesów wibroakustycznych, Materiały VII Sympozjonu Techniki Wibracyjnej i Wibroakustyki, Kraków, grudzień 1984, s. 206-213.
- [4] D.W. MARGUARDT: An Algorithm for Least Square Estimation of Non-linear Parameters, Journal of Soc. Ind. Appl. Math., 11, 1963, pp. 43-441.
- [5] J.A. CADZOW: ARMA Time Series Modelling: An Effective Method, IEEE Trans. on Aerospace and Electronic Systems, vol. AES-19, No 1, January 1983, pp. 49-58.
- [6] G.E.P. BOX, D.A. PIERCE: Distribution of Residual Autocorrelations in Autoregressive Integrated Moving Average Time Series Models, Journal of ASA, December 1970, vol. 65, No 332, pp. 1509-1526.
- [7] W. BATKO, J. KAŹMIERCZAK: Forecasting in Technical Diagnostics, Materiały VII Szkoły Diagnostyki DIAGNOSTYKA 85, Poznań-Rydzyń, październik 1985, s. 31-42.
- [8] Cz. CEMPEL: Proste metody prognozowania w drganiowej diagnostyce maszyn, Materiały VII Szkoły Diagnostyki DIAGNOSTYKA 85, Poznań-Rydzyń, październik 1985, s. 141-150.
- [9] W. CHOLEWA, A. SOLIPIWKO: Optymalizacja przestrzeni cech w wibroakustycznych badaniach diagnostycznych, Materiały VII Szkoły Diagnostyki DIAGNOSTYKA 85, Poznań-Rydzyń, październik 1985, s. 185-191.

- [10] W. BATKO: Metody syntezy diagnoz produkcyjnych w diagnostyce technicznej, Zeszyty Naukowe AGH, Seria Mechanika Nr 4, Kraków 1984.
- [11] Cz. CEMPEL: Podstawy wibroakustycznej diagnostyki maszyn, WNT, Warszawa 1982.
- [12] W. SOBCZAK, W. MALINA: Metody selekcji i redukcji informacji, WNT, Warszawa 1985.
- [13] J. KAZMIERCZAK: Odwzorowanie działania elektrostalowniczego pieca łukowego w przestrzeni sygnału akustycznego, Archiwum Akustyki, 19, 3, s. 201-218 (1984).
- [14] J. KAZMIERCZAK: Przykład modelu prognostycznego dla wibroakustycznego sygnału diagnostycznego, Materiały Konferencji DIAG 86, Kielce-Sielpia, listopad 1986, s. 171-176.

МОДЕЛИРОВАНИЕ ВИБРОАКУСТИЧЕСКОГО ДИАГНОСТИЧЕСКОГО СИГНАЛА
ДЛЯ НУЖД ПОТРЕБНОСТЕЙ ПРОГНОЗИРОВАНИЯ

Р е з ю м е

В докладе представлена проблема описания стохастических виброакустических сигналов, связанных с работой машин, с использованием линейных моделей типа "смешанный процесс авторегрессии и подвижной средней" (ARMA).

Принимая во внимание, что в диагностических сигналах очень часто выступают систематические составные (тренды), в докладе предлагается использовать для описания таких сигналов модифицированные модели типа ARIMA. Это делает возможным анализировать тоже нестационарные стохастические сигналы.

Главной целью описываемого метода является прогнозирование элементов временных рядов, представляющих собой временной ход диагностических сигналов и - через такие сигналы - прогнозирование технического состояния объекта исследований.

В докладе содержится краткое описание алгоритма метода и некоторые частные аспекты прогнозирования в технической диагностике. Показаны тоже примеры результатов использования метода для выбранных диагностических сигналов.

MODELLING THE VIBROACOUSTIC DIAGNOSTIC SIGNAL FOR FORECASTING

S u m m a r y

The paper reports the method of utilizing linear models of the ARMA type (autoregressive moving-averages) to describe vibroacoustic effects concerned with the functioning of machines and treated as random diagnostic signals. Taking into consideration a common presence of trends in such signals it has been proposed to use for the above mentioned purpose a class of modified models called ARIMA (I - integrated). It enables us to analyse non-stationary random processes/signals as well. The forecasting of elements of time-series representing time-depended features of diagnostic signals is the main goal of the presented method. The forecasts of signal features make it possible to formulate forecasting conclusions about states of investigated machines.

In the paper the algorithm of the method is shortly described. Additionally some aspects of forecasting in technical diagnostics are discussed. Some examples of results of using the method for particular cases of investigations are presented as well as some conclusions concerning the actual state of the investigations.

Recenzant: doc. dr hab. inż. Wojciech Batko

Wpłynęło do redakcji 19.II.1986 r.