

XIII MIĘDZYNARODOWE KOŁOKWIUM

"MODELE W PROJEKTOWANIU I KONSTRUOWANIU MASZYN"

13th INTERNATIONAL CONFERENCE ON

"MODELS IN DESIGNING AND CONSTRUCTION OF MACHINES"

25-28.04.1989 ZAKOPANE

Jan KAZMIERCZAK

Instytut Mechaniki i Podstaw Konstrukcji Maszyn
Politechnika Śląska

MODELOWANIE ZMIAN CECH SYGNAŁÓW DIAGNOSTYCZNYCH W DZIEDZINIE CZASU

Streszczenie. W pracy przedstawiono sposób opisu zadania diagnostycznego z wykorzystaniem sieci relacji wiążących stany procesu diagnozowanego oraz stany procesu traktowanego w badaniach jako sygnał diagnostyczny. Omówiono pobieżnie problemy modelowania relacji w zadaniu diagnostycznym oraz bardziej szczegółowo przedstawiono znaczenie modelowania zmienności w czasie cech sygnału diagnostycznego jako podstawy prognozowania w eksperymencie diagnostycznym. Referat zawiera przykład metody modelowania dyskretnej reprezentacji sygnału (szeregów czasowych) oraz opis algorytmu metody identyfikacji zmian cech sygnału w czasie dla potrzeb diagnostyki maszyn.

1. Wprowadzenie

Szczególną własnością badań diagnostycznych maszyn jest równoległe rozpatrywanie w nich dwóch grup zjawisk. Pierwszą z tych grup tworzą zjawiska zachodzące wewnątrz badanej maszyny. Druga grupa zjawisk obejmuje te oddziaływania pomiędzy maszyną i otoczeniem, które stanowią zewnętrzne efekty zjawisk z pierwszej grupy i są w badaniach diagnostycznych wykorzystywane jako nośniki informacji o działaniu maszyny. Podstawowym problemem diagnostyki maszyn jest określenie charakteru powiązań pomiędzy tymi dwoma grupami zjawisk.

Rozpatrując zmienność omawianych zjawisk w czasie możemy powiedzieć, że przedmiotem diagnozy w dziedzinie czasu eksploatacji jest pewien proces (lub procesy) zachodzący w maszynie. Dla procesu takiego przyjęto tu nazwę **procesu diagnozowanego**. Wykorzystywany w badaniach zbiór oddziaływań maszyny na otoczenie nazywać będziemy

W referacie przedstawiono fragment prac prowadzonych w ramach problemu CPBP 02.03, temat 3.15.

sygnałem diagnostycznym.

Przyjmijmy, że każdy z omawianych procesów rozpatrujemy jako ciąg dwojakiego rodzaju zdarzeń: stanów procesu oraz zmian tych stanów. Związek pomiędzy stanem maszyny i stanem sygnału diagnostycznego możemy wówczas traktować jako relację wiążącą zbiór (przestrzeń) wszystkich możliwych stanów maszyny $\{St\}$ i zbiór (przestrzeń) stanów sygnału diagnostycznego $\{Sy\}$.

Wyróżnijmy dwa podstawowe typy takich relacji. Pierwszy z nich obejmuje relacje $(R1)$ wiążące stany obiektu badań $\{St\}_t \subset \{St\}$ i stany sygnału diagnostycznego $\{Sy\}_t \subset \{Sy\}$. Relacje te możemy interpretować jako podzbiory w iloczynie kartezjańskim przestrzeni $\{St\}$ i $\{Sy\}$:

$$R1 \subset \{St\} \times \{Sy\} \quad (1)$$

Drugi typ relacji występujących w zadaniu diagnostycznym jest ściśle powiązany z dziedziną czasu eksploatacji maszyny. Oznaczmy takie relacje symbolem $R2$.

Jeżeli dla zdefiniowania relacji $R2$ wykorzystamy zbiór (przestrzeń) stanów maszyny $\{St\}$ lub stanów sygnału $\{Sy\}$ oraz zbiór chwil czasu $\{\theta\}$, w którym dodatkowo wybierzemy dwa podzbiory:

$$\{\theta_1\} \subset \{\theta\}, \quad \{\theta_2\} \subset \{\theta\}, \quad \{\theta_1\} \neq \{\theta_2\} \quad (2)$$

to relacje $R2$ możemy opisać jako podzbiory w iloczynach kartezjańskich zbiorów par:

$$R2(St) \subset \{\langle St, \theta_1 \rangle\} \times \{\langle St, \theta_2 \rangle\} \quad (3)$$

lub

$$R2(Sy) \subset \{\langle Sy, \theta_1 \rangle\} \times \{\langle Sy, \theta_2 \rangle\} \quad (4)$$

Relacje typu $R2$ wiążą chwilowe stany tego samego procesu, a więc elementy tylko jednej z przestrzeni stanów rozpatrywanych w zadaniu diagnostycznym. Oznacza to, że badania tych relacji dla potrzeb diagnostyki maszyn nie zastępują, lecz uzupełniają badania relacji $R1$. Równocześnie jednak relacje $R2$ stanowią podstawę do formułowania w obszarze diagnostyki maszyn jakościowo nowych problemów badawczych.

2. Modele relacji w zadaniu diagnostycznym

W każdym eksperymencie diagnostycznym liczba obserwowanych cech stanu maszyny oraz identyfikowanych cech sygnału diagnostycznego jest z różnych powodów ograniczana. Wybór ograniczonej liczby cech powoduje, że stan maszyny i sygnał diagnostyczny są reprezentowane przez pewne wielkości pomocnicze (identyfikatory). Cholewa [1] proponuje dla tego typu identyfikatorów nazwę "obrazu" - odpowiednio: "obraz stanu maszyny $\{OSt\}$ " i "obraz stanu sygnału diagnostycznego $\{OSy\}$ ".

Powiązania pomiędzy obrazami stanu i obrazami sygnału stanowią pewne przybliżenia (modele) odpowiednio relacji $R1$ i $R2$, których postać zależy od przyjętej metody badań. Szczególnie ważki wpływ na postać modeli relacji w eksperymencie diagnostycznym ma charakter

zbioru danych opisujących stany (obrazy standów) badanego procesu/procesów.

Modele relacji \hat{R}_1 i \hat{R}_2 mają w eksperymencie diagnostycznym swoje określone miejsca. W szczególności modele \hat{R}_1 stanowią podstawę wnioskowania diagnostycznego, czyli umożliwiają identyfikację obrazu stanu badanej maszyny na podstawie rozpoznanego w toku badań obrazu sygnału. Z tego też względu badania relacji typu R_1 stanowią przedmiot szczególnie wielu prac badawczych w obszarze diagnostyki maszyn.

Z formalnego punktu widzenia model \hat{R}_1 może być identyfikowany:

a) poprzez przyporządkowanie elementów przestrzeni obrazów stanu i obrazów sygnału, a więc jako relacja:

$$\hat{R}_1 \subset \{OS_t\} \times \{OSy\} \quad (5)$$

b) w postaci funkcyjnej:

$$(OS_t)_t = \hat{R}_1((OSy)_t) \quad (6)$$

Modele relacji typu R_2 , wykorzystywane na potrzeby badań diagnostycznych maszyn, przyjmują najczęściej postać funkcyjną. W dotychczasowej praktyce takich badań badań modele omawianego rodzaju tworzone są wyłącznie dla relacji $R_2(Sy)$. Modelem relacji typu R_2 może więc być np. zależność wiążąca chwilowy obraz sygnału w chwili t , $(OSy)_t \subset (OSy)$, z chwilowymi obrazami sygnału w przeszłości:

$$(OSy)_t = \hat{R}_2(OSy)_t((OSy)_i; i = \dots, t-2, t-1) \quad (7)$$

Uzależnienie postaci modelu relacji $\hat{R}_2(OSy)_t$ od wartości zmiennej, odpowiadającej upływowi czasu, umożliwia sformułowanie problemu określenia postaci takiego modelu poza przedziałem czasu objętym obserwacją. Możliwość ekstrapolowania postaci modelu poza chwilę bieżącą w kierunku narastającego czasu jest równoznaczna z możliwością prognozowania obrazów sygnału w zadaniu diagnostycznym.

3. Model relacji R_2 jako podstawa prognozowania diagnostycznego

Załóżmy, że identyfikator czasowy T odpowiada chwili, w której stan maszyny i sygnału możemy określić terminem "bieżący". Stany o identyfikatorach $t \in (\dots, T-2, T-1)$ są stanami przeszłymi i tworzą "historię" badanych procesów. W kierunku narastającego czasu pojawiają się stany będące przedmiotem prognozowania diagnostycznego.

W zadaniu prognostycznym sekwencja podejmowanych działań może być przedstawiona w postaci:

"historia obrazu sygnału" -----> "prognozowany obraz sygnału" -
 -----> "prognozowany obraz stanu" (- - - - > "prognoza stanu
 maszyny")

$$\{(OSy)_i; i = \dots, T-2, T-1, T\} \xrightarrow{\hat{R}_2} (OSy)_{T+1a} \xrightarrow{\hat{R}_1} (OS_t)_{T+1a} \quad (8)$$

Znajomość przeszłych elementów szeregu obrazów sygnału wraz z modelem relacji R_2 , będącym w takim wypadku modelem prognostycznym,

warunkuje możliwość prognozowania obrazów sygnału. Z kolei znajomość modelu relacji typu R1 umożliwia sformułowanie na podstawie prognozy obrazu sygnału prognozy obrazu stanu obiektu badań, a więc wnioskowanie prognostyczne. Suma takich dwóch operacji w świetle przedstawionych uprzednio rozważań odpowiada zrealizowaniu zadania, które możemy określić hasłem "prognozowanie w diagnostyce maszyn".

4. Przykład modelu prognostycznego

Założmy, że model pewnego układu dynamicznego, wzbudzanego losowym procesem "białego szumu" $\{A(t)\}$, ma postać dyskretnego filtru. Odpowiedzią układu jest proces losowy $\{Y(t)\}$. Dla potrzeb analizy numerycznej przyjmujemy, że procesy $\{A(t)\}$ i $\{Y(t)\}$ są reprezentowane przez realizacje, dane w postaci dyskretniej (szeregów czasowych Y_t i A_t).

Poprzez odpowiedni dobór funkcji przejścia rozpatrywanego filtru możemy wpływać na postać procesu wyjściowego. W szczególności możemy tak uformować funkcję przejścia, by odpowiedź układu na wymuszenie białym szumem mogła być traktowana jako model zadanego procesu losowego (ściślej - szeregu czasowego reprezentującego taki proces). Zbiór parametrów filtru opisuje więc model analizowanego szeregu czasowego.

W zaproponowanym przez Boxa i Jenkinsa [2] modelu ARMA element Y_t szeregu Y_t , reprezentującego proces $\{Y(t)\}$, jest ważoną sumą skończonej liczby "p" elementów tego samego 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:

$$\tilde{Y}_t = \varphi_1 \tilde{Y}_{t-1} + \dots + \varphi_p \tilde{Y}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (9)$$

gdzie: $\tilde{Y}_t = Y_t - \bar{Y}$

\bar{Y} - wartość średnia w szeregu czasowym Y_t

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

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

Box i Jenkins zaproponowali także [2] postać swojego modelu (ARIMA), pozwalającą na analizowanie szeregów czasowych reprezentujących procesy niestacjonarne, co umożliwia ich wykorzystanie w eksperymentach diagnostycznych. Wstępnym etapem takiej analizy jest wydzielenie składowej systematycznej (trendu) z szeregu czasowego poprzez przekształcenie szeregu czasowego Y_t na nowy szereg $Z_{t,d}$ z wykorzystaniem tzw. operatora różnicowego ∇ stopnia "d", definiowanego następująco:

$$\tilde{z}_{t,1} = \nabla \tilde{Y}_t = \tilde{Y}_{t+1} - \tilde{Y}_t = (1-B)Y_t \quad (10)$$

$$\tilde{z}_{t,d} = \nabla^d \tilde{Y}_t = \nabla^{d-1} \tilde{Y}_t - \nabla^{d-1} \tilde{Y}_{t-1} = (1-B)^d Y_t$$

gdzie: d - stopień operatora ∇ .

Szczególnie przy małej dynamice zmian wartości elementów przekształcanego szeregu czasowego Y_t w wynikowym szeregu czasowym $Z_{t,d}$ ze wzrostem wartości stopnia operatora różnicowego występuje lawinowy wzrost względnej amplitudy szumu. Jednakże pomimo tej wady opisywany sposób jest powszechnie stosowany, gdyż umożliwia on w dowolnym momencie odtworzenie postaci "wyjściowego" szeregu czasowego Y_t na podstawie szeregu $Z_{t,d}$, znanego stopnia operatora różnicowego "d" oraz zapamiętanych "d" początkowych wartości szeregu Y_t .

Przedmiotem opisu z zastosowaniem modelu omawianego typu staje się więc szereg czasowy $Z_{t,d}$, który w badaniach diagnostycznych możemy traktować jako dyskretną reprezentację składowej losowej w sygnale, a więc pewnego stacjonarnego procesu losowego $\{Z(t)\}$:

$$\tilde{z}_{t,d} = \varphi_1 \tilde{z}_{t-1,d} + \dots + \varphi_p \tilde{z}_{t-p,d} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (11)$$

gdzie: $\tilde{z}_{t,d} = z_{t,d} - \bar{z}_d$

\bar{z}_d - wartość średnia w szeregu czasowym $Z_{t,d}$.

W celu obliczenia prognozy wartości elementu analizowanego szeregu czasowego $y_t \in Y_t$, w szeregu tym wyróżnimy element y_T , $y_T \in Y_t$, i uznamy, że chwila T jest "chwila bieżąca" na osi czasu.

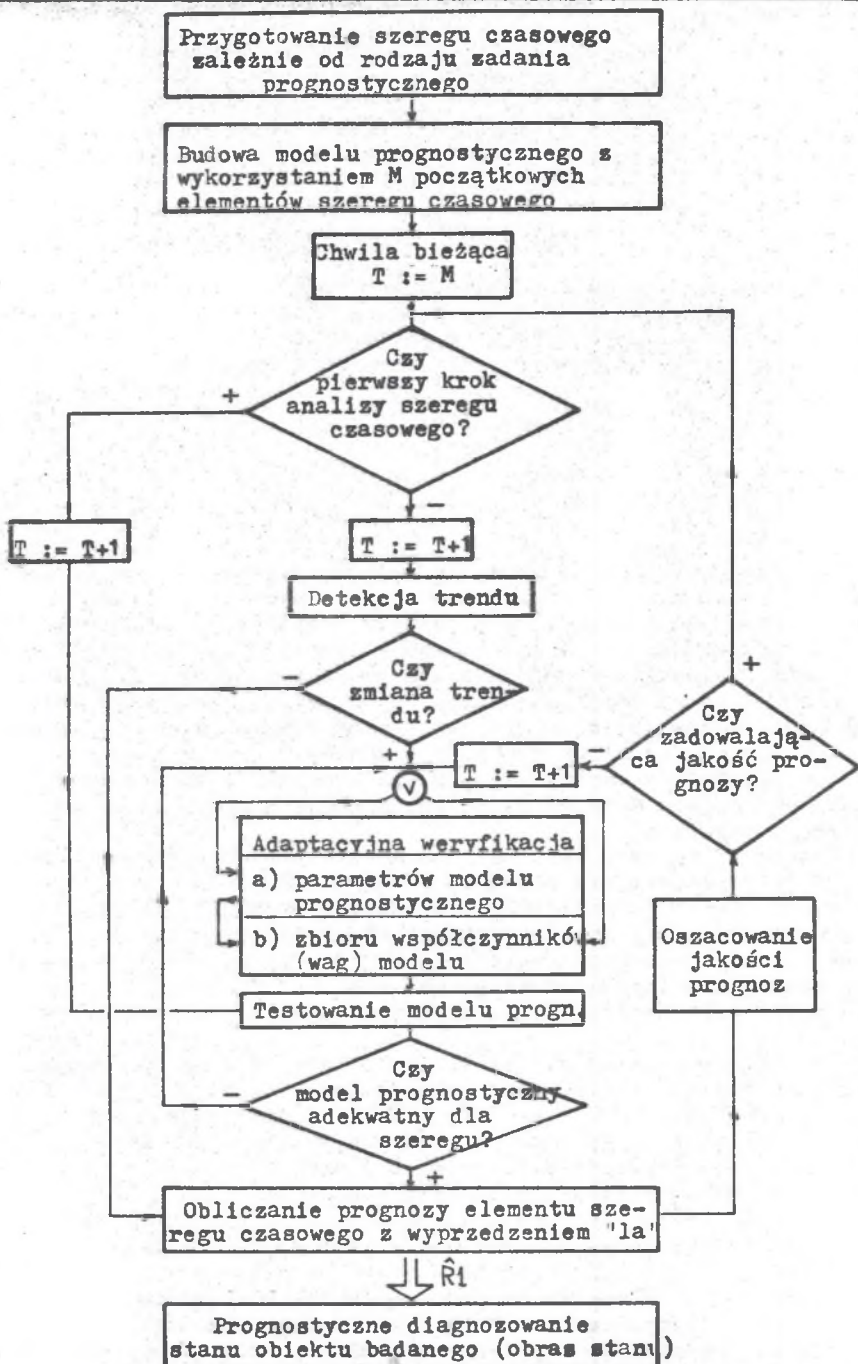
Wykorzystując podzbiór elementów szeregu Y_t : $y_t, t \in [T-M; T]$ zbudujemy dla analizowanego szeregu model typu ARMA lub ARIMA. Pod pojęciem "budowy modelu" należy tu rozumieć określenie wartości jego parametrów (p, (d) i q) oraz wartości współczynników autoregresji $\varphi_i, i=1, 2, \dots, p$ i/lub ruchomej średniej $\theta_j, j=1, 2, \dots, q$.

Obliczanie prognozy y_{T+1a} o wyprzedzeniu czasowym $1a$ z wykorzystaniem modelu ARMA/ARIMA możemy pokazać w postaci następującej sekwencji działań:

- zakładamy, że dany jest odcinek analizowanego szeregu czasowego Y_t , w którym ostatnim elementem danym (w kierunku rosnącej skali czasu) jest element y_T , odpowiadający "chwili bieżącej" oraz identyczny ze względu na wartości identyfikatora czasowego odcinek szeregu czasowego reszt prognoz A_t ($a_t = Y_t - y_t$), reprezentującego proces losowy $\{A(t)\}$;
- jeżeli $d > 0$, przekształcamy szereg czasowy Y_t do postaci szeregu Z_t ;
- na podstawie zależności (9) (lub (11), gdy $d > 0$) obliczamy prognozę elementu analizowanego szeregu y_{T+1} . Jako elementy szeregu A_t o identyfikatorach $t \in [T-q, T-1]$ przyjmujemy odpowiednie reszty prognoz, wyznaczone w poprzednich krokach obliczeń, natomiast jako element a_T przyjmujemy wartość stałą, obliczoną w toku estymacji modelu (współczynnik θ_0);
- prognoza (T+1)-go elementu szeregu y_{T+1a} jest wykorzystywana do wyliczenia prognozy elementu (T+2)-go y_{T+2} . Przyjmuje się, że element a_{T+1} szeregu reszt ma wartość zerową.

Obliczenie w takiej procedurze wartości elementu szeregu Y_t (Z_t) o identyfikatorze $t = T+1a$ zamyka cykl iteracji.

Jeżeli model prognozy jest typu ARIMA(p,d,q) i wynikiem prognozowania jest element szeregu różnic stopnia $d > 0$, na podstawie znajomości odpowiedniej liczby elementów "wyjściowego" szeregu cza-



Rys.1. Algorytm metody analizy zmienności w czasie cech sygnału diagnostycznego i prognozowania w diagnostyce maszyn.

owego Y_t oraz prognozy $\hat{z}_{T+1a,d}$ budowana jest prognoza \hat{y}_{T+1a} .

5. Analiza zmian cech sygnału diagnostycznego w czasie

Na rys.1 pokazano schemat blokowy algorytmu metody identyfikacji zmian w czasie cech sygnału diagnostycznego, zaproponowanej przez autora tego referatu [3].

Algorytm ten, obok etapów związanych bezpośrednio z analizą prognostyczną, a więc:

- przygotowaniem danych dla prognozowania,
- budową modelu prognozy,
- weryfikacją modelu prognozy,
- kontrolą jakości prognozy,
- wnioskowaniem prognostycznym

obejmuje również "nieprognostyczny" element analizy szeregów czasowych, jakim jest badanie obecności i charakteru trendów w takich szeregach [4].

Etapy pokazanego algorytmu mogą być realizowane w różny sposób, uwarunkowany m.in. typem zadania prognostycznego, jak i szczególnymi własnościami danych składających się na analizowany szereg czasowy.

Zdaniem autora tego opracowania, dopiero połączenie narzędzia prognostycznego z innymi sposobami analizy zmienności cech sygnału w czasie pozwala na pełne wykorzystanie informacji o tej zmienności dla potrzeb eksperymentu diagnostycznego. Wniosek taki potwierdzają próby zastosowań praktycznych przedstawionego algorytmu ([3], [5]).

6. Podsumowanie

W referacie przedstawiono ujęcie problemu prognozowania w diagnostyce maszyn, bazujące na potraktowaniu tego problemu jako zadania przetwarzania informacji, danej w eksperymencie diagnostycznym poprzez zbiór cech sygnału. Rozdzielenie zagadnienia wnioskowania o stanie maszyny na podstawie cech sygnału i zagadnienia opisu zmienności stanów maszyny i sygnału w czasie umożliwia realizację postawionego zadania z wykorzystaniem sprawdzonych sposobów, m.in. pokazanego tu sposobu wykorzystania modelu procesu losowego jako modelu wyróżnionego w tym opracowaniu typu R2 relacji diagnostycznej.

LITERATURA

- [1] Cholewa W.: Metoda diagnozowania maszyn z zastosowaniem zbiorów rozmytych, Zeszyty Naukowe Pol. Sl., Seria: Mechanika, zeszyt nr 79, Gliwice 1983.
- [2] Box G.E.P., Jenkins G.M.: Analiza szeregów czasowych: prognozowanie i sterowanie, PWN, Warszawa 1983.

- [3] Kaźmierczak J.: Zastosowanie liniowych modeli procesów losowych dla prognozowania w diagnostyce maszyn, Zeszyty Naukowe Pol.Sl., Seria: Mechanika (złożone do druku),
- [4] Kaźmierczak J.: Detekcja trendu w szeregach czasowych ocen sygnału diagnostycznego, Materiały VIII Szkoły DIAGNOSTYKA'87, Poznań-Rydzyna, sierpień 1987, s.147-154.
- [5] Kaźmierczak J.: Some aspects of the ARMA modeling of vibroacoustic signals in diagnostic research, Proceedings of the Nordic Acoustical Meeting NAM-88, Tampere/ Finland, June 1988, pp.173-176

THE MODELING OF CHANGES OF FEATURES OF DIAGNOSTIC SIGNALS IN TIME DOMAIN

S u m m a r y

The paper reports a method of the describing of the diagnostic experiment as a net of relations which joint states of the diagnosed process and states of the diagnostic signal. The problems of the modeling of such relations are discussed in the paper roughly, but the weightiness of the modeling of time liability of features of diagnostic signals is presented with particulars as the base of forecasting in technical diagnostics. The paper shows an example of the modeling of time series which can be treated as the discrete representations of the diagnostic signals in time domain. The algorithm of the method of identification of changes of signal features in time is shown in the paper as well.

МОДЕЛИРОВАНИЕ ИЗМЕНЕНИЙ СВОЙСТВ ДИАГНОСТИЧЕСКИХ СИГНАЛОВ В ОБЛАСТИ ВРЕМЕНИ

Р е з ю м е

В работе показан метод описывания диагностического эксперимента с использованием сети соотношений, которые связывают диагностируемый процесс и диагностический сигнал. Проблемы моделирования таких же соотношений в диагностическом эксперименте описаны в работе поверхностно, но значение анализа временных изменений свойств сигналов как основы метода прогнозирования в технической диагностике показаны подробно. Работа включает пример метода моделирования временных рядов свойств диагностических сигналов и описание алгоритма метода идентификации изменений свойств сигнала с течением времени.