ZESZYTY NAUKOWE POLITECHNIKI ŚLĄSKIEJ 1992

Seria: AUTOMATYKA z. 109 Nr kol. 1175

Grzegorz Kobyłecki, Zbigniew Banaszak
Wyższa Szkoła Inżynierska w Zielonej Górze

DWUSTOPNIOWA METODA IDENTYFIKACJI STRUKTURALNEJ

THE TWO-STEP METHOD OF STRUCTURAL IDENTIFICATION

ZWEISTUFIGE METHODE DER STRUKTURELLE IDENTIFIKATION

Streszczenie: W pracy przedstawiono dwustopniową metodę identyfikacji strukturalnej stanowiącą rozszerzenie metody selekcji grupowej wielkości wejściowych (SGWW) [2,3,6]. Istotę proponowanego rozszerzenia stanowi założenie mówiące, że o jakości klasteryzacji, w kontekście określonego kryterium, decydują pewne wyróżnione cechy identyfikowanego obiektu. Wykazano twierdzenie orzekające, że wyższą ocenę jakości klasteryzacji zbioru elementów opisanych cechami specyfikującymi obiekt uzyskuje się w przypadku, gdy przeprowadza się ją w oparciu o pewien, wyróżniony w metodzie SGWW, podzbiór cech, niż w przypadku, gdy klasteryzacja dokonywana jest w oparciu o zbiór wszystkich cech. Jakość klasteryzacji wpływa bezpośrednio na dokładność identyfikacji strukturalnej obiektu. Zastosowanie przedstawionej metody zilustrowane zostało na przykładzie pewnego zadania diagnostyki technicznej.

Summary: An approach to the application of an extended version of Group Method of Data Handling to design diagnosis aimed expert systems is presented. The method of the two-step structural identification is based on the procedures aimed at:
- selection of mutualy dependent parameters,
- structural identification and clustering.
An example of the method application to the problem of technical system diagnostics is shown.

Zussammenfasung: In diesem Artikel wird die Methode der Strukturelle Identifikation, die eine Erweiterung der GMDH Methode ist, vorgestellt. Diese Methode berücksicktigt folgende mathematische Prozedur:
- Selektion des Merkmales der Objekten,
- Strukturelle Identifikation und Cluster Analyse.
Die Anwendung dieser Methode wird für ein Beispiel dargestellt.

1. Wprowadzenie

W praktyce inżynierskiej często napotyka się na trudności związane z uzyskaniem pełnej informacji o bieżącym stanie sterowanego obiektu. Trudności te wiążą się zazwyczaj z wysokimi kosztami pomiaru określonych parametrów, brakiem odpowiednich czujników lub dostępnych miejsc pomiarowych [6]. Uniezależnienie się od tego typu ograniczeń ma bezpośredni wpływ na zwiększenie jakości pracy układów monitorowania oraz podniesienie efektywności funkcjonowania systemów sterowania i diagnostyki pracy obiektów.

Jednym z możliwych podejść do tego problemu jest wykorzystanie metody identyfikacji strukturalnej i parametrycznej [2,5,6]. Omawiana klasa metod

pozwala wyznaczać modele matematyczne badanych obiektów i tym samym wyznaczać nieznane wartości poszczególnych parametrów w oparciu o znane (np. zmierzone) wartości pozostałych parametrów. Efektywność znanych metod identyfikacji [6] oceniana np. z punktu widzenia ich złożoności obliczeniowej, dokładności uzyskiwanych modeli czy też wymagań stawianych środkom techniki obliczeniowej, jest silnie związana z wielkością i typem badanego obiektu, a także pewną aprioryczną o nim wiedzą. Uwzględniając wymienione kryteria, metodą zasługującą na szczególną uwagę jest metoda selekcji grupowej wielkości wejściowych [2,5,6]. Metoda ta nie stawia żadnych ograniczeń na wielkości (ilość parametrów) badanego (identyfikowanego) obiektu ani też nie wymaga żadnych apriorycznych informacji o strukturze czy naturze obiektu, natomiast w sposób kompromisowy godzi wymagania narzucone przez oczekiwaną dokładność identyfikowanych modeli z możliwościami powszechnie dostępnych środków techniki obliczeniowej.

Działanie omawianej metody selekcji grupowej wielkości wejściowych (SGWW) sprowadza się w zasadzie do wyznaczania pewnego wielomianu aproksymującego zadane (znane z wcześniejszych pomiarów lub obserwacji) dane wejściowe. Wielomian aproksymujący budowany jest w sposób iteracyjny w oparciu o arbitralnie wybraną część zbioru danych wejściowych. W każdej iteracji, w oparciu o pozostałe dane wejściowe dokonywana jest ocena aktualnego wielomianu aproksymującego, którego rząd oraz współczynniki zmieniają się w kolejnych iteracjach. Warunek stopu metody określony przez średniokwadratowe kryterium jakości estymacji wyznacza wielomian, którego rząd oraz tworzące go zmienne w sposób najlepszy, tzn. w sensie wspomnianego już średniokwadratowego kryterium jakości estymacji, aproksymują zgromadzone (w celu identyfikacji obiektu) dane wejściowe.

Z przedstawionego opisu działania metody wynika, że jest ona stosunkowo wrażliwa na wielkość zbioru danych wejściowych, który jest jedynym reprezentantem cech obiektu. Zbiór taki powinien zawierać możliwie jak najwięcej danych, co oznacza jednak, że część danych może być nadmiarowa. Dlatego celowe jest zastosowanie analizy skupień (klasteryzacji) w stosunku do zadanego zbioru danych wejściowych. Klasteryzacja taka umożliwia wyodrębnienie podzbiorów elementów wykazujących homogeniczność wybranych cech, a przez to zmniejszenie redundancji zbioru danych oraz zmniejszenie liczby przetwarzanych danych.

Wstępna klasteryzacja zbioru danych wejściowych wykorzystana została przy opracowaniu dwustopniowej metody identyfikacji strukturalnej. Istotą tej metody, stanowiącej pewne rozszerzenie metody SGWW [3,6,7] stanowi założenie mówiące, że o jakości klasteryzacji, w kontekście określonego kryterium, decydują pewne wyróżnione cechy identyfikowanego obiektu. Założenie takie może stanowić tezę pewnego twierdzenia orzekającego, że wyższe oceny jakości klasteryzacji zbioru elementów opisanych cechami specyfikującymi dany obiekt uzyskiwane są w przypadku, gdy klasteryzacja przeprowadzana jest w oparciu o pewien, wyróżniony przez metodę SGWW, podzbiór cech, niż to ma miejsce w przypadku analizy skupień realizowanej według wszystkich cech. Łatwo zauważyć, że jakość wstępnej klasteryzacji zbioru danych wejściowych ma istotny wpływ na dokładność identyfikacji prowadzonej metodą SGWW, w odniesieniu do danych wejściowych wyróżnionych przez klastry.

Rozdział drugi niniejszej pracy ilustruje koncepcję wstępnej klasteryzacji zbioru danych wejściowych oraz formułuje i wyprowadza tezę twierdzenia umożliwiającego wykorzystanie pewnego kryterium wyboru cech. W rozdziale trzecim przedstawiona została struktura oraz omówione zostało działanie proponowanej, dwustopniowej metody identyfikacji strukturalnej oraz przykład ilustrujący zastosowanie metody w wybranej klasie zadań diagnostyki technicznej. Rozdział czwarty omawia możliwości zastosowań przedstawionej metody oraz szkicuje niektóre z ważniejszych, związanych z dalszym jej rozwojem, problemów badawczych.

2. Wstępna klasteryzacja zbioru danych

2.1. *Formalny opis analizy skupień*

Dana jest euklidesowa przestrzeń klasteryzacji VXY rozpięta nad ciałem liczb rzeczywistych R^{m+n}, będąca sumą prostą dwóch podprzestrzeni

$$VXY = VX \cup VY \tag{1}$$

gdzie: $VX(R) = R^m$, $VY = R^n$.

Niech $x^i=(x_1,x_2,\dots,x_m) \subset VX$ oraz $y^i=(y_1,y_2,\dots,y_n) \subset VY$ będą wektorami, ktorych współrzędne odpowiadają wartościom cech rozpatrywanego obiektu.

Klasteryzacja zbioru punktów przestrzeni VXY polega na:

- wyodrębnieniu podprzestrzeni VX_iY_i, spełniającej następujące warunki:

(a) $VX_i \subset VX$,

(b) $VY_i \subset VY$,

(c) $VX_iY_i = VX_i \cup VY_i$,

(d) $\bigwedge_{x \in VX_i} \bigvee_{y \in VY_i} y = f(x)$.

- rozbiciu zbioru punktów zawartych w podprzestrzeni VX_iY_i na k podzbiorów:

$$X_i = \sum_{j=1}^{k} \{x^j\}_j \quad \text{oraz} \quad Y_i = \sum_{j=1}^{k} \{y^j\}_j, \quad \text{takich że:}$$

(e) istnieje wzajemna jednoznaczna odpowiedniość $\{x^j\}_j \Leftrightarrow \{y^j\}_j$ oraz

(f) spełnione jest zewnętrzne kryterium klasteryzacji (np. kryterium zgodności).

2.2. *Wpływ wyboru zbioru cech na jakość klasteryzacji*

Istotny wpływ na jakość analizy skupień dokonywanej według definicji przedstawionej w punkcie 2.1 ma wybór analizowanych cech, czyli wybór podprzestrzeni VX_iY_i. Szczególne znaczenie ma tu wyeliminowanie szkodliwej redundancji cech uwzględnionych w zbiorze danych wejściowych. Interesujące kryterium wyboru cech przedstawiono w [8]:

$$K' = \sum_{i=1}^{k} \frac{1}{p_i} \sum_{s,t=1}^{k} r_{i.st} . \tag{2}$$

Kryterium to służy do oceny wpływu podziału cech $X_1, \ldots, X_p$ na korelację cech uwzględnianych podczas klasteryzacji, tzn. pozwala ocenić wypadkową korelację cech w zależności od możliwych, k grupowych podziałów, przy czym p_i $(p_i > 0)$ jest ilością cech w grupie o numerze i, a $\sum_{s,t=1}^{k} r_{i.st}$ jest sumą wszystkich wyrazów macierzy korelacji tych cech.

Praktyczne zastosowanie przedstawionego kryterium napotyka na szereg ograniczeń związanych z dyskretyzacją wartości cech oraz złożonością obliczeniową algorytmu maksymalizującego kryterium realizującego strategię przeglądu zupełnego. Można, uwzględniając pewne właściwości obiektu, lecz nie przeprowadzając przeglądu zupełnego, dokonać takiego podziału cech, który zwiększa wartość kryterium. Twierdzenie uzasadniające takie postępowanie stanowi treść kolejnego punktu.

2.3. *Maksymalizacja kryterium wyboru cech*

Można sformułować następujące twierdzenie związane z niezależnością analizowanych cech.

TWIERDZENIE

Dany jest zbiór cech $X_1, \ldots, X_p$, wśród których można wyróżnić k grup cech takich, że cechy zawarte w jednej grupie są niezależne od innych cech. Niech K'_Z będzie wartością kryterium (2) podziału cech na takie grupy oraz niech K'_O będzie wartością tego kryterium, gdy żaden podział nie został dokonany.

Jeżeli $k>1$, to $K'_Z > K'_O$.

DOWÓD

Z definicji kryterium (2) po uwzględnieniu założeń tezy twierdzenia otrzymuje się:

$$K'_Z = \sum_{i=1}^{k} \frac{1}{p_i} \sum_{s,t=1}^{k} r_{i.st} . \tag{3}$$

oraz:

$$K'_O = \frac{1}{p} \sum_{s,t=1}^{p} r_{i.st} . \tag{4}$$

Z niezależności cech zawartych w różnych grupach (wartości tych cech można traktować jako zmienne losowe niezależne; fakt ten implikuje, że odpowiednie współczynniki korelacji są równe zero) wynika:

$$\sum_{s,t=1}^{p} r_{i.st} = \sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} . \tag{5}$$

Wiadomo również, że

$$p = \sum_{i=1}^{k} p_i \, . \tag{6}$$

Podstawiając (3), (4), (5) oraz (6), otrzymano przekształconą postać tezy twierdzenia

$$\sum_{i=1}^{k} \frac{1}{p_i} \sum_{s,t=1}^{p_i} r_{i.st} > \frac{1}{\sum_{i=1}^{k} p_i} \sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} \, . \tag{7}$$

Przy założeniu, że $p_i > 0$ nierówność (7) można dalej przekształcić do postaci

$$\frac{\sum_{i=1}^{k} \left(\prod_{n=1}^{i-1} p_n \prod_{n=i+1}^{k} p_n \sum_{s,t=1}^{p_i} r_{i.st} \right)}{\prod_{i=1}^{k} p_i} > \frac{1}{\sum_{i=1}^{k} p_i} \sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} \, . \tag{8}$$

Dla uproszczenia zapisu można podstawić

$$A = \min_{i \in \langle 1,k \rangle} \left\{ \prod_{n=1}^{i-1} p_n \prod_{n=i+1}^{k} p_n \right\} , \tag{9}$$

oraz niech i' będzie wartością i, dla której otrzymano A.

Wyprowadzając przed nawias, w liczniku lewej strony nierówności (8), wartość A (minimalną po wszystkich iloczynach) otrzymuje się nierówność

$$A \left(\sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} \right) \leq \sum_{i=1}^{k} \left(\prod_{n=1}^{i-1} p_n \prod_{n=i+1}^{k} p_n \right) \sum_{s,t=1}^{p_i} r_{i.st} \, . \tag{10}$$

W mianowniku lewej strony nierówności (8) można podstawić lewą stronę nierówności (10).

$$\frac{A \left(\sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} \right)}{\prod_{i=1}^{k} p_i} > \frac{1}{\sum_{i=1}^{k} p_i} \sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} \, . \tag{11}$$

Przekształcając dalej (11), otrzymano

$$A \left(\sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} \right) \sum_{i=1}^{k} p_i > \prod_{i=1}^{k} p_i \sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} \, , \tag{12}$$

a następnie

$$\left[A \left(\sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} \right) \sum_{i=1}^{i'-1} p_i \right] + \left(A \, p_{i'} \right) \left(\sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} \right) +$$

$$+ \left[A \left(\sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} \right) \sum_{i=i'+1}^{k} p_i \right] > \prod_{i=1}^{k} p_i \sum_{i=1}^{k} \sum_{s,t=1}^{p_i} r_{i.st} \, . \tag{13}$$

Ponieważ $A\,p_{i'} = \prod_{i=1}^{k} p_i$, zatem ostatecznie

$$[A(\sum_{i=1}^{k}\sum_{s,t=1}^{p_i} r_{i.st})\sum_{i=1}^{i'-1} p_i] + [A(\sum_{i=1}^{k}\sum_{s,t=1}^{p_i} r_{i.st})\sum_{i=i'+1}^{k} p_i] > 0. \qquad (14)$$

Przekształcając tezę twierdzenia, otrzymano nierówność (14), a ponieważ

$$A(\sum_{i=1}^{k}\sum_{s,t=1}^{p_i} r_{i.st})\sum_{i=1}^{i'-1} p_i] \geq 0 \quad i \quad A(\sum_{i=1}^{k}\sum_{s,t=1}^{p_i} r_{i.st})\sum_{i=i'+1}^{k} p_i] \geq 0$$

oraz

$$A(\sum_{i=1}^{k}\sum_{s,t=1}^{p_i} r_{i.st})\sum_{i=1}^{i'-1} p_i] > 0 \quad \text{lub} \quad A(\sum_{i=1}^{k}\sum_{s,t=1}^{p_i} r_{i.st})\sum_{i=i'+1}^{k} p_i] > 0$$

więc nierówność (14) jest prawdziwa, co kończy dowód. ■

Z przedstawionego twierdzenia wynika, że wstępny podział zbioru danych pomiarowych, np. według zależności opisujących je cech, stanowi warunek konieczny wzrostu wartości rozważanego kryterium jakości klasteryzacji.

W praktyce oznacza to, że dokładność modeli obiektu, uzyskanych w wyniku zastosowania aproksymacji strukturalnej, w obszarze zmienności parametrów wyznaczonym przez elementy tworzące dany klaster, będzie wyższa niż w przypadku modeli uzyskanych tymi samymi metodami aproksymacji, lecz w obszarze zmienności wyznaczonym przez elementy całego wejściowego zbioru danych. Zaobserwowany fakt stanowi główne założenie do budowy rozszerzonej wersji metody identyfikacji strukturalnej [6].

3. Metoda dwustopniowej identyfikacji strukturalnej

Na podstawie bazy danych, zebranych np. w procesie monitorowania pracy obiektu, specjalnie zaplanowanych eksperymentów lub też okresowo prowadzonych badań i testów kontrolnych, można zbudować tzw. pierwotną bazę wiedzy stanowiącą pewien podzbiór elementów zbioru bazy danych. Elementami tak rozumianej bazy są dane reprezentujące wartości cech zależnych. Baza taka zawiera oprócz danych pomiarowych pewną wiedzę o zależnościach cech charakteryzujących obiekt. Rozważany podzbiór dekomponowany jest następnie na klastry, według wartości cech elementów tworzących ten podzbiór. Uzyskane w ten sposób klastry tworzą tzw. właściwą bazę wiedzy.

Z przedstawionego opisu wynika, że w procesie przekształcania bazy danych do właściwej bazy wiedzy wykorzystywana była dwukrotnie, iteracyjnie analiza skupień. Mechanizmy leżące u podstaw wykonywanych klasteryzacji, jak też interpretacja i możliwości wykorzystania uzyskanej bazy wiedzy stanowią integralny element omawianej metody dwustopniowej identyfikacji strukturalnej.

3.1. *Struktura*

Zakładając, że baza danych utworzona jest przez zbiór wektorów

$$BD = \{ V_i \mid i = \overline{1,v} \}, \tag{15}$$

gdzie każdy wektor $V_i = (v_{i,1},\ldots,v_{i,j},\ldots,v_{i,r})$ reprezentuje pewien, odpowiadający momentowi pomiaru, zbiór r wartości cech obiektu, rozważany schemat dwuetapowej klasteryzacji BD sprowadza się odpowiednio do:

- wyodrębnienia spośród rozważanego zbioru r cech podzbioru $Z \subset \overline{1,r}$ zawierającego elementy zależne, a następnie przekształcenia BD w dwa podzbiory

$$W_Z = \{(crd^l V_i \mid l \in Z) \mid i = \overline{1,v}\},$$
$$W_N = \{(crd^k V_i \mid k \in \overline{1,r} \setminus Z) \mid i = \overline{1,v}\}, \tag{16}$$

gdzie $crd_i \overset{def}{=\!=} s_i$ dla $S = (s_1,\ldots, s_i,\ldots,s_q)$,

- wyboru metody klasteryzacji i dokonaniu za jej pomocą analizy skupień w zbiorze W_Z.

Uzyskany w efekcie zbiór

$$BW = \{BW_k \mid k = \overline{1,z}\},$$

taki, że $BW_i \cap BW_j = 0, \cup \{BW_k \mid k = \overline{1,z}\} = W_Z$, (17)

zawiera elementy opisane wielkościami zależnymi, o wartościach pozwalających wyodrębnić te elementy jako oddzielne klastry.

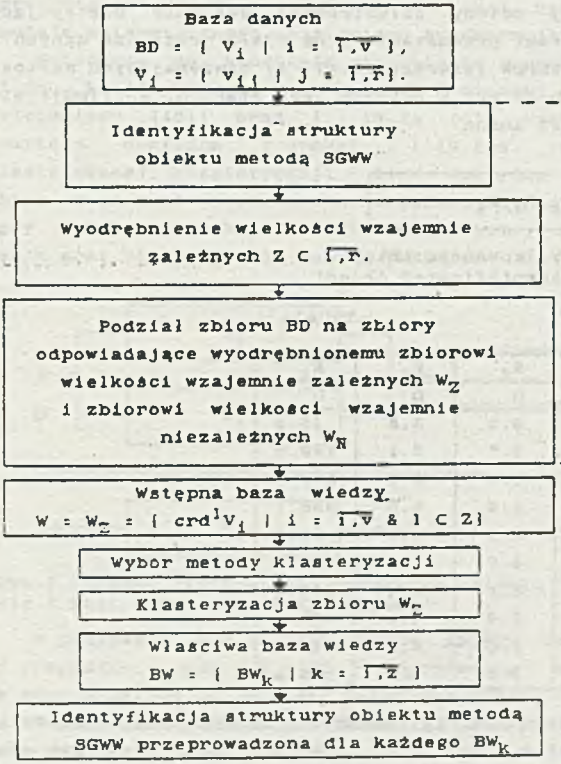

Rys. 1. Procedura dwustopniowej identyfikacji strukturalnej
Fig. 1. The two-step method of structural identyfication procedure

Strukturę omawianej metody dwustopniowej identyfikacji strukturalnej przedstawia rys. 1.

Ze struktury przedstawionej procedury wynika jej nazwa. Łatwo zauważyć, że w strukturze tej dwukrotnie wykorzystana jest metoda SGWW. Pierwsze wykorzystanie tej metody ma miejsce na etapie klasteryzacji cech (wielkości, parametrów) determinujących wektory bazy danych BD. Kryterium klasteryzacji jest stopień wzajemnej zależności wielkości opisujących obiekt. O wzajemnej zależności tych cech decyduje ich jednoczesne występowanie w wyznaczonym wielomianie Iwachnienki [2,6]. Wielomian ten jest modelem obiektu uzyskanym w wyniku zastosowania metody identyfikacji strukturalnej SGWW.

Po raz drugi procedura SGWW wykorzystywana jest na etapie identyfikacji struktury obiektu przeprowadzonej dla poszczególnych BW, tzn. dla wybranych, gwarantujących największą dokładność identyfikacji podzbiorów BD. Oznacza to, że wynikowy model obiektu stanowi zbiór modeli cząstkowych skojarzonych z poszczególnymi elementami BW.

3.2. *Działanie*

Działanie przedstawionej metody zilustrowane zostanie następującym przykładem. Dany jest obiekt przedstawiony na rys.2 oraz baza danych BD utworzona przez zbiór wektorów (wiersze tabeli 1) zawierających wartości wielkości charakteryzujących obiekt w różnych jego stanach. Przyjmuje się, że struktura obiektu nie jest znana.

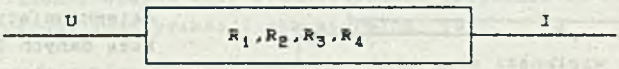

Rys.2.Schemat blokowy identyfikowanego obiektu
Fig.2.Block diagram of the identyficated object

Tabela 1

Lp.	I	R_1	R_2	R_3	R_4
	A	Ω	Ω	Ω	Ω
1	21.8	2.3	3.5	3.2	43.3
2	23.5	1.6	3.7	3.1	149.6
3	22.4	2.1	3.4	3.2	219.0
4	17.1	1.3	2.6	5.0	388.1
5	16.0	2.7	2.8	4.9	92.8
6	19.4	1.3	3.7	4.2	206.2
7	17.3	2.7	2.8	4.4	282.4
8	17.0	2.1	2.9	4.6	410.9
9	17.7	2.0	2.0	4.6	344.5
10	21.0	1.2	3.6	3.8	165.4

Należy wyznaczyć wartość I przy zadanych (zmierzonych) wartościach oporności $R_1 = 2\ \Omega$, $R_2 = 3\ \Omega$, $R_3 = 4\ \Omega$, $R_4 = 6\ \Omega$. Napięcie U jest stałe i wynosi 100V.

W wyniku zastosowania metody SGWW (przyjmując, że zbiór uczący zawiera

pomiary od 1 do 5, natomiast zbiór testujący zawiera pozostałe pomiary) otrzymano następujący wielomian aproksymujący

$$I = -381 - 42R_1 + 291R_2 - 22R_3 + 34R_1R_2 + R_2R_3 - 20R_1^2 - 54R_2^2 + 3R_3^2. \quad (18)$$

Z otrzymanego wielomianu wynika, że wielkości I, R_1, R_2 i R_3 są wzajemnie zależne, natomiast wielkość R_4 jest wielkością niezależną. Oznacza to, że uzyskana wstępna baza wiedzy jest zbiorem wierszy tabeli 1, z której usunięta została ostatnia kolumna, odpowiadająca R_4.

Uzyskana baza wiedzy BW została następnie poddana klasteryzacji metodą BHKSm [4,5]. W wyniku przeprowadzonej klasteryzacji otrzymano następujące klastry

BW_1 - zawiera punkty: 1,2,3,5,6,7,8,9,

BW_2 - zawiera punkt 4,

BW_3 - zawiera punkt 10.

Dla założonych, zmierzonych wartości oporności $R_1 = 2\ \Omega$, $R_2 = 3\ \Omega$, $R_3 = 4\ \Omega$ wyznaczono, metodą najbliższego sąsiedztwa, klaster W_1, któremu odpowiada wielomian aproksymujący postaci

$$I = 16 + 12R_2 + 12R_3 + 0.2R_2R_3 + 2R_2^2 - 1.8R_3^2 \quad (19)$$

Warto zauważyć, że rzeczywistą strukturę analizowanego obiektu przedstawia rys.3 i struktura ta jest zgodna ze strukturą otrzymanego modelu matematycznego (wielomianu aproksymującego).

Wyliczone na podstawie wielomianów aproksymujących, otrzymanych przed i po klasteryzacji, wartości I wynoszą odpowiednio I = 17,5A (dla wielomianu (18)) oraz I = 19,3A (dla wielomianu (19)). Przyjmując, że wartość dokładna I wynosi I = 19,23A, łatwo zauważyć, że w wyniku zastosowanej klasteryzacji błąd względny maleje z 9% (w przypadku gdy baza W poddana została klasteryzacji metodą BHKSm) do 0,04% (w przypadku gdy baza W poddana została klasteryzacji metodą wstępnej klasteryzacji cech oraz klasteryzacji metodą BHKSm).

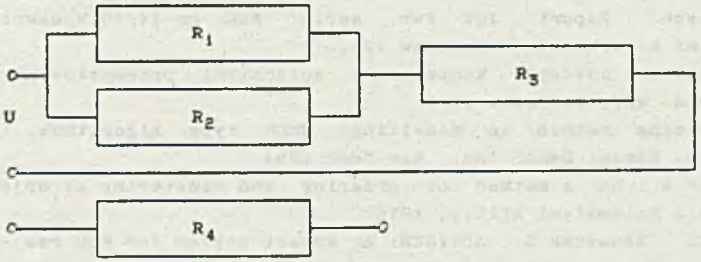

Rys.3.Schemat rzeczywistej struktury obiektu
Fig.3.Real structure of the object

W przypadku gdy klasteryzacja zbioru cech nie była dokonywana, tzn. w przypadku gdy W = BD, odpowiednia wartość I wyniosła 17,9A, a odpowiadająca jej wartość błędu względnego 7,4%.

Uzyskane wyniki potwierdzają korzyści wynikające z praktycznego wykorzystania przedstawionego twierdzenia, a w konsekwencji zaproponowanej metody dwustopniowej identyfikacji strukturalnej.

4. Uwagi końcowe

Przedstawiona metoda dwustopniowej identyfikacji strukturalnej pozwala uzyskiwać modele struktury analizowanych obiektów, których dokładność w ogólnym przypadku nie jest gorsza niż tych wyznaczonych za pomocą metody SGWW. Na jakość uzyskiwanych wyników decydujący wpływ posiada zarówno dobór parametrów określających działania, dwukrotnie wykorzystywanego algorytmu SGWW, (np. podziału BD na zbiór uczący i testujący, doboru kryterium jakości oceny, reguły ograniczania liczności generowanych rozwiązań itd.), jak również dobór metod klasteryzacji końcowej bazy wiedzy BW. Fakt ten oznacza konieczność poszukiwania warunków określających cechy i zmienne metody, które w danej klasie obiektów gwarantują uzyskiwanie modeli o z góry założonej dokładności.

Określenie wymienionych warunków pozwoli uczynić zaprezentowaną metodę nie tylko atrakcyjną dla rozwiązywania zadań identyfikacji strukturalnej, ale także dla zadań budowy systemów doradczych wykorzystywanych w problemach diagnostyki systemów technicznych [5,9].

5. Literatura

[1] Bijanen E.I.: Cluster analysis. Springer Verlag, Berlin 1974.

[2] Iwachnienko A.G.: Nieprierywnost i diskretnost. - Naukowa Dumka, Kijów - 1990.

[3] Iwachnienko A.G.: Issliedowanije charakteristik funkcjonirowania gibkoj proizwodstwiennoj sistemy metodom obiektiwnoj komputernoj klasterizacji. Wydawnictwa Politechniki Wrocławskiej, Wrocław 1989.

[4] Kucharczyk J.: Algorytmy analizy skupień w języku ALGOL 60. PWN, Warszawa 1982.

[5] Kus J.: System komputerowo wspomaganego podejmowania decyzji w zadaniach projektowania i eksploatacji elastycznych systemów produkcyjnych. Raport ICT PWr. seria: PRE nr 44/90,Wydawnictwa Politechniki Wrocławskiej, Wrocław 1990.

[6] Niederliński A.: Systemy komputerowe automatyki przemysłowej. t.2 Zastosowania. WNT, Warszawa 1985.

[7] Self-organizing method in modelling: GMDH type algorithms. -Ed. S.J. Farlow: Marsel Dekkr Inc., New York 1984.

[8] Szczotka F.A.: On a method of ordering and clustering of objects, Zastosowania Matematyki XIII,1, 1972.

[9] Szypułka L., Banaszak Z.: ADVISER: An expert system for FSM real-time dispatching. Proc. IV Int. Conf. on "Integrated Problems on Industrial Control". Kiev, Ukraine, 1990, v.2, pp. 197-201.

Recenzent: Prof.dr h.inż. Franciszek Marecki

Wpłynęło do Redakcji do 30.04.1992 r.

Abstract: An approach to the application of an extended version of Group Method of Data Handling to design diagnosis aimed expert systems is presented. The problem statement is as follows. According to the preassumed set of vectors $p \in P_1 \times P_2 \times \ldots \times P_N$, where P_i, $i=1,N$ are parameters of the system, and a given vector of actual measurement

$P_m \in P_1 \times P_2 \times \ldots \times P_{N-1}$ we want to answer the following question. What is the actual value of the N-th parameter ?
The solution of the problem is provided by a two-step method of structural identification (TSMSI) which is based on the procedures aimed at: selection of mutualy dependent parameters, structural identification and clustering.

The method presented can be easily applied to the problem of technical system diagnostics. For example let us consider the following problem of diagnosis. It is assumed that the nominal value of the N-th parameter is P_{Nnom}. Each characteristics describes an activity of a given part or subsystem of the system considered. Let us suppose that the values of all parameters P_i, $i=1,N-1$ are given. Does value of the N-th parameter is contained in the range $P_{Nnom} \pm \Delta$? The flow chart of the relevant solution procedure of the problem considered is shown on Fig. 1.

Fig.1 The flow chart of the solution procedure

Note, that the problem of diagnosis in the example considered can be understood as a problem of validation of the system component on the base of system parameter estimation.