

Halina DĄBROWSKA

OGÓLNY ALGORYTM HEURYSTYCZNEJ METODY IDENTYFIKACJI  
CHARAKTERYSTYK STATYCZNYCH OBIEKTÓW WIELOWYMIAROWYCH

Streszczenie. W artykule omówiono heurystyczną metodę identyfikacji charakterystyk statycznych obiektów z wykorzystaniem kryterium regularności i kryterium niezmienności. Przedstawiono opracowany ogólny algorytm umożliwiający przeprowadzanie identyfikacji różnych obiektów na maszynach cyfrowych. Omówiono opracowany dla tych celów program OBIEKT, napisany w języku FORTRAN 1900.

1. Wstęp

Identyfikację charakterystyk statycznych obiektów wielowymiarowych przeprowadza się w dwóch etapach:

1) wybór struktury modelu matematycznego należącego do określonej klasy modeli, np.:

$$y = b_1 + b_2x$$

$$y = b_1 + b_2x + b_3x^2$$

$$y = b_1 + b_2x_1 + b_2x_2 + b_3x_1x_2$$

2) estymacja nieznanymi parametrów modelu:  $b_1, b_2, \dots$

Struktura modelu określa model z dokładnością do skończonej ilości nieznanymi parametrów. Parametry modelu są to wartości stałych liczbowych w nim występujące. Estymację nieznanymi parametrów modelu przeprowadza się na podstawie pomiarów wielkości wejściowych i wyjściowych identyfikowanego obiektu.

W praktyce identyfikację obiektów statycznych przeprowadza się najczęściej następująco:

- część pomiarową na podstawie eksperymentu czynnego (zwłaszcza planowanego jako bardziej efektywnego);
- część obliczeniową w oparciu o analizę czynnikową lub analizę regresyjną stosowaną przy skomplikowanych planach oraz dla eksperymentu nieplanowanego.

Występowanie silnych zakłóceń na obiekcie nie pozwala często na przeprowadzanie zaplanowanego cyklu doświadczeń. Zastosowanie w takich wypad-

kach eksperymentu nieplanowanego prowadzi do zanęjszenia efektywności eksperymentu a także do korzystania z bardziej skomplikowanego aparatu matematycznego.

Stosowanie analizy czynnikowej praktycznie silnie uzależnia uzyskaną strukturę modelu od realizowanego planu. Powoduje więc tym samym niejednokrotnie dużą rozbieżność pomiędzy strukturą modelu a strukturą identyfikowanego obiektu. Wykorzystanie analizy regresyjnej pozwala na estymację parametrów arbitralnie wybranego modelu.

Prawidłowy dobór modelu decyduje o powodzeniu przeprowadzanej identyfikacji. Jedynie w przypadku, gdy znana jest natura zjawisk zachodzących w obiekcie, istnieje możliwość prawidłowego wyboru struktury modelu. Dlatego też opracowano metody doboru struktury modelu przybliżające ją do nieznannej struktury obiektu [2].

Aby model dobrze opisywał obiekt, należy uwzględnić jak najwięcej wejść, od których zależy wyjście obiektu. Jednak duża liczba wejść powoduje:

- skomplikowania modelu;
- zwiększenie pracochłonności obliczeń;
- podniesienie kosztu badań.

W związku z tym uwzględnia się zwykle tylko najistotniejsze wejścia, aby model był wystarczająco dokładny i w miarę możności mało skomplikowany.

Istnieje kilka metod doboru struktury modelu:

- metoda wszystkich możliwych regresji,
- metoda odrzucania,
- metoda dołączania,
- metoda dołączania i odrzucania,
- metody mieszane,
- metoda badania odchyleń.

Wybór konkretnej metody doboru modelu dla identyfikowanego obiektu uzależniony jest praktycznie od informacji, jakie posiadamy o danym obiekcie, a także od praktyki i doświadczenia osoby przeprowadzającej identyfikację.

Ogólnie zalecana jest przez autorów [2] i [9] metoda dołączania i odrzucania. Wymaga ona jednak, podobnie jak i pozostałe metody, znacznych mocy obliczeniowych.

## 2. Metoda selekcji grupowej wejść


### 2.1. Omówienie metody

Interesujące prace dotyczące nowych metod identyfikacji w oparciu o przesłanki heurystyczne zapoczątkowano w ZSRR, a obecnie podejmowane są również w innych państwach.

Aktualnie istnieje kilka modyfikacji metody opracowanej przez A.G. Iwanchnienko, a nazwanej przez autora "metodę selekcji grupowej wejść" [3].



Metoda ta umożliwia budowę modeli liniowych lub nieliniowych obiektów jedno- jak i wielowymiarowych. Nie posiada ona jeszcze dostatecznej podbudowy matematycznej. Istota tej metody jest następująca:



Rozpatrzmy dowolny obiekt o  $m$  wielkościach wejściowych i jednej wielkości wyjściowej (rys. 1). Załóżmy, że wykonano  $n$  doświadczeń. Wyniki pomiarów wejść i wyjścia obiektu otrzymane z  $n$  doświadczeń tworzą zbiór danych doświadczalnych:

Rys. 1. Schemat blokowy dowolnego obiektu wielowymiarowego

$x_{11}$	$x_{12}$	$x_{13}$	...	$x_{1j}$	...	$x_{1n}$
$x_{21}$	$x_{22}$	$x_{23}$	...	$x_{2j}$	...	$x_{2n}$
$x_{31}$	$x_{32}$	$x_{33}$	...	$x_{3j}$	...	$x_{3n}$
.....						
$x_{k1}$	$x_{k2}$	$x_{k3}$	...	$x_{kj}$	...	$x_{kn}$
.....						
$x_{m1}$	$x_{m2}$	$x_{m3}$	...	$x_{mj}$	...	$x_{mn}$
$y_1$	$y_2$	$y_3$	...	$y_j$	...	$y_n$

gdzie:

- $m$  - ilość wejść na obiekt,
- $n$  - ilość wykonanych doświadczeń,
- $j$  - numer doświadczenia ( $j = 1, 2, \dots, n$ ),
- $k$  - numer wejścia ( $k = 1, 2, \dots, m$ ),

$$\begin{bmatrix} x_{1j} \\ x_{2j} \\ x_{3j} \\ \vdots \\ x_{kj} \\ \vdots \\ x_{mj} \\ y_j \end{bmatrix}$$

- wektor wyników  $j$ -tego doświadczenia,

$X_{k1} \ X_{k2} \ X_{k3} \ \dots \ X_{kj} \ \dots \ X_{kn}$  - wektor wyników k-tej wielkości wejściowej dla n doświadczeń.

Zbiór ten należy podzielić na dwa zbiory: zbiór uczący i zbiór sprawdzający. Podziału tego można dokonać arbitralnie, jeżeli dane doświadczalne nie są obciążone zbyt dużymi błędami pomiarowymi i na obiekt działają małe zakłócenia lub gdy ich brak.

Ogólnie zaleca się podział zbioru danych doświadczalnych według wielkości:

$$D_j^2 = \sum_{k=1}^m x_{kj}^2$$

gdzie:

- m - ilość wejść na obiekt,
- j - numer doświadczenia ( $j = 1, 2, \dots, n$ ),
- k - numer wejścia ( $k = 1, 2, \dots, m$ ),
- $x_{kj}$  - wartość standaryzowana k-tej wielkości wejściowej w j-tym doświadczeniu,

$$x_{kj} = \frac{x_{k1} - \bar{x}_k}{\bar{x}_k}$$

- $x_{kj}$  - wartość k-tej wielkości wejściowej w j-tym doświadczeniu,
- $\bar{x}_k$  - wartość średnia wyników n doświadczeń dla k-tego wejścia.

Do zbioru uczącego zalicza się doświadczenia, które mają dużą wartość  $D_j^2$ , a do zbioru sprawdzającego - mniejszą. Stosunek liczby doświadczeń w zbiorze uczącym do liczby doświadczeń w zbiorze sprawdzającym powinien wynosić od 1:1 do 2:1. Podziału tego można dokonać też następująco:

- obliczyć wartość  $D_j^2$  dla wszystkich doświadczeń;
- doświadczenia uporządkować według wzrastającej wartości wielkości  $D_j^2$  i ponumerować;
- dane z doświadczeń o numerach parzystych tworzą zbiór uczący a pozostałe - zbiór sprawdzający.

Zbiory te poszerza się poprzez wprowadzenie kilku fikcyjnych wejść (np. iloczynny i kwadraty wejść naturalnych).

Wyznaczenie modelu statycznego metodą A.G. Iwachnienki odbywa się sekwencyjnie, w szeregu etapach zwanych stopniami selekcji. Dla każdego stopnia selekcji:

- wyznacza się dla każdej pary wejść metodą najmniejszych kwadratów parametry modeli cząstkowych o złożonej strukturze liniowej



$$Y = b_1 + b_2x_1 + b_3x_2$$

lub nieliniowej

$$Y = b_1 + b_2x_1 + b_3x_2 + b_4x_1x_2 + b_5x_1^2 + b_6x_2^2$$

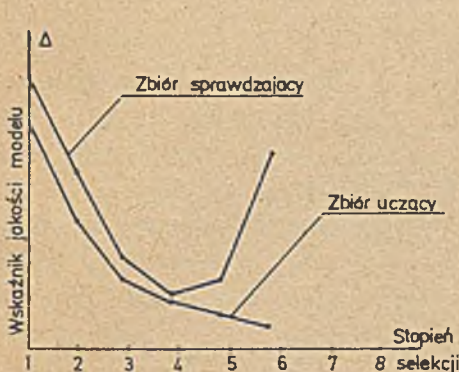
korzystając z danych zawartych w zbiorze uczącym,

- uzyskane modele cząstkowe sprawdza się na danych ze zbioru sprawdzającego w celu wyselekcjonowania tych spośród wyznaczonych modeli cząstkowych, które spełniają określone kryterium jakości modelu.


Jako wskaźnik jakości modelu wykorzystuje się parametry statystyczne, jak np.:

- sumę kwadratów odchyień (SKO) wielkości wyjściowych modelu od rzeczywistych wielkości wyjściowych,
- współczynnik korelacji  $K_{yy}$  - określony jako zależność statystyczną między wielkością wyjściową z modelu a rzeczywistą wielkością wyjściową z obiektu. Kryterium jakości modelu dla pierwszego wskaźnika żąda, by SKO było mniejsze od pewnej wartości granicznej (SKO) gr. - a dla drugiego wskaźnika żąda, by  $K_{yy}$  było większe od pewnej wartości granicznej ( $K_{yy}$ ) gr. Wartość graniczna parametru statystycznego przyjęta dla danego stopnia selekcji nazywa się progiem selekcji,
- wyjścia modeli cząstkowych wyselekcjonowanych na danym stopniu selekcji uważa się za wejścia modeli na następny stopień selekcji.

Proces ten powtarza się aż do momentu, gdy nastąpi pogorszenie się wskaźnika jakości modelu (rys. 2) lub (rys. 3) maleje stopień uwarunkowania od-



Rys. 2. Zależność wskaźnika jakości modelu w funkcji ilości stopni selekcji dla modeli cząstkowych kwadratowych [1] i [3]



Rys. 3. Zależność wskaźnika jakości modelu w funkcji ilości stopni selekcji dla modeli cząstkowych liniowych [1] i [3]



wracanej macierzy poniżej  $10^{-6}$  (oznacza to, że zbiór wyjść modeli cząstkowych poprzedniego stopnia selekcji jest niemal liniowo zależny).

Optymalną wartość wskaźnika jakości modelu uzyskuje się na stopniu selekcji poprzedzającym stopień selekcji, na którym następuje pogorszenie się wskaźnika jakości modelu (rys. 2, rys. 3).

Liczbę stopni selekcji potrzebną do znalezienia szukanego modelu ocenie się zgrubnie według następującej zasady: przy trzech wejściach optymalną wartość wskaźnika jakości modelu powinno się otrzymać na drugim stopniu, przy czterech - nie dalej niż na trzecim itd.

Jako model badanego obiektu wybiera się funkcję regresji z ostatniego stopnia selekcji dającą najlepszą aproksymację danych pomiarowych; funkcję tę wyraża się jako funkcję zmiennych wejściowych pierwszego stopnia selekcji. Proces obliczeniowy tworzenia modelu cząstkowego dla każdej pary wyjść wymaga obliczania macierzy  $6 \times 6$  dla modeli nieliniowych, a macierzy  $3 \times 3$  dla modeli liniowych. Jest to więc łatwe do zrealizowania na maszynie cyfrowej.

Zastosowanie klasycznej metody identyfikacji ogranicza się z reguły do zadań z liczbą wejściowych argumentów  $n \leq 7$ . Przedział ten dla metody selekcji grupowej wyjść jest znacznie większy,  $n \leq 100$  [3]. Ograniczenia te spowodowane są komplikowaniem się procesu obliczeniowego dla zadań o dużej liczbie wejściowych argumentów.

## 2.2. Stosowane kryteria selekcji

W algorytmach metody selekcji grupowej wyjść dla identyfikacji obiektów statycznych jako kryterium jakości modelu stosuje się kryterium regularności lub kryterium niezmienności. Dla kryterium regularności wskaźnikiem jakości modelu jest błąd średniokwadratowy

$$\Delta = \sqrt{\frac{1}{P} \sum_{j=1}^P (\varphi_j - \gamma_j)^2}$$

gdzie:

$P$  - liczba doświadczeń w zbiorze sprawdzającym,

$\bar{\varphi}_j$  - określona modelem wartość wielkości wyjściowej w  $j$ -tym doświadczeniu ( $j = 1, 2, \dots, P$ ),

$\gamma_j$  - wartość wielkości wyjściowej uzyskana z pomiarów w  $j$ -tym doświadczeniu.

Kryterium regularności żąda, aby błąd średniokwadratowy obliczony na zbiorze sprawdzającym był mniejszy od pewnej wartości granicznej  $\Delta_{gr}$ .

Wykres krzywej wartości błędu średniokwadratowego w funkcji ilości stopni selekcji charakteryzuje się dużą regularnością przebiegu. Dla kryterium

niezmienności według propozycji B.K. Swiateckiego [7] jako wskaźnik jakości modelu wykorzystuje się wartość odpowiednio określonego wskaźnika niezmienności  $n_{nz}$ . Kryterium niezmienności żąda, aby wskaźnik niezmienności  $n_{nz}$  był mniejszy od pewnej wartości granicznej ( $n_{nz}$ ) gr.

Przy korzystaniu z kryterium niezmienności należy na podstawie zbioru danych doświadczalnych:

- obliczyć wartość  $D_j^2$  dla każdego doświadczenia;
- doświadczenia uporządkować według wzrastającej wartości  $D_j^2$  i ponumerować;
- dokonać podziału tego zbioru na dwie części; doświadczenia z parzystymi numerami tworzą pierwszy zbiór danych  $A_1(R_1)$ , a z nieparzystymi - drugi  $A_2(R_2)$  gdzie:

$R_1$  - liczba doświadczeń w zbiorze  $A_1$ ,

$R_2$  - liczba doświadczeń w zbiorze  $A_2$ .

Zbiór  $A_1(R_1)$  przyjmujemy jako zbiór uczący, a zbiór  $A_2(R_2)$  - sprawdzający. Otrzymane modele cząstkowe oznaczamy przez  $y_k^* = f(x_1, x_j)$ .

Następnie postępujemy odwrotnie; zbiór  $A_1(R_1)$  traktujemy jako zbiór sprawdzający, a zbiór  $A_2(R_2)$  - uczący. Otrzymane przy tym modele cząstkowe oznaczmy przez  $y_k^{**} = f(x_1, x_j)$ . Każdy z otrzymanych modeli ocenia się według wartości wskaźnika niezmienności obliczonego na wszystkich punktach obu zbiorów:

$$n_{nz_{1k}} = \frac{1}{R_1 + R_2} \sum_{r=1}^{r=R_1+R_2} (y_{r_k}^* - y_{r_k}^{**})^2$$

gdzie:

k - numer modelu cząstkowego otrzymanego na danym stopniu selekcji.

Ze wszystkich modeli cząstkowych otrzymanych na pierwszym stopniu selekcji wybieramy F modeli cząstkowych, które mają małą wartość  $n_{nz_1}$ .

Dla pierwszego stopnia selekcji według kryterium niezmienności wyznacza się średni wskaźnik niezmienności wybieranych F najbardziej niezmiennych modeli cząstkowych:

$$N_{nz_1} = \frac{1}{F} \sum_{k=1}^{k=F} n_{nz_{1k}}$$

Następne stopnie selekcji zbudowane są tak samo jak i pierwszy.



Na drugim stopniu selekcji otrzymujemy modele cząstkowe o postaci

$$z_k^* = f(y_1, y_j); \quad z_k^{**} = f(y_1, y_j)$$

Wskaźnik niezmienności dla oceny każdego modelu cząstkowego otrzymanego na drugim stopniu selekcji wyraża się wzorem

$$y_{nz_{2k}} = \frac{1}{R_1 + R_2} \sum_{r=1}^{r=R_1+R_2} (z_{r_k}^* - z_{r_k}^{**})^2$$


a średni wskaźnik niezmienności

$$N_{nz_2} = \frac{1}{F} \sum_{k=1}^{k=F} n_{nz_{2k}}$$


Proces obliczeniowy trwa tak długo, jak długo średni wskaźnik niezmienności maleje. Wartość zerową wskaźnik niezmienności  $n_{nz}$  osiąga tylko w przypadku nieobecności zakłóceń w wyjściowych danych.

Kryterium regularności dla celów identyfikacji obiektów statycznych należy stosować przy występowaniu małych zakłóceń (rys. 4).

W wypadku występowania dużych zakłóceń działających na obiekt zaleca się stosować kryterium niezmienności współczynników (rys. 5). Zwiększenie zakłóceń powoduje wygięcie się krzywych, lecz minimum pozostaje na tym samym miejscu. Istotną zaletą tego kryterium jest także mniejsza wrażliwość na sposób podziału danych pomiarowych na zbiór uczący i sprawdzający.



Rys. 4. Zależność wyboru modelu według kryterium regularności od stopnia zakłóceń danych pomiarowych [7]



Rys. 5. Zależność wyboru modelu według kryterium niezmienności od stopnia zakłóceń danych pomiarowych [7]



### 3. Ogólny algorytm identyfikacji obiektów statycznych

Obecnie istnieje kilka algorytmów identyfikacji charakterystyk statycznych obiektów wielowymiarowych opracowanych na zasadach selekcji grupowej wejść. Dotyczą one jednak tylko rozwiązywania konkretnych przykładów obiektów. Brak jest natomiast ogólnego algorytmu umożliwiającego identyfikację różnych obiektów.

W związku z tym opracowano w oparciu o metodę heurystycznej identyfikacji ogólny algorytm nadający się do identyfikacji charakterystyk statycznych obiektów wielowymiarowych na maszynach cyfrowych serii ODRA 1300.

Opracowano również dla tego algorytmu program OBIEKT napisany w języku FORTRAN 1900, umożliwiający wygodne przeprowadzenie obliczeń oraz cechujący się łatwością adaptacji do stosowania różnych wskaźników oceny jakości modeli cząstkowych. Program OBIEKT został napisany w formie bloku programowego. Zawiera on kilka odrębnych programów, tworzących w sumie całość programu OBIEKT, realizujących poszczególne etapy obliczeń.

Taka struktura programu OBIEKT umożliwia przeprowadzenie w prosty sposób obliczeń nawet dla bardzo skomplikowanego obiektu statycznego.

Uzywane wyniki obliczeń na poszczególnych etapach wyprowadzane są na taśmy magnetyczne w postaci rekordów niezredagowanych. Stamtąd pobierane są do pamięci maszyny tylko te dane, które są niezbędne w danym momencie do wykonania dalszych obliczeń.

Program OBIEKT sprawdzono na szeregu przykładach literaturowych, a aktualnie przeprowadzane są na nim badania oddziały filtracji bikarbonatu sodowego.

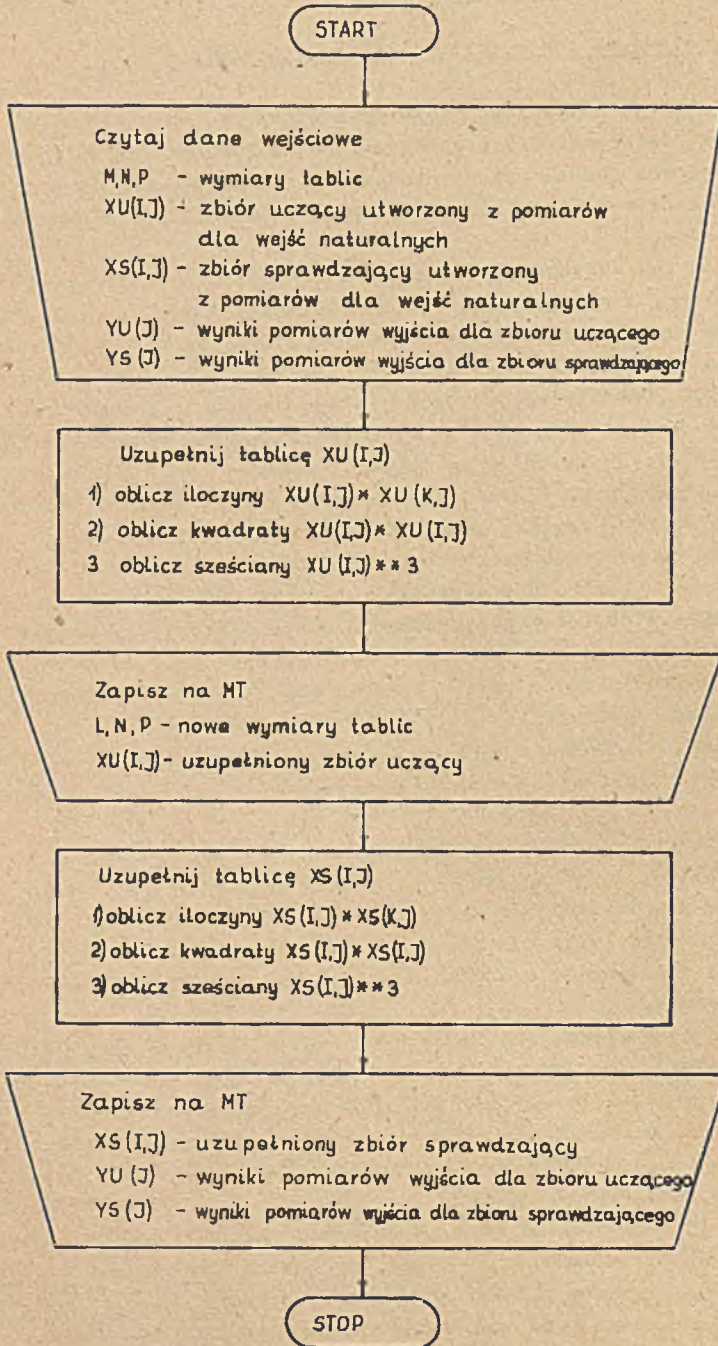
Schematy blokowe algorytmu przedstawiono na rysunkach 6, 7, 8, 9 i 10. Podają one realizację na maszynie cyfrową takiego algorytmu z wykorzystaniem kryterium regularności. Podziału zbioru danych pomiarowych na zbiór uczący i sprawdzający dokonuje się arbitralnie (w przypadku występowania bardzo słabych zakłóceń na obiekcie lub ich braku) bądź też sposobami omówionymi poprzednio.

Otrzymane w wyniku podziału zbiory:  $XU(I,J)$  - zbiór uczący,  $XS(I,J)$  - zbiór sprawdzający uzupełnia się poprzez wprowadzenie dodatkowych wejść.

Rys. 6 przedstawia schemat blokowy programu uzupełniania zbiorów  $XU(I,J)$  i  $XS(I,J)$  poprzez wprowadzenie wejść fikcyjnych. Otrzymane tablice zostają wysyłane na taśmę magnetyczną, przy czym stanowią one właściwe zbiory danych używane do dalszych obliczeń.

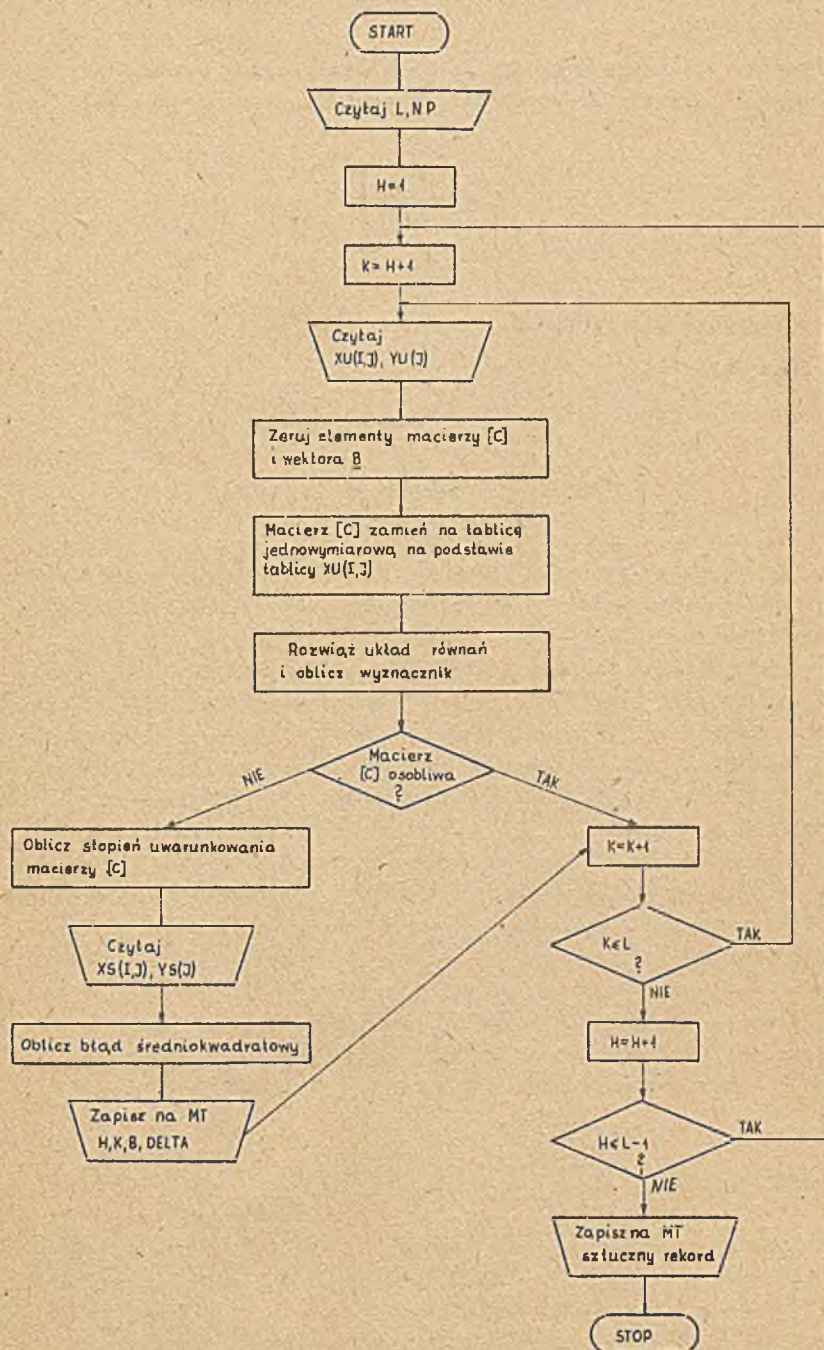
Rys. 7 przedstawia schemat blokowy programu obliczeń przedprogowych. Następuje tutaj łączenie wszystkich wejść (naturalne + fikcyjne) w pary na wszystkie możliwe sposoby. Liczba tworzonych kombinacji wynosi  $\frac{L(L-1)}{2}$ . Jeżeli w trakcie obliczeń kolejnego modelu cząstkowego wystąpi macierz słaba lub uwarunkowana, zostaje to zasygnalizowane przez program i następuje przejście do rozpatrywania następnej kombinacji par wejść.





Rys. 6. Schemat blokowy programu uzupełniania zbioru uczącego i zbioru sprawdzającego





Rys. 7. Schemat blokowy programu obliczeń przedprogowych



Sprawdzanie stopnia uwarunkowania macierzy dokonywane jest w programie dwukrotnie poprzez:

- podprogram rozwiązujący układ równań i obliczający wyznacznik;
- zastosowanie kryterium uwarunkowania macierzy według Foka [3]

$$K = \left| \frac{\Delta}{C^M} \right|$$

gdzie:

$\Delta$  - wyznacznik macierzy  $A$ ;

$M$  - rząd macierzy

$$C = \left| \frac{\sum_{1,1} a_{1j}^2}{M} \right|, \quad A = \left[ a_{1j} \right]_1^M, \quad 0 < K < 1$$

Wszystkie modele cząstkowe sprawdzane są na danych ze zbioru sprawdzającego. Wyniki wyprowadza się na taśmę magnetyczną w postaci rekordów niezredagowanych.

Rys. 8 przedstawia schemat blokowy programu WYBOR umożliwiającego wybór określonej liczby przepuszczanych przez próg modeli cząstkowych. Program ten dokonuje selekcji otrzymanych modeli cząstkowych. Następuje w nim analiza każdego modelu cząstkowego pod kątem stosowanego kryterium jakości modelu i wybranie  $L_2$  najlepszych modeli cząstkowych,  $L_2$  - jest z góry założone.

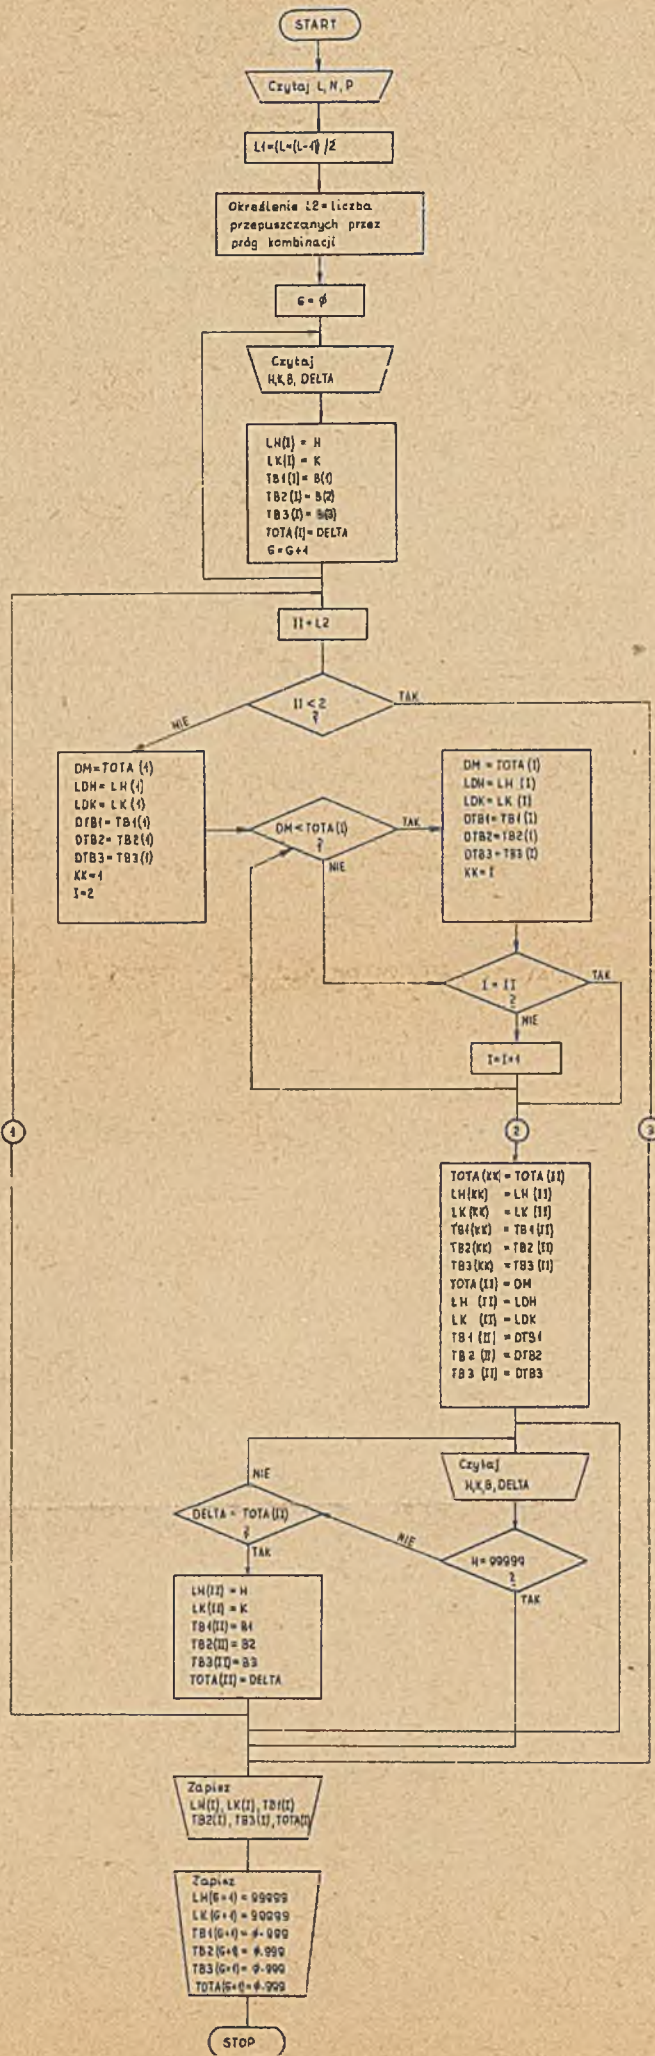
Rys. 9 przedstawia schemat blokowy obliczeń poprogowych. Program ten oblicza wyjścia wybranych modeli cząstkowych, przygotowuje nowe zbiory wejściowe (zbiór uczący i sprawdzający) dla następnego stopnia selekcji. Na podstawie nowo obliczonych tablic tworzy się wszystkie możliwe modele cząstkowe, które są potem analizowane jak poprzednio.

Dalsze obliczenia przeprowadza się wykorzystując na przemian program WYBOR (rys. 8) oraz program przedstawiony na rys. 9. W końcowym etapie poszukiwań otrzymuje się szukany model identyfikowanego obiektu.

#### 4. Uwagi końcowe

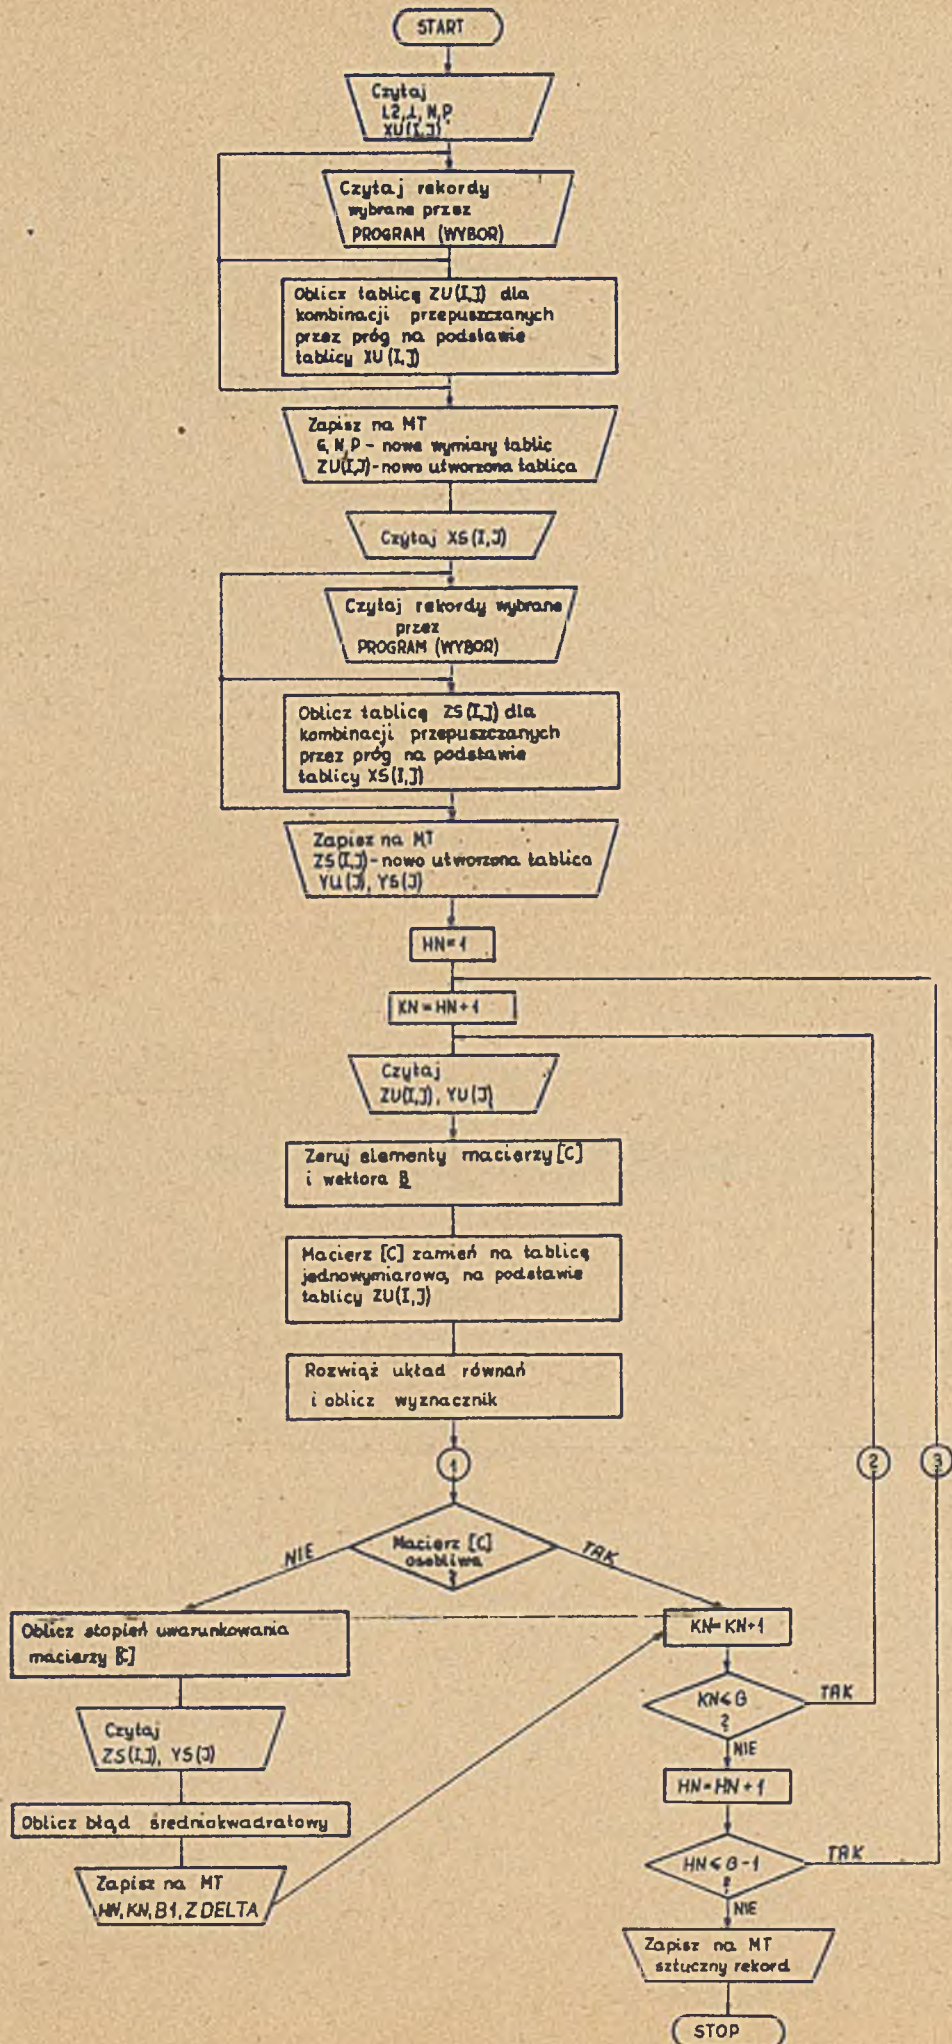
Przeprowadzenie selekcji przy z góry narzuconej wartości granicznej wskaźnika jakości modelu (np. błędu średniokwadratowego) jest niewygodne w praktyce (rys. 10). Trudno jest przewidzieć, jaką należy przyjąć wartość graniczną wskaźnika jakości modelu na każdym stopniu selekcji dla identyfikacji konkretnego obiektu.





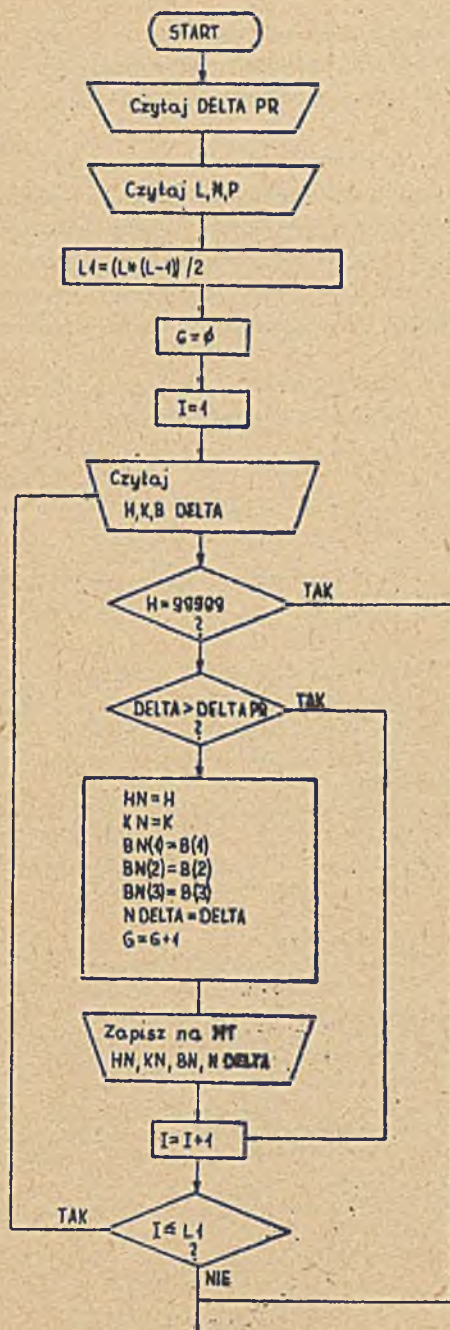
Schemat blokowy programu WYBOR





Rys. 9. Schemat blokowy programu obliczeń poprogowych





dalszy ciąg programu

Rys. 10. Schemat blokowy fragmentu programu przeprowadzania selekcji mode li cząstkowych przy z góry narzuconej wartości granicznej błędu średnio-kwadratowego



Normalnie dokonuje się tego metodą prób. Niekiedy obliczenia należy przeprowadzać wielokrotnie, dobierając różne wartości graniczne wskaźnika jakości modelu, kierując się dokładnością uzyskiwanych w każdej z prób modeli końcowych.

W związku z tym wyżej przedstawiony sposób (poprzez zastosowanie programu WYBOR) jest o wiele wygodniejszy dla przeprowadzania selekcji modeli cząstkowych na poszczególnych stopniach. Uniezależnia on nas od przewidywania wartości granicznej wskaźnika jakości modelu dla każdego stopnia selekcji. Wybór określonej ilości najlepszych modeli cząstkowych pod kątem stosowanego kryterium jakości modelu zostaje powierzony maszynie cyfrowej.

Przeprowadzone do tej pory badania wskazują na celowość stosowania takiego algorytmu do identyfikacji założonych obiektów statycznych.

#### LITERATURA

- [1] Bieliński H.: Właściwości heurystycznego algorytmu identyfikacji wg Iwachnienki i jego zastosowanie do identyfikacji filtra kwaśnego węgla sodu w procesie sodowym. Pomiarzy-Automatyka-Kontrola nr 5, Warszawa 1976.
- [2] Draper N.R., Smith H.: Analiza regresji stosowana. PWN, Warszawa 1973.
- [3] Iwachnjenko A.G.: Sistjemy ewristycznej samoorganizacji w tjechniczjeskiej kibjernjetikke, Izdatjelstwo "Tjechnika", Kijew 1971.
- [4] Iwachnjenko A.G., Łapa W.G.: Prjedakazanije sluczajnych procjessow Izdatjelstwo "Naukowa Dumka", Kijew 1971.
- [5] Iwachnjenko O.G.: Mjetod grupowego wrachuwannja argumentiw - konkurjent mjetodu stochasticznoj aproksimacij. Awtomatika nr 3, Kijew 1969.
- [6] Iwachnjenko O.G., Koppa Ju.W.: Rjegularizacija roz'jazujuczich funkcij u mjetodi grupowego wrachuwannja argumentiw, Awtomatika nr 2, Kijew 1970.
- [7] Iwachnjenko O.G., Szjerwaszidzje W.W., Szjeludko O.I., Patjerjeu S.G., Iwachnjenko N.O.: Widkrittja fizicznich zakoniw mjetodom MGWA za kritjeriem njezmieszczennosti, Awtomatika nr 6, Kijew 1973.
- [8] Iwachnjenko A.G., Iwachnjenko N.A.: Tjeorija samoorganizacji kak osnowanije prjamogo modjelirowanija sloznych sistjem po ekapjerimentalnym dannym, Kibjernjetika i Wyczielitjelnaja Tjechnika, Wypusk 32, izdatjelstwo "Naukowa Dumka", Kijew 1976.
- [9] Mańczak K., Arczewka W.: Metody automatycznego doboru struktury modelu regresji. Prace VI Krajowej Konferencji Automatyki, tom 1, sesje 1-9, Ministerstwo Nauki, Szkolnictwa Wyższego i Techniki, PAN Poznań, 9-11 września 1974.
- [10] Pawlow O.O.: Kritjerij ranzirowki dlja porogowego samowidboru zmjnych w algoritmach MGWA. Awtomatika nr 4, Kijew 1969.



ОБЩИЙ АЛГОРИТМ ЭВРИСТИЧЕСКОГО МЕТОДА ИДЕНТИФИКАЦИИ  
СТАТИЧЕСКИХ ХАРАКТЕРИСТИК СЛОЖНЫХ ОБЪЕКТОВ

## Р е з ю м е

В статье описывается эвристический метод идентификации статических характеристик объектов с использованием критерия регулярности и критерия неизменяемости. Представлен разработанный общий алгоритм, делающий возможным проведение идентификации различных объектов на электронно-вычислительной машине. Описывается также разработанная для этих целей программа "объект", написанная на языке фортран 1900.

THE GENERAL ALGORITHM OF THE HEURISTIC IDENTIFICATION  
METHOD OF THE STATIC CHARACTERISTIC OF MULTIVARIABLE SYSTEMS

## S u m m a r y

In this article a heuristic method of identification objects through the regularity criterion and the displacement criterion has been discussed.

There has been described a general algorithm of series structure which makes possible the identification of different objects on the digital computer. For the same purpose, the program OBIEKT described in language FORTRAN is also presented.