ZESZYTY NAUKOWE POLITECHNIKI ŚLĄSKIEJ 1989

Seria: AUTOMATYKA z. 93 Nr kol. 969

Damian HERNIK

MODELOWANIE MATEMATYCZNE CHARAKTERYSTYK PRZETWORNIKÓW POMIAROWYCH METODĄ GRUPOWEJ EWIDENCJI ARGUMENTÓW

Streszczenie. W pracy proponuje się zastosowanie metody grupowej ewidencji argumentów (MGEA) do modelowania matematycznego charakterystyk przetworników pomiarowych. Opierając się na iteracyjnym algorytmie MGEA proponuje się system modelowania obiektów na bazie danych empirycznych. Na podstawie opracowanego systemu przeprowadza się modelowanie rezonansowego czujnika wilgotności papieru.

1. Wstęp

Współczesny rozwój nauki i techniki, całkowita automatyzacja procesów technologicznych niejako wymusza konstruowanie i wytwarzanie czujników i systemów pomiarowych pozwalających kontrolować, sterować i przetwarzać informację o szybko zmieniających się procesach. Opracowanie takich systemów pomiarowych wymaga sporządzenia i zbadania adekwatnych modeli matematycznych. Jednakże często wiarygodna informacja o przebiegu badanych procesów jest niewystarczająca dla zastosowania tradycyjnych metod statystycznych. Związane to jest ze złożonością systemów pomiarowych i procesów w nich przebiegających, koniecznością prowadzenia badań w warunkach dynamicznych przy występowaniu zakłóceń, przy czym badania nie zawsze można dopełnić lub powtórzyć. Takie warunki wymagają zastosowania metody sprowadzającej wiarygodną a priori informację do minimum. Wymagania powyższe spełnia metoda grupowej ewidencji argumentów (MGEA) oparta na teorii samoorganizacji modeli na komputerach [1].

Modele matematyczne złożonych systemów lub procesów można również otrzymać stosując metody analizy regresji [2-4] lub inne [5]. Jednak wykorzystywane w nich kryteria (statystyczne - np. kryterium Fishera, informacyjne - np. kryterium Akaike AIC [6] i in.) wymagają przyjęcia specjalnych założeń statystycznych (własności populacji generalnej, poziom ufności, rodzaj rozkładu zakłóceń i in. [2-6]), które często trudno sprawdzić w praktyce. Kryteria stosowane w algorytmach MGEA nie wymagają przyjęcia powyższych założeń. Dlatego w pracy proponuje się zastosowanie MGEA do modelowania matematycznego charakterystyk przetworników pomiarowych (PP).

2. Modelowanie metodą grupowej ewidencji argumentów

Teoria samoorganizacji pozwala w sposób racjonalny zrealizować przegląd (selekcję) wielu wariantów modeli matematycznych w celu dokonania wyboru modelu optymalnego wg zadanego kryterium. Oparta jest na dwóch zasadach:

- zasada dopełnienia zewnętrznego; tylko kryteria zewnętrzne, oparte na nowej informacji, pozwalają odnaleźć rzeczywisty model obiektu ukryty w danych z szumami;
- zasada nieostatecznych rozwiązań D. Gabora [8]; każda procedura jednorzędowa może być zamieniona wielorzędową (iteracyjną) pod warunkiem zachowania wystarczającej "dowolności wyboru" kilku najlepszych rozwiązań z każdego poprzedniego rzędu.

MGEA zalicza się do metod modelowania strukturalnego na podstawie danych empirycznych. Jednak algorytmy MGEA realizują równocześnie modelowanie parametryczne i strukturalne wg następującego schematu: generowanie modeli różnego stopnia złożoności, estymacja ich parametrów, wybór modelu o złożoności optymalnej. Rozwiązanie obydwu problemów wymaga zastosowania przynajmniej dwóch kryteriów: jednego do estymacji parametrów, drugiego do wyboru modelu o złożoności optymalnej. W algorytmach MGEA do estymacji parametrów najczęściej stosuje się metodę najmniejszych kwadratów. Wyboru modeli dokonuje się na podstawie kryterium zewnętrznego, którego minimum, zgodnie z teorią samoorganizacji, określa model o złożoności optymalnej [1].

Zastosowanie kryterium zewnętrznego wymaga nowej informacji. Dlatego w algorytmach MGEA dokonuje się podziału danych empirycznych przynajmniej na dwie części (ciągi): ciąg uczący i ciąg sprawdzający. Ciąg uczący służy do estymacji parametrów, ciąg sprawdzający - do wyboru modelu optymalnego. Sposób podziału danych empirycznych na ciągi zależy od wybranego kryterium selekcji i od warunków (statycznych lub dynamicznych) eksperymentu [1, 9].

Strukturę iteracyjnego algorytmu MGEA można przedstawić w sposób następujący [10] (rys. 1): Argumenty algorytmu $x_1, x_2, \ldots, x_n$ zestawia się w zerowej iteracji zgodnie z zadanym zbiorem modeli M podlegających przeglądowi. Zbiór modeli M zadaje się wielomianem liniowym

$$y = a_o + \sum_{i=1}^{n} a_i x_i \tag{1}$$

Wyrazy wielomianu (1) wchodzą w zestaw argumentów, a ich dowolna kombinacja tworzy elementy zbioru M.

W pierwszej iteracji zestawia się opisy (modele) cząstkowe wszystkich kombinacji argumentów parami, przybliżające wg metody najmniejszych kwadratów zmienną wyjściową y:

$$z_1^1 = f(x_1, x_2); \quad z_2^1 = f(x_1, x_3); \ \ldots \ z_p^1 = f(x_{n-1}, x_n).$$

Spośród wszystkich $p = C_n^2$ modeli danej iteracji wybiera się F1 najlepszych wg znaczenia kryterium zewnętrznego.

W drugiej iteracji otrzymane modele $(z_1^1, z_2^1, \ldots, z_{F1}^1)$ tworzą zestaw argumentów drugiej iteracji i ponownie zestawia się modele cząstkowe, będące funkcją dwóch argumentów:

$$z_1^2 = f(z_1^1, z_2^1); \quad z_2^2 = f(z_1^1, z_3^1), \ \ldots \ z_l^2 = f(z_{F1-1}^1, z_{F1}^1); \quad l = C_{F1}^2.$$

Spośród nich wybiera się F2 najlepszych modeli, które tworzą zestaw argumentów w następnej iteracji itd. Narastanie iteracji następuje do momentu osiągnięcia przez kryterium zewnętrzne minimum.

Modele cząstkowe mogą być zarówno liniowymi (np. $f(x_i, x_j) = a_o + a_1 x_i + a_2 x_j$), jak i nieliniowymi (np. $f(x_i, x_j) = a_o + a_1 x_i + s_2 x_j + a_3 x_i x_j$) funkcjami dwóch zmiennych.

Z przedstawionego opisu wynika, że wiarygodna a priori informacja, potrzebna do modelowania na podstawie danych empirycznych wg MGEA, sprowadza się do zadania zbioru modeli M i wyboru kryterium selekcji. Należy w tym miejscu zwrócić uwagę na bardzo ważną zaletę iteracyjnego algorytmu MGEA. Pozwala on modelować obiekty lub procesy w przypadku, gdy liczba argumentów (n) wchodząca w skład syntetyzowanego modelu jest większa od liczby pomiarów (N) parametrów obiektu. Algebraiczne minimum liczby pomiarów określa się długością opisu cząstkowego.

3. System modelowania charakterystyk przetworników pomiarowych na podstawie danych empirycznych

Opierając się na iteracyjnym algorytmie MGEA z liniowymi opisami cząstkowymi można zaproponować następujący system modelowania PP na podstawie danych empirycznych (rys. 2).

Bazę informacyjną danego systemu tworzą zbiory modeli M, kryteria zewnętrzne, a także iteracyjny algorytm MGEA.

Zbiór modeli M można zadać w jednej z następujących postaci:

- wielomianu Kołmogorowa-Gabora [10]:

$$y = a_o + \sum_{i=1}^{k} a_i v_i + \sum_{i=1}^{k}\sum_{j=1}^{k} a_{ij} v_i v_j + \sum_{i=1}^{k}\sum_{j=1}^{k}\sum_{l=1}^{k} a_{ijl} v_i v_j v_l + \ldots \quad (2)$$

gdzie:

k - liczba zmiennych;

- multiplikatywnej:

$$y = p v_1^{a1} v_2^{a2} \ldots v_k^{ak},$$

którą logarytmowaniem można doprowadzić do następującej postaci:

$$\ln y = \ln p + \sum_{i=1}^{k} a_i \ln v_i; \tag{3}$$

- sumy składowych harmonicznych:

$$y = a_o + \sum_{i=1}^{k} a_i \sin\omega_i t + \sum_{j=1}^{k} a_j \cos\omega_j t \tag{4}$$

$\omega_i = i\,\frac{2\pi}{k};\ \omega$

$\omega_i = i\,\frac{2\pi}{k};\ \omega_j = j\,\frac{2\pi}{k};$ k - liczba podprzedziałów, na które dzieli się okres pierwszej harmonicznej;

- liniowego równania różnicowego jednorodnego:

$$y_{v+k} + a_{k-1} y_{v+k-1} + \ldots + a_o y_v = 0 \tag{5}$$

będącego skończonym różnicowym analogiem równania różniczkowego:

$$\frac{d^k y}{dv^k} + a_{k-1} \frac{d^{k-1} y}{dv^{k-1}} + \ldots + a_o y = 0$$

lub w ich kombinacji liniowej (oprócz postaci multiplikatywnej). Taka struktura zbiorów pozwala modelować PP zarówno w warunkach statycznych, jak i dynamicznych.

Kryterium selekcji należy wybrać spośród następujących, najczęściej stosowanych w algorytmach MGEA [11], kryteriów zewnętrznych:

- kryterium zgodności - odzwierciedla wymaganie, aby estymaty zmiennej wyjściowej $\hat{y}_i(A)$ i $\hat{y}_i(B)$ (wyliczone wg danych W) modelu o współczynnikach wyliczonych odpowiednio wg danych A i B, różniły się między sobą minimalnie:

$$n_z^2 = n_z^2(W/A,B) = \sum_{i \in W} \left[\hat{y}_i(A) - \hat{y}_i(B)\right]^2 \longrightarrow \min \tag{6}$$

gdzie:

A - ciąg uczący;

B - ciąg sprawdzający;

$W = A \cup B$;

- kryterium regularności - odzwierciedla wymaganie, aby błąd wyliczony wg danych B modelu o współczynnikach wyliczonych wg danych A, był minimalny:

$$\Delta^2(B) = \Delta^2(B/A) = \sum_{i \in B} \left[y_i - \hat{y}_i(A) \right]^2 \quad \min \tag{7}$$

gdzie:

y_i - empiryczne znaczenie zmiennej wyjściowej y;

- symetryczne kryterium regularności - jest symetryczną formą kryterium regularności:

$$d^2 = \Delta^2(B/A) + \Delta^2(A/B) = \sum_{i \in B} \left[y_i - \hat{y}_i(A) \right]^2 + \sum_{i \in A} \left[y_i - \hat{y}_i(B) \right]^2 \tag{8}$$

Kryteria można stosować zarówno oddzielnie, jak i łącznie lub kolejno, przy czym stosowanie łączne lub kolejno zwiększa ich odporność na zakłócenia [10].

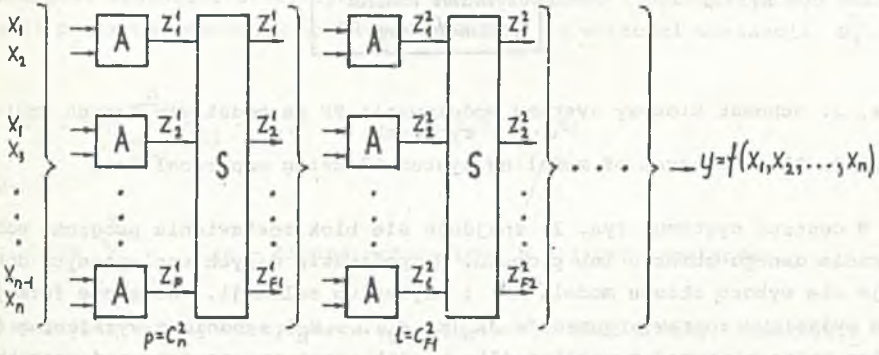

Rys. 1. Struktura iteracyjnego (wielorzędowego) algorytmu MGEA
A - algorytm przetwarzania argumentów parami, S - selekcja progowa najlepszych modeli (w każdej iteracji)
Fig. 1. k-th order iteration structure for MGEA algorithm

Struktura zastosowanego algorytmu została przedstawiona na rys. 1. Opisy cząstkowe mają następującą postać:

$$f(z_i^r, z_j^r) = a_1 z_i^r + a_2 z_j^r,$$

gdzie:

r - numer iteracji,

przy czym w każdej iteracji zestaw argumentów tworzą zarówno najlepsze modele poprzedniej iteracji $z_1^{r-1}, z_2^{r-1}, \ldots, z_{r-1}^{r-1}$, jak i argumenty wyjściowe

$x_1, x_2, \ldots, x_n$ oraz argument $x_o = 1$ (tzw. algorytm CML z udowodnioną zbieżnością wewnętrzną [12]). Dowolność wyboru wg Gabora w każdej iteracji jest równa F1=F2=...=F=n.

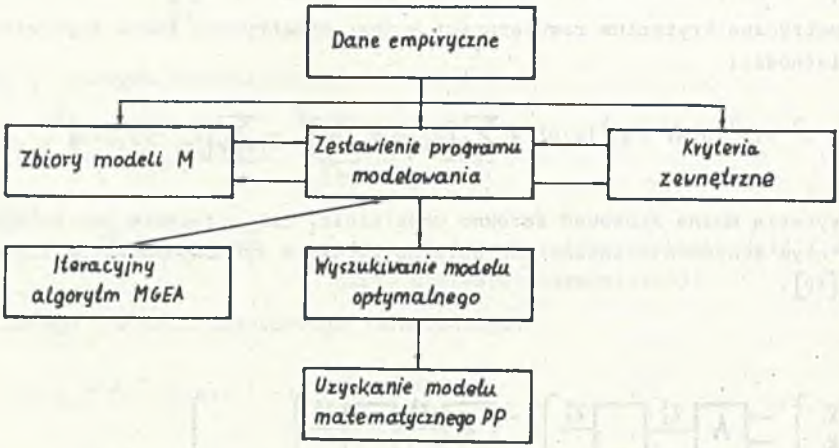

Rys. 2. Schemat blokowy systemu modelowania PP na podstawie danych empirycznych

Fig. 2. Block diagram of modeling system PP using empirical data

W centrum systemu (rys. 2) znajduje się blok zestawienia programu modelowania danego obiektu lub procesu. Na podstawie danych empirycznych dokonuje się wyboru zbioru modeli M i kryterium selekcji. Następnie formuje się wyjściowy zestaw argumentów $X_N(x_1, x_2, \ldots, x_n)$ zgodnie z wyrażeniem (1), które można otrzymać z wyrażeń (2) ... (5) przez zmianę oznaczeń wszystkich wyrazów oraz wprowadza się wektor wartości zmiennej wyjściowej $Y_N(y)$. Na podstawie otrzymanej bazy danych algorytm wyszukuje model o złożoności optymalnej, kierując się jedynie wartością kryterium selekcji. W momencie osiągnięcia przez zadane kryterium minimum, otrzymujemy wymagany model matematyczny.

4. Model matematyczny rezonansowego czujnika wilgotności papieru

Przedstawiony system modelowania PP na bazie danych empirycznych został zastosowany do sporządzenia modelu matematycznego rezonansowego czujnika wilgotności (RCW) stosowanego do pośredniego pomiaru wilgotności różnorodnych obiektów [13]. Zasada działania RCW oparta jest na zależności częstotliwości rezonansowej ω_r układu drgającego czujnika od wilgotności W obiektu. W danym przypadku RCW przeznaczony jest do pomiaru wilgotności papieru i celulozy.

Teoretyczne wyprowadzenie zależności $\omega_r = f(W)$ napotkało duże trudności związane ze złożonością przede wszystkim samych obiektów pomiaru, tj. próbek papieru. Na wielkość ω_r wpływała zarówno gęstość i grubość pomiaru, jak i jego niejednorodna struktura składająca się z włókien absolutnie suchej substancji, powietrza i wody. Dlatego do sporządzenia modelu matematycznego RCW wykorzystano dane empiryczne otrzymane w wyniku przeprowadzonych badań zależności ω_r od następujących parametrów papieru: wilgotności W, gęstości powierzchniowej σ i grubości d (rezultaty badań były już publikowane przez autora w [14]). Przebadano 31 próbek różnego rodzaju papieru z wystarczająco szerokim zakresem zmian jego parametrów ($W = 3,42...9,43\%$, $\sigma = 34,8...194,6$ g/m^2, $d = 63,0...347,5$ μm).

Zgodnie z przesłankami zawartymi w [1, 9], dane empiryczne rozdzielono na ciągi w sposób następujący: ostatnie 3 pomiary tworzą ciąg egzaminujący C służący do sprawdzenia wiarygodności otrzymanego modelu. W celu uzyskania podobieństwa własności statystycznych ciągu uczącego i sprawdzającego pozostałe 28 pomiarów uszeregowano w ciąg malejący wg wartości wariancji D_j^2:

$$D_j^2 = 1/n \sum_{i=1}^{n} (v_{ij} - \bar{v}_i)^2 \qquad (j = 1,2,...,N)$$

gdzie:

$$\bar{v}_i = 1/N \sum_{j=1}^{N} v_{ij} \quad \text{(n - liczba argumentów, N - liczba pomiarów).}$$

Nieparzyste wyrazy otrzymanego szeregu tworzą ciąg uczący, a parzyste - ciąg sprawdzający. Dane empiryczne przedstawiono w tablicy po dokonaniu podziału na ciągu, tj. pomiary z Nr 1-14 tworzą ciąg uczący, z Nr 15-28 - ciąg sprawdzający, a z Nr 29-31 - ciąg egzaminujący

Zestaw argumentów tworzyły wyrazy wielomianu Kołmogorowa-Gabora trzeciego stopnia przy trzech zmiennych v_1, v_2, v_3. Modelowanie przeprowadzono dwukrotnie; w pierwszym przypadku $v_1 = \sigma$, $v_2 = W$, $v_3 = 1/d$, w drugim $v_1 = \sigma$, $v_2 = W$, $v_3 = d$. W obydwu przypadkach liczba argumentów była równa $n = 20$.

Do wyboru modelu o złożoności optymalnej zastosowano kryteria: zgodności i regularności w następujący sposób: W każdej iteracji wg najmniejszej wartości kryterium regularności dokonywano wyboru $F=n=20$ najlepszych modeli danej iteracji. Następnie spośród nich wybierano jeden najlepszy wg najmniejszej wartości kryterium zgodności. Zatrzymanie pracy algorytmu następowało w momencie osiągnięcia przez kryterium zgodności minimum.

W rezultacie modelowania otrzymano następującą zależność:

$$\hat{\omega}_r = 9,544 - 3,399 \cdot 10^{-5}\sigma - 8,914 \cdot 10^{-5}\sigma W + 4,54 \cdot 10^{-9}\sigma W d \qquad (9)$$

Tabela 1

Przykładowe dane empiryczne

Lp.	σ, g/m^2	W, %	d, μm	ω_r, MHz	$\hat{\omega}_r$, MHz
1	2	3	4	5	6
1	100,8	4,82	118,4	9,486	9,498
2	100,2	5,48	121,2	9,496	9,492
3	102,0	8,08	129,4	9,457	9,468
4	70,8	7,66	84,2	9,498	9,494
5	70,7	8,54	85,1	9,489	9,488
6	187,3	6,89	327,9	9,412	9,425
7	194,6	9,07	347,5	9,400	9,383
8	40,0	8,56	64,0	9,512	9,512
9	40,2	7,45	64,0	9,518	9,516
10	60,6	6,43	66,0	9,518	9,508
11	61,3	8,01	67,0	9,490	9,499
12	67,8	9,43	66,0	9,498	9,485
13	51,4	6,60	63,0	9,508	9,512
14	34,8	3,42	63,0	9,532	9,533
15	97,3	4,01	119,9	9,504	9,507
16	101,0	5,94	127,0	9,489	9,488
17	99,6	8,40	123,2	9,447	9,467
18	70,0	4,70	80,8	9,513	9,513
19	69,4	5,26	80,0	9,502	9,510
20	189,1	6,60	308,7	9,423	9,428
21	190,6	7,26	316,3	9,415	9,417
22	50,5	5,22	63,0	9,521	9,519
23	52,0	7,86	63,0	9,497	9,506
24	36,8	8,50	63,0	9,530	9,515
25	56,3	6,24	71,0	9,519	9,511
26	57,6	8,39	72,0	9,498	9,499
27	57,3	7,47	72,0	9,506	9,504
28	36,3	7,05	64,0	9,534	9,520
29	54,8	6,63	70,0	9,521	9,510
30	55,5	8,39	70,0	9,499	9,501
31	51,1	7,47	70,0	9,501	9,509

przy wartościach kryteriów: $n_z^2 = 1{,}206 \cdot 10^{-3}$, $\Delta^2(B) = 1{,}047 \cdot 10^{-3}$. Wartości częstotliwości rezonansowej $\hat{\omega}_r$ wyliczone wg (9) przedstawiono w tablicy (kolumna 6) oraz razem z wartościami empirycznymi na rys. 3 w formie wykresu.

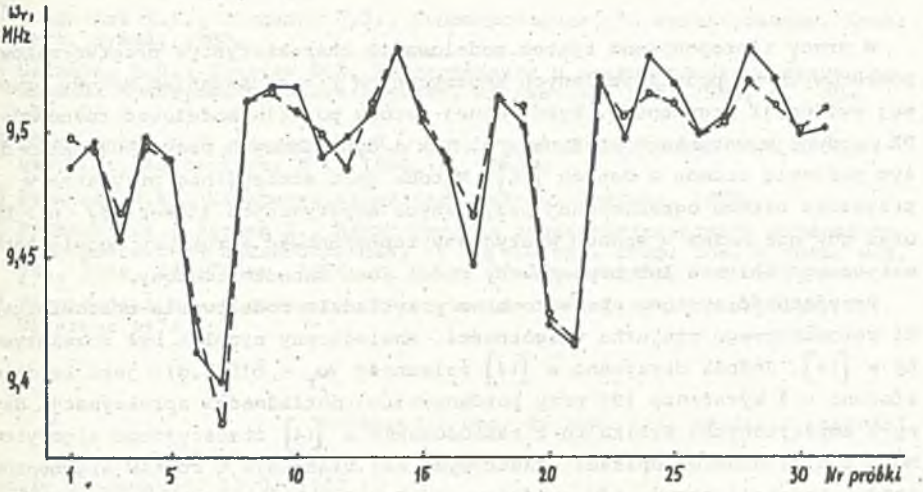

Rys. 3. Wykres zmian częstotliwości rezonansowej RCW
• - wartości empiryczne, o - wartości wyliczone wg [9]
Fig. 3. A chart of resonance frequency changes RCW

Dla porównania błąd średniokwadratowy wyliczony wg danych ciągów A, B, C wyniósł odpowiednio:

$$\xi_A \sqrt{1/14 \sum_{i=1}^{14} (\omega_{ri} - \hat{\omega}_{ri})^2} = 8{,}908 \cdot 10^{-3},$$

$$\xi_B = \sqrt{1/14 \sum_{i=15}^{28} (\omega_{ri} - \hat{\omega}_{ri})^2} = 8{,}775 \cdot 10^{-3},$$

$$\xi_C = \sqrt{1/3 \sum_{i=29}^{31} (\omega_{ri} - \hat{\omega}_{ri})^2} = 7{,}947 \cdot 10^{-3}.$$

gdzie:

ω_{ri}, $\hat{\omega}_{ri}$ - odpowiednio empiryczne i wyliczone wg (9) wartości częstotliwości rezonansowej.

Wyrażenie (9) w sposób stosunkowo prosty, a zarazem wystarczająco dokładny charakteryzuje zależność częstotliwości rezonansowej ω_r od parametrów papieru. Pierwszy człon (9) oznacza częstotliwość rezonansową ω_o układu drgającego czujnika, w przypadku nieobecności próbek papieru w jego obszarze pomiarowym.

5. Uwagi końcowe

W pracy zaproponowano system modelowania charakterystyk przetworników pomiarowych na podstawie danych empirycznych z zastosowaniem metody grupowej ewidencji argumentów. Wybór danej metody pozwala modelować różnorodne PP zarówno w warunkach statycznych, jak i dynamicznych przy stosunkowo dużym poziomie szumów w danych [10]. Metoda jest szczególnie przydatna w przypadku bardzo ograniczonej bazy danych empirycznych (nawet gdy $n > N$) oraz gdy nie można w sposób wiarygodny zaproponować struktury modelu matematycznego obiektu lub proponowany model jest zanadto złożony.

Przydatność systemu sprawdzono na przykładzie modelowania charakterystyki rezonansowego czujnika wilgotności. Analogiczny problem był rozwiązywany w [14]. Jednak otrzymana w [14] zależność $\omega_r = f(\sigma, W, d)$ jest bardziej złożona niż wyrażenie (9) przy porównywalnej dokładności aproksymacji danych empirycznych. Wynika to z zastosowania w [14] iteracyjnego algorytmu MGEA z nieliniowymi opisami cząstkowymi bez włączenia w zestaw argumentów każdej iteracji argumentów wyjściowych. Powodowało to szybszy wzrost złożoności modeli cząstkowych, na skutek czego model prostszy o analogicznej dokładności mógł zostać opuszczony. Nie przesądza to jednak o nieprzydatności algorytmów z nieliniowymi opisami cząstkowymi, gdyż posiadają bardzo ważną zaletę; wzrost złożoności modeli następuje w nich niejako automatycznie i maksymalnej złożoności modeli nie trzeba określać. Nieliniowe algorytmy MGEA nie są jeszcze dostatecznie zbadane. Najpilniejszą sprawą jest dokładne zbadanie ich zbieżności. Włączenie nieliniowego algorytmu MGEA do zaproponowanego systemu rozszerzy zakres rozwiązywanych z jego pomocą problemów.

LITERATURA

[1] Ивахненко А.Г., Индуктивный метод самоорганизации моделей сложных систем. Киев: Наук. думка, 1982.

[2] Seber G.A.F., Linear regression analysis. New York: Wiley, 1977.

[3] Draper N.R., Smith H., Applied regression analysis. New York: Wiley, 1981.

[4] Алгоритмы и программы восстановления зависимостей. В.Н. Вапник, Т.Г. Глазкова, В.А. Кошеев и др. Москва: Наука, 1984.

[5] Trends and progress in system identification. (Ed. by P. Eykhoff. Pergamon Press, Oxford, 1981.

[6] Козубовский С.Ф., Юрачковский Ю.П., Информационные критерии селекции модулей. Автоматика, № 4, 1981, с. 80-89.

[7] Mańczak K., Technika planowania eksperymentu, WNT, Warszawa 1976.

[8] Gabor D., Cybernetics and the future of industrial civilization. J. Cybernetics, 1971, N 1, 2, p. 1-4.

[9] Справочник по типовым программам моделирования. А.Г. Ивахненко, Ю.В. Коппа, В.С. Степашко и др. Киев: Техника, 1980.

[10] Ивахненко А.Г., Степашко В.С., Помехоустойчивость моделирования. Киев: Наук. думка, 1985.

[11] Степашко В.С., Кочерга Ю.Л. Классификация и анализ помехоустойчивости внешних критериев селекции моделей. Автоматика, № 3, 1984, с. 38-50.

[12] Юрачковский Ю.П., Мамедов М.И., О внутренней сходимости двух алгоритмов МГУА. Автоматика, № 1, 1984, с. 91-94.

[13] Берлинер М.А., Измерения влажности. Москва: Энергия, 1973.

[14] Рущенко В.Т., Хэрник Д., Идентификация диэлькометрического первичного преобразователя влажности. Мат. II науч.-техн. конф. сов. и поль. мол. уч., Киев, 14-17 окт. 1986, т. 2, с. 26-30, Вроцлав, Изд. ВПИ, 1986.

[15] Kacprzyński B., Planowanie eksperymentów. Podstawy matematyczne. WNT, Warszawa 1974.

Recenzent: Doc. dr hab. inż. Janusz Piotrowski

Wpłynęło do Redakcji 20.02.1987 r.

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ ИЗМЕРИТЕЛЬНЫХ ПРЕОБРАЗОВАТЕЛЕЙ МЕТОДОМ ГРУППОВОГО УЧЕТА АРГУМЕНТОВ

Р е з ю м е

В статье рассмотрен вопрос применения метода группового учета аргументов (МГУА) для составления математических моделей измерительных преобразователей. На основе итерационного алгоритма МГУА создана система моделирования объектов по экспериментальным данным. Составленная система применена для синтеза математической модели диэлектрометрического первичного преобразователя влажности.

MATHEMATICAL MODELING OF MEASUREMENT TRANSDUCERS CHARACTERISTICS BY MGEA METHOD

S u m m a r y

In the paper MGEA method is proposed to mathematical modeling of measurement transducers characteristics. An iteration MGEA algorithm is proposed as a basis for modeling system of plants using empirical data. This is applied to model of dieelectric humidity sensor of paper.