

EKSPERTOWA IDENTYFIKACJA ON-LINE WIELOWEJŚCIOWYCH PROCESÓW TECHNOLOGICZNYCH

Jan T. Duda, Paweł Stanek

*Katedra Automatyki, Akademia Górniczo-Hutnicza im. St. Staszica
al. Mickiewicza 30, 30-059 Kraków.*

Projekt badawczy Nr 8 S505 006 06; okres realizacji: 1.07.1994 - 30.06.1995

1. Wstęp

W Katedrze Automatyki AGH podjęto badania nad możliwościami szybkiej identyfikacji on-line procesów technologicznych do potrzeb sterowania adaptacyjnego, analizy alarmów itp. Zadanie to zamierza się realizować z wykorzystaniem metod ekspertowej identyfikacji, tj. poprzez połączenie algorytmów identyfikacji statycznej i dynamicznej z zalgorytmizowanymi procesami decyzyjnymi, których zadaniem jest ocena celowości identyfikacji, selekcja danych i ocena przydatności wyniku identyfikacji.

Literatura dotycząca identyfikacji dla potrzeb sterowania jest bardzo bogata. Z najnowszych prac przeglądowych na uwagę zasługuje obszerne omówienie metod adaptacji i śledzenia zmian modeli procesów zawarte w publikacji Ljunga i Gunnarssona [1] oraz metod podprzestrzeni w publikacji Viberga [2]. Obserwuje się także duże zainteresowanie identyfikacją z wykorzystaniem sieci neuronowych [3], [4] oraz metodami identyfikacji modeli rozmytych [5], [6], [7].

W algorytmach decyzyjnych identyfikacji ekspertowej istotną rolę odgrywa transformacja bieżących danych ilościowych o przebiegu procesu na informację jakościową, wykorzystywaną bezpośrednio w procesie decyzyjnym. Można do tego celu zastosować algorytmy klasyfikacji przebiegów zmiennych procesowych oparte na wykrywaniu istotnych zmian tych przebiegów. (przegląd algorytmów detekcji zmian zawiera praca Basseville'a [8]). W efekcie przebieg może być zaklasyfikowany jako stacjonarny w pewnym przedziale czasu lub niestacjonarny. Stwierdzenie stacjonarności wszystkich zmiennych procesowych może być traktowane jako wykrycie stanu ustalonego procesu. Odpowiednio uśrednione dane stanowią zatem obserwację statyczną procesu, którą można wykorzystać do identyfikacji modeli stanu ustalonego. Z drugiej strony wykrycie dużych, niestacjonarnych zmian co najmniej jednego wejścia umożliwia efektywną estymację parametrów odpowiednich torów modeli dynamicznych procesu. Problem oceny pobudzenia obiektu z punktu widzenia jakości uzyskanego modelu omawiają prace [9], [10], [11], [12]. Zainteresowania autorów niniejszego artykułu koncentrują się wokół powyższych zagadnień. W publikacji [13] omawia się koncepcję połączenia zadania optymalizacji statycznej z planowaniem eksperymentów dla identyfikacji on-line wymaganego modelu (ISOPE). Zagadnienie algorytmicznej selekcji danych postawiono w pracy Dudy [14], gdzie zaproponowano dedykowany algorytm przeznaczony do detekcji okresów stacjonarności. W pracy [15] Duda i Stanek porównali jego właściwości z klasycznym algorytmem Page'a-

Hinkley'a [8] wykorzystując dane symulacyjne. Badania właściwości metod ekspertowej identyfikacji wymagają jednak dostępu do obiektów fizycznych, ze względu na różnorodność uwarunkowań jakie winny być brane pod uwagę.

W związku z powyższym omawiany jednoroczny projekt badawczy miał na celu przygotowanie bazy laboratoryjnej dla testowania takich algorytmów oraz przeprowadzenie badań pilotowych ukierunkowanych na analizę przydatności algorytmów selekcji danych do identyfikacji. W tym wstępnym etapie ograniczono się do identyfikacji modeli statycznych.

W artykule zostanie przedstawiona baza laboratoryjna oraz podsumowanie badań identyfikacji modeli statycznych z selekcją danych publikowanych w [16], [17] i [18]. Pokazano wpływ algorytmów selekcji na jakość uzyskiwanych modeli [16] oraz porównano modele oparte na opisie stanu ustalonego z modelami Hammersteina [17]. Do porównania wykorzystano syntetyczne wskaźniki jakości (wariancja resztowa, test istotności Studenta) oraz modelowanie na podstawie danych spoza pola korelacji. Doświadczenia były prowadzone z wykorzystaniem trzech zbiorów danych, tj: zebranych na laboratoryjnej instalacji destylacji (Katedra Automatyki AGH), przemysłowej instalacji syntezy kwasu azotowego oraz dla danych z procesu wielkopieczowego [18].


2. Baza laboratoryjna

W Katedrze Automatyki AGH, przy znacznym wsparciu finansowym programu TEMPUS, w latach 1992-94 zostało zbudowane stanowisko laboratoryjne do badania algorytmów sterowania złożonymi procesami technologicznymi. Jego zasadniczą częścią jest model fizyczny procesu destylacji rzutowej i półkowej mieszaniny dwuskładnikowej woda-alkohol etylowy (rys.1). Stanowisko składa się z układu destylacji oraz obiegu wody chłodzącej. Układ destylacji tworzą: szklana kolumna półkowa R, wyparka elektryczno-olejowa H, dziewięć szklanych chłodziń typu "rura w rurze" (Cd1-Cd5, Cb1-Cb3, Cr), trzy pompy mediów technologicznych, trzy zbiorniki mediów, cztery zawory regulacyjne (CV1-CV4), mierników temperatury, ciśnienia (poziomu), przepływu.

System pomiarowy omawianej instalacji obejmuje 59 punktów pomiarowych, w tym: 40 czujników temperatury; 3 czujniki ciśnienia; 7 czujników różnicy ciśnień (pomiar poziomu) oraz 9 czujników przepływu (8 przepływomierzy turbinkowych i 1 rotametr).

Sterowanie bezpośrednie realizuje tyrystorowy regulator mocy dostarczanej do wyparki oraz dziewięć pętli regulacyjnych przepływu (stabilizacja dopływu surowca, odpływu produktów i przepływów wody chłodzącej w sześciu gałęziach). Jako urządzenia wykonawcze wykorzystano sześć precyzyjnych mikrozaworów elektrycznych firmy Platon i trzy zawory termiczne firmy Herz (dla mniej ważnych pętli układu chłodzenia).

Stanowisko jest wyposażone w **specjalistyczny sprzęt automatyki cyfrowej**: 2 sterowniki GE Fanuc (akwizycja danych pomiarowych; sterowanie bezpośrednie) oraz komputer przemysłowy ARCOM 486 (sterowanie nadrzędne; rezerwowanie pomiarów).



Komunikacja komputer-sterowniki odbywa się poprzez łącze RS z poziomu języka C, pakietu MATLAB (DOS), pakietu InTouch, QNX.

Komputer ARCOM, dzięki zastosowaniu karty pomiarowej, ma możliwość zbierania sygnałów pomiarowych z 16 czujników PT 100. Wykorzystanie kart Ethernet umożliwiło połączenie go z lokalną siecią komputerową zawierającą 7 komputerów PC pracujących pod kontrolą systemu operacyjnego czasu rzeczywistego QNX.

W ramach omawianego projektu przeprowadzono prace mające na celu przygotowanie stanowiska badawczego do badania właściwości algorytmów identyfikacji. Wymagało to osiągnięcia pełnej kontroli nad przebiegiem całego procesu i możliwości jego stabilizacji w zadanym punkcie pracy.

W związku z powyższym:

- przeprojektowano i zmieniono układ grzałek elektryczno-olejowych w wyparce w celu wymuszenia prawidłowej konwekcji oleju i uzyskania tą drogą założonej wydajności aparatu oraz zwiększenia jego niezawodności
- wykonano projekt struktury układu sterowania;
- wykonano projekt połączeń czujników i urządzeń wykonawczych ze sterownikiem;
- uruchomiono układy sterowania bezpośredniego;
- wykonano oprogramowanie zbierania danych do identyfikacji w czasie rzeczywistym.

3. Identyfikacja modeli stanu ustalonego

3.1. Identyfikacja charakterystyki statycznej w oparciu o dane z okresów stacjonarności.

Procesy przemysłowe ciągłe są często przewidziane do pracy w stanie ustalonym. W związku z tym ważnym zadaniem systemów sterowania komputerowego jest optymalizacja statycznego punktu pracy. Wymaga to identyfikacji charakterystyk statycznych obiektu w czasie rzeczywistym. Identyfikacja bierna tych na ogół nieliniowych i wielowejsściowych modeli rzadko przynosi oczekiwane rezultaty. Dlatego niezbędnym elementem takiej identyfikacji wydaje się być algorytmiczna detekcja okresów stacjonarności przebiegów sygnałów procesowych. Dane zebrane i uśrednione w okresach stacjonarności mogą służyć do identyfikacji charakterystyki statycznej.

Rozważmy dynamiczny, nieliniowy, stacjonarny i stabilny obiekt MISO o wyjściu $y^*(t)$ i wejściach $X^* = x_1^*, x_2^*, \dots, x_j^*$. Załóżmy, że wyjście $y^*(t)$ i każde z wejść $x_j^*(t)$ można przedstawić w postaci sum:

$$x^*(t) = x(t) + \delta x \quad (1)$$

$$y^*(t) = y(t) + \delta y \quad (2)$$

gdzie $\delta x_j(t)$ i $\delta y(t)$ są procesami ergodycznymi o wartości średniej zerowej, a $x_j(t)$ i $y(t)$ są funkcjami deterministycznymi, które w pewnych odcinkach czasu mogą przyjmować wartości stałe $x_{ju}(t) = x_{ju}$, $y_{ju}(t) = y_{ju}$. Załóżmy, że obiekt posiada jednoznaczną charakterystykę statyczną

$$y_u = f(X_u) = B_u^T \cdot \bar{u}, \quad (3)$$

gdzie B_u jest wektorem współczynników; $\bar{u} = \{u_1, u_2, \dots, u_k\}$ - wektorem wejść uogólnionych:

$$u_k = \varphi_k(X_u) \quad u_1 = 1 \quad (4)$$

przy czym funkcje φ_k odwzorowują wszystkie nieliniowości zależności (3).

Model (3) można zidentyfikować metodą najmniejszych kwadratów. W tym celu należy zarejestrować ciąg wartości $X = \{x_{1mu}, x_{2mu}, \dots, x_{jmu}, m=1, \dots, M\}$ oraz $Y = \{y_{mu}, m=1, \dots, M\}$, reprezentujących wejścia oraz wyjście obiektu w m-tym stanie ustalonym. Na podstawie założenia o stałości $x_j(t)$ i $y(t)$ wartości x_{jmu} , y_{mu} mogą być estymowane przez wartości średnie $\bar{x}^*(t)$, $\bar{y}^*(t)$ liczone w m-tym okresie stacjonarności sygnałów. Przedziały są zazwyczaj różne dla każdej zmiennej, ale powinny one mieć wspólny podprzedział, który można uznać za n-ty okres stanu ustalonego procesu.

3.2 Wpływ uchybu dynamicznego na jakość modelu stanu ustalonego

Przyjmijmy, że dla y^* założenie o stacjonarności wyjścia nie jest spełnione i przeanalizujmy wpływ wynikającego stąd błędu na jakość modelu. W tym celu uśrednione wyjście y_m zapiszemy w postaci:

$$y_m = B^T \bar{u}_m + v_m + z_m \quad (5)$$

gdzie z_m - reprezentuje zakłócenia, v_m - uchyb dynamiczny.

Jeżeli przedział czasu $< t_{m1} - t_{(m-1)1} >$ pomiędzy okresami, w których zarejestrowano kolejne uśrednione dane, jest dłuższy od czasu zaniku funkcji autokorelacji zmiennej y to z_m jest szumem białym. Uchyb v_m jest w ogólnym przypadku skorelowany ze zmiennymi X , zatem i z $\bar{u}$.

Oznaczając przez V i Z wektory uchybów dynamicznych w kolejnych obserwacjach $m=1, \dots, M$, układ równań normalnych regresji zapiszemy w postaci:

$$U^T \cdot U \cdot B = U^T \cdot Y + U^T \cdot V + U^T \cdot Z \quad (6)$$

Wynikiem rozwiązania równania (6) jest wektor $B = B_y + B_v + B_z$, przy czym dla dużych M $B_z = 0$, gdyż wartość oczekiwana $U^T \cdot Z = 0$.

Niech E_v oznacza wektor odchyłek modelu, spowodowanych obecnością V , a E_z - jak wyżej dla Z . Z założenia MNK spełnione są równości:

$$U^T E_v = 0, \quad U^T E_z = 0 \quad (7)$$

Jeżeli dla uchybu V jest $U^T V \neq 0$, to $B_v \neq 0$ zatem estymatory B współczynników B_y będą obciążone. Biorąc pod uwagę równość (7), nie ujawni się to w estymatorze wariancji wyjść modelu ($E^T E = Z^T Z + E_v^T E_v$). Uchyb dynamiczny skorelowany z wejściami $\bar{u}$ powoduje zatem, że wariancja wyjść obliczona z MNK nie daje informacji o zachowaniu się modelu poza polem korelacji. Poza tym błąd dynamiczny osłabia jakość modelu w polu korelacji. Biorąc to pod uwagę należy:

- a) dążyć do minimalizacji uchybów dynamicznych, tak aby $E_v^T E_v \cong Z^T Z$;
- b) unikać rejestracji danych z ciągu słabo zrandomizowanych punktów pracy.

Dla spełnienia postulatu a) proponuje się wykorzystanie algorytmów wykrywania istotnych zmian przebiegów wejść i wyjść umożliwiających algorytmiczną selekcję danych do identyfikacji.

3.3 Zastosowanie modelu Hammersteina

Rozważmy błąd dynamiczny

$$v_n = y_n - y_u \quad (8)$$

gdzie y_u jest wartością wyjścia w stanie ustalonym określoną przez (3).

Jeśli dane zostały zebrane podczas stanu ustalonego procesu ($y_n = y_{mu} = \text{const}$) wtedy odchylenie v_n jest związane tylko z błędami estymacji y_{mu} (wynikającymi z błędów oszacowania przedziału stanu ustalonego oraz z niedokładnej filtracją δy). Tak więc można oczekiwać, iż ma ono niewielki wpływ na estymaty współczynników modelu. Przyjmując po jednej wartości $y_n = y_{mu}$ z każdego przedziału stacjonarności, przy założeniu iż są one wystarczająco oddalone czasowo, uzyskuje się ciąg z_m o pomijalnej autokorelacji. Zatem metoda LMS daje nieobciążone estymatory wektora B_u . Tym niemniej, gdy odchyłki dynamiczne v_n są duże, błąd estymatora może być znaczny, szczególnie przy małej liczbie obserwacji używanych do identyfikacji. Tak dzieje się w przypadku procesów wolnozmiennych, gdzie stacjonarność $y(t)$ jest rzadko osiągana. Aby uwzględnić uchyb dynamiczny wyjścia należy dodać człon autoregresyjny:

$$v_n = \sum_{i=1}^{K_y} \alpha_i \cdot v_{n-i} \quad (9)$$

Tak więc, biorąc pod uwagę (3,4,8) możemy przepisać wzór (5) w postaci:

$$y_n = \sum_{i=0}^{K_y} \alpha_i \cdot y_{n-i} + \sum_{k=0}^{K_u} \beta_k \cdot \bar{u}_{km} + z_n = B^T \cdot \bar{w}_n + z_n \quad (10)$$

gdzie

$$\beta_k = b_{uk} \cdot \left(1 - \sum_{i=1}^{K_y} \alpha_i\right) \quad (11)$$

Wektory B , $\bar{w}_n$ zawierają odpowiednio współczynniki $\{\alpha_i, \beta_k\}$ oraz zmienne $\{y_{n-i}, \bar{u}_{km}\}$. Równanie (10) jest uproszczoną formą modelu Hammersteina i może być zidentyfikowane z wykorzystaniem np. metody zmiennej instrumentalnej [19]. Następnie współczynniki b_{ui} modelu (3) są wyliczane zgodnie z równaniem (11). Można również zamiast stałych wejść u_{km} rozważać postać ogólną modelu Hammersteina zawierającą u_{kn-di} , $u_{kn-di-1}$, (gdzie d_k jest opóźnieniem dla k -tego wejścia), lecz wyniki uzyskane tą drogą dla bardziej skomplikowanych systemów MISO są mało wiarygodne, ze względu na daleko idące uproszczenia części dynamicznej modelu.

3.4. Metody klasyfikacji przebiegów

Identyfikacja modelu statycznego (3) jak również uproszczonego modelu Hammersteina (10) wymaga detekcji przedziałów stałości składowej deterministycznej zmiennych procesowych. W tym celu mogą być zastosowane algorytmy wykrywania zmian [8], [15]. Rozważmy proces stochastyczny $x^*(t)$ określony przez (1). W publikacji [16] przedyskutowano stosowalność dwóch różnych metod. Pierwsza z nich, tzw. reguła Page'a-Hinkley'a [8], zakłada iż δx są gaussowskim szumem białym, a $x(t)$ jest odcinkami stałe. Druga metoda, przedstawiona szczegółowo w [14], jest dedykowana dla potrzeb selekcji i w pracy [16] została oceniona jako bardziej odpowiednia do tych celów. Bazuje ona na analizie statystycznej istotności trendu chwilowego zmiennej $x(t)$ oraz różnic pomiędzy krótko i długookresowymi średnimi. Brana jest pod uwagę korelacja wzajemna obu średnich. Trend oraz wartość średnia są estymowane w oknie zawierającym ustaloną liczbę M_x danych zmiennej $x^*(t)$. W metodzie zakłada się


gaussowskie zakłócenia wysokoczęstotliwościowe δx o wariancji σ_x i dolną granicą spektrum ω_x . Dopuszczalny jest dowolny przebieg zmiennej $x(t)$. Wartość ω_x winna być dobrana w taki sposób, aby wyodrębnić szumy, których wpływ na wyjście procesu jest pomijalny. Parametr ω_x odgrywa bardzo istotną rolę w tej metodzie. Im wyższa jest jego wartość tym węższe są przedziały ufności dla współczynnika trendu zmiennej $x(t)$, a tym samym detekcja zmian sygnału jest łatwiejsza.

4. Wyniki badań pilotowych

4.1 Selekcja danych

Rys. 2 przedstawia przykładową selekcję okresów stacjonarności dla wyparki elektryczno-olejowej oraz procesu syntezy kwasu azotowego. Pokazano przebiegi zmiennych procesowych oraz na ich tle - wynik uśredniania przez omówione wcześniej procedury. Odcinki poziome odpowiadają wykrytym przez procedurę okresom stacjonarności, a ich wartość określa wartość średnią sygnału w okresie stacjonarności. Jeśli wszystkie sygnały zostały zakwalifikowane jako stacjonarne, to przyjmuje się, iż obiekt jest w stanie ustalonym i kwalifikujemy taką obserwację (ściśle mówiąc - estymaty wartości średnich w okresach stacjonarności tych sygnałów) do identyfikacji statycznej. Okresy niestacjonarności sygnału są zobrazowane przez linie będące wynikiem filtracji sygnału pierwotnego. Jeśli niestacjonarne są wejścia to okresy takie nie są brane pod uwagę. Jeśli niestacjonarne jest tylko wyjście procesu, to odpowiednie dane możemy wykorzystać do identyfikacji modelu Hammersteina. Należy zauważyć że dla potrzeb identyfikacji statycznej każdy okres stanu ustalonego obiektu reprezentuje tylko jedna obserwacja, co powoduje znaczną kompresję danych. W przypadku instalacji kwasu azotowego z ciągów liczących po 28 000 danych wybrano tylko 91 obserwacji, dla których stwierdzono jednoczesną stacjonarność wszystkich 11 zmiennych procesowych. Dla wyparki, z 5000 zarejestrowanych próbek sześciu zmiennych wyselekcjonowano 52 obserwacje stanu ustalonego, ale już dla modelu Hammersteina zebrano 3500 obserwacji, w których wszystkie wejścia były stacjonarne. Jak widać, model Hammersteina może być adaptowany znacznie częściej.

W przypadku obiektów o bardzo rzadkiej zmienności stanów stacjonarnych oraz dla obiektów o bardzo wysokiej zmienności wejść przyjęte reguły selekcji mogą prowadzić do małej liczby obserwacji i co za tym idzie, do niedokładnych estymat parametrów modelu. Trudności w pierwszym przypadku można uzasadnić tym, iż sam sygnał niesie w sobie ubogą informację. Drugi przypadek wykracza poza przyjęte założenia. Należy wówczas poszukiwać innych metod.




Rys.2. Selekcja okresów stacjonarności metodą analizy istotności trendu dla wyparki elektryczno-olejowej (a) oraz procesu syntezy kwasu azotowego (b).

4.2. Identyfikacja

Do identyfikacji modeli statycznych zastosowano metodę regresji liniowej z minimalizacją liczby wejść uogólnionych (jednomianów wejść fizycznych) metodą odrzucania w oparciu o analizę uwarunkowania zadania, a następnie analizę istotności współczynników z wykorzystaniem statystyki T Studenta. Odpowiedni algorytm omawia praca [20]. Uzyskano w ten sposób zbiór wejść, z których w każdym cyklu identyfikacji wybierano wejścia istotne. Biorąc pod uwagę suboptymalny charakter zastosowanej metody eliminacji wejść, przeprowadzono wielowariantowe badania zależności modelowych przyjmując szeroki zbiór wejść uogólnionych. Jakość uzyskiwanych modeli oceniano według: a) wariancji resztowej modelu; b) współczynnika korelacji wielowymiarowej; c) liczby członów równania regresji. Jako ostateczne kryterium przyjęto jednak błędy prognoz wyjść obliczonych dla danych wejściowych nie wykorzystywanych do identyfikacji.

W przypadku danych przemysłowych przebadano modele statyczne dla trzech wyjść procesowych. Do identyfikacji wykorzystano dane uzyskane w oparciu o selekcję Page'a-Hinkley'a, analizę istotności trendu oraz zbiór porównawczy uzyskany metodą uśredniania danych w stałych rozłącznych 100 minutowych przedziałach czasowych. W przypadku identyfikacji laboratoryjnej wyparki rozważano dodatkowo modele Hammersteina ze względu na dynamiczny charakter wyjścia (Rys.2a). Rozważono tu modele o różnych strukturach, w tym model odpowiadający teoretycznym bilansom cieplnym. Przykładowy wynik modelowania obrazuje rysunek (3). Kółkami oznaczono wartości empiryczne wyjść (w kolejności ich rejestracji), liniami połączono wyjścia prognozowane według modelu.



Rys. 3 Modelowanie wyjścia procesu przemysłowego oraz ciśnienia pary wyparki

Dokładne omówienie wyników identyfikacji, tak pod względem parametrów syntetycznych, jak też bazujące na wynikach modelowania obiektu z wykorzystaniem danych spoza pola korelacji podają prace [16], [17], [18]. Charakterystyczne jest, że próba identyfikacji modelu Hammersteina bez selekcji danych stacjonarnych prowadzi do zależności niezgodnych jakościowo z modelem teoretycznym. Ogólnie, modele oparte na danych stacjonarnych nie mają istotnie lepszych wskaźników formalnych (a), (b), (c), niż zidentyfikowane na podstawie przypadkowo uśrednionych wejść i wyjść, ale ich zalety ujawniają się wyraźnie, gdy prognozuje się wyjścia dla danych wejściowych spoza pola korelacji.

Powyższe obserwacje wskazują na istotną rolę selekcji danych do identyfikacji.

5. Wnioski

Identyfikacja on-line modeli statycznych i dynamicznych wymaga odpowiedniej selekcji danych. Etapem wstępnym takiej selekcji może być algorytmiczna klasyfikacja przebiegów zmiennych procesowych z wydzieleniem okresów stacjonarności

Przeprowadzone badania porównawcze algorytmów klasyfikacji [16] wykazały lepsze właściwości algorytmu opartego na analizie istotności trendu [14] niż metody Page'a-Hinkley'a [8].

Dla modeli stanu ustalonego taka klasyfikacja pozwala zminimalizować wpływ uchybów dynamicznych na efektywność modelu. Dotyczy to zarówno modeli statycznych jak i modeli Hammersteina [17].

Dla modeli dynamicznych konieczne jest opracowanie reguł oceny jakości pobudzenia obiektu.

Stanowisko badawcze przygotowane w Katedrze Automatyki AGH daje pełne możliwości testowania algorytmów identyfikacji dla prostych i złożonych procesów nieliniowych

Literatura:

- [1] L. Ljung, S. Gunnarsson: Adaptation and tracking in system identification-Survey, *Automatica* Vol.26 (1990), Iss.1, pp.7-21
- [2] M.Viberg: Subspace methods in system identification. SYSID'95 Copenhagen, Denmark, Vol.1 (1995), pp.1-12
- [3] J. Sjöberg, H. Hjalmarsen, L. Ljung: Neural Networks in System Identification. SYSID'94, Copenhagen, Denmark, Vol.2 (1994), pp.49-72
- [4] K.J.Hunt; D.Sbarbaro; R.Zbikowski; P.J.Gawthrop: Neural networks for control systems. A survey. *Automatica*, Vol.28 (1994), Iss.6, pp.1083-1112
- [5] W.Pedrycz: Identification in fuzzy systems, *IEEE Trans.SMC*, Vol.14 (1984), Iss.2, p.361-6.
- [6] T.Takagi; M.Sugeno: Fuzzy identification of systems and its applications to modeling and control. *IEEE Tr.SMC*, Vol.15 (1985).
- [7] C.W.Xu, Y.Z.Lu: Fuzzy model identification and self-learning for dynamic systems, *IEEE Trans. SMC*, Vol.17 (1987).
- [8] M. Basseville: Detecting Changes in Signals and Systems - Survey. *Automatica* Vol.24 (1988). No.3, pp.309-326.
- [9] B.Armstrong: On finding exciting trajectories for identification experiments involving systems with nonlinear dynamics. *Int.J.of Robotics Research*, Vol.8 (1989), Iss.6, pp.28-48
- [10] G.Bastin; R.R.Bitmead; G.Campion: Identification of linearly overparametrized nonlinear systems. *IEEE AC*, Vol.37 (1992), Iss. 7, pp.1073-78
- [11] R.G.Hakvoort; R.J.P.Schrama; P.M.J.van den Hof: Approximate identification with closed-loop performance criterion and application to LQG feedback design. *Automatica*.Vol.30 (1994), Iss.4, pp.679-690
- [12] V.N.Ovcharenko: Input signal selection for identification of linear continuous systems from discrete observations. *Automation and Remote Control*, Vol.50 (1989), Iss.2, pp.198-204
- [13] P. Tatjewski, M. A. Brdyś, J. Duda: Optimizing control of uncertain plants with feedback controlled output constraints. *Int.Symp. on Large Scale System*, London'95 (1995)
- [14] J. Duda: Wybrane zagadnienia syntezy algorytmów sterowania nadrzędnego wolnozmiennymi ciągłymi procesami przemysłowymi, *Zeszyty Naukowe AGH Nr 1420, Automatyka* z.56 (1992)
- [15] J.Duda, P.Stanek, Ocena efektywności wykrywania zmian wartości średniej sygnałów, *Zeszyty Naukowe AGH, Nr 1555, Automatyka* z.67, (1994), str. 39-57.

- [16] J.T. Duda, P. Stanek, K. Janik: Algorytmiczna selekcja danych do identyfikacji on-line statycznych modeli procesów wolnozmiennych, XXI Międzynarodowe Sympozjum nt. Zastosowań Teorii Systemów, Zakopane, 1995.
- [17] J.T. Duda, P. Stanek: Identification of steady-state MIMO plant model with algorithmic data selection, Prepr. 10th Conference of Process Control'95 Vol.1 (1995), p.168-172
- [18] J.T. Duda, W. Byrski: Sterowanie nadrzędne procesem wielkopiecowym, Międzynarodowa Konferencja - Computer Applications in Mining, Geology and Metallurgy, Kraków, 1995, tom 1, str.33-42.
- [19] P.Stoica, T.Söderström: Instrumental variable methods for identification of Hammerstein systems, International Journal of Control, Vol.35 (1982), p. 459-476
- [20] J. Duda: Dobór struktury wielowymiarowych funkcji regresji, Zeszyty Naukowe AGH, Nr 1450, Automatyka z.59, (1992), str 99-106.

