

# ALGORYTMY NIELINIOWEJ REGULACJI PREDYKCYJNEJ

Zbigniew Ogonowski

Instytut Automatyki, Politechnika Śląska, Gliwice

## 1 Wstęp

Historia regulacji predykcyjnej sięga końca lat 60-tych tj. prac Richaleta [19]. Jednak szczególne zainteresowanie przypada na przełom lat 70-80 (prace Cutlera i Ramakera [6], Mehry [9], De Keysera [8], Ydstie [21], Clarke [3] i in.). Prace te dotyczyły syntezy liniowych algorytmów regulacji predykcyjnej. Tylko nieliczni autorzy rozpatrywali zagadnienia nieliniowe, ale prace te dotyczyły szczególnych przykładów obiektów lub szczególnych typów nieliniowości (np. Clarke [5], Seborg [20], Feng [7]). Brak jest jak dotąd zwartej teorii dotyczącej nieliniowej regulacji predykcyjnej oraz wskazań co do klas modeli, ich własności z punktu widzenia jakości predykcji, odporności itp.

Ogromny sukces jaki odnoszą liniowe regulatory predykcyjne, potwierdzony znaczną liczbą zastosowań (por. Clarke [4]) wskazują, że idea tzw. wydłużonego horyzontu predykcji powinna być również wykorzystana dla sterowania obiektów nieliniowych. Praktyka przemysłowa dostarcza szeregu przykładów tzw. obiektów trudnych, dla których klasyczna regulacja PID zawodzi. Przykład reaktora do polimeryzacji styrenu akrylo-nitrylowego, badany w pracy Ogonowskiego i in. [11] wskazuje, że zastosowanie adaptacji dla liniowego regulatora predykcyjnego tylko częściowo pozwala rozwiązać problem sterowania. Z drugiej strony zastosowanie nawet prostych modeli nieliniowych zdecydowanie polepsza jakość regulacji (por. Biegler [1]).


Wykorzystanie modelu nieliniowego w sposób parametryczny z reguły prowadzi do złożonych obliczeń numerycznych, a w przypadku syntezy regulatora predykcyjnego zadanie komplikuje się jeszcze bardziej ponieważ jest ono formułowane jako problem minimalizacji odpowiednio zdefiniowanej funkcji kryterialnej. Dlatego w pełni umotywowane jest poszukiwanie algorytmów regulacji predykcyjnej mniej złożonych i zapewniających odpowiednią jakość regulacji z jednoczesnym uwzględnieniem nieliniowego charakteru obiektu. Celowe jest przy tym konstruowanie algorytmów, które wykorzystują model obiektu w sposób nieparametryczny. Dzięki temu nie ma praktycznie ograniczeń jak chodzi o klasę modelu. Niniejsza praca dotyczy takich algorytmów.

Ideą przewodnią jest połączenie zasady regulatora z wydłużonym horyzontem predykcji z nieliniowym opisem sterowanego obiektu co prowadzi do powstania nowej klasy regulatorów, pozwalających rozwiązywać zadania sterowania obiektów trudnych. W badaniach realizowanych w projekcie wykorzystano dwa podejścia. Można wykazać (por. Niederliński i in. [10]), że liniowe algorytmy regulacji predykcyjnej dadzą się przedstawić jako

$$u(i) = q^T(w^* - y^0)$$

gdzie:  $u(i)$  dyskretna wartość sygnału sterującego,  $q$  wektor wagowy, którego elementy zależą od własności dynamicznych obiektu regulacji,  $w^*$  wektor reprezentujący żądany przebieg sygnału wyjściowego (tzw. trajektoria odniesienia),  $y^0$  wektor predykcji sygnału wyjściowego obiektu regulacji przy założeniu określonego "scenariusza" dla przyszłych wartości sygnału sterującego. Powyższa struktura algorytmu regulacji może być przeniesiona na

przypadek nieliniowego opisu obiektu regulacji, podobnie jak to zostało uczynione w pracy Ogonowskiego [12], gdzie syntezę liniowych regulatorów predykcyjnych przeprowadzono bez wykorzystywania modelu obiektu. W efekcie otrzymuje się algorytmy suboptymalne. Synteza algorytmów optymalnych jest drugim z proponowanych podejść. Sprowadza się ono do rozwiązania zadania nieliniowej optymalizacji statycznej.



Rys. 1: Idea regulacji predykcyjnej.

W kolejnych punktach zostaną przedstawione: idea algorytmów z wydłużonym horyzontem predykcyjnym i liniowym modelem, nieliniowe algorytmy predykcyjne, algorytmy suboptymalne, oraz zagadnienie wyboru typu modelu z punktu widzenia jakości predykcyjnej.

## 2 Idea regulacji predykcyjnej

Ideę regulacji predykcyjnej przedstawia rys.1. Horyzont predykcyjny wielkości wyjściowej układu regulacji został oznaczany przez  $H$ . W regulacji predykcyjnej można wyznaczać sterowania:  $u(i), u(i+1), \dots, u(i+H-1)$ . Scenariusz przyszłych sterowań na rys. 1 jest taki, że począwszy od chwili  $i+L$  przyrosty sterowania są z założenia równe zero. W tym przypadku wyznaczone są wartości wielkości sterującej  $u(i), u(i+1), \dots, u(i+L-1)$ . Pozwala to uzyskać dodatkowe możliwości kształtowania własności regulatorów predykcyjnych przy czym musi być spełniony warunek  $H \geq L$ . Liczbę  $L$  nazywa horyzontem sterowania.

Wartości sygnału sterującego można wyznaczać minimalizując różnicę pomiędzy przewidywaną trajektorią wielkości wyjściowej modelu, a przyszłymi wartościami wielkości zadanej. Jednak znaczną poprawę jakości regulacji można osiągnąć przez wprowadzenia do syntezy regulatora tzw. trajektorii odniesienia (zob. rys. 1). Trajektoria odniesienia rozpoczyna się aktualną wartością wielkości wyjściowej i zmierza do wartości zadanej; zadanie polega więc na wyznaczeniu przyszłych wartości wielkości sterującej, które będą minimalizować różnicę pomiędzy przewidywaną trajektorią wielkości wyjściowej, a trajektorią odniesienia. Trajektoria odniesienia będzie oznaczana przez  $w^*$  ponieważ oblicza się ją na podstawie przewidywanych w chwili  $i$  wartości wielkości zadanej  $w$  na chwilę  $i+j$

$$w^*(i+j) = K_m(z^{-1})w(i+j) = \frac{B_m(z^{-1})}{A_m(z^{-1})}w(i+j) \quad (1)$$

przy czym

$$w^*(i-s) = y(i-s) \quad s = 0, 1, \dots, nA_m - j \quad (2)$$

$$K_m(1) = 1. \quad (3)$$

Wykorzystano oznaczenia:  $y$  - wartość sygnału wyjściowego,  $nA_m$  stopień wielomianu  $A_m$ . Zależność (2) jest warunkiem początkowym dla rekurencyjnego wyznaczania trajektorii odniesienia z (1) co między innymi powoduje, że trajektoria odniesienia rozpoczyna się aktualną wartością sygnału wyjściowego obiektu. Jeśli przyszłe wartości wielkości zadanej  $w$  nie są znane należy przyjąć

$$w(i+1) = w(i+2) = \dots = w(i+H) = w(i). \quad (4)$$

Na ogół wystarczającym jest przyjęcie trajektorii pierwszego rzędu czyli

$$\frac{B_m}{A_m} = \frac{(1-\rho)z^{-1}}{1-\rho z^{-1}} \quad (5)$$

gdzie

$$0 < \rho < 1. \quad (6)$$

Wartość  $\rho$  jest ważnym parametrem strojenia algorytmów regulacji predykcyjnej. W zależności od jego doboru żąda się szybszego lub wolniejszego dochodzenia sygnału wyjściowego układu do wartości zadanej.

Wyznaczanie wartości sygnału sterującego jest wynikiem minimalizacji wskaźnika jakości regulacji, który jest funkcją predykcyj wielkości wyjściowej obiektu

$$J = E \left\{ \sum_{j=k}^H [y(i+j) - w^*(i+j)]^2 + \rho u^2(i+j-1) \right\}. \quad (7)$$

We wskaźniku (7) w miejscu sygnału sterującego może wystąpić jego przyrost. Minimalizacja wskaźnika  $J$  odbywa się po przyszłych wartościach sygnału sterującego w obrębie horyzontu predykcyj  $H$  z uwzględnieniem ewentualnego scenariusza przyszłych sterowań.

Z zasady sterowania repetycyjnego wynika, że z wyznaczonego ciągu przyszłych wartości wielkości sterującej stosuje się tylko pierwszy element, by w kolejnym kroku powtórzyć całość obliczeń.

Przykład liniowego regulatora predykcyjnego przedstawił Clarke [3]. Jako liniowy model obiektu przyjmuje się model ARIX:

$$y(i) = z^{-1} \frac{B(z^{-1})}{A(z^{-1})} u(i) + \frac{1}{\nabla A(z^{-1})} e(i) \quad (8)$$

gdzie  $\nabla$  oznacza operator różnicy wstecznej:  $\nabla = 1 - z^{-1}$ . Celem regulacji jest minimalizacja wskaźnika

$$J = E \left\{ \sum_{j=1}^H [y(i+j) - w^*(i+j)]^2 + \sum_{j=1}^H \rho_j [\Delta u(i+j-1)]^2 \right\} \quad (9)$$

gdzie  $\rho_j$  są współczynnikami ważenia przyrostów wielkości sterującej. Horyzont sterowania  $L$  może przyjmować wartości z przedziału od 1 do  $H$ . W wyniku minimalizacji otrzymuje się algorytm regulacji


$$u(i) = u(i-1) + q^T (\bar{w}^* - \bar{y}^0), \quad (10)$$

gdzie:

$$q^T = [q_1, q_2, \dots, q_H] = \bar{I}^T [Q^T Q + \rho I]^{-1} Q^T, \quad (11)$$

$$\bar{I}^T = [1, 0, 0, \dots, 0], \quad (12)$$

$$Q = \begin{bmatrix} h_0 & 0 & \dots & 0 \\ h_1 & h_0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ h_{L-1} & h_{L-2} & \dots & h_0 \\ \vdots & \vdots & & \vdots \\ h_{H-1} & h_{H-2} & \dots & h_{H-L} \end{bmatrix}, \quad (13)$$



Rys. 2: Struktura układu regulacji silnika asynchronicznego

$h_{(\cdot)}$  są wartościami odpowiedzi skokowej obiektu.

Przedstawiony regulator jest typowym regulatorem predykcyjnym z wydłużonym horyzontem predykcji, a jego struktura jest typowa dla algorytmów powstałych w wyniku analitycznego rozwiązania zadania optymalizacji kwadratowej funkcji kryterialnej (9). Wykorzystując inne modele liniowe, w tym także modele nieparametryczne lub zakładając inny scenariusz przyszłych sterowań otrzymuje się szereg podobnych algorytmów (por. Niedeliński i in. [10]) tzn. o takiej samej strukturze: wartość sygnału sterującego (lub jego przyrost) jest ważoną sumą różnic pomiędzy trajektorią odniesienia i predykcją odpowiedzi swobodnej.

### 3 Zastosowanie algorytmów liniowych do obiektu nieliniowego

Algorytmy liniowe można zastosować do regulacji obiektu nieliniowego. W syntezie regulatora trzeba wykorzystać model zlinearyzowany wokół punktu pracy obiektu. Przy dużych odchyleniach od tego punktu jakość regulacji może być jednak bardzo niezadawalająca lub wręcz prowadzić do niestabilności układu. Dlatego często stosuje się adaptacyjną wersję regulatora, w której liniowy model jest na bieżąco identyfikowany. W każdym okresie próbkowania dokonuje się syntezy regulatora na podstawie parametrów modelu (regulacja adaptacyjna pośrednia). Regulator (10) w postaci adaptacyjnej zastosowano do stabilizacji temperatury wewnątrz reaktora do produkcji styrenu akrylo-nitrylowego (Ogonowski i in. [11], Ogonowski [13]). Uzyskano poprawną jakość regulacji, ale dla bardzo szczególnego doboru parametrów regulatora ([13]) lub istotnie nadparametryzowanego modelu ([11]). W obu przypadkach można było zaobserwować typowy dla takich przypadków, trudny etap wstępnego nastrojenia regulatora jak również jego przestrajania.

Zastosowano również predykcyjne regulatory liniowe do szczególnego rodzaju obiektu tj. posiadającego większą liczbę wyjść niż wejść. Jeżeli "nadmiarowe" sygnały wyjściowe mają być stabilizowane na stałej wartości (np. zero), to idea regulacji predykcyjnej z wydłużonym horyzontem jest dobrym narzędziem syntezy odpowiedniego regulatora: odchylenie wartości "nadmiarowych" wyjść od wartości zadanej może być dodatkowym elementem minimalizowanej funkcji kryterialnej.

Na rys.2 przedstawiono przypadek silnika asynchronicznego, regulowanego przez adaptacyjny regulator GPC zmodyfikowany tak, by za pomocą dwóch sygnałów wejściowych  $u_{ax}$  – składową  $x$  napięcia statora w układzie wirującym i  $u_{ay}$  – składową  $y$  napięcia statora w układzie wirującym regulować moduł wartości strumienia pola magnetycznego statora  $|\Psi_s|$ , prędkością obrotową rotora  $\omega_r$  lub wymiennie – pola  $\omega_{ms}$  oraz dodatkowo aby minimalizować zmienność składowej  $y$  prądu statora w układzie wirującym czyli stabilizować na zerze pochodną tego prądu  $di_{sy}$ . W ogólnym przypadku modyfikacja algorytmu (10) wraz z rozszerzeniem na przypadek wielowymiarowy jest następująca. Będą wykorzystane oznaczenia:  $m$  – ilość wejść,  $n > m$  – ilość wyjść  $s = n - m$  – ilość dodatkowych wyjść. Zakłada się wielowymiarowy model typu ARIMAX

$$A(z^{-1})y(i) = B(z^{-1})u(i-1) + \frac{C(z^{-1})}{1-z^{-1}}e(i) \quad (14)$$

gdzie

$$A(z^{-1}) = I + A_1 z^{-1} + \dots + A_n z^{-n} \quad (15)$$

$$B(z^{-1}) = B_0 + B_1 z^{-1} + \dots + B_n z^{-n} \quad (16)$$

$$C(z^{-1}) = I + C_1 z^{-1} + \dots + C_n z^{-n} \quad (17)$$

$$y(i) = [y_1(i), y_2(i), \dots, y_n(i)]^T \quad (18)$$

$$u(i) = [u_1(i), u_2(i), \dots, u_m(i)]^T \quad (19)$$

$$e(i) = [e_1(i), e_2(i), \dots, e_n(i)]^T. \quad (20)$$

Elementy wektora  $e(i)$  są statystycznie niezależne. Funkcję kryterialną buduje się następująco

$$J = E \{ (\bar{y} - \bar{w}^*)^T W (\bar{y} - \bar{w}^*) + \bar{y}_a^T S \bar{y}_a + \Delta \bar{u}^T R \Delta \bar{u} \} \quad (21)$$

gdzie  $\bar{y}$  jest wektorem predykcji "podstawowych" wielkości wyjściowych,  $\bar{y}_a$  jest wektorem predykcji "dodatkowych" wielkości wyjściowych,  $\Delta \bar{u}$  jest wektorem przyrostów przyszłych wielkości sterujących (zmienne niezależne zadania optymalizacji),  $W$ ,  $S$ ,  $R$  są macierzami wagowymi. Wprowadzając minimalny horyzont predykcji  $N_1$ , maksymalny horyzont predykcji  $N_2$  oraz horyzont sterowania  $N_u$  odpowiednie wektory można zapisać następująco

$$\bar{y} = [\bar{y}^T(i + N_1), \bar{y}^T(i + N_1 + 1), \dots, \bar{y}^T(i + N_2)]^T \quad (22)$$

$$\bar{y}(i + j) = [y_1(i + j), y_2(i + j), \dots, y_m(i + j)]^T \quad (23)$$

$$\bar{y}_a = [\bar{y}_a^T(i + N_1), \bar{y}_a^T(i + N_1 + 1), \dots, \bar{y}_a^T(i + N_2)]^T \quad (24)$$

$$\bar{y}_a(i + j) = [y_{m+1}(i + j), y_{m+2}(i + j), \dots, y_{m+s}(i + j)]^T \quad (25)$$

$$\Delta \bar{u} = [\Delta u^T(i), \Delta u^T(i + 1), \dots, \Delta u^T(i + N_u - 1)]^T \quad (26)$$

$$\Delta u(i + j) = [\Delta u_1(i + j), \Delta u_2(i + j), \dots, \Delta u_m(i + j)]^T. \quad (27)$$

Optymalną w sensie minimalnokwadratowym predykcję dla odpowiednich wyjść można zapisać następująco:

$$\bar{y} = Q \Delta \bar{u} + \bar{y}^0 \quad (28)$$

$$\bar{y}_a = Q_a \Delta \bar{u} + \bar{y}_a^0. \quad (29)$$

Macierze  $Q$  and  $Q_a$  są niesymetrycznymi macierzami Toeplitza i zawierają parametry Markowa odpowiednio dla torów:  $\bar{u} \rightarrow \bar{y}$  and  $\bar{u} \rightarrow \bar{y}_a$ :

$$Q = \begin{bmatrix} H_{a,N_1} & H_{a,N_1-1} & \cdots & H_{a,1} & \cdots & 0 \\ \vdots & \vdots & & \vdots & \ddots & \vdots \\ H_{a,N_u} & H_{a,N_u-1} & \cdots & H_{a,N_u-N_1+1} & \cdots & H_{a,1} \\ \vdots & \vdots & & \vdots & & \vdots \\ H_{a,N_2} & H_{a,N_2-1} & \cdots & H_{a,N_2-N_1+1} & \cdots & H_{a,N_2-N_u+1} \end{bmatrix} \quad (30)$$

$$Q_a = \begin{bmatrix} H_{a,N_1} & H_{a,N_1-1} & \cdots & H_{a,1} & \cdots & 0 \\ \vdots & \vdots & & \vdots & \ddots & \vdots \\ H_{a,N_u} & H_{a,N_u-1} & \cdots & H_{a,N_u-N_1+1} & \cdots & H_{a,1} \\ \vdots & \vdots & & \vdots & & \vdots \\ H_{a,N_2} & H_{a,N_2-1} & \cdots & H_{a,N_2-N_1+1} & \cdots & H_{a,N_2-N_u+1} \end{bmatrix} \quad (31)$$

Bloki  $H_{a,1}$ ,  $H_{a,s}$  są parametrami Markowa. Elementy wektorów  $\bar{y}^0$  i  $\bar{y}_a^0$  reprezentują odpowiedź swobodne. Analogicznie jak w przypadku jednowymiarowym bez dodatkowych zmiennych wyjściowych można dokonać minimalizacji otrzymując następujące rozwiązanie

$$\Delta \bar{u}_{opt} = [Q_a^T W Q_a + R + Q_a^T S Q_a]^{-1} [Q^T W (\bar{w}^* - \bar{y}^0) - Q_a^T S y^0_a] \quad (32)$$

Opisany algorytm z powodzeniem zastosowano do regulacji silnika asynchronicznego (Ogonowski i in. [16]).

#### 4 Nieliniowe algorytmy optymalne

Optymalny nieliniowy regulator predykcyjny powstaje jako rozwiązanie zadania optymalizacji nieliniowej, w którym występuje ta sama jak poprzednio funkcja kryterialna (7) (lub odpowiednio (21)). Tym razem jednak predykcja wyjścia  $\bar{y}$  zależy nieliniowo od stanu początkowego i przyszłych wartości sygnału sterującego. Od stopnia złożoności modelu zależy stopień złożoności obliczeń numerycznych przy minimalizacji funkcji kryterialnej. Dodatkowo można uwzględniać ograniczenia na sygnały sterujące i stan obiektu regulacji. Tak więc w ogólnym przypadku jest to nieliniowe zadanie optymalizacji z ograniczeniami. Tylko w bardzo szczególnych i na ogół bardzo prostych przypadkach można znaleźć rozwiązanie analityczne takiego zadania. Jedynym praktycznym sposobem rozwiązania jest wykorzystanie numerycznych metod optymalizacji. Zadanie takie musi być rozwiązane w każdym okresie próbkowania.

Wobec istotnych trudności takiego podejścia należy postawić pytanie o znaczenie słowa "optymalny" w warunkach stosowania zasady repetycji. Rozwiązane zadanie optymalizacji daje bowiem optymalny ciąg przyszłych wartości sygnału sterującego w danej chwili czasu tzn. gdyby cały ten ciąg został zastosowany wtedy wartość funkcji celu byłaby minimalna. Jednak z uwagi na konieczność zamknięcia pętli regulacyjnej np. z powodu działania zakłóceń stosuje się tylko pierwszy element wyznaczonego ciągu sterowań. W istocie więc sformułowanie problemu optymalizacji jest "sztuczne" (Ogonowski [13], Ogonowski [14]).

Porównanie kilku algorytmów regulacji predykcyjnej dla bardzo typowego problemu regulacji obiektu nieliniowego, w którym nieliniowość wynika z nasycenia sygnału sterującego pokazuje jak niewielkie polepszenie jakości regulacji uzyskuje się dzięki rozwiązywaniu zadania optymalizacji (por. Ogonowski [17]). Oczywiście przyczyną tego faktu jest zasada repetycji i to, że optymalny ciąg sterowań z punktu widzenia zadania optymalizacji nie jest zarazem optymalny dla wskaźnika jakości regulacji. Ta "sztuczność" zadania optymalizacji przy syntezie regulatorów predykcyjnych znalazła też rozwinięcie w pracach Ogonowskiego [13] i [14].

## 5 Algorytmy subotymalne

Doświadczenia autora przy próbach wykorzystania różnych algorytmów regulacji temperatury wewnątrz reaktora do polimeryzacji styrenu akrylo-nitrylowego (np. Ogonowski [11]) wskazują, że zastosowanie liniowych algorytmów regulacji adaptacyjnej do nieliniowych obiektów może prowadzić do niezadawalających wyników. Po wielu próbach udało się dobrać wartości parametrów regulatora GPC oraz strukturę modelu liniowego dającą w sumie dobrą jakość regulacji, ale horyzont predykcji sygnału wyjściowego musiał wynosić 60! (Ogonowski [13]). Odporność takiego algorytmu była przy tym niewielka.

Przedstawiona w pracy Ogonowskiego [13] heurystyczna metoda syntezy algorytmu predykcyjnego wykorzystuje rozwiązanie zadania minimalizacji jak w przypadku modelu liniowego ale:

- predykcję sygnału odpowiedzi swobodnej dokonuje się przy wykorzystaniu modelu nieliniowego
- wektor wag  $q^T$  w regulatorze (por. (10)) dobiera się według modelu liniowego, ale tak aby zamknięty układ regulacji (przy założeniu, że obiekt jest liniowy) posiadał z góry założone bieguny.

Jako model nieliniowy wykorzystano statyczną sieć neuronową typu feed-forward. Uzyskano bardzo zadawalającą jakość regulacji, co więcej w zakresie zmian wartości zadanej znacznie większym niż dla innych algorytmów.

W pracy Ogonowskiego [14] przedstawiono inny sposób syntezy heurystycznego algorytmu predykcyjnego opartego na przedstawionej powyżej idei. Otrzymana z modelu nieliniowego predykcja odpowiedzi swobodnej służy do bezpośredniego wyznaczenia parametrów regulatora (wektora wag  $q^T$ ). Przedstawiony w pracy algorytm zastosowano do regulacji przykładu wielowymiarowego obiektu regulacji jakim jest wyparka cyrkulacyjna. Dla celów predykcji odpowiedzi swobodnej wykorzystano nieliniowy model wielomianowy. Uzyskano bardzo dobry przebiegi odpowiedzi na zmiany wartości zadanych. Badano przy tym prostą i adaptacyjną postać algorytmu (model wielomianowy może być identyfikowany na bieżąco rekurencyjną metodą najmniejszych kwadratów). Zagadnieniem, któremu poświęcono szczególną uwagę w pracy była odporność zaproponowanych algorytmów na zmiany parametrów obiektu regulacji i wpływ zakłóceń. Te własności układu regulacji badano na tle typowych regulatorów tj. jednopętlowych regulatorów PID, PID z odsprzęganiem oraz PID z kompensacją zakłóceń. We wszystkich przypadkach można było zaobserwować znacznie lepsze własności proponowanych regulatorów predykcyjnych niż regulatorów konwencjonalnych.

## 6 Problem predykcji – wybór modelu

Badano różne typy modeli obiektów regulacji przydatne do celów regulacji predykcyjnej w ramach zaproponowanych algorytmów regulacji. Należy tu podkreślić, że algorytmy subotymalne wykorzystują model w sposób nieparametryczny co jest ich niewątpliwą zaletą.

Wszędzie tam, gdzie dysponuje się dobrym modelem fenomenologicznym można go wykorzystać i użyć jednego z proponowanych w pracach Ogonowskiego [13] lub [14] algorytmów. W przypadku konieczności identyfikacji dobre wyniki może dać model wielomianowy jednak pod warunkiem, że zakres zmian sygnałów (wejście, stan) nie wykracza poza zakres w ramach którego dokonywano identyfikacji (Ogonowski [14]). W przeciwnym razie model wielomianowy prowadzi do bardzo dużych błędów. Problem ten jest poruszony w pracy Ogonowskiego [15].

Przykładem typowego modelu nieparametrycznego jest sztuczna sieć neuronowa. W projekcie badano takie modele pod kątem ich przydatności do proponowanych algorytmów regulacji predykcyjnej. Osobną pracę (Ogonowski [15]) poświęcono na struktury układów regulacji predykcyjnej z modelami neuronowymi. Zaproponowano dwie struktury. Pierwsza odpowiada opisanej w punkcie poprzednim metodzie wykorzystującej rozwiązanie zadania optymalizacji jak w problemie z liniowym modelem. Druga struktura jest tak skonstruowana aby rozwiązywała za pomocą sieci neuronowych problem optymalizacji.

Z wykorzystaniem sieci neuronowych wiąże się ważny i trudny problem uczenia sieci. Obecnie nie są znane algorytmy, realizujące uczenie sieci dostatecznie szybko. Najbardziej znany algorytm uczenia sieci typu feed-forward, algorytm wstecznej propagacji błędów wymaga wielu tysięcy iteracji. Tymczasem nie zawsze można poprzestać na jednokrotnym nauczeniu sieci z uwagi na potencjalną możliwość niestacjonarności obiektu. Dlatego w projekcie podjęto próbę opracowania algorytmów realizujących uczenie sieci na bieżąco. W wyniku tych prac powstało szereg propozycji, które przedstawiono w pracy Ogonowskiego i Majchera [18].

## 7 Podsumowanie

Zaproponowane algorytmy pozwalają regulować nieliniowe obiekty, dla których standardowe regulatory nie mogą być zastosowane (np. z powodu niestabilności układu) lub ich zastosowanie nie daje zadowalającej jakości regulacji. W projekcie przebadano własności algorytmów na przykładzie ich zastosowań do różnych nieliniowych obiektów regulacji. Zbadano też różne klasy modeli przydatnych do wykorzystania w proponowanych algorytmach. Rzeczą szczególnej wagi w przyszłych pracach autora jest głębsza analiza własności algorytmów oraz poszukiwanie możliwości szybkiej adaptacji modeli w warunkach niestacjonarności obiektu.

## 8 Literatura

### Literatura

- [1] L. T. Biegler, Wei Chong Li. Process Control Strategies for Constrained Nonlinear Systems. *Ind. Eng. Chem. Res.* 27, 1421-1433, 1988.
- [2] R. R. Bitmead, M. Gevers i V. Wertz. Adaptive optimal control and GPC: robustness analysis. W *Proceedings of ECC'91*, Grenoble, 1991.
- [3] D. W. Clarke, P. Tuffs i C. Mohtadi. Self-tuning control of a difficult process. W *Preprints 7th IFAC Symposium on Identification and System Parameter Estimation*, York, U.K., 1985.
- [4] D. W. Clarke. Application of Generalized Predictive Control. W *Proceedings of AD-CHEM'88*, 1988.
- [5] D. W. Clarke, T. T. C. Tsang. Generalised predictive control with input constraints. *IEE Proceedings* vol.135, no.6, 1988.
- [6] C. R. Cutler i B. C. Ramaker. Dynamic matrix control — a computer control algorithm. *AIChE National Mtg.*, 1979.
- [7] En-Bo Feng, Jin-Shou Yu, Wei-Sun Jiang. New method for predictive controller design for bilinear systems. *Int. J. Control* vol.53 no.1, 97-111, 1991.



- [8] R. M. C. Keyser de i A. R. van Cauvenberghe. Extended predictive self adaptive control. W *Preprints 7th IFAC Symposium on Identification and System Parameter Estimation*, 1255-1260, York, U.K., 1985.
- [9] R. Rouhani i R. K. Mehra. Model Algorithmic Control. Basic Properties. *Automatica*, vol.18, 4:401-414, 1982.
- [10] A. Niederliński, J. Mościński, Z. Ogonowski. Sterowanie adaptacyjne. Kurs wspomagany komputerem. *Monografia w przygotowaniu do druku*.
- [11] R. Dittmar, Z. Ogonowski i K. Damert. Predictive control of a nonlinear open-loop unstable polymerization reactor. *Chemical Engineering Science*, 46:2679-2689, 1991.
- [12] Z. Ogonowski. Non-Model Approach to Intelligent Control of a Class of Heat Exchangers. W *Preprints of Second International Conference on Automation, Robotics and Computer Vision*, Singapore, 1992.
- [13] Z. Ogonowski. Application of Model Based Predictive Control to Acrylnitryl *Polymerization Reactor* Proceedings of the 3rd IEEE Conference on Control Application, Glasgow, 1994, vol.3. pp.1903-1908
- [14] Z. Ogonowski Application of Predictive Control to Nonlinear MIMO Systems *Proceedings of IFAC Workshop: New Trends in Design of Control Systems*, Smolenice Slovakia, pp.110-115
- [15] Z. Ogonowski Neural Models in Predictive Control *Proceedings of International Symposium on Mathematical Models in Automation and Robotics*, Międzyzdroje, pp.169-174
- [16] Z. Ogonowski, Z. Świder, M.A. Brdys Generalized Predictive Control of Induction Motor *Proceedings of ECC'95*, Rzym, 1995.
- [17] Z. Ogonowski Algorytmy nieliniowej regulacji predykcijnej *Załącznik do raportu z wykonania projektu badawczego 3 P403 012 05*, praca niepublikowana, Gliwice, 1994.
- [18] Z. Ogonowski, D. Majcher *Problemy uczenia sieci neuronowych na bieżąco dla celów sterowania adaptacyjnego* Materiały I Krajowej Konferencji "Sieci Neuronowe i Ich Zastosowania", Kule, vol.2, pp.394-400
- [19] J. Richalet, B. Gibonet. Identification des systemes discrets lineaires multivariables par minimisation d'une distance de structure. *Electronic Letters*, vol.4, no.24 1968.
- [20] D. E. Seborg, T. S. Chang. A linear programming approach for multivariable feedback control with inequality constraints. *Int. J. Control* vol.37, no.3, 583-597, 1983.
- [21] B. E. Ydstie. Extended horizon adaptive control. W *Proceedings 9th IFAC World Congress*, Budapest, 1984.