

dr inż. Piotr Marusak
Instytut Automatyki i Informatyki Stosowanej
Politechniki Warszawskiej

ROZMYTE MODELE TAKAGI–SUGENO W UKŁADACH ZINTEGROWANEJ REGULACJI PREDYKCYJNEJ I OPTYMALIZACJI PUNKTU PRACY

Układy ze zintegrowanymi zadaniami regulacji predykcyjnej i optymalizacji punktu pracy są stosowane w przypadku, gdy zmienność zakłóceń jest porównywalna z dynamiką obiektu sterowania. W strukturach tych, w zadaniu zintegrowanej optymalizacji, są używane dwa modele obiektu: model dynamiczny z problemu optymalizacji algorytmu predykcyjnego oraz zlinearyzowany model statyczny. Zmiana zaproponowana w artykule polega na użyciu rozmytego modelu dynamicznego obiektu zarówno do celów regulacji, jak i optymalizacji punktu pracy. Podejście takie, przyczynia się do uproszczenia zadania, a może przynieść rozwiązania bardzo bliskie do otrzymanych w przypadku użycia dwóch modeli. Zostało to pokazane na przykładzie układu sterowania nieliniowego reaktora chemicznego z odpowiedzią odwrotną.

TAKAGI–SUGENO FUZZY MODELS IN CONTROL SYSTEMS WITH INTEGRATED PREDICTIVE CONTROL AND SET–POINT OPTIMIZATION

Control systems with integrated predictive control and set-point optimization are used in cases when variability of disturbances is comparable with dynamics of the control plant. In these structures, in the optimization problem solved by the integrated predictive controller, two control plant models are used: a dynamic model from optimization problem of a predictive algorithm and linearized steady-state model. The idea proposed in the paper consists in application of only one fuzzy (nonlinear) dynamic control plant model for realization of both tasks: predictive control and set-point optimization. Such an approach gives simplification of the problem and may give results very close to those obtained when two models are used. It is demonstrated using an example of a control system of a nonlinear chemical reactor with inverse response.

1. WSTĘP

Ze względu na niedostatki klasycznej, warstwowej struktury sterowania, ujawniające się w przypadku, gdy zmienność zakłóceń jest porównywalna z dynamiką obiektu, zaproponowane zostały w literaturze rozwiązania tego problemu polegające na wprowadzeniu stosowanych zmian do układu sterowania, zob. np. [3, 4, 5, 14, 17] i literaturę tam wymienioną. Zmiany te mają na celu częstsze przeprowadzanie optymalizacji punktu pracy niż ma to miejsce w przypadku struktury klasycznej, w której zadanie to, ze względu na konieczność rozwiązywania problemu optymalizacji nieliniowej, jest powtarzane stosunkowo rzadko. Podejścia, o których mowa, korzystają z liniowych aproksymacji modelu statycznego obiektu sterowania. W jednej z klas struktur, zadanie optymalizacji punktu pracy i zadanie regulatora predykcyjnego, są integrowane w jednym sterowniku predykcyjnym, przyczyniając się do

Praca naukowa finansowana ze środków budżetowych na naukę.

uproszczenia układu sterowania. W sterowniku predykcyjnym są więc używane dwa modele: dynamiczny model procesu z problemu optymalizacji algorytmu predykcyjnego oraz zlinearyzowany model statyczny procesu. Zmiana zaproponowana w artykule polega na użyciu dynamicznego rozmytego (nieliniowego) modelu obiektu zarówno do celów regulacji, jak i optymalizacji punktu pracy. Na podstawie tego modelu, w każdej iteracji sterownika, jest otrzymywany model liniowy, wykorzystywany zarówno do celów regulacji, jak i optymalizacji punktu pracy. Zaproponowane podejście, przyczynia się więc do uproszczenia sterownika predykcyjnego, a jednocześnie jego zastosowanie może przynieść rezultaty niewiele odbiegające od otrzymanych w przypadku użycia dwóch modeli.

W następnym rozdziale została przypomniana idea algorytmów regulacji predykcyjnej oraz krótko omówiony sposób przeprowadzania predykcji z użyciem modelu rozmytego Takagi–Sugeno. Zadanie optymalizacji punktu pracy z klasycznej, warstwowej struktury sterowania zostało przypomniane w rozdz. 3. Rozdz. 4 poświęcono sformułowaniu zadania zintegrowanej regulacji predykcyjnej i optymalizacji punktu pracy rozwiązywanych przez sterownik predykcyjny w każdej iteracji jego działania. Przedstawiono dwie wersje takiego zadania: • gdy głównym celem działania sterownika jest generacja sygnałów sterujących oraz • gdy głównym celem działania sterownika jest generacja wartości zadanych. W rozdz. 5 przedstawiono wyniki eksperymentów symulacyjnych prowadzonych w układzie sterowania nieliniowego obiektu z odpowiedzią odwrotną – reaktora z mieszaniem, w którym zachodzi reakcja van de Vusse’a. Artykuł kończy krótkie podsumowanie.

2. ALGORYTMY REGULACJI PREDYKCYJNEJ

Algorytmy regulacji predykcyjnej z przesuwającym horyzontem podczas wyznaczania sterowań biorą pod uwagę przewidywane zachowanie układu regulacji na wiele chwil do przodu. Ponadto, brane są pod uwagę ograniczenia istniejące w układzie regulacji. Dzięki takiemu podejściu, jest możliwe efektywne wykorzystanie całej dostępnej wiedzy na temat warunków działania układu regulacji podczas wyznaczania sygnałów sterujących [10]. Algorytmy predykcyjne formułuje się zwykle w postaci zadania optymalizacji [1, 7, 17]:

$$\min_{\Delta \mathbf{u}} \sum_{j=1}^{l_{wy}} \sum_{i=1}^p \kappa_j \cdot (\bar{y}_k^j - y_{k+i|k}^j)^2 + \sum_{j=1}^{l_{we}} \sum_{i=0}^{s-1} \lambda_j \cdot (\Delta u_{k+i|k}^j)^2, \quad (1)$$

przy ograniczeniach:

$$\Delta \mathbf{u}_{\min} \leq \Delta \mathbf{u} \leq \Delta \mathbf{u}_{\max}, \quad (2)$$

$$\mathbf{u}_{\min} \leq \mathbf{u} \leq \mathbf{u}_{\max}, \quad (3)$$

$$\mathbf{y}_{\min} \leq \mathbf{y} \leq \mathbf{y}_{\max}, \quad (4)$$

gdzie \bar{y}_k^j – wartość zadana dla wyjścia j , $y_{k+i|k}^j$ – przewidywana, na podstawie modelu obiektu regulacji, w bieżącej chwili k , wartość j -tego wyjścia obiektu regulacji dla przyszłej chwili $k+i$, $\Delta u_{k+i|k}^j$ – przyszłe (szukane) przyrosty sterowania dla j -tego wejścia, p jest horyzontem predykcji, $s \leq p$ jest horyzontem sterowania; l_{wy} , l_{we} – liczba odpowiednio: wyjść i wejść obiektu regulacji, $\kappa_j \geq 0$ to współczynniki ważące przyszłe uchyby na j -tym wyjściu, $\lambda_j \geq 0$ – współczynniki ważące przyrosty sterowania dla j -tego wejścia w składniku będącym karą za zmienność sterowania; $\Delta \mathbf{u}$, \mathbf{u} , \mathbf{y} – wektory przyszłych wartości odpowiednio: przyrostów sterowań, sterowań i wyjść, $\Delta \mathbf{u}_{\min}$, $\Delta \mathbf{u}_{\max}$, \mathbf{u}_{\min} , \mathbf{u}_{\max} , \mathbf{y}_{\min} , \mathbf{y}_{\max} – wektory ograniczeń dolnych i górnych odpowiednio: przyrostów sterowań, wartości sterowań i wartości wyjść obiektu.

Zauważmy, że minimalizowany wskaźnik jakości wyraża żądanie, aby przyszłe uchyby regulacji były możliwie małe, przy możliwie niewielkiej zmienności sygnału sterującego. W wyniku rozwiązania zadania optymalizacji (1), jest otrzymywany wektor przyszłych przyrostów sterowań Δu , z którego elementy $\Delta u_{k|k}^j$ są przekazywane do obiektu regulacji, a następnie zadanie optymalizacji jest rozwiązywane ponownie, w kolejnej iteracji.

Sposób wyznaczania predykcji y zależy od użytego modelu. Problem optymalizacji (1–4), w przypadku, gdy przyszłe wartości wyjść y są przewidywane z wykorzystaniem modelu liniowego jest powszechnie znanym, szeroko stosowanym i łatwym do rozwiązania zadaniem optymalizacji kwadratowej z liniowymi ograniczeniami. Niestety, w przypadku zastosowania algorytmu bazującego na modelu liniowym do nieliniowego obiektu, otrzymane rezultaty mogą być albo niezadowolające albo działanie układu regulacji może zostać poprawione dzięki skorzystaniu z nieliniowego modelu obiektu. Ma to duże znaczenie szczególnie w przypadku pracy w szerokim zakresie zmian wartości zadanych. Niestety, w wyniku bezpośredniego zastosowania modelu nieliniowego w zadaniu (1–4) otrzyma się, zamiast wypukłego zadania programowania kwadratowego, w ogólności niewypukły problem optymalizacji nieliniowej, którego rozwiązanie jest trudne i czasochłonne, bez gwarancji znalezienia optimum globalnego.

Mając powyższe na względzie, można zastosować szereg podejść polegających na otrzymywaniu, w każdej iteracji algorytmu, na podstawie nieliniowego modelu obiektu, jego liniowej aproksymacji, która jest następnie wykorzystywana do sformułowania zadania optymalizacji kwadratowej; zob. np. [8, 17].

2.1. Algorytmy z modelami rozmytymi Takagi–Sugeno

Otrzymywanie liniowej aproksymacji dynamicznego modelu obiektu jest szczególnie ułatwione w przypadku użycia modeli rozmytych typu Takagi–Sugeno [16]. Rozważmy przy tym łatwy do otrzymania model z następnikami w postaci odpowiedzi skokowych obiektu, opisany następującymi regułami:

Jeśli $y_k^{j_y}$ jest B_1^{f,j_y} i ... i $y_{k-n_p+1}^{j_y}$ jest $B_{n_p}^{f,j_y}$ i ... i $u_k^{j_u}$ jest C_1^{f,j_u} i ... i $u_{k-m_p+1}^{j_u}$ jest $C_{m_p}^{f,j_u}$

$$\text{to } \tilde{y}_{k+1}^{j,f} = \sum_{m=1}^{n_u} \sum_{i=1}^{p_d-1} a_i^{j,m,f} \cdot \Delta u_{k-i}^m + a_{p_d}^{j,m,f} \cdot u_{k-p_d}^m, \quad (5)$$

gdzie $y_k^{j_y}$ jest wartością j_y -tego wyjścia obiektu w k -tej chwili próbkowania, $u_k^{j_u}$ jest wartością j_u -tego sterowania w k -tej chwili próbkowania, $B_1^{f,j_y}, \dots, B_{n_p}^{f,j_y}, C_1^{f,j_u}, \dots, C_{m_p}^{f,j_u}$ są zbiorami rozmytymi, $a_i^{j,m,f}$ są współczynnikami odpowiedzi skokowych w f -tym modelu lokalnym opisującym wpływ m -tego sterowania na j -te wyjście, $j_y = 1, \dots, n_y, j_u = 1, \dots, n_u, f = 1, \dots, l$, l jest liczbą reguł. Wyjście całego modelu jest obliczane na podstawie następującego wzoru:

$$\tilde{y}_k^j = \sum_{m=1}^{n_u} \sum_{i=1}^{p_d-1} \tilde{a}_i^{j,m} \cdot \Delta u_{k-i}^m + \tilde{a}_{p_d}^{j,m} \cdot u_{k-p_d}^m, \quad (6)$$

gdzie $\tilde{a}_i^{j,m} = \sum_{f=1}^l \tilde{w}_f \cdot a_i^{j,m,f}$ a \tilde{w}_i są znormalizowanymi wagami obliczonymi w każdej iteracji przy użyciu wnioskowania rozmytego, dla bieżących wartości wejść i wyjść obiektu; zob.

np. [16]. Zauważmy, że model (6) może być interpretowany jako odpowiedź skokowa obiektu opisująca zachowanie obiektu w okolicach bieżącego punktu pracy. Modelu tego można użyć do predykcji zachowania obiektu, przeprowadzając tę predykcję w taki sam sposób, jak w algorytmie DMC [1, 7, 10, 15, 17], co prowadzi do sformułowania zadania (1–4) będącego kwadratowym problemem optymalizacji [9].

3. WARSTWA OPTIMALIZACJI EKONOMICZNEJ

W klasycznym, warstwowym układzie sterowania, za wyznaczanie pożądanych wartości zadanych odpowiada warstwa optymalizacji, w której, problem optymalizacji ekonomicznej ma zwykle następującą postać:

$$\min_{\bar{y}, \bar{u}} J_E(\bar{y}, \bar{u}), \quad (7)$$

przy ograniczeniach:

$$\bar{u}_{\min} \leq \bar{u} \leq \bar{u}_{\max}, \quad (8)$$

$$\bar{y}_{\min} \leq \bar{y} \leq \bar{y}_{\max}, \quad (9)$$

$$\bar{y} = F(\bar{u}, \tilde{d}), \quad (10)$$

gdzie $F: \mathbb{R}^{n_u} \times \mathbb{R}^{n_d} \rightarrow \mathbb{R}^{n_y}$ – zwykle nieliniowy model statyczny procesu, n_d – liczba zmiennych zakłócających, \bar{y} – wektor wartości zadanych \bar{y}_k^j , \bar{u} – wektor odpowiadających im wartości sterowań, wyznaczonych na podstawie modelu statycznego obiektu $\bar{y} = F(\bar{u}, \tilde{d})$, \tilde{d} – estymata zakłóceń, $\bar{u}_{\min}, \bar{u}_{\max}$ – wektory ograniczeń dolnych i górnych wejść obiektu, $\bar{y}_{\min}, \bar{y}_{\max}$ – wektory ograniczeń dolnych i górnych wyjść obiektu. $J_E(\bar{y}, \bar{u})$ jest wskaźnikiem jakości, zwykle natury ekonomicznej i przeważnie liniowym względem zmiennych wyjściowych i sterujących. W wyniku rozwiązania problemu optymalizacji (7–10), otrzymuje się wartości zadane dla regulatorów.

4. ZADANIA ZINTEGROWANEJ REGULACJI PREDYKCYJNEJ I OPTIMALIZACJI PUNKTU PRACY

W przypadku, gdy zmienność zakłóceń jest porównywalna z dynamiką obiektu sterowania, użycie klasycznej, warstwowej struktury sterowania, z niską częstotliwością interwencji warstwy optymalizacji punktu pracy, może przynieść rezultaty dalekie od optymalnych. Jednym z rozwiązań tego problemu jest zastosowanie zintegrowanej regulacji predykcijnej i optymalizacji punktu pracy [4, 5, 6, 17, 18, 19, 20]. W zależności od potrzeb, możliwe jest zastosowanie dwóch metod integracji. W przypadku pierwszej, głównym celem rozwiązane zadania zintegrowanego jest otrzymanie sterowań, które można następnie przesłać bezpośrednio do obiektu. W drugim przypadku, zadanie zintegrowane służy do generacji wartości zadanych, przekazywanych następnie warstwie regulacji bezpośredniej (regulatorom, które zwykle nie uwzględniają ograniczeń). W tej konfiguracji, sterownik dba nie tylko o generację wartości zadanych, ale także spełnienie ograniczeń istniejących w układzie sterowania. Integracji zadań należy dokonać w taki sposób, aby główna zaleta struktury zintegrowanej – efektywność numeryczna – była zachowana. Należy więc dążyć do sformułowania zadania zintegrowanego jako zadania optymalizacji kwadratowej.

4.1. Przypadek generacji sterowań

Integracja algorytmu regulacji predykcyjnej z optymalizacją punktu pracy, w tej wersji, polega na modyfikacji problemu optymalizacji regulatora predykcyjnego (1–4). Główne zmiany to: dodanie do wskaźnika jakości algorytmu składnika zależnego od funkcji celu $J_E(\bar{\mathbf{y}}, \bar{\mathbf{u}})$ z problemu rozwiązywanego w warstwie optymalizacji punktu pracy, dodanie ograniczeń (8) i (9) oraz dokonywanie aproksymacji modelu statycznego (10) procesu w każdej iteracji algorytmu. Więcej szczegółów, zainteresowany czytelnik może znaleźć, np. w [4, 5, 17, 18, 19, 20]. Problem optymalizacji rozwiązywany w każdej iteracji przez algorytm zintegrowanej regulacji i optymalizacji punktu pracy ma zwykle postać:

$$\min_{\Delta \mathbf{u}, \bar{\mathbf{y}}, \bar{\mathbf{u}}} J_{MPC}(\bar{\mathbf{y}}, \Delta \mathbf{u}) + \gamma \cdot J_E(\bar{\mathbf{y}}, \bar{\mathbf{u}}), \quad (11)$$

przy ograniczeniach:

$$\Delta \mathbf{u}_{\min} \leq \Delta \mathbf{u} \leq \Delta \mathbf{u}_{\max}, \quad (12)$$

$$\mathbf{u}_{\min} \leq \mathbf{u} \leq \mathbf{u}_{\max}, \quad (13)$$

$$\mathbf{y}_{\min} \leq \mathbf{y} \leq \mathbf{y}_{\max}, \quad (14)$$

$$\bar{\mathbf{u}}_{\min} \leq \bar{\mathbf{u}} \leq \bar{\mathbf{u}}_{\max}, \quad (15)$$

$$\bar{\mathbf{y}}_{\min} \leq \bar{\mathbf{y}} \leq \bar{\mathbf{y}}_{\max}, \quad (16)$$

$$\bar{\mathbf{y}} = \mathbf{H}(k) \cdot \bar{\mathbf{u}} + \mathbf{C}(k), \quad (17)$$

gdzie γ jest współczynnikiem wagowym (im większą wartość on przyjmuje, tym większy jest wpływ części ekonomicznej wskaźnika jakości); (17) jest liniowym przybliżeniem modelu statycznego obiektu sterowania. Zwykle stosuje się tutaj linearyzację pełnego, nieliniowego modelu statycznego procesu przeprowadzaną w każdej iteracji, zob. np. [4, 5, 17]. W takim przypadku, macierz $\mathbf{H}(k)$ jest macierzą, która zawiera pochodne cząstkowe modelu statycznego, zwykle obliczane numerycznie.

W rozwiązaniu proponowanym w niniejszej pracy, aproksymację modelu statycznego (17) otrzymuje się na podstawie modelu (6). Model (17) jest więc także zmieniany w każdej iteracji, ale główna część obliczeń jest i tak przeprowadzana na potrzeby wyznaczenia predykcji \mathbf{y} . Zauważmy, że dzięki zastosowaniu modelu rozmytego z modelami w postaci odpowiedzi skokowych, wyznaczanie macierzy $\mathbf{H}(k)$ jest szczególnie proste, ponieważ jej elementami będą ostatnie rzędne odpowiedzi skokowych $\tilde{\alpha}_{pd}^{j,m}$, będące, de facto, współczynnikami wzmocnień obiektu sterowania.

4.2. Przypadek generacji wartości zadanych

Problem zintegrowanej regulacji predykcyjnej i optymalizacji punktu pracy, w takiej wersji, może być sformułowany jako modyfikacja zadania (7–10) rozwiązywanego w warstwie optymalizacji [6]. Modyfikacja ta polega na: dodaniu ograniczeń (2–4) z problemu optymalizacji rozwiązywanego przez algorytm predykcyjny, linearyzacji modelu statycznego obiektu sterowania (10) i dodaniu modelu regulatorów warstwy bezpośredniej. Problem optymalizacji będzie miał, tym razem, postać:

$$\min_{\bar{\mathbf{y}}, \bar{\mathbf{u}}} J_E(\bar{\mathbf{y}}, \bar{\mathbf{u}}) \quad (18)$$

przy ograniczeniach:

$$\bar{\mathbf{u}}_{\min} \leq \bar{\mathbf{u}} \leq \bar{\mathbf{u}}_{\max}, \quad (19)$$

$$\bar{y}_{\min} \leq \bar{y} \leq \bar{y}_{\max}, \quad (20)$$

$$\bar{y} = \mathbf{H}(k) \cdot \bar{\mathbf{u}} + \mathbf{C}(k), \quad (21)$$

$$\Delta \mathbf{u}_{\min} \leq \Delta \mathbf{u} \leq \Delta \mathbf{u}_{\max}, \quad (22)$$

$$\mathbf{u}_{\min} \leq \mathbf{u} \leq \mathbf{u}_{\max}, \quad (23)$$

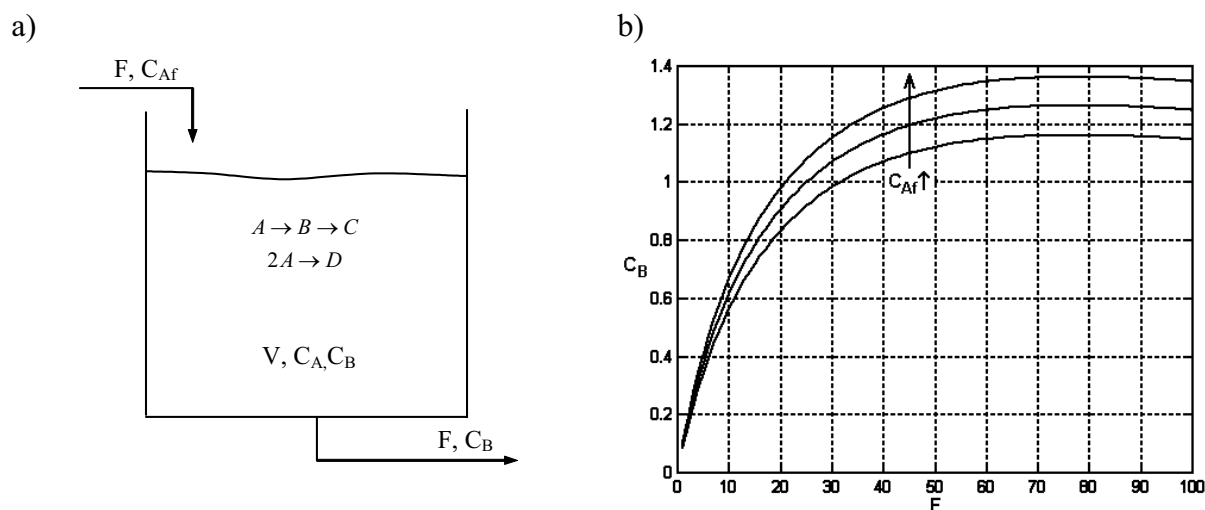
$$\mathbf{y}_{\min} \leq \mathbf{y} \leq \mathbf{y}_{\max}, \quad (24)$$

$$\Delta \mathbf{u} = R(\bar{y}, \mathbf{y}^p, \mathbf{u}^p), \quad (25)$$

gdzie (21) jest liniową aproksymacją modelu statycznego obiektu sterowania (którą można otrzymać na podstawie modelu rozmytego, w sposób opisany w rozdz. 4.1). Ograniczenia (22–24) są takie same, jak w zadaniu regulatora predykcyjnego (rozdz. 2). Przewidywane wartości wyjść \mathbf{y} są obliczane z wykorzystaniem dynamicznego modelu obiektu. Charakterystyczną cechą powyższego zadania jest to, że także model regulatorów tworzących warstwę regulacji bezpośredniej (25) jest uwzględniany podczas generacji wartości zadanych. Model ten jest zwykle liniową zależnością wartości zadanych \bar{y} , przeszłych wartości wyjść obiektu \mathbf{y}^p i przeszłych wartości sterowań \mathbf{u}^p . Najczęściej, w warstwie regulacji bezpośredniej stosuje się regulatory PID. Możliwe jest także użycie, szczególnie dla obiektów o trudnej dynamice lub o wielu wejściach i wielu wyjściach, regulatorów predykcyjnych w wersji analitycznej [10, 15, 17]. Dzięki uwzględnieniu modelu regulatorów w problemie optymalizacji (18–25), ograniczenia nałożone na wartości sterowań, generowanych przez regulatory warstwy bezpośredniej, są brane pod uwagę podczas wyznaczania wartości zadanych [6].

5. EKSPERYMENTY SYMULACYJNE

Przykładowym obiektem regulacji jest nieliniowy reaktor chemiczny, w którym zachodzi reakcja van de Vusse'a (rys. 1a) [2]. Charakterystyki statyczne obiektu są pokazane na rys. 1b.



Rys. 1. Reaktor chemiczny, w którym zachodzi reakcja van de Vusse'a;
a) schemat, b) charakterystyki statyczne $C_B(F)$

Równania opisujące zachodzące w reaktorze zmiany składów są następujące:

$$\begin{aligned}\frac{dC_A}{dt} &= -k_1 C_A - k_3 C_A^2 + \frac{F}{V} (C_{Af} - C_A), \\ \frac{dC_B}{dt} &= k_1 C_A - k_2 C_B - \frac{F}{V} C_B,\end{aligned}\quad (26)$$

gdzie C_A , C_B są stężeniami substancji A i B, F jest dopływem surowca (równym odpływowi z reaktora), V jest objętością, w której zachodzi reakcja (jest ona założona stała i równa $V=1$ l), C_{Af} jest stężeniem substancji A w strumieniu surowca. Wartości parametrów reakcji są następujące: $k_1=50$ 1/h, $k_2=100$ 1/h, $k_3=10$ l/h·mol [2].

Zmienną wyjściową jest stężenie C_B substancji B w produkcie, a zmienną sterującą – natężenie dopływu surowca F . Podczas eksperymentów założono, że zakłócenie C_{Af} zmienia się zgodnie z zależnością:

$$C_{Af}(t) = C_{Af0} - \sin\left(\frac{2\pi}{0,4} t\right), \quad (27)$$

gdzie $C_{Af0}=10$ mol/l. Przyjęto następującą ekonomiczną funkcję celu:

$$J_E = -F, \quad (28)$$

której minimalizacja zapewni maksymalną produkcję. Założono, że zmienna sterująca jest ograniczona

$$0 \text{ l/h} \leq F \leq 60 \text{ l/h}. \quad (29)$$


Założono również, że produkt powinien spełniać następujące kryterium czystości

$$1,1 \text{ mol/l} \leq C_B \leq 1,2 \text{ mol/l}. \quad (30)$$


Do przedstawionego obiektu sterowania zastosowano strukturę z regulatorem analitycznym oraz sterownikiem predykcyjnym generującym wartości zadane, opisanym w rozdz. 4.2. Jako regulatora analitycznego użyto algorytmu DMC bazującego na odpowiedzi skokowej obiektu pozyskanej z okolic punktu pracy $C_{B0}=1,12$ mol/l, $C_{A0}=3$ mol/l, $F=34,3$ l/h; przyjęto następujące wartości parametrów: $p=70$, $s=35$, $\kappa=1$, $\lambda=0,001$. Sterownik predykcyjny bazuje na modelu rozmytym typu Takagi–Sugeno z modelami lokalnymi w postaci odpowiedzi skokowych otrzymanych z okolic następujących punktów pracy:

- 1) $C_{B0}=0,91$ mol/l, $C_{A0}=2,18$ mol/l, $F=20$ l/h
- 2) $C_{B0}=1,12$ mol/l, $C_{A0}=3$ mol/l, $F=34,3$ l/h
- 3) $C_{B0}=1,22$ mol/l, $C_{A0}=3,66$ mol/l, $F=50$ l/h

Użyty model rozmyty jest więc złożony z trzech reguł. Założone funkcje przynależności zostały pokazane na rys. 2.



Rys. 2. Funkcje przynależności modelu rozmytego



Rys. 3. Odpowiedzi na zmiany składu surowca C_{Af} układów sterowania ze sterownikiem predykcyjnym: bazującym na modelu liniowym i linearyzacji modelu statycznego, bazującym na modelu rozmytym i linearyzacji modelu statycznego, bazującym na modelu rozmytym użytym również do wyznaczenia liniowej aproksymacji modelu statycznego; a) wyjście C_B , b) sterowanie F

Badano działanie trzech układów sterowania, ze sterownikiem predykcyjnym bazującym na:

- 1) modelu liniowym i linearyzacji modelu statycznego,
- 2) modelu rozmytym i linearyzacji modelu statycznego,
- 3) modelu rozmytym użytym także do wyznaczenia liniowej aproksymacji modelu statycznego. We wszystkich trzech przypadkach otrzymano podobne odpowiedzi na zmiany składu surowca C_{Af} (rys. 3). Miało to swoje odzwierciedlenie również w wartościach ekonomicznego wskaźnika jakości (zestawionych w tabl. 1) liczonego jako suma chwilowych wartości wskaźnika (28).

Tabl. 1. Wartości ekonomicznego wskaźnika jakości dla poszczególnych układów sterowania

Numer układu sterowania	Wartość wskaźnika jakości
1.	-55,9389
2.	-56,5788
3.	-56,7060

Użycie aproksymacji modelu statycznego obiektu, pozyskiwanej z dynamicznego modelu rozmytego obiektu, przyniosło rezultaty zbliżone do otrzymanych z zastosowaniem linearyzacji pełnego, nieliniowego modelu procesu. Zauważmy, analizując wartości wskaźnika jakości z tabl. 1, że różnica w działaniu układów ze sterownikami predykcyjnymi opartymi na modelu rozmytym Takagi–Sugeno (2 i 3) jest znacznie mniejsza niż między każdym z tych układów z osobna a układem 1, w którym sterownik predykcyjny bazuje na modelu liniowym (pojedynczej odpowiedzi skokowej). Istotne znaczenie dla jakości działania układu sterowa-

nia ma więc zastosowanie nieliniowego (w tym przypadku – rozmytego) modelu dynamicznego obiektu. Warto także zaznaczyć, że zadanie optymalizacji rozwiązywane w każdej iteracji sterownika predykcyjnego w wersji 3 zostało uproszczone w stosunku do zadania rozwiązywanego przez sterownik pracujący w konfiguracji 2.

6. PODSUMOWANIE

W niniejszej pracy podjęto problem uproszczenia układów ze sterownikami predykcyjnymi integrującymi zadania regulacji predykcyjnej i optymalizacji punktu pracy. Zaproponowano zmianę polegającą na użyciu dynamicznego modelu rozmytego obiektu zarówno do celów regulacji, jak i optymalizacji punktu pracy. Liniowa aproksymacja modelu statycznego procesu jest więc otrzymywana w każdej iteracji sterownika na podstawie rozmytego, dynamicznego modelu obiektu. Na przykładzie układu sterowania obiektu o trudnej dynamice pokazano, że zaproponowane podejście może przynieść rozwiązania bardzo bliskie otrzymywanych w układach, w których w każdej iteracji algorytmu sterownika predykcyjnego, wykonywana jest linearyzacja pełnego, nieliniowego modelu procesu.

W przedstawionym podejściu zaproponowano użycie modeli rozmytych typu Takagi–Sugeno z modelami lokalnymi w postaci odpowiedzi skokowych. Modele takie mogą być otrzymane stosunkowo łatwo, a ponadto uzyskanie na ich podstawie liniowej aproksymacji modelu statycznego procesu jest szczególnie proste. Przedstawione podejście można więc, w stosunkowo łatwy sposób, zastosować w już istniejących układach sterowania, rozszerzając tym samym ich możliwości.

7. LITERATURA

- [1] E.F. Camacho, C. Bordons: *Model Predictive Control in the process industry*; Springer, 1995.
- [2] F. Doyle, B.A. Ogunnaiké, R.K. Pearson: *Nonlinear model-based control using second-order Volterra models*. Automatica, tom 31, s. 697–714, 1995.
- [3] M. Ławryńczuk, P. Marusak, P. Tatjewski: *Integrating predictive control with steady-state optimisation*. 12th International Conference on Methods and Models in Automation and Robotics MMAR 2006, Międzyzdroje, s. 445–452.
- [4] M. Ławryńczuk, P. Marusak, P. Tatjewski: *Struktury i algorytmy współdziałania regulacji predykcyjnej i bieżącej optymalizacji ekonomicznej*. Pomiary Automatyka Kontrola, nr 10/2007, s. 55–61
- [5] M. Ławryńczuk, P. Marusak, P. Tatjewski: *Multilayer and integrated structures for predictive control and economic optimisation*. 11th IFAC/IFORS/IMACS/IFIP Symposium on Large Scale Systems: Theory and Applications, Gdańsk, CD-ROM, artykuł nr 60.
- [6] M. Ławryńczuk, P. Marusak, P. Tatjewski: *Set-Point Optimisation and Predictive Constrained Control for Fast Feedback Controlled Processes*. 13th IEEE/IFAC International Conference on Methods and Models in Automation and Robotics MMAR 2007, Szczecin, s. 357–362.
- [7] J.M. Maciejowski: *Predictive Control with constraints*; Prentice Hall 2002.
- [8] P. Marusak: *Regulacja predykcyjna obiektów nieliniowych z zastosowaniem techniki DMC i modelowania rozmytego*; Rozprawa doktorska, Wydz. Elektroniki i Technik Informatycznych Politechniki Warszawskiej, Warszawa, 2002.

- [9] P. Marusak: *Metoda szybkiej syntezy rozmytych regulatorów predykcyjnych DMC – zastosowanie do nieliniowego obiektu*; Konferencja Automation 2006, Warszawa, s. 382–391.
- [10] P. Marusak, J. Pułaczewski: *Szczególne zalety algorytmu regulacji Dynamic Matrix Control (DMC)*; Pomiary Automatyka Kontrola 12'99, s. 39–43.
- [11] P. Marusak, P. Tatjewski: *Output constraints in fuzzy DMC algorithms with parametric uncertainty in process models*; 7th International Conference MMAR 2001, Międzyzdroje, s. 517–522.
- [12] P. Marusak, P. Tatjewski: *Predictive control algorithms in systems tolerating actuator faults*; Proc. 10th International Conference MMAR 2004, Międzyzdroje, s. 1355–1360.
- [13] R.B. Newell, P.L. Lee: *Applied process control – a case study*; Prentice Hall, 1989.
- [14] S.J. Qin, T. A. Badgwell: *A survey of industrial model predictive control technology*; Control Engineering Practice, tom 11, s. 733–764, 2003.
- [15] J. Pułaczewski: *Wielowymiarowy algorytm DMC*; Raport IAiS PW nr 98–11, Warszawa, 1998
- [16] T. Takagi, M. Sugeno: *Fuzzy identification of systems and its application to modeling and control*. IEEE Trans. on Systems, Man and Cybernetics, tom 15, s. 116–132, 1985.
- [17] P. Tatjewski: *Advanced control of industrial processes: structures and algorithms*. Springer, Londyn, 2007.
- [18] M. Tvrzaska de Gouvea, D. Odloak: *One-layer real time optimization of LPG production in the FCC unit: procedure, advantages and disadvantages*. Computers & Chemical Engineering, tom 22, s. S191–S198, 1998.
- [19] A. Zanin, M. Tvrzaska de Gouvea, D. Odloak: *Industrial implementation of a real-time optimization strategy for maximizing production of LPG in a FCC unit*. Computers & Chemical Engineering, tom 24, s. 525–531, 2000.
- [20] A. Zanin, M. Tvrzaska de Gouvea, D. Odloak: *Integrating real-time optimization into model predictive controller of the FCC system*. Computers & Chemical Engineering, tom 26, s. 819–831, 2002.