

Wykorzystanie właściwości algorytmów regulacji predykcyjnej w detekcji uszkodzeń

Piotr M. Marusak

Instytut Automatyki i Informatyki Stosowanej, Politechnika Warszawska

Streszczenie: Algorytmy regulacji predykcyjnej dzięki sposobowi ich formułowania, w którym w umiejętny sposób wykorzystuje się model procesu, gwarantują bardzo dobrą jakość regulacji. Często ma to miejsce także w przypadku wystąpienia uszkodzenia w układzie regulacji. Wiele takich uszkodzeń może być nawet trudnych do zauważenia dzięki działaniu regulatora, jednak pożądane jest ich wykrycie. W artykule zaproponowano wykorzystanie w celu wykrywania uszkodzeń faktu, że w algorytmach regulacji predykcyjnej na bieżąco oceniana jest jakość modelu, na którym algorytm bazuje, przez porównywanie jego wyjścia z wartością wyjścia obiektu. Metoda może więc zostać użyta w algorytmach regulacji predykcyjnej dowolnego typu, bazujących zarówno na liniowych, jak i nieliniowych modelach obiektów.

Słowa kluczowe: regulacja predykcyjna, detekcja uszkodzeń, regulacja odporna na uszkodzenia

1. Wstęp

Dzięki użyciu modelu obiektu w algorytmach regulacji predykcyjnej dysponują one szeregiem zalet [1, 7, 19, 20]. Oferują one bardzo dobrą jakość regulacji, także w przypadku obiektów trudnych do sterowania (duże opóźnienia, odpowiedź odwrotna). Sprawdzają się również bardzo dobrze w układach regulacji tolerujących uszkodzenia. Większość prac na ten temat dotyczy algorytmów regulacji predykcyjnej bazujących na modelach liniowych [23, 24]. W pracy [21] można znaleźć szeroki przegląd zagadnienia projektowania algorytmów regulacji predykcyjnej dla układów regulacji tolerujących uszkodzenia, ukierunkowany głównie na algorytmy bazujące na modelach liniowych.

W [2] opisano podejście typu wirtualny element wykonawczy (ang. *virtual actuator*) dla algorytmu bazującego na modelu rozmytym Takagi-Sugeno. Sposoby rekonfiguracji algorytmów predykcyjnych bazujących zarówno na modelach nieliniowych, jak i liniowych, w przypadku wystąpienia awarii elementu wykonawczego zostały omówione w [9, 12, 14] a w przypadku awarii czujników w [8, 16]. Rozważane były szczególnie zagadnienia zapewnienia akceptowalnego działania układu regulacji po wystąpieniu awarii oraz spełnienia kluczowych ograniczeń. Przedstawione w wymienionej literaturze metody rekonfiguracji, mogą być zastosowane także w przypadku innych uszkodzeń a nie tylko awarii czujników czy elementów wykonawczych. Szersze możliwości przeciwdziałania skutkom awarii istnieją w strukturach z regulatorami predykcyj-

nymi współpracującymi z optymalizacją punktu. Zagadnienia te zostały podjęte w [10, 11, 13, 17].

Oprócz awarii prowadzących do strukturalnych zmian w układzie sterowania, mogą także wystąpić mniejsze uszkodzenia, które mogą powoli narastać. Dzięki pracy regulatora mogą one zostać przez dłuższy czas niezauważone, a jakość regulacji może nie ulec znaczącemu pogorszeniu. Ze względu jednak na to, że sytuacja z biegiem czasu może się pogorszyć i doprowadzić do kosztownej w skutkach awarii, należy wszelkie uszkodzenia jak najwcześniej wykrywać. Celowi temu służy szereg metod, których dokładne omówienie można znaleźć np. w [4–6, 22]. Metody te wymagają jednak użycia dodatkowego modułu, często skomplikowanego, na bieżąco analizującego proces.

W niniejszym artykule zaproponowano podejście, w którym obserwacja wewnętrznych sygnałów regulatora predykcyjnego może pomóc w wykryciu uszkodzenia. Metoda ta może zostać użyta z każdym algorytmem regulacji predykcyjnej, tzn. bazującym zarówno na liniowym, jak i nieliniowym modelu procesu, a w tym drugim przypadku także w algorytmach z linearyzacją.

W rozdziale 2 opisano algorytmy regulacji predykcyjnej bazujące zarówno na liniowych, jak i nieliniowych modelach obiektów. Przedstawiono tam także ideę zaproponowanego podejścia i wskazano, który element w sformułowaniu algorytmu może być przydatny do wykrywania uszkodzeń. W rozdziale 3 przedstawiono przykład zastosowania opisanej metody wykrywania uszkodzeń w układzie regulacji nieliniowego obiektu o trudnej dynamice. Zamieszczone w tym rozdziale wyniki eksperymentów symulacyjnych ilustrują przydatność zaproponowanego podejścia. Artykuł kończy krótkie podsumowanie.

2. Algorytmy regulacji predykcyjnej

Algorytmy regulacji predykcyjnej (ang. *Model Predictive Control* – MPC) podczas wyznaczania sterowania, korzystają z predykcji zachowania obiektu regulacji w wielu przyszłych chwilach. Sygnał sterujący jest generowany w taki sposób, aby przewidywane zachowanie obiektu regulacji spełniało założone kryteria. Kryteria te służą do sformułowania problemu optymalizacji (zwykle z ograniczeniami nałożonymi na sygnały sterujące i wyjściowe), w wyniku rozwiązania którego otrzymuje się bieżącą wartość sterowania, zob. np. [1, 7, 20]:

$$\arg \min_{\mathbf{u}} \left\{ J_{MPC} = \sum_{i=1}^p (\bar{y}_k - y_{k+i|k})^2 + \sum_{i=0}^{s-1} \gg \cdot (\Delta u_{k+i|k})^2 \right\}, \quad (1)$$

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 jest wartością zadaną, $y_{k+i|k}$ jest przewidywaną w bieżącej chwili k wartością wyjścia obiektu dla przyszłej chwili $k+i$, wyznaczaną na podstawie modelu obiektu regulacji, $\Delta u_{k+i|k}$ jest przyszłym (szukanym) przyrostem sterowania, p jest horyzontem predykcji, $s \leq p$ jest horyzontem sterowania, $\lambda \geq 0$ jest współczynnikiem ważącym przeszłe przyrosty sterowania, $\Delta \mathbf{u} = [\Delta u_{k|k}, \dots, \Delta u_{k+s-1|k}]^T$ jest wektorem zmiennych decyzyjnych, $\mathbf{u} = [u_{k|k}, \dots, u_{k+s-1|k}]^T$, $\mathbf{y} = [y_{k+1|k}, \dots, y_{k+p|k}]^T$; $\Delta \mathbf{u}_{\min}$, $\Delta \mathbf{u}_{\max}$, \mathbf{u}_{\min} , \mathbf{u}_{\max} , \mathbf{y}_{\min} , \mathbf{y}_{\max} są wektorami dolnych i górnych ograniczeń wartości odpowiednio: przyrostów sterowania, sterowania i wyjścia obiektu.

Rozwiązaniem zadania optymalizacji (1–4) jest wektor zawierający przyszłe, optymalne przyrosty sterowania. W bieżącej iteracji pierwszy z elementów tego wektora jest używany do sterowania obiektu a następnie algorytm przechodzi do kolejnej iteracji, w której problem optymalizacji (1–4) jest rozwiązywany ponownie, dla bieżących wartości wyjścia i sterowania.

Podstawą algorytmów predykcyjnych jest wyznaczenie przewidywanych wartości wyjścia obiektu $y_{k+i|k}$ na podstawie modelu obiektu:

$$y_{k+i|k} = \hat{y}_{k+i|k} + d_k, \quad (5)$$

gdzie $\hat{y}_{k+i|k}$ jest wartością wyjścia modelu dla chwili $k+i$, $d_k = y_k - \hat{y}_{k|k-1}$ jest modelem zakłóceń niemierzalnych typu DMC (jeśli nie dysponuje się lepszą prognozą zakłóceń, przyjmuje się, że jest ono stałe na całym horyzoncie predykcji), y_k jest zmierzoną wartością wyjścia obiektu. Zauważmy, że d_k opisuje różnicę między modelem a obiektem. W szczególności, jeśli w układzie regulacji dojdzie do uszkodzenia któregoś z elementów, a nie zostało to wcześniej wykryte i uwzględnione w modelu obiektu wykorzystywanym przez algorytm, wpływ tego uszkodzenia powinien być widoczny w sygnale d_k . Sygnał ten, oprócz sygnału sterującego generowanego przez regulator, można więc użyć do wykrycia uszkodzenia.

Uwaga: Model zakłóceń niemierzalnych d_k powinien być wykorzystywany w każdym z algorytmów regulacji predykcyjnej, niezależnie od użytego w nim modelu i sposobu wyznaczania predykcji. W przeciwnym przypadku działanie regulatora nie będzie zadowalające, w szczególności nie będzie eliminowany uchyb ustalony.

Dokładny sposób wyznaczania predykcji zależy od postaci użytego modelu. W przypadku modeli liniowych wyznaczenie predykcji jest szczególnie proste.

2.1. Algorytmy bazujące na modelach liniowych

Jeśli do predykcji używany jest model liniowy obiektu, wówczas problem optymalizacji (1–4) jest standardowym problemem liniowo-kwadratowym [1, 7, 19, 20]. Dzieje się tak, ponieważ w przypadku zastosowania modeli liniowych wektor zawierający przewidywane wartości wyjścia obiektu regulacji \mathbf{y} można, dzięki zasadzie superpozycji, zapisać w następującej postaci:

$$\mathbf{y} = \tilde{\mathbf{y}} + \mathbf{A} \cdot \Delta \mathbf{u}, \quad (6)$$

gdzie $\tilde{\mathbf{y}} = [\tilde{y}_{k+1|k}, \dots, \tilde{y}_{k+p|k}]^T$, jest wektorem zwanym odpowiedzią swobodną obiektu. Opisuje on, bowiem wpływ jedynie przeszłych oddziaływań na obiekt. Postać odpowiedzi swobodnej zależy od modelu użytego do predykcji, a jej elementy są dane wzorem:

$$\tilde{y}_{k+i|k} = \hat{y}_{k+i|k}^s + d_k, \quad (7)$$

gdzie $\hat{y}_{k+i|k}^s$ jest wartością wyjścia modelu dla chwili $k+i$, otrzymaną przy założeniu, że sygnał sterujący w przeszłości już się nie zmienia.

Zauważmy, że ponieważ odpowiedź swobodna zawiera to, co już wiadomo o układzie regulacji, zawiera również składnik d_k ze wzoru (5). Podobnie będzie w algorytmach wykorzystujących linearyzację, opisanych w drugiej części niniejszego rozdziału:

$$\mathbf{A} = \begin{bmatrix} a_1 & 0 & \cdots & 0 & 0 \\ a_2 & a_1 & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ a_p & a_{p-1} & \cdots & a_{p-s+2} & a_{p-s+1} \end{bmatrix}, \quad (8)$$

gdzie a_i są rzędnymi odpowiedzi skokowej obiektu. Macierz \mathbf{A} jest nazywana macierzą dynamiczną i można pokazać, że występuje we wszystkich odmianach algorytmów regulacji predykcyjnej, niezależnie od typu użytego modelu liniowego [20].

Zauważmy, że wskaźnik jakości ze wzoru (1) można zapisać w następującej postaci:

$$J_{MPC} = (\bar{\mathbf{y}} - \mathbf{y})^T \cdot (\bar{\mathbf{y}} - \mathbf{y}) + \lambda \cdot \Delta \mathbf{u}^T \cdot \Delta \mathbf{u}, \quad (9)$$

gdzie $\bar{\mathbf{y}} = [\bar{y}_k, \dots, \bar{y}_k]^T$ jest wektorem o długości p . Po skorzystaniu z predykcji (6) i przekształceniu wzoru (9), otrzymuje się:

$$J_{LMPC} = (\bar{\mathbf{y}} - \tilde{\mathbf{y}} - \mathbf{A} \cdot \Delta \mathbf{u})^T \cdot (\bar{\mathbf{y}} - \tilde{\mathbf{y}} - \mathbf{A} \cdot \Delta \mathbf{u}) + \lambda \cdot \Delta \mathbf{u}^T \cdot \Delta \mathbf{u}. \quad (10)$$

Wskaźnik jakości (10) zależy kwadratowo od zmiennych decyzyjnych zgrupowanych w wektorze $\Delta \mathbf{u}$. Ponadto ograniczenia (4) po skorzystaniu z predykcji (6) zależą

będą liniowo od zmiennych decyzyjnych. W takim razie został otrzymany, łatwy do rozwiązania przy użyciu standardowych procedur numerycznych, liniowo-kwadratowy problem optymalizacji.

2.2. Algorytmy bazujące na nieliniowych modelach procesów

Zastosowanie algorytmu bazującego na modelu liniowym do nieliniowego obiektu może przynieść niezadowalające rezultaty. W takim przypadku warto skorzystać z algorytmu regulacji predykcyjnej, bazującego na modelu nieliniowym:

$$\hat{y}_{k+1|k} = f(y_k, y_{k-1}, \dots, y_{k-n_a}, u_k, u_{k-1}, \dots, u_{k-n_b}) \quad (11)$$

gdzie $f()$ jest nieliniową funkcją wartości wyjść y_{k-i} i sterowań u_{k-i} z przeszłości.

Jeśli model obiektu (11) zostanie wprost użyty w sformułowaniu problemu optymalizacji jako kolejny zestaw ograniczeń (dla kolejnych chwil z horyzontu predykcji), wówczas problem optymalizacji (1–4), uzupełniony o model (11), staje się w ogólności nieliniowym, niewypukłym, niekwadratowym zadaniem optymalizacji. Zadanie takie jest trudne do rozwiązania online ze względu na problem minimów lokalnych oraz problemy numeryczne często towarzyszące rozwiązywaniu zadań tego typu. Ponadto nie można przewidzieć czasu potrzebnego do wyznaczenia rozwiązania. Jako modelu (11) można użyć praktycznie dowolnego nieliniowego modelu dynamicznego; sformułowanie zadania optymalizacji, będzie w każdym przypadku podobne. Tego typu algorytm będzie dalej nazywany NMPC (Nonlinear MPC).

Zastosowanie modelu nieliniowego w sposób opisany wyżej ma więc niestety wady. Z kolei użycie algorytmu regulacji predykcyjnej bazującego na modelu liniowym (LMPC) do nieliniowego procesu może przynieść rezultaty dalekie od zadowalających szczególnie w przypadku, gdy algorytm musi pracować w warunkach zmian punktu pracy. Kompromis został osiągnięty dzięki opracowaniu algorytmów wykorzystujących linearyzację modelu nieliniowego przeprowadzaną w każdej iteracji, dla bieżących wartości wyjścia i sterowania [18]. Ze względu na to, że predykcja może być przeprowadzana w różny sposób, możliwe jest sformułowanie algorytmów różniących się stopniem skomplikowania oraz oferowaną jakością regulacji.

2.2.1. Algorytmy typu MPC–SL

Najprostszym typem algorytmów predykcyjnych z linearyzacją modelu nieliniowego są algorytmy MPC–SL (z Sukcesywną Linearyzacją). Wykorzystują one podejście znane z algorytmów LMPC i przedstawione w rozdz. 2.1. W każdej iteracji takiego algorytmu wykonuje się kolejno następujące czynności:

1. Na podstawie modelu nieliniowego jest wyznaczany model liniowy dla bieżących wartości wyjścia obiektu i sterowania.
2. Otrzymany w poprzednim kroku liniowy model obiektu służy do wyznaczenia zestawu współczynników od-

powiedzi skokowych, potrzebnych to otrzymania macierzy dynamicznej.

3. Liniowy model obiektu jest wykorzystywany do otrzymania odpowiedzi swobodnej.
4. Odpowiedź swobodna oraz macierz dynamiczna są używane do sformułowania zadania optymalizacji kwadratowej.
5. Na podstawie rozwiązania zadania optymalizacji jest generowane sterowanie. W kolejnej iteracji algorytm wraca do p. 1.

W przypadku zastosowania w układzie regulacji nieliniowego obiektu, jakość regulacji oferowana przez algorytm typu MPC–SL jest zwykle znacznie wyższa od jakości oferowanej przez algorytmy bazujące na modelach liniowych. Jeśli jednak obiekt regulacji jest silnie nieliniowy, wtedy niedokładność predykcji może być znacząca. Można wówczas zastosować algorytmy, w których predykcja jest otrzymywana w inny sposób.

2.2.2. Algorytmy typu MPC–NPL

Algorytmy z Nieliniową Predykcją i Linearyzacją (MPC–NPL) są de facto zmodyfikowanymi algorytmami typu MPC–SL. W algorytmach tych odpowiedź swobodna obiektu jest wyznaczana z wykorzystaniem nieliniowego modelu obiektu (11). Model ten może być dowolnego typu (np. rozmyty lub neuronowy, lecz nie tylko). Zaletą tego podejścia tkwi w tym, że jedynie wpływ przyszłych przyrostów sterowań, tj. zmiennych decyzyjnych, jest wyznaczany na podstawie macierzy dynamicznej, uzyskanej z modelu zlinearyzowanego. W takim razie, w stosunku do algorytmu MPC–SL, zmieni się jedynie krok 3 algorytmu (pozostałe kroki (1, 2, 4 i 5) nie ulegają zmianie):

- 3 Odpowiedź swobodna obiektu jest generowana z wykorzystaniem nieliniowego modelu obiektu rekurencyjnie, tzn. obliczenia tej odpowiedzi dla chwili $k+1$ oraz kolejnych dokonuje się, korzystając z dostępnych informacji o przeszłych wartościach sterowania, pomiarów zmiennej wyjściowej oraz, gdy jest to potrzebne, z już wyznaczonych elementów odpowiedzi swobodnej, tzn. korzysta się ze wzoru (7) oraz z zależności:

$$\hat{y}_{k+i|k}^s = f(\hat{y}_{k+i-1|k}^s, \hat{y}_{k+i-2|k}^s, \dots, y_{k-n_a+i-1}, u_{k-1}, u_{k-2}, \dots, u_{k-n_b+i-1}) \quad (12)$$

Chociaż powyżej opisana zmiana w algorytmie jest stosunkowo prosta do wykorzystania, zastosowanie algorytmu MPC–NPL przynosi zwykle zauważalną poprawę jakości działania układu regulacji w stosunku do układu z algorytmem typu MPC–SL. Dzieje się tak, ponieważ odpowiedź swobodna jest otrzymywana z użyciem modelu nieliniowego. Co więcej, im mniejsze będą przyszłe przyrosty sterowania, których wpływ na predykcję otrzymuje się korzystając z modelu zlinearyzowanego, tym dokładniejszą predykcję się otrzyma.

2.2.3. Inne algorytmy z linearyzacją

Możliwe jest dalsze poprawianie jakości predykcji [20]. W tym celu można, zamiast odpowiedzi swobodnej, wy-


znaczać odpowiedź na już znane wartości sterowania dla całej trajektorii przyszłych wartości sterowania, czyli na wartości $u_{k+i|k-1}$, $i=1, \dots, s-1$. Wówczas jedynie wpływ poprawek tej trajektorii na predykcję musiałby być obliczany z wykorzystaniem modelu zlinearyzowanego. Co więcej, tak otrzymaną odpowiedź na już znane wartości sterowania można iteracyjnie poprawiać. Można także elementy macierzy dynamicznej wyznaczać tak, aby odpowiadały elementom otrzymanej odpowiedzi swobodnej.

Istnieje więc wiele możliwości poprawy działania układu regulacji dzięki wyborowi właściwego algorytmu regulacji predykcyjnej z linearyzacją. Często już najprostszy algorytm typu MPC-NPL generuje odpowiedzi bardzo zbliżone do tych otrzymywanych z algorytmem NMPC. Ponieważ w algorytmach wszystkich typów występuje model zakłócenia niemierzalnego d_k , w każdym z tych algorytmów analiza tego sygnału może pomóc w wykryciu uszkodzenia.

3. Przykład

3.1. Obiekt regulacji

Rozważmy układ regulacji nieliniowego reaktora chemicznego, w którym zachodzi reakcja van de Vusse'a [3]. Schemat reaktora został przedstawiony na rys. 1.



Rys. 1. Schemat reaktora chemicznego, w którym zachodzi reakcja van de Vusse'a

Fig. 1. Diagram of the CSTR with van de Vusse reaction

Równania opisujące zachodzące w reaktorze zmiany składów są następujące:

$$\begin{aligned} \frac{dC_A}{dt} &= -k_1 C_A - k_3 C_A^2 + \frac{F}{V} (C_{Af} - C_A), \\ \frac{dC_B}{dt} &= k_1 C_A - k_2 C_B - \frac{F}{V} C_B, \end{aligned} \quad (13)$$

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 (zakłada się, że jest ona stała i równa $V=1$ l), C_{Af} jest stężeniem substancji A w strumieniu surowca. Wartości parametrów reakcji są następujące [3]:

$$k_1=50 \text{ 1/h}, k_2=100 \text{ 1/h}, k_3=10 \text{ l/h}\cdot\text{mol}. \quad (14)$$


Zmienną wyjściową jest stężenie C_B substancji B w produkcie, a zmienną sterującą – natężenie dopływu surowca F , przy czym założono, że zmienna sterująca jest ograniczona:


$$0 \text{ l/h} \leq F \leq 60 \text{ l/h}. \quad (15)$$

Do przedstawionego obiektu dobrano algorytm regulacji predykcyjnej typu MPC-NPL bazujący na rozmytym modelu obiektu, który został dokładnie przedstawiony w pracy [15]. Przebiegi otrzymane w sprawnym układzie regulacji, tzn. przed wystąpieniem uszkodzenia, zostały oznaczone na rys. 2 kolorem niebieskim. Przyjęto przy tym, że model użyty do otrzymania odpowiedzi swobodnej jest nieco odstrojony (wartości parametrów reakcji zwiększone o 1 %). Podczas eksperymentów założono także, że mierzony sygnał wyjściowy jest zaszumiony. Zauważmy, że regulator w sposób zadowalający wypełnia swoje zadanie.

W celu zademonstrowania użyteczności zaproponowanego podejścia rozważmy sytuację, gdy uszkodzenie (blokada przepływu surowca) stopniowo narasta i ciężko jest jego wpływ zaobserwować na sygnale wyjściowym z obiektu (rys. 3, kolor czerwony). Z takim przypadkiem możemy mieć do czynienia np. gdy stopniowo zarasta rura doprowadzająca surowiec do reaktora, choć będzie to proces wolniejszy, niż to zostało zasymulowane.

Pomimo niepożądanych zmian w obiekcie, działanie algorytmu regulacji sprawia, że sygnał wyjściowy nie ulega widocznej zmianie. Sygnał sterujący z kolei stopniowo, powoli narasta, co wskazuje na wystąpienie problemu. Obserwacja wewnętrznego sygnału d_k w zastosowanym algorytmie zdecydowanie potwierdza, że coś niedobrego dzieje się w układzie regulacji i wskazuje na problem, który się pojawił. Sygnał d_k zamiast ustalić się na pewnej niewielkiej wartości, podąża w kierunku coraz mniejszych wartości. W takim razie nawet prosty test jego wartości może wskazać w pewnym momencie na wystąpienie problemu.





Rys. 2. Odpowiedzi układu regulacji z algorytmem MPC-NPL na skok wartości zadanej do 1.02 w sprawnym układzie regulacji (kolor niebieski) oraz w przypadku wystąpienia uszkodzenia (kolor czerwony); góra – przebieg wyjściowy, dół – sterowanie

Fig. 2. Responses of the control system with MPC-NPL algorithm to the set-point change to 1.02 in the healthy system (blue color) and in the faulty system (red color); above – output signal, below – control signal

4. Podsumowanie

W artykule zaproponowano metodę umożliwiającą wykrywanie uszkodzeń w układach regulacji z algorytmami regulacji predykcyjnej, dzięki analizie wewnętrznego sygnału d_k występującego w tego typu algorytmach. Sygnał ten jest istotny dla działania algorytmów, ponieważ jest różnicą między zmierzoną wartością wyjścia obiektu a wyjściem modelu użytego do predykcji. Służy on algorytmowi do bieżącej oceny i korekty modelu, na którym algorytm bazuje. Wykorzystanie tego sygnału w detekcji uszkodzeń oznacza de facto użycie do tego celu modelu obiektu, z którego korzysta algorytm regulacji predykcyjnej. Analiza wewnętrznego sygnału, pozwala więc na wy-

krycie potencjalnego uszkodzenia, które w układzie regulacji wystąpiło. Metoda jest szczególnie przydatna w przypadku uszkodzeń, których wpływ na wyjście obiektu jest w znacznym stopniu niwelowany dzięki działaniu algorytmu regulacji. W takiej jednak sytuacji, ponieważ dzieje się to za pośrednictwem wewnętrznego sygnału d_k , analiza tego sygnału pozwala wykryć niepokojące problemy.

Podziękowanie

Praca naukowa finansowana ze środków budżetowych na naukę.

Bibliografia

1. Camacho E.F., Bordons C.: *Model predictive control*. Springer, 1999.
2. Dziekan L., Witczak M., Korbicz J.: *A predictive fault-tolerant control scheme for Takagi-Sugeno fuzzy systems*, Proc. 18th IFAC World Congress, Mediolan, Włochy, 2011.
3. Doyle F., Ogunnaike B.A., Pearson R.K.: *Nonlinear model-based control using second-order Volterra models*. "Automatica", vol. 31, 1995, 697–714.
4. Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W.: *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*; WNT, Warszawa 2002.
5. Korbicz J., Kościelny J.M.: *Modelowanie, diagnostyka i sterowanie nadrzędne procesami; Implementacja w systemie DiaSter*, WNT, Warszawa 2009.
6. Kościelny J.M.: *Diagnostyka zautomatyzowanych procesów przemysłowych*; Akademicka Oficyna Wydawnicza EXIT, Warszawa 2001.
7. Maciejowski J.M.: *Predictive control with constraints*. Prentice Hall 2002.
8. Marusak P.: *Predictive control algorithms in constrained control systems tolerating sensor faults*. 12th International Conference on Methods and Models in Automation and Robotics MMAR 2006, Międzyzdroje, 28–31 sierpnia 2006, 797–804.
9. Marusak P.: *Actuator Fault Tolerant Control in Control Systems with Analytical Predictive Controllers and Output Constraints*. 13th IEEE/IFAC International Conference on Methods and Models in Automation and Robotics MMAR 2007, Szczecin, 27–30 sierpnia 2007, 825–832.
10. Marusak P.: *Predictive Controllers Integrated with Economic Optimization in Constrained Control Systems Tolerating Sensor Faults*. 13th IEEE/IFAC International Conference on Methods and Models in Automation and Robotics MMAR 2007, Szczecin, 27–30 sierpnia 2007, 535–542.
11. Marusak P.: *Predictive controllers integrated with economic optimization tolerating actuator faults: application to a nonlinear plant*, [w:] Korbicz J., Patan K., Kowal M.: *Fault diagnosis and fault tolerant control*, Academic Publishing House EXIT, Warszawa 2007.
12. Marusak P.: *Układy regulacji predykcyjnej tolerujące uszkodzenia elementów wykonawczych: dokładna stabi-*

- lizacja wybranego wyjścia. „Pomiary Automatyka Robotyka” 2’2007, CD-ROM "Materiały konferencyjne Automation 2007", 2007, referat nr 47.
13. Marusak P.: *Układy sterowania z regulatorami predykcyjnymi tolerujące uszkodzenia elementów wykonawczych: modyfikacja warstwy optymalizacji*. „Pomiary Automatyka Robotyka” 2’2007, CD-ROM "Materiały konferencyjne Automation 2007", 2007, referat nr 48.
 14. Marusak P.: *Easily reconfigurable analytical fuzzy predictive controllers: actuator faults handling*. "Lecture Notes in Computer Science", vol. 5370, 2008, 396–405.
 15. Marusak P.: *Efficient model predictive control algorithm with fuzzy approximations of nonlinear models*. "Lecture Notes in Computer Science", vol. 5495, 2009, 448–457.
 16. Marusak P.: *Disturbance measurement utilization in easily reconfigurable fuzzy predictive controllers: sensor fault tolerance and other benefits*. "Lecture Notes in Computer Science" (Lecture Notes in Artificial Intelligence), vol. 6086, 2010, 551–559.
 17. Marusak P., Tatjewski P.: *Actuator fault tolerance in control systems with predictive constrained set-point optimizers*. "International Journal of Applied Mathematics and Computer Science", vol. 18, no. 4, 2008, 539–551.
 18. Morari M., Lee J.H.: *Model predictive control: past, present and future*. "Computers and Chemical Engineering", vol. 23, 1999, 667–682.
 19. Rossiter J.A.: *Model-based predictive control, a practical approach*. CRC Press, Boca Raton, 2003.
 20. Tatjewski P.: *Sterowanie zaawansowane obiektów przemysłowych: struktury i algorytmy*. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2002.
 21. Tatjewski P.: *Model predictive control in fault-tolerant control systems*. Proc. Diagnostics of Processes and Systems 2011, Zamość, 2011.
 22. Venkatasubramanian V., Rengaswamy R., Yin K., Kavuri S.N.: *A review of process fault detection and diagnosis*. "Computers and Chemical Engineering", vol. 27, 293–346, 2003.
 23. Yetendje A., Seron M.M., De Dona J.A.: *Robust MPC design for fault-tolerance of constrained multi-sensor linear systems*. Proc. 2010 Conference on Control and Fault Tolerant Systems, Nicea, Francja, 2010, 752–758.
 24. Yetendje A., Seron M.M., De Dona J.A.: *Robust MPC multicontroller design for actuator fault-tolerance of constrained systems*, Proc. 18th IFAC World Congress, Mediolan, Włochy, 2011. ■


Exploitation of properties of the MPC algorithms in fault detection

Abstract: The model predictive control (MPC) algorithms due to their formulation and clever usage of the process model offer good control performance. It is also the case when some faults take place in the control system. Many of such faults can be even hard to notice thanks to the operation of the controller. It is, however, desired to be able to detect such situations. In the paper it is proposed to use internal signals of the MPC controllers in order to detect faults that occurred in the system. The method can be applied in the MPC algorithms based on both linear or nonlinear models.

Keywords: model predictive control, fault detection, fault-tolerant control

dr inż. Piotr Marusak

Urodzony w Warszawie w 1974 r. Dyplom magistra inżyniera uzyskał w 1997 r. a doktora – w 2003 r., obydwu na Wydziale Elektroniki i Technik Informatycznych Politechniki Warszawskiej. Pracuje w Instytucie Automatyki i Informatyki Stosowanej Politechniki Warszawskiej. Jego zainteresowania naukowe obejmują: sterowanie obiektów nieliniowych, algorytmy regulacji predykcyjnej, modelowanie i sterowanie rozmyte, układy regulacji odporne na uszkodzenia, układy sterowania z optymalizacją punktu pracy.



e-mail: P.Marusak@ia.pw.edu.pl