

# Sterowanie predykcyjne (MPC, *ang. Model Predictive Control*)

Sterowanie Procesami Ciągłymi

2017

# Istota pomysłu

W tradycyjnym układzie regulacji sterowanie jest generowane w oparciu o funkcję uchybu  $\varepsilon(t)$  w chwili bieżącej i w chwilach poprzednich.

W sterowaniu predykcyjnym buduje się model obiektu i wylicza prognozę jego zachowania się. Sposób sterowania uwzględnia przewidywane zachowanie się obiektu w przyszłości.

# Przesuwany horyzont

- horyzont prognozy  $H_p$

$$k + 1, k + 2, \dots, k + H_p$$

- horyzont sterowania  $H_s$

$$k + 1, k + 2, \dots, k + H_s$$

zazwyczaj  $H_s < H_p$

# Algorytm

1. Na podstawie obecnych i przeszłych pomiarów wejścia, wyjścia i stanu (ew. szacowanych), stosując model obiektu (wzór opisujący jego zachowanie), wyznaczyć prognozę wyjścia na  $H_p$  chwil "w przyszłość"

$$\bar{y}_{k+1}, \bar{y}_{k+2}, \dots, \bar{y}_{k+H_p}$$

Prognozowane wartości wyjść wyznaczone w etapie 1 zależą oczywiście od wartości przyszłych sterowań (są ich funkcjami).

2. Przy danym żadanym (zadany) procesie wyjściowym  $y_{\dot{z},k+1}, y_{\dot{z},k+2}, \dots, \bar{y}_{\dot{z},k+H_p}$  zminimalizować wskaźnik kosztu sterowania

$$J(u_{k+1}, \dots, u_{k+H_s}) = \sum_{t=k+1}^{H_p} \left\{ w_y (\bar{y}_t - y_{\dot{z},t})^2 + w_u (\Delta u_t)^2 \right\},$$

gdzie  $w_y$  i  $w_u$  to wagi, zaś  $\Delta u_t = u_t - u_{t-1}$ , tzn. preferujemy małe zmiany sterowania.

## Algorytm (c.d.)

3. Z uzyskanego rozwiązania optymalnego  $u_{k+1}^*, \dots, u_{k+H_s}^*$  w chwili kolejnej, tj.  $t = k + 1$  podać na wejście obiektu wartość  $u_{k+1}^*$  (tylko pierwszą wartość z ciągu optymalnego wyznaczonego w chwili  $k$ ).
4. Przesunąć horyzont czasowy o jeden, tzn. chwilą obecną staje się  $t = k + 1$ , okresem prognozy chwile

$$t = k + 2, k + 3, \dots, k + H_p + 1,$$

a horyzontem sterowania

$$t = k + 2, k + 3, \dots, k + H_s + 1$$

5. Przejść do etapu 1 powtarzając optymalizację dla przesuniętego horyzontu.

# Heurystyczne metody optymalizacji

Symulowane wyżarzanie (metoda iteracyjna)

W  $i$ -tej iteracji dla wektora

$$\mathbf{x}^{(i)} = (x_1^{(i)}, x_2^{(i)}, \dots, x_d^{(i)})^T$$

losuje się wektor z jego otoczenia

$$\tilde{\mathbf{x}} = (x_1^{(i)} + \Delta_1, x_2^{(i)} + \Delta_2, \dots, x_d^{(i)} + \Delta_d)^T$$

Jeżeli nastąpi poprawa funkcji kryterialnej ( $J(\tilde{\mathbf{x}}) < J(\mathbf{x}^{(i)})$ ) to przechodzi się **bezwarunkowo** do punktu  $\tilde{\mathbf{x}}$ , tzn.

$$\mathbf{x}^{(i+1)} = \tilde{\mathbf{x}}$$

# Heurystyczne metody optymalizacji

Symulowane wyżarzanie (c.d.)

W przeciwnym wypadku ( $J(\tilde{\mathbf{x}}) \geq J(\mathbf{x}^{(i)})$ ) warunkiem akceptacji nowego rozwiązania  $\tilde{\mathbf{x}}$  jest zajście zdarzenia losowego

$$u < c_1 e^{c_2 i},$$

gdzie wylosowane  $u$  ma rozkład jednostajny na odcinku  $[0, 1]$ .  
Jeśli warunek losowy nie zachodzi, pozostaje się przy starym rozwiązaniu, tj.

$$\mathbf{x}^{(i+1)} = \mathbf{x}^{(i)}$$

# Heurystyczne metody optymalizacji

## Algorytmy genetyczne

- Pojęcie pokolenia

$$\{\mathbf{x}_n^{(i)}\}_{n=1}^N$$

$i$  – numer pokolenia

$\mathbf{x}_n^{(i)}$  –  $n$ -ty osobnik w  $i$ -tym pokoleniu (wektor  $d$ -wymiarowy)

- **Selekcja** – wybór osobników do roli rodziców (do generacji kolejnego pokolenia). Prawdopodobieństwo selekcji zależne od wartości funkcji celu danego osobnika (np. reguła ruletki.)



# Heurystyczne metody optymalizacji

## Algorytmy genetyczne (c.d.)

- **Krzyżowanie** – dobór wyselekcjonowanych osobników w pary i generacja potomków. Przykładowym operatorem może być średnia dwóch wektorów. Stosuje się też operacje białotwe.
- **Mutacja** – modyfikacja wygenerowanych potomków w stosunku do wartości otrzymanych w wyniku krzyżowania rodziców.