

# Laboratorium sterowania adaptacyjnego

Instytut Automatyki i Robotyki (IAR)  
Politechnika Poznańska (PP)  
opracowanie: Maciej M. Michałek

---

## C1 REKURSYWNA METODA LS ESTYMACJI PARAMETRYCZNEJ

Ćwiczenie poświęcone jest rekursywnym wersjom metody LS identyfikacji parametrycznej. Zastosowanie algorytmów rekursywnych: (a) pozwala na ograniczenie objętości wymaganej pamięci do składowania danych, (b) upraszcza obliczenia numeryczne w procesie estymacji parametrycznej (brak konieczności odwracania macierzy danych pomiarowych), (c) umożliwia wykorzystanie aktualnego modelu systemu w czasie rzeczywistym (tj. na bieżąco), co ma szczególne znaczenie np. w realizacji algorytmów sterowania adaptacyjnego lub w zastosowaniach służących diagnostyce uszkodzeń/awarii systemu. Podczas ćwiczenia przyjęte zostanie założenie o znajomości struktury identyfikowanego systemu przy nieznajomości wartości jego parametrów (model i identyfikacja typu GREY-BOX).

### 1 Identyfikacja bezpośrednia systemu dynamicznego czasu dyskretnego metodą RLS

Rekursywny algorytm identyfikacji RLS (*Recursive LS*) wynika z przekształcenia estymatora wsadowego zdefiniowanego dla danych spróbkowanych. Stanowi on zatem rekursywny odpowiednik wsadowej metody LS i asymptotycznie (tj. dla liczby danych  $N \rightarrow \infty$ ) charakteryzuje się tymi samymi właściwościami statystycznymi co oryginalna metoda wsadowa LS.

W dalszej części rozważań zakładamy, że strukturę rzeczywistego systemu dynamicznego czasu dyskretnego *generującego* dane pomiarowe można zapisać w postaci regresyjnej, tzn.:

$$y(n) = G_o(q^{-1}, \mathbf{p}_o)u(n) + v^*(n) \quad \Rightarrow \quad y(n) = \boldsymbol{\varphi}^\top(n) \mathbf{p}_o + v(n), \quad (1)$$

gdzie  $v^*(n)$  i  $v(n)$  są zakłóceniami stochastycznymi (białymi lub kolorowymi), a  $\mathbf{p}_o$  reprezentuje wektor rzeczywistych parametrów systemu.

Charakterystyczną cechą metod rekursywnych jest iteracyjny sposób realizacji obliczeń estymacji parametrów, gdzie w każdym kroku iteracji aktualizacja estymat jest wyznaczana na podstawie bieżącej pary pomiarów wejścia i wyjścia identyfikowanego systemu. Estymata parametrów  $\hat{\mathbf{p}}(n)$  w dyskretniej chwili  $n$ -tej jest zatem uaktualniana według następującego ogólnego schematu:

$$\hat{\mathbf{p}}(n) = \hat{\mathbf{p}}(n-1) + \mathbf{k}(n) \varepsilon(n), \quad (2)$$

gdzie  $\mathbf{k}(n) \varepsilon(n)$  jest poprawką, którą określa się na podstawie nowej pary pomiarów  $\{y(n), u(n)\}$ . Wielkość  $\varepsilon(n) = y(n) - \boldsymbol{\varphi}^\top(n) \hat{\mathbf{p}}(n-1)$  jest bieżącą wartością błędu predykcji (obliczaną na podstawie estymaty parametrów z poprzedniej iteracji), natomiast  $\mathbf{k}(n) \in \mathbb{R}^d$  jest wektorowym wzmocnieniem zależnym od aktualnej macierzy kowariancyjnej. Należy zaznaczyć, że pomimo zapisu równania aktualizacji (2) w dziedzinie czasu dyskretnego, symbol  $n$  może alternatywnie oznaczać po prostu numer iteracji, jeżeli obliczenia nie są wykonywane w czasie rzeczywistym a raczej jako szeregowe przetwarzanie zbioru danych pomiarowych  $Z^N = \{y(n), u(n)\}_{n=0}^{N-1}$ .

Pełny schemat obliczeń rekursywnej metody LS (czyli metody RLS) określony w dziedzinie

czasu dyskretnego  $n$  jest następujący:

$$\hat{\mathbf{p}}^{\text{LS}}(n) = \hat{\mathbf{p}}^{\text{LS}}(n-1) + \mathbf{k}(n) \varepsilon(n), \quad (3)$$

$$\varepsilon(n) = \mathcal{Y}(n) - \boldsymbol{\varphi}^\top(n) \hat{\mathbf{p}}^{\text{LS}}(n-1), \quad (4)$$

$$\mathbf{k}(n) = \mathbf{P}^{\text{LS}}(n) \boldsymbol{\varphi}(n), \quad (5)$$

$$\mathbf{P}^{\text{LS}}(n) = \mathbf{P}^{\text{LS}}(n-1) - \frac{\mathbf{P}^{\text{LS}}(n-1) \boldsymbol{\varphi}(n) \boldsymbol{\varphi}^\top(n) \mathbf{P}^{\text{LS}}(n-1)}{1 + \boldsymbol{\varphi}^\top(n) \mathbf{P}^{\text{LS}}(n-1) \boldsymbol{\varphi}(n)}, \quad (6)$$

gdzie  $\mathcal{Y}(n)$  jest bieżącą próbką *umownego wyjścia* (dla modelu (1) mamy  $\mathcal{Y}(n) \equiv y(n)$ ), przy czym ze względu na ciąg przyczynowy obliczenia wykonuje się w każdym kroku w kolejności (6)→(5)→(4)→(3). Warto zwrócić uwagę, iż (w odróżnieniu od metody wsadowej) równanie (3) definiuje pewien proces obliczeniowy, którego wynik poczynając od warunków początkowych  $\hat{\mathbf{p}}^{\text{LS}}(0)$ ,  $\mathbf{P}^{\text{LS}}(0)$  będzie ewoluował w czasie dyskretnym poprzez stany przejściowe aż do stanu ustalonego (teoretycznie osiąganego dla  $n \rightarrow \infty$ ). Po zaniknięciu stanów przejściowych (w praktyce przyjmujemy, że nastąpi to w przybliżeniu w czasie skończonym  $n \rightarrow N-1$  dla dostatecznie dużej wartości  $N$ ) estymata  $\hat{\mathbf{p}}^{\text{LS}}(N-1)$  winna odpowiadać (przynajmniej w sensie statystycznym) wartości estymatora LS metody wsadowej uzyskanej dla zbioru  $N$  pomiarów. Warunki początkowe  $\hat{\mathbf{p}}^{\text{LS}}(0)$  oraz  $\mathbf{P}^{\text{LS}}(0)$  dla rekursji (3)-(6) można wybrać na różne sposoby, np.:

- wybór na podstawie wiedzy wstępnej o możliwym zakresie wartości parametrów  $\mathbf{p}_0$ ,
- wybór arbitralny np.:  $\hat{\mathbf{p}}^{\text{LS}}(0) := \mathbf{0}$ ,  $\mathbf{P}^{\text{LS}}(0) := \rho \cdot \mathbf{I}$ , gdzie  $\rho \gg 0$ , a  $\mathbf{I} \in \mathbb{R}^{d_p \times d_p}$  jest macierzą jednostkową, natomiast  $d_p = \dim(\hat{\mathbf{p}}^{\text{LS}})$ .

W interpretacji statystycznej odwrotność macierz  $\mathbf{P}^{\text{LS}}(0)$  reprezentuje stopień wiarygodności jakim obdarzamy początkową estymatę  $\hat{\mathbf{p}}^{\text{LS}}(0)$ . Ponadto przy zgodności struktury modelu ze strukturą systemu oraz jeżeli zakłócenie  $v(n)$  w (1) jest szumem białym o wariancji  $\sigma_o^2$ , wówczas

$$\text{Cov}[\hat{\mathbf{p}}^{\text{LS}}] = \sigma_o^2 \mathbf{P}^{\text{LS}}. \quad (7)$$

Zwróćmy uwagę na ważną właściwość macierzy kowariancyjnej obliczanej na podstawie równania (6), a mianowicie:

$$\mathbf{P}^{\text{LS}}(n) \xrightarrow{n \rightarrow \infty} \mathbf{0}, \quad (8)$$

co oznacza, że przy założeniu nieustannego pobudzania systemu estymata  $\hat{\mathbf{p}}^{\text{LS}}(n)$  będzie dla  $n \rightarrow \infty$  zmierzała do pewnej stałej wartości granicznej  $\hat{\mathbf{p}}_{\text{lim}}^{\text{LS}}$  (zbieżność wg prawdopodobieństwa). Wartość graniczna  $\hat{\mathbf{p}}_{\text{lim}}^{\text{LS}}$  będzie odpowiadała prawdziwym parametrom  $\mathbf{p}_0$ , jeżeli spełnione będą założenia dotyczące białości zakłócenia  $v(n)$  w strukturze (1) oraz zgodności struktury modelu ze strukturą identyfikowanego systemu, a sygnał wejściowy  $u(n)$  będzie nieustannie pobudzający.

### 1.1 Identyfikacja systemu dynamicznego czasu dyskretnego metodą RLS.

- Plik `SystemARMAX.mdl` zawiera blok reprezentujący system dynamiczny czasu dyskretnego o następującej strukturze:

$$y(n) = \underbrace{\frac{b_{20}q^{-2}}{1 + a_{10}q^{-1} + a_{20}q^{-2}}}_{G_o(q^{-1}, \mathbf{p}_o)} u(n) + \underbrace{\frac{1 + c_{10}q^{-1}}{1 + a_{10}q^{-1} + a_{20}q^{-2}}}_{H_o(q^{-1}, \mathbf{p}_o)} e(n), \quad (9)$$

gdzie  $a_{10}, a_{20}, b_{20}$  i  $c_{10}$  reprezentują rzeczywiste parametry systemu, a  $e(n)$  jest szumem białym. Model systemu (9) należy do rodziny ARMAX o postaci ogólnej:  $Ay(n) = Bu(n) + Ce(n) \Rightarrow y(n) = Gu(n) + He(n)$ ,  $G = B/A$ ,  $H = C/A$ . Jeżeli w systemie  $c_{10} = 0$ , wówczas struktura modelu odpowiadająca systemowi (9) redukuje się rodziny ARX. Dla  $c_{10} \neq 0$  zakłócenie  $(1 + c_{10}q^{-1})e(n)$  jest już kolorowe z wszelkimi konsekwencjami tego faktu.

- Zapisać model rzeczywistego systemu (9) w postaci regresji liniowej przyjmując  $v(n) := (1 + c_{1o}q^{-1})e(n)$ .
- Zainicjować następujące zmienne globalne:  $T_p = 0.1$ ,  $T_{end} = 1000$ ,  $T_d = 1500$ , które oznaczają (w sekundach), odpowiednio: okres próbkowania, horyzont czasowy symulacji oraz czas, po którym nastąpi zmiana wartości parametru  $b_{2o}$  (tutaj  $T_{end} < T_d$ , więc zmiana nie nastąpi wcale – identyfikowany system będzie miał stałe parametry w całym horyzoncie symulacji). **Uwaga:** Wszystkie bloki obliczeniowe należy synchronizować tym samym okresem próbkowania  $T_p$ , a w ustawieniach symulacji wymusić: **Type: Fixed-step**, **Solver: discrete (no continuous states)**.
- Zainicjować wartość parametru  $c_{1o} = 0$  (utworzyć w tym celu zmienną globalną  $c_{1o}$  w środowisku Matlab) w celu wymuszenia zakłócenia  $v(n) \equiv e(n)$  w równaniu regresji. Przeprowadzić identyfikację parametryczną toru sterowania systemu (9) metodą RLS przyjmując jako wejście pobudzające  $u(n)$  sygnał prostokątny (symetryczny względem zera) o amplitudzie jednostkowej i częstotliwości  $f_u = 0.025$  Hz. Przyjąć zerowy warunek początkowy dla estymat.
- Przeanalizować przebiegi estymat  $\hat{\mathbf{p}}^{LS}(n)$  dla wartości  $\rho \in \{10, 1, 0.1\}$  używanych do inicjalizacji macierzy  $\mathbf{P}^{LS}(0)$ .
- Sprawdzić przebieg śladu macierzy  $\mathbf{P}^{LS}(n)$  podczas estymacji (funkcja `trace()`).
- Zaimplementować bloki wyznaczające odpowiedź modelu symulowanego oraz odpowiedź predyktora jednokrokowego dla systemu (9) tak, aby oba bloki wykorzystywały do obliczeń aktualne estymaty parametrów. Sprawdzić jakość identyfikacji porównując (w czasie rzeczywistym podczas estymacji i przy tym samym pobudzeniu  $u(n)$ ):
  - odpowiedź modelu symulowanego  $y_m(n)$  z odpowiedzią niezakłóconą  $y_o(n)$  systemu (oznaczenie 'yo(n)' w bloku z pliku `SystemARMAX.mdl`),
  - odpowiedź predyktora jednokrokowego  $\hat{y}(n|n-1)$  z zakłóconą odpowiedzią  $y(n)$  systemu,
  - odpowiedź modelu symulowanego  $y_m(n)$  z odpowiedzią  $y(n)$  systemu.

Które w powyższych porównaniach sygnałów jest najbardziej miarodajne z punktu widzenia oceny jakości identyfikacji? Czy wszystkie powyższe porównania można wykonać w praktyce?
- Zainicjować wartość parametru  $c_{1o} = 0.7$  w celu wymuszenia zakłócenia kolorowego  $v(n) = (1 + c_{1o}q^{-1})e(n)$  w równaniu regresji. Ponownie przeprowadzić identyfikację parametryczną metodą RLS i przeanalizować zbieżność estymat  $\hat{\mathbf{p}}^{LS}(n)$ .

## 2 Adaptacyjna identyfikacja niestacjonarnego systemu dynamicznego czasu dyskretnego

Można podać wiele przykładów systemów, których parametry ulegają zmianie bądź w sposób gwałtowny (np. co pewien interwał czasowy), bądź powolny lecz ustawiczny<sup>1</sup> (mówi się wtedy o tzw. dryfie parametrów); opis regresyjny systemu niestacjonarnego przyjmuje postać:

$$y(n) = \boldsymbol{\varphi}^\top(n) \mathbf{p}_o(n) + v(n). \quad (10)$$

<sup>1</sup>Rozważamy zmiany wyłącznie parametrów zakładając, że struktura modelu nie ulega zmianie.

W przypadku systemu niestacjonarnego algorytmy identyfikacji powinny mieć zdolność do śledzenia (w czasie rzeczywistym) zmian wartości parametrów systemu tak, aby wyznaczany model był w danym momencie jak najbardziej aktualny – mówimy w tym przypadku o *identyfikacji adaptacyjnej*. Podstawowa metoda RLS rozważana w poprzednim punkcie nie ma zdolności adaptacyjnych, ponieważ ślad macierzy kowariancyjnej zbiega z upływem czasu asymptotycznie do zera i tym samym zdolność do korekty wektora estymat parametrów jest z biegiem czasu coraz mniejsza.

Aby zagwarantować gotowość algorytmu identyfikacyjnego do śledzenia zmiennych w czasie parametrów systemu należy zapewnić, by ślad macierzy kowariancyjnej  $\mathbf{P}(n)$  nie zbiegał do zera. Właściwość tę można uzyskać stosując jeden z trzech klasycznych mechanizmów:

- wprowadzenie do równania aktualizacji macierzy  $\mathbf{P}(n)$  tzw. *współczynnika zapominania*  $\lambda \in (0; 1)$  (zwykle w celu **śledzenia parametrów wolnozmiennych**); równania estymacji rekursywnej przyjmują w tym przypadku następującą postać:

$$\hat{\mathbf{p}}(n) = \hat{\mathbf{p}}(n-1) + \mathbf{k}(n) \varepsilon(n), \quad (11)$$

$$\varepsilon(n) = y(n) - \boldsymbol{\varphi}^\top(n) \hat{\mathbf{p}}(n-1), \quad (12)$$

$$\mathbf{k}(n) = \mathbf{P}(n) \boldsymbol{\varphi}(n), \quad (13)$$

$$\mathbf{P}(n) = \frac{1}{\lambda} \left[ \mathbf{P}(n-1) - \frac{\mathbf{P}(n-1) \boldsymbol{\varphi}(n) \boldsymbol{\varphi}^\top(n) \mathbf{P}(n-1)}{\lambda + \boldsymbol{\varphi}^\top(n) \mathbf{P}(n-1) \boldsymbol{\varphi}(n)} \right]; \quad (14)$$

powyższa rekursja nosi nazwę metody RLS $_{\lambda}$ ,

- poprzez *resetowanie* macierzy kowariancyjnej w celu **śledzenia gwałtownych zmian parametrów** systemu; resetowanie polega na przypisywaniu do macierzy  $\mathbf{P}$  założonej macierzy nieujemnie określonej, gdy spełniony zostanie odpowiedni warunek resetowania:

R1. resetowanie okresowe (z okresem  $T > 0$ )

$$\mathbf{P}(n) := \text{diag}\{\rho_1, \dots, \rho_d\}, \quad \text{gdy} \quad n = kT, \quad k = 1, 2, \dots$$

R2. resetowanie z warunkiem na wartość błędu predykcji  $\varepsilon$  lub błędu wyjściowego  $\varepsilon_{\text{OE}}$

$$\mathbf{P}(n) := \text{diag}\{\rho_1, \dots, \rho_d\}, \quad \text{gdy} \quad |\varepsilon(n)| > \varepsilon_{\max} \quad \text{lub} \quad |\varepsilon_{\text{OE}}(n)| > \varepsilon_{\max}$$

R3. resetowanie z warunkiem na wartość śladu macierzy kowariancyjnej

$$\mathbf{P}(n) := \text{diag}\{\rho_1, \dots, \rho_d\}, \quad \text{gdy} \quad \text{tr}(\mathbf{P}(n)) < P_{\min}$$

przy czym  $\rho_i \geq 0$ ,  $T > 0$ ,  $\varepsilon_{\max} > 0$  oraz  $P_{\min} > 0$  są parametrami projektowymi; powyższe warunki resetowania można łączyć (np. stosując koniunkcję warunków) lub modyfikować w zależności od zastosowania i warunków identyfikacji systemu,

- wykorzystanie koncepcji filtracji Kalmana w celu **śledzenia ustawicznych zmian parametrów**  $\mathbf{p}_o(n)$  o charakterze tzw. *błądzenia losowego*, które wynika z rozwiązania następującego równania różnicowego

$$\mathbf{p}_o(n) = \mathbf{p}_o(n-1) + \mathbf{w}(n-1), \quad \text{Cov}[\mathbf{w}(n)] = \mathbf{V}_o = \text{diag}\{v_{1o}, \dots, v_{do}\}, \quad (15)$$

gdzie  $\mathbf{w}(n)$  jest wektorem (niemierzalnych) nieskorelowanych zaburzeń losowych o jednokowym rozkładzie normalnym i diagonalnej macierzy kowariancji  $\mathbf{V}_o$ ; w takim przypadku równania rekursywnej estymacji parametrów przyjmują postać:

$$\mathbf{P}(n|n-1) = \mathbf{P}(n-1) + \hat{\mathbf{V}}^*, \quad (16)$$

$$\hat{\mathbf{p}}(n) = \hat{\mathbf{p}}(n-1) + \mathbf{k}(n) \varepsilon(n), \quad (17)$$

$$\varepsilon(n) = y(n) - \boldsymbol{\varphi}^\top(n) \hat{\mathbf{p}}(n-1), \quad (18)$$

$$\mathbf{k}(n) = \mathbf{P}(n|n-1) \boldsymbol{\varphi}(n) [1 + \boldsymbol{\varphi}^\top(n) \mathbf{P}(n|n-1) \boldsymbol{\varphi}(n)]^{-1}, \quad (19)$$

$$\mathbf{P}(n) = \mathbf{P}(n|n-1) - \mathbf{k}(n) \boldsymbol{\varphi}^\top(n) \mathbf{P}(n|n-1), \quad (20)$$

gdzie dobierana doświadczalnie macierz  $\hat{\mathbf{V}}^* := \text{diag}\{\hat{v}_1^*, \dots, \hat{v}_d^*\}$ ,  $\hat{v}_i^* \geq 0$ ,  $i = 1, \dots, d$  posiada niezerowe elementy na tych pozycjach diagonal, które odpowiadają zmiennym w czasie parametrom modelu. Macierz  $\hat{\mathbf{V}}^*$  jest oszacowaniem ilorazu  $\mathbf{V}_0/\sigma_0^2$ , gdzie  $\sigma_0^2$  reprezentuje wariancję białego zakłócenia  $v(n) \equiv e(n)$  z równania systemu (10) (w ujęciu Kalmana jest to jednocześnie *równanie wyjścia* stowarzyszone z *równaniem stanu* (15)).

Koszt wprowadzenia jakiegokolwiek z powyższych mechanizmów jest zwykle związany ze zwiększoną fluktuacją estymat parametrów podczas procesu estymacji. Zatem stopień modyfikacji wprowadzany przez powyższe mechanizmy (wynikający z doboru wartości parametrów  $\lambda$ ,  $\hat{v}_i^*$ ,  $\rho_i$ ,  $T$ ,  $\varepsilon_{\max}$ ,  $P_{\min}$ ) powinien wynikać z kompromisu między zdolnością estymatora do śledzenia zmian parametrów systemu a poziomem fluktuacji estymat parametrów.

## 2.1 Adaptacyjna identyfikacja systemu dynamicznego czasu dyskretnego.

- Dostosować schemat obliczeń z punktu 1 poprzez zainicjowanie parametrów  $T_{\text{end}} = 1500$ ,  $T_d = 500$  – skokowa zmiana wartości parametru  $b_{2o}$  systemu (10) nastąpi dla chwilach  $t_1 = n_1 T_p = 500$  s oraz  $t_2 = n_2 T_p = 1000$  s;
- Przyjąć parametr  $c_{1o} = 0$  (zakładamy zakłócanie szumem białym w równaniu regresyjnym).
- Stosując metodę  $\text{RLS}_\lambda$  wg wzorów (11)-(14) przeprowadzić identyfikację parametryczną toru sterowania systemu (10) przyjmując współczynnik zapominania  $\lambda$  z zakresu  $[0.98; 0.999]$ . Szczególną uwagę zwrócić na zdolność estymatora do śledzenia zmian parametru  $b_{2o}(n)$  systemu (zmianę wartości  $b_{2o}(n)$  można obserwować wyświetlając wyjście 'b2o' bloku identyfikowanego systemu w pliku `SystemARMAX.mdl`). Sprawdzić przebieg śladu macierzy kowariancyjnej  $\mathbf{P}(n)$  podczas identyfikacji.
- Sprawdzić wpływ wartości współczynnika  $\lambda \in (0; 1)$  na jakość identyfikacji i fluktuacje estymat parametrów.
- Przeanalizować jakość identyfikacji adaptacyjnej stosując mechanizm resetowania macierzy kowariancyjnej  $\mathbf{P}(n)$  – zastosować połączone kryteria R2 do R3, tj.:

$$\text{IF } [|\varepsilon_{\text{OE}}| > \varepsilon_{\max}] \wedge [\text{tr}(\mathbf{P}) < P_{\min}] \text{ THEN } \mathbf{P} := \text{diag}\{\rho_1, \dots, \rho_d\}$$

Sprawdzić wpływ wartości parametrów  $\rho_i$  na jakość identyfikacji i fluktuacje estymat parametrów dla:

$$\mathbf{P} := \text{diag}\{10, 10, 10\}, \quad \mathbf{P} := \text{diag}\{0, 0, 10\}, \quad \mathbf{P} := \text{diag}\{0, 0, 1\}.$$

- Wymusić błędzenie losowe dla parametru  $b_{2o}(n)$  (przełączyć źródło zmian parametru wewnątrz systemu ARMAX). Stosując metodę filtracji Kalmana przeprowadzić identyfikację parametryczną toru sterowania systemu (10) z wykorzystaniem aktualizacji (16)-(20) przyjmując:

$$\hat{\mathbf{V}}^* := \text{diag}\{1, 1, 1\} \cdot 10^{-4}, \quad \hat{\mathbf{V}}^* := \text{diag}\{0, 0, 0.001\}, \quad \hat{\mathbf{V}}^* := \text{diag}\{0, 0, 0.01\}.$$

Zwrócić uwagę na zdolność estymatora do śledzenia parametru  $b_{2o}(n)$  systemu oraz na zbieżność i poziom fluktuacji estymat wszystkich parametrów.

### 3 Identyfikacja bezpośrednia systemu dynamicznego czasu ciągłego metodą RLS

Bezpośrednia rekursywna identyfikacja systemu czasu ciągłego

$$[y(t)] = G_o(s, \mathbf{p}_o)[u(t)] + [v(t)] = \frac{B_o(s, \mathbf{p}_o)}{A_o(s, \mathbf{p}_o)}[u(t)] + [v(t)], \quad (21)$$

gdzie  $[v(t)] = H_o(s)[e(t)]$  reprezentuje (jako filtrowany szum biały) zakłócenie stochastyczne o nieznannej charakterystyce, wymaga zapisu modelu systemu

$$[y(t)] = G(s, \mathbf{p})[u(t)] + [v(t)] = \frac{B(s, \mathbf{p})}{A(s, \mathbf{p})}[u(t)] + [v(t)], \quad (22)$$

przy czym  $A(s, \mathbf{p}) = s^{n_a} + a_1 s^{n_a-1} + \dots + a_{n_a}$  oraz  $B(s, \mathbf{p}) = b_0 s^{n_b} + b_1 s^{n_b-1} + \dots + b_{n_b}$ . Po zastosowaniu filtracji SVF równanie (22) można przepisać w postaci regresyjnej:

$$\underbrace{y_F^{(n_a)}(nT_p)}_{\mathcal{Y}(nT_p)} = \underbrace{[-y_F^{(n_a-1)}(nT_p) \dots - y_F(nT_p) \quad u_F^{(n_b)}(nT_p) \dots u_F(nT_p)]}_{\boldsymbol{\varphi}^\top(nT_p)} \mathbf{p} + \xi_F(nT_p), \quad (23)$$

przy czym  $\xi_F(nT_p)$  jest filtrowanym zakłóceniem  $[\xi(t)] = A(s, \mathbf{p})[v(t)]$  w równaniu regresji,  $n_b$  i  $n_a \geq n_b$  są stopniami wielomianów  $B(s, \mathbf{p})$  i  $A(s, \mathbf{p})$  modelu, natomiast indeks 'F' oznacza sygnały filtrowane

$$\chi_F^{(j)}(nT_p) = \mathcal{L}^{-1} \left\{ F_{\text{SVF}}^j(s) [\chi(t)] \right\} \Big|_{t=nT_p}, \quad \chi \in \{y, u, \xi\} \quad (24)$$

filtrami SVF

$$F_{\text{SVF}}^j(s) \triangleq \frac{s^j}{(1 + sT_F)^n}, \quad n \geq n_a, \quad T_F > 0. \quad (25)$$

Przy odpowiednio dobranej wartości stałej czasowej  $T_F$  filtry SVF mogą jednocześnie pełnić rolę filtrów antyaliasingowych. Należy zauważyć, że przy powyższym zapisie równań (24) filtracja SVF odbywa się w **klasyczny** sposób, tj. PRZED próbkowaniem sygnałów branych do regresji liniowej (23).

Po próbkowaniu sygnałów filtrowanych można wprost wykorzystać równania (3)-(6) rekursywnej metody LS lub jednej z jej wersji adaptacyjnych, zastępując w równaniu (4) pomiar wyjścia  $y(n)$  wartością umownego wyjścia  $\mathcal{Y}(nT_p)$  zdefiniowanego w (23).

#### 3.1 Bezpośrednia identyfikacja systemu czasu ciągłego metodą RLS.

- Plik `SystemSISOC.mdl` zawiera blok identyfikowanego systemu czasu ciągłego reprezentowanego równaniem (21), o którym wiadomo, że  $n_a = 2$  i  $n_b = 0$  (wiedza wstępna o strukturze transmitancji  $G_o$ ). Zakłada się, że pomiarowo dostępne są sygnały  $u(t)$  oraz  $y(t)$ , przy czym sygnał  $y(t)$  zawiera zakłócenie stochastyczne.
- W przestrzeni roboczej środowiska Matlab zainicjować następujące parametry: `Tp=0.05s` oraz `sigma2e=0.1`. Do celów pobudzania identyfikowanego systemu wybrać sygnał prostokątny (symetryczny względem zera – blok `Signal Generator`) o jednostkowej amplitudzie i częstotliwości  $f_u = 0.04$  Hz.
- W środowisku Simulink przygotować schemat blokowy eksperymentu identyfikacyjnego z odpowiednimi filtrami SVF minimalnego rzędu (należy użyć bloków transmitancji operatora Laplace'a  $s$ , aby uzyskać analogową wersję filtracji).

- Czas symulacji dobrać tak, aby horyzont symulacji obejmował  $N = 20000$  próbek. Przyjąć stałą czasową filtrów SVF:  $T_F = 8T_p$ . W ustawieniach symulacji wymusić: `Max step size = 0.01`, `Solver: ode45 (Dormand-Prince)`, `Type: Variable-step`.
- Stosując metodę RLS przeprowadzić w czasie rzeczywistym rekursywną identyfikację parametryczną toru sterowania systemu z pliku `SystemSISO.mdl`. Obserwować przebieg estymat  $\hat{\mathbf{p}}^{\text{LS}}(nT_p)$  przy jednoczesnym wyświetlaniu wartości numerycznych estymat w bloku `Display`.
- Na wspólnym wykresie porównać przebiegi sygnałów:  $y(t)$ ,  $y_o(t)$  oraz  $y_m(t)$ , gdzie  $y_o(t)$  jest niezakłóconą odpowiedzią systemu (w praktyce niedostępną), natomiast  $y_m(t)$  jest odpowiedzią modelu symulowanego na pobudzenie  $u(t)$ .
- Sprawdzić wpływ stałej czasowej filtrów  $T_F \in \{8T_p, 40T_p, 400T_p\}$  na jakość identyfikacji i stan przejściowy estymat parametrów.

□