

# Identificação Caixa Cinza de Modelos em Espaço de Estados

I Webinar 2024 da SBA

**Prof. Rodrigo A. Ricco**

[ricco@ufop.edu.br](mailto:ricco@ufop.edu.br)




**UFOP**

Universidade Federal  
de Ouro Preto

31 de janeiro de 2024


- 1 Introdução, Problema e Histórico
- 2 Parte 1: Métodos Clássicos
- 3 Parte 2 - Métodos Caixa Cinza
- 4 Parte 3 - Métodos Caixa Cinza para Sistemas Não Lineares
- 5 Considerações Finais

# Modelagem de Sistemas



# Formulação do Problema: Caixa-Preta

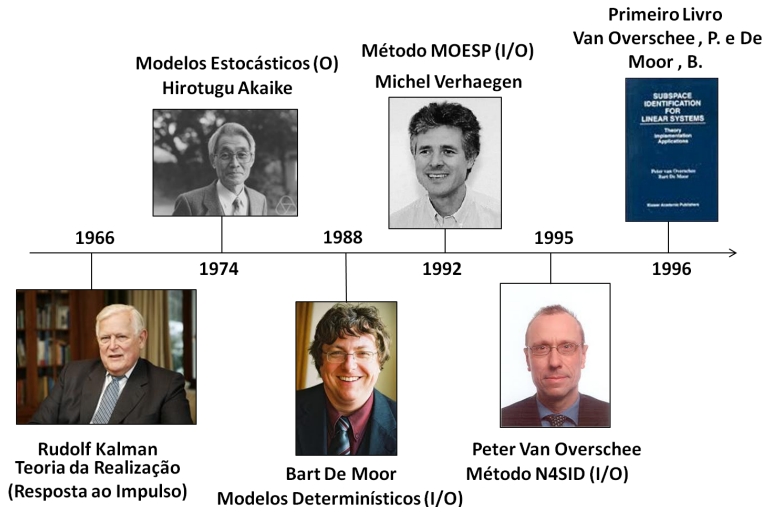
Seja o seguinte sistema discreto, linear e invariante no tempo:



**Figura:** Formulação do problema de identificação caixa-preta no espaço de estados no contexto linear.

Dado um número suficiente de  $N$  medições das entradas  $u_k$  e saídas  $y_k$  geradas pelo sistema desconhecido, determinar, usando somente as  $N$  medições, a ordem  $n$  e as matrizes  $A$ ,  $B$ ,  $C$  e  $D$  do sistema.

# Histórico

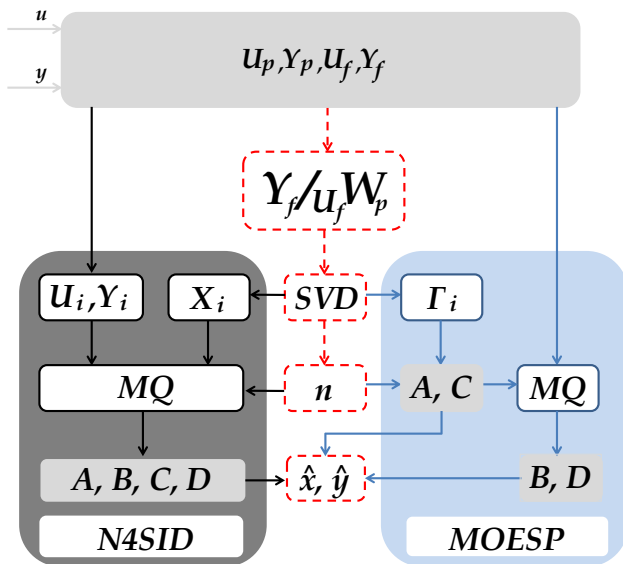


# Por onde começar



Figura: Livros recomendados: (a) em 1996 por Peter van Overschee e Bart De Moor; (b) em 2005 por Tohru Katayama; (c) em 2007 por Michael Verhaegen e Vincent Verdult.

# Métodos clássicos



# N4SID

Considere

$$\hat{X}_i = (\hat{x}_i, \dots, \hat{x}_{i+j-1}), \quad \hat{X}_{i+1} = (\hat{x}_{i+1}, \dots, \hat{x}_{i+j}),$$

$$U_i = (u_i, \dots, u_{i+j-1}), \quad Y_i = (y_i, \dots, y_{i+j-1}),$$

em que o índice  $j \in \mathbb{N}$  é definido tal que  $j \gg i$ .

Portanto,

$$\begin{pmatrix} \hat{X}_{i+1} \\ Y_i \end{pmatrix} = \begin{pmatrix} A & B \\ C & D \end{pmatrix} \begin{pmatrix} \hat{X}_i \\ U_i \end{pmatrix}. \quad (1)$$

Denotando:

$$\Theta = \begin{pmatrix} A & B \\ C & D \end{pmatrix}, \quad \mathcal{X} = \begin{pmatrix} \hat{X}_i \\ U_i \end{pmatrix}, \quad \mathcal{Y} = \begin{pmatrix} \hat{X}_{i+1} \\ Y_i \end{pmatrix},$$

o parâmetro  $\Theta$  pode ser estimado como se segue

$$\hat{\Theta}_{MQ}^{N4SID} = \arg \min_{\Theta} \|\mathcal{Y} - \Theta \mathcal{X}\|_F^2. \quad (2)$$



# MOESP

Sabe-se que

$$\Gamma_i \triangleq \begin{pmatrix} C \\ CA \\ CA^2 \\ \vdots \\ CA^{i-1} \end{pmatrix} \in \mathbb{R}^{mi \times n} \Rightarrow$$

$$\hat{C} = \Gamma_i(1:m,:),$$

$$\hat{A} = \Gamma_i(1:(i-1)m,:)^\dagger \Gamma_i(l+1:im,:).$$

Considere a seguinte equação de saída:

$$y_k = \hat{C}\hat{A}^k x_0 + \left( \sum_{\tau=0}^{k-1} u_\tau^T \otimes \hat{C}\hat{A}^{k-\tau-1} \right) \text{vec}(B) + \left( u_k^T \otimes I_l \right) \text{vec}(D) + e_k$$


Definindo

$$\theta = \begin{bmatrix} x_0 \\ \text{vec}(B) \\ \text{vec}(D) \end{bmatrix} \text{ e } \phi_k^T = \begin{bmatrix} \hat{C}\hat{A}^k & \left( \sum_{\tau=0}^{k-1} u_\tau^T \otimes \hat{C}\hat{A}^{k-\tau-1} \right) & \left( u_k^T \otimes I_l \right) \end{bmatrix}.$$

O vetor  $\theta$  pode ser estimado por

$$\hat{\theta}_{MQ}^{MOESP} = \arg \min_{\theta} \|y_k - \phi_k^T \theta\|_2^2. \quad (3)$$

## Exemplo - Estimação da ordem $\hat{n}$



$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1/C \\ -1/L & -R/L \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 1 \\ 1/L \end{bmatrix} u. \quad (4)$$

$$y = \begin{bmatrix} -1 & -R \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + u. \quad (5)$$


**Figura:** Circuito RLC série.

Escolhendo-se  $R = 10\Omega$ ,  $C = 0,02F$  e  $L = 20H$  e discretizando o sistema (4)-(5) com  $T_s = 0,1s$ , tem-se

$$\begin{bmatrix} x_{1,k+1} \\ x_{2,k+1} \end{bmatrix} = \begin{bmatrix} 0,9877 & 4,8568 \\ -0,0049 & 0,9392 \end{bmatrix} \begin{bmatrix} x_{1,k} \\ x_{2,k} \end{bmatrix} + \begin{bmatrix} 0,0123 \\ 0,0049 \end{bmatrix} u_k, \quad (6)$$


$$y_k = \begin{bmatrix} -1 & -10 \end{bmatrix} \begin{bmatrix} x_{1,k} \\ x_{2,k} \end{bmatrix} + u_k. \quad (7)$$

## Exemplo - Efeito do ruído



**Figura:** Valores singulares da matriz resultante da projeção oblíqua para ruído branco adicionado à saída para diferentes valores de relação sinal ruído ( $SNR$ ), sendo: (x)  $SNR = 20$ , (o)  $SNR = 2$ , (\*)  $SNR = 1$  e (+)  $SNR = 0,67$ .


# Exemplo - Uso de variáveis instrumentais



**Figura:** Comparativo dos valores singulares estimados pelos métodos MOESP, MOESP-PI e MOESP-PO ao determinar a ordem do sistema. Ruído colorido adicionado à saída com  $\text{SNR} = 70$ .


# Planta Piloto de Flotação em Coluna

- **3 entradas:**  $u_1$ : sinal de controle de velocidade da bomba do não flotado,  $u_2$ : vazão de água de lavagem e  $u_3$ : vazão de alimentação de ar;
- **2 saídas:**  $y_1$ : pressão no ponto superior na seção de concentração e  $y_2$ : pressão no ponto inferior na seção de concentração.




**Figura:** Saraiva, E. T. S. (1999). Identificação de uma Planta Piloto de Flotação em Coluna. Mestrado - PPGEE/UFMG.

# Testes para identificação



**Figura:** Teste de identificação da planta piloto de flotação em coluna. Sinais de entrada: (a) velocidade da bomba de não flotado ( $u_1(k)$ ), (b) vazão da água de lavagem ( $u_2(k)$ ) e (c) vazão de ar ( $u_3(k)$ ).

# Testes para identificação



**Figura:** Teste de identificação da planta piloto de flotação em coluna. Sinais de saída, pressões da seção de concentração da coluna: (a) ponto superior ( $y_1(k)$ ) e (b) ponto inferior ( $y_2(k)$ ).

# Modelagem: Clássica $\times$ Subespaços




Figura: Ordem  $\hat{n}$  do sistema a partir dos valores singulares. (a) ARC, (b) MOESP-PI e (c) MOESP-PO.



# Modelagem

## ARC

Modelo linear de terceira ordem com parâmetros:

$$A = \begin{bmatrix} 0,9993 & -0,0764 & -0,0125 \\ 0,0052 & 0,9323 & 0,3948 \\ -0,0009 & -0,0685 & 0,9251 \end{bmatrix},$$

$$B = \begin{bmatrix} 0,1187 & -0,1772 & 0,3574 \\ 0,0204 & -0,0574 & -1,7880 \\ -0,0182 & 0,0171 & 0,3917 \end{bmatrix},$$

$$C = \begin{bmatrix} -0,3851 & -0,1528 & 0,0824 \\ -0,3875 & -0,1508 & 0,0798 \end{bmatrix},$$

$$D = \begin{bmatrix} -0,0176 & 0,0415 & 0,0635 \\ -0,0163 & 0,0421 & 0,1972 \end{bmatrix}. \quad (8)$$

## MOESP-PO

Modelo linear de segunda ordem com parâmetros:

$$A_1 = \begin{bmatrix} 0,9957 & -0,1127 \\ 0,0021 & 0,7686 \end{bmatrix},$$

$$B_1 = \begin{bmatrix} 0,0426 & -0,0613 & -0,0479 \\ -0,0005 & -0,0152 & -0,4473 \end{bmatrix},$$

$$C_1 = \begin{bmatrix} -1,1951 & -0,4338 \\ -1,2357 & -0,4345 \end{bmatrix},$$

$$D_1 = \begin{bmatrix} -0,0179 & 0,0415 & 0,0926 \\ -0,0175 & 0,0430 & 0,2622 \end{bmatrix}. \quad (9)$$

# Modelagem

## MOESP-PO

Modelo linear de segunda ordem com parâmetros:

$$A_2 = \begin{bmatrix} 0,9977 & -0,0877 \\ 0,0029 & 0,8280 \end{bmatrix},$$

$$B_2 = \begin{bmatrix} 0,0305 & -0,0439 & -0,0396 \\ 0,0006 & -0,0147 & -0,3949 \end{bmatrix},$$

$$C_2 = \begin{bmatrix} -1,6835 & -0,4497 \\ -1,6988 & -0,4448 \end{bmatrix},$$

$$D_2 = \begin{bmatrix} -0,0181 & 0,0420 & 0,1083 \\ -0,0172 & 0,0428 & 0,2402 \end{bmatrix}. \quad (10)$$


# Modelagem

## MQE

Modelos lineares de quarta e segunda ordem, respectivamente:

$$\begin{aligned}
 y_1(k) &= 0,5855y_1(k-1) + 0,7976y_1(k-2) + 0,4555y_2(k-4) \\
 &\quad -0,0492u_1(k-1) + 0,0694u_2(k-1) + 0,3338u_3(k-4) \\
 &\quad -0,0055u_2(k-10) - 0,0099u_1(k-5) + 0,4702y_2(k-1) \\
 &\quad -0,4340u_3(k-11) - 0,9274y_2(k-2) - 0,4643y_1(k-4) \\
 &\quad -0,1124u_3(k-12) - 0,4070u_3(k-5) + 0,3827u_3(k-8) \\
 &\quad 0,0651y_1(k-5), \\
 y_2(k) &= 0,9754y_2(k-1) - 0,0792y_2(k-2) + 0,2115u_3(k-7) \\
 &\quad -0,0479u_1(k-1) + 0,0672u_2(k-1) - 0,0089u_2(k-7) \\
 &\quad 0,0898y_1(k-1) - 0,0051u_2(k-15) - 0,0105u_2(k-3) \\
 &\quad -0,3476u_3(k-11) - 0,0083u_2(k-10) + 0,0033u_2(k-11) \\
 &\quad 0,0081u_2(k-8) + 0,0005u_2(k-13) + 0,1732u_3(k-4) \\
 &\quad 0,0350u_3(k-1),
 \end{aligned} \tag{11}$$

# Validação



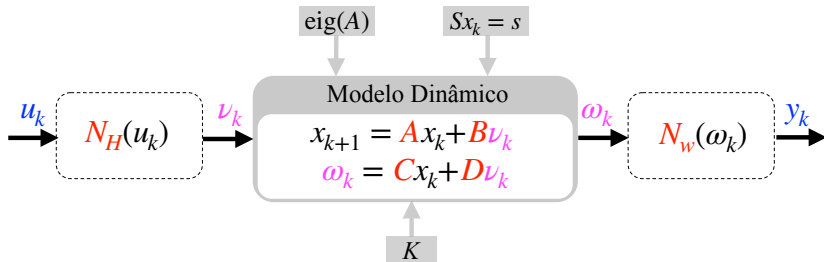
**Figura:** Pressões da seção de concentração da coluna: (a) ponto superior e (b) ponto inferior. (-) pressões na saída. (●) MQE (RMSE {0,37, 0,37}). (×) ARC (RMSE {0,42, 0,41}). (\*) MOESP-PI (RMSE {0,20, 0,25}). (○) MOESP-PO (RMSE {0,19, 0,24}). SID com tempo de simulação em média  $7 \times$  menor.

# Vantagens × Desvantagens

- Não precisa de CI;
- Abordagem entrada-estado-saída;
- Parametrização simples para sistemas MIMO;
- Baseado em ferramentas numéricas eficientes: SVD e QR;
- Totalmente caixa-preta;
- Difícil interpretação física;
- Linear?
- Sensível a quantidade de dados disponíveis;
- Malha aberta.

# Formulação do Problema: Caixa Cinza

Seja o seguinte sistema discreto, linear e invariante no tempo:



Dado que o modelo caixa preta não atende aos requisitos de projeto, determinar, quais informações auxiliares disponíveis podem ser mapeadas e incorporadas adequadamente no modelo  $A$ ,  $B$ ,  $C$  e  $D$  do sistema.

# Ganho em Estado Estacionário

Considere a restrição do ganho em estado estacionário proposta por Prívará (2012)

$$K = D + CB + CAB + CA^2B + \cdots + CA^k B, \quad (12)$$

que pode ser reescrita como

$$\text{vec}(K) = \underbrace{[I_{p \times p} \otimes \hat{C}(I_{n \times n} - \hat{A})^{-1} \quad I_{pm \times pm}]}_{\Gamma_s} \begin{bmatrix} \text{vec}(B) \\ \text{vec}(D) \end{bmatrix}. \quad (13)$$

Prívará (2012), propõe estimar  $\theta$  por

$$\hat{\theta} = \arg \min_{\theta: c = S_c \theta} \|y_k - \phi_k^T \theta\|_2^2, \quad (14)$$

em que  $c = \text{vec}(K)$  e  $S_c = [0_{pm \times n} \quad \Gamma_s]$ , ou,

$$\hat{\theta} = \arg \min_{\theta} \left\| \begin{bmatrix} y_k \\ \text{vec}(K) \end{bmatrix} - \begin{bmatrix} \phi_k^T \\ [0_{pm \times n} \quad \Gamma_s] \end{bmatrix} \theta \right\|_W^2. \quad (15)$$

- Prívará, S., Cigler, J., Vaná, Z., and Ferkl, L. (2012). Incorporation of System Steady State Properties into Subspace Identification Algorithm. *International Journal of Modelling, Identification and Control*, 16(2): 159 - 167.

# Ganho em Estado Estacionário: Exemplo

Considere o seguinte sistema MIMO:

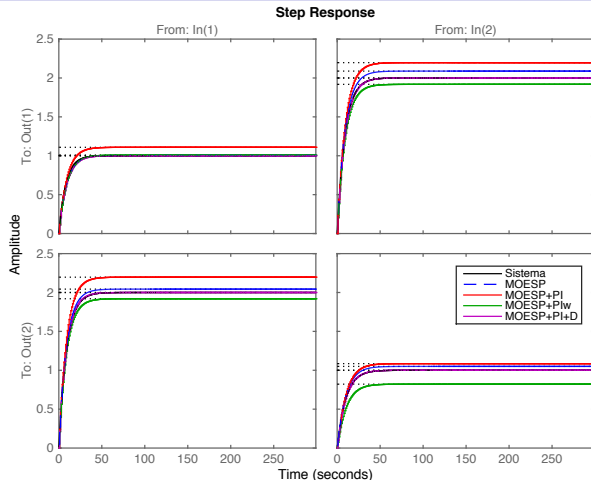
$$G_e(s) = \begin{bmatrix} \frac{1}{8s+1} & \frac{2}{9s+1} \\ \frac{2}{9s+1} & \frac{1}{10s+1} \end{bmatrix}.$$

- $T_s = 1s$ ;
- $u_{k,1}$  e  $u_{k,2} \Rightarrow$  PRBS de 8 bits e  $m = 4$ ;
- $N_s = 300$  amostras;
- $y_{k,1}$  e  $y_{k,2} \Rightarrow$  sinais brancos independentes com variância igual a 0.1 filtrados por

$$H_e(z) = \frac{1}{z - 0.5};$$

- $W = 0.25$ ;
- Informação *a priori*:

$$K = \begin{bmatrix} 1 & 2 \\ 2 & 1 \end{bmatrix}.$$



A informação *a priori* conhecida contribuiu para o desempenho do modelo!



# Ganho em Estado Estacionário: Exemplo

Considere o seguinte sistema MIMO:


$$G_e(s) = \begin{bmatrix} \frac{1}{8s+1} & \frac{2}{9s+1} \\ \frac{2}{9s+1} & \frac{1}{10s+1} \end{bmatrix}.$$

- $T_s = 1s$ ;
- $u_{k,1}$  e  $u_{k,2} \Rightarrow$  PRBS de 8 bits e  $m = 4$ ;
- $N_s = 300$  amostras;
- $y_{k,1}$  e  $y_{k,2} \Rightarrow$  sinais brancos independentes com variância igual a 0.1 filtrados por

$$H_e(z) = \frac{1}{z - 0.5};$$

- $W = 0.25$ ;
- Informação *a priori*:

$$K = \begin{bmatrix} 1.1 & 2.2 \\ 2.2 & 1.1 \end{bmatrix}.$$



A informação *a priori* incerta teve um efeito relevante no desempenho em estado estacionário!

# Localização dos Polos

## D-Estabilidade

Ideia de Miller e de Callafon (2013)




Figura: Regiões  $D$  estáveis. Adaptado de Miller et al.(2012).

### Observação 4.1

A interseção de duas regiões LMIs,  $D_1$  e  $D_2$ , também é uma região LMI.

$$f_{D_1 \cap D_2}(z) = \begin{bmatrix} f_{D_1}(z) & 0 \\ 0 & f_{D_2}(z) \end{bmatrix}.$$

# Localização dos Polos

## D-Estabilidade

É possível escrever essas regiões na forma de uma LMI?

### Lema 4.1

(Chilali e Gahinet, 1996) Uma matriz  $A$  é  $D$ -estável se, e somente se, existir uma matriz  $P \in \mathbb{R}^{n \times n}$  tal que

$$P = P^T > 0, \quad M_{D_c}(A, P) \geq 0 \quad (16)$$

em que  $M_{D_c}(A, P) = \lambda \otimes P + \beta \otimes (AP) + \beta^T \otimes (AP)^T,$  (17)

sendo a região  $D_c$  convexa do plano complexo definida por

$$D_c = \{z \in \mathbb{C} : f_{D_c} \geq 0\} \quad (18)$$

onde  $f_{D_c}(z) = \lambda + \beta z + \beta^T \bar{z},$  (19)

em que  $\lambda$  é uma matriz simétrica e  $\beta$  é uma matriz quadrada.

# Localização dos Polos

## Função Custo

Sabe-se que

$$\hat{\Gamma}^T = \begin{bmatrix} \textcolor{red}{C}^T & \textcolor{blue}{(CA)}^T & \dots & (CA^{i-1})^T \end{bmatrix}, \quad (20)$$

Tem-se que

$$\textcolor{red}{\hat{\Gamma}}_0 = \hat{\Gamma}(1 : m(i-1), :) \quad \text{e} \quad \textcolor{blue}{\hat{\Gamma}}_1 = \hat{\Gamma}(m+1 : mi, :), \quad (21)$$

Portanto,

$$J_{\Gamma}^0(A) = \left\| \textcolor{red}{\hat{\Gamma}}_0 A - \textcolor{blue}{\hat{\Gamma}}_1 \right\|_F. \quad (22)$$

Multiplicando por  $P$ , forma-se a seguinte função custo modificada:

$$\textcolor{green}{J}_{\Gamma}^1(A, P) = \left\| \hat{\Gamma}_0 A P - \hat{\Gamma}_1 P \right\|_F. \quad (23)$$

# Identificação de Sistemas com Restrição nos Autovalores

Defina  $Q \triangleq AP$ .

## Problema 4.1

Dada a estimativa de  $\hat{F}$  e uma região LMI descrita pelos parâmetros  $\lambda$  e  $\beta$

$$\text{minimize} \quad J_F^C(Q, P), \quad (24)$$

$$\text{sujeito a} \quad M_D(Q, P) \geq 0, \quad (25)$$

$$P = P^T > 0, \quad (26)$$

$$\text{tr}(P) = n, \quad (27)$$

em que,

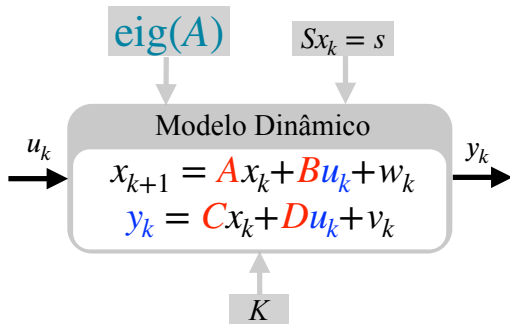
$$J_F^C(Q, P) \triangleq \left\| \hat{F}_0 Q - \hat{F}_1 P \right\|_F^2, \quad (28)$$

$$M_D(Q, P) \triangleq \lambda \otimes P + \beta \otimes Q + \beta^T \otimes Q^T. \quad (29)$$

Encontrando  $Q$  e  $P$ , tem-se que  $\hat{A} = QP^{-1}$ .

## Como obter na prática os parâmetros $\lambda$ e $\beta$ ?


# Mapeamento de Informações Auxiliares em Regiões LMI Convexas



- Resposta ao degrau;
- Mapeamento das regiões;
- Conservadorismo das regiões para IS;
- Importância do uso correto da informação auxiliar.

- RICCO, R. A.; TEIXEIRA, B. O. S.. Mapping prior information onto LMI eigenvalue-regions for discrete-time subspace identification. IET Control Theory & Applications. vol. 14, no. 2, pp. 358 - 366, 2020.

## Regiões LMI em Identificação por Subespaços





**Figura:** Resposta ao degrau  $y_k$  (SNR  $\approx 5$ dB) de um sistema de segunda ordem com  $K = 0.7$ ,  $\zeta = 0.2$  e  $w_n = 1$  em **preto** e sem ruído em **azul**.

# Máximo Sobressinal $O_s(\zeta)$

$$O_s \leq O_s^{\max} \implies \zeta \geq 0.6 \left( 1 - \frac{O_s^{\max}}{100} \right), \quad (30)$$

em que  $\zeta \geq \zeta^{\min}$  e  $0 < \zeta^{\min} < 1$ ,  $\pm\beta = \cos^{-1}(\zeta)$ .





# Máximo sobressinal $O_s(\zeta)$

Essas Regiões LMI são úteis em Identificação de Sistemas?

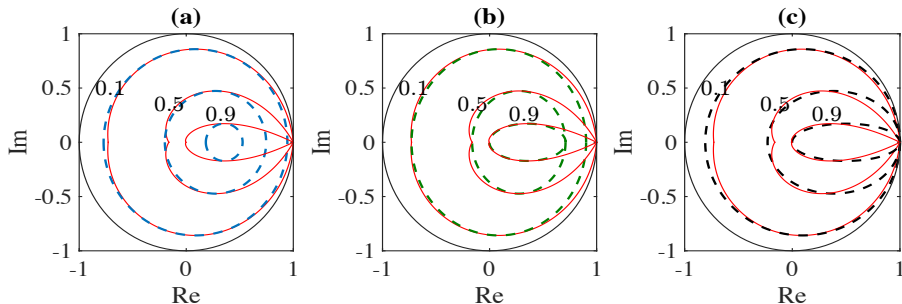



Figura: (Rosinova, 2014): (a) Disco e (b) Elipse. Proposta: (c) Elipse reparametrizada.

# Região do Período entre Oscilações Amortecidas $T_d(w_d)$

$$T_d \geq T_d^{\max} \Rightarrow w_d \leq \frac{2\pi}{T_d^{\max}}, \quad (31)$$



em que  $w_d \leq w_d^{\max}$  e  $w_d^{\max} > 0$ .  $\theta^{\max} = w_d^{\max} T_s$  com  $\theta^{\max} \leq \pi/2$ , tal que  $T_s \leq T_d^{\max}/4$ .



# Região do Tempo de Acomodação $t_s^{\max}(\zeta w_n)$

$$t_{s,1\%} \leq t_{s,1\%}^{\max} \implies \zeta w_n \geq \frac{4.6}{t_{s,1\%}^{\max}}, \quad (32)$$

em que  $\zeta w_n \geq \zeta w_n^{\min}$ , tal que  $\zeta w_n^{\min} > 0$ ,  $c_s \triangleq 0$  e  $r_s^{\max} \triangleq e^{-\zeta w_n^{\min} T_s}$ .





## Aspectos Práticos na Construção de Regiões LMI

$$\zeta^{\min} \triangleq \hat{\zeta} - \Delta_{\zeta}, \quad 0 < \zeta^{\min} < 1, \quad (33)$$

$$w_d^{\max} \triangleq \hat{w}_d + \Delta_{w_d}, \quad 0 < w_d^{\max} < w_s/4 \quad (34)$$

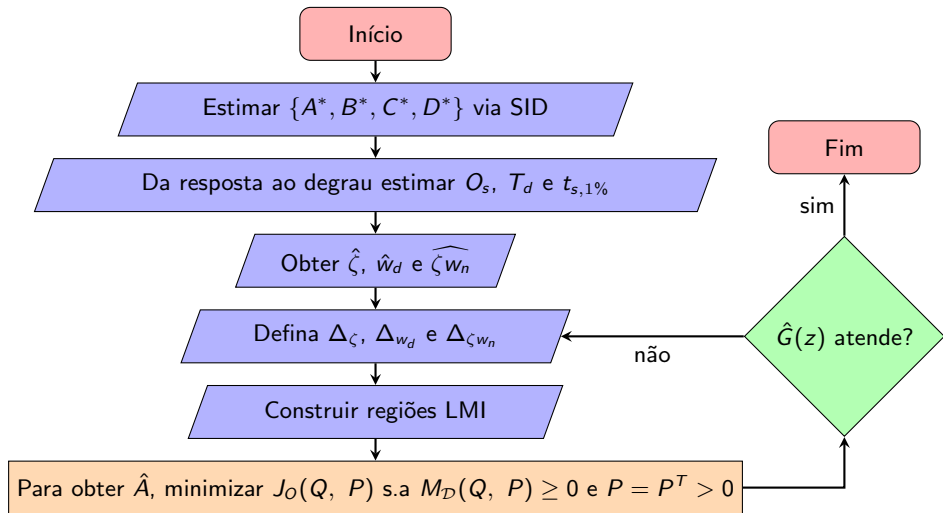
$$\zeta w_n^{\min} \triangleq \widehat{\zeta w_n} - \Delta_{\zeta w_n}, \quad \zeta w_n^{\min} > 0, \quad (35)$$

em que,  $\Delta_{\zeta}$ ,  $\Delta_{w_d}$  and  $\Delta_{\zeta w_n}$  são definidos pelo usuário.




# Identificação por Subespaços com Restrição

## Mapeamento de Restrições LMI no Tempo Discreto

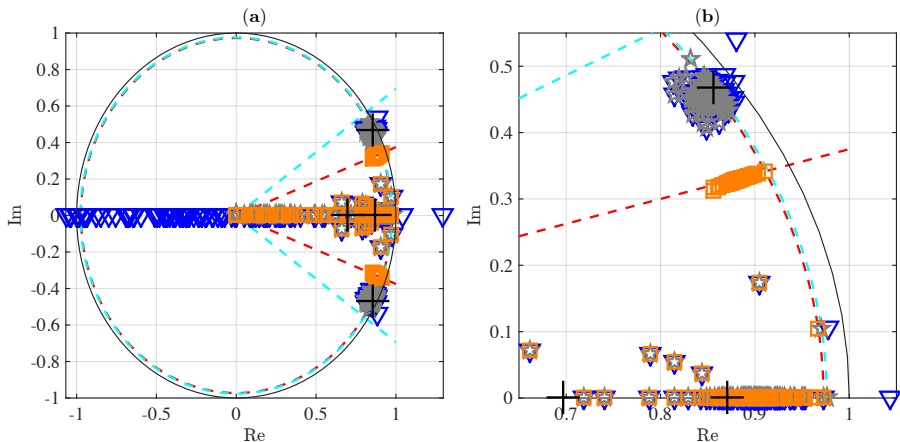


## Exemplo : Regiões LMI Conservadoras



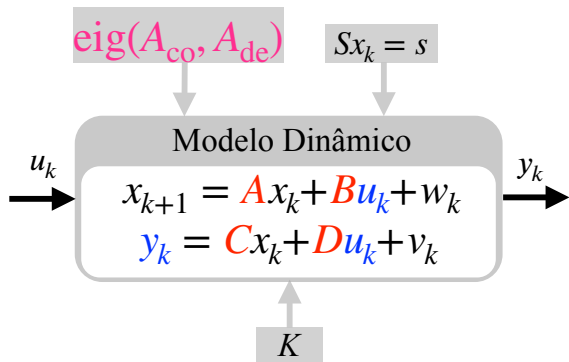
**Figura:** Resposta ao degrau  $y_k$  ( $\text{SNR} \approx 5\text{dB}$ ) de um sistema de quarta ordem em **preto** e sem ruído em **azul**. Média de 100 simulações obtidas por modelos restritos a região obtida por □ é mostrada em (-.-) e por X é mostrada em (- -).

# Exemplo: Regiões LMI Conservadoras



**Figura:** Autovalores reais em (+). MOESP-PI (▽). Estimativas na interseção do disco (tempo de acomodação) e o cone (período entre oscilações) são indicadas em (□) para a região em (- -). Estimativas usando as variáveis de ajuste (33)-(35) são mostradas em (☆) para região em (- -).

# Identificação por Subespaços com Restrição Parcial nos Autovalores



- Autovalores restritos as mesmas regiões;
- Forçar a estrutura do modelo;
- Restringir somente os autovalores de interesse;
- Método de duas etapas.

- RICCO, R. A.; VERLY, A; PAULA, M. V.; TEIXEIRA, B. O. S.. Subspace Identification of Linear Systems with Partial Eigenvalue Constraints. IEEE Latin America Transactions. vol 17, no. 2, pp. 288 - 296, 2019.



## Restrição Parcial nos Autovalores

Qual a estrutura de  $A_{co}$ ,  $P_{co}$  e  $Q_{co}$  para realizar a estimação com restrição parcial?

$$\Lambda(z) \triangleq \prod_{i=1}^{n_p} \left[ \prod_{j=1}^{m_i} (z + p_{ij}) \right], \quad (36)$$

$n_p \in \mathbb{Z}_+^*$  é o número de partições do polinômio,  $m_i$  é o número de autovalores por partição,  $i \in \mathbb{Z}_+^*$  é a posição de cada partição e  $j \in \mathbb{Z}_+^*$  é a posição de cada autovalor em cada uma das partições.

Para autovalores  $\neq s$

$$A_i \triangleq \text{diag}\{p_{i1}, p_{i2}, \dots, p_{im_i}\} \quad (37)$$

Se  $n_{co}$  partições são conhecidas

$$A \triangleq \text{diag}\{\underbrace{A_1, \dots, A_{n_{co}}}_{n_{co}}, A_{de}\}, \quad (38)$$

Defina

$$P \triangleq \text{diag}\{P_{co}, I\} \text{ e } Q \triangleq \text{diag}\{Q_{co}, A_{de}\} \quad (39)$$

em que  $P_{co}$  é um conjunto de matrizes simétricas  $P_i \forall i \in \{1, \dots, n_{co}\}$  e  $Q_{co} = A_{co}P_{co}$ .

# Restrição Parcial nos Autovalores

## Problema 4.2

Dada a estimativa de  $A^*$  e uma região LMI descrita pelos parâmetros  $\lambda$  e  $\beta$

$$\text{minimize} \quad J_{RP}(Q, P), \quad (40)$$

$$\text{sujeito a} \quad M_D(Q_{co}, P_{co}) \geq 0, \quad (41)$$

$$P_{co} = P_{co}^T > 0, \quad (42)$$

$$\text{tr}(P_{co}) = n - m, \quad (43)$$

em que,

$$J_{RP}(Q, P) \triangleq \|A^*P - Q\|_F^2, \quad (44)$$

$$M_D(Q_{co}, P_{co}) \triangleq \lambda \otimes P_{co} + \beta \otimes Q_{co} + \beta^T \otimes Q_{co}^T. \quad (45)$$

Encontrando  $Q_{co}$  e  $P_{co}$ , tem-se que  $\hat{A}_{co} = Q_{co}P_{co}^{-1}$ .

# Sistema de terceira ordem




Figura: MOESP (+). MOESP-R (x): disco (—•)  $\cap$  cone amortecido (—•). MOESP-RP (\*). A região LMI da etapa 1 do MOESP-RP é limitada pelo disco (—•), enquanto a região LMI da etapa 2 do MOESP-RP é a mesma do MOESP-R.





Figura: Saída  $y(kT_s)$  sem ruído (—). A média de 200 realizações das respostas ao degrau são apresentadas em (—•) para o MOESP-R, em (—•) para o MOESP-RP e em (••) para o MOESP irrestrito.

# Tópicos de Interesse

## Sistemas Lineares

- Estimação de parâmetros com **parcimônia** entre dados **dinâmicos** e dados em **estado estacionário**;
  - ▶ HOU, J. ; YANG, Z.; LI, T. ; WANG, H. ; JIANG, J. ; CHEN, X. . Full-parameter constrained parsimonious subspace identification with steady-state information for DC-DC converters. Control Theory and Technology, 2023.  
<https://doi.org/10.1007/s11768-023-00148-9>, 2023;
- Identificação de modelos com restrições de **igualdade** nos estados;
  - ▶ RICCO, R. A. ; TEIXEIRA, B. O. S.. Least-Squares Parameter Estimation for State-Space Models with State Equality Constraints. International Journal of Systems and Science. vol. 53, no. 1, pp. 1 - 13, 2022;
- Obtenção de uma **transformação de similaridade** em **base conveniente** adivinda do problema de filtragem;
  - ▶ MUSSOT, V. ; MERCÈRE, G.; DAIRAY, T.; ARVIS, V.; VAYSSETTES, J. . Noise covariance matrix estimation with subspace model identification for Kalman filtering. International Journal Adaptive Control and Signal Processing. vol. 35, no. 4, pp. 591 - 611, 2021.;

# Curva estática não linear




**Figura:** a) Curva não linear aproximada por três retas; b) Curva não linear sinuosa aproximada por treze retas.

# Modelos de Blocos Interconectados

- Estimação de modelos do tipo Hammerstein ou Wiener MIMO em batelada;
  - ▶ GÓMEZ, J.C. e BAYENS, E.. Subspace Identification of Multivariable Hammerstein and Wiener Models, European Journal of Control, Vol. 11, No. 2, 2005.;
- Uso de múltiplos degraus;
  - ▶ PAULA, M. V. ; RICCO, R. A. ; TEIXEIRA, B. O. S. . Identificação de Modelos de Hammerstein e Wiener para Sistemas Não Lineares Multivariáveis via Métodos de Subespaços. In: XII Simpósio Brasileiro de Automação Inteligente - SBAI, 2015.;
- Uso de sinais harmônicos para modelos de Wiener;
  - ▶ PAULA, M. V. ; RICCO, R. A. ; TEIXEIRA, B. O. S. . Identificação Semi Paramétrica de Sistemas MIMO do Tipo Wiener por meio de Sinais Harmônicos e Métodos de Subespaços. In: XXI Congresso Brasileiro de Automática, - CBA 2016.;

# Modelos de Hammerstein e Wiener

## Estimação conjunta



### Hammerstein

$$v_k = \sum_{i=1}^r \alpha_i g_i(u_k),$$

$$x_{k+1} = Ax_k + \tilde{B}u_k + \xi_k,$$

$$y_k = Cx_k + \tilde{D}u_k + e_k.$$

$$[\tilde{B}_{rp \times n}^T \quad \tilde{D}_{rp \times m}^T]^T \triangleq \Theta_{BD} = \begin{bmatrix} B_{n \times p} \\ D_{m \times p} \end{bmatrix} \alpha_{p \times rp}^T.$$

$$(\hat{B}, \hat{D}, \hat{\alpha}) = \arg_{B, D, \alpha} \min \left\{ \left\| \hat{\Theta}_{BD} - \begin{bmatrix} B \\ D \end{bmatrix} \alpha^T \right\|_2^2 \right\}.$$

$$\left( \begin{bmatrix} \hat{B}_{n \times p} \\ \hat{D}_{m \times p} \end{bmatrix}, \hat{\alpha}_{rp \times p} \right) = (U_1 \Sigma_1, V_1),$$

### Wiener

$$\alpha Y_k \triangleq \sum_{i=1}^r \alpha_i g_i(y_k).$$

$$x_{k+1} = Ax_k + Bu_k + \xi_k,$$

$$Y_k = \tilde{C}x_k + \tilde{D}u_k + \tilde{e}_k.$$

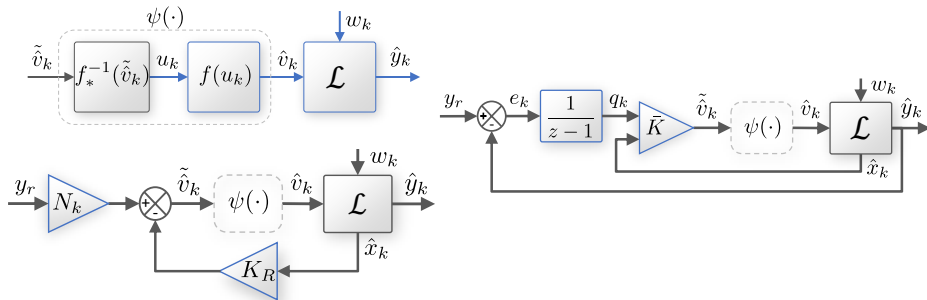
$$[\tilde{C}_{rm \times n} \quad \tilde{D}_{rm \times m}] \triangleq \Theta_{CD} = \alpha_{rm \times m}^\dagger [C_{m \times n} \quad D_{m \times p}].$$

$$(\hat{C}, \hat{D}, \hat{\alpha}^\dagger) = \arg_{C, D, \alpha^\dagger} \min \left\{ \left\| \hat{\Theta}_{CD} - \alpha^\dagger [C \quad D] \right\|_2^2 \right\}.$$

$$(\hat{\alpha}_{rm \times m}^\dagger, [\hat{C}_{m \times n} \quad \hat{D}_{m \times p}]) = (U_1^\dagger, \Sigma_1 V_1^T).$$

# Tópicos de Interesse


## Controle de Sistemas Não Lineares



### ● Controle robusto baseado em modelo linearizado:

- ▶ SANTOS, L. H. ; BRAGA, M. F. ; RICCO, R. A. . Nova Abordagem para Linearização de Modelos de Hammerstein Identificados por Métodos de Subespaço. In: XV SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE - SBAI, 2021. p. 879-886.;
- ▶ SANTOS, L. H., BRAGA, M. F. e RICCO, R. A.. A New Approach for Robust Control Based on Parametric Hammerstein Models. (Em desenvolvimento).






**Figura:** Sistema 2 de tanques interconectados com saturação na entrada: [19] Z. Rayouf, C. Ghorbel, and N. Braiek, A new Hammerstein model control strategy: feedback stabilization and stability analysis, International Journal of Dynamics and Control, vol. 7, no. 4, pp. 1453 - 1461, 2018.

# Tópicos de Interesse


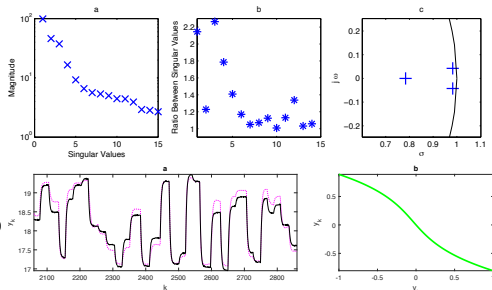

## Sistemas Não Lineares Incertos



### Modelos de Hammerstein e Wiener com incerteza paramétrica;




- ▶ PAULA, M. V., RICCO, R. A. e TEIXEIRA, B. O. S.. Subspace Identification of Hammerstein Models with Interval Uncertainties. (Em desenvolvimento);
- ▶ PAULA, M. V., RICCO, R. A. e TEIXEIRA, B. O. S.. Nonlinear system identification based on state-space uncertain Wiener models. (Em desenvolvimento);

# Tópicos de Interesse



# Tópicos de Interesse

## Não Linearidades Fortes



- Hammerstein MIMO com não linearidades fortes;

- ▶ SANTOS, L. H.; RICCO, R. A. ; TEIXEIRA, B. O. S. Identificação de Modelos de Hammerstein Multivariáveis com Não Linearidades Estáticas Fortes. In: XVI Simpósio Brasileiro de Automação Inteligente - SBAI, 2023;
- ▶ SANTOS, L. H., RICCO, R. A. e TEIXEIRA, B. O. S.. Identification of Multivariable Hammerstein Systems with Hysteresis Nonlinearities (Em desenvolvimento);

- **Luís Henrique dos Santos.** Identificação de Modelos de Hammerstein Multivariáveis com Não Linearidades Estáticas ou Quase Estáticas Fortes. Data: **23-02-2024 às 09h00.** Link da defesa no site do PPGE(UFMG);

# Estado da arte

(a)



Automatica

Volume 43, Issue 6, June 2007, Pages 1034-1048



## The role of vector autoregressive modeling in predictor-based subspace identification



PBSID

Alessandro Chiuso 

(b)

Journals & Magazines > IEEE Transactions on Automati... > Volume: 65 Issue: 10 

## Constrained Subspace Method for the Identification of Structured State-Space Models (COSMOS)

Publisher: IEEE

[Cite This](#)

[PDF](#)

Chengpu Yu  ; Lennart Ljung  ; Adrian Wills  ; Michel Verhaegen  [All Authors](#)

58

Cites in  
Papers


1379

Full  
Text Views

Dezembro de 2019



(c)



# Considerações Finais

- 1 Identificação em malha fechada;
- 2 Identificação em tempo contínuo;
- 3 Variantes no tempo;
- 4 Restrições nos zeros SISO (MIMO - algumas ideias em implementação);
- 5 Aplicações práticas (projetos);
- 6 Efeito multiplicador do conhecimento.

# Agradecimentos

- CAPES e CNPq;
- Laboratório de Modelagem, Identificação, Instrumentação e Controle - LMI2C (UFOP);
- Departamento de Engenharia Elétrica da UFOP;
- Prof. Bruno O. S.Teixeira (UFMG);
- PPGEE, Grupo MACSIN (UFMG);

**PPGEE em associação ampla entre UFOP e UNIFEI!**  
**Início previsto: (2S/2024)**

# Contato

**OBRIGADO!**

ricco@ufop.edu.br