

MODELOS PARAMÉTRICOS

GABRIELA W GABRIEL

IEE-S / ITA – Sala 195 – Ramal 5991

ggabriel@ita.br / gabriela.gabriel@gp.ita.br

São José dos Campos, 2 de Setembro de 2021


CONTEÚDO

1 MODELOS DE SISTEMAS ESTOCÁSTICOS


- Caracterização do Ruído Estocástico
- Caracterização do Sistema
- Famílias de Modelos Paramétricos em FT

CARACTERIZAÇÃO DO RUÍDO ESTOCÁSTICO

- Para estudo do modelo, vamos considerar ruído aditivo, sendo



|||

FIGURA: Sistema com entrada $u(t)$ e ruído aditivo de medida $w(t)$.

CARACTERIZAÇÃO DO RUÍDO ESTOCÁSTICO

- Sendo $w[k]$ desconhecido a priori, como caracterizá-lo?



Determinando **TODAS** as suas p.d.f conjuntas?

CARACTERIZAÇÃO DO RUÍDO ESTOCÁSTICO

- Sendo $w[k]$ desconhecido a priori, como caracterizá-lo?



Determinando **TODAS** as suas p.d.f conjuntas?

CARACTERIZAÇÃO DO RUÍDO ESTOCÁSTICO

- Sendo $w[k]$ desconhecido a priori, como caracterizá-lo?



Determinando **TODAS** as suas p.d.f conjuntas?



$w[k]$ é um ruído GAUSSIANO : características de 1a e 2a ordens são suficientes!

CARACTERIZAÇÃO DO RUÍDO ESTOCÁSTICO

- $w[k]$ pode ser construído a partir de um ruído branco

$$w[k] = \sum_{j=0}^{\infty} h(j)e[k-j]$$




FIGURA: Modelo entrada-saída do ruído

- $\{e[k]\}_{k \in \mathbb{N}}$ é uma sequência de ruídos brancos i.i.d, com $e[k] \sim \mathcal{N}(0, \sigma^2)$

CARACTERIZAÇÃO DO RUÍDO ESTOCÁSTICO

- Relembrando, $q^{-j}w[k] = w[k - j]$. Assim,

$$w[k] = H(q)e[k] ; \quad H(q) = \sum_{j=0}^{\infty} h(j)q^{-j}$$

- Média e covariância de $w[k]$

$$\mathcal{E}(w[k]) = 0 \quad \mathcal{E}(w[k]w[k - \tau]) = \sigma^2 \sum_{j=0}^{\infty} h(j)h(j - \tau)$$

$w[k]$ é WSS!

CARACTERIZAÇÃO DO SISTEMA

- Para o sistema completo, teremos

$$y[k] = \sum_{j=0}^{\infty} g(j)u[k-j] + w[k] = \sum_{j=0}^{\infty} g(j)q^{-j}u[k] + w[k] = G(q)u[k] + H(q)e[k]$$

- Para o caso de um sistema originalmente contínuo, podemos escrever

$$G(q) \approx G_c \left(\frac{q-1}{T} \right), \quad \text{Aproximação de Euler}$$

ou,

$$G(q) \approx G_c \left(\frac{2}{T} \frac{q-1}{q+1} \right), \quad \text{Aproximação de Tustin}$$

MODELOS DE SISTEMAS LTI

- Sistemas LTI podem ser caracterizados por
 - 1 Resposta ao Impulso do Sistema: $\{g[k]\}_{k=0}^{\infty}$
 - 2 Densidade espectral do ruído: $S_w(\omega) = \sigma^2 |H(e^{j\omega})|^2$
 - 3 p.d.f. de $e[k]$, alternativamente por $\mathcal{E}(e[k])$ e $\mathcal{E}(e[k]^2)$
- Mesmo conhecendo $e[k]$, precisamos DETERMINAR $\{g(q)\}$ e $\{h(q)\}$

$\{g(q)\}$ e $\{h(q)\}$ são **SEQUÊNCIAS INFINITAS** em q

MODELOS DE SISTEMAS LTI

- Sistemas LTI podem ser caracterizados por
 - 1 Resposta ao Impulso do Sistema: $\{g[k]\}_{k=0}^{\infty}$
 - 2 Densidade espectral do ruído: $S_w(\omega) = \sigma^2 |H(e^{j\omega})|^2$
 - 3 p.d.f. de $e[k]$, alternativamente por $\mathcal{E}(e[k])$ e $\mathcal{E}(e[k]^2)$
- Mesmo conhecendo $e[k]$, precisamos DETERMINAR $\{g(q)\}$ e $\{h(q)\}$

$\{g(q)\}$ e $\{h(q)\}$ são **SEQUÊNCIAS INFINITAS** em q



Séries de Potências **Truncadas**

MODELOS DE SISTEMAS LTI

- A **Identificação de Sistemas** paramétrica corresponde a encontrarmos um modelo do tipo

$$y[k] = G(q)u[k] + H(q)e[k]$$

em que as funções de transferência possuem coeficientes, em quantidade finita, a serem determinados.

MODELOS DE SISTEMAS LTI

- A **Identificação de Sistemas** paramétrica corresponde a encontrarmos um modelo do tipo

$$y[k] = G(q)u[k] + H(q)e[k]$$

em que as funções de transferência possuem coeficientes, em quantidade finita, a serem determinados.



PARÂMETROS : θ (vetor)

portanto,

$$y[k] = G(\theta, q)u[k] + H(\theta, q)e[k]$$

(Família ou Conjunto de Modelos)

MODELOS BLACK-BOX

- Há **diferentes famílias de modelos** determinados pelas funções de transferência G e H
- G e H serão **funções racionais** em θ e q
- G e H serão determinadas a partir das **medidas dos sinais de ENTRADA e SAÍDA** realizadas no sistema
- **Notação:**
 - * Parâmetro θ obtido a partir dos coeficientes dos polinômios envolvidos nos modelos

$$\theta = [a_1 \quad a_2 \quad \cdots \quad a_{na} \quad b_1 \quad b_2 \quad \cdots \quad b_{nb} \quad \cdots]'$$

para polinômios do tipo

$$A(q) = 1 + a_1 q^{-1} + a_2 q^{-2} + \cdots + a_{na} q^{-na}$$

$$B(q) = b_1 q^{-1} + b_2 q^{-2} + \cdots + b_{nb} q^{-nb}$$

...

MODELO ARX

$$y[k] + a_1y[k-1] + \dots + a_nay[k-na] \\ = b_1u[k-1] + b_2u[k-2] + \dots + b_nbu[k-nb] + e[k]$$

(Modelo com Erro na Equação)


- 1 Parâmetro $\theta = [a_1 \ a_2 \ \dots \ a_{na} \ b_1 \ b_2 \ \dots \ b_{nb}]'$
 - 2 Polinômio $A(q) = 1 + a_1q^{-1} + a_2q^{-2} + \dots + a_naq^{-na}$
 - 3 Polinômio $B(q) = b_1q^{-1} + b_2q^{-2} + \dots + b_nbq^{-nb}$
- Podemos escrever

$$G(q, \theta) = \frac{B(q)}{A(q)}$$

$$H(q, \theta) = \frac{1}{A(q)}$$

MODELO ARX

- O diagrama de blocos correspondente é



que corresponde a

$$A(q)y[k] = B(q)u[k] + e[k]$$

(Família de modelos Autoregressivo com Entrada Exógena (ARX))

MODELO ARX

- Modelo ARX

- 1 Autoregressivo pois $y[k]$ **depende de seus valores anteriores**
- 2 Com Entrada Exógena pois **depende de $u[k]$**
- 3 Ruído passa pela dinâmica do próprio sistema ($1/A(q)$) (?)

- Caso particular: $na = 0 \implies A(q) = 1$, então

$$y[k] = B(q)u[k] + e[k]$$

(Família de modelos Resposta ao Impulso Finita (FIR))

MODELO ARX – ESTIMADOR

- Podemos escrever

$$y[k] = B(q)u[k] + [1 - A(q)]y[k] + e[k]$$

Se o erro $e[k]$ é o erro de estimação, então

$$\hat{y}(k|\theta) = B(q)u[k] + [1 - A(q)]y[k]$$

(Estimador ou preditor ARX para $y[k]$)

MODELO ARX – REGRESSÃO LINEAR

- Para o **vetor de regressores**

$$\varphi(k) = [-y[k-1] \cdots -y[k-na] \ u[k-1] \cdots u[k-nb]]'$$

e para o **vetor de parâmetros**

$$\theta = [a_1 \ a_2 \ \cdots \ a_{na} \ b_1 \ b_2 \ \cdots \ b_{nb}]'$$

$$\hat{y}(k|\theta) = \theta' \varphi(k) = \varphi(k)' \theta$$

(Regressão linear)

- Caso alguns parâmetros sejam conhecidos, podemos separá-los gerando

$$\hat{y}(k|\theta) = \theta' \varphi(k) + \mu(k)$$

MODELO ARMAX

- Adicionamos flexibilidade ao modelo, adicionando uma **Média Móvel** ao ruído branco

$$y[k] + a_1y[k-1] + \dots + a_nay[k-na] \\ = b_1u[k-1] + \dots + b_nbu[k-nb] + e[k] + c_1e[k-1] + \dots + c_nce[k-nc]$$

(Modelo com Erro na Equação)


que gera, para $C(q) = 1 + c_1q^{-1} + \dots + c_nq^{-nc}$,

$$A(q)y[k] = B(q)u[k] + C(q)e[k]$$

(Família de modelos Autoregressivo com Média Móvel e Entrada Exógena
(ARMAX))

MODELO ARMAX

- O diagrama neste caso, torna-se



com vetor de parâmetros correspondente

$$\theta = [a_1 \cdots a_{na} \ b_1 \cdots b_{nb} \ c_1 \cdots c_{nc}]'$$

MODELO ARMAX - ESTIMADOR

- Separando o ruído branco

$$\frac{A(q)}{C(q)}y[k] = \frac{B(q)}{C(q)}u[k] + e[k]$$

que leva ao estimador da forma

$$\hat{y}(k|\theta) + [C(q) - 1]\hat{y}(k|\theta) = B(q)u[k] + [C(q) - A(q)]y[k]$$

Portanto,

$$C(q)\hat{y}(k|\theta) = B(q)u[k] + [C(q) - A(q)]y[k]$$

(Estimador ou Preditor do modelo ARMAX)

MODELO ARMAX – REGRESSÃO PSEUDOLINEAR

- Podemos escrever a equação anterior como

$$\hat{y}(k|\theta) = B(q)u[k] + [1 - A(q)]y[k] + [C(q) - 1]\varepsilon(k, \theta)$$

com $\varepsilon(k, \theta) = y[k] - \hat{y}(k|\theta)$.

- Observe que para o **vetor de regressores**

$$\varphi(k) = \begin{bmatrix} -y[k-1] & \cdots & -y[k-na] & u[k-1] & \cdots \\ & & & u[k-nb] & \varepsilon(k-1, \theta) & \cdots & \varepsilon(k-nc, \theta) \end{bmatrix}' = \varphi(k, \theta)$$

teremos

$$\hat{y}(k|\theta) = \theta' \varphi(k, \theta) = \varphi(k, \theta)' \theta$$

(Regressão pseudolinear)

OUTROS MODELOS TIPO ERRO NA EQUAÇÃO

- Para uma maior flexibilidade do modelo, poderíamos adicionar outras funções de transferência ao ruído!

1 Adição de um modelo AR

$$A(q)y[k] = B(q)u[k] + \frac{1}{D(q)}e[k]$$

(Família de modelos ARARX)

2 Adição de um modelo ARMA

$$A(q)y[k] = B(q)u[k] + \frac{C(q)}{D(q)}e[k]$$

(Família de modelos ARARMAX)

OUTROS MODELOS TIPO ERRO NA EQUAÇÃO

- A família **ARARMAX** é o caso geral dentre os anteriores




FIGURA: Diagrama de blocos da família de modelos ARARMAX

Observe que todos são **filtrados por** $\frac{1}{A(q)}$.

MODELO ERRO NA SAÍDA

- Para tentar tirar a dependência de $A(q)$, vamos definir $z[k]$, uma saída livre de ruído definida como

$$z(k) + f_1 z(k-1) + \dots + f_{nf} z(k-nf) = b_1 u[k-1] + \dots + b_{nb} u[k-nb]$$

- Neste caso, no modelo ARX, chamando $F(q) = 1 + f_1 q^{-1} + \dots + f_{nf} q^{-nf}$

$$y[k] = z(k) + e[k] = \frac{B(q)}{F(q)} u[k] + e[k]$$

(Família de modelos Erro na Saída (OE))

MODELO ERRO NA SAÍDA

- Sua estrutura de blocos é




FIGURA: Diagrama de blocos da família de modelos OE

ESTRUTURA MAIS FÁCIL DE SER IDENTIFICADA, porém sem flexibilidade no sinal de erro!

MODELO ERRO NA EQUAÇÃO – ESTIMADOR

- O sinal $z[k]$ não pode ser fisicamente observado. Assim, por construção $z(k) = z(k, \theta)$, e escrevemos

$$z(k, \theta) + f_1 z(k-1, \theta) + \dots + f_{nf} z(k-nf, \theta) = b_1 u[k-1] + \dots + b_{nb} u[k-nb]$$

onde

$$\theta = [b_1 \ \dots \ b_{nb} \ f_1 \ \dots \ f_{nf}]'$$

- Um estimador para este sistema é

$$\hat{y}(k|\theta) = \frac{B(q)}{F(q)} u[k] = z(k, \theta)$$

(Estimador ou Preditor para o Modelo OE)

MODELO ERRO NA EQUAÇÃO – REGRESSÃO PSEUDOLINEAR

- Considerando

$$\varphi(k, \theta) = [u[k-1] \quad \cdots \quad u[k-nb] \quad -z(k-1, \theta) \quad \cdots \quad -z(k-nf, \theta)]'$$

teremos

$$\hat{y}(k|\theta) = \varphi(k, \theta)' \theta = \theta' \varphi(k, \theta)$$

$z(k-j, \theta)$ não pode ser observado, mas pode ser CALCULADO
como $z(k-j, \theta) = \hat{y}(k-j|\theta)$!

MODELO BOX-JENKINS

- A partir do modelo OE, adicionamos uma estrutura do tipo ARMA ao erro.

$$y[k] = \frac{B(q)}{F(q)} u[k] + \frac{C(q)}{D(q)} e[k]$$

(Família de modelos Box-Jenkins (BJ))

- Seu diagrama de blocos é dado por




FIGURA: Diagrama de blocos do modelo BJ

MODELO BOX-JENKINS – ESTIMADOR

Sua estrutura apresenta funções $G(q)$ e $H(q)$ independentes!

- Seu preditor natural é

$$\hat{y}(k|\theta) = \frac{D(q)B(q)}{C(q)F(q)}u[k] + \frac{C(q) - D(q)}{C(q)}y[k]$$

(Estimador ou Preditor do modelo (BJ))

- Seu preditor implica no método de **regressão pseudolinear**, com parâmetros

$$\theta = [b_1 \ \cdots \ b_{nb} \ c_1 \ \cdots \ c_{nc} \ d_1 \ \cdots \ d_{nd} \ f_1 \ \cdots \ f_{nf}]'$$

MODELO GERAL

- Outros modelos podem ser gerados a partir de escolhas particulares do polinômios $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$
- De uma forma geral

$$A(q)y[k] = \frac{B(q)}{F(q)}u[k] + \frac{C(q)}{D(q)}e[k]$$

- Este modelo permite facilmente inserir **DELAY** no caminho ENTRADA-SAÍDA, sendo $\bar{u}[k - nk + 1] = u[k]$

$$A(q)y[k] = q^{-nk} \frac{B(q)}{F(q)}u[k] + \frac{C(q)}{D(q)}e[k]$$

(Família Geral de Modelos)

MODELO GERAL – ESTIMADOR

- Para o caso sem atraso na equação, o preditor é

$$\hat{y}(k|\theta) = \frac{B(q)D(q)}{C(q)F(q)}u[k] + \left[1 - \frac{D(q)A(q)}{C(q)}\right]y[k]$$

(Preditor ou Estimador para o Modelo Geral)

MODELO GERAL – TABELA DE FAMÍLIAS

TABELA: Famílias de modelos derivadas da Estrutura Geral

Nome da Família	Operadores Utilizados
FIR	$B(q)$
ARX	$A(q), B(q)$
ARMAX	$A(q), B(q), C(q)$
ARMA	$A(q), C(q)$
ARARX	$A(q), B(q), D(q)$
ARARMAX	$A(q), B(q), C(q), D(q)$
OE	$B(q), F(q)$
BJ	$B(q), C(q), D(q), F(q)$

MODELO GERAL – REGRESSÃO PSEUDOLINEAR

- Podemos reescrever o Preditor para o Modelo Geral como

$$\hat{y}(k|\theta) = B(q)D(q)u[k] + [1 - C(q)F(q)]\hat{y}(k|\theta) + F(q)[C(q) - A(q)D(q)]y[k]$$

que nos permite escrever

$$\hat{y}(k|\theta) = B(q)D(q)u[k] + [C(q)F(q) - 1]\varepsilon(k, \theta) + [1 - F(q)A(q)D(q)]y[k]$$

onde $\varepsilon(k, \theta) = y[k] - \hat{y}(k|\theta)$.

- De forma equivalente,

$$\varepsilon(k, \theta) = \frac{D(q)}{C(q)} \underbrace{\left[A(q)y[k] - \overbrace{\frac{B(q)}{F(q)}u[k]}^{z(k, \theta)} \right]}_{v(k, \theta)}$$

MODELO GERAL – REGRESSÃO PSEUDOLINEAR

- Consequentemente, temos

$$\varepsilon(k, \theta) = y[k] - \hat{y}(k|\theta) = \frac{D(q)}{C(q)} v(k, \theta)$$

$$v(k, \theta) = A(q)y[k] - z(k, \theta)$$

$$z(k, \theta) = \frac{B(q)}{F(q)} u[k]$$

- Reescrevendo

$$z(k, \theta) = b_1 u[k-1] + \dots + b_{nb} u[k-nb] - f_1 z(k-1, \theta) - \dots - f_{nf} z(k-nf, \theta)$$

$$v(k, \theta) = y[k] + a_1 y[k-1] + \dots + a_{na} y[k-na] - z(k, \theta)$$

$$\varepsilon(k, \theta) = v(k, \theta) + d_1 v(k-1, \theta) + \dots + d_{nd} v(k-nd, \theta) - c_1 \varepsilon(k-1, \theta) - \dots - c_{nc} \varepsilon(k-nc, \theta)$$

MODELO GERAL – REGRESSÃO PSEUDOLINEAR

- Assim,

$$y[k] - \hat{y}(k, \theta) = d_1 v(k-1, \theta) + \dots + d_{nd} v(k-nd, \theta) - c_1 \varepsilon(k-1, \theta) - \dots - c_{nc} \varepsilon(k-nc, \theta) + v(k, \theta)$$

$$v(k, \theta) = y[k] + a_1 y[k-1] + \dots + a_{na} y[k-na] - z(k, \theta)$$

$$z(k, \theta) = b_1 u[k-1] + \dots + b_{nb} u[k-nb] - f_1 z(k-1, \theta) - \dots - f_{nf} z(k-nf, \theta)$$

- Reorganizando a expressão

$$\hat{y}(k, \theta) = \theta' \varphi(k, \theta) = \varphi(k, \theta)' \theta$$

em que

$$\theta = [a_1 \quad \dots \quad a_{na} \quad b_1 \quad \dots \quad b_{nb} \quad f_1 \quad \dots \quad f_{nf} \quad c_1 \quad \dots \quad c_{nc} \quad d_1 \quad \dots \quad d_{nd}]'$$

$$\varphi = [-y[k-1] \quad \dots \quad y[k-na] \quad u[k-1] \quad \dots \quad u[k-nb] \quad -z(k-1, \theta) \quad \dots \quad -z(k-nf, \theta) \quad \varepsilon(k-1, \theta) \quad \dots \quad \varepsilon(k-nc, \theta) \quad -v(k-1, \theta) \quad \dots \quad -v(k-nd, \theta)]'$$