

# FUNDAMENTOS DA ESTIMAÇÃO PARAMÉTRICA

**GABRIELA W GABRIEL**

IEE-S / ITA – Sala 195 – Ramal 5991

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

São José dos Campos, 11 de Maio de 2021

# CONTEÚDO

- 1 INTRODUÇÃO
- 2 PRINCIPAIS MÉTODOS DE ESTIMAÇÃO
- 3 PROPRIEDADES DOS ESTIMADORES
- 4 PRINCÍPIO DA ORTOGONALIDADE

## DEFINIÇÃO DO PROBLEMA

- Técnicas de estimação de **parâmetros ESTÁTICOS**, posteriormente estendido para estimação de **parâmetros DINÂMICOS** no tempo.
- Vamos considerar a forma geral na forma de **Regressão Pseudolinear**

$$y[k] = \varphi(k, \theta)' \theta + w[k]$$

$\theta$  é o vetor de parâmetros desconhecidos  
em que,  $\varphi$  é o vetor dos regressores referente a  $k$  medidas conhecidas  
 $w[k]$  é um ruído que corrompe a leitura de  $\varphi' \theta$

## DEFINIÇÃO DO PROBLEMA

- Consideremos um conjunto de  $k$  medidas  $y[j], u[j], j = 1, 2, \dots, k$  do parâmetro  $\theta$  na presença do ruído de medida  $w[\cdot]$ , representado por  $\varphi^k \triangleq \{y[j], u[j]\}_{j=1}^k$  (**conhecido**)
- Nosso objetivo é

Encontrar uma função destas  $k$  observações do parâmetro  $\theta$  do tipo

$$\hat{\theta}_k = \hat{\theta}(k, \varphi^k)$$

e que **ESTIME** o valor de  $\theta$  segundo algum critério preestabelecido.

- Para isso, definiremos o **erro da estimação** realizada como

$$\tilde{\theta} \triangleq \theta - \hat{\theta}$$

## DEFINIÇÃO DO PROBLEMA

- Os **MÉTODOS DE ESTIMAÇÃO PARAMÉTRICA** corresponde ao mapeamento  $\varphi^k \rightarrow \hat{\theta}$
- Como escolhemos o **melhor** estimador? Dentre **quais** métodos?
- Para isso, precisamos entender duas possíveis abordagens:
  - $\theta$  é **determinístico**. Há UM ÚNICO valor verdadeiro
  - $\theta$  é uma **variável aleatória**. Sua p.d.f é CONHECIDA E CONSTANTE durante as medições

## PARÂMETROS DETERMINÍSTICOS

- Conhecida como abordagem não bayesiana (abordagem de Fisher)
- Nesta abordagem definimos uma **função de verossimilhança**  $\Lambda_y(\theta)$ .

### **DEFINIÇÃO V.1**

A **função de verossimilhança** corresponde a *p.d.f* das medidas de  $\theta$  condicionadas a  $\theta$ .

$$\Lambda_y(\theta) \triangleq f_{y|\theta}(\beta|\alpha)$$

- Observe que, neste caso, não há conhecimento prévio da estatística do parâmetro

## PARÂMETRO ESTOCÁSTICO

- Conhecida como abordagem bayesiana
- Temos **conhecimento a priori** de  $f_{\theta}(\alpha)$ , que permanece o mesmo durante todo o processo de medição.
- Dado um conjunto de  $k$  (fixo) medidas com  $f_y(\beta) = c$ , seguindo a fórmula de Bayes, dado  $(f_{y|\theta}(\beta|\alpha))$ , determinamos a **densidade a posteriori** conforme

$$f_{\theta|y}(\alpha|\beta) = \frac{f_{y|\theta}(\beta|\alpha)f_{\theta}(\alpha)}{c}$$

$c$  também é dita constante de normalização.

## MÉTODOS DE ESTIMAÇÃO

Escolhida uma **FAMÍLIA DE MODELOS**



**Objetivo:**

**Encontrar uma estimativa coerente para o vetor  $\theta$ .**

- Diferentes modelos geram diferentes erros de predição



- Escolha do modelo baseada no **ERRO DE PREDIÇÃO**

$$\varepsilon(k, x) = y[k] - \hat{y}(k, x)$$

segundo algum critério estocástico, dado  $\varphi^k = [y[1] \cdots y[k] \cdots u[k] \cdots]$ .

## MÉTODOS DE ESTIMAÇÃO

- Vamos considerar a família de modelos genérica

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

- Seu preditor associado corresponde a

$$\hat{y}(k|\theta) = \underbrace{W_y(q, \theta)}_{[1-H^{-1}(q, \theta)]} y[k] + \underbrace{W_u(q, \theta)}_{H^{-1}(q, \theta)G(q, \theta)} u[k]$$

**Exercício:** Reescrever o sistema

$$\begin{aligned} x_{k+1} &= Ax_k + Bu_k \\ y_k &= Cx_k + Du_k + \nu_k \end{aligned}$$

na representação padrão e indicar a qual família de modelos pertence.

# MÉTODOS DE ESTIMAÇÃO

## NOTAÇÃO DE ESTIMADORES

- ▶ Aqui,  $\hat{x}_k$  denota a estimativa de  $x$  dadas  $k$  observações
- ▶ Para um conjunto de  $k$  observações de  $x$ , denotamos por

$$\hat{x}(Y) \triangleq \hat{x}(k, Y^k) \triangleq \hat{x}(k, \varphi^k)$$

- ▶ Faremos ainda a simplificação

$$f_{x|y}(\alpha|\beta) = f_{x|y}(x|y) \text{ denotada apenas por } f_{x|y}$$

Analogamente para as p.d.f. marginais.

**NOTA:**  $x$  é o parâmetro a ser estimado,  $y_j$ , a medida realizada no instante  $j$  e  $w_j$ , o ruído de medida que incide sobre a  $j$ -ésima leitura.

## MÁXIMA VEROSSIMILHANÇA

- Estimador de máxima verossimilhança (ML – *Maximum Likelihood*)
- Método **não bayesiano** com estimador

$$\hat{x}^{\text{ML}}(Y) = \arg \max_x \Lambda_Y(x) = \arg \max_x f_{y|x}$$

- Há **um único** valor verdadeiro  $x = x_0$
- $\hat{x}^{\text{ML}}(Y)$  é um vetor de medidas (**aleatório**) dada a presença de  $w[\cdot]$ , obtido segundo

$$\frac{d\Lambda_Y(x)}{dx} = \frac{df_{y|x}}{dx} = 0$$

## MÁXIMO A POSTERIORI

- Estimador de máximo a posteriori (MAP – *Maximum A Posteriori*)
- Método **bayesiano**, pressupõe que  $x$  é uma v.a. e sua estimativa é obtida a partir da p.d.f. a posteriori

$$\hat{x}^{\text{MAP}}(Y) = \arg \max_x f_{x|y} = \arg \max_x \left[ \frac{f_{y|x} f_x}{f_y} \right]$$

onde  $f_y \neq 0$ .

- Tanto o parâmetro  $x$  quanto sua estimativa  $\hat{x}$  são v.a.

## EXERCÍCIOS

- 1 Obtenha o melhor estimador  $\hat{x}^{\text{ML}}$  para um parâmetro  $x$ , dado que o ruído que entra no sistema é  $w \sim \mathcal{N}(0, \sigma^2)$ , e sua medida descrita por

$$y = x + w$$

- 2 Vamos considerar agora que temos  $k$  medidas realizadas do parâmetro  $x$ , e portanto

$$y[j] = x + w[j], \quad j = 1, 2, \dots, k$$

sendo os ruídos conhecidos com  $w[j] \sim \mathcal{N}(0, \sigma^2)$ , para todo  $j$ . Calcule o melhor estimador  $\hat{x}^{\text{ML}}$  nesta nova situação.

- 3 Por fim, obtenha o melhor estimador  $\hat{x}^{\text{MAP}}$  de  $x \sim \mathcal{N}(\bar{x}, \sigma_x^2)$ , para um experimento descrito conforme

$$y = x + w, \quad w \sim \mathcal{N}(0, \sigma^2)$$

- 4 Estimar (utilizando o estimador ML, o valor de um parâmetro  $x$  a partir de um conjunto de  $k$  medidas  $y_i$ ,  $i = 1, 2, \dots, k$ , sendo sua média nula e variância também desconhecida.

## MÍNIMOS QUADRADOS

- Estimador dos mínimos quadrados (LS – *Least Squares*) é outro método **não bayesiano**
- Dado um conjunto de medidas  $y_j = h(j, x) + w_j$  com  $j = 1, 2, \dots, k$ , a estimativa de  $x$  é tal que

$$\hat{x}^{\text{LS}}(Y) = \arg \min_x \left\{ \sum_{j=1}^k [y_j - h(j, x)]^2 \right\}$$

- $y$  é uma função não linear de  $x$  através de  $h(j, x)$
- Não há hipótese sobre o ruído  $w$ . Para  $w$  gaussiano, o estimador LS corresponde ao estimador ML.

## MÍNIMO ERRO QUADRÁTICO MÉDIO

- Estimador do mínimo erro quadrático médio (MMSE – *Minimum Mean Square Error*)
- Contrapartida aleatória do estimador dos mínimos quadrados, ou seja,  $x$  é uma v.a. com p.d.f. conhecida a priori
- Estimador calculado conforme

$$\hat{x}^{\text{MMSE}}(Y) = \mathcal{E}(x|Y) \triangleq \int_{-\infty}^{\infty} xf_{x|y} dx$$

que é a solução de

$$\hat{x}^{\text{MMSE}}(Y) = \arg \min_{\hat{x}} \mathcal{E}((\hat{x} - x)^2|Y)$$

- A estimativa MMSE será uma v.a. em decorrência de  $x$  e  $w$  serem v.a.

## POLARIZAÇÃO DE ESTIMADORES

- **BIAS** é um valor persistente que distancia a estimativa do valor verdadeiro de um parâmetro.

### DEFINIÇÃO V.1

Um estimador é dito **Não Polarizado (unbiased)** se o erro de estimativa possui média nula, ou seja,

$$\mathcal{E}(\tilde{x}) = 0, \quad \tilde{x} \triangleq x - \hat{x}$$

- Interpretações:

- Abordagem **não bayesianas**

$$\mathcal{E}(\hat{x}(Y)) = x_0$$

onde  $x_0$  é o valor verdadeiro do parâmetro  $x$ .

- Abordagem **bayesianas**.

$$\mathcal{E}(\hat{x}(Y)) = \mathcal{E}(x)$$

sendo  $f_x$  conhecida a priori e  $f_{x|y}$  calculada.

## POLARIZAÇÃO DE ESTIMADORES

### **DEFINIÇÃO V.2**

Um estimador é dito (simplesmente) **NÃO POLARIZADO** se a Definição V.1 é válida para todo  $k$ .

### **DEFINIÇÃO V.3**

Um estimador é dito **ASSINTOTICAMENTE NÃO POLARIZADO** se a Definição V.1 é válida para  $k \rightarrow \infty$ .

## VARIÂNCIA E ERRO QUADRÁTICO MÉDIO DE UM ESTIMADOR

### **DEFINIÇÃO V.4**

A **variância (covariância) de um estimador** é definida como

$$\text{var}(\hat{x}) \triangleq \mathcal{E}([\hat{x}(Y) - \mathcal{E}(\hat{x}(Y))]^2)$$

$$\text{cov}(\hat{x}) \triangleq \mathcal{E}([\hat{x}(Y) - \mathcal{E}(\hat{x}(Y))] [\hat{x}(Y) - \mathcal{E}(\hat{x}(Y))]')$$

### **DEFINIÇÃO V.5**

O **erro quadrático médio (MSE)** definido, para o caso escalar, como

$$\text{MSE}(\hat{x}(Y)) = \mathcal{E}(\tilde{x}^2)$$

onde  $\tilde{x} \triangleq x - \hat{x}$ , ou para o caso vetorial

$$\text{MSE}(\hat{x}(Y)) = \mathcal{E}(\tilde{x}\tilde{x}')$$

## VARIÂNCIA E ERRO QUADRÁTICO MÉDIO DE UM ESTIMADOR

- ▶ O  $MSE(\hat{x})$  indica a dispersão do estimador em torno do valor verdadeiro do parâmetro  $x$  enquanto a  $cov(\hat{x})$  é utilizada para avaliar sua convergência para o valor médio.
- ▶ Para o caso de estimador **unbiased**, temos que  $\mathcal{E}(\hat{x}(Y)) = x$ .

- Se  $x$  for ainda NÃO BAYESIANO

$$\begin{aligned} MSE(\hat{x}(Y)) &= \mathcal{E}(\tilde{x}^2) = \mathcal{E}([\hat{x}(Y) - x_0]^2) = \mathcal{E}([\hat{x}(Y) - \mathcal{E}(\hat{x}(Y))]^2) \\ &= \text{var}(\hat{x}(Y)) \end{aligned}$$

- Se  $x$  for BAYESIANO

$$\begin{aligned} MSE(\hat{x}(Y)) &\triangleq \mathcal{E}([\hat{x}(Y) - x]^2) = \mathcal{E}(\mathcal{E}([\hat{x}(Y) - x]^2 | Y)) \\ &= \mathcal{E}(MSE(\hat{x}(Y) | Y)) \end{aligned}$$

$\mathcal{E}(MSE(\hat{x}(Y) | Y))$  é o **erro médio quadrático condicional**.

## DESvio PADRÃO DE UM ESTIMADOR

### **DEFINIÇÃO V.6**

O desvio padrão de um estimador é dado por

$$\sigma_{\hat{x}(y)} = \sqrt{\text{var}(\hat{x}(y))}$$

## CONSISTÊNCIA DE UM ESTIMADOR

### **DEFINIÇÃO V.6**

Um estimador é dito **consistente** se a estimativa convergir para o valor verdadeiro em algum sentido estocástico.

- ▶ Equivale a exigir que o erro de estimação convirja para zero, sob algum sentido estocástico

- ▶ Calculamos

- Para o caso não bayesiano

$$\lim_{k \rightarrow \infty} \mathcal{E} \left( (\hat{x}(k, Y^k) - x_0)^2 \right)$$

- Para o caso bayesiano,

$$\lim_{k \rightarrow \infty} \mathcal{E} \left( (\hat{x}(k, Y^k) - x)^2 \right)$$

- ▶ Nos dois casos acima, se  $\lim_{k \rightarrow \infty} \mathcal{E}(\tilde{x}^2) = 0$  o estimador será consistente.

## LIMITANTE INFERIOR DE CRAMER-RAO E INFORMAÇÃO DE FISHER

- ▶  $\Lambda(x) = f_{y|x}$ , por construção, pode ser entendida como a quantidade de informação que temos a priori a respeito de um determinado parâmetro a ser estimado
- ▶ O funcional  $J$ , associado a  $\Lambda(x)$ , quantifica esta informação, a Informação de Fisher.

### **DEFINIÇÃO V.7**

A **Informação de FISHER**, para o caso escalar, é

$$J \triangleq -\mathcal{E} \left( \frac{\partial^2 \ln f_{y|x}}{\partial x^2} \right)_{x=x_0} = \mathcal{E} \left( \left[ \frac{\partial \ln f_{y|x}}{\partial x} \right]^2 \right)_{x=x_0}$$

em que  $x_0$  é o valor verdadeiro do parâmetro  $x$ . Para o caso vetorial,

$$J \triangleq -\mathcal{E} \left( \nabla_x \nabla'_x \ln f_{y|x} \right)_{x=x_0}$$

conhecida como **Matriz de Informação de Fisher (FIM)**.

## DESIGUALDADE DE CRAMER-RAO

- ▶ O valor verdadeiro do parâmetro  $x_0$  não é conhecido, portanto, o valor exato de  $J$ , também não será conhecido
- ▶ A quantidade de informação disponível corresponde a quantidade de informação extraída pelo Estimador de Máxima Verossimilhança (ML)

### TEOREMA V.1

*A estimativa de um parâmetro escalar  $x$  dado um estimador unbiased  $\hat{x}(Y)$  tem sua variância limitada de acordo com*

$$\mathcal{E} \left( [\hat{x}(Y) - x_0]^2 \right) \geq J^{-1}$$

*em que  $x_0$  é o valor verdadeiro do parâmetro  $x$ , a função densidade de probabilidade de  $Y^k$  é  $f_y(x_0, Y^k)$  e suas derivadas de primeira e segunda ordem existem. Esta desigualdade é conhecida como **Desigualdade de Cramer-Rao** ou (CRLB).*

## EFICIÊNCIA DE UM ESTIMADOR

- ▶ A eficiência dos estimadores é uma medida da quantidade de informação que pode ser extraída de um parâmetro

### **DEFINIÇÃO V.8**

*Um estimador é dito **eficiente** se sua VARIÂNCIA é igual ao limítante inferior de Cramer-Rao ( $J^{-1}$ ).*

- ▶ um estimador é então eficiente se a quantidade de informação que ele pode extrair é igual a quantidade de informação existente.

## MELHOR ESTIMADOR

- ▶ Buscamos o **MELHOR ESTIMADOR** segundo algum critério pré-definido.
  - Simplicidade
  - Requeira a menor quantidade de informação a priori



- △ Funções lineares
- △ Estimadores não polarizados (*unbiased*)
- △ Erro de estimação descorrelacionado da medida/observação
- △ **Princípio da ortogonalidade**

## MELHOR ESTIMADOR

- ▶ Critério que minimiza o erro (quadrático) de estimação **MMSE**
- ▶ Problema

$$\min_{\hat{x}} \mathcal{E} ([x - \hat{x}]^2 | Y)$$

com  $\hat{x}$  obtido a partir do conjunto de medidas  $Y^k$

## ESTIMADORES LINEARES

- ▶ Supondo relação **linear** de  $\hat{x}$  com as medidas  $Y^k$

$$\hat{x} = \sum_{j=1}^k \alpha_j y_j$$

onde  $\alpha_j > 0$  são coeficientes normalizados tais que  $\sum_{j=1}^k \alpha_j = 1$

- ▶ Substituindo o  $\hat{x}$  na expressão anterior
  - Problema linear de fácil solução
  - Solução independe das funções densidade de probabilidades

## ESTIMADORES LINEARES

- ▶  $y_i, i = 1, 2, \dots, k$ , escalares (ou vetores), v.a. com médias nulas e reais,  $y_i$  definido no espaço vetorial de Hilbert
- ▶ Espaço fechado em relação a soma e a multiplicação, com norma  $\langle y_i, y_i \rangle = \mathcal{E}(y_i^2) = \|y_i\|^2$ , sendo

$$\langle y_i, y_k \rangle = \mathcal{E}(y_i y_k)$$

Da álgebra linear, dois vetores são ortogonais ( $y_i \perp y_k$ ) se e somente se  $\langle y_i, y_k \rangle = 0$



$$\langle y_i, y_k \rangle = \mathcal{E}(y_i y_k) = 0$$



$y_i$  e  $y_k$  são **descorrelacionadas**, uma vez que possuem média nula

## ESTIMADORES LINEARES

- Considere um **estimador linear** de  $x$

Encontrar  $\hat{x}$  a partir da minimização de

$$\|\tilde{x}\|^2 = \mathcal{E}([x - \hat{x}]^2)$$



$$\mathcal{E}\left(-2xy_i + 2y_i \sum_{j=1}^k \alpha_j y_j\right) = 0 \implies \mathcal{E}\left(\left(x - \sum_{j=1}^k \alpha_j y_j\right) y_i\right) = 0$$



$$\langle \tilde{x}, y_i \rangle = 0, \quad \forall i = 1, 2, \dots, k$$

## PRINCÍPIO DA ORTOGONALIDADE

- ▶ De  $\langle \tilde{x}, y_i \rangle = 0$  temos  $\tilde{x} \perp y_i, i = 1, 2, \dots, k$ .

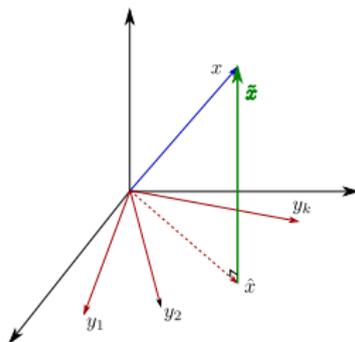
O melhor (MMSE) estimador linear de um parâmetro  $x$  é aquele cujo erro é ortogonal ao conjunto de medidas  $y_i, i = 1, 2, \dots, k$ .

## PRINCÍPIO DA ORTOGONALIDADE

### **PRINCÍPIO DA ORTOGONALIDADE**

*Para que um estimador tenha **NORMA MÍNIMA** seu erro deve ser **ORTOGONAL** às observações.*

**OBSERVAÇÃO** : O estimador ótimo  $\hat{x}$ , dado um conjunto de medidas  $Y^k$  de  $x$ , é a projeção ortogonal de  $x$  no espaço gerado pelo conjunto de  $k$  medidas  $y$



## ESTIMADORES LINEARES – CONSIDERAÇÕES

- ▶ Para uma v.a.  $x$ , o melhor estimador linear, no caso geral, será

$$\hat{x} = \beta_0 + \sum_{j=1}^k \beta_j y_j$$

- ▶ O erro médio quadrático (MSE) será

$$\mathcal{E}(\tilde{x}^2) = \text{var}(\tilde{x}) - \mathcal{E}(\tilde{x})^2$$

- ▶ Condições para determinar  $\hat{x}$ :
  - Estimador não polarizado  $\mathcal{E}(\tilde{x}) = \mathcal{E}(x - \hat{x}) = 0$
  - Estimador MMSE sendo,  $\text{MSE} = \mathcal{E}(\tilde{x}^2)$