

Teoria da Estimação

Obter o melhor estimador de um parâmetro ou mais parâmetros desconhecidos a partir de um conjunto de observações de um processo estocástico relacionado ao parâmetro desconhecido.

Conjunto de amostras: $\underline{x} = [x(0) \dots x(N-1)]^T$

Parâmetros desconhecidos: $\underline{\theta} = [\theta(0) \dots \theta(L-1)]^T$

Estimador:

$$\hat{\underline{\theta}} = \varphi \{ x(0) \dots x(N-1) \} = \varphi \{ \underline{x} \}$$

Como \underline{x} é um processo aleatório, o estimador é uma variável aleatória.

Desafio: determinar o conjunto de funções $\varphi \{ \cdot \}$ que proporciona a melhor estimativa de $\underline{\theta}$.

Propriedades dos Estimadores:

1) Polarizações (Bias)

Um estimador é dito não-polarizado se

$$E\{\hat{\underline{\theta}}\} = E\{\underline{\theta}\}$$

Sí $\underline{\theta}$ é determinístico, $E\{\hat{\underline{\theta}}\} = \underline{\theta}$

$$\text{Bias}(\hat{\underline{\theta}}) = E\{\hat{\underline{\theta}}\} - E\{\underline{\theta}\}$$

2) Eficiência:

No caso escalar, um estimador $\hat{\theta}$ é mais eficiente que um estimador $\tilde{\theta}$, considerando que ambos não sejam polarizados, se $\text{Var}(\hat{\theta}) \leq \text{Var}(\tilde{\theta})$.

No caso de múltiplos parâmetros, a condição é dada por

$$C_{\hat{\theta}}(\hat{\theta}) \leq C_{\tilde{\theta}}(\tilde{\theta}) \quad (C_{\tilde{\theta}}(\tilde{\theta}) - C_{\hat{\theta}}(\hat{\theta}) \text{ é simétrica e positiva})$$

onde $C_x = E\{(x - E[x])(x - E[x])^T\}$ é a matriz de covariâncias de x .

No contexto de estimadores não polarizados, é possível estabelecer um limite inferior de desempenho, o chamado limite de Cramér-Rao (Cramér-Rao Bound CRB)

$$\text{Var}(\hat{\theta}) \geq F^{-1}(\theta) \quad (\text{escalar})$$

ou

$$C(\hat{\theta}) \geq F^{-1}(\theta) \quad (\text{vetorial})$$

F é a matriz de informações de Fisher.

Exemplo: Constante main m\'ido aditivo gaussiano.

$$x(n) = \theta + \eta(n)$$

$$\eta(n) \sim N(0, \sigma^2)$$

$$\underline{x} = [x(0) \dots x(N-1)]^\top$$

Dois possíveis estimadores:

$$\tilde{\theta} = x(0)$$

$$\hat{\theta} = \frac{1}{N} \sum_{n=0}^{N-1} x(n)$$

Polarizações:

$$E\{\tilde{\theta}\} = E\{x(0)\} = \theta$$

$$E\{\hat{\theta}\} = E\left\{\frac{1}{N} \sum_{n=0}^{N-1} x(n)\right\} = \frac{1}{N} \sum_{n=0}^{N-1} E\{x(n)\} = \frac{1}{N}(N\theta) = \theta$$

Eficiência:

$$\text{Var}(\tilde{\theta}) = \text{Var}(x(0)) = \sigma^2$$

$$\text{Var}(\hat{\theta}) = \text{Var}\left(\frac{1}{N} \sum_{n=0}^{N-1} x(n)\right) = \frac{1}{N^2} \sum_{n=0}^{N-1} \text{Var}(x(n)) = \frac{1}{N^2}(N\sigma^2) = \frac{\sigma^2}{N}$$

∴ O estimador de média amostral é mais eficiente
se $N > 1$

Podemos apontar duas famílias principais de métodos de estimação:

1º Caso: θ é um vetor de parâmetros constantes e desconhecidos.

- Não há informações estatísticas sobre θ
- Principal representante: estimador de máxima verossimilhança (Maximum Likelihood, ML)

$$\hat{\theta}_{ML} = \arg \max_{\theta} f_X(x|\theta) \rightarrow \left\{ \begin{array}{l} \text{Para um conjunto de observações } \underline{x}, \\ \text{buscamos os parâmetros } \theta \text{ que} \\ \text{levam à maior probabilidade } f_X(x|\theta) \\ \text{com a qual os dados foram gerados.} \end{array} \right.$$

$$\hat{\theta}_{ML} = \arg \max_{\theta} [\ln(f_X(x|\theta))]$$

$$\text{Solução: } \frac{\partial}{\partial \theta} \ln[f_X(x|\theta)] = 0$$

Frequentemente, o problema tem natureza não linear e apresenta mais do que uma solução. Nesse caso, $\hat{\theta}_{ML}$ é o máximo global.

O estimador ML é assintoticamente eficiente, isto é,

$$\text{Var}(\hat{\theta}) = \text{CRB} \quad \text{qdo } N \rightarrow \infty$$

Exemplo: Constante mais ruído WGN

$$x(n) = \theta + \eta(n) \quad n=0, 1, \dots N-1 \quad \eta(n) \sim N(0, \sigma^2)$$

$$f_{X|\Theta}(x(n)|\theta) = f_\eta(x(n)-\theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{1}{2\sigma^2}(x(n)-\theta)^2\right]$$

$$\begin{aligned} f_{X|\Theta}(x|\theta) &= \prod_{n=0}^{N-1} f_{X|\Theta}(x(n)|\theta) = \prod_{n=0}^{N-1} \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{1}{2\sigma^2}(x(n)-\theta)^2\right] \\ &= \frac{1}{(2\pi\sigma^2)^{N/2}} \cdot \exp\left[-\frac{1}{2\sigma^2} \sum_{n=0}^{N-1} (x(n)-\theta)^2\right] \end{aligned}$$

Aplicando o logaritmo natural e derivando,

$$\begin{aligned} \frac{\partial \ln[f_{X|\Theta}(x|\theta)]}{\partial \hat{\theta}} &= \frac{\partial}{\partial \hat{\theta}} \left[-\ln[(2\pi\sigma^2)^{N/2}] - \frac{1}{2\sigma^2} \sum_{n=0}^{N-1} (x(n)-\hat{\theta})^2 \right] \\ &= \frac{1}{\sigma^2} \sum_{n=0}^{N-1} (x(n)-\hat{\theta}) = \frac{N}{\sigma^2} (\bar{x} - \hat{\theta}) \end{aligned}$$

$$\bar{x} = \frac{1}{N} \sum_{n=0}^{N-1} x(n)$$

Igualando a derivada a 0:

$$\frac{N}{\sigma^2} (\bar{x} - \hat{\theta}) = 0 \Rightarrow \boxed{\hat{\theta} = \bar{x}}$$

2º caso : $\underline{\theta}$ é um vetor aleatório.

- É necessário um conhecimento estatístico sobre as V.A.s em $\underline{\theta}$: $f_{\underline{\theta}}(\underline{\theta})$

- Abordagem Bayesiana de estimadores.

Vamos dois representantes desta família de estimadores: MAP e MMSE

(1) Estimador de Máxima Probabilidade a Posteriori (MAP)

- Dado o conjunto de observações \underline{x} , buscamos o vetor de parâmetros $\underline{\theta}$ com a maior probabilidade $f_{\underline{\theta}|\underline{x}}(\underline{\theta}|\underline{x})$ de ter gerado o conjunto de amostras.

$$\hat{\underline{\theta}}_{MAP} = \arg \max_{\underline{\theta}} f_{\underline{\theta}|\underline{x}}(\underline{\theta}|\underline{x}) = \arg \max_{\underline{\theta}} f_{\underline{x}|\underline{\theta}}(\underline{x}|\underline{\theta}) \underbrace{f_{\underline{\theta}}(\underline{\theta})}_{\underline{\theta} \text{ uniforme}}$$

$$MAP = MLE$$


Solução obtida a partir de

$$\frac{\partial f_{\underline{x}|\underline{\theta}}(\underline{x}|\underline{\theta})}{\partial \underline{\theta}} = 0$$

Exemplo: constante + WGN

$$f(\theta|x) = \frac{f(x|\theta) f(\theta)}{f(x)} = \frac{f(x|\theta) f_\theta(\theta)}{\int_{-\infty}^{\infty} f(x|\theta) f(\theta) d\theta}$$

$$f_\theta(\theta) = \begin{cases} \frac{1}{2\theta_0}, & |\theta| \leq \theta_0 \\ 0, & |\theta| > \theta_0 \end{cases}$$



$$f(\theta|x) = \begin{cases} \frac{1}{2\theta_0(2\pi\sigma^2)^{N/2}} \exp\left[-\frac{1}{2\sigma^2} \sum_{n=0}^{N-1} (x(n) - \theta)^2\right], & |\theta| \leq \theta_0 \\ \int_{-\theta_0}^{\theta_0} \frac{1}{2\theta_0(2\pi\sigma^2)^{N/2}} \exp\left[-\frac{1}{2\sigma^2} \sum_{n=0}^{N-1} (x(n) - \theta)^2\right] d\theta, & |\theta| > \theta_0 \end{cases}$$

$$f(\theta|x) = \frac{1}{(2\pi\sigma^2)^{N/2}} \exp\left[-\frac{1}{2\sigma^2} \sum_{n=0}^{N-1} (x(n) - \bar{x})^2\right]$$


mas

$$\sum_{n=0}^{N-1} (x(n) - \theta)^2 = \sum_{n=0}^{N-1} x(n)^2 - 2N\bar{x}\bar{x} + N\bar{x}^2 = N(\bar{x} - \theta)^2 + \sum_{n=0}^{N-1} x(n)^2 - N\bar{x}^2$$


$$f(\theta|x) = \begin{cases} \frac{1}{C\sqrt{2\pi\frac{\sigma^2}{N}}} \exp\left[-\frac{1}{2\frac{\sigma^2}{N}} (\bar{x} - \theta)^2\right], & |\theta| \leq \theta_0 \\ 0, & |\theta| > \theta_0 \end{cases}$$

$$C = \int_{-\theta_0}^{\theta_0} \frac{1}{\sqrt{2\pi\frac{\sigma^2}{N}}} \exp\left[-\frac{1}{2\frac{\sigma^2}{N}} (\bar{x} - \theta)^2\right] d\theta$$


- $\bar{\theta}_0 \leq \bar{x} \leq \theta_0$:



- $\bar{x} > \theta_0$:



- $\bar{x} < -\theta_0$:



$$\hat{\theta}_{MAP} = \begin{cases} -\theta_0, & \bar{x} < -\theta_0 \\ \bar{x}, & -\theta_0 \leq \bar{x} \leq \theta_0 \\ \theta_0, & \bar{x} > \theta_0 \end{cases}$$

(2) Estimador de mínimo erro quadrático médio
(Minimum Mean-Squared Error, MMSE)

$$J_{\text{MSE}}(\underline{\theta}) = E \left\{ \| \underline{\theta} - \hat{\underline{\theta}} \|^2 \right\}$$

Como $\underline{\theta}$ é um vetor de V.A.s, o operador de esperança leva em conta a pd.f. conjunta $f_{X,\underline{\theta}}(\underline{x},\underline{\theta})$

$$\begin{aligned} J_{\text{MSE}}(\underline{\theta}) &= \iint \| \underline{\theta} - \hat{\underline{\theta}} \|^2 f_{X,\underline{\theta}}(\underline{x},\underline{\theta}) d\underline{x} d\underline{\theta} \\ &= \left\{ \iint \| \underline{\theta} - \hat{\underline{\theta}} \|^2 f_{\underline{\theta}|X}(\underline{\theta}|\underline{x}) d\underline{\theta} \right\} f_X(\underline{x}) d\underline{x} \end{aligned}$$

Como $f_X(\underline{x}) \geq 0$, $J_{\text{MSE}}(\underline{\theta})$ só minimizado se o termo entre $\{ \cdot \}$ for minimizado para cada valor de \underline{x} :

$$\frac{\partial}{\partial \hat{\theta}} \int \| \underline{\theta} - \hat{\underline{\theta}} \|^2 f_{\underline{\theta}|X}(\underline{\theta}|\underline{x}) d\underline{\theta} = -2 \int \underline{\theta} f_{\underline{\theta}|X}(\underline{\theta}|\underline{x}) d\underline{\theta} + 2\hat{\theta} \underbrace{\int f_{\underline{\theta}|X}(\underline{\theta}|\underline{x}) d\underline{\theta}}_{=1}$$

Igualando a derivada a zero, temos:

$$\hat{\theta}_{\text{MSE}} = \int_{-\infty}^{\infty} \underline{\theta} \cdot f_{\underline{\theta}|X}(\underline{\theta}|\underline{x}) d\underline{\theta} = E\{\underline{\theta}|\underline{x}\}$$

Em geral, o estimador MMSE tem natureza não-linear e é difícil obtê-lo.

Alternativa: supor que $\hat{\underline{\theta}}$ é função linear das observações \rightarrow Filtagem linear ótima

Exemplo :

$$\hat{\theta}_{\text{MMSE}} = E\{\theta | \underline{x}\}$$

$$= \int_{-\infty}^{\infty} \theta f(\theta | \underline{x}) d\theta$$

$$= \frac{\int_{-\Theta_0}^{\Theta_0} \theta \cdot \frac{1}{\sqrt{2\pi\frac{\sigma^2}{N}}} \exp\left[-\frac{1}{2\frac{\sigma^2}{N}} (\theta - \bar{x})^2\right] d\theta}{\int_{-\Theta_0}^{\Theta_0} \frac{1}{\sqrt{2\pi\frac{\sigma^2}{N}}} \exp\left[-\frac{1}{2\frac{\sigma^2}{N}} (\theta - \bar{x})^2\right] d\theta}$$

