

# Capítulo 2

## Fundamentos da Teoria de Estimação

### 2.1 Introdução

Estimação é a determinação de grandezas físicas não observáveis a partir de grandezas mensuráveis. A teoria de estimação compreende basicamente duas classes de problemas, a saber:

- a) Identificação Experimental: A identificação de um Modelo de um sistema através de medidas das suas entradas e saídas, também denominada de modelagem “caixa preta”.
- b) Filtragem: A determinação dos Estados de um sistema a partir de medidas das suas entradas e saídas.

Nesse capítulo serão apresentados métodos para a estimação de parâmetros de um sistema linear monovariável utilizando dados medidos da sua entrada e saída. A estimação de estados será apresentada em outro capítulo. Assume-se conhecida *a priori* a ordem do modelo. Nesse contexto, considera-se a estimação de parâmetros de um modelo linear de tempo discreto descrito pela equação (2.1). O ítem sobre filtragem será desenvolvido no capítulo 5.

$$y_k = \mathbf{u}_k^T \boldsymbol{\theta} + v_k \quad (2.1)$$

Na equação (2.1)  $\boldsymbol{\theta} \in \Re^n$  é o vetor de parâmetros desconhecidos,  $y_k$  é a saída medida no instante  $k$ ,  $\mathbf{u}_k^T$  é um vetor com elementos conhecidos (mensuráveis), normalmente a entrada do sistema, e  $v_k$  é uma perturbação atuando no processo. O modelo anterior pode ser também escrito como:

$$y_k = \theta_0 u_k + \theta_1 u_{k-1} + \dots + \theta_{m-1} u_{k-m+1} + v_k \quad (2.2)$$

ou

$$y_k = \sum_{i=0}^{m-1} \theta_i u_{k-i} + v_k$$

ou ainda

$$y_k = \mathbf{u}_k^T \boldsymbol{\theta} + v_k \quad (2.3)$$

com

$$\mathbf{u}_k^T = [ u_k \quad u_{k-1} \quad \dots \quad u_{k-m+1} ]$$

$$\boldsymbol{\theta}^T = [ \theta_0 \quad \theta_1 \quad \dots \quad \theta_{m-1} ]$$

Nesta equação deve-se obter um estimador  $\hat{\boldsymbol{\theta}}$  dos parâmetros desconhecidos  $\boldsymbol{\theta}$  a partir das medidas realizadas. Para tanto, vamos supor que sejam realizadas  $N$  medidas, conforme descrito a seguir:

$$\begin{aligned} y_1 &= \mathbf{u}_1^T \boldsymbol{\theta} + v_1 \\ y_2 &= \mathbf{u}_2^T \boldsymbol{\theta} + v_2 \\ &\vdots \\ y_N &= \mathbf{u}_N^T \boldsymbol{\theta} + v_N \end{aligned}$$

$$\mathbf{y} = U \boldsymbol{\theta} + \mathbf{v}$$

$$\mathbf{y}^T = [ y_1 \quad y_2 \quad \dots \quad y_N ]$$

$$\mathbf{v}^T = [ v_1 \quad v_2 \quad \cdots \quad v_N ]$$

$$U = \begin{bmatrix} u_1^T \\ u_2^T \\ \vdots \\ u_N^T \end{bmatrix}$$

## 2.2 Método dos Mínimos Quadrados

Este método foi tratado de forma independente por Gauss e Legendre e é um dos métodos mais conhecidos e utilizados nas diversas áreas do conhecimento. Gauss, durante observações astronômicas, afirmou que:

*“O valor mais provável de grandezas desconhecidas é o que minimiza a soma dos quadrados da diferença entre o valor medido e o valor calculado, ponderado pelo grau de precisão da medida”.*

Seja  $\hat{\boldsymbol{\theta}}$  o valor estimado de  $\boldsymbol{\theta}$  e  $\hat{\mathbf{y}}$  a saída estimada do sistema, dada por:

$$\hat{\mathbf{y}} = U\hat{\boldsymbol{\theta}} \quad (2.4)$$

Sejam os erros entre os vetores de parâmetros desconhecidos e estimados e entre a saída do sistema e a saída do modelo definidos respectivamente por  $\tilde{\boldsymbol{\theta}} = \boldsymbol{\theta} - \hat{\boldsymbol{\theta}}$  e  $\tilde{\mathbf{y}} = \mathbf{y} - \hat{\mathbf{y}}$ . Logo, tem-se que:

$$\tilde{\mathbf{y}} = U\tilde{\boldsymbol{\theta}} + \mathbf{v} \quad (2.5)$$

A equação (2.5) é denominada equação do erro. O estimador é obtido minimizando-se:

$$J(\hat{\boldsymbol{\theta}}) = w(1)\tilde{y}_1^2 + w(2)\tilde{y}_2^2 + \cdots + w(N)\tilde{y}_N^2$$

onde  $w(i)$  é a ponderação em cada componente do erro, que é função da precisão da medida. Esta equação pode ser rescrita como segue:

$$J(\hat{\boldsymbol{\theta}}) = \tilde{\mathbf{y}}^T W \tilde{\mathbf{y}}$$

onde  $\tilde{\mathbf{y}} = [\tilde{y}_1 \ \tilde{y}_2 \ \cdots \ \tilde{y}_N]^T$  e  $W = \text{diag}(w(1) \ w(2) \ \cdots \ w(N))$ . Deseja-se:

$$\hat{\boldsymbol{\theta}}_M = \arg \min_{\hat{\boldsymbol{\theta}}} J(\hat{\boldsymbol{\theta}}) = \arg \min_{\hat{\boldsymbol{\theta}}} \|\mathbf{y} - U\hat{\boldsymbol{\theta}}\|_W^2$$

sendo que a função  $J(\hat{\boldsymbol{\theta}})$  pode ainda ser reescrita como:

$$J(\hat{\boldsymbol{\theta}}) = \mathbf{y}^T W \mathbf{y} - 2\mathbf{y}^T W U \hat{\boldsymbol{\theta}} + \hat{\boldsymbol{\theta}}^T U^T W U \hat{\boldsymbol{\theta}}$$

Sabe-se que  $\hat{\boldsymbol{\theta}}_M$  deve ser tal que  $dJ/d\hat{\boldsymbol{\theta}} = 0$ , o que implica:

$$\frac{dJ}{d\hat{\boldsymbol{\theta}}} = -2[\mathbf{y}^T W U]^T + 2U^T W U \hat{\boldsymbol{\theta}} = 0$$

$$[U^T W U] \hat{\boldsymbol{\theta}} = U^T W \mathbf{y} \tag{2.6}$$

que é denominada Equação Normal e produz o seguinte estimador:

$$\hat{\boldsymbol{\theta}}_M = [U^T W U]^{-1} U^T W \mathbf{y} \tag{2.7}$$

A matriz  $[U^T W U]^{-1} U^T W$  é denominada matriz Pseudo-Inversa. O estimador (2.7) é denominado Estimador de Markov, Mínimos Quadrados Ponderados (*Weighted Least Squares* – WLS) ou ainda Mínimos Quadrados Generalizado. Quando  $W = \sigma^2 I_N$ , onde  $\sigma$  é um escalar e  $I_N$  é a matriz de identidade  $N \times N$ , obtém-se o estimador dos Mínimos Quadrados convencional, descrito por:

$$\hat{\boldsymbol{\theta}}_{MQ} = [U^T U]^{-1} U^T \mathbf{y} \tag{2.8}$$

Nesse caso tem-se que  $\hat{\boldsymbol{\theta}}_{MQ}$  é seguramente um ponto de mínimo pois a matriz Hessiana:

$$\frac{d^2 J}{d\hat{\boldsymbol{\theta}}^2} = 2U^T W U$$

é definida positiva posto que  $W = \sigma^2 I_N$  é definida positiva. Logo,  $\hat{\boldsymbol{\theta}}_{MQ}$  em (2.8) é uma solução ótima. Como é única, é uma solução ótima global. No caso geral do estimador em (2.7) a otimalidade requer apenas que a matriz de ponderação  $W$  seja definida positiva.

### 2.2.1 Interpretação Geométrica do Estimador

A equação  $\hat{\mathbf{y}} = U\hat{\boldsymbol{\theta}}$  define o subespaço  $\mathcal{R}(U) = \hat{\mathcal{Y}}$ . Da equação normal para o estimador dos Mínimos Quadrados tem-se que:

$$(U^T U)\hat{\boldsymbol{\theta}} - U^T \mathbf{y} = 0$$

$$U^T(\mathbf{y} - \hat{\mathbf{y}}) = 0$$

$$U^T \tilde{\mathbf{y}} = 0 \quad (2.9)$$

A equação (2.9) mostra que  $\tilde{\mathbf{y}}$  pertence ao espaço nulo de  $U^T$ ,  $\mathcal{N}(U^T)$ . Como  $\mathcal{N}(U^T) = [\mathcal{R}(U)]^\perp$  então  $\tilde{\mathbf{y}}$  pertence ao complemento ortogonal ( $\perp$ ) de  $U$ , isto é,  $\tilde{\mathbf{y}}$  é normal ao subespaço  $\hat{\mathcal{Y}}$ . A propriedade da ortogonalidade do estimador dos mínimos quadrados pode também ser ilustrada graficamente, conforme mostra a figura 2.1.

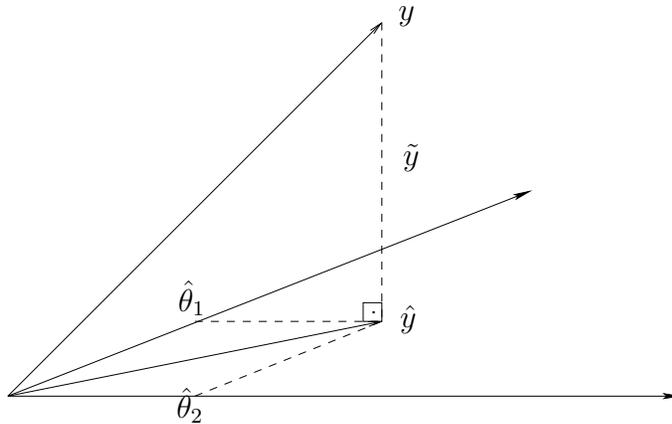


Figura 2.1: Propriedade de Ortogonalidade do Estimador de Mínimos Quadrados.

### 2.2.2 Exemplos

#### Exemplo 1

Seja o sistema descrito por:

$$y(t) = \theta_0 + v(t); \quad t = 1, \dots, N$$

onde  $y(t)$  é a saída do sistema e  $v(t)$  é uma perturbação com variância  $\sigma_{v(t)}^2 = 1$ . Obter o estimador dos Mínimos Quadrados de  $\theta_0$ .

Nesse caso tem-se que:

$$U = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}; \quad \mathbf{y} = [y(1) \cdots y(N)]^T$$

$$\hat{\theta}_0 = [U^T U]^{-1} U^T \mathbf{y} = \frac{1}{N} \sum_{i=1}^N y(i)$$

Portanto, o estimador nesse caso corresponde à média aritmética das medidas. Suponha agora que a variância da perturbação seja dada por  $\sigma_{v(t)}^2 = \lambda_t^2$ . Nesse caso pode-se definir:

$$W = \begin{bmatrix} \lambda_1^2 & 0 & \cdots & 0 \\ 0 & \lambda_2^2 & \cdots & 0 \\ \vdots & \vdots & \vdots & 0 \\ 0 & \cdots & \lambda_{N-1}^2 & 0 \\ 0 & 0 & \cdots & \lambda_N^2 \end{bmatrix}$$

e utilizar o estimador de Markov em (2.7) para obter:

$$\hat{\theta}_0 = \frac{1}{\sum_{j=1}^N (1/\lambda_j^2)} \sum_{i=1}^N (1/\lambda_i^2) y(i)$$

que é a média ponderada das medidas. Dessa equação pode-se observar que se a medida tem maior precisão (menor variância) então ela possui maior peso no cálculo do estimador.

### **Exemplo 2**

Seja o sistema descrito por:

$$y(t) = \theta_0 u(t) + \theta_1 u(t-1) + v(t); \quad t = 1, \dots, N$$

onde  $u(t)$  e  $y(t)$  são respectivamente a entrada e a saída do sistema (supostas mensuráveis) e  $v(t)$  é uma perturbação. Obter o estimador dos mínimos quadrados de  $\theta_0$  e  $\theta_1$ .

Nesse caso tem-se que:

$$y(t) = [ u(t) \quad u(t-1) ] \begin{bmatrix} \theta_0 \\ \theta_1 \end{bmatrix} + v(t)$$

$$U = \begin{bmatrix} u(1) & u(0) \\ u(2) & u(1) \\ \vdots & \vdots \\ u(N) & u(N-1) \end{bmatrix}$$

e portanto:

$$U^T U = \begin{bmatrix} \sum_{t=1}^N (u^2(t)) & \sum_{t=1}^N (u(t)u(t-1)) \\ \sum_{t=1}^N (u(t-1)u(t)) & \sum_{t=1}^N (u^2(t-1)) \end{bmatrix}$$

Observações:

- a) A matriz  $U^T U$  no caso geral é tal que  $U^T U \in \mathfrak{R}^{m \times m}$  onde  $m$  é o número de parâmetros desconhecidos.
- b) A matriz  $U^T U$  é simétrica e seus elementos são somas de “correlações”.
- c) Para a existência da solução da equação do estimador a matriz  $U^T U$  deve ser não singular. Para tanto a entrada  $u(t)$  deve apresentar *excitação persistente*, isso é, deve possuir variação suficiente para que o determinante da matriz seja diferente de zero (não nulo).

Considere, por exemplo, uma entrada constante  $u(t) = 1$ . Nesse caso tem-se:

$$y(t) = (\theta_0 + \theta_1) + v(t)$$

e

$$\frac{1}{N} [U^T U] = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}$$

Essa matriz é não singular o que significa que sua inversa não existe. Nesse caso não existe solução única para o problema de estimação dos parâmetros.

### Exemplo 3

Considere um sistema estático em que se deseja obter o modelo mais adequado às seguintes medidas:

$$\begin{aligned} t = 1 : u(1) = 0 \quad y(1) = 0 \\ t = 2 : u(2) = 1 \quad y(2) = 0.9 \\ t = 3 : u(3) = 2 \quad y(3) = 2.1 \end{aligned}$$

Considere inicialmente um modelo constante<sup>1</sup>, isto é:

$$y(t) = \theta_0$$

Nesse caso tem-se:

$$U = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}$$

e

$$\mathbf{y} = \begin{bmatrix} 0 \\ 0.9 \\ 2.1 \end{bmatrix}$$

O estimador dos Mínimos Quadrados de  $\theta_0$  é dado por:

$$\hat{\theta}_0 = [U^T U]^{-1} U^T \mathbf{y}$$

$$\hat{\theta}_0 = 3^{-1}(0 + 0.9 + 2.1) = 1.0$$

que corresponde à média aritmética das medidas. O custo associado à obtenção desse modelo é dado por:

---

<sup>1</sup>O mais simples!

$$J = \tilde{y}^T \tilde{y} = 1 + 0.1^2 + 1.1^2 = 2.22$$

Vamos a seguir considerar um modelo linear e verificar se ele representa melhor os dados. Seja então:

$$y(t) = \theta_0 + \theta_1 u(t)$$

ou

$$y(t) = \begin{bmatrix} 1 & u(t) \end{bmatrix} \begin{bmatrix} \theta_0 \\ \theta_1 \end{bmatrix}$$

Nesse caso a matriz  $U$  é dada por:

$$U = \begin{bmatrix} 1 & 0 \\ 1 & 1 \\ 1 & 2 \end{bmatrix}$$

O estimador  $\hat{\theta}$  é dado por:

$$\hat{\theta} = \begin{bmatrix} -0.05 \\ 1.05 \end{bmatrix}$$

O custo associado a esse modelo é  $J = 0.015$ , que é significativamente menor que aquele associado ao modelo anterior, indicando que esse modelo representa melhor os dados fornecidos.

Considere agora um modelo (não linear) de segunda ordem, isso é:

$$y(t) = \theta_0 + \theta_1 u(t) + \theta_2 u^2(t)$$

que pode ser rescrito como:

$$y(t) = \begin{bmatrix} 1 & u(t) & u^2(t) \end{bmatrix} \begin{bmatrix} \theta_0 \\ \theta_1 \\ \theta_2 \end{bmatrix}$$

$$U = \begin{bmatrix} 1 & 0 & 0 \\ 1 & 1 & 1 \\ 1 & 2 & 4 \end{bmatrix}$$

Nesse caso  $\hat{\theta}$  é dado por:

$$\hat{\boldsymbol{\theta}} = \begin{bmatrix} 0 \\ 0.75 \\ 0.15 \end{bmatrix}$$

O custo associado a esse modelo é  $J = 0.0$  que é o menor valor que pode ser obtido para esses dados. Essa condição ocorre quando o número de medidas é igual ao número de parâmetros a serem estimados e a matriz  $U$  é não singular. Na validação do modelo também deve-se incluir uma medida de parcimônia para evitar modelos de ordem elevada (vide seção de validação de modelos).

### 2.3 Propriedades do Estimador dos Mínimos Quadrados

Definições:

1. O estimador  $\hat{\boldsymbol{\theta}} = f(\mathbf{y})$  de  $\boldsymbol{\theta}$  diz-se não polarizado se  $\hat{\boldsymbol{\theta}}$  possui valor médio igual a  $\boldsymbol{\theta}$  qualquer que seja  $\boldsymbol{\theta} \in \mathfrak{R}^m$ , isto é:

$$\mathcal{E}_{Y/\boldsymbol{\theta}}\{f(\mathbf{y})\} = \boldsymbol{\theta}$$

onde  $\mathcal{E}$  denota a esperança matemática.

2. Um estimador  $\hat{\boldsymbol{\theta}} = f(\mathbf{y})$  de  $\boldsymbol{\theta}$  diz-se um estimador não polarizado e de variância mínima (*Minimum Variance Unbiased Estimator* – MVUE) se é não polarizado e

$$\mathcal{E}_{Y/\boldsymbol{\theta}}\{(f(\mathbf{y}) - \boldsymbol{\theta})(f(\mathbf{y}) - \boldsymbol{\theta})^T\} \leq \mathcal{E}_{Y/\boldsymbol{\theta}}\{(f^*(\mathbf{y}) - \boldsymbol{\theta})(f^*(\mathbf{y}) - \boldsymbol{\theta})^T\} \quad (2.10)$$

para qualquer  $\boldsymbol{\theta} \in \mathfrak{R}^m$  e qualquer estimador  $f^*(\mathbf{y})$  não polarizado.

3. Um estimador  $f(\mathbf{y})$  de  $\boldsymbol{\theta}$  é o melhor estimador linear não polarizado (*Best Linear Unbiased Estimator* – BLUE) se a equação (2.10) é satisfeita para qualquer  $\boldsymbol{\theta} \in \mathfrak{R}^m$  e estimadores  $f^*$  da classe de estimadores lineares não polarizados.

### 2.3. PROPRIEDADES DO ESTIMADOR DOS MÍNIMOS QUADRADOS 11

**Teorema 1** *O estimador de Markov é não polarizado se a perturbação tem média nula ( $\mathcal{E}\{\mathbf{v}\} = 0$ ) e os sinais de entrada e de perturbação são independentes.*

Prova: Da equação do estimador de Markov tem-se que:

$$\begin{aligned}\hat{\boldsymbol{\theta}} &= [U^T W U]^{-1} U^T W [U \boldsymbol{\theta} + \mathbf{v}] \\ \hat{\boldsymbol{\theta}} &= \boldsymbol{\theta} + [U^T W U]^{-1} U^T W \mathbf{v} \\ \mathcal{E}\{\hat{\boldsymbol{\theta}}\} &= \boldsymbol{\theta} + \mathcal{E}\{(U^T W U)^{-1} U^T W \mathbf{v}\}\end{aligned}\quad (2.11)$$

Se  $\mathbf{u}$  e  $\mathbf{v}$  são independentes, então a equação (2.11) pode ser reescrita como segue:

$$\mathcal{E}\{\hat{\boldsymbol{\theta}}\} = \boldsymbol{\theta} + \mathcal{E}\{(U^T W U)^{-1} U^T W\} \mathcal{E}\{\mathbf{v}\} = \boldsymbol{\theta}$$

Deve-se notar que a independência entre  $\mathbf{u}$  e  $\mathbf{v}$  é uma condição suficiente, mas não necessária, pois a partir da equação (2.11) tem-se a seguinte implicação:

$$\mathcal{E}\{(U^T W U)^{-1} U^T W \mathbf{v}\} = 0 \quad \rightarrow \quad \mathcal{E}\{\hat{\boldsymbol{\theta}}\} = \boldsymbol{\theta}$$

Conhecida como condição de ortogonalidade, é mais fraca que a condição de independência, mas mais difícil de ser verificada.

**Teorema 2** *Se a perturbação tem média nula ( $\mathcal{E}\{\mathbf{v}\} = 0$ ) e além disso a entrada  $\mathbf{u}$  é determinística e a perturbação  $\mathbf{v}$  é uma variável aleatória com matriz de covariância  $V$  então a covariância do erro de estimação do estimador de Markov é dada por:*

$$\text{cov} \tilde{\boldsymbol{\theta}} = [U^T W U]^{-1} U^T W V W U [U^T W U]^{-1}$$

onde  $V = \mathcal{E}\{\mathbf{v} \mathbf{v}^T\}$ .

Prova:

$$\text{cov} \tilde{\boldsymbol{\theta}} = \mathcal{E}\{[\tilde{\boldsymbol{\theta}} - \mathcal{E}\tilde{\boldsymbol{\theta}}][\tilde{\boldsymbol{\theta}} - \mathcal{E}\tilde{\boldsymbol{\theta}}]^T\}$$

Dado que  $\mathcal{E}\tilde{\boldsymbol{\theta}} = \mathcal{E}\{\boldsymbol{\theta} - \hat{\boldsymbol{\theta}}\} = \mathcal{E}\{\boldsymbol{\theta}\} - \mathcal{E}\{\hat{\boldsymbol{\theta}}\} = \boldsymbol{\theta} - \boldsymbol{\theta} = 0$ , pois  $\boldsymbol{\theta}$  é determinístico e o estimador é não polarizado (teorema 1), tem-se:

$$\text{cov}\tilde{\boldsymbol{\theta}} = \mathcal{E}\{\tilde{\boldsymbol{\theta}}\tilde{\boldsymbol{\theta}}^T\}$$

Do teorema 1 tem-se:

$$\boldsymbol{\theta} - \hat{\boldsymbol{\theta}} = -[U^T W U]^{-1} U^T W \mathbf{v} = \tilde{\boldsymbol{\theta}}$$

e portanto

$$\text{cov}\tilde{\boldsymbol{\theta}} = \mathcal{E}\{[U^T W U]^{-1} U^T W \mathbf{v} \mathbf{v}^T W U [U^T W U]^{-1}\}$$

Se a entrada for determinística tem-se que<sup>2</sup>:

$$\text{cov}\tilde{\boldsymbol{\theta}} = [U^T W U]^{-1} U^T W V W U [U^T W U]^{-1}$$

Quando a perturbação atuando no sistema é dada por  $V = \sigma^2 I_N$ , isto é, é tal que suas componentes são independentes e identicamente distribuídas (i.i.d.), tem-se que:

$$\text{cov}\tilde{\boldsymbol{\theta}} = \sigma^2 [U^T U]^{-1}$$

onde  $\sigma^2$  é um parâmetro da distribuição da medida, que em geral é desconhecido e necessita ser estimado.

**Teorema 3** Um estimador não polarizado de  $\sigma^2$  é dado por:

$$\hat{\sigma}^2 = \frac{\tilde{\mathbf{y}}^T \tilde{\mathbf{y}}}{\dim(\mathbf{v}) - \dim(\boldsymbol{\theta})} = \frac{\tilde{\mathbf{y}}^T \tilde{\mathbf{y}}}{N - m} \quad (2.12)$$

*Prova:*

$$\tilde{\mathbf{y}} = \mathbf{y} - \hat{\mathbf{y}} = \mathbf{y} - U \hat{\boldsymbol{\theta}}$$

$$\hat{\boldsymbol{\theta}} = \boldsymbol{\theta} + [U^T U]^{-1} U^T \mathbf{v} \quad (\text{do teorema 1 para } W = I_N)$$

$$\tilde{\mathbf{y}} = U \boldsymbol{\theta} + \mathbf{v} - U[\boldsymbol{\theta} + [U^T U]^{-1} U^T \mathbf{v}] = \mathbf{v} - U[U^T U]^{-1} U^T \mathbf{v}$$

$$\tilde{\mathbf{y}} = [I_N - U[U^T U]^{-1} U^T] \mathbf{v}$$

---

<sup>2</sup>Dado que  $U^T W U$  é não singular, segue que  $([U^T W U]^{-1})^T = ([U^T W U]^T)^{-1} = [U^T W U]^{-1}$ .

### 2.3. PROPRIEDADES DO ESTIMADOR DOS MÍNIMOS QUADRADOS 13

Definindo  $A = I_N - U[U^T U]^{-1} U^T$  tem-se que  $\tilde{\mathbf{y}} = A\mathbf{v}$ , sendo que a matriz  $A$  apresenta as propriedades  $A^2 = AA = A$  e  $A^T = A$ . Portanto:

$$\mathcal{E}\{\tilde{\mathbf{y}}^T \tilde{\mathbf{y}}\} = \mathcal{E}\{\mathbf{v}^T [I_N - U[U^T U]^{-1} U^T] [I_N - U[U^T U]^{-1} U^T] \mathbf{v}\} = \mathcal{E}\{\mathbf{v}^T A^2 \mathbf{v}\}$$

$$\mathcal{E}\{\tilde{\mathbf{y}}^T \tilde{\mathbf{y}}\} = \mathcal{E}\{\mathbf{v}^T [I_N - U(U^T U)^{-1} U^T] \mathbf{v}\} = \mathcal{E}\{\mathbf{v}^T A \mathbf{v}\}$$

Lembrando as seguintes propriedades de matrizes:

$$\mathbf{p}^T P \mathbf{p} = \text{tr}(P \mathbf{p} \mathbf{p}^T)$$

$$\mathcal{E}\{\text{tr}(P)\} = \text{tr}(\mathcal{E}\{P\})$$

$$\text{tr}(P + Q) = \text{tr}(Q + P)$$

$$\text{tr}(PQ) = \text{tr}(QP)$$

tem-se que:

$$\mathcal{E}\{\tilde{\mathbf{y}}^T \tilde{\mathbf{y}}\} = \mathcal{E}\{\text{tr}(A \mathbf{v} \mathbf{v}^T)\}$$

$$\mathcal{E}\{\tilde{\mathbf{y}}^T \tilde{\mathbf{y}}\} = \text{tr}(A \mathcal{E}\{\mathbf{v} \mathbf{v}^T\}) = \text{tr}(\sigma^2 A)$$

$$\mathcal{E}\{\tilde{\mathbf{y}}^T \tilde{\mathbf{y}}\} = \sigma^2 \text{tr}(I_N) - \sigma^2 \text{tr}(U[U^T U]^{-1} U^T) = \sigma^2 (N - \text{tr}([U^T U]^{-1} U^T U))$$

$$\mathcal{E}\{\tilde{\mathbf{y}}^T \tilde{\mathbf{y}}\} = \sigma^2 (N - \text{tr}(I_m)) = \sigma^2 (N - m)$$

Logo,  $\hat{\sigma}^2$  em (2.12) é um estimador não polarizado de  $\sigma^2$  pois  $\mathcal{E}\{\hat{\sigma}^2\} = \sigma^2$ .

**Teorema 4** O estimador dos Mínimos Quadrados dado por  $\hat{\boldsymbol{\theta}} = [U^T U]^{-1} U^T \mathbf{y}$  possui as seguintes propriedades para  $V = \mathcal{E}\{\mathbf{v} \mathbf{v}^T\} = \sigma^2 I_N$  e  $\mathcal{E}\{\mathbf{v}\} = 0$ :

a) É uma função linear das medidas;

- b) É um estimador não polarizado;  
 c) É um estimador BLUE, isto é:

$$\mathcal{E}\{(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T\} \leq \mathcal{E}\{(\boldsymbol{\theta}^* - \boldsymbol{\theta})(\boldsymbol{\theta}^* - \boldsymbol{\theta})^T\}$$

onde  $\boldsymbol{\theta}^*$  é qualquer estimador linear das medidas.

*Prova:*

a)  $\hat{\boldsymbol{\theta}} = [U^T U]^{-1} U^T \mathbf{y} = C\mathbf{y}$ .

b) Já foi demonstrado (teorema 1).

c) Seja um estimador  $\boldsymbol{\theta}^* = C\mathbf{y}$  tal que  $\mathcal{E}\boldsymbol{\theta}^* = \boldsymbol{\theta}$  (não polarizado). Logo, é simples demonstrar que  $\mathcal{E}\{C\mathbf{y}\} = \boldsymbol{\theta}$  implica  $CU\boldsymbol{\theta} = \boldsymbol{\theta}$ , dado que  $\mathcal{E}\{\mathbf{v}\} = 0$ . A covariância de  $\boldsymbol{\theta}^*$  é dada por:

$$\begin{aligned} \mathcal{E}\{(\boldsymbol{\theta}^* - \boldsymbol{\theta})(\boldsymbol{\theta}^* - \boldsymbol{\theta})^T\} &= \mathcal{E}\{(C\mathbf{y} - \boldsymbol{\theta})(C\mathbf{y} - \boldsymbol{\theta})^T\} = \\ &= \mathcal{E}\{(C\mathbf{y} - CU\boldsymbol{\theta} + CU\boldsymbol{\theta} - \boldsymbol{\theta})(C\mathbf{y} - CU\boldsymbol{\theta} + CU\boldsymbol{\theta} - \boldsymbol{\theta})^T\} = \\ &= \mathcal{E}\{(C\mathbf{y} - CU\boldsymbol{\theta})(C\mathbf{y} - CU\boldsymbol{\theta})^T\} = C\mathcal{E}\{(\mathbf{y} - U\boldsymbol{\theta})(\mathbf{y} - U\boldsymbol{\theta})^T\}C^T = \\ &= C\mathcal{E}\{\mathbf{v}\mathbf{v}^T\}C^T = CC^T\sigma^2 \end{aligned}$$

Seja  $D = C - (U^T U)^{-1} U^T$ . Então, dado que  $CU\boldsymbol{\theta} = \boldsymbol{\theta}$  implica  $CU = I_m$ , tem-se que:

$$\begin{aligned} DD^T &= [C - (U^T U)^{-1} U^T][C - (U^T U)^{-1} U^T]^T \\ DD^T &= CC^T - CU(U^T U)^{-1} - (U^T U)^{-1} U^T C^T + (U^T U)^{-1} \\ DD^T &= CC^T - (U^T U)^{-1} \end{aligned}$$

Portanto, como  $DD^T \geq 0$  e  $(U^T U)^{-1} > 0$  (assumindo que a inversa existe), tem-se  $\text{cov}\hat{\boldsymbol{\theta}} \leq \text{cov}\boldsymbol{\theta}^*$ , pois é simples demonstrar que  $\text{cov}(\hat{\boldsymbol{\theta}}) = \text{cov}(\tilde{\boldsymbol{\theta}}) = \sigma^2 [U^T U]^{-1}$  (teorema 2).

### 2.3. PROPRIEDADES DO ESTIMADOR DOS MÍNIMOS QUADRADOS 15

**Teorema 5** Seja  $\mathcal{E}\{\mathbf{v}\} = 0$  e  $\text{cov}\mathbf{v} = V$ . Então o estimador BLUE de  $\boldsymbol{\theta}$  é dado por:

$$\hat{\boldsymbol{\theta}} = [U^T V^{-1} U]^T U^T V^{-1} \mathbf{y}$$

*Prova:* Como  $V$  é uma matriz simétrica definida positiva, tem-se que  $V$  pode ser escrita como  $V = PP^T$  com  $P$  triangular e não singular. Definindo  $\mathbf{y}^* = P^{-1}\mathbf{y}$  tem-se que:

$$\mathbf{y} = U\boldsymbol{\theta} + \mathbf{v}$$

$$P^{-1}\mathbf{y} = P^{-1}U\boldsymbol{\theta} + P^{-1}\mathbf{v}$$

$$\mathbf{y}^* = U^*\boldsymbol{\theta} + \mathbf{v}^*$$

A partir dessa transformação tem-se:

$$\text{cov}\mathbf{v}^* = \mathcal{E}\{[\mathbf{y}^* - U^*\boldsymbol{\theta}][\mathbf{y}^* - U^*\boldsymbol{\theta}]^T\} = \mathcal{E}\{P^{-1}(\mathbf{y} - U\boldsymbol{\theta})(\mathbf{y} - U\boldsymbol{\theta})^T P^{-T}\}$$

$$\text{cov}\mathbf{v}^* = P^{-1}VP^{-T} = P^{-1}PP^T P^{-T} = I_N$$

sendo  $P^{-T} \triangleq (P^{-1})^T = (P^T)^{-1}$ , uma vez que  $P$  é não singular. Com essa transformação a perturbação passa a satisfazer as condições do teorema 4. Aplicando então o teorema no sistema transformado resulta:

$$\hat{\boldsymbol{\theta}} = [U^{*T} U^*]^{-1} U^{*T} \mathbf{y}^*$$

$$\hat{\boldsymbol{\theta}} = [UP^{-T}P^{-1}U]^{-1} U^T P^{-T} P^{-1} \mathbf{y} = [U^T V^{-1} U]^{-1} U^T V^{-1} \mathbf{y}$$

O termo  $P^{-1}$  é denominado filtro embranquecedor.

**Teorema 6** (Gauss-Markov) Seja  $\mathbf{v}$  um vetor aleatório com  $\mathcal{E}\{\mathbf{v}\} = 0$  e  $\mathcal{E}\{\mathbf{v}\mathbf{v}^T\} = V$ . O estimador de variância mínima é obtido minimizando o critério:

$$J = (\mathbf{y} - U\boldsymbol{\theta})^T W (\mathbf{y} - U\boldsymbol{\theta}) \quad W = V^{-1}$$

## 2.4 Estimador de Bayes

### 2.4.1 Definições

O método de estimação apresentado na seção anterior assume que os valores desconhecidos a serem estimados são determinísticos. Nos métodos de estimação de Bayes os parâmetros desconhecidos  $\boldsymbol{\theta}$  são assumidos como sendo variáveis aleatórias e dispõe-se de alguma informação sobre a sua função de distribuição de probabilidade, denominada informação *à-priori*. Como será visto os métodos de Bayes obtém o estimador dos parâmetros desconhecidos realizando uma combinação desta informação inicial com a informação contida nas medidas realizadas. Para tanto assume-se que o vetor de medidas  $\mathbf{y}_k$  é descrito pela equação (2.13):

$$\mathbf{y}_k = \mathbf{h}(\boldsymbol{\theta}, \mathbf{v}_k) \quad (2.13)$$

onde  $\mathbf{h}$  é uma função não linear relacionando as variáveis desconhecidas e a perturbação com as medidas. Em geral,  $\mathbf{h}$  é uma função desconhecida.  $\mathbf{v}_k$  é um vetor de variáveis aleatórias, com função densidade de probabilidade suposta conhecida, representando as perturbações na medida e no sistema. No estimador de Bayes, dada a informação inicial sobre a função densidade de probabilidade (f.d.p) do vetor de variáveis aleatórias  $\boldsymbol{\theta}$ , isto é,  $p(\boldsymbol{\theta})$  deseja-se calcular a f.d.p da variável aleatória  $\boldsymbol{\theta}$  quando dispõe-se de um conjunto de medidas da saída do sistema descrito por (2.13). Isto é, deve-se calcular  $p(\boldsymbol{\theta}|\mathbf{Y})$  onde:  $\mathbf{Y}^T = [\mathbf{y}_1^T \quad \mathbf{y}_2^T \quad \cdots \quad \mathbf{y}_N^T]$ . A nova informação sobre o vetor de parâmetros  $\boldsymbol{\theta}$  é calculada utilizando o regra de Bayes conforme segue:

$$p(\boldsymbol{\theta}|\mathbf{Y}) = \frac{p(\mathbf{Y}|\boldsymbol{\theta})p(\boldsymbol{\theta})}{p(\mathbf{Y})} \quad (2.14)$$

A solução da equação (2.14) é o estimador de Bayes, onde  $p(\boldsymbol{\theta}|\mathbf{Y})$  é a densidade *a-posteriori* de  $\boldsymbol{\theta}$ . Contudo, em geral, calcular a função densidade *a-posteriori* utilizando (2.14) é um problema complexo. Assim procura-se obter informação sobre alguma estatística desta densidade, e esta informação é denominada estimador ( $\hat{\boldsymbol{\theta}}$ ) de  $\boldsymbol{\theta}$ . Os diferentes estimadores de Bayes são obtidos otimizando algum critério função do erro de estimação dado por

$\tilde{\theta} = \theta - \hat{\theta}$ . Para tanto define-se o funcional  $J$  conforme segue:

$$J(\hat{\theta}) = \mathcal{E}(R(\tilde{\theta})) \quad (2.15)$$

$$J(\hat{\theta}) = \int R(\tilde{\theta})p_{\theta}(\theta)d(\theta)$$

$$J(\hat{\theta}) = \int \int R(\tilde{\theta})p_{\theta\mathbf{Y}}(\theta, \mathbf{Y})d(\theta)d(\mathbf{Y})$$

onde  $p_{\theta}(\theta)$  é a densidade de probabilidade marginal de  $\theta$ ,  $p_{\theta\mathbf{Y}}(\theta, \mathbf{Y})$  é a densidade conjunta das variáveis aleatórias  $\theta$  e  $\mathbf{Y}$ . O estimador ótimo de Bayes é obtido minimizando-se o critério  $J(\hat{\theta})$ . Variando-se a função de custo  $R(\tilde{\theta})$  obtém-se os diferentes estimadores de Bayes. A seguir apresenta-se os dois estimadores mais comuns citados na literatura.

### 2.4.2 Estimador de Bayes de Mínimos Quadrados

Seja a função de custo  $R(\tilde{\boldsymbol{\theta}}) = \tilde{\boldsymbol{\theta}}^T Q \tilde{\boldsymbol{\theta}}$  onde  $Q$  é uma matriz simétrica semi-definida positiva. Neste caso o critério a ser minimizado pode ser escrito como:

$$J(\hat{\boldsymbol{\theta}}) = \int \int \tilde{\boldsymbol{\theta}}^T Q \tilde{\boldsymbol{\theta}} p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}, \mathbf{Y}) d(\boldsymbol{\theta}) d(\mathbf{Y})$$

Utilizando a definição de função de densidade de probabilidade condicional pode-se reescrever a equação acima como:

$$J(\hat{\boldsymbol{\theta}}) = \int \left\{ \int \tilde{\boldsymbol{\theta}}^T Q \tilde{\boldsymbol{\theta}} p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}|\mathbf{Y}) d(\boldsymbol{\theta}) \right\} p_{\mathbf{Y}}(\mathbf{Y}) d(\mathbf{Y})$$

Como  $p_{\mathbf{Y}}(\mathbf{Y})$  é sempre positiva, minimizar  $J$  é equivalente a minimizar a integral interna da equação anterior, isto é, deve-se minimizar

$$J_{BMQ}(\hat{\boldsymbol{\theta}}) = \int \tilde{\boldsymbol{\theta}}^T Q \tilde{\boldsymbol{\theta}} p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}|\mathbf{Y}) d(\boldsymbol{\theta})$$

A condição necessária para a minimização de  $J_{BMQ}$  é dada por:

$$\left. \frac{\partial J_{BMQ}(\hat{\boldsymbol{\theta}})}{\partial \hat{\boldsymbol{\theta}}} \right|_{\hat{\boldsymbol{\theta}} = \hat{\boldsymbol{\theta}}_{BMQ}} = -2Q \int_{-\infty}^{\infty} (\boldsymbol{\theta} - \hat{\boldsymbol{\theta}}) p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}|\mathbf{Y}) d(\boldsymbol{\theta}) \Big|_{\hat{\boldsymbol{\theta}} = \hat{\boldsymbol{\theta}}_{BMQ}} = 0$$

$$\hat{\boldsymbol{\theta}}_{BMQ} \int_{-\infty}^{\infty} p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}|\mathbf{Y}) d(\boldsymbol{\theta}) = \int_{-\infty}^{\infty} \boldsymbol{\theta} p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}|\mathbf{Y}) d(\boldsymbol{\theta})$$

$$\hat{\boldsymbol{\theta}}_{BMQ} = \int_{-\infty}^{\infty} \boldsymbol{\theta} p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}|\mathbf{Y}) d(\boldsymbol{\theta})$$

$$\hat{\boldsymbol{\theta}}_{BMQ} = \mathcal{E}(\boldsymbol{\theta}|\mathbf{Y})$$

Esta solução é um ponto de mínimo pois tem-se que:

$$\frac{\partial^2 J_{BMQ}(\hat{\boldsymbol{\theta}})}{\partial^2 \hat{\boldsymbol{\theta}}} = 2Q > 0$$

### 2.4.3 Propriedades do Estimador de Bayes de Mínimos Quadrados

a) É um operador linear

Prova: Seja o estimador de Bayes de Mínimos Quadrados dado por  $\hat{\boldsymbol{\theta}}_{BMQ}$ , a matriz  $A$  e o vetor  $\mathbf{b}$  com dimensões apropriadas, então:

$$\mathcal{E}((A\hat{\boldsymbol{\theta}}_{BMQ} + \mathbf{b})|\mathbf{Y}) = A\mathcal{E}(\boldsymbol{\theta}|\mathbf{Y}) + \mathbf{b} = A\hat{\boldsymbol{\theta}}_{BMQ} + \mathbf{b}$$

Sejam os estimadores de Bayes de variância mínima  $\hat{\boldsymbol{\theta}}_{BMQ}$  e  $\hat{\boldsymbol{\alpha}}_{BMQ}$  com a mesma dimensão, então:

$$\mathcal{E}((\hat{\boldsymbol{\theta}} + \hat{\boldsymbol{\alpha}})|\mathbf{Y}) = \mathcal{E}(\hat{\boldsymbol{\theta}}|\mathbf{Y}) + \mathcal{E}(\hat{\boldsymbol{\alpha}}|\mathbf{Y}) = \hat{\boldsymbol{\theta}}_{BMQ} + \hat{\boldsymbol{\alpha}}_{BMQ}$$

b) É um estimador não polarizado

Prova:

$$\mathcal{E}(\boldsymbol{\theta} - \hat{\boldsymbol{\theta}}_{BMQ}) = \mathcal{E}(\boldsymbol{\theta}) - \mathcal{E}(\mathcal{E}(\boldsymbol{\theta}|\mathbf{Y})) = \mathcal{E}(\boldsymbol{\theta}) - \mathcal{E}(\boldsymbol{\theta}) = 0$$

c) O erro de estimação  $\tilde{\boldsymbol{\theta}} = \boldsymbol{\theta} - \hat{\boldsymbol{\theta}}_{BMQ}$  é ortogonal a qualquer função  $\mathbf{g}(\mathbf{Y})$ .

Prova: Deve-se provar que:

$$\mathcal{E}\{\mathbf{g}(\mathbf{Y})\tilde{\boldsymbol{\theta}}^T\} = 0$$

Utilizando a propriedade de esperança matemática deve-se provar que:

$$\mathcal{E}\{\mathbf{g}(\mathbf{Y})\tilde{\boldsymbol{\theta}}^T|\mathbf{Y}\} = 0$$

Para cada valor  $\mathbf{y}$  de  $\mathbf{Y}$  tem-se que:

$$\begin{aligned} \mathcal{E}\{\mathbf{g}(\mathbf{Y})\tilde{\boldsymbol{\theta}}^T|\mathbf{Y} = \mathbf{y}\} &= \mathcal{E}\{\mathbf{g}(\mathbf{Y})(\boldsymbol{\theta} - \hat{\boldsymbol{\theta}}_{BMQ})^T|\mathbf{Y} = \mathbf{y}\} = \\ &= \mathbf{g}(\mathbf{y})\mathcal{E}\{(\boldsymbol{\theta}^T - \hat{\boldsymbol{\theta}}_{BMQ}^T)|\mathbf{Y} = \mathbf{y}\} \\ &= \mathbf{g}(\mathbf{y})\{\hat{\boldsymbol{\theta}}_{BMQ}^T - \hat{\boldsymbol{\theta}}_{BMQ}^T\} = 0 \end{aligned}$$

### 2.4.4 Estimador de máximo à-posteriori(MAP)

Neste caso a função de custo é selecionada de forma a ponderar igualmente os erros de estimação maiores que um valor infinitesimal. Assumindo, sem perda de generalidade, que  $\boldsymbol{\theta} \in \mathbf{R}$ , tem-se o seguinte critério de custo:

$$R(\tilde{\boldsymbol{\theta}}) = \begin{cases} 0 & \text{se } \tilde{\boldsymbol{\theta}} < \varepsilon \\ 1 & \text{se } \tilde{\boldsymbol{\theta}} \geq \varepsilon \end{cases}$$

com  $\tilde{\boldsymbol{\theta}} = \boldsymbol{\theta} - \hat{\boldsymbol{\theta}}$  e  $\varepsilon \rightarrow 0$ . Assim tem-se que:

$$J(\hat{\boldsymbol{\theta}}) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} R(\tilde{\boldsymbol{\theta}}) p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}|\mathbf{Y}) d(\boldsymbol{\theta}) p_{\mathbf{Y}}(\mathbf{Y}) d(\mathbf{Y})$$

$$J(\hat{\boldsymbol{\theta}}) = \int_{-\infty}^{\infty} \left\{ 1 - \int_{\hat{\boldsymbol{\theta}}-\varepsilon}^{\hat{\boldsymbol{\theta}}+\varepsilon} p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}|\mathbf{Y}) d(\boldsymbol{\theta}) \right\} p_{\mathbf{Y}}(\mathbf{Y}) d(\mathbf{Y})$$

Como  $p_{\mathbf{Y}}(\mathbf{Y})$  é positiva, para minimizar  $J(\hat{\boldsymbol{\theta}})$  em relação a  $\hat{\boldsymbol{\theta}}$  deve-se maximizar

$$\int_{\hat{\boldsymbol{\theta}}-\varepsilon}^{\hat{\boldsymbol{\theta}}+\varepsilon} p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}|\mathbf{Y}) d(\boldsymbol{\theta})$$

Quando  $\varepsilon \rightarrow 0$  esta função é maximizada para o valor de  $\hat{\boldsymbol{\theta}}$  que maximiza  $p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}|\mathbf{Y}) d(\boldsymbol{\theta})$ . Logo

$$\hat{\boldsymbol{\theta}}_{MAP} = \max_{\boldsymbol{\theta}} p_{\boldsymbol{\theta}|\mathbf{Y}}(\boldsymbol{\theta}|\mathbf{Y})$$

## 2.5 Estimador de Máxima Verossimilhança

Neste caso assume-se que a saída do sistema( $\mathbf{y}$ ) pode ser descrita por um elemento de uma família de funções densidades de probabilidade  $p(\cdot|\boldsymbol{\theta})$  onde  $\boldsymbol{\theta}$  é o vetor de parâmetros desconhecidos. Assim para uma medida  $\mathbf{y} = \mathbf{y}_{med}$  a função  $p(\mathbf{y} = \mathbf{y}_{med}|\boldsymbol{\theta})$  é uma função de  $\boldsymbol{\theta}$  denominada função de verossimilhança.

Definição: O estimador de máxima verossimilhança é uma função  $\hat{\boldsymbol{\theta}}(\mathbf{y})$  tal que:

$$\hat{\boldsymbol{\theta}}(\mathbf{y}) = \max_{\boldsymbol{\theta}} p(\mathbf{y}|\boldsymbol{\theta}) \quad (2.16)$$

### Desigualdade de Cramer-Rao

#### Teorema 7 Desigualdade de Cramer-Rao

Seja  $p(\mathbf{y}, \boldsymbol{\theta})$  e a matriz  $M_{\boldsymbol{\theta}} = \{m_{ij}\}$  dada por:

$$m_{ij} = \mathcal{E}_{\boldsymbol{\theta}} \left\{ \frac{\partial \log p(\mathbf{y}, \boldsymbol{\theta})}{\partial \theta_i} \frac{\partial \log p(\mathbf{y}, \boldsymbol{\theta})}{\partial \theta_j} \right\} \quad (2.17)$$

com  $\boldsymbol{\theta}^T = [\theta_1 \theta_2 \dots \theta_p]$ . Se  $M_{\boldsymbol{\theta}}$  é uma matriz não singular e seja  $\mathbf{g}(\mathbf{y})$  um estimador não polarizado de  $\boldsymbol{\theta}$ , então:

$$\text{cov}_{\boldsymbol{\theta}} \mathbf{g}(\mathbf{y}) \geq M_{\boldsymbol{\theta}}^{-1}$$

$M_{\boldsymbol{\theta}}$  é denominada matriz de informação de Fisher.

### Definições

#### a) Estimador Eficaz

Um estimador é eficaz quando é válido o sinal de igualdade na desigualdade de Cramer-Rao.

Exemplo: Eficiência do Estimador dos Mínimos Quadrados. Seja um sistema descrito por:

$$\mathbf{y} = U\boldsymbol{\theta} + \mathbf{v} \quad p(\mathbf{v}) = N(0, \sigma^2 I) \quad \mathbf{y} \in \mathfrak{R}^N$$

Nesse caso a função distribuição de probabilidade condicional  $p(y/\theta)$  é dada por:

$$\begin{aligned} p(y/\theta) &= \\ &= \frac{\exp(-0.5(y - U\theta)^T(\sigma^2 I_N)^{-1}(y - U\theta))}{(2\pi)^{N/2} \det[\sigma^2 I_N]^{0.5}} \end{aligned}$$

Como  $\det([\sigma^2 I_N]^{0.5}) = (\sigma^2)^{N/2}$

$$\begin{aligned} \ln p(y/\theta) &= \ln(2\pi)^{-N/2} + \\ &+ \ln(\sigma^2)^{-N/2} - \frac{(y - U\theta)^T((y - U\theta))}{2\sigma^2} \\ \ln p(y/\theta) &= -\frac{N}{2} \ln(2\pi) - \frac{N}{2} \ln(\sigma^2) - \frac{(y - U\theta)^T((y - U\theta))}{2\sigma^2} \end{aligned}$$

e

$$\begin{aligned} \frac{\partial \ln p(y/\theta)}{\partial \theta} &= \frac{\partial [y^T y - \theta^T U^T y - y^T U \theta + \theta^T U^T U \theta]}{2\sigma^2 \partial \theta} \\ &= \frac{-U^T y - U^T y + (U^T U + U^T U) \theta}{2\sigma^2} \\ \frac{\partial \ln p(y/\theta)}{\partial \theta} &= \frac{[-2U^T(y - U\theta)]}{2\sigma^2} \end{aligned}$$

e

$$\begin{aligned} I &= \mathcal{E} \left\{ \frac{\partial \ln p(y/\theta)}{\partial \theta} \right\} \left\{ \frac{\partial \ln p(y/\theta)}{\partial \theta} \right\}^T = \\ &= \frac{1}{\sigma^4} \mathcal{E} \{ U^T (y - U\theta) (y - U\theta)^T U \} \\ &= \frac{1}{\sigma^4} U^T \mathcal{E} v v^T U \\ &= \frac{U^T U}{\sigma^2} \end{aligned}$$

e

$$\text{cov} \hat{\theta} \geq \mathcal{E} [(U^T U)^{-1}] \sigma^2 = \text{cov} \hat{\theta}_{MQ}$$

que é a covariância do estimador dos mínimos quadrados. Portanto o estimador dos mínimos quadrados é eficiente. Este resultado mostra que o estimador dos Mínimos quadrados apresenta a menor variância entre todos os estimadores lineares e não lineares não polarizados, quando a perturbação for Gaussiana e o sistema puder ser descrito pelo modelo  $y(t) = u^T \theta + v(t)$ .

**Teorema 8** *A condição necessária e suficiente para que um estimador não polarizado seja eficaz é que:*

$$M(\theta)[\hat{\theta}_{ef} - \theta] = \left[ \frac{\partial \ln p(y : \theta)}{\partial \theta} \right]^T$$

onde  $M(\theta)$ , independente de  $y$ , é a matriz de informação de Fisher. (Obs: assume-se, sem perda de generalidade, que  $\theta \in R$ .)

b) Estimador Consistente

Um Estimador é consistente se:

$$\lim_{n \rightarrow \infty} P\{\|\hat{\theta}_n - \theta\|^2 = 0\} \rightarrow 1$$

**Teorema 9** *Se existir um estimador  $f(y)$  não polarizado de  $\theta$  que satisfaz o limite de Cramer-Rao, isto é, ele é eficaz, então este estimador também é o estimador de máxima verossimilhança.*

**Teorema 10** *Seja*

$$y = U\theta + v \quad p(v) = N(0, V) \quad y \in \mathfrak{R}^m$$

então o estimador de máxima verossimilhança de  $\theta$  é dado por:

$$\hat{\theta}_{ML} = [U^T V^{-1} U]^{-1} U^T V^{-1} y = \hat{\theta}_{Markov}$$

**Teorema 11** *O estimador de máxima verossimilhança é consistente e normal com densidade dada por  $N(\theta, M^{-1})$*

### 2.5.1 Aplicação em Sistemas Lineares com Ruído Gaussiano

Seja

$$y = Hx + v$$

$$p_0(x) = N(x_0, X_0) \text{ e } p_v(v) = N(0, V)$$

$$\hat{x} = \mathcal{E}(x/y) = x_0 + C_{xy} Y^{-1} (y - \bar{y})$$

$$\begin{aligned}
C_{x/y} &= X - C_{xy}Y^{-1}C_{xy} \\
y &\sim N(Hx_0, HX_0H^T + V) \\
\mathcal{E}(y - \bar{y})(y - \bar{y})^T &= \mathcal{E}((Hx + v - Hx_0)(Hx + v - Hx_0)^T) = \\
&= H\mathcal{E}((x - x_0)(x - x_0)^T)H^T + \mathcal{E}vv^T + H\mathcal{E}(x - x_0)\mathcal{E}v^T + \\
&\quad + \mathcal{E}v\mathcal{E}(x - x_0)^T H^T = \\
&= HX_0H^T + V \\
C_{yx} &= \mathcal{E}(y - \bar{y})(x - x_0)^T = HX_0 \\
C_{xy} &= X_0H^T \\
\hat{x} &= x_0 + X_0H^T(V + HX_0H^T)^{-1}(y - Hx_0) \\
C_{x/y} &= X_0 - X_0H^T(HX_0H^T + V)^{-1}HX_0
\end{aligned}$$

## 2.6 Estimador Linear Seqüencial

Seja o sistema descrito por:

$$\begin{aligned}
y &= \Theta_1u_1 + \Theta_2u_2 + \dots + \Theta_mu_m + v \\
y &= u^T\Theta + v \\
\Theta^T &= [\Theta_1\Theta_2\dots\Theta_m] \\
u^T &= [u_1u_2\dots u_m] \quad v \sim N(0, \sigma_k^2) \\
y_1 &= u_1^T\Theta + v_1 \\
y_2 &= u_2^T\Theta + v_2 \\
&\vdots \\
y_k &= u_k^T\Theta + v_k \\
y_k &= U_k\Theta + v \\
U_k &= \begin{bmatrix} u_1^T \\ u_2^T \\ \vdots \\ u_k^T \end{bmatrix} \quad V_k = \begin{bmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_k^2 \end{bmatrix}
\end{aligned}$$

$$\hat{\Theta}_k = [U_k^T V_k^{-1} U_k]^{-1} U_k^T V_k^{-1} y_k$$

onde o índice  $k$  representa que o estimador é calculado com as medidas disponíveis até o instante  $k$ . Agora deseja-se obter o estimador quando realiza-se uma nova medida, isto é, deseja-se:

$$\begin{aligned} \hat{\Theta}_{k+1} &= f(\hat{\Theta}_k, y_{k+1}) \\ \hat{\Theta}_{k+1} &= [U_{k+1}^T V_{k+1}^{-1} U_{k+1}]^{-1} U_{k+1}^T V_{k+1}^{-1} y_{k+1} \end{aligned}$$

Tem-se que:

$$\begin{aligned} [U_{k+1}^T V_{k+1}^{-1} U_{k+1}]^{-1} &= \left[ [U_k^T : u_{k+1}] \left[ \begin{array}{c|c} V_k & 0 \\ \hline 0 & \sigma_{k+1}^2 \end{array} \right]^{-1} \begin{bmatrix} U_k \\ \vdots \\ u_{k+1}^T \end{bmatrix} \right]^{-1} \\ &= [U_k^T \quad V_k^{-1} \quad U_k + (1/\sigma_{k+1})u_{k+1}u_{k+1}^T]^{-1} \end{aligned}$$

Seja:

$$\begin{aligned} P_{k+1} &= [U_{k+1}^T \quad V_{k+1}^{-1} \quad U_{k+1}]^{-1} \\ P_{k+1} &= [P_k^{-1} + (1/\sigma_{k+1}^2)u_{k+1}u_{k+1}^T]^{-1} \end{aligned}$$

Propriedade:

$$[X^{-1} + H^T V^{-1} H]^{-1} = X - X H^T [H X H^T + V]^{-1} H X$$

Seja  $X = P_k^{-1}$ ;  $H^T = u_{k+1}$  e  $V^{-1} = 1/\sigma_{k+1}^2$  tem-se que:

$$P_{k+1} = P_k - P_k u_{k+1} [u_{k+1}^T P_k u_{k+1} + \sigma_{k+1}^2]^{-1} u_{k+1}^T P_k \quad (2.18)$$

$$\hat{\Theta}_{k+1} = P_{k+1} [U_k^T u_{k+1}] \left[ \begin{array}{c|c} V_k & 0 \\ \hline 0 & \sigma_{k+1}^2 \end{array} \right]^{-1} \begin{bmatrix} \underline{y}_k \\ y_{k+1} \end{bmatrix}$$

$$\hat{\Theta}_{k+1} = P_{k+1} [U_k^T V_k^{-1} \underline{y}_k + u_{k+1} y_{k+1} / \sigma_{k+1}^2]$$

Que resulta em:

$$\begin{aligned} \hat{\Theta}_{k+1} &= \hat{\Theta}_k + K_k \varepsilon_{k+1} \\ K_k &= P_k u_{k+1} / (\sigma_{k+1}^2 + u_{k+1}^T P_k u_{k+1}) \\ P_{k+1} &= P_k - P_k u_{k+1} u_{k+1}^T P_k / (\sigma_{k+1}^2 + u_{k+1}^T P_k u_{k+1}) \\ \varepsilon_{k+1} &= y_{k+1} - u_{k+1}^T \hat{\Theta}_k \end{aligned}$$

O par  $(\hat{\Theta}_k P_k)$  representa o menor número de variáveis caracterizando os dados de entrada-saída que devem ser atualizados a cada nova medida.