



Capítulo 5 - O Estimador de Mínimos Quadrados

Eduardo Mendes

`emmendes@cpdee.ufmg.br`

Departamento de Engenharia Eletrônica
Universidade Federal de Minas Gerais
Av. Antônio Carlos 6627, Belo Horizonte, MG, Brasil



Introdução

- 1) Gauss se refere a um número de observações *estritamente necessário* à determinação das grandezas desconhecidas;



Introdução

- 1) Gauss se refere a um número de observações *estritamente necessário* à determinação das grandezas desconhecidas;
- 2) Gauss deixa claro que, por causa dos erros de medição, mais observações do que o número mínimo são necessárias. O uso dessas observações “redundantes” resultará na redução dos efeitos dos erros;



Introdução

- 1) Gauss se refere a um número de observações *estritamente necessário* à determinação das grandezas desconhecidas;
- 2) Gauss deixa claro que, por causa dos erros de medição, mais observações do que o número mínimo são necessárias. O uso dessas observações “redundantes” resultará na redução dos efeitos dos erros;
- 3) o problema da modelagem está implícito na observação de que o movimento observado satisfaz as leis de Kepler;



Introdução

- 1) Gauss se refere a um número de observações *estritamente necessário* à determinação das grandezas desconhecidas;
- 2) Gauss deixa claro que, por causa dos erros de medição, mais observações do que o número mínimo são necessárias. O uso dessas observações “redundantes” resultará na redução dos efeitos dos erros;
- 3) o problema da modelagem está implícito na observação de que o movimento observado satisfaz as leis de Kepler;
- 4) os parâmetros estimados devem satisfazer as observações da forma mais exata possível. A diferença entre observação e cálculo (usando os parâmetros estimados) deve ser mínima.



Gerando Sistemas de Equações - Sistemas com solução única

- ▶ Seja uma função escalar $y = f(x)$ e várias aplicações da mesma

$$y_1 = f(x_1)$$

$$y_2 = f(x_2)$$

$$\vdots = \vdots$$

$$y_N = f(x_N).$$



Gerando Sistemas de Equações - Sistemas com solução única

- ▶ Seja uma função escalar $y = f(x)$ e várias aplicações da mesma

$$y_1 = f(x_1)$$

$$y_2 = f(x_2)$$

$$\vdots = \vdots$$

$$y_N = f(x_N).$$

- ▶ No caso vetorial, $f(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}$ depende de um vetor de n parâmetros, θ .



Gerando Sistemas de Equações - Sistemas com solução única

- ▶ Seja uma função escalar $y = f(x)$ e várias aplicações da mesma

$$\begin{aligned}y_1 &= f(x_1) \\y_2 &= f(x_2) \\&\vdots = \vdots \\y_N &= f(x_N).\end{aligned}$$

- ▶ No caso vetorial, $f(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}$ depende de um vetor de n parâmetros, θ .
- ▶ Dizemos então que a função $f(\mathbf{x})$ é parametrizada por $\theta \in \mathbb{R}^n$ e pode ser representada da seguinte forma:

$$y = f(\mathbf{x}, \theta).$$



▶ Semelhantemente, tem-se

$$y_1 = f(\mathbf{x}_1, \boldsymbol{\theta})$$

$$y_2 = f(\mathbf{x}_2, \boldsymbol{\theta})$$

$$\vdots = \vdots$$

$$y_N = f(\mathbf{x}_N, \boldsymbol{\theta}).$$

- 
-
- ▶ Semelhantemente, tem-se

$$y_1 = f(\mathbf{x}_1, \boldsymbol{\theta})$$

$$y_2 = f(\mathbf{x}_2, \boldsymbol{\theta})$$

$$\vdots = \vdots$$

$$y_N = f(\mathbf{x}_N, \boldsymbol{\theta}).$$

- ▶ Sendo conhecidos os conjuntos $\{y_1, \dots, y_N\}$ e $\{\mathbf{x}_1, \dots, \mathbf{x}_N\}$, é pertinente perguntar se é possível determinar f e $\boldsymbol{\theta}$.



Considerações

- ▶ A função f e o vetor θ não variam de uma restrição para a outra, ou seja, todas as restrições são de fato da mesma equação.



Considerações

- ▶ A função f e o vetor θ não variam de uma restrição para a outra, ou seja, todas as restrições são de fato da mesma equação.
- ▶ $y = f(\mathbf{x}, \theta)$ pode ser rescrita como

$$y = \mathbf{x}^T \theta.$$



Considerações

- ▶ A função f e o vetor θ não variam de uma restrição para a outra, ou seja, todas as restrições são de fato da mesma equação.
- ▶ $y = f(\mathbf{x}, \theta)$ pode ser reescrita como

$$y = \mathbf{x}^T \theta.$$

- ▶ Serão tomadas n restrições a fim de se ter n equações para determinar os n elementos de θ , ou seja, nesse caso $N = n$.

- 
- Tendo feito tais considerações, pode-se escrever

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} \mathbf{x}_1 & \mathbf{x}_2 & \dots & \mathbf{x}_n \end{bmatrix} \begin{bmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_n \end{bmatrix},$$
$$\mathbf{y} = X \boldsymbol{\theta},$$

sendo $X \in \mathbb{R}^{n \times n}$.

- 
- ▶ Tendo feito tais considerações, pode-se escrever

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = [\mathbf{x}_1 \ \mathbf{x}_2 \ \dots \ \mathbf{x}_n] \begin{bmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_n \end{bmatrix},$$
$$\mathbf{y} = X \boldsymbol{\theta},$$

sendo $X \in \mathbb{R}^{n \times n}$.

- ▶ Se X for não singular, é possível determinar o vetor de parâmetros invertendo tal matriz, ou seja,

$$\boldsymbol{\theta} = X^{-1} \mathbf{y}.$$

Sistema de equações Wiener-Hopf com solução única

- ▶ Neste exemplo, partindo da equação de Wiener-Hopf, será montado e resolvido um sistema de equações com solução única.

$$\begin{bmatrix} r_{uy}(0) \\ r_{uy}(1) \\ \vdots \\ r_{uy}(N-1) \end{bmatrix} = \begin{bmatrix} r_{uu}(0) & r_{uu}(-1) & \dots & r_{uu}(-N+1) \\ r_{uu}(1) & r_{uu}(0) & \dots & r_{uu}(-N+2) \\ \vdots & \vdots & \vdots & \vdots \\ r_{uu}(N-1) & r_{uu}(N-2) & \dots & r_{uu}(0) \end{bmatrix} \begin{bmatrix} h(0) \\ h(1) \\ \vdots \\ h(N-1) \end{bmatrix}$$

$$\mathbf{r}_{uy} = R_{uu} \mathbf{h}.$$

Sistema de equações Wiener-Hopf com solução única

- ▶ Neste exemplo, partindo da equação de Wiener-Hopf, será montado e resolvido um sistema de equações com solução única.

$$\begin{bmatrix} r_{uy}(0) \\ r_{uy}(1) \\ \vdots \\ r_{uy}(N-1) \end{bmatrix} = \begin{bmatrix} r_{uu}(0) & r_{uu}(-1) & \dots & r_{uu}(-N+1) \\ r_{uu}(1) & r_{uu}(0) & \dots & r_{uu}(-N+2) \\ \vdots & \vdots & \vdots & \vdots \\ r_{uu}(N-1) & r_{uu}(N-2) & \dots & r_{uu}(0) \end{bmatrix} \begin{bmatrix} h(0) \\ h(1) \\ \vdots \\ h(N-1) \end{bmatrix}$$

$$\mathbf{r}_{uy} = R_{uu} \mathbf{h}.$$

- ▶ Por construção, a matriz R_{uu} é quadrada, e se ela tiver inversa, tem-se

$$\mathbf{h} = R_{uu}^{-1} \mathbf{r}_{uy}.$$



Sistemas sobredeterminados

Se $N > n$ restrições forem tomadas, tem-se então um sistema de equações sobredeterminado. Como a matriz X não é quadrada, ela não pode ser invertida. Entretanto, pré-multiplicando a equação $\mathbf{y} = X \boldsymbol{\theta}$ por X^T em ambos os lados tem-se

$$X^T \mathbf{y} = X^T X \boldsymbol{\theta},$$

que é chamada de *equação normal* e

$$\boldsymbol{\theta} = [X^T X]^{-1} X^T \mathbf{y},$$

no caso de $X^T X$ não ser singular. A matriz $[X^T X]^{-1} X^T$, na equação acima, é conhecida como a *matriz pseudo-inversa*.



O Método de Mínimos Quadrados

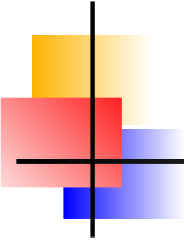
Será assumido que se conhece o valor estimado do vetor de parâmetros, $\hat{\boldsymbol{\theta}}$, e que é cometido um erro ξ , ou seja,

$$y = \mathbf{x}^T \hat{\boldsymbol{\theta}} + \xi.$$

$N > n$ aplicações em forma matricial são

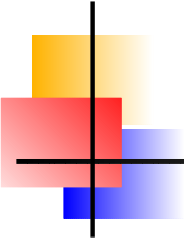
$$\mathbf{y} = X \hat{\boldsymbol{\theta}} + \boldsymbol{\xi},$$

sendo que $\boldsymbol{\xi} \in \mathbb{R}^N$ é o vetor de erros cometidos ao se tentar explicar \mathbf{y} como $X \hat{\boldsymbol{\theta}}$.

- 
- ▶ Intuitivamente, seria interessante que $\hat{\boldsymbol{\theta}}$ fosse tal que reduzisse o somatório do quadrado dos erros

$$J_{\text{MQ}} = \sum_{i=1}^N \xi(i)^2 = \boldsymbol{\xi}^T \boldsymbol{\xi} = \| \boldsymbol{\xi} \|^2 .$$

$$\begin{aligned} J_{\text{MQ}} &= (\mathbf{y} - X \hat{\boldsymbol{\theta}})^T (\mathbf{y} - X \hat{\boldsymbol{\theta}}) \\ &= \mathbf{y}^T \mathbf{y} - \mathbf{y}^T X \hat{\boldsymbol{\theta}} - \hat{\boldsymbol{\theta}}^T X^T \mathbf{y} + \hat{\boldsymbol{\theta}}^T X^T X \hat{\boldsymbol{\theta}} . \end{aligned}$$

- 
- ▶ Intuitivamente, seria interessante que $\hat{\boldsymbol{\theta}}$ fosse tal que reduzisse o somatório do quadrado dos erros

$$J_{\text{MQ}} = \sum_{i=1}^N \xi(i)^2 = \boldsymbol{\xi}^T \boldsymbol{\xi} = \| \boldsymbol{\xi} \|^2 .$$

$$\begin{aligned} J_{\text{MQ}} &= (\mathbf{y} - X \hat{\boldsymbol{\theta}})^T (\mathbf{y} - X \hat{\boldsymbol{\theta}}) \\ &= \mathbf{y}^T \mathbf{y} - \mathbf{y}^T X \hat{\boldsymbol{\theta}} - \hat{\boldsymbol{\theta}}^T X^T \mathbf{y} + \hat{\boldsymbol{\theta}}^T X^T X \hat{\boldsymbol{\theta}} . \end{aligned}$$

- ▶ A fim de minimizar a função de custo J_{MQ} com respeito a $\hat{\boldsymbol{\theta}}$, é necessário resolver $(\partial J_{\text{MQ}} / \partial \hat{\boldsymbol{\theta}}) = 0$. Fazendo-se isso, tem-se

$$\begin{aligned} \frac{\partial J_{\text{MQ}}}{\partial \hat{\boldsymbol{\theta}}} &= -(\mathbf{y}^T X)^T - X^T \mathbf{y} + (X^T X + X^T X) \hat{\boldsymbol{\theta}} \\ &= -X^T \mathbf{y} - X^T \mathbf{y} + 2X^T X \hat{\boldsymbol{\theta}} . \end{aligned}$$

- 
-
- ▶ Igualando-se a última equação a zero tem-se

$$\hat{\theta} = [X^T X]^{-1} X^T \mathbf{y}.$$

- 
-
- ▶ Igualando-se a última equação a zero tem-se

$$\hat{\theta} = [X^T X]^{-1} X^T \mathbf{y}.$$

- ▶ Para que $\hat{\theta}$ seja o mínimo, é necessário verificar que

$$\frac{\partial^2 J_{\text{MQ}}}{\partial \hat{\theta}^2} = 2X^T X > 0.$$

A equação acima é verdadeira, pois $2X^T X$ é positiva definida por construção.

- 
- ▶ Igualando-se a última equação a zero tem-se

$$\hat{\theta} = [X^T X]^{-1} X^T \mathbf{y}.$$

- ▶ Para que $\hat{\theta}$ seja o mínimo, é necessário verificar que

$$\frac{\partial^2 J_{\text{MQ}}}{\partial \hat{\theta}^2} = 2X^T X > 0.$$

A equação acima é verdadeira, pois $2X^T X$ é positiva definida por construção.

- ▶ Resumindo,

$$\begin{aligned} \hat{\theta}_{\text{MQ}} &= \arg_{\theta} \min J_{\text{MQ}} \\ &= [X^T X]^{-1} X^T \mathbf{y}. \end{aligned}$$



Estimação dos parâmetros de uma reta usando MQ

- 1) Determinar uma função f parametrizada por θ .
 $f(x) = \theta_1 + \theta_2 x$ é uma boa função candidata.



Estimação dos parâmetros de uma reta usando MQ

- 1) Determinar uma função f parametrizada por θ .
 $f(x) = \theta_1 + \theta_2 x$ é uma boa função candidata.
- 2) As vinte e uma aplicações podem ser colocadas em formato matricial, da seguinte forma: $\mathbf{y} = X\boldsymbol{\theta}$, sendo $\mathbf{y} \in \mathbb{R}^{21 \times 1}$, $X \in \mathbb{R}^{21 \times 2}$ e $\boldsymbol{\theta} \in \mathbb{R}^{2 \times 1}$.



Estimação dos parâmetros de uma reta usando MQ

- 1) Determinar uma função f parametrizada por θ .
 $f(x) = \theta_1 + \theta_2 x$ é uma boa função candidata.
- 2) As vinte e uma aplicações podem ser colocadas em formato matricial, da seguinte forma: $\mathbf{y} = X\boldsymbol{\theta}$, sendo $\mathbf{y} \in \mathbb{R}^{21 \times 1}$, $X \in \mathbb{R}^{21 \times 2}$ e $\boldsymbol{\theta} \in \mathbb{R}^{2 \times 1}$.
- 3) Usando-se a equação pseudo-inversa chega-se à reta
 $y = -0,9567 \times 10^{-3} + 7,142 \times 10^{-4}x$.





Figura 1: Estimação dos parâmetros de uma reta (x) dados medidos e (–) reta ajustada usando o método MQ .

Relação entre o estimador MQ e funções de correlação

- ▶ Portanto, usando-se o somatório de convolução para definir um sistema de equações, tem-se

$$\begin{bmatrix} y(0) \\ y(1) \\ \vdots \\ y(N-1) \end{bmatrix} = \begin{bmatrix} u(0) & u(-1) & \dots & u(1-n_i) \\ u(1) & u(0) & \dots & u(2-n_i) \\ \vdots & \vdots & \dots & \vdots \\ u(N-1) & u(N-2) & \dots & u(N-n_i) \end{bmatrix} \begin{bmatrix} h(0) \\ h(1) \\ \vdots \\ h(n_i-1) \end{bmatrix}$$

$$\mathbf{y} = \mathbf{U} \mathbf{h}.$$

Relação entre o estimador MQ e funções de correlação

- ▶ Portanto, usando-se o somatório de convolução para definir um sistema de equações, tem-se

$$\begin{bmatrix} y(0) \\ y(1) \\ \vdots \\ y(N-1) \end{bmatrix} = \begin{bmatrix} u(0) & u(-1) & \dots & u(1-n_i) \\ u(1) & u(0) & \dots & u(2-n_i) \\ \vdots & \vdots & \dots & \vdots \\ u(N-1) & u(N-2) & \dots & u(N-n_i) \end{bmatrix} \begin{bmatrix} h(0) \\ h(1) \\ \vdots \\ h(n_i-1) \end{bmatrix}$$

$$\mathbf{y} = \mathbf{U} \mathbf{h}.$$


- ▶ A estimativa usando-se mínimos quadrados é

$$\hat{\mathbf{h}} = [\mathbf{U}^T \mathbf{U}]^{-1} \mathbf{U}^T \mathbf{y}.$$



Desenvolvendo-se a matriz $U^T U$, tem-se

$$U^T U = \begin{bmatrix} u(0) & u(1) & \dots & u(N-1) \\ u(-1) & u(0) & \dots & u(N-2) \\ \vdots & \vdots & \dots & \vdots \\ u(1-n_i) & u(2-n_i) & \dots & u(N-n_i) \end{bmatrix} \times$$
$$\times \begin{bmatrix} u(0) & u(-1) & \dots & u(1-n_i) \\ u(1) & u(0) & \dots & u(2-n_i) \\ \vdots & \vdots & \dots & \vdots \\ u(N-1) & u(N-2) & \dots & u(N-n_i) \end{bmatrix}$$



$$U^T U = \begin{bmatrix}
 \sum_i u(i)^2 & \sum_i u(i)u(i-1) & \dots \\
 \sum_i u(i-1)u(i) & \sum_i u(i-1)^2 & \dots \\
 \vdots & \vdots & \vdots \\
 \sum_i u(i+1-n_i)u(i) & \sum_i u(i+1-n_i)u(i-1) & \dots \\
 \dots & \sum_i u(i)u(i+1-n_i) & \\
 \dots & \sum_i u(i-1)u(i+1-n_i) & \\
 \vdots & \vdots & \\
 \dots & \sum_i u(i+1-n_i)^2 &
 \end{bmatrix} \cdot$$

- 
- ▶ Lembrando-se de que para o caso estacionário

$$r_{uu}(k) = \frac{1}{N} \sum_{i=0}^N u(i)u(i-k) = r_{uu}(-k),$$

$$U^T U = N \begin{bmatrix} r_{uu}(0) & r_{uu}(1) & \dots & r_{uu}(n_i - 1) \\ r_{uu}(1) & r_{uu}(0) & \dots & r_{uu}(n_i - 2) \\ \dots & \dots & \vdots & \dots \\ r_{uu}(n_i - 1) & r_{uu}(n_i - 1) & \dots & r_{uu}(0) \end{bmatrix} = NR_{uu}.$$

- 
- ▶ Lembrando-se de que para o caso estacionário

$$r_{uu}(k) = \frac{1}{N} \sum_{i=0}^N u(i)u(i-k) = r_{uu}(-k),$$

$$U^T U = N \begin{bmatrix} r_{uu}(0) & r_{uu}(1) & \dots & r_{uu}(n_i - 1) \\ r_{uu}(1) & r_{uu}(0) & \dots & r_{uu}(n_i - 2) \\ \dots & \dots & \vdots & \dots \\ r_{uu}(n_i - 1) & r_{uu}(n_i - 1) & \dots & r_{uu}(0) \end{bmatrix} = NR_{uu}.$$

- ▶ De forma análoga, tem-se

$$U^T \mathbf{y} = N \begin{bmatrix} r_{uy}(1) \\ r_{uy}(2) \\ \vdots \\ r_{uy}(n_i) \end{bmatrix} = N\mathbf{r}_{uy}.$$



▶ Portanto,

$$\hat{\mathbf{h}} = \frac{1}{N} R_{uu}^{-1} N \mathbf{r}_{uy}$$

$$\hat{\mathbf{h}} = R_{uu}^{-1} \mathbf{r}_{uy}.$$



$h(k)$ pode ser estimada de duas formas distintas

- 1) calculando-se $r_{uu}(k)$ e $r_{uy}(k)$, que têm boa robustez ao ruído, e resolvendo-se $\hat{\mathbf{h}} = R_{uu}^{-1} \mathbf{r}_{uy}$;



$h(k)$ pode ser estimada de duas formas distintas

- 1) calculando-se $r_{uu}(k)$ e $r_{uy}(k)$, que têm boa robustez ao ruído, e resolvendo-se $\hat{\mathbf{h}} = R_{uu}^{-1} \mathbf{r}_{uy}$;
- 2) usando-se os mesmos sinais de entrada e saída *diretamente* no somatório de convolução, montando-se e resolvendo-se o sistema sobredeterminado de equações resultante usando-se o estimador de mínimos quadrados. Ou seja, $\hat{\mathbf{h}} = [U^T U]^{-1} U^T \mathbf{y}$.



$h(k)$ pode ser estimada de duas formas distintas

- 1) calculando-se $r_{uu}(k)$ e $r_{uy}(k)$, que têm boa robustez ao ruído, e resolvendo-se $\hat{\mathbf{h}} = R_{uu}^{-1} \mathbf{r}_{uy}$;
- 2) usando-se os mesmos sinais de entrada e saída *diretamente* no somatório de convolução, montando-se e resolvendo-se o sistema sobredeterminado de equações resultante usando-se o estimador de mínimos quadrados. Ou seja, $\hat{\mathbf{h}} = [U^T U]^{-1} U^T \mathbf{y}$.

Ou seja

$$\hat{\mathbf{h}} = R_{uu}^{-1} \mathbf{r}_{uy} = [U^T U]^{-1} U^T \mathbf{y}.$$

Portanto, o estimador MQ goza das mesmas propriedades de robustez ao ruído que o método de identificação utilizando as funções de correlação.



Ortogonalidade

- ▶ Se \mathbf{x} , \mathbf{y} e \mathbf{z} forem vetores com a mesma dimensão e $\mathbf{z} = \mathbf{x} + \mathbf{y}$, então

$$\begin{aligned}\|\mathbf{z}\|^2 &= \mathbf{z}^T \mathbf{z} \\ &= (\mathbf{x} + \mathbf{y})^T (\mathbf{x} + \mathbf{y}) \\ &= \mathbf{x}^T \mathbf{x} + \mathbf{x}^T \mathbf{y} + \mathbf{y}^T \mathbf{x} + \mathbf{y}^T \mathbf{y}.\end{aligned}$$



Ortogonalidade

- ▶ Se \mathbf{x} , \mathbf{y} e \mathbf{z} forem vetores com a mesma dimensão e $\mathbf{z} = \mathbf{x} + \mathbf{y}$, então

$$\begin{aligned}\|\mathbf{z}\|^2 &= \mathbf{z}^T \mathbf{z} \\ &= (\mathbf{x} + \mathbf{y})^T (\mathbf{x} + \mathbf{y}) \\ &= \mathbf{x}^T \mathbf{x} + \mathbf{x}^T \mathbf{y} + \mathbf{y}^T \mathbf{x} + \mathbf{y}^T \mathbf{y}.\end{aligned}$$

- ▶ Se \mathbf{x} e \mathbf{y} forem ortogonais, então $\mathbf{x}^T \mathbf{y} = \mathbf{y}^T \mathbf{x} = 0$. Portanto, se $\mathbf{x} \perp \mathbf{y}$, então

$$\begin{aligned}\|\mathbf{z}\|^2 &= \mathbf{x}^T \mathbf{x} + \mathbf{y}^T \mathbf{y} \\ &= \|\mathbf{x}\|^2 + \|\mathbf{y}\|^2,\end{aligned}$$

ou seja, \mathbf{x} não tem componente sobre \mathbf{y} e vice-versa.

- 
- ▶ Será utilizada a seguinte nomenclatura $\hat{\mathbf{y}} = X\hat{\boldsymbol{\theta}}$.

$$\begin{aligned}\hat{\mathbf{y}}^T \boldsymbol{\xi} &= \hat{\boldsymbol{\theta}}_{\text{MQ}}^T X^T (\mathbf{y} - X\hat{\boldsymbol{\theta}}_{\text{MQ}}^T) \\ &= \{[X^T X]^{-1} X^T \mathbf{y}\}^T X^T (\mathbf{y} - X[X^T X]^{-1} X^T \mathbf{y}) \\ &= \mathbf{y}^T X [X^T X]^{-1} X^T (\mathbf{y} - X[X^T X]^{-1} X^T \mathbf{y}) \\ &= \mathbf{y}^T X [X^T X]^{-1} X^T \mathbf{y} - \mathbf{y}^T X [X^T X]^{-1} X^T X [X^T X]^{-1} X^T \mathbf{y} \\ &= 0.\end{aligned}$$

Os vetores $\hat{\mathbf{y}}$ e $\boldsymbol{\xi}$ são ortogonais quando o correspondente vetor de parâmetros é estimado, usando-se o estimador MQ.



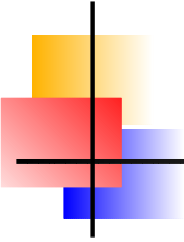
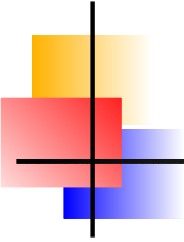


Figura 2: Propriedade de ortogonalidade do estimador de MQ
Representação gráfica da propriedade de ortogonalidade do
estimador MQ, para uma superfície de ordem dois.

- 
-
- ▶ A interpretação da Figura anterior é a seguinte. Dado um vetor de observações \mathbf{y} e uma matriz de regressores, X , o estimador MQ determinará parâmetros que definem $\hat{\mathbf{y}}$ de tal forma que $\hat{\mathbf{y}}$ é a projeção ortogonal de \mathbf{y} sobre a hipersuperfície gerada pelas colunas de X , sendo a matriz de projeção $P(X)$ tal que

$$\hat{\mathbf{y}} = X\hat{\boldsymbol{\theta}} = X[X^T X]^{-1} X^T \mathbf{y} = P(X)\mathbf{y}.$$

- 
- ▶ A interpretação da Figura anterior é a seguinte. Dado um vetor de observações \mathbf{y} e uma matriz de regressores, X , o estimador MQ determinará parâmetros que definem $\hat{\mathbf{y}}$ de tal forma que $\hat{\mathbf{y}}$ é a projeção ortogonal de \mathbf{y} sobre a hipersuperfície gerada pelas colunas de X , sendo a matriz de projeção $P(X)$ tal que

$$\hat{\mathbf{y}} = X\hat{\boldsymbol{\theta}} = X[X^T X]^{-1} X^T \mathbf{y} = P(X)\mathbf{y}.$$

- ▶ Conseqüentemente, parâmetros são estimados de forma que a diferença (distância) entre os dados \mathbf{y} e $\hat{\mathbf{y}}$ é mínima. A equação acima mostra que tanto $\hat{\boldsymbol{\theta}}$ quanto $\hat{\mathbf{y}}$ são lineares nas observações \mathbf{y} .

Ortogonalidade de estimadores do tipo

$$\hat{\theta} = Ay$$

- ▶ O objetivo do presente exemplo é derivar as condições de ortogonalidade para estimadores do tipo $\hat{\theta} = Ay$.

Ortogonalidade de estimadores do tipo

$$\hat{\theta} = Ay$$

- ▶ O objetivo do presente exemplo é derivar as condições de ortogonalidade para estimadores do tipo $\hat{\theta} = Ay$.
- ▶ A condição para que cada regressor seja ortogonal a ξ , é

$$\begin{aligned} X^T \xi &= X^T (\mathbf{y} - \hat{\mathbf{y}}) \\ &= X^T (\mathbf{y} - X\hat{\theta}) \\ &= X^T (\mathbf{y} - XAy) = 0. \end{aligned}$$

Ortogonalidade de estimadores do tipo

$$\hat{\theta} = Ay$$

- ▶ O objetivo do presente exemplo é derivar as condições de ortogonalidade para estimadores do tipo $\hat{\theta} = Ay$.
- ▶ A condição para que cada regressor seja ortogonal a ξ , é

$$\begin{aligned} X^T \xi &= X^T (\mathbf{y} - \hat{\mathbf{y}}) \\ &= X^T (\mathbf{y} - X\hat{\theta}) \\ &= X^T (\mathbf{y} - XAy) = 0. \end{aligned}$$

- ▶ Portanto,

$$X^T X A \mathbf{y} = X^T \mathbf{y}.$$



O estimador de mínimos quadrados ponderados

- ▶ Considere a seguinte função

$$J_{\text{MQP}} = \sum_{i=1}^N \xi(i) w_i \xi(i) = \boldsymbol{\xi}^T \mathbf{W} \boldsymbol{\xi},$$

sendo que $\mathbf{W} \in \mathbb{R}^{N \times N}$ é uma matriz diagonal cujos elementos são os pesos w_i , ou seja, $\mathbf{W} = \text{diag}\{w_1 \ w_2 \ \dots \ w_N\}$.

$$\frac{\partial J_{\text{MQP}}}{\partial \hat{\boldsymbol{\theta}}} = 2(\mathbf{X}^T \mathbf{W} \mathbf{X} \hat{\boldsymbol{\theta}} - \mathbf{X}^T \mathbf{W} \mathbf{y}).$$



O estimador de mínimos quadrados ponderados

- ▶ Considere a seguinte função

$$J_{\text{MQP}} = \sum_{i=1}^N \xi(i) w_i \xi(i) = \boldsymbol{\xi}^T \mathbf{W} \boldsymbol{\xi},$$

sendo que $\mathbf{W} \in \mathbb{R}^{N \times N}$ é uma matriz diagonal cujos elementos são os pesos w_i , ou seja, $\mathbf{W} = \text{diag}\{w_1 \ w_2 \ \dots \ w_N\}$.

$$\frac{\partial J_{\text{MQP}}}{\partial \hat{\boldsymbol{\theta}}} = 2(\mathbf{X}^T \mathbf{W} \mathbf{X} \hat{\boldsymbol{\theta}} - \mathbf{X}^T \mathbf{W} \mathbf{y}).$$

- ▶ Igualando-se a expressão acima a zero e resolvendo-se para $\hat{\boldsymbol{\theta}}$, tem-se

$$\hat{\boldsymbol{\theta}}_{\text{MQP}} = [\mathbf{X}^T \mathbf{W} \mathbf{X}]^{-1} \mathbf{X}^T \mathbf{W} \mathbf{y}.$$



O estimador de mínimos quadrados ponderados

- ▶ Considere a seguinte função

$$J_{\text{MQP}} = \sum_{i=1}^N \xi(i) w_i \xi(i) = \boldsymbol{\xi}^T \mathbf{W} \boldsymbol{\xi},$$

sendo que $\mathbf{W} \in \mathbb{R}^{N \times N}$ é uma matriz diagonal cujos elementos são os pesos w_i , ou seja, $\mathbf{W} = \text{diag}\{w_1 \ w_2 \ \dots \ w_N\}$.

$$\frac{\partial J_{\text{MQP}}}{\partial \hat{\boldsymbol{\theta}}} = 2(\mathbf{X}^T \mathbf{W} \mathbf{X} \hat{\boldsymbol{\theta}} - \mathbf{X}^T \mathbf{W} \mathbf{y}).$$

- ▶ Igualando-se a expressão acima a zero e resolvendo-se para $\hat{\boldsymbol{\theta}}$, tem-se

$$\hat{\boldsymbol{\theta}}_{\text{MQP}} = [\mathbf{X}^T \mathbf{W} \mathbf{X}]^{-1} \mathbf{X}^T \mathbf{W} \mathbf{y}.$$

- ▶ Se \mathbf{W} for semidefinida positiva, então $\mathbf{X}^T \mathbf{W} \mathbf{X}$ também o será e existirá a inversa.



Estimação dos parâmetros de uma reta usando MQP

No presente exemplo será considerado o mesmo problema do exemplo **da reta** e a mesma massa de dados. Serão atribuídos pesos diferentes às observações 9, 10 e 11.

$$W = \text{diag} [w_1 \dots w_{21}],$$

sendo $w_i = a$, $i = 1, \dots, 8, 12, \dots, 21$ e $w_i = b$, $i = 9, 10, 11$. Dois casos foram calculados. No primeiro $b = 100a$ e no segundo $b = 1000a$.




Figura 3: Estimação dos parâmetros de uma reta usando MQP (x) dados medidos, e retas ajustadas usando o estimador MQP com (—) $b = 100a$ e (- · -) $b = 1000a$. As três observações que receberam peso diferenciado estão indicadas \otimes .



O estimador MQP sem a propriedade de ortogonalidade

- ▶ É interessante notar que o estimador MQP é um estimador linear do tipo $\hat{\boldsymbol{\theta}} = A\mathbf{y}$, com $A = [X^T W X]^{-1} X^T W$. Para esse estimador tem-se

$$\begin{aligned} X^T X A \mathbf{y} &\stackrel{?}{=} X^T \mathbf{y} \\ X^T X [X^T W X]^{-1} X^T W \mathbf{y} &\stackrel{?}{=} X^T \mathbf{y}, \end{aligned} \quad (-39)$$

sendo que a condição não é satisfeita para o estimador MQP.



O estimador MQP sem a propriedade de ortogonalidade

- ▶ É interessante notar que o estimador MQP é um estimador linear do tipo $\hat{\theta} = Ay$, com $A = [X^T W X]^{-1} X^T W$. Para esse estimador tem-se

$$\begin{aligned} X^T X A y &\stackrel{?}{=} X^T y \\ X^T X [X^T W X]^{-1} X^T W y &\stackrel{?}{=} X^T y, \end{aligned} \quad (-38)$$

sendo que a condição não é satisfeita para o estimador MQP.

- ▶ Percebe-se que na equação acima seria errado fazer o seguinte:

$$\cancel{X}^T X [X^T W X]^{-1} X^T W y = \cancel{X}^T y, \quad (-39)$$

uma vez que isso equivaleria a dividir ambos os lados da equação por X^T , o que é uma impossibilidade, pois X não é uma matriz quadrada.



Estimação de Parâmetros de Modelos ARX Usando MQ

- ▶ Será comum representar o modelo como

$$y(k | \hat{\theta}) = \psi^T(k-1) \hat{\theta} + \xi(k),$$

sendo que k indica o instante considerado e $\psi(k-1)$ é um vetor de $n_\theta = \dim[\hat{\theta}]$ variáveis regressoras,

$$\psi(k-1) = [\psi_1 \ \psi_2 \ \dots \ \psi_{n_\theta}]^T,$$

tomadas até o instante $k-1$.



Estimação de Parâmetros de Modelos ARX Usando MQ

- ▶ Será comum representar o modelo como

$$y(k | \hat{\theta}) = \psi^T(k-1) \hat{\theta} + \xi(k),$$

sendo que k indica o instante considerado e $\psi(k-1)$ é um vetor de $n_\theta = \dim[\hat{\theta}]$ variáveis regressoras,

$$\psi(k-1) = [\psi_1 \ \psi_2 \ \dots \ \psi_{n_\theta}]^T,$$

tomadas até o instante $k-1$.

- ▶ Será comum representar um conjunto de equações gerado a partir de um modelo dinâmico como

$$\mathbf{y} = \Psi \hat{\theta} + \xi.$$

- 
-
- ▶ Portanto, a função custo para modelos ARX pode ser expressa de forma detalhada como se segue:

$$J_{\text{MQ}} = \sum_{k=1}^N \xi(k | k-1, \hat{\boldsymbol{\theta}})^2 = \boldsymbol{\xi}^T \boldsymbol{\xi} = \| \boldsymbol{\xi} \|^2 .$$

- 
- ▶ Portanto, a função custo para modelos ARX pode ser expressa de forma detalhada como se segue:

$$J_{\text{MQ}} = \sum_{k=1}^N \xi(k | k-1, \hat{\boldsymbol{\theta}})^2 = \boldsymbol{\xi}^T \boldsymbol{\xi} = \| \boldsymbol{\xi} \|^2 .$$

- ▶ Os estimadores MQ e MQP podem ser representados, respectivamente, como

$$\hat{\boldsymbol{\theta}}_{\text{MQ}} = [\boldsymbol{\Psi}^T \boldsymbol{\Psi}]^{-1} \boldsymbol{\Psi}^T \mathbf{y}$$

e

$$\hat{\boldsymbol{\theta}}_{\text{MQP}} = [\boldsymbol{\Psi}^T \mathbf{W} \boldsymbol{\Psi}]^{-1} \boldsymbol{\Psi}^T \mathbf{W} \mathbf{y} .$$

- 
- ▶ Essas equações podem ser rescritas da seguinte forma:

$$\hat{\boldsymbol{\theta}}_{\text{MQ}} = \left[\frac{1}{N} \sum_{k=1}^N \boldsymbol{\psi}(k-1) \boldsymbol{\psi}^T(k-1) \right]^{-1} \left[\frac{1}{N} \sum_{k=1}^N \boldsymbol{\psi}(k-1) y(k) \right],$$

- 
- ▶ Essas equações podem ser rescritas da seguinte forma:

$$\hat{\boldsymbol{\theta}}_{\text{MQ}} = \left[\frac{1}{N} \sum_{k=1}^N \boldsymbol{\psi}(k-1) \boldsymbol{\psi}^T(k-1) \right]^{-1} \left[\frac{1}{N} \sum_{k=1}^N \boldsymbol{\psi}(k-1) y(k) \right],$$

- ▶ e

$$\hat{\boldsymbol{\theta}}_{\text{MQP}} = \left[\frac{1}{N} \sum_{k=1}^N w_k \boldsymbol{\psi}(k-1) \boldsymbol{\psi}^T(k-1) \right]^{-1} \left[\frac{1}{N} \sum_{k=1}^N w_k \boldsymbol{\psi}(k-1) y(k) \right]$$

para $W = \text{diag}[w_1 \dots w_N]$ diagonal.



Estimação de parâmetros de um modelo ARX

▶ Seja o modelo

$$y(k) = 1,7649y(k-1) - 0,8027y(k-2) + 0,8661u(k-3) \\ - 0,73578u(k-1) + 0,07513u(k-2) + \xi(k).$$



Estimação de parâmetros de um modelo ARX

- ▶ Seja o modelo

$$y(k) = 1,7649y(k-1) - 0,8027y(k-2) + 0,8661u(k-3) \\ - 0,73578u(k-1) + 0,07513u(k-2) + \xi(k).$$

- ▶ Sejam os dados

$$y(k) = [12,2 \ 11,8 \ 11,6 \ 11,6 \ 11,8 \ 12,2 \ 13,0 \ 14,4 \ 16,2 \ 15,8] \\ u(k) = [2,50 \ 2,50 \ 2,50 \ 2,50 \ 2,50 \ 2,23 \ 2,20 \ 2,20 \ 2,21 \ 2,20].$$



Estimação de parâmetros de um modelo ARX

- ▶ Seja o modelo

$$y(k) = 1,7649y(k-1) - 0,8027y(k-2) + 0,8661u(k-3) \\ - 0,73578u(k-1) + 0,07513u(k-2) + \xi(k).$$

- ▶ Sejam os dados

$$y(k) = [12,2 \ 11,8 \ 11,6 \ 11,6 \ 11,8 \ 12,2 \ 13,0 \ 14,4 \ 16,2 \ 15,8] \\ u(k) = [2,50 \ 2,50 \ 2,50 \ 2,50 \ 2,50 \ 2,23 \ 2,20 \ 2,20 \ 2,21 \ 2,20].$$

- ▶ O vetor de regressores é

$$\psi(k-1) = [y(k-1) \ y(k-2) \ u(k-3) \ u(k-1) \ u(k-2)]^T,$$

- 
- e gera o seguinte conjunto de restrições ao longo dos dados acima:

$$\begin{bmatrix} 11,6 \\ 11,8 \\ 12,2 \\ 13,0 \\ 14,4 \\ 16,2 \\ 15,8 \end{bmatrix} = \begin{bmatrix} 11,6 & 11,8 & 2,50 & 2,50 & 2,50 \\ 11,6 & 11,6 & 2,50 & 2,50 & 2,50 \\ 11,8 & 11,6 & 2,50 & 2,50 & 2,50 \\ 12,2 & 11,8 & 2,50 & 2,23 & 2,50 \\ 13,0 & 12,2 & 2,50 & 2,20 & 2,23 \\ 14,4 & 13,0 & 2,23 & 2,20 & 2,20 \\ 16,2 & 14,4 & 2,20 & 2,21 & 2,20 \end{bmatrix} \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \\ \theta_4 \\ \theta_5 \end{bmatrix} .$$



▶ Usando-se a pseudo-inversa, obtém-se

$$\begin{bmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \\ \hat{\theta}_3 \\ \hat{\theta}_4 \\ \hat{\theta}_5 \end{bmatrix} = \begin{bmatrix} 3,4167 \\ -3,4799 \\ 4,7104 \\ 1,0410 \\ -0,6832 \end{bmatrix} .$$



▶ Usando-se a pseudo-inversa, obtém-se

$$\begin{bmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \\ \hat{\theta}_3 \\ \hat{\theta}_4 \\ \hat{\theta}_5 \end{bmatrix} = \begin{bmatrix} 3,4167 \\ -3,4799 \\ 4,7104 \\ 1,0410 \\ -0,6832 \end{bmatrix} .$$

▶

$$\begin{aligned} \xi &= \mathbf{y} - \Psi \hat{\boldsymbol{\theta}} \\ &= [0,3584 \quad -0,1376 \quad -0,4209 \quad -0,0106 \quad -0,1052 \quad 0,9467 \quad -0,6006]^T \end{aligned}$$

$$\begin{aligned} \Psi^T \xi &= [\psi_1^T \xi \quad \psi_2^T \xi \quad \psi_3^T \xi \quad \psi_4^T \xi \quad \psi_5^T \xi]^T \\ &= [0,1661 \quad 0,1574 \quad 0,0306 \quad 0,0296 \quad 0,0301]^T \times 10^{-8} . \end{aligned}$$



Estimação de parâmetros de um modelo contínuo no tempo

- ▶ Este exemplo é análogo ao anterior, porém o modelo usado é contínuo no tempo.



Estimação de parâmetros de um modelo contínuo no tempo

- ▶ Este exemplo é análogo ao anterior, porém o modelo usado é contínuo no tempo.
- ▶ Considere o circuito elétrico descrito por:

$$\begin{aligned}v(t) &= LC\ddot{v}_c(t) + RC\dot{v}_c(t) + v_c(t) \\ \frac{1}{C}v_c(t) &= \frac{1}{C}v(t) - L\ddot{v}_c(t) - R\dot{v}_c(t)\end{aligned}\quad (-56)$$



Estimação de parâmetros de um modelo contínuo no tempo

- ▶ Este exemplo é análogo ao anterior, porém o modelo usado é contínuo no tempo.
- ▶ Considere o circuito elétrico descrito por:

$$\begin{aligned}v(t) &= LC\ddot{v}_c(t) + RC\dot{v}_c(t) + v_c(t) \\ \frac{1}{C}v_c(t) &= \frac{1}{C}v(t) - L\ddot{v}_c(t) - R\dot{v}_c(t)\end{aligned}\quad (-57)$$

- ▶ o modelo foi simulado $C = 0,8$, $L = 0,5$, $R = 0,2$ e o sinal de entrada é um PRBS.

- 
- ▶ O vetor de regressores e o vetor de parâmetros do modelo são, respectivamente

$$\phi(t) = [v(t) - \ddot{v}_c(t) - \dot{v}_c(t)]^T$$

e

$$\theta = \begin{bmatrix} \frac{1}{C} \\ L \\ R \end{bmatrix}$$

- 
- ▶ O vetor de regressores e o vetor de parâmetros do modelo são, respectivamente

$$\phi(t) = [v(t) - \ddot{v}_c(t) - \dot{v}_c(t)]^T$$

e

$$\theta = \begin{bmatrix} \frac{1}{C} \\ L \\ R \end{bmatrix}$$

- ▶ Obtém-se, então

$$\begin{bmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \\ \hat{\theta}_3 \end{bmatrix} = \begin{bmatrix} 1,25 \\ 0,5 \\ 0,2 \end{bmatrix}$$



A qualidade dos resultados obtidos é devido a dois fatores:

- ▶ Nenhum ruído foi adicionado aos dados



A qualidade dos resultados obtidos é devido a dois fatores:

- ▶ Nenhum ruído foi adicionado aos dados
- ▶ As derivadas do sinal $v_c(t)$ não foram estimadas, mas calculadas utilizando-se as seguintes equações do circuito:

$$\dot{v}_c(t) = \frac{1}{C}i(t)$$

$$\ddot{v}_c(t) = \frac{1}{C} \frac{di(t)}{dt}$$

$$\frac{di(t)}{dt} = -\frac{R}{L}i(t) - \frac{1}{L}v_c(t) + \frac{1}{L}v(t)$$



A qualidade dos resultados obtidos é devido a dois fatores:

- ▶ Nenhum ruído foi adicionado aos dados
- ▶ As derivadas do sinal $v_c(t)$ não foram estimadas, mas calculadas utilizando-se as seguintes equações do circuito:

$$\dot{v}_c(t) = \frac{1}{C}i(t)$$

$$\ddot{v}_c(t) = \frac{1}{C} \frac{di(t)}{dt}$$

$$\frac{di(t)}{dt} = -\frac{R}{L}i(t) - \frac{1}{L}v_c(t) + \frac{1}{L}v(t)$$

A estimação das derivadas é normalmente numérica.