



Capítulo 6 - Propriedades Estatísticas de Estimadores

Eduardo Mendes

`emmendes@cpdee.ufmg.br`

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



Introdução

Seja o sinal medido a superposição do sinal ideal com o ruído

$$y(k) = y^i(k) + e(k).$$

Após vários testes, ainda que $y^i(k)$ permaneça o mesmo, é de se esperar que parâmetros estimados usando-se $y(k)$ também variem. Se tais parâmetros forem considerados como variáveis aleatórias, quais seriam as suas características estatísticas?



Polarização de Estimadores — Conceitos

A polarização (*bias*) é definida como

$$\mathbf{b} = \mathbb{E}[\hat{\boldsymbol{\theta}}] - \boldsymbol{\theta}.$$



Polarização de um estimador de ganho

► Considere

$$y(k) = Ku(k) + e(k), \quad k = 1, 2, \dots, N,$$

sendo que $u(k)$ é a entrada do sistema e K é o ganho.



Polarização de um estimador de ganho

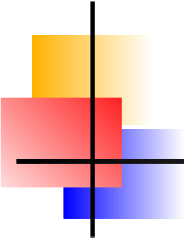
- ▶ Considere

$$y(k) = Ku(k) + e(k), \quad k = 1, 2, \dots, N,$$

sendo que $u(k)$ é a entrada do sistema e K é o ganho.

- ▶ Supondo que o ruído não afete a entrada $u(k)$, uma forma de se estimar o ganho K a partir dos dados de entrada e saída do sistema é calcular

$$\hat{K} = \frac{1}{N} \left(\sum_{k=1}^N \frac{y(k)}{u(k)} \right).$$

- 
- ▶ A polarização deste estimador pode ser determinada a partir da definição como se segue:

$$\begin{aligned} b &= \mathbb{E}[\hat{K}] - K = \frac{1}{N} \sum_{k=1}^N \left(\frac{\mathbb{E}[Ku(k) + e(k)]}{u(k)} \right) - K \\ &= \frac{1}{N} \sum_{k=1}^N \left(K + \frac{\mathbb{E}[e(k)]}{u(k)} \right) - K \\ &= \frac{1}{N} \sum_{k=1}^N \overline{\frac{e(k)}{u(k)}}. \end{aligned}$$



Polarização - modelo $y(k) = \psi^T(k-1)\theta + e(k)$

- ▶ Será considerada a polarização do estimador do vetor de parâmetros de um modelo do tipo $y(k) = \psi^T(k-1)\theta + e(k)$, que é linear em θ . Um modelo deste tipo gera um conjunto de equações do tipo $\mathbf{y} = \Psi\theta + \mathbf{e}$, e

$$\hat{\theta} = A\mathbf{y},$$

sendo que Ψ é a chamada *matriz de regressores* e A é uma matriz cujos elementos dependem dos regressores.



Polarização - modelo $y(k) = \psi^T(k-1)\theta + e(k)$

- ▶ Será considerada a polarização do estimador do vetor de parâmetros de um modelo do tipo $y(k) = \psi^T(k-1)\theta + e(k)$, que é linear em θ . Um modelo deste tipo gera um conjunto de equações do tipo $\mathbf{y} = \Psi\theta + \mathbf{e}$, e

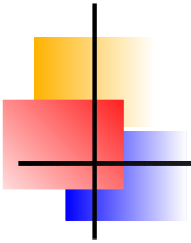
$$\hat{\theta} = A\mathbf{y},$$

sendo que Ψ é a chamada *matriz de regressores* e A é uma matriz cujos elementos dependem dos regressores.

- ▶ Então, tem-se

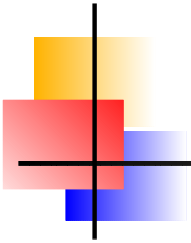
$$\begin{aligned}\mathbf{b} &= \mathbf{E}[A\mathbf{y}] - \theta, \\ &= \mathbf{E}[A(\Psi\theta + \mathbf{e})] - \theta, \\ &= \mathbf{E}[(A\Psi - I)\theta] + \mathbf{E}[A\mathbf{e}], \\ &= \mathbf{E}[A\Psi - I]\theta + \mathbf{E}[A\mathbf{e}],\end{aligned}$$

sendo que θ foi considerado determinístico.



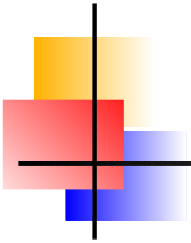
Para que a polarização seja nula ($\mathbf{b} = 0$) as seguintes considerações precisam ser satisfeitas:

1) A matriz A deve ser tal que $A\Psi = I$.



Para que a polarização seja nula ($\mathbf{b} = 0$) as seguintes considerações precisam ser satisfeitas:

- 1) A matriz A deve ser tal que $A\Psi = I$.
- 2) Os elementos de A não estão correlacionados com o vetor de erro \mathbf{e} , logo $E[A\mathbf{e}] = E[A]E[\mathbf{e}]$.



Para que a polarização seja nula ($\mathbf{b} = 0$) as seguintes considerações precisam ser satisfeitas:

- 1) A matriz A deve ser tal que $A\Psi = I$.
- 2) Os elementos de A não estão correlacionados com o vetor de erro \mathbf{e} , logo $E[A\mathbf{e}] = E[A]E[\mathbf{e}]$.
- 3) O erro deve ter média zero, isto é, $E[\mathbf{e}] = 0$.



Polarização do Estimador MQ

- ▶ O estimador de mínimos quadrados é um estimador linear do tipo $\hat{\theta} = Ay$, sendo que

$$A = [\Psi^T \Psi]^{-1} \Psi^T.$$



Polarização do Estimador MQ

- ▶ O estimador de mínimos quadrados é um estimador linear do tipo $\hat{\theta} = Ay$, sendo que

$$A = [\Psi^T \Psi]^{-1} \Psi^T.$$

- ▶ A condição mais relevante para o estimador de mínimos quadrados é a **7-a**.



Polarização do Estimador MQ

- ▶ O estimador de mínimos quadrados é um estimador linear do tipo $\hat{\theta} = Ay$, sendo que

$$A = [\Psi^T \Psi]^{-1} \Psi^T.$$

- ▶ A condição mais relevante para o estimador de mínimos quadrados é a **7-a**.



Polarização do estimador de MQP

Usando a definição de polarização

$$\begin{aligned}\mathbf{b} &= \mathbf{E}[\hat{\boldsymbol{\theta}}_{\mathbf{w}}] - \boldsymbol{\theta}, \\ &= \mathbf{E}[A_{\mathbf{w}}\mathbf{y}] - \boldsymbol{\theta}, \\ &= \mathbf{E}[A_{\mathbf{w}}(\Psi\boldsymbol{\theta} + \mathbf{e})] - \boldsymbol{\theta}, \\ &= \mathbf{E}[(A_{\mathbf{w}}\Psi - I)\boldsymbol{\theta}] + \mathbf{E}[A_{\mathbf{w}}\mathbf{e}], \\ &= \mathbf{E}[A_{\mathbf{w}}\Psi - I]\boldsymbol{\theta} + \mathbf{E}[A_{\mathbf{w}}\mathbf{e}],\end{aligned}$$

sendo que $A_{\mathbf{w}} = [\Psi^T W \Psi]^{-1} \Psi^T W$ e W é uma matriz de pesos constantes. As mesmas considerações 7 a 7-a, mas com $A = A_{\mathbf{w}}$, devem ser satisfeitas para garantir que o vetor de parâmetros estimados, $\hat{\boldsymbol{\theta}}_{\mathbf{w}}$, seja não polarizado.



Uma interpretação de polarização

- ▶ Se o estimador MQ for usado, o vetor de resíduos será,
 $\xi = \mathbf{y} - \hat{\mathbf{y}} = \mathbf{y} - \Psi \hat{\boldsymbol{\theta}}_{\text{MQ}}$. Logo,

$$\begin{aligned}\xi &= \mathbf{y} - \Psi \hat{\boldsymbol{\theta}}_{\text{MQ}} \\ &= \Psi \boldsymbol{\theta} + \mathbf{e} - \Psi \hat{\boldsymbol{\theta}}_{\text{MQ}} \\ &= \Psi(\boldsymbol{\theta} - \hat{\boldsymbol{\theta}}_{\text{MQ}}) + \mathbf{e}.\end{aligned}$$



Uma interpretação de polarização

- ▶ Se o estimador MQ for usado, o vetor de resíduos será, $\xi = \mathbf{y} - \hat{\mathbf{y}} = \mathbf{y} - \Psi \hat{\boldsymbol{\theta}}_{\text{MQ}}$. Logo,

$$\begin{aligned}\xi &= \mathbf{y} - \Psi \hat{\boldsymbol{\theta}}_{\text{MQ}} \\ &= \Psi \boldsymbol{\theta} + \mathbf{e} - \Psi \hat{\boldsymbol{\theta}}_{\text{MQ}} \\ &= \Psi(\boldsymbol{\theta} - \hat{\boldsymbol{\theta}}_{\text{MQ}}) + \mathbf{e}.\end{aligned}$$

- ▶ Os resíduos são ortogonais aos regressores, portanto

$$\begin{aligned}\Psi^T \xi &= \mathbf{0} \\ &= \Psi^T \Psi(\boldsymbol{\theta} - \hat{\boldsymbol{\theta}}_{\text{MQ}}) + \Psi^T \mathbf{e},\end{aligned}$$

e

$$\begin{aligned}\Psi^T \mathbf{e} &= \Psi^T \Psi(\hat{\boldsymbol{\theta}}_{\text{MQ}} - \boldsymbol{\theta}) \\ \mathbf{E}[\Psi^T \mathbf{e}] &= \mathbf{E}[\Psi^T \Psi(\hat{\boldsymbol{\theta}}_{\text{MQ}} - \boldsymbol{\theta})] \\ &= \Psi^T \Psi \mathbf{E}[(\hat{\boldsymbol{\theta}}_{\text{MQ}} - \boldsymbol{\theta})],\end{aligned}$$



▶ de onde vem que

$$\mathbf{b}_{MQ} = [\Psi^T \Psi]^{-1} \mathbf{E}[\Psi^T \mathbf{e}].$$



▶ de onde vem que

$$\mathbf{b}_{MQ} = [\Psi^T \Psi]^{-1} \mathbf{E}[\Psi^T \mathbf{e}].$$

▶ É necessário que o vetor de erro seja ortogonal à hipersuperfície gerada pelos regressores
 $\Psi^T \mathbf{e} = \mathbf{0}$.



Polarização devida à tendência

- ▶ Seja $y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k)$. Supondo-se que o erro seja

$$e(k) = \alpha k + \beta + \nu(k),$$

sendo que $\nu(k)$ é uma variável aleatória não autocorrelacionada (ruído branco) e α e β são constantes. Portanto, $e(k)$ não tem média nula.



Polarização devida à tendência

- ▶ Seja $y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k)$. Supondo-se que o erro seja

$$e(k) = \alpha k + \beta + \nu(k),$$

sendo que $\nu(k)$ é uma variável aleatória não autocorrelacionada (ruído branco) e α e β são constantes. Portanto, $e(k)$ não tem média nula.

- ▶ O valor da saída medido no instante k é

$$y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + \alpha k + \beta + \nu(k).$$



Polarização devida à tendência

- ▶ Seja $y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k)$. Supondo-se que o erro seja

$$e(k) = \alpha k + \beta + \nu(k),$$

sendo que $\nu(k)$ é uma variável aleatória não autocorrelacionada (ruído branco) e α e β são constantes. Portanto, $e(k)$ não tem média nula.

- ▶ O valor da saída medido no instante k é

$$y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + \alpha k + \beta + \nu(k).$$

- ▶ Suponha que um dos regressores seja $y(k-1)$. Por comparação com o caso anterior, tem-se

$$y(k-1) = \boldsymbol{\psi}^T(k-2)\boldsymbol{\theta} + e(k-1),$$



▶ mas há uma relação clara entre $e(k)$ e $e(k - 1)$ que é

$$\begin{aligned}e(k - 1) &= \alpha[k - 1] + \beta + \nu(k - 1) \\ &= \alpha k + \beta + \nu(k) + \nu(k - 1) - \alpha - \nu(k) \\ &= e(k) + \nu(k - 1) - \alpha - \nu(k).\end{aligned}$$

- 
-
- ▶ mas há uma relação clara entre $e(k)$ e $e(k - 1)$ que é

$$\begin{aligned}e(k - 1) &= \alpha[k - 1] + \beta + \nu(k - 1) \\ &= \alpha k + \beta + \nu(k) + \nu(k - 1) - \alpha - \nu(k) \\ &= e(k) + \nu(k - 1) - \alpha - \nu(k).\end{aligned}$$

- ▶ O regressor $y(k - 1)$ está correlacionado com $e(k)$, logo, $E[\Psi^T \mathbf{e}] \neq 0$.

Sinais reais com tendência




Figura 1: Sinais reais com tendência Série de saturação de oxigênio dissolvido no sangue de um humano. A escala vertical está em unidades arbitrárias





Figura 2: Sinais reais com tendência - Série de vazão de ar numa planta piloto de flotação em coluna.



Polarização em modelos ARX

▶ Seja um modelo ARX

$$\begin{aligned}\boldsymbol{\psi}^T(k-1) &= [y(k-1) \dots y(k-n_y) \ u(k-1) \dots u(k-n_u)] \\ \boldsymbol{\theta} &= [a_1 \dots a_{n_y} \ b_1 \dots b_{n_u}]^T.\end{aligned}$$



Polarização em modelos ARX

- ▶ Seja um modelo ARX

$$\begin{aligned}\boldsymbol{\psi}^T(k-1) &= [y(k-1) \dots y(k-n_y) \ u(k-1) \dots u(k-n_u)] \\ \boldsymbol{\theta} &= [a_1 \dots a_{n_y} \ b_1 \dots b_{n_u}]^T.\end{aligned}$$

- ▶ Aplicando-se o modelo acima ao longo dos dados, gera-se a equação matricial $\mathbf{y} = \boldsymbol{\Psi}\boldsymbol{\theta} + \boldsymbol{\nu}$. A condição para que o estimador MQ seja não polarizado é que os regressores e $\boldsymbol{\nu}$ não sejam correlacionados.



É conveniente escrever o modelo na forma

$$F(q)y(k) = B(q)u(k) + e(k),$$

sendo que $e(k) = F(q)\nu(k)$ e $\nu(k)$ é branco.

- ▶ A menos que $F(q) = 1$, $e(k)$ não será ruído branco.



É conveniente escrever o modelo na forma

$$F(q)y(k) = B(q)u(k) + e(k),$$

sendo que $e(k) = F(q)\nu(k)$ e $\nu(k)$ é branco.

- ▶ A menos que $F(q) = 1$, $e(k)$ não será ruído branco.
- ▶ Em modelos ARX erros de regressão brancos não resultam em polarização do estimador MQ.



É conveniente escrever o modelo na forma

$$F(q)y(k) = B(q)u(k) + e(k),$$

sendo que $e(k) = F(q)\nu(k)$ e $\nu(k)$ é branco.

- ▶ A menos que $F(q) = 1$, $e(k)$ não será ruído branco.
- ▶ Em modelos ARX erros de regressão brancos não resultam em polarização do estimador MQ.
- ▶ Ao passo que a adição de ruído branco em modelos de erro na saída (ruído de medição) acarreta em polarização do estimador de MQ.



Polarização em modelos de erro na saída e ARX

- ▶ O modelo ARX simulado foi

$$y(k) = 1,5y(k-1) - 0,7y(k-2) + 0,5u(k-1) + \nu(k),$$

sendo que $u(k)$ e $\nu(k)$ são sinais aleatórios com distribuição normal, média nula e variâncias $\sigma_u^2 = 1$ e $\sigma_\nu^2 = 0,04$.



Polarização em modelos de erro na saída e ARX

- ▶ O modelo ARX simulado foi

$$y(k) = 1,5y(k-1) - 0,7y(k-2) + 0,5u(k-1) + \nu(k),$$

sendo que $u(k)$ e $\nu(k)$ são sinais aleatórios com distribuição normal, média nula e variâncias $\sigma_u^2 = 1$ e $\sigma_\nu^2 = 0,04$.

- ▶ O modelo de erro na saída usado foi

$$\begin{aligned}w(k) &= 1,5w(k-1) - 0,7w(k-2) + 0,5u(k-1) \\y(k) &= w(k) + \nu(k),\end{aligned}$$

sendo $u(k)$ e $\nu(k)$ definidos da mesma forma que para o modelo ARX.

- 
-
- ▶ Observar que a simulação do modelo de erro na saída corresponde a simular a função de transferência

$$G(q) = \frac{B(q)}{F(q)} = \frac{0,5q^{-1}}{1 - 1,5q^{-1} + 0,7q^{-2}},$$

excitada pela entrada $u(k)$, gerando assim $w(k)$ e posteriormente acrescentar o ruído $\nu(k)$, ponto a ponto.





Figura 3: Polarização em modelos de erro na saída e ARX - Histogramas de parâmetros estimados usando-se o estimador MQ. Os gráficos (a), (b) e (c) se referem ao modelo de erro na saída e os gráficos (d), (e) e (f) se referem ao modelo ARX. Os valores reais dos parâmetros são: (a) e (d) $\theta_1 = 1,5$; (b) e (e) $\theta_2 = -0,7$ e (c) e (f) $\theta_3 = 0,5$.





Figura 4: Polarização em modelo erro na saída - $\theta_1 = 1,5$





Figura 5: Polarização em modelo ARX - $\theta_1 = 1,5$





Figura 6: Polarização em modelo erro na saída - $\theta_2 = -0,7$





Figura 7: Polarização em modelo ARX - $\theta_2 = -0,7$





Figura 8: Polarização em modelo erro na saída - $\theta_3 = 0,5$





Figura 9: Polarização em modelo ARX - $\theta_3 = 0,5$



Polarização devida a ruído AR e regressores $y(k - i)$

Seja o modelo ARX

$$y(k) = a y(k - 1) + b u(k - 1) + e(k)$$

com

$$e(k) = c e(k - 1) + \nu(k),$$

sendo que $r_{\nu\nu}(\tau) = 0, \forall \tau \neq 0$.

▶ Tem-se então

$$y(k) = a y(k - 1) + b u(k - 1) + c e(k - 1) + \nu(k)$$



Polarização devida a ruído AR e regressores $y(k - i)$

Seja o modelo ARX

$$y(k) = a y(k - 1) + b u(k - 1) + e(k)$$

com

$$e(k) = c e(k - 1) + \nu(k),$$

sendo que $r_{\nu\nu}(\tau) = 0, \forall \tau \neq 0$.

▶ Tem-se então

$$y(k) = a y(k - 1) + b u(k - 1) + c e(k - 1) + \nu(k)$$

▶ e

$$y(k - 1) = a y(k - 2) + b u(k - 2) + e(k - 1).$$



▶ Fazendo-se substituições, obtém-se

$$y(k) = \left\{ a[a y(k-2) + b u(k-2) + \underline{e(k-1)}] + b u(k-1) \right\} \\ + \underline{c e(k-1)} + \nu(k).$$

- 
-
- ▶ Fazendo-se substituições, obtém-se

$$y(k) = \left\{ a[a y(k-2) + b u(k-2) + \underline{e(k-1)}] + b u(k-1) \right\} \\ + \underline{c e(k-1)} + \nu(k).$$

- ▶ Se não houvesse regressores do tipo $y(k-i)$, ter-se-ia

$$y(k) = b u(k-1) + c e(k-1) + \nu(k) \\ = b u(k-1) + e(k).$$

Nesse caso, o estimador MQ estimaria b sem polarização.



Polarização - Significado

A polarização pode ser vista como o resultado do estimador estar “forçando” $\Psi^T \xi = 0$ (propriedade de ortogonalidade entre regressores e resíduos), sendo que $\Psi^T e \neq 0$. Em outras palavras, a polarização surge em função do conflito que existe entre a propriedade do estimador de mínimos quadrados, $\Psi^T \xi = 0$, e a propriedade do erro de regressão, $\Psi^T e \neq 0$.




Figura 10: Polarização do estimador de MQ Polarização do estimador MQ quando o erro não é ortogonal aos regressores. Nesse caso os parâmetros corretos são $[\theta_1 \ \theta_2]^T$, e o estimador MQ determina $[\hat{\theta}_{p1} \ \hat{\theta}_{p2}]^T$.

O problema de "erros nas variáveis"

Considere

$$u(k) = u^i(k) + \nu_u(k),$$

$$y(k) = y^i(k) + e_y(k).$$

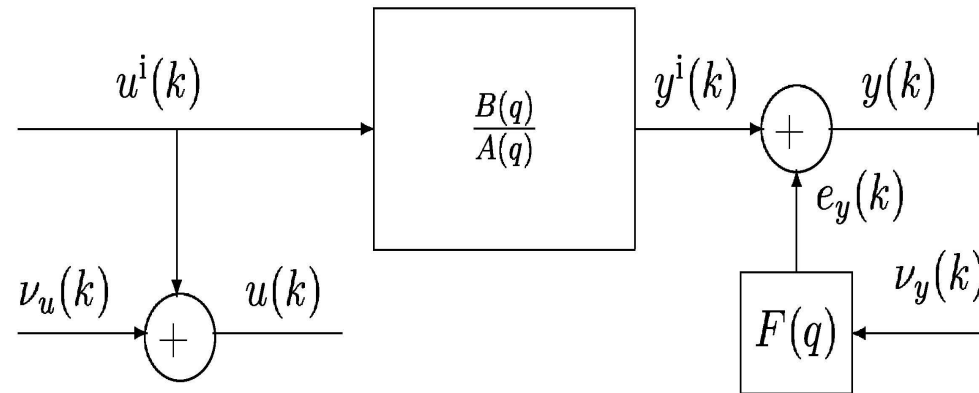


Figura 11: Ruído de observação na entrada e na saída. Tanto o sinal de entrada quanto o de saída estão contaminados por ruído de observação.



▶ Matematicamente, tem-se

$$A(q)y^i(k) = B(q)u^i(k)$$

$$A(q)[y(k) - e_y(k)] = B(q)[u(k) - \nu_u(k)]$$

$$A(q)y(k) = B(q)u(k) + [A(q)F(q)\nu_y(k) - B(q)\nu_u(k)],$$

sendo que $\nu_y(k)$ e $\nu_u(k)$ são ruídos brancos não correlacionados entre si.

- 
- ▶ Matematicamente, tem-se

$$A(q)y^i(k) = B(q)u^i(k)$$

$$A(q)[y(k) - e_y(k)] = B(q)[u(k) - \nu_u(k)]$$

$$A(q)y(k) = B(q)u(k) + [A(q)F(q)\nu_y(k) - B(q)\nu_u(k)],$$

sendo que $\nu_y(k)$ e $\nu_u(k)$ são ruídos brancos não correlacionados entre si.

- ▶ Os parâmetros do modelo serão estimados usando-se

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

O erro na equação de regressão não é branco, pois apesar de $\nu_y(k)$ e $\nu_u(k)$ serem brancos, assume-se que os filtros $A(q)F(q) \neq 1$ e $B(q) \neq 1$.

- 
-
- ▶ Uma outra forma de entender a polarização neste caso é observar que tanto o erro de regressão

$$e(k) = A(q)F(q)v_y(k) - B(q)v_u(k)$$

quanto a própria entrada dependem de $v_u(k)$. Portanto $u(k)$ e $e(k)$ estão correlacionados, ou seja, $r_{ue}(k) \neq 0$.

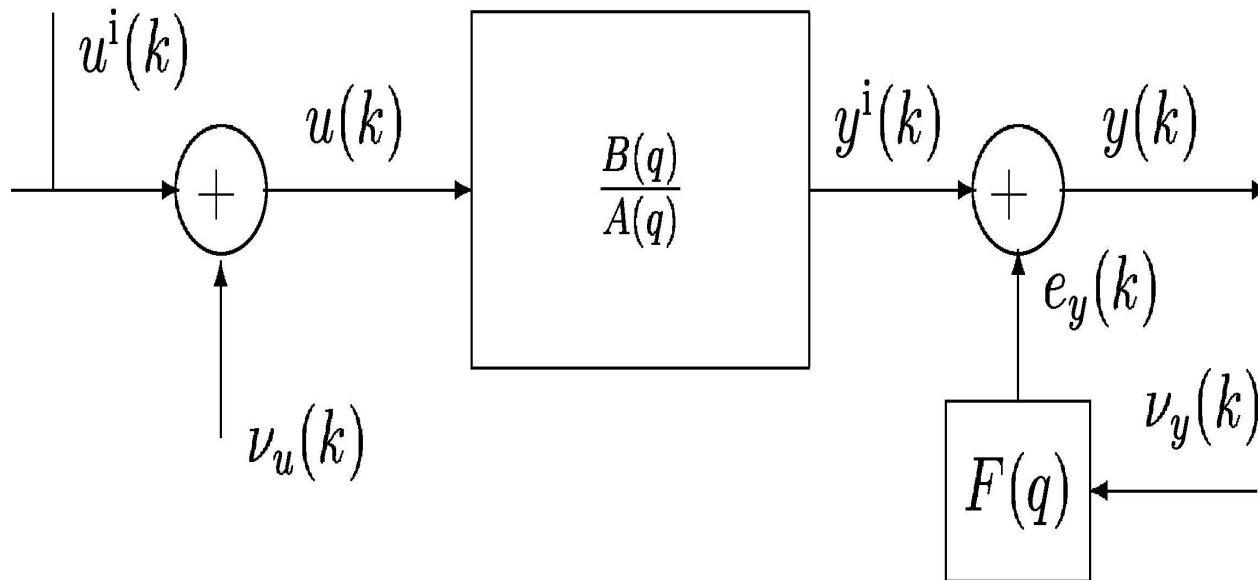



Figura 12: Entrada contaminada por ruído no atuador O sinal de entrada está contaminado por *ruído de atuador*. O algoritmo, entretanto, usa o sinal ideal $u^i(k)$. O sinal de saída está contaminado por *ruído de medição*. Nesta situação, o estimador MQ não é polarizado.



▶ Matematicamente, tem-se

$$A(q)y^i(k) = B(q)u(k)$$

$$A(q)[y(k) - e_y(k)] = B(q)[u^i(k) + \nu_u(k)]$$

$$A(q)y(k) = B(q)u^i(k) + A(q)F(q)\nu_y(k) + B(q)\nu_u(k).$$

- 
- ▶ Matematicamente, tem-se

$$A(q)y^i(k) = B(q)u(k)$$

$$A(q)[y(k) - e_y(k)] = B(q)[u^i(k) + \nu_u(k)]$$

$$A(q)y(k) = B(q)u^i(k) + A(q)F(q)\nu_y(k) + B(q)\nu_u(k).$$

- ▶ Portanto, o estimador MQ só será polarizado se $A(q)F(q)\nu_y(k)$ não for branco, uma vez que $u^i(k)$ não depende de $\nu_u(k)$. Ou seja, o ruído de atuador aparece no erro da equação de regressão, mas não no sinal de entrada utilizado pelo estimador.



Covariância de Estimadores

▶ A variância de uma variável escalar é

$$\text{var}[x] = \sigma_x^2 = \text{E} [(x - \text{E}[x])^2] ,$$



Covariância de Estimadores

- ▶ A variância de uma variável escalar é

$$\text{var}[x] = \sigma_x^2 = \text{E} [(x - \text{E}[x])^2] ,$$

- ▶ Para um vetor $\mathbf{x} \in \mathbb{R}^n$, a matriz de covariância tem dimensão $n \times n$ e é

$$\begin{aligned} \text{cov}[\mathbf{x}] &= \text{E} [(\mathbf{x} - \text{E}[\mathbf{x}])(\mathbf{x} - \text{E}[\mathbf{x}])^T] \\ &= \text{E}[\mathbf{x}\mathbf{x}^T] - \text{E}[\mathbf{x}]\text{E}[\mathbf{x}^T]. \end{aligned}$$

$\text{cov}[\mathbf{x}]$ é simétrica e semidefinida positiva. Também,

$$\text{cov}[C\mathbf{x}] = C\text{cov}[\mathbf{x}]C^T.$$

- 
-
- ▶ O *valor quadrático médio* de um escalar x é

$$\text{vqm}[x] = \mathbf{E}[x^2],$$

e a *matriz de valor quadrático médio* de um vetor \mathbf{x} é

$$\text{mms}[\mathbf{x}] = \mathbf{E}[\mathbf{x}\mathbf{x}^T].$$

Variância de estimadores do tipo $\hat{\theta} = Ay$


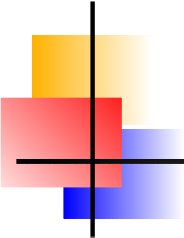


Figura 13: Histograma de um parâmetro estimado Histograma de valores estimados de um parâmetro com valor 0,2. Mesmo que o estimador utilizado não fosse polarizado (conforme a figura), percebe-se que valores relativamente afastados de 0,2 têm probabilidade alta de ocorrer.

- 
- ▶ Dado o sistema $y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k)$, o vetor de parâmetros pode ser obtido por um estimador do tipo $\hat{\boldsymbol{\theta}} = A\mathbf{y}$. Se o estimador for não polarizado, a sua matriz de covariância será

$$\begin{aligned}\text{cov}[\hat{\boldsymbol{\theta}}] &= \text{E} \left[(\hat{\boldsymbol{\theta}} - \text{E}[\hat{\boldsymbol{\theta}}])(\hat{\boldsymbol{\theta}} - \text{E}[\hat{\boldsymbol{\theta}}])^T \right] \\ &= \text{E} [(A\mathbf{y} - \boldsymbol{\theta})(A\mathbf{y} - \boldsymbol{\theta})^T] \\ &= \text{E} [A\mathbf{y}\mathbf{y}^T A^T - A\mathbf{y}\boldsymbol{\theta}^T - \boldsymbol{\theta}\mathbf{y}^T A^T + \boldsymbol{\theta}\boldsymbol{\theta}^T] \\ &= \text{E} [A(\boldsymbol{\Psi}\boldsymbol{\theta} + \mathbf{e})(\boldsymbol{\Psi}\boldsymbol{\theta} + \mathbf{e})^T A^T - A(\boldsymbol{\Psi}\boldsymbol{\theta} + \mathbf{e})\boldsymbol{\theta}^T \\ &\quad - \boldsymbol{\theta}(\boldsymbol{\Psi}\boldsymbol{\theta} + \mathbf{e})^T A^T + \boldsymbol{\theta}\boldsymbol{\theta}^T] \\ &= \text{E} [(A\boldsymbol{\Psi}\boldsymbol{\theta} + A\mathbf{e})(A\boldsymbol{\Psi}\boldsymbol{\theta} + A\mathbf{e})^T - (A\boldsymbol{\Psi}\boldsymbol{\theta} + A\mathbf{e})\boldsymbol{\theta}^T \\ &\quad - \boldsymbol{\theta}(A\boldsymbol{\Psi}\boldsymbol{\theta} + A\mathbf{e})^T + \boldsymbol{\theta}\boldsymbol{\theta}^T].\end{aligned}$$



► Mas como $A\Psi = I$

$$\text{cov}[\hat{\boldsymbol{\theta}}] = \mathbb{E} [(\boldsymbol{\theta} + A\mathbf{e})(\boldsymbol{\theta} + A\mathbf{e})^T - (\boldsymbol{\theta} + A\mathbf{e})\boldsymbol{\theta}^T - \boldsymbol{\theta}(\boldsymbol{\theta} + A\mathbf{e})^T + \boldsymbol{\theta}\boldsymbol{\theta}^T].$$



▶ Mas como $A\Psi = I$

$$\text{cov}[\hat{\boldsymbol{\theta}}] = \text{E} [(\boldsymbol{\theta} + A\mathbf{e})(\boldsymbol{\theta} + A\mathbf{e})^T - (\boldsymbol{\theta} + A\mathbf{e})\boldsymbol{\theta}^T - \boldsymbol{\theta}(\boldsymbol{\theta} + A\mathbf{e})^T + \boldsymbol{\theta}\boldsymbol{\theta}^T].$$

▶ Finalmente chega-se a

$$\text{cov}[\hat{\boldsymbol{\theta}}] = \text{E} [A\mathbf{e}\mathbf{e}^T A^T].$$



Variância de estimadores do tipo $\hat{\theta} = Ay$

- ▶ Qual é a variância de um estimador do tipo $\hat{\theta} = Ay$ no caso em que o erro de regressão é ruído branco?



Variância de estimadores do tipo $\hat{\boldsymbol{\theta}} = A\mathbf{y}$

- ▶ Qual é a variância de um estimador do tipo $\hat{\boldsymbol{\theta}} = A\mathbf{y}$ no caso em que o erro de regressão é ruído branco?
- ▶ Se \mathbf{e} é ruído branco, ele pode ser expresso da seguinte forma: $\text{cov}[\mathbf{e}] = \text{E}[\mathbf{e}\mathbf{e}^T] = \sigma_e^2 I$. Portanto, a variância é

$$\text{cov}[\hat{\boldsymbol{\theta}}] = \text{E}[AA^T] \sigma_e^2,$$

sendo que σ_e^2 é a variância do ruído.



Variância de estimadores do tipo $\hat{\theta} = Ay$

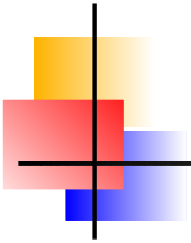
- ▶ Qual é a variância de um estimador do tipo $\hat{\theta} = Ay$ no caso em que o erro de regressão é ruído branco?
- ▶ Se \mathbf{e} é ruído branco, ele pode ser expresso da seguinte forma: $\text{cov}[\mathbf{e}] = \text{E}[\mathbf{e}\mathbf{e}^T] = \sigma_e^2 I$. Portanto, a variância é

$$\text{cov}[\hat{\theta}] = \text{E}[AA^T] \sigma_e^2,$$

sendo que σ_e^2 é a variância do ruído.

- ▶ Para o estimador de mínimos quadrados, sabe-se que $A = [\Psi^T \Psi]^{-1} \Psi^T$ e, portanto, a última equação torna-se

$$\text{cov}[\hat{\theta}_{\text{MQ}}] = \text{E}[(\Psi^T \Psi)^{-1}] \sigma_e^2.$$



Uma observação importante a ser feita é que, quando o vetor de erros \mathbf{e} é branco, a variância do estimador de mínimos quadrados é a menor de todos os estimadores do tipo $\hat{\boldsymbol{\theta}} = \mathbf{A}\mathbf{y}$ que sejam *não polarizados*. Ou seja, $\text{cov}[\hat{\boldsymbol{\theta}}_{\text{MQ}}] \leq \text{cov}[\hat{\boldsymbol{\theta}}]$.

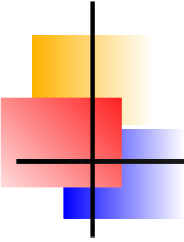


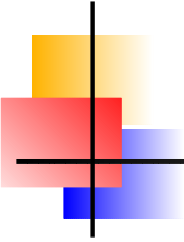
Eficiência de Estimadores

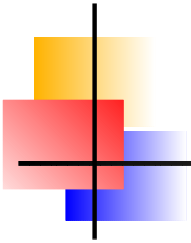
Seria interessante comparar a variância do estimador a um valor de variância “ótimo”. O padrão comumente usado para estimadores não polarizados é a *norma de Cramér-Rao*. A *eficiência de um estimador* é definida como

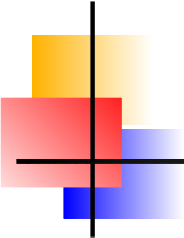
$$E_f = \frac{F^{-1}}{\text{cov}[\hat{\theta}]},$$

sendo E_f a eficiência do estimador de θ e F^{-1} , a norma de Cramér-Rao.

- 
-
- ▶ Para efeito de discussão, um estimador qualquer será representado por $\hat{\theta} = E(\mathbf{y}, \mathbf{u})$. Note que o estimador $E(\cdot)$ não deve ser confundido com o operador de esperança matemática.

- 
-
- ▶ Para efeito de discussão, um estimador qualquer será representado por $\hat{\theta} = E(\mathbf{y}, \mathbf{u})$. Note que o estimador $E(\cdot)$ não deve ser confundido com o operador de esperança matemática.
 - ▶ Portanto, estimadores lineares podem ser representados da seguinte forma conhecida $\hat{\theta} = A\mathbf{y}$, sendo que A normalmente depende dos vetores de dados de entrada e saída \mathbf{u} e \mathbf{y} , de dimensão N .

- 
- ▶ Para efeito de discussão, um estimador qualquer será representado por $\hat{\theta} = E(\mathbf{y}, \mathbf{u})$. Note que o estimador $E(\cdot)$ não deve ser confundido com o operador de esperança matemática.
 - ▶ Portanto, estimadores lineares podem ser representados da seguinte forma conhecida $\hat{\theta} = A\mathbf{y}$, sendo que A normalmente depende dos vetores de dados de entrada e saída \mathbf{u} e \mathbf{y} , de dimensão N .
 - ▶ Assim, um estimador não polarizado $\hat{\theta} = E(\mathbf{y}, \mathbf{u})$ é *mais eficiente* do que um outro estimador $\hat{\tilde{\theta}} = E(\mathbf{y}, \mathbf{u})$ se $\text{cov}[\hat{\theta}] \leq \text{cov}[\hat{\tilde{\theta}}]$, para todo valor de N .

- 
- ▶ Para efeito de discussão, um estimador qualquer será representado por $\hat{\theta} = E(\mathbf{y}, \mathbf{u})$. Note que o estimador $E(\cdot)$ não deve ser confundido com o operador de esperança matemática.
 - ▶ Portanto, estimadores lineares podem ser representados da seguinte forma conhecida $\hat{\theta} = A\mathbf{y}$, sendo que A normalmente depende dos vetores de dados de entrada e saída \mathbf{u} e \mathbf{y} , de dimensão N .
 - ▶ Assim, um estimador não polarizado $\hat{\theta} = E(\mathbf{y}, \mathbf{u})$ é *mais eficiente* do que um outro estimador $\hat{\theta} = E(\mathbf{y}, \mathbf{u})$ se $\text{cov}[\hat{\theta}] \leq \text{cov}[\hat{\theta}]$, para todo valor de N .
 - ▶ Além disso, diz-se que um estimador é *eficiente* se sua variância atinge a norma de Cramér-Rao, que é o mínimo atingível por todos os estimadores (lineares e não-lineares) não polarizados.



A Norma de Cramér-Rao

- ▶ A norma de Cramér-Rao de um estimador de θ é F^{-1} , onde F , a matriz de informação de Fisher, é definida como

$$\begin{aligned} F &= \mathbb{E}_{y|\theta} \left[\left(\frac{\partial}{\partial \theta} \ln p(y | \theta) \right) \left(\frac{\partial}{\partial \theta} \ln p(y | \theta) \right)^T \right] \\ &= - \left(\mathbb{E}_{y|\theta} \left[\frac{\partial^2 \ln p(y | \theta)}{\partial \theta^2} \right] \right), \end{aligned}$$

sendo $p(y | \theta)$ a função de densidade de probabilidade das medições y dado o vetor de parâmetros θ . Nota-se que tal matriz quantifica como variações de θ afetam $p(y | \theta)$.



A Norma de Cramér-Rao

- ▶ A norma de Cramér-Rao de um estimador de θ é F^{-1} , onde F , a matriz de informação de Fisher, é definida como

$$\begin{aligned} F &= \mathbb{E}_{y|\theta} \left[\left(\frac{\partial}{\partial \theta} \ln p(y | \theta) \right) \left(\frac{\partial}{\partial \theta} \ln p(y | \theta) \right)^T \right] \\ &= - \left(\mathbb{E}_{y|\theta} \left[\frac{\partial^2 \ln p(y | \theta)}{\partial \theta^2} \right] \right), \end{aligned}$$

sendo $p(y | \theta)$ a função de densidade de probabilidade das medições y dado o vetor de parâmetros θ . Nota-se que tal matriz quantifica como variações de θ afetam $p(y | \theta)$.

- ▶ É possível provar que para estimadores não polarizados

$$\text{cov}[\hat{\theta}(y)] \geq F^{-1},$$

sendo que o argumento no vetor estimado simplesmente evidencia que $\hat{\theta}(y)$ é estimado a partir de medições $y(k)$.



Eficiência de um estimador não polarizado

Deseja-se estimar o parâmetro α da função de densidade de probabilidade $p(y | \alpha) = (1/\alpha)\exp[-y/\alpha]$, $y \geq 0$, a partir de N medições independentes de y .

- ▶ Primeiramente, será determinada a norma mínima de Cramér-Rao de um estimador não polarizado qualquer do parâmetro α .



Eficiência de um estimador não polarizado

Deseja-se estimar o parâmetro α da função de densidade de probabilidade $p(y | \alpha) = (1/\alpha)\exp[-y/\alpha]$, $y \geq 0$, a partir de N medições independentes de y .

- ▶ Primeiramente, será determinada a norma mínima de Cramér-Rao de um estimador não polarizado qualquer do parâmetro α .
- ▶ Em segundo lugar, será determinada a variância do estimador em questão, $\hat{\alpha} = \sum_{k=1}^N y(k)/N$, e, finalmente, será verificado se ela atinge ou não a norma de Cramér-Rao.



Eficiência de um estimador não polarizado

Deseja-se estimar o parâmetro α da função de densidade de probabilidade $p(y | \alpha) = (1/\alpha)\exp[-y/\alpha]$, $y \geq 0$, a partir de N medições independentes de y .

- ▶ Primeiramente, será determinada a norma mínima de Cramér-Rao de um estimador não polarizado qualquer do parâmetro α .
- ▶ Em segundo lugar, será determinada a variância do estimador em questão, $\hat{\alpha} = \sum_{k=1}^N y(k)/N$, e, finalmente, será verificado se ela atinge ou não a norma de Cramér-Rao.
- ▶ A função densidade de probabilidade conjunta das medições $y(k)$ para $k = 1, \dots, N$ é

$$p(y(1), \dots, y(N) | \alpha) = \prod_{k=1}^N p(y(k) | \alpha) = \alpha^{-N} \exp \left[- \sum_{k=1}^N \frac{y(k)}{\alpha} \right].$$



► As seguintes entidades podem agora ser determinadas:

$$\ln p(y | \alpha) = -N \ln \alpha - \sum_{k=1}^N y(k) / \alpha$$

$$\frac{\partial}{\partial \alpha} \ln p(y | \alpha) = -N / \alpha + \sum_{k=1}^N y(k) / \alpha^2$$

$$\frac{\partial^2}{\partial \alpha^2} \ln p(y | \alpha) = N / \alpha^2 - 2 \sum_{k=1}^N y(k) / \alpha^3.$$

- 
- As seguintes entidades podem agora ser determinadas:

$$\ln p(y | \alpha) = -N \ln \alpha - \sum_{k=1}^N y(k)/\alpha$$

$$\frac{\partial}{\partial \alpha} \ln p(y | \alpha) = -N/\alpha + \sum_{k=1}^N y(k)/\alpha^2$$

$$\frac{\partial^2}{\partial \alpha^2} \ln p(y | \alpha) = N/\alpha^2 - 2 \sum_{k=1}^N y(k)/\alpha^3.$$

- Substituindo-se, tem-se

$$\begin{aligned} F &= -\mathbb{E} \left[N/\alpha^2 - 2 \sum_{k=1}^N y(k)/\alpha^3 \right] \\ &= -N/\alpha^2 + 2 \frac{\mathbb{E}[\sum_{k=1}^N y(k)]}{\alpha^3}, \end{aligned}$$

mas como $\mathbb{E}[y(k)] = \alpha$, então $\mathbb{E}[\sum_{k=1}^N y(k)] = N\alpha$.



▶ Então

$$\begin{aligned} F &= -N/\alpha^2 + 2\frac{E[N\alpha]}{\alpha^3} \\ &= N/\alpha^2. \end{aligned}$$



▶ Então

$$\begin{aligned} F &= -N/\alpha^2 + 2\frac{\mathbf{E}[N\alpha]}{\alpha^3} \\ &= N/\alpha^2. \end{aligned}$$

▶ Logo, $F^{-1} = \alpha^2/N$ é a norma mínima de Cramér-Rao para este exemplo. Portanto, $\text{var}[\hat{\alpha}] \geq \alpha^2/N$. Resta agora determinar a variância do estimador:

$$\begin{aligned} \text{var}[\hat{\alpha}] &= \mathbf{E}[(\alpha - \hat{\alpha})^2] \\ &= \mathbf{E}\left[\frac{(\sum y(k))^2}{N^2} - 2\alpha\frac{\sum y(k)}{N} + \alpha^2\right] \\ &= \alpha^2/N. \end{aligned}$$

Portanto, o estimador deste exemplo é eficiente.



Polarização do estimador de MQ usando correlação — Um exemplo

Seja um sistema representado pelo seguinte modelo ARMAX:

$$y(k) + a_1 y(k-1) = b_1 u(k-1) + c_1 \nu(k-1) + \nu(k), \quad (-47)$$

sendo que $u(k)$ e $\nu(k)$ são seqüências aleatórias de média nula e variâncias σ_u^2 e σ_ν^2 , respectivamente. Os valores das funções de autocorrelação e correlação cruzada da saída e entrada para os atrasos 0 e 1 podem ser determinados analiticamente, para $N \rightarrow \infty$, como

$$\begin{aligned} r_{yy}(0) &= \frac{(1 + c_1^2 - 2a_1 c_1)\sigma_\nu^2 + b_1^2 \sigma_u^2}{1 - a_1^2} & (-46) \\ r_{yy}(-1) &= \frac{(c_1 - a_1 - a_1 c_1^2 - a_1^2 c_1)\sigma_\nu^2 + a_1 b_1^2 \sigma_u^2}{1 - a_1^2} \\ r_{yu}(0) &= 0 \\ r_{yu}(-1) &= b_1 \sigma_u^2. \end{aligned}$$



Usando-se a seguinte equação de regressão:

$$y(k) + a_1 y(k-1) = b_1 u(k-1) + e(k), \quad (-45)$$

é fácil mostrar que a equação normal pode ser expressa em termos das funções de autocorrelação e correlação cruzada da saída e entrada da seguinte forma (note que

$r_{uy}(1) = r_{yu}(-1)$):

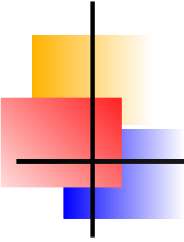
$$\begin{bmatrix} r_{yu}(-1) \\ -r_{yy}(-1) \end{bmatrix} = \begin{bmatrix} -r_{yu}(0) & r_{uu}(0) \\ r_{yy}(0) & -r_{yu}(0) \end{bmatrix} \begin{bmatrix} \hat{a}_1 \\ \hat{b}_1 \end{bmatrix}, \quad (-44)$$

sendo que o que premultiplica o vetor de parâmetros é a matriz de covariância R_{yu} .



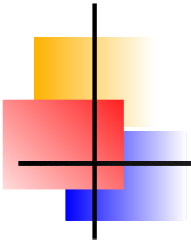
A solução de equação anterior é é (usando-se os valores analiticamente calculados para as funções de correlação)

$$\hat{a}_1 = a_1 - \frac{c_1 \sigma_v^2 (1 - a_1^2)}{(1 + c_1^2 - 2a_1 c_1) \sigma_v^2 + b_1^2 \sigma_u^2}$$
$$\hat{b}_1 = b_1.$$



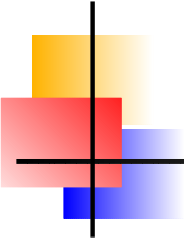
O resultado acima tem diversos aspectos interessantes, dentre os quais ressaltam-se os seguintes:

- ▶ \hat{a}_1 estará normalmente polarizado;



O resultado acima tem diversos aspectos interessantes, dentre os quais ressaltam-se os seguintes:

- ▶ \hat{a}_1 estará normalmente polarizado;
- ▶ \hat{b}_1 nunca estará polarizado. Portanto, é possível que num mesmo vetor de parâmetros alguns revelem polarização e outros não;



O resultado acima tem diversos aspectos interessantes, dentre os quais ressaltam-se os seguintes:

- ▶ \hat{a}_1 estará normalmente polarizado;
- ▶ \hat{b}_1 nunca estará polarizado. Portanto, é possível que num mesmo vetor de parâmetros alguns revelem polarização e outros não;
- ▶ para evitar polarização na estimativa de a_1 , usando-se o modelo de regressão (-45) e o estimador MQ, é necessário eliminar o erro em (-47) de forma a garantir $\sigma_v^2 = 0$ ou $c_1 = 0$. A última condição é equivalente a garantir que o erro na equação de regressão seja branco.



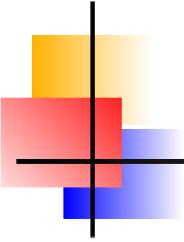
Variância mínima do estimador MQ

Neste complemento será mostrado que o estimador de mínimos quadrados tem a menor variância dentre todos os estimadores lineares não polarizados quando o vetor de erro de regressão é ruído branco. Como indicado anteriormente, isso corresponde a provar que $\sigma_e^2 (AA^T - [\Psi^T \Psi]^{-1})$ é semi-definida positiva.

A fim de provar esta propriedade, deve ser notado que a matriz esperada do produto de uma matriz real pela sua transposta é semidefinida positiva, ou seja $E[XX^T]$ é semidefinida positiva se X for uma matriz real (ver propriedade ??). Se

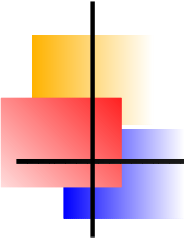
$X = A - [\Psi^T \Psi]^{-1} \Psi^T$, tem-se

$$\begin{aligned} XX^T &= (A - [\Psi^T \Psi]^{-1} \Psi^T) (A - [\Psi^T \Psi]^{-1} \Psi^T)^T \\ &= AA^T - A\Psi[\Psi^T \Psi]^{-1} - [\Psi^T \Psi]^{-1} \Psi^T A^T + [\Psi^T \Psi]^{-1} \Psi^T \Psi [\Psi^T \Psi]^{-1} \end{aligned} \quad (4.43)$$

- 
-
- ▶ Escolhendo $A = [C\Psi]^{-1}C$ (note que esta escolha satisfaz a condição $A\Psi = I$), tem-se

$$\begin{aligned} A\Psi[\Psi^T\Psi]^{-1} &= [C\Psi]^{-1}C\Psi[\Psi^T\Psi]^{-1} \\ &= \Psi^{-1}C^{-1}C\Psi[\Psi^T\Psi]^{-1} \\ &= [\Psi^T\Psi]^{-1}, \end{aligned} \tag{-42}$$

sendo que a propriedade $[XY]^{-1} = Y^{-1}X^{-1}$ foi utilizada.

- 
- ▶ Escolhendo $A = [C\Psi]^{-1}C$ (note que esta escolha satisfaz a condição $A\Psi = I$), tem-se

$$\begin{aligned} A\Psi[\Psi^T\Psi]^{-1} &= [C\Psi]^{-1}C\Psi[\Psi^T\Psi]^{-1} \\ &= \Psi^{-1}C^{-1}C\Psi[\Psi^T\Psi]^{-1} \\ &= [\Psi^T\Psi]^{-1}, \end{aligned} \tag{-40}$$

sendo que a propriedade $[XY]^{-1} = Y^{-1}X^{-1}$ foi utilizada.

- ▶ Analogamente, é possível verificar que

$$[\Psi^T\Psi]^{-1}\Psi^T A^T = [\Psi^T\Psi]^{-1}. \tag{-41}$$

- 
- ▶ Escolhendo $A = [C\Psi]^{-1}C$ (note que esta escolha satisfaz a condição $A\Psi = I$), tem-se

$$\begin{aligned} A\Psi[\Psi^T\Psi]^{-1} &= [C\Psi]^{-1}C\Psi[\Psi^T\Psi]^{-1} \\ &= \Psi^{-1}C^{-1}C\Psi[\Psi^T\Psi]^{-1} \\ &= [\Psi^T\Psi]^{-1}, \end{aligned} \tag{-42}$$

sendo que a propriedade $[XY]^{-1} = Y^{-1}X^{-1}$ foi utilizada.

- ▶ Analogamente, é possível verificar que

$$[\Psi^T\Psi]^{-1}\Psi^T A^T = [\Psi^T\Psi]^{-1}. \tag{-43}$$

- ▶ Portanto, substituindo-se (-42) e (-41) em (-43), tem-se

$$XX^T = AA^T - [\Psi^T\Psi]^{-1}. \tag{-44}$$

- 
- ▶ Finalmente, aplicando-se a esperança matemática à última equação, obtém-se

$$\begin{aligned} E[XX^T] &= E[AA^T] - E[(\Psi^T \Psi)^{-1}] \\ &= \frac{\text{cov}[\hat{\theta}]}{\sigma_e^2} - \frac{\text{cov}[\hat{\theta}_{\text{MQ}}]}{\sigma_e^2}, \end{aligned} \quad (-43)$$

sendo que a matriz do lado esquerdo da igualdade é semidefinida positiva por construção. Portanto, a variância do estimador de mínimos quadrados é a menor dentre todos os estimadores lineares não polarizados no caso do vetor de erro ser ruído branco.



Eficiência do estimador MQ

Considere a saída $y(k)$ de um processo parametrizado da seguinte forma $y(k) = \boldsymbol{\psi}^T \boldsymbol{\theta} + e(k)$, sendo que o erro $e(k)$ é normalmente distribuído com média zero e desvio padrão igual a σ_e . Além disso, a função de densidade de probabilidade das medições é dada por

$$p(\mathbf{y} | \boldsymbol{\theta}) = \frac{\exp \left[-0,5(\mathbf{y} - \boldsymbol{\Psi}\boldsymbol{\theta})^T (\sigma_e^2 \mathbf{I}_N)^{-1} (\mathbf{y} - \boldsymbol{\Psi}\boldsymbol{\theta}) \right]}{(2\pi)^{N/2} \det[\sigma_e^2 \mathbf{I}_N]^{0,5}}, \quad (-42)$$

sendo que N é o número de observações e \mathbf{I}_N é a matriz identidade de dimensão N . Agora será determinada a norma de Cramér-Rao de um estimador não polarizado de $\boldsymbol{\theta}$.



Tem-se

$$\begin{aligned}\ln p(\mathbf{y} \mid \boldsymbol{\theta}) &= \ln(2\pi)^{-N/2} + \ln(\sigma_e^2)^{-N/2} - \frac{(\mathbf{y} - \Psi\boldsymbol{\theta})^\top (\mathbf{y} - \Psi\boldsymbol{\theta})}{2\sigma_e^2} \\ &= -\frac{N}{2}\ln(2\pi) - \frac{N}{2}\ln(\sigma_e^2) - \frac{(\mathbf{y} - \Psi\boldsymbol{\theta})^\top (\mathbf{y} - \Psi\boldsymbol{\theta})}{2\sigma_e^2} \quad (-41)\end{aligned}$$

sendo que foi usado $\det[kA] = k^n \det[A]$, $n = \dim[A]$. Além disso,

$$\begin{aligned}\frac{\partial \ln p(\mathbf{y} \mid \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} &= -\frac{\partial}{2\sigma_e^2 \partial \boldsymbol{\theta}} [\mathbf{y}^\top \mathbf{y} - \boldsymbol{\theta}^\top \Psi^\top \mathbf{y} - \mathbf{y}^\top \Psi \boldsymbol{\theta} + \boldsymbol{\theta}^\top \Psi^\top \Psi \boldsymbol{\theta}] \\ &= -\frac{1}{2\sigma_e^2} [-\Psi^\top \mathbf{y} - \Psi^\top \mathbf{y} + (\Psi^\top \Psi + \Psi^\top \Psi) \boldsymbol{\theta}] \\ &= -\frac{1}{2\sigma_e^2} [-2\Psi^\top (\mathbf{y} - \Psi\boldsymbol{\theta})]. \quad (-40)\end{aligned}$$



Finalmente,

$$\frac{\partial^2 \ln p(y | \boldsymbol{\theta})}{\partial \boldsymbol{\theta}^2} = \frac{1}{\sigma_e^2} [\boldsymbol{\Psi}^T \boldsymbol{\Psi}].$$

Logo, a desigualdade de Cramér-Rao se torna

$$\text{cov}[\hat{\boldsymbol{\theta}}] \geq - \left\{ \text{E} \left[\frac{\boldsymbol{\Psi}^T \boldsymbol{\Psi}}{\sigma_e^2} \right] \right\}^{-1} = \text{E} [(\boldsymbol{\Psi}^T \boldsymbol{\Psi})^{-1}] \sigma_e^2, \quad (-39)$$

que é precisamente a covariância do estimador de mínimos quadrados (veja a equação (-35)). Logo, o estimador MQ atinge a norma mínima de Cramér-Rao e portanto é eficiente. Este resultado mostra que o estimador MQ apresenta a menor covariância dentre todos os estimadores (lineares e não-lineares) não polarizados, *quando o erro for gaussiano e a função densidade de probabilidade for como mostrada na equação (-42).*



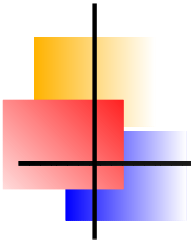
Convergência e consistência do estimador MQ

Suponha que os dados observados tenham sido gerados pelo sistema

$$y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k), \quad (-38)$$

sendo $e(k)$ uma seqüência de erros qualquer. Usando-se (-38) como equação de regressão, resulta na equação normal $\boldsymbol{\Psi}^T \mathbf{y} = \boldsymbol{\Psi}^T \boldsymbol{\Psi} \boldsymbol{\theta}$. Portanto, o estimador MQ pode ser expresso como

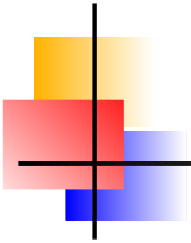
$$\hat{\boldsymbol{\theta}}_{\text{MQ}} = [\boldsymbol{\Psi}^T \boldsymbol{\Psi}]^{-1} \boldsymbol{\Psi}^T \mathbf{y}.$$



Lembrando que a equação (-38) pode ser usada para gerar a equação matricial $\mathbf{y} = \Psi\boldsymbol{\theta} + \mathbf{e}$, e substituindo-se tal equação na do MQ, resulta em

$$\begin{aligned}\hat{\boldsymbol{\theta}}_{\text{MQ}} &= \boldsymbol{\theta} + [\Psi^T \Psi]^{-1} \Psi^T \mathbf{e} \\ &= \boldsymbol{\theta} + \left[\frac{1}{N} \sum_{k=1}^N \boldsymbol{\psi}(k-1) \boldsymbol{\psi}^T(k-1) \right]^{-1} \left[\frac{1}{N} \sum_{k=1}^N \boldsymbol{\psi}(k-1) e(k) \right] \\ &= \boldsymbol{\theta} + [R_\psi]^{-1} \frac{1}{N} \sum_{k=1}^N \boldsymbol{\psi}(k-1) e(k),\end{aligned}\tag{-37}$$

sendo R_ψ uma matriz de covariância (ver equações (??) e (-44), que contêm matrizes análogas). Seria desejável que $\hat{\boldsymbol{\theta}}_{\text{MQ}} \approx \boldsymbol{\theta}$, o que requer que a segunda parcela do lado direito de (-37) seja pequena. Além disso, também seria desejável que $\hat{\boldsymbol{\theta}}_{\text{MQ}} \rightarrow \boldsymbol{\theta}$, para $N \rightarrow \infty$.

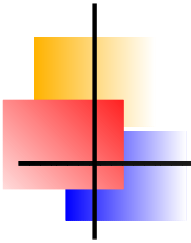


A fim de investigar o comportamento de $\hat{\boldsymbol{\theta}}_{\text{MQ}}$ quando $N \rightarrow \infty$, é conveniente supor que $e(k)$ e $u(k)$ são processos estacionários de maneira que matrizes de covariância do tipo

$$R_{uu}(N, \tau) = \frac{1}{N} \sum_{k=1}^N u(k)u(k - \tau) \rightarrow R_{uu}(\tau), \quad (-36)$$

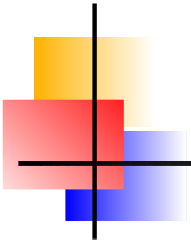
para $N \rightarrow \infty$. Neste caso, $R_{\psi} \rightarrow \bar{R}_{\psi}$ convergirá em probabilidade, uma vez que é composta de somatórios do tipo (-36). Semelhantemente, a segunda parcela do lado direito de (-37) convergirá em probabilidade para $\bar{R}_{\psi e}$. Portanto, desde que R_{ψ} seja não singular,

$$\hat{\boldsymbol{\theta}}_{\text{MQ}} = \boldsymbol{\theta} + [\bar{R}_{\psi}]^{-1} \bar{R}_{\psi e}, \quad N \rightarrow \infty. \quad (-35)$$



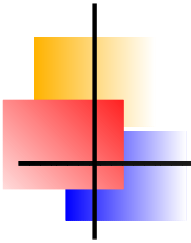
Finalmente, para que o estimador seja *consistente*, deve-se ter $\hat{\theta}_{\text{MQ}} \rightarrow \theta$ à medida que $N \rightarrow \infty$. As condições necessárias para isso são:

- ▶ \bar{R}_ψ seja não singular. Para isso $u(k)$ e $e(k)$ devem ser independentes e $u(k)$ deve ser persistentemente excitante de ordem suficientemente elevada, conforme discutido no capítulo 4.



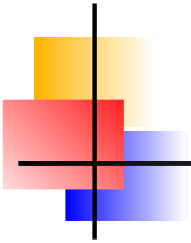
Finalmente, para que o estimador seja *consistente*, deve-se ter $\hat{\theta}_{\text{MQ}} \rightarrow \theta$ à medida que $N \rightarrow \infty$. As condições necessárias para isso são:

- ▶ \bar{R}_ψ seja não singular. Para isso $u(k)$ e $e(k)$ devem ser independentes e $u(k)$ deve ser persistentemente excitante de ordem suficientemente elevada, conforme discutido no capítulo 4.
- ▶ $e(k)$ é ruído branco. Neste caso $\bar{R}_{\psi e} = 0$, pois $e(k)$ não dependerá do que tiver acontecido até o instante $k - 1$ (note que o vetor de regressores, $\psi(k - 1)$ em (-38), só tem informação até o instante $k - 1$); ou



Finalmente, para que o estimador seja *consistente*, deve-se ter $\hat{\theta}_{\text{MQ}} \rightarrow \theta$ à medida que $N \rightarrow \infty$. As condições necessárias para isso são:

- ▶ \bar{R}_ψ seja não singular. Para isso $u(k)$ e $e(k)$ devem ser independentes e $u(k)$ deve ser persistentemente excitante de ordem suficientemente elevada, conforme discutido no capítulo 4.
- ▶ $e(k)$ é ruído branco. Neste caso $\bar{R}_{\psi e} = 0$, pois $e(k)$ não dependerá do que tiver acontecido até o instante $k - 1$ (note que o vetor de regressores, $\psi(k - 1)$ em (-38), só tem informação até o instante $k - 1$); ou
- ▶ $u(k)$ e $e(k)$ sejam independentes e não haja regressores da saída em $\psi(k - 1)$, ou seja, $n_y = 0$ em (??), assim $\psi(k - 1)$ é independente de $e(k)$.



Finalmente, para que o estimador seja *consistente*, deve-se ter $\hat{\theta}_{\text{MQ}} \rightarrow \theta$ à medida que $N \rightarrow \infty$. As condições necessárias para isso são:

- ▶ \bar{R}_ψ seja não singular. Para isso $u(k)$ e $e(k)$ devem ser independentes e $u(k)$ deve ser persistentemente excitante de ordem suficientemente elevada, conforme discutido no capítulo 4.
- ▶ $e(k)$ é ruído branco. Neste caso $\bar{R}_{\psi e} = 0$, pois $e(k)$ não dependerá do que tiver acontecido até o instante $k - 1$ (note que o vetor de regressores, $\psi(k - 1)$ em (-38), só tem informação até o instante $k - 1$); ou
- ▶ $u(k)$ e $e(k)$ sejam independentes e não haja regressores da saída em $\psi(k - 1)$, ou seja, $n_y = 0$ em (??), assim $\psi(k - 1)$ é independente de $e(k)$.

É interessante notar que algumas das condições listadas acima