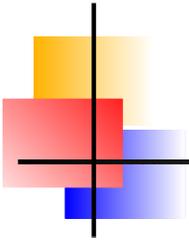


## *Capítulo 7 - Estimadores Não Polarizados*

Eduardo Mendes

`emmendes@cpdee.ufmg.br`

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

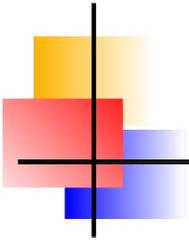


# Introdução

---

Neste capítulo serão apresentados três estimadores que contornam o problema de polarização na situação descrita acima:

- ▶ o estimador estendido de mínimos quadrados (EMQ),




# Introdução

---

Neste capítulo serão apresentados três estimadores que contornam o problema de polarização na situação descrita acima:

- ▶ o estimador estendido de mínimos quadrados (EMQ),
- ▶ o estimador generalizado de mínimos quadrados (GMQ)




# Introdução

---

Neste capítulo serão apresentados três estimadores que contornam o problema de polarização na situação descrita acima:

- ▶ o estimador estendido de mínimos quadrados (EMQ),
- ▶ o estimador generalizado de mínimos quadrados (GMQ)
- ▶ e o estimador das variáveis instrumentais (VI).



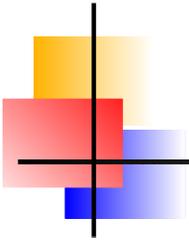
# Introdução

---

Neste capítulo serão apresentados três estimadores que contornam o problema de polarização na situação descrita acima:

- ▶ o estimador estendido de mínimos quadrados (EMQ),
- ▶ o estimador generalizado de mínimos quadrados (GMQ)
- ▶ e o estimador das variáveis instrumentais (VI).

Tais algoritmos serão denominados *estimadores não polarizados*.



# Introdução

---

Neste capítulo serão apresentados três estimadores que contornam o problema de polarização na situação descrita acima:

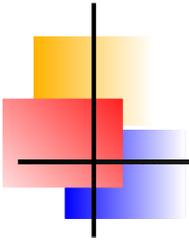
- ▶ o estimador estendido de mínimos quadrados (EMQ),
- ▶ o estimador generalizado de mínimos quadrados (GMQ)
- ▶ e o estimador das variáveis instrumentais (VI).

Tais algoritmos serão denominados *estimadores não polarizados*.

Uma forma de evitar a polarização (usada pelos estimadores EMQ e GMQ) é transformar a equação matricial  $\mathbf{y} = \Psi\boldsymbol{\theta} + \mathbf{e}$  em

$$\mathbf{y}^* = \Psi^*\boldsymbol{\theta}^* + \mathbf{e}^*,$$

sendo  $\mathbf{e}^*$  branco de forma que  $E[A^*\mathbf{e}^*] = 0$  e  $A^*\Psi^* = I$ .



# O Estimador Estendido de MQ

---

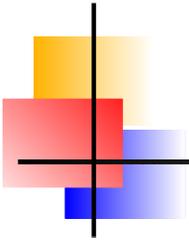
## Polarização devida a ruído MA — análise

- ▶ Seja o modelo ARX:

$$y(k) = ay(k-1) + bu(k-1) + e(k),$$

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

e  $\nu(k)$  é ruído branco.



# O Estimador Estendido de MQ

## Polarização devida a ruído MA — análise

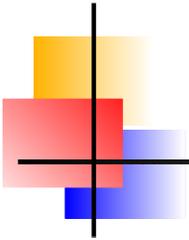
- ▶ Seja o modelo ARX:

$$\begin{aligned}y(k) &= ay(k-1) + bu(k-1) + e(k), \\e(k) &= cv(k-1) + \nu(k),\end{aligned}$$

e  $\nu(k)$  é ruído branco.

- ▶ Fazendo-se substituições, tem-se

$$\begin{aligned}y(k) &= ay(k-1) + bu(k-1) + cv(k-1) + \nu(k), \\y(k-1) &= ay(k-2) + bu(k-2) + cv(k-2) + \nu(k-1).\end{aligned}$$



► Finalmente, chega-se a


$$y(k) = a[ay(k-2) + bu(k-2) + c\underline{\nu(k-2)} + \underline{\nu(k-1)}] \\ + bu(k-1) + \underline{c\underline{\nu(k-1)}} + \nu(k),$$

que está na forma  $y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k)$ , sendo

$$\boldsymbol{\psi}^T(k-1) = \left[ \left( a y(k-2) + b u(k-2) + c \underline{\nu(k-2)} + \underline{\nu(k-1)} \right) \quad u(k-1) \right]$$

$$\boldsymbol{\theta} = [a \ b]^T$$

$$e(k) = \underline{c\underline{\nu(k-1)}} + \nu(k).$$



# Polarização devida a ruído MA — simulação

---

Os dados serão gerados pelo seguinte modelo:

$$y(k) = ay(k-1) + bu(k-1) + e(k),$$

$$e(k) = 0,8\nu(k-1) + \nu(k),$$

sendo que  $\nu(k)$  e  $u(k)$  são independentes, brancos e gaussianos com  $\sigma_\nu^2 = 0,04$  e  $\sigma_u^2 = 1$ .



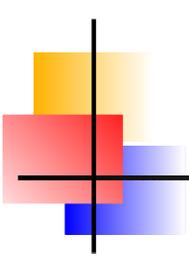


Figura 1: Polarização em modelos ARX. Os valores reais dos parâmetros são (a)  $a = 0,7$  e (b)  $b = 0,5$




# Eliminando polarização com o estimador EMQ — análise

A equação matricial gerada por

$$y(k) = a[ay(k-2) + bu(k-2) + c\underline{\nu(k-2)} + \underline{\nu(k-1)}] + bu(k-1) + \underline{c\nu(k-1)} + \nu(k),$$

pode ser rescrita da seguinte forma:

$$\begin{bmatrix} y(k) \\ y(k+1) \\ \vdots \\ y(k+N-1) \end{bmatrix} = \begin{bmatrix} [y(k-1)] & u(k-1) & \nu(k-1) \\ [y(k)] & u(k) & \nu(k) \\ \vdots & \vdots & \vdots \\ [y(k+N-2)] & u(k+N-2) & \nu(k+N-2) \end{bmatrix} \begin{bmatrix} a \\ b \\ c \end{bmatrix} + \begin{bmatrix} \nu(k) \\ \nu(k+1) \\ \vdots \\ \nu(k+N-1) \end{bmatrix}$$




---

▶ Logo, pode-se escrever

$$\mathbf{y}^* = \Psi^* \boldsymbol{\theta}^* + \mathbf{e}^*,$$

sendo que  $\mathbf{y}^* = \mathbf{y}$ ,  $\mathbf{e}^* = [\nu(k) \dots \nu(k + N - 1)]^T$ ,

- 
- ▶ Logo, pode-se escrever


$$\mathbf{y}^* = \Psi^* \boldsymbol{\theta}^* + \mathbf{e}^*,$$

sendo que  $\mathbf{y}^* = \mathbf{y}$ ,  $\mathbf{e}^* = [\nu(k) \dots \nu(k + N - 1)]^T$ ,

- ▶ A matrix estendida de regressores é:


$$\Psi^* = \begin{bmatrix} & \vdots & \nu(k-1) \\ & \vdots & \nu(k) \\ \Psi & \vdots & \nu(k+1) \\ & \vdots & \vdots \\ & \vdots & \nu(k+N-2) \end{bmatrix}$$

$$\mathbf{e} \boldsymbol{\theta}^* = [\boldsymbol{\theta}^T \vdots c]^T.$$

- 
- 
- ▶ Deve ser notado que  $e^*(k)$  é uma variável aleatória “branca”, ou seja,

$$r_{e^*e^*}(k) = 0, \quad \forall k \neq 0,$$

e conseqüentemente  $E[\Psi e^*] = \mathbf{0}$ ,  $E[A^* e^*] = \mathbf{0}$  e  $E[\Psi^* e^*] = \mathbf{0}$ .

- 
- ▶ Deve ser notado que  $e^*(k)$  é uma variável aleatória “branca”, ou seja,

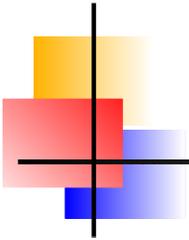
$$r_{e^*e^*}(k) = 0, \quad \forall k \neq 0,$$

e conseqüentemente  $E[\Psi \mathbf{e}^*] = \mathbf{0}$ ,  $E[A^* \mathbf{e}^*] = \mathbf{0}$  e  $E[\Psi^* \mathbf{e}^*] = \mathbf{0}$ .

- ▶ Logo, a estimativa

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

não apresentará polarização, ou seja,  $E[\hat{\boldsymbol{\theta}}^*] = [\boldsymbol{\theta}^{\text{T}} \mathbf{c}]^{\text{T}}$ .



## Resíduos como estimativa do ruído

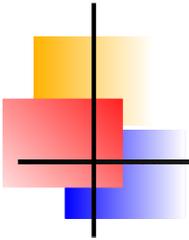
---

- ▶ Os dados serão gerados pelo seguinte modelo:

$$y(k) = ay(k-1) + bu(k-1) + e(k),$$

$$e(k) = 0,8\nu(k-1) + \nu(k),$$

sendo que  $\nu(k)$  e  $u(k)$  são independentes, brancos e gaussianos com  $\sigma_\nu^2 = 0,04$  e  $\sigma_u^2 = 1$ .



## Resíduos como estimativa do ruído

---

- ▶ Os dados serão gerados pelo seguinte modelo:


$$y(k) = ay(k-1) + bu(k-1) + e(k),$$

$$e(k) = 0,8\nu(k-1) + \nu(k),$$


sendo que  $\nu(k)$  e  $u(k)$  são independentes, brancos e gaussianos com  $\sigma_\nu^2 = 0,04$  e  $\sigma_u^2 = 1$ .

- ▶ Usando-se a estrutura acima como equação de regressão, obtém-se um modelo do tipo

$$y(k) = \hat{a}y(k-1) + \hat{b}u(k-1) + \xi(k).$$



(a)



(b)






Figura 2: Funções de autocorrelação de: (o) ruído MA e (+) resíduos  $\xi(k)$ . No gráfico superior os resíduos são de modelo polarizado. No gráfico inferior cruzes indicam a EAC do vetor de



---

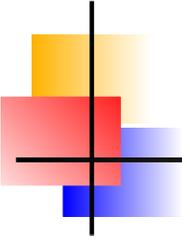
▶ A figura mostra que

$$e(k) = 0,8\nu(k-1) + \nu(k) \approx \hat{c}_1\tilde{\xi}(k-1) + \hat{c}_2\tilde{\xi}(k-2) + \tilde{\xi}(k).$$

- 
- 
- ▶ A figura mostra que


$$e(k) = 0,8\nu(k-1) + \nu(k) \approx \hat{c}_1\tilde{\xi}(k-1) + \hat{c}_2\tilde{\xi}(k-2) + \tilde{\xi}(k).$$

- ▶ Assumindo-se que a parte modelável do vetor de erro foi devidamente modelada (isso será constatado verificando-se que a polarização é eliminada).

- 
- 
- ▶ A figura mostra que


$$e(k) = 0,8\nu(k-1) + \nu(k) \approx \hat{c}_1\tilde{\xi}(k-1) + \hat{c}_2\tilde{\xi}(k-2) + \tilde{\xi}(k).$$

- ▶ Assumindo-se que a parte modelável do vetor de erro foi devidamente modelada (isso será constatado verificando-se que a polarização é eliminada.
- ▶ ou seja, se for verificado que  $0,8\nu(k-1) \approx \hat{c}_1\tilde{\xi}(k-1) + \hat{c}_2\tilde{\xi}(k-2)$ , então  $\tilde{\xi}(k) \approx \nu(k)$ .

- 
- ▶ A figura mostra que

$$e(k) = 0,8\nu(k-1) + \nu(k) \approx \hat{c}_1\tilde{\xi}(k-1) + \hat{c}_2\tilde{\xi}(k-2) + \tilde{\xi}(k).$$


- ▶ Assumindo-se que a parte modelável do vetor de erro foi devidamente modelada (isso será constatado verificando-se que a polarização é eliminada.
- ▶ ou seja, se for verificado que  $0,8\nu(k-1) \approx \hat{c}_1\tilde{\xi}(k-1) + \hat{c}_2\tilde{\xi}(k-2)$ , então  $\tilde{\xi}(k) \approx \nu(k)$ .
- ▶ Portanto, este exemplo verificou que, *após a convergência*, os resíduos podem ser utilizados como estimativa da nova variável regressora  $\nu(k)$  que aparece em  $\Psi^*$ . É precisamente isso que é feito pelo estimador EMQ.



## Mínimos Quadrados Estendido

---


- ▶ a partir da equação de regressão  $y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k)$  e dos dados disponíveis, monte a equação matricial  $\mathbf{y} = \boldsymbol{\Psi}\boldsymbol{\theta} + \mathbf{e}$ , como no método de mínimos quadrados, e determine  $\hat{\boldsymbol{\theta}}_{\text{MQ}} = [\boldsymbol{\Psi}^T\boldsymbol{\Psi}]^{-1}\boldsymbol{\Psi}^T\mathbf{y}$ ;



## Mínimos Quadrados Estendido

---


- ▶ a partir da equação de regressão  $y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k)$  e dos dados disponíveis, monte a equação matricial  $\mathbf{y} = \boldsymbol{\Psi}\boldsymbol{\theta} + \mathbf{e}$ , como no método de mínimos quadrados, e determine  $\hat{\boldsymbol{\theta}}_{\text{MQ}} = [\boldsymbol{\Psi}^T\boldsymbol{\Psi}]^{-1}\boldsymbol{\Psi}^T\mathbf{y}$ ;
- ▶ calcule o vetor de resíduos  $\boldsymbol{\xi}_1 = \mathbf{y} - \boldsymbol{\Psi}\hat{\boldsymbol{\theta}}_{\text{MQ}}$ ;



## Mínimos Quadrados Estendido

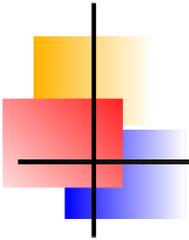
---

- ▶ a partir da equação de regressão  $y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k)$  e dos dados disponíveis, monte a equação matricial  $\mathbf{y} = \boldsymbol{\Psi}\boldsymbol{\theta} + \mathbf{e}$ , como no método de mínimos quadrados, e determine  $\hat{\boldsymbol{\theta}}_{\text{MQ}} = [\boldsymbol{\Psi}^T\boldsymbol{\Psi}]^{-1}\boldsymbol{\Psi}^T\mathbf{y}$ ;
- ▶ calcule o vetor de resíduos  $\boldsymbol{\xi}_1 = \mathbf{y} - \boldsymbol{\Psi}\hat{\boldsymbol{\theta}}_{\text{MQ}}$ ;
- ▶ faça  $i = 2$  ( $i$  indica o número da iteração);




## Mínimos Quadrados Estendido

- ▶ a partir da equação de regressão  $y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k)$  e dos dados disponíveis, monte a equação matricial  $\mathbf{y} = \boldsymbol{\Psi}\boldsymbol{\theta} + \mathbf{e}$ , como no método de mínimos quadrados, e determine  $\hat{\boldsymbol{\theta}}_{\text{MQ}} = [\boldsymbol{\Psi}^T\boldsymbol{\Psi}]^{-1}\boldsymbol{\Psi}^T\mathbf{y}$ ;
- ▶ calcule o vetor de resíduos  $\boldsymbol{\xi}_1 = \mathbf{y} - \boldsymbol{\Psi}\hat{\boldsymbol{\theta}}_{\text{MQ}}$ ;
- ▶ faça  $i = 2$  ( $i$  indica o número da iteração);
- ▶ com  $\boldsymbol{\xi}_{i-1}$ , monte a matriz estendida de regressores,  $\boldsymbol{\Psi}_i^*$ , e estime  $\hat{\boldsymbol{\theta}}_{\text{EMQ}i}^* = [\boldsymbol{\Psi}_i^{*T}\boldsymbol{\Psi}_i^*]^{-1}\boldsymbol{\Psi}_i^{*T}\mathbf{y}$ ;




## Mínimos Quadrados Estendido

- ▶ a partir da equação de regressão  $y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k)$  e dos dados disponíveis, monte a equação matricial  $\mathbf{y} = \boldsymbol{\Psi}\boldsymbol{\theta} + \mathbf{e}$ , como no método de mínimos quadrados, e determine  $\hat{\boldsymbol{\theta}}_{\text{MQ}} = [\boldsymbol{\Psi}^T\boldsymbol{\Psi}]^{-1}\boldsymbol{\Psi}^T\mathbf{y}$ ;
- ▶ calcule o vetor de resíduos  $\boldsymbol{\xi}_1 = \mathbf{y} - \boldsymbol{\Psi}\hat{\boldsymbol{\theta}}_{\text{MQ}}$ ;
- ▶ faça  $i = 2$  ( $i$  indica o número da iteração);
- ▶ com  $\boldsymbol{\xi}_{i-1}$ , monte a matriz estendida de regressores,  $\boldsymbol{\Psi}_i^*$ , e estime  $\hat{\boldsymbol{\theta}}_{\text{EMQ}i}^* = [\boldsymbol{\Psi}_i^{*T}\boldsymbol{\Psi}_i^*]^{-1}\boldsymbol{\Psi}_i^{*T}\mathbf{y}$ ;
- ▶ determine o vetor de resíduos  $\boldsymbol{\xi}_i = \mathbf{y} - \boldsymbol{\Psi}_i^*\hat{\boldsymbol{\theta}}_{\text{EMQ}i}^*$ ;



## Mínimos Quadrados Estendido


- ▶ a partir da equação de regressão  $y(k) = \boldsymbol{\psi}^T(k-1)\boldsymbol{\theta} + e(k)$  e dos dados disponíveis, monte a equação matricial  $\mathbf{y} = \boldsymbol{\Psi}\boldsymbol{\theta} + \mathbf{e}$ , como no método de mínimos quadrados, e determine  $\hat{\boldsymbol{\theta}}_{\text{MQ}} = [\boldsymbol{\Psi}^T\boldsymbol{\Psi}]^{-1}\boldsymbol{\Psi}^T\mathbf{y}$ ;
- ▶ calcule o vetor de resíduos  $\boldsymbol{\xi}_1 = \mathbf{y} - \boldsymbol{\Psi}\hat{\boldsymbol{\theta}}_{\text{MQ}}$ ;
- ▶ faça  $i = 2$  ( $i$  indica o número da iteração);
- ▶ com  $\boldsymbol{\xi}_{i-1}$ , monte a matriz estendida de regressores,  $\boldsymbol{\Psi}_i^*$ , e estime  $\hat{\boldsymbol{\theta}}_{\text{EMQ}i}^* = [\boldsymbol{\Psi}_i^{*T}\boldsymbol{\Psi}_i^*]^{-1}\boldsymbol{\Psi}_i^{*T}\mathbf{y}$ ;
- ▶ determine o vetor de resíduos  $\boldsymbol{\xi}_i = \mathbf{y} - \boldsymbol{\Psi}_i^*\hat{\boldsymbol{\theta}}_{\text{EMQ}i}^*$ ;
- ▶ faça  $i = i + 1$  e volte ao passo 4. Repita até convergir.



---

$$\begin{aligned}\nu(k) &= y(k) - ay(k-1) - bu(k-1) - c\nu(k-1) \\ &= y(k) - \boldsymbol{\psi}^{*\text{T}}(k-1, \boldsymbol{\theta}^*)\boldsymbol{\theta}^*.\end{aligned}$$

Modelos com esta propriedade são às vezes chamados de modelos *pseudolineares*.



# Eliminando polarização com o estimador EMQ — simulação

---

- ▶ Os dados serão gerados pelo seguinte modelo:

$$y(k) = ay(k-1) + bu(k-1) + e(k),$$

$$e(k) = 0,8\nu(k-1) + \nu(k),$$

sendo que  $\nu(k)$  e  $u(k)$  são independentes, brancos e gaussianos com  $\sigma_\nu^2 = 0,04$  e  $\sigma_u^2 = 1$ .



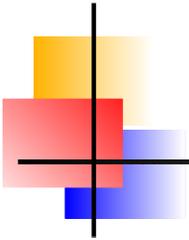


Figura 3: Eliminando polarização com o estimador EMQ. Os valores reais dos parâmetros são: (a)  $a = 0,7$ ; (b)  $b = 0,5$ ; (c)  $c_1 = c = 0,8$  e (d)  $c_2 = 0$ .




# Estimador EMQ com modelo de erro na saída

---

- ▶ Seja o modelo de erro na saída

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

que está representada na forma de um modelo ARMAX, com  $A(q) = F(q)$  e  $C(q) = F(q)$ .



# Estimador EMQ com modelo de erro na saída

---

- ▶ Seja o modelo de erro na saída

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


que está representada na forma de um modelo ARMAX, com  $A(q) = F(q)$  e  $C(q) = F(q)$ .

- ▶ Assim, para gerar os dados usou-se

$$w(k) = 1,5w(k-1) - 0,7w(k-2) + 0,5u(k-1)$$

$$y(k) = w(k) + \nu(k),$$

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

- 
- 
- ▶ A equação de regressão foi

$$A(q)y(k) = B(q)u(k) + C(q)v(k).$$

Constata-se que  $E[\hat{A}(q)] \approx E[\hat{C}(q)] \approx E[F(q)]$ .



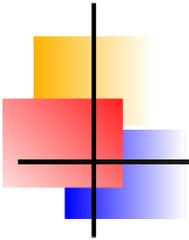


Figura 4: Estimador EMQ com modelo de erro na saída. Parâmetros estimados usando-se o estimador EMQ e um modelo ARMAX. Os dados foram gerados por um modelo de erro na saída. Os valores reais dos parâmetros são: (a,b)  $a_1 = c_1 = 1.5$ ;



## O Estimador Generalizado de MQ


---

- ▶ Uma outra maneira de eliminar a polarização é filtrar o vetor de erro original de forma que  $e^* = Qe$  seja branco. Portanto,

$$Q\mathbf{y} = Q(\Psi\boldsymbol{\theta} + \mathbf{e})$$

$$Q\mathbf{y} = Q\Psi\boldsymbol{\theta} + Q\mathbf{e}$$

$$\mathbf{y}^* = \Psi^*\boldsymbol{\theta} + \mathbf{e}^*.$$



## O Estimador Generalizado de MQ

- ▶ Uma outra maneira de eliminar a polarização é filtrar o vetor de erro original de forma que  $\mathbf{e}^* = Q\mathbf{e}$  seja branco. Portanto,

$$Q\mathbf{y} = Q(\Psi\boldsymbol{\theta} + \mathbf{e})$$


$$Q\mathbf{y} = Q\Psi\boldsymbol{\theta} + Q\mathbf{e}$$

$$\mathbf{y}^* = \Psi^*\boldsymbol{\theta} + \mathbf{e}^*.$$


- ▶ Seja  $R = \text{cov}[\mathbf{e}]$  a matriz de covariância do ruído da equação de regressão. Portanto,  
 $\text{cov}[\mathbf{e}^*] = \text{cov}[Q\mathbf{e}] = Q\text{cov}[\mathbf{e}]Q^T = QRQ^T$ . Também,  
 $\text{cov}[\mathbf{e}^*] = QRQ^T = \sigma_e^2 I$  e, portanto,

$$R = Q^{-1}\sigma_e^2Q^{-T} \quad \text{e} \quad R^{-1} = \frac{Q^T Q}{\sigma_e^2},$$

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

- 
- ▶ A estimativa de mínimos quadrados de  $\theta$  a partir das grandezas filtradas  $\Psi^*$  e  $\mathbf{y}^*$  é

$$\begin{aligned}\hat{\theta}_{\text{GMQ}} &= [\Psi^{*\text{T}} \Psi^*]^{-1} \Psi^{*\text{T}} \mathbf{y}^* \\ &= [(Q\Psi)^{\text{T}} (Q\Psi)]^{-1} (Q\Psi)^{\text{T}} Q\mathbf{y} \\ &= [\Psi^{\text{T}} Q^{\text{T}} Q\Psi]^{-1} \Psi^{\text{T}} Q^{\text{T}} Q\mathbf{y} \\ &= [\Psi^{\text{T}} \sigma_e^2 R^{-1} \Psi]^{-1} \Psi^{\text{T}} \sigma_e^2 R^{-1} \mathbf{y} \\ &= [\Psi^{\text{T}} R^{-1} \Psi]^{-1} \Psi^{\text{T}} R^{-1} \mathbf{y}.\end{aligned}$$



## O estimador de Markov

---

- ▶ Os dados serão gerados pelo seguinte modelo:

$$y(k) = ay(k-1) + bu(k-1) + e(k),$$

$$e(k) = 0,8\nu(k-1) + \nu(k),$$

sendo que  $\nu(k)$  e  $u(k)$  são independentes, brancos e gaussianos com  $\sigma_\nu^2 = 0,04$  e  $\sigma_u^2 = 1$ .





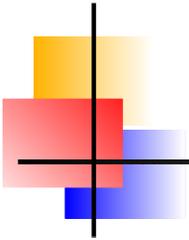


Figura 5: Estimador de Markov Os valores reais dos parâmetros são (a)  $a = 0,7$  e (b)  $b = 0,5$ .



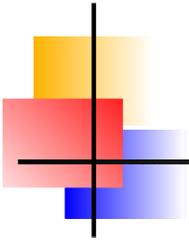
## O Estimador GMQ Iterativo

---

- ▶ O modelo será representado na seguinte forma:

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{C(q)}{D(q)}\nu(k),$$

sendo que  $A, B, C$  e  $D$  são polinômios em  $q^{-1}$  e  $\nu(k)$  é ruído branco.



## O Estimador GMQ Iterativo

---

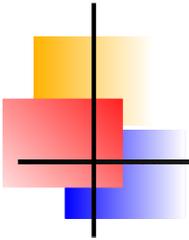
- ▶ O modelo será representado na seguinte forma:

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{C(q)}{D(q)}\nu(k),$$

sendo que  $A, B, C$  e  $D$  são polinômios em  $q^{-1}$  e  $\nu(k)$  é ruído branco.

- ▶ Tomando  $C = 1$  e omitindo os argumentos, tem-se

$$Ay(k) = Bu(k) + \frac{A}{D}\nu(k).$$



## O Estimador GMQ Iterativo

- ▶ O modelo será representado na seguinte forma:

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{C(q)}{D(q)}\nu(k),$$

sendo que  $A, B, C$  e  $D$  são polinômios em  $q^{-1}$  e  $\nu(k)$  é ruído branco.

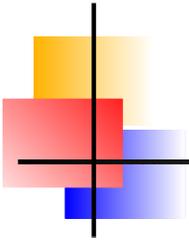
- ▶ Tomando  $C = 1$  e omitindo os argumentos, tem-se

$$Ay(k) = Bu(k) + \frac{A}{D}\nu(k).$$

- ▶ Substituindo-se  $D = AD'$  na última equação, tem-se

$$Ay(k) = Bu(k) + \frac{1}{D'}\nu(k),$$

sendo que o erro  $e(k) = \nu(k)/D'$  não será branco, a menos que  $D' = 1$ .




---

► Supondo que  $D'$  seja conhecido. Nesse caso tem-se

$$y^*(k) = D'y(k)$$

$$u^*(k) = D'u(k).$$

- 
- 
- ▶ Supondo que  $D'$  seja conhecido. Nesse caso tem-se


$$y^*(k) = D'y(k)$$

$$u^*(k) = D'u(k).$$

- ▶ Multiplicando-se por  $D'$  tem-se

$$AD'y(k) = BD'u(k) + \nu(k)$$


$$Ay^*(k) = Bu^*(k) + \nu(k).$$



## O estimador GMQ iterativo

---


1. Usando o estimador MQ, estime  $\hat{A}_i$  e  $\hat{B}_i$  com  $y_{i-1}^*(k)$  e  $u_{i-1}^*(k)$ ;



## O estimador GMQ iterativo

---


1. Usando o estimador MQ, estime  $\hat{A}_i$  e  $\hat{B}_i$  com  $y_{i-1}^*(k)$  e  $u_{i-1}^*(k)$ ;
2. determine os resíduos fazendo  $\xi_i(k) = \hat{A}_i y(k) - \hat{B}_i u(k)$ ;



## O estimador GMQ iterativo

---

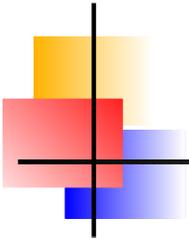
1. Usando o estimador MQ, estime  $\hat{A}_i$  e  $\hat{B}_i$  com  $y_{i-1}^*(k)$  e  $u_{i-1}^*(k)$ ;
2. determine os resíduos fazendo  $\xi_i(k) = \hat{A}_i y(k) - \hat{B}_i u(k)$ ;
3. ajuste um modelo auto-regressivo usando o estimador MQ para a seqüência de resíduos, ou seja,  
 $\xi_i(k) = -\hat{D}'_i(q)\xi_i(k) + \nu_i(k)$ . Aqui,  $\hat{D}'_i(q)$  é o filtro descorrelacionador de ruído a ser utilizado na iteração  $i$ ;



## O estimador GMQ iterativo

---

1. Usando o estimador MQ, estime  $\hat{A}_i$  e  $\hat{B}_i$  com  $y_{i-1}^*(k)$  e  $u_{i-1}^*(k)$ ;
2. determine os resíduos fazendo  $\xi_i(k) = \hat{A}_i y(k) - \hat{B}_i u(k)$ ;
3. ajuste um modelo auto-regressivo usando o estimador MQ para a seqüência de resíduos, ou seja,  
 $\xi_i(k) = -\hat{D}'_i(q)\xi_i(k) + \nu_i(k)$ . Aqui,  $\hat{D}'_i(q)$  é o filtro descorrelacionador de ruído a ser utilizado na iteração  $i$ ;
4. atualize as séries filtradas  $y_i^*(k) = \hat{D}'_i(q)y(k)$  e  $u_i^*(k) = \hat{D}'_i(q)u(k)$ . Incremente  $i$  e volte ao passo 1 até observar convergência.



## O estimador GMQ com ruído MA e AR

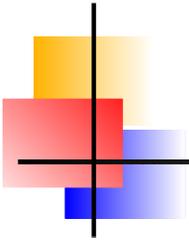
---

- ▶ Os dados serão gerados pelo seguinte modelo:

$$y(k) = ay(k-1) + bu(k-1) + e(k),$$

$$e(k) = 0,8\nu(k-1) + \nu(k),$$

sendo que  $\nu(k)$  e  $u(k)$  são independentes, brancos e gaussianos com  $\sigma_\nu^2 = 0,04$  e  $\sigma_u^2 = 1$ .



## O estimador GMQ com ruído MA e AR

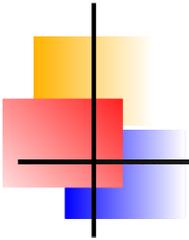
- ▶ Os dados serão gerados pelo seguinte modelo:

$$y(k) = ay(k-1) + bu(k-1) + e(k),$$

$$e(k) = 0,8\nu(k-1) + \nu(k),$$

sendo que  $\nu(k)$  e  $u(k)$  são independentes, brancos e gaussianos com  $\sigma_\nu^2 = 0,04$  e  $\sigma_u^2 = 1$ .

- ▶ O estimador GMQ foi empregado para obter  $\hat{a}$  e  $\hat{b}$  em 400 realizações diferentes do ruído  $\nu(k)$  ( $N = 500$ ).



## O estimador GMQ com ruído MA e AR

- ▶ Os dados serão gerados pelo seguinte modelo:

$$y(k) = ay(k-1) + bu(k-1) + e(k),$$

$$e(k) = 0,8\nu(k-1) + \nu(k),$$

sendo que  $\nu(k)$  e  $u(k)$  são independentes, brancos e gaussianos com  $\sigma_\nu^2 = 0,04$  e  $\sigma_u^2 = 1$ .

- ▶ O estimador GMQ foi empregado para obter  $\hat{a}$  e  $\hat{b}$  em 400 realizações diferentes do ruído  $\nu(k)$  ( $N = 500$ ).

Neste exemplo o ruído será tanto um processo MA quanto um processo AR. Na formulação usada do estimador GMQ iterativo, o ruído é sempre modelado (parametrizado) como um processo AR. O presente exemplo ilustra o desempenho desse estimador em ambos os casos.





Figura 6: Estimador GMQ com ruído MA. Histogramas dos parâmetros estimados pelo estimador GMQ para o caso de erros do tipo ruído MA ( $e(k) = 0,8\nu(k-1) + \nu(k)$ ) e presença de regressores de saída. Os gráficos (a) e (c) correspondem aos valores dos parâmetros estimados na primeira iteração do algoritmo ite-





Figura 7: Estimador GMQ com ruído MA, coeficiente de ruído. Histograma de estimativas de  $-\hat{d}_1$ , sendo  $\hat{D}'(q) = 1 + \hat{d}_1 q^{-1}$ . A razão de  $E(-\hat{d}_1) \neq 0,8$  deve-se ao fato de que o estimador GMQ pressupõe ruído AR e, na realidade, o ruído usado para gerar os dados foi do tipo MA.


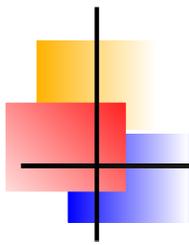


Figura 8: Estimador GMQ com ruído AR. Histogramas dos parâmetros estimados pelo estimador GMQ no caso do erro ser do tipo ruído AR ( $e(k) = 0,8e(k - 1) + \nu(k)$ ) e presença de regressores de saída. Os gráficos (a) e (c) correspondem aos valores dos parâmetros estimados na primeira iteração do algoritmo ite-







Figura 9: Estimador GMQ com ruído AR, coeficiente de ruído. Histograma de estimativas de  $-\hat{d}_1$ , sendo  $\hat{D}'(q) = 1 + \hat{d}_1 q^{-1}$ . O valor real de  $d_1$  é 0,8.



## *O Método das Variáveis Instrumentais*

---

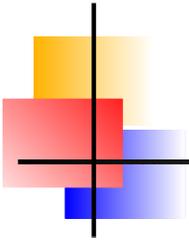
- ▶ A definição de polarização utilizada até o presente é a definição para pequenas amostras (PPA).



## O Método das Variáveis Instrumentais

---

- ▶ A definição de polarização utilizada até o presente é a definição para pequenas amostras (PPA).
- ▶ Uma alternativa à definição de polarização PPA é a polarização *assintótica*. A idéia é relaxar um pouco a definição PPA e, por um lado, permitir que haja polarização para uma amostra pequena, mas por outro, verificar se tal polarização desaparece à medida que o tamanho do conjunto de observações cresce.





## O Método das Variáveis Instrumentais

- ▶ A definição de polarização utilizada até o presente é a definição para pequenas amostras (PPA).
- ▶ Uma alternativa à definição de polarização PPA é a polarização *assintótica*. A idéia é relaxar um pouco a definição PPA e, por um lado, permitir que haja polarização para uma amostra pequena, mas por outro, verificar se tal polarização desaparece à medida que o tamanho do conjunto de observações cresce.


$$\begin{aligned} \mathbf{b}_a &= \lim_{N \rightarrow \infty} E[\hat{\boldsymbol{\theta}}(N)] - \boldsymbol{\theta} \\ &= \text{plim}[\hat{\boldsymbol{\theta}}] - \boldsymbol{\theta} \\ &= \text{plim} [A(\Psi\boldsymbol{\theta} + \mathbf{e})] - \boldsymbol{\theta} \\ &= \text{plim} [A\Psi\boldsymbol{\theta} + A\mathbf{e}] - \boldsymbol{\theta} \\ &= \text{plim} [A\mathbf{e}], \end{aligned}$$

sendo que foi assumido que  $A\Psi = I$ .

- 
- 
- ▶ Deseja-se ter  $A = BC$ , sendo que  $B = f(\mathbf{z}) \in \mathbb{R}^{n \times n}$  e  $C = g(\mathbf{z}) \in \mathbb{R}^{n \times N}$ , sendo  $\mathbf{z} \in \mathbb{R}^n$  um vetor de variáveis aleatórias.

- 
- 
- ▶ Deseja-se ter  $A = BC$ , sendo que  $B = f(\mathbf{z}) \in \mathbb{R}^{n \times n}$  e  $C = g(\mathbf{z}) \in \mathbb{R}^{n \times N}$ , sendo  $\mathbf{z} \in \mathbb{R}^n$  um vetor de variáveis aleatórias.
  - ▶ As matrizes  $B$  e  $C$  podem ser definidas da seguinte forma:


$$B = [Z^T \Psi]^{-1} \quad \text{e} \quad C = Z^T.$$

- 
- ▶ Deseja-se ter  $A = BC$ , sendo que  $B = f(\mathbf{z}) \in \mathbb{R}^{n \times n}$  e  $C = g(\mathbf{z}) \in \mathbb{R}^{n \times N}$ , sendo  $\mathbf{z} \in \mathbb{R}^n$  um vetor de variáveis aleatórias.
  - ▶ As matrizes  $B$  e  $C$  podem ser definidas da seguinte forma:

$$B = [Z^T \Psi]^{-1} \quad \text{e} \quad C = Z^T.$$

- ▶ Tem-se o seguinte estimador

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



▶ Deseja-se ter  $A=BC$ , sendo que  $B=f(\mathbf{z}) \in \mathbb{R}^{n \times n}$  e  $C=g(\mathbf{z}) \in \mathbb{R}^{n \times N}$ , sendo  $\mathbf{z} \in \mathbb{R}^n$  um vetor de variáveis aleatórias.

▶ As matrizes  $B$  e  $C$  podem ser definidas da seguinte forma:


$$B = [Z^T \Psi]^{-1} \quad \text{e} \quad C = Z^T.$$

▶ Tem-se o seguinte estimador

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

▶ Portanto, tem-se

$$\begin{aligned} \mathbf{b}_a &= \text{plim} [A\mathbf{e}] \\ &= \text{plim} [(Z^T \Psi)^{-1} Z^T \mathbf{e}] \\ &= \text{plim} [(Z^T \Psi)^{-1}] \text{plim} [Z^T \mathbf{e}], \end{aligned}$$




---

▶ Finalmente

$$\mathbf{b}_a = N_{\text{plim}} [(Z^T \Psi)^{-1}] \mathbf{c},$$

sendo  $\mathbf{c}$  o vetor de correlação cruzada entre as colunas de  $Z$  (geradas pelas variáveis instrumentais) e  $\mathbf{e}$ .




## O estimador VI sem a propriedade de ortogonalidade

À semelhança do estimador MQP, o estimador VI também é do tipo  $\hat{\theta} = Ay$ , mas para o caso do estimador VI tem-se  $A = [Z^T \Psi]^{-1} Z^T$ . Logo, pode-se testar se o estimador VI satisfaz a condição de ortogonalidade. Para esse estimador, tem-se

$$\begin{aligned}\Psi^T \Psi Ay &\stackrel{?}{=} \Psi^T \mathbf{y} \\ \Psi^T \Psi [Z^T \Psi]^{-1} Z^T \mathbf{y} &\stackrel{?}{=} \Psi^T \mathbf{y},\end{aligned}$$

sendo que a condição não é satisfeita para o estimador em estudo. Esse resultado não deve causar nenhuma surpresa. A forma do estimador VI evitar a polarização é diferente da forma usada pelo estimador EMQ. O estimador VI não força os resíduos a serem brancos e, portanto, o vetor de resíduos *não* é ortogonal à hipersuperfície gerada pelos regressores do modelo.

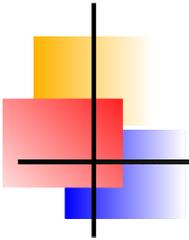


## *O estimador VI*

---

Neste exemplo, o estimador VI será utilizado em três situações distintas.

- ▶ Em primeiro lugar, será considerado o caso em que há ruído de observação e este é branco.




## *O estimador VI*

---

Neste exemplo, o estimador VI será utilizado em três situações distintas.

- ▶ Em primeiro lugar, será considerado o caso em que há ruído de observação e este é branco.
- ▶ Os outros dois casos investigados usam erros do tipo ruídos MA e AR na equação de regressão.




## *O estimador VI*

---

Neste exemplo, o estimador VI será utilizado em três situações distintas.

- ▶ Em primeiro lugar, será considerado o caso em que há ruído de observação e este é branco.
- ▶ Os outros dois casos investigados usam erros do tipo ruídos MA e AR na equação de regressão.

Para cada caso, duas escolhas de regressores foram testadas.



## O estimador VI


---

Neste exemplo, o estimador VI será utilizado em três situações distintas.

- ▶ Em primeiro lugar, será considerado o caso em que há ruído de observação e este é branco.
- ▶ Os outros dois casos investigados usam erros do tipo ruídos MA e AR na equação de regressão.

Para cada caso, duas escolhas de regressores foram testadas.

- ▶ Primeiramente, os regressores do sinal de saída, do tipo  $y(k - 1)$ , foram substituídos pelas respectivas previsões de um passo à frente,  $\hat{y}(k - 1)$ .



## O estimador VI


---

Neste exemplo, o estimador VI será utilizado em três situações distintas.

- ▶ Em primeiro lugar, será considerado o caso em que há ruído de observação e este é branco.
- ▶ Os outros dois casos investigados usam erros do tipo ruídos MA e AR na equação de regressão.

Para cada caso, duas escolhas de regressores foram testadas.


- ▶ Primeiramente, os regressores do sinal de saída, do tipo  $y(k-1)$ , foram substituídos pelas respectivas previsões de um passo à frente,  $\hat{y}(k-1)$ .
- ▶ Uma segunda alternativa substitui o vetor de regressores  $\psi(k-1) = [y(k-1) \ u(k-1)]^T$  pelo vetor de variáveis instrumentais  $\mathbf{z}(k-1) = [u(k-1) \ u(k-2)]^T$ .



## Exemplo

---

- ▶ Os dados para a primeira parte do exemplo foram gerados pelo modelo  $y^i(k) = 0,7y^i(k-1) + 0,5u(k-1)$ , com condições iniciais nulas e tomando  $u(k)$  como ruído branco, distribuição gaussiana com média zero e variância unitária.



## Exemplo

---

- ▶ Os dados para a primeira parte do exemplo foram gerados pelo modelo  $y^i(k) = 0,7y^i(k-1) + 0,5u(k-1)$ , com condições iniciais nulas e tomando  $u(k)$  como ruído branco, distribuição gaussiana com média zero e variância unitária.
- ▶ A seguir, adicionou-se ruído de observação de tal forma a gerar  $y(k) = y^i(k) + \nu(k)$ , sendo  $\nu(k)$  ruído branco e gaussiano com  $E(\nu(k))=0$  e  $\sigma_\nu^2 = 0,04$ . Em todas as simulações numéricas deste exemplo foram usadas 400 realizações com  $N = 500$ .





Figura 10: Estimador VI com ruído de observação. Histogramas dos parâmetros estimados pelo estimador VI para o caso de ruído de observação branco. Os gráficos (a) e (c) correspondem aos valores dos parâmetros estimados pelo estimador MQ. Os gráficos (b) e (d) correspondem ao estimador VI com





Figura 11: Estimador VI com ruído de observação. Histogramas dos parâmetros estimados pelo estimador VI para o caso de ruído de observação branco. Os gráficos (a) e (c) correspondem aos valores dos parâmetros estimados pelo estimador MQ. Os gráficos (b) e (d) correspondem ao estimador VI com





Figura 12: Estimador VI com erro AR de regressão. Histogramas dos parâmetros estimados pelo estimador VI para o caso de erro de regressão do tipo ruído AR. Os gráficos (a) e (c) correspondem aos valores dos parâmetros estimados pelo estimador MQ. Os gráficos (b) e (d) correspondem ao estimador VI com







Figura 13: Estimador VI com erro AR de regressão. Histogramas dos parâmetros estimados pelo estimador VI para o caso de erro de regressão do tipo ruído AR. Os gráficos (a) e (c) correspondem aos valores dos parâmetros estimados pelo estimador MQ. Os gráficos (b) e (d) correspondem ao estimador VI com os ins-



# Complementos - Solução do problema de erro nas variáveis

---

Neste exemplo os dados ideais serão gerados por

$$y^i(k) = 1,5y^i(k-1) - 0,7y^i(k-2) + 0,5u^i(k-1),$$

sendo que  $u^i(k)$  é um sinal aleatório com distribuição normal, média nula e variância  $\sigma_u^2 = 1$ .

Tanto o sinal de entrada quanto o de saída são observados com ruído branco, de média nula e variância 0,04. Isso é representado da seguinte forma  $y(k) = y^i(k) + e_y(k)$  e  $u(k) = u^i(k) + e_u(k)$ . Além disso,  $e_y(k)$  e  $e_u(k)$  não estão correlacionados.





Figura 14: Eliminando polarização com o estimador MQT. Histogramas de valores estimados usando os estimadores MQ e MQT quando os sinais de entrada e saída têm ruído de medição branco. Os gráficos (a,c,e) correspondem ao estimador MQ e os gráficos (b,d,f) correspondem ao estimador MQT. Os valores reais