

Capítulo 8 - Estimadores Recursivos

Eduardo Mendes

`emmendes@cpdee.ufmg.br`

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



Introdução

Será que é possível utilizar os dados seqüencialmente para atualizar o vetor de parâmetros de um determinado modelo? A resposta é afirmativa e o procedimento é conhecido como estimação recursiva.

No presente capítulo serão estudados alguns algoritmos recursivos. Algumas pequenas modificações serão feitas na nomenclatura. Neste capítulo, o subíndice k indicará a iteração do respectivo algoritmo recursivo.



Atualização Recursiva

- ▶ Seja o sistema $y(k) = \psi^T \theta + e(k)$, sendo $E[e(k)] = 0$ e $\text{cov}[e(k)] = R$. Um modelo para o sistema acima pode ser escrito da seguinte maneira:

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

sendo que o vetor de regressores $\psi_k(k-1)$ é formado na iteração k com informação disponível até a iteração $k-1$ e $\hat{\theta}_k$ indica o vetor de parâmetros estimado na iteração k .



Atualização Recursiva

- ▶ Seja o sistema $y(k) = \boldsymbol{\psi}^T \boldsymbol{\theta} + e(k)$, sendo $E[e(k)] = 0$ e $\text{cov}[e(k)] = R$. Um modelo para o sistema acima pode ser escrito da seguinte maneira:

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

sendo que o vetor de regressores $\boldsymbol{\psi}_k(k-1)$ é formado na iteração k com informação disponível até a iteração $k-1$ e $\hat{\boldsymbol{\theta}}_k$ indica o vetor de parâmetros estimado na iteração k .

- ▶ Propõe-se, então, escrever

$$\hat{\boldsymbol{\theta}}_k = J_k \hat{\boldsymbol{\theta}}_{k-1} + K_k y(k),$$

e J_k e K_k são matrizes que deverão ser determinadas de tal maneira a garantir que $\hat{\boldsymbol{\theta}}_k$ seja uma boa estimativa.



Serão usadas as seguintes restrições:

i) $\hat{\theta}_k$ deve ser não polarizado, ou seja, $E[\hat{\theta}_k] - \theta = 0$;



Serão usadas as seguintes restrições:

- i) $\hat{\theta}_k$ deve ser não polarizado, ou seja, $E[\hat{\theta}_k] - \theta = 0$;
- ii) $\text{cov}(\hat{\theta}_k)$ deve ser tão pequena quanto possível.



Atualização recursiva não polarizada

► Impondo-se não-polarização, tem-se

$$\begin{aligned}\boldsymbol{\theta} &= \mathbf{E}[\hat{\boldsymbol{\theta}}_k] \\ &= \mathbf{J}_k \mathbf{E}[\hat{\boldsymbol{\theta}}_{k-1}] + \mathbf{K}_k \mathbf{E}[y(k)] \\ &= \mathbf{J}_k \boldsymbol{\theta} + \mathbf{K}_k \mathbf{E}[\boldsymbol{\psi}_k^T \hat{\boldsymbol{\theta}}_k] + \mathbf{K}_k \mathbf{E}[\xi(k)].\end{aligned}$$



Atualização recursiva não polarizada

- ▶ Impondo-se não-polarização, tem-se

$$\begin{aligned}\boldsymbol{\theta} &= \mathbf{E}[\hat{\boldsymbol{\theta}}_k] \\ &= \mathbf{J}_k \mathbf{E}[\hat{\boldsymbol{\theta}}_{k-1}] + \mathbf{K}_k \mathbf{E}[y(k)] \\ &= \mathbf{J}_k \boldsymbol{\theta} + \mathbf{K}_k \mathbf{E}[\boldsymbol{\psi}_k^T \hat{\boldsymbol{\theta}}_k] + \mathbf{K}_k \mathbf{E}[\xi(k)].\end{aligned}$$

- ▶ Considerando a média dos resíduos nula e os regressores determinísticos, tem-se

$$\begin{aligned}\boldsymbol{\theta} &= \mathbf{J}_k \boldsymbol{\theta} + \mathbf{K}_k \boldsymbol{\psi}_k^T \boldsymbol{\theta} \\ \mathbf{I} &= \mathbf{J}_k + \mathbf{K}_k \boldsymbol{\psi}_k^T \\ \mathbf{J}_k &= \mathbf{I} - \mathbf{K}_k \boldsymbol{\psi}_k^T.\end{aligned}$$



► Portanto,

$$\hat{\boldsymbol{\theta}}_k = (I - K_k \boldsymbol{\psi}_k^T) \hat{\boldsymbol{\theta}}_{k-1} + K_k y(k)$$
$$\hat{\boldsymbol{\theta}}_k = \hat{\boldsymbol{\theta}}_{k-1} + K_k (y(k) - \boldsymbol{\psi}_k^T \hat{\boldsymbol{\theta}}_{k-1}).$$



▶ Portanto,

$$\begin{aligned}\hat{\boldsymbol{\theta}}_k &= (I - K_k \boldsymbol{\psi}_k^T) \hat{\boldsymbol{\theta}}_{k-1} + K_k y(k) \\ \hat{\boldsymbol{\theta}}_k &= \hat{\boldsymbol{\theta}}_{k-1} + K_k (y(k) - \boldsymbol{\psi}_k^T \hat{\boldsymbol{\theta}}_{k-1}).\end{aligned}$$

▶ A *inovação* é

$$\eta(k) = y(k) - \boldsymbol{\psi}_k^T \hat{\boldsymbol{\theta}}_{k-1}.$$



Atualização recursiva não polarizada de mínima covariância

- ▶ A seguir, $P_k = \text{cov}[\hat{\boldsymbol{\theta}}_k]$ indicará a matriz de covariância calculada na iteração k .

$$\begin{aligned} P_k &= \text{E} \left[(\hat{\boldsymbol{\theta}}_k - \text{E}[\hat{\boldsymbol{\theta}}_k]) (\hat{\boldsymbol{\theta}}_k - \text{E}[\hat{\boldsymbol{\theta}}_k])^T \right] \\ &= \text{E} \left[\left((I - K_k \boldsymbol{\psi}_k^T) \hat{\boldsymbol{\theta}}_{k-1} + K_k y(k) - \boldsymbol{\theta}_k \right) (\bullet)^T \right], \end{aligned}$$



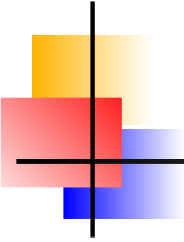
Atualização recursiva não polarizada de mínima covariância

- ▶ A seguir, $P_k = \text{cov}[\hat{\boldsymbol{\theta}}_k]$ indicará a matriz de covariância calculada na iteração k .

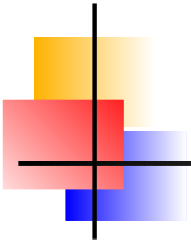
$$\begin{aligned} P_k &= \text{E} \left[(\hat{\boldsymbol{\theta}}_k - \text{E}[\hat{\boldsymbol{\theta}}_k]) (\hat{\boldsymbol{\theta}}_k - \text{E}[\hat{\boldsymbol{\theta}}_k])^T \right] \\ &= \text{E} \left[\left((I - K_k \boldsymbol{\psi}_k^T) \hat{\boldsymbol{\theta}}_{k-1} + K_k y(k) - \boldsymbol{\theta}_k \right) (\bullet)^T \right], \end{aligned}$$

- ▶ Somando-se e subtraindo-se a matriz $K_k \boldsymbol{\psi}_k^T \boldsymbol{\theta}$ nos parênteses da equação (-4), chega-se a

$$\begin{aligned} P_k &= \text{E} \left[\left((I - K_k \boldsymbol{\psi}_k^T) (\hat{\boldsymbol{\theta}}_{k-1} - \boldsymbol{\theta}) + K_k (y(k) - \boldsymbol{\psi}_k^T \boldsymbol{\theta}_k) \right) (\bullet)^T \right] \\ &= \text{E} \left[\left((I - K_k \boldsymbol{\psi}_k^T) (\hat{\boldsymbol{\theta}}_{k-1} - \boldsymbol{\theta}) + K_k e(k) \right) (\bullet)^T \right]. \end{aligned}$$

- 
-
- ▶ Considerando-se que o ruído $e(k)$ não está correlacionado com o vetor de regressores ψ_k nem com $(\hat{\theta}_{k-1} - \theta)$, pode-se escrever

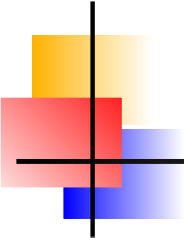
$$P_k = E \left[(I - K_k \psi_k^T) (\hat{\theta}_{k-1} - \theta) (\hat{\theta}_{k-1} - \theta)^T (I - K_k \psi_k^T)^T \right] \\ + E [K_k e(k) e(k)^T K_k^T].$$

- 
- ▶ Considerando-se que o ruído $e(k)$ não está correlacionado com o vetor de regressores ψ_k nem com $(\hat{\theta}_{k-1} - \theta)$, pode-se escrever

$$P_k = E \left[(I - K_k \psi_k^T) (\hat{\theta}_{k-1} - \theta) (\hat{\theta}_{k-1} - \theta)^T (I - K_k \psi_k^T)^T \right] + E [K_k e(k) e(k)^T K_k^T].$$

- ▶ Considerando-se os regressores determinísticos, tem-se

$$P_k = (I - K_k \psi_k^T) E \left[(\hat{\theta}_{k-1} - \theta) (\hat{\theta}_{k-1} - \theta)^T \right] (I - K_k \psi_k^T)^T + K_k E [e(k) e(k)^T] K_k^T.$$

- 
- ▶ Considerando-se que o ruído $e(k)$ não está correlacionado com o vetor de regressores ψ_k nem com $(\hat{\theta}_{k-1} - \theta)$, pode-se escrever

$$P_k = \mathbb{E} \left[(I - K_k \psi_k^T) (\hat{\theta}_{k-1} - \theta) (\hat{\theta}_{k-1} - \theta)^T (I - K_k \psi_k^T)^T \right] + \mathbb{E} [K_k e(k) e(k)^T K_k^T].$$

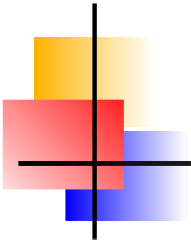
- ▶ Considerando-se os regressores determinísticos, tem-se

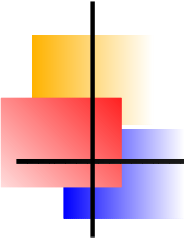
$$P_k = (I - K_k \psi_k^T) \mathbb{E} \left[(\hat{\theta}_{k-1} - \theta) (\hat{\theta}_{k-1} - \theta)^T \right] (I - K_k \psi_k^T)^T + K_k \mathbb{E} [e(k) e(k)^T] K_k^T.$$

- ▶ Finalmente, supondo que o ruído tem média nula, tem-se

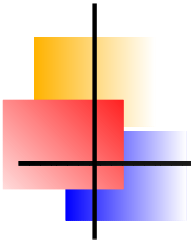
$$P_k = (I - K_k \psi_k^T) P_{k-1} (I - K_k \psi_k^T)^T + K_k R K_k^T,$$

sendo $\text{cov}[e(k)] = R = \mathbb{E} [e(k) e(k)^T]$.

- 
-
- ▶ No caso monovariável, $e(k)$ é um escalar e, portanto, $R = \sigma_e^2$ é simplesmente a variância do ruído.

- 
- ▶ No caso monovariável, $e(k)$ é um escalar e, portanto, $R = \sigma_e^2$ é simplesmente a variância do ruído.
 - ▶ P_k é uma função discreta e nesse caso deseja-se minimizar a variação ΔP_k provocada por uma variação ΔK_k . Assim, chamando $P_k^* = P_k + \Delta P_k$ o novo valor de P_k devido a uma variação em K_k , tem-se

$$\begin{aligned}\Delta P_k &= (I - (K_k + \Delta K_k)\psi_k^T) P_{k-1} (I - (K_k + \Delta K_k)\psi_k^T)^T + \\ &\quad (K_k + \Delta K_k)R(K_k + \Delta K_k)^T - \\ &\quad (I - K_k\psi_k^T)P_{k-1}(I - K_k\psi_k^T)^T - K_k R K_k^T.\end{aligned}$$

- 
- ▶ No caso monovariável, $e(k)$ é um escalar e, portanto, $R = \sigma_e^2$ é simplesmente a variância do ruído.
 - ▶ P_k é uma função discreta e nesse caso deseja-se minimizar a variação ΔP_k provocada por uma variação ΔK_k . Assim, chamando $P_k^* = P_k + \Delta P_k$ o novo valor de P_k devido a uma variação em K_k , tem-se

$$\begin{aligned} \Delta P_k = & (I - (K_k + \Delta K_k)\psi_k^T) P_{k-1} (I - (K_k + \Delta K_k)\psi_k^T)^T + \\ & (K_k + \Delta K_k)R(K_k + \Delta K_k)^T - \\ & (I - K_k\psi_k^T)P_{k-1}(I - K_k\psi_k^T)^T - K_kRK_k^T. \end{aligned}$$

- ▶ Desprezando-se os termos quadráticos em ΔK_k e igualando-se a expressão resultante a zero, obtém-se

$$\begin{aligned} \Delta P_k \approx & \Delta K_k [-\psi_k^T P_{k-1} (I - \psi_k K_k^T) + RK_k^T] \\ & - [(I - K_k\psi_k^T)P_{k-1}\psi_k - K_kR] \Delta K_k^T. \end{aligned}$$

- 
-
- ▶ Para que $\Delta P_k = 0$, ambos os termos entre colchetes devem ser nulos. Essas condições geram as seguintes equações:

$$0 = -\psi_k^T P_{k-1} (I - \psi_k K_k^T) + R K_k^T$$

$$0 = (I - K_k \psi_k^T) P_{k-1} \psi_k - K_k R.$$

- 
- Para que $\Delta P_k = 0$, ambos os termos entre colchetes devem ser nulos. Essas condições geram as seguintes equações:

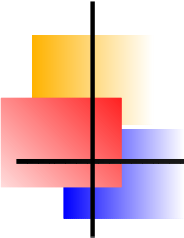
$$0 = -\psi_k^T P_{k-1} (I - \psi_k K_k^T) + R K_k^T$$

$$0 = (I - K_k \psi_k^T) P_{k-1} \psi_k - K_k R.$$

- Finalmente, da última equação, tem-se

$$K_k (\psi_k^T P_{k-1} \psi_k + R) = P_{k-1} \psi_k$$

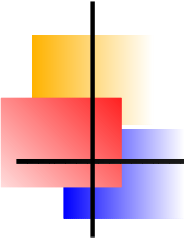
$$K_k = P_{k-1} \psi_k (\psi_k^T P_{k-1} \psi_k + R)^{-1}.$$

- 
-
- ▶ Portanto, um algoritmo recursivo para a estimação do vetor θ é

$$K_k = P_{k-1} \psi_k (\psi_k^T P_{k-1} \psi_k + R)^{-1};$$

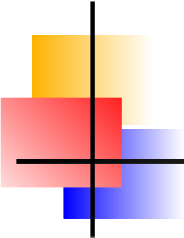
$$\hat{\theta}_k = \hat{\theta}_{k-1} + K_k (y(k) - \psi_k^T \hat{\theta}_{k-1});$$

$$P_k = (I - K_k \psi_k^T) P_{k-1} (I - K_k \psi_k^T)^T + K_k R K_k^T.$$

- 
-
- ▶ A dimensão da matriz $[\psi_k^T P_{k-1} \psi_k + R]$ é igual ao número de saídas medidas.

Na primeira iteração tem-se

$$\begin{aligned} y(1) &= \psi_1^T \hat{\theta}_1 \\ &= \psi_1^T \left[\hat{\theta}_0 + K_1 \left(y(1) - \psi_1^T \hat{\theta}_0 \right) \right] \\ &= \psi_1^T \left[\hat{\theta}_0 + P_0 \psi_1 (\psi_1^T P_0 \psi_1 + R)^{-1} \left(y(1) - \psi_1^T \hat{\theta}_0 \right) \right]. \end{aligned}$$

- 
- ▶ A dimensão da matriz $[\psi_k^T P_{k-1} \psi_k + R]$ é igual ao número de saídas medidas.

Na primeira iteração tem-se

$$\begin{aligned} y(1) &= \psi_1^T \hat{\theta}_1 \\ &= \psi_1^T \left[\hat{\theta}_0 + K_1 \left(y(1) - \psi_1^T \hat{\theta}_0 \right) \right] \\ &= \psi_1^T \left[\hat{\theta}_0 + P_0 \psi_1 (\psi_1^T P_0 \psi_1 + R)^{-1} \left(y(1) - \psi_1^T \hat{\theta}_0 \right) \right]. \end{aligned}$$

- ▶ Se $\psi_1^T P_0 \psi_1 \gg R$ (isso pode ser conseguido para valores elevados de P_0) a última equação pode ser aproximada por:

$$\begin{aligned} \hat{y}(1) &\approx \psi_1^T \hat{\theta}_0 + \psi_1^T P_0 \psi_1 (\psi_1^T P_0 \psi_1)^{-1} y(1) \\ &\quad - \psi_1^T P_0 \psi_1 (\psi_1^T P_0 \psi_1)^{-1} \psi_1^T \hat{\theta}_0 \\ &\approx \psi_1^T \hat{\theta}_0 + y(1) - \psi_1^T \hat{\theta}_0 = y(1). \end{aligned}$$



Estimador Recursivo MQ

O ponto de partida é o modelo $y(k) = \boldsymbol{\psi}^T(k-1)\hat{\boldsymbol{\theta}} + \xi(k)$ e uma seqüência de dados, representados em $y(k)$ e $\boldsymbol{\psi}(k-1)$, $k = 1, \dots$

- ▶ O objetivo nesta seção é derivar um algoritmo recursivo baseado no estimador MQ que pode ser escrito da seguinte forma

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



▶ A seguir será usada a seguinte notação:

$$P_k = \left[\sum_{i=1}^k \psi(i-1)\psi^T(i-1) \right]^{-1},$$
$$P_k^{-1} = \left[\sum_{i=1}^{k-1} \psi(i-1)\psi^T(i-1) \right] + \psi(k-1)\psi^T(k-1)$$
$$= P_{k-1}^{-1} + \psi(k-1)\psi^T(k-1).$$

- 
- ▶ A seguir será usada a seguinte notação:

$$P_k = \left[\sum_{i=1}^k \boldsymbol{\psi}(i-1)\boldsymbol{\psi}^T(i-1) \right]^{-1},$$
$$P_k^{-1} = \left[\sum_{i=1}^{k-1} \boldsymbol{\psi}(i-1)\boldsymbol{\psi}^T(i-1) \right] + \boldsymbol{\psi}(k-1)\boldsymbol{\psi}^T(k-1)$$
$$= P_{k-1}^{-1} + \boldsymbol{\psi}(k-1)\boldsymbol{\psi}^T(k-1).$$

- ▶ O estimador pode ser reescrito

$$\hat{\boldsymbol{\theta}}_k = P_k \left[\sum_{i=1}^{k-1} \boldsymbol{\psi}(i-1)y(i) + \boldsymbol{\psi}(k-1)y(k) \right].$$

- 
- Escrevendo-se o estimador para o instante $k - 1$, obtém-se

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

sendo que o l.e. da eq. pode ser representado em forma compacta como sendo $P_{k-1}^{-1} \hat{\boldsymbol{\theta}}_{k-1}$, resultando em

$$\begin{aligned} \hat{\boldsymbol{\theta}}_k &= P_k \left[P_{k-1}^{-1} \hat{\boldsymbol{\theta}}_{k-1} + \boldsymbol{\psi}(k-1)y(k) \right] \\ &= P_k \left[(P_k^{-1} - \boldsymbol{\psi}(k-1)\boldsymbol{\psi}^T(k-1)) \hat{\boldsymbol{\theta}}_{k-1} + \boldsymbol{\psi}(k-1)y(k) \right] \\ &= \hat{\boldsymbol{\theta}}_{k-1} - P_k \boldsymbol{\psi}(k-1)\boldsymbol{\psi}^T(k-1) \hat{\boldsymbol{\theta}}_{k-1} + P_k \boldsymbol{\psi}(k-1)y(k) \\ &= \hat{\boldsymbol{\theta}}_{k-1} + P_k \boldsymbol{\psi}(k-1) \left[y(k) - \boldsymbol{\psi}^T(k-1) \hat{\boldsymbol{\theta}}_{k-1} \right] \\ &= \hat{\boldsymbol{\theta}}_{k-1} + K_k \eta(k), \end{aligned}$$

sendo $K_k = P_k \boldsymbol{\psi}(k-1)$ uma matriz de ganho e $\eta(k) = y(k) - \boldsymbol{\psi}^T(k-1) \hat{\boldsymbol{\theta}}_{k-1}$ a inovação no instante k .

- 
-
- ▶ Aplicando-se o lema da inversão tem-se

$$P_k = P_{k-1} - P_{k-1}\psi(k-1) (\psi^T(k-1)P_{k-1}\psi(k-1) + 1)^{-1} \psi^T(k-1)P_{k-1},$$

e, como antes, o termo a ser invertido será um escalar para modelos com apenas uma saída.

- 
- ▶ Aplicando-se o lema da inversão tem-se

$$P_k = P_{k-1} - P_{k-1}\psi(k-1)(\psi^T(k-1)P_{k-1}\psi(k-1) + 1)^{-1}\psi^T(k-1)P_{k-1},$$

e, como antes, o termo a ser invertido será um escalar para modelos com apenas uma saída.

- ▶ Finalmente, chega-se a

$$\begin{aligned} K_k &= P_{k-1}\psi(k-1) - \frac{P_{k-1}\psi(k-1)\psi^T(k-1)P_{k-1}\psi(k-1)}{\psi^T(k-1)P_{k-1}\psi(k-1) + 1} \\ &= \frac{P_{k-1}\psi(k-1)}{\psi^T(k-1)P_{k-1}\psi(k-1) + 1}. \end{aligned}$$



▶ Portanto, o algoritmo recursivo de MQ (RMQ) é

$$\left. \begin{aligned} K_k &= \frac{P_{k-1} \psi_k}{\psi_k^T P_{k-1} \psi_k}; \\ \hat{\theta}_k &= \hat{\theta}_{k-1} + K_k \left[y(k) - \psi_k^T \hat{\theta}_{k-1} \right]; \\ P_k &= P_{k-1} - K_k \psi_k^T P_{k-1}, \end{aligned} \right\} \cdot$$



Outros Estimadores Recursivos

Nesta seção serão mencionados os estimadores recursivos EMQ e VI, além do estimador para aproximação estocástica.

▶ Seja o modelo ARMAX

$$\begin{aligned} y(k) &= -\hat{a}_1 y(k-1) \dots - \hat{a}_{n_y} y(k-n_y) + \hat{b}_1 u(k-\tau_d-1) \dots \\ &\quad \dots + \hat{b}_{n_u} u(k-\tau_d-n_u) + \hat{c}_1 \xi(k-1) \dots + \hat{c}_{n_e} \xi(k-n_e) + \xi(k) \\ &= [y(k-1) \dots y(k-n_y) u(k-\tau_d-1) \dots u(k-\tau_d-n_u) \\ &\quad \xi(k-1) \dots \xi(k-n_e)] \hat{\boldsymbol{\theta}} + \xi(k) \\ &= \boldsymbol{\psi}^T(k-1) \hat{\boldsymbol{\theta}} + \xi(k). \end{aligned}$$

Estimador recursivo estendido de mínimos quadrados

- ▶ O estimador recursivo estendido de mínimos quadrados é a seguinte:

$$K_k = P_{k-1} \psi_k [\psi_k^T P_{k-1} \psi_k + 1]^{-1};$$

$$\hat{\theta}_k = \hat{\theta}_{k-1} + K_k [y(k) - \psi_k^T \hat{\theta}_{k-1}];$$

$$P_k = P_{k-1} - K_k \psi_k^T P_{k-1};$$

$$\xi(k) = y(k) - \psi_k^T \hat{\theta}_k,$$

sendo que, na primeira iteração, ψ_k^T não contém resíduos $\xi(k)$.



Estimador recursivo de variáveis instrumentais

- ▶ Chamando de \mathbf{z}_k o vetor de variáveis instrumentais na k -ésima iteração, o *estimador recursivo de variáveis instrumentais* pode ser implementado como se segue:

$$M_k = M_{k-1} - M_{k-1} \mathbf{z}_k [1 + \boldsymbol{\psi}_k^T M_{k-1} \mathbf{z}_k]^{-1} \boldsymbol{\psi}_k^T M_{k-1};$$

$$K_k = M_k \mathbf{z}_k;$$

$$\hat{\boldsymbol{\theta}}_k = \hat{\boldsymbol{\theta}}_{k-1} + K_k [y(k) - \boldsymbol{\psi}_k^T \hat{\boldsymbol{\theta}}_{k-1}];$$

$$\xi(k) = y(k) - \boldsymbol{\psi}_k^T \hat{\boldsymbol{\theta}}_k.$$



Deve estar claro que no estimador VI a matriz M não é simétrica e não mais corresponde à matriz de covariância $\text{cov}(\hat{\theta})$.



Deve estar claro que no estimador VI a matriz M não é simétrica e não mais corresponde à matriz de covariância $\text{cov}(\hat{\theta})$.

Se a matriz de ganho for $K_k \neq P_k \psi_k$, o estimador continuará sendo não polarizado, porém não será de variância mínima.



Estimador recursivo de aproximação estocástica

Em casos nos quais as limitações de tempo de computação são críticas pode-se usar uma matriz de ganho do tipo $K_k = \gamma_k \psi_k$. O resultado é o *estimador recursivo de aproximação estocástica*

$$K_k = \gamma_k \psi_k;$$

$$\hat{\theta}_k = \hat{\theta}_{k-1} + K_k \left[y(k) - \psi_k^T \hat{\theta}_{k-1} \right];$$

$$\xi(k) = y(k) - \psi_k^T \hat{\theta}_k,$$

para uma dada seqüência γ_k . Uma forma de escolher γ_k é $\gamma_k = C k^{-\alpha}$; $0,5 \leq \alpha \leq 1$ e C uma constante positiva. A escolha de γ_k deverá ser um compromisso entre tempo de convergência e covariância do vetor estimado.



Estimação de Parâmetros Variantes no Tempo

- ▶ Começa-se pelo estimador MQP

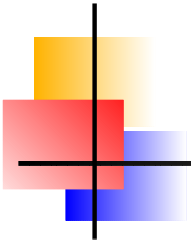
$$\begin{aligned}\hat{\boldsymbol{\theta}}_k &= \left[\sum_{i=1}^k w_i(k) \boldsymbol{\psi}(i-1) \boldsymbol{\psi}^T(i-1) \right]^{-1} \sum_{i=1}^k w_i(k) \boldsymbol{\psi}(i-1) y(i) \\ &= P_k F_k.\end{aligned}$$

sendo que $w_i(k)$ é o valor do i -ésimo peso na k -ésima iteração ($k \geq i$).

- 
-
- ▶ A seqüência de pesos deverá satisfazer as seguintes restrições:

$$\left. \begin{aligned} w_k(k) &= 1 \\ w_i(k) &= \lambda w_i(k-1), \end{aligned} \right\}$$

ou seja, o maior peso sempre corresponde ao último valor recebido e é igual a um. Quando um novo dado é recebido, todos os pesos são multiplicados por um fator λ , que na prática recebe valores na faixa $0,95 \leq \lambda \leq 0,99$.



▶ $P_k^{-1} \hat{e}$

$$\begin{aligned} P_k^{-1} &= \sum_{i=1}^{k-1} w_i(k) \boldsymbol{\psi}(i-1) \boldsymbol{\psi}^T(i-1) + w_k(k) \boldsymbol{\psi}(k-1) \boldsymbol{\psi}^T(k-1) \\ &= \sum_{i=1}^{k-1} \lambda w_i(k-1) \boldsymbol{\psi}(i-1) \boldsymbol{\psi}^T(i-1) + \boldsymbol{\psi}(k-1) \boldsymbol{\psi}^T(k-1) \\ &= \lambda P_{k-1}^{-1} + \boldsymbol{\psi}(k-1) \boldsymbol{\psi}^T(k-1), \end{aligned}$$

e

$$\begin{aligned} F_k &= \sum_{i=1}^{k-1} w_i(k) \boldsymbol{\psi}(i-1) y(i) + w_k(k) \boldsymbol{\psi}(k-1) y(k) \\ &= \lambda F_{k-1} + \boldsymbol{\psi}(k-1) y(k). \end{aligned}$$



▶ Após algumas substituições, chega-se a

$$\begin{aligned}\hat{\boldsymbol{\theta}}_k &= P_k F_k \\ &= P_k [\lambda F_{k-1} + \boldsymbol{\psi}(k-1)y(k)] \\ &= P_k [\lambda P_{k-1}^{-1} \hat{\boldsymbol{\theta}}_{k-1} + \boldsymbol{\psi}(k-1)y(k)] \\ &= P_k \left\{ \lambda \left[\frac{P_k^{-1} - \boldsymbol{\psi}(k-1)\boldsymbol{\psi}^T(k-1)}{\lambda} \right] \hat{\boldsymbol{\theta}}_{k-1} + \boldsymbol{\psi}(k-1)y(k) \right\} \\ &= \hat{\boldsymbol{\theta}}_{k-1} + P_k \boldsymbol{\psi}(k-1) [y(k) - \boldsymbol{\psi}^T(k-1)\hat{\boldsymbol{\theta}}_{k-1}].\end{aligned}$$

- 
- ▶ Após algumas substituições, chega-se a

$$\begin{aligned}
 \hat{\boldsymbol{\theta}}_k &= P_k F_k \\
 &= P_k [\lambda F_{k-1} + \boldsymbol{\psi}(k-1)y(k)] \\
 &= P_k \left[\lambda P_{k-1}^{-1} \hat{\boldsymbol{\theta}}_{k-1} + \boldsymbol{\psi}(k-1)y(k) \right] \\
 &= P_k \left\{ \lambda \left[\frac{P_{k-1}^{-1} - \boldsymbol{\psi}(k-1)\boldsymbol{\psi}^T(k-1)}{\lambda} \right] \hat{\boldsymbol{\theta}}_{k-1} + \boldsymbol{\psi}(k-1)y(k) \right\} \\
 &= \hat{\boldsymbol{\theta}}_{k-1} + P_k \boldsymbol{\psi}(k-1) \left[y(k) - \boldsymbol{\psi}^T(k-1)\hat{\boldsymbol{\theta}}_{k-1} \right].
 \end{aligned}$$

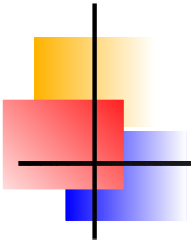
- ▶ Aplicando-se o lema da inversão, fazendo-se $A = \lambda P_{k-1}^{-1}$, $B = D^T = \boldsymbol{\psi}(k-1)$ e $C = 1$, tem-se

$$\begin{aligned}
 P_k &= \frac{P_{k-1}}{\lambda} - \frac{P_{k-1}}{\lambda} \boldsymbol{\psi}(k-1) \left[\boldsymbol{\psi}^T(k-1) P_{k-1} \boldsymbol{\psi}(k-1) \right]^{-1} \frac{\lambda \boldsymbol{\psi}^T(k-1) P_{k-1}}{\lambda} \\
 &= \frac{1}{\lambda} \left(P_{k-1} - \frac{P_{k-1} \boldsymbol{\psi}(k-1) \boldsymbol{\psi}^T(k-1) P_{k-1}}{\boldsymbol{\psi}^T(k-1) P_{k-1} \boldsymbol{\psi}(k-1) + \lambda} \right).
 \end{aligned}$$



► Finalmente,

$$\begin{aligned} K_k &= P_k \boldsymbol{\psi}(k-1) \\ &= \frac{1}{\lambda} \left(P_{k-1} \boldsymbol{\psi}(k-1) - \frac{P_{k-1} \boldsymbol{\psi}(k-1) \boldsymbol{\psi}^\top(k-1) P_{k-1} \boldsymbol{\psi}(k-1)}{\boldsymbol{\psi}^\top(k-1) P_{k-1} \boldsymbol{\psi}(k-1) + \lambda} \right) \\ &= \frac{P_{k-1} \boldsymbol{\psi}(k-1)}{\boldsymbol{\psi}^\top(k-1) P_{k-1} \boldsymbol{\psi}(k-1) + \lambda}. \end{aligned}$$

- 
- ▶ Portanto, o estimador recursivo de mínimos quadrados com fator de esquecimento λ é

$$\left. \begin{aligned} K_k &= \frac{P_{k-1} \psi_k}{\psi_k^T P_{k-1} \psi_k + \lambda}; \\ \hat{\theta}_k &= \hat{\theta}_{k-1} + P_k \psi_k \left[y(k) - \psi_k^T \hat{\theta}_{k-1} \right]; \\ P_k &= \frac{1}{\lambda} \left(P_{k-1} - \frac{P_{k-1} \psi_k \psi_k^T P_{k-1}}{\psi_k^T P_{k-1} \psi_k + \lambda} \right), \end{aligned} \right\} .$$

Estimação recursiva de ganho e constante de tempo

O processo consiste basicamente de uma resistência elétrica dentro de uma caixa metálica sendo que a temperatura externa da caixa é medida e armazenada.

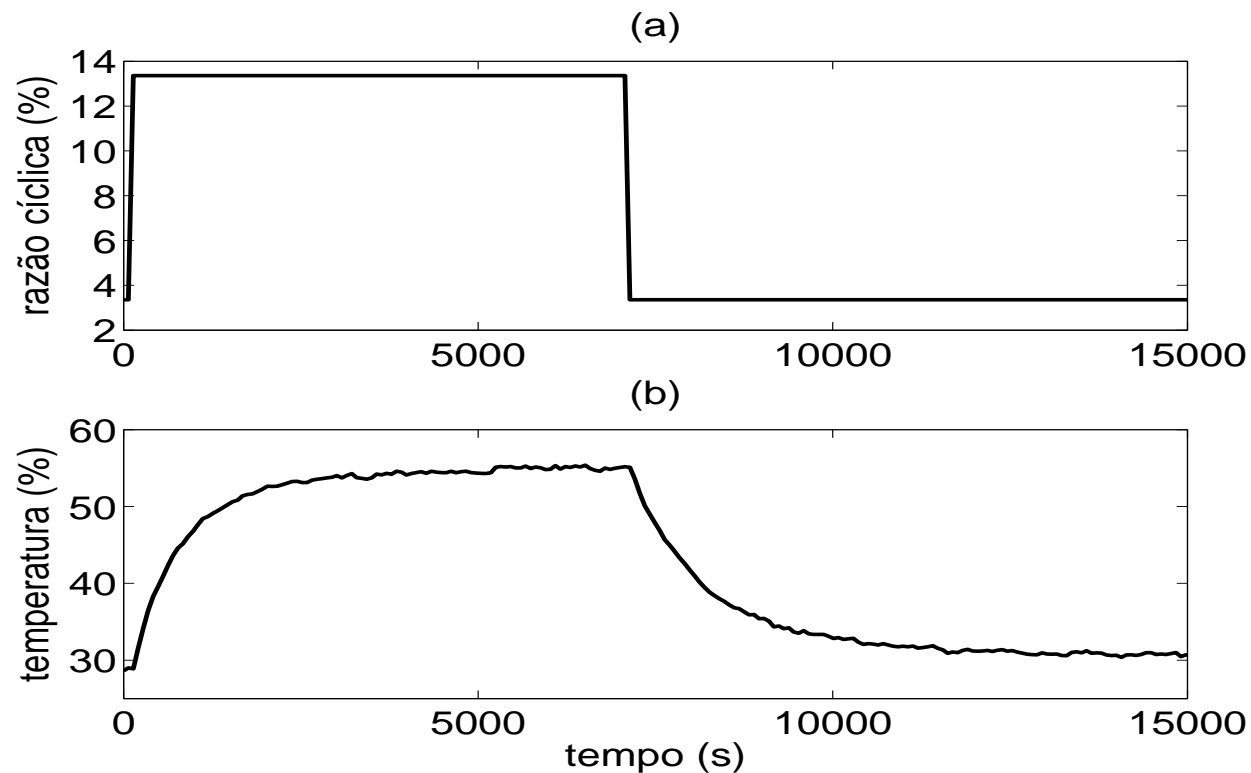


Figura 1: Dados de teste de um processo térmico Dados de teste realizado em malha aberta de um processo térmico. (a) entrada $u(k)$, razão cíclica, e (b) saída $y(k)$, temperatura.

- 
-
- ▶ Uma vez que se deseja estimar ganho e constante de tempo, utilizou-se um modelo de primeira ordem do tipo

$$\frac{Y(s)}{U(s)} = \frac{K}{\tau s + 1}.$$

- 
- ▶ Uma vez que se deseja estimar ganho e constante de tempo, utilizou-se um modelo de primeira ordem do tipo

$$\frac{Y(s)}{U(s)} = \frac{K}{\tau s + 1}.$$

- ▶ Mas como o modelo a ser estimado é discreto, utilizou-se a aproximação $\dot{y} = [y(k+1) - y(k)]/T_d$, com $T_d = T_s$, resultando em $y(k) = a_1 y(k-1) + b_1 u(k-1)$, sendo que

$$a_1 = 1 - \frac{T_s}{\tau}; \quad b_1 = \frac{T_s K}{\tau}.$$





Figura 2: Constante de tempo e ganho recursivamente estimados Constante de tempo e ganho recursivamente estimados a partir dos dados da Figura 1. (a) constante de tempo e (b) ganho.

- 
-
- ▶ A constante de tempo e o ganho estimados na k -ésima iteração são, respectivamente,

$$\hat{\tau}_k = \frac{-T_s}{\hat{a}_{1k} - 1}; \quad \hat{K}_k = \frac{\hat{b}_{1k} \tau_k}{T_s}.$$




Figura 3: Efeito do fator de esquecimento na estimação recursiva da constante de tempo a partir dos dados da Figura 1.



Complementos - Estimação de matrizes de estado

Neste exemplo os dados serão gerados pelo seguinte modelo em espaço de estados:

$$\mathbf{x}(k) = \begin{bmatrix} 0,8 & 0,1 & 0,005 \\ 0,0 & 0,7 & 0,1 \\ 0,0 & 0,0 & 0,9 \end{bmatrix} \mathbf{x}(k-1) + \begin{bmatrix} 1,0 & 0,05 & 0,0025 \\ 0,0 & 1,0 & 0,05 \\ 0,0 & 0,0 & 1,0 \end{bmatrix} \mathbf{u}(k-1) + \mathbf{e}(k),$$

sendo que o vetor de entradas $\mathbf{u}(k)$ é composto por três variáveis aleatórias de média zero, distribuição gaussiana e variância unitária. Semelhantemente, $\mathbf{e}(k)$ é também composto de três variáveis com distribuição gaussiana e variância tal que resulta numa relação sinal ruído igual a 50 dB.



Foi considerada a matriz de observação $C_d = [1 \ 1 \ 1]$, portanto

$$y(k) = C_d \mathbf{x}(k)$$

$$\hat{y}(k) = C_d \hat{\mathbf{x}}(k),$$

sendo $\hat{\mathbf{x}}(k) = \hat{\Phi} \mathbf{x}(k-1) + \hat{\Gamma} \mathbf{u}(k-1)$.

Os autovalores do modelo original são 0,7; 0,8 e 0,9. Os autovalores da matriz de estado estimada são $\text{eig}(\hat{\Phi}) = (0,6953; 0,8143; 0,8923)$.





Figura 4: Desempenho de modelo em espaço de estados Saída (—) $y(k)$ e saída estimada (— · —) $\hat{y}(k)$ utilizando o modelo em espaço de estados.