

## Processamento Estatístico de Sinais: Lista 2

**Problema 1** Seja  $\{\mathbf{X}_k\}$ ,  $k \geq 0$ , uma seqüência de vetores aleatórios gaussianos reais  $\mathbf{X}_k$  de dimensão  $n \times 1$ , e seja por outro lado  $\{\mathbf{Y}_k\}$  uma seqüência de vetores aleatórios gaussianos  $\mathbf{Y}_k$  de dimensão  $l \times 1$  tal que

$$\mathbf{Y}_k = \mathbf{H}_k \mathbf{X}_k + \mathbf{V}_k \quad k \geq 0 \quad (1)$$

onde  $\{\mathbf{V}_k\}$ ,  $k \geq 0$ , é uma seqüência independente, identicamente distribuída de vetores aleatórios reais de dimensão  $l \times 1$  com  $p(\mathbf{v}_k) = N(\mathbf{0}, \mathbf{R})$ ,  $\forall k \geq 0$ . As seqüências  $\{\mathbf{X}_k\}$  e  $\{\mathbf{V}_k\}$  são estatisticamente independentes e a seqüência de matrizes  $l \times n$ ,  $\{\mathbf{H}_k\}$ , é assumida conhecida para  $k \geq 0$ .

Para um dada realização  $\{\mathbf{y}_k\}$ ,  $k \geq 0$ , de  $\{\mathbf{Y}_k\}$ , introduza agora a seqüência de inovações  $\{\underline{\nu}_k\}$ ,  $k \geq 0$ , tal que

$$\underline{\nu}_k = \mathbf{y}_k - \hat{\mathbf{y}}_{k|k-1} \quad k \geq 0 \quad (2)$$

onde

$$\hat{\mathbf{y}}_{k|k-1} = E[\mathbf{Y}_k | \mathbf{y}_0 \dots \mathbf{y}_{k-1}] \quad k \geq 1 \quad (3)$$

$$\hat{\mathbf{y}}_{0|-1} = E[\mathbf{Y}_0] = \mathbf{H}_0 E[\mathbf{X}_0] \quad (4)$$

Verifique que qualquer vetor observado  $\mathbf{y}_{0:k} = [\mathbf{y}_0^T \mathbf{y}_1^T \dots \mathbf{y}_k^T]^T$  pode ser escrito na forma  $\mathbf{b} + \mathbf{A}\underline{\nu}_{0:k}$  onde  $\underline{\nu}_{0:k}$  é o vetor correspondente de inovações e a matriz  $\mathbf{A}$  é inversível.

**Problema 2** Sejam  $\{\mathbf{X}_k\}$  e  $\{\mathbf{Y}_k\}$ ,  $\mathbf{X}_k: \mathcal{S} \rightarrow \Re^N$ ,  $\mathbf{Y}_k: \mathcal{S} \rightarrow \Re^L$ , duas seqüências de vetores aleatórios definidas em um espaço de probabilidade  $(\mathcal{S}, \mathcal{F}, P)$  e descritas pelo modelo dinâmico

$$\mathbf{X}_{k+1} = \mathbf{F}_k \mathbf{X}_k + \mathbf{G}_k \mathbf{W}_k + \mathbf{L}_k \mathbf{u}_k \quad k \geq 0 \quad (5)$$

$$\mathbf{Y}_k = \mathbf{H}_k \mathbf{X}_k + \mathbf{V}_k \quad k \geq 0 \quad (6)$$

onde  $\mathbf{u}_k$  é um sinal determinístico conhecido, e  $\{\mathbf{W}_k\}$  e  $\{\mathbf{V}_k\}$ ,  $k \geq 0$ , são seqüências de vetores aleatórios de média nula tais que

$$E \left\{ \begin{bmatrix} \mathbf{W}_k \\ \mathbf{V}_k \end{bmatrix} \begin{bmatrix} \mathbf{W}_l^T & \mathbf{V}_l^T \end{bmatrix} \right\} = \begin{bmatrix} \mathbf{Q}_k & \mathbf{S}_k \\ \mathbf{S}_k^T & \mathbf{R}_k \end{bmatrix} \delta_{kl} . \quad (7)$$

Em (7),  $\delta_{kl}$  é o delta de Kronecker e  $\mathbf{R}_k$  e  $\mathbf{Q}_k$  são matrizes positivas definidas para qualquer  $k \geq 0$ .

Assumindo-se que  $\mathbf{X}_0$ ,  $\{\mathbf{W}_k\}_{k \geq 0}$  e  $\{\mathbf{V}_k\}_{k \geq 0}$ , são mutuamente gaussianos e que  $\{\mathbf{W}_k\}_{k \geq 0}$  e  $\{\mathbf{V}_k\}_{k \geq 0}$  são independentes de  $\mathbf{X}_0$ , mostre que

$$\hat{\mathbf{x}}_{k+1|k} = E[\mathbf{X}_{k+1} | \mathbf{y}_0, \dots, \mathbf{y}_k] = \mathbf{F}_k \hat{\mathbf{x}}_{k|k-1} + \mathbf{L}_k \mathbf{u}_k + \mathbf{K}_k (\mathbf{y}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}) \quad (8)$$

com o ganho de Kalman (modificado)  $\mathbf{K}_k$  dado por

$$\mathbf{K}_k = (\mathbf{F}_k \mathbf{\Pi}_{k|k-1} \mathbf{H}_k^T + \mathbf{G}_k \mathbf{S}_k) (\mathbf{H}_k \mathbf{\Pi}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k)^{-1} . \quad (9)$$

Na expressão (9),  $\mathbf{\Pi}_{k|k-1}$  é a matriz de covariância do erro do preditor, ou seja,

$$\mathbf{\Pi}_{k|k-1} = E[(\mathbf{X}_k - \hat{\mathbf{X}}_{k|k-1})(\mathbf{X}_k - \hat{\mathbf{X}}_{k|k-1})^T] . \quad (10)$$

Observação: A equação do filtro de Kalman vista em aula é um caso particular da equação (8) quando  $\mathbf{L}_k$  e  $\mathbf{S}_k$  são iguais a zero.

**Problema 3 (Identificação de filtros FIR)** Seja  $W$  um filtro FIR de comprimento  $L + 1$  tal que para uma dada seqüência de entrada,  $\{x_n\}$ ,  $n \in \mathcal{Z}$ , obtém-se a seqüência de saída  $\{d_n\}$  com

$$d_n = \sum_{k=0}^L w_k x_{n-k} .$$

Observando-se as seqüências de entrada  $\{x_n\}$  e de saída,  $\{d_n\}$ , deseja-se obter um algoritmo recursivo para estimar os coeficientes desconhecidos  $\mathbf{w} = [w_0 \ w_1 \ \dots \ w_L]^T$  do filtro  $W$ .

Para resolver o problema, introduza um vetor de pesos aleatório  $\mathbf{W}_n$  que varia no tempo de acordo com a equação

$$\mathbf{W}_{n+1} = \mathbf{W}_n + \mathbf{U}_n \quad n \geq 0 \quad (11)$$

onde  $\{\mathbf{U}_n\}$  é uma seqüência i.i.d. com fdp  $N(\mathbf{0}, \mathbf{Q}_n)$ . A seguir, para uma seqüência observada (fixa) de entradas, modele a saída do sistema  $d_n$  no instante  $n$  como uma amostra da variável aleatória  $D_n$  tal que

$$D_n = \mathbf{x}_n^T \mathbf{W}_n + V_n \quad n \geq 0 \quad (12)$$

onde  $\{V_n\}$  é outra seqüência i.i.d com fdp  $N(0, \sigma_v^2)$  e

$$\mathbf{x}_n = [x_n \ x_{n-1} \ \dots \ x_{n-L}]^T .$$

As seqüências  $\{\mathbf{U}_n\}$ ,  $\{V_n\}$  e a condição inicial  $\mathbf{W}_0$  são assumidas conjuntamente gaussianas e mutuamente não-correlacionadas.

Defina agora

$$\hat{\mathbf{w}}_{n|n} = E[\mathbf{W}_n | d_0 \dots d_n] \quad (13)$$

$$\mathbf{S}_{n|n} = E[(\mathbf{W}_n - \hat{\mathbf{W}}_{n|n})(\mathbf{W}_n - \hat{\mathbf{W}}_{n|n})^T] \quad (14)$$

e introduza em seguida a matriz

$$P_n = \frac{\lambda \mathbf{S}_{n+1|n}}{\sigma_v^2} \quad (15)$$

onde  $\lambda$  é uma constante tal que  $0 < \lambda < 1$ . Mostre que, se no modelo (11) tomarmos

$$Q_n = (\lambda^{-1} - 1)\mathbf{S}_{n|n}, \quad (16)$$

então a aplicação direta das equações do filtro de Kalman para o modelo em espaço de estados dado pelas equações (11) e (12) leva ao seguinte algoritmo recursivo para o cálculo de  $\hat{\mathbf{w}}_{n|n}$ :

$$\hat{\mathbf{w}}_{n|n} = \hat{\mathbf{w}}_{n-1|n-1} + \frac{\mathbf{P}_{n-1}\mathbf{x}_n}{\mathbf{x}_n^T\mathbf{P}_{n-1}\mathbf{x}_n + \lambda} [d_n - \mathbf{x}_n^T\mathbf{w}_{n-1|n-1}] \quad (17)$$

$$\mathbf{P}_n = \frac{1}{\lambda} \left[ \mathbf{P}_{n-1} - \frac{\mathbf{P}_{n-1}\mathbf{x}_n\mathbf{x}_n^T\mathbf{P}_{n-1}}{\mathbf{x}_n^T\mathbf{P}_{n-1}\mathbf{x}_n + \lambda} \right]. \quad (18)$$

Compare o algoritmo acima ao algoritmo RLS (“recursive least squares”) da literatura de filtragem adaptativa.

**Problema 4 (Estimação de Fase)** Seja  $\{\mathbf{X}_k = [\Lambda_k \ \Theta_k]^T\}$ ,  $k \geq 0$ , uma seqüência de vetores aleatórios (reais) tal que

$$\mathbf{X}_{k+1} = \begin{bmatrix} \Lambda_{k+1} \\ \Theta_{k+1} \end{bmatrix} = \mathbf{F}\mathbf{X}_k + \mathbf{G}W_k$$

onde  $\{W_k\}$  é uma seqüência de variáveis aleatórias (reais) tal que  $E\{W_k\} = 0$  e  $E\{W_k W_l\} = q \delta_{kl}$ .

Seja agora  $\{Y_k\}$ ,  $k \geq 0$ , uma seqüência de observações aleatórias tal que

$$Y_k = \sqrt{2} \sin(\omega_0 k + \Theta_k) + V_k$$

onde  $E\{V_k\} = 0$  e  $E\{V_k V_l\} = r \delta_{kl}$ . Assuma ainda que  $\mathbf{X}_0$ ,  $\{W_k\}$ ,  $k \geq 0$  e  $\{V_k\}$ ,  $k \geq 0$ , são mutuamente independentes. Usando o filtro estendido de Kalman, verifique que a estimativa  $\hat{\mathbf{x}}_{k|k} = E[\mathbf{X}_k | y_0 \dots y_k]$  pode ser aproximadamente calculada pela recursão

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \Pi_{k|k-1} \sqrt{2} \mathbf{1} (\cos \omega_0 k + \mathbf{1}^T \hat{\mathbf{x}}_{k|k-1}) \Omega_k^{-1} [y_k - \sqrt{2} \sin(\omega_0 k + \mathbf{1}^T \hat{\mathbf{x}}_{k|k-1})]$$

$$\Pi_{k|k} = \Pi_{k|k-1} - 2 \Pi_{k|k-1} \mathbf{1} \mathbf{1}^T \Pi_{k|k-1} \Omega_k^{-1} \cos^2(\omega_0 k + \mathbf{1}^T \hat{\mathbf{x}}_{k|k-1})$$

onde

$$\begin{aligned}\mathbf{I}^T &= [0 \ 1] \\ \Omega_k &= 2\mathbf{I}^T \Pi_{k|k-1} \mathbf{I} \cos^2(\omega_0 k + \mathbf{I}^T \mathbf{x}_{k|k-1}) + r \\ \Pi_{k|k-1} &\approx E \left[ (\mathbf{X}_k - \hat{\mathbf{X}}_{k|k-1})(\mathbf{X}_k - \hat{\mathbf{X}}_{k|k-1})^T \mid \mathbf{y}_{0:k-1} \right] .\end{aligned}$$

**Problema 5** Seja  $\{X_n\}$ ,  $n \geq 1$ , uma seqüência de variáveis aleatórias não-observadas tal que

$$X_n = \frac{1}{2}X_{n-1} + 25\frac{X_{n-1}}{1 + X_{n-1}^2} + 8 \cos(1.2n) + U_{n-1} \quad n \geq 1$$

onde  $\{U_k\}$ ,  $k \geq 0$ , é uma seqüência de variáveis gaussianas independentes e identicamente distribuídas com média zero e variância  $\sigma_u^2$  e  $\mathbf{X}_0$  é uma variável aleatória gaussiana de média zero e variância  $\sigma_0^2$ . Seja por outro lado  $\{Y_n\}$ ,  $n \geq 1$ , uma outra seqüência de variáveis aleatórias tal que

$$Y_n = \frac{X_n^2}{20} + V_n \quad n \geq 1$$

onde  $\{V_k\}$ ,  $k \geq 1$ , é uma seqüência de variáveis gaussianas independentes e identicamente distribuídas com média zero e variância  $\sigma_v^2$ .

a) Assumindo-se que as variáveis aleatórias  $\mathbf{X}_0$ ,  $\{V_k\}$  e  $\{U_k\}$  são estatisticamente independentes e fazendo  $\sigma_0^2 = \sigma_u^2 = 10$  e  $\sigma_v^2 = 1$ , simule uma realização  $\{x_n\}$  da seqüência aleatória  $\{X_n\}$  para  $1 \leq n \leq 100$ . Simule ainda a correspondente seqüência observada  $\{y_n\}$ ,  $1 \leq n \leq 100$ , e plote as seqüências oculta e observada em função de  $n$ .

b) Usando um filtro de partículas baseado na técnica SIR (“sampling/importance resampling”) vista em aula, obtenha a estimativa MMSE  $\hat{x}_n | n$  da variável oculta  $x_n$  no instante  $n$  dadas as observações  $y_1, y_2, \dots, y_n$  para  $1 \leq n \leq 100$ . Plote  $\{\hat{x}_n | n\}$  versus  $n$  e  $\{\hat{x}_n | n\}$  versus  $\{x_n\}$  para  $1 \leq n \leq 100$ . Repita esse exercício usando respectivamente  $N_p = 1000$  e  $N_p = 3000$  partículas.

c) Repita o item (b) usando agora um filtro estendido de Kalman (EKF). Compare então o erro de estimação para o EKF e para o filtro de partículas.