

Processamento Estatístico de Sinais: Lista 4

Problema 1 Sejam $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M$, M vetores aleatórios de dimensão N , independentes e identicamente distribuídos com função densidade de probabilidade normal $\mathcal{N}(\mathbf{m}, \mathbf{R})$.

a) Assumindo que a matriz \mathbf{R} é conhecida e o vetor \mathbf{m} é desconhecido e parametrizado por um vetor $\underline{\theta} \in \mathbb{R}^p$, mostre que a matriz de informação de Fisher usada no cálculo do limite inferior de Cramer-Rao para o erro quadrático médio de qualquer estimativa sem viés dos parâmetros θ_i , $i = 1, \dots, p$, é dada por $\mathbf{J} = [J_{k,l}]_{1 \leq k, l \leq p}$, onde

$$J_{k,l} = M \frac{\partial \mathbf{m}^T}{\partial \theta_k} \mathbf{R}^{-1} \frac{\partial \mathbf{m}}{\partial \theta_l}.$$

b) Assumindo a seguir que \mathbf{m} é conhecido e a matriz \mathbf{R} é desconhecida e parametrizada pelo vetor $\underline{\theta}$, mostre que

$$J_{k,l} = \frac{M}{2} \text{tr} \left[\mathbf{R}^{-1} \frac{\partial \mathbf{R}}{\partial \theta_k} \mathbf{R}^{-1} \frac{\partial \mathbf{R}}{\partial \theta_l} \right].$$

Problema 2 (Rank One Signal) Observa-se uma amostra da seqüência iid de vetores aleatórios $(\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_M)$ onde

$$Y_k(n) = A e^{j\omega n} + V_k(n) \quad 0 \leq n \leq N-1, \quad 1 \leq k \leq M.$$

Na equação acima, ω é um parâmetro real determinístico no intervalo $[-\pi, \pi]$ e A é uma variável aleatória complexa de média nula e variância σ_1^2 . O ruído de observação \mathbf{V}_k é gaussiano com $E[V_k(n)] = 0$ e $E[V_k(n)V_k^*(m)] = \sigma^2 \delta(n-m)$, $0 \leq n, m \leq N-1$. Assuma ainda que $E[AV_k^*(n)] = 0$.

a) Considerando que o parâmetro ω é conhecido, mostre que as estimativas ML de σ_1^2 e σ^2 dada uma seqüência observada $(\mathbf{y}_1, \dots, \mathbf{y}_M)$ satisfazem a equação

$$(\mathbf{e}_1^H \mathbf{e}_1) \widehat{\sigma}_1^2 + \widehat{\sigma}^2 = \frac{\mathbf{e}_1^H \mathbf{S} \mathbf{e}_1}{\mathbf{e}_1^H \mathbf{e}_1}$$

onde H denota o hermitiano de um vetor, $\mathbf{e}_1 = [1 \exp(-j\omega) \dots \exp(-j(N-1)\omega)]^H$, e \mathbf{S} é a “matriz de covariância amostral” dada por

$$\mathbf{S} = \frac{1}{M} \sum_{i=1}^M \mathbf{y}_i \mathbf{y}_i^H.$$

b) Calcule o limite inferior de Cramér-Rao para o erro quadrático médio de estimação dos parâmetros

σ_1^2 e σ^2 .

Problema 3 (Least Squares Fitting of Structured Covariance Matrices)

Seja $\mathbf{R} \in \mathfrak{R}^{n \times n}$ uma matriz de covariância parametrizada por um vetor de parâmetros desconhecidos $\theta \in \mathfrak{R}^p$. Seja \mathbf{S} uma estimativa *não-estruturada* de \mathbf{R} obtida a partir de dados experimentais. Por exemplo, tome \mathbf{S} igual à “sample covariance” obtida a partir da amostra $(\mathbf{x}_1, \dots, \mathbf{x}_M)$ com $\mathbf{x}_i, \mathbf{x}_i \in \mathfrak{R}^n, 1 \leq i \leq M$, uma seqüência i.i.d. onde $p(\mathbf{x}_i) = N(\mathbf{0}, \mathbf{R})$.

Usando-se um critério de mínimos quadrados, deseja-se obter a melhor aproximação estruturada $\hat{\mathbf{R}} = \hat{\mathbf{R}}(\theta)$ para a covariância estimada \mathbf{S} , ou seja, deseja-se determinar $\mathbf{R}(\theta)$ que minimize

$$\varepsilon = \text{tr} \left[(\mathbf{S} - \mathbf{R}(\theta))^T (\mathbf{S} - \mathbf{R}(\theta)) \right] = \sum_{i=1}^n \sum_{j=1}^n [S_{ij} - R_{ij}(\theta)]^2 \quad (1)$$

onde “tr” denota o operador traço.

a) Mostre que as estimativas de mínimos quadrados dos parâmetros $\theta_k, 1 \leq k \leq p$, são soluções do sistema de equações

$$\text{tr} \left\{ [\mathbf{S} - \mathbf{R}(\theta)]^T \frac{\partial \mathbf{R}(\theta)}{\partial \theta_k} \right\} = 0 . \quad (2)$$

b) Assuma agora que \mathbf{R} é uma matriz *Toeplitz* simétrica com estrutura

$$\mathbf{R} = \sum_{i=0}^{n-1} r_i \mathbf{Q}_i \quad (3)$$

onde $\mathbf{Q}_0 = \mathbf{I}$ e, para $1 \leq k \leq n-1, Q_k(i, j) = 1$ se $|i - j| = k$ e, igual a zero caso contrário. Usando o resultado do item (a), mostre que as estimativas de mínimos quadrados dos parâmetros $r_i, 0 \leq i \leq n-1$, são dadas por

$$\hat{r}_0 = \frac{1}{n} \sum_{i=1}^n S_{ii} \quad (4)$$

$$\hat{r}_k = \frac{1}{2(n-k)} \sum_{j=k+1}^n S_{j-k, j} + \sum_{i=k+1}^n S_{i, i-k} \quad k \neq 0 . \quad (5)$$

Interprete esse resultado.

c) Considere agora a situação em que a matriz \mathbf{R} desejada é uma matriz real $n \times n$ de posto $p < n$, com estrutura

$$\mathbf{R} = \sum_{i=1}^p \sigma_i^2 \mathbf{u}_i \mathbf{u}_i^T \quad (6)$$

onde $\{\mathbf{u}_i\}, 1 \leq i \leq p$, é um conjunto de p vetores conhecidos, linearmente independentes e de dimensão $n \times 1$. Deseja-se obter a melhor aproximação de mínimos quadrados

$$\hat{\mathbf{R}} = \sum_{i=1}^p \hat{\sigma}_i^2 \mathbf{u}_i \mathbf{u}_i^T \quad (7)$$

para a estimativa não-estruturada (posto cheio) \mathbf{S} da matriz de covariância. Usando o resultado do item (a), mostre que as estimativas de mínimos quadrados $\widehat{\sigma}^2$ são a solução do sistema linear

$$\begin{bmatrix} (\mathbf{u}_1^T \mathbf{u}_1)^2 & \dots & (\mathbf{u}_1^T \mathbf{u}_p)^2 \\ \vdots & & \vdots \\ (\mathbf{u}_p^T \mathbf{u}_1)^2 & \dots & (\mathbf{u}_p^T \mathbf{u}_p)^2 \end{bmatrix} \begin{bmatrix} \widehat{\sigma}_1^2 \\ \vdots \\ \widehat{\sigma}_p^2 \end{bmatrix} = \begin{bmatrix} \mathbf{u}_1^T \mathbf{S} \mathbf{u}_1 \\ \vdots \\ \mathbf{u}_p^T \mathbf{S} \mathbf{u}_p \end{bmatrix}. \quad (8)$$

d) Na seqüência, assuma que a estrutura desejada da matriz \mathbf{R} é dada por

$$\mathbf{R} = \mathbf{U} \mathbf{\Sigma}^2 \mathbf{U}^T \quad (9)$$

onde

$$\mathbf{\Sigma}^2 = \mathbf{\Sigma}_p^2 + \sigma_n^2 \mathbf{I} \quad (10)$$

com $\mathbf{\Sigma}_p^2 = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_p^2, 0, \dots, 0)$ e $\mathbf{U} \mathbf{U}^T = \mathbf{U}^T \mathbf{U} = \mathbf{I}$.

Seja \mathbf{S} a matriz de covariância estimada não-estruturada e admita conhecida a matriz \mathbf{U} na estrutura desejada \mathbf{R} . Mostre que, no caso particular em que $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_p^2 = \sigma_s^2$, as estimativas de mínimos quadrados $\widehat{\sigma}_s^2$ e $\widehat{\sigma}_n^2$ são dadas por

$$\widehat{\sigma}_n^2 = \frac{1}{N-p} \text{tr}[(\mathbf{I} - \mathbf{P})\mathbf{S}] \quad (11)$$

$$\widehat{\sigma}_s^2 = \frac{1}{p} \text{tr}[\mathbf{P}\mathbf{S}] - \widehat{\sigma}_n^2 \quad (12)$$

onde

$$\mathbf{P} = \mathbf{U}_p \mathbf{U}_p^T \quad (13)$$

é o operador de projeção ortogonal sobre o subespaço gerado pelas p primeiras colunas da matriz \mathbf{U} .

Problema 4 (Constrained Least Squares) Seja $\mathbf{y} \in \mathfrak{R}^n$ um vetor observado. Deseja-se obter o vetor $\theta \in \mathfrak{R}^p$ que minimize

$$\varepsilon = (\mathbf{y} - \mathbf{H}\theta)^T (\mathbf{y} - \mathbf{H}\theta) \quad (14)$$

e seja simultaneamente sujeito à restrição

$$\mathbf{C}^T \theta = \mathbf{0} \quad (15)$$

onde são conhecidos: $\mathbf{H} \in \mathfrak{R}^{n \times p}$, $n \geq p$, com posto p ; $\mathbf{C}^T \in \mathfrak{R}^{r \times p}$, $r \leq p$, com posto r .

(a) Mostre que a solução do problema de minimização com restrições é dada por

$$\hat{\theta}_{CLS} = \mathbf{P} \hat{\theta}_{LS} \quad (16)$$

onde

$$\hat{\theta}_{LS} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{y} \quad (17)$$

$$\mathbf{P} = \mathbf{I} - (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{C} \left[\mathbf{C}^T (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{C} \right]^{-1} \mathbf{C}^T. \quad (18)$$

Dica Calcule e iguale a zero o gradiente em relação a θ de

$$J = (\mathbf{y} - \mathbf{H}\theta)^T(\mathbf{y} - \mathbf{H}\theta) + 2\lambda^T(\mathbf{C}^T\theta)$$

onde λ é o vetor de multiplicadores de Lagrange.

(b) Verifique que

$$\hat{\mathbf{x}}_{CLS} = \mathbf{H}\hat{\theta}_{CLS} = (\mathbf{P}_H - \mathbf{P}_C)\mathbf{y} \quad (19)$$

onde

$$\mathbf{P}_H = \mathbf{H}(\mathbf{H}^T\mathbf{H})^{-1}\mathbf{H}^T \quad (20)$$

$$\mathbf{P}_C = \mathbf{H}(\mathbf{H}^T\mathbf{H})^{-1}\mathbf{C} \left[\mathbf{C}^T(\mathbf{H}^T\mathbf{H})^{-1}\mathbf{C} \right]^{-1} \mathbf{C}^T(\mathbf{H}^T\mathbf{H})^{-1}\mathbf{H}^T . \quad (21)$$

(c) Verifique que \mathbf{P}_C é o operador de projeção ortogonal de posto r construído a partir de $\mathbf{H}(\mathbf{H}^T\mathbf{H})^{-1}\mathbf{C}$. Conclua ainda que

$$\mathbf{P}_H\mathbf{P}_C\mathbf{P}_H = \mathbf{P}_H\mathbf{P}_C = \mathbf{P}_C\mathbf{P}_H = \mathbf{P}_C \quad (22)$$

e, portanto,

$$\hat{\mathbf{x}}_{CLS} = (\mathbf{I} - \mathbf{P}_C)\hat{\mathbf{x}}_{LS} = \mathbf{P}_H(\mathbf{y} - \mathbf{P}_C\hat{\mathbf{x}}_{LS}) . \quad (23)$$

Interprete esse resultado geometricamente.