

**Examen Master SICOM, Cours Identification**  
**Luc Pronzato, Décembre 2004**

**QUELQUES INDICATIONS**

Les parties 2 et 3 sont totalement indépendantes. Dans la partie 3, les questions a, b, c et d sont largement indépendantes.

On prendra soin de **souligner les vecteurs** et de noter les matrices par des lettres capitales. Un vecteur  $\mathbf{v}$  est toujours supposé être du type colonne, on notera  $\mathbf{v}^\top$  un vecteur ligne.

**ÉNONCÉ DU PROBLÈME**

On considère une suite d'observations  $y_k = y(x_k)$ ,  $k = 1, 2, \dots$  dans un modèle de régression linéaire pour lequel

$$y(x_k) = \mathbf{r}^\top(x_k)\bar{\theta} + \varepsilon_k$$

avec  $\bar{\theta} \in \mathbb{R}^p$  la vraie valeur (inconnue) des paramètres du modèle et  $(\varepsilon_k)$  une suite de variables aléatoires indépendantes et identiquement distribuées, de moyenne zéro et de variance  $\sigma^2$ . On notera  $\mathbf{r}_i = \mathbf{r}(x_i)$  pour tout  $i$  et

$$\mathbf{X}_k = \begin{pmatrix} \mathbf{r}_1^\top \\ \vdots \\ \mathbf{r}_k^\top \end{pmatrix}, \mathbf{y}_1^k = (y_1, \dots, y_k)^\top \text{ et } \mathbf{M}_k = \mathbf{X}_k^\top \mathbf{X}_k \text{ pour tout } k.$$

**1) ESTIMATEUR DES MOINDRES CARRÉS**

**a)** Donner l'expression de l'estimateur des moindres carrés  $\hat{\theta}^k$  après observation de  $\mathbf{y}_1^k$  en fonction de  $\mathbf{X}_k$  et  $\mathbf{y}_1^k$ .

Quelle est sa moyenne  $E\{\hat{\theta}^k\}$ ?

Que vaut sa covariance  $\text{Var}\{\hat{\theta}^k\}$ ? (On la notera  $\mathbf{C}_k$ .)

**b)** On effectue une observation supplémentaire  $y_{k+1}$ . Exprimer  $\hat{\theta}^{k+1}$  en fonction de  $\mathbf{M}_{k+1}$ ,  $\mathbf{X}_k$ ,  $\mathbf{y}_1^k$  et  $y_{k+1}\mathbf{r}_{k+1}$ . En exprimant  $\mathbf{M}_k$  en fonction de  $\mathbf{M}_{k+1}$  et  $\mathbf{r}_{k+1}$ , en déduire la forme récursive de l'estimateur

$$\hat{\theta}^{k+1} = \hat{\theta}^k + \delta_k$$

où l'on exprimera le terme correctif  $\delta_k$  en fonction de  $\mathbf{M}_{k+1}$ ,  $\mathbf{r}_{k+1}$  et de l'erreur de prédiction  $e_{k+1}(\hat{\theta}^k) = y_{k+1} - \mathbf{r}_{k+1}^\top \hat{\theta}^k$ .

**c)** Enfin, à partir du lemme d'inversion matricielle  $(A + BCD)^{-1} = A^{-1} - A^{-1}B(C^{-1} + DA^{-1}B)^{-1}DA^{-1}$  (où l'on suppose inversibles les matrices à inverser...) on exprimera  $\delta_k$  en fonction de  $\mathbf{M}_k$ ,  $\mathbf{r}_{k+1}$  et  $e_{k+1}(\hat{\theta}^k)$ .

En déduire la forme récursive de l'estimateur des moindres carrés

$$\begin{aligned} \mathbf{C}_{k+1} &= \mathbf{C}_k - \dots \\ \hat{\theta}^{k+1} &= \hat{\theta}^k + \dots \end{aligned}$$

où les membres de droite ne font intervenir que  $\mathbf{C}_k$ ,  $\mathbf{r}_{k+1}$ ,  $e_{k+1}(\hat{\theta}^k)$  et  $\sigma^2$ .

**2) ESTIMATEUR LMS (Least Mean Squares)**

**a)** Considérons à présent l'algorithme de calcul suivant :

$$\tilde{\theta}^{k+1} = \tilde{\theta}^k + \lambda_{k+1}\mathbf{r}_{k+1}e_{k+1}(\tilde{\theta}^k),$$

avec  $\tilde{\theta}^k$  l'estimée après observation de  $\mathbf{y}_1^k$  (et a priori  $\tilde{\theta}^k \neq \hat{\theta}^k$ ) et  $\lambda_{k+1}$  un pas scalaire. Pourquoi est-il plus simple à mettre en œuvre que l'algorithme des moindres carrés récursifs?

Supposons que  $E\{\tilde{\theta}^k\} = \bar{\theta}$ . Que vaut  $E\{\tilde{\theta}^{k+1}\}$ ? (On rappelle que  $\varepsilon_{k+1}$  est indépendant de  $\mathbf{y}_1^k$ .)

Supposons que  $\text{Var}\{\tilde{\theta}^k\} = \mathbf{C}_k$ . Exprimer  $\mathbf{V}_{k+1} = \text{Var}\{\tilde{\theta}^{k+1}\}$  en fonction de  $\mathbf{C}_k$ ,  $\mathbf{r}_{k+1}$ ,  $\lambda_{k+1}$  et  $\sigma^2$ .

**b)** On suppose que  $\|\mathbf{r}_{k+1}\| = 1$ . Calculer  $\lambda_{k+1}^*$ , la valeur de  $\lambda_{k+1}$  qui minimise  $\text{trace}(\mathbf{V}_{k+1})$ , en fonction de  $\rho_{k+1} = \sigma^2 / (\mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1})$ .

Calculer  $\text{trace}(\mathbf{C}_{k+1})$ , avec  $\mathbf{C}_{k+1}$  la matrice de covariance de l'estimateur des moindres carrés  $\hat{\theta}^{k+1}$ .

Utiliser l'inégalité de Cauchy-Schwarz pour conclure quant aux performances des deux estimateurs (pour le critère  $\text{trace}(\text{Var})$ ).

### 3) PLANIFICATION D'EXPÉRIENCES

On utilise de nouveau l'estimateur des moindres carrés.

**a)** Lorsque  $\mathbf{C}_k$  est fixée et que la seule contrainte sur  $\mathbf{r}_{k+1}$  est  $\|\mathbf{r}_{k+1}\| \leq r$ , comment choisir  $\mathbf{r}_{k+1}$  qui minimise  $\det(\mathbf{C}_{k+1})$ ? (On rappelle que  $\det(A + \mathbf{v}\mathbf{v}^\top) = (1 + \mathbf{v}^\top A^{-1}\mathbf{v}) \det(A)$ .) On notera  $\mathbf{r}_{k+1}^*$  ce choix, que l'on exprimera en fonction des vecteurs propres de  $\mathbf{C}_k$ .

**b)** On s'intéresse à la prédiction de la réponse du modèle en un point  $x$ . Après observation de  $\mathbf{y}_1^k$ , on prédit cette réponse par  $\hat{y}^k(x) = \mathbf{r}^\top(x)\hat{\theta}^k$ . Calculer la moyenne de cette prédiction en un  $x$  donné,  $E\{\hat{y}^k(x)|x\}$ , ainsi que sa variance  $\text{var}\{\hat{y}^k(x)|x\}$ . Justifier le choix  $\mathbf{r}_{k+1}^*$  de la question a).

**c)** On suppose que  $\mathbf{r}(x) = \begin{pmatrix} 1 \\ x \end{pmatrix}$ . On souhaite choisir les vecteurs  $\mathbf{r}(x_i)$  qui forment  $\mathbf{X}_k$ , avec  $x_i$  appartenant à l'intervalle  $[-1, 1]$ ,  $i = 1, \dots, k$ , de façon à minimiser

$$d(x^*, \mathbf{X}_k) = \max_{x \in [-1, 1]} \text{var}\{\hat{y}^k(x)|x\}.$$

On pose

$$\mathbf{C}_k = \begin{pmatrix} c^2 & b \\ b & a^2 \end{pmatrix}.$$

Justifier l'écriture des termes diagonaux sous forme de carrés et montrer que  $a, b$  et  $c$  satisfont une inégalité élémentaire. Montrer que  $d(x, \mathbf{X}_k) = \text{var}\{\hat{y}^k(x)|x\}$  est nécessairement maximum en  $-1$  ou en  $+1$ . En déduire l'expression de  $d(x^*, \mathbf{X}_k)$  en fonction de  $a, b$  et  $c$ . Exprimer  $a, b$  et  $c$  en fonction de

$$\mu_1 = \sum_{i=1}^k x_i, \mu_2 = \sum_{i=1}^k x_i^2, \sigma^2 \text{ et } k.$$

En déduire les valeurs de  $\mu_1$  et  $\mu_2$  qui minimisent  $d(x^*, \mathbf{X}_k)$ . Comment réaliser cette expérience quand  $k$  est un nombre pair?

**d)** On s'intéresse à présent à la moyenne par rapport à  $x$  de l'erreur quadratique moyenne de la prédiction en  $x$ , lorsque  $x$  a une densité de probabilité  $\varphi(x)$ . Montrer que le critère s'écrit

$$\Phi(\mathbf{X}_k) = \int \text{var}\{\hat{y}^k(x)|x\} \varphi(x) dx$$

puis exprimer  $\Phi(\mathbf{X}_k)$  en fonction de  $\mathbf{C}_k$  et de

$$\mathbf{V}_x = \int \mathbf{r}(x)\mathbf{r}^\top(x) \varphi(x) dx.$$

- On suppose que  $\varphi$  est de moyenne 0 et de variance  $s^2$ .  
Exprimer  $\Phi(\mathbf{X}_k)$  en fonction de  $\mu_1, \mu_2, \sigma^2, k$  et  $s^2$ . On suppose de nouveau que  $k$  est pair. Comparer aux résultats de la question c).
- On suppose que  $\varphi$  est de moyenne 1 et de variance  $s^2$ . Exprimer de nouveau  $\Phi(\mathbf{X}_k)$  en fonction de  $\mu_1, \mu_2, \sigma^2, k$  et  $s^2$ . On fait tendre  $k$  vers l'infini et on suppose qu'une proportion  $\alpha$  des observations sont faites en  $x_i = -1$  et une proportion  $1 - \alpha$  en  $x_i = 1$ . Exprimer  $\psi(\alpha) = \lim_{k \rightarrow \infty} k\Phi(\mathbf{X}_k)$  en fonction de  $\alpha, \sigma^2$  et  $s^2$  et déterminer la valeur optimale  $\alpha^*(s)$  qui minimise  $\psi(\alpha)$  (justifier qu'il s'agit bien d'un minimum).  
Que se passe-t-il quand  $s$  tend vers 0? Justifier la valeur limite de  $\alpha^*$ .  
Que se passe-t-il quand  $s \rightarrow \infty$ ?