

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

**1a)** L'estimateur des moindres carrés est donné par  $\hat{\theta}^k = (\mathbf{X}_k^\top \mathbf{X}_k)^{-1} \mathbf{X}_k^\top \mathbf{y}_1^k$ .

Sa moyenne vaut  $E\{\hat{\theta}^k\} = (\mathbf{X}_k^\top \mathbf{X}_k)^{-1} \mathbf{X}_k^\top E\{\mathbf{y}_1^k\} = (\mathbf{X}_k^\top \mathbf{X}_k)^{-1} \mathbf{X}_k^\top \mathbf{X}_k \bar{\theta} = \bar{\theta}$ .

Sa covariance vaut  $\mathbf{C}_k = E\{(\hat{\theta}^k - \bar{\theta})(\hat{\theta}^k - \bar{\theta})^\top\} = (\mathbf{X}_k^\top \mathbf{X}_k)^{-1} \mathbf{X}_k^\top E\{(\mathbf{y}_1^k - \mathbf{X}_k \bar{\theta})(\mathbf{y}_1^k - \mathbf{X}_k \bar{\theta})^\top\} \mathbf{X}_k (\mathbf{X}_k^\top \mathbf{X}_k)^{-1} = (\mathbf{X}_k^\top \mathbf{X}_k)^{-1} \mathbf{X}_k^\top \sigma^2 \mathbf{I}_k \mathbf{X}_k (\mathbf{X}_k^\top \mathbf{X}_k)^{-1}$  avec  $\mathbf{I}_k$  la matrice identité de dimension  $k$ , d'où  $\mathbf{C}_k = \sigma^2 (\mathbf{X}_k^\top \mathbf{X}_k)^{-1}$ .

**1b)**

$$\begin{aligned} \hat{\theta}^{k+1} &= \mathbf{M}_{k+1}^{-1} \mathbf{X}_{k+1}^\top \mathbf{y}_1^{k+1} \\ &= \mathbf{M}_{k+1}^{-1} (\mathbf{X}_k^\top \mathbf{y}_1^k + y_{k+1} \mathbf{r}_{k+1}). \end{aligned}$$

$\mathbf{M}_{k+1} = \mathbf{M}_k + \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top$ , d'où

$$\begin{aligned} \hat{\theta}^{k+1} &= \mathbf{M}_{k+1}^{-1} (\mathbf{M}_k \hat{\theta}^k + y_{k+1} \mathbf{r}_{k+1}) \\ &= \mathbf{M}_{k+1}^{-1} [(\mathbf{M}_{k+1} - \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top) \hat{\theta}^k + y_{k+1} \mathbf{r}_{k+1}] \\ &= \hat{\theta}^k + \underbrace{\mathbf{M}_{k+1}^{-1} \mathbf{r}_{k+1} (y_{k+1} - \mathbf{r}_{k+1}^\top \hat{\theta}^k)}_{e_{k+1}(\hat{\theta}^k)} \end{aligned}$$

**1c)**

$$\mathbf{M}_{k+1}^{-1} = \mathbf{M}_k^{-1} - \frac{\mathbf{M}_k^{-1} \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top \mathbf{M}_k^{-1}}{1 + \mathbf{r}_{k+1}^\top \mathbf{M}_k^{-1} \mathbf{r}_{k+1}}$$

d'où

$$\mathbf{M}_{k+1}^{-1} \mathbf{r}_{k+1} = \frac{\mathbf{M}_k^{-1} \mathbf{r}_{k+1}}{1 + \mathbf{r}_{k+1}^\top \mathbf{M}_k^{-1} \mathbf{r}_{k+1}}$$

et

$$\hat{\theta}^{k+1} = \hat{\theta}^k + \frac{\mathbf{M}_k^{-1} \mathbf{r}_{k+1}}{1 + \mathbf{r}_{k+1}^\top \mathbf{M}_k^{-1} \mathbf{r}_{k+1}} e_{k+1}(\hat{\theta}^k).$$

Comme  $\mathbf{M}_k^{-1} = \mathbf{C}_k / \sigma^2$  pour tout  $k$ , on obtient

$$\begin{aligned} \mathbf{C}_{k+1} &= \mathbf{C}_k - \frac{\mathbf{C}_k \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top \mathbf{C}_k}{\sigma^2 + \mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1}} \\ \hat{\theta}^{k+1} &= \hat{\theta}^k + \frac{\mathbf{C}_k \mathbf{r}_{k+1}}{\sigma^2 + \mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1}} e_{k+1}(\hat{\theta}^k). \end{aligned}$$

**2a)** L'estimateur obtenu par LMS est plus facile à mettre en œuvre que celui des moindres carrés car il ne demande pas la manipulation de matrices.

On a  $E\{\hat{\theta}^{k+1}\} = E\{\hat{\theta}^k\} + \lambda_{k+1} \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top (\bar{\theta} - E\{\hat{\theta}^k\}) = \bar{\theta}$  (puisque l'on suppose que  $E\{\hat{\theta}^k\} = \bar{\theta}$ ).

De même,

$$\begin{aligned} \mathbf{V}_{k+1} &= \text{Var}\{(\mathbf{I}_p - \lambda_{k+1} \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top) \hat{\theta}^k + \lambda_{k+1} \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top \bar{\theta} + \lambda_{k+1} \mathbf{r}_{k+1} \varepsilon_{k+1}\} \\ &= (\mathbf{I}_p - \lambda_{k+1} \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top) \mathbf{C}_k (\mathbf{I}_p - \lambda_{k+1} \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top) + \lambda_{k+1}^2 \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top \sigma^2 \\ &= \mathbf{C}_k - \lambda_{k+1} \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top \mathbf{C}_k - \lambda_{k+1} \mathbf{C}_k \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top + \lambda_{k+1}^2 \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top (\mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1} + \sigma^2). \end{aligned}$$

**2b)** Pour  $\|\mathbf{r}_{k+1}\| = 1$  on obtient  $\text{trace}(\mathbf{V}_{k+1}) = \text{trace}(\mathbf{C}_k) - 2\lambda_{k+1} \mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1} + \lambda_{k+1}^2 (\mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1} + \sigma^2)$ , qui est minimum pour

$$\lambda_{k+1} = \lambda_{k+1}^* = \frac{\mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1}}{\mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1} + \sigma^2} = \frac{1}{1 + \rho_{k+1}}.$$

Pour  $\lambda_{k+1} = \lambda_{k+1}^*$ , on obtient

$$\text{trace}(\mathbf{V}_{k+1}) = \text{trace}(\mathbf{C}_k) - \frac{(\mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1})^2}{\mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1} + \sigma^2}.$$

D'un autre coté, pour l'estimateur des moindres carrés on a

$$\text{trace}(\mathbf{C}_{k+1}) = \text{trace}(\mathbf{C}_k) - \frac{\mathbf{r}_{k+1}^\top \mathbf{C}_k^2 \mathbf{r}_{k+1}}{\mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1} + \sigma^2}.$$

L'inégalité de Cauchy-Schwarz  $(\mathbf{u}^\top \mathbf{v})^2 \leq \|\mathbf{u}\|^2 \|\mathbf{v}\|^2$  donne pour  $\mathbf{u} = \mathbf{r}_{k+1}$  et  $\mathbf{v} = \mathbf{C}_k \mathbf{r}_{k+1}$

$$(\mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1})^2 \leq (\mathbf{r}_{k+1}^\top \mathbf{r}_{k+1})(\mathbf{r}_{k+1}^\top \mathbf{C}_k^2 \mathbf{r}_{k+1}) = \mathbf{r}_{k+1}^\top \mathbf{C}_k^2 \mathbf{r}_{k+1}$$

et donc  $\text{trace}(\mathbf{C}_{k+1}) \leq \text{trace}(\mathbf{V}_{k+1})$ , l'estimateur des moindres carrés est donc plus performant que celui obtenu par LMS.

**3a)** Minimiser  $\det(\mathbf{C}_{k+1})$  revient à maximiser  $\det(\mathbf{M}_{k+1}) = \det(\mathbf{M}_k + \mathbf{r}_{k+1} \mathbf{r}_{k+1}^\top) = \det(\mathbf{M}_k)(1 + \mathbf{r}_{k+1}^\top \mathbf{M}_k^{-1} \mathbf{r}_{k+1})$ . Il s'agit donc de choisir  $\mathbf{r}_{k+1} = \mathbf{r}_{k+1}^*$  qui maximise  $\mathbf{r}_{k+1}^\top \mathbf{M}_k^{-1} \mathbf{r}_{k+1} = \mathbf{r}_{k+1}^\top \mathbf{C}_k \mathbf{r}_{k+1} / \sigma^2$ . Par conséquent  $\mathbf{r}_{k+1}^* = \pm r_{\mathbf{u}_k}$  avec  $\mathbf{u}_k$  vecteur propre de  $\mathbf{C}_k$  associé à sa valeur propre maximale.

**3b)**  $\mathbb{E}\{\hat{y}^k(x)|x\} = \mathbf{r}^\top(x) \mathbb{E}\{\hat{\theta}^k\} = \mathbf{r}^\top(x) \bar{\theta}$ ,  $\text{var}\{\hat{y}^k(x)|x\} = \mathbf{r}^\top(x) \text{Var}\{\hat{\theta}^k\} \mathbf{r}(x) = \mathbf{r}^\top(x) \mathbf{C}_k \mathbf{r}(x)$ .

Le choix  $\mathbf{r}_{k+1}^*$  correspond à observer là où la variance de la prédiction est maximale et donc où la prédiction est la plus incertaine.

**3c)**  $\mathbf{C}_k$  est une matrice de covariance, et donc définie non-négative :  $\mathbf{u}^\top \mathbf{C}_k \mathbf{u} \geq 0$  pour tout  $\mathbf{u}$ . En prenant  $\mathbf{u} = (1 \ 0)^\top$  puis  $\mathbf{u} = (0 \ 1)^\top$  on trouve que les termes diagonaux sont forcément positifs ou nuls. Aussi,  $\det(\mathbf{C}_k) \geq 0$  et donc  $|b| \leq ac$ .

$$d(x, \mathbf{X}_k) = \text{var}\{\hat{y}^k(x)|x\} = \mathbf{r}^\top(x) \mathbf{C}_k \mathbf{r}(x) = (1 \ x) \begin{pmatrix} c^2 & b \\ b & a^2 \end{pmatrix} \begin{pmatrix} 1 \\ x \end{pmatrix} = c^2 + 2bx + a^2x^2,$$

qui forme une parabole convexe (tournée vers le haut). Le maximum pour  $x \in [-1, 1]$  est donc atteint en  $x^* = \pm 1$  et  $d(x^*, \mathbf{X}_k) = c^2 + a^2 + 2|b|$ .

Puisque  $\mathbf{C}_k = \sigma^2 \mathbf{M}_k^{-1}$  avec

$$\mathbf{M}_k = \sum_{i=1}^k \mathbf{r}(x_i) \mathbf{r}^\top(x_i) = \begin{pmatrix} k & \mu_1 \\ \mu_1 & \mu_2 \end{pmatrix},$$

on a

$$c^2 = \sigma^2 \frac{\mu_2}{k\mu_2 - \mu_1^2}, \quad a^2 = \sigma^2 \frac{k}{k\mu_2 - \mu_1^2} \quad \text{et} \quad b = -\sigma^2 \frac{\mu_1}{k\mu_2 - \mu_1^2}.$$

En reportant dans  $d(x^*, \mathbf{X}_k)$  on obtient

$$d(x^*, \mathbf{X}_k) = \sigma^2 \frac{\mu_2 + k + 2\mu_1}{k\mu_2 - \mu_1^2}$$

qui est minimum pour  $\mu_1 = 0$  et  $\mu_2 = k$  (notons que  $-k \leq \mu_1 \leq k$  et  $0 \leq \mu_2 \leq k$ ). Lorsque  $k$  est pair, ceci est réalisable en plaçant  $k/2$  points  $x_i$  en +1 et  $k/2$  en -1.

**3d)**

$$EQM\{\hat{y}^k(x)|x\} = \mathbb{E}\{(\hat{y}^k(x) - \mathbf{r}^\top(x) \bar{\theta})^2|x\} = \text{var}\{\hat{y}^k(x)|x\}$$

puisque  $\mathbb{E}[\hat{y}^k(x)|x] = \mathbf{r}^\top(x) \bar{\theta}$ . Par conséquent,

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

ou encore

$$\Phi(\mathbf{X}_k) = \int \mathbf{r}^\top(x) \mathbf{C}_k \mathbf{r}(x) \varphi(x) dx = \text{trace}[\mathbf{C}_k \mathbf{V}_x].$$

Lorsque  $\varphi$  est de moyenne nulle et de variance  $s^2$ ,

$$\mathbf{V}_x = \begin{pmatrix} 1 & 0 \\ 0 & s^2 \end{pmatrix}$$

et

$$\Phi(\mathbf{X}_k) = \text{trace}[\mathbf{C}_k \mathbf{V}_x] = c^2 + s^2 a^2 = \sigma^2 \frac{\mu_2 + k s^2}{k \mu_2 - \mu_1^2}.$$

De nouveau  $\Phi(\mathbf{X}_k)$  est minimum pour  $\mu_1 = 0$  et  $\mu_2 = k$ , réalisable de la même manière qu'en c) lorsque  $k$  est pair.

Lorsque  $\varphi$  est de moyenne 1 et de variance  $s^2$ ,

$$\mathbf{V}_x = \begin{pmatrix} 1 & 1 \\ 1 & 1 + s^2 \end{pmatrix}$$

et

$$\Phi(\mathbf{X}_k) = \text{trace}[\mathbf{C}_k \mathbf{V}_x] = c^2 + 2b + (1 + s^2)a^2 = \sigma^2 \frac{\mu_2 - 2\mu_1 + k(1 + s^2)}{k\mu_2 - \mu_1^2}.$$

On obtient donc

$$k\Phi(\mathbf{X}_k) = \sigma^2 \frac{\mu_2/k - 2\mu_1/k + (1 + s^2)}{\mu_2/k - (\mu_1/k)^2}$$

avec  $\mu_2/k = 1$  et  $\mu_1/k \rightarrow 1 - 2\alpha$  quand  $k \rightarrow \infty$ . Par conséquent,

$$\Psi(\alpha) = \lim_{k \rightarrow \infty} k\Phi(\mathbf{X}_k) = \sigma^2 \frac{s^2 + 4\alpha}{4\alpha(1 - \alpha)},$$

qui tend vers  $+\infty$  quand  $\alpha$  tend vers  $0^+$  ou  $1^-$ . La dérivée  $\Psi'(\alpha)$  de  $\Psi(\alpha)$  vaut

$$\Psi'(\alpha) = \sigma^2 \frac{4\alpha^2 + 2s^2\alpha - s^2}{4\alpha^2(1 - \alpha)^2}$$

qui a une seule racine positive  $\alpha^*(s) = (s/4)(\sqrt{s^2 + 4} - s)$ ,  $\alpha^*$  correspond donc à un minimum de  $\Psi$ .

Quand  $s \rightarrow 0$ ,  $\alpha^*(s) \rightarrow 0$ ;  $\varphi$  tend alors à être concentrée en  $x = 1$  et placer toutes les observations en  $x_i = 1$  ( $\alpha = 0$ ) est optimum pour la précision de la prédiction en  $x = 1$ .

Quand  $s \rightarrow \infty$ ,  $\alpha^*(s) \rightarrow 1/2$ : il faut placer la moitié des observations en  $+1$  et l'autre moitié en  $-1$ .