

Examen DEA SICOM, Cours Identification
Luc Pronzato, Décembre 2003

CORRIGÉ

1)

Posons $G = N_G/D_G$, $F = N_F/D_F$, on a $y(k) = N_F(q)/D_F(q)u(k) + N_G(q)/D_G(q)\epsilon(k)$, soit $A(q)y(k) = B(q)u(k) + C(q)\epsilon(k)$, avec $A(q) = D_F(q)D_G(q)$, $B(q) = N_F(q)D_G(q)$ et $C(q) = D_F(q)N_G(q)$.

2)

$$\begin{aligned} y_1(k) &= y_1(k-1) + a_1 y_1(k-2) + u(k-1) + b_1 u(k-2) + \epsilon_1(k) + c_1 \epsilon(k-1) \\ y_2(k) &= y_2(k-1) + a_2 y_2(k-2) + u(k-1) + b_2 u(k-2) + \epsilon_2(k) \end{aligned}$$

La stabilité du système dépend des valeurs de a_1 et a_2 : le système est stable si les valeurs de z pour lesquelles $A_1(z) = 1 - z^{-1} - a_1 z^{-2}$ et $A_2(z) = 1 - z^{-1} - a_2 z^{-2}$ s'annulent sont de module inférieur à 1. On a $A_i(z) = z^{-2}(z^2 - z - a_i)$, $i = 1, 2$, qui s'annule en $z = (1 \pm \sqrt{1 + 4a_i})/2$. Pour $-1/4 < a_i < 0$ le système est donc stable. De plus, les zéros des $A_i(z)$ sont réels et positifs, la réponse indicielle du système est donc non-oscillante.

3)

$$\begin{aligned} e_1(k) &= -c_1 \epsilon(k-1) + y_1(k) - y_1(k-1) - a_1 y_1(k-2) - u(k-1) - b_1 u(k-2) \\ e_2(k) &= y_2(k) - y_2(k-1) - a_2 y_2(k-2) - u(k-1) - b_2 u(k-2) \end{aligned}$$

4)

$\log \pi(\mathbf{y}|\boldsymbol{\theta}, \sigma_1^2, \sigma_2^2) = \log \pi_\epsilon(\mathbf{e}|\boldsymbol{\theta}, \sigma_1^2, \sigma_2^2)$ avec $\mathbf{e} = (e(1), \dots, e(N))$ et π_ϵ la densité de probabilité des erreurs. Du fait de l'indépendance,

$$\begin{aligned} \log \pi(\mathbf{y}|\boldsymbol{\theta}, \sigma_1^2, \sigma_2^2) &= \sum_{i=1,2} \sum_{k=1}^N \log \left\{ \frac{1}{\sigma_i \sqrt{2\pi}} \exp \left[-\frac{e_i^2(k)}{2\sigma_i^2} \right] \right\} \\ &= \sum_{i=1,2} \left\{ -\frac{N}{2} \log(2\pi) - \frac{N}{2} \log(\sigma_i^2) - \frac{1}{2\sigma_i^2} \sum_{k=1}^N e_i^2(k) \right\} \end{aligned}$$

avec $e_i(k)$ dépendant de $\boldsymbol{\theta}_i$, $i = 1, 2$.

Dérivons par rapport à σ_i^2 , cette dérivée doit être nulle à l'optimum, c'est-à-dire pour la valeur estimée des paramètres. On obtient

$$\hat{\sigma}_i^2 = \frac{1}{N} \sum_{k=1}^N \hat{e}_i^2(k), \quad i = 1, 2.$$

On reporte dans $\log \pi(\mathbf{y}|\boldsymbol{\theta}, \sigma_1^2, \sigma_2^2)$, ce qui donne comme critère à maximiser

$$\sum_{i=1,2} \left\{ -\frac{N}{2} \log(2\pi) - \frac{N}{2} \log \left[\frac{1}{N} \sum_{k=1}^N e_i^2(k) \right] - \frac{N}{2} \right\},$$

c'est-à-dire, $\hat{\boldsymbol{\theta}}_i$ minimise $\sum_{k=1}^N e_i^2(k)$, $i = 1, 2$.

5)

V_i correspond au terme de la matrice d'information de Fisher associé au paramètre σ_i^2 , $1/V_i$ est donc la variance asymptotique de l'estimateur de σ_i^2 . La dérivée $\partial \log \pi(\mathbf{y}|\boldsymbol{\theta}, \sigma_1^2, \sigma_2^2) / \partial \sigma_i^2$ a été calculée en 4, elle vaut

$$\frac{\partial \log \pi(\mathbf{y}|\boldsymbol{\theta}, \sigma_1^2, \sigma_2^2)}{\partial \sigma_i^2} = -\frac{N}{2\sigma_i^2} + \frac{1}{2\sigma_i^4} \sum_{k=1}^N e_i^2(k).$$

On a donc

$$\mathbf{E} \left\{ \left[\frac{\partial \log \pi(\mathbf{y}|\boldsymbol{\theta}, \sigma_1^2, \sigma_2^2)}{\partial \sigma_i^2} \right]^2 \middle| \boldsymbol{\theta}, \sigma_1^2, \sigma_2^2 \right\} = \frac{N^2}{4\sigma_i^4} - \frac{2N}{4\sigma_i^6} \mathbf{E} \left\{ \sum_{k=1}^N e_i^2(k) \middle| \boldsymbol{\theta}, \sigma_i^2 \right\} + \frac{1}{4\sigma_i^8} \mathbf{E} \left\{ \left[\sum_{k=1}^N e_i^2(k) \right]^2 \middle| \boldsymbol{\theta}, \sigma_i^2 \right\},$$

avec

$$\mathbb{E} \{ e_i^2(k) | \boldsymbol{\theta}, \sigma_i^2 \} = \sigma_i^2, \mathbb{E} \{ e_i^4(k) | \boldsymbol{\theta}, \sigma_i^2 \} = 3\sigma_i^4, \text{ et pour } j \neq k, \mathbb{E} \{ e_i^2(k) e_i^2(j) | \boldsymbol{\theta}, \sigma_i^2 \} = \sigma_i^4.$$

Par conséquent,

$$\begin{aligned} \mathbb{E} \left\{ \sum_{k=1}^N e_i^2(k) \middle| \boldsymbol{\theta}, \sigma_i^2 \right\} &= N\sigma_i^2 \\ \mathbb{E} \left\{ \left[\sum_{k=1}^N e_i^2(k) \right]^2 \middle| \boldsymbol{\theta}, \sigma_i^2 \right\} &= 3N\sigma_i^4 + N(N-1)\sigma_i^4 \end{aligned}$$

et finalement

$$V_i = \frac{N}{2\sigma_i^4}.$$

6)

On a, d'après l'indépendance des $\epsilon(k)$,

$$\begin{aligned} \log \pi(\mathbf{y} | \boldsymbol{\theta}, \boldsymbol{\Sigma}) &= \sum_{k=1}^N \log \left[\frac{1}{2\pi \sqrt{\det \boldsymbol{\Sigma}}} \exp \left(-\frac{1}{2} \mathbf{e}(k)^\top \boldsymbol{\Sigma}^{-1} \mathbf{e}(k) \right) \right] \\ &= -N \log(2\pi) - \frac{N}{2} \log \det \boldsymbol{\Sigma} - \frac{1}{2} \sum_{k=1}^N \mathbf{e}(k)^\top \boldsymbol{\Sigma}^{-1} \mathbf{e}(k). \end{aligned}$$

La dérivée par rapport à $\boldsymbol{\Sigma}$ doit être nulle à l'optimum (valeur estimée des paramètres), c'est-à-dire

$$-\frac{N}{2} \hat{\boldsymbol{\Sigma}}^{-1} + \frac{1}{2} \hat{\boldsymbol{\Sigma}}^{-1} \left[\sum_{k=1}^N \hat{\mathbf{e}}(k) \hat{\mathbf{e}}^\top(k) \right] \hat{\boldsymbol{\Sigma}}^{-1} = \mathbf{0},$$

soit

$$\hat{\boldsymbol{\Sigma}} = \frac{1}{N} \sum_{k=1}^N \hat{\mathbf{e}}(k) \hat{\mathbf{e}}^\top(k).$$

On reporte dans l'expression de $\log \pi(\mathbf{y} | \boldsymbol{\theta}, \boldsymbol{\Sigma})$ qui devient

$$-N \log(2\pi) - \frac{N}{2} \log \det \left[\frac{1}{N} \sum_{k=1}^N \hat{\mathbf{e}}(k) \hat{\mathbf{e}}^\top(k) \right] - \frac{1}{2} \text{trace}(N \mathbf{I}_2)$$

avec \mathbf{I}_2 la matrice identité de dimension 2, et $\hat{\boldsymbol{\theta}}$ doit minimiser $\log \det[\sum_{k=1}^N \mathbf{e}(k) \mathbf{e}^\top(k)]$.

7)

On commence par calculer $\det \boldsymbol{\Sigma} = \sigma^4(1 - \alpha^2)$ et

$$\boldsymbol{\Sigma}^{-1} = \frac{1}{\sigma^2(1 - \alpha^2)} \begin{pmatrix} 1 & -\alpha \\ -\alpha & 1 \end{pmatrix}.$$

On reprend l'expression trouvée en 6,

$$\begin{aligned} \log \pi(\mathbf{y} | \boldsymbol{\theta}, \sigma^2, \alpha) &= -N \log(2\pi) - \frac{N}{2} \log \sigma^4 - \frac{N}{2} \log(1 - \alpha^2) - \frac{1}{2\sigma^2(1 - \alpha^2)} \sum_{k=1}^N [e_1^2(k) + e_2^2(k) - 2\alpha e_1(k) e_2(k)] \\ &= -N \log(2\pi) - N \log \sigma^2 - \frac{N}{2} \log(1 - \alpha^2) - \frac{1}{2\sigma^2(1 - \alpha^2)} (S_N - 2\alpha P_N). \end{aligned}$$

La dérivée par rapport à σ^2 doit être nulle à l'optimum, soit

$$-\frac{N}{\hat{\sigma}^2} + \frac{1}{2\hat{\sigma}^4(1 - \hat{\alpha}^2)} (\hat{S}_N - 2\hat{\alpha} \hat{P}_N) = 0$$

et donc

$$\hat{\sigma}^2 = \frac{1}{2N(1 - \hat{\alpha}^2)} (\hat{S}_N - 2\hat{\alpha} \hat{P}_N).$$

On reporte dans $\log \pi(\mathbf{y}|\boldsymbol{\theta}, \sigma^2, \alpha)$, qui devient

$$\begin{aligned}\log \pi(\mathbf{y}|\boldsymbol{\theta}, \alpha) &= -N \log(2\pi) + N \log[2N(1 - \alpha^2)] - N \log(S_N - 2\alpha P_N) - \frac{N}{2} \log(1 - \alpha^2) - N \\ &= -N \log(2\pi) + N \log(2N) - N - N \log(S_N - 2\alpha P_N) + \frac{N}{2} \log(1 - \alpha^2).\end{aligned}$$

Sa dérivée par rapport à α doit être nulle à l'optimum, soit

$$\frac{\hat{\alpha}}{1 - \hat{\alpha}^2} = \frac{2\hat{P}_N}{\hat{S}_N - 2\hat{\alpha}\hat{P}_N}$$

d'où $\hat{\alpha} = 2\hat{P}_N/\hat{S}_N$.

Par définition, S_N est positif et $S_N + 2P_N \geq 0$ et $S_N - 2P_N \geq 0$, donc $-1 \leq \hat{\alpha} \leq 1$, ce qui est était à prévoir puisque α est le coefficient de corrélation entre $\epsilon_1(k)$ et $\epsilon_2(k)$.

On reporte la valeur de $\hat{\alpha}$ dans celle de $\hat{\sigma}^2$, ce qui donne $\hat{\sigma}^2 = \hat{S}_N/(2N)$.

On reporte la valeur de $\hat{\alpha}$ dans $\log \pi(\mathbf{y}|\boldsymbol{\theta}, \alpha)$, qui devient

$$\begin{aligned}& -N \log(2\pi) + N \log(2N) - N - \frac{N}{2} \log(S_N^2 - 4P_N^2) \\ &= -N \log(2\pi) + N \log(2N) - N - \frac{N}{2} \log(S_N - 2P_N) - \frac{N}{2} \log(S_N + 2P_N) \\ &= -N \log(2\pi) + N \log(2N) - N - \frac{N}{2} \log \left[\sum_{k=1}^N (e_1(k) - e_2(k))^2 \right] - \frac{N}{2} \log \left[\sum_{k=1}^N (e_1(k) + e_2(k))^2 \right].\end{aligned}$$

Par conséquent, $\hat{\boldsymbol{\theta}}$ doit minimiser $\log[\sum_{k=1}^N (e_1(k) - e_2(k))^2] + \log[\sum_{k=1}^N (e_1(k) + e_2(k))^2]$.

8)

On a pour $\alpha = 0$

$$\frac{\partial \log \pi(\mathbf{y}|\boldsymbol{\theta}, \sigma^2, \alpha)}{\partial \sigma^2} = -\frac{N}{\sigma^2} + \frac{1}{2\sigma^4} S_N$$

et donc

$$\mathbf{E} \left\{ \left[\frac{\partial \log \pi(\mathbf{y}|\boldsymbol{\theta}, \sigma^2, \alpha)}{\partial \sigma^2} \right]^2 \middle| \boldsymbol{\theta}, \sigma^2, 0 \right\} = \frac{N^2}{\sigma^4} - \frac{N}{\sigma^6} \mathbf{E} \{ S_N | \boldsymbol{\theta}, \sigma^2 \} + \frac{1}{4\sigma^8} \mathbf{E} \{ S_N^2 | \boldsymbol{\theta}, \sigma^2 \},$$

avec

$$\mathbf{E} \{ S_N | \boldsymbol{\theta}, \sigma^2 \} = 2N\sigma^2, \mathbf{E} \{ S_N^2 | \boldsymbol{\theta}, \sigma^2 \} = 8N\sigma^4 + 4N(N-1)\sigma^4.$$

Par conséquent, $V = N/\sigma^4$, tandis qu'en 4, $V_i = N/(2\sigma_i^2)$. La variance est donc deux fois plus faible à présent, ce qui s'explique par le fait que deux fois plus de données (les $e_1(k)$ et les $e_2(k)$) sont utilisées pour estimer σ^2 .

9)

Le critère d'Akaike fait intervenir $-\log \pi(\mathbf{y}|\hat{\boldsymbol{\theta}}, \hat{\sigma}^2, \hat{\alpha}) + p$ avec p le nombre de paramètres dans le modèle. Dans le premier cas, il y a 5+2=7 paramètres (5 pour $\boldsymbol{\theta}$, 2 pour σ^2 et α), dans le second seulement 4+2=6. Le critère (à minimiser) conduit donc à préférer la structure la plus simple, c'est-à-dire la seconde.