

**Examen Master SICOM, Cours Optimisation
Luc Pronzato, janvier 2006 — Correction**

ÉNONCÉ DU PROBLÈME

PARTIE 1

On considère un modèle paramétrique dont la réponse $\eta(\theta, t)$ pour un vecteur de paramètres $\theta = (\theta_1, \theta_2)^\top$ en fonction du temps t est donnée par la solution de l'équation différentielle

$$\theta_1 \left[\frac{\partial^2 \eta(\theta, t)}{\partial t^2} + \eta(\theta, t) \right] + \frac{\partial \eta(\theta, t)}{\partial t} = \theta_2 u(t), \quad (1)$$

avec des conditions initiales nulles. On souhaite estimer θ à partir d'observations $y(t_1), \dots, y(t_n)$ recueillies aux instants t_1, \dots, t_n pour le critère des moindres carrés

$$J(\theta) = \frac{1}{2} \sum_{i=1}^n [y(t_i) - \eta(\theta, t_i)]^2.$$

1) Exprimez le gradient du critère $\mathbf{g}(\theta) = \partial J(\theta) / \partial \theta$ en fonction des fonctions de sensibilité

$$s_1(\theta, t) = \frac{\partial \eta(\theta, t)}{\partial \theta_1} \quad \text{et} \quad s_2(\theta, t) = \frac{\partial \eta(\theta, t)}{\partial \theta_2}.$$

On a $\mathbf{g}(\theta) = \sum_{i=1}^n [\eta(\theta, t_i) - y(t_i)] [s_1(\theta, t_i), s_2(\theta, t_i)]^\top$.

On notera dans la suite plus simplement $\eta = \eta(\theta, t)$, $s_1 = s_1(\theta, t)$, $s_2 = s_2(\theta, t)$, et $\dot{\eta}$, \dot{s}_1 , \dot{s}_2 , $\ddot{\eta}$, \ddot{s}_1 , \ddot{s}_2 leurs dérivées premières et secondes par rapport à t .

2) Écrivez les équations différentielles satisfaites par s_1 et s_2 .

En dérivant (1) par rapport à θ_1 et θ_2 on obtient

$$\theta_1 [\dot{s}_1 + s_1] + \dot{s}_1 = -\dot{\eta} - \eta \quad (2)$$

$$\theta_1 [\dot{s}_2 + s_2] + \dot{s}_2 = u(t). \quad (3)$$

3) Combien d'équations différentielles faut-il résoudre pour connaître η , s_1 et s_2 ? Écrivez ces équations et représentez les sur un schéma bloc (on notera $1/s$ le bloc intégrateur et on indiquera sur le schéma où sont obtenus η , s_1 et s_2).

On simule (2) pour obtenir s_2 , puis du fait de la linéarité des équations différentielles (1) et (3) η est donné par $\eta = \theta_2 s_2$. On a donc aussi $\dot{\eta} = \theta_2 \dot{s}_2$. L'équation (2) peut donc s'écrire

$$\theta_1 [\dot{s}_1 + s_1] + \dot{s}_1 = -\theta_2 (\dot{s}_2 + s_2) = -\frac{\theta_2}{\theta_1} [u(t) - \dot{s}_2]. \quad (4)$$

Il y a donc seulement deux équations différentielles à simuler, (3) et (4).

4) En définissant \mathbf{x} le vecteur d'état

$$\mathbf{x} = (\dot{s}_2, s_2, \dot{s}_1, s_1)^\top$$

écrivez les équations différentielles de la question 3 sous la forme

$$\dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{b}u(t) \quad (5)$$

et explicitez la matrice $\mathbf{A} \in \mathbb{R}^4 \times \mathbb{R}^4$ et le vecteur $\mathbf{b} \in \mathbb{R}^4$. Exprimer $\mathbf{z} = (\eta, s_1, s_2)^\top$ sous la forme $\mathbf{z} = \mathbf{C}\mathbf{x}$ en explicitant la matrice \mathbf{C} .

On obtient directement

$$\dot{\mathbf{x}} = \begin{pmatrix} \dot{s}_2 \\ \dot{s}_2 \\ \dot{s}_1 \\ \dot{s}_1 \end{pmatrix} = \begin{pmatrix} -1/\theta_1 & -1 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ \theta_2/\theta_1^2 & 0 & -1/\theta_1 & -1 \\ 0 & 0 & 1 & 0 \end{pmatrix} \mathbf{x} + \begin{pmatrix} 1/\theta_1 \\ 0 \\ -\theta_2/\theta_1^2 \\ 0 \end{pmatrix} u(t) \quad (6)$$

et

$$\mathbf{z} = \begin{pmatrix} \eta \\ s_1 \\ s_2 \end{pmatrix} = \begin{pmatrix} 0 & \theta_2 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 \end{pmatrix} \mathbf{x}.$$

5) Le calcul du déterminant $d = \det[\lambda \mathbf{I} - \mathbf{A}]$, avec \mathbf{I} la matrice identité, donne

$$d = \frac{(\lambda^2 \theta_1 + \lambda + \theta_1)^2}{\theta_1^2}.$$

Discutez la stabilité des équations différentielles de la question 3 suivant la valeur de θ_1 .

Le déterminant ci-dessus a deux racines doubles dans \mathbb{C} données par $[-1 \pm \sqrt{1 - 4\theta_1^2}]/(2\theta_1)$. Le système d'équations différentielles (6) est stable si et seulement ces racines ont une partie réelle négative, c'est-à-dire si $\theta_1 > 0$.

6) Dans l'équation différentielle de départ (1), posez $\mathbf{x} = (\eta, \eta)^\top$, et écrivez l'équation différentielle sous la forme (5) (où à présent $\mathbf{A} \in \mathbb{R}^2 \times \mathbb{R}^2$ et $\mathbf{b} \in \mathbb{R}^2$). Calculer $\det[\lambda \mathbf{I} - \mathbf{A}]$ et discuter la stabilité de (1) en fonction de θ_1 . Pourquoi les résultats des calculs de la question 5) étaient-ils prévisibles?

On obtient

$$\dot{\mathbf{x}} = \begin{pmatrix} -1/\theta_1 & -1 \\ 1 & 0 \end{pmatrix} \mathbf{x} + \begin{pmatrix} \theta_2/\theta_1 \\ 0 \end{pmatrix} u(t)$$

et à présent $\det[\lambda \mathbf{I} - \mathbf{A}] = (\lambda^2 \theta_1 + \lambda + \theta_1)/\theta_1$ qui a les mêmes racines que précédemment. Ce n'est pas surprenant car le système (6) a été obtenu à partir de (1) en dérivant par rapport à θ_1 et θ_2 , ce qui ne change rien aux propriétés de stabilité.

PARTIE 2

On considère l'algorithme du gradient à pas optimum pour l'optimisation de la fonction

$$f(\mathbf{x}) = \frac{1}{2}(\mathbf{x} - \mathbf{x}^*)^\top \mathbf{A}(\mathbf{x} - \mathbf{x}^*)$$

avec $\mathbf{x} \in \mathbb{R}^d$ et \mathbf{A} une matrice symétrique définie positive.

1) Calculez le gradient de f en \mathbf{x} , que l'on notera $\mathbf{g}(\mathbf{x})$.

$$\mathbf{g}(\mathbf{x}) = \mathbf{A}(\mathbf{x} - \mathbf{x}^*).$$

2) Si \mathbf{x}_k est la valeur proposée par l'algorithme à l'itération k , donnez la valeur optimale du pas, notée γ_k , pour passer au point suivant \mathbf{x}_{k+1} . Exprimez γ_k en fonction de \mathbf{A} et $\mathbf{g}_k = \mathbf{g}(\mathbf{x}_k)$ puis \mathbf{x}_{k+1} en fonction de \mathbf{x}_k , \mathbf{A} et \mathbf{g}_k .

Puisque $\mathbf{x}_{k+1} = \mathbf{x}_k - \gamma_k \mathbf{g}_k$, avec γ_k choisi de façon à minimiser $f(\mathbf{x}_{k+1})$, γ_k satisfait

$$\gamma_k = \frac{\mathbf{g}_k^\top \mathbf{A}(\mathbf{x}_k - \mathbf{x}^*)}{\mathbf{g}_k^\top \mathbf{A} \mathbf{g}_k} = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{g}_k^\top \mathbf{A} \mathbf{g}_k}$$

et donc

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{g}_k^\top \mathbf{A} \mathbf{g}_k} \mathbf{g}_k.$$

3) Donnez l'expression de \mathbf{g}_{k+1} en fonction de \mathbf{A} et \mathbf{g}_k .

On déduit de l'équation précédente

$$\mathbf{A}(\mathbf{x}_{k+1} - \mathbf{x}^*) = \mathbf{A}(\mathbf{x}_k - \mathbf{x}^*) - \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{g}_k^\top \mathbf{A} \mathbf{g}_k} \mathbf{A} \mathbf{g}_k$$

d'où il vient

$$\mathbf{g}_{k+1} = \mathbf{g}_k - \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{g}_k^\top \mathbf{A} \mathbf{g}_k} \mathbf{A} \mathbf{g}_k$$

4) On définit

$$\mathbf{z}_k = \frac{\mathbf{g}_k}{\sqrt{\mathbf{g}_k^\top \mathbf{g}_k}}$$

et $\mu_i^k = \mathbf{z}_k^\top \mathbf{A}^i \mathbf{z}_k$ pour tout i . Que vaut μ_0^k ? Exprimez \mathbf{z}_{k+1} en fonction de \mathbf{A} , μ_1^k , μ_2^k et \mathbf{z}_k . Exprimez ensuite μ_i^{k+1} en fonction de μ_i^k , μ_{i+1}^k , μ_{i+2}^k , μ_1^k , et μ_2^k . Calculez la vitesse de convergence à l'itération k

$$r_k = \frac{f(\mathbf{x}_{k+1})}{f(\mathbf{x}_k)}$$

en fonction de μ_1^k et μ_{-1}^k .

$$\mu_0^k = \mathbf{z}_k^\top \mathbf{z}_k = 1.$$

\mathbf{z}_{k+1} est proportionnel à \mathbf{g}_{k+1} , posons $\mathbf{z}_{k+1} = C_{k+1} \mathbf{g}_{k+1}$. On a

$$\mathbf{z}_{k+1} = C_{k+1} \left(\mathbf{I} - \frac{\mathbf{z}_k^\top \mathbf{z}_k}{\mathbf{z}_k^\top \mathbf{A} \mathbf{z}_k} \mathbf{A} \right) \mathbf{g}_k = C_{k+1} (\mathbf{I} - \mathbf{A}/\mu_1^k) \mathbf{g}_k.$$

Puisque $\mathbf{z}_{k+1}^\top \mathbf{z}_{k+1} = 1$,

$$C_{k+1}^2 [\mathbf{g}_k^\top \mathbf{g}_k + \mathbf{g}_k^\top \mathbf{A}^2 \mathbf{g}_k / (\mu_1^k)^2 - 2\mathbf{g}_k^\top \mathbf{A} \mathbf{g}_k / \mu_1^k] = 1$$

et

$$\begin{aligned} \mathbf{z}_{k+1} &= \frac{(\mathbf{I} - \mathbf{A}/\mu_1^k) \mathbf{g}_k}{[\mathbf{g}_k^\top \mathbf{g}_k + \mathbf{g}_k^\top \mathbf{A}^2 \mathbf{g}_k / (\mu_1^k)^2 - 2\mathbf{g}_k^\top \mathbf{A} \mathbf{g}_k / \mu_1^k]^{1/2}} \\ &= \frac{(\mathbf{I} - \mathbf{A}/\mu_1^k) \mathbf{z}_k}{[\mu_2^k / (\mu_1^k)^2 - 1]^{1/2}}. \end{aligned}$$

Par conséquent on obtient par un calcul direct

$$\mu_i^{k+1} = \mathbf{z}_{k+1}^\top \mathbf{A}^i \mathbf{z}_{k+1} = \frac{\mu_{i+2}^k / (\mu_1^k)^2 - 2\mu_{i+1}^k / \mu_1^k + \mu_i^k}{\mu_2^k / (\mu_1^k)^2 - 1}.$$

Le calcul de la vitesse de convergence donne

$$\begin{aligned} r_k &= \frac{(\mathbf{x}_{k+1} - \mathbf{x}^*)^\top \mathbf{A} (\mathbf{x}_{k+1} - \mathbf{x}^*)}{(\mathbf{x}_k - \mathbf{x}^*)^\top \mathbf{A} (\mathbf{x}_k - \mathbf{x}^*)} = \frac{\mathbf{g}_{k+1}^\top \mathbf{A}^{-1} \mathbf{g}_{k+1}}{\mathbf{g}_k^\top \mathbf{A}^{-1} \mathbf{g}_k} \\ &= \frac{\mathbf{z}_{k+1}^\top \mathbf{A}^{-1} \mathbf{z}_{k+1}}{\mathbf{z}_k^\top \mathbf{A}^{-1} \mathbf{z}_k} \frac{\mathbf{g}_{k+1}^\top \mathbf{g}_{k+1}}{\mathbf{g}_k^\top \mathbf{g}_k} \\ &= \frac{\mu_{-1}^{k+1}}{\mu_{-1}^k} [\mu_2^k / (\mu_1^k)^2 - 1] = 1 - \frac{1}{\mu_1^k \mu_{-1}^k}. \end{aligned}$$

5) On suppose que \mathbf{A} est sous la forme diagonale, $\mathbf{A} = \text{diag}(\lambda_1, \dots, \lambda_d)$. Expliquez pourquoi $(\{\mathbf{z}_k\}_i)^2$, avec $\{\mathbf{z}_k\}_i$ la composante numéro i de \mathbf{z}_k , peut être considéré comme une masse affectée à la valeur propre λ_i de \mathbf{A} à l'itération k . Quelle est alors l'interprétation des μ_i^k ? Montrez que

$$(\{\mathbf{z}_{k+1}\}_i)^2 = H_k(\lambda_i, \mu_1^k, \mu_2^k) (\{\mathbf{z}_k\}_i)^2$$

pour tout $i = 1, \dots, d$, et explicitez la fonction H_k .

On a dans l'espace des vecteurs propres de \mathbf{A}

$$\mu_j^k = \mathbf{z}_k^\top \mathbf{A}^j \mathbf{z}_k = \sum_{i=1}^d \lambda_i^j (\{\mathbf{z}_k\}_i)^2$$

qui peut être considéré comme le moment d'ordre j de la mesure de probabilité discrète sur le spectre de \mathbf{A} affectant la masse $(\{\mathbf{z}_k\}_i)^2$ à la valeur propre λ_i .

D'après l'équation donnant \mathbf{z}_{k+1} en fonction de \mathbf{z}_k on a

$$(\{\mathbf{z}_{k+1}\}_i)^2 = \frac{(1 - \lambda_i / \mu_1^k)^2}{\mu_2^k / (\mu_1^k)^2 - 1} (\{\mathbf{z}_k\}_i)^2.$$