

Optimisation, algorithmique (MML1E31) (M1 Maths, 2016-2017)

Examen du mercredi 4 janvier 2017

Nombre de pages du sujet : 4. Durée 2h.

Les documents suivants sont autorisés :

- **Polycopiés distribués en cours et notes de cours manuscrites correspondantes,**
- **Sujets de TP imprimés et notes manuscrites correspondantes.**

La consultation de tout autre document (livres, etc.) et l'utilisation de tout appareil électronique sont interdites.

Exercice 1. *(sur environ 12 points)*

Rappel sur les fonctionnelles quadratiques : On rappelle qu'une fonction $g : \mathbb{R}^n \rightarrow \mathbb{R}$ est une fonctionnelle quadratique s'il existe une matrice carrée symétrique $A \in \mathcal{M}_n(\mathbb{R})$, un vecteur $b \in \mathbb{R}^n$ et une constante $c \in \mathbb{R}$ tels que

$$\forall x \in \mathbb{R}^n, \quad g(x) = \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle + c$$

(et alors la matrice A , le vecteur b et la constante c sont uniques).

Fonctionnelle des moindres carrés : Soient $n, p \in \mathbb{N}^*$ deux entiers non nuls. Soient $A \in \mathcal{M}_{p,n}(\mathbb{R})$ une matrice rectangulaire, $b \in \mathbb{R}^p$ un vecteur. On définit la fonction $f : \mathbb{R}^n \rightarrow \mathbb{R}$ par

$$f(x) = \frac{1}{2} \|Ax - b\|^2.$$

Attention on utilisera la même notation pour la norme et le produit scalaire dans \mathbb{R}^n et dans \mathbb{R}^p , mais les vecteurs ne sont a priori pas de la même taille !

1. Montrer que f est une fonctionnelle quadratique et préciser la matrice carrée $A' \in \mathcal{M}_n(\mathbb{R})$, le vecteur $b' \in \mathbb{R}^n$ et la constante $c' \in \mathbb{R}$ associés à f .
2. Donner l'expression du gradient $\nabla f(x)$ et de la matrice hessienne $\nabla^2 f(x)$ de f en tout point $x \in \mathbb{R}^n$ (on pourra se référer à un résultat du cours plutôt que de faire les calculs).
3. Montrer que f est convexe.
4. Montrer que f est fortement convexe si et seulement si $\ker(A) = \{0\}$.
5. Soit $x \in \mathbb{R}^n$ tel que $\nabla f(x) \neq 0$. Rappeler la définition d'une direction de descente $d \in \mathbb{R}^n$ au point x et montrer que $d \in \mathbb{R}^n$ est une direction de descente si et seulement si

$$\langle Ax - b, Ad \rangle < 0$$

(en particulier $Ad \neq 0$).

6. Soit $x \in \mathbb{R}^n$ tel que $\nabla f(x) \neq 0$ et d une direction de descente au point x . Montrer que le problème d'optimisation

$$\inf_{t \in \mathbb{R}} f(x + td)$$

admet une unique solution donnée par

$$t^* = -\frac{\langle \nabla f(x), d \rangle}{\|Ad\|^2}. \quad (1)$$

Algorithme de gradient conjugué pour les moindres carrés : On suppose désormais que $\ker(A) = \{0\}$. On rappelle ci-dessous le pseudo-code de l'algorithme du gradient conjugué afin de minimiser une fonctionnelle quadratique

$$g(x) = \frac{1}{2} \langle A'x, x \rangle - \langle b', x \rangle + c'$$

lorsque A' est symétrique définie positive (ce qui revient à résoudre le système linéaire $A'x = b'$). On rappelle que, par convention, pour cet algorithme ce sont les vecteurs opposés $-d^{(k)}$ qui sont des directions de descente.

Algorithme 1 : Algorithme du gradient conjugué

Données : Un point initial $x^{(0)} \in \mathbb{R}^n$, un seuil de tolérance $\varepsilon > 0$

Résultat : Un point $x \in \mathbb{R}^n$ proche de x^*

Initialiser x :

$$x \leftarrow x^{(0)} ;$$

$$k \leftarrow 0 ;$$

Première itération :

1. Calculer $d^{(0)} = \nabla g(x)$ ($d^{(0)} = \nabla g(x^{(k)})$)

2. Calculer le pas de descente optimal $t^{(0)}$ dans la direction de descente $-d^{(0)}$

3. Mettre à jour x :

$$x \leftarrow x^{(1)} = x^{(0)} - t^{(0)}d^{(0)} ; \text{ (attention c'est bien un signe -)}$$

$$k \leftarrow k + 1 ;$$

tant que $\|\nabla f(x)\|^2 > \varepsilon^2$ **faire**

1. Calculer $d^{(k)} = \nabla g(x^{(k)}) + \frac{\|\nabla g(x^{(k)})\|^2}{\|\nabla g(x^{(k-1)})\|^2} d^{(k-1)}$.

2. Calculer le pas de descente optimal $t^{(k)}$ dans la direction de descente $-d^{(k)}$

3. Mettre à jour x :

$$x \leftarrow x^{(k+1)} = x^{(k)} - t^{(k)}d^{(k)} ; \text{ (attention c'est bien un signe -)}$$

$$k \leftarrow k + 1 ;$$

fin

7. En utilisant l'équation (1), donner l'expression des pas de descente $t^{(0)}$ et $t^{(k)}$, $k \geq 1$, pour la fonction $f(x) = \frac{1}{2} \|Ax - b\|^2$ en fonction de $\nabla f(x^{(0)})$, A et $d^{(0)}$ pour $t^{(0)}$ et $\nabla f(x^{(k)})$, A et $d^{(k)}$ pour $t^{(k)}$ (en faisant attention à la convention sur les directions de descentes).

8. Ecrire une fonction scilab

function x = grad_conj_moindres_carres(A, b, x0, eps)

qui applique l'algorithme du gradient conjugué à la fonctionnelle $f(x) = \frac{1}{2}\|Ax - b\|^2$ en partant du point x_0 et avec une tolérance ε pour le critère d'arrêt. On pourra introduire une fonction intermédiaire qui calcule le gradient de f (non obligatoire).

Exercice 2. (sur environ 9 points)

Soit $n \geq 2$ un entier. On note e_1, e_2, \dots, e_n les vecteurs de la base canonique de \mathbb{R}^n . On note $\|x\| = \sqrt{\langle x, x \rangle}$ la norme euclidienne usuelle de \mathbb{R}^n et

$$\|x\|_\infty = \max_{i \in \{1, \dots, n\}} |x_i|.$$

Dans la suite de l'exercice, $f : \mathbb{R}^n \rightarrow \mathbb{R}$ désigne une fonction deux fois différentiable sur \mathbb{R}^n et fortement convexe telle que

$$\forall x, h \in \mathbb{R}^n, \quad m\|h\|^2 \leq \langle \nabla^2 f(x)h, h \rangle \leq M\|h\|^2$$

avec $0 < m \leq M$. On note x^* le point où f atteint son minimum global et $p^* = f(x^*)$ la valeur minimale de f .

Le but de l'exercice est d'étudier la convergence d'un algorithme de descente qui prend pour direction de descente à l'étape k le vecteur

$$d^{(k)} = -\frac{\partial f}{\partial x_i}(x^{(k)})e_i$$

où i est le plus petit indice pour lequel

$$\left| \frac{\partial f}{\partial x_i}(x^{(k)}) \right| = \|\nabla f(x^{(k)})\|_\infty.$$

Plus précisément, on considère l'Algorithme 2 ci-dessous.

Algorithme 2 : Algorithme de descente selon la dérivée partielle maximale

Données : Un point initial $x^{(0)} \in \mathbb{R}^n$, un seuil de tolérance $\varepsilon > 0$

Résultat : Un point $x \in \mathbb{R}^n$ proche de x^*

Initialiser x :

$$x \leftarrow x^{(0)} ;$$

$$k \leftarrow 0 ;$$

tant que $\|\nabla f(x)\| > \varepsilon$ **faire**

1. Déterminer le plus petit indice i tel que $\left| \frac{\partial f}{\partial x_i}(x^{(k)}) \right| = \|\nabla f(x^{(k)})\|_\infty$

2. Déterminer un pas de descente $t^{(k)} > 0$ par la méthode exacte pour la direction de descente $d^{(k)} = -\frac{\partial f}{\partial x_i}(x^{(k)})e_i$ (ou par la méthode de rebroussement de paramètres α et β).

3. Mettre à jour x :

$$x \leftarrow x^{(k+1)} = x^{(k)} + t^{(k)}d^{(k)} ;$$

$$k \leftarrow k + 1 ;$$

fin

Implémentation de l'Algorithme 2 avec la méthode de rebroussement On suppose que les fonctions

function $fx = f(x)$ et function $gfx = \text{grad}f(x)$

sont définies dans scilab. On rappelle qu'en Scilab si u est un vecteur $u = (u_1, \dots, u_n)$, alors

- $\text{abs}(u)$ renvoie le vecteur $(|u_1|, \dots, |u_n|)$.
- $[\nu, i] = \text{max}(u)$ renvoie la valeur maximale $v = \max_i u_i$ des coordonnées de u ainsi que le plus petit indice i tel que $u_i = v = \max_i u_i$.

1. Ecrire une fonction scilab

function $x = \text{desc_der_partielle_max}(x0, \text{eps}, \text{alph}, \text{bet})$

qui prend en entrées un point initial $x^{(0)} \in \mathbb{R}^n$, un seuil de tolérance $\varepsilon > 0$, et deux paramètres α et β , et renvoie le point x calculé par l'algorithme de descente selon la dérivée partielle maximale utilisant la méthode de rebroussement pour le calcul du pas de descente (avec les paramètres $\alpha \in [0, \frac{1}{2}[$ et $\beta \in]0, 1]$).

Etude de la convergence de l'Algorithme 2 avec la méthode exacte Le but de la fin de l'exercice est de démontrer la convergence de l'Algorithme 2 avec la méthode exacte pour le calcul du pas de descente. On rappelle que la forte convexité de f implique que pour tout $x \in \mathbb{R}^n$,

$$\|\nabla f(x)\|^2 \geq 2m(f(x) - p^*).$$

On suppose qu'à l'étape k de l'Algorithme 2 le point $x^{(k)}$ est différent de x^* . On note i le plus petit indice tel que $\left| \frac{\partial f}{\partial x_i}(x^{(k)}) \right| = \|\nabla f(x^{(k)})\|_\infty$ et on pose $d^{(k)} = -\frac{\partial f}{\partial x_i}(x^{(k)})e_i$.

2. Montrer que $\langle \nabla f(x^{(k)}), d^{(k)} \rangle = -\|\nabla f(x^{(k)})\|_\infty^2$ (ce qui montre que $d^{(k)}$ est bien une direction de descente pour le point x).
3. Montrer que pour tout $t > 0$,

$$f(x^{(k+1)}) \leq f(x^{(k)} + td^{(k)}) \leq f(x^{(k)}) - t\|\nabla f(x^{(k)})\|_\infty^2 + t^2 \frac{M}{2} \|\nabla f(x^{(k)})\|_\infty^2.$$

4. En déduire que

$$f(x^{(k+1)}) \leq f(x^{(k)}) - \frac{1}{2M} \|\nabla f(x^{(k)})\|_\infty^2.$$

5. Démontrer que pour tout $x \in \mathbb{R}^n$, $\|x\|_\infty^2 \geq \frac{1}{n} \|x\|^2$.

6. Montrer, à l'aide des deux questions précédentes, que

$$f(x^{(k+1)}) - p^* \leq \left(1 - \frac{m}{nM}\right) (f(x^{(k)}) - p^*).$$

7. Conclure sur la convergence de l'Algorithme 2.