

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

**Examen du mercredi 4 janvier 2017  
Corrigé**

**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  $\varepsilon$  pour le critère d'arrêt. On pourra introduire une fonction intermédiaire qui calcule le gradient de  $f$  (non obligatoire).

**Solution de l'exercice 1.**

1.

$$\begin{aligned} f(x) &= \frac{1}{2}\|Ax - b\|^2 \\ &= \frac{1}{2}\langle Ax - b, Ax - b \rangle \\ &= \frac{1}{2}\langle Ax, Ax \rangle - \langle b, Ax \rangle + \frac{1}{2}\langle b, b \rangle \\ &= \frac{1}{2}\langle A^T Ax, x \rangle - \langle A^T b, x \rangle + \frac{1}{2}\|b\|^2. \end{aligned}$$

Donc  $f$  est quadratique avec

$$A' = A^T A, \quad b' = A^T b, \quad c = \frac{1}{2}\|b\|^2.$$

2. D'après les expressions du gradient et de la matrice hessienne des fonctionnelles quadratiques,

$$\nabla f(x) = A'x - b' = A^T(Ax - B)$$

et

$$\nabla^2 f(x) = A' = A^T A.$$

3. Pour tout  $h \in \mathbb{R}^n$ ,

$$\langle \nabla^2 f(x)h, h \rangle = \langle A^T Ah, h \rangle = \|Ah\|^2 \geq 0.$$

Donc la matrice hessienne de  $f$  est positive en tout point  $x \in \mathbb{R}^n$ ,  $f$  est donc convexe. On peut également justifier que  $f$  est convexe car c'est la composée de l'application affine  $x \mapsto Ax - b$  et de la fonction convexe  $y \mapsto \|y\|^2$ .

4. Supposons que  $f$  soit fortement convexe. Alors il existe  $m > 0$  tel que

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

Or  $\langle \nabla^2 f(x)h, h \rangle = \|Ah\|^2$ . D'où,  $\|Ah\|^2 \geq m\|h\|^2$  pour tout  $h \in \mathbb{R}^n$ , en particulier,  $h \neq 0$  implique  $Ah \neq 0$ , donc  $\ker(A) = \{0\}$ .

Supposons que  $\ker(A) = \{0\}$ . Alors  $A' = A^T A$  est une matrice réelle symétrique définie positive. Elle admet une valeur propre minimale  $\lambda > 0$  et on a

$$\langle A^T Ah, h \rangle \geq \lambda\|h\|^2,$$

donc  $f$  est fortement convexe pour  $m = \lambda$ .

5.  $d \in \mathbb{R}^n$  est une *direction de descente* au point  $x$  si  $\langle \nabla f(x), d \rangle < 0$ . Ainsi  $d$  est une direction de descente ssi

$$\langle A^T(Ax - b), d \rangle < 0$$

soit ssi

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

6. La fonction  $\varphi : t \mapsto f(x + td)$  est un trinôme du second degré pour la variable  $t$ . En effet, on a

$$\varphi(t) = f(x + td) = f(x) + t \underbrace{\langle A^T(Ax - b), d \rangle}_{=\nabla f(x)} + \frac{t^2}{2} \|Ad\|^2.$$

Cette fonction est minimale au point  $t$  tel que  $\varphi'(t) = 0$ , soit

$$\langle \nabla f(x), d \rangle + t \|Ad\|^2 = 0$$

d'où l'expression de  $t^*$ .

7. On en appliquant l'équation (1) avec  $d = -d^{(0)} = -\nabla f(x^{(0)})$ ,

$$t^{(0)} = \frac{\|d^{(0)}\|^2}{\|Ad^{(0)}\|^2}.$$

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

8.

```
function x = grad_conj_moindres_carres(A, b, x0, eps)
x = x0
k = 0
gfx = A' * (A*x-b)
sqngfx = gfx' * gfx
d = gfx;
Ad = A*d;
t = sqngfx / (Ad' * Ad)
x = x - t*d
sqngfxold = sqngfx
gfx = A' * (A*x - b)
sqngfx = gfx' * gfx
k = k+1

while(sqngfx > eps^2 & k < 1000)
    d = gfx + sqngfx / sqngfxold * d
    Ad = A*d;
    t = gfx' * d / (Ad' * Ad)
    x = x - t*d
    sqngfxold = sqngfx
    gfx = A*x - b
    sqngfx = gfx' * gfx
    k = k+1
```

```

disp([k, sqngfx]);
end

endfunction

```

**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  $\alpha$  et  $\beta$ ).

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  $(|u_1|, \dots, |u_n|)$ .
- $[\text{v}, \text{i}] = \text{max}(u)$  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  $\alpha$  et  $\beta$ , 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.

**Solution de l'exercice 2.**

1.

```

function x = desc_der_partielle_max(x0, eps, alph, bet)
x=x0;
gfx=gradf(x);
sqngfx = gfx'*gfx;
while(sqngfx > eps^2)
    [ninfgfx,i] = max(abs(gfx));
    d = zeros(gfx);
    d(i) = -gfx(i);

    t=1;
    xk = x;
    fxk = f(xk);
    x = xk + t*d;
    fx = f(x);
    while(fx > fxk - alph*t*ninfgfx^2)
        // ou fxk + alph*t*gfx'*d sans utiliser la question 2)
        t = bet*t;
        x = xk + t*d;
        fx = f(x);
    end
    gfx=gradf(x);
    sqngfx = gfx'*gfx;
    disp(fx)
end
endfunction

```

```

// Test:
function fx = objectif(x,A,b)
    fx = sum(exp(A*x + b));
endfunction

```

```

function gfx = grad_obj(x,A,b)
    gfx = A'*exp(A*x + b);
endfunction

```

```

// Attention : Besoin de definir les variables A et b avant d'appeler ces
deff('fx=f(x)', 'fx = objectif(x,A,b)');
deff('gfx=gradf(x)', 'gfx = grad_obj(x,A,b)');

```

```

// Definition de la fonctionnelle
A = [ 1 3 ; 1 -3 ; -1 0 ]
b = [ -0.1 ; -0.1 ; -0.1 ]
x0 = [-2 ; 3]
eps = 10^(-8)
alph = 0.4;
bet = 0.8;

```

```
// Solution
[xstar, vg_min] = fsolve(x0, gradf)
pstar = f(xstar)

x = desc_der_partielle_max(x0, eps, alph, bet)
```

2. On a

$$\langle \nabla f(x^{(k)}), d^{(k)} \rangle = -\frac{\partial f}{\partial x_i}(x^{(k)})^2 = -\|\nabla f(x^{(k)})\|_\infty^2.$$

3. Par définition de la méthode exacte pour le calcul du pas de descente,

$$f(x^{(k+1)}) = \min_{t>0} f(x^{(k)} + td^{(k)}),$$

donc pour tout  $t > 0$ , on a bien

$$f(x^{(k+1)}) \leq f(x^{(k)} + td^{(k)}).$$

D'après la formule de Taylor-Maclaurin, il existe  $z \in [x^{(k)}, x^{(k)} + td^{(k)}]$  tel que

$$f(x^{(k)} + td^{(k)}) = f(x^{(k)}) + t\langle \nabla f(x^{(k)}), d^{(k)} \rangle + t^2 \frac{1}{2} \langle \nabla^2 f(z) d^{(k)}, d^{(k)} \rangle.$$

Or par hypothèse,

$$\langle \nabla^2 f(z) d^{(k)}, d^{(k)} \rangle \leq M \|d^{(k)}\|^2 = M \frac{\partial f}{\partial x_i}(x^{(k)})^2 = M \|\nabla f(x^{(k)})\|_\infty^2,$$

d'où la deuxième inégalité.

4. On choisit le  $t > 0$  qui minimise l'expression  $f(x^{(k)}) - t\|\nabla f(x^{(k)})\|_\infty^2 + t^2 \frac{M}{2} \|\nabla f(x^{(k)})\|_\infty^2$ .  
Il est donné pour  $t$  tel que

$$-\|\nabla f(x^{(k)})\|_\infty^2 + tM\|\nabla f(x^{(k)})\|_\infty^2 = 0$$

soit

$$t = \frac{1}{M}.$$

Pour cette valeur de  $t$  on a

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

Ainsi, on a bien

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

5. Soit  $x \in \mathbb{R}^n$ . Alors pour tout  $i \in \{1, \dots, n\}$ ,  $x_i^2 \leq \|x\|_\infty^2$ , d'où

$$\|x\|^2 = \sum_{i=1}^n x_i^2 \leq n\|x\|_\infty^2.$$

Donc on a bien  $\|x\|_\infty^2 \geq \frac{1}{n}\|x\|^2$ .

6. On a

$$\|\nabla f(x^{(k)})\|_{\infty}^2 \geq \frac{1}{n} \|\nabla f(x^{(k)})\|^2 \geq \frac{2m}{n} (f(x) - p^*),$$

d'où

$$f(x^{(k+1)}) - p^* \leq f(x^{(k)}) - p^* - \frac{1}{2M} \|\nabla f(x^{(k)})\|_{\infty}^2 \leq \left(1 - \frac{m}{nM}\right) (f(x^{(k)}) - p^*).$$

7. Par récurrence immédiate on a

$$f(x^{(k)}) - p^* \leq \left(1 - \frac{m}{nM}\right)^k (f(x^{(0)}) - p^*)$$

et  $1 - \frac{m}{nM} \in [0, 1[$  donc l'Algorithme 2 converge linéairement.