

**Optimisation (MML1E31) (M1 MM, 2017-2018)**

**Examen partiel du lundi 20 novembre 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 6 points)

Soient  $m$  et  $n$  deux entiers non nuls. Soient  $f : \mathbb{R}^m \rightarrow \mathbb{R}$  une fonction,  $A \in M_{m,n}(\mathbb{R})$  une matrice rectangulaire et  $b \in \mathbb{R}^m$  un vecteur colonne. On pose  $g : \mathbb{R}^n \rightarrow \mathbb{R}$  la fonction définie par

$$\forall x \in \mathbb{R}^n, \quad g(x) = f(Ax + b).$$

1. Rappeler la définition d'une fonction strictement convexe sur  $\mathbb{R}^n$ .
2. On suppose que  $\text{Ker}(A) \neq \{0\}$ . Montrer que  $g$  n'est pas strictement convexe sur  $\mathbb{R}^n$ .
3. Montrer que si  $f$  est strictement convexe sur  $\mathbb{R}^m$  et  $\text{Ker}(A) = \{0\}$  alors la fonction  $g$  est également strictement convexe sur  $\mathbb{R}^n$ .
4. On considère la fonction  $h : \mathbb{R}^2 \rightarrow \mathbb{R}$  définie par

$$h(x) = e^{2x_1 - x_2 - 1} + e^{-x_1 + 2} + e^{x_2}.$$

Démontrer que  $h$  est strictement convexe sur  $\mathbb{R}^2$  à l'aide de la question précédente.

5. Donner un script Octave qui :
  - Définit une fonction  $h = @ (x)$  qui évalue  $h(x)$  en s'assurant que cette fonction puisse être évaluée sur des listes de  $p$  points  $(x^{(1)}, x^{(2)}, \dots, x^{(p)})$  données sous la forme d'une matrice de taille  $n \times p$ .
  - Affiche le graphe de la fonction  $h$  sur le domaine  $[0, 2] \times [0, 2]$ .

**Solution de l'exercice 1.**

1.  $f$  est strictement convexe sur  $\mathbb{R}^m$  si

$$\forall x, y \in \mathbb{R}^m, \quad x \neq y, \quad \forall \theta \in ]0, 1[, \quad f(\theta x + (1 - \theta)y) < \theta f(x) + (1 - \theta)f(y).$$

2. Pour tout  $x \in \text{Ker}(A)$ ,  $g(x) = f(Ax + b) = f(b)$ . En particulier, comme  $\text{Ker}(A)$  n'est pas réduit à  $\{0\}$  il existe  $x, y \in \text{Ker}(A)$  tel que  $x \neq y$ , et alors pour tout  $\theta \in ]0, 1[$ ,

$$g(\theta x + (1 - \theta)y) = f(b) = \theta f(b) + (1 - \theta)f(b) = \theta g(x) + (1 - \theta)g(y).$$

Donc  $g$  n'est pas strictement convexe.

3. Soient  $x, y \in \mathbb{R}^n$ ,  $x \neq y$  et  $\theta \in ]0, 1[$ . On a,

$$g(\theta x + (1 - \theta)y) = f(A(\theta x + (1 - \theta)y) + b) = f(\theta(Ax + b) + (1 - \theta)(Ay + b))$$

Comme  $\text{Ker}(A) \neq 0$ ,  $x \mapsto Ax$  est injective, et donc  $x \neq y$  implique  $Ax \neq Ay$ . On peut donc appliquer l'inégalité de strict convexité de  $f$  aux points  $Ax + b \neq Ay + b \in \mathbb{R}^m$ , ce qui donne

$$g(\theta x + (1 - \theta)y) < \theta f(Ax + b) + (1 - \theta)f(Ay + b) = \theta g(x) + (1 - \theta)g(y).$$

Donc  $g$  est bien strictement convexe.

4.  $h$  est la composée de la fonction

$$\begin{aligned} \mathbb{R}^2 &\rightarrow \mathbb{R}^3 \\ x &\mapsto Ax + b \end{aligned}$$

avec

$$A = \begin{pmatrix} 2 & -1 \\ -1 & 0 \\ 0 & 1 \end{pmatrix} \quad \text{et} \quad b = \begin{pmatrix} -1 \\ 2 \\ 0 \end{pmatrix}$$

et la fonction

$$\begin{aligned} \mathbb{R}^3 &\rightarrow \mathbb{R} \\ \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} &\mapsto e^{y_1} + e^{y_2} + e^{y_3}. \end{aligned}$$

On a clairement  $\text{Ker}(A) = \{0\}$  car les deux vecteurs colonnes ne sont pas colinéaires. Par ailleurs, on a

$$\nabla^2 f(y) = \begin{pmatrix} e^{y_1} & 0 & 0 \\ 0 & e^{y_2} & 0 \\ 0 & 0 & e^{y_3} \end{pmatrix}$$

qui est définie positive pour tout  $y \in \mathbb{R}^3$ , donc  $f$  est bien strictement convexe sur  $\mathbb{R}^3$ . D'après la question 3),  $h = f(Ax + b)$  est bien strictement convexe sur  $\mathbb{R}^2$ .

5.

```
x1 = linspace(0, 2, 200); x2 = x1; [X1, X2] = meshgrid(x1, x2); Z
= f([X1(:), X2(:)]'); Z = reshape(Z, size(X1));
mesh(X1, X2, Z)
```

**Exercice 2.** (sur environ 17 points)

Soit  $n \geq 2$  un entier. On note  $\|x\| = \sqrt{\langle x, x \rangle}$  la norme euclidienne usuelle de  $\mathbb{R}^n$ ,

$$\|x\|_\infty = \max_{i \in \{1, \dots, n\}} |x_i| \quad \text{et} \quad \|x\|_1 = \sum_{i=1}^n |x_i|.$$

Pour  $x \in \mathbb{R}^n$  on note  $\text{sign}(x)$  le vecteur de  $\{-1, 1\}^n$  tel que pour tout  $i \in \{1, \dots, n\}$

$$(\text{sign}(x))_i = \begin{cases} 1 & \text{si } x_i \geq 0, \\ -1 & \text{si } x_i < 0. \end{cases}$$

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

$$d^{(k)} = -\|\nabla f(x^{(k)})\|_1 \text{sign}(\nabla f(x^{(k)})).$$

Plus précisément, on considère l'Algorithme 1 ci-dessous.

<p><b>Algorithme 1</b> : Algorithme de descente selon la direction de plus grande pente pour <math>\ \cdot\ _1</math></p> <p><b>Données</b> : Un point initial <math>x^{(0)} \in \mathbb{R}^n</math>, un seuil de tolérance <math>\varepsilon &gt; 0</math></p> <p><b>Résultat</b> : Un point <math>x \in \mathbb{R}^n</math> proche de <math>x^*</math></p> <p>Initialiser <math>x</math> :</p> <p style="padding-left: 20px;"><math>x \leftarrow x^{(0)}</math> ;</p> <p style="padding-left: 20px;"><math>k \leftarrow 0</math> ;</p> <p><b>tant que</b> <math>\ \nabla f(x)\  &gt; \varepsilon</math> <b>faire</b></p> <div style="border-left: 1px solid black; padding-left: 20px; margin-left: 20px;"> <p>1. Calculer la direction de descente <math>d^{(k)} = -\ \nabla f(x^{(k)})\ _1 \text{sign}(\nabla f(x^{(k)}))</math>.</p> <p>2. Déterminer un pas de descente <math>t^{(k)} &gt; 0</math> par la méthode exacte pour la direction de descente <math>d^{(k)} = -\ \nabla f(x^{(k)})\ _1 \text{sign}(\nabla f(x^{(k)}))</math> (ou par la méthode de rebroussement de paramètres <math>\alpha</math> et <math>\beta</math>).</p> <p>3. Mettre à jour <math>x</math> :</p> <p style="padding-left: 20px;"><math>x \leftarrow x^{(k+1)} = x^{(k)} + t^{(k)}d^{(k)}</math> ;</p> <p style="padding-left: 20px;"><math>k \leftarrow k + 1</math> ;</p> </div> <p><b>fin</b></p>
---

### Partie I : Implémentation de l'Algorithme 1 avec la méthode de rebroussement (sur environ 4 points)

On suppose que les fonctions  $f = @ (x)$  et  $\text{grad}f = @ (x)$  qui évaluent respectivement  $f(x)$  et  $\nabla f(x)$  sont définies dans Octave. On rappelle qu'en Octave si  $u$  est un vecteur  $u = (u_1, \dots, u_n)$ , alors  $\text{abs}(u)$  renvoie le vecteur  $(|u_1|, \dots, |u_n|)$ .

1. Ecrire une fonction Octave `sign` qui prend en entrée un vecteur colonne  $u$  et renvoie le vecteur  $\text{sign}(u) \in \{-1, 1\}^n$ .
2. Ecrire une fonction Octave

```

fonction x = descente_norme_un(x0, eps, alph, bet, f, gradf)
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 les fonctions f et gradf et renvoie le point  $x$  calculé par l'Algorithme 1 utilisant la méthode de rebroussement pour le calcul du pas de descente (avec les paramètres  $\alpha \in [0, \frac{1}{2}[$  et  $\beta \in ]0, 1]$ ).

```

**Partie II : Quelques propriétés générales** (sur environ 6 points)

3. Montrer que pour tout  $x \in \mathbb{R}^n$ ,  $\|x\|_1 \geq \|x\|$ .

4. Soit  $x \in \mathbb{R}^n$ . Montrer que

$$\langle x, -\text{sign}(x) \rangle = \min_{u \in \mathbb{R}^n, \|u\|_\infty \leq 1} \langle x, u \rangle.$$

5. Montrer que pour tout  $y \in \mathbb{R}^n$ ,

$$f(y) \geq f(x) + \langle \nabla f(x), y - x \rangle + \frac{m}{2} \|y - x\|^2.$$

6. Montrer que  $g : y \mapsto f(x) + \langle \nabla f(x), y - x \rangle + \frac{m}{2} \|y - x\|^2$  est une fonctionnelle quadratique pour laquelle on précisera la matrice  $A$ , le vecteur  $b$  et la constante  $c$ .

7. Déterminer le minimum de  $g$  et en déduire que

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

**Partie III : Etude de la convergence de l'Algorithme 1 avec la méthode exacte** (sur environ 7 points)

Le but de la fin de l'exercice est de démontrer la convergence de l'Algorithme 1 avec la méthode exacte pour le calcul du pas de descente. On suppose qu'à l'étape  $k$  de l'Algorithme 1 le point  $x^{(k)}$  est différent de  $x^*$  et on pose  $d^{(k)} = -\|\nabla f(x^{(k)})\|_1 \text{sign}(\nabla f(x^{(k)}))$ .

8. Montrer que  $\langle \nabla f(x^{(k)}), d^{(k)} \rangle = -\|\nabla f(x^{(k)})\|_1^2$  et justifier que  $d^{(k)}$  est bien une direction de descente pour le point  $x$ .

9. Montrer que pour tout  $t > 0$ ,

$$f(x^{(k+1)}) \leq f(x^{(k)} + td^{(k)}) \leq f(x^{(k)}) - t\|\nabla f(x^{(k)})\|_1^2 + t^2 \frac{M}{2} n \|\nabla f(x^{(k)})\|_1^2.$$

10. En déduire que

$$f(x^{(k+1)}) \leq f(x^{(k)}) - \frac{1}{2nM} \|\nabla f(x^{(k)})\|_1^2.$$

11. En déduire à l'aide des inégalités de la Partie II que

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

12. Conclure sur la convergence de l'Algorithme 1.

**Solution de l'exercice 2.**

```
1. function v = sign(u)
    v = ones(size(u));
    v(find(u<0)) = -1;
end
```

2.

```

function v = sign(u)
v = ones(size(u));
v(find(u<0)) = -1;
end

function x = descente_norme_un(x0, eps, alph, bet, f, gradf)
x=x0;
gfx=gradf(x);
sqngfx = gfx'*gfx;
while(sqngfx > eps^2)
    normungfx = sum(abs(gfx));
    d = -normungfx*(sign(gfx));
    t=1;
    fx = f(x);
    while(f(x+t*d) > fx - alph*t*normungfx^2)
        % ou fx + alph*t*gfx'*d sans utiliser la question 6
        t = bet*t;
    end
    x = x+t*d;
    gfx = gradf(x);
    sqngfx = gfx'*gfx;
end
endfunction

% Parametres
A = [ 1 3 ; 1 -3 ; -1 0 ]
b = [ -0.1 ; -0.1 ; -0.1 ]

% Fonction somme d'exponentielle
f = @(x) sum(exp(A*x + b));

% Fonction gradient
gradf = @(x) A'*exp(A*x + b);

x0 = [0;0];
alph = 1/3;
bet = 0.8;
eps = 10^(-8);

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

x = descente_norme_un(x0, eps, alph, bet, f, gradf)
f(x)

```

3.

$$\left(\sum_{i=1}^n |x_i|\right)^2 = \sum_{i=1}^n x_i^2 + 2 \sum_{i<j} |x_i||x_j| \geq \sum_{i=1}^n x_i^2 = \|x\|^2.$$

4. On a bien  $\|-\text{sign}(x)\|_\infty = 1$  et pour tout  $u = (u_1, u_2, \dots, u_n)$  tel que  $\|u\|_\infty \leq 1$  on a  $1 \leq u_i \leq -1$ , d'où

$$\langle x, u \rangle = \sum_{i=1}^n x_i u_i \geq \sum_{i=1}^n -|x_i||u_i| \geq \sum_{i=1}^n -|x_i| = \langle x, -\text{sign}(x) \rangle.$$

5. D'après la formule de Taylor-Maclaurin, il existe  $z \in [x, y]$  tel que

$$f(y) = f(x) + \langle \nabla f(x), y - x \rangle + \frac{1}{2} \langle \nabla^2 f(z)(y - x), y - x \rangle.$$

Or par hypothèse,

$$\langle \nabla^2 f(z)(y - x), y - x \rangle \geq m\|y - x\|^2$$

d'où l'inégalité.

6. Un simple calcul montre que  $y \mapsto g(y)$  est une fonctionnelle quadratique avec  $A = mI_n$  et  $b = mx - \nabla f(x)$  et  $c = g(0) = f(x) + \langle \nabla f(x), x \rangle + \frac{m}{2}\|x\|^2$ .

7. On a

$$p^* = \min_{y \in \mathbb{R}^n} f(y) \geq \min_{y \in \mathbb{R}^n} f(x) + \langle \nabla f(x), y - x \rangle + \frac{m}{2}\|y - x\|^2.$$

Or  $y \mapsto g(y)$  est une fonctionnelle quadratique avec  $A = mI_n$  et  $b = mx - \nabla f(x)$ .  $A = mI_n$  est définie positive donc  $g$  admet un unique minimum global atteint en  $y^* = A^{-1}b = \frac{1}{m}(mx - \nabla f(x)) = x - \frac{1}{m}\nabla f(x)$ . On a alors la valeur

$$g(y^*) = f(x) - \frac{1}{m}\|\nabla f(x)\|^2 + \frac{1}{2m}\|\nabla f(x)\|^2 = f(x) - \frac{1}{2m}\|\nabla f(x)\|^2.$$

Ainsi

$$p^* \geq f(x) - \frac{1}{2m}\|\nabla f(x)\|^2$$

et donc

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

8. On a

$$\begin{aligned} \langle \nabla f(x^{(k)}), d^{(k)} \rangle &= -\|\nabla f(x^{(k)})\|_1 \langle \nabla f(x^{(k)}), \text{sign}(\nabla f(x^{(k)})) \rangle \\ &= -\|\nabla f(x^{(k)})\|_1 \sum_{i=1}^n \left| \frac{\partial f}{\partial x_i}(x^{(k)}) \right| = -\|\nabla f(x^{(k)})\|_1^2 \end{aligned}$$

On a donc  $\langle \nabla f(x^{(k)}), d^{(k)} \rangle < 0$ ,  $d^{(k)}$  est bien une direction de descente au point  $x^{(k)}$ .

9. 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,

$$\langle \nabla^2 f(z) d^{(k)}, d^{(k)} \rangle \leq M \|d^{(k)}\|^2.$$

Enfin, on remarque que

$$\|d^{(k)}\|^2 = \|\nabla f(x^{(k)})\|_1^2 \|\text{sign}(\nabla f(x^{(k)}))\|^2 = \|\nabla f(x^{(k)})\|_1^2 n$$

et on vient de montrer que

$$\langle \nabla f(x^{(k)}), d^{(k)} \rangle = \|\nabla f(x^{(k)})\|_1^2.$$

10. On choisit le  $t > 0$  qui minimise l'expression  $f(x^{(k)}) - t\|\nabla f(x^{(k)})\|_1^2 + t^2 \frac{M}{2} n \|\nabla f(x^{(k)})\|_1^2$ .  
Il est donné pour  $t$  tel que

$$-\|\nabla f(x^{(k)})\|_1^2 + tMn\|\nabla f(x^{(k)})\|_1^2 = 0$$

soit

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

Pour cette valeur de  $t$  on a

$$f(x^{(k)}) - t\|\nabla f(x^{(k)})\|_1^2 + t^2 \frac{M}{2} n \|\nabla f(x^{(k)})\|_1^2 = f(x^{(k)}) - \frac{1}{2nM} \|\nabla f(x^{(k)})\|_1^2.$$

Ainsi, on a bien

$$f(x^{(k+1)}) \leq f(x^{(k)}) - \frac{1}{2Mn} \|\nabla f(x^{(k)})\|_1^2.$$

11. On a

$$\|\nabla f(x^{(k)})\|_1^2 \geq \|\nabla f(x^{(k)})\|^2 \geq 2m(f(x) - p^*),$$

d'où

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

12. 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 1 converge linéairement.