

# CC2 Optimisation numérique

2024-25 : correction

Ex 1

9 pts

1) (2 pts)  $C$  est un ensemble fermé (intersection de fermés car inégalités larges + continuité de  $\Phi_i$  par convexité). De plus  $C$  est borné. Par continuité de  $J$ , on obtient l'existence d'un minimum de  $J$  sur  $C$  (on aurait

pu aussi utiliser la coercivité).  
De plus,  $C$  est convexe. En effet,

si  $x, y \in C$ , on a

$$\Phi_i(\lambda x + (1-\lambda)y) \leq \lambda \Phi_i(x) + (1-\lambda)\Phi_i(y)$$

$$\leq 0$$

et  $\lambda x + (1-\lambda)y \in C$ .

Comme  $J$  est strictement convexe, on a bien l'unicité du minimum précédent.

2) (2 pts) On considère  $k > 0$  et on note  
 $D_k = \{x \in \mathbb{R}^n / \Phi_i(x) \leq -\frac{1}{k}, \forall i\}$

On a si  $\alpha \in D \setminus D_k$  :

$$J_\varepsilon(\alpha) \geq J(\alpha) + \varepsilon k$$

Comme  $D_k$  est un ensemble compact et convexe, en procédant comme en 1),  $J_\varepsilon$  possède un unique minimum sur  $D_k$ . Par  $k$  assez grand, ce minimum est aussi l'unique minimum de  $J_\varepsilon$  sur  $D$ .

3) (3 pts)

Avec le raisonnement précédent, on constate que  $x_\varepsilon$  est localisé dans

un compact (du type  $D_k$ , avec  $k_0$  fixé) par  $\varepsilon$  suffisamment petit. Ainsi, quitte à extraire, il existe  $\tilde{\alpha} \in D_{k_0}$  tel que  $x_\varepsilon \rightarrow \tilde{\alpha}$  lorsque  $\varepsilon \rightarrow 0$ .

Soit  $\alpha \in D$ . Par définition

$$J_\varepsilon(\alpha) \geq J_\varepsilon(x_\varepsilon) \text{ soit :}$$

$$J_\varepsilon(\alpha) \geq J(x_\varepsilon) - \varepsilon \sum_{i=1}^m \frac{1}{\Phi_i(x_\varepsilon)}$$

Par passage à la limite ( $\varepsilon \rightarrow 0$ )

sachant que  $\tilde{\alpha} \in D_{k_0}$ ,

on a  $\Phi_i(\tilde{\alpha}) \leq -\frac{1}{k_0}$  et

ainsi :

$$J(x) \geq J(\tilde{x}) \quad \forall x \in D$$

Comme  $C$  est l'adhérence de  $D$   
cette inégalité est aussi valable  
sur  $C$  et on a bien  $\tilde{x} = x^*$ .

4) <sup>(2pts)</sup> On écrit les 2 relations de définition

$$J(x_{\frac{\varepsilon}{2}}) - \varepsilon \sum_{\frac{\Phi_i(x_{\frac{\varepsilon}{2}})}{\varepsilon}} \leq J(x_{\varepsilon'}) - \varepsilon \sum_{\frac{\Phi_i(x_{\varepsilon'})}{\varepsilon}}$$

et

$$J(x_{\varepsilon}) - \varepsilon \sum_{\frac{\Phi_i(x_{\varepsilon})}{\varepsilon}} \leq J(x) - \varepsilon \sum_{\frac{\Phi_i(x)}{\varepsilon}}$$

En effectuant l'opération  $\varepsilon' \cdot (1) + \varepsilon \cdot (2)$

on trouve :

3

$$(\varepsilon' - \varepsilon) J(x) \leq (\varepsilon' - \varepsilon) J(x_{\frac{\varepsilon}{2}})$$

ce qui implique, si  $0 < \varepsilon' < \varepsilon$  :

$$J(x_{\frac{\varepsilon}{2}}) \leq J(x_{\varepsilon})$$

L'inégalité  $J(x^*) \leq J(x_{\frac{\varepsilon}{2}})$   
provient de la définition de  $x^*$ .

Ex 2

9 pts

1) <sup>(15pts)</sup> on a

$$d(x_0, D)^2 = \inf_{y \in D} \|x_0 - y\|^2$$

Il s'agit donc de minimiser

$$J(y) = \|x_0 - y\|_2^2 = \|y\|_2^2 - 2\langle \alpha_0, y \rangle + \|\alpha_0\|_2^2$$

sous les  $m$  contraintes

$$\text{égalité : } Ax = b$$

2) (1,5 pts) La fonction  $J$  est strictement convexe et coercive sur  $\mathbb{R}^n$  ( $\text{Id} \in \mathcal{S}_n^{++}(\mathbb{R})$ ). Elle possède donc un unique minimum sur  $D$ , ensemble fermé et convexe, noté  $x^*$ .

3) (3 pts) On a

$$\mathcal{L}(y, \lambda) = J(y) + \lambda^T \cdot (Ay - b)$$

$\uparrow$   
 $\in \mathbb{R}^m$

Les conditions KKT s'écrivent <sup>4</sup>

ici :

$$\begin{cases} 2x^* - 2\alpha_0 + A^T \lambda^* = 0 \\ Ax^* = b \end{cases}$$

$$Ax^* = b$$

Il vient alors :

$$2b - 2A\alpha_0 + (A \cdot A^T) \lambda^* = 0$$

Comme  $A$  est de rang maximal, la matrice  $A \cdot A^T \in \mathcal{S}_m^{++}(\mathbb{R})$  et :

$$\lambda^* = -2(A \cdot A^T)^{-1} (b - A\alpha_0)$$

puis :

$$x^* = \alpha_0 + A(A \cdot A^T)^{-1} (b - A\alpha_0)$$

4) (1 pts) si  $m=1$ , on a  
 $x^* = x_0 + A^T \|A\|^{-2} (b - Ax_0)$

$$\text{et } d(x_0, D) = \|x_0 - x^*\|$$

$$= \frac{1}{\|A\|^2} \|A^T (b - Ax_0)\|$$

$\in \mathbb{R}$

$$= \frac{1}{\|A\|} \|b - Ax_0\|$$

5) (2 pts) Initialisation:  $x_0, \lambda_0 = 0$

↓ Iteration:  $(\alpha_1, \alpha_2 = \text{pas})$

$$x \rightarrow x - \alpha_1 (2x - 2x_0 + A^T \lambda)$$

$$\lambda \rightarrow \lambda + \alpha_2 (Ax - b)$$

Ex3 } 6 pts } 5  
(2 pts)

1) On cherche ici à minimiser la fonction

$$J(x, y) = x^2 + xy \text{ sous}$$

la contrainte :

$$x^2 y = 2V_0$$

par une méthode de pénalisation

(paramètre  $\rho$ ), résolue par

une descente de gradient  
(recherche linéaire de type  
"backtracking + Armijo")

2) (1 pt) "rho" représente le paramètre (ou le poids) de la pénalisation choisie. "x" renvoie le résultat de l'optimisation après N itérations

3) (2 pts) On écrit ici

$$x^2 y = 2000 \Rightarrow y = \frac{2000}{x^2}$$

$$\text{et } J(x, y) = x^2 + \frac{2000}{x}$$

$g(x)$

On calcule  $g'(x) = 2x - \frac{2000}{x^2}$

ce qui donne comme variations de  $g$  :

$x$	0	10	$+\infty$
$g'$	-	0	+
$g$	$+\infty$	300	$+\infty$

Le résultat exact est donc :

$$(x, y) = (10, 20)$$

4) (1 pt) le script canneted

utilise la fonction Hessian :

"def Hess(v)"

qui calcule la matrice Hessienne

et qui remplace l'itération

$x_k$  en :

$$x_{k+1} = x_k - \eta \text{p.inv}(\text{Hess} \mathcal{J}(x_k)) @ \text{Grad} \mathcal{J}(x_k)$$

~~7~~