

Chapitre 3

Algorithmes

3.1 Méthode du gradient

Définition 3.1 Soit f une fonction définie de \mathbb{R}^n dans \mathbb{R} , $x_k \in \mathbb{R}^n$ et $d_k \in \mathbb{R}^n$. On dit que d_k est une direction de descente au point x_k si il existe $\beta > 0$ telle que

$$f(x_k + \alpha d_k) < f(x_k), \forall \alpha \in]0, \beta[.$$

Proposition 3.1 Soit $f: \mathbb{R}^n \rightarrow \mathbb{R}$ une fonction différentiable au point $x_k \in \mathbb{R}^n$. Si

$$\nabla f(x_k)^T d_k < 0,$$

alors d_k est une direction de descente.

Principe de la Méthode

On veut minimiser une fonction f . Pour cela on se donne un point de départ arbitraire $x_0 \in \mathbb{R}^n$, pour construire l'itéré suivant x_1 il faut penser qu'on veut se rapprocher du minimum de f , on veut donc que $f(x_1) < f(x_0)$. On cherche alors x_1 sous la forme : $x_1 = x_0 + \alpha_0 d_0$ où $d_0 \in \mathbb{R}^n$ et $\alpha_0 > 0$. En pratique, on cherche α_0 et d_0 pour que $f(x_0 + \alpha_0 d_0) < f(x_0)$. On ne peut pas toujours trouver d_0 . Quand d_0 existe on dit que c'est une direction de descente et α_0 est le pas de descente. La direction et le pas de descente peuvent être fixes ou changer à chaque itération. Le schéma général d'une méthode de descente est le suivant :

$$\left\{ \begin{array}{l} x_0 \in \mathbb{R}^n \text{ donné,} \\ x_{k+1} = x_k + \alpha_k d_k, \alpha_k > 0, d_k \in \mathbb{R}^n, \end{array} \right.$$

où α_k et d_k sont choisis de telle sorte que :

$$f(x_k + \alpha_k d_k) < f(x_k).$$

Une idée pour trouver une direction descente est de faire un développement de Taylor à l'ordre 2 de la fonction f entre deux itérés x_k et $x_{k+1} = x_k + \alpha_k d_k$. La fonction f est de classe C^1 .

$$f(x_{k+1}) = f(x_k + \alpha_k d_k) = f(x_k) + \alpha_k \nabla f(x_k)^T d_k.$$

Si

$$\nabla f(x_k)^T d_k < 0,$$

alors

$$f(x_{k+1}) < f(x_k).$$

Donc d_k est une direction descendente.

On a :

$$\nabla f(x_k)^T \cdot d_k = \|\nabla f(x_k)\| \|d_k\| \cos(\nabla f(x_k), d_k),$$

si $\cos(\nabla f(x_k), d_k) = -1$, on obtient la meilleure localement. Ce qui donne $d_k = -\nabla f(x_k)$.

D'où

$$x_{k+1} = x_k - \alpha_k \nabla f(x_k).$$

Choix u pas α_k

Méthode du gradient à pas constant (fixe)

On prend $\alpha_k = \alpha$ constant et

$$x_{k+1} = x_k - \alpha \nabla f(x_k), \quad \alpha > 0.$$

Si α est très grand on a un risque de divergence.

Si α est très petit, la convergence est très lente.

Si α est à gradient lipchitzien de constante L , on choisit $\alpha = \frac{1}{L}$.

$$\|\nabla f(x) - \nabla f(y)\| \leq L \|x - y\|.$$

Si f est fortement convexe de rapport a , on choisit $\alpha \in]0, \frac{2a}{L^2}[$.

Méthode du gradient à pas variable

On choisie α_k tel que :

$$\alpha_k > 0, \sum_{k \geq 0} \alpha_k = \infty \text{ et } \sum_{k \geq 0} \alpha_k^2 < \infty.$$

Exemple 3.1 Soit $\alpha_k = \frac{1}{k+1}$, alors

$$\sum_{k \geq 0} \frac{1}{k+1} \text{ diverge et } \sum_{k \geq 0} \frac{1}{(k+1)^2} \text{ converge.}$$

3.1.1 Méthode du gradient à pas optimal

L'algorithme de gradient à pas optimal est donné pas :

Etape1 : Choisir $x_0 \in \mathbb{R}^n$ et mettre $k = 0$.

Etape2 : Si $\nabla f(x_k) < 0$, mettre $x_k = x^*$. Terminer. Si non aller en (3).

Etape3 : Calculer la direction $d_k = \nabla f(x_k)$.

Etape4 : Calculer α_k , $\alpha_k = \arg \min_{\alpha > 0} (f(x_k) - \alpha \nabla f(x_k))$.

Etape5 : Mettre $x_{k+1} = x_k - \alpha_k \nabla f(x_k)$, poser $k = k + 1$ et aller à l'étape 2.

Test d'arrêt On fait les test suivant :

1. $\|x_{k+1} - x_k\| \leq \varepsilon$, $\varepsilon = 10^{-6} \|x_0\|$,

et

2. $\|\nabla f(x_{k+1})\| \leq \varepsilon$, $\varepsilon = 10^{-6} \|\nabla f(x_0)\|$.

Exemple 3.2 Soit f la fonction définie pour tout couple (x, y) de \mathbb{R}^2 par :

$$f(x, y) = x^2 + y^2 - 7x - 4y - xy + 35.$$

En démarrant du point initial $x_0 = (x_0, y_0) = (1, 1)$ et en appliquant l'algorithme du gradient, trouver la solution optimale x^* du problème suivant :

$$\begin{cases} \min f(x, y) \\ (x, y) \in \mathbb{R}^2 \end{cases}.$$

Solution : (1) : $x_1 = x_0 + \alpha_0 d_0$ avec $\alpha_0 = \arg \min_{\alpha > 0} (f(x_0) - \alpha \nabla f(x_0))$ et $d_0 = \nabla f(x_0)$.
On calcul le gradient

$$\nabla f(x, y) = \begin{pmatrix} \frac{\partial f}{\partial x}(x, y) \\ \frac{\partial f}{\partial y}(x, y) \end{pmatrix} = \begin{pmatrix} 2x - y - 7 \\ 2y - x - 4 \end{pmatrix},$$

et

$$\nabla f(x_0) = \nabla f(1, 1) = (-6, -3), \quad d_0 = -\nabla f(x_0) = (6, 3).$$

On calcul aussi α_0 ,

$$\alpha_0 = \arg \min_{\alpha > 0} (f(x_0) - \alpha \nabla f(x_0)),$$

alors

$$f((x_0) - \alpha \nabla f(x_0)) = f((1, 1) - \alpha(6, 3)) = f(1 + 6\alpha, 1 + 3\alpha),$$

$$\begin{aligned}
& f(1 + 6\alpha, 1 + 3\alpha) \\
&= (1 + 6\alpha)^2 + (1 + 3\alpha)^2 - 7(1 + 6\alpha) - 4(1 + 3\alpha) - (1 + 6\alpha)(1 + 3\alpha) + 35 \\
&= 27\alpha^2 - 45\alpha + 25,
\end{aligned}$$

$$f(1 + 6\alpha, 1 + 3\alpha)' = 54\alpha - 45 = 0 \Rightarrow \alpha_0 = \frac{45}{54} = \frac{5}{6},$$

donc

$$x_1 = x_0 + \alpha_0 d_0 = \begin{pmatrix} 1 \\ 1 \end{pmatrix} + \frac{5}{6} \begin{pmatrix} 6 \\ 3 \end{pmatrix} = \begin{pmatrix} 6 \\ \frac{7}{2} \end{pmatrix}.$$

$$(2) : x_2 = x_1 + \alpha_1 d_1, x_1 = \left(6, \frac{7}{2}\right) \text{ et } d_1 = -\nabla f\left(6, \frac{7}{2}\right) = -\left(\frac{-3}{2}, 3\right).$$

$$\begin{aligned}
& f\left(6 - \frac{3}{2}\alpha, \frac{7}{2} + 3\alpha\right) \\
&= \left(6 - \frac{3}{2}\alpha\right)^2 + \left(\frac{7}{2} + 3\alpha\right)^2 - 7\left(6 - \frac{3}{2}\alpha\right) - 4\left(\frac{7}{2} + 3\alpha\right) - \left(6 - \frac{3}{2}\alpha\right)\left(\frac{7}{2} + 3\alpha\right) + 35.
\end{aligned}$$

Alors

$$f\left(6 - \frac{3}{2}\alpha, \frac{7}{2} + 3\alpha\right)' = \frac{63}{2}\alpha - \frac{45}{4} = 0 \Rightarrow \alpha_1 = \frac{5}{14}.$$

donc

$$x_2 = x_1 + \alpha_1 d_1 = \begin{pmatrix} 6 \\ \frac{7}{2} \end{pmatrix} + \frac{5}{14} \begin{pmatrix} \frac{-3}{2} \\ 3 \end{pmatrix} = \begin{pmatrix} \frac{5}{4}, \frac{44}{7} \end{pmatrix}.$$

$$(3) : x_3 = x_2 + \alpha_2 d_2, x_2 = \left(\frac{153}{28}, \frac{32}{7}\right) \text{ et } d_2 = -\nabla f\left(\frac{153}{28}, \frac{32}{7}\right) = -\left(\frac{9}{14}, \frac{9}{28}\right).$$

$$f\left(\frac{153}{28} + \frac{9}{14}\alpha, \frac{32}{7} + \frac{9}{28}\alpha\right)' = 0 \Rightarrow \alpha_2 = \frac{5}{2}.$$

$$x_3 = \begin{pmatrix} \frac{153}{28} \\ \frac{32}{7} \end{pmatrix} + \frac{5}{2} \begin{pmatrix} \frac{9}{14} \\ \frac{9}{28} \end{pmatrix} = \begin{pmatrix} 6 \\ 4, 83 \end{pmatrix}.$$

Remarque 3.1 L'algorithme du gradient à pas optimal a les propriétés suivantes :

(a) : Deux directions succesives de descente sont orthogonales.

En effet

$$\frac{d}{d\alpha} ((f(x_k) - \alpha_k \nabla f(x_k)))_{\alpha_k = \alpha} = 0$$

$$\Rightarrow -\nabla f(x_k)^T \nabla (f(x_k) - \alpha_k \nabla f(x_k)) = 0$$

$$\Rightarrow \nabla f(x_k)^T \nabla f(x_{k+1}) = 0.$$

(b) : Cas où f est quadratique : i.e $f(x) = \frac{1}{2}x^T A x - b^T x$.

$$\nabla f(x) = Ax - b \text{ et } \nabla^2 f(x) = A.$$

Le pas optimal α_k se déduit à partir de la relation suivante :

$$\nabla f(x_k)^T \nabla f(x_{k+1}) = 0 \dots \dots \dots (I)$$

$$\begin{aligned} (I) &\Rightarrow (Ax_k - b)^T (Ax_{k+1} - b) = 0 \\ &\Rightarrow (Ax_k - b)^T (A(x_k - \alpha_k A(Ax_k - b)) - b) = 0 \\ &\Rightarrow (Ax_k - b)^T (Ax_k - b - \alpha_k (Ax_k - b)) = 0 \\ &\Rightarrow \|(Ax_k - b)\|^2 - \alpha_k \|(Ax_k - b)\|_A^2 = 0 \\ &\Rightarrow \alpha_k = \frac{\|(Ax_k - b)\|^2}{\|(Ax_k - b)\|_A^2}. \end{aligned}$$

On pose :

$$\begin{cases} B_k = Ax_k - b = \nabla f(x_k), \\ \alpha_k = \frac{\|B_k\|^2}{\|B_k\|_A^2}. \end{cases}$$

Algorithme (f est quadratique)

Etape 1 : Choisir $x_0 \in \mathbb{R}^n$,

Etape 2 : $x_{k+1} = x_k - \alpha_k B_k$,

$$\alpha_k = \frac{\|B_k\|^2}{\|B_k\|_A^2}, \quad B_k = Ax_k - b = \nabla f(x_k).$$

Test d'arrêt On fait les test suivant :

$$\|B_k\| \leq \varepsilon, \quad \varepsilon = 10^{-6} \|B_0\|.$$

Exemple 3.3 Résoudre le problème suivant :

$$\begin{cases} \min_{(x,y) \in \mathbb{R}^2} f(x,y) = 4x^2 + 4y^2 - 2xy - 6x - 6y, \\ (x_0, y_0) = (0,0). \end{cases}$$

Solution : On a :

$$\nabla f(x,y) = \begin{pmatrix} 8x - 2y - 6 \\ 8y - 2x - 6 \end{pmatrix} \quad \text{et} \quad \nabla^2 f(x,y) = \begin{pmatrix} 8 & -2 \\ -2 & 8 \end{pmatrix}.$$

Alors

$$f(x, y) = \frac{1}{2}(x, y) \begin{pmatrix} 8 & -2 \\ -2 & 8 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} - (6, 6) \begin{pmatrix} x \\ y \end{pmatrix},$$

donc f est quadratique. On a :

$$x_{k+1} = x_k - \alpha_k B_k,$$

avec

$$\alpha_k = \frac{\|B_k\|^2}{\|B_k\|_A^2}, \quad B_k = Ax_k - b = \nabla f(x_k).$$

Pour $k = 1$, on a : $x_1 = x_0 - \alpha_0 B_0$, $B_0 = \nabla f(0, 0) = -(6, 6)$ et $\alpha_0 = \frac{\|B_0\|^2}{\|B_0\|_A^2}$,

$$\|B_0\|^2 = 36 + 36 = 72,$$

et

$$\|B_0\|_A^2 = -(6, 6) \begin{pmatrix} 8 & -2 \\ -2 & 8 \end{pmatrix} \begin{pmatrix} -6 \\ -6 \end{pmatrix} = 432,$$

ce qui donne

$$\alpha_0 = \frac{\|B_0\|^2}{\|B_0\|_A^2} = \frac{72}{432} =$$

donc

$$x_1 = (0, 0) + \frac{72}{432} (6, 6) = (1, 1),$$

et

$$\nabla f(x^*) = \nabla f(1, 1) = 0 < 10^{-6} \|B_0\| = 7210^{-6}.$$

D'où $x^* = (1, 1)$, $f(x^*) = f(1, 1) = -6$.

3.2 Méthode du gradient conjugué

Soit le problème d'optimisation sans contraintes suivant :

$$(P_{scq}) : \begin{cases} \min f(x) = \frac{1}{2}x^T Ax - b^T x, \\ x \in \mathbb{R}^n, \end{cases}$$

où A est une matrice symétrique définie positive sur \mathbb{R}^n .

Théorème 3.1 *Le problème (P_{scq}) a une solution unique x^* , solution du système linéaire $Ax = b$, c'est à dire que x^* vérifie :*

$$x^* = A^{-1}b.$$

Preuve. Exercice. ■

Définition 3.2 *Soit A une matrice symétrique définie positive sur \mathbb{R}^n et d_1 et d_2 deux vecteurs de \mathbb{R}^n . On dit que d_1 et d_2 sont A -conjugués si*

$$d_1^T A d_2 = 0.$$

Exemple 3.4 *Considérons la matrice A suivante :*

$$A = \begin{pmatrix} 3 & 0 & 1 \\ 0 & 4 & 2 \\ 1 & 2 & 3 \end{pmatrix}.$$

a) : *Montrer que A est définie positive.*

b) : *Construire d_0, d_1, d_2 A -conjugués.*

Solution : a) : *On calcule les déterminants des mineurs principaux de A .*

$$\Delta_1 = 3 > 0, \quad \Delta_2 = \begin{vmatrix} 3 & 0 \\ 0 & 4 \end{vmatrix} = 12 > 0$$

$$\Delta_3 = \det(A) = \begin{vmatrix} 3 & 0 & 1 \\ 0 & 4 & 2 \\ 1 & 2 & 3 \end{vmatrix} = 20 > 0.$$

Donc A est définie positive.

b) : *On commence par : $d_0^T = (1, 0, 0)$ et on construit $d_1^T = (d_{11}, d_{12}, d_{13})$ et $d_2^T = (d_{21}, d_{22}, d_{23})$ tels que :*

$$d_0^T A d_1 = 0, \quad d_0^T A d_2 = 0 \quad \text{et} \quad d_1^T A d_2 = 0.$$

Calcul de d_1 :

d_1 doit vérifier $d_0^T A d_1 = 0$

$$d_0^T A d_1 = 0 \Leftrightarrow (1, 0, 0) \begin{pmatrix} 3 & 0 & 1 \\ 0 & 4 & 2 \\ 1 & 2 & 3 \end{pmatrix} \begin{pmatrix} d_{11} \\ d_{12} \\ d_{13} \end{pmatrix} = 3d_{11} + d_{13} = 0,$$

si on prend : $d_{11} = 1$ et $d_{12} = 0$, alors l'équation précédente implique que $d_{13} = -3d_{11}$, donc $d_1 = (1, 0, -3)$. On peut vérifier facilement que :

$$d_0^T A d_1 = 0 \Leftrightarrow (1, 0, 0) \begin{pmatrix} 3 & 0 & 1 \\ 0 & 4 & 2 \\ 1 & 2 & 3 \end{pmatrix} \begin{pmatrix} 1 \\ 0 \\ -3 \end{pmatrix} = 0.$$

Calcul de d_2 :

d_2 doit vérifier $d_0^T A d_2 = 0$ et $d_1^T A d_2 = 0$. Alors

$$d_0^T A d_2 = 0 \Leftrightarrow (1, 0, 0) \begin{pmatrix} 3 & 0 & 1 \\ 0 & 4 & 2 \\ 1 & 2 & 3 \end{pmatrix} \begin{pmatrix} d_{21} \\ d_{22} \\ d_{23} \end{pmatrix} = 3d_{21} + d_{23} = 0,$$

et

$$d_1^T A d_2 = 0 \Leftrightarrow (1, 0, -3) \begin{pmatrix} 3 & 0 & 1 \\ 0 & 4 & 2 \\ 1 & 2 & 3 \end{pmatrix} \begin{pmatrix} d_{21} \\ d_{22} \\ d_{23} \end{pmatrix} = -6d_{22} - 8d_{23} = 0.$$

Autrement dit d_2^T doit vérifier le système suivant :

$$\begin{cases} 3d_{21} + d_{23} = 0 \\ -6d_{22} - 8d_{23} = 0. \end{cases}$$

On prend par exemple $d_{21} = 1$, le système précédent devient

$$\begin{cases} 3 + d_{23} = 0 \\ -6d_{22} - 8d_{23} = 0 \end{cases} \Leftrightarrow \begin{cases} d_{23} = -3 \\ -6d_{22} = -24 \end{cases} \Leftrightarrow \begin{cases} d_{23} = -3 \\ d_{22} = 4 \end{cases}.$$

Par conséquent $d_2^T = (1, -3, 4)$.

Remarque 3.2 On n'a pas unicité des vecteurs d_0, d_1, d_2 A -conjugués.

Définition 3.3 Soit A une matrice carrée symétrique. Les directions d_0, d_1, \dots, d_n sont dites A -conjugués si on a :

$$d_i^T A d_j = 0, \quad 0 \leq i, j \leq n.$$

Proposition 3.2 Soit Q une matrice (n, n) symétrique et définie positive. Si les directions d_0, d_1, \dots, d_k avec $0 \leq k \leq n-1$, sont non nulles et A -conjuguées, alors elles sont linéairement indépendants.

Preuve. Supposons que

$$\alpha_0 d_0 + \alpha_1 d_1 + \dots + \alpha_n d_n = 0 \quad (I).$$

On multiplie l'égalité (I) par $d_i^T A$, $0 \leq i \leq n$. on obtient

$$\sum_{j=0}^n \alpha_j d_i^T A d_j = \alpha_i d_i^T A d_i = 0,$$

Or

$$\alpha_i d_i^T A d_i = 0 \Rightarrow \alpha_i = 0, \quad 0 \leq i \leq n.$$

car A est définie positive et par conséquent $d_i^T A d_i > 0$. Donc le système $\{d_0, d_1, \dots, d_n\}$ est libre. ■

Proposition 3.3 Soit A une matrice symétrique définie positive. Si les vecteurs d_0, d_1, \dots, d_n sont deux à deux A -conjugués, alors ils forment une base de \mathbb{R}^n .

Soit x^* la solution unique du système $Ax = b$, ($x^* = A^{-1}b$), puisque $\{d_0, d_1, \dots, d_{n-1}\}$ base de \mathbb{R}^n deux à deux A -conjugués, on peut écrire :

$$x^* = \sum_{j=0}^{n-1} \alpha_j d_j \quad (II).$$

En multipliant à gauche de (II) par $d_i^T A$, on obtient :

$$d_i^T A x^* = \sum_{j=0}^{n-1} \alpha_j d_i^T A d_j = \alpha_i d_i^T A d_i = \alpha_i \|d_i\|_A^2,$$

alors

$$\alpha_i = \frac{d_i^T A x^*}{\|d_i\|_A^2} = \frac{d_i^T b}{\|d_i\|_A^2}, \quad i = 1, \dots, n-1.$$

Problème du construction des directions d_i ?

On construit des directions d_i ($d_i^T A d_j = 0, \forall i \neq j$) comme suit :

* : Fixons x_0 et choisissons $d_0 = \nabla f(x_0)$.

** : On Note x_1 le vecteur obtenu par l'algorithme du gradient à pas optimal : $x_1 = x_0 - \alpha_0 d_0$, avec

$$\alpha_0 = \frac{\|\nabla f(x_0)\|^2}{\|\nabla f(x_0)\|_A^2} = \frac{d_0^T \nabla f(x_0)}{\|d_0\|_A^2}.$$

On Cherche d_1 comme combinaison linéaire $\nabla f(x_1)$ et d_0 :

$$d_1 = \nabla f(x_1) - B_0 d_0.$$

B_0 choisir de telle sorte que d_0 et d_1 sont A -conjugués.

$$d_1 = \nabla f(x_1) - B_0 d_0 \Leftrightarrow d_0^T A d_1 = d_0^T A \nabla f(x_1) - B_0 d_0^T A d_0 = 0,$$

ce qui implique

$$B_0 = \frac{d_0^T A \nabla f(x_1)}{d_0^T A d_0} = \frac{d_0^T A \nabla f(x_1)}{\|d_0\|_A^2}.$$

Maintenant : $x_2 = x_1 - \alpha_1 d_1$, avec $\alpha_1 = \frac{d_1^T \nabla f(x_1)}{\|d_1\|_A^2}$ et on cherche d_2 comme suit :

$$d_2 = \nabla f(x_2) - B_1 d_1, \text{ qui soit } A - \text{conjugués avec } d_0 \text{ et } d_1,$$

avec

$$B_1 = \frac{d_1^T A \nabla f(x_2)}{\|d_1\|_A^2}.$$

Algorithme du gradient conjugué

Etape 1 : Choisir $x_0 \in \mathbb{R}^n$,

Etape 2 : $x_{k+1} = x_k - \alpha_k d_k$, $\alpha_k = \frac{d_k^T \nabla f(x_k)}{\|d_k\|_A^2}$,

$$d_k = \nabla f(x_{k+1}) - B_k d_k, \quad B_k = \frac{d_k^T A \nabla f(x_{k+1})}{\|d_k\|_A^2}.$$

Exemple 3.5 Résoudre le problème suivant :

$$\begin{cases} \min_{(x,y) \in \mathbb{R}^2} f(x,y) = \frac{3}{2}x^2 + \frac{1}{2}y^2 - xy - 2x, \\ (x_0, y_0) = (0, 0), \end{cases}$$

en utilisant l'algorithme du gradient conjugué.

Solution : On a :

$$f(x,y) = \frac{1}{2}(x,y) \begin{pmatrix} 3 & -1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} - (2,0) \begin{pmatrix} x \\ y \end{pmatrix}$$

et

$$\nabla f(x, y) = (3x + -y - 2, 2y - x), \nabla f(0, 0) = (-2, 0).$$

Calcul de x_1 :

$$x_1 = x_0 - \alpha_0 d_0, \alpha_0 = \frac{d_0^T \nabla f(x_0)}{\|d_0\|_A^2} = \frac{4}{12} = \frac{1}{3}, d_0 = \nabla f(0, 0) = (-2, 0),$$

donc

$$x_1 = (0, 0) - \frac{1}{3}(-2, 0) = \left(\frac{2}{3}, 0\right).$$

Calcul de x_2 :

$$x_2 = x_1 - \alpha_1 d_1, \alpha_1 = \frac{d_1^T \nabla f(x_1)}{\|d_1\|_A^2}, \nabla f(x_1) = \nabla f\left(\frac{2}{3}, 0\right) = \left(0, -\frac{2}{3}\right),$$

$$d_1 = \nabla f(x_1) - \alpha_0 B_0, B_0 = \frac{d_0^T A \nabla f(x_1)}{\|d_0\|_A^2},$$

$$d_0^T A \nabla f(x_1) = (-2, 0) \begin{pmatrix} 3 & -1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} 0 \\ -\frac{2}{3} \end{pmatrix} = \frac{-4}{3},$$

$$\|d_0\|_A^2 = (-2, 0) \begin{pmatrix} 3 & -1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} -2 \\ 0 \end{pmatrix} = 12,$$

$$d_1 = \nabla f(x_1) - \alpha_0 B_0 = \left(0, -\frac{2}{3}\right) + \frac{1}{9}(-2, 0) = \left(-\frac{2}{9}, -\frac{2}{3}\right),$$

$$d_1^T \nabla f(x_1) = \left(-\frac{2}{9}, -\frac{2}{3}\right) \begin{pmatrix} 0 \\ -\frac{2}{3} \end{pmatrix} = \frac{4}{9},$$

$$\|d_1\|_A^2 = \left(-\frac{2}{9}, -\frac{2}{3}\right) \begin{pmatrix} 3 & -1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} -\frac{2}{9} \\ -\frac{2}{3} \end{pmatrix} = \frac{8}{27},$$

$$\alpha_1 = \frac{d_1^T \nabla f(x_1)}{\|d_1\|_A^2} = \frac{3}{2}.$$

donc

$$x_2 = x_1 - \alpha_1 d_1 = \left(\frac{2}{3}, 0\right) + \frac{3}{2} \begin{pmatrix} \frac{2}{9} \\ \frac{2}{3} \end{pmatrix} = (1, 1),$$

et

$$\nabla f(x_2) = \nabla f(1, 1) = 0.$$

D'où $x^* = (1, 1)$, $f(x^*) = f(1, 1) = -1$.

Remarque 3.3 L'algorithme du gradient conjugué converge ver la solution en n -itérations.

Théorème 3.2 Les directions $\{d_0, d_1, \dots, d_{n-1}\}$ engendrées par l'algorithme du gradient conjugué sont A -conjuguées.

Preuve. La preuve se fait par récurrence.

(i) : On montre que la A -conjuguées est vraie pour $k = 1$, i.e. $d_0^T Ad_1 = 0$.

En effet. On a :

$$B_0 = \frac{d_0^T A \nabla f(x_1)}{\|d_0\|_A^2}, \quad d_1 = \nabla f(x_1) - B_0 d_0,$$

donc

$$\begin{aligned} d_0^T Ad_1 &= d_0^T A (\nabla f(x_1) - B_0 d_0) = d_0^T A \nabla f(x_1) - B_0 d_0^T Ad_0 \\ &= d_0^T A \nabla f(x_1) - d_0^T Ad_0 \frac{d_0^T A \nabla f(x_1)}{\|d_0\|_A^2} = d_0^T A \nabla f(x_1) - d_0^T A \nabla f(x_1) = 0. \end{aligned}$$

(ii) : On Suppose que $\{d_0, d_1, \dots, d_k\}, k < n - 1$ sont A -conjuguées et on montre que $\{d_0, d_1, \dots, d_{k+1}\}, k < n - 1$ sont A -conjuguées, c-à-d on montre que

$$d_j^T Ad_{k+1} = 0, \quad j \in \{0, \dots, k\}. \quad (I)$$

En effet $\{0, \dots, k\} = \{0, \dots, k - 1\} \cup \{k\}$

(ii₁) : La relation (I) est vraie pour $j = k$.

En effet. On a :

$$B_k = \frac{d_k^T A \nabla f(x_{k+1})}{\|d_k\|_A^2}, \quad d_{k+1} = \nabla f(x_{k+1}) - B_k d_k,$$

donc

$$\begin{aligned} d_k^T Ad_{k+1} &= d_k^T A (\nabla f(x_{k+1}) - B_k d_k) = d_k^T A \nabla f(x_{k+1}) - B_k d_k^T Ad_k \\ &= d_k^T A \nabla f(x_{k+1}) - d_k^T Ad_k \frac{d_k^T A \nabla f(x_{k+1})}{\|d_k\|_A^2} \\ &= d_k^T A \nabla f(x_{k+1}) - d_k^T A \nabla f(x_{k+1}) = 0. \end{aligned}$$

(ii₂) : La relation (I) est vraie pour $j \in \{0, \dots, k - 1\}$.

En effet. Soit $j \in \{0, \dots, k - 1\}$,

$$d_{k+1}^T Ad_j = (\nabla f(x_{k+1}) - B_k d_k)^T Ad_j = \nabla f(x_{k+1})^T Ad_j - B_k d_k^T Ad_j \quad (II).$$

Puisque

$$d_k^T Ad_j = 0, \quad j \in \{0, \dots, k - 1\}.$$

Par conséquent (II) devient

$$d_{k+1}^T Ad_j = \nabla f(x_{k+1})^T Ad_j, \quad j \in \{0, \dots, k - 1\}.$$

On a :

$$\nabla f(x_{j+1}) - \nabla f(x_j) = \alpha_j Ad_j, \quad j = 0, \dots, k - 1,$$

par conséquent

$$Ad_j = \frac{1}{\alpha_j} (\nabla f(x_{j+1}) - \nabla f(x_j)),$$

La relation (II) donne

$$\begin{aligned}
 d_{k+1}^T A d_j &= \frac{1}{\alpha_j} d_{k+1}^T (\nabla f(x_{j+1}) - \nabla f(x_j)) \\
 &= \frac{1}{\alpha_j} \nabla f(x_{j+1})^T \left(\nabla f(x_{j+1}) - \nabla f(x_{j+1})^T \nabla f(x_j) \right) \\
 &= \frac{1}{\alpha_j} \nabla f(x_{j+1})^T \nabla f(x_{j+1}) - \frac{1}{\alpha_j} \nabla f(x_{j+1})^T \nabla f(x_j) = 0.
 \end{aligned}$$

Par conséquent la relation (II) est vraie pour $j \in \{0, \dots, k-1\}$.

(ii₁) et ii₂) impliquent que la relation (II) est vraie pour $j \in \{0, \dots, k\}$. Par conséquent les directions $\{d_0, d_1, \dots, d_{n-1}\}$ sont A -conjugués. ■

Théorème 3.3 *Partant d'un point initial $x_0 \in \mathbb{R}^N$ quelconque, l'algorithme du gradient conjugué précédent converge vers la solution optimale unique x^* du problème (Pscq) dans n -itérations, c'est à dire qu'on a :*

$$x_n^* = x^* \text{ et } Ax_n^* = Ax^* = b.$$

Preuve. Exercice. ■

3.3 Méthode de relaxation

Principe de la méthode : Minimiser la fonction f "composante par composante".

i.e Les directions de descentes successives sont les axes de \mathbb{R}^n .

On suppose que $x^{(k)} = (x_1^{(k)}, x_2^{(k)}, \dots, x_n^{(k)})$ est connu et on cherche $x^{(k+1)} = (x_1^{(k+1)}, x_2^{(k+1)}, \dots, x_n^{(k+1)})$ comme suit :

$$\begin{aligned}
 (x_1^{(k+1)}, x_2^{(k)}, \dots, x_n^{(k)}) &\leftarrow \arg \min_{\varphi \in \mathbb{R}} f(\varphi, x_2^{(k)}, \dots, x_n^{(k)}), \\
 (x_1^{(k+1)}, x_2^{(k+1)}, \dots, x_n^{(k)}) &\leftarrow \arg \min_{\varphi \in \mathbb{R}} f(x_1^{(k+1)}, \varphi, \dots, x_n^{(k)}), \\
 &\vdots \\
 (x_1^{(k+1)}, x_2^{(k+1)}, \dots, x_n^{(k+1)}) &\leftarrow \arg \min_{\varphi \in \mathbb{R}} f(x_1^{(k+1)}, x_2^{(k+1)}, \dots, x_{n-1}^{(k+1)}, \varphi).
 \end{aligned}$$

Algorithme de la méthode de relaxation

Etape 1 : Choisir $x_0 \in \mathbb{R}^n$,

Etape 2 : Pour $i = 1, \dots, n$, on calcule la solution $x_{i+1}^{(k+1)}$:

$$(x_1^{(k+1)}, x_2^{(k+1)}, \dots, x_{i-1}^{(k+1)}, x_{i+1}^{(k)}, \dots, x_n^{(k)}) \leftarrow \arg \min_{\varphi \in \mathbb{R}} f(x_1^{(k+1)}, x_2^{(k+1)}, \dots, x_{i-1}^{(k+1)}, \varphi, \dots, x_n^{(k)}).$$

Test d'arrêt On fait le test suivant :

$$1. \|\nabla f(x_{k+1})\| < \varepsilon, \varepsilon : \text{donnée},$$

$$2. \|x_{k+1} - x_k\| < \varepsilon, \varepsilon : \text{donnée}.$$

Exemple 3.6 On considère le problème d'optimisation suivant :

$$\begin{cases} \min f(x_1, x_2) = x_1^2 + x_2^2 + x_1x_2 \\ (x_1, x_2) \in \mathbb{R}^2. \end{cases}$$

et $x^{(0)} = (x_1^{(0)}, x_2^{(0)}) = (1, 1)$.

En effet, on a :

$$(x_1^{(1)}, 1) \leftarrow \arg \min_{\varphi \in \mathbb{R}} f(\varphi, 1),$$

alors

$$f(\varphi, 1) = \varphi^2 + 1 + \varphi, \quad f(\varphi, 1)' = 2\varphi + 1 = 0,$$

donc

$$x_1^{(1)} = \varphi = -\frac{1}{2}.$$

aussi

$$\left(-\frac{1}{2}, x_2^{(1)}\right) \leftarrow \arg \min_{\varphi \in \mathbb{R}} f\left(-\frac{1}{2}, \varphi\right),$$

alors

$$f\left(-\frac{1}{2}, \varphi\right) = \frac{1}{4} + \varphi^2 - \frac{1}{2}\varphi, \quad f\left(-\frac{1}{2}, \varphi\right)' = 2\varphi - \frac{1}{2} = 0,$$

ce qui donne

$$x_2^{(1)} = \varphi = \frac{1}{4},$$

donc

$$x^{(1)} = (x_1^{(1)}, x_2^{(1)}) = \left(-\frac{1}{2}, \frac{1}{4}\right).$$

Maintenant on calcule $x^{(2)} = (x_1^{(2)}, x_1^{(2)})$:

$$\left(x_1^{(2)}, \frac{1}{4}\right) \leftarrow \arg \min_{\varphi \in \mathbb{R}} f\left(\varphi, \frac{1}{4}\right),$$

on a :

$$f\left(\varphi, \frac{1}{4}\right) = \varphi^2 + \frac{1}{16} + \frac{1}{4}\varphi,$$

et

$$f\left(\varphi, \frac{1}{4}\right)' = 2\varphi + \frac{1}{4} = 0,$$

alors

$$\varphi = -\frac{1}{8} = x_1^{(2)}.$$

Pour $x_1^{(2)}$, on a :

$$\begin{aligned} \left(-\frac{1}{8}, x_2^{(2)}\right) &\leftarrow \arg \min_{\varphi \in \mathbb{R}} f\left(-\frac{1}{8}, \varphi\right), \\ f\left(-\frac{1}{8}, \varphi\right) &= \frac{1}{64} + \varphi^2 - \frac{1}{8}\varphi, \\ f\left(-\frac{1}{8}, \varphi\right)' &= 2\varphi^2 - \frac{1}{8} = 0, \end{aligned}$$

alors

$$\varphi = \frac{1}{16} = x_2^{(2)}.$$

Donc

$$x^{(2)} = \left(x_1^{(2)}, x_2^{(2)}\right) = \left(-\frac{1}{8}, \frac{1}{16}\right).$$

$$\nabla f(x_1, x_2) = \begin{pmatrix} 2x_1 + x_2 \\ x_1 + 2x_2 \end{pmatrix}, \nabla f\left(-\frac{1}{8}, \frac{1}{16}\right) = \begin{pmatrix} -\frac{1}{4} + \frac{1}{16} \\ -\frac{1}{8} + \frac{1}{8} \end{pmatrix} = \begin{pmatrix} \frac{3}{16} \\ 0 \end{pmatrix},$$

$$\|\nabla f(x^{(2)})\| < \varepsilon = 10^{-6} \|\nabla f(x^0)\|.$$

D'où $x^* = x^{(2)}$, $f(x^*) = 0.011719$.

3.4 Méthode de Newton

Considérons le problème d'optimisation sans contraintes :

$$\begin{cases} \min f(x) \\ x \in \mathbb{R}^n \end{cases}$$

où f une fonction définie de \mathbb{R}^n dans \mathbb{R} de classe C^2 .

Le principe de la méthode de Newton consiste à minimiser successivement les approximations du second ordre de la fonction f , plus précisément si

$$f(x) = f(x_0) + \nabla f(x_0)^T (x - x_0) + \frac{1}{2} (x - x_0)^T \nabla^2 f(x_0) (x - x_0), \quad x_0 \in \mathbb{R}^n.$$

La minimisation de la fonction f donne le point x_1 solution du système : $\nabla f(x) = 0$. Alors

$$\nabla f(x_1) = \nabla f(x_0) + \nabla^2 f(x_0) (x_1 - x_0) = 0,$$

ce qui donne

$$\nabla^2 f(x_0) (x_1 - x_0) = -\nabla f(x_0),$$

ce qui implique

$$x_1 = x_0 - [\nabla^2 f(x_0)]^{-1} \nabla f(x_0), \quad (\nabla^2 f(x_k) : \text{inversible}),$$

à étape $k + 1$, on a

$$x_{k+1} = x_k - [\nabla^2 f(x_k)]^{-1} \nabla f(x_k), \quad (\nabla^2 f(x_k) : \text{inversible}).$$

Algorithme de la méthode de Newton

Étape 1 : Choisir $x_0 \in \mathbb{R}^n$,

Étape 2 : $x_{k+1} = x_k - [\nabla^2 f(x_k)]^{-1} \nabla f(x_k)$.

Test d'arrêt On fait le test suivant :

$$\|\nabla f(x_{k+1})\| < \varepsilon, \quad \varepsilon : \text{donnée.}$$

Si f est quadratique, on a :

$$x_{k+1} = x_k - A^{-1}(Ax_k - b) = x_k - A^{-1}Ax_k + A^{-1}b = A^{-1}b.$$

Dans ce cas la méthode de Newton converge en une seule itération.

Exemple 3.7 *Considérons la fonction $f : \mathbb{R}^2 \rightarrow \mathbb{R}$ définie par :*

$$f(x, y) = x^2 + 2y^2, \quad x_0 = (2, 2).$$

On a :

$$\nabla f(x, y) = \begin{pmatrix} 2x \\ 4y \end{pmatrix}, \quad \nabla f(x_0) = \nabla f(2, 2) = \begin{pmatrix} 4 \\ 8 \end{pmatrix},$$

et

$$\nabla^2 f(x, y) = \begin{pmatrix} 2 & 0 \\ 0 & 4 \end{pmatrix}, \quad [\nabla^2 f(x_0)]^{-1} = \begin{pmatrix} \frac{1}{2} & 0 \\ 0 & \frac{1}{4} \end{pmatrix},$$

alors

$$\begin{aligned} x_1 &= x_0 - [\nabla^2 f(x_0)]^{-1} \nabla f(x_0) \\ &= \begin{pmatrix} 2 \\ 2 \end{pmatrix} - \begin{pmatrix} \frac{1}{2} & 0 \\ 0 & \frac{1}{4} \end{pmatrix} \begin{pmatrix} 4 \\ 8 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}. \end{aligned}$$

et

$$\nabla f(0, 0) = 0.$$

D'où $x^* = (0, 0)$, $f(x^*) = f(0, 0) = 0$.

Théorème 3.4 Si f est une forme quadratique définie positive, alors la méthode de Newton converge vers la solution optimale en une seule itération $\forall x_0 \in \mathbb{R}^n$.

Preuve. Soit $f(x) = \frac{1}{2}x^T Ax - b^T x$, A est une matrice symétrique définie positive sur \mathbb{R}^n .
On a :

$$\nabla f(x) = Ax - b \text{ et } \nabla^2 f(x) = A.$$

Alors

$$x_1 = x_0 - [\nabla^2 f(x_0)]^{-1} \nabla f(x_0)$$

$$\begin{aligned} x_0 - A^{-1}(Ax_0 - b) &= x_0 - A^{-1}Ax_0 + A^{-1}b \\ &= A^{-1}b. \end{aligned}$$

■

3.5 Exercices corrigés

Exercice 3.1 On considère la fonction $f : \mathbb{R}^2 \rightarrow \mathbb{R}$, définie par :

$$f(x, y) = 4x^2 - 4xy + 2y^2.$$

et le point initial,

$$x_0 = (x_0, y_0) = (2, 3).$$

En appliquant l'algorithme du gradient à pas optimal résoudre le problème suivant :

$$\begin{cases} \min f(x, y) \\ (x, y) \in \mathbb{R}^2 \end{cases}.$$

Solution : 1 : On a : $x_{k+1} = x_k - \alpha_k \nabla f(x_k)$, $\alpha_k = \arg \min_{\alpha > 0} (f(x_k) - \alpha \nabla f(x_k))$,
et

$$\nabla f(x, y) = \begin{pmatrix} \frac{\partial f}{\partial x}(x, y) \\ \frac{\partial f}{\partial y}(x, y) \end{pmatrix} = \begin{pmatrix} 8x - 4y \\ 4y - 4x \end{pmatrix},$$

$$\nabla f(x_0) = \nabla f(2, 3) = (4, 4), \quad d_0 = -\nabla f(x_0) = -(4, 4).$$

Pour $k = 0$, on a,

$$\begin{aligned} f((x_0) - \alpha \nabla f(x_0)) &= f((2, 3) - \alpha(4, 4)) = f(2 - 4\alpha, 3 - 4\alpha) \\ &= 4(2 - 4\alpha)^2 - 4(2 - 4\alpha)(3 - 4\alpha) + 2(3 - 4\alpha)^2, \end{aligned}$$

alors

$$f(2 - 4\alpha, 3 - 4\alpha)' = 0 \Rightarrow \alpha = \frac{1}{2} = \alpha_0,$$

donc

$$x_1 = x_0 + \alpha_0 d_0 = (2, 3) - \frac{1}{2}(4, 4) = (0, 1).$$

Maintenant en calculant le gradient de f au point x_1 , on trouve :

$$\nabla f(x_1) = \nabla f(0, 1) = (4, 4), \quad d_0 = -\nabla f(x_0) = -(-4, 4).$$

Pour $k = 1$, on a,

$$\begin{aligned} f((x_1) - \alpha \nabla f(x_1)) &= f((0, 1) + \alpha(4, -4)) = f(4\alpha, 1 - 4\alpha) \\ &= 4(4\alpha)^2 - 4(4\alpha)(1 - 4\alpha) + 2(1 - 4\alpha)^2, \end{aligned}$$

alors

$$f(4\alpha, 1 + 4\alpha)' = 0 \Rightarrow \alpha = \frac{1}{10} = \alpha_1,$$

donc

$$x_2 = x_1 + \alpha_1 d_1 = (0, 1) - \frac{1}{10}(4, -4) = \left(\frac{2}{5}, \frac{3}{5}\right).$$

De la même manière on trouve : $x_3 = (0, \frac{1}{5})$.

Exercice 3.2 Soit la forme quadratique $f : \mathbb{R}^n \rightarrow \mathbb{R}$ définie par :

$$f(x) = \frac{1}{2}x^T A x - b^T x, \quad \forall x \in \mathbb{R}^n, b \in \mathbb{R}^n,$$

A : Matrice symétrique et définie positive.

1 : Montrer que si les directions d_1, d_2, \dots, d_n sont A -conjuguées, alors ils sont linéairement indépendantes.

2 : Pour $n = 2$, on a : $f(x, y) = \frac{3}{2}x^2 + \frac{1}{2}y^2 - xy - 2x$.

2.1 : Calculer la matrice Hessienne (A) de $f(x, y)$.

2.2 : Montrer que A est définie positive.

2.3 : Construire d_0, d_1, d_2 A -conjugués.

3 : En appliquant l'algorithme du gradient à pas optimal (effectuer trois iterations) déterminer le minimum du problème suivant :

$$(I) \begin{cases} \min f(x, y) = x^2 + 2y^2 - 2xy + 2y + 2 \\ (x, y) \in \mathbb{R}^2 \end{cases}, \quad \text{avec } (x, y) = (0, 0).$$

Solution : 1 : Supposons que

$$\beta_1 d_1 + \beta_2 d_2 + \dots + \beta_n d_n = 0, \tag{3.1}$$

Multiplions l'égalité (1) par $d_j^T A$, $1 \leq j \leq n$, on trouve :

$$\sum_{i=1}^n \beta_j d_j^T A d_i = \beta_j d_j^T A d_j = 0.$$

Or

$$\beta_j d_j^T A d_j = 0 \Rightarrow \beta_j = 0, \quad j = 1, \dots, n,$$

car A est définie positive et par conséquent $d_j^T A d_j > 0$. Donc d_1, d_2, \dots, d_n sont linéairement indépendantes.

$$2.1 : H_f = A = \begin{pmatrix} 3 & -1 \\ -1 & 1 \end{pmatrix}.$$

$$2.2 : \Delta_1 = 3 > 0, \Delta_2 = 2 > 0 \Rightarrow A : D.P.$$

$$2.3 : \text{on pose } d_0 = (1, 0), d_1 = (d_{11}, d_{12}) = ?, d_2 = (d_{21}, d_{22}) = ?.$$

$$\text{On a : } d_1^T A d_0 = 0 \Rightarrow (d_{11}, d_{12}) \begin{pmatrix} 3 & -1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} 1 \\ 0 \end{pmatrix} = 3d_{11} - d_{12} = 0.$$

$$\Rightarrow \begin{cases} d_{11} = \frac{1}{3} \\ d_{12} = 1 \end{cases}, d_1 = \left(\frac{1}{3}, 1\right).$$

$$d_2^T A d_1 = (d_{21}, d_{22}) \begin{pmatrix} 3 & -1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} \frac{1}{3} \\ 1 \end{pmatrix} = d_{22} = 0 \Rightarrow \begin{cases} d_{21} = 2 \\ d_{22} = 0 \end{cases}, d_2 = (2, 0).$$

$$(3.1.a) : \nabla f(x_0) = (0, -2), \alpha_0 = \arg \min_{\alpha > 0} (f(x_0) - \alpha \nabla f(x_0)) = \frac{1}{4},$$

$$x_1 = x_0 - \alpha_0 \nabla f(x_0) = \begin{pmatrix} 0 \\ -\frac{1}{2} \end{pmatrix}.$$

$$(3.1.b) : \nabla f(x_1) = \begin{pmatrix} 0 \\ -\frac{3}{2} \end{pmatrix}, \alpha_1 = \arg \min_{\alpha > 0} (f(x_1) - \alpha \nabla f(x_1)) = \frac{1}{2},$$

$$x_2 = x_1 - \alpha_1 \nabla f(x_1) = \begin{pmatrix} -\frac{1}{2} \\ -\frac{1}{2} \end{pmatrix}.$$

$$(3.1.c) : \nabla f(x_2) = \begin{pmatrix} 0 \\ 1 \end{pmatrix}, \alpha_2 = \arg \min_{\alpha > 0} (f(x_2) - \alpha \nabla f(x_2)) = \frac{1}{4}.$$

$$x_3 = x_2 - \alpha_2 \nabla f(x_2) = \begin{pmatrix} -\frac{1}{2} \\ -\frac{3}{4} = 0.75 \end{pmatrix}.$$

Exercice 3.3 Soit $a \in \mathbb{R}$. On considère la fonction $f_a : \mathbb{R}^2 \rightarrow \mathbb{R}$ définie par :

$$f_a(x_1, x_2) = x_1^2 + x_2^2 + ax_1x_2 - 2x_1 - 2x_2.$$

1 : Étudier la convexité de la fonction f_a selon les valeurs de a .

2 : Déterminer en fonction des valeurs du paramètre a les points critiques de la fonction f_a et préciser leur nature.

4. On suppose que $a = 1$. En démarrant du point initial $x_0 = (0, 1)$ et en appliquant l'algorithme du gradient conjugué, trouver la solution optimale x^* du problème suivant :

$$(I) \begin{cases} \min f_a(x_1, x_2) \\ (x_1, x_2) \in \mathbb{R}^2 \end{cases}.$$

Solution : 1 : On a : $\nabla^2 f(x) = \begin{pmatrix} 2 & a \\ a & 2 \end{pmatrix} \Rightarrow \begin{cases} \Delta_1 = 2 \\ \Delta_2 = 4 - a^2 \end{cases}$

donc f est convexe si $a \in [-2, 2]$.

2 : Les points critiques : $\nabla f(x) = \begin{pmatrix} 2x + ay - 2 \\ 2y + ax - 2 \end{pmatrix} = 0 \Rightarrow \begin{cases} 2x + ay - 2 = 0 \\ 2y + ax - 2 = 0 \end{cases} \Rightarrow$

$$\begin{cases} x = y \\ x = \frac{a}{2+a} \end{cases},$$

la nature du points critiques : $\nabla^2 f(x) = \begin{pmatrix} 2 & a \\ a & 2 \end{pmatrix}$.

si $a \in]-2, 2[\Rightarrow \begin{cases} \Delta_1 > 0 \\ \Delta_2 > 0 \end{cases} \Rightarrow \nabla^2 f$ est D.P sur $\mathbb{R}^2 \Rightarrow (\frac{a}{2+a}, \frac{a}{2+a})$ est un minimum local

strict de f

et comme f est convexe alors le point $(\frac{a}{2+a}, \frac{a}{2+a})$ est un minimum globale de f sur \mathbb{R}^2 .

4 : Pour $a = 1$, on a : $f_1(x_1, x_2) = x_1^2 + x_2^2 + x_1x_2 - 2x_1 - 2x_2, x_0 = (0, 1)$,

$$\nabla f(x) = \begin{pmatrix} 2x + y - 2 \\ 2y + x - 2 \end{pmatrix}, \nabla f(x_0) = \begin{pmatrix} -1 \\ 0 \end{pmatrix} = d_0, \alpha_0 = \frac{d_0^T \nabla f(x_0)}{\|d_0\|_A^2} = \frac{1}{2},$$

$$4.1 : x_1 = x_0 - \alpha_0 d_0 = \begin{pmatrix} 0 \\ 1 \end{pmatrix} + \frac{1}{2} \begin{pmatrix} 1 \\ 0 \end{pmatrix} = (\frac{1}{2}, 1), \nabla f(x_1) = \begin{pmatrix} 0 \\ -\frac{1}{2} \end{pmatrix}.$$

$$4.2 : x_2 = x_1 - \alpha_1 d_1, \beta_0 = \frac{d_0^T \nabla f(x_1)}{\|d_0\|_A^2} = \frac{1}{4},$$

$$d_1 = \begin{pmatrix} 0 \\ -\frac{1}{2} \end{pmatrix} - \frac{1}{4} \begin{pmatrix} -1 \\ 0 \end{pmatrix} = \begin{pmatrix} \frac{1}{4} \\ -\frac{1}{2} \end{pmatrix}, \alpha_1 = \frac{d_1^T \nabla f(x_1)}{\|d_1\|_A^2} = \frac{2}{3}$$

$$\text{donc } x_2 = \begin{pmatrix} \frac{1}{2} \\ 1 \end{pmatrix} + \frac{2}{3} \begin{pmatrix} \frac{1}{4} \\ -\frac{1}{2} \end{pmatrix} = \begin{pmatrix} \frac{2}{3} \\ \frac{3}{3} \end{pmatrix} = x^*, \nabla f(x^*) = 0.$$

Exercice 3.4 Soit f une fonction définie de \mathbb{R}^2 dans \mathbb{R} par :

$$f(x_1, x_2) = x_1^2 + x_2^2 - 3x_1 - x_1x_2 + 3, x_0 = (0, 0).$$

1 : En appliquant les conditions d'optimalité déterminer les points critiques de f et préciser leur nature.

2 : Résoudre le problème $\min_{(x_1, x_2) \in \mathbb{R}^2} f(x_1, x_2)$, en appliquant :

2.1. L'algorithme du gradient à pas optimal (effectuer trois iterations)

2.2. La méthode de relaxation (effectuer trois iterations).

Solution : 1 : On a :

$$\nabla f(x) = \begin{pmatrix} 2x_1 - x_2 - 3 \\ 2x_2 - x_1 \end{pmatrix} = 0 \Rightarrow \begin{pmatrix} x_1 = 2 \\ x_2 = 1 \end{pmatrix} = x_0$$

donc $x_0 = \begin{pmatrix} 2 \\ 1 \end{pmatrix}$ le seul point critique.

1 ** : $\nabla^2 f(x) = \begin{pmatrix} 2 & -1 \\ -1 & 2 \end{pmatrix}$, puisque $\Delta_1 > 0, \Delta_2 > 0$, on a $\nabla^2 f$ est D.P.

$\begin{cases} \nabla f(x_0) = 0 \\ \nabla^2 f(x_0) \text{ D.P.} \end{cases} \Rightarrow \begin{pmatrix} x_1 = 2 \\ x_2 = 1 \end{pmatrix} = x_0$ est minimum local stricte.

(2.1.a) : On a : $\nabla f(x_0) = (-3, 0)$, $\alpha_0 = \arg \min_{\alpha > 0} (f(x_0) - \alpha \nabla f(x_0)) = \frac{1}{2}$,

$$x_1 = x_0 - \alpha_0 \nabla f(x_0) = \begin{pmatrix} \frac{3}{2} = 1.5 \\ 0 \end{pmatrix}.$$

(2.1.b) : $\nabla f(x_1) = \begin{pmatrix} 0 \\ -\frac{3}{2} \end{pmatrix}$, $\alpha_1 = \arg \min_{\alpha > 0} (f(x_1) - \alpha \nabla f(x_1)) = \frac{1}{2}$,

$$x_2 = x_1 - \alpha_1 \nabla f(x_1) = \begin{pmatrix} \frac{3}{2} = 1.5 \\ \frac{3}{4} = 0.75 \end{pmatrix}.$$

(2.1.c) : $\nabla f(x_2) = \begin{pmatrix} -\frac{3}{4} \\ 0 \end{pmatrix}$, $\alpha_2 = \arg \min_{\alpha > 0} (f(x_2) - \alpha \nabla f(x_2)) = \frac{1}{2}$.

$$x_3 = x_2 - \alpha_2 \nabla f(x_2) = \begin{pmatrix} \frac{15}{8} = 1.875 \\ \frac{3}{4} = 0.75 \end{pmatrix}.$$

$$(2.2.a) : \begin{cases} \begin{pmatrix} x_1^{(1)} \\ 0 \end{pmatrix} \leftarrow \arg \min_{\varphi \in \mathbb{R}} f(\varphi, 0), \varphi = \frac{3}{2} = x_1^{(1)}, \\ \begin{pmatrix} \frac{3}{2} \\ x_2^{(1)} \end{pmatrix} \leftarrow \arg \min_{\varphi \in \mathbb{R}} f\left(\frac{3}{2}, \varphi\right), \varphi = \frac{3}{4} = x_2^{(1)}, \end{cases} , \begin{pmatrix} x_1^{(1)} \\ x_2^{(1)} \end{pmatrix} = \left(\frac{3}{2}, \frac{3}{4}\right),$$

$$(2.2.b) : \begin{cases} \begin{pmatrix} x_1^{(2)} \\ \frac{3}{4} \end{pmatrix} \leftarrow \arg \min_{\varphi \in \mathbb{R}} f\left(\varphi, \frac{3}{4}\right), \varphi = \frac{15}{8} = x_1^{(2)}, \\ \begin{pmatrix} \frac{15}{8} \\ x_2^{(2)} \end{pmatrix} \leftarrow \arg \min_{\varphi \in \mathbb{R}} f\left(\frac{15}{8}, \varphi\right), \varphi = \frac{15}{16} = x_2^{(2)}, \end{cases} , \begin{pmatrix} x_1^{(2)} \\ x_2^{(2)} \end{pmatrix} = \left(\frac{15}{8}, \frac{15}{16}\right).$$

$$(2.2.c) : \begin{cases} \begin{pmatrix} x_1^{(3)} \\ \frac{15}{16} \end{pmatrix} \leftarrow \arg \min_{\varphi \in \mathbb{R}} f\left(\varphi, \frac{15}{16}\right), \varphi = \frac{63}{32} = x_1^{(3)}, \\ \begin{pmatrix} \frac{63}{32} \\ x_2^{(3)} \end{pmatrix} \leftarrow \arg \min_{\varphi \in \mathbb{R}} f\left(\frac{63}{32}, \varphi\right), \varphi = \frac{63}{64} = x_2^{(3)}, \end{cases} , \begin{pmatrix} x_1^{(3)} \\ x_2^{(3)} \end{pmatrix} = \left(\frac{63}{32}, \frac{63}{64}\right).$$

Exercice 3.5 On considère la fonction la fonction $f : \mathbb{R}^2 \rightarrow \mathbb{R}$, définie par :

$$f(x_1, x_2) = (x - 2)^4 + (x - 2)^2 y^2 + (x + 1)^2.$$

En appliquant la méthode de Newton résoudre le problème suivant :

$$(I) \begin{cases} \min f(x, y), \\ (x, y) \in \mathbb{R}^2, \\ x^0 = (x_0, y_0) = (1, 1), \end{cases}$$

Solution : 1 : On a :

$$\nabla f(x, y) = \begin{pmatrix} 4(x-2)^3 + 2(x-2)y^2 + 2(x+1) \\ 2(x-2)^2 y \end{pmatrix},$$

et

$$\nabla^2 f(x, y) = \begin{pmatrix} 12(x-2) + 2y^2 + 2 & 4(x-2)y \\ 4(x-2)y & 2(x-2)^2 \end{pmatrix}.$$

Alors pour $k = 1$, on a :

$$x_1 = x_0 - [\nabla^2 f(x_0)]^{-1} \nabla f(x_0) = \left(1, \frac{1}{2}\right) \text{ et } f(x_1) = 1,5.$$

Pour $k = 2$, on a :

$$x_2 = x_1 - [\nabla^2 f(x_1)]^{-1} \nabla f(x_1) = (1,39, -0,696) \text{ et } f(x_2) = 16.642,$$

pour $k = 3$, on a :

$$x_3 = x_2 - [\nabla^2 f(x_2)]^{-1} \nabla f(x_2) = (1,746, -0,949) \text{ et } f(x_3) = 15.642.$$