

Soit  $J: \mathbb{R}^n \rightarrow \mathbb{R}$  la fonction objective

Méthode du gradient On considère l'algorithme suivant

$$(I) \quad \left\{ \begin{array}{l} x_0 \in \mathbb{R}^n \text{ à l'étape initiale} \\ x_{k+1} = A(x_k), k \geq 0 \text{ les itérations} \end{array} \right.$$

On va minimiser la fonction objective  $J(x)$ , pour cela, on constue la suite  $(x_k)$  de telle sorte que  $J(x_k) \geq J(x_{k+1}) \forall k \geq 0$

et d'après le théorème des bornes, s'il existe une direction de descente  $d$  alors il existe  $\delta > 0$  tel que  $f(x + \delta d) < f(x)$

C.-à-d., on construit la suite  $(x_k)$  où  $x_{k+1} = x_k + s_k d_k$   
où  $d_k$  est une direction de descente et  $s_k$  est le pas de descente.

On choisit la direction la plus forte descente C.-à-d  $d_k = -\nabla J(x_k)$   
donc l'algorithme (I), sera :

$$\text{II} \quad \left\{ \begin{array}{l} x_0 \in \mathbb{R}^n \\ x_{k+1} = x_k - s_k \nabla J(x_k) \quad k \geq 0, s_k > 0 \end{array} \right.$$

C.-à-d., on peut récrire l'algorithme II sous la forme  
Initialisations  
 $\begin{cases} x_0 \in \mathbb{R}^n \text{ donnée} \\ s > 0 \text{ donné} \\ k = 0; \epsilon \text{ assez petit} \end{cases}$

$$\text{Iterations} \quad \left[ \begin{array}{l} x_{k+1} = x_k - s \nabla J(x_k) \\ \|x_{k+1} - x_k\| \leq \epsilon \text{ ou } \|\nabla J(x_k)\| \leq \epsilon \quad (\text{on vérifie la condition d'optimalité suffisante } \nabla J(x^*) = 0) \\ k = k+1 \end{array} \right]$$

Théorème Soit  $J \in C^1(\mathbb{R}^n)$  localement et strictement convexe  
s'il existe  $M > 0$  tel que

$$\|\nabla J(x) - \nabla J(y)\| \leq M \|x-y\| \Leftrightarrow \text{gradient lipschitzien}$$

Alors la méthode du gradient converge &  $\beta_k \in [\beta_1, \beta_2]$   
tel que  $0 < \beta_1 < \beta_2 < \frac{\epsilon}{M}$ .

Hypothèse: si  $f$  est elliptique alors elle est convexe  
et strictement convexe.

Exemple:  $f(x,y) = x^2 + y^2$ ,  $\lambda = 0,9; 0,5; 1,5$ ;  $x_0 = \begin{pmatrix} 1 \\ 2 \end{pmatrix}$ .

La méthode du gradient à pas variable:

On peut faire varier le pas à chaque itération

On obtient l'algorithme Smart

Initialisations

$$x_0 \in \mathbb{R}^n$$

$$\beta_0 > 0$$

$$\lambda = 0$$

$$\epsilon > 0 \text{ assez petit}$$

→ Iteration

$$x_{k+1} = x_k - \beta_k \nabla J(x_k)$$

$$\|\nabla J(x_k)\| \leq \epsilon$$

$$k \rightarrow k+1$$

```
cLc; clear all;
```

```
x = input(' le vecteur initial ');
```

```
r = input(' le pas ');
```

```
k = 0; epsilon = 1;
```

```
while epsilon > 10^-2
```

```
    k = k + 1;
```

```
    r = r - 0,1;
```

```
    x = x - r * grad(x);
```

```
    gd = grad(x);
```

```
    epsilon = norm(gd);
```

```
end
```

```
min = x
```

```
iter = k
```

```
- function f = grad(x)
```

```
f(1) = 2 * x(1)
```

```
f(2) = 2 * x(2)
```

```
end
```

Exemple:  $f(x) = 4x^2 + e^x$

$$\nabla f(x) = f'(x) = 8x + e^x$$

$$f \in C^1(\mathbb{R})$$

On considère  $x_0 = 1,5$

$$f = 0,02, \epsilon = 10^{-3}$$

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

$$x_1 = 1,5 - 0,02 \nabla f(1,5) = 1,17$$

$$x_2 = 1,17 - 0,02 \nabla f(1,17) = 0,91$$

⋮

$$x_{30} = -0,10 - 0,02 \nabla f(-0,10) = -0,00$$

$$|x_{30} - x_{29}| = 8,5 \times 10^{-4} < \epsilon.$$

examiner la méthode  
du gradient à pas constant  
et à pas variable pour

$$g: g: 0,5 \mapsto g = 1$$

les cas suivant

$$1) f(x,y) = \frac{1}{2}x^2 + \frac{1}{2}y^2$$

$$2) f(x,y) = (x-3)^4 + y^4$$

$$3) f(x) = \frac{1}{2} \langle Ax, x \rangle - \langle Bx \rangle + d$$

$$A = \begin{pmatrix} 1 & 1 & 0 \\ 1 & 4 & 2 \\ 0 & 0 & 2 \end{pmatrix}, B = (1, -1, 1)^T$$

$$d = -5.$$

$$4) f(x) = \frac{1}{2} \langle Ax, x \rangle + \langle Bx \rangle$$

$$A = \begin{pmatrix} 10 & -2 \\ -2 & 10 \end{pmatrix}$$

$$B = (3, 3)^T.$$

Méthode du gradient à pas optimal: Cette méthode impose un choix du pas qui rend la fonction objective minimale le long de la direction de descente choisie, c.-à-d., on cherche le pas  $\beta_k$

$$x_{k+1} = x_k + \beta_k d_k$$

qui réalise le minimum  $\Phi_k(\beta)$  de la fonction brisée:

$$\mathbb{R}^+ \rightarrow \mathbb{R}: \quad \Phi_k(\beta) = J(x_k + \beta d_k)$$

sous la condition de la continuité différentiable de  $J$

Exemple: On considère le problème de minimisation sans

Contrainte finie

$$\left\{ \begin{array}{l} \min \frac{1}{2}x^2 + \frac{7}{2}y^2 \\ (x,y) \in \mathbb{R}^2 \end{array} \right.$$

On suppose que  $X^k = (x_k, y_k)_{k \geq 0}$  alors, d'après l'algorithme du gradient  $X^{k+1} = X^k - \beta \nabla f(X^k)$ . On  $f(x,y) = \frac{1}{2}x^2 + \frac{7}{2}y^2$   
 $\nabla f(x,y) = (x, 7y)$  alors  $\nabla f(X^k) = \nabla f(x_k, y_k) = (x_k, 7y_k)$

$$X^{k+1} = X^k - \beta(x_k, 7y_k) = (x_k, y_k) - \beta(x_k, 7y_k)$$

$$\begin{aligned} \Leftrightarrow (x^{k+1}, y^{k+1}) &= (x_k - \beta x_k, y_k - \beta 7y_k) \\ &= (x_k(1-\beta), y_k(1-7\beta)) \end{aligned}$$

On calcule maintenant le pas optimal, on pose

$$\begin{aligned} \phi(\beta_p) &= f[x_k(1-\beta_p), y_k(1-7\beta_p)] \\ &= \frac{x_k^2}{2}(1-\beta_p)^2 + \frac{7}{2}y_k^2(1-7\beta_p)^2 \end{aligned}$$

$$\phi'(\beta_p) = x_k^2(1-\beta_p) + 7y_k^2(7-7\beta_p)$$

Le min de  $\phi$  est caractérisé par  $\phi'(\beta_p) = 0$

$$x_k^2 - x_k\beta_p + 7y_k^2 - 7y_k\beta_p = 0 \Leftrightarrow x_k^2(1-\beta_p) + 49y_k^2(7-7\beta_p) = 0$$

$$\Leftrightarrow \beta_p = \frac{x_k^2 + 7y_k^2}{x_k^2 + 49y_k^2}$$

le schéma de l'algorithme prend la forme :

$$(x_{k+1}, y_{k+1}) = (x_k, y_k) - \frac{x_k^2 + 7y_k^2}{x_k^2 + 7^3y_k^3} (x_k, 7y_k)$$

## Règle d'Armijo :

$\alpha_k$  vérifie la règle d'Armijo si on a :

$$f(x_k + \alpha_k d_k) \leq f(x_k) + \alpha_k \beta_1 \nabla^T f(x_k) d_k \quad 0 < \beta_1 < 1, \\ \beta_1 = 0,9 \text{ généralement}$$

### Remarques

1) Si on pose  $\phi(\alpha_k) = f(x_k + \alpha_k d_k)$  ( $\phi : \mathbb{R}^+ \rightarrow \mathbb{R}$ )

on a  $\phi(\alpha_k)$  développable au voisinage de "0" d'ordre 1 et on a :

$$\begin{aligned} \phi(\alpha_k) &= \phi(0) + \alpha_k \phi'(0) \quad \text{ou} \quad \left\{ \begin{array}{l} \phi(0) = f(x_k) \\ \phi'(0) = \langle d_k, \nabla f(x_k) \rangle \end{array} \right. \\ &= \phi(0) + \alpha_k \nabla^T f(x_k) d_k \end{aligned}$$

2) Si  $\alpha_k$  vérifie la règle d'Armijo, on a

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

## Algorithmus de la règle d'Armijo

① Initialisation

② Choisir  $\hat{\alpha} \in ]0, +\infty[$  ( $\hat{\alpha} = 1$  généralement)  
 $0 < \beta_1 < 1$  ( $\beta_1 = 0,9$  "

③ Calculer  $f(x_k + \hat{\alpha} d_k)$

$$f(x_k)$$

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

④ Etape principale

$$\text{Si } f(x_k + \hat{\alpha} d_k) \leq f(x_k) + \hat{\alpha} \beta_1 \nabla^T f(x_k) d_k$$

$\hat{\alpha} = 2 \hat{\alpha}$  on va ④ (généralement fois 2 pour chercher le plus grand  $\hat{\alpha}$ )

Sinon

FIN  $\hat{\alpha} = \frac{\hat{\alpha}}{2}$  (généralement, on cherche le plus petit  $\hat{\alpha}$  qui vérifie la règle "le premier")

Example

$$f : \mathbb{D}^2 \rightarrow \mathbb{R}$$

$$(x_0, y_0) \mapsto f(x_0, y_0) = x_0^2 + y_0^4.$$

On pose  $(x_1, y_1) = (1, 1)$  et  $f(1, 1) = 2$

$$\text{et } d_1 = -\nabla f(1, 1) = -\begin{pmatrix} 2x \\ 4y^3 \end{pmatrix} \Big|_{(1,1)} = -\begin{pmatrix} 2 \\ 4 \end{pmatrix}$$

On pose  $\hat{\alpha} = 1$ ,  $\beta_1 = 0,9$ .

$$x_k + \hat{\alpha} d_k = (x_k, y_k) + \hat{\alpha} d_k$$

$$\begin{aligned} x_1 + \hat{\alpha} d_1 &= (x_1, y_1) + \hat{\alpha} d_1 = (1, 1) + \hat{\alpha} (-2, -4) \\ &= (1 - 2\hat{\alpha}, 1 - 4\hat{\alpha}) \end{aligned}$$

$$\begin{aligned} f(x_1 + \alpha d_1) &= f(1 - 2\hat{\alpha}, 1 - 4\hat{\alpha}) = (1 - 2\hat{\alpha})^2 + (1 - 4\hat{\alpha})^4 \\ &= 256\hat{\alpha}^4 - 256\hat{\alpha}^3 + 100\hat{\alpha}^2 - 20\hat{\alpha} + 2 \end{aligned}$$

On pose  $\Phi(\alpha) = f(x_1 + \alpha d_1) = 256\hat{\alpha}^4 - 256\hat{\alpha}^3 + 100\hat{\alpha}^2 - 20\hat{\alpha} + 2$

On calcule  $f(x_k) + \hat{\alpha} \beta_1 \nabla f(x_k) d_k$

$$\begin{aligned} f(x_1) + \hat{\alpha} \beta_1 \nabla f(x_1, y_1) d_1 &= f(1, 1) - \alpha \beta_1 \| \nabla f(1, 1) \|^2 \\ &= f(1, 1) - \hat{\alpha} (0, 9) \times 20 = 2 - 18\hat{\alpha} \end{aligned}$$

On pose  $\Theta(\alpha) = 2 - 18\hat{\alpha}$ .

$\hat{\alpha}$  vérifie la règle d'Armijo si

$$\Phi(\hat{\alpha}) \leq \Theta(\hat{\alpha})$$

On pose

$$\hat{\alpha} = 1 \quad \Phi(1) = 82 \quad \Theta(1) = -16$$

On a  $\Phi(\hat{\alpha}) > \Theta(\hat{\alpha})$  n'est pas vérifié

On pose  $\frac{\hat{\alpha}}{2} = 0,5$   $\Phi(0,5) = 1$ ,  $\Theta(0,5) = -7$

$\Phi(0,5) > \Theta(0,5)$  n'est pas vérifié

$$\frac{\hat{\alpha}}{2} = 0,25$$

$$\phi(0,25) = 0,25 \quad \vartheta(0,25) = -25^\circ$$

n'importe

$$\frac{\hat{\alpha}}{2} = 0,125 \quad n'importe$$

$$\frac{\hat{\alpha}}{2} = 0,0625 \quad n'importe$$

$$\frac{\hat{\alpha}}{2} = 0,03125 \quad n'importe$$

$$\frac{\hat{\alpha}}{2} = 0,015625$$

$$\phi(0,015625) = 1,71095^\circ$$

$$\vartheta(0,015625) = 1,71875$$

$$\phi(\hat{\alpha}) < \vartheta(\hat{\alpha})$$

On mette et on prend  $\hat{\alpha} = 0,015625$

$$\text{donc } x_2 = x_1 - \alpha_1 \nabla f(x_1) = (1,1) - 0,015625 (2,4) =$$

et on pose  $x_3 = x_2 - \alpha_2 \nabla f(x_2)$ , et on examine  $\alpha_2$  par la règle d'Armijo

## Exercice

On considère les deux minimisations suivantes

$$\begin{cases} f(x) = \frac{1}{2} \langle Ax, x \rangle + B(x) \\ x \in \mathbb{R}^n \end{cases}$$

tel que  $A = \begin{pmatrix} 2 & 1 \\ 1 & 1 \end{pmatrix}$ ,  $B = 10 \begin{pmatrix} 1 \\ 1 \end{pmatrix}$ .

\* Calculer les deux premiers termes en utilisant la méthode du gradient par le pas d'Armijo.

On détermine d'abord

$$\text{la fonction } \Phi(\alpha) = f(x - \alpha \nabla f(x))$$

$$\begin{aligned} f(x,y) &= \frac{1}{2}x^2 + y^2 + xy + 10x + 10y \\ &= x^2 + \frac{1}{2}y^2 + xy + 10x + 10y \end{aligned}$$

$$\nabla f(x,y) = \begin{pmatrix} 2x + y + 10 \\ y + x + 10 \end{pmatrix}$$

$$\Phi(\alpha) = f\left((x,y) - \alpha \begin{pmatrix} 2x + y + 10 \\ y + x + 10 \end{pmatrix}\right)$$

$$\Phi(\alpha) = \frac{1}{2} \begin{pmatrix} x - 2\alpha x - \alpha y - 10\alpha \\ y - \alpha y - \alpha x - 10\alpha \end{pmatrix}^T \begin{pmatrix} x - 2\alpha x - \alpha y - 10\alpha \\ y - \alpha y - \alpha x - 10\alpha \end{pmatrix}$$

$$\Phi(\alpha) = \underbrace{\alpha^2}_{(1)} + \frac{1}{2} \underbrace{(2)}_{(2)} + \underbrace{\alpha}_{(1)} \underbrace{\alpha}_{(2)} + 10 \underbrace{\alpha}_{(1)} + 10 \underbrace{\alpha}_{(2)}$$

Pour simplifier la chose on prend

$$f(x,y) = 2x^2 + y^2 \Rightarrow \nabla f(x,y) = \begin{pmatrix} 2x \\ 2y \end{pmatrix}$$

$$\text{et } \Phi(\alpha) = f\left(\begin{pmatrix} (1-2\alpha)x \\ (1-2\alpha)y \end{pmatrix}\right) = (1-2\alpha)^2 (x^2 + y^2)$$

$$\Phi'(0) = -4(1-2\alpha)(x^2 + y^2)$$

$$\Phi'(0) = -4(x^2 + y^2)$$

$$\Phi'(0) = \alpha^2 + y^2$$

$$\text{si } \alpha_0 = 1, \quad x_0 = (1, 1); \quad f = 0,9.$$

$$\Phi(0) = \alpha f' + \frac{1}{2} \alpha^2$$

$$= 2 + 0,9 \times 8 = 9,2 \quad \Phi(0) = 1,18$$

$$\text{On pose } \alpha = \frac{0,9}{2} = 0,45$$

## Méthode du gradient conjugué :

Def Soit  $A \in M_n(\mathbb{R})$  symétrique et définie positive

On dit que deux vecteurs  $x, y \in \mathbb{R}^n$  sont  $-A$  conjugués

(ou conjugués par rapport à  $A$ ) si il vérifient  $x^T A x = 0$ . et que  $x^T A y = 0 \Leftrightarrow 2y_1 = 4y_2 + 2y_2 - 4$

Exemple

$$x = \begin{pmatrix} 1 \\ 2 \end{pmatrix}, A = \begin{pmatrix} 2 & 1 \\ 1 & 1 \end{pmatrix}, y = \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}$$
$$x^T A y = 0 \Leftrightarrow 2y_1 + 4y_2 = 0 \Leftrightarrow 2y_1 = 4y_2 + 2y_2 - 4$$

## Démarques

- \* Si  $A = 0$ , chaque deux vecteur sont  $-A$  conjugués.  $x^T A y = 0$
- \* Si  $A = I$ ,  $x^T A y = 0 \Leftrightarrow x^T y = 0$   $\forall x, y \in \mathbb{R}^n$   
 $\Rightarrow x$  et  $y$  sont orthogonaux

Proposition Soit  $A$  une matrice symétrique définie positive,

Si  $\{d_1, \dots, d_k\}$  des vecteurs  $-A$  conjugués, alors il sont linéairement indépendantes.

Preuve Supposons qu'il existe  $\alpha_i \in \mathbb{R}^*$ ,  $i = 1, \dots, k$  tels que

$$\alpha_1 d_1 + \alpha_2 d_2 + \dots + \alpha_k d_k = 0 \quad \dots \quad (*)$$

en multipliant  $\overbrace{\alpha_1 d_1 + \alpha_2 d_2 + \dots + \alpha_k d_k}^{(*)}$  par  $A$ , on obtient  $(*)$  (car  $(A+B)^T = A^T + B^T$ ) et  $0^T = 0$

$$\alpha_1 d_1^T A + \alpha_2 d_2^T A + \dots + \alpha_k d_k^T A = 0 \quad \dots \quad (**)$$

et en multipliant  $(**)$  par  $d_i^T$ ,  $i = 1, \dots, k$ , on obtient

$$\alpha_1 d_1^T A d_1 + \alpha_2 d_2^T A d_1 + \dots + \alpha_k d_k^T A d_1 = 0 \Leftrightarrow \alpha_1 d_1^T A d_1 = 0$$

-  $A$  conjuguées

$$\alpha_1 d_1^T A d_2 + \alpha_2 d_2^T A d_2 + \dots + \alpha_k d_k^T A d_2 = 0 \Leftrightarrow \alpha_2 d_2^T A d_2 = 0$$

$$\alpha_1 d_1^T A d_k + \alpha_2 d_2^T A d_k + \dots + \alpha_k d_k^T A d_k = 0 \Leftrightarrow \alpha_k d_k^T A d_k = 0$$

$$\Rightarrow \alpha_i d_i^T A d_i = 0, \forall i = 1, \dots, k \text{ mais } d_i^T A d_i > 0$$

$$\Rightarrow \alpha_i = 0 \quad \forall i = 1, \dots, k \Rightarrow \text{Contradiction}$$

Exemple On considère la matrice symétrique  $A = \begin{pmatrix} 3 & 0 & 1 \\ 0 & 4 & 2 \\ 1 & 2 & 3 \end{pmatrix}$

On va déterminer les vecteurs qui sont  $A$ -conjugués à partie

$$\text{du vecteur } d_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$$

2 - On va montrer que  $A$  est définie positive, on calcule les déterminants de ses matrice principales  $\Delta_1 = 3 > 0$ ,  $\Delta_2 = \begin{vmatrix} 3 & 0 \\ 0 & 1 \end{vmatrix} = 12 > 0$  et  $\Delta_3 = \begin{vmatrix} 3 & 0 & 1 \\ 0 & 4 & 2 \\ 1 & 2 & 3 \end{vmatrix} = 20 > 0$ .

$\Rightarrow A$  est définie positive et de plus elle est symétrique ( $A^T = A$ ).

On pose  $d_1 = \begin{pmatrix} d_1 \\ d_2 \\ d_3 \end{pmatrix}$  et  $d_3 = \begin{pmatrix} c_1 \\ c_2 \\ c_3 \end{pmatrix}$ , on a:

$$d_1^T A d_2 = 0 \Leftrightarrow (1 \ 0 \ 0) \begin{pmatrix} 3 & 0 & 1 \\ 0 & 4 & 2 \\ 1 & 2 & 3 \end{pmatrix} \begin{pmatrix} d_1 \\ d_2 \\ d_3 \end{pmatrix} = 0$$

$$\Leftrightarrow 3d_1 + d_3 = 0 \quad \dots \quad ①$$

Si on prend  $d_1 = 1$  et  $d_2 = 0$ , de ① on obtient  $d_3 = -3$

$$\Rightarrow d_2 = (1, 0, -3)^T$$

Pour  $d_3$ , on a  $d_1^T A d_3 = 0$  et  $d_2^T A d_3 = 0$ .

$$\begin{cases} d_1^T A d_3 = 0 \Leftrightarrow \begin{cases} 3c_1 + c_3 = 0 \\ -6c_2 - 8c_3 = 0 \end{cases} \\ d_2^T A d_3 = 0 \Leftrightarrow \begin{cases} c_3 = -3 \\ c_2 = 1 \end{cases} \end{cases} \quad \dots \quad ②$$

Si on prend par exemple  $c_3 = 1$  le système ② devient

$$\begin{cases} 3 + c_3 = 0 \\ -6c_2 - 8c_3 = 0 \end{cases} \Leftrightarrow \begin{cases} c_3 = -3 \\ c_2 = 1 \end{cases} \Rightarrow d_3^T = (1 \ 4 \ -3)$$

Remarque On n'a pas l''unicité' des vecteurs  $d_1, d_2, d_3$  qui sont  $A$ -conjugués.

La méthode suppose que  $f$  est quadratique strictement convexe  
 et - d  $f(x) = q(x) = \frac{1}{2} x^T A x + b^T x + c$ ,  $x \in \mathbb{R}^n$ ,  $A \in M_n(\mathbb{R})$   
 $b \in \mathbb{R}^n$ ,  $c \in \mathbb{R}$   
 cette méthode suit de la forme  $\left\{ \begin{array}{l} \text{non donné} \\ x_{k+1} = x_k + \alpha_k d_k, k \geq 1 \end{array} \right.$   
 Symétrique définie positive.

où  $d_k$  est optimal et  $d_1, \dots, d_k$  sont  $q$ -conjugués.

Calcul de  $\alpha_k$ ,  $d_k$  est optimal par rapport à  $d_k$ .

donc  $\alpha_k$  est le min de  $\phi(\delta)$  sur  $\phi(\delta) = q(x_k + \delta d_k)$ .  
 $\Rightarrow \phi'(\alpha_k) = 0$

$$\begin{aligned} \phi'(\alpha_k) &= d_k^T \triangleright q(x_k + \alpha_k d_k) = d_k^T \triangleright q(x_{k+1}) = 0 \\ &= d_k^T (A x_{k+1} + b) = 0 \end{aligned}$$

$$= d_k^T A x_{k+1} + d_k^T b = d_k^T A(x_k + \alpha_k d_k) + d_k^T \delta = 0$$

$$= d_k^T A x_k + \alpha_k d_k^T A d_k + d_k^T b = d_k^T (A x_k + b) + \alpha_k d_k^T A d_k$$

$$\Leftrightarrow \alpha_k = -\frac{d_k^T (A x_k + b)}{d_k^T A d_k} \quad \text{--- --- ①}$$

## Théorème (Zoutendijk)

considérons la suite d'itération  $(x_k)_{k \geq 0}$ , i.e.  $x_{k+1} = x_k + \alpha_k d_k$   $\forall k \geq 1$

où  $d_k$  sont des directions de descentes et  $\alpha_k$  est le pas optimal (de Wolfe), si  $f$  est continûment différentiable et  $\nabla f$  est lipschitzien alors on a :  $\sum_{k \geq 0} \frac{(\nabla f(x_k) \cdot d_k)^2}{\|d_k\|^2} < +\infty$ .

## Construire les directions A-conjuguées :

des directions A-conjuguées  $d_0, \dots, d_k$  peuvent être générées à l'aide d'un ensemble de vecteurs linéairement indépendants  $h_0, \dots, h_k$  en utilisant la procédure de Gram-Schmidt où  $\left\langle \left\{ d_i \right\}_{i=0,1} \right\rangle = \left\langle \left\{ h_i \right\}_{i=0,1} \right\rangle$ .  
les  $d_i$  sont construites comme suit :

$$\forall i \geq 0 \quad d_{i+1} = h_{i+1} + \sum_{m=0}^i \epsilon(m+1) d_m \quad \dots \quad (1) \text{ et } d_0 = h_0$$

où  $\epsilon(m+1)$  sont choisis de manière à assurer la A-conjugaison des  $d_0, \dots, d_{i+1}$ .

## Méthode du gradient conjugué dans le cas quadratique

supposons que la fonction objective est quadratique à -à - d

$$f(x) = q(x) = \frac{1}{2} \langle Ax, x \rangle + \langle b, x \rangle$$

En appliquant la procédure de G-S aux gradient  $\vec{g}_0 = \nabla q(x_0)$

$\vec{g}_1 = -\nabla q(x_1), \dots, \vec{g}_n = -\nabla q(x_n)$ , et d'autre part on a :

$$\nabla q(x) = Ax + b \Rightarrow \nabla^2 q(x) = A$$

La méthode se termine si  $\nabla q(x_K) = 0$ .

Construire les directions  $d_0, \dots, d_k$ :

On écrit ① sous la forme:

$$d_{k+1} = d_{k+1} + \beta_{k+1} d_k \quad k \geq 0 \quad \text{et } d_0 = -\nabla q(x_0)$$

car la direction  $d_k$  est obtenue comme combinaison linéaire du gradient et de direction précédente  $d_{k-1}$ .

$$l - a - d \quad d_{k+1} = -\nabla q(x_{k+1}) + \beta_{k+1} d_k \quad k \geq 0.$$

et les coefficients  $\beta_{k+1}$  étant choisis pour que soit conjuguée avec les directions précédentes  $d_k$  l - a - d  $d_{k+1}^T A d_k = 0$ .

$$\Rightarrow (-\nabla q(x_{k+1}) + \beta_{k+1} d_k)^T A d_k = 0$$

$$\Rightarrow -\nabla^T q(x_{k+1}) A d_k + \beta_{k+1} d_k^T A d_k = 0$$

$$\Rightarrow \beta_{k+1} = \frac{\nabla^T q(x_{k+1}) A d_k}{d_k^T A d_k}.$$

$$\text{et de ①} \quad \alpha_k = \frac{-d_k^T (Ax_k + b)}{d_k^T A d_k} = \frac{-d_k^T \nabla q(x_k)}{d_k^T A d_k}.$$

L'algorithme:

Initialisation

$$x_0; \nabla q(x_0) = Ax_0 + b; k=0; \epsilon \text{ assez petit. } d_0 = -\nabla q(x_0)$$

Iterations  $x_k = \frac{-d_k^T \nabla q(x_k)}{d_k^T A d_k};$

$$x_{k+1} = x_k + \alpha_k d_k$$

$$\beta_{k+1} = \frac{\nabla^T q(x_{k+1}) A d_k}{d_k^T A d_k}; \quad d_{k+1} = -\nabla q(x_{k+1}) + \beta_{k+1} d_k$$

$$k=k+1$$

critère d'arrêt  $\|\nabla q(x_k)\| < \epsilon$

T l'astème Dans le cas où la fonction objective est quadratique

On a  $\beta_{k+1}^{HS} = \beta_{k+1}^{PRP} = \beta_{k+1}^{FQ} = \beta_{k+1}^{CD} = \beta_{k+1}^{DY}$ .

et dans le cas non quadratique, les quantités généralement différentes.

Méthode du gradient conjugué dans le cas général (non quadratique)

Soit  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  une fonction objective non nécessairement quadratique.

La méthode du gradient conjugué dans ce cas définie par

$$x_{k+1} = x_k + \alpha_k d_k.$$

où  $\alpha_k \in \mathbb{R}$  étant déterminé par une recherche linéaire.

et les directions  $d_k$  sont définies par la relation les trois

$$d_k = \begin{cases} -\nabla q(x_0) \\ -\nabla q(x_k) + \beta_k d_{k-1} & k \geq 1 \end{cases}$$

où  $\beta_k$  prend l'une des valeurs  $\beta_k^{PRP}$ ,  $\beta_k^{FQ}$ ,  $\beta_k^{CD}$ .

Exemple 1

On considère  $f(x) = q(x) = \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle$  où

$$A = \begin{pmatrix} 5 & 1 \\ 1 & 2 \end{pmatrix} \text{ et } b = \begin{pmatrix} 2 \\ 1 \end{pmatrix}$$

Il est donné que  $f$  est continue différentiable et  $A$  symétrique et définie positive alors d'après la méthode du gradient conjugué. On pose:

$$x_0 = \begin{pmatrix} 1 \\ 2 \end{pmatrix} \Rightarrow d_0 = -\nabla q(x_0) = -Ax_0 + b = \begin{pmatrix} -5 \\ -3 \end{pmatrix} \leftarrow d_0$$

$$\alpha_0 = -\frac{d_0^T \nabla q(x_0)}{d_0^T A d_0} = -\frac{(-5)(-3)}{(-5)(-3)(5)(-3)} = \frac{34}{173}.$$

alors  $x_{k+1} = x_k + \alpha_k d_0$ .

$$x_0 = \frac{x_0 + x_0 - d_0}{2} \Rightarrow q(x_0) = \begin{pmatrix} 1 \\ 2 \end{pmatrix} + \frac{34}{173} \begin{pmatrix} -5 \\ -3 \end{pmatrix} = \begin{pmatrix} 0,017 \\ 0,017 \end{pmatrix}.$$

$$\beta_1 = \frac{\nabla^T q(x_0) A d_0}{d_0^T A d_0} = \frac{(A x_0 - b)^T A d_0}{d_0^T A d_0} = \frac{\left[ \begin{pmatrix} 5 & 1 \\ 1 & 2 \end{pmatrix} \begin{pmatrix} 0,017 \\ 0,017 \end{pmatrix} - \begin{pmatrix} 1 & 4 \\ 2 & 1 \end{pmatrix} \begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix} \begin{pmatrix} -5 \\ -3 \end{pmatrix} \right]}{(-5)(-3)(1)(-3)} \\ = \frac{(-0,004 \quad 0,839) \begin{pmatrix} -28 \\ -11 \end{pmatrix}}{(-28 \quad -11)(-3)} = \frac{4,883}{173} = 0,028$$

$$d_1 = -\nabla q(x_1) + \frac{0,028}{\beta_1} \begin{pmatrix} -5 \\ -3 \end{pmatrix} = \begin{pmatrix} -0,504 \\ 0,839 \end{pmatrix} + 0,028 \begin{pmatrix} -5 \\ -3 \end{pmatrix} \\ = \begin{pmatrix} -0,644 \\ 0,755 \end{pmatrix}$$

$$\alpha_1 = -\frac{d_1^T \nabla q(x_1)}{d_1^T A d_1}$$

$$x_1 = x_0 + \alpha_1 d_1$$

$$\beta_2 = \frac{\nabla q(x_2) A d_1}{d_1^T A d_1}$$

$$d_2 = -\nabla q(x_1) + \beta_2 d_1$$

$$\text{et jusqu'à } \nabla q(x_k) = 0$$

Exercice On considère le pb de minimisation somat

$$\begin{cases} \min \left\{ \frac{3}{2}x^2 + 2y^2 + \frac{3}{2}z^2 + xy + xyz - 3x - 3 \right\} \\ (x, y, z) \in \mathbb{R}^3 \end{cases}$$

à partir du vecteur initial  $x_0 = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}$  calculer les deux premières itérations

en utilisant la méthode du gradient conjugué.

Solution On peut écrire le pb sous forme matriciel somat

$$\begin{cases} \min \frac{1}{2} x^T A x - b x \\ x \in \mathbb{R}^3 \end{cases} \quad x_0 = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} \text{ et } A = \begin{pmatrix} 3 & 0 & 1 \\ 0 & 4 & 2 \\ 1 & 2 & 3 \end{pmatrix}, b = \begin{pmatrix} 3 \\ 0 \\ 1 \end{pmatrix}$$

$$\nabla f(x_0) = Ax_0 - b = \begin{pmatrix} 3 & 0 & 1 \\ 0 & 4 & 2 \\ 1 & 2 & 3 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} - \begin{pmatrix} 3 \\ 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 3x_1 + x_3 - 3 \\ 4x_2 + 2x_3 \\ x_1 + 2x_2 + 3x_3 - 1 \end{pmatrix}$$

$$\nabla^T f(x_0) = Ax_0 - b = \begin{pmatrix} -3 \\ 0 \\ -1 \end{pmatrix}$$

$$d_0 = -\nabla f(x_0) = \begin{pmatrix} 3 \\ 0 \\ 1 \end{pmatrix}$$

$$d_0 = -\frac{\nabla f(x_0) d_0}{d_0^T A d_0} = \frac{10}{36} = 0,2778 = -\frac{\begin{pmatrix} -3 \\ 0 \\ -1 \end{pmatrix}^T \begin{pmatrix} 3 \\ 0 \\ 1 \end{pmatrix}}{\begin{pmatrix} 3 \\ 0 \\ 1 \end{pmatrix}^T A \begin{pmatrix} 3 \\ 0 \\ 1 \end{pmatrix}}$$

$$x_1 = x_0 + d_0 d_0 = \begin{pmatrix} 0 \\ 0,8333 \\ 0,2778 \end{pmatrix}$$

$$\nabla f(x_1) = Ax_1 - b = (-0,222 \quad 0,556 \quad 0,668)^T$$

$$\beta_0 = \frac{\nabla f(x_1) A d_0}{d_0^T A d_0} = \frac{2,892}{36} = 0,08025.$$

$$d_1 = -\nabla f(x_1) + \beta_0 d_0 = \begin{pmatrix} 0,46275 \\ -0,5556 \\ -0,58655 \end{pmatrix}$$

$$x_2 = x^* = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}.$$

### Méthode de Newton

Le principe de la méthode de Newton consiste à minimiser successivement les approximations du second ordre de  $f$ ; plus précisément si  $f$  est deux fois différentiable au sens de Bolzaux, elle admet un développement de Taylor à l'ordre "2" au voisinage de  $x_k$ , et on a :

$$f(x) = f(x_k) + \langle \nabla f(x_k), x - x_k \rangle + \frac{1}{2} \langle \nabla^2 f(x_k)(x - x_k), (x - x_k) \rangle + o(\|x - x_k\|^2)$$

$$\text{Posons: } q(x) = f(x_k) + \nabla^T f(x_k)(x - x_k) + \frac{1}{2} (x - x_k)^T \nabla^2 f(x_k) (x - x_k).$$

Et une forme quadratique de la forme  $\frac{1}{2} A(x, x) + b(x) + c$  tel que

$$A = \nabla^2 f(x_k), \quad b = \nabla^T f(x_k) \quad \text{et} \quad c = f(x_k) \quad [\text{Quand } x - x_k \rightarrow x]$$

$$\text{donc } \nabla q(x) = Ax + b = \nabla^2 f(x_k)(x - x_k) + \nabla^T f(x_k)$$

Soit  $x_{k+1}$  l'optimum de  $q$ , alors il vérifie  $\nabla q(x_{k+1}) = 0$ . C-à-d

$$\nabla^2 f(x_k) (x_{k+1} - x_k) + \nabla f(x_k) = 0$$

Donc  $\nabla^2 f(x_k) (x_{k+1} - x_k) = -\nabla f(x_k)$

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

L'algorithme de la méthode :

Initialisation:  $\varepsilon > 0$  (assez petit),  $x_0$  (le point de départ),  $k=1$

Iteration

$$3^\circ \quad \| \nabla f(x_0) \| < \varepsilon \quad \text{stop}$$

Sinon

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

$$k = k+1.$$

Exemple:  $f(x,y) = \frac{1}{2} x^2 + x \cos y$  et  $x_0 = \begin{pmatrix} x_0 \\ y_0 \end{pmatrix} = \begin{pmatrix} 0 \\ \pi/2 \end{pmatrix}$

$$\nabla f(y) = \begin{pmatrix} x + \cos y \\ -x \sin y \end{pmatrix} \Rightarrow \nabla f\left(\begin{pmatrix} 0 \\ \pi/2 \end{pmatrix}\right) = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

$$\nabla^2 f(x,y) = \begin{pmatrix} 1 & -\sin y \\ -\sin y & -x \cos y \end{pmatrix} \Rightarrow \nabla^2 f(0, \pi/2) = \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix}$$

$$x_1 = \begin{pmatrix} x_1 \\ y_1 \end{pmatrix} = x_0 - [\nabla^2 f(x_k)]^{-1} \nabla f(x_k)$$

### Demandes

- 1) Cette méthode fonctionne très bien pour les pb de petite dimension ( $n \leq 10$ ) lorsque on peut calculer facilement la matrice hessienne et son inverse, et on a des problèmes pour les grandes tailles.
- 2) L'inverse d'une matrice n'est pas toujours existe, alors  $\alpha_{k+1}$  n'est pas toujours défini.
- 3) Si l'inverse de la matrice hessienne existe, la direction  $d_k = -[\nabla^2 f(\alpha_k)]^{-1} \nabla f(\alpha_k)$  n'est pas toujours une direction de descente.