

# Méthodes d'optimisation de gradient

## 1. Le principe des méthodes à direction de descente

Soit le problème d'optimisation P sans contraintes suivant :

$$\min_{X \in \mathbb{R}^n} f(X)$$

Avec  $f(X)$  est une fonction continument différentiable de  $n$  variables. On doit chercher le point  $X^*$  qui réalise le minimum de  $f(X)$ , c.à.d.  $X^*$  sera la solution de notre problème P.

Prenons l'exemple du bonhomme qui voulait partir d'un point  $X_0$  vers une destination. Il devait faire deux choses essentielles :

- a. Prendre **une direction  $d_k$**  à l'étape  $k$ .
- b. Déterminer le meilleur point d'arrêt dans cette direction c.à.d. il doit choisir aussi **le pas  $a_k$**  avec lequel il va avancer vers  $X_{k+1}$  dans la direction  $d_k$ .

Ces deux opérations  $a.$  et  $b.$  vont se répéter en générant une suite des point  $\{X_k\}_{k \geq 1}$  approchant une solution  $X^*$  par la récurrence.

$$X_{k+1} = X_k + a_k \cdot d_k$$

Le choix de  $a_k$  et  $d_k$  dépend des données du problème. En optimisation, on cherche généralement à minimiser  $f(X)$ . On doit donc faire décroître  $f(X)$ .

$a_k$  et  $d_k$  sont alors choisis tel que :

$$f(X_{k+1}) \leq f(X_k)$$

$f(X_{k+1})$  va prendre des valeurs descendante vers le minimum, donc  $d_k$  doit être **une direction de descente** pour minimiser  $f(X)$ , d'où l'idée d'utiliser des méthodes à direction de descente connues pour minimiser des fonctions. Parmi ces méthodes, nous avons la méthode du Newton que nous avons vu en TP et la méthode du gradient que nous allons voir dans ce cours.

## 2. La méthode du gradient

Soit le problème d'optimisation P sans contraintes suivant :

$$P : \min_{X \in \mathbb{R}^n} f(X)$$

A partir de  $X_k$  ( $k \geq 1$ ), on voudrait trouver un voisinage de  $X_k$  :

$$X_{k+1} = X_k + a_k \cdot d_k \text{ tel que } f(X_{k+1}) \leq f(X_k)$$

### Etape a : Le choix de la direction $d_k$

La méthode du gradient est une méthode à direction de descente où :

$$d_k = -\nabla f(X_k)$$

### Etape b : Le choix du pas $a_k$

Dans cette étape, on distingue 3 méthodes :

1. **Choisir un  $a$  fixe** c.à.d :  $a_1 = a_2 = a_3 = \dots = a_k = a_{k+1}$ .
2. **Choisir un  $a_k$  variable**, c.à.d. on doit choisir une valeur pour  $a_k$  différente d'une itération à une autre ( $a_k$  est donné par une expression en fonction de  $k$ ).
3. **Optimiser  $a_k$  à chaque itération  $k$**  : Dans la méthode de descente, on calcul  $X_{k+1}$  tel que  $f(X_{k+1}) \leq f(X_k)$  et cela en agissant sur  $a_k$ , c.à.d. on doit trouver le meilleur pas  $a_k$  tel que  $f(X_{k+1})$  est le plus petit.

Pour cela, on pose :

$$f_k(a_k) = f(X_k)$$

$$f_k(a_k) = f(X_{k-1} - a_k \cdot \nabla f(X_{k-1}))$$

Pour trouver  $a$  tel que  $f_k(a)$  soit minimum, il suffit de résoudre le problème suivant :

$$f'_k(a_k) = 0$$

→

$$f'(X_{k-1} - a_k \cdot \nabla f(X_{k-1})) = 0$$

Donc, nous avons passé d'un problème d'optimisation dans  $R^n$  à un problème dans  $R$  dont on cherche à trouver  $a_k$ , solution de l'équation ci-dessus.

$$a_k = \text{Argmin } f_k(a_k)$$

Cette expression donne la valeur du pas  $a_k$  à l'itération  $k$  pour laquelle  $f$  atteint son minimum.

### 3. Algorithmes de méthode du gradient

#### a. Méthode du gradient à pas fixe

Méthode a.1	Méthode a.2
<ul style="list-style-type: none"> <li>• <math>k = 0</math></li> <li>• Choisir un point initial <math>X_0</math></li> <li>• Choisir un pas fixe <math>a</math></li> <li>• Tant que <math>\ \nabla f(X_k)\  &gt; \varepsilon</math> <ul style="list-style-type: none"> <li>○ <math>k = k + 1</math></li> <li>○ <math>X_k = X_{k-1} - a \cdot \nabla f(X_{k-1})</math></li> </ul> </li> <li>• Fin tant que</li> </ul>	<ul style="list-style-type: none"> <li>• Choisir un point initial <math>X_0</math></li> <li>• <math>k = 1</math></li> <li>• Choisir un pas fixe <math>a</math></li> <li>• <math>X_k = X_{k-1} - a \cdot \nabla f(X_{k-1})</math></li> <li>• Tant que <math>\ X_k - X_{k-1}\  &gt; \varepsilon</math> <ul style="list-style-type: none"> <li>○ <math>k = k + 1</math></li> <li>○ <math>X_k = X_{k-1} - a \cdot \nabla f(X_{k-1})</math></li> </ul> </li> <li>• Fin tant que</li> </ul>

**Remarque :**  $\|\nabla f(X_k)\| > \varepsilon$  est une condition d'arrêt (la même chose pour  $\|X_k - X_{k-1}\| < \varepsilon$ )

- Si  $\|\nabla f(X_k)\| < \varepsilon \rightarrow \text{STOP}$ ,  $X^* = X_k$
- Sinon : On passe à l'itération suivante :
  - $k = k + 1$
  - $X_k = X_{k-1} - a \cdot \nabla f(X_{k-1})$

La différence entre la méthode a.1 et la méthode a.2 réside seulement dans la condition d'arrêt (la même chose pour les méthodes b et c).

#### b. Méthode du gradient à pas variable

Méthode b.1	Méthode b.2
<ul style="list-style-type: none"> <li>• <math>k = 0</math></li> <li>• Choisir un point initial <math>X_0</math></li> <li>• Tant que <math>\ \nabla f(X_k)\  &gt; \varepsilon</math> <ul style="list-style-type: none"> <li>○ <math>k = k + 1</math></li> <li>○ <math>a_k = \frac{1}{3k}</math> (par exemple)</li> <li>○ <math>X_k = X_{k-1} - a_k \cdot \nabla f(X_{k-1})</math></li> </ul> </li> <li>• Fin tant que</li> </ul>	<ul style="list-style-type: none"> <li>• Choisir un point initial <math>X_0</math></li> <li>• <math>k = 1</math></li> <li>• <math>a_k = \frac{1}{k}</math> (un autre exemple)</li> <li>• <math>X_k = X_{k-1} - a_k \cdot \nabla f(X_{k-1})</math></li> <li>• Tant que <math>\ X_k - X_{k-1}\  &gt; \varepsilon</math> <ul style="list-style-type: none"> <li>○ <math>k = k + 1</math></li> <li>○ <math>a_k = \frac{1}{3k}</math> (par exemple)</li> <li>○ <math>X_k = X_{k-1} - a_k \cdot \nabla f(X_{k-1})</math></li> </ul> </li> <li>• Fin tant que</li> </ul>

### c. Méthode du gradient à pas optimal

Méthode c.1	Méthode c.2
<ul style="list-style-type: none"> <li>• <math>k = 0</math></li> <li>• Choisir un point initial <math>X_0</math></li>   <li>• <b>Tant que <math>\ \nabla f(X_k)\  &gt; \varepsilon</math></b> <ul style="list-style-type: none"> <li>○ <math>k = k + 1</math></li> <li>○ <math>\mathbf{a}_k = \underset{a_k &gt; 0}{\operatorname{argmin}} f(X_{k-1} - \mathbf{a}_k \cdot \nabla f(X_{k-1}))</math></li> <li>○ <math>X_k = X_{k-1} - a_k \cdot \nabla f(X_{k-1})</math></li> </ul> </li> <li>• Fin tant que</li> </ul>	<ul style="list-style-type: none"> <li>• Choisir un point initial <math>X_0</math></li> <li>• <math>k = 1</math></li> <li>• <math>\mathbf{a}_k = \operatorname{argmin} f(X_{k-1} - \mathbf{a}_k \cdot \nabla f(X_{k-1}))</math></li> <li>• <math>X_{k+1} = X_k - a_k \cdot \nabla f(X_k)</math></li> <li>• <b>Tant que <math>\ X_k - X_{k-1}\  &gt; \varepsilon</math></b> <ul style="list-style-type: none"> <li>○ <math>k = k + 1</math></li> <li>○ <math>\mathbf{a}_k = \underset{a_k &gt; 0}{\operatorname{argmin}} f(X_{k-1} - \mathbf{a}_k \cdot \nabla f(X_{k-1}))</math></li> <li>○ <math>X_k = X_{k-1} - a_k \cdot \nabla f(X_{k-1})</math></li> </ul> </li> <li>• Fin tant que</li> </ul>

**Exercice 1 :** Soit le problème d'optimisation suivant :

$$\min f(x, y) = x^2 + \frac{1}{2}y^2 - 3(x + y)$$

Avec :  $X_0 = \begin{pmatrix} -2 \\ -7 \end{pmatrix}$  et  $\varepsilon = 0.1$

Utiliser la méthode **du gradient à pas optimal** pour résoudre le problème.

On calcule d'abord :

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

Il est clair que la solution de ce problème analytiquement est :  $X^* = \begin{pmatrix} 3 \\ 3 \end{pmatrix}$

$k = 0$

$$\nabla f(X_0) = \begin{pmatrix} -7 \\ -10 \end{pmatrix} \rightarrow \|\nabla f(X_0)\| = 12.2$$

Est-ce que  $\|\nabla f(X_0)\| > \varepsilon$  ? **Oui  $\rightarrow$  on fait une première itération**

**1<sup>ère</sup> itération**

$k = k + 1 = 1$

$$a_k = \operatorname{argmin} f(X_{k-1} - a_k \cdot \nabla f(X_{k-1})) \rightarrow$$

$$a_1 = \operatorname{argmin} f[X_0 - a_1 \cdot \nabla f(X_0)]$$

Donc, on doit résoudre le problème d'optimisation suivant :

$$\min f(a_1) = \min_{a_1 > 0} f[X_0 - a_1 \cdot \nabla f(X_0)] \rightarrow$$

$$\min f(a_1) = \min_{a_1 > 0} f \left[ \begin{pmatrix} -2 \\ -7 \end{pmatrix} - a_1 \cdot \begin{pmatrix} -7 \\ -10 \end{pmatrix} \right] = \min_{a_1 > 0} f \begin{pmatrix} -2 + 7a_1 \\ -7 + 10a_1 \end{pmatrix}$$

$$f \begin{pmatrix} -2 + 7a_1 \\ -7 + 10a_1 \end{pmatrix} = (-2 + 7a_1)^2 + \frac{1}{2}(-7 + 10a_1)^2 - 3(-2 + 7a_1 - 7 + 10a_1)$$

$$f \begin{pmatrix} -2 + 7a_1 \\ -7 + 10a_1 \end{pmatrix} = 99a_1^2 - 149a_1 + \frac{111}{2}$$

$$\min_{a_1 > 0} f(a_1) = 99a_1^2 - 149a_1 + \frac{111}{2}$$

Pour trouver résoudre ce problème, il faut résoudre l'équation suivante :

$$f'(a_1) = 0 \rightarrow$$

$$f'(a_1) = 198a_1 - 149 = 0 \rightarrow$$

$$\rightarrow a_1 = 0.7525$$

$$\rightarrow X_1 = X_0 - a_1 \cdot \nabla f(X_0) = \begin{pmatrix} -2 \\ -7 \end{pmatrix} - 0.7526 \cdot \begin{pmatrix} -7 \\ -10 \end{pmatrix} \rightarrow X_1 = \begin{pmatrix} 3.2677 \\ 0.5253 \end{pmatrix}$$

$$\nabla f(X_1) = \begin{pmatrix} 3.5354 \\ -2.4747 \end{pmatrix}$$

$$\rightarrow \|\nabla f(X_1)\| = 4.3154$$

Est-ce que  $\|\nabla f(X_1)\| > \varepsilon$  ? **Oui  $\rightarrow$  on passe à la deuxième itération**

**2<sup>ème</sup> itération**

$$k = k + 1 = 2$$

$$a_k = \operatorname{argmin} f(X_{k-1} - \mathbf{a}_k \cdot \nabla f(X_{k-1})) \rightarrow$$

$$a_2 = \operatorname{argmin} f[X_1 - \mathbf{a}_2 \cdot \nabla f(X_1)]$$

Donc, on doit résoudre le problème d'optimisation suivant :

$$\min f(a_2) = \min_{a_2 > 0} f[X_1 - \mathbf{a}_2 \cdot \nabla f(X_1)] \rightarrow$$

$$\min f(a_1) = \min_{a_2 > 0} f \left[ \begin{pmatrix} 3.267 \\ 0.525 \end{pmatrix} - \mathbf{a}_2 \cdot \begin{pmatrix} 3.535 \\ -2.473 \end{pmatrix} \right] = \min_{a_2 > 0} f \begin{pmatrix} 3.267 - 3.535 \cdot a_2 \\ 0.525 - 2.473 \cdot a_2 \end{pmatrix}$$

$$f \begin{pmatrix} 3.26 - 3.535 \cdot a_2 \\ 0.525 - 2.473 \cdot a_2 \end{pmatrix}$$

$$= (3.267 - 3.535 \cdot a_2)^2 + \frac{1}{2}(0.525 - 2.473 \cdot a_2)^2 - 3(3.267 - 3.535 \cdot a_2 + 0.525 - 2.473 \cdot a_2)$$

$$f \begin{pmatrix} 3.26 - 3.535 \cdot a_2 \\ 0.525 - 2.473 \cdot a_2 \end{pmatrix} = (\dots) \cdot a_2^2 + (\dots) \cdot a_2 + (\dots)$$

$$\min_{a_2 > 0} f(a_2) = (\dots) \cdot a_2^2 + (\dots) \cdot a_2 + (\dots)$$

$$\rightarrow a_2 = 0.5984$$

$$\rightarrow X_2 = X_1 - a_2 \cdot \nabla f(X_1) = \begin{pmatrix} 3.2677 \\ 0.5253 \end{pmatrix} - 0.5984 \cdot \begin{pmatrix} 3.5354 \\ -2.4747 \end{pmatrix} \rightarrow X_2 = \begin{pmatrix} 1.1521 \\ 2.0061 \end{pmatrix}$$

$$\nabla f(X_2) = \begin{pmatrix} -0.6956 \\ -0.9939 \end{pmatrix}$$

$$\rightarrow \|\nabla f(X_2)\| = 1.2131$$

Est-ce que  $\|\nabla f(X_3)\| > \varepsilon$  ? **Oui  $\rightarrow$  on passe à la troisième itération**

$$k = k + 1 = 3$$

.....

.....

.....

$k$	$a_k$	$X_k$	$\nabla f(X_k)$	$\ \nabla f(X_k)\ $	$\ \nabla f(X_k)\  > \varepsilon ???$
0	/	$\begin{pmatrix} -2 \\ -7 \end{pmatrix}$	$\begin{pmatrix} -7 \\ -10 \end{pmatrix}$	12.2065	Oui
1	0.7525	$\begin{pmatrix} 3.2677 \\ 0.5253 \end{pmatrix}$	$\begin{pmatrix} 3.5354 \\ -2.4747 \end{pmatrix}$	4.3154	Oui
2	0.5984	$\begin{pmatrix} 1.1521 \\ 2.0061 \end{pmatrix}$	$\begin{pmatrix} -0.6956 \\ -0.9939 \end{pmatrix}$	1.2131	Oui
3	0.7526	$\begin{pmatrix} 1.6757 \\ 2.7541 \end{pmatrix}$	$\begin{pmatrix} 0.3515 \\ -0.2459 \end{pmatrix}$	0.4289	Oui
4	0.5982	$\begin{pmatrix} 1.4654 \\ 2.9012 \end{pmatrix}$	$\begin{pmatrix} -0.069 \\ -0.0988 \end{pmatrix}$	0.1205	Oui
5	0.7535	$\begin{pmatrix} 1.5175 \\ 2.9756 \end{pmatrix}$	$\begin{pmatrix} 0.035 \\ -2.0243 \end{pmatrix}$	0.0426	Non

La solution du problème est  $X^* = X_5 = \begin{pmatrix} 1.5175 \\ 2.9756 \end{pmatrix}$