

Cours 10 : Optimisation non linéaire multidimensionnelle sans contraintes

Christophe Gonzales

LIP6 – Université Paris 6, France

Plan du cours

Optimisation d'une fonction différentiable à n variables

- 1 méthode du gradient
- 2 méthode du gradient conjugué (la semaine prochaine)

Cours 10 : Optimisation non linéaire multidimensionnelle sans contraintes 2/14

Fonction différentiable

$f : C \mapsto \mathbb{R}$: fonction définie dans un convexe ouvert C de \mathbb{R}^n :

$$f : x = \begin{bmatrix} x_1 \\ \dots \\ x_j \\ \dots \\ x_n \end{bmatrix} \mapsto f(x) = f(x_1, \dots, x_j, \dots, x_n)$$

fonction différentiable

f est **différentiable** en $x \in C$ si \exists dérivées partielles $\frac{\partial f(x)}{\partial x_j}$,

$j = 1, \dots, n$ et admet pour approximation du 1^{er} ordre la forme linéaire qu'elles définissent :

$$f(x+h) = [f(x_1+h_1, \dots, x_n+h_n)] = f(x) + \sum_{j=1}^n \frac{\partial f(x)}{\partial x_j} \cdot h_j + o(\|h\|)$$

Gradient (1/3)

Définition du gradient

$$\vec{\nabla} f(x) : \text{gradient de } f \text{ en } x = \text{le vecteur } \vec{\nabla} f(x) = \begin{bmatrix} \frac{\partial f(x)}{\partial x_1} \\ \dots \\ \frac{\partial f(x)}{\partial x_j} \\ \dots \\ \frac{\partial f(x)}{\partial x_n} \end{bmatrix}$$

$$\implies f(x+h) = f(x) + \vec{\nabla} f(x)^T \cdot h + o(\|h\|)$$

$$\implies \text{La variation de } f \text{ est du 2}^{\text{ème}} \text{ ordre lorsque } \vec{\nabla} f(x)^T \cdot h = 0$$

$$\vec{\nabla} f(x) \neq 0 \implies \left\{ y : f(y) = f(x) + \vec{\nabla} f(x)^T \cdot [y - x] \right\} = \text{l'hyperplan tangent en } x \text{ à l'hypersurface de niveau } \{z : f(z) = f(x)\}$$

$$\text{normale de l'hyperplan} = \vec{\nabla} f(x)$$

Cours 10 : Optimisation non linéaire multidimensionnelle sans contraintes 3/14

Cours 10 : Optimisation non linéaire multidimensionnelle sans contraintes 4/14


normale de l'hyperplan = $\vec{\nabla}f(x)$

$$\begin{aligned} f(x + \lambda \vec{\nabla}f(x)) &= f(x) + \lambda \vec{\nabla}f(x)^T \cdot \vec{\nabla}f(x) \\ &= f(x) + \lambda \|\vec{\nabla}f(x)\|^2 \\ &> f(x) \text{ pour } \lambda > 0 \end{aligned}$$

\implies normale dirigée du côté des points où f prend des valeurs plus élevées qu'en x

on cherche $\min f \implies \delta = -\vec{\nabla}f(x)$ = direction intéressante

$$\delta = -\vec{\nabla}f(x) = \text{direction de l'anti-gradient}$$



Minima et points stationnaires

- minimum (global ou absolu) de f en $\hat{x} : x \in C \implies f(x) \geq f(\hat{x})$
- minimum local de f en $\hat{x} : \exists$ un voisinage V de \hat{x} tel que $x \in V \implies f(x) \geq f(\hat{x})$
- voisinage V de \hat{x} dans C = un sous-ensemble de C contenant une boule ouverte $\{y : \|y - x\| < \epsilon\}$
- \hat{x} = point stationnaire de f si $\vec{\nabla}f(\hat{x}) = 0$

Lemme

- f différentiable
- minimum local de f en $\hat{x} \implies \hat{x}$ = point stationnaire
- de plus, si f convexe :
 \hat{x} = point stationnaire $\implies \hat{x}$ = minimum local

Direction de l'anti-gradient (1/2)

La méthode du gradient s'appuie sur :

Proposition

La direction de l'anti-gradient est la direction de plus grande pente :

$$\max_{\{h: \|h\| = \|\vec{\nabla}f(x)\|\}} \lim_{\lambda \downarrow 0} \frac{f(x) - f(x + \lambda h)}{\lambda \|h\|}$$

est atteint pour $h = -\vec{\nabla}f(x)$.

Direction de l'anti-gradient (2/2)

Démonstration de la proposition :

$$f(x) - f(x + \lambda h) = -\lambda \vec{\nabla} f(x)^T \cdot h + o(\lambda \|h\|) \implies \text{pour } \|h\| = \|\vec{\nabla} f(x)\| :$$

$$\frac{f(x) - f(x + \lambda h)}{\lambda \|h\|} = \frac{-\lambda \vec{\nabla} f(x)^T \cdot h + o(\lambda \|\vec{\nabla} f(x)\|)}{\lambda \|\vec{\nabla} f(x)\|}$$

$$= \frac{-\vec{\nabla} f(x)^T \cdot h}{\|\vec{\nabla} f(x)\|} + \frac{o(\lambda)}{\lambda}$$

$$\implies \lim_{\lambda \downarrow 0} \frac{f(x) - f(x + \lambda h)}{\lambda \|h\|} = \frac{-\vec{\nabla} f(x)^T \cdot h}{\|\vec{\nabla} f(x)\|}$$

où $-\vec{\nabla} f(x) \cdot h$ est maximum (sous $\|h\| = \|\vec{\nabla} f(x)\|$) pour $h = -\vec{\nabla} f(x)$

Pas de la méthode du gradient

variations de f lorsque l'on part de x dans la direction de l'anti-gradient = celles de la fonction d'une seule variable $\lambda \geq 0$:

$$\varphi : \lambda \mapsto \varphi(\lambda) = f(x - \lambda \vec{\nabla} f(x))$$

$$\text{Or } \varphi'(\lambda) = - \sum_{j=1}^n \frac{\partial f}{\partial x_j} (x - \lambda \vec{\nabla} f(x)) \cdot \vec{\nabla} f_j(x) = -\vec{\nabla} f(x - \lambda \vec{\nabla} f(x)) \cdot \vec{\nabla} f(x)$$

$$\text{en particulier : } \varphi'(0) = -\vec{\nabla} f(x)^T \cdot \vec{\nabla} f(x) = -\|\vec{\nabla} f(x)\|^2 < 0$$

$\implies \varphi$ strictement décroissante au voisinage de $\lambda = 0$

tant que $\varphi'(\lambda) > 0$, on continue à se déplacer et on s'arrête en : $\tilde{x} = x - \tilde{\lambda} \vec{\nabla} f(x)$, où $\tilde{\lambda}$ est la plus petite valeur de λ solution de $\varphi'(\lambda) = 0$ (si elle existe)

Méthode du gradient (1/2)

Méthode du gradient — Cauchy (1847), Curry (1944)


- partir d'un point initial x^0
- on répète le pas $x \rightarrow \tilde{x}$ précédent : $x^k \rightarrow x^{k+1} = \tilde{x}^k$

critères d'arrêts possibles :

- $\max_{i=1}^n \left| \frac{\partial f}{\partial x_i} (x^k) \right| < \epsilon$
- $\|\vec{\nabla} f(x^k)\| < \epsilon$
- $|f(x^{k+1}) - f(x^k)| < \epsilon$

Les 3 critères d'arrêt indiquent que f est proche d'être stationnaire

Méthode du gradient (2/2)



$$\varphi'(\tilde{\lambda}) = -\vec{\nabla}f(\tilde{x})^T \cdot \vec{\nabla}f(x) = 0$$

⇒ les gradients en x et \tilde{x} sont orthogonaux

⇒ à chaque pas on prend une direction orthogonale à la direction précédente

cheminement de la méthode du gradient : «en zigzag»

⇒ pour éviter les zigzags et accélérer la convergence, on peut avoir recours à l'un des procédés suivants :

- **diminuer le pas** : ne pas aller jusqu'en \tilde{x} .

Polyak (66) : effectuer des pas prédéterminés en imposant une suite (λ^k) telle que $\lambda^k \downarrow 0$ et $\sum_k \lambda^k = +\infty$
⇒ (x^k) tend vers \hat{x}

- **utiliser d'autres directions que l'anti-gradient** :

Forsythe (1968), Luenberger (1973) : toutes les m itérations, au lieu de partir dans la direction de l'anti-gradient en x^k , «couper» en partant dans la direction $\delta = x^k - x^{k-m}$

- **utiliser des directions «conjuguées»**