

Chapitre 4

OPTIMISATION SANS CONTRAINTES.CONDITIONS D'OPTIMALITE

4.1 Définitions

Définition(Fonction convexe différentiable) Soit $C \subseteq \mathbb{R}^n$ non vide, $f : \mathbb{R}^n \rightarrow \mathbb{R}$ et $\hat{x} \in \text{int}(C)$. f est dite différentiable au point \hat{x} , s'il existe un vecteur $A \in \mathbb{R}^n$ et une fonction $\alpha : \mathbb{R}^n \rightarrow \mathbb{R}$ telle que

$$f(x) = f(\hat{x}) + A(x - \hat{x}) + \|x - \hat{x}\| \alpha(\hat{x}, x - \hat{x}),$$

où $\alpha(\hat{x}, x - \hat{x})_{x \rightarrow \hat{x}} \rightarrow 0$. On peut noter le vecteur A comme suit : $A = \nabla f(\hat{x})^T$.

Définition(Fonction convexe deux fois différentiable) Soit $C \subseteq \mathbb{R}^n$ non vide, $f : \mathbb{R}^n \rightarrow \mathbb{R}$ est dite deux fois différentiable au point $\hat{x} \in \text{int}(C)$ s'il existe un vecteur $\nabla f(\hat{x})$ et une matrice symétrique $H(\hat{x})$ d'ordre $(n \times n)$ appelée matrice hessienne, et une fonction $\alpha : \mathbb{R}^n \rightarrow \mathbb{R}$ telle que

$$\forall x \in C, f(x) = f(\hat{x}) + \nabla f(\hat{x})^T (x - \hat{x}) + \frac{1}{2}(x - \hat{x})^T H(\hat{x})(x - \hat{x}) + \|x - \hat{x}\|^2 \alpha(\hat{x}, x - \hat{x}),$$

où $\alpha(\hat{x}, x - \hat{x})_{x \rightarrow \hat{x}} \rightarrow 0$ et $H(\hat{x})$ est la matrice Hessienne au point \hat{x} .

Définition Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$, on appelle problème de minimisation sans contraintes le problème (P) suivant :

$$(P) \quad \min \{f(x) : x \in \mathbb{R}^n\}.$$

1) $\hat{x} \in \mathbb{R}^n$ est un minimum global de (P) si et seulement si

$$f(\hat{x}) \leq f(x) : \forall x \in \mathbb{R}^n.$$

2) $\hat{x} \in \mathbb{R}^n$ est un minimum local de (P) si et seulement si il existe un voisinage $V_\varepsilon(\hat{x})$ tel que

$$f(\hat{x}) \leq f(x) : \forall x \in V_\varepsilon(\hat{x}).$$

3) $\hat{x} \in \mathbb{R}^n$ est un minimum local strict de (P) si et seulement si il existe un voisinage $V_\varepsilon(\hat{x})$ tel que

$$f(\hat{x}) < f(x) : \forall x \in V_\varepsilon(\hat{x}), x \neq \hat{x}.$$

4.2 Direction de descente

Définition Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $\hat{x} \in \mathbb{R}^n$, $d \in \mathbb{R}^n$ est dite direction de descente au point \hat{x} si et seulement si il existe $\delta > 0$ tel que

$$f(\hat{x} + \lambda d) < f(\hat{x}) : \forall \lambda \in]0, \delta[.$$

Donnons maintenant une condition suffisante pour que d soit une direction de descente.




Figure 2.1: Les différents types de minimas.

Théorème Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$ différentiable au point $\hat{x} \in \mathbb{R}^n$ et $d \in \mathbb{R}^n$ une direction vérifiant la condition suivante :

$$f'(\hat{x}, d) = \nabla f(\hat{x})^t \cdot d < 0.$$

Alors d est une direction de descente au point \hat{x} .

Preuve. f est différentiable au point \hat{x} . Donc

$$f(\hat{x} + \lambda d) = f(\hat{x}) + \lambda \nabla f(\hat{x})^t \cdot d + \lambda \|d\| \alpha(\hat{x}, \lambda d),$$

avec

$$\alpha(\hat{x}, \lambda d) \xrightarrow{\lambda \rightarrow 0} 0,$$

ceci implique que

$$f'(\hat{x}, d) = \lim_{\lambda \rightarrow 0} \frac{f(\hat{x} + \lambda d) - f(\hat{x})}{\lambda} = \nabla f(\hat{x})^t \cdot d < 0.$$

La limite étant strictement négative, alors il existe un voisinage de zéro $V(0) =]-\delta, +\delta[$ tel que

$$\frac{f(\hat{x} + \lambda d) - f(\hat{x})}{\lambda} < 0, \quad \forall \lambda \in]-\delta, +\delta[. \quad (1)$$

La relation (1) est particulièrement vraie pour tout $\lambda \in]0, +\delta[$. On obtient le résultat cherché en multipliant la relation (1) par $\lambda > 0$. ■

4.3 Schémas général des algorithmes d'optimisation sans contraintes

Supposons que d_k soit une direction de descente au point x_k . Ceci nous permet de considérer le point x_{k+1} , successeur de x_k , de la manière suivante :

$$x_{k+1} = x_k + \lambda_k d_k, \quad \lambda_k \in]0, +\delta[.$$

Vu la définition de direction de descente, on est assuré que

$$f(x_{k+1}) = f(x_k + \lambda_k d_k) < f(x_k).$$

Un bon choix de d_k et de λ_k permet ainsi de construire une multitude d'algorithmes d'optimisation.

4.3.1 Exemples de choix de directions de descente

Par exemple si on choisit $d_k = -\nabla f(x_k)$ et si $\nabla f(x_k) \neq 0$, on obtient la méthode du gradient. La méthode de Newton correspond à $d_k = -(H(x_k))^{-1} \cdot \nabla f(x_k)$. Bien sur $-\nabla f(x_k)$ est une direction de descente ($\nabla f(x_k)^t \cdot d_k = -\nabla f(x_k)^t \cdot \nabla f(x_k) = -\|\nabla f(x_k)\|^2 < 0$). Pour la deuxième direction si la matrice hessienne $H(x_k)$ est définie positive alors $d_k = -(H(x_k))^{-1} \cdot \nabla f(x_k)$ est aussi une direction de descente.

4.3.2 Exemple de choix de pas λ_k

On choisit en général λ_k de façon optimale, c'est à dire que λ_k doit vérifier

$$f(x_k + \lambda_k d_k) \leq f(x_k + \lambda d_k) : \forall \lambda \in [0, +\infty[.$$

En d'autres termes on est ramené à étudier à chaque itération un problème de minimisation d'une variable réelle. C'est ce qu'on appelle recherche linéaire.

4.4 Conditions nécessaires d'optimalité

4.4.1 Conditions nécessaires d'optimalité du premier ordre

Théorème Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$ différentiable au point $\hat{x} \in \mathbb{R}^n$. Si \hat{x} est un minimum local de (P) alors $\nabla f(\hat{x}) = 0$.

Preuve. C'est une conséquence directe du Théorème 1. En effet, supposons que $\nabla f(\hat{x}) \neq 0$. Puisque la direction $d = -\nabla f(\hat{x})$ est une direction de descente, alors il existe $\delta > 0$ tel que :

$$f(\hat{x} + \lambda d) < f(\hat{x}), \forall \lambda \in]0, \delta[.$$

Ceci est contradiction avec le fait que \hat{x} est une solution optimale locale de (P) . ■ ■

4.4.2 Condition nécessaire d'optimalité du second ordre

Théorème Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$ deux fois différentiable au point $\hat{x} \in \mathbb{R}^n$. Si \hat{x} est un minimum local de (P) alors $\nabla f(\hat{x}) = 0$ et la matrice hessienne de f au point \hat{x} , qu'on note $H(\hat{x})$, est semi définie positive.

Preuve. Soit $x \in \mathbb{R}^n$ quelconque, f étant deux fois différentiable au point \hat{x} , on aura pour tout $\lambda \neq 0$

$$f(\hat{x} + \lambda x) = f(\hat{x}) + \frac{1}{2} \lambda^2 x^t H(\hat{x}) x + \lambda^2 \|x\| \alpha(\hat{x}, \lambda x), \quad \alpha(\hat{x}, \lambda x) \xrightarrow{\lambda \rightarrow 0} 0.$$

Ceci implique

$$\frac{f(\hat{x} + \lambda x) - f(\hat{x})}{\lambda^2} = \frac{1}{2} x^t H(\hat{x}) x + \|x\| \alpha(\hat{x}, \lambda x). \quad (2)$$

\hat{x} est un optimum local, il existe alors $\delta > 0$ tel que

$$\frac{f(\hat{x} + \lambda x) - f(\hat{x})}{\lambda^2} \geq 0, \quad \forall \lambda \in]-\delta, +\delta[.$$

Si on prend en considération (2) et on passe à la limite quand $\lambda \rightarrow 0$, $\lambda \neq 0$, on obtient

$$x^t H(\hat{x}) x \geq 0, \quad \forall x \in \mathbb{R}^n.$$

■

4.5 Conditions suffisantes d'optimalité

Théorème Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$ deux fois différentiable au point $\hat{x} \in \mathbb{R}^n$. Si $\nabla f(\hat{x}) = 0$ et $H(\hat{x})$ est définie positive alors \hat{x} est un minimum local strict de (P) .

Preuve. f étant deux fois différentiable au point \hat{x} , on aura pour tout $x \in \mathbb{R}^n$

$$f(x) = f(\hat{x}) + \frac{1}{2} (x - \hat{x})^t H(\hat{x}) (x - \hat{x}) + \left\| (x - \hat{x}) \right\|^2 \alpha(\hat{x}, (x - \hat{x})), \quad \alpha(\hat{x}, (x - \hat{x})) \xrightarrow{x \rightarrow \hat{x}} 0, \quad (3)$$

Supposons que \hat{x} n'est pas un optimum local strict. Alors il existe une suite $\{x_k\}_{k \in \mathbb{N}^*}$ telle que $x_k \neq \hat{x} : \forall k$ et

$$x_k \neq \hat{x} : \forall k, \quad x_k \xrightarrow[k \rightarrow \infty]{} \hat{x} \quad \text{et} \quad f(x_k) \leq f(\hat{x}). \quad (4)$$

Dans (3) prenons $x = x_k$, divisons le tout par $\left\| (x_k - \hat{x}) \right\|^2$ et notons $d_k = \frac{(x_k - \hat{x})}{\left\| (x_k - \hat{x}) \right\|}$, on obtient

$$\frac{f(x_k) - f(\hat{x})}{\left\| (x_k - \hat{x}) \right\|^2} = \frac{1}{2} d_k^t H(\hat{x}) d_k + \alpha(\hat{x}, (x_k - \hat{x})), \quad \alpha(\hat{x}, (x_k - \hat{x})) \xrightarrow[k \rightarrow \infty]{} 0 \quad (5)$$

(4) et (5) impliquent

$$\frac{1}{2}d_k^t H(\hat{x}) d_k + \alpha \left(\hat{x}, (x_k - \hat{x}) \right) \leq 0, \quad \forall k.$$

D'autre part la suite $\{d_k\}_{k \in \mathbb{NN}^*}$ est bornée ($\|d_k\| = 1, \forall k$). Donc il existe une sous suite $\{d_k\}_{k \in N_1 \subset \mathbb{NN}}$ telle que

$$d_k \xrightarrow[k \rightarrow \infty, k \in N_1]{} \tilde{d}.$$

Finalement lorsque $k \rightarrow \infty, k \in N_1$, on obtient

$$\frac{1}{2}\tilde{d}^t H(\hat{x}) \tilde{d} \leq 0.$$

La dernière relation et le fait que $\tilde{d} \neq 0$ ($\|\tilde{d}\| = 1$) impliquent que la matrice hessienne $H(\hat{x})$ n'est pas définie positive. Ceci est en contradiction avec l'hypothèse. ■

4.6 Les modes de convergence

Définition : Soit $\{x^k\}_{k \in \mathbb{N}}$ une suite dans \mathbb{R}^n convergeant vers x^* .

1- Si $\limsup_{k \rightarrow \infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|} = \alpha < 1$, on dit que $\{x^k\}_{k \in \mathbb{N}}$ converge vers x^* linéairement avec le taux α .

Lorsque $\|x^{k+1} - x^*\| \simeq \alpha \|x^k - x^*\|$, la convergence est dite linéaire asymptotique.

2- Si $\limsup_{k \rightarrow \infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|^\gamma} < +\infty, \gamma > 1$ la convergence est dite superlinéaire d'ordre γ .

3- Si $\lim_{k \rightarrow \infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|} = 0$, on dit que $\{x^k\}_{k \in \mathbb{N}}$ tend vers x^* de façon superlinéaire.

Lorsque $\|x^{k+1} - x^*\| \leq l \|x^k - x^*\|^\gamma$, la convergence est dite superlinéaire asymptotique.