

Chapitre IV Optimisation

4.1 Position des problèmes d'optimisation

Soit $K \subset \mathbb{R}^n$ une partie et $J: K \rightarrow \mathbb{R}$ une fonction.

$$(P) \quad \left\{ \begin{array}{l} \text{Trouver } u \in K \\ \text{tq } J(u) = \inf_{u \in K} J(u) \end{array} \right.$$

J : fonction coût K : ensemble de contraintes

Applications nombreuses, en physique chimie, en économie.

4.2

Rappels historiques sur les problèmes d'optimisation

(a) Conditions suffisantes d'existence d'une solution à (P)

Prop: Si $K \subset \mathbb{R}^n$ est une partie compacte et $J: K \rightarrow \mathbb{R}$ continue
 $\exists u_0 \in K \quad J(u_0) = \inf_{u \in K} J(u)$.

Corollaire:

Déf: $J: \mathbb{R}^n \rightarrow \mathbb{R}^m$ est dite coercive si $\lim_{\|u\| \rightarrow +\infty} J(u) = +\infty$.

Prop: Si $F \subset \mathbb{R}^n$ est une partie fermée et $J: F \rightarrow \mathbb{R}^m$ continue coercive
 $\exists u_0 \in F \quad J(u_0) = \inf_{u \in F} J(u)$.

Preuve: L'hypothèse signifie

$$\forall M > 0 \quad \exists r > 0 \quad \|x\| > r \Rightarrow f(x) \geq M.$$

Sur $v \in F$ posons $M = J(v) + 1$ et $r = r(M)$.

Alors $K = F \cap \overline{B}(0, r)$ compact et donc $f|_K$ a un minimum en $u_0 \in K$.

On a $J(u_0) \leq J(v) \leq M - 1$ et donc si $u \in F \cap \{ \|x\| > r\}$ $J(u) > J(u_0)$.

Donc u_0 est le min de $J|_F$.

(b) Conditions d'existence d'un élément de (P)

Prop: Si $U \subset \mathbb{R}^n$ ouvert et $J: U \rightarrow \mathbb{R}$ ^{de classe C^2 .} Soit $u_0 \in U$ un minimum local de J alors $\frac{\partial J}{\partial x}(u_0) = 0$

$$\left(\frac{\partial^2 J}{\partial x_i \partial x_j}(u_0) \right) \geq 0$$

Récapot

$$\nabla J = \left(\frac{\partial J}{\partial x_i}(x_0) = 0 \quad i=1 \dots n \right)$$

$$H(f) = \left(\frac{\partial^2 f}{\partial x_i \partial x_j}(x_0) \right) \text{ définie positive}$$

Alors x_0 est un minimum local (qu'on dira non dégénéré).

Prop (mult. de Lagrange) Soit $J \in C^1(\mathbb{R}^n; \mathbb{R})$ et $f : \mathbb{R}^n \xrightarrow{C^1} \mathbb{R}$.
On pose $P = f'(0)$

$$\begin{cases} \text{si } u_0 \in P \text{ on vérifie} \\ \left\{ \begin{array}{l} J(u_0) = \min_{u \in P} J(u) \\ \left(\frac{\partial J}{\partial x_i}(u_0) \right) \neq 0. \end{array} \right. \end{cases}$$

$$\text{Alors } \exists \lambda \in \mathbb{R} \quad \frac{\partial J}{\partial x_i}(u_0) = \lambda \cdot \frac{\partial f}{\partial x_i}(u_0).$$

Ces deux propriétés sont des clarifications des cours de calcul différentiel.

4.3 Algorithmes d'optimisation pour les problèmes sans contraintes

(a) méthode de Newton Elle rent à étudier le système $\frac{\partial J}{\partial x_i} = 0 \quad i=1 \dots n$.

Prop Si $J \in C^2(\mathbb{R}^n; \mathbb{R})$ et u_0 vérifie $\frac{\partial J}{\partial x_i}(u_0) = 0$ et $\left(\frac{\partial^2 J}{\partial x_i \partial x_j}(u_0) \right)$ inversible

Alors u_0 est un pt fixe attractif de la méthode de Newton.

$$u_{n+1} = \Phi(u_n)$$

$$\text{avec } \Phi(x) = x - \left[\frac{\partial^2 J}{\partial x_i \partial x_j}(x) \right]^{-1} \begin{pmatrix} \frac{\partial J}{\partial x_1} \\ \vdots \\ \frac{\partial J}{\partial x_n} \end{pmatrix} = x - H(J)^{-1} \nabla J(x).$$

Variante: méthode de la corde

(b) méthode de relaxation pour les fonctions elliptiques u

Déf $J \in C^2(\mathbb{R}^n; \mathbb{R})$ J est \star (elliptique) si

$$\exists \alpha > 0 \quad H(J) \geq \alpha I_n$$

(i.e. La matrice sym. $H(J) - \alpha I_n$ est définie semi-positive).

Chercher les minima de fonctions C². à la restrictive:

Théorème: Soit u₀ un min. local non dégénéré de $J \in C^2(\mathbb{R}^n; \mathbb{R})$
alors $\exists \tilde{J} \in C^2(\mathbb{R}^n, \mathbb{R})$ tq

$$\begin{cases} J(u_0) = \min_{u \in \mathbb{R}^n} J(u) \\ J = \tilde{J} \text{ dans un voisinage de } u_0 \end{cases}$$

La preuve sort du programme de ce cours.
Elle est relativement simple.

Proposition: Soit $J: \mathbb{R}^n \rightarrow \mathbb{R}$ est $\alpha > 0$ comme dans la définition

(1) $\forall (x, y) \in \mathbb{R}^n$ $J(x) - J(y) \geq (\nabla J(y), x - y) + \frac{\alpha}{2} \|x - y\|^2$.

(2) J convexe

(3) Ex. Soit $U \subset \mathbb{R}^n$ une partie convexe fermée non vide.

$$\text{Alors } \exists ! u_0 \in U \quad J(u_0) = \min_{u \in U_0} J(u).$$

Preuve: $f(t) = f(y + t(x-y)) \text{ en } t=0$
• le formule de Taylor appliquée à $j(t) = f(y + t(x-y))$

donne: $j(1) = j(0) + j'(0) + \frac{j''(c)}{2}$ pour un certain $c \in]0, 1[$.

$$\begin{aligned} j(1) &= J(y) \\ j(0) &= J(y) \\ j'(0) &= (\nabla J(y); (x-y)) = \partial_y J(y)(x-y) \end{aligned}$$

$$j''(t) = \sum_{i=1}^n \frac{\partial^2 f}{\partial x_i^2} (y + t(x-y)) \cdot (x_i - y_i)$$

$$j''(t) = \sum_{i=1}^n \sum_{j=1}^n \frac{\partial^2 f}{\partial x_i \partial x_j} (y + t(x-y)) (x_i - y_i) (x_j - y_j)$$

$$= H(f)(y + t(x-y)) \cdot (x-y); (x-y)$$

$\geq \alpha \|x-y\|^2$ par la propriété caractéristique
de la définition. D'où (1).

• En particulier $J(x) \geq (\nabla J(0), x) + \frac{\alpha}{2} \|x\|^2 \geq -B \|x\| + \frac{\|x\|^2}{2}$

$$B = \|\nabla J(0)\| \quad \text{et } \lim_{x \rightarrow \infty} J(x) = +\infty \quad \text{D'où (2).}$$

L'existence d'un minimum de J on démontre. Soit $u_0 \in U$ un tel minimum et $v \in V$ alors tout $v_t = u_0 + t(v - u_0)$ $t \in [0,1]$ on a :

$$\begin{aligned} J(v_t) - J(u_0) &\geq (\nabla J(u_0); (v_t - u_0)) + \frac{\alpha}{2} \|v_t - u_0\|^2 \\ &\geq \lambda (\nabla J(u_0); v - u_0) + \frac{\alpha}{2} \|v - u_0\|^2 t^2. \end{aligned}$$

De plus $\lim_{t \rightarrow 0^+} \frac{J(v_t) - J(u_0)}{t} = (\nabla J(u_0); v - u_0)$ donc

car u_0 un minimum
Donc $(\nabla J(u_0); v - u_0) \geq 0$

de sorte que $J(v_t) - J(u_0) \geq \frac{\alpha}{2} \|v - u_0\|^2 t^2 > 0$ si $v \neq u_0$.
D'où l'unicité dans (3).

Méthode de relaxation

Soit $J: \mathbb{R}^n \rightarrow \mathbb{R}$ unif. convexe

Soit $x_0 \in \mathbb{R}^n$ - (e_1, \dots, e_n) base canonique

On pose

$$x_0^{(0)} = x_0$$

$$x_0^{(1)} = x_0^{(0)} + t_0^{(1)} e_1 \quad \text{avec} \quad J(x_0^{(0)} + t_0^{(1)} e_1) = \min_{t^{(1)} \in \mathbb{R}} J(x_0^{(0)} + t^{(1)} e_1)$$

$$x_0^{(k+1)} = x_0^{(k)} + t_0^{(k+1)} e_{k+1} \quad \text{avec} \quad J(x_0^{(k)} + t_0^{(k+1)} e_{k+1}) = \min_{t^{(k+1)} \in \mathbb{R}} J(x_0^{(k)} + t^{(k+1)} e_{k+1})$$

Ce qui définit $x_0^{(0)}, \dots, x_0^{(n)}$.

On pose alors $x_1 = x_0^{(n)}$ puis on itère de façon à obtenir

une suite $(x_i)_{i \in \mathbb{N}}$ [et même $(x_i^{(k)})_{i \in \mathbb{N}}$ $k=0, \dots, n$].

Théorème: Si J coercive pour tout $x_0 \in \mathbb{R}^n$ la méthode de relaxation converge vers l'unique minimum de J sur \mathbb{R}^n .

Preuve: Appliquons l'inégalité (1) de la proposition :

$$J(x_i^{(k)}) - J(x_i^{(k+1)}) \geq (\nabla J(x_i^{(k)}), (x_i^{(k)} - x_i^{(k+1)}))$$

$$+ \frac{\alpha}{2} \|x_i^{(k)} - x_i^{(k+1)}\|^2.$$

mais $(\nabla J(x_i^{(k+1)})(x_i^{(k)} - x_i^{(k+1)})) = 0$ car $x_i^{(k+1)}$ est
le point où
 $\|e_i^{(k)}\|_2^2 e_{k+1}$. Ja un min. sur
 $x_i^{(k)} + \mathbb{R} e_{k+1}$.

Donc

$$J(x_i^{(k)}) - J(x_i^{(k+1)}) \geq \frac{\alpha}{2} \|x_i^{(k)} - x_i^{(k+1)}\|^2$$

$$\text{et } J(x_i^{(n)}) - J(x_i^{(0)}) \geq \frac{\alpha}{2} \sum_{k=0}^{n-1} \|x_i^{(k)} - x_i^{(k+1)}\|^2$$

$$= \frac{\alpha}{2} \|x_i^{(n)} - x_i^{(0)}\|^2 = \frac{\alpha}{2} \|x_i^{(n)} - x_i^{(k+1)}\|^2$$

car les $(x_i^{(k)} - x_i^{(k+1)})$
sont 2-orthogonaux.

Donc $(J(x_i))_{i \in \mathbb{N}}$ est décroissante minorée donc converge.

$$\text{et } \lim_{n \rightarrow \infty} \|x_{i+1} - x_i\| = 0$$

$$(\text{ainsi } \lim_{n \rightarrow \infty} \|x_i^{(k)} - x_i\| = 0)$$

Soit u_0 le point où le mi de J est atteint.

$$0 \geq J(u_0) - J(x_i) \geq (\nabla J(x_i); u_0 - x_i) + \frac{\alpha}{2} \|u_0 - x_i\|^2.$$

$$\frac{\alpha}{2} \|u_0 - x_i\|^2 \leq - \sum_{\ell=1}^n \frac{\partial J}{\partial x_\ell}(x_i^{(\ell)}) \cdot (u_{0,\ell} - x_{i,\ell})$$

Comme $\frac{\partial J}{\partial x_\ell}(x_i^{(k)}) = 0$

$$\begin{aligned} \sum_{\ell=1}^n \frac{\partial J}{\partial x_\ell}(x_i) \cdot (x_{i,\ell} - u_{0,\ell}) &= \sum_{\ell=1}^n \frac{\partial J}{\partial x_\ell}(x_i) - \frac{\partial J}{\partial x_\ell}(x_i^{(k)}) \\ &\leq \|u_0 - x_i\| \cdot \sum_{\ell=1}^n \left| \frac{\partial J}{\partial x_\ell}(x_i) - \frac{\partial J}{\partial x_\ell}(x_i^{(k)}) \right| \end{aligned}$$

Donc

$$\frac{\alpha}{2} \|u_0 - x_i\| \leq \sum_{\ell=1}^n \left| \frac{\partial J}{\partial x_\ell}(x_i) - \frac{\partial J}{\partial x_\ell}(x_i^{(k)}) \right|$$

• Comme J coercive $(x_i)_{i \in \mathbb{N}}$ $(x_i^{(k)})_{i \in \mathbb{N}}$ restent dans
une boule fermée de \mathbb{R}^n un compact K

Or $\frac{\partial J}{\partial x_\ell}$ est continue donc uniforme continue sur K

$$\forall \varepsilon > 0 \quad \exists \delta > 0 \quad \forall x, y \in K \quad \|x - y\| < \delta \Rightarrow \left| \frac{\partial J}{\partial x_\ell}(x) - \frac{\partial J}{\partial x_\ell}(y) \right| < \varepsilon$$

$$\text{Or } x_i - x_i^{(k)} \xrightarrow[i \rightarrow \infty]{} 0 \quad \text{pour } i \geqslant i_0 \quad |x_i - x_i^{(k)}| < \Theta(\frac{2\varepsilon}{\alpha})$$

$$\text{et on a pour } i \geqslant i_0 \quad \|u_0 - x_i\| \leq \varepsilon.$$

Donc $\lim_{i \rightarrow \infty} x_i = u_0 \quad \square$

(c) méthode du gradient optimal pour les fonctions unif. convexes.

$J \in C^2(\mathbb{R}^n, \mathbb{R})$ elliptique.

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

On pose

$$\begin{cases} x_{k+1} = x_k - e_k \nabla J(x_k) \\ e_k \text{ choisi tel que} \end{cases}$$

$$J(x_{k+1}) = \min_{t \in \mathbb{R}} J(x_k - t \nabla J(x_k)) \quad (*)$$

Noter que $x_{k+1} = x_k$ si $\nabla J(x_k) = 0$ auquel cas x_k est le min. recherché

Thm: $(x_k)_{k \in \mathbb{N}}$ converge vers l'arg. minimum de J sur \mathbb{R}^n .

Preuve: Cette preuve est une variante de la précédente et ne sera pas donnée en ampli

• Comme précédent on a

$$J(x_k) - J(x_{k+1}) \geq \frac{\alpha}{2} \|x_k - x_{k+1}\|^2$$

Donc $J(x_k)$ converge et $\|x_k - x_{k+1}\| \xrightarrow[k \rightarrow \infty]{} 0$.

• le fait que $J(x_{k+1})$ soit le minimum comme en (*)

donne $(\nabla J(x_{k+1}), \nabla J(x_k)) = 0$

$$\text{Donc } \|\nabla J(x_k)\|^2 = (\nabla J(x_k), \nabla J(x_k) - \nabla J(x_{k+1}))$$

$$\leq \|\nabla J(x_k)\| \cdot \|\nabla J(x_k) - \nabla J(x_{k+1})\|.$$

$$\text{et } \|\nabla J(x_k)\| \leq \|\nabla J(x_k) - \nabla J(x_{k+1})\|$$

(même si $\nabla J(x_k) = 0 \dots$)

• Comme $(x_k)_{k \in \mathbb{N}}$ bornée et ∇J uniformément continue son argument reste dans un compact
l'arg. final du théorème précédent s'applique.

(d) méthode de gradient conjugué

C'est une variante de la précédente. On fixe $k \geq 1$ et on suppose défini (x_0, x_1, \dots, x_k) $k \geq k$.

on définit x_{k+1} comme le point dans l'espace affine $x_k + V_k$ $V_k = \text{Vect}(\nabla J(x_k), \nabla J(x_{k-1}), \dots, \nabla J(x_{k-k+1}))$

où $J_f(x_k + v)$ atteint son minimum.

Cette méthode est a priori meilleure que les précédentes mais nous n'effectuons pas son analyse détaillée, faute de temps.