

# Chapitre 2

## Les Fondements de l'optimisation sans contraintes

### 2.1 Définitions

On aborde le problème d'optimisation sans contrainte qui est normalement non-linéaire. Le problème est posé dans  $\mathbb{R}^n$ , donc

$$\min_{x \in \mathbb{R}^n} f(x), \quad (2.1)$$

où  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ .

#### Définition 2.1.

- Un vecteur  $x^*$  de  $\mathbb{R}^n$  est appelé *minimum local* de  $f$  sur  $\mathbb{R}^n$ , s'il existe une boule  $B(x^*, \rho)$  de centre  $x^*$  et de rayon  $\rho > 0$ , telle que

$$\forall x \in B(x^*, \rho), f(x) \geq f(x^*).$$

- Un *minimum global* de  $f$  sur  $\mathbb{R}^n$  est un vecteur  $x^*$  de  $\mathbb{R}^n$  tel que

$$\forall x \in \mathbb{R}^n, f(x) \geq f(x^*). \quad (2.2)$$

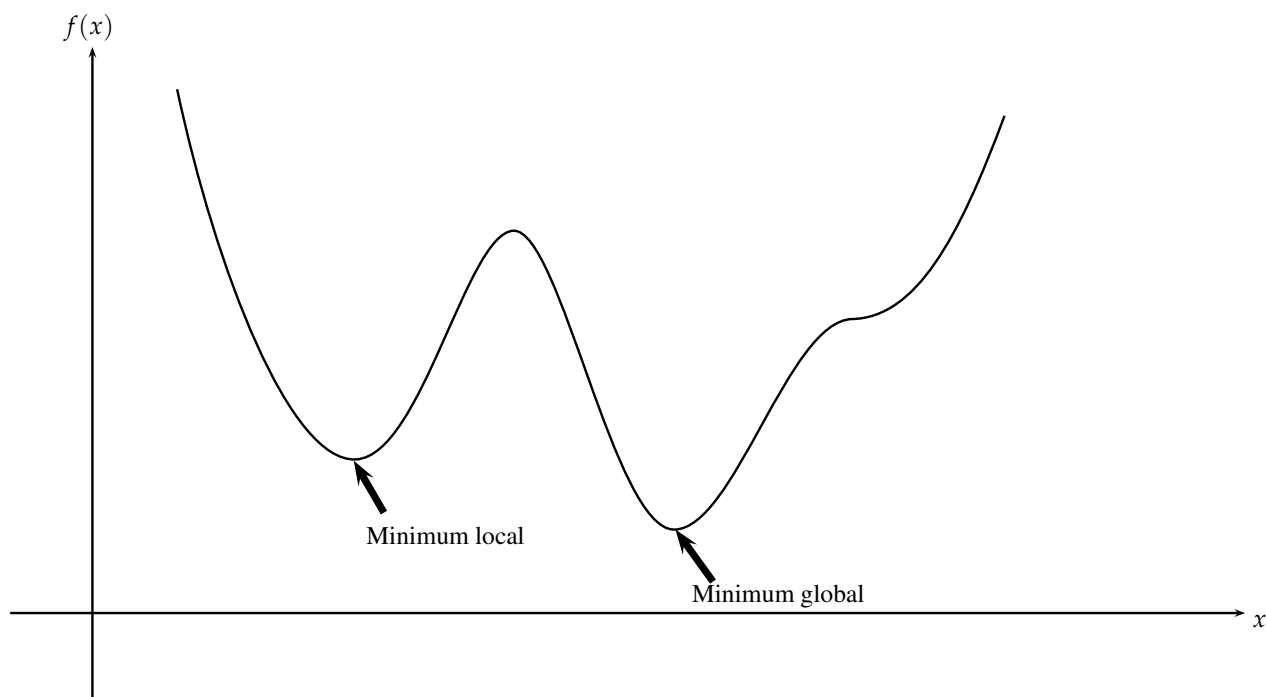


Figure 2.1: Les différents types de minimas.

**Remarque 2.1.** *En dehors de cas particulièrement favorable (il n'existe qu'un seul minimum ou bien on est dans le cas de la programmation linéaire continue, ou quadratique à matrice semi-définie positive, ou en programmation convexe), on devra se contenter de découvrir des minimas locaux de  $f$ .*

### 2.1.1 Principe général de résolution

Pour résoudre le problème (2.1), on applique un algorithme qui, d'un point initial  $x_0 \in \mathbb{R}^n$ , construit itérativement une suite de vecteurs dans  $\mathbb{R}^n$ , défini par

$$x_{k+1} = x_k + t_k d_k, \quad (2.3)$$

où,  $d_k$  est un vecteur non nul de  $\mathbb{R}^n$  appelé direction et  $t_k$  une valeur réelle non nulle qu'on appelle le pas. Le choix du vecteur  $d_k$  et le scalaire  $t_k$  détermine le type d'algorithme utilisé pour résoudre (2.1) ainsi que la convergence et la vitesse de convergence de la suite  $\{x_k\}$  engendrée par l'algorithme.

**Définition 2.2.** Soit  $d$  un vecteur non nul de  $\mathbb{R}^n$ , s'il existe un réel  $\delta > 0$  tel que pour tout  $t$  dans l'intervalle  $]0, \delta[$ , on a

$$f(x + td) < f(x),$$

alors le vecteur  $d$  est dit une direction de descente en  $x$ .

**Théorème 2.1.** Si  $f$  est différentiable en un point  $x \in \mathbb{R}^n$  et  $d \in \mathbb{R}^n$  telle que

$$g(x)^\top d < 0. \quad (2.4)$$

Alors  $d$  est une direction de descente en  $x$ .




Figure 2.2: Cône des directions de descente.

## 2.2 Conditions d'optimalité

Les conditions d'optimalité d'un point  $x \in \mathbb{R}^n$  sont des équations, des inéquations ou des propriétés que vérifient les solutions de (2.1) (conditions nécessaires) ou qui assurent à un point d'être solution de (2.1) (conditions suffisantes). Ces conditions sont utiles pour

- Vérifier l'optimalité éventuelle d'un point  $x \in \mathbb{R}^n$ , voir si c'est un minimum, un maximum ou un point stationnaire.

- Calculer les solutions de (2.1).
- Élaborer des méthodes numériques permettant de résoudre (2.1).
- Définir des tests d'arrêt des itérations dans les algorithmes de résolution de (2.1).

## 2.2.1 Le cas différentiable

### Conditions nécessaires d'optimalité du premier ordre

**Théorème 2.2.** Soit  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  différentiable en  $\bar{x}$ . Si  $\bar{x}$  est minimum local, alors

$$g(\bar{x}) = 0. \quad (2.5)$$

#### *Démonstration.*

Par l'absurde, en supposant que  $g(\bar{x}) \neq 0$  et on prend  $d = -g(\bar{x})$  qui est une direction de descente (car  $g(\bar{x})^\top d = -\|g(\bar{x})\|^2 < 0$ ) et d'après la définition 2.1,  $\bar{x}$  n'est pas un optimum local.

□

Ces conditions ne sont pas suffisantes. En effet la fonction  $f(x, y) = x^2 - y^2$  considérée sur  $[-1, 1] \times [-1, 1]$ , vérifie  $f(\bar{x}) = 0$  en  $\bar{x} = (0, 0)$ , cependant ce point n'est pas un optimum local, mais un point de selle (voir figure 2.3).




Figure 2.3: Une fonction avec un point selle en  $(x, y) = (0, 0)$ .

### Conditions nécessaires d'optimalité du second ordre

**Théorème 2.3.** Soit  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  deux fois différentiable en  $\bar{x}$  et supposant que  $\bar{x}$  soit un minimum local. Alors  $g(\bar{x}) = 0$  et  $H(\bar{x})$  est semi-définie positive.

*Démonstration.*

Le premier point est le résultat du théorème précédent. Le deuxième se démontre par contradiction. Supposons que  $H(\bar{x})$  n'est pas SDP. Alors, on peut choisir un vecteur  $d$  tel que  $d^\top H(\bar{x})d < 0$ . En utilisant le développement de Taylor au voisinage de  $\bar{x}$ , il existe un  $\bar{t} \in ]0, 1[$  tel que pour tout  $t \in ]0, \bar{t}[$  on a

$$f(\bar{x} + td) = f(\bar{x}) + tg(\bar{x})^\top d + \frac{1}{2}t^2 d^\top H(\bar{x})d < f(\bar{x}).$$

□

Moyennant un léger renforcement, les conditions du théorème précédent s'avèrent suffisantes pour garantir un minimum local.

### Conditions suffisantes d'optimalité du second ordre

**Théorème 2.4.** Soit  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  deux fois différentiable en  $\bar{x}$ . Si  $g(\bar{x}) = 0$  et  $H(\bar{x})$  est définie positive, alors  $\bar{x}$  est un minimum local strict.

*Démonstration.*

Choisissons  $\epsilon > 0$  assez petit de sorte que pour tout  $x \in B(x^*, r) = \{z \in \mathbb{R}^n : \|z - x^*\| < \epsilon\}$  on a

$$f(x) = f(x^*) + g(x^*)^\top (x - x^*) + \frac{1}{2} (x - x^*)^\top H(x^*) (x - x^*) = f(x^*) + \frac{1}{2} (x - x^*)^\top H(x^*) (x - x^*),$$

puisque  $H(x^*)$  est défini positif, alors

$$f(x) - f(x^*) = \frac{1}{2} d^\top H(x^*) d > 0 \Rightarrow f(x) > f(x^*).$$

□

### 2.2.2 Le cas convexe

La convexité est d'un grand intérêt, car elle permet une caractérisation globale des extremums et elle permet aussi d'énoncé des résultats en absence de la différentiabilité.

**Définition 2.3.** Une fonction  $f$  définie sur un ensemble convexe  $X$ , est dite convexe si  $\forall x_1, x_2 \in X$ , et  $\forall \alpha \in ]0, 1[$  on a

$$f(\alpha x_1 + (1 - \alpha)x_2) \leq \alpha f(x_1) + (1 - \alpha)f(x_2). \quad (2.6)$$

Elle est dite strictement convexe si  $\forall x_1, x_2 \in X, x_1 \neq x_2$  et  $\forall \alpha \in ]0, 1[$  on a

$$f(\alpha x_1 + (1 - \alpha)x_2) < \alpha f(x_1) + (1 - \alpha)f(x_2). \quad (2.7)$$

Lorsqu'une fonction est différentiable, il y a d'autre manières de caractériser la convexité.

#### Caractérisation de la convexité

**Théorème 2.5.** Soit  $X$  un sous-ensemble ouvert et convexe de  $\mathbb{R}^n$ ,

1. Si  $f$  est de classe  $C^1$ , alors  $f$  est convexe sur  $X$  si et seulement si

$$f(x_2) \geq f(x_1) + g(x_1)^\top (x_2 - x_1), \forall x_1, x_2 \in X. \quad (2.8)$$

2. Si  $f$  est de classe  $C^2$ , alors  $f$  est convexe sur  $X$  si et seulement si  $H(x)$  est semi-définie positive dans tout  $X$ ,
3. Si  $H(x)$  est définie positive sur  $X$  alors  $f$  est strictement convexe sur  $X$ .

#### Conditions suffisantes d'optimalité du premier ordre

La convexité permet d'énoncer des conditions nécessaires et suffisantes d'optimalité pour des minimas globaux.

**Théorème 2.6.** On suppose que  $f$  est convexe sur  $\mathbb{R}^n$ , alors

1. Tout minimum local est aussi un minimum global.

2. Si  $f$  est différentiable en  $\bar{x} \in \mathbb{R}^n$  et si

$$g(\bar{x}) = 0. \quad (2.9)$$

alors  $\bar{x}$  est un minimum global.

**Démonstration.**

1. Soit  $\bar{x}$  un minimum local de  $f$  sur  $\mathbb{R}^n$ . S'il existe  $x \in \mathbb{R}^n$  tel que  $f(x) < f(\bar{x})$ , on peut écrire par convexité de  $f$  (pour  $\alpha \in ]0, 1[$ )

$$f(\alpha x + (1 - \alpha)\bar{x}) \leq \alpha f(x) + (1 - \alpha)f(\bar{x}) < f(\bar{x}),$$

ce qui contredit le fait que  $\bar{x}$  est un minimum local.

2. Soit  $\bar{x} \in \mathbb{R}^n$  tel que  $g(\bar{x}) = 0$ . Pour tout point  $x \neq \bar{x}$  dans  $\mathbb{R}^n$ , la convexité de  $f$  permet d'écrire

$$f(x) \geq f(\bar{x}) + g(\bar{x})^\top (x - \bar{x}), \quad \forall x \in \mathbb{R}^n,$$

Si de plus on a  $g(\bar{x}) = 0$ , alors pour tout  $x \in \mathbb{R}^n$ ,  $f(x) \geq f(\bar{x})$ . Donc  $\bar{x}$  est bien un minimum global.

□

**Remarque 2.2.** Les théorèmes 2.2, 2.3, 2.4, 2.5 et 2.6 restent valables si  $\mathbb{R}^n$  est remplacé par un ensemble  $X$ , ouvert (et convexe pour le théorème 2.6).

## 2.3 Algorithmes

Considérons maintenant le problème non linéaire sans contraintes (2.1), où l'on suppose que  $f$  est continûment différentiable sur  $\mathbb{R}^n$ .

### 2.3.1 Existence

Le fait que  $f$  soit minorée n'implique pas l'existence d'une solution à (2.1).

**Exemple 2.1.**  $f$  est minorée par 0 mais on ne peut jamais obtenir  $x \in \mathbb{R}$ , tel que  $f(x) = 0$ .

Il faut donc une hypothèse de plus, le lemme suivant va dans ce sens.

**Lemme 2.1.** *Soit  $f$  une fonction de classe  $C^2$ , s'il existe une constant  $m > 0$  vérifiant*

$$d^\top H(x)d \geq m \|d\|^2; \forall x, d \in \mathbb{R}^n.$$

*Alors, pour tout vecteur  $y \in \mathbb{R}^n$ , l'ensemble*

$$\mathcal{L} = \{x \in \mathbb{R}^n : f(x) \leq f(y)\}, \tag{2.10}$$

*est convexe et compact.*

**Démonstration.**

La fermeture de l'ensemble est une conséquence de la continuité de la la fonction  $f$ , même chose pour la convexité de l'ensemble résulte du fait que  $f$  l'est aussi. Par conséquent nous avons juste à prouver que l'ensemble est borné. Prenons  $d$  un vecteur dans  $\mathbb{R}^n$  tel que  $\|d\| = 1$ . Soit la fonction réelle  $\theta$  définie par

$$\theta(t) = f(y + td).$$

A partir des conditions sur  $f$  et la normalisation de  $d$ , on en déduit l'inégalité

$$\theta''(t) \geq m,$$

d'où il suit que la fonction définie par

$$\psi(t) = \theta(t) - \theta(0) - td^\top g(y) - \frac{1}{2}t^2m.$$

est convexe. Maintenant  $\psi$  est choisie pour satisfaire  $\psi(0) = \psi'(0) = 0$ , donc on en déduit l'inégalité

$$\theta(t) \geq \theta(0) + td^\top g(y) + \frac{1}{2}t^2m.$$

Mais le côté droit de cette inégalité est plus grand que



$\theta(0)$  si

$$|t| > 2 \frac{\|g(y)\|}{m} \geq 2 \frac{|d^\top g(y)|}{m}.$$

Par conséquent, et puisque le vecteur  $d$  est arbitraire,  $f(x) \geq f(y)$  si  $\|x - y\| > 2 \frac{\|g(y)\|}{m}$ . Par conséquent l'ensemble des points  $x$  satisfaisant la condition  $f(x) < f(y)$  est borné.

□

**Remarque importante :** Théoriquement, le but d'un algorithme de minimisation est l'identification d'un minimum, dans la pratique on est plus modeste, on se contente souvent de chercher un point stationnaire (c'est-à-dire un point qui vérifie l'équation (2.5)).

### 2.3.2 La méthode du gradient

On se propose de trouver une solution du problème (2.1). On remplace,  $f(x + d)$  par  $f(x) + g(x)^\top d$  (ce qui est possible pour  $\|d\|$  assez petit), Donc

$$f(x + d) = f(x) + g(x)^\top d. \quad (2.11)$$

Soit  $d_k$  une solution du problème approché correspondant

$$\begin{cases} \min g(x_k)^\top d, \\ \|d\| \leq 1, \end{cases} \quad (2.12)$$

ensuite  $x_{k+1}$  est rechercher le long de  $d_k$  c'est à dire

$$x_{k+1} = x_k + td_k.$$

#### Remarque 2.3.

- La contrainte  $\|d\| \leq 1$  est essentielle pour assurer une solution à (2.12) mais la longueur de la direction n'a aucune importance (on peu prendre  $\|d\| \leq a$ ), car elle sera corrigée par le choix du pas  $t$ .
- Il est possible de résoudre (2.12) suivant le choix de la norme  $\|\cdot\|$ .

**Cas de la norme  $l^1$** 

Dans ce cas,  $\|x\|_1 = \sum_{i=1}^{i=n} |x_i|$ . L'ensemble  $S = \left\{ d \in \mathbb{R}^n : \|d\|_1 = \sum_{i=1}^{i=n} |d_i| \leq 1 \right\}$  est un polyèdre de sommées

$$E = \{e_1, e_2, \dots, e_n, -e_1, -e_2, \dots, -e_n\},$$

où  $\{e_i\}_{1 \leq i \leq n}$  est une base de  $\mathbb{R}^n$ .




Figure 2.4: L'ensemble  $S$  dans  $\mathbb{R}^2$

Puisque la fonction  $d \rightarrow g(x_k)^\top d$  est linéaire alors le problème (2.12) est équivalent au problème d'optimisation linéaire (voir [2, 22])

$$\begin{cases} \min g(x_k)^\top d, \\ d \in E. \end{cases}$$

Et donc

$$(2.12) \iff \min_{1 \leq i \leq n} \{g_i(x_k), -g_i(x_k)\}$$

tel que,  $g(x_k) = (g_1(x_k), \dots, g_n(x_k))$ , donc

$$d_k = (0, 0, \dots, \varepsilon_i, 0, \dots, 0) = \varepsilon_i e_i,$$

où  $i$  et  $\varepsilon_i$  est donné par

$$\begin{cases} g_i(x_k) = \max \{ |g_j(x_k)| ; 1 \leq j \leq n \} \\ \varepsilon_i = -\frac{g_i(x_k)}{|g_i(x_k)|}. \end{cases}$$

Graphiquement la solution  $d_k$  est parallèle à un certain axe de coordonnées (correspondant à la plus grande composante du gradient). Posant  $\theta(t) = f(x_k + td_k)$  et cherchons  $t_k$  une solution du problème

$$\min_{t>0} \theta(t).$$

L'idée immédiate est de chercher une solution de

$$\theta'(t) = \frac{d}{dt} f(x_k + td_k) = g(x_k + td_k)^\top d_k = 0, \quad t > 0. \quad (2.13)$$

Or  $d_k$  est l'un des vecteurs de base (à un signe près), ce qui donne

$$\begin{aligned} g(x_k + td_k)^\top d_k &= g(x_k + \varepsilon_i t e_i)^\top (\varepsilon_i e_i) \\ &= \varepsilon_i g_i(x_k + \varepsilon_i t e_i) = 0, \quad i = 1, 2, \dots, n. \end{aligned}$$

C'est donc résoudre une seule composante du gradient, ce qui nous donne une interprétation de la méthode Gauss-Seidel. Maintenant on choisit parmi les solutions  $t_k$  possible celle qui donne

$$f(x_k + t_k d_k) < f(x_k).$$

### Cas de la norme $l^2$

Dans ce cas  $\|x\| = \|x\|_2 = \sqrt{\sum_{i=1}^n |x_i|^2}$ . Abordant un Lemme essentiel pour la suite.

**Lemme 2.2.** *Supposant que  $f$  est différentiable en  $x$  tel que  $g(x) \neq 0$ . Alors le problème d'optimisation*

$$\begin{cases} \min g(x)^\top d \\ \|d\| \leq 1 \end{cases}$$

admet une solution  $d_k = -\frac{g(x_k)}{\|g(x_k)\|}$

- On peut prendre  $d_k = -g(x_k)$  selon la remarque précédente
- Comme auparavant, posons  $\theta(t) = f(x_k + td_k)$  et cherchons  $t_k$  une solution de

$$\min_{t>0} \theta(t), \quad (2.14)$$

telle que  $\theta(t_k) < \theta(0)$

### L'algorithme de la plus profonde descente (Steepest Descent)

(i)  $d_k = -g(x_k)$

(ii)  $t_k$  solution de

$$\min_{t>0} \theta(t)$$

qui vérifie

$$\theta(t_k) < \theta(0)$$

(iii)  $x_{k+1} = x_k + t_k d_k$

**Remarque 2.4.** La méthode (i), (ii), (iii) donne une interprétation directe de la méthode des approximations successive vue en (1.5.2) de plus, (ii) permet de calculer avec précision le pas  $t_k$ , contrairement au théorème 1.4.

- La contrainte  $t > 0$  est justifier par le fait que si  $t_k = 0$

$$\theta'(0) = g(x_k)^\top d_k = g(x_k)^\top (-g(x_k)) = -\|g(x_k)\|^2 = 0 \Rightarrow g(x_k) \equiv 0$$

et on aura  $x_{k+1} = x_k$

- Dans les deux cas (la norme  $l^1$  ou  $l^2$ ) on voit bien que le vecteur  $d_k$  est une direction de descente puisque  $g(x_k)^\top d_k < 0$

### 2.3.3 Étude globale de la convergence

Il est plus intéressant de démontrer la convergence d'une variante de la méthode (i),(ii),(iii) où le pas  $t_k$  est calculé de façon plus général, considérons au lieu de (ii)

(ii')  $t_k$  est tel que

$$\theta(t_k) \leq \theta(t_k^*), \quad (2.15)$$

où  $t_k^*$  est la plus petite solution de (2.14)

Pour la convergence de cette méthode, nous reprenons une proposition dû à [3].

**Proposition 2.1.** *On suppose le gradient  $g$  lipschitzien sur la tranche*

$$\mathcal{L} = \{x \in \mathbb{R}^n : f(x) \leq f(x_0)\}.$$

Alors la méthode définie par (i), (ii') et (iii), satisfait à

- Soit  $f(x_k)$  est non bornée inférieurement.
- Soit  $g(x_k) \rightarrow 0$ .

**Démonstration.** Observons que  $\theta(t)$  est décroissante sur  $]0, t_k^*]$  puisque

$$\begin{cases} \theta'(0) < 0 \\ \theta'(t) \text{ continue (} g \text{ continue)} \\ t_k^* \text{ est le premier zero de } \theta'(t) = 0, t > 0 \end{cases} \Rightarrow \theta'(t) < 0, \forall t \in ]0, t_k^*]$$

Donc  $t_k^*$  est le plus petit minimum de  $\theta(t)$ ,  $t > 0$  Si on pose  $x^* = x_k + t_k^* d_k$ , on a :  $x^*, x_k \in \mathcal{L}$  (par construction).

(1) On va montrer que dans le voisinage de  $t = 0$ ,  $f(x_k + td_k)$  décroît sensiblement. Prenons  $z = x_k + td_k$ ,  $t > 0$  assez petit de façon à ce que  $z \in \mathcal{L}$ , la formule de la moyenne pour  $z'$  entre  $x_k$  et  $z$  donne

$$\begin{aligned} f(z) &= f(x_k) + g(z')^\top (z - x_k) = f(x_k) + (g(z') - g(x_k))^\top (z - x_k) + \\ &\quad + g(x_k)^\top (z - x_k). \end{aligned} \quad (2.16)$$

Puisque  $z' \in \mathcal{L}$ , du fait que  $z' = x_k + \tau d_k$ ,  $\tau \in ]0, t]$ , alors

$$f(z') \leq f(z) \leq f(x_k)$$

$g$  est lipschitzien sur  $\mathcal{L}$  et grâce l'inégalité de Cauchy-Schwarz on a

$$\begin{aligned} (g(z') - g(x_k))^\top (z - x_k) &\leq \|g(z') - g(x_k)\| \|z - x_k\| \leq M \|z' - x_k\| \|z - x_k\| \\ &\leq M \|z - x_k\|^2, \end{aligned}$$

donc

$$\begin{aligned} f(z) &\leq f(x_k) - \|g(x_k)\| \|z - x_k\| + M \|z - x_k\|^2, \\ f(z) &\leq f(x_k) + (M t^2 - t) \|g(x_k)\|^2, \end{aligned}$$

Si on prend  $t \leq \frac{1}{2M}$ , alors  $M t^2 \leq t/2$  et donc pour  $t \leq \min\{t_k^*, \frac{1}{2M}\}$ , on a

$$f(z) \leq f(x_k) - \frac{t}{2} \|z - x_k\|.$$

Ce qui démontre (1).

**(2) Minoration de  $t_k$ .** Soit  $x^* = x_k + t_k^* d_k$ , On a  $g(x^*)^\top d_k = \theta'(t_k^*) = 0$ . Donc

$$0 = g(x^*)^\top (x^* - x_k) = (g(x^*) - g(x_k))^\top (x^* - x_k) + g(x_k)^\top (x^* - x_k).$$

En utilisant les mêmes techniques qu'en (1), on obtient

$$0 \leq \|x^* - x_k\| [M \|x^* - x_k\| - \|g(x_k)\|]$$

et donc

$$\|x_{k+1} - x_k\| \geq \|x^* - x_k\| \geq \frac{\|g(x_k)\|}{M}.$$

Puisque

$$0 < t_k^* \|g(x_k)\| = \|x^* - x_k\| \leq \|x_{k+1} - x_k\| = t_k \|g(x_k)\|,$$

du fait que  $t_k^* \leq t_k$  (rappelons que  $\theta$  est décroissante dans  $]0, t_k^*]$  et de (ii')).

D'où (2) à savoir

$$\|x_{k+1} - x_k\| \geq \|x^* - x_k\| \geq \frac{\|g(x_k)\|}{M}.$$

Maintenant, prenons  $t \leq \frac{\|g(x_k)\|}{2M} \Rightarrow z = x_k + td_k$  d'après (2),  $z$  est entre  $x_k$  et  $x^*$  donc

$$z = x_k + td_k, t \in ]0, t_k^*] \Rightarrow f(z) = \theta(t) \geq \theta(t_k^*) = f(x^*).$$

Et de (ii') on a

$$f(x_{k+1}) = \theta(t_k) \leq \theta(t_k^*) = f(x^*),$$

ce qui donne

$$f(x_{k+1}) \leq f(x^*) \leq f(z) \Rightarrow f(x_{k+1}) \leq f(z). \quad (2.17)$$

De l'argument (1) et (2.17)

$$f(z) \leq f(x_k) - \frac{\|g(x_k)\|^2}{4M},$$

donc  $\|g(x_k)\|^2 \leq 4M[f(x_k) - f(z)] \leq 4M[f(x_k) - f(x_{k+1})]$ , ce qui implique

$$\sum_{i=1}^{i=k} \|g(x_i)\| \leq 4M[f(x_1) - f(x_{k+1})].$$

Si  $f$  est bornée inférieurement on a  $[f(x_1) - f(x_{k+1})] \leq C, \forall k \in \mathbb{N}^*$  ce qui donne

$$\sum_{i=1}^{i=\infty} \|g(x_i)\| \leq C \Rightarrow g(x_k) \rightarrow 0.$$

□

### 2.3.4 Etude locale de la convergence

Maintenant, on va analyser la convergence locale de cette méthode, c'est-à-dire la vitesse de convergence des suites générées par l'algorithme au voisinage du point optimum.

**Théorème 2.7.** *Si  $f$  est quadratique de la forme  $f(x) = \frac{1}{2}x^\top Qx - b^\top x$ , avec  $Q \in \mathcal{M}_n$  symétrique définie positive,  $b \in \mathbb{R}^n$ , la méthode "steepest descent" (i),(ii),(iii), converge vers la solution du problème avec une vitesse linéaire de rapport*

$$r = \frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1},$$

où  $\lambda_n = \max(\sigma(Q))$  et  $\lambda_1 = \min(\sigma(Q))$ .

**Démonstration.** La condition suffisante d'optimalité (CS2) permet d'identifier la solution de (2.1), il suffit de résoudre l'équation (2.13), ce qui donne

$$t_k = \frac{g(x_k)^\top g(x_k)}{g(x_k)^\top Q g(x_k)}. \quad (2.18)$$

Avec un calcul simple, on trouve

$$f(x_{k+1}) = \left[ 1 - \frac{(g(x_k)^\top g(x_k))^2}{(g(x_k)^\top Q g(x_k))(g(x_k)^\top Q^{-1} g(x_k))} \right] f(x_k) \quad (2.19)$$

En utilisant (iii) et grâce à l'inégalité de Kantorovich [22]

$$\frac{\|x\|^4}{\|x\|_Q^2 \|x\|_{Q^{-1}}^2} \geq \frac{4\lambda_1\lambda_n}{(\lambda_1 + \lambda_n)^2}$$

on a

$$f(x_{k+1}) \leq \left[ \frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1} \right]^2 f(x_k). \quad (2.20)$$

□

**Remarque 2.5.** L'inégalité (2.10) montre que la vitesse de convergence de la suite  $\{f(x_k)\}$  est linéaire, et elle dépend clairement du rapport  $\frac{\lambda_n}{\lambda_1}$ . Si ce dernier est très grand (dans le cas d'une matrice  $Q$ , mal conditionnée) le terme

$$\frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1}$$

s'approchera du 1 donc, la convergence est sous-linéaire.

Dans un cadre plus général (fonction  $f$  non-linéaire), l'analyse précédente reste valable, car en s'approchant de l'optimum  $x^*$ , la fonction  $f$  peut être approximée quadratiquement par

$$f(x) \approx f(x^*) + g(x^*)^\top (x - x^*) + \frac{1}{2}(x - x^*)^\top H(x^*)(x - x^*)$$

où le hessien  $H(x^*)$  est maintenant définie positive.

**Algorithme 2.1.**



**Etape 0 (Initialisation) :**  $x_0$  et  $\varepsilon > 0$  donnée,  $k = 0$

**Etape 1 :** Test d'arrêt : calculer  $g(x_k)$ , si  $\|g(x_k)\| < \varepsilon$  alors stop sinon

**Etape 2 :** Calcul de la direction  $d_k = -g(x_k)$

**Etape 3 :** Recherche linéaire : Trouver  $t_k$  qui vérifie "les bonnes hypothèses" en particulier  $f(x_k + t_k d_k) < f(x_k)$

**Etape 4 :** Si la recherche linéaire réussie  $x_{k+1} = x_k + t_k d_k$ , remplacer  $k$  par  $k + 1$  et aller en 1.

**Remarque 2.6.** Dans ce schéma, tout est clair sauf l'étape 3, qui ne dit ni quelle condition précise doit vérifier le pas  $t_k$ , ni comment le trouver. La recherche du pas s'effectue en fait par une sous-itération sur  $t > 0$  durant laquelle s'établit un dialogue avec un sous programme qui se charge de calculer  $t_k$ . Le problème de la recherche linéaire est suffisamment important pour justifier le chapitre suivant à lui tout seul.

## Exercices

**Exercice 2.1.** Calculer le gradient  $g(x)$  et le hessien  $g(x)$  de la fonction Rosenbrock

$$f(x) = 100(y - x^2)^2 + (1 - x_1)^2.$$

Montrer que  $x^* = (1, 1)^T$  est le seul minimum local de cette fonction. Montrer que la fonction  $f(x) = 8x_1 + 12x_2 + x_1^2 - 2x_2^2$  a un seul point stationnaire, et que ce n'est ni un maximum et ni un minimum, mais un point de selle. "Croquiser" les courbes à niveaux de  $f$ .

**Exercice 2.2.** Considérons la fonction  $f : \mathbb{R}^2 \rightarrow \mathbb{R}$  définie par  $f(x) = \|x\|^2$ . Montrer que la suite d'itérations  $\{x_k\}$  définie par

$$x_{k+1} = \left(1 + \frac{1}{2^k}\right) \begin{pmatrix} \cos(k) \\ \sin(k) \end{pmatrix},$$

satisfait  $f(x_{k+1}) < f(x_k)$ ,  $k = 1, 2, \dots$  que tout point sur le cercle unité  $\{x : \|x\| = 1\}$  est un point limite de  $\{x_k\}$ . Astuce : Chaque valeur  $\theta \in [0, 2\pi]$  est un point limite de la sous-suite

$$\xi_i = k \pmod{2\pi} = k - 2\pi \left\lfloor \frac{k}{2\pi} \right\rfloor,$$

où l'opérateur  $[ \cdot ]$  est la partie entière d'un réel.

**Exercice 2.3.** Montrer que tous les minimas locaux isolés sont strictes.

**Exercice 2.4.** Supposons que  $f$  est une fonction convexe. Montrer que l'ensemble des minimas globaux de  $f$  est un ensemble convexe.

**Exercice 2.5.** Considérons la fonction  $f(x_1, x_2) = (x_1 + x_2^2)^2$ . Au point  $x^T = (1, 0)$ , nous considérons la direction  $d^T = (-1, 1)$ . Montrer que  $d$  est une direction de descente et trouver toutes les minimas du problème

$$\min_{t>0} f(x + t d).$$

**Exercice 2.6.** Supposons que  $\tilde{f}(z) = f(x)$ , où  $x = Sz + s$  pour un certain  $S \in \mathbb{R}^{n \times m} = \mathcal{M}^{n \times m}$  et  $s \in \mathbb{R}^n$ . Montrer que

$$\tilde{g}(z) = \nabla \tilde{f}(z) = S^T \nabla f(x), \quad \tilde{H}(z) = \nabla^2 \tilde{f}(z) = S^T H(x) S.$$