

# Méthode du gradient

Hamza Ennaji

22 mars 2024

## ❖ Directions de descente

**Définition 1.** Soit  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  une fonction de classe  $C^1$ . On dit qu'un vecteur non nul  $\mathbf{d}$  de  $\mathbb{R}^n$  est une direction de descente de  $f$  en  $x$  si

$$f'(x; \mathbf{d}) = \nabla f(x)^T \mathbf{d} < 0.$$

Il se trouve que suivre des directions de descentes avec un pas suffisamment petit, on arrive à décroître la fonction objective. On a le résultat suivant :

**Lemme 1.** Soit  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  une fonction de classe  $C^1$  et  $\mathbf{d}$  une direction de descente de  $f$  en  $x \in \mathbb{R}^n$ . Alors, il existe  $\epsilon > 0$  tel que

$$f(x + t\mathbf{d}) < f(x),$$

pour tout  $t \in (0, \epsilon]$ .

**Preuve.** Laissez en exercice. □

D'une façon générale, une méthode de descente s'écrit comme suit

### Méthode de descente

- Initialisation : On se donne un  $x_0 \in \mathbb{R}^n$ .
- Pour  $k \geq 0$ 
  - Choisir une direction de descente  $\mathbf{d}_k$ .
  - Choisir un pas  $t_k$  tel que :  $f(x + t_k \mathbf{d}_k) < f(x)$ .
  - Prendre  $x_{k+1} = x_k + t_k \mathbf{d}_k$ .
  - Si un critère d'arrêt est vérifié, renvoyer  $x_{k+1}$ .

**Remarque.** — Le choix de la direction de descente donne lieu à des méthodes différentes de descentes (e.g., gradient, gradient conjugué, Newton, quasi-Newton etc).

- Il existe plusieurs critères d'arrêt, le plus utilisé est  $\|\nabla f(x_{k+1})\| \leq \epsilon$  pour une tolérance  $\epsilon > 0$  donnée.
- Le procédé permettant de trouver le pas  $t_k$  s'appelle **recherche linéaire** (line search en anglais). L'appellation vient du fait que ça revient à minimiser la fonction  $g(t) = f(x_k + t\mathbf{d}_k)$ . On discute ici quelques choix populaires.

1. **Pas constant** : dans ce cas  $t_k = \bar{t}$  pour tout  $k$ . Bien que c'est un choix simple, un pas trop petit peut donner lieu à une convergence lente de l'algorithme tandis qu'un pas grand on peut perdre la décroissance de la fonction objective. (c.f. TP).
2. **Recherche linéaire exacte** : dans ce cas on cherche à minimiser exactement la fonction  $g(t)$  définie ci-dessus. On choisit donc  $t_k \in \operatorname{argmin}_{t \geq 0} f(x_k + t\mathbf{d}_k)$ . Il se trouve qu'en général, on ne peut pas trouver le minimiseur exacte de  $g$ .
3. **Backtracking** : cette approche est permet d'éviter une recherche linéaire exacte de en choisissant convenablement un pas assurant la décroissance de la fonction objective. L'approche requiert trois paramètres  $s > 0$  et  $\alpha, \beta \in (0, 1)$ . Dans un premier temps on prend  $t_k = s$  et tant que

$$f(x_k) - f(x_k + t_k \mathbf{d}_k) < -\alpha t_k \nabla f(x_k)^T \mathbf{d}_k$$

on met à jour  $t_k$  par  $t_k \beta$ . Dans ce cas, le pas choisi serait  $t_k = s \beta^{i_k}$  où  $i_k$  est le plus petit entier tel que

$$f(x_k) - f(x_k + t_k \mathbf{d}_k) \geq -\alpha s \beta^{i_k} \nabla f(x_k)^T \mathbf{d}_k$$

L'exemple suivant présente le cas d'une recherche linéaire exacte pour une fonction quadratique.

**Exemple.** On considère  $f(x) = x^T A x + 2b^T x + c$  avec  $A \in \mathcal{S}_n^{++}$ ,  $b \in \mathbb{R}^n$ ,  $c \in \mathbb{R}$ . Soit  $x \in \mathbb{R}^n$  et  $\mathbf{d} \in \mathbb{R}^n \setminus \{0\}$  une direction de descente de  $f$  en  $x$ . Effectuer une

recherche linéaire exacte revient à résoudre

$$\min_{t \geq 0} f(x + t\mathbf{d}) := g(t).$$

On a  $g'(t) = t\mathbf{d}^T \nabla f(x + t\mathbf{d})$  et comme  $\nabla f(x) = 2(Ax + b)$ , on trouve que  $g'(t) = 2(\mathbf{d}^T A\mathbf{d})t + 2\mathbf{d}^T \nabla f(x)$ . Donc

$$g'(t) = 0 \Leftrightarrow t = -\frac{\mathbf{d}^T \nabla f(x)}{2\mathbf{d}^T A\mathbf{d}} > 0.$$

Comme  $g''(t) = 2(\mathbf{d}^T A\mathbf{d}) > 0$  alors le pas donné par la méthode de recherche linéaire exacte est  $t^* = -\frac{\mathbf{d}^T \nabla f(x)}{2\mathbf{d}^T A\mathbf{d}}$ .

## ❖ Descente de gradient

### ❖ La méthode

Comme son nom l'indique, le choix de la direction de descente dans la méthode du gradient est  $d_k = -\nabla f(x_k)$ . Ce choix est bien une direction de descente au sens de la Définition-1. En effet, pour  $\nabla f(x_k) \neq 0$  :

$$f'(x_k; -\nabla f(x_k)) = -\nabla f(x_k)^T \nabla f(x_k) = -\|\nabla f(x_k)\|^2 < 0.$$

On présente ci-dessous les étapes de la méthode, avec comme critère d'arrêt  $\|\nabla f(x_{k+1})\| \leq \epsilon$  pour une tolérance  $\epsilon$  donnée.

#### Méthode du gradient

- Initialisation : On se donne un  $x_0 \in \mathbb{R}^n$ .
- Pour  $k \geq 0$ 
  - Choisir un pas  $t_k$  par recherche linéaire sur  $g(t) = f(x_k - t\nabla f(x_k))$ .
  - Prendre  $x_{k+1} = x_k - t_k \nabla f(x_k)$ .
  - Si  $\|\nabla f(x_{k+1})\| \leq \epsilon$  s'arrêter et renvoyer  $x_{k+1}$ .

## ❖ Analyse de convergence

Avons de commencer notre analyse, rappelons qu'une fonction  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  est dans  $C_L^{1,1}(\mathbb{R}^n)$  si elle est de classe  $C^1$  et que son gradient  $\nabla f : \mathbb{R}^n \rightarrow \mathbb{R}^n$  est  $L$ -Lipschitz, i.e.,

$$\|\nabla f(x) - \nabla f(y)\| \leq L\|x - y\| \text{ pour tout } x, y \in \mathbb{R}^n.$$

**Exemple.** — On vérifie facilement que  $f(x) = a^T x + b \in C_0^{1,1}(\mathbb{R}^n)$ .

— Un fonction quadratique  $f(x) = x^T A x + 2b^T x + c$  avec  $A \in \mathcal{S}_n, b \in \mathbb{R}^n$  et  $c \in \mathbb{R}$  est  $2\|A\|$ -Lipschitz. En effet, comme  $\nabla f(x) = 2Ax + b$  on a

$$\|\nabla f(x) - \nabla f(y)\| = 2\|(Ax + b) - (Ay + b)\| \leq 2\|A\|\|x - y\|.$$

Si la fonction est  $C^2$  alors régularité Lipschitz du gradient est équivalente au fait que la Hessienne est bornée :

**Théorème 1.** Soit  $f \in C^2(\mathbb{R}^n)$ . Alors


$$f \in C_L^{1,1}(\mathbb{R}^n) \Leftrightarrow \|\nabla^2 f(x)\| \leq L \text{ pour tout } x \in \mathbb{R}^n.$$

Le résultat suivant joue un rôle important dans la suite.

**Lemme 2** (Lemme de descente). Soit  $f \in C_L^{1,1}(\mathbb{R}^n)$ . Alors pour tout  $x, y \in \mathbb{R}^n$

$$f(y) \leq f(x) + \nabla f(x)^T (y - x) + \frac{L}{2} \|x - y\|^2.$$

**Preuve.** Voir TD. □



Fixons  $x \in \mathbb{R}^n$  et considérons  $h_x(y) = f(x) + \nabla f(x)^T (y - x) + \frac{L}{2} \|x - y\|^2$  qui est quadratique en  $y$  et majore  $f$  :  $f(y) \leq h_x(y)$  pour tout  $y \in \mathbb{R}^n$ . En plus, le minimum de  $h_x$  est atteint en  $x^* = x - \frac{1}{L} \nabla f(x)$  (see Figure-??).

Comme conséquence du Lemme-2, on a

**Lemme 3.** Soit  $f \in C_L^{1,1}(\mathbb{R}^n)$ . Alors pour tout  $x \in \mathbb{R}^n$  et  $t > 0$

$$f(x) - f(x - t\nabla f(x)) \geq t \left(1 - \frac{tL}{2}\right) \|\nabla f(x)\|^2. \quad (1)$$

**Preuve.** On applique le Lemme de descente avec  $y = x - t\nabla f(x)$  pour un  $x \in \mathbb{R}^n$ . On a donc

$$f(x - t\nabla f(x)) \leq f(x) + t\nabla f(x)^T \nabla f(x) + \frac{Lt^2}{2} \|\nabla f(x)\|^2.$$

□

Si nous optons pour une stratégie avec un pas constant, i.e.,  $t_k = t_* \in (0, 2/L)$  pour tout  $k$ , on a alors d'après Lemme-3

$$f(x_k) - f(x_{k+1}) \geq t_* \left(1 - \frac{t_*L}{2}\right) \|\nabla f(x_k)\|^2.$$

La fonction  $t \mapsto t \left(1 - \frac{tL}{2}\right)$  sur  $(0, 2/L)$  atteint un maximum en  $t^* = 1/L$ . Pour ce choix on a  $x_{k+1} = x_k - \frac{1}{L}\nabla f(x_k)$  et

$$f(x_k) - f(x_{k+1}) \geq \frac{1}{2L} \|\nabla f(x_k)\|^2.$$

Pour une recherche linéaire exacte, i.e.,  $x_{k+1} = x_k - t_k \nabla f(x_k)$  avec

$$t_k \in \operatorname{argmin}_{t \geq 0} f\left(x_k - t \nabla f(x_k)\right),$$

on remarque que  $f(x_k - t_k \nabla f(x_k)) \leq f\left(x_k - \frac{1}{L} \nabla f(x_k)\right)$  soit

$$f(x_k) - f(x_{k+1}) \geq f(x_k) - f\left(x_k - \frac{1}{L} \nabla f(x_k)\right) \geq \frac{1}{2L} \|\nabla f(x_k)\|^2.$$

Dans le cadre de backtracking, on cherche pour  $\alpha \in (0, 1)$ , un pas  $t_k$  suffisamment petit tel que

$$f(x_k) - f(x_{k+1}) \geq \alpha t_k \|\nabla f(x_k)\|^2.$$

Dans ce cas deux options se présentent : prendre  $t_k = s$  où  $s > 0$  est la valeur initiale du pas, soit prendre  $t_k$  avec la méthode de backtracking comme décrit dans la remarque-, et dans ce cas, le choix  $t_k = t_k/\beta$  ne serait pas admissible, i.e.,

$$f(x_k) - f\left(x_k - \frac{t_k}{\beta} \nabla f(x_k)\right) < \frac{\alpha t_k}{\beta} \|\nabla f(x_k)\|^2. \quad (2)$$

En appliquant (15) avec  $x = x_k$  et  $t = \frac{t_k}{\beta}$  on obtient

$$f(x_k) - f\left(x_k - \frac{t_k}{\beta} \nabla f(x_k)\right) \geq \frac{t_k}{\beta} \left(1 - \frac{t_k L}{\beta}\right) \|\nabla f(x_k)\|^2. \quad (3)$$

Les équations (2)-(3) impliquent que  $\frac{t_k}{\beta} \left(1 - \frac{t_k L}{\beta}\right) < \frac{\alpha t_k}{\beta}$ , soit  $t_k > \frac{2(\alpha-1)\beta}{L}$ . Finalement, pour la méthode de backtracking, on a

$$f(x_k) - f\left(x_k - t_k \nabla f(x_k)\right) \geq \alpha \min\left(s, \frac{2(\alpha-1)\beta}{L}\right) \|f(x_k)\|^2.$$

On récapitule cette discussion dans le résultat suivant :

**Proposition 1.** Soit  $f \in C_L^{1,1}(\mathbb{R}^n)$  et  $(x_k)_k$  la suite générée par la méthode du gradient pour résoudre

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

avec pas constant, recherche linéaire exacte et backtracking de paramètres  $s > 0, \alpha, \beta \in (0, 1)$ . Alors

$$f(x_k) - f\left(x_k - \frac{t_k}{\beta} \nabla f(x_k)\right) \geq M \|\nabla f(x_k)\|^2, \quad (4)$$

avec

$$M = \begin{cases} t^* \left(1 - \frac{t^* L}{2}\right) & \text{pas constant,} \\ \frac{1}{2L} & \text{recherche linéaire exacte,} \\ \alpha \min\left(s, \frac{2(\alpha-1)\beta}{L}\right) & \text{backtracking.} \end{cases}$$

On démontre maintenant que  $\|\nabla f(x_k)\| \rightarrow 0$  quand  $k \rightarrow \infty$ .

**Théorème 2.** Soit  $f \in C_L^{1,1}(\mathbb{R}^n)$  et  $(x_k)_k$  la suite générée par la méthode du gradient pour résoudre

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

avec pas constant, recherche linéaire exacte et backtracking de paramètres  $s > 0, \alpha, \beta \in (0, 1)$ . Supposons que  $f$  est minorée, i.e., il existe  $c > 0$  tel que  $f(x) > c$  pour tout  $x \in \mathbb{R}^n$ . Alors

1. La suite  $(f(x_k))_k$  est décroissante, avec  $f(x_{k+1}) < f(x_k)$  sauf si  $\|\nabla f(x_k)\| = 0$ .
2.  $\|f(x_k)\| \rightarrow 0$  quand  $k \rightarrow \infty$ .

**Preuve.** 1. On a grâce à (4)

$$f(x_k) - f\left(x_k - \frac{t_k}{\beta} \nabla f(x_k)\right) \geq M \|\nabla f(x_k)\|^2 \geq 0, \quad (5)$$

pour  $M > 0$ . Donc  $(f(x_k))_k$  est décroissante et  $f(x_k) = f(x_{k+1})$  ne peut avoir lieu que si  $\nabla f(x_k) = 0$ .

2. Comme la suite  $(f(x_k))_k$  est décroissante et  $f$  minorée, alors elle est convergente, i.e.,  $f(x_k) - f(x_{k+1}) \xrightarrow{k \rightarrow \infty} 0$ . Cela implique avec (5) que  $\|\nabla f(x_k)\| \rightarrow 0$  quand  $k \rightarrow \infty$ .

□

On termine cette section avec le résultat suivant permettant d'avoir des taux de convergence de la norme du gradient.

**Théorème 3.** Sous les mêmes hypothèses, on a pour tout  $n \geq 0$

$$\min_{k=0, \dots, n} \|\nabla f(x_k)\| \leq \sqrt{\frac{f(x_0) - f^*}{M(n+1)}}, \quad (6)$$

où  $f^*$  est la limite de la suite  $(f(x_k))_k$  et la constante  $M$  donnée dans Proposition-1.

**Preuve.** En sommant de 0 à  $n$  dans l'inégalité (4), on obtient

$$f(x_0) - f(x_{n+1}) = \sum_{k=0}^n f(x_k) - f(x_{k+1}) \geq M \sum_{k=0}^n \|\nabla f(x_k)\|^2.$$

Par définition,  $f^* \leq f(x_{k+1})$ , et par la suite

$$f(x_0) - f^* \geq M \sum_{k=0}^n \|\nabla f(x_k)\|^2 \geq M \min_{k=0, \dots, n} \|\nabla f(x_k)\|^2 \sum_{k=0}^n 1,$$

soit

$$f(x_0) - f^* \geq M(n+1) \min_{k=0, \dots, n} \|\nabla f(x_k)\|^2.$$

Finalement  $\min_{k=0, \dots, n} \|\nabla f(x_k)\| \leq \sqrt{\frac{f(x_0) - f^*}{M(n+1)}}$ , comme voulu. □

## ❖ Méthode de Newton

Avant de présenter la méthode de Newton comme une méthode de décente, rappelons la méthode de Newton pour trouver les zéros d'une fonction réelle. Soit donc  $f : \mathbb{R} \rightarrow \mathbb{R}$ , on cherche à résoudre l'équation  $f(t) = 0$ . L'idée est de remplacer  $f$  par son approximation de premier ordre en un point  $t_0$ , i.e., résoudre  $\tilde{f}(t) = f(t_0) + (t - t_0)f'(t_0) = 0$  au lieu de  $f(t) = 0$ . Si  $f'(t_0) \neq 0$ , on obtient  $t = t_0 - \frac{f(t_0)}{f'(t_0)}$ . Les itérations de Newton s'écrivent

$$t_{k+1} = t_k - \frac{f(t_k)}{f'(t_k)}.$$

Maintenant, soit  $g : \mathbb{R}^n \rightarrow \mathbb{R}^n$ . On s'intéresse au système linéaire  $g(x) = 0$ . De la même manière, en approchant  $g$  à l'ordre un autour d'un point  $x_0 \in \mathbb{R}^n$ , i.e.,  $g(x_0) + \nabla g(x_0)(x - x_0) = 0$ . On obtient

$$\tilde{g}(x) := g(x_0) + \nabla g(x_0)(x - x_0) = 0 \Rightarrow x = x_0 - \left(\nabla g(x_0)\right)^{-1} g(x_0).$$

L'équation ci-dessus suppose évidemment que  $\det(\nabla g(x_0)) \neq 0$ . De même, on peut construire une suite  $(x_k)_k$  qui approchera, à priori le zéro de  $g$ , en définissant

$$x_{k+1} = x_k - \left(\nabla g(x_k)\right)^{-1} g(x_k). \quad (7)$$

Maintenant, revenons à notre problème d'optimisation

$$\min_{x \in \mathbb{R}^n} f(x). \quad (8)$$

On s'intéresse ici au système linéaire  $\nabla f(x) = 0$ . Rappelons que lorsque  $f$  est convexe, la conditions  $\nabla f(x^*) = 0$  est nécessaire et suffisante pour dire que  $x^*$  minimise  $f$ . On applique (7) avec  $g = \nabla f$ , pour trouver

$$x_{k+1} = x_k - \left(\nabla^2 f(x_k)\right)^{-1} \nabla f(x_k). \quad (9)$$

Ceci est une façon pour faire le lien entre Newton et Newton...

Une autre façon pour retrouver (12) est la suivante. Supposons que  $f$  est  $C^2$  et que  $\nabla^2 f(x) \in \mathcal{S}_n^{++}$  pour tout  $x \in \mathbb{R}^n$ . On cherchera donc à minimiser l'approximation d'ordre deux de  $f$  autour d'un certain  $x_0 \in \mathbb{R}^n$ , i.e., remplacer  $f$

$$\tilde{f}(x) = f(x_0) + (x - x_0)^T \nabla f(x_0) + \frac{1}{2}(x - x_0)^T \nabla^2 f(x_0)(x - x_0) \quad (10)$$



dans le problème (8). Donc étant donnée une itérée  $x_k$ ,  $x_{k+1}$  est obtenue comme suit

$$x_{k+1} = \operatorname{argmin}_{x \in \mathbb{R}^n} \left\{ f(x_k) + (x - x_k)^T \nabla f(x_k) + \frac{1}{2} (x - x_k)^T \nabla^2 f(x_k) (x - x_k) \right\}. \quad (11)$$

L'unique minimiseur de (11) est en fait l'unique point stationnaire, et on a

$$\nabla \tilde{f}(x_{k+1}) = 0 \Leftrightarrow \nabla f(x_k) + \nabla^2 f(x_k)(x_{k+1} - x_k) = 0,$$

ce qui donne

$$x_{k+1} = x_k - \left( \nabla^2 f(x_k) \right)^{-1} \nabla f(x_k). \quad (12)$$

La méthode de Newton est donc une méthode de descente avec comme direction  $d_k = -\left( \nabla^2 f(x_k) \right)^{-1} \nabla f(x_k)$ .

Il se trouve que sous certaines conditions de régularité sur la Hessienne, on peut obtenir autour de la solution optimale un taux de convergence quadratique.

**Théorème 4.** Soit  $f \in C^2(\mathbb{R}^n)$  et supposons que :

1. il existe  $m > 0$  tel que  $\nabla^2 f(x) \geq mI_n$  pour tout  $x \in \mathbb{R}^n$ ,
2. il existe  $L > 0$  tel que

$$\|\nabla^2 f(x) - \nabla^2 f(y)\| \leq L\|x - y\|$$

pour tout  $x, y \in \mathbb{R}^n$ .

Alors

$$\|x_{k+1} - x^*\| \leq \frac{L}{2m} \|x_k - x^*\|^2,$$

où  $(x_k)_k$  est la suite générée par la méthode de Newton et  $x^*$  l'unique minimiseur de  $f$  sur  $\mathbb{R}^n$ . De plus, si  $\|x_0 - x^*\| \leq m/L$ , alors

$$\|x_k - x^*\| \leq \frac{2m}{L} \left( \frac{1}{2} \right)^{2^k}, \quad k \geq 0.$$

**Preuve.** Laissez en exercice. □

## ❖ Méthode de gradient projeté

### 6.1 Cas général

On s'intéresse ici à des problèmes du type

$$\min_{x \in C} f(x), \quad (13)$$

où  $C \subset \mathbb{R}^n$  est un convexe fermé et  $f : C \rightarrow \mathbb{R}$  de classe  $C^1$ . Il se trouve qu'on peut caractériser les points stationnaires de (16) en terme de l'opérateur de projection orthogonale.

**Théorème 5.** Soit  $f : C \rightarrow \mathbb{R}$  de classe  $C^1$  où  $C$  est un convexe fermé et  $s > 0$ . Alors  $x^*$  est un point stationnaire de (16) si et seulement si

$$x^* = P_C(x^* - s\nabla f(x^*)). \quad (14)$$

**Preuve.** Laissée en exercice.  $\square$

L'équation (14) affirme que  $x^*$  est point fixe de l'application  $x \mapsto P_C(x - s\nabla f(x))$ . Cela suggère des algorithmes du type point fixe pour résoudre (14), et donc (16).

#### Méthode du gradient projeté

On se donne une tolérance  $\epsilon > 0$ .

- Initialisation : On se donne un  $x_0 \in C$ .
- Pour  $k \geq 0$ 
  - Choisir un pas  $t_k$  par recherche linéaire.
  - Prendre  $x_{k+1} = P_C(x_k - t_k \nabla f(x_k))$ .
  - Si  $\|x_k - x_{k+1}\| \leq \epsilon$ , renvoyer  $x_{k+1}$ .

On démontre un résultat similaire au Lemme-3.

**Lemme 4.** Soit  $f \in C_L^{1,1}(\mathbb{R}^n)$ . Alors pour tout  $x \in \mathbb{R}^n$  et  $t > 0$

$$f(x) - f(P_C(x - t\nabla f(x))) \geq t \left(1 - \frac{tL}{2}\right) \left\| \nabla \frac{1}{t}(x - P_C(x - t\nabla f(x))) \right\|^2. \quad (15)$$

**Preuve.** Il suffit d'appliquer le Lemme-2 avec  $y = P_C(x - t\nabla f(x))$  et utiliser le fait que

$$\langle x - t\nabla f(x) - y, x - y \rangle \leq 0.$$

$\square$

**Remarque.** Quand  $C = \mathbb{R}^n$ , la méthode du gradient projeté n'est rien d'autre que la méthode de descente du gradient classique présentée en Section-3.

**Notation.** Par la suite, on note, pour  $M > 0$

$$G_M(x) = M \left( x - P_C \left( x - \frac{1}{M} \nabla f(x) \right) \right).$$

On note que pour  $C = \mathbb{R}^n$ ,  $G_M(x) = \nabla f(x)$ . L'opérateur servira comme une mesure d'optimalité. Avec cette notation, le Lemme-4 se réécrit

$$f(x) - f(P_C(x - t\nabla f(x))) \geq t \left(1 - \frac{tL}{2}\right) \|G_{1/t}(x)\|^2.$$

On peut démontrer sans difficultés un résultat similaire au Théorème-2 pour la méthode du gradient projeté, on changera  $\nabla f(x)$  par  $G_M(x)$ .

## 6.2 Cas convexe

On s'intéresse ici à des problèmes du type

$$\min_{x \in C} f(x), \tag{16}$$

où  $C \subset \mathbb{R}^n$  est un convexe fermé et  $f \in C_L^{1,1}(C)$  est convexe. Dans ce cas, on peut démontrer à la fois la convergence de  $(f(x_k))_k$  vers  $f^*$  ainsi que la suite  $(x_k)_k$ .

**Théorème 6.** Soit  $f \in C_L^{1,1}(C)$  une fonction convexe avec  $C$  un convexe fermé de  $\mathbb{R}^n$ . Soit  $(x_k)_k$  la suite générée par la méthode du gradient projeté avec un pas  $t_k = t^* \in (0, 1/L]$ . Supposons que  $\operatorname{argmin}_C f := S \neq \emptyset$ . Alors

1. Pour tout  $k \geq 0$  et  $x^* \in S$

$$f(x_k) - f^* \leq \frac{\|x_0 - x^*\|^2}{2t^*k}.$$

2.  $x_k \rightarrow x^* \in S$  lorsque  $k \rightarrow \infty$ .