



*Modèles convexes et algorithmes d'optimisation  
en imagerie.*

Pierre Weiss.

April 21, 2011

III.1/ Théorie de la complexité en  
optimisation convexe.  
Applications à l'imagerie.

## *Plan de la partie*

1. Éléments d'analyse convexe dans  $\mathbb{R}^n$ .
2. Quelques résultats en théorie de la complexité.
3. Algorithmes efficaces optimaux dans le cas différentiable et non différentiable.

## Quelques références

1. T. Rockafellar *Convex Analysis* 1970.
2. B. Polyak *Introduction to optimization*, 1987.
3. D. Bertsekas *Nonlinear Programming*, 1999.
4. Y. Nesterov *Introductory lectures on optimization*, 2003.
5. A. Juditsky, cours en ligne optimisation, (ENSIMAG).
6. Bonnans, Gilbert, Lemaréchal, Sagastizàbal, *Numerical optimization*, 2006.

## *Elements d'analyse convexe*

### **Notations :**

On travaille dans  $\mathbb{R}^n$ ,  $n \in \mathbb{N}$  avec :

- Un produit scalaire  $\langle \cdot, \cdot \rangle$ . A moins que ce ne soit spécifié, il correspond au produit scalaire usuel.
- On munit l'espace d'une norme :

$$\|x\| = \sqrt{\langle x, x \rangle}.$$

## *Elements d'analyse convexe*

Dans tout l'exposé, nous nous intéressons à des fonctions :

$$f : \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}.$$

**Définition (domaine d'une fonction) :**

$$\text{dom}(f) := \{x \in \mathbb{R}^n, f(x) < +\infty\}.$$

On suppose systématiquement que  $\text{dom}(f) \neq \emptyset$ .

**Intérêt (l'un d'eux) :**

$$\inf_{x \in \mathbb{R}^n} f(x) = \inf_{x \in \text{dom}(f)} f(x)$$

Les problèmes contraints s'écrivent indifféremment des problèmes non contraints.

## *Elements d'analyse convexe*

### **Définition (fonction convexe) :**

$f$  est dite convexe si :

1.  $\text{dom}(f)$  est convexe.
2.  $f$  est convexe sur  $\text{dom}(f)$ ,  $\forall (x_1, x_2) \in \mathbb{R}^n \times \mathbb{R}^n, \forall \alpha \in [0, 1]$ ,

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

### **Théorème :**

Toute fonction  $f$  convexe en dimension finie est continue sur  $\text{int}(\text{dom}(f))$ .

## *Elements d'analyse convexe*

**Définition (épigraphe) :**

$$\text{epi}(f) = \{(x, t) \in \text{dom}(f) \times \mathbb{R}, t \geq f(x)\}.$$

**Théorème :**

$f$  est convexe si et seulement si son épigraphe est convexe.  
(Schéma ?)

## *Elements d'analyse convexe*

### **Un problème :**

Bien qu'une fonction convexe soit continue sur  $\text{int}(\text{dom}(f))$ , elle peut avoir un comportement complexe sur le bord.

### **Exemple :**

$$f(x, y) = \begin{cases} 0 & \text{si } x^2 + y^2 < 1 \\ \phi(x, y) \geq 0 & \text{si } x^2 + y^2 = 1 \\ +\infty & \text{si } x^2 + y^2 > 1 \end{cases}$$

**Minimisation :** On suppose  $g$  continue sur  $\mathbb{R}^2$  et on veut trouver :

$$\min_{(x,y) \in \mathbb{R}^2} f(x, y) + g(x, y)$$

Si  $g$  n'atteint pas son minimum sur le disque, il n'y a pas d'autre choix que d'explorer **exhaustivement** l'ensemble  $\{(x, y) \in \mathbb{R}^2, x^2 + y^2 = 1\}$  !

## *Elements d'analyse convexe*

### **Définition (fonction convexe fermée) :**

Une fonction convexe est dite *fermée* ou *semi-continue inférieurement (s.c.i.)* si  $\text{epi}(f)$  est fermé.


### **Exemples 1D :**

Voir tableau...

## *Elements d'analyse convexe*

**Définition (sous-différentiel) :** Soit  $f : \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$  convexe s.c.i. Le *sous-différentiel* de  $f$  en  $x \in \text{dom}(f)$  est défini par :

$$\partial f(x) = \{\eta \in \mathbb{R}^n, \forall y \in \mathbb{R}^n, f(y) \geq f(x) + \langle \eta, y - x \rangle\}.$$



*Figure:* Sous-différentiel.

## *Elements d'analyse convexe*

**Propriété 1 :** Si  $f$  est différentiable en  $x_0$ , alors

$$\partial f(x_0) = \{\nabla f(x_0)\}.$$

**Propriété 2 :** Le sous-différentiel est non vide, convexe, fermé sur  $\text{int}(\text{dom}(f))$ .

Mais il peut être **vide sur le bord du domaine**.

Exemple :

$$f(x) = -\sqrt{x}$$

est convexe s.c.i. sur  $[0, +\infty[$ .

Et on a  $\lim_{x \rightarrow 0^+} f'(x) = -\infty$  et  $-\infty \notin \mathbb{R}$  !

## *Elements d'analyse convexe*

On considère le problème :

$$\text{Trouver } x^* \in \underset{x \in \mathbb{R}^n}{\text{Arg min}} f(x)$$

où  $f$  est convexe s.c.i.

**Théorème (fondamental) :**

$x^*$  est minimiseur de  $f$  si et seulement si  $0 \in \partial f(x^*)$ .

**Une règle de calcul utile :**

Soit  $g(x) = f(Ax)$  où  $A$  est un opérateur linéaire, alors :

$$\partial g(x) = A^* \partial f(Ax)$$

où  $A^*$  est l'opérateur adjoint de  $A$ .

## Algorithme : descente de sous-gradient (Polyak $\sim$ 1980)

### Problème :

Trouver  $x^* \in \underset{x \in X}{\text{Arg min}} f(x)$

- $f : X \rightarrow \mathbb{R}$  est convexe, s.c.i.
- $X$  est un ensemble convexe fermé.

### Algorithme :

1. Choisir  $x^0 \in X$  et une suite réelle de pas  $(h_k)_{k \in \mathbb{N}}$  telle que :

- $h_k \geq 0, \forall k \in \mathbb{N}$ .
- $\lim_{k \rightarrow +\infty} h_k = 0$ .
- $\sum_{k=0}^{+\infty} h_k = +\infty$ .

2.

$$x_{k+1} = \Pi_X \left( x_k - h_k \frac{\eta(x_k)}{\|\eta(x_k)\|} \right), \quad \eta(x_k) \in \partial f(x_k)$$

## Algorithme : descente de sous-gradient (Polyak $\sim$ 1980)

### Résultat :

Si  $f$  est  $L$ -Lipschitz sur  $B = \{x \in \mathbb{R}^n, \|x_0 - x^*\| \leq R\}$ , alors :

$$f_k - f^* \leq L \frac{R^2 + \sum_{i=0}^k h_i^2}{2 \sum_{i=0}^k h_i}$$

En particulier, si  $h_k = \frac{R}{\sqrt{k+1}}$  (optimal) :

$$f_k - f^* \leq \frac{LR}{\sqrt{k+1}}$$

avec :  $f_k^* = \min(f(x_0), f(x_1), \dots, f(x_k))$ .

Ce taux est ajusté.

## *Algorithme : descente de sous-gradient*

### **Note importante :**

En supposant  $L = R = 1$ , et si on souhaite :

$$f_k^* - f^* \leq 10^{-3}$$

Dans un scénario au pire des cas, il faut  $10^6$  itérations !

### **Conclusion :**

- Les descentes de sous-gradient avec pas décroissant ne doivent pas être utilisées en général.
- Elles peuvent présenter un intérêt pour **coder rapidement** des **approximations grossières** des solutions avec des **pas précalculés** (10-20 itérations).
- Note : les constantes  $L$  et  $R$  peuvent dépendre implicitement de la dimension  $n$  !

## Optimisation convexe non différentiable : complexité

Soit  $\mathcal{M}$  l'ensemble des méthodes de sous-gradient de la forme :

$$x_{k+1} \in x_0 + \text{vect}(\eta(x_0), \dots, \eta(x_k)), \quad \text{où } \eta(x_i) \in \partial f(x_i).$$

**Théorème :** Pour tout  $k \leq n - 1$ , pour toute méthode  $m \in \mathcal{M}$ , il existe une fonction  $f : \mathbb{R}^n \rightarrow \mathbb{R}$

- convexe fermée.
- $L$ -Lipschitz sur une boule de rayon  $R$  autour d'un minimiseur  $x^*$ .

telle que :

$$f(x_k) - f^* \geq \frac{MR}{1 + \sqrt{k+1}}$$

**Corollaire :** Les méthodes de sous-gradient avec pas en  $O\left(\frac{1}{\sqrt{k}}\right)$  sont optimales.

## Optimisation convexe non différentiable : complexité

### Idée :

La fonction  $f_k : x \mapsto \max_{1 \leq i \leq k} x(i) + \frac{1}{2} \|x\|^2$  est difficile à minimiser pour toutes les méthodes de sous-gradient.

### Éléments de preuve :

La descente de sous-gradient avec  $x_0 = 0$ , assure que :

$$x_k \in \mathbb{R}^{k,n} := \{x \in \mathbb{R}^n, x(i) = 0, \forall i > k\}$$

(on ajoute qu'une coordonnée à chaque itération).

On a de plus :

$$\min_{x \in \mathbb{R}^{k,n}} f(x) - f^* \geq O\left(\frac{1}{\sqrt{k}}\right).$$

## *Optimisation convexe différentiable : complexité*

La classe des fonctions convexes non différentiables est trop vaste pour espérer avoir des schémas génériques efficaces.

### **Complexité de la classe des fonctions convexes différentiables.**

Soit  $\mathcal{C}$ , la classe des fonctions  $f$  telles que :

- $f$  est convexe, différentiable.
- $\nabla f$  est  $L$ -Lipschitz (régularité indispensable).

### **Classe de méthodes :**

On considère les méthodes qui génèrent des itérées du type

$$x_{k+1} \in x_0 + \text{vect}(\nabla f(x_0), \dots, \nabla f(x_k)).$$

**Exemples :** descentes de gradient, gradient conjugué.

## Optimisation convexe différentiable : complexité

**Théorème :** Pour tout  $k \leq \frac{n-1}{2}$  et  $x_0 \in \mathbb{R}^n$  il existe une fonction  $f \in \mathcal{C}$  telle que :

$$f(x_k) - f^* \geq \frac{3L\|x_0 - x^*\|^2}{32(k+1)^2}$$

et

$$\|x_k - x^*\|^2 \geq \frac{1}{8}\|x_0 - x^*\|^2.$$

**Conséquence :**

- En général, on ne peut rien dire sur la distance au minimiseur !
- Les taux de convergence linéaires (vus en cours) ( $\|x_k - x^*\| \leq \alpha^k \|x_0 - x^*\|$ ,  $\alpha < 1$ ) sont hors de portée en général.
- Le taux en  $O\left(\frac{1}{k^2}\right)$  n'est pas si décourageant.

## Optimisation convexe différentiable : complexité

**Eléments de preuve** : on exhibe la fonction **la pire au monde**

:

$$f_k(x) = \frac{L}{4} (\langle A_k x, x \rangle - x(1))$$

où :

$$A_k = \begin{bmatrix} 2 & -1 & 0 & 0 & \dots & 0_{n-k,1} \\ -1 & 2 & -1 & 0 & \dots & 0_{n-k,1} \\ 0 & -1 & 2 & -1 & \dots & 0_{n-k,1} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & 2 & 0_{n-k,1} \\ & & 0_{k,n-k} & & & 0_{n-k,n-k} \end{bmatrix}$$

**Problème** : Discrétisation d'un laplacien tronqué en 1D : ce n'est rien d'autre qu'une régularisation  $H^1$  !

## Optimisation convexe différentiable : complexité

### Eléments de preuve :

1. On pose  $x_0 = 0$ .
2. On remarque que  $\nabla f(x_k) \in \mathbb{R}^{k,n}$ .
3. D'où  $x_k \in \mathbb{R}^{k,n}$ .
4. Pour  $x \in \mathbb{R}^{k,n}$ , on montre :
  - $f(x) - f^* \geq O\left(\frac{L\|x_0 - x^*\|^2}{k^2}\right)$  et
  - $\|x - x^*\|^2 \geq \frac{1}{8}\|x_0 - x^*\|^2$ .

## Optimisation convexe différentiable : descente de gradient

On considère :

$$\min_{x \in \mathbb{R}^n} f(x), \quad \text{où } \nabla f \text{ est } L - \text{Lipschitz.}$$

Et la descente de gradient :

$$x_{k+1} = x_k - \tau \nabla f(x_k)$$

**Preuve de convergence :**

On a  $\forall (x, y) \in \mathbb{R}^n \times \mathbb{R}^n$  (inégalité boom boom !):

$$f(y) \leq \underbrace{f(x) + \langle \nabla f(x), y - x \rangle + \frac{L}{2} \|y - x\|^2}_{\psi(y,x)} \quad (1)$$

$$= f(x) + \frac{L}{2} \left\| y - \left( x - \frac{\nabla f(x)}{L} \right) \right\|^2 - \frac{\|\nabla f(x)\|^2}{2L} \quad (2)$$

## Optimisation convexe différentiable : descente de gradient

En posant :

$$x_{k+1} = \arg \min_{x \in \mathbb{R}^n} \psi(x, x_k) \quad (3)$$

$$= x_k - \frac{\nabla f(x_k)}{L}, \quad (4)$$

on assure que :

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

On peut ensuite sommer ces inégalités de  $k = 0$  à  $N$  :

$$f(x_N) - f(x_0) \leq - \sum_{k=0}^N \frac{\|\nabla f(x_k)\|^2}{2L} \quad (5)$$

$$\leq - \frac{N}{2L} \min_{1 \leq k \leq N} \|\nabla f(x_k)\|^2 \quad (6)$$

## Optimisation convexe différentiable : descente de gradient

On a donc :

$$\min_{1 \leq k \leq N} \|\nabla f(x_k)\|^2 \leq \frac{2L}{N} \cdot (f(x_0) - f^*)$$

En utilisant de plus la convexité de  $f$  (**inégalité boom boom 2 !**):

$$f(x^*) \geq f(x_k) + \langle \nabla f(x_k), x_k - x^* \rangle$$

et donc :

$$f(x_k) - f(x^*) \leq \|\nabla f(x_k)\| \cdot \|x_k - x^*\|$$

## *Optimisation convexe différentiable : descente de gradient*

### **Résultat de convergence (relaxation):**

Si  $f$  a un gradient  $L$ -Lipschitz, la descente de gradient assure que :

$$\min_{1 \leq k \leq N} \|\nabla f(x_k)\|^2 \leq \frac{2L}{N} \cdot (f(x_0) - f^*)$$

si de plus  $f$  est convexe :

$$f(x_k) - f^* \leq O\left(\frac{L\|x_0 - x^*\|^2}{k}\right)$$

Ce taux de convergence est ajusté.

**La méthode de gradient est sous-optimale !**

# *Optimisation convexe différentiable : méthodes optimales*

Méthodes optimales : proposées en 1983 par Y. Nesterov.

*Idée générale.*

*Les méthodes d'optimisation à un pas ne permettent pas d'obtenir des taux de convergence optimaux ! Il faut aller au delà des principes de relaxation.*

⇒

- Utiliser *vect* ( $\{\nabla f(x_0), \nabla f(x_1), \dots, \nabla f(x_k)\}$ ) pour calculer  $x_{k+1}$ .
- Si  $f$  est convexe,  $\nabla f$  apporte une information sur la topologie globale de  $f$  !
- Impératif informatique : ne pas stocker tous les gradients.

# Optimisation convexe différentiable : méthodes optimales




Figure: Sous-différentiel.

## Optimisation convexe différentiable : méthodes optimales

Ancêtres : les méthodes "heavy-ball" (B. Polyak).

Descente de gradient oscillantes : **ajouter de l'inertie !**

Résoudre l'équation différentielle :

$$\ddot{x} + a\dot{x} + b\nabla f(x) = 0$$

(Solide soumis à une force de gravité et de friction)

Discrétisation :

$$\frac{-x_{k+1} + 2x_k - x_{k-1}}{\Delta t} + a \frac{(x_{k+1} - x_k)}{\Delta t} + b\nabla f(x_k) = 0$$

Soit encore :

$$x_{k+1} = x_k - a_k \nabla f(x_k) + b_k (x_k - x_{k-1})$$

(Preuve dans le cas fortement convexe à venir...)

# Optimisation convexe différentiable : méthodes optimales

*Idée générale*

**Outils :**

- Une suite minimisante  $(x_k)$ .
- Une suite de coefficients  $A_0 = 0$ ,  $A_{k+1} = A_k + a_k$ , avec  $a_k > 0$ .
- Une suite de fonctions  $(\psi_k)$  approchant  $A_k f$  de la forme :

$$\psi_k(x) = \sum_{i=1}^k a_i (f(x_i) + \langle \nabla f(x_i), x - x_i \rangle) + \frac{1}{2} \|x - x_0\|^2$$

## *Optimisation convexe différentiable : méthodes optimales*

**Maintenir les inégalités :**

$$\begin{cases} A_k f(x_k) \leq \min_{x \in \mathbb{R}^n} \psi_k(x) \\ \psi_k(x) \leq A_k f(x) + \frac{1}{2} \|x - x_0\|^2 \quad \forall x \in \mathbb{R}^n \end{cases}$$



Ainsi, en prenant  $x = x^*$ , on obtient :

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

La rapidité de croissance de  $(A_k)$  détermine la rapidité de convergence du schéma.

**Non trivial !**

# Optimisation convexe différentiable : méthodes optimales



## *Schéma multi-pas [Nesterov 83].*

- **In:** Nombre d'itérations  $N$ , point initial  $x_0 \in \mathbb{R}^n$ .
- **Out:**  $x_N$  une estimée de  $x^*$ .
- **Init:** Poser  $t_1 = 1$ ,  $y_1 = x_0$ .

Pour  $k$  allant de 0 à  $N$ :

- Poser  $x_k = y_k - \frac{\nabla f(y_k)}{L}$ .
- Calculer  $t_{k+1} = \frac{1 + \sqrt{1 + 4t_k^2}}{2}$ .
- Poser  $y_{k+1} = x_k + \left(\frac{t_k - 1}{t_{k+1}}\right) (x_k - x_{k-1})$ .

## *Schéma multi-pas [Nesterov 83].*

### *Résultat de convergence*

L'algorithme assure que :

$$f(x^k) - f(x^*) \leq \frac{L \|x^0 - x^*\|^2}{k^2}$$

C'est un taux de convergence optimal !

## *Distance au minimiseur.*

Impossible d'obtenir des certificats sur la **distance au minimiseur** sous la seule hypothèse de convexité.

**Définition (forte convexité).**

Une fonction  $f$  est dite fortement convexe si elle est convexe et qu'il existe  $\mu > 0$  tel que :

$$\forall (x, y) \in \text{dom}(f)^2, \forall \eta \in \partial f(x), f(y) \geq f(x) + \langle \eta, y - x \rangle + \frac{\mu}{2} \|y - x\|^2$$

**Distance au minimiseur.** Une fonction fortement convexe admet un unique minimiseur  $x^*$  et

$$f(x) \geq f(x^*) + \frac{\mu}{2} \|x - x^*\|^2$$

**Proposition.** Une fonction  $C^2$  est  $\mu$ -fortement convexe ssi

$$\lambda_{\min}(H_f(x)) \geq \mu, \forall x \in \text{dom}(f).$$

## *Forte convexité et conditionnement.*

**Propriété.** Soient  $f$  et  $g$  deux fonctions fortement convexes de paramètre  $\mu_1 \geq 0$  et  $\mu_2 \geq 0$ , alors :

$$\forall (\alpha, \beta) \in \mathbb{R}_+^2, \quad x \mapsto \alpha f(x) + \beta g(x)$$

est fortement convexe de module  $\alpha\mu_1 + \beta\mu_2$ .

### **Généralisation du conditionnement.**

Soit  $f(x) = \frac{1}{2} \|Ax - b\|^2$

Ainsi :  $\nabla f(x) = A^*(Ax - b)$ .

- Constante de Lipschitz du gradient  $L = \lambda_{max}(A^*A)$ .
- Paramètre de forte convexité  $\mu = \lambda_{min}(A^*A)$ .
- Le conditionnement du système linéaire est :

$$\kappa(A^*A) = \frac{\lambda_{max}}{\lambda_{min}} = \frac{L}{\mu} = \kappa(f).$$

## *Forte convexité.*

### **Quelques exemples de fonctions fortement convexes**

- $f(x) = \frac{1}{2}\|x - x_0\|^2$  ( $\mu = 1$ ).
- $f(x) = g(x) + \frac{1}{2}\|x - x_0\|^2$  où  $g$  est convexe ( $\mu = 1$ ).
- $f(x) = \frac{1}{2}\|Ax - b\|^2$ , ( $\mu = \lambda_{\min}(A^*A)$ ).
  - $A$  doit être de rang plein.

#### **Notes :**

- La notion peut-être étendue à un cadre non hilbertien.
- Il peut être intéressant de changer les métriques pour faire varier ces constantes (préconditionnement).

## *Convergence des méthodes de gradient dans le cas fortement convexe.*

Soit  $f$  une fonction  $\mu$ -fortement convexe, à gradient  $L$ -Lipschitz et  $\kappa = \frac{L}{\mu}$ .

**Théorème 1 :** La descente de gradient

$x_{k+1} = x_k - \frac{2}{\mu+L} \nabla f(x_k)$  assure que :

$$\|x_k - x^*\| \leq \left( \frac{\kappa - 1}{\kappa + 1} \right)^k \|x_0 - x^*\|.$$

(Arguments de point fixe).

**Théorème 2 :** Les schémas multi-pas avec une **modification mineure** du calcul des coefficients  $a_k$  assurent que :

$$\|x_k - x^*\| \leq \left( \frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1} \right)^k \|x_0 - x^*\|.$$

**L'accélération est automatique pour les schémas simples !**

## Preuve de convergence.

Descente de gradient (*contraction*).

On a :

$$\begin{aligned} & \|x - \tau \nabla f(x) - (y - \tau \nabla f(y))\| \\ &= \|(I - \tau \nabla f)(x - y)\| \\ &\leq \underbrace{\left\| \int_{t=0}^1 (I - \tau \nabla^2 f(x + t(y - x)))(y - x) dt \right\|}_{f'(x) - f'(y) = \int_y^x f''(t) dt} \\ &\leq \underbrace{\sup_{z \in \mathbb{R}^n} \|I - \tau \nabla^2 f(z)\|}_{\text{Th.Ch.G.N.}} \cdot \|x - y\| \end{aligned}$$

Or

$$\begin{aligned} & sp(I - \tau \nabla^2 f(z)) = 1 - \tau sp(\nabla^2 f(z)) \\ \Rightarrow & \sup_{z \in \mathbb{R}^n} \|I - \tau \nabla^2 f(z)\| = \max(|1 - \tau \mu|, |1 - \tau L|) \end{aligned}$$

## *Preuve de convergence.*

*Descente de gradient.*

En prenant

$$\tau = \min_{\tau} \max(|1 - \tau\mu|, |1 - \tau L|) = \frac{2}{\mu + L},$$

on obtient :

$$\|(I - \tau\nabla f)(x - y)\| \leq \left(\frac{\kappa - 1}{\kappa + 1}\right) \|x - y\|$$

Ainsi :

$$\begin{aligned} & \|x_{k+1} - x^*\| \\ &= \|x_k - \tau\nabla f(x_k) - (x^* - \tau\nabla f(x^*))\| \\ &\leq \left(\frac{\kappa - 1}{\kappa + 1}\right) \|x_k - x^*\| \end{aligned}$$

## Preuve de convergence schéma accéléré.

**Idée :** étudier  $\|x_{k+1} - x^*\|^2 + \|x_k - x^*\|^2$

$$\begin{aligned} & \left\| \begin{bmatrix} x_{k+1} - x^* \\ x_k - x^* \end{bmatrix} \right\| \\ &= \left\| \begin{bmatrix} x_k - \alpha_k \nabla f(x_k) + \beta_k(x_k - x_{k-1}) - x^* \\ x_k - x^* \end{bmatrix} \right\| \\ &= \left\| \begin{bmatrix} (1 + \beta_k)I & -\beta_k I \\ I & 0 \end{bmatrix} \begin{bmatrix} x_k - x^* \\ x_{k-1} - x^* \end{bmatrix} - \alpha_k \begin{bmatrix} \nabla f(x_k) \\ 0 \end{bmatrix} \right\| \\ &\leq \sup_{z \in \mathbb{R}^n} \left\| \begin{bmatrix} (1 + \beta_k)I - \alpha_k \nabla^2 f(z) & -\beta_k I \\ I & 0 \end{bmatrix} \right\| \cdot \left\| \begin{bmatrix} x_k - x^* \\ x_{k-1} - x^* \end{bmatrix} \right\| \end{aligned}$$

Puis on résout :

$$\min_{\alpha_k, \beta_k} \sup_{z \in \mathbb{R}^n} \left\| \begin{bmatrix} (1 + \beta_k)I - \alpha_k \nabla^2 f(z) & -\beta_k I \\ I & 0 \end{bmatrix} \right\| \quad (7)$$

## *Preuve de convergence schéma accéléré.*

En posant :

$$\beta_k = \max(|1 - \sqrt{\alpha_k l}|, |1 - \sqrt{\alpha_k L}|)^2,$$

et

$$\alpha_k = \frac{4}{(\sqrt{L} + \sqrt{l})^2}.$$

On obtient :

$$\sup_{z \in \mathbb{R}^n} \left\| \begin{bmatrix} (1 + \beta_k)I - \alpha_k \nabla^2 f(z) & -\beta_k I \\ I & 0 \end{bmatrix} \right\| \leq \left( \frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1} \right).$$

## *Preuve de convergence schéma accéléré.*

*Conclusion cas fortement convexe :*

- Si  $\kappa \gg 1$ , alors :

$$\left( \frac{\kappa - 1}{\kappa + 1} \right) \simeq 1 - \frac{2}{\kappa}.$$

$$\left( \frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1} \right) \simeq 1 - \frac{2}{\sqrt{\kappa}}.$$

- Si  $\kappa \gg 1$ , alors les **taux polynomiaux à l'origine sont plus importants que les taux linéaires asymptotiques.**
- Ne pas oublier de modifier les paramètres de l'algorithme !