

# ↳ Optimisation numérique ↳

## Chap. 2 : algorithmes d'optimisation locale sans contraintes

### 2.1) Principe général des méthodes de descente



Pb à résoudre :

$$f : \mathbb{R}^n \rightarrow \mathbb{R}, C^1, \text{ voire } C^2$$

$x_0 \in \mathbb{R}^n$  On cherche à approcher

un minimum local de  $f$  situé

à proximité de  $x_0$ , en construisant une suite d'approximations  $(x_k)_{k \in \mathbb{N}}$  de  $x^*$ .



Une méthode de descente impose  
d'avoir

$$\forall k \in \mathbb{N}, f(x_{k+1}) \leq f(x_k)$$

(strict si  $x_{k+1} \neq x_k$ )

Plus précisément, on construit  $(x_k)$   
de manière itérative à un pas, en  
se donnant

} \* une direction de descente  $d_k \in (\mathbb{R}^n)^{\alpha}$   
} \* un pas dans la direction  $d_k$  :  $\alpha_k \in \mathbb{R}_+^{\alpha}$


Ainsi, on a l'itération :

$$x_{k+1} = x_k + \alpha_k d_k$$

2  
L'objectif va consister à  
construire de telles méthodes et à  
justifier leur convergence éventuelle  
vers un minimum local de  $f$ .

Il ne suffit pas d'imposer  
une descente stricte pour obtenir  
la convergence vers  $x^*$ .

Deux "contre-exemples" en  
dimension  $n=1$  en attestent.




$$f(x) = x^2$$

$$(x_0 = 2, x_{k+1} = x_k + \alpha_k d_k \text{ avec}$$

$$d_k = (-1)^{k+1} \text{ or } \alpha_k = 2 + \frac{3}{2^{k+1}})$$

Pas trop grand (\*) par rapport à la descente effectuée.  
(\*) par une descente trop faible)



$$f(x) = x^2$$

$$(x_0 = 2, x_{k+1} = x_k + \alpha_k d_k \text{ avec}$$

$$d_k = -1, \alpha_k = \frac{1}{2^{k+1}})$$

Pas trop petit.

Dans les 2 cas,  $(x_k)$  ne converge pas vers le minimum  $x^* = 0$  de  $f$ .

Pour assurer un résultat de convergence, il faut définir une stratégie de recherche linéaire pour une direction donnée (pas ni trop grand, ni trop petit)

Le choix de la direction de descente est très important. La direction opposée au gradient :

$$d_k = -\nabla f(x_k)$$

est une possibilité (on parle dans ce cas de méthode du

gradient ou de plus forte pente) mais ce n'est pas forcément la meilleure direction.

Remarque : le seul cas où on ne peut pas définir de direction de descente est lorsque  $\nabla f(x_k) = 0$ . L'algorithme s'arrête dans ce cas.

2.2) Un exemple de recherche linéaire: "backtracking + Armijo"

→ Principe de backtracking  
\* On suppose qu'on se donne à chaque étape une direction de descente ( $d_k$ )

\* On se donne un pas de référence

$\alpha_{init} > 0$  qu'on teste dans un premier temps:

$$\tilde{\alpha}_0 = \alpha_{init} d_R$$


\* Si  $f(\tilde{\alpha}_0) < f(x_R)$ , on garde  $x_{R+1} = \tilde{\alpha}_0$  (et  $d_R = \alpha_{init}$ )

• Sinon, on teste une nouvelle valeur de

$$d_R: \quad \tilde{\alpha} = \bar{\sigma} \alpha_{init} \text{ où } \bar{\sigma} \in ]0, 1[ \text{ fixe) et de } \tilde{\alpha}:$$

$$\tilde{\alpha}_1 = \tilde{\alpha} d_R$$

et ainsi de suite jusqu'à obtenir une descente effective avec  $\tilde{\alpha}_l$  ( $l \geq 1$ )



$$(\alpha_{init} = 4, \bar{\sigma} = \frac{1}{2})$$

Comme  $d_R$  est une direction de descente, cet algorithme s'arrête en temps fini

$$(f(\tilde{\alpha}_l) < f(x_R))$$

Cet algorithme de backtracking permet de se prémunir des pas trop petits (voir Th.)

→ Condition d'Armijo :

la condition d'Armijo permet d'assurer  
une descente suffisante dans le cas du  
pas grands :

on remplace la condition de descente


$f(x_{k+1}) < f(x_k)$  par :  $< \alpha (d_k : \text{descente})$

$$f(x_k + \alpha d_k) \leq f(x_k) + \beta \alpha \langle d_k, \nabla f(x_k) \rangle$$

(où  $\beta \in ]0, 1[$  fixé, en général petit)


Interprétation géométrique : on considère

$$h : \begin{cases} ]0, +\infty[ \rightarrow \mathbb{R} \\ t \mapsto f(x_k + t d_k) \end{cases}$$



$$h'(t) = \langle d_k, \nabla f(x_k + t d_k) \rangle$$

et  $h'(0) = \langle d_k, \nabla f(x_k) \rangle < 0$



Cette condition donne des valeurs admissibles de pas, en particulier il existe toujours un intervalle initial admissible.

Proposition soit  $f: C^1: \mathbb{R}^n \rightarrow \mathbb{R}$  telle que  $g = \nabla f: \mathbb{R}^n \rightarrow \mathbb{R}^n$  est Lipschitz:

$$\|g(y) - g(x)\| \leq \gamma \|y - x\|$$

Alors la condition d'Armijo en un point  $x \in \mathbb{R}^n$  et par une direction de descente  $d \in \mathbb{R}^n \setminus \{0\}$  est satisfaite si

$$t \in \left[ 0, \frac{2(\beta - 1) \langle d, \nabla f(x) \rangle}{\gamma \|d\|^2} \right]$$

preuve: en utilisant Taylor et l'hypothèse sur  $\nabla f$ , on montre que

$$f(x + td) \leq f(x) + t \langle d, \nabla f(x) \rangle + \frac{1}{2} \gamma t^2 \|d\|^2$$


(à faire en exercice)

Si  $t \leq \frac{2(\beta-1) \langle d, \nabla f(x) \rangle}{\gamma \|d\|^2}$ ,

alors

$$f(x+td) \leq f(x) + t \langle d, \nabla f(x) \rangle + t \frac{1}{2} \gamma \|d\|^2 t \leq f(x) + t \beta \langle d, \nabla f(x) \rangle$$

et  $t$  vérifie bien la condition d'Armijo.



On dispose donc d'une stratégie de recherche linéaire "backtracking + Armijo" (paramètres :  $\alpha_{init}$ ,  $\beta$ ,  $\gamma$ )

On montre que cette stratégie permet de construire des suites d'approximation  $(x_k)_{k \in \mathbb{N}}$  qui convergent vers un minimum local de  $f$ .

**Théorème** : soit  $f \in C^1$  et  $g = \nabla f$  Lipschitz continue. Alors la suite d'approximation  $(x_k)$  telle que

$$x_{k+1} = x_k + \alpha_k d_k \text{ avec}$$

$d_k$  : direction de descente  
 $\alpha_k$  : pas fixe suivant la

stratégie "backtracking + Armijo"

est telle que :

soit (i)  $\nabla f(x_k) = 0$  pour un certain  $k$

soit (ii)  $\lim_{k \rightarrow -\infty} f(x_k) = -\infty$

soit (iii)

$$\lim_{k \rightarrow +\infty} \text{Min} \left( |\langle d_k, \nabla f(x_k) \rangle|, \frac{|\langle d_k, \nabla f(x_k) \rangle|}{\|d_k\|^2} \right) = 0$$

Corollaire : on prend les mêmes hypothèses avec de plus  $f$  minorée et  $d_k = -\nabla f(x_k)$ . Alors

soit  $\nabla f(x_k) = 0$  pour un certain  $k$ , soit

$$\lim_{k \rightarrow +\infty} \nabla f(x_k) = 0$$

(preuve du corollaire immédiate :  $\lim_{k \rightarrow +\infty} (\text{Min}(\|d_k\|^2, 1)) = 0$ )

# Démonstration du théorème (partie 1)

10

$$(iii) \lim_{k \rightarrow +\infty} \text{Min} (|\langle d_k, \nabla f(x_k) \rangle|, \frac{|\langle d_k, \nabla f(x_k) \rangle|}{\|d_k\|^2}) = 0$$

(cas particulier:  $d_k = -\nabla f(x_k)$ :  $\nabla f(x_k) \rightarrow 0$ )

preuve <sup>(k)</sup> on a  $f(x_{k+1}) \leq f(x_k) + \beta \alpha_k \langle d_k, \nabla f(x_k) \rangle$

$$\left| \sum_{k=0}^k \right| \Rightarrow f(x_{k+1}) \leq f(x_0) + \beta \sum_{k=0}^k \underbrace{\alpha_k \langle d_k, \nabla f(x_k) \rangle}_{< 0} < 0$$

La série à termes négatifs est minorée, elle est donc convergente. On en déduit  $\lim_{k \rightarrow +\infty} \alpha_k \langle d_k, \nabla f(x_k) \rangle = 0$

(iv) on suppose non (ii) et non (i)

(partie 2)

11

\* 2 cas pour  $\alpha_k$  sont possibles :

\* si

$$\alpha_{init} \leq \frac{2(\beta-1) \langle d_k, \nabla f(x_k) \rangle}{\gamma \|d_k\|^2}$$

alors  $\alpha_k = \alpha_{init}$

et  $|\alpha_k \langle d_k, \nabla f(x_k) \rangle| = \alpha_{init} |\langle d_k, \nabla f(x_k) \rangle|$

\* si  $\alpha_{init} \geq \left( \frac{\gamma \|d_k\|^2}{2(\beta-1) \langle d_k, \nabla f(x_k) \rangle} \right)$ , alors

$$\alpha_k \geq \frac{\gamma \|d_k\|^2}{2(\beta-1) \langle d_k, \nabla f(x_k) \rangle}$$

(backtracking)

(part 3)

12



Alors

$$|\alpha_k \langle d_k, \nabla f(\alpha_k) \rangle| \geq \frac{2\sigma_1(\beta-1)}{\gamma} \frac{|\langle d_k, \nabla f(\alpha_k) \rangle|}{\|d_k\|^2}$$

↓  
0

↓  
0

# Ex 1) TD3 (un exemple d'itération de cette méthode)

Un exemple d'itération de cette méthode:

Ex 1) TD3

$$J(x, y, z) = x^2 + y^2 + z^2 - x + y - z \quad \text{à minimiser sur } \mathbb{R}^3$$

1) Solution exacte?  $\nabla J(x, y, z) = \begin{pmatrix} 2x-1 \\ 4y+1 \\ 2z-1 \end{pmatrix} = 0 \Leftrightarrow \begin{pmatrix} x \\ y \\ z \end{pmatrix} = \begin{pmatrix} \frac{1}{2} \\ -\frac{1}{4} \\ \frac{1}{2} \end{pmatrix}$

$$HJ(x, y, z) = \begin{pmatrix} 2 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 2 \end{pmatrix} \gg 0 \Rightarrow \left(\frac{1}{2}, -\frac{1}{4}, \frac{1}{2}\right) \text{ min global de } J$$

2) On part de  $X_0 = (0, 1, 1)$  On prend  $\alpha_{\text{init}} = 1$ ;  $\bar{\alpha} = 0, 1$ ;  $\beta = 0, 1$   
Que vaut  $X_1$ ? (avec direction de plus forte pente:  $d_0 = -\nabla J(X_0)$ )

(suite)

$d_0 = -\nabla f(x_0) = - \begin{pmatrix} -1 \\ 5 \\ 1 \end{pmatrix} = \begin{pmatrix} 1 \\ -5 \\ -1 \end{pmatrix}$



$J(x_0) = 3$

$\tilde{x} = x_0 + \alpha_{\text{init}} d_0$

$= \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix} + \begin{pmatrix} 1 \\ -5 \\ -1 \end{pmatrix} = \begin{pmatrix} 1 \\ -4 \\ 0 \end{pmatrix}$

$J(\tilde{x}) = 28 > 3$  refuse //

(suite dfin)

$$\tilde{X}_1 = \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix} + \frac{1}{10} \begin{pmatrix} 1 \\ -5 \\ -1 \end{pmatrix} = \begin{pmatrix} 0,1 \\ 0,5 \\ 0,9 \end{pmatrix}$$

15

$$J(\tilde{X}_1) = 0,01 + 95 + 981 - 9,1 + 0,5 - 9 \\ = 0,82$$

et

$$J(X_0) + \frac{1}{10} \langle d_0, \nabla f(X_0) \rangle =$$

$$3 + \frac{1}{100} (-27) > 0,82$$

On a donc  $X_1 = \begin{pmatrix} 0,1 \\ 0,5 \\ 0,9 \end{pmatrix}$

# Remarques


16

Remarques :

1) Il existe d'autres principes de recherche linéaire (Wolfe, Goldstein) avec certaines démonstrations de convergence (voir TD 3).

2) La direction de la plus forte pente n'est pas le meilleur choix dans certains cas : cas de la fonction de Rosenbrock

$$J(x, y) = 100(y - x^2)^2 + (x - 1)^2$$



# TD3) Ex 2) (pt de Cauchy)



TD3. Quelques stratégies de recherche linéaire

Déjà vu (Ex 1) : backtracking + Armijo

Ex 2 (pt de Cauchy)

Hyp:  $f \in C^1$ , coercive,  $\forall L$  Lipschitz

$(x_k)$  suite d'approximations :

$$x_{k+1} = x_k + t_k \underbrace{d_k}_{\text{descente}} \quad \text{ou}$$

$d_k$  : descente

$$t_k = \begin{cases} 0 & \text{si } \nabla f(x_k) = 0 \text{ et sur } A \\ \text{Inf} \{ t \geq 0 \mid h'(t_k) = 0 \text{ et } h(t_k) < h(0) \} \end{cases}$$

$$\text{ou } h: \mathbb{R}_+ \rightarrow \mathbb{R} \\ t \mapsto f(x_t + t d_k)$$

$$h'(0) = \langle d_k, \nabla f(x_k) \rangle < 0$$

1) Prouver que la définition est valide  
Représenter graphiquement un exemple.

$A \subset \mathbb{R}$  admet un inf car  $A$  est minorée par 0 et  $A$  est non vide : en effet  $h'(0) < 0$  et  $\lim_{t \rightarrow +\infty} h(t) = +\infty$

Soit  $T > 0$  tq  
 $h(T) = h(0)$  et  
 $h(t) < h(0)$  si  $t \in [0, T]$   
( $h$  coercive + T.V.A.)



Par Rolle, il existe  $\tilde{t} \in ]0, T[$  tq  $h'(\tilde{t}) = 0$  et  $h(\tilde{t}) < h(0)$   
Donc  $t_k$  existe et  $t_k > 0$  //

TD3. Quelques stratégies de recherche linéaire


2 a) Montrer que: si  $t \in ]0, t_k[$

(Lipschitz de  $\nabla f$ )

$$h(t_k) \leq h(t) \leq h(0) + t \langle d_k, \nabla f(x_k) \rangle + \frac{1}{2} t^2 (L \|d_k\|^2)$$

( $t_k = \inf \{ t \geq 0 \mid h'(t_k) = 0 \text{ et } h(t_k) < h(0) \}$ )  
~~1<sup>ère</sup> inégalité~~  
 For l'absolu de,  $\exists \hat{t} \in ]0, t_k[$  et  $h(\hat{t}) < h(t_k)$ .

2<sup>ème</sup> inégalité



$$h(t) = f(x_k + td_k) \quad (t \in ]0, t_k[)$$

$$h'(t) = \langle d_k, \nabla f(x_k + td_k) \rangle$$

$$|h'(t) - h'(0)| = |\langle d_k, \nabla f(x_k + td_k) - \nabla f(x_k) \rangle|$$

$$\leq \|d_k\| \cdot \|\nabla f(x_k + td_k) - \nabla f(x_k)\|$$

C. Schwarz

$$h'(t) - h'(0) \leq L t \|d_k\|^2$$

$$\int_0^t ds \rightarrow h(t) - h(0) - t h'(0) \leq L \frac{t^2}{2} \|d_k\|^2$$

$\langle d_k, \nabla f(x_k) \rangle$

TD3. Quelques stratégies de recherche linéaire

En déduire que

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

On a

$$t_{\min} \leq t_k$$

En effet, en  $t_k$ , la dérivée de la parabole est positive (voir (1))

Avec 2a) appliqué en  $t = t_{\min}$

$$h(t_k) \leq h(0) + t_{\min} \langle d_k, \nabla f(x_k) \rangle$$

$$+ \frac{1}{2} t_{\min}^2 L \|d_k\|^2$$



2b) Trouver  $t_{\min}$  tel que l'expression de droite soit minimale

La dérivée de l'expression de droite (parabole) s'annule en  $t_{\min}$  :

$$\langle d_k, \nabla f(x_k) \rangle + t_{\min} L \|d_k\|^2 = 0 \Rightarrow$$

$$t_{\min} = - \frac{\langle d_k, \nabla f(x_k) \rangle}{L \|d_k\|^2}$$

2c) Trouver  $0 \leq \langle d_k, \nabla f(x_k) \rangle + t_k L \|d_k\|^2$  (\*)

$$h'(t_k) = 0 \text{ soit } \langle d_k, \nabla f(x_k + t_k d_k) \rangle = 0$$

$$\text{d'après (1) } \langle d_k, \nabla f(x_k + t_k d_k) - \nabla f(x_k) \rangle \leq L t_k \|d_k\|^2$$

$$\Rightarrow 0 \leq \langle d_k, \nabla f(x_k) \rangle + L t_k \|d_k\|^2$$

(suite Ex 2)

20

PARTIE 2

PARTIE 1

03. Quelques stratégies de recherche linéaire

série à termes positifs  $\sum \|d_k\|^2$  est  
forcée, elle est donc convergente. Ainsi,  
terme général tend vers 0 :

$$\lim_{k \rightarrow +\infty} d_k = \lim_{k \rightarrow +\infty} \nabla f(x_k) = 0$$

4) On suppose  $d_k = -\nabla f(x_k)$ . Montrer que

$$\lim_{k \rightarrow +\infty} \nabla f(x_k) = 0$$

On a dans ce cas

$$f(x_{k+1}) \leq f(x_k) - \frac{\langle d_k, -d_k \rangle}{2L \|d_k\|^2}$$

soit

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

soit par somme de 0 à K :

$$f(x_{K+1}) \leq f(x_0) - \frac{1}{2L} \sum_{k=0}^K \|d_k\|^2$$

$$\Leftrightarrow \frac{1}{2L} \sum_{k=0}^K \|d_k\|^2 \leq \underbrace{f(x_0) - f(x_{K+1})}_{\text{majoré}}$$

Ex3  
(Wolfe)

