

## C10, algorithmes pour l'optimisation sans contrainte

$f \in C(\mathbb{R}^n, \mathbb{R})$ . On suppose qu'il existe  $\bar{x} \in \mathbb{R}^n$  tel que  $f(\bar{x}) \leq f(x)$  pour tout  $x \in \mathbb{R}^n$

**Objectif** : calculer un tel point  $\bar{x}$

Nous allons distinguer deux types de méthodes

1. Méthodes de descente

Il s'agit ici de construire une suite  $(x^{(k)})_{k \in \mathbb{N}}$  telle que

$$f(x^{(k+1)}) \leq f(x^{(k)}) \text{ pour tout } k \in \mathbb{N},$$

en espérant que  $\lim_{k \rightarrow +\infty} x^{(k)} = \bar{x}$

2. Si  $f$  est de classe  $C^1$ , chercher une solution de l'équation  $\nabla f(x) = 0$  (puis vérifier que  $f$  est bien minimale au point  $x$ ). Cette équation s'appelle "Equation d'Euler" du problème de minimisation de  $f$

# Direction de descente

## Definition

$f \in C(\mathbb{R}^n, \mathbb{R})$ ,  $x \in \mathbb{R}^n$ ,  $w \in \mathbb{R}^n$ ,  $w \neq 0$

1.  $w$  est une direction de descente (dd) au point  $x$  si il existe  $a_0 > 0$  tel que

$$f(x + aw) \leq f(x) \text{ pour tout } a \in ]0, a_0]$$

2.  $w$  est une direction de descente (dds) au point  $x$  si il existe  $a_0 > 0$  tel que

$$f(x + aw) < f(x) \text{ pour tout } a \in ]0, a_0]$$

# Méthode de descente

## Definition

$f \in C(\mathbb{R}^n, \mathbb{R})$ , Une méthode de descente consiste à construire une suite de la manière suivante

**Initialisation** Choisir  $x^{(0)} \in \mathbb{R}^n$

**Itération** pour  $k \geq 0$

- ▶ Choisir (si c'est possible) une dds au point  $x^{(k)}$ , notée  $w^{(k)}$
- ▶ Prendre  $x^{(k+1)} = x^{(k)} + \alpha_k w^{(k)}$  avec  $\alpha_k$  bien choisi de manière à avoir, en particulier,  $f(x^{(k+1)}) < f(x^{(k)})$

# Condition nécessaire et condition suffisante pour une dds

## Proposition

$f \in C^1(\mathbb{R}^n, \mathbb{R})$ ,  $x \in \mathbb{R}^n$ ,  $w \in \mathbb{R}^n$ ,  $w \neq 0$

1. (CN) Si  $w$  est une dds au point  $x$ , alors  $w \cdot \nabla f(x) \leq 0$
2. (CS) Si  $w \cdot \nabla f(x) < 0$  alors  $w$  est une dds au point  $x$

Exemple fondamental :

Si  $\nabla f(x) \neq 0$  alors  $w = -\nabla f(x)$  est une dds au point  $x$

# Démonstration de la proposition

Hypothèse :  $f \in C^1(\mathbb{R}^n, \mathbb{R})$ ,  $x \in \mathbb{R}^n$ ,  $w \in \mathbb{R}^n$ ,  $w \neq 0$

$\varphi(t) = f(x + tw)$ , de sorte  $\varphi \in C^1(\mathbb{R}, \mathbb{R})$ ,  $\varphi'(t) = \nabla f(x + tw) \cdot w$

1. (CN) Si  $w$  est une dds au point  $x$ ,

il existe  $a_0 > 0$  tel que  $\varphi(t) = f(x + tw) < f(x)$  pour tout  $t \in ]0, a_0]$ ,

$$\frac{\varphi(t) - \varphi(0)}{t} < 0 \text{ pour tout } t \in ]0, a_0],$$

et donc, quand  $t \rightarrow 0$ ,  $\varphi'(t) = \nabla f(x) \cdot w \leq 0$

2. (CS) Si  $w \cdot \nabla f(x) < 0$ , on a  $\varphi'(0) = \nabla f(x) \cdot w < 0$

Il existe  $a_0 > 0$  tel que  $\varphi'(t) < 0$  pour tout  $t \in ]0, a_0]$ , et donc (par le théorème des Accroissements Finis)  $\varphi(t) < \varphi(0)$  tout  $t \in ]0, a_0]$

Ceci prouve que  $w$  est une dds au point  $x$

# Algorithme du Gradient à Pas Fixe (GPF)

Hypothèse :  $f \in C^1(\mathbb{R}^n, \mathbb{R})$ . On choisit  $\rho > 0$

**Initialisation**  $x^{(0)} \in \mathbb{R}^n$ .

**Itération** pour  $k \geq 0$ , on choisit  $w^{(k)} = -\nabla f(x^{(k)})$

$$x^{(k+1)} = x^{(k)} + \rho w^{(k)}$$

Si  $\nabla f(x^{(k)}) \neq 0$ ,  $w^{(k)}$  est une dds au point  $x^{(k)}$ , mais deux questions :

1. A t'on  $f(x^{(k+1)}) \leq f(x^{(k)})$  ?
2. A t'on  $\lim_{k \rightarrow +\infty} x^{(k)} = \bar{x}$  ?

En général, non et non...

# Convergence de l'algorithme GPF

## Theorem

Soit  $f \in C^1(\mathbb{R}^n, \mathbb{R})$ . On suppose qu'il existe  $\alpha > 0$  et  $M > 0$  tels que

(mon)  $(\nabla f(x) - \nabla f(y)) \cdot (x - y) \geq \alpha|x - y|^2$  pour tout  $x, y \in \mathbb{R}^n$

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

Alors, si  $\rho < \frac{2\alpha}{M^2}$ , on a bien

(des)  $f(x^{(k+1)}) \leq f(x^{(k)})$  pour tout  $k \geq 0$

(cve)  $\lim_{k \rightarrow +\infty} x^{(k)} = \bar{x}$  et  $\bar{x} = \operatorname{argmin}_{\mathbb{R}^n} f$

petit rappel : l'hypothèse (mon) implique que  $f$  est strictement convexe et  $f(x) \rightarrow +\infty$  quand  $|x| \rightarrow +\infty$  et donc qu'il existe un unique  $\bar{x} \in \mathbb{R}^n$  tel que  $f(\bar{x}) \leq f(x)$  pour tout  $x \in \mathbb{R}^n$ . De plus  $\bar{x}$  est caractérisé par  $\nabla f(\bar{x}) = 0$

## Démonstration du théorème, convergence vers $\bar{x}$

On pose  $h(x) = x - \rho \nabla f(x)$

L'algorithme (GPF) est l'algorithme du point fixe pour  $h$ . On déjà vu (Cours 6, point fixe de relaxation) que sous les hypothèses (mon)-(lip), si  $\rho < \frac{2\alpha}{M^2}$ , la fonction  $h$  est strictement contractante et  $\lim_{k \rightarrow +\infty} x^{(k)} = \bar{x}$  avec  $\nabla f(\bar{x}) = 0$  (et donc ici  $\bar{x} = \operatorname{argmin}_{\mathbb{R}^n} f$ )

rappel du cours 6,  $h(x) = x - \omega g(x)$  avec  $g$  vérifiant (mon)-(lip) et  $0 < \omega < \frac{2\alpha}{M^2}$ , théorème 2.8

## Dém. du théorème, (GPF) est une méthode de descente

On suppose que  $f$  vérifie (mon)-(lip),  $\rho < \frac{2\alpha}{M^2}$ ,  $\nabla f(x^{(k)}) \neq 0$ ,  
 $x^{(k+1)} = x^{(k)} - \rho \nabla f(x^{(k)})$ . On va montrer  $f(x^{(k+1)}) < f(x^{(k)})$

Remarque : Les hypothèses (mon)-(lip) impliquent  $\alpha \leq M$  car

$$\alpha|x - y|^2 \leq (\nabla f(x) - \nabla f(y)) \cdot (x - y) \leq M|x - y|^2$$

et donc  $\rho < \frac{2\alpha}{M^2} < \frac{2}{M}$

$$y = x^{(k+1)}, \quad x = x^{(k)}, \quad y = x - \rho \nabla f(x)$$

$$\begin{aligned} f(y) - f(x) &= \int_0^1 \nabla f(x + t(y - x)) \cdot (y - x) dt = \\ & \int_0^1 (\nabla f(x + t(y - x)) - \nabla f(x)) \cdot (y - x) dt + \nabla f(x) \cdot (y - x) \\ & \leq \frac{M}{2}|y - x|^2 - \frac{1}{\rho}|y - x|^2 < 0, \end{aligned}$$

car  $\rho < \frac{2}{M}$

# Algorithme du Gradient à Pas Optimal (GP0)

Hypothèse :  $f \in C^1(\mathbb{R}^n, \mathbb{R})$

**Initialisation**  $x^{(0)} \in \mathbb{R}^n$

**Itération** pour  $k \geq 0$ ,

1. on choisit  $w^{(k)} = -\nabla f(x^{(k)})$ ,
2. on choisit (si c'est possible)  $\rho_k > 0$  tel que  $f(x^{(k)} + \rho w^{(k)}) \leq f(x^{(k)} + \rho w^{(k)})$  pour tout  $\rho \geq 0$ ,
3.  $x^{(k+1)} = x^{(k)} + \rho_k w^{(k)}$

Si  $\nabla f(x^{(k)}) \neq 0$ ,  $w^{(k)}$  est une dds au point  $x^{(k)}$ , mais trois questions :

1. Existence de  $\rho_k$  ?
2. Calcul de  $\rho_k$  ?
3. A t'on  $\lim_{k \rightarrow +\infty} x^{(k)} = \bar{x}$  ?

# Convergence de l'algorithme GP0, questions 1 et 3

## Theorem

Soit  $f \in C^1(\mathbb{R}^n, \mathbb{R})$  telle que  $f(x) \rightarrow +\infty$  quand  $\|x\| \rightarrow +\infty$  Alors

1. la suite  $(x^{(k)})_{k \in \mathbb{N}}$  est bien définie par l'algorithme (GPO) (c'est-à-dire que  $\rho_k$  existe pour tout  $k$ ),
2. la suite  $(x^{(k)})_{k \in \mathbb{N}}$  est bornée et toute sous suite convergente converge vers un point qui annule  $\nabla f$ ,
3. si  $f$  est convexe, toute sous suite convergente converge vers un point appartenant à  $\operatorname{argmin}_{\mathbb{R}^n} f$ ,
4. si  $f$  est strictement convexe  $\lim_{k \rightarrow +\infty} x^{(k)} = \bar{x}$  et  $\bar{x} = \operatorname{argmin}_{\mathbb{R}^n} f$

La démonstration sera faite en td, le point difficile est le deuxième item

## Calcul de $\rho_k$ dans (GPO), question 2

$x^{(k)}$  est connu,

$w^{(k)} = -\nabla f(x^{(k)}) \neq 0$  (sinon  $x^{(k+1)} = x^{(k)}$ , l'algorithme s'arrête)

On suppose qu'il existe  $\rho_k \geq 0$  tel

$f(x^{(k)} + \rho_k w^{(k)}) \leq f(x^{(k)} + \rho w^{(k)})$  pour tout  $\rho \geq 0$

On pose  $\varphi(\rho) = f(x^{(k)} + \rho w^{(k)})$

Comme  $w^{(k)}$  est une dds au point  $x^{(k)}$  on a  $\rho_k > 0$  et donc

$\varphi'(\rho_k) = 0$ , c'est-à-dire

$$\nabla f(x^{(k)} + \rho_k w^{(k)}) \cdot w^{(k)} = 0$$

Ceci permet parfois de calculer  $\rho_k$

Noter aussi  $\nabla f(x^{(k+1)}) \cdot w^{(k)} = 0$

## Calcul de $\rho_k$ , fonctionnelle quadratique

$f(x) = \frac{1}{2}Ax \cdot x - b \cdot x$  où  $A \in \mathcal{M}_n(\mathbb{R})$  est s.d.p. et  $b \in \mathbb{R}^n$

$$\nabla f(x) = Ax - b$$

Pour  $w \neq 0$ , on cherche  $\rho$  tel que

$$\nabla f(x + \rho w) \cdot w = 0,$$

c'est-à-dire  $(Ax + \rho Aw - b) \cdot w = 0$  et donc

$$\rho = \frac{(b - Ax) \cdot w}{Aw \cdot w}$$

Ceci permet le calcul de  $\rho$  quelquesoit  $w$  dds au point  $x$

Le cas d'une fonctionnelle générale est plus compliqué

## Algorithme du gradient conjugué (1)

$f(x) = \frac{1}{2}Ax \cdot x - b \cdot x$  où  $A \in \mathcal{M}_n(\mathbb{R})$  est s.d.p. et  $b \in \mathbb{R}^n$

Rappel :  $\nabla f(x) = Ax - b$

idée (1952) :

Construire la suite des itérées  $x^{(k)}$  telle que :

1. Pour chaque  $k \geq 0$ ,  $x^{(k+1)} = x^{(k)} + \rho_k w^{(k)}$  avec  $w^{(k)}$  dds en  $x^{(k)}$  et  $\rho_k$  optimal dans la direction  $w^{(k)}$
2.  $Aw^{(k)} \cdot w^{(l)} = 0$  si  $l < k$  (orthogonalité des  $w^{(k)}$  pour le produit scalaire induit par  $A$ )
3.  $(b - Ax^{(k)}) \cdot w^{(l)} = 0$  si  $l < k$

La propriété 1 est facile à obtenir si  $w^{(k)}$  est une dds. Pour les propriétés 2 et 3, la seule égalité facile est

$$(b - Ax^{(k)}) \cdot w^{(k-1)} = -\nabla f(x^{(k)}) \cdot w^{(k-1)} = 0,$$

car  $\rho_k$  est optimal dans la direction  $w^{(k)}$

## Algorithme du gradient conjugué (2)

intérêt (si on peut construire une telle suite) :

La suite s'arrête au plus tard à l'itération  $n$  car on alors  $(b - Ax^{(n)})$  orthogonal à la famille  $\{w^{(0)} \dots w^{(n-1)}\}$  qui forme une base de  $\mathbb{R}^n$  (car c'est une famille de  $n$  vecteurs orthogonaux 2 à 2 non nuls).

Donc,  $Ax^{(n)} = b$

il s'agit donc d'une méthode directe mais on peut même espérer avoir "presque" la solution en moins de  $n$  itérations

Pour avoir les propriétés demandées, il suffit (par miracle) de choisir pour  $k > 0$

$w^{(k)} = (b - Ax^{(k)}) + \lambda_k w^{(k-1)}$  avec  $\lambda_k$  choisi pour avoir  $Aw^{(k)} \cdot w^{(k-1)} = 0$

(On a alors  $Aw^{(k)} \cdot w^{(l)} = 0$  et  $(b - Ax^{(k)}) \cdot w^{(l)} = 0$  pour tout  $l < k$  et pas seulement pour  $l = k - 1$ )

# Gradient conjugué préconditionné

Intérêt réel de la méthode du gradient conjugué : nul...

Préconditionnement, 1980 :

La méthode est extrêmement intéressante si on l'utilise avec un "préconditionnement" consistant à remplacer  $A$  par  $L^{-1}A(L^t)^{-1}$  et  $b$  par  $L^{-1}b$ , où  $L$  est "proche" de la matrice de factorisation de  $A$  par la méthode de Choleski

Le bon choix de la matrice de préconditionnement dépend du problème considéré

# Méthode de Newton pour minimiser $f$

On cherche par la méthode de Newton un point annulant  $\nabla f$ .

Rappel :  $J_{\nabla f}(x) = H_f(x)$  (on suppose  $f$  de classe  $C^2$ )

**Initialisation**  $x^{(0)} \in \mathbb{R}^n$

**Itération** pour  $k \geq 0$ ,  $H_f(x^{(k)})(x^{(k+1)} - x^{(k)}) = -\nabla f(x^{(k)})$

Si la matrice  $H_f(x^{(k)})$  est s.d.p. (ce qui est presque toujours vrai si  $f$  est strictement convexe), cette méthode est une méthode de descente

Elle s'écrit  $x^{(k+1)} = x^{(k)} + w^{(k)}$  avec

$w^{(k)} = -(H_f(x^{(k)}))^{-1} \nabla f(x^{(k)})$  et, si  $\nabla f(x^{(k)}) \neq 0$ ,

$$w^{(k)} \cdot \nabla f(x^{(k)}) = -(H_f(x^{(k)}))^{-1} \nabla f(x^{(k)}) \cdot \nabla f(x^{(k)}) < 0$$

Intérêt de la méthode : convergence quadratique

Inconvénient de la méthode : calculer la Hessienne de  $f$

# Méthode de quasi-Newton pour minimiser $f$

Objectif : éviter de calculer la Hessienne de  $f$

Idée : remplacer dans la méthode de Newton la matrice  $H_f(x^{(k)})$  par une matrice  $B^{(k)}$ , facile à calculer et telle que :

1.  $B^{(k)}$  est s.d.p.
2.  $B^{(k)}$  approche de mieux en mieux la hessienne de  $f$  au cours des itérations

**Initialisation**  $x^{(0)} \in \mathbb{R}^n$

**Itération** pour  $k \geq 0$ ,  $B^{(k)}(x^{(k+1)} - x^{(k)}) = -\nabla f(x^{(k)})$

Question : Comment choisir  $B^{(k)}$  ?

## Choix de $B^{(k)}$ , méthode (BFGS)

Rappel (idée de Broyden) :

Pour que  $B^{(k)}$  se rapproche de la hessienne de  $f$  on va demander  $B^{(k)}(x^{(k)} - x^{(k-1)}) = \nabla f(x^{(k)}) - \nabla f(x^{(k-1)})$

**Initialisation**  $B^{(0)}$  s.d.p. (par exemple  $B^{(0)} = I$ )

**Itération** pour  $k > 0$ , on note

$$s^{(k)} = x^{(k)} - x^{(k-1)}, y^{(k)} = \nabla f(x^{(k)}) - \nabla f(x^{(k-1)}).$$

Si  $s^{(k)} \neq 0$ , on choisit

$$B^{(k)} = B^{(k-1)} + \frac{y^{(k)}(y^{(k)})^t}{(y^{(k)})^t s^{(k)}} - \frac{B^{(k-1)} s^{(k)} (s^{(k)})^t B^{(k-1)}}{(s^{(k)})^t B^{(k-1)} s^{(k)}}$$

On a bien  $B^{(k)}$  symétrique et  $B^{(k)}(s^{(k)}) = y^{(k)}$

**Theorem (1976)**

$f \in C^2(\mathbb{R}^n, \mathbb{R})$  strictement convexe et  $f(x) \rightarrow +\infty$  quand  $\|x\| \rightarrow +\infty$ .

On note  $\bar{x} = \operatorname{argmin}_{\mathbb{R}^n} f$ . On suppose  $H_f(\bar{x})$  est s.d.p.

Alors  $\lim_{k \rightarrow +\infty} x^{(k)} = \bar{x}$  et la convergence est superlinéaire

Remarque : sous les hypothèses du théorème,  $(y^{(k)})^t s^{(k)} > 0$  si  $s^{(k)} \neq 0$

# Résumé

1. Méthodes de gradient, (GPF) et (GPO). La convergence est en général linéaire
2. Méthode de gradient conjugué pour fonctionnelle quadratique (donc correspond à la résolution d'un système linéaire)
3. Méthode de Newton. La convergence est quadratique
4. Méthode de quasi-Newton. La convergence est superlinéaire (mais, par rapport aux méthodes de gradient, demande, à chaque itération, la résolution d'un système linéaire)