



# Optimisation non linéaire sans contraintes

Recherche opérationnelle  
GC-SIE

Méthodes de descente

# Directions de descente

- **Problème :**

$$\min f : \mathbb{R}^n \rightarrow \mathbb{R}$$

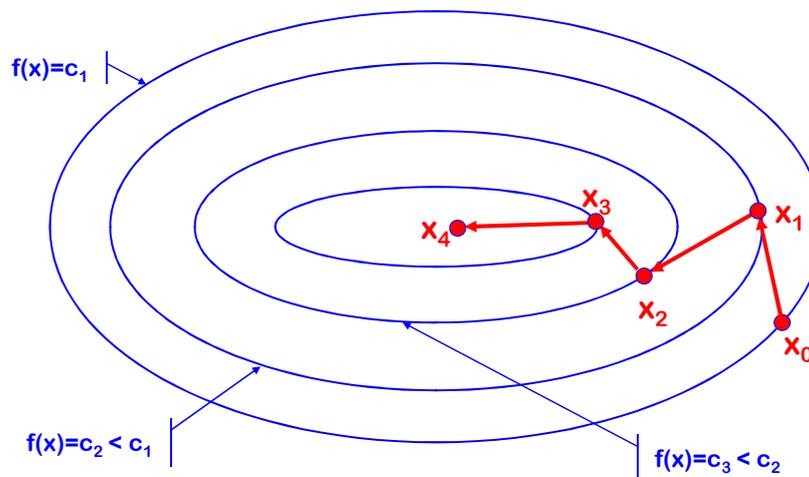
$f$  continûment différentiable

- **Idée :**

- On démarre d'un point  $x_0$
- On génère des vecteurs  $x_1, x_2, \dots$  tels que la valeur de  $f$  décroît à chaque itération :

$$f(x_{k+1}) < f(x_k) \quad k=1,2,\dots$$

# Directions de descente



## Directions de descente

- Soit  $x \in \mathbb{R}^n$  tel que  $\nabla f(x) \neq 0$ .
- Considérons la demi-droite

$$x_\alpha = x - \alpha \nabla f(x)$$

- Théorème de Taylor (1<sup>er</sup> ordre)

$$f(x+s) = f(x) + \nabla f(x)^T s + o(\|s\|)$$

avec  $s = x_\alpha - x$

$$\begin{aligned} f(x_\alpha) &= f(x) + \nabla f(x)^T (x_\alpha - x) + o(\|x_\alpha - x\|) \\ &= f(x) - \alpha \|\nabla f(x)\|^2 + o(\alpha \|\nabla f(x)\|) \\ &= f(x) - \alpha \|\nabla f(x)\|^2 + o(\alpha) \end{aligned}$$

## Directions de descente

$$f(x_\alpha) = f(x) - \alpha \|\nabla f(x)\|^2 + o(\alpha)$$

- Si  $\alpha$  est petit, on peut négliger  $o(\alpha)$
- Donc, pour  $\alpha$  positif mais petit,

$$f(x_\alpha) < f(x)$$

**Théorème :**

- Il existe  $\delta$  tel que, pour tout  $\alpha \in ]0, \delta[$

$$f(x - \alpha \nabla f(x)) < f(x)$$

## Directions de descente

- Gradient = plus forte pente
- **Question** : y a-t-il d'autres directions de descente que  $-\nabla f(x)$  ?
- Appliquons le même raisonnement avec  $d \neq 0$ .

## Directions de descente

- Considérons la demi-droite

$$x_\alpha = x + \alpha d$$

- Théorème de Taylor (1<sup>er</sup> ordre)

$$f(x+s) = f(x) + \nabla f(x)^T s + o(\|s\|)$$

avec  $s = x_\alpha - x$

$$f(x_\alpha) = f(x) + \nabla f(x)^T (x_\alpha - x) + o(\|x_\alpha - x\|)$$

$$= f(x) + \alpha \nabla f(x)^T d + o(\alpha \|d\|)$$

$$= f(x) + \alpha \nabla f(x)^T d + o(\alpha)$$

## Directions de descente

$$f(x_\alpha) = f(x) + \alpha \nabla f(x)^T d + o(\alpha)$$

- Si  $\alpha$  est petit, on peut négliger  $o(\alpha)$
- Pour avoir  $f(x_\alpha) < f(x)$ , il faut

$$\nabla f(x)^T d < 0$$

### Théorème :

- Soit  $d$  tel que  $\nabla f(x)^T d < 0$ . Il existe  $\delta$  tel que, pour tout  $\alpha \in ]0, \delta[$

$$f(x + \alpha d) < f(x)$$

## Directions de descente

### Définition :

- Soit  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , une fonction continûment différentiable, et  $x$  un vecteur de  $\mathbb{R}^n$ . Le vecteur  $d \in \mathbb{R}^n$  est appelé **direction de descente** de  $f$  en  $x$  ssi

$$\nabla f(x)^T d < 0$$

## Méthodes de descente

### Algorithme de base :

- Soit  $x_0 \in \mathbb{R}^n$ . Poser  $k=0$ .
- Tant que  $\nabla f(x_k) \neq 0$ 
  - Choisir  $d_k$  tel que  $\nabla f(x_k)^T d_k < 0$
  - Choisir  $\alpha_k > 0$
  - Poser  $x_{k+1} = x_k + \alpha_k d_k$

## Méthodes de descente

### Notes :

- Il y a beaucoup de choix possibles
- En général, on choisit  $\alpha_k$  tel que
$$f(x_k + \alpha_k d_k) < f(x_k)$$
mais il y a des exceptions
- Il n'y a aucune garantie de convergence pour l'algorithme de base

## Choix de la direction

- Ecrivons  $\mathbf{d}_k = -\mathbf{D}_k \nabla f(\mathbf{x}_k)$   
où  $\mathbf{D}_k$  est une matrice  $n \times n$
- La condition  $\nabla f(\mathbf{x}_k)^\top \mathbf{d}_k < 0$  s'écrit  
$$\nabla f(\mathbf{x}_k)^\top \mathbf{D}_k \nabla f(\mathbf{x}_k) > 0$$
- Si  $\mathbf{D}_k$  est définie positive, cette condition est toujours vérifiée.
- Le choix de la direction revient donc au choix d'une matrice définie positive.

## Choix de la direction

Quelques exemples souvent utilisés

- **Méthode de la plus forte pente**

–  $\mathbf{D}_k = \mathbf{I}$

–  $\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \nabla f(\mathbf{x}_k)$

- **Méthode de Newton**

–  $\mathbf{D}_k = (\nabla^2 f(\mathbf{x}_k))^{-1}$

–  $\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k (\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$

**Attention: il faut que  $\nabla^2 f(\mathbf{x}_k)$  soit inversible et déf. pos.**

## Choix de la direction

- Mise à l'échelle diagonale

$$- D_k = \begin{pmatrix} d_{k1} & 0 & 0 & \dots & 0 \\ 0 & d_{k2} & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & d_{kn} \end{pmatrix}$$

-  $d_{ki} > 0$  pour tout  $i$

- Exemple :  $d_{ki} = \left( \frac{\partial^2 f(x_k)}{\partial x_i^2} \right)^{-1}$

## Choix de la direction

- Méthode de Newton modifiée

-  $D_k = (\nabla^2 f(x_0))^{-1}$

-  $x_{k+1} = x_k - \alpha_k (\nabla^2 f(x_0))^{-1} \nabla f(x_k)$

- etc...

# Choix du pas

## 1. Règle de minimisation

- Problème à une seule variable

## 2. Règle d'approximation

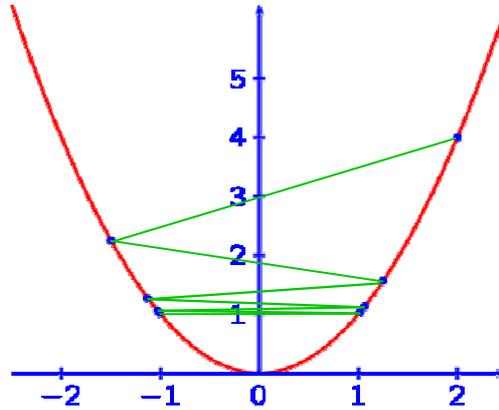
- Minimisation prend du temps
- Section d'or nécessite l'unimodalité
- A-t-on besoin du minimum exact ?
- Idée :
  - Choisir un pas qui diminue suffisamment la valeur de la fonction.

# Choix du pas : approximation

- Démarche:
  - Voyons d'abord ce que sont de « mauvais » pas.
  - Déterminons des règles empêchant les « mauvais » pas.
- Prenons
  - $f(x) = x^2$
  - $x^* = 0$

## Choix du pas : approximation

- Algorithme
  - $d_k = (-1)^{k+1}$
  - $\alpha_k = 2+3(2^{-(k+1)})$
  - $x_k = (-1)^k(1+2^{-k})$
- Lorsque  $k$  est grand
  - $d_k = (-1)^{k+1}$
  - $\alpha_k \approx 2$
  - $x_k \approx (-1)^k$



## Choix du pas : approximation

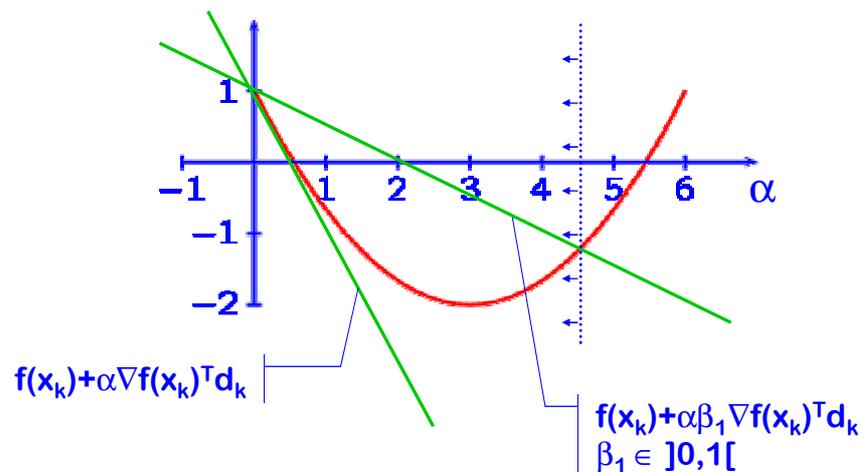
- Algorithme
  - $d_k = (-1)^{k+1}$
  - $\alpha_k = 2+3(2^{-(k+1)})$
  - $x_k = (-1)^k(1+2^{-k})$
- Lorsque  $k$  est grand
  - $d_k = (-1)^{k+1}$
  - $\alpha_k \approx 2$
  - $x_k \approx (-1)^k$

$k$	$x_k$	$d_k$	$\alpha_k$	$f(x_k)$
0	2.000	-1	3.500	4.000
1	-1.500	1	2.750	2.250
2	1.250	-1	2.375	1.563
3	-1.125	1	2.188	1.266
4	1.063	-1	2.094	1.129
5	-1.031	1	2.047	1.063
10	1.001	-1	2.001	1.002
999	-1.000	1	2.000	1.000
1000	1.000	-1	2.000	1.000

## Choix du pas : approximation

- Problème :
  - très petites diminutions de  $f$  relativement à la longueur des pas
- Solution :
  - exiger une diminution suffisante de  $f$

## Choix du pas : approximation



## Choix du pas : approximation

- On choisit  $\alpha_k$  tel que

$$f(x_k + \alpha_k d_k) \leq f(x_k) + \alpha_k \beta_1 \nabla f(x_k)^T d_k$$
$$\beta_1 \in ]0,1[$$

- Reprenons l'exemple (k grand et impair)

- $f(x) = x^2$ ,  $x_k = -1$ ,  $d_k = 1$ ,  $\alpha_k = 2$ ,  $f'(x) = 2x$

$$f(-1 + 2 \cdot 1) \leq 1 + 2\beta_1(-2 \cdot 1)$$

$$1 \leq 1 - 4\beta_1$$

$$4\beta_1 \leq 0$$

Impossible

L'algorithme sera rejeté par cette règle

## Choix du pas : approximation

- Conditions d'Armijo-Goldstein

$$f(x_k + \alpha_k d_k) \leq f(x_k) + \alpha_k \beta_1 \nabla f(x_k)^T d_k$$

$$\beta_1 \in ]0,1[$$

## Choix du pas : approximation

### Algorithme de recherche linéaire

- Soient  $g(\alpha)$ ,  $\beta_1, \lambda \in ]0,1[$ ,  $\alpha_0 > 0$
- Pour  $k=1,2,\dots$ 
  - Si  $f(x_k + \alpha_k d_k) \leq f(x_k) + \alpha_k \beta_1 \nabla f(x_k)^T d_k$  alors  $\alpha^* = \alpha_k$   
**STOP**
  - $\alpha_{k+1} = \lambda \alpha_k$

## Convergence

### Concept de non orthogonalité

- Supposons que  $d_k$  est déterminée de manière unique par  $x_k$ .
- On dit que la suite  $(d_k)_{k=0,1,\dots}$  est en **relation gradient** avec la suite  $(x_k)_{k=0,1,\dots}$  si la propriété suivante est vérifiée :

- Pour toute sous-suite  $(x_k)_{k \in \mathcal{K}}$  qui converge vers un point non stationnaire, la sous-suite correspondante  $(d_k)_{k \in \mathcal{K}}$  est bornée et vérifie :

$$\limsup_{\{k \rightarrow \infty, k \in \mathcal{K}\}} \nabla f(x_k)^T d_k < 0$$

## Convergence

### Notes :

- On peut souvent garantir a priori que  $(d_k)$  est en relation-gradient.
- En particulier, c'est le cas si
  - $d_k = -D_k \nabla f(x_k)$ , et
  - les valeurs propres de  $D_k$  sont bornées, i.e. pour  $c_1$  et  $c_2 > 0$ , on a

$$c_1 \|z\|^2 \leq z^T D_k z \leq c_2 \|z\|^2, \forall z \in \mathbb{R}^n, k=0,1,\dots$$

## Convergence

### Théorème :

- Si  $(d_k)$  est en relation-gradient avec  $(x_k)$
- Si le pas est choisi
  - soit par la règle de minimisation
  - soit par la règle d'Armijo-Goldstein
- Alors tous les points limites de  $(x_k)$  sont stationnaires.

## Critère d'arrêt

- En général, ces méthodes ne permettent pas de trouver la solution en un nombre fini d'itérations.
- Quand arrête-t-on les itérations ?

### Critère 1:

$$\|\nabla f(x_k)\| < \varepsilon, \text{ avec } \varepsilon > 0 \text{ petit.}$$

- Problèmes :
  - Supposons  $\varepsilon=10^{-3}$ , et  $f(x) \in [10^{-7}, 10^{-5}]$ . Il est probable que toutes les valeurs de  $x$  vérifieront la condition d'arrêt.
  - Par contre, si  $f(x) \in [10^5, 10^7]$ , cela n'arrivera peut-être jamais.

## Critère d'arrêt

### Critère 2 :

$$\|r(x)\|_{\infty} \leq \varepsilon, \text{ avec } \varepsilon > 0 \text{ petit,}$$

$$\text{avec } r(x)_i = (\nabla f(x)_i x_i) / f(x).$$

$r(x)$  est le gradient relatif en  $x$ .

Ce critère est indépendant de changement d'unités en  $f$  et en  $x$ .

Attention si  $f$  ou  $x$  est proche de 0.



## Critère d'arrêt

Critère 3 :

$$\max_{1 \leq i \leq n} \left| \frac{\nabla f(x_k)_i \max(|(x_k)_i|, tx_i)}{\max(|f(x_k)|, tf)} \right| \leq \varepsilon$$

où

- $\varepsilon > 0$  est petit.
- $tx_i$  est une valeur typique de  $x_i$ .
- $tf$  est une valeur typique de  $f$ .