



# Optimisation

Fabrice Rossi

Télécom ParisTech

## Introduction

## Outils mathématiques

Différentiabilité

Convexité

## Résultats théoriques d'optimisation sans contrainte

Existence et unicité d'un minimum

Conditions d'optimalité

## Algorithmes

Fonctions définies sur  $\mathbb{R}$

Fonctions définies sur  $\mathbb{R}^n$

## Introduction

### Outils mathématiques

Différentiabilité

Convexité

### Résultats théoriques d'optimisation sans contrainte

Existence et unicité d'un minimum

Conditions d'optimalité

### Algorithmes

Fonctions définies sur  $\mathbb{R}$

Fonctions définies sur  $\mathbb{R}^n$



## Régression linéaire multiple

- Expliquer  $y$  par une combinaison linéaire des  $(x_j)_{1 \leq j \leq p}$

$$\hat{y} = \sum_{j=1}^n a_j x_j = \langle \mathbf{a}, \mathbf{x} \rangle$$

- Comment choisir les  $a_j$  ?



## Régression linéaire multiple

- Expliquer  $y$  par une combinaison linéaire des  $(x_j)_{1 \leq j \leq p}$

$$\hat{y} = \sum_{j=1}^n a_j x_j = \langle \mathbf{a}, \mathbf{x} \rangle$$

- Comment choisir les  $a_j$  ?
- Minimisation de l'erreur quadratique sur un ensemble d'exemples  $(y_i, \mathbf{x}_i)_{1 \leq i \leq n}$

$$\begin{aligned} \mathbf{a}^* &= \arg \min_{\mathbf{a}} \sum_{i=1}^n (y_i - \langle \mathbf{a}, \mathbf{x}_i \rangle)^2 \\ &= \arg \min_{\mathbf{a}} \|\mathbf{y} - \mathbf{a}^T X\|_2^2, \end{aligned}$$

avec  $X = (\mathbf{x}_1, \dots, \mathbf{x}_n)$

- Pas de contrôle de  $\mathbf{a}$  :
  - explosion possible des coefficients
  - problème mal conditionné
  - trop de coefficients non nuls

- Pas de contrôle de  $\mathbf{a}$  :
  - explosion possible des coefficients
  - problème mal conditionné
  - trop de coefficients non nuls
- Régression *ridge* :

- contrainte sur  $\|\mathbf{a}\|_2 = \sqrt{\sum_{j=1}^p a_j^2}$

$$\begin{array}{ll} \text{minimiser} & \|\mathbf{y} - \mathbf{a}^T X\|_2^2 \\ \text{avec} & \|\mathbf{a}\|_2 \leq \lambda \end{array}$$

- Pas de contrôle de  $\mathbf{a}$  :
  - explosion possible des coefficients
  - problème mal conditionné
  - trop de coefficients non nuls
- Régression *ridge* :

- contrainte sur  $\|\mathbf{a}\|_2 = \sqrt{\sum_{j=1}^p a_j^2}$

$$\begin{array}{ll} \text{minimiser} & \|\mathbf{y} - \mathbf{a}^T X\|_2^2 \\ \text{avec} & \|\mathbf{a}\|_2 \leq \lambda \end{array}$$

- Régression parcimonieuse (*lasso*) :

- contrainte sur  $\|\mathbf{a}\|_1 = \sum_{j=1}^p |a_j|$

$$\begin{array}{ll} \text{minimiser} & \|\mathbf{y} - \mathbf{a}^T X\|_2^2 \\ \text{avec} & \|\mathbf{a}\|_1 \leq \lambda \end{array}$$



- Objectif : investissement dans un portefeuille d'actifs avec minimisation du risque sous contrainte de rendement
- Modèle :
  - $r_i$  rendement de l'actif  $i$
  - évolution stochastique :  $\mathbf{r}$  est de moyenne  $\boldsymbol{\mu}$  et de covariance  $\Sigma$
  - proportion des actifs dans le portefeuille,  $\mathbf{x}$   
( $\sum_i x_i = 1 = \mathbf{1}^T \mathbf{x}$ )
  - espérance de rendement :  $\boldsymbol{\mu}^T \mathbf{x}$
  - variance du rendement :  $\mathbf{x}^T \Sigma \mathbf{x}$



- Objectif : investissement dans un portefeuille d'actifs avec minimisation du risque sous contrainte de rendement
- Modèle :
  - $r_i$  rendement de l'actif  $i$
  - évolution stochastique :  $\mathbf{r}$  est de moyenne  $\boldsymbol{\mu}$  et de covariance  $\boldsymbol{\Sigma}$
  - proportion des actifs dans le portefeuille,  $\mathbf{x}$   
( $\sum_i x_i = 1 = \mathbf{1}^T \mathbf{x}$ )
  - espérance de rendement :  $\boldsymbol{\mu}^T \mathbf{x}$
  - variance du rendement :  $\mathbf{x}^T \boldsymbol{\Sigma} \mathbf{x}$
- Problème

$$\begin{array}{ll} \text{minimiser} & \mathbf{x}^T \boldsymbol{\Sigma} \mathbf{x} \\ \text{avec} & \mathbf{1}^T \mathbf{x} = 1 \\ & \boldsymbol{\mu}^T \mathbf{x} \geq r_{\min} \end{array}$$



## Forme générale

- un problème d'optimisation ( $\mathcal{P}$ ) est défini par

$$\begin{array}{ll} \text{minimiser sur } \mathbb{R}^n & J(\mathbf{x}) \\ \text{avec} & g_i(\mathbf{x}) \leq 0, 1 \leq i \leq p \\ & h_j(\mathbf{x}) = 0, 1 \leq j \leq q \end{array}$$



## Forme générale

- un problème d'optimisation ( $\mathcal{P}$ ) est défini par

$$\begin{aligned} & \text{minimiser sur } \mathbb{R}^n && J(\mathbf{x}) \\ & \text{avec} && g_i(\mathbf{x}) \leq 0, 1 \leq i \leq p \\ & && h_j(\mathbf{x}) = 0, 1 \leq j \leq q \end{aligned}$$

- vocabulaire :

- $J$  (à valeur dans  $\mathbb{R} \cup \{\infty\}$ ) est la **fonction de coût**, la **fonction objectif** ou encore le **critère**
- les  $g_i$  sont les **contraintes d'inégalité**
- les  $h_j$  sont les **contraintes d'égalité**
- l'**ensemble des contraintes** est

$$\mathcal{C} = \{\mathbf{x} \in \mathbb{R}^n \mid g_i(\mathbf{x}) \leq 0, 1 \leq i \leq p \text{ et } h_j(\mathbf{x}) = 0, 1 \leq j \leq q\}$$

**ensemble des points admissibles** ou **réalisables**



- optimum local : meilleure valeur *localement* au sens de la métrique de l'espace et de l'ensemble des contraintes
- formellement :
  - $\mathcal{C} \subset X$  espace métrique et  $J$  de  $\mathcal{C}$  dans  $\mathbb{R}$
  - $x^* \in \mathcal{C}$  réalise un **minimum local** de  $J$  sur  $\mathcal{C}$  ssi  $\exists$  une boule ouverte  $B$  centrée en  $x^*$  telle que  $\forall x \in B \cap \mathcal{C}, J(x) \geq J(x^*)$
  - inégalité *stricte* pour  $x \neq x^* \rightarrow$  minimum local *strict*



- optimum local : meilleure valeur *localement* au sens de la métrique de l'espace et de l'ensemble des contraintes
- formellement :
  - $\mathcal{C} \subset X$  espace métrique et  $J$  de  $\mathcal{C}$  dans  $\mathbb{R}$
  - $x^* \in \mathcal{C}$  réalise un **minimum local** de  $J$  sur  $\mathcal{C}$  ssi  $\exists$  une boule ouverte  $B$  centrée en  $x^*$  telle que  $\forall x \in B \cap \mathcal{C}, J(x) \geq J(x^*)$
  - inégalité *stricte* pour  $x \neq x^* \rightarrow$  minimum local *strict*
- $x^* \in \mathcal{C}$  réalise un **minimum global** de  $J$  sur  $\mathcal{C}$  ssi  $\forall x \in \mathcal{C}, J(x) \geq J(x^*)$



- optimum local : meilleure valeur *localement* au sens de la métrique de l'espace et de l'ensemble des contraintes
- formellement :
  - $\mathcal{C} \subset X$  espace métrique et  $J$  de  $\mathcal{C}$  dans  $\mathbb{R}$
  - $x^* \in \mathcal{C}$  réalise un **minimum local** de  $J$  sur  $\mathcal{C}$  ssi  $\exists$  une boule ouverte  $B$  centrée en  $x^*$  telle que  $\forall x \in B \cap \mathcal{C}, J(x) \geq J(x^*)$
  - inégalité *stricte* pour  $x \neq x^* \rightarrow$  minimum local *strict*
- $x^* \in \mathcal{C}$  réalise un **minimum global** de  $J$  sur  $\mathcal{C}$  ssi  $\forall x \in \mathcal{C}, J(x) \geq J(x^*)$
- Propriété : minimum de  $J \Leftrightarrow$  maximum de  $-J$



- problème de moindres carrés
  - $J$  est quadratique et il n'y a pas de contraintes
  - résolution facile (inverse ou pseudo-inverse de matrice)
- programmation linéaire :
  - $J(\mathbf{x}) = \mathbf{c}^T \mathbf{x}$  (ou affine)
  - contraintes linéaires (ou affines)
  - résolution relativement facile
- programmation convexe :
  - les fonctions  $J$  et  $g_i$  sont convexes et les  $h_i$  affines
  - résolution possible
- cas général :
  - résolution complète (c.-à-d. trouver un minimum **global**) très difficile (coût exponentiel en la taille du problème)
  - résolution locale envisageable

## Introduction

## Outils mathématiques

Différentiabilité

Convexité

## Résultats théoriques d'optimisation sans contrainte

Existence et unicité d'un minimum

Conditions d'optimalité

## Algorithmes

Fonctions définies sur  $\mathbb{R}$

Fonctions définies sur  $\mathbb{R}^n$

- deux outils mathématiques fondamentaux pour l'analyse des problèmes d'optimisation
- différentiabilité :
  - approximation linéaire locale
  - tendances locales, par exemple plus grande pente
  - caractérisation des optima
- convexité :
  - pour les ensembles : on peut se promener sur un segment
  - pour les fonctions : quand on se promène sur un segment, la fonction reste « sous le segment »
  - existence d'optima
- lien important entre les deux propriétés : une fonction convexe est minorée globalement par son approximation linéaire locale

- espace vectoriel normé :
  - espace vectoriel
  - norme (définie positive, sous-additive et homogène)
- espace de Banach : espace vectoriel normé complet
- espace de Hilbert :
  - espace vectoriel
  - produit scalaire (bilinéaire, symétrique, défini positif)
  - complet

## Ordre un

- $J$  est définie sur ouvert  $U$  d'un Banach  $X$  et à valeurs dans  $\mathbb{R}$
- $J$  est **différentiable** (au sens de **Fréchet**) en  $x \in U$  s'il existe une forme linéaire **continue**  $DJ_x$  telle que

$$\lim_{\|h\|_X \rightarrow 0} \frac{J(x+h) - J(x) - DJ_x(h)}{\|h\|_X} = 0,$$

c'est-à-dire  $J(x+h) = J(x) + DJ_x(h) + o(\|h\|_X)$

## Ordre un

- $J$  est définie sur ouvert  $U$  d'un Banach  $X$  et à valeurs dans  $\mathbb{R}$
- $J$  est **différentiable** (au sens de **Fréchet**) en  $x \in U$  s'il existe une forme linéaire **continue**  $DJ_x$  telle que

$$\lim_{\|h\|_X \rightarrow 0} \frac{J(x+h) - J(x) - DJ_x(h)}{\|h\|_X} = 0,$$

c'est-à-dire  $J(x+h) = J(x) + DJ_x(h) + o(\|h\|_X)$

- si  $X$  est un espace de Hilbert, on définit le **gradient** de  $J$  en  $x$  comme l'élément de  $X$ , noté  $\nabla J(x)$ , tel que

$$DJ_x(h) = \langle \nabla J(x), h \rangle_X$$

Théorème de représentation de Riesz ( $X' = X$ )

## Exemples

- si  $J(x) = \langle a, x \rangle_x$ ,  $\nabla J(x) = a$
- dans  $\mathbb{R}^n$ , si  $J(\mathbf{x}) = \mathbf{x}^T A \mathbf{x}$ , alors  $\nabla J(\mathbf{x}) = (A + A^T) \mathbf{x}$
- cas particulier, si  $J(\mathbf{x}) = \|\mathbf{x}\|^2$ , alors  $\nabla J(\mathbf{x}) = 2\mathbf{x}$
- dans  $\mathbb{R}$ ,  $\nabla J(x) = J'(x)$
- dans  $\mathbb{R}^n$ ,

$$\nabla J(\mathbf{x}) = \left( \frac{\partial J}{\partial x_1}(\mathbf{x}), \dots, \frac{\partial J}{\partial x_n}(\mathbf{x}) \right)^T$$



## Différentielle au sens de Gâteaux

- différentielle au sens de Gâteaux : dérivée directionnelle linéaire continue
- $J$  est définie sur un ouvert  $U$  d'un Banach  $X$  et à valeurs dans  $\mathbb{R}$
- $J$  est **Gâteaux-différentiable** en  $x \in U$  ssi la dérivée directionnelle

$$J'(x, h) = \lim_{t \rightarrow 0^+} \frac{J(x + th) - J(x)}{t},$$

existe pour tout  $h \neq 0$  et si  $h \mapsto J'(x, h)$  est une forme linéaire continue

- linéaire n'est pas automatique :  $J(u, v) = \frac{u^2 v^2}{(u^2 + v^2)^{\frac{3}{2}}}$  en  $(0, 0)$   
avec  $J(u, v) = 0$
- la notion de gradient s'applique aussi dans le cas Gâteaux-différentiable :  $J'(x, h) = \langle \nabla J(x), h \rangle_X$  (pour  $X$  un Hilbert)
- Fréchet différentiable implique Gâteaux différentiable
- réciproque fausse :
  - $J(x, y) = \frac{x^6}{(y-x^2)^2+x^8}$  avec  $J(0, 0) = 0$
  - $J$  n'est pas continue en  $(0, 0)$ , mais est Gâteaux différentiable
  - principe de l'exemple : approche linéaire ok, mais approche « curviligne » discontinue

- différentielle : approximation linéaire locale
- différentielle à l'ordre deux : approximation **quadratique** locale
- $J$  est définie sur un ouvert  $U$  d'un Banach  $X$  et à valeurs dans  $\mathbb{R}$
- $J$  est différentiable à l'ordre deux en  $x \in U$  si elle est différentiable dans un voisinage de  $x$  et si  $u \mapsto DJ_u$  est différentiable en  $x$
- Remarque :
  - $DJ_u$  est à valeurs dans  $X'$  le dual (topologique) de  $X$
  - différentielle d'une fonction à valeurs dans un Banach  $V$  : il suffit de considérer  $\|J(x+h) - J(x) - DJ_x(h)\|_V$  (qui doit être  $o(\|h\|_X)$ )
  - Gâteaux ou Fréchet

- plus simplement,  $J$  est Fréchet différentiable à l'ordre deux en  $x \in U$  ssi il existe une application linéaire continue  $DJ_x$  et une application bilinéaire symétrique continue  $D^2J_x$  telles que

$$J(x + h) = J(x) + DJ_x(h) + \frac{1}{2}D^2J_x(h, h) + o(\|h\|_X^2)$$

- dans un Hilbert
  - $DJ_x(h) = \langle \nabla J(x), h \rangle_X$
  - $D^2J_x(h, h) = \langle \nabla^2 J(x)(h), h \rangle_X$  pour un endomorphisme symétrique continu  $\nabla^2 J(x)$  (appelé le **Hessien** par abus de langage)



## Deuxième ordre

### Exemples

- dans  $\mathbb{R}^n$ , la matrice Hessienne est donnée par

$$\nabla^2 J = \begin{pmatrix} \frac{\partial^2 J}{\partial x_1^2} & \frac{\partial^2 J}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 J}{\partial x_1 \partial x_n} \\ \frac{\partial^2 J}{\partial x_2 \partial x_1} & \frac{\partial^2 J}{\partial x_2^2} & \cdots & \frac{\partial^2 J}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 J}{\partial x_n \partial x_1} & \frac{\partial^2 J}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 J}{\partial x_n^2} \end{pmatrix}$$

- dans  $\mathbb{R}^n$ , si  $J(\mathbf{x}) = \mathbf{x}^T \mathbf{A} \mathbf{x}$ , alors  $\nabla^2 J(\mathbf{x}) = (\mathbf{A} + \mathbf{A}^T)$

- convexe : contient les segments entre ses points
- formellement,  $\mathcal{C} \subset X$  (un espace vectoriel) est **convexe** ssi

$$\forall x, y \in \mathcal{C}, \forall t \in [0, 1], (1 - t)x + ty \in \mathcal{C}$$

- convexe : contient les segments entre ses points
- formellement,  $\mathcal{C} \subset X$  (un espace vectoriel) est **convexe** ssi

$$\forall x, y \in \mathcal{C}, \forall t \in [0, 1], (1 - t)x + ty \in \mathcal{C}$$

- une fonction  $J$  de  $\mathcal{C} \subset X$  dans  $\mathbb{R} \cup \{\infty\}$  est **convexe** ssi :
  - $\mathcal{C}$  est convexe et,
  - $\forall x, y \in \mathcal{C}, \forall t \in [0, 1],$

$$J((1 - t)x + ty) \leq (1 - t)J(x) + tJ(y)$$

- convexité **stricte** si quand  $x \neq y$  et  $\forall t \in ]0, 1[$ ,

$$J((1 - t)x + ty) < (1 - t)J(x) + tJ(y)$$

- $J$  est (strictement) concave si  $-J$  est (strictement) convexe

- remarque :  $J$  est convexe ssi toutes les fonctions  $g(\lambda) = J(\mathbf{x} + \lambda h)$  sont convexes
- les fonctions affines  $J(\mathbf{x}) = \mathbf{a}^T \mathbf{x} + b$  sont convexes
- sur  $\mathbb{R}^n$  :
  - toute norme est convexe (inégalité triangulaire + homogénéité)
  - $J(\mathbf{x}) = \max_i x_i$  est convexe
  - $|x|$  est convexe
  - que dire de  $J(\mathbf{x}) = \mathbf{x}^T A \mathbf{x} + \mathbf{b}^T \mathbf{x} + c$  avec  $A$  symétrique ?

- domaine de définition d'une fonction convexe

$$\text{dom}(J) = \{x \in \mathcal{C} \mid J(x) < \infty\}$$

- $J$  est dite **propre** quand  $\text{dom}(J) \neq \emptyset$
- si  $\mathcal{C} \subset \mathbb{R}^n$ , une fonction convexe propre est continue sur l'intérieur de son domaine
  - dans le cas Banach, il faut supposer que  $J$  est majorée et non identiquement égale à  $-\infty$  sur un ouvert (non vide) inclus dans  $\text{dom}(J)$  pour obtenir la continuité



## Caractérisation par les différentielles

- soit  $J$  de  $\mathcal{C} \subset H$  (Hilbert) dans  $\mathbb{R}$  et Gâteaux différentiable sur  $\mathcal{C}$  un convexe,  $J$  est convexe ssi

$$\forall x, y \in \mathcal{C}, J(y) \geq J(x) + \langle \nabla J(x), y - x \rangle_H$$

- en d'autres termes : l'approximation linéaire **locale** est un minorant **global**



## Caractérisation par les différentielles

- soit  $J$  de  $\mathcal{C} \subset H$  (Hilbert) dans  $\mathbb{R}$  et Gâteaux différentiable sur  $\mathcal{C}$  un convexe,  $J$  est convexe ssi

$$\forall x, y \in \mathcal{C}, J(y) \geq J(x) + \langle \nabla J(x), y - x \rangle_H$$

- en d'autres termes : l'approximation linéaire **locale** est un minorant **global**
- preuve :

⇒ passage à la limite sur  $t$  positif de

$$\frac{J(x + t(y - x)) - J(x)}{t} \leq J(x) - J(y)$$

⇐ combinaison de deux applications de la minoration

$$J(x) \geq J(x + t(y - x)) - t \langle \nabla J(x + t(y - x)), y - x \rangle_H$$

$$J(y) \geq J(x + t(y - x)) + (1 - t) \langle \nabla J(x + t(y - x)), y - x \rangle_H$$



- autre caractérisation,  $J$  est convexe ssi  $\nabla J$  est un opérateur monotone

$$\forall x, y \in \mathcal{C}, \langle \nabla J(y) - \nabla J(x), y - x \rangle_H \geq 0$$

- remarque : la convexité stricte est impliquée par une version stricte des conditions (minoration globale et monotonie)
- ordre 2 : si  $J$  est  $C^2$ , elle est convexe ssi  $\nabla^2 J(x)$  est positive en tout  $x \in \mathcal{C}$

- que dire de  $J(x) = \frac{1}{x^2}$  ?
- maximum « assoupli » :  $J(\mathbf{x}) = \log \left( \sum_{i=1}^n \exp x_i \right)$
- $J(A) = \log \det A$  est concave sur l'ensemble des matrices symétriques définies positives

## Introduction

## Outils mathématiques

Différentiabilité

Convexité

## Résultats théoriques d'optimisation sans contrainte

Existence et unicité d'un minimum

Conditions d'optimalité

## Algorithmes

Fonctions définies sur  $\mathbb{R}$

Fonctions définies sur  $\mathbb{R}^n$

- on s'intéresse à  $(\mathcal{P}) \min_{\mathbf{x} \in \mathbb{R}^n} J(\mathbf{x})$  : pas de contrainte
- remarque :  $\inf_{\mathbf{x} \in \mathbb{R}^n} J(\mathbf{x})$  est toujours bien défini, le problème est de **réaliser** un minimum

- on s'intéresse à  $(\mathcal{P}) \min_{x \in \mathbb{R}^n} J(x)$  : pas de contrainte
- remarque :  $\inf_{x \in \mathbb{R}^n} J(x)$  est toujours bien défini, le problème est de **réaliser** un minimum
- $J$  est à valeurs dans  $\mathbb{R} \cup \{+\infty\}$
- $J$  est coercitive (*coercive*) si  $\lim_{\|x\| \rightarrow \infty} J(x) = +\infty$

- on s'intéresse à  $(\mathcal{P}) \min_{x \in \mathbb{R}^n} J(x)$  : pas de contrainte
- remarque :  $\inf_{x \in \mathbb{R}^n} J(x)$  est toujours bien défini, le problème est de **réaliser** un minimum
- $J$  est à valeurs dans  $\mathbb{R} \cup \{+\infty\}$
- $J$  est coercitive (*coercive*) si  $\lim_{\|x\| \rightarrow \infty} J(x) = +\infty$
- Résultat : si  $J$  est propre (non identiquement infinie), continue et coercitive alors  $(\mathcal{P})$  a **au moins** une solution

- En général, on a des minima, pas un minimum
- Cas particulier : si  $J$  est **strictement** convexe, alors  $(\mathcal{P})$  a au plus une solution

- En général, on a des minima, pas un minimum
- Cas particulier : si  $J$  est **strictement** convexe, alors  $(\mathcal{P})$  a **au plus** une solution
- Preuve :
  - soit  $d$  un minimum atteint en  $x$  et  $y$
  - si  $x \neq y$ , par convexité stricte, on a

$$J\left(\frac{1}{2}x + \frac{1}{2}y\right) < \frac{1}{2}J(x) + \frac{1}{2}J(y) = d,$$

ce qui est impossible, puisque  $d$  est le minimum de  $J$

- En général, on a des minima, pas un minimum
- Cas particulier : si  $J$  est **strictement** convexe, alors  $(\mathcal{P})$  a **au plus** une solution
- Preuve :
  - soit  $d$  un minimum atteint en  $x$  et  $y$
  - si  $x \neq y$ , par convexité stricte, on a

$$J\left(\frac{1}{2}x + \frac{1}{2}y\right) < \frac{1}{2}J(x) + \frac{1}{2}J(y) = d,$$

ce qui est impossible, puisque  $d$  est le minimum de  $J$

- Remarque :
  - un minimum **local** d'une fonction convexe est **global**
  - l'ensemble des points qui réalisent le minimum d'une fonction convexe est convexe

- Si  $J$  est strictement convexe et coercitive alors  $(\mathcal{P})$  admet une solution unique
- Cas intéressant, les fonctions **elliptiques** ( $\alpha$ -convexes ou fortement convexes) :
  - $J$  est elliptique ssi existe une constante d'ellipticité  $\alpha > 0$  telle que  $\forall x, y, t \in [0, 1]$ ,

$$J((1-t)x + ty) \leq (1-t)J(x) + tJ(y) - \frac{\alpha}{2}t(1-t)\|x - y\|^2$$

- elliptique  $\Rightarrow$  strictement convexe et coercitive

## ■ Caractérisations à l'ordre 1 :

- si  $J$  est différentiable au sens de Gâteaux,  $J$  est  $\alpha$ -convexe ssi :
  - $\forall x, y, J(y) \geq J(x) + \langle \nabla J(x), y - x \rangle + \frac{\alpha}{2} \|x - y\|^2$
  - $\forall x, y, \langle \nabla J(y) - \nabla J(x), y - x \rangle \geq \alpha \|x - y\|^2$

## ■ Caractérisation à l'ordre 2 :

- si  $J$  est  $C^2$ ,  $J$  est  $\alpha$ -convexe ssi :

$$\forall x, h, \langle \nabla J^2(x)h, h \rangle \geq \alpha \|h\|^2$$

- Preuves dans le même esprit que pour la caractérisation des fonctions convexes
- Exemple :  $J(\mathbf{x}) = \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{b}^T \mathbf{x} + c$  avec  $\mathbf{A}$  symétrique



## Condition d'optimalité du 1er ordre

- si  $J$  Gâteaux différentiable en  $x^*$  qui réalise un minimum local de  $J$ , alors  $\nabla J(x^*) = 0$
- preuve :
  - pour  $t$  assez petit  $J(x^*) \leq J(x^* + th)$  et donc  $J'(x, h) \geq 0$
  - par linéarité,  $\forall h, \langle \nabla J(x^*), h \rangle = 0$  et donc  $\nabla J(x^*) = 0$
  - la linéarité est indispensable, cf  $J(u, v) = \frac{u^2 v^2}{(u^2 + v^2)^{\frac{3}{2}}}$
- ce n'est pas une condition suffisante, par ex.  $J(x) = x^3$  en zéro
- vocabulaire :
  - $\nabla J(x^*) = 0$  est l'**équation d'Euler**
  - les  $x^*$  tels que  $\nabla J(x^*) = 0$  sont les **points critiques** ou **stationnaires**

- si  $J$  est Gâteaux différentiable et convexe alors  $x^*$  réalise un minimum global si et seulement si  $\nabla J(x^*) = 0$
- preuve : une fonction convexe est minorée globalement par son approximation linéaire locale

- si  $J$  est Gâteaux différentiable et convexe alors  $x^*$  réalise un minimum global si et seulement si  $\nabla J(x^*) = 0$
- preuve : une fonction convexe est minorée globalement par son approximation linéaire locale
- extension :
  - $J$  convexe n'est pas toujours différentiable, par ex.  
 $J(x) = |x|$
  - un **sous-gradient** de  $J$  en  $x$  est un vecteur  $v$  tel que

$$\forall y, J(y) - J(x) \geq \langle v, y - x \rangle$$

- la **sous-différentielle** de  $J$  en  $x$  est l'ensemble des sous-gradients, notée  $\partial J(x)$  (dans  $\mathbb{R}^n$ , c'est un ensemble non vide, compact et convexe)
- exemple  $\partial|x|(0) = [-1, 1]$
- CNS d'optimalité  $0 \in \partial J(x^*)$



## Condition d'optimalité du 2ème ordre

- si  $J$  est  $C^2$  et si  $x^*$  réalise un minimum de  $J$  alors :
  - $\nabla J(x^*) = 0$
  - $\langle \nabla^2 J(x^*)h, h \rangle \geq 0$  pour tout  $h$
- preuve par passage à la limite du développement limité à l'ordre 2
- ce n'est pas une condition suffisante, par ex.  $J(x) = x^3$



## Condition d'optimalité du 2ème ordre

- si  $J$  est  $C^2$  et si  $x^*$  réalise un minimum de  $J$  alors :
  - $\nabla J(x^*) = 0$
  - $\langle \nabla^2 J(x^*)h, h \rangle \geq 0$  pour tout  $h$
- preuve par passage à la limite du développement limité à l'ordre 2
- ce n'est pas une condition suffisante, par ex.  $J(x) = x^3$
- si  $J$  est  $C^2$  et si
  - $\nabla J(x^*) = 0$
  - il existe  $\alpha > 0$  tel que  $\langle \nabla^2 J(x^*)h, h \rangle \geq \alpha \|h\|^2$  ( $\nabla^2 J(x)$  est défini positif)
  - alors  $x^*$  réalise un minimum local (strict) de  $J$
- preuve identique
- **ellipticité locale**
- ce n'est pas une condition nécessaire, par ex.  $J(x) = x^4$

## Introduction

## Outils mathématiques

Différentiabilité

Convexité

## Résultats théoriques d'optimisation sans contrainte

Existence et unicité d'un minimum

Conditions d'optimalité

## Algorithmes

Fonctions définies sur  $\mathbb{R}$

Fonctions définies sur  $\mathbb{R}^n$

- algorithmes numériques :
  - pas de résultat exact
  - notion de convergence
  - coût par itération
- hypothèses algorithmiques :
  - fonctions plus ou moins régulières
  - compromis coût d'une itération et nombre d'itérations
- hypothèses mathématiques :
  - pour garantir la convergence
  - convexité plus ou moins forte



## Section dorée

- minimisation de  $f$  de  $\mathbb{R}$  dans  $\mathbb{R}$
- outil de base : permet de construire des algorithmes pour  $J$  définie sur  $\mathbb{R}^n$
- méthode de la section dorée :
  - trois points initiaux tels que  $f(x_1) > f(x_2)$  et  $f(x_3) > f(x_2)$
  - on cherche le minimum dans  $]x_1, x_3[$
  - on évalue  $f$  en  $x_4$  choisit dans le plus grand de deux intervalles déterminés par  $x_2$  par exemple  $[x_1, x_2]$
  - on fonction de  $f(x_4)$  :
    - on passe dans  $[x_4, x_3]$  si  $f(x_4) > f(x_2)$
    - sinon on passe dans  $[x_1, x_2]$
  - réduction optimale de la longueur de l'intervalle de recherche si le grand sous intervalle est  $\frac{1+\sqrt{5}}{2}$  plus long que le petit (nombre d'or)

- méthode de recherche d'un zéro d'une fonction  $f$  :
  - approximation linéaire de  $f$

$$f(x + h) = f(x) + hf'(x) + o(h)$$

- au premier ordre,  $f(x + h) = 0$  conduit à  $h = -\frac{f(x)}{f'(x)}$
  - algorithme :  $x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)}$
  - convergence quadratique :  $|x_{n+1} - x^*| \leq \mu |x_{n+1} - x^*|^2$
- application à la minimisation de  $f$  :
    - on cherche à résoudre l'équation d'Euler  $f'(x) = 0$
    - algorithme

$$x_{n+1} = x_n - \frac{f'(x_n)}{f''(x_n)}$$

- méthode naïve : optimisations successives par rapport à chaque variable
- algorithme :
  1. point initial  $\mathbf{x}^0$  (avec  $J(\mathbf{x}^0) < \infty$ )
  2. pour  $k \geq 1$  croissant
    - 2.1 pour  $i$  allant de 1 à  $n$  :

$$x_i^{k+1} = \arg \min_{x \in \mathbb{R}} J(x_1^{k+1}, \dots, x_{i-1}^{k+1}, x, x_{i+1}^k, \dots, x_n^k)$$

- 2.2 tester la convergence  $\|\mathbf{x}^{k+1} - \mathbf{x}^k\| < \epsilon$
- remarque : calcul du minimum dans  $\mathbb{R}$  par un algorithme adapté
  - **Attention** : très mauvais algorithme en pratique (mais analysable théoriquement...)

- on suppose :
  - $J$  coercive,
  - $J$   $C^1$  et  $\alpha$ -convexe,
  - $\nabla J$   $M$ -Lipschitzienne :

$$\forall \mathbf{x}, \mathbf{y} \quad \|\nabla J(\mathbf{x}) - \nabla J(\mathbf{y})\| \leq M \|\mathbf{x} - \mathbf{y}\|$$

- alors l'algorithme de relaxation converge vers le minimum de  $J$

■ principe général :

1. point initial  $\mathbf{x}_0$
2. pour  $k \geq 1$  croissant
  - 2.1 choisir une **direction de descente**  $\mathbf{d}_k \neq \mathbf{0}$
  - 2.2 choisir un **pas de descente**  $\rho_k > 0$
  - 2.3 poser  $\mathbf{x}_{k+1} = \mathbf{x}_k + \rho_k \mathbf{d}_k$
  - 2.4 tester la convergence (par ex.  $\|\mathbf{x}_{k+1} - \mathbf{x}_k\| < \epsilon$ )

## ■ principe général :

1. point initial  $\mathbf{x}_0$
2. pour  $k \geq 1$  croissant
  - 2.1 choisir une **direction de descente**  $\mathbf{d}_k \neq \mathbf{0}$
  - 2.2 choisir un **pas de descente**  $\rho_k > 0$
  - 2.3 poser  $\mathbf{x}_{k+1} = \mathbf{x}_k + \rho_k \mathbf{d}_k$
  - 2.4 tester la convergence (par ex.  $\|\mathbf{x}_{k+1} - \mathbf{x}_k\| < \epsilon$ )

## ■ il faut qu'on puisse descendre :

- on doit pouvoir trouver  $\rho_k$  tel que  $J(\mathbf{x}_{k+1}) < J(\mathbf{x}_k)$
- si  $J$  est convexe,  $J(\mathbf{x}_{k+1}) \geq J(\mathbf{x}_k) + \rho_k \langle \mathbf{v}, \mathbf{d}_k \rangle$  pour tout sous-gradient  $\mathbf{v}$  : on doit donc avoir  $\langle \mathbf{v}, \mathbf{d}_k \rangle < 0$  pour au moins un sous-gradient  $\mathbf{v}$

## ■ principe général :

1. point initial  $\mathbf{x}_0$
2. pour  $k \geq 1$  croissant
  - 2.1 choisir une **direction de descente**  $\mathbf{d}_k \neq \mathbf{0}$
  - 2.2 choisir un **pas de descente**  $\rho_k > 0$
  - 2.3 poser  $\mathbf{x}_{k+1} = \mathbf{x}_k + \rho_k \mathbf{d}_k$
  - 2.4 tester la convergence (par ex.  $\|\mathbf{x}_{k+1} - \mathbf{x}_k\| < \epsilon$ )

## ■ il faut qu'on puisse descendre :

- on doit pouvoir trouver  $\rho_k$  tel que  $J(\mathbf{x}_{k+1}) < J(\mathbf{x}_k)$
- si  $J$  est convexe,  $J(\mathbf{x}_{k+1}) \geq J(\mathbf{x}_k) + \rho_k \langle \mathbf{v}, \mathbf{d}_k \rangle$  pour tout sous-gradient  $\mathbf{v}$  : on doit donc avoir  $\langle \mathbf{v}, \mathbf{d}_k \rangle < 0$  pour au moins un sous-gradient  $\mathbf{v}$

## ■ solution classique :

- algorithme du **gradient**
- $\mathbf{d}_k = -\nabla J(\mathbf{x}_k)$

- L'algorithme du gradient converge sous des conditions assez fortes :
  - $J$  est  $C^1$ , coercitive et strictement convexe
  - $\nabla J$  est  $M$ -Lipschitzienne
  - si  $\rho_k \in [\beta_1, \beta_2]$  avec  $0 < \beta_1 < \beta_2 < \frac{2}{M}$
- On peut obtenir une preuve plus simple en supposant que  $J$  est  $\alpha$ -convexe  $C^1$  et de gradient  $M$ -Lipschitzien :
  - on suppose alors que  $\rho_k \in ]0, \frac{2\alpha}{M^2}[$
  - on obtient une vitesse de convergence linéaire


$$\|\mathbf{x}_{k+1} - \mathbf{x}^*\| \leq \sqrt{1 - 2\alpha\rho_k + M^2\rho_k^2} \|\mathbf{x}_k - \mathbf{x}^*\|,$$

optimale de valeur  $\sqrt{1 - \frac{\alpha^2}{M^2}}$  (pour  $\rho_k = \frac{\alpha}{M^2}$ )

- pas constant
- pas variable :
  - adaptation du pas au problème
  - pas optimal :
    - $\rho_k = \arg \min_{\rho > 0} J(\mathbf{x}_k - \rho \nabla J(\mathbf{x}_k))$
    - avantage : meilleure réduction possible par itération
    - inconvénient : coût de la recherche
  - pas approximativement optimal :
    - rechercher un  $\rho_k$  qui réduit « assez »  $J$
    - comme
$$J(\mathbf{x}_k - \rho \nabla J(\mathbf{x}_k)) = J(\mathbf{x}_k) - \rho \|\nabla J(\mathbf{x}_k)\|^2 + o(\rho \|\nabla J(\mathbf{x}_k)\|),$$
on peut demander une réduction d'au moins  $\alpha \rho \|\nabla J(\mathbf{x}_k)\|^2$   
(avec  $\alpha < \frac{1}{2}$ )


## Gradient conjugué

- Analyse de l'algorithme du gradient sur le cas particulier des formes quadratiques  $J(\mathbf{x}) = \frac{1}{2} \langle \mathbf{x}, A\mathbf{x} \rangle - \langle \mathbf{b}, \mathbf{x} \rangle$  pour  $A$  définie positive
- si  $A$  est mal conditionnée, l'algorithme du gradient est mauvais




## Gradient conjugué


- Analyse de l'algorithme du gradient sur le cas particulier des formes quadratiques  $J(\mathbf{x}) = \frac{1}{2} \langle \mathbf{x}, A\mathbf{x} \rangle - \langle \mathbf{b}, \mathbf{x} \rangle$  pour  $A$  définie positive
- si  $A$  est mal conditionnée, l'algorithme du gradient est mauvais



- Analyse de l'algorithme du gradient sur le cas particulier des formes quadratiques  $J(\mathbf{x}) = \frac{1}{2} \langle \mathbf{x}, A\mathbf{x} \rangle - \langle \mathbf{b}, \mathbf{x} \rangle$  pour  $A$  définie positive
- si  $A$  est mal conditionnée, l'algorithme du gradient est mauvais



- Analyse de l'algorithme du gradient sur le cas particulier des formes quadratiques  $J(\mathbf{x}) = \frac{1}{2} \langle \mathbf{x}, A\mathbf{x} \rangle - \langle \mathbf{b}, \mathbf{x} \rangle$  pour  $A$  définie positive
- si  $A$  est mal conditionnée, l'algorithme du gradient est mauvais





## Méthode du gradient conjugué

- idée fondamentale : utiliser des directions de descentes **conjuguées** c.-à-d. orthogonales au sens de  $A$
- autrement dit : ne pas perturber l'optimisation précédente
- principe général :
  - algorithme de descente à pas optimal
  - directions de descente obtenues par récurrence à partir des gradients aux points précédents
- applicable à des fonctions quelconques (pas seulement quadratiques)

1. point initial  $\mathbf{x}_0$ , gradient initial  $\mathbf{g}_0 = A\mathbf{x}_0 - b$ , direction de descente initiale  $\mathbf{w}_0 = \mathbf{g}_0$  (on suppose que  $\mathbf{g}_0 \neq \mathbf{0}$ )
2. pour  $k \geq 1$  croissant
  - 2.1  $\rho_{k-1} = \frac{\langle \mathbf{g}_{k-1}, \mathbf{w}_{k-1} \rangle}{\langle A\mathbf{w}_{k-1}, \mathbf{w}_{k-1} \rangle}$
  - 2.2  $\mathbf{x}_k = \mathbf{x}_{k-1} - \rho_{k-1} \mathbf{w}_{k-1}$
  - 2.3  $\mathbf{g}_k = A\mathbf{x}_k - b$
  - 2.4  $\mathbf{g}_k = \mathbf{0}$  fin de l'algorithme
  - 2.5 sinon :
    - 2.5.1  $\alpha_k = -\frac{\langle \mathbf{g}_k, A\mathbf{w}_{k-1} \rangle}{\langle A\mathbf{w}_{k-1}, \mathbf{w}_{k-1} \rangle}$
    - 2.5.2  $\mathbf{w}_k = \mathbf{g}_k + \alpha_k \mathbf{w}_{k-1}$

1. point initial  $\mathbf{x}_0$ , gradient initial  $\mathbf{g}_0 = A\mathbf{x}_0 - b$ , direction de descente initiale  $\mathbf{w}_0 = \mathbf{g}_0$  (on suppose que  $\mathbf{g}_0 \neq \mathbf{0}$ )
  2. pour  $k \geq 1$  croissant
    - 2.1  $\rho_{k-1} = \frac{\langle \mathbf{g}_{k-1}, \mathbf{w}_{k-1} \rangle}{\langle A\mathbf{w}_{k-1}, \mathbf{w}_{k-1} \rangle}$
    - 2.2  $\mathbf{x}_k = \mathbf{x}_{k-1} - \rho_{k-1} \mathbf{w}_{k-1}$
    - 2.3  $\mathbf{g}_k = A\mathbf{x}_k - b$
    - 2.4  $\mathbf{g}_k = \mathbf{0}$  fin de l'algorithme
    - 2.5 sinon :
      - 2.5.1  $\alpha_k = -\frac{\langle \mathbf{g}_k, A\mathbf{w}_{k-1} \rangle}{\langle A\mathbf{w}_{k-1}, \mathbf{w}_{k-1} \rangle}$
      - 2.5.2  $\mathbf{w}_k = \mathbf{g}_k + \alpha_k \mathbf{w}_{k-1}$
- $\rho_k$  est un pas optimal
  - $\alpha_k$  est tel que  $\langle \mathbf{w}_k, A\mathbf{w}_{k-1} \rangle = 0$

- pour tout  $l < k$  :
  - $\langle \nabla J(\mathbf{x}_k), \nabla J(\mathbf{x}_l) \rangle = 0$
  - $\langle \nabla J(\mathbf{x}_k), \mathbf{w}_l \rangle = 0$
  - $\langle \mathbf{w}_k, A\mathbf{w}_l \rangle = 0$
- l'algorithme trouve le minimum de  $J(\mathbf{x}) = \frac{1}{2} \langle \mathbf{x}, A\mathbf{x} \rangle - \langle \mathbf{b}, \mathbf{x} \rangle$  en au plus  $n$  itérations ( $n$  est l'ordre de  $A$ )
- erreurs numériques : critère d'arrêt sur  $\|\nabla J(\mathbf{x}_k)\|$



## Cas non linéaire

1. point initial  $\mathbf{x}_0$ , gradient initial  $\mathbf{g}_0 = \nabla J(\mathbf{x}_0)$ , direction de descente initiale  $\mathbf{w}_0 = \mathbf{g}_0$  (on suppose que  $\mathbf{g}_0 \neq \mathbf{0}$ )
  2. pour  $k \geq 1$  croissant
    - 2.1  $\rho_{k-1} = \arg \min_{\rho > 0} J(\mathbf{x}_{k-1} - \rho \mathbf{w}_{k-1})$
    - 2.2  $\mathbf{x}_k = \mathbf{x}_{k-1} - \rho_{k-1} \mathbf{w}_{k-1}$
    - 2.3  $\mathbf{g}_k = \nabla J(\mathbf{x}_k)$
    - 2.4  $\mathbf{g}_k = \mathbf{0}$  fin de l'algorithme
    - 2.5 sinon :
      - 2.5.1 choisir un  $\alpha_k$
      - 2.5.2  $\mathbf{w}_k = \mathbf{g}_k + \alpha_k \mathbf{w}_{k-1}$
- Diverses formules pour le calcul de  $\alpha_k$ , par exemple
$$\alpha_k = \frac{\|\mathbf{g}_k\|^2}{\|\mathbf{g}_{k-1}\|^2} \text{ (Fletcher-Reeves)}$$
  - « Redémarrage » :  $\mathbf{w}_k = \mathbf{g}_k$  de temps en temps

- on cherche un zéro de  $\nabla J$ , or

$$\nabla J(\mathbf{x} + \mathbf{h}) = \nabla J(\mathbf{x}) + \nabla^2 J(\mathbf{x})\mathbf{h} + o(\|\mathbf{h}\|)$$

donc au premier ordre

$$\mathbf{h} = -\nabla^2 J(\mathbf{x})^{-1} \nabla J(\mathbf{x})$$

- correspond aussi au minimum de l'approximation au deuxième ordre

$$J(\mathbf{x} + \mathbf{h}) = J(\mathbf{x}) + \mathbf{h}^T \nabla J(\mathbf{x}) + \frac{1}{2} \mathbf{h}^T \nabla^2 J(\mathbf{x}) \mathbf{h} + o(\|\mathbf{h}\|^2)$$

- si  $\nabla^2 J(\mathbf{x})$  est définie positive,  $\mathbf{h}$  est une direction de descente

$$\left\langle \nabla J(\mathbf{x}), -\nabla^2 J(\mathbf{x})^{-1} \nabla J(\mathbf{x}) \right\rangle < 0$$

- Newton pur :
  1. point initial  $\mathbf{x}_0$
  2. pour  $k \geq 1$  croissant
    - 2.1 calculer  $\mathbf{d}_k = -\nabla^2 J(\mathbf{x}_k)^{-1} \nabla J(\mathbf{x}_k)$
    - 2.2 tester la convergence par  $\langle \nabla J(\mathbf{x}_k), \nabla^2 J(\mathbf{x}_k)^{-1} \nabla J(\mathbf{x}_k) \rangle < \epsilon$
    - 2.3 poser  $\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{d}_k$
- variante dite « gardée » :
  - mise à jour par  $\mathbf{x}_{k+1} = \mathbf{x}_k + \rho_k \mathbf{d}_k$
  - recherche de  $\rho_k \leq 1$  par réduction suffisante
- on peut montrer la convergence de l'algorithme gardé sous les hypothèses classiques ( $\alpha$ -convexité) et si le Hessien est Lipschitzien

- algorithme du gradient :
  - coût en  $O(n)$
  - grand nombre d'itérations
- gradient conjugué :
  - coût en  $O(n)$
  - nombre d'itérations beaucoup plus faible que le gradient simple
- méthode Newton :
  - coût en  $O(n^3)$
  - nombre d'itérations faible (convergence quadratique près du minimum)
- solutions intermédiaires :
  - méthodes de quasi-Newton (par ex. BFGS)
  - approximation de  $\nabla^2 J(\mathbf{x})^{-1}$
  - coût en  $O(n^2)$  ou même  $O(n)$
  - convergence rapide