

Optimisation et convexité : introduction, motivations, exemples

Claude LEMARÉCHAL

Jérôme MALICK

École de recherche “Optimisation & Convexité” – Partie 1
ENS Lyon – Janvier 2011

Plan de la présentation

1 Vue d'ensemble

2 Introduction à l'optimisation

3 Introduction à l'analyse convexe

4 Exemples de problèmes d'optimisation convexe

- Exemple dans l'industrie : gestion de la production électrique
- Exemples dans un domaine scientifique : apprentissage statistique


Quel est le point commun ?



production électrique



robotique, mécanique




Quel est le point commun ?



production électrique



robotique, mécanique



graphes, réseaux



risque en finance



météo

Réponse :
optimisation
(convexe)

Optimisation... convexe

L'optimisation en 2 mots

- “la science du mieux-faire” ou “la science de la décision”
- Discipline mature des maths applis (théorie, algos, logiciels)
- Explosion récente des applications dans les sciences et technologies

Optimisation... convexe

L'optimisation en 2 mots

- “la science du mieux-faire” ou “la science de la décision”
- Discipline mature des maths applis (théorie, algos, logiciels)
- Explosion récente des applications dans les sciences et technologies

Et pourquoi convexe ?

- Propriétés géométriques : globalité, garanties,...
- Précieux outils: **dualité**, analyse de sensibilité...
- Résoudre des problèmes non-convexes à l'aide de l'optimisation convexe

Optimisation... convexe

L'optimisation en 2 mots

- “la science du mieux-faire” ou “la science de la décision”
- Discipline mature des maths applis (théorie, algos, logiciels)
- Explosion récente des applications dans les sciences et technologies

Et pourquoi convexe ?

- Propriétés géométriques : globalité, garanties,...
- Précieux outils: **dualité**, analyse de sensibilité...
- Résoudre des problèmes non-convexes à l'aide de l'optimisation convexe

Un cours en optimisation convexe ?

- Optim. linéaire vs. non-linéaire, déterministe vs. stochastique...
- Théorie, algorithmes, applications,...
- Il y a beaucoup (trop) à dire, on va se concentrer sur un thème...

Optimisation convexe non-différentiable

Objectif : Optimisation convexe non-différentiable

- Encore peu connue mais en pleine expansion (théorie, applications)
- Application en optimisation combinatoire (antonymiques ?)
- Applications en ingénierie, en apprentissage,...

Optimisation convexe non-différentiable

Objectif : Optimisation convexe non-différentiable


- Encore peu connue mais en pleine expansion (théorie, applications)
- Application en optimisation combinatoire (antonymiques ?)
- Applications en ingénierie, en apprentissage,...

Contenu du cours

- Introduction aux bases de l'optimisation (algorithmes)
- Illustrer avec des exemples d'applications (apprentissage, météo...)
- Présentation de l'analyse convexe et de l'algorithmique non-diff.
- Insister sur leur utilisation dans deux domaines :



production électrique



graphes et applications

Plan de cette semaine : “Optimisation & Convexité”

- Lundi (10h30 - 12h 13h30 - 15h30)
 - Introduction générale, exemples (partie 1)
- Mardi (10h30 - 12h 13h30 - 17h30)
 - “Rappels” d'optimisation différentiable (partie 2)
 - TP – optimisation numérique (scilab)
- Mercredi (10h30 - 12h 13h30 - 17h30)
 - Introduction à optimisation non-différentiable (partie 3.1)
 - TD – dualité convexe
- Jeudi (10h30 - 12h 13h30 - 17h30)
 - Théorie de l'optimisation convexe (partie 3.2)
 - TD – analyse convexe
- Vendredi (9h - 12h 13h30 - 15h30)
 - Algorithmique de l'optimisation non-différentiable (partie 3.3)
 - Examen – optimisation dans les réseaux telecom

Plan d'aujourd'hui (Partie 1) : Introductions, exemples

1 Vue d'ensemble

2 Introduction à l'optimisation

3 Introduction à l'analyse convexe

4 Exemples de problèmes d'optimisation convexe

- Exemple dans l'industrie : gestion de la production électrique
- Exemples dans un domaine scientifique : apprentissage statistique

Plan de la présentation

1 Vue d'ensemble

2 **Introduction à l'optimisation**

3 Introduction à l'analyse convexe

4 Exemples de problèmes d'optimisation convexe

- Exemple dans l'industrie : gestion de la production électrique
- Exemples dans un domaine scientifique : apprentissage statistique

C'est quoi l'optimisation ?

- **Problème d'optimisation :** formulation mathématique

$$\left\{ \begin{array}{l} \min f(x) \\ x \in C \end{array} \right.$$

- variable $x = (x_1, \dots, x_n) \in \mathbb{R}^n$
- fonction objectif $f: \mathbb{R}^n \rightarrow \mathbb{R}$
- ensemble des contraintes $C \subset \mathbb{R}^n$

C'est quoi l'optimisation ?

- **Problème d'optimisation :** formulation mathématique

$$\left\{ \begin{array}{l} \min f(x) \\ x \in C \end{array} \right.$$

- variable $x = (x_1, \dots, x_n) \in \mathbb{R}^n$
- fonction objectif $f: \mathbb{R}^n \rightarrow \mathbb{R}$
- ensemble des contraintes $C \subset \mathbb{R}^n$

- **Solution :** trouver $\bar{f} \in \mathbb{R}$ et $\bar{x} \in C$ tel que

$$f(\bar{x}) = \bar{f} \leq f(x) \quad \text{pour tout } x \in C$$

C'est quoi l'optimisation ?

- **Problème d'optimisation :** formulation mathématique

$$\left\{ \begin{array}{l} \min_{x \in C} f(x) \end{array} \right.$$

- variable $x = (x_1, \dots, x_n) \in \mathbb{R}^n$
- fonction objectif $f: \mathbb{R}^n \rightarrow \mathbb{R}$
- ensemble des contraintes $C \subset \mathbb{R}^n$

- **Solution :** trouver $\bar{f} \in \mathbb{R}$ et $\bar{x} \in C$ tel que

$$f(\bar{x}) = \bar{f} \leq f(x) \quad \text{pour tout } x \in C$$

- L'**“optimisation”**, c'est au moins trois choses :

- ① L'art de formuler les problèmes (de décision)
- ② Une théorie mathématique
- ③ Des techniques algorithmiques

Exemple : moindres carrés parcimonieux

- Pb : trouver quelques facteurs socio-économiques importants qui expliquent les prix de l'immobilier (prix du m^2)
- Données :
 - n régions, p facteurs : données normalisées $A \in \mathbb{R}^{n \times p}$
 - prix moyen par région $b \in \mathbb{R}^n$

Exemple : moindres carrés parcimonieux

- Pb : trouver quelques facteurs socio-économiques importants qui expliquent les prix de l'immobilier (prix du m^2)
- Données :
 - n régions, p facteurs : données normalisées $A \in \mathbb{R}^{n \times p}$
 - prix moyen par région $b \in \mathbb{R}^n$
- Modélisation :
 - trouver $x \in \mathbb{R}^p$ qui donne $Ax \approx b$
 - avec peu de $x_i \neq 0$

Exemple : moindres carrés parcimonieux

- Pb : trouver quelques facteurs socio-économiques importants qui expliquent les prix de l'immobilier (prix du m^2)
- Données :
 - n régions, p facteurs : données normalisées $A \in \mathbb{R}^{n \times p}$
 - prix moyen par région $b \in \mathbb{R}^n$
- Modélisation :
 - trouver $x \in \mathbb{R}^p$ qui donne $Ax \approx b$
 - avec peu de $x_i \neq 0$
- Problème d'optimisation (convexe, non-différentiable)

$$\min_{x \in \mathbb{R}^p} \|Ax - b\|^2 + \alpha \|x\|_1$$

Exemple : moindres carrés parcimonieux

- Pb : trouver quelques facteurs socio-économiques importants qui expliquent les prix de l'immobilier (prix du m^2)
- Données :
 - n régions, p facteurs : données normalisées $A \in \mathbb{R}^{n \times p}$
 - prix moyen par région $b \in \mathbb{R}^n$
- Modélisation :
 - trouver $x \in \mathbb{R}^p$ qui donne $Ax \approx b$
 - avec peu de $x_i \neq 0$
- Problème d'optimisation (convexe, non-différentiable)

$$\min_{x \in \mathbb{R}^p} \|Ax - b\|^2 + \alpha \|x\|_1$$

- Problème au coeur du “compressed sensing” (traitement du signal)

Exemple : moindres carrés parcimonieux

- Pb : trouver quelques facteurs socio-économiques importants qui expliquent les prix de l'immobilier (prix du m^2)
- Données :
 - n régions, p facteurs : données normalisées $A \in \mathbb{R}^{n \times p}$
 - prix moyen par région $b \in \mathbb{R}^n$
- Modélisation :
 - trouver $x \in \mathbb{R}^p$ qui donne $Ax \approx b$
 - avec peu de $x_i \neq 0$
- Problème d'optimisation (convexe, non-différentiable)


$$\min_{x \in \mathbb{R}^p} \|Ax - b\|^2 + \alpha \|x\|_1$$

- Problème au coeur du “compressed sensing” (traitement du signal)
- Plus généralement : **Problèmes inverses** (très fréquents)

minimiser erreur(données, modèle) + terme régularisateur

Exemple dans les graphes : coupe maximale


Graph : ensemble de n noeuds
dont certains sont reliés par des arêtes



Exemple dans les graphes : coupe maximale

Graphe : ensemble de n noeuds
dont certains sont reliés par des arêtes


Coupe : partition de l'ensemble des
noeuds en deux (5 arêtes coupées)



Exemple dans les graphes : coupe maximale

Graphe : ensemble de n noeuds
dont certains sont reliés par des arêtes

Coupe : partition de l'ensemble des
noeuds en deux (6 arêtes coupées)




- Problème de la coupe maximale : trouver une coupe qui maximise le nombre d'arêtes coupées – ex d'appli. : physique statistique (!)

Exemple dans les graphes : coupe maximale

Graphe : ensemble de n noeuds
dont certains sont reliés par des arêtes

Coupe : partition de l'ensemble des
noeuds en deux (6 arêtes coupées)



- Problème de la coupe maximale : trouver une coupe qui maximise le nombre d'arêtes coupées – ex d'appli. : physique statistique (!)
- Modélisation :
 - variable : $x \in \mathbb{R}^n$ (x_i pour le noeud i)
 - contrainte : $x_i = 1$ ou -1 (choix de l'ensemble)
 - objectif : nombre d'arêtes coupées (arête (ij) $\iff a_{ij} \in \{0, 1\}$)
 (ij) coupée $\iff (a_{ij} = 1 \text{ et } 1 - x_i x_j = 0) \iff a_{ij}(1 - x_i x_j)/2 = 1$


- Formulation :

$$\begin{cases} \max \quad \sum_{ij} a_{ij}(1 - x_i x_j)/2 \\ \quad x \in \{-1, 1\}^n \end{cases}$$

Exemple dans les graphes : coupe maximale

Graphe : ensemble de n noeuds
dont certains sont reliés par des arêtes

Coupe : partition de l'ensemble des
noeuds en deux (6 arêtes coupées)



- Problème de la coupe maximale : trouver une coupe qui maximise le nombre d'arêtes coupées — ex d'appli. : physique statistique (!)
- Modélisation :
 - variable : $x \in \mathbb{R}^n$ (x_i pour le noeud i)
 - contrainte : $x_i = 1$ ou -1 (choix de l'ensemble)
 - objectif : nombre d'arêtes coupées (arête (ij) $\iff a_{ij} \in \{0, 1\}$)
 (ij) coupée $\iff (a_{ij} = 1 \text{ et } 1 - x_i x_j = 0) \iff a_{ij}(1 - x_i x_j)/2 = 1$
- Formulation : $Q = (-a_{ij}/2)_{ij}$ matrice d'adjacence (facteur $-1/2$)

$$\begin{cases} \min & x^\top Q x + \text{cste} \\ & x \in \{-1, 1\}^n \end{cases}$$

- Problème “fini” mais dur ! (NP dur... OK pour $n \leq 500$)

Résoudre un problème d'optimisation

- En général

résoudre un problème d'optimisation est très difficile

- Ce qu'on voudrait...

- Situation idéale : calculer \bar{x} et \bar{f} explicitement
 - Bonne situation : avoir un algorithme qui génère une suite

$$x_k \rightarrow \bar{x} \quad f(x_k) \rightarrow \bar{f}$$

Résoudre un problème d'optimisation

- En général

résoudre un problème d'optimisation est très difficile

- Ce qu'on voudrait...

- Situation idéale : calculer \bar{x} et \bar{f} explicitement
- Bonne situation : avoir un algorithme qui génère une suite

$$x_k \rightarrow \bar{x} \quad f(x_k) \rightarrow \bar{f}$$

- **Exemple** : optimisation linéaire

$$\begin{cases} \min & c^T x \\ & Ax = b \\ & x \geq 0 \end{cases}$$

- théorie et algorithmes (2e guerre mondiale)
- logiciels efficaces et disponibles (20 ans)
- outils pour modéliser sous forme linéaire

Résoudre un problème d'optimisation

- En général

résoudre un problème d'optimisation est très difficile

- Ce qu'on voudrait...

- Situation idéale : calculer \bar{x} et \bar{f} explicitement
- Bonne situation : avoir un algorithme qui génère une suite

$$x_k \rightarrow \bar{x} \quad f(x_k) \rightarrow \bar{f}$$

- **Exemple** : optimisation linéaire

$$\left\{ \begin{array}{l} \min \quad c^T x \\ \quad Ax = b \\ \quad x \geq 0 \end{array} \right. \quad \begin{array}{l} \text{— théorie et algorithmes (2e guerre mondiale)} \\ \text{— logiciels efficaces et disponibles (20 ans)} \\ \text{— outils pour modéliser sous forme linéaire} \end{array}$$

- Ce qu'on a souvent...

- Pas de globalité : on a une sous-suite $x_{k'} \rightarrow \bar{x}$ minimum **local**

$$f(x_{k'}) \rightarrow f(\bar{x}) = \bar{f} \leq f(x) \quad \text{pour tout } x \in C \cap B(\bar{x}, r)$$

- Sous-optimalité : on a un **minorant** de la valeur optimale

$$m_k \rightarrow \bar{m} < \bar{f} \leq f(x) \quad \text{pour tout } x \in C$$

Résoudre un problème d'optimisation convexe

$$\begin{cases} \min & f(x) \\ x \in C & f: \mathbb{R}^n \rightarrow \mathbb{R} \text{ convexe} \\ & C = \{x \in \mathbb{R}^n : a_i^\top x = b_i, g_j(x) \leq 0\} \text{ convexe} \end{cases}$$

- Problèmes précédents = manque de convexité !

Résoudre un problème d'optimisation convexe

$$\begin{cases} \min & f(x) & f: \mathbb{R}^n \rightarrow \mathbb{R} \text{ convexe} \\ x \in C & & C = \{x \in \mathbb{R}^n : a_i^\top x = b_i, g_j(x) \leq 0\} \text{ convexe} \end{cases}$$

- Problèmes précédents = manque de convexité !
- Pour les problèmes convexes, on est dans la “bonne” situation
- On dispose d'algorithmes : $f(x_k) \rightarrow \bar{f}$, $x_k \rightarrow \bar{x}$
- Contrôle du comportement \rightarrow théorie de la complexité
- En général,

résoudre un problème d'optimisation **convexe** est plus facile

Résoudre un problème d'optimisation convexe

$$\begin{cases} \min & f(x) & f: \mathbb{R}^n \rightarrow \mathbb{R} \text{ convexe} \\ x \in C & & C = \{x \in \mathbb{R}^n : a_i^\top x = b_i, g_j(x) \leq 0\} \text{ convexe} \end{cases}$$

- Problèmes précédents = manque de convexité !
- Pour les problèmes convexes, on est dans la “bonne” situation
- On dispose d’algorithmes : $f(x_k) \rightarrow \bar{f}$, $x_k \rightarrow \bar{x}$
- Contrôle du comportement → théorie de la complexité
- En général,

résoudre un problème d'optimisation **convexe** est plus facile

- Beaucoup de problèmes se **modélisent** comme des problèmes d'optimisation convexe (ex: prix de l'immobilier)
- Beaucoup de problèmes se résolvent à l'aide d'optimisation convexe (ex: résoudre un max-cut par branch-and-bound)

Se situer dans le temps...

Repères historiques pour l'optimisation convexe:

- 1900** Début de l'étude mathématique de la convexité (ex: H. Minkowski)
- 1947** Algorithme du simplexe pour l'optimisation linéaire (G. Dantzig)
Premières applications militaires puis en "recherche opérationnelle"
- 1970** Analyse convexe (W. Fenchel, J.-J. Moreau, T. Rockafellar)
- 1994** Algorithme de points intérieurs (Y. Nesterov & A. Nemirovski)
- 1990 → 2010**
 - nombreuses applications en sciences de l'ingénieur
(traitement du signal, réseaux, statistiques, robotique...)
 - nouvelles familles de problèmes
(optimisation semidéfinie, optimisation robuste, stochastique...)

Se situer dans l'optimisation...

Nomenclature en optimisation:

- linéaire vs. non-linéaire (dichotomie classique)
- continue vs. discrète
- déterministe vs. stochastique (dans l'incertain)
- statique vs. dynamique (ex: commande optimale)
- unique vs. multi : critère ou décideur (ex: théorie des jeux)
- convexe vs. non-convexe
- autres: grande taille, incrémentale... (ex: apprentissage)

Se situer dans l'optimisation...

Nomenclature en optimisation:

- linéaire vs. non-linéaire (dichotomie classique)
 - continue vs. discrète
 - déterministe vs. stochastique (dans l'incertain)
 - statique vs. dynamique (ex: commande optimale)
 - unique vs. multi : critère ou décideur (ex: théorie des jeux)
 - convexe vs. non-convexe
 - autres: grande taille, incrémentale... (ex: apprentissage)
- objectif : optimisation convexe non-différentiable
applications en combinatoire
- début : introduction aux base de l'optimisation numérique

Plan de la présentation

1 Vue d'ensemble

2 Introduction à l'optimisation

3 Introduction à l'analyse convexe

4 Exemples de problèmes d'optimisation convexe


- Exemple dans l'industrie : gestion de la production électrique
- Exemples dans un domaine scientifique : apprentissage statistique

Ensemble convexe

$C \subset \mathbb{R}^n$ est convexe si



$$x_1, x_2 \in C, \quad 0 \leq \alpha \leq 1$$

$$\implies \alpha x_1 + (1 - \alpha)x_2 \in C$$



Exemples :

- Un espace affine $\{x \in \mathbb{R}^n : Ax = b\}$ est convexe
- Un demi-espace $\{x \in \mathbb{R}^n : a^\top x \leq \beta\}$ est convexe
- L'intersection (quelconque) d'ensembles convexes est convexe




Ensemble convexe

$C \subset \mathbb{R}^n$ est convexe si




$$x_1, x_2 \in C, \quad 0 \leq \alpha \leq 1$$

$$\implies \alpha x_1 + (1 - \alpha)x_2 \in C$$



Exemples :

- Un espace affine $\{x \in \mathbb{R}^n : Ax = b\}$ est convexe
- Un demi-espace $\{x \in \mathbb{R}^n : a^\top x \leq \beta\}$ est convexe
- L'intersection (quelconque) d'ensembles convexes est convexe



Propriété de base :


- Soit C convexe fermé; alors tout point $x \in \mathbb{R}^n$ a une unique projection sur C ! (caractéristique des ensembles convexes fermés)

Cône convexe

$C \subset \mathbb{R}^n$ est un cône convexe si

C est convexe

$x \in C, 0 < \alpha \implies \alpha x \in C$



Cône convexe

$C \subset \mathbb{R}^n$ est un cône convexe si

C est convexe


$x \in C, 0 < \alpha \implies \alpha x \in C$

Exemples :

- L'ensemble des matrices (semidéfinies) positives

$$\mathcal{S}_n^+ = \{X \in \mathcal{S}_n : u^\top X u \geq 0 \text{ pour tout } u \in \mathbb{R}^n\}$$

est un cône convexe (fermé)



Cône convexe

$C \subset \mathbb{R}^n$ est un cône convexe si

C est convexe

$x \in C, 0 < \alpha \implies \alpha x \in C$


Exemples :

- L'ensemble des matrices (semidéfinies) positives

$$\mathcal{S}_n^+ = \{X \in \mathcal{S}_n : u^\top X u \geq 0 \text{ pour tout } u \in \mathbb{R}^n\}$$

est un cône convexe (fermé)

Rem: ensemble convexe en statistiques : matrices de corrélation




Cône convexe

$C \subset \mathbb{R}^n$ est un cône convexe si

C est convexe

$x \in C, 0 < \alpha \implies \alpha x \in C$



Exemples :

- L'ensemble des matrices (semidéfinies) positives

$$\mathcal{S}_n^+ = \{X \in \mathcal{S}_n : u^\top X u \geq 0 \text{ pour tout } u \in \mathbb{R}^n\}$$


est un cône convexe (fermé)

Rem: ensemble convexe en statistiques : matrices de corrélation

- Cône "du second ordre" dans \mathbb{R}^3

$$K_\mu = \left\{ r \in \mathbb{R}^3 : \sqrt{r_1^2 + r_2^2} \leq \mu r_3 \right\}$$

Rem: cône convexe en mécanique



Exemple : optimisation conique

Optimisation linéaire

$$\begin{cases} \min & c^\top x \\ & Ax = b \\ & x \geq 0 \end{cases}$$

Optimisation conique (linéaire)

$$\begin{cases} \min & c^\top x \\ & Ax = b \\ & x \in K \end{cases}$$

Optimisation conique

- On garde presque les mêmes propriétés théoriques
- Travail pour adapter/développer des algorithmes
- Formalisme pour de nouvelles applications...

Exemple : optimisation conique

Optimisation linéaire

$$\begin{cases} \min & c^T x \\ & Ax = b \\ & x \geq 0 \end{cases}$$

Optimisation conique (linéaire)



$$\begin{cases} \min & c^T x \\ & Ax = b \\ & x \in K \end{cases}$$

Optimisation conique


- On garde presque les mêmes propriétés théoriques
- Travail pour adapter/développer des algorithmes
- Formalisme pour de nouvelles applications...
- En particulier : optimisation semidéfinie ! (**SDP**)

Optimisation semidéfinie


$$\begin{cases} \min & \langle C, X \rangle \\ & AX = b \\ & X \in \mathcal{S}_n^+ \end{cases}$$



Exemple : localisation de réseaux de capteurs



Exemple : localisation de réseaux de capteurs




- D matrice “distance euclidienne”
 $\exists p_1, \dots, p_n \in \mathbb{R}^r$

$$D_{ij} = \|p_i - p_j\|^2$$

- Problème : retrouver les p_i connaissant certains $D_{ij} \dots$

Exemple : localisation de réseaux de capteurs



- D matrice “distance euclidienne”
 $\exists p_1, \dots, p_n \in \mathbb{R}^r$
- $$D_{ij} = \|p_i - p_j\|^2$$
- Problème : retrouver les p_i connaissant certains $D_{ij} \dots$

D'où vient la modélisation avec l'optimisation semidéfinie ?

- $P = [p_1, \dots, p_n]$ et $Y = P^\top P \in \mathcal{S}_n^+$

$$D_{ij} = p_i^\top p_i + p_j^\top p_j - 2p_j^\top p_i = Y_{ii} + Y_{jj} - 2Y_{ij} =: K(Y)$$

- D distance euclidienne $\iff D = K(Y)$ et $Y \in \mathcal{S}_n^+$
- ...

Fonction convexe


La fonction $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ est convexe si

$$x_1, x_2 \in \mathbb{R}^n \quad 0 \leq \alpha \leq 1 \quad f(\alpha x_1 + (1 - \alpha)x_2) \leq \alpha f(x_1) + (1 - \alpha)f(x_2)$$

ce qui équivaut à :

$$\text{epi } f = \{(x, t) \in \mathbb{R}^{n+1} : f(x) \leq t\}$$

est un ensemble convexe de \mathbb{R}^{n+1}



Fonction convexe

La fonction $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ est convexe si

$$x_1, x_2 \in \mathbb{R}^n \quad 0 \leq \alpha \leq 1 \quad f(\alpha x_1 + (1 - \alpha)x_2) \leq \alpha f(x_1) + (1 - \alpha)f(x_2)$$


ce qui équivaut à :

$$\text{epi } f = \{(x, t) \in \mathbb{R}^{n+1} : f(x) \leq t\}$$

est un ensemble convexe de \mathbb{R}^{n+1}

Exemples :

- Les fonctions affines sont convexes
- Les normes sont convexes (ex: $\|\cdot\|_1$)



Fonction convexe

La fonction $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{+\infty\}$ est convexe si

$$x_1, x_2 \in \mathbb{R}^n \quad 0 \leq \alpha \leq 1 \quad f(\alpha x_1 + (1 - \alpha)x_2) \leq \alpha f(x_1) + (1 - \alpha)f(x_2)$$

ce qui équivaut à :

$$\text{epi } f = \{(x, t) \in \mathbb{R}^{n+1} : f(x) \leq t\}$$



est un ensemble convexe de \mathbb{R}^{n+1}

Exemples :

- Les fonctions affines sont convexes
- Les normes sont convexes (ex: $\|\cdot\|_1$)
- Un sup de fonctions convexes est convexe

$$f(x) = \sup_{i \in I} f_i(x) \text{ convexe}$$

- Apparition de la non-différentiabilité...



Fonction convexe différentiable

Rappel: La fonction $f: \mathbb{R}^n \rightarrow \mathbb{R}$ est différentiable en x si

$$f(y) = f(x) + \nabla f(x)^\top (y - x) + o(y - x)$$

Fonction convexe différentiable

Rappel: La fonction $f: \mathbb{R}^n \rightarrow \mathbb{R}$ est différentiable en x si

$$f(y) = f(x) + \nabla f(x)^\top (y - x) + o(y - x)$$

Caractérisation des fonctions convexes différentiables :

Pour f différentiable sur U (ouvert convexe), on a l'équivalence entre

- f est convexe sur U
- “le graphe de f est au-dessus de ses tangentes”

$$f(y) \geq f(x) + \nabla f(x)^\top (y - x)$$

- $\nabla^2 f(x)$ est semidéfini positif pour tout $x \in U$

Fonction convexe différentiable

Rappel: La fonction $f: \mathbb{R}^n \rightarrow \mathbb{R}$ est différentiable en x si

$$f(y) = f(x) + \nabla f(x)^\top (y - x) + o(y - x)$$

Caractérisation des fonctions convexes différentiables :

Pour f différentiable sur U (ouvert convexe), on a l'équivalence entre

- f est convexe sur U
- “le graphe de f est au-dessus de ses tangentes”

$$f(y) \geq f(x) + \nabla f(x)^\top (y - x)$$

- $\nabla^2 f(x)$ est semidéfini positif pour tout $x \in U$

Ex : $f(x) = x^\top A x + b^\top x$ convexe $\iff A \in \mathcal{S}_n^+$

Fonction convexe différentiable

Rappel: La fonction $f: \mathbb{R}^n \rightarrow \mathbb{R}$ est différentiable en x si

$$f(y) = f(x) + \nabla f(x)^\top (y - x) + o(y - x)$$

Caractérisation des fonctions fortement convexes différentiables :

Pour f différentiable sur U (ouvert convexe), on a l'équivalence entre

- f est **fortement convexe** sur U ($f(x) = g(x) + c\|x\|^2$ avec g convexe)
- “le graphe de f est au-dessus de ses tangentes” (+ du quadratique)

$$f(y) \geq f(x) + \nabla f(x)^\top (y - x) + c\|y - x\|^2$$

- $\nabla^2 f(x)$ est **uniformément semidéfini** positif pour tout $x \in U$

Ex : $f(x) = x^\top A x + b^\top x$ fortement convexe $\iff A \in \mathcal{S}_n^{++}$

Premières conséquences de la convexité en optimisation

$$\left\{ \begin{array}{l} \min f(x) \\ x \in C \end{array} \right. \quad \begin{array}{l} C \subset \mathbb{R}^n \text{ ensemble convexe} \\ f: \mathbb{R}^n \rightarrow \mathbb{R} \text{ fonction convexe} \end{array}$$

- **Globalité :** les minimums locaux sont globaux
(et l'ensemble des minimums est un convexe)

Premières conséquences de la convexité en optimisation

$$\left\{ \begin{array}{l} \min_{x \in C} f(x) \\ \end{array} \right. \quad \begin{array}{l} C \subset \mathbb{R}^n \text{ ensemble convexe} \\ f: \mathbb{R}^n \rightarrow \mathbb{R} \text{ fonction convexe} \end{array}$$

- **Globalité** : les minimums locaux sont globaux
(et l'ensemble des minimums est un convexe)
- **Unicité** : si f est strictement convexe ($\Leftarrow f$ fortement convexe)
alors il existe au plus un minimum


Premières conséquences de la convexité en optimisation

$$\left\{ \begin{array}{l} \min_{x \in C} f(x) \\ \end{array} \right. \quad \begin{array}{l} C \subset \mathbb{R}^n \text{ ensemble convexe} \\ f: \mathbb{R}^n \rightarrow \mathbb{R} \text{ fonction convexe} \end{array}$$

- **Globalité** : les minimums locaux sont globaux
(et l'ensemble des minimums est un convexe)
- **Unicité** : si f est strictement convexe ($\iff f$ fortement convexe)
alors il existe au plus un minimum
- **Conditions d'optimalité** : nécessaires

Ex: sans contrainte et f différentiable

$$\bar{x} \text{ sol. de } \min_{x \in \mathbb{R}^n} f(x) \implies \nabla f(\bar{x}) = 0$$




Premières conséquences de la convexité en optimisation

$$\left\{ \begin{array}{l} \min_{x \in C} f(x) \\ \end{array} \right. \quad \begin{array}{l} C \subset \mathbb{R}^n \text{ ensemble convexe} \\ f: \mathbb{R}^n \rightarrow \mathbb{R} \text{ fonction convexe} \end{array}$$


- **Globalité** : les minimums locaux sont globaux
(et l'ensemble des minimums est un convexe)
- **Unicité** : si f est strictement convexe ($\iff f$ fortement convexe)
alors il existe au plus un minimum
- **Conditions d'optimalité** : nécessaires et suffisantes

Ex: sans contrainte et f différentiable

$$\bar{x} \text{ sol. de } \min_{x \in \mathbb{R}^n} f(x) \iff \nabla f(\bar{x}) = 0$$



Exemple : (non)convexité en finance




Value-at-risk : mesure de risque pour un placement financier ($\omega \in \mathbb{R}^n$)

- popularisée par JP Morgan (1993)
- institutionalisée par "Bâle II" (2004)

Soit $r(\omega)$ rendement (variable aléatoire)

$$\text{VaR}_{5\%}(\omega) = \max \{ \alpha : P(r(\omega) < \alpha) < 5\% \}$$

Exemple : (non)convexité en finance



Value-at-risk : mesure de risque pour un placement financier ($\omega \in \mathbb{R}^n$)

- popularisée par JP Morgan (1993)
- institutionalisée par “Bâle II” (2004)

Soit $r(\omega)$ rendement (variable aléatoire)


$$VaR_{5\%}(\omega) = \max \{ \alpha : P(r(\omega) < \alpha) < 5\% \}$$

Mais “VaR a sous-estimé l’importance des pertes du marché du crédit” (2008) comportement non-intuitif : il existe $VaR(\omega_1) = VaR(\omega_2)$

$$VaR((\omega_1 + \omega_2)/2) > VaR(\omega_1) = (VaR(\omega_1) + VaR(\omega_2))/2$$

→ manque de convexité !...

Exemple : (non)convexité en finance



Value-at-risk : mesure de risque pour un placement financier ($\omega \in \mathbb{R}^n$)

- popularisée par JP Morgan (1993)
- institutionalisée par “Bâle II” (2004)

Soit $r(\omega)$ rendement (variable aléatoire)

$$\text{VaR}_{5\%}(\omega) = \max \{ \alpha : P(r(\omega) < \alpha) < 5\% \}$$

Mais “VaR a sous-estimé l’importance des pertes du marché du crédit” (2008) comportement non-intuitif : il existe $\text{VaR}(\omega_1) = \text{VaR}(\omega_2)$

$$\text{VaR}((\omega_1 + \omega_2)/2) > \text{VaR}(\omega_1) = (\text{VaR}(\omega_1) + \text{VaR}(\omega_2))/2$$

→ manque de convexité !... Solution : **Conditional VaR**

$$\text{CVaR}_\beta(\omega) = \frac{1}{\beta} \int_0^\beta \text{VaR}_\alpha(\omega) d\alpha \quad \text{qui est convexe}$$

→ notion de mesure “cohérente” du risque (incluant la convexité)

Conclusion (provisoire) sur la convexité

- La convexité : notion incroyablement simple...
- ...mais qui donne naissance à une géométrie et une analyse riches
- Aussi : porte d'entrée de l'analyse non-différentiable
- Convexité et optimisation
 - apporte des propriétés globales
 - permet de construire des algorithmes
 - théorie de la dualité
- Propriété recherchée...
- “Convexification” de problèmes : **relaxation**

Plan de la présentation

- 1 Vue d'ensemble
- 2 Introduction à l'optimisation
- 3 Introduction à l'analyse convexe
- 4 **Exemples de problèmes d'optimisation convexe**
 - Exemple dans l'industrie : gestion de la production électrique
 - Exemples dans un domaine scientifique : apprentissage statistique

Plan de la présentation

- 1 Vue d'ensemble
- 2 Introduction à l'optimisation
- 3 Introduction à l'analyse convexe
- 4 **Exemples de problèmes d'optimisation convexe**
 - Exemple dans l'industrie : gestion de la production électrique
 - Exemples dans un domaine scientifique : apprentissage statistique

Production électrique en France

- La production d'électricité en France est assurée $n \simeq 200$ centrales

nucléaire 80%



pétrole + charbon 3%




hydraulique 17%




Production électrique en France

- La production d'électricité en France est assurée $n \simeq 200$ centrales

nucléaire 80%



pétrole + charbon 3%



hydraulique 17%



- Question de l'organisation de la production : quelle unité produit quoi et quand ? pour satisfaire la demande à chaque instant ?
- Modélisation comme un problème d'optimisation... dur !
(unit-commitment)

Production électrique en France

- La production d'électricité en France est assurée $n \simeq 200$ centrales

nucléaire 80%

pétrole + charbon 3%

hydraulique 17%



- Question de l'organisation de la production : quelle unité produit quoi et quand ? pour satisfaire la demande à chaque instant ?
- Modélisation comme un problème d'optimisation... dur !
(unit-commitment)
- Depuis 2003, EDF optimise sa production d'électricité par un algorithme d'optimisation convexe

Modèle (simplifié) de la planification de production

- Données : centrales : n [$\simeq 200$] centrales
intervalle : T [= 96] (2 jours \times 48 demi-heures)
- Variables : programme de production pour chaque centrale i

$$p_i = (p_i^1, \dots, p_i^T) \in P_i \quad \text{contraintes technologiques}$$

- Objectif : minimiser les coûts de production
- Chaque centrale i a ses coûts $c_i(p_i)$ et ses contraintes $p_i \in P_i$
- Contrainte : satisfaire les demandes (connues) d^t aux temps t
- Problème d'optimisation dur : grande taille, hétérogène, délais serrés

$$\left\{ \begin{array}{ll} \min & \sum_i c_i(p_i) & \text{(somme des coûts)} \\ & p_i \in P_i \quad i = 1, \dots, n & \text{(contraintes techniques)} \\ & \sum_i p_i^t = d^t \quad t = 1, \dots, T & \text{(répondre à la demande)} \end{array} \right.$$

“Décomposition par les prix”

- On “dualise” les contraintes couplantes... plus mercredi !
- Variables primales : plannings de production $p \in P = P_1 \times \cdots \times P_n$
Variables duales : les “prix” $\lambda = (\lambda^1, \dots, \lambda^T) \in \mathbb{R}^T$
- Problème frère (“dual”) : minimiser “la perte” θ
→ problème convexe non-différentiable non-explicite !

“Décomposition par les prix”

- On “dualise” les contraintes couplantes... plus mercredi !
- Variables primales : plannings de production $p \in P = P_1 \times \cdots \times P_n$
Variables duales : les “prix” $\lambda = (\lambda^1, \dots, \lambda^T) \in \mathbb{R}^T$
- Problème frère (“dual”) : minimiser “la perte” θ
→ problème convexe non-différentiable non-explicite !
- Calcul de la fonction duale à λ fixé = n problèmes indépendants !
- Algorithme efficace
d'optimisation convexe
(type “faisceaux”, cf jeudi)
→ résolution en 1/2h
recherche en cours...






Illustration numérique

Exemple de
demande sur 2 jours
(Ex: de 35000 MW à 70000 MW)



Écart apriori à la demande $\sum_i p_i - d$
(Ex: de -15 MW à 30MW)
à corriger...



Plan de la présentation

1 Vue d'ensemble

2 Introduction à l'optimisation

3 Introduction à l'analyse convexe

4 Exemples de problèmes d'optimisation convexe

- Exemple dans l'industrie : gestion de la production électrique
- Exemples dans un domaine scientifique : apprentissage statistique

Exemples dans un domaine scientifique : apprentissage

- Apprentissage (...) : construire une représentation à partir d'observation
- Applications : bio-stats, vison par ordinateur (semaine prochaine !),...
- Caractéristiques : problèmes de très grande dimension, bruités

Exemples dans un domaine scientifique : apprentissage

- Apprentissage (...) : construire une représentation à partir d'observation
- Applications : bio-stats, vison par ordinateur (semaine prochaine !),...
- Caractéristiques : problèmes de très grande dimension, bruités
- Trois applications de l'optimisation convexe en apprentissage
 - ① Filtrage collaboratif
 - ② Classification supervisée
 - ③ Classification supervisée multiclasse

Exemples dans un domaine scientifique : apprentissage

- Apprentissage (...) : construire une représentation à partir d'observation
- Applications : bio-stats, vison par ordinateur (semaine prochaine !),...
- Caractéristiques : problèmes de très grande dimension, bruités
- Trois applications de l'optimisation convexe en apprentissage
 - ① Filtrage collaboratif
 - ② Classification supervisée
 - ③ Classification supervisée multiclasse
- Bien d'autres ! (interaction optimisation \leftrightarrow apprentissage)
 - Déjà vu : moindres carrés (parcimonieux)
 - Classification non-supervisée \rightarrow optimisation combinatoire
 - ...

Exemples dans un domaine scientifique : apprentissage

- Apprentissage (...) : construire une représentation à partir d'observation
- Applications : bio-stats, vison par ordinateur (semaine prochaine !),...
- Caractéristiques : problèmes de très grande dimension, bruités
- Trois applications de l'optimisation convexe en apprentissage
 - ① **Filtrage collaboratif**
 - ② Classification supervisée
 - ③ Classification supervisée multiclasse
- Bien d'autres ! (interaction optimisation \leftrightarrow apprentissage)
 - Déjà vu : moindres carrés (parcimonieux)
 - Classification non-supervisée \rightarrow optimisation combinatoire
 - ...

Exemples dans un domaine scientifique : apprentissage

- Apprentissage (...) : construire une représentation à partir d'observation
- Applications : bio-stats, vison par ordinateur (semaine prochaine !),...
- Caractéristiques : problèmes de très grande dimension, bruités
- Trois applications de l'optimisation convexe en apprentissage
 - ➊ Filtrage collaboratif
 - ➋ Classification supervisée
 - ➌ Classification supervisée multiclasse
- Bien d'autres ! (interaction optimisation \leftrightarrow apprentissage)
 - Déjà vu : moindres carrés (parcimonieux)
 - Classification non-supervisée \rightarrow optimisation combinatoire
 - ...

Exemples dans un domaine scientifique : apprentissage

- Apprentissage (...) : construire une représentation à partir d'observation
- Applications : bio-stats, vison par ordinateur (semaine prochaine !),...
- Caractéristiques : problèmes de très grande dimension, bruités
- Trois applications de l'optimisation convexe en apprentissage
 - ❶ Filtrage collaboratif
 - ❷ Classification supervisée
 - ❸ **Classification supervisée multiclasse**
- Bien d'autres ! (interaction optimisation \leftrightarrow apprentissage)
 - Déjà vu : moindres carrés (parcimonieux)
 - Classification non-supervisée \rightarrow optimisation combinatoire
 - ...

Exemple 3 : classification supervisée multiclasse

- But : classer des objets (auxquels sont associés des descripteurs)
 - données : couples descripteurs/classes $(x_i, y_i) \in \mathbb{R}^p \times \{0, 1\}^K$
 - assigner une classe à un nouvel objet décrit par x ?
- Ex : vision par ordinateur

Exemple 3 : classification supervisée multiclasse

- But : classer des objets (auxquels sont associés des descripteurs)
 - données : couples descripteurs/classes $(x_i, y_i) \in \mathbb{R}^p \times \{0, 1\}^K$
 - assigner une classe à un nouvel objet décrit par x ?
- Ex : vision par ordinateur
- Optimisation : apprendre un classifieur à partir des données
 - calculer une matrice de poids $W \in \mathbb{R}^{p \times K}$
 - minimiser une fonction d'erreur (+ régularisation)

$$\min_{W \in \mathbb{R}^{p \times K}} \frac{1}{n} \sum_{i=1}^n L(y_i, W^\top x_i) + \alpha \text{Reg}(W)$$

- pour classer suivant $\max_{k=1, \dots, K} w_k^\top x$

Exemple 3 : classification supervisée multiclasse

- But : classer des objets (auxquels sont associés des descripteurs)
 - données : couples descripteurs/classes $(x_i, y_i) \in \mathbb{R}^p \times \{0, 1\}^K$
 - assigner une classe à un nouvel objet décrit par x ?
- Ex : vision par ordinateur
- Optimisation : apprendre un classifieur à partir des données
 - calculer une matrice de poids $W \in \mathbb{R}^{p \times K}$
 - minimiser une fonction d'erreur (+ régularisation)


$$\min_{W \in \mathbb{R}^{p \times K}} \frac{1}{n} \sum_{i=1}^n L(y_i, W^\top x_i) + \alpha \text{Reg}(W)$$

- pour classer suivant $\max_{k=1, \dots, K} w_k^\top x$

- Situation : OK pour $K = 2$ (et $K \approx 10 \dots$ en revenant au cas 2!)
- Défi : K grand (avec une véritable approche multiclasse)
- Ex: Pascal Challenge '10 "Imagenet" : $K \approx 1000$ mais peu fiable


Exemple 3 : classification multiclasse avec sous-structure

- Structure sous-jacente inconnue
- $\text{rang}(W)$ faible
- Factorisation de l'information
(et calculs moins chers)
- $W = UV^\top$, $U \in \mathbb{R}^{p \times r}, V \in \mathbb{R}^{K \times r}$



Exemple 3 : classification multiclasse avec sous-structure

- Structure sous-jacente inconnue
 - rang(W) faible
 - Factorisation de l'information
(et calculs moins chers)
 - $W = UV^\top$, $U \in \mathbb{R}^{p \times \textcolor{red}{r}}$, $V \in \mathbb{R}^{K \times \textcolor{red}{r}}$




- Optimisation : problème grande taille non-convexe

$$\min_{W \in \mathbb{R}^{p \times K}} \alpha \operatorname{rang}(W) + \frac{1}{n} \sum_{i=1}^n L(y_i, W^\top x_i)$$

Exemple 3 : classification multiclasse avec sous-structure

- Structure sous-jacente inconnue
- $\text{rang}(W)$ faible
- Factorisation de l'information (et calculs moins chers)
- $W = UV^\top$, $U \in \mathbb{R}^{p \times r}, V \in \mathbb{R}^{K \times r}$




- Optimisation : **relaxation convexe** non-différentiable

$$\min_{W \in \mathbb{R}^{p \times K}} \alpha \|\sigma(W)\|_1 + \frac{1}{n} \sum_{i=1}^n L(y_i, W^\top x_i)$$

où $\sigma(W)$ est le vecteur des valeurs singulières

Exemple 3 : classification multiclasse avec sous-structure

- Structure sous-jacente inconnue
- $\text{rang}(W)$ faible
- Factorisation de l'information (et calculs moins chers)
- $W = UV^\top$, $U \in \mathbb{R}^{p \times r}, V \in \mathbb{R}^{K \times r}$



- Optimisation : **relaxation convexe** non-différentiable

$$\min_{W \in \mathbb{R}^{p \times K}} \alpha \|\sigma(W)\|_1 + \frac{1}{n} \sum_{i=1}^n L(y_i, W^\top x_i)$$

où $\sigma(W)$ est le vecteur des valeurs singulières

- Recherche en cours : approche constructive + contrôle du rang

Plan d'aujourd'hui (Partie 1) : Introductions, exemples

1 Vue d'ensemble

2 Introduction à l'optimisation

3 Introduction à l'analyse convexe

4 Exemples de problèmes d'optimisation convexe

- Exemple dans l'industrie : gestion de la production électrique
- Exemples dans un domaine scientifique : apprentissage statistique