

COURS D'OPTIMISATION

ISIMA – F4 3ème année – Master Recherche Maths

Jonas Koko

ISIMA

Plan

- 1 Ensembles convexes
- 2 Fonctions convexes
- 3 Dualité
- 4 Algorithmes

Motivations



Régularisations de problèmes de type “moindres carrés”

Applications :

- Programmation quadratique
- Restauration d'images
- least absolute deviations $\| Ax - b \|_1$
- ℓ_1 Loss minimization $\min l(x) + \lambda \| x \|_1$
- LASSO $\| Ax - b \|_2^2 + \lambda \| x \|_1$
- ...



Norme $\| \cdot \|_2$

$$f(x) = \| x \|_2$$



Norme $\| \cdot \|_1$

$$f(x) = \| x \|_1$$



Quelques Rappels

Définition (Boule unité)

$$B = \{x \in \mathbb{R}^n \mid \|x\| \leq 1\}$$

Définition

C un ensemble

- *Fermeture* : $cl(C) = \bigcap_{\epsilon > 0} (C + \epsilon B)$
- *Intérieur* : $int(C) = \{x \in C \mid \exists \epsilon > 0; x + \epsilon B \subset C\}$
- C est un cône si $\forall x \in C, \lambda x \in C, \forall \lambda \geq 0$.

Rappels II

Définition (Hyperplan)

Dans \mathbb{R}^n , un sous-espace de dimension $n - 1$. Par exemple,

$$x_i = \sum_{j \neq i} a_j x_j$$

Définition (Opérateur monotone)

A est monotone si

$$\langle A(u) - A(v), u - v \rangle \geq 0, \quad \forall u, v$$

Si A est linéaire

$$\langle A(u), u \rangle \geq 0, \quad \forall u$$

Si A est une matrice (\cdot, \cdot) A est défini positif

Ensemble convexe

Définition (Ensemble convexe)

C est convexe si $\lambda x + (1 - \lambda)y \in C$, $\forall x, y \in C$ et $\forall \lambda \in (0, 1)$.

Exemples :

- Les boules $B(x_0, r) = \{x : \|x - x_0\| \leq r\}$
- Cônes
- Sous-espaces vectoriels, sous-espaces affines

Propriétés :

- C_1, C_2 convexes, alors $C_1 \cap C_2$ convexe
- C_1, C_2 convexes, alors $\alpha_1 C_1 + \alpha_2 C_2$ convexe, $\forall \alpha_1, \alpha_2$

Définition (Combinaison convexe)

$$\sum_{i=1}^m \lambda_i x_i, \quad \lambda_i \geq 0, \quad \sum_{i=1}^m \lambda_i = 1.$$

Ensembles convexes II

Définition (Enveloppe convexe)

S ensemble convexe

$$\text{conv}(S) = \left\{ x \in \mathbb{R}^n, : x = \sum_{i=1}^m \lambda_i a_i, \lambda_i \geq 0, \sum_{i=1}^m \lambda_i = 1, a_i \in S \right\}$$

$\text{conv}(S)$ est convexe.

Projection

Définition (Projection)

C ensemble convexe de \mathbb{R}^n , $u \in \mathbb{R}^n$. Le vecteur p est meilleure approximation de u sur C si

$$\|u - p\|_2 = \min_{x \in C} \|u - x\|_2$$

Théorème

C convexe fermé non vide. $u \in \mathbb{R}^n$ possède un unique p tel que

$$\|u - p\|_2 = \min_{x \in C} \|u - x\|_2$$

$$\langle p - u, p - x \rangle \leq 0, \quad \forall x \in C.$$

Projection II

Théorème (monotonie)

φ_C projection sur C alors

$$\langle \varphi_C(u) - \varphi_C(v), u - v \rangle \geq 0, \forall u, v \in C (\text{monotone})$$

$$\| \varphi_C(u) - \varphi_C(v) \| \leq \| u - v \|, \forall u, v \in C (\text{non-expansive})$$

Fonctions convexes

Définition

- *Domaine* : $Dom(f) = \{x \mid f(x) < +\infty\}$
- *f propre* si $Dom(f) \neq \emptyset$ et $f(x) > -\infty$
- *Epigraphe* $epi(f) = \{(x, z) \in \mathbb{R}^{n+1} \mid f(x) \leq z\}$

Définition (Fonction convexe)

$f : C \rightarrow \mathbb{R}$ convexe si $\forall \lambda \in (0, 1)$

$$f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y), \quad \forall x, y \in C.$$

f fortement convexe si $\exists \alpha > 0$

$$f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y) - \frac{\alpha}{2} \lambda(1 - \lambda) \|x - y\|^2, \quad \forall x, y \in C.$$

Exemples de fonctions convexes

Remarque

Si f convexe, la fonction $g = -f$ est concave

- Fonctions affines (linéaires)
- $f(x) = (1/2x^T Qx - b^T x, Q$ semi-définie positive
- $f(x) = x^2$
- $f(x) = e^x$
- $f(x) = -\log(x), x > 0$
- $f(x) = -\sqrt{x}, x \geq 0$
- $f(x) = 1/x, x > 0$
- $f(x) = |x|$

Propriétés

Théorème (caractérisation fondamentale)

f est convexe si, et seulement si, $\text{epi}(f)$ est convexe.

f_1, f_2 convexes et $\text{Dom}(f_1) \cup \text{Dom}(f_2) \neq \emptyset$

- $f_1 + f_2$ convexe
- af_1 convexe, $\forall a \geq 0$
- $\sup\{f_1, f_2\}$ convexe
- $f_1 \square f_2(x) := \inf_z f_1(z) + f_2(x - z)$ (inf-convolution) est convexe
- f convexe et A affine, $(f \circ A)(x) = f(Ax)$ convexe
- f_i ($i \in I$) affines, $f(x) = \sup_{i \in I} f_i(x)$ convexe.

Continuité

Définition (Continuité)

C convexe ouvert de \mathbb{R}^n , $f : C \rightarrow \mathbb{R}$. f *semi-continue inférieurement (sci)* en $x \in C$ si $\forall \{x_k\} \subset C, x_k \rightarrow x$

$$f(x) \leq \liminf_{x_k \rightarrow x} f(x_k).$$

Définition (Dérivée directionnelle)

$f : C \rightarrow \mathbb{R}$, La dérivée directionnell de f en $x \in C$ dans la direction $d \in \mathbb{R}^n$ (si elle existe) est

$$f'(x; d) = \lim_{t \rightarrow 0} \frac{1}{t} (f(x + td) - f(x))$$

f différentiable en x si $f'(x; d)$ existe dans toutes les directions.

Propriétés

Théorème

C ouvert convexe et f différentiable sur C , alors les affirmations suivantes sont équivalentes

f convexe sur C

$$\forall x, y \in C, \langle \nabla f(x), y - x \rangle \leq f(y) - f(x)$$

$$\forall x, y \in C, \langle \nabla f(x) - \nabla f(y), y - x \rangle \geq 0.$$

Théorème

f fortement convexe sur C convexe ouvert de \mathbb{R}^n , alors

$$\forall x, y \in C, \langle \nabla f(x) - \nabla f(y), y - x \rangle \geq \alpha \|x - y\|_2^2.$$

$\nabla^2 f(x)$ semi définie positive

Fonction conjuguée

Définition (Fonction support)

C sous-ensemble de \mathbb{R}^n ,

$$\sigma_C(y) = \sup_{x \in C} \langle y, x \rangle$$

La fonction σ_C est convexe sci.

Définition (Fonction conjuguée)

La conjuguée d'une fonction f de \mathbb{R}^n dans \mathbb{R} est

$$f^*(y) = \sup_{x \in \text{Dom}(f)} \langle x, y \rangle - f(x)$$

Inégalité de Fenchel

$$f(x) \geq \langle x, y \rangle - f^*(y) \quad \forall y \in \text{Dom}(f^*) \text{ et } \forall x \in \text{Dom}(f)$$

Fonction conjuguée : exemple de calcul

- $f(x) = |x|$

$$xy \leq |x||y| \Rightarrow yx - |x| \leq (|y| - 1)|x| \Rightarrow f^*(y) = \begin{cases} 0 & \text{si } |y| \leq 1 \\ +\infty & \text{sinon} \end{cases}$$

- $f(x) = \chi_C$, C convexe

$$f^*(y) = \sup \langle x, y \rangle - \chi_C(x) = \sup_{x \in C} \langle x, y \rangle = \sigma_C(y)$$

Sous-différentiabilité

Définition (Sous-gradient)

$\gamma \in \mathbb{R}^n$ *sous-gradient* de f en x_0 si

$$f(x) \geq f(x_0) + \langle \gamma, x - x_0 \rangle, \quad \forall x \in \text{Dom}(f).$$

$\partial f(x_0)$ *ensemble des sous-gradient* en x_0 (*sous-différentiel*).

Conditions équivalentes

$$y_0 \in \partial f(x_0)$$

$$x_0 \in \partial f^*(y_0)$$

$$f(x_0) + f^*(y_0) = \langle x_0, y_0 \rangle$$

f différentiable en $x_0 \Leftrightarrow \partial f(x_0) = \{\nabla f(x_0)\}$

Dualité de Fenchel

X, Y \mathbb{R} -espaces vectoriels normés complets de dual X^*, Y^*

$\Lambda \in \mathcal{L}(X, Y), \Lambda^* \in \mathcal{L}(Y^*, X^*)$ (adjoint)

$F : X \rightarrow \bar{\mathbb{R}}$ convexe, $G : Y \rightarrow \bar{\mathbb{R}}$ convexe

F^*, G^* conjuguées

Définition (Problème primal)

$$(P) \quad \inf_{x \in X} F(x) + G(\Lambda x)$$

Définition (Problème dual)

$$(P^*) \quad \sup_{y^* \in Y^*} -F^*(-\Lambda^* y^*) - G^*(y^*)$$

Conditions d'optimalités

Theorem (Fenchel)

F, G convexes sci propres

$\exists x_0 \in X, F(x_0) < +\infty, G(\lambda x_0) < +\infty, G$ continue en λx_0 .

Alors (P) et (P^*) admettent au moins une solution \bar{x} et \bar{y}^*

$$\alpha = \inf_{x \in X} F(x) + G(\lambda x) = \sup_{y^* \in Y^*} -F^*(-\Lambda^* y^*) - G^*(y^*)$$

Theorem

Si $|\alpha| < +\infty$ alors

$$-\Lambda^* \bar{y}^* \in \partial F(\bar{x})$$

$$\bar{y}^* \in \partial G(\Lambda \bar{x})$$

\bar{x} solution de (P) , \bar{y}^* solution de (P^*)

Descente du gradient

Gradient Descent (GD)

1 For $k = 0, \dots, K - 1$

$$g_k \in \partial f(x_k)$$

$$x_{k+1} = x_k - t_k g_k$$

2 Return x_K or $x_m = (x_0 + \dots + x_{K-1})/K$

Marche aussi pour le cas avec contrainte, $x \in C$:

$$x_{k+1} = \text{Proj}_C(x_k - t_k g_k)$$

Descente du Gradient 2

Hypothèse (HL) (Lipschitz)

$$\exists L > 0, \quad \forall x, \quad g \in \partial f(x) \text{ tel que } \|g\| \leq L$$

Théorème

Si (HL) et $t_k = R/(L\sqrt{K})$ alors

$$f\left(\frac{1}{K} \sum_{k=0}^{K-1} x_k\right) - f(x^*) \leq \frac{RL}{\sqrt{K}}$$

Rem : Pour une précision ε , $K = R^2 L^2 / \varepsilon^2$

Descente du Gradient 3

Hypothèse (βL) (β -Lipschitz)

$$\forall x, y, \quad \|\nabla f(x) - \nabla f(y)\| \leq \beta \|x - y\|$$

Théorème

Si (βL) et $t_k = 1/\beta$ alors

$$f(x_K) - f(x^*) \leq \frac{2\beta \|x_0 - x^*\|^2}{K + 4}$$

Rem : Pour une précision ε , $K = 2\beta/\varepsilon$

Descente du Gradient 4

Hypothèse (αC) f fortement convexe

$$\forall x, y, \quad g_x \in \partial f(x), \quad f(y) \geq f(x) + \langle g, y - x \rangle + \frac{\alpha}{2} \|y - x\|^2$$

Théorème

Si (βL) , (αC) et $t_k = 1/(\alpha(k+1))$ alors

$$f\left(\frac{1}{K} \sum_{k=0}^{K-1} x_k\right) - f(x^*) \leq \frac{2L^2 \log(K)}{\alpha K}$$

Rem : Pour une précision ε , $K = 2L^2/(\alpha\varepsilon)$

Descente du Gradient accélérée (Nesterov)

Nesterov

- 1 $k = 0, y_1 = x_0, t_0 = 1$
- 2 For $k \geq 0$

$$x_k = y_k - (1/L)\nabla f(y_k)$$

$$t_{k+1} = (1 + \sqrt{1 + 4t_k^2})/2$$

$$y_{k+1} = x_k + (t_k - 1)(x_k - x_{k-1})/t_{k+1}$$

Théorème

$$f(x_k) - f(x^*) \leq \frac{2L \|x_0 - x^*\|^2}{k^2}$$

Rem : Pour une précision ε , $K = 2L/\sqrt{\varepsilon}$

ADMM

ADMM = Alternating Direction Method of Multiplier.
 Problem modèle

$$\min_{x,z} f(x) + g(z)$$

$$Ax + Bz = c$$

$x \in \mathbb{R}^n$, $z \in \mathbb{R}^m$, A $p \times n$, B $p \times m$, $c \in \mathbb{R}^p$.

$$p^* = \inf_{(x,z)} \{f(x) + g(z) \mid Ax + Bz = c\}$$

Lagrangien augmenté

$$\mathcal{L}_r(x, z, \lambda) = f(x) + g(z) + \lambda^\top (Ax + Bz - c) + \frac{r}{2} \|Ax + Bz - c\|_2^2.$$

ADMM Standard

$r > 0$ fixé; λ^0, z^0 données

$$x^{k+1} = \arg \min_x \mathcal{L}_r(x, z^k, \lambda^k)$$

$$z^{k+1} = \arg \min_z \mathcal{L}_r(x^{k+1}, z, \lambda^k)$$

$$\lambda^{k+1} = \lambda^k + r(Ax^{k+1} + Bz^{k+1} - c)$$

ADMM Symétrique

$r > 0$ fixé; λ^0, z^0 données

$$x^{k+1} = \arg \min_x \mathcal{L}_r(x, z^k, \lambda^k)$$

$$\lambda^{k+1/2} = \lambda^k + \frac{r}{2}(Ax^{k+1} + Bz^k - c)$$

$$z^{k+1} = \arg \min_x \mathcal{L}_r(x^{k+1}, z, \lambda^{k+1/2})$$

$$\lambda^{k+1} = \lambda^{k+1/2} + \frac{r}{2}(Ax^{k+1} + Bz^{k+1} - c)$$

ADMM Convergence

- (H1) f, g sci convexes propres fermées (épigraphe de f et g convexes fermées non vides)
 (H2) \mathcal{L}_r admet un selle

$$\mathcal{L}_r(x^*, z^*, \lambda) \leq \mathcal{L}_r(x^*, z^*, \lambda^*) \leq \mathcal{L}_r(x, z, \lambda^*)$$

Théorème

Si (H1)+(H2), alors quand $k \rightarrow +\infty$

$$r^k = Ax^k + Bz^k - c \rightarrow 0 \quad (1)$$

$$f(x^k) + g(z^k) \rightarrow p^* \quad (2)$$

$$\lambda^k \rightarrow \lambda^* \quad (3)$$