

Cours SOD314: TD1

Mardi 4 février 2020

Ex. 1: Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$ une fonction continue différentiable. Soit $x \in \mathbb{R}^n$.

- Résoudre le problème

$$\begin{aligned} \min_{d \in \mathbb{R}^n} \quad & \nabla f(x)^\top d \\ \text{s.t.} \quad & \|d\|_2 = 1, \end{aligned} \tag{1}$$

et montrer que la direction de pente maximale est $-\nabla f(x)$.

- On suppose maintenant que le gradient de f est L -Lipschitzien:

$$\|\nabla f(x) - \nabla f(y)\| \leq L\|x - y\|. \tag{2}$$

On rappelle que f satisfait alors l'inégalité:

$$f(y) \leq f(x) + \nabla f(x)^\top (y - x) + \frac{L}{2} \|y - x\|_2^2. \tag{3}$$

Montrer que le pas optimal de descente est $\frac{1}{L}$.

Correction: *i)* On réécrit la contrainte $\|d\|_2^2 = 1$ pour obtenir un problème équivalent. On dualise alors la contrainte pour obtenir le Lagrangien $\mathcal{L}(d, \mu) = \nabla f(x)^\top d + \mu(\|d\|_2^2 - 1)$. Les conditions d'optimalité au premier ordre donne: $\nabla_d \mathcal{L}(d, \mu) = 0$, soit $\nabla f(x) + 2\mu d = 0$, soit $d = -\frac{\nabla f(x)}{2\mu}$. Par ailleurs, on a $\|d\|_2 = 1$, d'où $\mu = \frac{\|\nabla f(x)\|}{2}$, puis $d = -\frac{\nabla f(x)}{\|\nabla f(x)\|}$.

ii) Soit $x_{k+1} = x_k - \alpha \nabla f(x_k)$. On a alors

$$\begin{aligned} f(x_{k+1}) &\leq f(x_k) + \nabla f(x_k)^\top (x_{k+1} - x_k) + \frac{L}{2} \|x_{k+1} - x_k\|_2^2 \\ &= f(x_k) - \alpha \nabla f(x_k)^\top \nabla f(x_k) + \frac{L}{2} \|\alpha \nabla f(x_k)\|_2^2 \\ &= f(x_k) + \left(\frac{L}{2} \alpha^2 - \alpha\right) \|\nabla f(x_k)\|_2^2. \end{aligned}$$

En prenant alors $\alpha = \frac{1}{L}$ on minimise le terme de droite, qui est lui-même une borne supérieure pour $f(x_{k+1})$. On assure alors que l'objectif décroît au moins de $-\frac{1}{2L} \|\nabla f(x_k)\|_2^2$ entre deux itérations.

Ex. 2:(Transformée de Fenchel) Calculer la transformée de Fenchel des fonctions suivantes:

- $f(x) = |x|$.
- $f(x) = \frac{1}{2} \|x\|_2^2$.
- $f(x) = \frac{1}{2} x^\top Qx + b^\top x$ où $Q \in \mathbb{R}^{n \times n}$ est une matrice symétrique définie positive.
- $f(x) = \log(1 + \exp(x))$.

Correction:

i) Notons que $f^*(p) = \sup_{x \in \mathbb{R}} (px - |x|) = \sup \{ \sup_{x \geq 0} (px - x), \sup_{x < 0} (px + x) \}$. On a alors

- Si $p < -1$, alors $\sup_{x < 0}((p+1)x) = +\infty$ et donc $f^*(p) = +\infty$.
- Si $p > 1$ alors $\sup_{x \geq 0}((p-1)x) = +\infty$ et donc $f^*(p) = +\infty$.
- Si $|p| \leq 1$, alors $\sup_{x < 0}((p+1)x) = 0$ et $\sup_{x \geq 0}((p-1)x) = 0$. D'où $f^*(p) = 0$.

On en déduit alors

$$f^*(p) = \begin{cases} 0 & \text{si } |p| \leq 1 \\ +\infty & \text{sinon} \end{cases}$$

ii) On a par définition $f^*(p) = \sup_{x \in \mathbb{R}^n} p^\top x - \frac{1}{2} \|x\|_2^2$. Les conditions d'optimalité au premier ordre nous donne que le minimum satisfait $x^\# = p$, d'où $f^*(p) = \frac{1}{2} \|p\|_2^2$.

iii) On a $f^*(p) = \sup_x p^\top x - \frac{1}{2} x^\top Qx - b^\top x$. Les conditions d'optimalité au premier ordre donnent

$$p - Qx - b = 0$$

soit $x = Q^{-1}(p-b)$. En remplaçant dans le problème d'optimisation précédent, on obtient $f^*(p) = \frac{1}{2}(p-b)^\top Q^{-1}(p-b)$.

iv) On a $f^*(p) = \sup_x p^\top x - \log(1 + \exp(x))$. Les conditions d'optimalité au premier ordre nous donnent, si existence de la solution: $p = \frac{\exp x}{1 + \exp x}$. On en déduit:

- Si $p \in]0, 1[$, alors $x = \log(\frac{p}{1-p})$. En remplaçant on obtient alors $f^*(p) = p \log(\frac{p}{1-p}) + \log(1-p) = (1-p) \log(1-p) + p \log(p)$.
- Si $p \in \{0, 1\}$, $f^*(p) = 0$. Dans ce cas, le sup n'est pas atteint.
- Sinon $f^*(p) = +\infty$.

Ex. 3: Soit $f : \mathbb{R}^n \rightarrow]-\infty, +\infty]$ et $g : \mathbb{R}^n \rightarrow]-\infty, +\infty]$ deux fonctions propres, convexes, s.c.i. On définit l'opération d'inf-convolution comme

$$(f \square g)(x) = \inf_{y \in \mathbb{R}^n} f(y) + g(x-y) . \quad (4)$$

Montrer que $(f+g)^* = f^* \square g^*$.

Correction:

On a

$$\begin{aligned} (f \square g)^*(p) &= \sup_x p^\top x - \inf_y (f(y) + g(x-y)) \\ &= \sup_{x,y} p^\top x - f(y) - g(x-y) \\ &= \sup_{x,y} p^\top y + p^\top (x-y) - f(y) - g(x-y) \\ &= \sup_{y,z} p^\top y + p^\top z - f(y) - g(z) \\ &= \sup_y (p^\top y - f(y)) + \sup_z (p^\top z - g(z)) \\ &= f^*(p) + g^*(p) \end{aligned}$$

On en déduit $(f \square g)^* = f^* + g^*$. Si on prend $f' = f^*$ et $g' = g^*$, le résultat se réécrit $(f^* \square g^*)^* = f + g$. En effet, f et g étant convexes propres s.c.i, on a que $f^{**} = f$ et $g^{**} = g$ (Chapitre 1, proposition 5). D'où le résultat final en prenant les transformées de Fenchel des deux membres de l'égalité précédente.

Ex. 4: On étudie un problème de régression avec une régularisation en norme ℓ_1 . On suppose disponible un ensemble de labels $y_1, \dots, y_n \in \mathbb{R}$ correspondant à des observations $x_1, \dots, x_n \in \mathbb{R}^p$. Le problème de régression cherche à trouver le paramètre $\theta \in \mathbb{R}^p$ solution du problème d'optimisation

$$\min_{\theta \in \mathbb{R}^p} \sum_{i=1}^n l(x_i^\top \theta, y_i) + \lambda \|\theta\|_1 , \quad (5)$$

où $l : \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$ est une fonction de pénalisation et $\lambda \in \mathbb{R}$ un paramètre de régularisation. Le terme $\|\cdot\|_1$ est non-differentiable. Pour le prendre en compte, on réécrit le problème sous la forme:

$$\min_{\theta \in \mathbb{R}^p} F(\theta) + G(\theta) , \quad (6)$$

avec $G : x \rightarrow \|x\|_1$.

- Calculer le sous-différentiel de G .
- Calculer la transformée de Fenchel de G . Faire un dessin.
- Exprimer $(F + G)^*$ en fonction de F^* et G^* .
- Expliquer l'intérêt de la formulation duale du problème.

Correction:

i) On a $G(x) = \|x\|_1 = \sum_{i=1}^n |x_i|$ qui est une fonction additive.

ii) On sait que la transformée de Fenchel de $h(x) = \|x\|_1$ vaut $h^*(p) = \chi_{[-1,1]}(p)$, où $\chi_{[-1,1]}$ désigne la fonction indicatrice de l'intervalle $[-1, 1]$. En utilisant l'additivité de G , on en déduit $G^*(p) = \chi_B(p)$, avec $B = \{p \in \mathbb{R}^n : |x_i| \leq 1, \forall i = 1, \dots, n\}$.

iii) En utilisant l'exercice 3, on obtient $(F + G)^* = F^* \square G^*$.

iv) Si la transformée de Fenchel de F est facile à calculer, la formulation duale du problème $(F+G)^*$ présente l'avantage de ne plus être non-lisse, la fonction G se réécrivant dans le dual comme une fonction indicatrice, induisant des contraintes sur les bornes de $p \in \mathbb{R}^n$. Ces contraintes de borne sont habituellement faciles à traiter pour les solveurs d'optimisation.