

Mathématique pour l'intelligence artificielle (MIA)

Séance 3

Table des matières :

1. Résolution d'exercice de la planche précédente (Planche 2)

2. Optimisation

2.1. Optimisation sans contraintes

2.1.1. *Analyse*

2.1.2. *Convexité*

2.2. Optimisation sous contraintes

2.2.1. *Condition nécessaire d'optimalité : Intuition*

2.3. Dualité

3. Exercices

1. Résolution d'exercice de la planche précédente (Planche 2)

Exercice 2 :

1) $[v_1, \dots, v_m][v_1, \dots, v_m]^T$

$[v_1, \dots, v_m]^T [v_1, \dots, v_m]$: produit scalaire entre

vecteurs orthogonaux donne $\rightarrow 0$ si les vecteurs sont différents
 $\hookrightarrow 1$ sinon

$$V^T V = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

On peut le montrer par : $\bullet AB = Id$

$\bullet BA = Id$

Si on trouve C linéaire et inverse, alors :

$BC = Id$

\hookrightarrow pour prouver que $C=A$, on peut prendre : $ABC = C = A$

$V^T V = Id \quad \equiv \quad V V^T = Id$

2. Optimisation

2.1. Optimisation sans contraintes

Les fonctions de la classe C^1 sont continues dérivables et admettent donc plusieurs dérivées partielles.

Une matrice Jacobienne est définie de $\mathbb{R}^m \mapsto \mathbb{R}^m \times \mathbb{R}^m$

Rappel : On dit d'une fonction qu'elle est la composée d'autres fonctions quand sa forme est un ensemble de ces fonctions. En générale on note la composition par le signe "o".

Exemple : on note $h = g \circ f$, on a :

$f: x \mapsto Ax - y$ et $g: z \mapsto \|z\|_2^2$

D'où : $h(x) = \|Ax - y\|_2^2$

Une chain rule est tel que : $J f \circ g(a) = J f(g(a)) J g(a)$

\hookrightarrow domaine de départ = arriver de g

2.1.1. Analyse

La matrice Hessienne de f ce défini comme :

$\nabla^2 f: U \subset \mathbb{R}^m \mapsto \mathbb{R}$

$$\nabla^2 f = H(f) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_m} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \dots & \frac{\partial^2 f}{\partial x_2 \partial x_m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_m \partial x_1} & \frac{\partial^2 f}{\partial x_m \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_m^2} \end{bmatrix}$$

2.1.2. Convexité

Si deux points d'un ensemble sont reliés entre eux, tous les points sur la droite ainsi formée sont dans l'ensemble.

Si f est une fonction strictement convexe définie sur un ensemble convexe $X \subset \mathbb{R}^n$, alors f admet au plus un minimum global. Cependant, de même façon, si cette fois ci f est convexe non stricte, alors il y a plusieurs minimum globaux de f possibles.

2.2. Optimisation sous contraintes

Exemple :

On veut $x_1 + x_2$ à min, avec comme contrainte $x_1 \cdot x_2 = 10$

On peut écrire : $-x_1 \cdot x_2 \geq 10$

$-x_1 \cdot x_2 - 10 \geq 0$

2.2.1. Condition nécessaire d'optimalité : Intuition

Sur une figure donnée, lorsque les gradient calculés préalablement sont affichés, on ne peut se déplacer en partant de chacun d'eux que de façon orthogonale, dans la continuité de f.

Si λ_i^* est une contrainte active, elle est égale à 0 et donc la condition nécessaire d'optimalité est nulle ($\lambda_i^* c_i(x^*) = 0$).

2.3. Dualité

L'idée générale de la dualité est de voir un même problème sous un angle différent. Cela permet souvent de déduire des propriétés différentes.

Le Lagrangien peut s'écrire de deux façon, comme une somme ou une soustraction, en fonction de l'inégalité :

$L(x, \mu) = f(x) - \mu^t g(x)$

ou $L(x, \mu) = f(x) + \mu^t g(x)$

Dans les problème de dualité, la fonction $q(\mu)$ n'est pas forcément une fonction continue.

On appelle "Duality Gap" la différence entre q^* et f^* .

Sur la figure a) diapo 86, on cherche la droite $q(\mu)$ qui minimise sa position sur l'axe y, tel que la droite passe par au moins un point de la figure.

3. Exercices

Exercice 1 :

1) $\frac{\partial f(x,y)}{\partial x} \mapsto 2xy$

$\frac{\partial f(x,y)}{\partial y} \mapsto x^2$

2) $\|x\|_2 = \sqrt{\|x\|_2^2} = \sqrt{x^T \cdot x^*}$

$f: \mathbb{R}^m \mapsto \mathbb{R}^+$ $J_f(x) = 2x^*$
 $x \mapsto x^T \cdot x$

$g: \mathbb{R}^+ \mapsto \mathbb{R}$ $J_g(y) = \frac{1}{2\sqrt{y}}$
 $x \mapsto \sqrt{x}$

$h: x \mapsto \|x\|_2$ $h = g \circ f$ $J_h = \frac{2a}{2\sqrt{a}} = \frac{a}{\|a\|_2}$

$* x^T \cdot x = \sum_{i=1}^m x_i^2$

$\frac{\partial x^T \cdot x}{\partial x} = [2x_1, 2x_2, \dots, 2x_m]$
 $= 2x$

Conditions d'optimalité : La réciproque est non vrai.

Exercice 2 :

1) Le théorème dis que ce doit être ouvert, hors dans ce cas il est fermé donc cela ne peut pas marcher.

$\tilde{f}:]0, \pi[\mapsto \mathbb{R}$

$x \mapsto \sin(x)$
 Notons x^* un minimum globale de f :

Si $x^* \in]0, \pi[$:

alors $\nabla \tilde{f}(x^*) = 0$

i.e $\cos(x^*) = 0$

C'est impossible

Si $x^* = 0$, alors $\min f = 0$

Si $x^* = \pi$, alors $\min f = 0$

Donc le minimum globale de f est égale à 0.

Exercice 6 :

1) $f: x, y \mapsto x^2 + y^2$ $KKT \ x^*, y^*$
 $C_1: x + y - 1$ $x^* + y^* \geq 1$
 $C_2: x, y \mapsto 2 - y$ $y^* \leq 2$
 $C_3: x, y \mapsto y^2 - x$ $y^{*2} \geq x^*$

$L(x, y, \lambda_1, \lambda_2, \lambda_3) = x^2 + y^2 - \lambda_1(x + y - 1) - \lambda_2(2 - y) - \lambda_3(y^2 - x)$

$\nabla_x L(x, y, \lambda) = 2x - \lambda_1 + \lambda_3$

$\nabla_y L(x, y, \lambda) = 2y - \lambda_1 - \lambda_2 - 2\lambda_3 y$

Donc : $x^* = \frac{\lambda_1 - \lambda_3}{2}$ $y^* = \frac{\lambda_1 - \lambda_2}{2(1 - \lambda_3)}$

$\lambda_1, \lambda_2, \lambda_3 \geq 0$

$\lambda_1(x^* + y^* - 1) = 0$

$\lambda_2(2 - y^*) = 0$

$\lambda_3(y^{*2} - x^*) = 0$

2) Pas de solution compatible si $\lambda_1, \lambda_2, \lambda_3 = 0$
 λ_1 et $\lambda_3 \neq 0$ $\lambda_2 = 0$ 2 solutions

Exercice 8 :

1) $f: x \mapsto \sum_{i=1}^m x_i^2$
 $C_1: x \mapsto \sum_{i=1}^m x_i \leq c$
 $C_2: x \mapsto x_i \geq 0$
 $f^*: x \mapsto -x^T \cdot x$
 $g^*: x \mapsto \sum_{i=1}^m x_i - c$
 $g_1, \dots, g_m, x \mapsto -x_1, \dots, -x_m$
 $L(x, \mu_1, \dots, \mu_m) = -x^T \cdot x - \sum_{i=1}^m \mu_i x_i + \mu \sum_{i=1}^m x_i - \mu c$
 $= \sum_{i=1}^m -x_i^2 - \mu_i x_i + \mu x_i - \frac{\mu c}{m}$

$\inf (f_1(x_1) + f_2(x_2), x_1, x_2, \dots, x_m + \dots + f_m(x_m))$

$\Leftrightarrow \inf_{x_1} (f_1(x_1)) + \inf_{x_2} (f_2(x_2)) + \dots + \inf_{x_m} (f_m(x_m))$