

Notes du cours MTH1101 – Calcul I

Partie III: Optimisation

Guy Desaulniers

Département de mathématiques et de génie industriel
École Polytechnique de Montréal

Automne 2022

Table des matières

- 1 Optimisation
 - Valeurs extrêmes
 - Optimisation sans contraintes
 - Méthode du gradient
 - Optimisation avec contraintes : multiplicateurs de Lagrange

Table des matières

- 1 Optimisation
 - Valeurs extrêmes
 - Optimisation sans contraintes
 - Méthode du gradient
 - Optimisation avec contraintes : multiplicateurs de Lagrange

Soit un domaine $D \subseteq \mathbb{R}^n$ et une fonction $f : D \rightarrow \mathbb{R}$ de n variables.
On cherche un point $\vec{x} \in D$ qui minimise la valeur de $f(\vec{x})$ sur D .
On écrit :

$$\min_{\vec{x} \in D} f(\vec{x}).$$

La fonction f est appelée la **fonction objectif**.

Définition : minimum absolu

$\vec{x}^* \in D$ est un **minimum absolu (global)** de $f(\vec{x})$ sur D si

$$f(\vec{x}^*) \leq f(\vec{x}), \quad \forall \vec{x} \in D.$$

Définition : minimum local

$\vec{x}^* \in D$ est un **minimum local** de $f(\vec{x})$ sur D s'il existe $\epsilon > 0$ tel que

$$f(\vec{x}^*) \leq f(\vec{x}), \quad \forall \vec{x} \in D \cap B_\epsilon(\vec{x}^*),$$

où

$$B_\epsilon(\vec{x}^*) = \{\vec{x} \in \mathbb{R}^n : \|\vec{x} - \vec{x}^*\| < \epsilon\}$$

est la boule de rayon ϵ centrée en \vec{x}^* .

Remarques

- 1 Un minimum absolu est aussi un minimum local.
- 2 Un minimum peut aussi être un maximum.
- 3 Il n'existe pas toujours de minimum absolu, ni de minimum local.
- 4 En général, il est difficile de trouver un minimum absolu. Dans le cours, on se concentre surtout sur la recherche d'un minimum local.
- 5 Résoudre un problème de maximisation est équivalent à résoudre un problème de minimisation, i.e.,

$$\max_{\vec{x} \in D} f(\vec{x}) \quad \equiv \quad - \min_{\vec{x} \in D} -f(\vec{x}).$$

On peut donc se concentrer que sur les problèmes de minimisation.

Table des matières

- 1 Optimisation
 - Valeurs extrêmes
 - Optimisation sans contraintes
 - Méthode du gradient
 - Optimisation avec contraintes : multiplicateurs de Lagrange

En optimisation sans contraintes, on considère $D = \mathbb{R}^n$. On cherche donc à résoudre

$$\min_{\vec{x} \in \mathbb{R}^n} f(\vec{x}).$$

Condition nécessaire d'optimalité du premier ordre

Si \vec{x}^* est un minimum local, alors

$$\nabla f(\vec{x}^*) = \vec{0}.$$

Définition : point critique

\vec{x}^* est un **point critique** de $f(\vec{x})$ si $\nabla f(\vec{x}^*) = \vec{0}$.

Un point critique peut être

- un minimum local
- un maximum local
- un point de selle (i.e., $\forall \epsilon > 0$, il existe $\vec{a}, \vec{b} \in B_\epsilon(\vec{x}^*)$ tels que $f(\vec{a}) < f(\vec{x}^*) < f(\vec{b})$).

Définition : matrice hessienne

Soit $f(\vec{x})$ une fonction de n variables. La **matrice hessienne** de $f(\vec{x})$, notée $\nabla^2 f(\vec{x})$, est donnée par

$$\nabla^2 f(\vec{x}) = \begin{pmatrix} \frac{\partial^2 f}{\partial x_1^2}(\vec{x}) & \frac{\partial^2 f}{\partial x_1 \partial x_2}(\vec{x}) & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n}(\vec{x}) \\ \frac{\partial^2 f}{\partial x_2 \partial x_1}(\vec{x}) & \frac{\partial^2 f}{\partial x_2^2}(\vec{x}) & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n}(\vec{x}) \\ \cdots & \cdots & \ddots & \cdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1}(\vec{x}) & \frac{\partial^2 f}{\partial x_n \partial x_2}(\vec{x}) & \cdots & \frac{\partial^2 f}{\partial x_n^2}(\vec{x}) \end{pmatrix}.$$

Cette matrice est symétrique si toutes les dérivées sont continues.

Conditions nécessaires du second ordre

Si \vec{x}^* est un minimum local de $f(\vec{x})$, alors

$$\nabla f(\vec{x}^*) = \vec{0} \quad \text{et} \quad \vec{y}^T \nabla^2 f(\vec{x}^*) \vec{y} \geq 0, \quad \forall \vec{y} \in \mathbb{R}^n$$

(i.e., la matrice hessienne $\nabla^2 f(\vec{x}^*)$ est semi-définie positive).

Conditions suffisantes du second ordre

Soit $\vec{x}^* \in \mathbb{R}^n$. Si

$$\nabla f(\vec{x}^*) = \vec{0} \quad \text{et} \quad \vec{y}^T \nabla^2 f(\vec{x}^*) \vec{y} > 0, \quad \forall \vec{y} \in \mathbb{R}^n$$

(i.e., la matrice hessienne $\nabla^2 f(\vec{x}^*)$ est définie positive), alors \vec{x}^* est un minimum local de $f(\vec{x})$.

Une matrice $n \times n$ symétrique A est **définie positive** si

$$\det([a_{11}]) > 0, \det \left(\begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \right) > 0,$$

$$\det \left(\begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \right) > 0, \dots, \det(A) > 0.$$

Une matrice $n \times n$ symétrique A est **définie négative** si la matrice $-A$ est définie positive.

Une matrice $n \times n$ symétrique A est **semi-définie positive** si $\det(A) \geq 0$ et toutes ses sous-matrices carrées obtenues en éliminant des lignes et les colonnes correspondantes ont un déterminant non négatif.

Par exemple, une matrice 2×2 symétrique A est semi-définie positive si

$$\det([a_{11}]) \geq 0, \det([a_{22}]) \geq 0 \quad \text{et} \quad \det(A) \geq 0.$$

Une matrice $n \times n$ symétrique A est **semi-définie négative** si la matrice $-A$ est semi-définie positive.

En pratique, pour résoudre un problème d'optimisation sans contraintes, on trouve un point critique \vec{x}^* et on étudie sa nature :

- 1 Si $\nabla^2 f(\vec{x}^*)$ est définie positive, alors \vec{x}^* est un minimum local
- 2 Si $\nabla^2 f(\vec{x}^*)$ est définie négative, alors \vec{x}^* est un maximum local
- 3 Si $\nabla^2 f(\vec{x}^*)$ n'est pas semi-définie positive, alors \vec{x}^* n'est pas un minimum local
- 4 Si $-\nabla^2 f(\vec{x}^*)$ n'est pas semi-définie négative, alors \vec{x}^* n'est pas un maximum local
- 5 Si les conditions 3 et 4 sont satisfaites, alors \vec{x}^* est un point de selle.

Table des matières

- 1 Optimisation
 - Valeurs extrêmes
 - Optimisation sans contraintes
 - **Méthode du gradient**
 - Optimisation avec contraintes : multiplicateurs de Lagrange

Méthode du gradient dans \mathbb{R}^2

- Cette méthode permet de trouver, en général, un minimum local d'une fonction $f(x, y)$.
- C'est une méthode itérative
 - (x_k, y_k) : point courant au début de l'itération k
 - $\vec{d}_k = -\nabla f(x_k, y_k)$: direction de descente au point (x_k, y_k)
 - $h(\alpha) = f((x_k, y_k) + \alpha \vec{d}_k)$: fonction à une variable à minimiser à l'itération k

Pseudo-code de l'algorithme

- 1: Soit (x_0, y_0) un point initial.
- 2: Poser $k = 0$.
- 3: Calculer $\vec{d}_k = -\nabla f(x_k, y_k)$.
- 4: **Si** $\|\vec{d}_k\| = 0$ **alors**
- 5: Arrêter car (x_k, y_k) est un point critique.
- 6: **Sinon**
- 7: Résoudre le problème de recherche linéaire

$$\min_{\alpha \geq 0} h(\alpha) = f((x_k, y_k) + \alpha \vec{d}_k).$$

Dénoter par α^* le minimum obtenu.

- 8: Poser $(x_{k+1}, y_{k+1}) = (x_k, y_k) + \alpha^* \vec{d}_k$.
- 9: Poser $k = k + 1$.
- 10: Aller à l'étape 3.

Remarques

- En général, l'algorithme trouve un point critique qui est un minimum local.
- L'algorithme peut ne pas converger (i.e., aller vers $-\infty$).
- S'il y a plusieurs minima locaux et que l'algorithme converge, on ne sait pas vers quel minimum local.
- Plusieurs méthodes peuvent être utilisées pour résoudre le problème de recherche linéaire. Dans le cours, il sera résolu de façon analytique.
- Pour un problème de maximisation, on choisit $\vec{d}_k = \nabla f(x_k, y_k)$ et on maximise pour la recherche linéaire.
- L'algorithme se généralise au cas de plus de deux variables.
- L'algorithme s'approche d'un point critique en zigzaguant.

Table des matières

- 1 Optimisation
 - Valeurs extrêmes
 - Optimisation sans contraintes
 - Méthode du gradient
 - Optimisation avec contraintes : multiplicateurs de Lagrange

Soit $D \subseteq \mathbb{R}^n$ un domaine et $f : D \rightarrow \mathbb{R}$ une fonction de n variables. Considérons P , le problème d'optimisation avec contraintes

$$\min_{\vec{x} \in D} f(\vec{x}).$$

Définitions : ensemble fermé, ensemble borné

- Un ensemble S est **fermé** si tout point \vec{x} de la frontière de S appartient à S .
- Un ensemble S est **borné** s'il existe une constante $M \in \mathbb{R}$ telle que $\|\vec{x}\| \leq M, \forall \vec{x} \in S$.

Théorème

Si D est fermé et borné et $f(\vec{x})$ est une fonction continue sur D , alors le problème P a au moins un minimum absolu $\vec{x}^* \in D$.

Premier cas (une contrainte d'égalité) :

$$D = \{\vec{x} \in \mathbb{R}^n : g(\vec{x}) = k\}.$$

Conditions nécessaires d'optimalité du premier ordre

Si \vec{x}^* est un minimum local de $f(\vec{x})$ sur $D \in \mathbb{R}^n$ et $\nabla g(\vec{x}^*) \neq \vec{0}$, alors il existe $\lambda \in \mathbb{R}$ tel que

$$\nabla f(\vec{x}^*) = \lambda \nabla g(\vec{x}^*) \quad (1)$$

$$g(\vec{x}^*) = k. \quad (2)$$

Définition : point critique

Les points \vec{x}^* pour lesquels il existe λ tel que les conditions (1) et (2) sont satisfaites sont appelés des **points critiques**.

Chacun de ces points peut être un minimum local, un maximum local ou un point de selle.

Définition : multiplicateur de Lagrange

λ est appelé le **multiplicateur de Lagrange** associé à la contrainte $g(\vec{x}) = k$.

Soit

$$\begin{aligned} v(k) = \min & \quad f(\vec{x}) \\ \text{s.à} & \quad g(\vec{x}) = k \end{aligned}$$

une fonction qui donne la valeur minimale de ce problème d'optimisation en fonction de k .

Proposition

Soit λ le multiplicateur de Lagrange associé à $g(\vec{x}) = k$. Alors

$$\lambda = v'(k).$$

Pour un minimum local, λ indique le taux de variation de la valeur du minimum local.

Le polynôme de Taylor de degré 1 de $v(k)$ autour de k_0 est

$$T_1(k) = v(k_0) + \lambda_0(k - k_0),$$

où λ_0 est le multiplicateur de Lagrange pour $k = k_0$. Ce polynôme peut être utilisé pour estimer les valeurs optimales $v(k)$ pour k près de k_0 , i.e.,

$$v(k) \approx v(k_0) + \lambda_0(k - k_0).$$

Second cas (plusieurs contraintes d'égalité) :

$$D = \{\vec{x} \in \mathbb{R}^n : g_j(\vec{x}) = k_j, j = 1, 2, \dots, m\}.$$

Conditions nécessaires d'optimalité du premier ordre

Si \vec{x}^* est un minimum local de $f(\vec{x})$ sur $D \in \mathbb{R}^n$ et l'ensemble des gradients $\{\nabla g_j(\vec{x}^*) : j = 1, 2, \dots, m\}$ est linéairement indépendant, alors il existe $\lambda_j \in \mathbb{R}, j = 1, 2, \dots, m$, tels que

$$\nabla f(\vec{x}^*) = \sum_{j=1}^m \lambda_j \nabla g_j(\vec{x}^*) \quad (3)$$

$$g_j(\vec{x}^*) = k_j, \quad j = 1, 2, \dots, m. \quad (4)$$

Troisième cas (une contrainte d'inégalité) :

$$D = \{\vec{x} \in \mathbb{R}^n : g(\vec{x}) \leq k\}.$$

Il y a deux possibilités :

- 1 un minimum local \vec{x}^* est dans l'intérieur strict de D et alors $\nabla f(\vec{x}^*) = 0$.
- 2 un minimum local \vec{x}^* est sur la frontière de D et alors il satisfait les conditions (1) et (2) :

$$\begin{aligned}\nabla f(\vec{x}^*) &= \lambda \nabla g(\vec{x}^*) \\ g(\vec{x}^*) &= k.\end{aligned}$$

Méthode d'optimisation (si D est fermé et borné)

- 1 Trouver tous les points tels que

$$\nabla f(\vec{x}) = 0 \quad \text{et} \quad g(\vec{x}) < k$$

ou

$$\nabla f(\vec{x}) = \lambda \nabla g(\vec{x}) \quad \text{avec} \quad \lambda \in \mathbb{R}, \quad g(\vec{x}) = k \quad \text{et} \quad \nabla g(\vec{x}) \neq 0.$$

- 2 Évaluer $f(\vec{x})$ en tous ces points et comparer leurs valeurs pour trouver un minimum absolu.