

OPTIMISATION ET CONTRÔLE

Grégoire Allaire
Département de mathématiques appliquées
Ecole Polytechnique

- **Optimisation:** leçons 1 à 6.
- **Contrôle:** leçons 7 à 10.
- **Site web Moodle du cours:**
`https://moodle.polytechnique.fr/course/view.php?id=9673`
- **Page du cours sur mon site web:**
`http://www.cmap.polytechnique.fr/~allaire/cours_map435.html`
- **Me contacter:** `gregoire.allaire@polytechnique.fr`



- 1 Chapitre 1: introduction, motivation et exemples.
 - Optimisation.
 - Contrôle.
- 2 Chapitre 2: aspects théoriques de l'optimisation.
 - Définitions et notations.
 - Résultats d'existence.

Innombrables applications de l'optimisation et du contrôle:

- Sciences de l'ingénieur: industries de haute technologie (aéronautique, énergie, transport, communications), science des données, automatique, finance...
- Autres sciences: physique, mécanique, économie, informatique, sciences sociales...
- Domaines nouveaux ou inattendus: biologie, gestion, marketing, internet et réseaux sociaux...
- Chaque année de nouveaux problèmes arrivent !

Et toujours, trois étapes des mathématiques appliquées:

- 1 Modélisation.
- 2 Analyse mathématique du modèle.
- 3 Algorithmes de résolution numérique.

Qu'est ce que l'optimisation ?

- Pour améliorer un système, on **modélise** sa performance par une fonction $J : V \rightarrow \mathbb{R}$, où V est un espace de Hilbert qui représente les paramètres ou variables du modèle.
- Il peut y avoir des **contraintes** sur les paramètres, représentées par un sous-ensemble non-vide $K \subset V$.

Un problème d'optimisation s'écrit

$$\min_{v \in K \subset V} J(v).$$

(On minimise toujours: pour maximiser, considérer $\min -J(v)$.)

Remarque. Parfois les **contraintes** sont représentées par une fonction $C : V \rightarrow \mathbb{R}^M$ et on considère

$$\min_{v \in V \text{ tel que } C(v) \leq 0} J(v).$$

Pourquoi un espace de Hilbert ?

Est-il vraiment nécessaire d'étudier l'optimisation dans un espace de Hilbert de dimension infinie ?

On pourrait croire que non:

- beaucoup de problèmes d'optimisation sont posés en dimension finie, $V = \mathbb{R}^n$,
- après "discrétisation" tout se ramène à la dimension finie,
- c'est beaucoup plus simple en dimension finie.

Néanmoins, la dimension infinie est essentielle:

- souvent la variable d'optimisation est une fonction (comme en contrôle optimal), donc il faut travailler en dimension infinie,
- même en dimension finie, si la dimension est grande, le point de vue et les méthodes de la dimension infinie sont très utiles,
- les espaces de Hilbert sont les plus simples en dim. infinie.



Quelques exemples en optimisation

- ① Transport optimal
- ② Problème d'affectation
- ③ Consommation des ménages
- ④ Apprentissage machine
- ⑤ Calcul des variations

Optimisation de la livraison à N clients à partir de M entrepôts.

- stock s_i pour l'entrepôt $1 \leq i \leq M$
- commande r_j du client $1 \leq j \leq N$
- coût c_{ij} de transport unitaire entre l'entrepôt i et le client j
- quantité v_{ij} de marchandise allant de i vers le client j

On minimise le coût du transport

$$\min_{(v_{ij}) \in \mathbb{R}^{N \times M}} \left(\sum_{i=1}^M \sum_{j=1}^N c_{ij} v_{ij} \right)$$


sous les contraintes de limites des stocks et de satisfaction des commandes des clients

$$v_{ij} \geq 0, \quad \sum_{j=1}^N v_{ij} \leq s_i, \quad \sum_{i=1}^M v_{ij} = r_j \quad \text{pour } 1 \leq i \leq M, \quad 1 \leq j \leq N.$$

Il s'agit d'un exemple de programmation linéaire.



Transport optimal



Entrepôts E_i

Clients C_j

Problème d'affectation

Soit N candidats, $1 \leq i \leq N$, et N postes, $1 \leq j \leq N$. Soit $a_{ij} = 1$ si le candidat i et le poste j sont en adéquation, sinon $a_{ij} = 0$. On optimise le nombre d'affectations "satisfaisantes". Si \mathcal{S}_N est l'ensemble des permutations de $\{1, \dots, N\}$, on maximise

$$\max_{\sigma \in \mathcal{S}_N} \sum_{i=1}^N a_{i\sigma(i)}.$$

Si on introduit les variables de décision v_{ij} , on obtient

$$\max_{(v_{ij}) \in \mathbb{R}^{N \times N}} \left(\sum_{i=1}^N \sum_{j=1}^N a_{ij} v_{ij} \right)$$


sous les contraintes

$$v_{ij} = 0 \text{ ou } 1, \quad \sum_{j=1}^N v_{ij} \leq 1, \quad \sum_{i=1}^M v_{ij} \leq 1 \quad \text{pour } 1 \leq i, j \leq N.$$

Il s'agit d'un exemple d'optimisation combinatoire ou en variables entières.



Problème d'affectation



Consommation des ménages

- Soit n marchandises dont les prix forment un vecteur $p \in \mathbb{R}_+^n$.
- Soit $x \in \mathbb{R}_+^n$ le vecteur des quantités achetées par un ménage.
- Soit $u(x)$ fonction croissante et concave de \mathbb{R}_+^n dans \mathbb{R} qui mesure la "satisfaction" que le ménage tire de sa consommation.
- Soit $b > 0$ le budget dont dispose le ménage.

La consommation du ménage est le vecteur x qui maximise

$$\max_{x \in \mathbb{R}_+^n, x \cdot p \leq b} u(x)$$

$u(x)$ est appelée fonction d'utilité.



Apprentissage machine (ou SVM)

- Soit des données $(x_i)_{1 \leq i \leq n}$ avec $x_i \in \mathbb{R}^d$ qui sont classées par un label $y_i = -1$ ou $+1$.
- Soit la fonction de prédiction, $h_{w,b}(x) = w \cdot x - b$, où $w \in \mathbb{R}^d$ et $b \in \mathbb{R}$ sont des paramètres à optimiser pour que

$$\text{sgn}(h_{w,b}(x_i)) \approx y_i$$

- Soit la fonction de perte qui approche le "bon signe"

$$P(h, y) = \log(1 + \exp(-hy)) \quad (h, y) \in \mathbb{R} \times \{-1, +1\}$$


Pour "apprendre", on minimise

$$\min_{w \in \mathbb{R}^d, b \in \mathbb{R}} \frac{1}{n} \sum_{i=1}^n P(h_{w,b}(x_i), y_i).$$

On peut "régulariser" le vecteur w et, pour $\ell > 0$, on minimise

$$\min_{w \in \mathbb{R}^d, b \in \mathbb{R}} \frac{1}{n} \sum_{i=1}^n P(h_{w,b}(x_i), y_i) + \frac{\ell}{2} \|w\|_2^2.$$

SVM (séparateur à vaste marge)



- Soit une poutre horizontale $(0, L)$.
- Soit une force verticale $f(x)$ qui agit sur la poutre.
- Soit $u(x)$ le déplacement vertical.
- Soit $\mu > 0$ le coefficient de rigidité de la poutre.

La position d'équilibre de la poutre est obtenue par minimisation de l'énergie (somme des énergies de déformation et potentielle)



$$\min_{u \in C^1(0,L)} \frac{1}{2} \int_0^L \mu |u'(x)|^2 dx - \int_0^L f(x) u(x) dx,$$

Si la poutre est encastree à une ou deux extrémités on rajoute les contraintes $u(0) = 0$ et/ou $u(L) = 0$.

Beaucoup de problèmes de physique ou de mécanique sont issus de minimisation d'énergie.



Poutre horizontale



- ① Existence (et parfois unicité) de solutions de problèmes d'optimisation:
facile en dimension finie, délicat en dimension infinie (mais pas le but de ce cours).
- ② Caractérisation des solutions: conditions d'optimalité:
très important en pratique !
- ③ Algorithmes numériques d'optimisation:
tous basés sur des dérivées (dans ce cours).

Optimisation dans la "vraie vie"

- 1 Pour des raisons pédagogiques, ce cours se limite à des problèmes d'optimisation **simples**.
- 2 Dans les applications en ingénierie, les problèmes d'optimisation peuvent être plus **complexes**:
 - 1 **modélisation** de la fonction objectif et des contraintes,
 - 2 modèles **stochastiques** ou avec incertitudes,
 - 3 modèles avec **équations aux dérivées partielles**.
- 3 Pour aller plus loin en 3ème année:
 - 1 MAP 557 (recherche opérationnelle),
 - 2 MAP 562 (conception optimale de structures),
 - 3 MAP 545 (optimisation et apprentissage profond).

Qu'est ce que le contrôle ?

Pour une fonction $f : [0, T] \times \mathbb{R}^d \times \mathbb{R}^k \rightarrow \mathbb{R}^d$ on considère un système dynamique dont l'inconnue est $x : [0, T] \rightarrow \mathbb{R}^d$

$$\begin{cases} \dot{x}(t) = f(t, x(t), u(t)), & \forall t \in [0, T], \\ x(0) = x_0 \in \mathbb{R}^d, \end{cases}$$

où $u : [0, T] \rightarrow \mathbb{R}^k$ est un "contrôle" à notre disposition.

Peut-on choisir le contrôle $u(t)$ pour atteindre une cible ?

$$x(T) \in C$$

Ou bien suivre au mieux une trajectoire ?

$$x(t) \approx x_{traj}(t) \quad \forall t \in [0, T]$$

Est-ce possible même si $k < d$?



Quelques exemples en contrôle

- 1 Contrôlabilité d'un tram
- 2 Aspirateur robot
- 3 Contrôle optimal
- 4 Traversée d'un canal

Contrôlabilité d'un tram

Soit $X(t) : [0, T] \rightarrow \mathbb{R}$ la position d'un tram sur une ligne.
Le tram est contrôlé par son accélération $u(t) : [0, T] \rightarrow \mathbb{R}$

$$m\ddot{X}(t) = u(t), \quad \forall t \in [0, T].$$

On introduit la vitesse $V(t) := \dot{X}(t)$ pour réécrire

$$\dot{x}(t) = \underbrace{\begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix}}_{=:A} x(t) + \underbrace{\begin{pmatrix} 0 \\ 1/m \end{pmatrix}}_{=:B} u(t), \quad \text{avec } x(t) := \begin{pmatrix} X(t) \\ V(t) \end{pmatrix}.$$

Il y a $d = 2$ degrés de liberté et $k = 1$ variable de contrôle. Pour $T > 0$ et $x(0) = 0$, existe-t-il un contrôle u qui permette d'atteindre la prochaine gare (et de s'arrêter !) $x(T) = (X_c, 0)$?
(On peut aussi vouloir limiter l'accélération $u(t) \in [u_{\min}, u_{\max}]$.)



Aspirateur robot

Le robot est décrit par $(X, Y, \theta) : [0, T] \rightarrow \mathbb{R}^3$ ($d = 3$) où (X, Y) est la position dans le plan et θ l'angle des roues par rapport à l'axe des X .

Le contrôle est dans le volant qui oriente les roues: $u : [0, T] \rightarrow \mathbb{R}$ ($k = 1$). Pour une vitesse v constante, la dynamique est:

$$\begin{cases} \dot{X}(t) = v \cos(\theta(t)), \\ \dot{Y}(t) = v \sin(\theta(t)), \\ \dot{\theta}(t) = u(t), \end{cases} \quad \leftarrow \text{action sur le système}$$

On peut envisager plusieurs problèmes:

- 1 atteindre une cible prescrite,
- 2 le faire en temps minimum,
- 3 le faire en action (du contrôle) minimum,
- 4 suivre une trajectoire.

Il s'agit d'un exemple de contrôle d'un système non-linéaire.



On mélange contrôle et optimisation !

Exemple du système **linéaire-quadratique**. EDO **linéaire**:

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) + f(t) & \forall t \in [0, T], \\ x(0) = x_0, \end{cases}$$

avec $x(t) \in \mathbb{R}^d$, $u(t) \in \mathbb{R}^k$, A et B matrices $d \times d$ et $d \times k$.

Soit une cible z_T et une trajectoire $z(t)$ que l'on veut approcher de manière optimale. Le problème est donc de résoudre


$$\min_{u(t) \in \mathbb{R}^k, t \in [0, T]} J(u),$$

avec un critère **quadratique**, défini pour 3 matrices $R, Q, D \geq 0$

$$J(u) = \int_0^T Ru \cdot u dt + \int_0^T Q(x-z) \cdot (x-z) dt + D(x(T) - z_T) \cdot (x(T) - z_T)$$



Traversée d'un canal



Une barque doit traverser un canal horizontal de largeur l .

La barque a une vitesse (relative) constante v , et le courant a une vitesse $c(Y) > v$.

Le contrôle est l'angle $u \in [0, 2\pi]$ de la vitesse de la barque.

L'état de la barque est décrit par le couple $x := (X, Y) \in \mathbb{R}^2$:

$$\dot{x}(t) = f(x(t), u(t)) = \begin{pmatrix} v \cos(u(t)) + c(Y(t)) \\ v \sin(u(t)) \end{pmatrix}, \quad \forall t \in [0, T],$$

avec $x(0) = (0, 0)$.

Traversée d'un canal (suite)

On veut atteindre la berge opposée (contrainte de cible $Y(T) = \ell$) et aussi:

- 1 soit minimiser le déport latéral

$$J_1(u) = X(T),$$

ce qui donne le problème de minimisation sous contraintes

$$\min_{u(t) \in [0, 2\pi], t \in [0, T], Y(T) = \ell} J_1(u).$$

- 2 soit minimiser le temps de traversée

$$J_2(u) = \int_0^T dt = T,$$

ce qui donne le problème de minimisation sous contraintes

$$\min_{u(t) \in [0, 2\pi], t \in [0, T], Y(T) = \ell} J_2(u).$$

Dans ces deux problèmes, le temps T n'est pas fixé et est une inconnue supplémentaire.

But du cours en contrôle

- ① Contrôlabilité et existence de contrôles:
critère de Kalman dans le cas linéaire, contrôlabilité locale dans le cas non-linéaire.
- ② Caractérisation des contrôles optimaux:
conditions d'optimalité, notion d'état adjoint.
- ③ Principe du minimum de Pontryaguine:
méthode pratique pour trouver un contrôle optimal.

Pour aller plus loin en 3ème année: MAP 561 (Automatique).

II - 1 - Optimisation: définitions et notations

Soit V un espace de Hilbert réel. Soit $K \subset V$ un sous-ensemble non-vide. Soit $J : V \rightarrow \mathbb{R}$. Un problème d'optimisation s'écrit:

$$\inf_{v \in K} J(v) \quad \text{ou bien} \quad \min_{v \in K} J(v)$$

Notation. On utilise **inf** lorsqu'on ne sait pas a priori si la valeur minimum est atteinte et **min** dans le cas contraire.

S'il existe $v^* \in K$ tel que $J(v^*) \leq J(v)$ pour tout $v \in K$, alors

$$J(v^*) = \min_{v \in K} J(v).$$

Définition. L'infimum est le plus grand des minorants de J sur K :

$$\inf_{v \in K} J(v) = \max \{ C \in \mathbb{R} \cup \{-\infty\} \text{ tel que } C \leq J(v) \text{ pour tout } v \in K \}.$$



Définition. Une **suite minimisante** du critère (ou objectif) J sur l'ensemble K est une suite $(u^n)_{n \in \mathbb{N}}$ telle que

$$u^n \in K \quad \forall n \quad \text{et} \quad \lim_{n \rightarrow +\infty} J(u^n) = \inf_{v \in K} J(v).$$

Par définition de l'infimum de J sur K **il existe toujours des suites minimisantes !**

Définition. On dit que u est un **minimum global** de J sur K si

$$u \in K \quad \text{et} \quad J(v) \geq J(u) \quad \forall v \in K .$$

On dit que u est un **minimum local** de J sur K si

$$u \in K \quad \text{et} \quad \exists \delta > 0 , \forall v \in K , \|v - u\| < \delta \implies J(v) \geq J(u) .$$

Remarque. **Il y a une différence entre la théorie et la pratique numérique !** En théorie on considère un minimum global, alors qu'en pratique on calcule un minimum local.

Cas facile: optimisation en dimension finie $V = \mathbb{R}^N$.

Théorème. Soit K un ensemble fermé non vide de \mathbb{R}^N , et J une fonction continue sur K à valeurs dans \mathbb{R} vérifiant la propriété, dite “infinie à l’infini”,

$$\forall (u^n)_{n \geq 0} \text{ suite dans } K, \lim_{n \rightarrow +\infty} \|u^n\| = +\infty \implies \lim_{n \rightarrow +\infty} J(u^n) = +\infty .$$

Alors il existe au moins un point de minimum de J sur K . De plus, on peut extraire de toute suite minimisante de J sur K une sous-suite convergeant vers un point de minimum sur K .

(Idée: les fermés bornés sont compacts en dimension finie.)

Remarque. La propriété “infinie à l’infini” est évidente pour des ensembles bornés K .



Démonstration du théorème

Preuve. Soit $(u^n)_{n \in \mathbb{N}}$ une suite minimisante. Comme K est non vide, $J(u^n) \leq C < +\infty$ pour tout n .

A cause de la propriété “infinie à l’infini”, la suite est bornée

$$\|u^n\| \leq C < +\infty \quad \text{pour tout } n \in \mathbb{N}.$$

Il existe donc une sous-suite $(u^{n_k})_{k \in \mathbb{N}}$ qui converge vers une limite u . Comme K est fermé, u appartient à K . Comme J est continue, $J(u^{n_k})$ converge vers $J(u)$ qui est donc le minimum.

Autrement dit, si on note B_C la boule fermée de rayon C , on a

$$\inf_{v \in K} J(v) = \inf_{v \in K \cap B_C} J(v)$$

et la fonction continue J atteint son minimum sur le fermé borné $K \cap B_C \subset \mathbb{R}^N$.



Nettement plus délicat ! En général le théorème précédent est faux...

Problème: une fonction continue sur un fermé borné n'atteint pas toujours son minimum !

Il existe donc des problèmes d'optimisation "raisonnables" en dimension infinie qui n'admettent pas de solution.

Donnons deux contre-exemples (un théorique et un plus concret).

Mécanisme de non-existence: oscillation ou fuite à l'infini de la suite minimisante.

Premier contre-exemple

Soit l'espace de Hilbert des suites de carré sommable dans \mathbb{R}

$$\ell_2(\mathbb{R}) = \left\{ x = (x_i)_{i \geq 1} \text{ tel que } \sum_{i=1}^{+\infty} x_i^2 < +\infty \right\},$$

muni du produit scalaire $\langle x, y \rangle = \sum_{i=1}^{+\infty} x_i y_i$. Soit le problème

$$\inf_{x \in \ell_2(\mathbb{R})} J(x) = (\|x\|^2 - 1)^2 + \sum_{i=1}^{+\infty} \frac{x_i^2}{i}.$$

Lemme. Il n'existe pas de point de minimum $x^* \in \ell_2(\mathbb{R})$ tel que $J(x^*) \leq J(x)$ pour tout $x \in \ell_2(\mathbb{R})$.

Preuve. On va montrer que

$$\inf_{x \in \ell_2(\mathbb{R})} J(x) = 0.$$

Comme $J(x) > 0$ pour tout $x \in \ell_2(\mathbb{R})$, cela prouve le Lemme.



Premier contre-exemple (fin)

$$J(x) = (\|x\|^2 - 1)^2 + \sum_{i=1}^{+\infty} \frac{x_i^2}{i}.$$

On construit une suite minimisante x^n définie par $x_i^n = \delta_{in}$ pour tout $i \geq 1$

$$x^n = \underbrace{(0, \dots, 0, 1, 0, 0, \dots)}_n$$

On a $\|x^n\| = 1$,

$$J(x^n) = \frac{1}{n} \longrightarrow 0 \quad \text{quand } n \rightarrow +\infty,$$

et comme $J(x) \geq 0$ pour tout $x \in \ell_2(\mathbb{R})$, on en déduit

$$\inf_{x \in \ell_2(\mathbb{R})} J(x) = 0.$$

Remarque: on voit que la suite minimisante x^n "part à l'infini" et ne converge pas (bien qu'elle soit bornée).



Second contre-exemple

Problème modèle en science des matériaux pour expliquer le changement de phase solide/solide et les alliages à mémoire de forme.

Soit l'espace V des fonctions continues sur $[0, 1]$ et dérivables par morceaux. On considère le problème

$$\inf_{v \in V} J(v) = \int_0^1 \left((|v'(x)| - 1)^2 + v(x)^2 \right) dx .$$

Lemme. Il n'existe pas de solution à ce problème de minimisation.

Remarque: difficulté indépendante du choix de l'espace. On peut aussi prendre l'espace de Hilbert $V = H^1(0, 1)$.




Second contre-exemple (fin)

Preuve. Il n'existe aucun $v \in V$ tel que $J(v) = 0$, et pourtant

$$\inf_{v \in H^1(0,1)} J(v) = 0,$$

car si on définit la suite u^n telle que $(u^n)' = \pm 1$



on a $J(u^n) = \int_0^1 u^n(x)^2 dx = \frac{1}{4n} \rightarrow 0$.

Remarque. On voit que la suite minimisante u^n oscille de plus en plus (elle converge mais pas sa dérivée).

Remarque. Dans la pratique numérique, la non-existence de solutions se manifeste par la variation de la solution numérique selon les paramètres de calcul !

- Pour calculer une solution numérique, on approche l'espace V de dimension infinie par un espace V_N de dimension finie N (discrétisation).
- On appelle u_N la solution approchée dans V_N .
- Si on augmente N , la suite u_N ne converge pas !

Définition de la convexité

Pour obtenir des résultats d'existence en dimension infinie on rajoute une hypothèse de convexité.

Définition. Un ensemble $K \subset V$ est dit **convexe** si, pour tout $x, y \in K$ et tout réel $\theta \in [0, 1]$, l'élément $(\theta x + (1 - \theta)y)$ appartient à K .

Définition. On dit qu'une fonction J définie sur un ensemble convexe non vide $K \subset V$ et à valeurs dans \mathbb{R} est **convexe** sur K si et seulement si


$$J(\theta u + (1 - \theta)v) \leq \theta J(u) + (1 - \theta)J(v) \quad \forall u, v \in K, \forall \theta \in [0, 1].$$

De plus, J est dite **strictement convexe** si l'inégalité est stricte lorsque $u \neq v$ et $\theta \in]0, 1[$.


Interprétation de la convexité: la fonction J est sous sa corde.



Ensemble convexe K

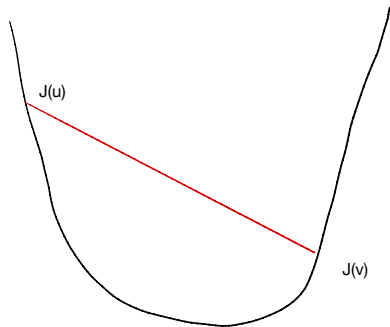


Convexe




Non-convexe

Fonction convexe J



Convexe



Non-convexe

Continuité des fonctions convexes

Lemme. Une fonction convexe J de V dans \mathbb{R} , localement majorée, est continue.

Preuve. Sans perte de généralité, on prouve la continuité en 0 et on suppose $J(0) = 0$. Soit $v \neq 0$, $\theta = \|v\| \leq 1$ et M la borne de J sur la boule unité. Par convexité

$$J(v) = J\left(\theta \frac{v}{\|v\|} + (1 - \theta)0\right) \leq \theta J\left(\frac{v}{\|v\|}\right) + (1 - \theta)J(0) \leq M\|v\|.$$

Par ailleurs, toujours par convexité

$$0 = J(0) \leq \frac{1}{1 + \|v\|} J(v) + \frac{\|v\|}{1 + \|v\|} J\left(\frac{-v}{\|v\|}\right) \leq \frac{1}{1 + \|v\|} (J(v) + M\|v\|),$$

d'où l'on déduit la continuité

$$|J(v)| \leq M\|v\|.$$



Proposition. Si J est une fonction convexe sur un convexe K , alors tout minimum local est un minimum global.

Preuve. Soit u un minimum local de J sur K

$$\exists \delta > 0, \forall w \in K, \|w - u\| < \delta \implies J(w) \geq J(u).$$

Soit $v \in K$. Pour $0 < \theta \ll 1$, $w_\theta = \theta v + (1 - \theta)u \in K$ vérifie $\|w_\theta - u\| < \delta$. Donc

$$J(u) \leq J(w_\theta) \leq \theta J(v) + (1 - \theta)J(u),$$

et ainsi $J(u) \leq J(v)$, i.e. u est un minimum global sur K .



Proposition. Si J est strictement convexe sur un convexe K , alors il existe **au plus un** point de minimum dans K .

Preuve. Si u_1 et u_2 sont deux minima et si $\theta \in]0, 1[$, alors $w = \theta u_1 + (1 - \theta)u_2$ est un minimum puisque $w \in K$ et que

$$\inf_{v \in K} J(v) \leq J(w) \leq \theta J(u_1) + (1 - \theta)J(u_2) = \inf_{v \in K} J(v).$$

Si J est strictement convexe, alors nécessairement $u_1 = u_2$.



Exemple. La fonction $J(x) = \frac{1}{2}Ax \cdot x - b \cdot x$, définie sur \mathbb{R}^n , est convexe si la matrice A est positive. Elle est strictement convexe si A est définie positive.

Exercice.

- (i) La somme de deux fonctions convexes est convexe.
- (ii) Le maximum de deux fonctions convexe est convexe.

Définition. Une fonction $J(v)$ est concave si $-J(v)$ est convexe.

Définition. On dit qu'une fonction J définie sur un ensemble convexe K est **fortement convexe** si et seulement si il existe $\alpha > 0$ tel que, pour tout $u, v \in K$ et pour tout $0 \leq \theta \leq 1$,

$$J(\theta u + (1 - \theta)v) \leq \theta J(u) + (1 - \theta)J(v) - \frac{\alpha}{2}\theta(1 - \theta)\|u - v\|^2$$

On dit aussi dans ce cas que J est **α -convexe**.

Exercice. Vérifier que $J(u)$ est fortement convexe, si et seulement si $J(u) - \frac{\alpha}{2}\|u\|^2$ est convexe.



Proposition. Si J est convexe continue sur un convexe fermé non vide $K \subset V$, alors il existe une forme linéaire continue $L \in V'$ et une constante $\delta \in \mathbb{R}$ telles que

$$J(v) \geq L(v) + \delta \quad \forall v \in K .$$

Si de plus J est fortement convexe sur K , alors il existe deux constantes $\gamma > 0$ et $\eta \in \mathbb{R}$ telles que

$$J(v) \geq \gamma \|v\|^2 + \eta \quad \forall v \in K .$$

Remarque. Ce résultat nous sera utile pour majorer les suites minimisantes (voir la prochaine leçon).



Minoration des fonctions convexes (suite)

Preuve. On définit l'épigraphe de J comme l'ensemble

$$\text{Epi}(J) = \{(\lambda, v) \in \mathbb{R} \times K, \lambda \geq J(v)\}.$$

Si J est convexe, alors $\text{Epi}(J)$ est un convexe dans $\mathbb{R} \times V$. Soit $v_0 \in K$ et $\lambda_0 < J(v_0)$. Puisque $(\lambda_0, v_0) \notin \text{Epi}(J)$, on déduit du théorème de séparation d'un point et d'un convexe l'existence de $\alpha, \beta \in \mathbb{R}$ et d'une forme linéaire continue $L \in V'$ tels que

$$\beta\lambda + L(v) > \alpha > \beta\lambda_0 + L(v_0) \quad \forall (\lambda, v) \in \text{Epi}(J).$$


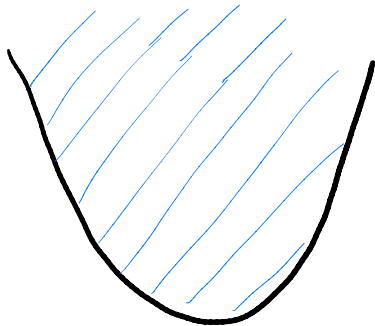
Nécessairement $\beta \geq 0$ quand $\lambda \rightarrow +\infty$. De plus, $\beta \neq 0$ quand $v = v_0$. On choisit alors $\lambda = J(v)$, ce qui donne

$$J(v) + L(v)/\beta > \alpha/\beta \quad \forall v \in K.$$

Donc J est minorée par un hyperplan affine.



Epigraphe d'une fonction



Epigraphe d'une fonction J

Finalement, si J est α -convexe, pour $\theta = 1/2$ on a

$$\frac{J(v)}{2} + \frac{J(v_0)}{2} \geq J\left(\frac{v+v_0}{2}\right) + \frac{\alpha}{8}\|v-v_0\|^2 \geq \frac{L(v) + L(v_0)}{2} + \frac{\alpha}{8}\|v-v_0\|^2 + \delta.$$

Comme L est linéaire continue, $|L(v)| \leq \|L\|_{V'}\|v\|$, on a

$$J(v) \geq \frac{\alpha}{4}\|v\|^2 - \left(\|L\|_{V'} + \frac{\alpha\|v_0\|}{2}\right)\|v\| + C_1 \geq \frac{\alpha}{8}\|v\|^2 + \eta,$$

par Cauchy-Schwarz, pour $\eta \in \mathbb{R}$ bien choisi.



Lors de la prochaine leçon:

- ① on montrera l'existence de point de minimum pour les fonctions fortement convexes en dimension infinie,
- ② on commencera l'étude des conditions d'optimalité.