

219:

Extrêmes : existence, caractérisation
recherche. Exemple d'application.

Ref: [Con2] Gordon, Analyse
[HL] Hirsch (Lacoste, Eléments d'Analyse Fonctionnelle. [Tou] Touloul, Analyse Convexe.

[All] Allaire, Analyse convexe et optimisation.
[Con2] Con2, Analyse convexe et optimisation.

Def:

11, 12
13, 14, 15
22, 33
40

John Loewner

Ref: Riesz

Ex: Hirsch (Lacoste)

Gradient optimal

[FGN3]

[HL]

[Ave3]

[Con2]

[All] 294

292

290

290

290

290

290

290

290

290

290

290

290

Cache: On se donne $J: E \rightarrow \mathbb{R}$ avec E un espace vectoriel normé. On cherche les extrema locaux ou globaux de J , quitte à remplacer J par $-J$, on peut se concentrer de regarder les minima.

1. Existence d'unicité du minimum.

1) Compacité. Fonction.

Prop 1: Si K est compact dans E , et J est continue, alors J est bornée sur K et atteint ses bornes.

Appl 2: Si K, K' sont deux compacts de E , il existe $x, x' \in K \times K'$ tel que $d(x, x') = d(K, K')$

Théor 3: Si E est de dimension finie, $K \subseteq E$ un fermé non vide $J: K \rightarrow \mathbb{R}$ continue et coercive, (à dire $\lim_{\|x\| \rightarrow \infty} J(x) = +\infty$).

Alors J admet un minimum sur K . De plus, on peut extraire de toute suite minimisante de J sur K une sous-suite convergente vers le minimum.

Appl 4: Soit $[a, b]$ un segment réel. Pour $f: [a, b] \rightarrow \mathbb{R}$ continue et $f \in C^1$, il existe $P \in \mathbb{R}_m[X]$ tel que $\|f - P\|_\infty$ soit minimal.

Ex 3: Sur l'espace de Hilbert $\ell^2(\mathbb{N})$, la fonctionnelle $J(x) = (\|x\|^2 - 1) + \sum_{i=1}^{\infty} x_i^2$ n'admet pas de minimum même si J est coercive.

Appl 6 (B. de la Vallée Poussin) Pour $P \in \mathbb{C}[X]$ non constant, il existe dans $\mathbb{C}$ au moins une racine de P .

2) Convexité.

Pour prouver des résultats comparables à la dimension finie. On doit rajouter des hypothèses de convexité.

Def 7: Pour $K \subseteq E$ un convexe non vide, on dit que $J: K \rightarrow \mathbb{R}$ est convexe si: $\forall x, y \in K, \forall \theta \in [0, 1], J(\theta x + (1-\theta)y) \leq \theta J(x) + (1-\theta)J(y)$. On dit que J est strictement convexe si l'inégalité précédente est stricte pour $x \neq y$ et $\theta \in]0, 1[$. En fin, on dit que J est α -convexe pour $\alpha > 0$ si:

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

pour les conditions précédentes.

Prop 8: Si J est une fonction convexe sur K un ensemble convexe, tout minimum local de J est en fait un minimum global et l'ensemble de points minimums de K forme un ensemble convexe (éventuellement vide). Si de plus J est strictement convexe, il existe au plus un minimum.

Appl 1: Pour $x_1, \dots, x_n \in \mathbb{R}_+$ on a $(\prod_{i=1}^n x_i)^{1/n} \leq \frac{1}{n} \sum_{i=1}^n x_i$ (Inégalité arithmético-géométrique).

Appl 10 (Hölder) Pour $p, q > 1, \frac{1}{p} + \frac{1}{q} = 1, f \in L^p, g \in L^q$, alors $fg \in L^1$ et on a $\|fg\|_1 \leq \|f\|_p \|g\|_q$.

lemme (Connexion logarithmique du déterminant). Pour $A, B \in M_n(\mathbb{R})$, $\alpha, \beta \in \mathbb{R}_+, \alpha + \beta = 1$. Alors $\det(\alpha A + \beta B) \geq \alpha^\alpha \det A + \beta^\beta \det B$ et l'inégalité est stricte si: $0 < \alpha < 1$ et $A \neq B$.

Théor 2: (John Loewner) Soit $K \neq \emptyset$ un compact de $\mathbb{R}^n$ d'intérieur non vide. Alors il existe un unique ellipsoïde centré en 0 de volume minimal qui contient K .

3) Les espaces hilbertiens.

On suppose ici que $E = (E, \langle \cdot, \cdot \rangle)$ est un espace de Hilbert, on va retrouver certains résultats analogues à la dimension finie.

Théor 3: Soit $\emptyset \neq C \subseteq E$ une partie convexe fermée. Alors $\forall x \in E, \exists! y \in C$ d(x, y) = d(x, C).

On l'appelle projection (orthogonale) de x sur C , il est caractérisé par la propriété $\forall y \in C, \operatorname{Re}(y - z, y - x) \leq 0$.

Cor 14: Si $F \subseteq E$ est un sous-espace vectoriel fermé, alors $E = F \oplus F^\perp$.

Appl 15 (Théorème de Riesz) à application de E dans E définie par $y \mapsto (\cdot, y)$ est une isométrie surjective.

Théor 16 (ax. Milgram) Si E est un $\mathbb{R}$ -espace de Hilbert $a: E \times E \rightarrow \mathbb{R}$ une forme bilinéaire continue et coercive: $a(x, x) \geq \alpha \|x\|^2$ pour un $\alpha > 0$. Alors pour tout $v \in E$, il existe $u \in E$ tel que $a(u, v) = L(v)$ où L est une forme linéaire continue.

De plus si a est symétrique, ce u est caractérisé comme minimum de la fonctionnelle $\frac{1}{2} a(x, x) - L(x)$ (fonctionnelle quadratique).

[All]

[Con2]

[FGN3]

229

[HL]

91

101

[Apt]

Appli 17: On considère l'équation $-\Delta u = f$ sur Ω , $u = 0$ sur $\partial\Omega$, la résolution de ce problème dans $H_0^1(\Omega)$ est équivalente à celle de la formulation variationnelle $\int \nabla u \cdot \nabla v = \int f v$ $\forall v \in H_0^1(\Omega)$.

Théor 18: Soit $C \subseteq E$, $f: C \rightarrow \mathbb{R}$ continue coercive convexe, alors J admet un minimum.

1) Les des fonctions holomorphes.

Prop 19: Soit $U \subseteq \mathbb{C}$ un ouvert et $f: U \rightarrow \mathbb{C}$ une fonction continue, on a équivalence

(i) Pour tout disque $D(a, r) \subseteq U$, on a $|f(a)| = \frac{1}{2\pi} \int_0^{2\pi} |f(a + re^{it})| dt$

(ii) Pour tout disque $D(a, r) \subseteq U$, on a $|f(a)| = \frac{1}{\pi r^2} \int_{D(a, r)} |f(x)| dx$.

On dit alors que f respecte la propriété de la moyenne sur U .

Prop 20: $f: U \rightarrow \mathbb{C}$ holomorphe respecte la propriété de la moyenne sur U .

Théor 21: Soit $U \subseteq \mathbb{C}$ un ouvert et f continue sur U . Si f vérifie la propriété de la moyenne sur U , alors f respecte le principe du maximum:

Si f admet un extremum relatif en $a \in U$, f est constante au voisinage de a .

Cor 22: Si $f: U \rightarrow \mathbb{C}$ est continue, vérifie la propriété de la moyenne sur U (U ouvert connexe borné de $\mathbb{C}$). Alors f atteint son maximum sur ∂U , et est constante si ce maximum est atteint en un point intérieur.

II. Caractérisation d'extremums locaux.

1) Différentiabilité et points critiques.

Prop 23: Si $J: U \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$ admet un extremum relatif en $a \in U$ et J est différentiable en a , alors $dJ_a = 0$ (c'est-à-dire que a vérifie l'équation d'Euler).

Théor 24: Dans le cas général, cette condition n'est pas suffisante, elle donne seulement une liste de candidats possibles: $x \mapsto x^3$ admet un point critique en 0 sans s'annuler.

Prop 25: Si $J: U \rightarrow \mathbb{R}$ est de classe C^2 et soit $a \in U$ tel que $dJ_a = 0$. En la formule de Taylor Young, on a au voisinage de a :

$$J(a+h) = J(a) + \frac{Q(h)}{2} + o(\|h\|^2)$$

où $Q = d^2 J_a$ est une forme quadratique.

- Si J admet un minimum local, alors Q est positive

- Si Q est définie positive, alors J admet un minimum local isolé en a .

Ex 25: A nouveau ces conditions laissent un cas douteux, où $x \mapsto x^3$ en 0. On donne encore un contre-exemple.

[Lan] 85 86

Ex 26: Si $n=2$. On pose $A = \begin{pmatrix} 2 & 1 \\ 1 & 1 \end{pmatrix} \in \mathcal{S}_2(\mathbb{R})$ la hessienne de J . On a par le théorème précédent

- $\lambda_1 = -3 < 0$ et $\lambda_2 > 0 \Rightarrow J$ admet un minimum relatif en a

- $\lambda_1 = -3 < 0 \Rightarrow J$ n'admet pas d'extremum en a

- $\lambda_1 = -3 < 0 \Rightarrow$ Cas douteux

Ex 27: Si $J(x, y) = x^4 + y^4 - 2(x-y)^2$. Alors J a trois points critiques $(0, 0)$, $(\sqrt{2}, -\sqrt{2})$ et $(-\sqrt{2}, \sqrt{2})$. Il y a un minimum local en $(\sqrt{2}, -\sqrt{2})$ mais en $(0, 0)$, on ne peut pas conclure (on fait il n'y en a pas).

2) Fonctions convexes.

Prop 28: Soit $J: E \rightarrow \mathbb{R}$ différentiable. On a équivalence entre

- J est convexe sur E $\iff \forall x, y \in E, J(y) \geq J(x) + \langle \nabla J(x), y-x \rangle$

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

(et les mêmes équivalences avec le cas strictement convexe).

Prop 29: Avec les notations précédentes, et $\alpha > 0$. Les assertions suivantes sont équivalentes

- J est α -convexe sur E $\iff \forall x, y \in E, J(y) \geq J(x) + \langle \nabla J(x), y-x \rangle + \frac{\alpha}{2} \|x-y\|^2$

- $\langle \nabla J(x), \nabla J(y), x-y \rangle \geq \alpha \|x-y\|^2 \forall x, y \in E$.

Théor 30: (Inégalité d'Euler, cas convexe) Soit $u \in K$ convexe. On suppose J différentiable en u . Si u est un minimum local de J sur K , alors

$$\langle \nabla J(u), x-u \rangle \geq 0 \quad \forall x \in K$$

On a la réciproque si J est convexe (u est alors même un minimum global)

Prop 31: Si J est convexe sur E , alors $u \in E$ est un extremum si et seulement si: $\nabla J(u) = 0$.

3) Optimisation sous contrainte.

On peut chercher à minimiser J sur un ensemble $K \subseteq E$, on considère deux cas principaux:

$K = \{x \in E \mid f(x) = 0\}$ pour une $f \neq 0$ (contrainte d'égalité)

$K = \{x \in E \mid f(x) \leq 0\}$ pour une $f \neq 0$ (contrainte d'inégalité).

Théor 32: (Extrema liés) Soient $f, g_1, \dots, g_r: U \rightarrow \mathbb{R}$ des fonctions C^1 . On pose

$-(g_1, \dots, g_r) = g: U \rightarrow \mathbb{R}^r$ $\nabla = \{x \in U \mid g(x) = 0\}$.

Si $a \in \nabla$ est un extremum local de $f|_{\nabla}$, alors $d f_a$ est une famille libre de $(\mathbb{R}^n)^*$ alors $\exists \lambda_1, \dots, \lambda_r \in \mathbb{R}$ tel que $d f_a = \sum \lambda_i d g_i$ on appelle les λ_i les multiplicateurs de Lagrange

Appli 33: Si $(E, \langle \cdot, \cdot \rangle)$ est euclidien, l'endomorphisme symétrique de E diagonalisable sur une base orthonormée de E .

[Lan] 317 308

[Apt] 305 309

[Gom] 715 316

[Apt] 317

[AEP]
316.
317

Pour le cas des contraintes inégalité. On doit rajouter des conditions sur les contraintes.

On pose $f = f_1 \dots f_m: E \rightarrow \mathbb{R}^m$

Def 34: Pour $x \in K$, on pose $I(x) = \{i \in \{1, \dots, m\} \mid f_i(x) = 0\}$ les contraintes actives en x

Def 35: On dit que les contraintes sont qualifiées en $x \in K$ s'il existe $\bar{w} \in E$ telle que pour tout $i \in I(x)$, on a $\langle f'_i(x), \bar{w} \rangle < 0$ ou $\langle f'_i(x), \bar{w} \rangle = 0$ et f_i est affine.

Thé 36: Si J et les f_i sont différentiables en u et les contraintes sont qualifiées en u . Alors si u est un minimum local de J sur K , il existe $\lambda_1, \dots, \lambda_m \geq 0$, les multiplicateurs de Lagrange, tels que $\nabla J(u) + \sum_{i=1}^m \lambda_i f'_i(u) = 0$, $\lambda_i \geq 0$, $\lambda_i < 0$: $f_i(u) \leq 0$

III. Optimisation numérique.

1) Méthodes de relaxation et de gradient. (dim $< \infty$)

On cherche, étant donnée J et u_0 de construire une suite convergente vers une minimum de J (on suppose qu'un tel minimum existe).

1ère méthode: Méthode de relaxation On choisit x^{n+1} à partir de x^n en minimisant

successivement J le long des directions canoniques: Si x^n est fixé, on pose pour $i \in \{1, \dots, m\}$ x_i^{n+1} tel que $J(x_1^n, \dots, x_i^{n+1}, \dots, x_m^n) = \inf_{t \in \mathbb{R}} J(x_1^n, \dots, x_i + t e_i, \dots, x_m^n)$

On pose enfin $x^{n+1} = (x_1^{n+1}, \dots, x_m^{n+1}) \in \mathbb{R}^m$.

Thé 37: Si la fonctionnelle J est elliptique (d-convexe), alors la méthode de relaxation est bien posée et converge vers la solution globale.

Rq 38: Un exemple fameux de fonctionnelle d-convexe est donnée par les fonctionnelles quadratiques: Pour $A \in M^m(\mathbb{R})$, $b \in \mathbb{R}^m$, on pose $J(x) = \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle$. On a alors $\nabla J(x) = Ax - b$. Si $A \in S_m^{++}(\mathbb{R})$, alors J est d-convexe et admet comme unique minimum la solution de $Ax = b$. La minimisation de J est alors une méthode de résolution d'un système linéaire. Avec cette lecture, la méthode de relaxation correspond à la méthode de Gauss-Seidel.

On peut chercher à être plus subtil que les retours de base canonique comme choix de direction et prendre $\nabla J(x^n)$, en effet, pour $x \in E$, on a $J(x + \nabla J(x)) \sim J(x) - \rho \|\nabla J(x)\|^2$ pour ρ assez petit.

Les méthodes de la forme $x^{n+1} = x^n - \rho \nabla J(x^n)$ sont dites méthodes de gradient. On a essentiellement deux options raisonnables quant au choix de ρ .

- Prendre ρ constant (ne dépendant pas de n). C'est le gradient à pas fixe.
- Prendre ρ^n minimisant la fonction à une variable $\rho \mapsto J(x^n - \rho \nabla J(x^n))$ c'est le gradient à pas optimal.

[Cia]
184
189

Thé 39: Si J est une fonctionnelle d-convexe différentiable, et ∇J est lipschitzien sur E . Alors pour $\rho \in]0, 2/L[$, l'algorithme du gradient à pas fixe converge quel que soit le point de départ, vers le minimum de J .

Thé 40: Si J est d-convexe différentiable et ∇J est lipschitzien sur tout borné de E . Alors l'algorithme de gradient à pas optimal converge. DVP

Rq 41: La condition du théorème 39 n'est pas optimale, dans le cas d'une fonctionnelle quadratique, on peut aller jusqu'à $\rho = 2/\lambda_m$ ou $\lambda_m = \rho(A)$: (le pas fixe optimal est alors donné par $2/(\lambda_1 + \lambda_m)$).

Rq 42: A priori, le calcul du pas optimal dans l'algorithme annoncé peut beaucoup rallonger les calculs. Dans le cas des fonctionnelles quadratiques à noyau constant. Le pas optimal est explicite, et donné par $\frac{\|\nabla J(x^n)\|^2}{\langle Ax^n, x^n \rangle}$.

2) Méthode de Newton.

Si E est de dimension finie. $F: \mathbb{R}^n \rightarrow \mathbb{R}^m$ de classe C^2 , γ : γ est un zéro de F tel que $J(\gamma)$ est minimum. La méthode de Newton consiste à résoudre $F(x) = 0$ en posant $x^{n+1} = x^n - (DF(x^n))^{-1} F(x^n)$ pour $n \geq 0$.

Pour un problème d'optimisation, on va chercher à résoudre $\nabla J(x) = 0$ par la méthode de Newton (si J est assez régulière).

Rq 43: Notons que cette méthode n'a aucun intérêt pour une fonctionnelle quadratique les itérations consistent déjà à résoudre des systèmes linéaires.

Thé 44: Si $F: \mathbb{R}^n \rightarrow \mathbb{R}^m$ est de classe C^2 , γ un zéro régulier de F . Il existe un $\varepsilon > 0$ tel que si x^0 est assez proche de la solution γ (à ε près). La méthode de Newton définie ci-dessus converge vers γ , et il existe $C > 0$ telle que $\|x^{n+1} - \gamma\| \leq C \|x^n - \gamma\|^2$

(la convergence est excellente).

Rq 45: En pratique, on se rapproche de la solution par un algorithme grossier, avant de lancer la méthode de Newton.

Rq 46: En dimension 1, on retrouve la méthode de Newton "classique".

[AEP]
339
340

[Cia]

[AEP]
347
348