

CONCEPTION OPTIMALE DE STRUCTURES

G. ALLAIRE

13 Janvier 2010

CHAPITRE III

RAPPELS D'OPTIMISATION

DEFINITIONS

Soit V un espace de Banach, i.e., un espace vectoriel muni d'une norme qui est complet (toute suite de Cauchy est convergente dans V).

Soit $K \subset V$ un sous-ensemble non-vide. Soit $J : V \rightarrow \mathbb{R}$. On considère

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

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

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

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

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

(différence: théorie \leftrightarrow global / numérique \leftrightarrow local)

Définition. Une **suite minimisante** du critère J sur l'ensemble K est une suite $(u^n)_{n \in \mathbf{N}}$ 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 en existe toujours !**

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**”,

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

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.)

Optimisation en dimension infinie

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

Exemple de non-existence: soit l'espace de Sobolev $H^1(0, 1)$ muni de la norme $\|v\| = \left(\int_0^1 (v'(x)^2 + v(x)^2) dx \right)^{1/2}$. Soit

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

On vérifie que l'application J est continue et "infinie à l'infini", et pourtant le problème de minimisation

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


n'admet pas de solution. (Difficulté indépendante du choix de l'espace.)

Démonstration

Il n'existe aucun $v \in H^1(0, 1)$ tel que $J(v) = 0$, et pourtant

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

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



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

On voit dans cet exemple que la suite minimisante u^n “oscille” de plus en plus et n'est pas compacte dans $H^1(0, 1)$ (bien qu'elle soit bornée).


Une parenthèse en sciences des matériaux

La non-existence de solution à des problèmes de minimisation est utile en sciences des matériaux !



Théorie de Ball-James (1987).

Matériaux à mémoire de forme = alliages avec des changements de phase.

Co-existence de plusieurs phases cristallines: austenite et martensite.

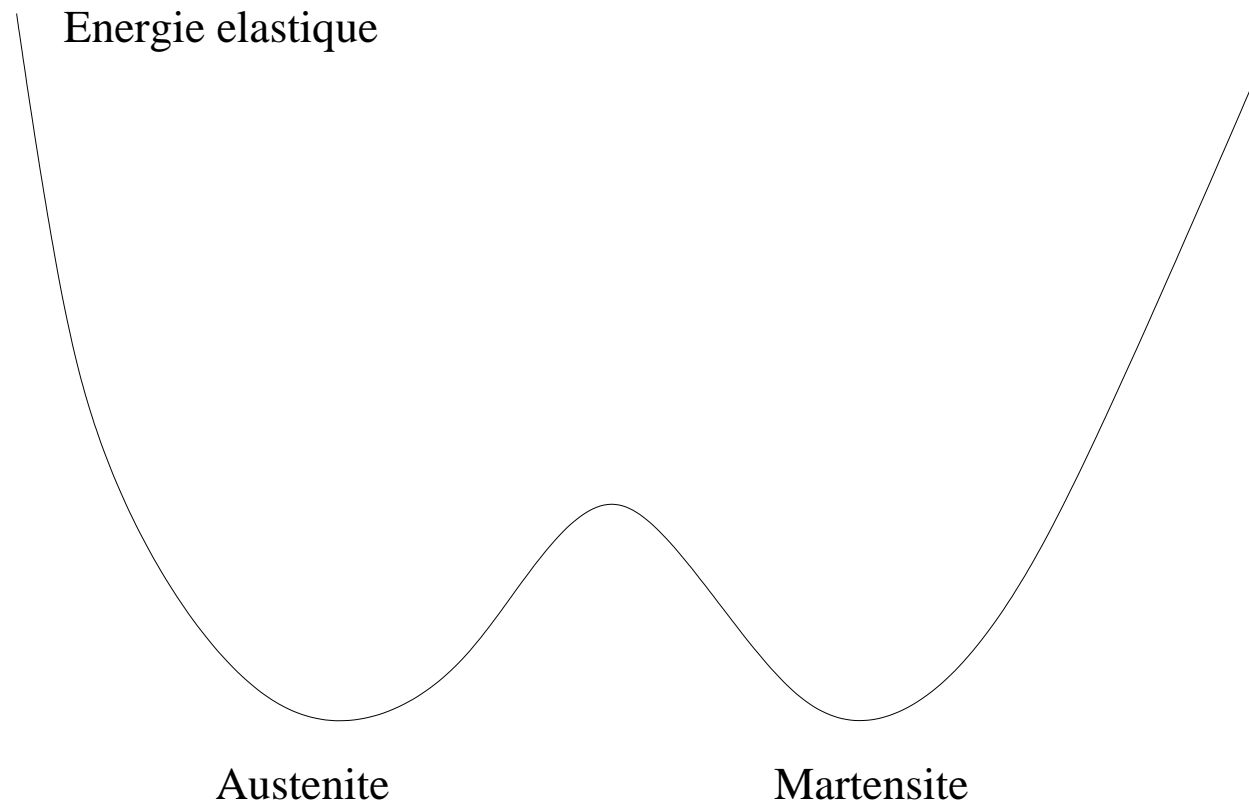


Alliage Cu-Al-Ni (clichés YONG S. CHU)





Mécanisme proposé par J. Ball et R. James: pour s'adapter aux efforts appliqués, l'alliage a intérêt à coexister sous plusieurs phases convenablement alignées et qui minimisent l'énergie \Rightarrow **suite minimisante !**



Analyse convexe

Pour obtenir des résultats d'existence 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

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

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

Résultats d'existence

Théorème. Soit K un convexe fermé non vide d'un espace de Banach réflexif V , et J une fonction **convexe** continue sur K , qui est “**infinie à l'infini**” dans K , à savoir,

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

Alors il existe un minimum de J sur K .

Remarques:

1. V Banach réflexif $\Leftrightarrow (V')' = V$ (V' est le dual de V)
2. Ce théorème reste vrai si l'on suppose simplement que V est le dual d'un espace de Banach séparable.
3. En pratique, **c'est vrai pour tous les espaces que l'on va rencontrer**: par exemple, $L^p(\Omega)$ avec $1 < p \leq +\infty$.

Unicité

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

Proposition. Si J est une fonction convexe sur un ensemble convexe K , tout point de **minimum local** de J sur K est un **minimum global**.

Remarque. Pour les fonctions convexes il n'y a donc pas de différence entre minima locaux et globaux .

Exemple. Minimisation de l'énergie

$$\min_{u \in H_0^1(\Omega)} \frac{1}{2} \int_{\Omega} |\nabla u|^2 dx - \int_{\Omega} f u dx$$

On retrouve

$$-\Delta u = f \text{ dans } \Omega, \quad u = 0 \text{ sur } \partial\Omega.$$

Remarque. Autre méthode d'existence: compacité.

Différentiabilité

Définition. Soit V un espace de Banach. On dit que la fonction J , définie sur un voisinage de $u \in V$ à valeurs dans \mathbb{R} , est **différentiable au sens de Fréchet** en u s'il existe une forme linéaire continue sur V , $L \in V'$, telle que

$$J(u + w) = J(u) + L(w) + o(w) \quad , \quad \text{avec} \quad \lim_{w \rightarrow 0} \frac{|o(w)|}{\|w\|} = 0 .$$

On appelle L la différentielle (ou la dérivée, ou le gradient) de J en u et on note $L = J'(u)$, ou $L(w) = \langle J'(u), w \rangle_{V',V}$.

- ☞ Si V est un espace de Hilbert, on peut identifier V et son dual V' grâce au Théorème de représentation de Riesz. Il existe donc un unique $p \in V$ tel que $\langle p, w \rangle = L(w)$. On note aussi $p = J'(u)$.
- ☞ On utilise l'identification $V = V'$ si $V = \mathbb{R}^n$ ou $V = L^2(\Omega)$.
- ☞ En pratique, il est plus facile de calculer la **dérivée directionnelle** $j'(0) = \langle J'(u), w \rangle_{V',V}$ avec $j(t) = J(u + tw)$.

Exemple classique à connaître absolument

Soit $J(v) = \frac{1}{2}a(v, v) - L(v)$ avec a **symétrique**. On pose $j(t) = J(u + tw)$

$$j(t) = \frac{t^2}{2}a(w, w) + t\left(a(u, w) - L(w)\right) + J(u)$$

et on dérive $t \rightarrow j(t)$

$$j'(t) = ta(w, w) + \left(a(u, w) - L(w)\right).$$

Par définition, $j'(0) = \langle J'(u), w \rangle_{V', V}$, donc

$$\langle J'(u), w \rangle_{V', V} = a(u, w) - L(w).$$

La condition $J'(u) = 0$ est une formulation variationnelle. On peut démontrer ainsi l'équivalence entre la minimisation de l'énergie $J(v)$ et la résolution de la F.V.

Exemples: (on utilise le produit scalaire "usuel" de L^2)

$$1. J(v) = \int_{\Omega} \left(\frac{1}{2}v^2 - fv \right) dx \text{ avec } v \in L^2(\Omega)$$

$$\langle J'(u), w \rangle = \int_{\Omega} (uw - fw) dx.$$

Donc

$$J'(u) = u - f \in L^2(\Omega) \text{ (identifié à son dual)}$$

$$2. J(v) = \int_{\Omega} \left(\frac{1}{2}|\nabla v|^2 - fv \right) dx \text{ avec } v \in H_0^1(\Omega)$$

$$\langle J'(u), w \rangle = \int_{\Omega} (\nabla u \cdot \nabla w - fw) dx.$$

Donc, après intégration par parties,

$$J'(u) = -\Delta u - f \in H^{-1}(\Omega) = (H_0^1(\Omega))' \text{ (non identifié à son dual)}$$

Conditions d'optimalité

Théorème (Inéquation d'Euler). Soit $u \in K$ convexe. On suppose que J est différentiable en u . Si u est un point de minimum local de J sur K , alors

$$\langle J'(u), v - u \rangle \geq 0 \quad \forall v \in K .$$

Si $u \in K$ vérifie cette inéquation et si J est convexe, alors u est un minimum global de J sur K .

Remarques.

- ➡ Si u est intérieur à K , on obtient l'équation d'Euler $J'(u) = 0$.
- ➡ L'inéquation d'Euler est seulement nécessaire en général. Pour les fonctions convexes, elle est nécessaire et suffisante.

Minimisation avec contraintes d'égalité

$$\inf_{v \in V, F(v)=0} J(v)$$

avec $F(v) = (F_1(v), \dots, F_M(v))$ une application dérivable de V dans \mathbb{R}^M .

Définition. On appelle **Lagrangien** du problème la fonction

$$\mathcal{L}(v, \mu) = J(v) + \sum_{i=1}^M \mu_i F_i(v) = J(v) + \mu \cdot F(v) \quad \forall (v, \mu) \in V \times \mathbb{R}^M.$$

La nouvelle variable $\mu \in \mathbb{R}^M$ est appelée **multiplicateur de Lagrange** pour la contrainte $F(v) = 0$.

Lemme. Le problème de minimisation est équivalent à

$$\inf_{v \in V, F(v)=0} J(v) = \inf_{v \in V} \sup_{\mu \in \mathbb{R}^M} \mathcal{L}(v, \mu).$$

Stationnarité du Lagrangien

Théorème. On suppose que J et F sont continûment dérivables au voisinage de $u \in V$ tel que $F(u) = 0$. Si u est un minimum local, et si les vecteurs $(F'_i(u))_{1 \leq i \leq M}$ sont **linéairement indépendants**, alors il existe des multiplicateurs de Lagrange $\lambda_1, \dots, \lambda_M \in \mathbb{R}$, tels que

$$\frac{\partial \mathcal{L}}{\partial v}(u, \lambda) = J'(u) + \lambda \cdot F'(u) = 0 \quad \text{et} \quad \frac{\partial \mathcal{L}}{\partial \mu}(u, \lambda) = F(u) = 0 .$$

Minimisation avec contraintes d'inégalité

$$\inf_{v \in V, F(v) \leq 0} J(v)$$

où $F(v) \leq 0$ signifie que $F_i(v) \leq 0$ pour $1 \leq i \leq M$, avec F_1, \dots, F_M fonctions dérivables de V dans \mathbb{R} .

Définition. Soit u tel que $F(u) \leq 0$. L'ensemble $I(u) = \{i \in \{1, \dots, M\}, F_i(u) = 0\}$ est appelé l'ensemble des contraintes **actives** en u . On dit que les contraintes d'inégalité sont **qualifiées** en $u \in K$ si la famille $(F'_i(u))_{i \in I(u)}$ est libre.

Définition. On appelle **Lagrangien** du problème la fonction

$$\mathcal{L}(v, \mu) = J(v) + \sum_{i=1}^M \mu_i F_i(v) = J(v) + \mu \cdot F(v) \quad \forall (v, \mu) \in V \times (\mathbb{R}^+)^M.$$

La nouvelle variable **positive** $\mu \in (\mathbb{R}^+)^M$ est appelée **multiplicateur de Lagrange** pour la contrainte $F(v) \leq 0$.

Lemme. Le problème de minimisation est équivalent à

$$\inf_{v \in V, F(v) \leq 0} J(v) = \inf_{v \in V} \sup_{\mu \in (\mathbb{R}^+)^M} \mathcal{L}(v, \mu).$$

Stationnarité du Lagrangien

Théorème. On suppose que les contraintes sont qualifiées en u tel que $F(u) \leq 0$. Alors, si u est un minimum local, il existe $\lambda_1, \dots, \lambda_M \geq 0$, appelés **multiplicateurs de Lagrange**, tels que

$$J'(u) + \sum_{i=1}^M \lambda_i F'_i(u) = 0, \quad \lambda_i \geq 0, \quad \lambda_i = 0 \text{ si } F_i(u) < 0 \quad \forall i \in \{1, \dots, M\}.$$

Cette condition est bien la stationnarité du Lagrangien puisque

$$\frac{\partial \mathcal{L}}{\partial v}(u, \lambda) = J'(u) + \lambda \cdot F'(u) = 0,$$

et que la condition $\lambda \geq 0, F(u) \leq 0, \lambda \cdot F(u) = 0$ est équivalente à l'inéquation d'Euler pour la **maximisation** par rapport à μ dans le convexe fermé $(\mathbb{R}^+)^M$

$$\frac{\partial \mathcal{L}}{\partial \mu}(u, \lambda) \cdot (\mu - \lambda) = F(u) \cdot (\mu - \lambda) \leq 0 \quad \forall \mu \in (\mathbb{R}^+)^M.$$

Une interprétation des multiplicateurs de Lagrange

Soit le Lagrangien pour la minimisation de $J(v)$ sous la contrainte $F(v) = c$

$$\mathcal{L}(v, \mu, c) = J(v) + \mu \cdot (F(v) - c)$$

On étudie la sensibilité du minimum à la variation de c .

On note $u(c)$ et $\lambda(c)$ le point de minimum et le multiplicateur de Lagrange correspondant. On suppose qu'ils sont dérivables par rapport à c . Alors

$$\nabla_c \left(J(u(c)) \right) = -\lambda(c).$$

λ donne la dérivée (sans la calculer) du minimum par rapport à c !

En effet

$$\nabla_c \left(J(u(c)) \right) = \nabla_c \left(\mathcal{L}(u(c), \lambda(c), c) \right) = \frac{\partial \mathcal{L}}{\partial c} (u(c), \lambda(c), c) = -\lambda(c)$$

car

$$\frac{\partial \mathcal{L}}{\partial v} (u(c), \lambda(c), c) = 0 \quad , \quad \frac{\partial \mathcal{L}}{\partial \mu} (u(c), \lambda(c), c) = 0 .$$

Dualité et point selle

Définition. Soit un Lagrangien $\mathcal{L}(v, q)$. On dit que $(u, p) \in U \times P$ est un **point-selle** (ou col, ou min-max) de \mathcal{L} sur $U \times P$ si

$$\forall q \in P \quad \mathcal{L}(u, q) \leq \mathcal{L}(u, p) \leq \mathcal{L}(v, p) \quad \forall v \in U .$$

Pour $v \in U$ et $q \in P$, posons $\mathcal{J}(v) = \sup_{q \in P} \mathcal{L}(v, q)$ et $\mathcal{G}(q) = \inf_{v \in U} \mathcal{L}(v, q)$.

On appelle **problème primal**

$$\inf_{v \in U} \mathcal{J}(v) ,$$

et **problème dual**

$$\sup_{q \in P} \mathcal{G}(q) .$$

Exemple. $U = V$, $P = \mathbb{R}^M$ ou \mathbb{R}_+^M , et $\mathcal{L}(v, q) = J(v) + q \cdot F(v)$. Dans ce cas $\mathcal{J}(v) = J(v)$ si $F(v) = 0$ et $\mathcal{J}(v) = +\infty$ sinon, tandis qu'il n'y a pas de contraintes pour le problème dual (autres que $q \in P$).

Lemme (dualité faible). On a toujours

$$\inf_{v \in U} \mathcal{J}(v) \geq \sup_{q \in P} \mathcal{G}(q).$$

Preuve: $\inf \sup \mathcal{L} \geq \sup \inf \mathcal{L}$.

Théorème (dualité forte). Le couple (u, p) est un point-selle de \mathcal{L} sur $U \times P$ si et seulement si

$$\mathcal{J}(u) = \min_{v \in U} \mathcal{J}(v) = \max_{q \in P} \mathcal{G}(q) = \mathcal{G}(p) .$$

Remarque. Le problème dual est souvent plus simple que le primal (pas de contraintes). Si on peut résoudre le dual, on obtient la solution du primal grâce à une minimisation sans contrainte.

Application: énergie complémentaire ou duale

Très important pour la suite !

Soit $f \in L^2(\Omega)$. On sait que pour résoudre

$$\begin{cases} -\Delta u = f & \text{dans } \Omega \\ u = 0 & \text{sur } \partial\Omega \end{cases}$$

il suffit de minimiser l'énergie dite **primale**

$$\min_{v \in H_0^1(\Omega)} \left\{ J(v) = \frac{1}{2} \int_{\Omega} |\nabla v|^2 dx - \int_{\Omega} f v dx \right\}$$

On introduit une **énergie duale** (ou complémentaire)

$$\max_{\substack{\tau \in L^2(\Omega)^N \\ -\operatorname{div} \tau = f \text{ dans } \Omega}} \left\{ G(\tau) = -\frac{1}{2} \int_{\Omega} |\tau|^2 dx \right\}.$$

J est convexe et G est concave.

Proposition. Soit $u \in H_0^1(\Omega)$ la solution unique de l'équation. On pose $\sigma = \nabla u$. Alors,

$$J(u) = \min_{v \in H_0^1(\Omega)} J(v) = \max_{\substack{\tau \in L^2(\Omega)^N \\ -\operatorname{div}\tau = f \text{ dans } \Omega}} G(\tau) = G(\sigma),$$

et σ est l'unique point de maximum de G .

Preuve. On introduit le Lagrangien dans $H_0^1(\Omega) \times L^2(\Omega)^N$

$$\mathcal{L}(v, \tau) = -\frac{1}{2} \int_{\Omega} |\tau|^2 dx - \int_{\Omega} (f + \operatorname{div}\tau)v dx.$$

Par intégration par parties

$$\mathcal{L}(v, \tau) = -\frac{1}{2} \int_{\Omega} |\tau|^2 dx - \int_{\Omega} f v dx + \int_{\Omega} \tau \cdot \nabla v dx.$$

v est le multiplicateur de Lagrange pour la contrainte $-\operatorname{div}\tau = f$.

On vérifie que le dual du dual est le primal !

$$\max_{\tau} \mathcal{L}(v, \tau) = J(v).$$

Fin de la démonstration

Par définition, si τ vérifie la contrainte $-\operatorname{div}\tau = f$, on a

$$G(\tau) = \mathcal{L}(v, \tau) \quad \forall v$$

D'autre part,

$$\mathcal{L}(v, \tau) \leq \max_{\tau} \mathcal{L}(v, \tau) = J(v).$$

Or, par intégration par parties, on a $\int_{\Omega} |\nabla u|^2 dx = \int_{\Omega} f u dx$, donc

$$J(u) = \frac{1}{2} \int_{\Omega} |\nabla u|^2 dx - \int_{\Omega} f u dx = -\frac{1}{2} \int_{\Omega} |\nabla u|^2 dx = G(\nabla u).$$

Autrement dit, pour tout τ vérifiant $-\operatorname{div}\tau = f$,

$$G(\tau) = \mathcal{L}(u, \tau) \leq J(u) = G(\sigma)$$

c'est-à-dire que $\sigma = \nabla u$ maximise G parmi tous les τ tels que $-\operatorname{div}\tau = f$.

Algorithmes numériques de minimisation

Panorama simpliste:

☞ Algorithmes stochastiques: **minimum global**. Exemples: Monte-Carlo, recuit simulé, génétique. Voir le dernier chapitre et le dernier amphi.

Inconvénient: très couteux en CPU.

☞ Algorithmes déterministes: **minimum local**. Exemples: méthodes de gradient, Newton.

Inconvénient: il faut pouvoir disposer du gradient.

Gradient à pas optimal

On veut résoudre

$$\inf_{v \in V} J(v) .$$

Initialisation: choisir u^0 dans V . **Itérations:** pour $n \geq 0$

$$u^{n+1} = u^n - \mu^n J'(u^n) ,$$

où $\mu^n \in \mathbb{R}$ est choisi à chaque étape tel que

$$J(u^{n+1}) = \inf_{\mu \in \mathbb{R}^+} J(u^n - \mu J'(u^n)) .$$

Idée principale: si $u^{n+1} = u^n - \mu w^n$ avec $\mu > 0$ petit, alors

$$J(u^{n+1}) = J(u^n) - \mu \langle J'(u^n), w^n \rangle + \mathcal{O}(\mu^2),$$

donc pour descendre il vaut mieux prendre w^n colinéaire à $J'(u^n)$.

Convergence

Théorème On suppose que J est fortement convexe différentiable et que J' est Lipschitzien sur tout borné de V , c'est-à-dire que

$$\forall M > 0, \quad \exists C_M > 0, \quad \|v\| + \|w\| \leq M \Rightarrow \|J'(v) - J'(w)\| \leq C_M \|v - w\|.$$

Alors l'algorithme de gradient à pas optimal **converge**: quel que soit u^0 , la suite (u^n) converge vers la solution u .

Remarque. Si J n'est pas fortement convexe:

- ☞ l'algorithme peut ne pas converger (il oscille entre plusieurs solutions),
- ☞ l'algorithme peut converger vers un minimum local,
- ☞ le résultat de l'algorithme peut varier selon l'initialisation.

Variante: gradient à pas fixe

On veut résoudre

$$\inf_{v \in V} J(v) .$$

Initialisation: choisir u^0 dans V . **Itérations:** pour $n \geq 0$

$$u^{n+1} = u^n - \mu J'(u^n) ,$$

Théorème. On suppose que J est fortement convexe, différentiable et que J' est Lipschitzien sur V . Alors, si $\mu > 0$ est suffisamment petit, l'algorithme de gradient à pas fixe converge : quel que soit u^0 , la suite (u^n) converge vers la solution u .

Remarque. Variante intermédiaire possible: on ne garde pas le pas fixe mais on ne le prend pas optimal non plus ; on se contente d'augmenter le pas $\mu_{n+1} = 1.1\mu_n$ si J décroît, et de le réduire $\mu_{n+1} = 0.5\mu_n$ si J croît.

Gradient projeté

Soit K convexe fermé non vide de V . On veut résoudre

$$\inf_{v \in K} J(v) .$$

Initialisation: choisir u^0 dans K . **Itérations:** pour $n \geq 0$

$$u^{n+1} = P_K(u^n - \mu J'(u^n)) ,$$

avec P_K projection sur K .

Théorème. On suppose que J est fortement convexe différentiable et que J' est Lipschitzien sur V . Alors, si $\mu > 0$ est suffisamment petit, l'algorithme de gradient à pas fixe avec projection converge.

Remarque. On peut aussi **pénaliser** les contraintes, i.e. on remplace

$$\inf_{v \in V, F(v) \leq 0} J(v) \quad \text{par} \quad \inf_{v \in V} \left(J(v) + \frac{1}{\epsilon} \sum_{i=1}^M [\max(F_i(v), 0)]^2 \right) .$$

Exemples d'opérateurs de projection P_K

☞ Si $V = \mathbb{R}^M$ et $K = \prod_{i=1}^M [a_i, b_i]$, alors pour $x = (x_1, x_2, \dots, x_M) \in \mathbb{R}^M$

$$P_K(x) = y \quad \text{avec} \quad y_i = \min(\max(a_i, x_i), b_i) \quad \text{pour} \quad 1 \leq i \leq M.$$

☞ Si $V = \mathbb{R}^M$ et $K = \{x \in \mathbb{R}^M \mid \sum_{i=1}^M x_i = c_0\}$, alors

$$P_K(x) = y \quad \text{avec} \quad y_i = x_i - \lambda \quad \text{et} \quad \lambda = \frac{1}{M} \left(-c_0 + \sum_{i=1}^M x_i \right).$$

☞ Même chose si $V = L^2(\Omega)$ et $K = \{\phi \in V \mid a(x) \leq \phi(x) \leq b(x)\}$ ou
 $K = \{\phi \in V \mid \int_{\Omega} \phi dx = c_0\}$.

Pour des convexes fermés K plus généraux, P_K peut être très difficile à déterminer. Dans ce cas on utilise [l'algorithme d'Uzawa](#) qui recherche un point selle du Lagrangien.

Algorithmes de Newton (ordre 2)

Idée principale: si $V = \mathbb{R}^N$ et si $J'' \geq 0$

$$J(w) \approx J(v) + J'(v) \cdot (w - v) + \frac{1}{2} J''(v)(w - v) \cdot (w - v),$$

dont le minimum est $w = v - (J''(v))^{-1} J'(v)$.

Algorithme: $u^{n+1} = u^n - (J''(u^n))^{-1} J'(u^n)$.

☞ Converge plus vite si u^0 est proche du minimum u

$$\|u^{n+1} - u\| \leq C \|u^n - u\|^2 .$$

☞ Nécessite d'inverser un système linéaire de matrice $J''(u^n)$.

☞ Peut se généraliser en méthode de quasi-Newton (sans calculer J'') ou au cas avec contraintes.

CHAPITRE IV

CONTROLE OPTIMAL

Optimisation des systèmes distribués:
Calcul du gradient par état adjoint

Contrôle d'une membrane élastique

Pour $f \in L^2(\Omega)$, le déplacement vertical de la membrane u est solution de

$$\begin{cases} -\Delta u = f + v & \text{dans } \Omega \\ u = 0 & \text{sur } \partial\Omega, \end{cases}$$

où v est une **force de contrôle** qui sera la variable d'optimisation (par exemple, un actionneur piézzo-électrique). On définit alors l'ensemble des contrôles admissibles

$$K = \{v \in L^2(\omega) \mid v_{min}(x) \leq v(x) \leq v_{max}(x) \text{ dans } \omega \text{ et } v = 0 \text{ dans } \Omega \setminus \omega\}.$$

On veut **contrôler la membrane** pour qu'elle adopte un déplacement $u_0 \in L^2(\Omega)$ en minimisant ($c > 0$)

$$\inf_{v \in K} \left\{ J(v) = \frac{1}{2} \int_{\Omega} (|u - u_0|^2 + c|v|^2) dx \right\}.$$

Existence d'un contrôle optimal

Proposition.

Il existe un unique contrôle optimal $\bar{v} \in K$.

Preuve. $v \rightarrow J(v)$ est fortement convexe et K est convexe (voir le livre de cours).

Remarque. L'existence est souvent beaucoup plus dure, mais ce qui importe surtout c'est le calcul du gradient $J'(v)$ pour mettre en oeuvre une méthode numérique.

Attention: la solution u de l'e.d.p. dépend du contrôle v .

Gradient et condition d'optimalité

La méthode la plus sûre et la plus simple pour **calculer le gradient** est

$$\lim_{\epsilon \rightarrow 0} \frac{J(v + \epsilon w) - J(v)}{\epsilon} = \langle J'(v), w \rangle = \int_{\Omega} J'(v)w \, dx .$$

Par linéarité, on a $u(v + \epsilon w) = u(v) + \epsilon \tilde{u}(w)$ avec

$$\begin{cases} -\Delta \tilde{u}(w) = w & \text{dans } \Omega \\ \tilde{u}(w) = 0 & \text{sur } \partial\Omega. \end{cases}$$

Autrement dit, $\tilde{u}(w) = \langle u'(v), w \rangle$.

Comme $J(v)$ est quadratique le calcul est très simple et on obtient

$$\int_{\Omega} J'(v)w \, dx = \int_{\Omega} \left((u(v) - u_0)\tilde{u}(w) + cvw \right) dx,$$

Malheureusement $J'(v)$ n'est pas explicite !

Etat adjoint

Pour simplifier l'expression du gradient on utilise l'état adjoint p défini comme l'unique solution dans $H_0^1(\Omega)$ de

$$\begin{cases} -\Delta p = u - u_0 & \text{dans } \Omega \\ p = 0 & \text{sur } \partial\Omega. \end{cases}$$

On multiplie l'équation de $\tilde{u}(w)$ par p et réciproquement, puis on intègre par parties

$$\text{équation pour } p \times \tilde{u}(w) \quad \Rightarrow \quad \int_{\Omega} \nabla p \cdot \nabla \tilde{u}(w) \, dx = \int_{\Omega} (u - u_0) \tilde{u}(w) \, dx$$

$$\text{équation pour } \tilde{u}(w) \times p \quad \Rightarrow \quad \int_{\Omega} \nabla \tilde{u}(w) \cdot \nabla p \, dx = \int_{\Omega} wp \, dx$$

Par comparaison de ces deux égalités on en déduit que

$$\int_{\Omega} J'(v)w \, dx = \int_{\Omega} (p + cv)w \, dx.$$

Conclusion l'état adjoint

On a donc trouvé une **formule explicite** du gradient

$$J'(v) = p + cv.$$

- ☞ **Méthode adjointe**: calcul du gradient grâce à la résolution de **2** problèmes aux limites (u et p).
- ☞ Si on ne calcule pas l'adjoint: pour **chaque** direction w il faut calculer **2** problèmes aux limites (u et $\tilde{u}(w)$) pour connaître $\langle J'(v), w \rangle$.
Par exemple, si $J'(v)$ est un vecteur en dimension n , pour obtenir ses n composantes il faut résoudre $(n + 1)$ problèmes !
- ☞ Très efficace en pratique: c'est la meilleure méthode possible.
- ☞ Inconvénient: si on utilise un solveur numérique pour u en **boite noire**, il peut être très compliqué de le modifier pour obtenir la solution p de l'état adjoint.

- ➡ Si l'équation d'état est non-autoadjointe (forme bilinéaire non symétrique), l'opérateur principal de l'équation adjointe est le transposé ou **adjoint** de celui de l'équation d'état.
- ➡ Si l'équation d'état est non-linéaire, l'équation adjointe est linéaire.

Méthode générale pour trouver l'état adjoint

On considère l'équation d'état comme une **contrainte** et, pour tout $(\hat{v}, \hat{u}, \hat{p}) \in L^2(\Omega) \times H_0^1(\Omega) \times H_0^1(\Omega)$, on introduit le Lagrangien du problème de minimisation

$$\mathcal{L}(\hat{v}, \hat{u}, \hat{p}) = \frac{1}{2} \int_{\Omega} (|\hat{u} - u_0|^2 + c|\hat{v}|^2) dx + \int_{\Omega} \hat{p}(\Delta \hat{u} + f + \hat{v}) dx,$$

où \hat{p} est le **multiplicateur de Lagrange** pour la contrainte qui relie les deux variables **indépendantes** \hat{v} et \hat{u} .

Par intégration par parties

$$\mathcal{L}(\hat{v}, \hat{u}, \hat{p}) = \frac{1}{2} \int_{\Omega} (|\hat{u} - u_0|^2 + c|\hat{v}|^2) dx + \int_{\Omega} (-\nabla \hat{p} \cdot \nabla \hat{u} + f\hat{p} + \hat{v}\hat{p}) dx.$$

Proposition. Les conditions d'optimalité sont équivalentes à la stationnarité du Lagrangien, c'est-à-dire que

$$\frac{\partial \mathcal{L}}{\partial v} = \frac{\partial \mathcal{L}}{\partial u} = \frac{\partial \mathcal{L}}{\partial p} = 0.$$

Démonstration

- $\frac{\partial \mathcal{L}}{\partial p} = 0 \Rightarrow$ par construction, on trouve l'équation vérifiée par l'état u .
- $\frac{\partial \mathcal{L}}{\partial u} = 0 \Rightarrow$ équation vérifiée par l'état adjoint p . En effet,

$$\lim_{\epsilon \rightarrow 0} \frac{\mathcal{L}(u + \epsilon w) - \mathcal{L}(u)}{\epsilon} = \left\langle \frac{\partial \mathcal{L}}{\partial u}, w \right\rangle = \int_{\Omega} ((u - u_0)w - \nabla p \cdot \nabla w) dx$$

ce qui est la formulation variationnelle de l'équation adjointe.

- $\frac{\partial \mathcal{L}}{\partial v} = 0 \Rightarrow$ formule pour $J'(v)$. En effet,

$$\lim_{\epsilon \rightarrow 0} \frac{\mathcal{L}(v + \epsilon w) - \mathcal{L}(v)}{\epsilon} = \left\langle \frac{\partial \mathcal{L}}{\partial v}, w \right\rangle = \int_{\Omega} (cv + p)w dx$$

Formule simple de la dérivée

On a obtenu dans la démonstration précédente

$$J'(v) = \frac{\partial \mathcal{L}}{\partial v}(v, u, p)$$

avec u l'état, et p l'adjoint.

Cela n'est pas une surprise ! En effet,

$$J(v) = \mathcal{L}(v, u, \hat{p}) \quad \forall \hat{p}$$

car u est l'état. Donc, si $u(v)$ est dérivable, on a

$$\langle J'(v), w \rangle = \left\langle \frac{\partial \mathcal{L}}{\partial v}(v, u, \hat{p}), w \right\rangle + \left\langle \frac{\partial \mathcal{L}}{\partial u}(v, u, \hat{p}), \frac{\partial u}{\partial v}(w) \right\rangle$$

On prend alors $\hat{p} = p$, l'adjoint, pour obtenir

$$\langle J'(v), w \rangle = \left\langle \frac{\partial \mathcal{L}}{\partial v}(v, u, p), w \right\rangle$$

Une (autre) interprétation de l'état adjoint

L'état adjoint p est le multiplicateur de Lagrange pour la contrainte de l'équation d'état. Mais c'est aussi une **fonction de sensibilité**.

Soit le Lagrangien

$$\mathcal{L}(\hat{v}, \hat{u}, \hat{p}, f) = \frac{1}{2} \int_{\Omega} (|\hat{u} - u_0|^2 + c|\hat{v}|^2) dx + \int_{\Omega} (-\nabla \hat{p} \cdot \nabla \hat{u} + f\hat{p} + \hat{v}\hat{p}) dx.$$

On étudie la sensibilité du minimum à la variation de f .

On note $v(f)$, $u(f)$ et $p(f)$ les valeurs optimales, dépendant de f . On suppose qu'ils sont dérivables par rapport à f . Alors

$$\nabla_f \left(J(v(f)) \right) = p(f).$$

p donne la dérivée (sans la calculer) du minimum par rapport à f !

En effet $J(v(f)) = \mathcal{L}(v(f), u(f), p(f), f)$ et $\frac{\partial \mathcal{L}}{\partial v} = \frac{\partial \mathcal{L}}{\partial u} = \frac{\partial \mathcal{L}}{\partial p} = 0$.