

# APPROXIMATION NUMERIQUE ET OPTIMISATION

G. ALLAIRE

13 novembre 2018

CHAPITRE IV (fin)

- ☞ Algorithmes d'optimisation avec contraintes.
- ☞ Méthodes d'approximations successives.
- ☞ Notions de programmation linéaire.

## Algorithmes d'optimisation avec contraintes.

- Gradient projeté.
- Algorithme d'Uzawa.
- Pénalisation des contraintes.
- Méthodes d'approximations successives.

## 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 orthogonale sur  $K$ .

**Théorème.** On suppose que  $J$  est  $\alpha$ -convexe différentiable pour  $\alpha > 0$ ,

$$J(v) \geq J(u) + \langle J'(u), v - u \rangle + \frac{\alpha}{2} \|v - u\|^2 \quad \forall u, v \in V$$

et que  $J'$  est Lipschitzien sur  $V$ : il existe  $C > 0$  tel que

$$\|J'(v) - J'(u)\| \leq C \|v - u\| \quad \forall u, v \in V .$$

Alors, si  $0 < \mu < 2\alpha/C^2$ , l'algorithme de gradient projeté converge.

Preuve

Condition d'optimalité (inéquation d'Euler)

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

Pour  $\mu > 0$ , c'est équivalent à

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

Autrement dit, l'unique point de minimum  $u \in K$  est caractérisé par

$$u = P_K(u - \mu J'(u)) \quad \text{avec } P_K \text{ l'opérateur de projection orthogonale sur } K.$$


On va montrer que l'application

$$f(v) = P_K(v - \mu J'(v))$$

est strictement contractante. Donc elle admet un unique point fixe  $u = f(u)$  et la suite

$$u^{n+1} = P_K(u^n - \mu J'(u^n)) \quad \text{converge vers } u.$$

*nécessaire et suffisante car J convexe*



Preuve (suite)

Définition de  $P_K v$ :

$$\langle P_K v - v, w - P_K v \rangle \geq 0$$

L'opérateur de projection  $P_K$  est faiblement contractant

$$\|P_K v - P_K w\| \leq \|v - w\|.$$



On développe

$$\begin{aligned} \|P_K v - P_K w\|^2 &= \underbrace{\langle P_K v - P_K w, v - w \rangle}_{\leq \|P_K v - P_K w\| \cdot \|v - w\|} + \underbrace{\langle P_K v - P_K w, P_K v - v \rangle}_{\leq 0} + \underbrace{\langle P_K v - P_K w, w - P_K w \rangle}_{\leq 0} \\ &\leq \|P_K v - P_K w\| \cdot \|v - w\| \end{aligned}$$

par def. de  $P_K v$ 
par def. de  $P_K w$

Preuve (fin)

La fonction  $v \rightarrow v - \mu J'(v)$  est strictement contractante car

$$\|v - \mu J'(v) - w + \mu J'(w)\|^2 = \|v - w\|^2 - 2\mu \langle v - w, J'(v) - J'(w) \rangle + \mu^2 \|J'(v) - J'(w)\|^2$$

Grâce à l' $\alpha$ -convexité

$$\langle v - w, J'(v) - J'(w) \rangle \geq \alpha \|v - w\|^2$$

La Lipschitziannité de  $J'$  donne

$$\|J'(v) - J'(w)\|^2 \leq C^2 \|v - w\|^2$$

Donc

$$\|v - \mu J'(v) - w + \mu J'(w)\|^2 \leq (1 - 2\mu\alpha + \mu^2 C^2) \|v - w\|^2$$

Si  $0 < \mu < \frac{2\alpha}{C^2}$  alors  $(1 - 2\mu\alpha + \mu^2 C^2) < 1$  et on conclut.

## Exemples d'opérateurs de projection $P_K$

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

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

☞ Si  $V = \mathbb{R}^n$ ,  $B$  matrice  $m \times n$  avec  $\text{rg}(B) = m \leq n$  et  $K = \{x \in \mathbb{R}^n \mid Bx = c\}$ , alors


$$P_K(x) = x + B^*(BB^*)^{-1}(c - Bx).$$

$$\forall u \in \mathbb{R}^m \quad u \perp \text{Im } B^*$$

$$x - p_K x \in \text{Im } B^*$$

$$p_K x = x + B^* p$$

$$\text{on calcule } p \text{ en éliminant } B(p_K x) = c$$



**Remarque.** Pour des convexes fermés  $K$  plus généraux,  $P_K$  peut être très difficile à déterminer en pratique.

## Algorithme d'Uzawa

L'algorithme d'Uzawa recherche un point selle du Lagrangien  $\mathcal{L}(v, q) = J(v) + q \cdot F(v)$  pour le problème de minimisation

$$\min_{F(v) \leq 0} J(v) ,$$

**Rappel (Théorème de Kuhn et Tucker).** Si  $J$  et  $F$  sont convexes et différentiables, alors il existe un point de minimum  $u$  avec multiplicateur de Lagrange  $p$  **si et seulement si**  $(u, p)$  est un point-selle du Lagrangien

$$\forall q \in \mathbb{R}_+^M \quad \mathcal{L}(u, q) \leq \mathcal{L}(u, p) \leq \mathcal{L}(v, p) \quad \forall v \in V .$$

**Idée de l'algorithme:** alternativement on **minimise** en  $v$  à  $q$  fixé, et on **maximise** en  $q$  à  $v$  fixé.

## Algorithme d'Uzawa (suite)

**Initialisation:** soit  $p^0 \in (\mathbb{R}_+)^M$ .

**Itérations:** on construit les suites  $(u^n)$  et  $(p^n)$  par

$$\mathcal{L}(u^n, p^n) = \inf_{v \in V} \mathcal{L}(v, p^n),$$

$$p^{n+1} = P_{\mathbb{R}_+^M}(p^n + \mu F(u^n)),$$

avec  $\mu > 0$  fixé (c'est une itération de l'algorithme du gradient projeté pour maximiser en  $q$ ).

### Remarques.

1. Variante: **algorithme d'Arrow-Hurwicz** (un seul pas de gradient pour la minimisation en  $v$ ).
2. Peut être mis en oeuvre pour des contraintes d'égalité.


## Algorithme d'Uzawa (fin)

**Théorème.** On suppose que  $J$  est  $\alpha$ -convexe différentiable, que  $F$  est convexe et Lipschitzienne de  $V$  dans  $\mathbb{R}^M$ ,  $\exists C > 0$  tel que


$$\|F(v) - F(w)\| \leq C\|v - w\| \quad \forall v, w \in V,$$

et qu'il existe un point-selle  $(u, p)$  du Lagrangien sur  $V \times (\mathbb{R}_+)^M$ . Alors, si  $0 < \mu < 2\alpha/C^2$ , l'algorithme d'Uzawa converge :  $\forall p^0 \in (\mathbb{R}_+)^M$ , la suite  $(u^n)$  converge vers le point de minimum  $u$ .

$$\lambda \rightarrow \max(0, \lambda)$$



## Pénalisation des contraintes



Par exemple, on remplace

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

par

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

où on a **pénalisé** les contraintes avec un petit paramètre  $\epsilon > 0$ .

On utilise ensuite un algorithme sans contrainte.

## Méthodes d'approximations successives.

Que faire pour résoudre

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

quand  $J$  et  $F$  n'ont pas de propriétés particulières ?

**Idée:** remplacer  $J$  et  $F$  par leurs développements de Taylor d'ordre 1 ou 2.

**Initialisation:**  $v^0 \in V$ . **Itérations:**

1. Soit  $v^n$  la solution approchée à l'itération  $n$ . On définit les approximations  $J^n(v)$  et  $F^n(v)$  au voisinage de  $v^n$ .
2. On calcule la solution  $v^{n+1}$  de

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

**Remarque.** On peut aussi imposer une condition de **région de confiance**  $\|v - v^n\| \leq \epsilon$  pour être certain que l'approximation est correcte.

## Programmation linéaire séquentielle (SLP)

On linéarise (Taylor d'ordre 1):

$$\inf_{F(v^{n-1}) + F'(v^{n-1}) \cdot (v - v^{n-1}) = 0} \left\{ J(v^{n-1}) + J'(v^{n-1}) \cdot (v - v^{n-1}) \right\},$$

Il existe des algorithmes **très efficace** pour ce problème linéaire.

On note  $v^n$  un point de minimum et on itère.

**Remarque.** Si l'infimum vaut  $-\infty$ , on rajoute la condition de région de confiance (linéaire)  $\|v - v^{n-1}\|_\infty \leq \epsilon$ .

## Programmation quadratique séquentielle (SQP)

Approximation quadratique pour  $J$ , linéaire pour  $F$ :

$$\inf_{F^n(v)=0} J^n(v),$$

avec

$$F^n(v) = F(v^{n-1}) + F'(v^{n-1}) \cdot (v - v^{n-1})$$

$$J^n(v) = J(v^{n-1}) + J'(v^{n-1}) \cdot (v - v^{n-1}) + \frac{1}{2} Q^{n-1} (v - v^{n-1}) \cdot (v - v^{n-1})$$

mais  $Q^{n-1}$  n'est pas la Hessienne de  $J$  mais du Lagrangien

$$Q^{n-1} = J''(v^{n-1}) + \lambda^{n-1} \cdot F''(v^{n-1})$$

avec  $\lambda^{n-1}$  le multiplicateur de Lagrange pour l'itération  $n - 1$ .

En effet, il faut rester sur la variété définie par la contrainte !

Autre version méthode de Newton pour résoudre  $J'(u) + \lambda \cdot F'(u) = 0$

$$J(v) \approx J(v_{n-1}) + \langle J'(v_{n-1}), v - v_{n-1} \rangle + \frac{1}{2} \langle J''(v_{n-1})(v - v_{n-1}), v - v_{n-1} \rangle$$

$$F(v) = 0 \approx F(v_{n-1}) + \langle F'(v_{n-1}), v - v_{n-1} \rangle + \frac{1}{2} \langle F''(v_{n-1})(v - v_{n-1}), v - v_{n-1} \rangle$$

$$J(v) = J(v) + \lambda F(v) \quad \text{si} \quad F(v) = 0 \quad \approx_0 \text{ si } \lambda = \lambda_{n-1}$$

$$J(v) + \lambda F(v) \approx J(v_{n-1}) + \lambda \cdot F(v_{n-1}) + \langle J'(v_{n-1}) + \lambda F'(v_{n-1}), v - v_{n-1} \rangle + \frac{1}{2} \langle (J'' + \lambda F'')(v_{n-1})(v - v_{n-1}), v - v_{n-1} \rangle$$

## Notions de programmation linéaire.

On appelle **programme linéaire** sous forme standard

$$\inf_{x \in \mathbb{R}^n \text{ tel que } Ax=b, x \geq 0} c \cdot x,$$

où  $A$  est une matrice  $m \times n$  (avec  $\text{rg}(A) = m$ ),  $b \in \mathbb{R}^m$ ,  $c \in \mathbb{R}^n$ .

**Lemme.** Tout programme linéaire


$$(*) \quad \inf_{x \in \mathbb{R}^n \text{ tel que } Ax \geq b, A'x = b'} c \cdot x. \quad \begin{matrix} m \times n & b \in \mathbb{R}^m \end{matrix}$$

peut se mettre sous la forme standard.

**Preuve.** On introduit des variables d'écart (slack variable)  $y \in \mathbb{R}^m$   $y \geq 0$

$$Ax = y + b \Leftrightarrow Ax \geq b$$

$$(*) \Leftrightarrow \inf_{\substack{z \in \mathbb{R}^n \\ y \in \mathbb{R}^m \\ y \geq 0}} c \cdot z \\ Ax = b + y \quad A'z = b'$$



## Définitions

1) L'ensemble  $X_{ad}$  des vecteurs de  $\mathbb{R}^n$  qui satisfont les contraintes

$$X_{ad} = \{x \in \mathbb{R}^n \text{ tel que } Ax = b, x \geq 0\},$$

est appelé ensemble des **solutions admissibles** (c'est un polyèdre).

2) Un point de minimum de

$$\inf_{x \in X_{ad}} c \cdot x$$


est appelé **solution optimale**.

3) On appelle **sommet** ou point extrémal de  $X_{ad}$  tout point  $\bar{x} \in X_{ad}$  qui ne peut pas se décomposer en une combinaison convexe de deux autres points de  $X_{ad}$ , c'est-à-dire que, s'il existe  $y, z \in X_{ad}$  et  $\theta \in ]0, 1[$  tels que  $\bar{x} = \theta y + (1 - \theta)z$ , alors  $y = z = \bar{x}$ . Ce sont les sommets du polyèdre.

**Proposition.** S'il existe une solution optimale du programme linéaire, alors il existe une solution optimale qui est un **sommet du polyèdre**.

**Remarque.** Il y a un nombre fini de sommets. **L'algorithme du simplexe** de Dantzig énumère l'ensemble des sommets en faisant décroître la fonction  $c \cdot x$ .

**Preuve (géométrique).**



on augmente la cste de  $-\infty$  jusqu'à ce qu'on touche le polyèdre

## Rappels de dualité

**Définition.** Soit un Lagrangien  $\mathcal{L}(v, q)$  défini sur  $V \times P$ .

Pour  $v \in V$  posons  $\mathcal{J}(v) = \sup_{q \in P} \mathcal{L}(v, q)$ .

Pour  $q \in P$  posons  $\mathcal{G}(q) = \inf_{v \in V} \mathcal{L}(v, q)$ .

On appelle **problème primal**

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

et **problème dual**

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

## Rappels de dualité

**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. Si on peut résoudre le dual, on obtient la solution du primal grâce à une minimisation sans contrainte.

## Application à la programmation linéaire

Soit le programme linéaire standard ou **problème primal**

$$\inf_{x \in \mathbb{R}^n \text{ tel que } Ax=b, x \geq 0} c \cdot x \quad (P)$$

avec  $x, c \in \mathbb{R}^n$ ,  $b \in \mathbb{R}^m$  et  $A$  matrice  $m \times n$ . Pour  $p \in \mathbb{R}^m$ , le Lagrangien est

$$L(x, p) = c \cdot x + p \cdot (b - Ax),$$

où on ne “dualise” que les contraintes d’égalité. On introduit la fonction duale

$$G(p) = \min_{x \geq 0} L(x, p) = \begin{cases} p \cdot b & \text{si } A^*p - c \leq 0 \\ -\infty & \text{sinon.} \end{cases}$$

Le **problème dual** est donc

$$\sup_{p \in \mathbb{R}^m \text{ tel que } A^*p - c \leq 0} p \cdot b \quad (D)$$

$$\inf_{x \in \mathbb{R}^n \text{ tel que } Ax=b, x \geq 0} c \cdot x \quad (P)$$

$$\sup_{p \in \mathbb{R}^m \text{ tel que } A^*p - c \leq 0} p \cdot b \quad (D)$$

**Théorème.** Si (P) ou (D) a une valeur finie, alors il existe un point selle  $(x^*, p^*)$  du Lagrangien et  $x^*$  est une solution optimale de (P) tandis que  $x^*$  est une solution optimale de (D).

Le problème primal a  $n$  inconnues et  $m$  contraintes.

Le problème dual a  $m$  inconnues et  $n$  contraintes.

**Une conséquence.** Si  $m \ll n$ , alors le dual est plus facile que le primal.

