

# OPTIMISATION ET CONTRÔLE

Grégoire Allaire  
Département de mathématiques appliquées  
Ecole Polytechnique

**Algorithmes pour l'optimisation sous contraintes**

Pour un sous-ensemble  $K \subset V$  d'un espace de Hilbert (qui représente des contraintes), on veut résoudre

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

- 1 Gradient projeté pour un convexe  $K$ .
- 2 Algorithme d'Uzawa.
- 3 Pénalisation des contraintes.
- 4 Méthode du Lagrangien augmenté.
- 5 Méthodes (ou stratégies) d'approximations successives.
- 6 Quelques algorithmes utilisant la **structure** du problème.



# 1 - Gradient projeté

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

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

**Initialisation:** choisir  $u^0 \in K$  (par exemple  $u^0 = P_K(0)$ ).

**Itérations:** pour  $n \geq 0$

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

avec  $P_K$  opérateur de projection orthogonale sur  $K$ .

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

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

et que  $J'$  est Lipschitzien: il existe  $L > 0$  tel que

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

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



**Théorème.** Soit  $V$  un espace de Hilbert. Soit  $K \subset V$  un convexe fermé non vide. Pour tout  $x \in V$ , il existe un unique  $x_K \in K$  tel que

$$\|x - x_K\| = \min_{y \in K} \|x - y\|.$$

De façon équivalente,  $x_K$  est caractérisé par la propriété

$$x_K \in K, \langle x_K - x, x_K - y \rangle \leq 0 \quad \forall y \in K.$$

On appelle  $P_K$  l'opérateur de projection orthogonale sur  $K$  défini par

$$P_K(x) = x_K.$$

**Preuve.** Il existe un unique point de minimum  $u \in K$ .

**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,  $u \in K$  est caractérisé par

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

On va montrer que, pour  $0 < \mu < 2\alpha/L^2$ , 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

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



L'opérateur de projection  $P_K$  est faiblement contractant

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

En effet, si on développe

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

car par définition de  $P_K v$  et de  $P_K w$

$$\langle P_K v - v, P_K v - z \rangle \leq 0 \quad \forall z \in K \text{ (prendre } z = P_K w)$$

$$\langle P_K w - w, P_K w - z \rangle \leq 0 \quad \forall z \in K \text{ (prendre } z = P_K v)$$



La fonction  $v \rightarrow v - \mu J'(v)$  est strictement contractante. En effet,

$$\begin{aligned}\|v - \mu J'(v) - w + \mu J'(w)\|^2 &= \|v - w\|^2 - 2\mu \langle v - w, J'(v) - J'(w) \rangle \\ &\quad + \mu^2 \|J'(v) - J'(w)\|^2\end{aligned}$$

Grâce à l' $\alpha$ -convexité de  $J$

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

ainsi que  $J'$  Lipschitz

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

on obtient

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

Si  $0 < \mu < \frac{2\alpha}{L^2}$ , alors  $(1 - 2\mu\alpha + \mu^2 L^2) < 1$  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  $x = (x_1, \dots, x_n)$

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

- 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

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

En effet, la condition d'optimalité implique que  $(x - P_K(x))$  est orthogonal à  $\ker B$  donc appartient à  $\text{Im} B^*$ , c'est-à-dire  $x - P_K(x) = B^*y$ . Enfin  $y = (BB^*)^{-1}(Bx - c)$  à cause de la condition  $BP_K(x) = c$ .

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





On veut résoudre

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

où  $K$  est un sous-ensemble fermé non vide, **non-convexe** de  $V$ .

Projeter sur un convexe n'est déjà pas facile...

**Mais si  $K$  n'est pas convexe, c'est encore pire !** Pour ne pas dire impossible...

# Algorithme faisable ou infaisable ?

Pour un problème d'optimisation sous contrainte

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

il existe deux types d'algorithmes:

- 1 **faisable** si la suite d'itérées  $u^n$  appartient à  $K$ ,
- 2 **infaisable** si la suite d'itérées  $u^n$  n'appartient pas à  $K$  (mais converge vers une limite dans  $K$ ).

L'algorithme du gradient projeté est **faisable** mais pour  $K$  "compliqué" on ne sait pas calculer l'opérateur  $P_K$ .

On va étudier d'autres algorithmes, comme celui d'**Uzawa**, qui est **infaisable** mais facile à mettre en oeuvre.



## 2 - 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 (2)

Intuition (heuristique) du Lagrangien pour l'optimisation sous contraintes. On veut résoudre

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

A la place on minimise le Lagrangien, pour  $q \geq 0$  fixé,

$$v \rightarrow \mathcal{L}(v, q) = J(v) + q \cdot F(v)$$

Deux cas de figure: (une seule contrainte,  $M = 1$ , pour simplifier)

- 1 si  $F(v) < 0$ , alors  $q = 0$  et on minimise seulement  $J(v)$ ,
- 2 si  $F(v) \geq 0$ , alors  $q \geq 0$  et on minimise une combinaison de  $J$  et  $F$  pour **à la fois** rendre la contrainte satisfaite et diminuer la fonction objectif.

Evidemment, il faut modifier  $q$  itérativement pour tenir compte de la contrainte, active ou pas. Si on maximise  $q \rightarrow \mathcal{L}(v, q)$ , on augmente  $q$  lorsque  $F(v) \geq 0$ , pour améliorer la satisfaction de la contrainte.

# Algorithme d'Uzawa (3)

**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 On n'est pas garanti d'avoir  $F(u^n) \leq 0$  (**algorithme infaisable**).
- 3 Algorithme de maximisation du problème **dual** !
- 4 Peut être mis en oeuvre pour des contraintes d'égalité.

# Algorithme d'Uzawa (4)

**Lien avec la dualité.** Le problème dual est

$$\sup_{p \in \mathbb{R}_+^M} \left\{ \mathcal{G}(p) = \inf_{v \in V} \mathcal{L}(v, p) \right\}$$

Supposons qu'il existe un unique  $v(p)$  tel que

$$\mathcal{G}(p) = \mathcal{L}(v(p), p) \quad \text{et} \quad p \rightarrow v(p) \text{ est dérivable.}$$

Comme  $\mathcal{L}(v, p) = J(v) + p \cdot F(v)$ , la condition d'optimalité donne

$$\mathcal{G}'(p) = \underbrace{\langle J'(v(p)) + p \cdot F'(v(p)), v'(p) \rangle}_{=0} + F(v(p)) = F(v(p)).$$

Donc l'algorithme d'Uzawa est

$$\begin{aligned} \mathcal{L}(u^n, p^n) &= \inf_{v \in V} \mathcal{L}(v, p^n) = \mathcal{G}(p^n) \\ p^{n+1} &= P_{\mathbb{R}_+^M}(p^n + \mu \mathcal{G}'(p^n)) \end{aligned}$$

l'algorithme du gradient projeté pour maximiser le dual !



# Algorithme d'Uzawa (5)

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

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

que l'ensemble  $\{F(v) \leq 0\}$  est non vide et que les contraintes sont qualifiées en l'unique point de minimum  $u$  de  $J$  sous les contraintes  $F \leq 0$ . Si  $0 < \mu < 2\alpha/L^2$ , alors l'algorithme d'Uzawa converge :  $\forall p^0 \in (\mathbb{R}_+)^M$ , la suite  $(u^n)$  converge vers  $u$ .

**Lemme (technique).** Si  $J_1$  et  $J_2$  sont deux fonctions convexes dont seule  $J_1$  est différentiable, alors la condition d'optimalité (nécessaire et suffisante) pour que  $u$  soit un minimum de  $J_1 + J_2$  sur un convexe fermé  $K$  est

$$\langle J'_1(u), v - u \rangle + J_2(v) - J_2(u) \geq 0 \quad \text{pour tout } v \in K.$$



# Algorithme d'Uzawa (6)

**Preuve du théorème.** On applique le lemme à  $J$  et  $F$  pour  $u$  et  $u^n$  (avec leurs multiplicateurs de Lagrange  $p$  et  $p^n$ )

$$(1) \quad \langle J'(u), v - u \rangle + p \cdot (F(v) - F(u)) \geq 0 \quad \forall v \in V$$

$$(2) \quad \langle J'(u^n), v - u^n \rangle + p^n \cdot (F(v) - F(u^n)) \geq 0 \quad \forall v \in V$$

On prend  $v = u^n$  dans (1) et  $v = u$  dans (2) et on additionne

$$\langle J'(u) - J'(u^n), u^n - u \rangle + (p - p^n) \cdot (F(u^n) - F(u)) \geq 0,$$

d'où par  $\alpha$ -convexité de  $J$  et en posant  $r^n = p^n - p$

$$r^n \cdot (F(u^n) - F(u)) \leq -\alpha \|u^n - u\|^2.$$

D'autre part, on soustrait

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

la projection  $P_{\mathbb{R}_+^M}$  étant faiblement contractante, on obtient

$$\|r^{n+1}\| \leq \|r^n + \mu(F(u^n) - F(u))\|$$



# Algorithme d'Uzawa (7)

En développant

$$\|r^{n+1}\| \leq \|r^n + \mu(F(u^n) - F(u))\|$$

on obtient

$$\|r^{n+1}\|^2 \leq \|r^n\|^2 + 2\mu r^n \cdot (F(u^n) - F(u)) + \mu^2 \|F(u^n) - F(u)\|^2.$$

Utilisant  $r^n \cdot (F(u^n) - F(u)) \leq -\alpha \|u^n - u\|^2$ , il vient

$$\|r^{n+1}\|^2 \leq \|r^n\|^2 + (L^2\mu^2 - 2\mu\alpha) \|u^n - u\|^2.$$

Si  $0 < \mu < 2\alpha/L^2$ , alors  $2\mu\alpha - L^2\mu^2 > 0$ , d'où

$$0 < (2\mu\alpha - L^2\mu^2) \|u^n - u\|^2 \leq \|r^n\|^2 - \|r^{n+1}\|^2.$$

Ainsi la suite  $\|r^n\|^2$  est décroissante, minorée, donc convergente, ce qui entraîne que  $u^n$  tend vers  $u$ .

# Preuve du lemme technique

Comme  $K$  est convexe,  $u + \theta(v - u) \in K$  pour  $0 \leq \theta \leq 1$ , et  $u$  minimum est équivalent

$$J_1(u + \theta(v - u)) + J_2(u + \theta(v - u)) \geq J_1(u) + J_2(u).$$

On fait un développement de Taylor pour  $J_1$  et on utilise la convexité pour  $J_2$

$$J_1(u) + \theta \langle J_1'(u), v - u \rangle + o(\theta) + (1 - \theta)J_2(u) + \theta J_2(u) \geq J_1(u) + J_2(u).$$

On élimine les termes de droite et on divise par  $\theta \rightarrow 0$

$$(1) \quad \langle J_1'(u), v - u \rangle + J_2(v) - J_2(u) \geq 0$$

Réciproquement, (1)  $\Rightarrow u$  minimum de  $J_1 + J_2$  par convexité de  $J_1$

$$J_1(v) - J_1(u) \geq \langle J_1'(u), v - u \rangle$$



### 3 - Pénalisation des contraintes

Par exemple, on remplace

$$(P) \quad \inf_{v \in \mathbb{R}^N, F(v) \leq 0} J(v)$$

par

$$(P_\varepsilon) \quad \inf_{v \in \mathbb{R}^N} \left( J(v) + \frac{1}{\varepsilon} \sum_{i=1}^M [\max(F_i(v), 0)]^2 \right).$$

où on a **pénalisé** les contraintes avec un petit paramètre  $\varepsilon > 0$ .  
On utilise ensuite un algorithme sans contrainte.

**Proposition.** Soit  $J$  continue, strictement convexe, infinie à l'infini, et  $F(v)$  convexe, continue, avec  $K = \{F(v) \leq 0\}$  non vide. Alors la suite des solutions  $u_\varepsilon$  du problème pénalisé  $(P_\varepsilon)$  converge vers l'unique solution  $u$  du problème  $(P)$  quand  $\varepsilon \rightarrow 0$ .



## Pénalisation des contraintes (2)

**Preuve.** Solutions uniques  $u$  pour  $(P)$  et  $u_\varepsilon$  pour  $(P_\varepsilon)$ . Soit

$$G(v) = \sum_{i=1}^M [\max(F_i(v), 0)]^2 \quad \text{et} \quad J_\varepsilon(v) = J(v) + \frac{G(v)}{\varepsilon}$$

Comme  $G(u) = 0$ , on a

$$(1) \quad J(u_\varepsilon) \leq J_\varepsilon(u_\varepsilon) \leq J_\varepsilon(u) = J(u).$$

Donc  $u_\varepsilon$  est borné dans  $\mathbb{R}^N$  car  $J$  est infinie à l'infini. Une sous-suite  $u_\varepsilon$  converge vers une limite  $u_*$ . Or  $0 \leq G(u_\varepsilon) \leq \varepsilon(J(u) - J(u_\varepsilon))$  donc  $G(u_*) = 0$ , et  $F(u_*) \leq 0$ . Comme (1) implique  $J(u_*) \leq J(u)$ , on en déduit  $u_* = u$  et toute la suite converge.

**Remarque.** Si en plus on suppose une condition de qualification pour les contraintes de  $(P)$  alors on peut montrer la convergence des multiplicateurs de Lagrange

$$\lim_{\varepsilon \rightarrow 0} \left[ \frac{2}{\varepsilon} \max(F_i(u_\varepsilon), 0) \right] = \lambda_i.$$

# Pénalisation des contraintes (3)

## Quelques remarques d'ordre pratique.

- Très facile à mettre en oeuvre !
- En général, on applique une **méthode de continuation**, c'est-à-dire que la valeur de  $\varepsilon > 0$  est diminuée au cours des itérations.
- Malgré cela, cette méthode de pénalisation souffre d'un problème numérique de **conditionnement** quand  $\varepsilon$  est petit.
- On peut appliquer la même technique à des contraintes d'égalité.

# Pénalisation des contraintes (4)

La technique précédente était une **pénalisation extérieure**, c'est-à-dire que les solutions pénalisées ne vérifient pas les contraintes (sauf à convergence  $\varepsilon \rightarrow 0$ ).

Une approche opposée est de procéder à une **pénalisation intérieure**. Pour  $\varepsilon > 0$ , on considère

$$\inf_{v \in \mathbb{R}^N, F(v) < 0} \left( J(v) - \varepsilon \sum_{i=1}^M \frac{1}{F_i(v)} \right)$$

où le deuxième terme est appelée une **fonction barrière** qui empêche  $F(v)$  de s'approcher de 0. Les contraintes d'inégalité sont toujours inactives ! **C'est un algorithme faisable.**

Cela nécessite de connaître une initialisation qui vérifie  $F(v) < 0$ .



## 4 - Algorithme du Lagrangien augmenté

**Idée:** combiner les avantages des méthodes de pénalisation et celles à base de Lagrangien (type Uzawa).

Soit un problème de minimisation avec contraintes d'égalité

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

où  $J : \mathbb{R}^N \rightarrow \mathbb{R}$  et  $F : \mathbb{R}^N \rightarrow \mathbb{R}^M$  sont de classe  $C^1$ . Pour  $\mu > 0$  c'est équivalent à

$$\inf_{F(v)=0} J(v) + \frac{\mu}{2} \|F(v)\|^2$$

Pour  $v \in \mathbb{R}^N$ ,  $\lambda \in \mathbb{R}^M$ ,  $\mu > 0$ , on définit le **Lagrangien augmenté**

$$\mathcal{L}_{aug}(v, \lambda, \mu) = J(v) + \lambda \cdot F(v) + \frac{\mu}{2} \|F(v)\|^2$$

où  $\lambda$  est un multiplicateur de Lagrange.

**Remarque.**  $\mu \neq 1/\varepsilon$  car  $\mu$  ne sera pas très grand en pratique !



# Algorithme du Lagrangien augmenté (2)

## Principe de l'algorithme:

- Pour  $\mu$  fixé, on calcule un point selle de  $\mathcal{L}_{aug}(v, \lambda, \mu)$ .
- On utilise une **nouvelle formule** de mise à jour du multiplicateur de Lagrange  $\lambda$ .

Soit  $v^n$  le point de minimum de  $v \rightarrow \mathcal{L}_{aug}(v, \lambda^n, \mu)$ . On a

$$J'(v^n) + \lambda^n \cdot F'(v^n) + \mu F(v^n) \cdot F'(v^n) = 0.$$

Si  $v^n$  était la **vraie** solution, elle vérifierait la condition d'optimalité

$$J'(v^n) + \lambda^* \cdot F'(v^n) = 0.$$

Par comparaison, si  $\text{rg} F'(v^n) = M$ , on obtient

$$\lambda^* = \lambda^n + \mu F(v^n).$$





# Algorithme du Lagrangien augmenté (3)

**Algorithme du Lagrangien augmenté:** on choisit  $\mu > 0$ ,  $\lambda_0 \in \mathbb{R}^M$  et pour  $n \geq 0$  e

$$\mathcal{L}_{aug}(v^n, \lambda^n, \mu) = \min_{v \in \mathbb{R}^N} \mathcal{L}_{aug}(v, \lambda^n, \mu),$$

$$\lambda^{n+1} = \lambda^n + \mu F(v^n).$$

De temps en temps, on augmente  $\mu$  mais il n'est pas nécessaire d'avoir  $\mu$  très grand (voir polycopié).

Remarques:

- ça ressemble à Uzawa mais la convergence est plus rapide,
- ça ressemble à la pénalisation mais c'est plus robuste.



## 5 - 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:** pour  $n \geq 0$

- 1 Définir des approximations  $J^n(v)$  et  $F^n(v)$  au voisinage de  $v^n$ .
- 2 Calcul de  $v^{n+1}$  comme solution de

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

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

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 (voir le chapitre suivant).

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 !



# Programmation quadratique séquentielle (SQP) (2)

Expliquons pourquoi c'est la **Hessienne du Lagrangien** et pas de  $J$  qui apparaît. On a

$$(1) \quad J(v) \approx J(v^*) + J'(v^*) \cdot (v - v^*) + \frac{1}{2} J''(v^*) (v - v^*) \cdot (v - v^*)$$

$$(2) \quad F(v) \approx F(v^*) + F'(v^*) \cdot (v - v^*) + \frac{1}{2} F''(v^*) (v - v^*) \cdot (v - v^*)$$

On multiplie (2) par le multiplicateur de Lagrange  $\lambda^*$  et, comme  $F(v) = 0$ , on somme le résultat à (1), ce qui donne l'approximation (SQP), à une constante près, en utilisant la contrainte linéaire.

**Remarque.** La condition d'optimalité d'ordre 2 affirme que  $J''(v^*) + \lambda^* \cdot F''(v^*) \geq 0$  (et pas que  $J''(v^*) \geq 0$  !).



# Remarques sur les approximations successives

- Algorithmes très efficaces pour SLP et SQP (nombreux logiciels: AMPL, IpOpt, Knitro,...).
- Valable pour des contraintes d'égalité et d'inégalité.
- La variable  $d = -(v - v^n)$  est une **direction de descente**.  
Donc on peut coupler cette approche avec une recherche de pas  $\mu > 0$ .  
Plutôt que de poser

$$v^{n+1} = v^n - d^n$$

on adapte le pas  $\mu > 0$  pour garantir la décroissance de  $J$  et la satisfaction des contraintes

$$v^{n+1} = v^n - \mu d^n$$



## 6 - Quelques algorithmes utilisant la structure du problème

Le **but du jeu** est de montrer l'importance de la **modélisation** et de savoir bien utiliser la **structure des modèles** pour développer des algorithmes d'optimisation efficaces.

Trois exemples (parmi d'autres):

- 1 Fonctions composées et rétro-propagation du gradient.
- 2 Optimisation sous contrainte de modèle et état adjoint.
- 3 Décomposition-coordination.

L'idée n'est pas de rentrer dans les détails mais d'expliquer des idées originales.



# Algorithme de la rétro-propagation du gradient

On minimise sans contrainte une fonction objectif  $J$ , composée de  $m$  fonctions différentiables,

$$\inf_{v \in \mathbb{R}^N} J(v) = J_m \circ J_{m-1} \circ \cdots \circ J_1(v),$$

avec  $J_i(v_i) : \mathbb{R}^{N_i} \mapsto \mathbb{R}^{N_{i+1}}$ ,  $1 \leq i \leq m$ , et  $N_1 = N$  et  $N_{m+1} = 1$ .

**Motivation:** deux applications importantes.

- 1 Réseaux de neurones profonds en intelligence artificielle.
- 2 Différentiation automatique de programmes informatiques.



# Algorithme de la rétro-propagation du gradient

**Lemme (dérivation composée).** On note  $v_i = J_{i-1} \circ \dots \circ J_1(v)$  pour  $2 \leq i \leq m$  et  $v_1 = v$ . La fonction  $J(v) = J_m \circ J_{m-1} \circ \dots \circ J_1(v)$  est différentiable au sens de Fréchet en tout  $v \in \mathbb{R}^N$  et vérifie pour tout  $h \in \mathbb{R}^N$

$$J(v+h) = J(v) + J'_m(v_m) \cdot (J'_{m-1}(v_{m-1}) \cdots J'_1(v_1)h) + o(h),$$

où  $J'_i(v_i)$  est une matrice  $N_{i+1} \times N_i$ , pour  $1 \leq i \leq m-1$ .

**Preuve:** classique, voir le polycopié.

Formule utile pour calculer la **dérivée directionnelle**  $J'(v) \cdot h$  (dans le même ordre que l'on calcule  $J(v)$ ).

Mais comment calculer le gradient complet  $J'(v)$  autrement qu'en faisant  $N$  calculs avec  $h = e_i$ ,  $1 \leq i \leq N$  ?

**Remarque (cruciale):**  $J'_m(v_m)$  est un vecteur (ligne) car l'espace d'arrivée de  $J_m$  est  $\mathbb{R}$ .



# Algorithme de la rétro-propagation du gradient

On se propose de calculer autrement le gradient  $J'(v)$ . Pour cela, on transpose les matrices gradients en passant de (1) à (2)

$$(1) \quad J'(v) \cdot h = J'_m(v_m) \cdot \left( J'_{m-1}(v_{m-1}) \cdots J'_1(v_1) h \right)$$

$$(2) \quad J'(v) \cdot h = \left( J'_1(v_1)^* J'_2(v_2)^* \cdots J'_{m-1}(v_{m-1})^* J'_m(v_m) \right) \cdot h$$

Autrement dit, on vient de trouver une **formule explicite**

$$J'(v) = J'_1(v_1)^* J'_2(v_2)^* \cdots J'_{m-1}(v_{m-1})^* J'_m(v_m),$$

où on a juste interprété  $J'_m(v_m)$  comme un vecteur colonne.

L'algorithme de **rétro-propagation du gradient** est donc l'algorithme du gradient à pas fixe avec cette formule du gradient.

**Rétro-propagation:** on part du dernier gradient que l'on multiplie par les gradients transposés dans l'ordre **décroissant** des indices.



# Optimisation sous contrainte de modèle et état adjoint

Soit une fonction objectif  $J(v, y)$ ,  $C^1$  de  $\mathbb{R}^N \times \mathbb{R}^M$  dans  $\mathbb{R}$ , et une **contrainte de modèle**  $Ay = b(v)$  où  $A$  est une matrice inversible  $M \times M$  et  $b(v)$  est une fonction  $C^1$  de  $\mathbb{R}^N$  dans  $\mathbb{R}^M$ . On considère

$$\inf_{v \in \mathbb{R}^N, y \in \mathbb{R}^M \text{ tel que } Ay = b(v)} J(v, y).$$

**Motivation:**  $v = \text{variables d'optimisation}$ ,  $y = \text{état}$  donné par le modèle (EDO, EDP, voir plus tard la théorie du contrôle).

On peut éliminer  $y(v) = A^{-1}b(v)$

$$\tilde{J}(v) = J(v, A^{-1}b(v))$$

**Lemme.** Pour tout  $h \in \mathbb{R}^N$ , on a

$$\tilde{J}'(v) \cdot h = \frac{\partial J}{\partial v}(v, A^{-1}b(v)) \cdot h + \left\langle \frac{\partial J}{\partial y}(v, A^{-1}b(v)), A^{-1}b'(v) \cdot h \right\rangle,$$

où  $\langle, \rangle$  désigne le produit scalaire de  $\mathbb{R}^M$ .



$$\tilde{J}'(v) \cdot h = \frac{\partial J}{\partial v}(v, A^{-1}b(v)) \cdot h + \left\langle \frac{\partial J}{\partial y}(v, A^{-1}b(v)), A^{-1}b'(v) \cdot h \right\rangle$$

Si on veut utiliser cette formule pour calculer  $\tilde{J}'(v)$ , il faut calculer  $A^{-1}b'(v) \cdot h$  en faisant  $N$  résolutions de système linéaire avec  $h = e_i$ ,  $1 \leq i \leq N$ . **Trop cher !**

**Méthode adjointe.** On introduit l'état adjoint  $p \in \mathbb{R}^M$  solution de

$$A^*p = \frac{\partial J}{\partial y}(v, A^{-1}b(v)).$$

Alors on obtient  $\tilde{J}'(v) = \frac{\partial J}{\partial v}(v, A^{-1}b(v)) + \langle p, b'(v) \rangle$  car

$$\left\langle \frac{\partial J}{\partial y}(v, y), A^{-1}b'(v) \cdot h \right\rangle = \left\langle (A^*)^{-1} \frac{\partial J}{\partial y}(v, y), b'(v) \cdot h \right\rangle$$

Un seul système linéaire à résoudre pour  $p$  !



On considère un problème d'optimisation sous contraintes d'égalité

$$(1) \quad \inf_{v \in \mathbb{R}^N, F(v)=F_0} J(v),$$

avec  $J : \mathbb{R}^N \mapsto \mathbb{R}$ ,  $F : \mathbb{R}^N \mapsto \mathbb{R}^M$  et  $F_0 \in \mathbb{R}^M$  un niveau fixé de contrainte. On suppose que le problème est **décomposable**, au sens où  $v = (v_1, \dots, v_n)$ , avec  $v_i \in \mathbb{R}^{n_i}$  et  $\sum_{i=1}^n n_i = N$ ,

$$J(v) = \sum_{i=1}^n J_i(v_i) \quad \text{et} \quad F(v) = \sum_{i=1}^n F_i(v_i).$$

Donc le problème (1) est équivalent à

$$\inf_{v_i \in \mathbb{R}^{n_i}} \sum_{i=1}^n J_i(v_i) \quad \text{sous la contrainte} \quad \sum_{i=1}^n F_i(v_i) = F_0.$$



# Algorithme de décomposition par les prix

Pour  $p \in \mathbb{R}^M$  et  $v \in \mathbb{R}^N$ , on introduit le Lagrangien

$$\mathcal{L}(v, p) = J(v) + p \cdot (F(v) - F_0) = \sum_{i=1}^n (J_i(v_i) + p \cdot F_i(v_i)) - p \cdot F_0.$$

L'algorithme d'Uzawa, pour une initialisation  $p_0 \in \mathbb{R}^M$ , construit les suites  $(u^k)$  et  $(p^k)$ , pour  $k \geq 0$ , et un pas  $\mu > 0$ ,

$$\mathcal{L}(u^k, p^k) = \inf_{v \in \mathbb{R}^N} \mathcal{L}(v, p^k),$$

$$p^{k+1} = p^k + \mu(F(u^k) - F_0).$$

L'hypothèse de décomposition rend la minimisation du Lagrangien très facile car  $u^k = (u_1^k, \dots, u_n^k)$ , avec  $u_i^k$  solution de

$$J_i(u_i^k) + p^k \cdot F_i(u_i^k) = \inf_{v_i \in \mathbb{R}^{n_i}} (J_i(v_i) + p^k \cdot F_i(v_i)).$$

Chacun de ces problèmes est de plus petite taille et indépendant des autres.

On l'appelle algorithme de **décomposition par les prix**.



# Interprétation de la décomposition par les prix

- Une entreprise doit produire une quantité  $F_0$  de biens.
- Elle a  $n$  unités, indicées par  $i$ , qui a ses propres variables de production  $v_i$ .
- Chaque unité a un coût de production  $J_i(v_i)$  et produit une quantité  $F_i(v_i)$ .

**Algorithme de décomposition par les prix:** on itère en  $k$

- 1 La direction de l'entreprise prédit un **prix des biens**  $-p^k$ .
- 2 Chaque unité optimise son **gain**

$$\inf_{v_i \in \mathbb{R}^{n_i}} \left( J_i(v_i) + p^k \cdot F_i(v_i) \right)$$

qui est le coût de production moins le prix de vente fois la quantité produite.

- 3 A l'itération suivante l'entreprise **ajuste ses prix**  $-p^{k+1}$  pour produire la quantité requise  $F_0$ .

