

# Optimisation

Fabrice Rossi

Décembre 2009/Janvier 2010

## Plan

## Table des matières

<b>1 Résultats théoriques</b>	<b>1</b>
1.1 Introduction . . . . .	1
1.2 Existence et unicité . . . . .	2
1.3 Conditions d'optimalité . . . . .	2
1.4 Dualité . . . . .	6
1.5 Second ordre . . . . .	7
<b>2 Algorithmes</b>	<b>8</b>
2.1 Introduction . . . . .	8
2.2 Gradient . . . . .	9
2.3 Pénalisation . . . . .	9
2.4 Dualité . . . . .	11

## 1 Résultats théoriques

### 1.1 Introduction

#### Forme générale

- un problème d'optimisation ( $\mathcal{P}$ ) est défini par

$$\begin{aligned} & \text{minimiser sur } \mathbb{R}^n && J(\mathbf{x}) \\ & \text{avec} && h_i(\mathbf{x}) = 0, 1 \leq i \leq p \\ & && g_j(\mathbf{x}) \leq 0, 1 \leq j \leq q \end{aligned}$$

- rappel de vocabulaire :
  - les  $h_i$  sont les **contraintes d'égalité** (notées  $\mathbf{h}(\mathbf{x}) = 0$ )
  - les  $g_j$  sont les **contraintes d'inégalité** (notées  $\mathbf{g}(\mathbf{x}) \leq 0$ )
  - l'**ensemble des contraintes** est

$$\mathcal{C} = \{\mathbf{x} \in \mathbb{R}^n | h_i(\mathbf{x}) = 0, 1 \leq i \leq p \text{ et } g_j(\mathbf{x}) \leq 0, 1 \leq j \leq q\}$$

**ensemble des points admissibles** ou **réalisables**

#### Conséquences

- les contraintes changent les conditions d'optimalité
- exemple :
  - $J(x, y) = x^2 + y^2$  à minimiser sous la contrainte  $g(x, y) = 4 - x^2 - y^2 \leq 0$
  - sur  $\mathbb{R}^2$ , on étudierait  $\nabla J = 2(x, y)^T$
  - mais ici, le minimum vaut 4 et est atteint sur le cercle  $x^2 + y^2 = 4$  sur lequel  $\nabla J \neq \mathbf{0}$

- mais pas toujours :
  - $J(x, y) = x^2 + y^2$  à minimiser sous la contrainte  $g(x, y) = x^2 + y^2 - 4 \leq 0$
  - le minimum est atteint en  $(0, 0)$ , avec  $\nabla J = \mathbf{0}$
- les contraintes doivent donc apparaître dans les conditions d'optimalité

## 1.2 Existence et unicité

### Existence d'un minimum

- cas général :  $(\mathcal{P}) : \min J(\mathbf{x}), \mathbf{x} \in \mathcal{C} \subset \mathbb{R}^n$
- on suppose :
  - $J$  continue
  - et  $\mathcal{C}$  fermé et non vide
- alors :
  - si :
    - $\mathcal{C}$  est borné
    - ou si  $J$  est coercitive
  - alors  $(\mathcal{P})$  admet au moins une solution

---

### Notes

---

Preuve :

- si  $\mathcal{C}$  est borné, c'est un résultat classique
  - sinon, on procède comme en l'absence de contraintes : on montre que le minimum est atteint en toute valeur d'adhérence de la suite minimisante et qu'il y a au moins une valeur d'adhérence
- 

### Existence et unicité

- remarque : si

$$\mathcal{C} = \{\mathbf{x} \in \mathbb{R}^n \mid h_i(\mathbf{x}) = 0, 1 \leq i \leq p \text{ et } g_j(\mathbf{x}) \leq 0, 1 \leq j \leq q\}$$

- avec des  $h_i$  et  $g_j$  continues, alors  $\mathcal{C}$  est fermé
- si  $J$  est strictement convexe et  $\mathcal{C}$  est convexe, alors  $(\mathcal{P})$  admet **au plus** une solution
- problème convexe :
  - $J$  est convexe
  - les  $h_i$  sont affines
  - les  $g_j$  sont convexes
  - et donc  $\mathcal{C}$  est convexe

---

### Notes

---

- pour la remarque :  $\mathcal{C}$  est l'intersection d'images réciproques de fermés par des applications continues
  - pour le cas convexe : déjà vu dans la situation sans contrainte
- 

## 1.3 Conditions d'optimalité

### Condition du premier ordre

- si  $J$  est Gâteaux-différentiable en  $x^*$  solution de  $(\mathcal{P})$  et si  $\mathcal{C}$  est convexe, alors :

$$\forall \mathbf{x} \in \mathcal{C}, \langle \nabla J(\mathbf{x}^*), \mathbf{x} - \mathbf{x}^* \rangle \geq 0$$

- remarques :
  - intuitivement : on ne peut s'éloigner du minimum que dans une direction de montée
  - généralisable : notion de direction admissible
  - si  $\mathbf{x}^*$  est un point intérieur de  $\mathcal{C}$  alors  $\nabla J(\mathbf{x}^*) = 0$
  - si  $J$  est convexe la condition est nécessaire et suffisante

---

### Notes

---

- on peut généraliser la condition nécessaire à  $\mathcal{C}$  non convexe grâce à la notion de direction admissible : intuitivement, il s'agit des directions qui restent dans  $\mathcal{C}$  en partant de  $\mathbf{x}^*$ .
- preuve :
  - si  $J$  est Gâteaux-différentiable, pour tout  $\mathbf{h}$  et  $t > 0$

$$J(\mathbf{x}^* + t\mathbf{h}) = J(\mathbf{x}^*) + t \langle \nabla J(\mathbf{x}^*), \mathbf{h} \rangle + o(t)$$

- la convexité de  $\mathcal{C}$  permet d'assurer que si  $\mathbf{x}$  et  $\mathbf{x}^*$  sont dans  $\mathcal{C}$ , alors  $\mathbf{x}^* + t\mathbf{h}$  est aussi dans  $\mathcal{C}$  si  $t \in [0, 1]$  et  $\mathbf{h} = \mathbf{x} - \mathbf{x}^*$ .
- on a alors

$$t \langle \nabla J(\mathbf{x}^*), \mathbf{x} - \mathbf{x}^* \rangle + o(t) \geq 0$$

ce qui donne le résultat par passage à la limite

- cas convexe : il suffit d'utiliser la caractérisation de la convexité à l'ordre un

$$J(\mathbf{x}) \geq J(\mathbf{x}^*) + \langle \nabla J(\mathbf{x}^*), \mathbf{x} - \mathbf{x}^* \rangle$$


---

### Égalités et inégalités

- Conditions nécessaires non qualifiées
- cas particulier  $h_i(\mathbf{x}) = 0$  et  $g_j(\mathbf{x}) \leq 0$  où tout est  $C^1$  ( $J$  inclus)
- soit  $\mathbf{x}^*$  une solution de  $(\mathcal{P})$ , alors il existe  $\boldsymbol{\lambda}^* = (\lambda_1^*, \dots, \lambda_p^*)$  et  $\boldsymbol{\mu}^* = (\mu_0^*, \mu_1^*, \dots, \mu_q^*)$  tels que
  - $(\boldsymbol{\lambda}^*, \boldsymbol{\mu}^*) \neq \mathbf{0}$
  - $h_i(\mathbf{x}^*) = 0$ ,  $1 \leq i \leq p$  (admissibilité en égalité)
  - $g_j(\mathbf{x}^*) \leq 0$ ,  $1 \leq j \leq q$  (admissibilité en inégalité)
  - $\mu_j^* \geq 0$ ,  $0 \leq j \leq q$
  - $\mu_j^* g_j(\mathbf{x}^*) = 0$ ,  $1 \leq j \leq q$  (**conditions de complémentarité**)
  - et

$$\mu_0^* \nabla J(\mathbf{x}^*) + \sum_{i=1}^p \lambda_i^* \nabla h_i(\mathbf{x}^*) + \sum_{j=1}^q \mu_j^* \nabla g_j(\mathbf{x}^*) = 0$$

---

### Notes

---

Preuve :

- on considère  $(\mathcal{P}_k)$  le problème de minimisation sur  $\mathcal{B}(\mathbf{x}^*, \rho)$  (boule fermée) de

$$J_k(\mathbf{x}) = J(\mathbf{x}) + \frac{k}{2} \sum_{i=1}^p h_i(\mathbf{x})^2 + \frac{k}{2} \sum_{j=1}^q g_j^+(\mathbf{x})^2 + \|\mathbf{x}^* - \mathbf{x}\|^2,$$

avec  $g_j^+(\mathbf{x}) = \max(0, g_j(\mathbf{x}))$

- idées de la preuve :
  - se ramener à un problème sans contrainte
  - s'arranger pour que la solution de ce problème soit proche de celle de  $(\mathcal{P})$
  - principe de pénalisation : une violation des contraintes augmente la fonction objectif
  - $J_k$  est  $C^1$  :

- on définit  $l(u) = \max(0, u)^2$ . Il est clair que  $l$  est  $C^1$  en dehors de 0, avec  $l'(u) = 0$  pour  $u < 0$  et  $l'(u) = 2u$  pour  $u > 0$
- en 0, on a

$$|l(h) - l(0)| \leq h^2,$$

et donc  $l'(0) = 0$ , ce qui achève de montrer que  $l$  est  $C^1$  sur  $\mathbb{R}$ . En outre, on a

$$l'(u) = 2 \max(0, u)$$

- $J_k$  est donc clairement  $C^1$  et on a

$$\nabla (g_j^+(\mathbf{x})^2) = 2g_j^+(\mathbf{x})\nabla g_j(\mathbf{x})$$

- comme  $J_k$  est continue sur le compact  $\mathcal{B}(\mathbf{x}^*, \rho)$ , elle y atteint son minimum en  $\mathbf{x}_k$ . On montre alors que  $\lim_{k \rightarrow \infty} \mathbf{x}_k = \mathbf{x}^*$  :
  - par hypothèse

$$J_k(\mathbf{x}_k) \leq J_k(\mathbf{x}^*) = J(\mathbf{x}^*),$$

et donc

$$\frac{J(\mathbf{x}_k)}{k} + \frac{1}{2} \sum_{i=1}^p h_i(\mathbf{x}_k)^2 + \frac{1}{2} \sum_{j=1}^q g_j^+(\mathbf{x}_k)^2 + \frac{\|\mathbf{x}^* - \mathbf{x}_k\|^2}{k} \leq \frac{J(\mathbf{x}^*)}{k}$$

- soit  $\mathbf{u}^*$  une valeur d'adhérence de  $(\mathbf{x}_k)_k$ . En passant à la limite sur  $k$  sur la suite extraite dans la majoration au dessus, on a

$$\frac{1}{2} \sum_{i=1}^p h_i(\mathbf{u}^*)^2 + \frac{1}{2} \sum_{j=1}^q g_j^+(\mathbf{u}^*)^2 \leq 0,$$

et donc  $\mathbf{u}^* \in \mathcal{C}$ .

- comme

$$J(\mathbf{x}_k) + \|\mathbf{x}^* - \mathbf{x}_k\|^2 \leq J(\mathbf{x}^*),$$

on a

$$J(\mathbf{u}^*) + \|\mathbf{x}^* - \mathbf{u}^*\|^2 \leq J(\mathbf{x}^*),$$

et donc  $\|\mathbf{x}^* - \mathbf{u}^*\|^2 = 0$ , ce qui donne la conclusion.

- pour  $k$  suffisamment grand,  $\mathbf{x}_k$  est dans la boule ouverte  $\mathcal{B}(\mathbf{x}^*, \rho)$ , et on peut donc utiliser l'équation d'Euler, ce qui donne

$$\nabla J(\mathbf{x}_k) + k \sum_{i=1}^p h_i(\mathbf{x}_k) \nabla h_i(\mathbf{x}_k) + k \sum_{j=1}^q g_j^+(\mathbf{x}_k) \nabla g_j(\mathbf{x}_k) + 2(\mathbf{x}^* - \mathbf{x}_k) = 0$$

- on pose

$$s_k = \sqrt{1 + k^2 \sum_{i=1}^p h_i(\mathbf{x}_k)^2 + k^2 \sum_{j=1}^q g_j^+(\mathbf{x}_k)^2},$$

et on divise l'équation précédente par  $s_k$ . On pose

$$\begin{aligned} \mu_0^k &= \frac{1}{s_k}, \\ \mu_i^k &= \frac{k g_j^+(\mathbf{x}_k)}{s_k}, \\ \lambda_i^k &= \frac{k h_i(\mathbf{x}_k)}{s_k}. \end{aligned}$$

- Les vecteurs  $(\boldsymbol{\lambda}^k, \boldsymbol{\mu}^k)^T$  sont de norme 1 et on peut donc considérer une valeur d'adhérence  $(\boldsymbol{\lambda}^*, \boldsymbol{\mu}^*)^T$  de la suite. En passant à la limite, on obtient

$$\mu_0^* \nabla J(\mathbf{x}^*) + \sum_{i=1}^p \lambda_i^* \nabla h_i(\mathbf{x}^*) + \sum_{j=1}^q \mu_j^* \nabla g_j(\mathbf{x}^*) = 0.$$

- En outre :
    - $(\boldsymbol{\lambda}^*, \boldsymbol{\mu}^*)^T$  est de norme 1, donc les coefficients ne sont pas tous nuls.
    - $\mu_i^k \geq 0$  et donc  $\mu_i^* \geq 0$ .
    - si  $g_j(\mathbf{x}^*) < 0$ ,  $g_j(\mathbf{x}_k^*) < 0$  à partir d'un certain rang et donc  $\mu_i^k = 0$ , puis  $\mu_i^* = 0$ .
- 

### Qualification

- condition utile si  $\mu_0 \neq 0$
- problème de *qualification* des contraintes :
  - conditions (locales) sur le problème qui garantissent que  $\mu_0 \neq 0$
  - très nombreuses variantes plus ou moins sophistiquées
- *contrainte active* :  $g_j$  est **active** (ou saturée) en  $\mathbf{x}^*$  si  $g_j(\mathbf{x}^*) = 0$ ;  $I(\mathbf{x}^*)$ , ensemble des indices des contraintes actives en  $\mathbf{x}^*$
- *régularité* :  $\mathbf{x}^*$  est régulier pour  $\mathbf{g}$  et  $\mathbf{h}$  si
  - $\mathbf{x}^*$  est admissible
  - les  $\nabla h_i(\mathbf{x}^*)$  sont linéairement indépendants
  - il existe  $d \neq 0$  tel que  $\langle \nabla h_i(\mathbf{x}^*), d \rangle = 0$  pour tout  $i$  et  $\langle \nabla g_j(\mathbf{x}^*), d \rangle < 0$  pour tout  $j \in I(\mathbf{x}^*)$  (ou  $\langle \nabla g_j(\mathbf{x}^*), d \rangle = 0$  si  $g_j$  est affine)
  - régularité de Mangasarian-Fromowitz

### Conditions qualifiées

- Conditions nécessaires qualifiées du 1er ordre de KKT (*Karush, Kuhn et Tucker*)
- Hypothèses :
  - $J$ ,  $\mathbf{h}$  et  $\mathbf{g}$   $C^1$
  - $\mathbf{x}^*$  solution de  $(\mathcal{P})$
  - $\mathbf{x}^*$  est régulier pour  $\mathbf{g}$  et  $\mathbf{h}$
- Alors il existe  $\boldsymbol{\lambda}^* = (\lambda_1^*, \dots, \lambda_p^*)$  et  $\boldsymbol{\mu}^* = (\mu_1^*, \dots, \mu_q^*)$  tels que
  - $h_i(\mathbf{x}^*) = 0$ ,  $1 \leq i \leq p$
  - $g_j(\mathbf{x}^*) \leq 0$ ,  $1 \leq j \leq q$
  - $\mu_j^* \geq 0$ ,  $1 \leq j \leq q$
  - $\mu_j^* g_j(\mathbf{x}^*) = 0$ ,  $1 \leq j \leq q$
  - et

$$\nabla J(\mathbf{x}^*) + \sum_{i=1}^p \lambda_i^* \nabla h_i(\mathbf{x}^*) + \sum_{j=1}^q \mu_j^* \nabla g_j(\mathbf{x}^*) = 0$$

---

### Notes

---

Preuve :

- par l'absurde à partir des conditions non qualifiées

$$\mu_0^* \nabla J(\mathbf{x}^*) + \sum_{i=1}^p \lambda_i^* \nabla h_i(\mathbf{x}^*) + \sum_{j=1}^q \mu_j^* \nabla g_j(\mathbf{x}^*) = 0$$

- on suppose  $\mu_0^* = 0$  :
  - alors au moins un des  $\mu_j^*$  pour  $j \geq 1$  est non nul car sinon  $\sum_{i=1}^p \lambda_i^* \nabla h_i(\mathbf{x}^*) = 0$  et donc  $\boldsymbol{\lambda}^* = \mathbf{0}$  par indépendance

- comme  $\mu_j^* g_j(\mathbf{x}^*) = 0$ , l'indice du  $\mu_{j_0} \neq 0$  est dans  $I(\mathbf{x}^*)$
- mais alors

$$\begin{aligned} \sum_{i=1}^p \lambda_i^* \langle \nabla h_i(\mathbf{x}^*), d \rangle + \sum_{j=1}^q \mu_j^* \langle \nabla g_j(\mathbf{x}^*), d \rangle &= 0 \\ &\leq \mu_{j_0}^* \langle \nabla g_{j_0}(\mathbf{x}^*), d \rangle \\ &< 0 \end{aligned}$$

### Cas convexe

- si le problème ( $\mathcal{P}$ ) est convexe, les conditions de KKT sont *nécessaires et suffisantes* en un point  $\mathbf{x}^*$  régulier
- remarque : le caractère suffisant ne nécessite pas la régularité
- conditions de qualification plus simples (de Slater) : il existe au moins un point strictement admissible  $\mathbf{g}(\mathbf{x}) < 0$

### Notes

- preuve :
- si KKT est vérifié,  $\mathbf{x}^*$  est un minimum de la fonction convexe

$$H(\mathbf{x}) = J(\mathbf{x}) + \sum_{i=1}^p \lambda_i^* h_i(\mathbf{x}) + \sum_{j=1}^q \mu_j^* g_j(\mathbf{x})$$

- quand  $\mathbf{x}$  est admissible,  $H(\mathbf{x}) \leq J(\mathbf{x})$
- par KKT,  $H(\mathbf{x}^*) = J(\mathbf{x}^*)$  car  $\mu_j^* g_j(\mathbf{x}^*) = 0$
- donc pour tout  $\mathbf{x}$  est admissible,

$$J(\mathbf{x}^*) = H(\mathbf{x}^*) \leq H(\mathbf{x}) \leq J(\mathbf{x})$$

- Remarque : conditions de qualification de Slater pour un problème convexe : il existe au moins un point strictement admissible  $\mathbf{g}(\mathbf{x}) < 0$

## 1.4 Dualité

### Lagrangien

- le *Lagrangien* du problème ( $\mathcal{P}$ ) est la fonction

$$L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\mu}) = J(\mathbf{x}) + \sum_{i=1}^p \lambda_i h_i(\mathbf{x}) + \sum_{j=1}^q \mu_j g_j(\mathbf{x})$$

- quand  $J$ ,  $\mathbf{h}$  et  $\mathbf{g}$  sont  $C^1$  les conditions de KKT s'expriment par  $\nabla_{\mathbf{x}} L(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\mu}^*) = 0$
- les  $\lambda_i$  et les  $\mu_j$  sont les *multiplicateurs* de Lagrange associés aux contraintes

### Dualité

- *fonction duale* de Lagrange

$$g(\boldsymbol{\lambda}, \boldsymbol{\mu}) = \inf_{\mathbf{x}} L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\mu})$$

- $g$  est toujours concave

- pour  $\boldsymbol{\mu} \geq 0$

$$g(\boldsymbol{\lambda}, \boldsymbol{\mu}) \leq \inf_{\mathbf{x} \in \mathcal{C}} J(\mathbf{x})$$

- *problème dual* ( $\mathcal{Q}$ ) associé au problème primal ( $\mathcal{P}$ )

$$\begin{aligned} & \text{maximiser sur } \mathbb{R}^{p+q} && g(\boldsymbol{\lambda}, \boldsymbol{\mu}) \\ & \text{avec} && \mu_j \geq 0, 1 \leq j \leq q \end{aligned}$$

- *saut de dualité* :  $\inf_{\mathbf{x} \in \mathcal{C}} J(\mathbf{x}) - \max_{\boldsymbol{\mu} \geq 0} g(\boldsymbol{\lambda}, \boldsymbol{\mu})$

---

### Notes

---

La concavité vient de la définition en tant qu'infimum de fonctions affines.

---

### Point selle

- symétrisation du problème : ( $\mathcal{P}$ ) est équivalent à

$$\inf_{\mathbf{x}} \sup_{\boldsymbol{\lambda}, \boldsymbol{\mu} \geq 0} L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\mu})$$

- le problème dual ( $\mathcal{Q}$ ) est

$$\sup_{\boldsymbol{\lambda}, \boldsymbol{\mu} \geq 0} \inf_{\mathbf{x}} L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\mu})$$

- point selle : minimal par rapport à une variable, maximal par rapport à l'autre
- $(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\mu}^*)$  est un point selle du Lagrangien si pour tout  $(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\mu})$  ( $\boldsymbol{\mu}^* \geq 0$  et  $\boldsymbol{\mu} \geq 0$ )

$$L(\mathbf{x}^*, \boldsymbol{\lambda}, \boldsymbol{\mu}) \leq L(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\mu}^*) \leq L(\mathbf{x}, \boldsymbol{\lambda}^*, \boldsymbol{\mu}^*)$$

### Théorème de dualité

- $(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\mu}^*)$  est un point selle avec  $\boldsymbol{\mu}^* \geq 0$  ssi  $\mathbf{x}^*$  est une solution de ( $\mathcal{P}$ ),  $(\boldsymbol{\lambda}^*, \boldsymbol{\mu}^*)$  est une solution de ( $\mathcal{Q}$ ) et le saut de dualité est nul
- intérêt : pour résoudre le problème, on peut donc chercher un point selle du Lagrangien
- *remarque* : un point selle du Lagrangien vérifie les conditions de KKT (sans hypothèse autre que  $J, \mathbf{h}$  et  $\mathbf{g}$   $C^1$ )
- si le problème est convexe : point selle  $\Leftrightarrow$  KKT

## 1.5 Second ordre

### Régularité

- Condition plus forte que celle de Mangasarian-Fromowitz :
  - $\mathbf{x}^*$  est admissible
  - $\nabla h_i(\mathbf{x}^*)$  et les  $\nabla g_j(\mathbf{x}^*)$  sont linéairement indépendants pour  $j \in I(\mathbf{x}^*)$
- Contraintes *fortement* actives :

$$I^+(\mathbf{x}^*) = \{j \mid g_j(\mathbf{x}^*) = 0 \text{ et } \mu_j^* > 0\}$$

- si  $I(\mathbf{x}^*) = I^+(\mathbf{x}^*)$  on a complémentarité stricte

### Conditions nécessaires du 2ème ordre

- Hypothèses :
  - $J, \mathbf{h}$  et  $\mathbf{g}$   $C^2$
  - $\mathbf{x}^*$  solution de ( $\mathcal{P}$ ) et fortement régulier
- alors il existe  $\boldsymbol{\lambda}^* = (\lambda_1^*, \dots, \lambda_p^*)$  et  $\boldsymbol{\mu}^* = (\mu_1^*, \dots, \mu_q^*)$  tels que
  - les conditions de KKT sont vérifiées

- et pour tout  $d$  vérifiant :
  - $\langle \nabla h_i(\mathbf{x}^*), d \rangle = 0$  pour  $1 \leq i \leq p$
  - $\langle \nabla g_j(\mathbf{x}^*), d \rangle = 0$  pour  $j \in I^+(\mathbf{x}^*)$
  - $\langle \nabla g_j(\mathbf{x}^*), d \rangle \leq 0$  pour  $I(\mathbf{x}^*) \setminus I^+(\mathbf{x}^*)$

on a

$$\langle \nabla_{\mathbf{xx}}^2 L(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\mu}^*) d, d \rangle \geq 0$$

### Conditions suffisantes

- Hypothèses :
  - $J, \mathbf{h}$  et  $\mathbf{g}$   $C^2$
  - $(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\mu}^*)$  vérifie les conditions KKT
- si la matrice  $\nabla_{\mathbf{xx}}^2 L(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\mu}^*)$  est définie positive sur

$$\left\{ d \in \mathbb{R}^n \mid \langle \nabla h_i(\mathbf{x}^*), d \rangle = 0, 1 \leq i \leq p \right. \\ \left. \text{et } \langle \nabla g_j(\mathbf{x}^*), d \rangle = 0, j \in I^+(\mathbf{x}^*) \right\}$$

alors  $\mathbf{x}^*$  est un minimum local de  $J$  sur  $\mathcal{C}$

## 2 Algorithmes

### 2.1 Introduction

#### Classes d'algorithmes

- quelques grandes classes d'algorithmes :
  - gradient projeté :
    - descente de gradient
    - projection sur  $\mathcal{C}$  à chaque étape
  - pénalisation :
    - optimisation sans contrainte de  $J$ +pénalité
    - méthodes extérieures : on ramène progressivement le candidat minimum dans  $\mathcal{C}$
    - méthodes intérieures : on relâche progressivement les pénalités
  - programmation quadratique successive : résoudre des approximations quadratiques du problème
- principe sous-jacent : résoudre une série de problèmes sans contrainte (ou plus simple)

#### Projection

- outil important : projection sur un convexe fermé
  - soit  $C$  un convexe fermé et non vide de  $\mathbb{R}^n$
  - pour tout  $\mathbf{x}$  alors

$$\pi_C(\mathbf{x}) = \arg \min_{\mathbf{y} \in C} \|\mathbf{x} - \mathbf{y}\|^2$$

existe et est unique

- propriétés :
  - $\pi_C(\mathbf{x})$  est l'unique élément de  $C$  tel que

$$\forall \mathbf{y} \in C, \langle \mathbf{x} - \pi_C(\mathbf{x}), \mathbf{y} - \pi_C(\mathbf{x}) \rangle \leq 0$$

ou encore tel que

$$\forall \mathbf{y} \in C, \langle \pi_C(\mathbf{x}) - \mathbf{y}, \mathbf{y} - \mathbf{x} \rangle \leq 0$$

## Projection

- $\pi_C$  est une contraction :

$$\forall \mathbf{x}, \mathbf{y}, \|\pi_C(\mathbf{x}) - \pi_C(\mathbf{y})\| \leq \|\mathbf{x} - \mathbf{y}\|$$

- preuve simple :
- on a

$$\begin{aligned}\langle \mathbf{x} - \pi_C(\mathbf{x}), \pi_C(\mathbf{y}) - \pi_C(\mathbf{x}) \rangle &\leq 0 \\ \langle \mathbf{y} - \pi_C(\mathbf{y}), \pi_C(\mathbf{x}) - \pi_C(\mathbf{y}) \rangle &\leq 0\end{aligned}$$

- soit

$$\langle \mathbf{x} - \mathbf{y}, \pi_C(\mathbf{y}) - \pi_C(\mathbf{x}) \rangle + \|\pi_C(\mathbf{x}) - \pi_C(\mathbf{y})\|^2 \leq 0$$

- et on termine par Cauchy-Schwartz

## 2.2 Gradient

### Gradient projeté

- minimisation de  $J$  sur  $C$  convexe fermé
- algorithme :
  1. point initial  $\mathbf{x}_0$
  2. pour  $k \geq 1$  croissant
    - (a) calculer  $\mathbf{y}_{k+1} = \mathbf{x}_k - \rho_k \nabla J(\mathbf{x}_k)$
    - (b) puis  $\mathbf{x}_{k+1} = \pi_C(\mathbf{y}_{k+1})$
    - (c) tester la convergence et quitter la boucle le cas échéant (par ex.  $\|\mathbf{x}_{k+1} - \mathbf{x}_k\| < \epsilon$ )
- formulation simple mais mise en oeuvre potentiellement délicate :
  - si  $C$  est simple (par ex.,  $l_i \leq x_i \leq u_i$ ), pas de problème
  - sinon le calcul de  $\pi_C(\mathbf{y}_{k+1})$  est un problème d'optimisation sous contraintes

### Convergence

- si  $J$  est  $C^1$ ,  $\alpha$ -convexe et de dérivée  $M$ -lipschitzienne
- et si  $\rho_k \in [\beta_1, \beta_2]$  avec  $0 < \beta_1 < \beta_2 < \frac{2\alpha}{M^2}$
- alors l'algorithme du gradient projeté converge :
  - preuve très proche de celle du cas sans contrainte
  - si  $\mathbf{x}^*$  est l'optimum, on a pour tout  $\rho$

$$\mathbf{x}^* = \pi_C(\mathbf{x}^* - \rho \nabla J(\mathbf{x}^*))$$

- donc par contraction de  $\pi_C$

$$\|\mathbf{x}_{k+1} - \mathbf{x}^*\|^2 \leq \|(\mathbf{x}_k - \rho_k \nabla J(\mathbf{x}_k)) - (\mathbf{x}^* - \rho_k \nabla J(\mathbf{x}^*))\|^2$$

ce qui nous ramène au cas sans projection

## 2.3 Pénalisation

### Pénalisation

- idée principale : remplacer un problème avec contraintes par un problème sans contrainte dont la fonction objectif « décourage » les points non admissibles
- solution naïve :
  - on définit

$$\alpha(\mathbf{x}) = \begin{cases} +\infty & \mathbf{x} \notin C \\ 0 & \mathbf{x} \in C \end{cases}$$

- alors trouver  $\arg \min_{\mathbf{x} \in C} J(\mathbf{x})$  est équivalent à trouver  $\arg \min_{\mathbf{x} \in \mathbb{R}^n} J(\mathbf{x}) + \alpha(\mathbf{x})$
- solutions réalistes : utiliser une fonction  $\alpha$  régulière ( $C^1$  au moins) petite sur  $C$  et grande en dehors

### Méthodes de point extérieur

- $\alpha$  vérifie :
  - $\alpha$  est continue sur  $\mathbb{R}^n$
  - $\alpha(\mathbf{x}) \geq 0$
  - $\alpha(\mathbf{x}) = 0 \Leftrightarrow \mathbf{x} \in C$
- Exemples :
  - $\mathbf{h}(\mathbf{x}) = 0$  est représentée par  $\alpha(\mathbf{x}) = \|\mathbf{h}(\mathbf{x})\|^2$
  - $\mathbf{g}(\mathbf{x}) \leq 0$  est représentée par  $\alpha(\mathbf{x}) = \|\mathbf{g}^+(\mathbf{x})\|^2$
- on considère la famille de problèmes  $(\mathcal{P}_r)$  pour  $r > 0$  définis par

$$\min_{\mathbf{x} \in \mathbb{R}^n} (J(\mathbf{x}) + r\alpha(\mathbf{x}))$$

- méthodes de point extérieur : on ne peut pas garantir  $\mathbf{x}_r^* \in C$

### Méthodes de point intérieur

- même principe, mais avec des points à l'intérieur de  $C$
- pour les contraintes d'inégalité seulement
- $\alpha$  est une *barrière* et vérifie :
  - $\alpha$  est continue sur  $\overset{\circ}{C}$
  - $\mathbf{x} \notin C \Rightarrow \alpha(\mathbf{x}) = \infty$
- pour les contraintes  $\mathbf{g}(\mathbf{x}) \leq 0$ , on prend généralement

$$-\sum_{j=1}^q \log(-g_j(\mathbf{x}))$$

- comme pour les méthodes de point extérieur, on considère les problèmes  $(\mathcal{P}_r)$  pour  $r > 0$  définis par

$$\min_{\mathbf{x} \in \mathbb{R}^n} (J(\mathbf{x}) + r\alpha(\mathbf{x}))$$

- ici, on a toujours  $\mathbf{x}_r^* \in \overset{\circ}{C}$

### Pénalisation

- minimisation de  $J$  sur  $C$  convexe fermé
- algorithme (pour une suite  $(r_k)_k$  croissante) :
  1. point initial  $\mathbf{x}_0$
  2. pour  $k \geq 1$  croissant
    - (a) résoudre le problème  $(\mathcal{P}_{r_k})$

$$\min_{\mathbf{x} \in \mathbb{R}^n} (J(\mathbf{x}) + r_k\alpha(\mathbf{x}))$$

en partant de la solution  $\mathbf{x}_{k-1}$

- (b) tester la qualité du point obtenu  $\mathbf{x}_k$  et quitter la boucle le cas échéant
- fonctionne très bien en pratique pour le cas du point intérieur (on résout  $(\mathcal{P}_{r_k})$  par une méthode de (quasi)Newton avec contraintes d'égalités)
  - l'efficacité vient du redémarrage depuis un bon candidat

### Convergence

- on suppose  $J$  continue et coercitive, et  $C$  fermé et non vide
- on considère une méthode de point extérieur
- résultat :
  - pour tout  $r > 0$ ,  $(\mathcal{P}_r)$  possède au moins une solution

- toute famille  $(\mathbf{x}_r)_{r>0}$  de solutions est bornée
- les valeurs d'adhérence de toute famille  $(\mathbf{x}_r)_{r>0}$  de solutions sont des solutions de  $(\mathcal{P})$
- preuve ( $\mathbf{x}^*$  est une solution de  $(\mathcal{P})$ ) :
  - $J_r(\mathbf{x}) = J(\mathbf{x}) + r\alpha(\mathbf{x})$  est coercitive et continue
  - $\mathbf{x}_r$  solution de  $(\mathcal{P}_r)$ ,  $J(\mathbf{x}_r) \leq J_r(\mathbf{x}_r) \leq J_r(\mathbf{x}^*) = J(\mathbf{x}^*)$ , donc  $(\mathbf{x}_r)_{r>0}$  est bornée
  - comme  $\alpha(\mathbf{x}_r) \leq \frac{1}{r}(J(\mathbf{x}^*) - J(\mathbf{x}_r))$ , on a  $\lim_{r \rightarrow +\infty} \alpha(\mathbf{x}_r) = 0$
  - et donc pour toute valeur d'adhérence  $\hat{\mathbf{x}}$ ,  $J(\hat{\mathbf{x}}) \leq J(\mathbf{x}^*)$

## 2.4 Dualité

### Algorithme d'Uzawa

- idée : chercher directement un point selle du Lagrangien
- algorithme (paramètre  $\rho > 0$ ) :
  1. valeurs initiales des multiplicateurs  $\boldsymbol{\lambda}^1, \boldsymbol{\mu}^1$
  2. pour  $k \geq 1$  croissant
    - (a) trouver  $\mathbf{x}_k$  solution du problème (sans contrainte)

$$\min_{\mathbf{x} \in \mathbb{R}^n} L(\mathbf{x}, \boldsymbol{\lambda}^k, \boldsymbol{\mu}^k)$$

- (b) mettre à jour  $(\boldsymbol{\lambda}^k, \boldsymbol{\mu}^k)$  par

$$\begin{aligned} \lambda_i^{k+1} &= \lambda_i^k + \rho h_i(\mathbf{x}_k) \\ \mu_j^{k+1} &= \max(0, \mu_j^k + \rho g_j(\mathbf{x}_k)) \end{aligned}$$

- (c) tester la convergence et quitter la boucle le cas échéant (par ex.  $\|\mathbf{x}_{k+1} - \mathbf{x}_k\| < \epsilon$ )

### Algorithme d'Uzawa

- on peut montrer que l'algorithme d'Uzawa est un gradient projeté sur le problème dual :
  - on montre que  $\nabla g(\boldsymbol{\lambda}, \boldsymbol{\mu}) = (\boldsymbol{\lambda}, \boldsymbol{\mu})^T$
  - on maximise  $g(\boldsymbol{\lambda}, \boldsymbol{\mu})$ , ce qui explique le signe dans la mise à jour des multiplicateurs
  - intéressant parce que la projection est triviale
- Convergence :
  - si  $J$  est  $C^1$ ,  $\alpha$ -convexe,  $\mathbf{h}$  affine et  $\mathbf{g}$  convexe et  $M_g$  lipschitzienne
  - et si  $L$  possède un point selle  $(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\mu}^*)$
  - alors l'algorithme converge vers  $\mathbf{x}^*$  pour tout choix de  $\rho$  dans  $]0, \frac{2\alpha}{M_g^2 + M_h^2}[$