



Optimisation sous contraintes

Fabrice Rossi

TELECOM ParisTech

Décembre 2009/Janvier 2010

Résultats théoriques

Introduction

Existence et unicité

Conditions d'optimalité

Dualité

Second ordre

Algorithmes

Introduction

Gradient

Pénalisation

Dualité

Résultats théoriques

Introduction

Existence et unicité

Conditions d'optimalité

Dualité

Second ordre

Algorithmes

Introduction

Gradient

Pénalisation

Dualité

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

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

- 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

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

ensemble des points admissibles ou **réalisables**

- 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 $\nabla J \neq \mathbf{0}$

- 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 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

- 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

- 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



- si J est Gâteaux-différentiable en \mathbf{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

- 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 $\lambda^* = (\lambda_1^*, \dots, \lambda_p^*)$ et $\mu^* = (\mu_0^*, \mu_1^*, \dots, \mu_q^*)$ tels que
 - $(\lambda^*, \mu^*) \neq \mathbf{0}$
 - $h_i(\mathbf{x}^*) = 0, 1 \leq i \leq p$ (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

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

- 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

- 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}^*

- 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 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 $\lambda^* = (\lambda_1^*, \dots, \lambda_p^*)$ et $\mu^* = (\mu_1^*, \dots, \mu_q^*)$ 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

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

- 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 $\mathbf{g}(\mathbf{x}) < 0$

- 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 λ_i et les μ_j sont les multiplicateurs de Lagrange associés aux contraintes

- fonction duale de Lagrange

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

- g est toujours concave
- pour $\mu \geq 0$

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

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

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

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

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

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

- le problème dual (\mathcal{Q}) est

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

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

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

- le problème dual (\mathcal{Q}) est

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

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

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

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

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

- 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} \mathcal{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

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

- 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}

Résultats théoriques

Introduction

Existence et unicité

Conditions d'optimalité

Dualité

Second ordre

Algorithmes

Introduction

Gradient

Pénalisation

Dualité

- 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)

- 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

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

- π_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

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

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

- 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

- minimisation de J sur C convexe fermé
- algorithme :
 1. point initial \mathbf{x}_0
 2. pour $k \geq 1$ croissant
 - 2.1 calculer $\mathbf{y}_{k+1} = \mathbf{x}_k - \rho_k \nabla J(\mathbf{x}_k)$
 - 2.2 puis $\mathbf{x}_{k+1} = \pi_C(\mathbf{y}_{k+1})$
 - 2.3 tester la convergence et quitter la boucle le cas échéant (par ex. $\|\mathbf{x}_{k+1} - \mathbf{x}_k\| < \epsilon$)

- minimisation de J sur C convexe fermé
- algorithme :
 1. point initial \mathbf{x}_0
 2. pour $k \geq 1$ croissant
 - 2.1 calculer $\mathbf{y}_{k+1} = \mathbf{x}_k - \rho_k \nabla J(\mathbf{x}_k)$
 - 2.2 puis $\mathbf{x}_{k+1} = \pi_C(\mathbf{y}_{k+1})$
 - 2.3 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

- si J est C^1 , α -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 ρ

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

- donc par contraction de π_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

- 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 α régulière (C^1 au moins) petite sur C et grande en dehors



■ α vérifie :

- α est continue sur \mathbb{R}^n
- $\alpha(\mathbf{x}) \geq 0$
- $\alpha(\mathbf{x}) = 0 \Leftrightarrow \mathbf{x} \in \mathcal{C}$

■ 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 $\mathbf{x}_r^* \in \mathcal{C}$



Méthodes de point intérieur

- même principe, mais avec des points à l'intérieur de C
- pour les contraintes d'inégalité seulement
- α est une **barrière** et vérifie :
 - α 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 $\mathbf{x}_r^* \in \overset{\circ}{C}$

- 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
 - 2.1 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}

- 2.2 tester la qualité du point obtenu \mathbf{x}_k et quitter la boucle le cas échéant

- 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
 - 2.1 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}

- 2.2 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

- 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})

- 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 $\hat{\mathbf{x}}$, $J(\hat{\mathbf{x}}) \leq J(\mathbf{x}^*)$

- idée : chercher directement un point selle du Lagrangien
- algorithme (paramètre $\rho > 0$) :

1. valeurs initiales des multiplicateurs λ^1, μ^1
2. pour $k \geq 1$ croissant

2.1 trouver \mathbf{x}_k solution du problème (sans contrainte)

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

2.2 mettre à jour (λ^k, μ^k) par

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

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

- on peut montrer que l'algorithme d'Uzawa est un gradient projeté sur le problème dual :
 - on montre que $\nabla g(\lambda, \mu) = (\lambda, \mu)^T$
 - on maximise $g(\lambda, \mu)$, 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 , α -convexe, \mathbf{h} affine et \mathbf{g} convexe et M_g lipschitzienne
 - et si L possède un point selle $(\mathbf{x}^*, \lambda^*, \mu^*)$
 - alors l'algorithme converge vers \mathbf{x}^* pour tout choix de ρ dans $]0, \frac{2\alpha}{M_g^2 + M_h^2}[$