

Pénalisation

1	Introduction	1
1.1	Vue d'ensemble	1
1.2	Principes généraux	2
2	Pénalisation extérieure	6
2.1	Exemples, définition, convergence	6
2.2	Schéma algorithmique	9
3	Pénalisation intérieure	11
3.1	Exemples	11
4	Lagrangien augmenté	12
4.1	Objectifs	12
4.2	Exactitude du lagrangien	12
4.3	Lagrangien augmenté de (P_E)	14
4.4	Méthode des multiplicateurs pour (P_E)	17

1) Introduction

1A Vue d'ensemble

Pour la résolution des problèmes d'optimisation avec contraintes

- On a vu une famille d'algorithmes duaux dans la séance sur la dualité : ils se concentrent sur la minimisation d'une suite de multiplicateurs $(d_n) \rightarrow d_*$; une solution optimale x_* peut parfois être obtenue en résolvant le problème

$$\inf_{x \in X} \varphi(x, \bar{y}) = d_*$$

- On présente dans cette séance une famille d'algorithmes primaux

- ⊗ ils se concentrent sur la minimisation d'une suite primales $(x_n) \rightarrow x_*$
- ⊗ un multiplicateur optimal d_* peut être obtenu comme sous-produit des algorithmes

→ Proposition 1.11 (faire passer un terme de l'objectif en contrainte) (P) (P')

$$\inf_{x \in E} f(x) + \varphi(x) = \inf_{(x, \gamma) \in E \times \mathbb{R}} f(x) + \gamma$$

$$\varphi(x) \leq \gamma$$

x_* est sol de (P) avec $\gamma_* = \varphi(x_*)$
 $\Leftrightarrow (x_*, \gamma_*)$ est solution de (P')

→ Pénalisation (faire passer les contraintes dans l'objectif)

$$\inf_{x \in X} f(x)$$

6) Principes généraux

- On cherche à résoudre (algorithmiquement ou théoriquement) le problème avec contrainte

$$(P_x) \begin{cases} \inf f(x) \\ x \in X \end{cases} \quad \begin{matrix} f: X \rightarrow \mathbb{R} \\ X \subset \text{espace vectoriel } E \end{matrix}$$

- Dans les méthodes de pénalisation, on remplace (P_x) par un ou plusieurs problèmes sans contrainte, de la forme

$$(P_r) \inf_{x \in E} \theta_r(x)$$


où (souvent) $\theta_r: E \rightarrow \mathbb{R}$ (parfois $\overline{\mathbb{R}}$) prend en $x \in E$ la valeur

$$\theta_r(x) = f(x) + r p(x)$$

\uparrow
facteur de pénalisation
 (souvent > 0)

$p: E \rightarrow \overline{\mathbb{R}}$
fonction pénalisante

- On pourrait prendre $p = I_X$ (indicatrice de X) et $r = 1$, mais ce n'est pas utile en pratique ; c'est utile en théorie pour pouvoir prendre dans le même cadre les problèmes avec et sans contrainte.



$$I_X(x) = \begin{cases} 0 & \text{si } x \in X \\ +\infty & \text{sinon} \end{cases}$$

- À quoi ça sert ?

- On peut alors utiliser des algorithmes d'optimisation sans contrainte pour résoudre le problème avec contrainte (P_x) .

C'est la "méthode du pauvre"

(on ne connaît pas grand chose et on en fait le moins possible → de moins en moins le cas, grâce au développement de bons solveurs d'optimisation)

- C'est aussi un outil pour construire des algorithmes plus sophistiqués (points intérieurs, par ex.) (globalisation de SQP)

- Cela permet d'interpréter certains algorithmes, de mieux les comprendre ; cela définit un cadre conceptuel.

- Sert aussi à la théorie

- pour montrer l'existence de solution de (P_x) à partir de celles des (P_r)

- pour donner des propriétés de (P_x) à partir de celles des (P_r)

- pour établir des conditions d'optimalité de (P_x) à partir de celles de (P_r)

- Pénalisation exacte et inexacte

(concepts vagues mais très utiles !)

- On dit que la pénalisation est exacte si

x_x "solution" de (P_x) " \Leftrightarrow " x_x "solution" de (P_r)

- il faut toujours dire ce que l'on entend par "solution" (point stationnaire, min local / global)
- l'équivalence est rarement vraie ; on est déjà content si l'on peut montrer " \Rightarrow " pour un certain r (l'implication réciproque est rarement vraie, sauf si l'on suppose $x_x \in X$)
- il faut préciser les valeurs de r pour lesquelles la propriété est vraie.
- avantage : il suffit de résoudre un (P_r) pour résoudre (P_x) !
- inconvénient : (P_r) est souvent un problème non différentiable.

- On dit que la pénalisation est inexacte dans tous les autres cas.

- il faut alors résoudre plusieurs (P_r) (une infinité ?) pour résoudre (P_x)

Proposition (monotonie en pénalisation)

Si $\forall r$ considérés, $\theta_r(x) = f(x) + r p(x)$
a un minimiseur \bar{x}_r

alors lorsque $r \uparrow$, on a

1) $p(\bar{x}_r) \searrow$

2) $f(\bar{x}_r) \nearrow$ (si $r \geq 0$)

Dém

1)

$r_1 < r_2$

$\theta_{r_1}(x_1) \leq \theta_{r_1}(x_2)$

$x_i = \bar{x}_{r_i} \leq r_1 p(x_i)$

$\theta_{r_2}(x_2) \leq \theta_{r_2}(x_1)$
 $\rightarrow f(x_1) + r_1 p(x_1) \leq f(x_2) + r_1 p(x_2)$
 $\rightarrow f(x_1) + r_2 p(x_1) \leq f(x_1) + r_2 p(x_2)$

$(r_2 - r_1) p(x_1) \leq (r_2 - r_1) p(x_2)$
 $> 0 \qquad \qquad \qquad > 0$

$\Rightarrow p(x_2) \leq p(x_1)$

2) $f(x_1) \leq f(x_2)$

□


2) Pénalisation extérieure

A Exemples, définition, convergence

• Exemples ----- (P_x) cdf $f(x)$, $X \subset E$

	<u>définition de X</u>	Θ_r
⊗	$c(x) = 0$	$f(x) + \frac{r}{2} \ c(x)\ _2^2$
⊗	$c(x) \leq 0$	$f(x) + \frac{r}{2} \ c(x)^+\ _2^2$

$c(x)^+ = \max(0, c(x))$



$\left. \begin{array}{l} \min f(x) \\ x \leq 0 \end{array} \right\}$
 $\min f(x) + r [\max(0, x)]^2$

Pénalisation quadratique

• Définition On va établir un résultat général montrant ce qui se passe pour $\bar{x}_r \in \arg \min \Theta_r$ lorsque $r \nearrow \infty$, sous les hypothèses suivantes

$$\Theta_r(x) = f(x) + r p(x)$$

- (H) $\left\{ \begin{array}{l} (i) \quad p \text{ est s.e.c sur } E \\ (ii) \quad p(x) \geq 0, \forall x \in E \\ (iii) \quad p(x) = 0 \Leftrightarrow x \in X \end{array} \right.$

la pénalisation de f par p n'intervient qu'à l'extérieur de X (d'où l'appellation)

théor (convergence de la pénalisation quadratique)

7

Si • X fermé, non vide de E

• $f: E \rightarrow \mathbb{R}$ vérifie (H)

• f est s.c.i. $\theta_n(x) = f(x) + \frac{n}{2} p(x)$

• $\exists r_0 \geq 0$: θ_{r_0} est coercive

alors 1) $\forall n \geq r_0$, (P_n) a une solution, disons \bar{x}_n

2) $(\bar{x}_n)_{n \rightarrow \infty}$ est bornée

3) tout point d'adhérence de (\bar{x}_n) est solution de (P_X)

Leçon : pour résoudre (P_X) , on génère une suite (\bar{x}_n) de minimiseurs de θ_n avec $n \rightarrow \infty$

Dem' 1) si $n \geq r_0$, $x \in E$

$$\theta_n(x) = \theta_{r_0}(x) + \underbrace{(n-r_0)}_{\geq 0} \underbrace{p(x)}_{\geq 0} \quad (H)$$

$$\geq \underbrace{\theta_{r_0}(x)}_{\text{coercive}}$$

$\Rightarrow \theta_n$ coercive si $n \geq r_0$

$\Rightarrow \exists$ solution $\bar{x}_n \in \arg \min_{x \in E} \theta_n(x)$

$$2) \quad \theta_{r_0}(\bar{x}_n) \leq \theta_r(\bar{x}_n) \leq \theta_r(x) \leq f(x) \quad \begin{array}{l} \text{c\u00e0 d\u00e9p} \\ \text{de } r \end{array}$$

$$\begin{array}{ccc} \uparrow & \uparrow & \uparrow \\ \forall r > r_0 & \forall x \in E & \forall x \in X \end{array}$$

on fixe \bar{x}

θ_{r_0} coercive $\Rightarrow (\bar{x}_n)$ born\u00e9e

3) Soit $\bar{x}_n \rightarrow \bar{x}$ (s\u00e9q. - suite)
 $\nexists \bar{x} \in \text{Sol}(P_X)$

$\bar{x} \in X$?

$$\theta_{r_0}(\bar{x}_n) + (r-r_0)p(\bar{x}_n) = \theta_r(\bar{x}_n) \leq f(x)$$

$\geq \min \theta_{r_0}$ \uparrow
 $\forall x \in X$

$$\Rightarrow 0 \leq p(\bar{x}_n) \leq \frac{f(x) - \min \theta_{r_0}}{r-r_0} \quad (x \in X \text{ fixe})$$

$\rightarrow 0$ lorsque $r \rightarrow \infty$

$$0 \leq p(\bar{x}) \leq \liminf_{r \rightarrow \infty} p(\bar{x}_n) = 0$$

$$\Rightarrow p(\bar{x}) = 0 \Rightarrow \bar{x} \in X$$

$f(\bar{x}) \leq f(x), \forall x \in X$?

$$f(\bar{x}_n) \leq \theta_r(\bar{x}_n) \leq f(x), \forall x \in X$$

$$\Rightarrow f(\bar{x}) \leq \liminf_{r \rightarrow \infty} f(\bar{x}_n) \leq f(x)$$

□

B Schema algorithmique

- On passe de $(x_k, r_k) \rightarrow (x_{k+1}, r_{k+1})$ par
- 1) si x_k est satisfaisant \rightarrow arrêt
 - 2) prende $r_{k+1} > r_k$ (heuristique)
 - 3) x_{k+1} solution (approché) de $\min_{u \in \mathbb{E}} \theta_{r_{k+1}}(u)$

Remarques

- 1) " x_k satisfaisant " ne vient souvent à vérifier que les contraintes sont presque satisfaites.
 - 2) IL ne suffit pas de prendre r très grand une fois pour toutes !! Étrange :
 - c'est quoi r grand
 - si r trop grand, on ne "voit" plus f
 - si r est grand, θ_r est mal conditionnée (voir ci-dessous) et prendre x_k comme point de départ à l'étape 3 permet en partie de faire face au mauvais conditionnement
 - 3) si r grand, θ_r est mal conditionnée ; voyons cela pour (PE) et la pénalisation quadratique :

$$\bullet \theta_r(u) = f(u) + \frac{r}{2} \|c(u)\|_2^2$$

$$\bullet D\theta_r(u) = Df(u) + r c'(u)^T c(u)$$

$$\bullet D^2\theta_r(u) = D^2f(u) + \sum_i r c_i(u) D^2c_i(u) + r c'(u)^T c'(u)$$

$$\left\{ \begin{array}{l} \min f(u) \\ c(x) = 0 \end{array} \right.$$

\downarrow
 multi-coûts
 optimal
 (voir ci-dessus)

\downarrow
 ex, les c avec r
- $\Rightarrow \kappa_2(D^2\theta_r(\bar{u}_r)) \nearrow \infty$


figure

$$\begin{cases} \min f(x) \\ c(x) = 0 \end{cases}$$




$$\min_{x \in \mathbb{R}^2} f(x) + r \|c(x)\|_2^2$$


$r = 0$




$r = 1$



$r = 10$



$r = 100$



Chemin des minimiseurs

Prop (réciprocité d'un multiplicateur optimal)

$$(P_E) \begin{cases} \inf f(x) \\ c(x) = 0 \end{cases} \quad \theta_r(x) = f(x) + \frac{r}{2} \|c(x)\|_2^2$$

- Si
- $\nabla_x \theta(\bar{x}_r) = 0$
 - $\bar{x}_r \rightarrow \bar{x}$ lorsque $r \rightarrow \infty$
 - $c'(\bar{x})$ surjective

- alors
- 1) $c(\bar{x}) = 0$
 - 2) $\exists \lambda \in \mathbb{R}^m : \nabla_x \ell(\bar{x}, \lambda) = 0$
 - 3) $r c(\bar{x}_r) \rightarrow \lambda$

Dém

$$1) \nabla_x \theta_r(\bar{x}_r) = 0 = \frac{1}{r} \nabla f(\bar{x}_r) + r \sum_i c_i(\bar{x}_r) \nabla c_i(\bar{x}_r)$$

$$\frac{1}{r} + \lim_{r \rightarrow \infty} \rightarrow 0$$

$$\Rightarrow \sum_i c_i(\bar{x}) \underbrace{\nabla c_i(\bar{x})}_{\text{L.I.}} = 0$$

$$\Rightarrow c(\bar{x}) = 0$$

$$2) \nabla f(\bar{x}_r) + \sum_i (r c_i(\bar{x}_r)) \nabla c_i(\bar{x}_r) = 0$$

$$\downarrow \quad \downarrow \text{méc} \quad \downarrow$$

$$\nabla f(\bar{x}) + \sum_i \underbrace{r c_i(\bar{x}_r)}_{\substack{\text{q-ch.} \\ \parallel \\ \lambda}} \nabla c_i(\bar{x}) = 0$$

$$\Rightarrow \nabla_x \ell(\bar{x}, \lambda) = 0$$

□

3) Pénalisation à l'intérieur



Exemple (rien de plus...)

$$\begin{cases} \min f(x) \\ c(x) \leq 0 \end{cases} \rightarrow \min f(x) - \mu \sum_i \log(-c_i(x))$$

↓ 0

on reste à l'intérieur de l'ensemble admissible

barrière logarithmique (→ +∞ si x s'approche du bord de l'ensemble admissible)



Pénalisation logarithmique

4) Lagrangien augmenté

A Objectifs

On cherche une fonction de pénalisation telle que

- on ne doit plus prendre $r \uparrow \infty$ (donc on évite le mauvais conditionnement)
- pour un r fini, θ_r a une solution en une solution de (P_r) , c-à-d θ_r est une fonction de pénalisation exacte

B Exactitude du Lagrangien

$$(PEI) \begin{cases} \min f(x) \\ C_E(x) = 0 \\ C_I(x) \leq 0 \end{cases}$$

prop

si

- (PEI) est convexe (f, C_I convexes, C_E affine)
- \bar{x} solution de (PEI)
- f et c sont dérivables en \bar{x}
- $\exists \bar{\lambda}$ tel que $(\bar{x}, \bar{\lambda})$ vérifie KKT

alors $x \mapsto l(x, \bar{\lambda})$ a un min global en \bar{x}

Dem (dijà vu dans le cours sur la dualité)

$$l(\bar{x}, \bar{\lambda}) \leq l(x, \bar{\lambda}), \forall x \in E$$

Deux inconvénients

① $\ell(\cdot, \mathcal{I})$ est pas universel si $(P \in \mathcal{I})$ n'est pas

exemple
$$\begin{cases} \min & -x^2 \\ x & = 0 \end{cases} \rightarrow (\bar{x}, \mathcal{I}) = (0, 0)$$

$\ell(x, \mathcal{I}) = -x^2$ n'est pas universel!

② il faudrait connaître \mathcal{I}

→ dans cette approche, il faut résoudre une suite de problèmes

$$\inf_{x \in E} \ell(x, d)$$

$$x \in E$$

avec mise à jour de $d \rightarrow \mathcal{I}$

→ c'est la relaxation logarithmique
(voir cours sur la dualité)

C) Le lagrangien augmenté de (P_E)

L'édic est la suivante $(P_E) \begin{cases} \min f(x) \\ c(x) = 0 \end{cases}$


- La pénalisation quadratique

$$\theta_2(x) = f(x) + \frac{\lambda}{2} \|c(x)\|_2^2$$

ne peut pas être exacte (en général) car en une solution x_* de (P_E) , on a

$$\begin{aligned} \nabla \theta_2(x_*) &= \nabla f(x_*) + \lambda \underbrace{c'(x_*)^T c(x_*)}_{=0} \\ &= \nabla f(x_*) \end{aligned}$$


non nul en général.




- Le lagrangien augmenté "redresse" d'abord f pour que la "fonction redressée" ait une pente nulle en x_* , puis on pénalise. La fonction redressée est le lagrangien, qui a en effet une pente nulle en x_*


$$l_2 : E \times F \rightarrow \mathbb{R}$$

$$l_2(x, d) = l(x, d) + \frac{\lambda}{2} \|c(x)\|_2^2$$





Pénalisation quadratique



Pénalisation quadratique du lagrangien

Lemme de FINSLER (1937)

Si

- M et $A \in S^n$ (matrices symétriques d'ordre n)
- $A \succcurlyeq 0$ (semi-définie positive)
- $M \succ 0$ sur $N(A)$, c-à-d

$v^T M v > 0, \forall v \in N(A) \setminus \{0\}$

Alors $\exists \alpha, \forall \lambda \geq \alpha, M + \lambda A \succ 0$

Dém (par l'absurde)

$\Rightarrow \exists \lambda_k \nearrow \infty : M + \lambda_k A \not\succ 0$
 $\exists v_k \neq 0 : v_k^T (M + \lambda_k A) v_k \leq 0$

- on peut supposer que $\|v_k\| = 1$
- Soit $v_k \rightarrow v$ (sous-suite)

$A v = 0 \quad \left(\begin{matrix} v^T A v = 0 \\ A \succcurlyeq 0 \end{matrix} \right) \Rightarrow A v = 0$

$\frac{v_k^T M v_k + \lambda_k v_k^T A v_k}{\lambda_k} \leq 0$
 \downarrow
 0

\downarrow
 $v^T A v$
 $\Rightarrow v^T A v = 0$

$v^T M v \leq 0 \quad v_k^T M v_k + \lambda_k v_k^T A v_k \leq 0$
 $\Rightarrow v_k^T M v_k \leq 0 \Rightarrow v^T M v \leq 0$

- $v \neq 0$

Contradiction □

Theor (exactitude du lagrangien augmenté)

Si . f et c sont 2 fois dérivable en \bar{x}

- \bar{x} minimum local de (P_E)
- $\exists \bar{d}$ tel que $\nabla_n l(\bar{x}, \bar{d}) = 0$ et CS2

alors $\exists \underline{\lambda}$, $\forall \lambda \geq \underline{\lambda}$, \bar{x} est un minimum local strict de $l_n(\cdot, \bar{d})$.

Dém

$$l_n(x, d) = f(x) + d^T c(x) + \frac{\lambda}{2} \|c(x)\|^2$$

$$\nabla_n l_n(x, d) = \nabla f(x) + c'(x)^T d + \lambda c'(x)^T c(x)$$

$$\nabla_n l_n(\bar{x}, \bar{d}) = 0$$

$$\nabla_{xx}^2 l_n(\bar{x}, \bar{d}) = \underbrace{\nabla_{xx}^2 l(\bar{x}, \bar{d})}_M + \underbrace{\lambda c'(\bar{x})^T c'(\bar{x})}_A$$

$M \succ 0$ sur $N(A)$ par CS2

Fischer

\Rightarrow pour λ assez grand, $\nabla_{xx}^2 l_n(\bar{x}, \bar{d}) \succ 0$

□

Remarques

- 1) On ne doit pas faire tendre $\lambda \rightarrow \infty$
- 2) On doit toujours trouver une suite de $\lambda_k \rightarrow \bar{\lambda}$
 \rightarrow c'est la relaxation lagrangienne augmentée

D Méthode des multiplicateurs par (PE)

- On passe de $(d_h, r_h) \rightarrow (d_{h+1}, r_{h+1})$ par
- 1) on minimise $l_{r_h}(\cdot, d_h) \rightarrow r_h$
 - 2) si (r_h, d_h) est satisfaisant \rightarrow arrêt
 - 3) $d_{h+1} = d_h + r_h c(r_h)$
 - 4) $r_{h+1} \uparrow$ si nécessaire (heuristique)

D'où vient la formule de d_{h+1} ?

- c'est une heuristique (elle se justifie très bien pour les problèmes convexes)

$$0 = \nabla_{r_h} l_{r_h}(r_h, d_h) \quad \text{par l'étope 1}$$

$$= \nabla f(r_h) + c'(r_h)^T (d_h + r_h c(r_h))$$

||
 d_{h+1} car
 on souhaite que
 $\nabla_x l(\cdot, d_{h+1}) = 0$

- si (PE) convexe, on montre que l'algorithme est une méthode proximale sur la fonction duale