

Algorithme SQP/OQS

1	Orientation	1
2	L'algorithme local	3
2.1	Un algorithme à éviter	4
2.2	L'algorithme SQP	5
2.3	Convergence locale	8
3	Pénalisation exacte	9
3.1	Motivation	9
3.2	Exactitude de Θ_σ	11
4	Globalisation	15

① Orientation (Chap 14)

— On cherche à résoudre numériquement

$$(P_{E,I}) \begin{cases} \min f(x) \\ c_E(x) = 0 \\ c_I(x) \leq 0 \end{cases} \Leftrightarrow \begin{cases} c_i(x) = 0, \forall i \in E \\ c_i(x) \leq 0, \forall i \in I \end{cases}$$

$E \cap I = \emptyset, E \cup I = [1:m]$

$f: E \rightarrow \mathbb{R}$ (E un espace vectoriel)

$c: E \rightarrow \mathbb{R}^m$, composantes c_i

pour $v \in \mathbb{R}^m$, on note $v^\# \in \mathbb{R}$ dfin par

$$(v^\#)_i = \begin{cases} v_i & \text{si } i \in E \\ v_i^+ = \max(0, v_i) & \text{si } i \in I \end{cases}$$

alors $c_i(x)^\# = 0 \Leftrightarrow x$ admissible pour $(P_{E,I})$

— Méthodes de résolution de $(P_{E,I})$

- primales (pénalisation \rightarrow cours précédent)
- duales (méthodes de dualité \rightarrow cours précédent)
- primale - duale (SQP / OQS, aujourd'hui)

— OQS = Optimisation Quadratique Successive

SQP = Sequential Quadratic Programming

C'est un algorithme du type Newton en $(x,d) \in E \times \mathbb{R}^m$ (donc primale - duale)

- Il a fallu long temps pour le trouver :
30 ans (1945 → 1975)

- essai d'étendre le principe (DL)
à l'ONL

- persécution } ont pu cédé
- duplicité }

- Difficultés à surmonter

• comprendre comment intervenir la
combinaison des contraintes d'équité
(→ de \mathbb{R}^2 à \mathbb{R}^n)

• comprendre comment prendre en
compte les inéquités.

• accepter une itération + coûteuse
que la résolution d'un SL

II

L'algorithme local

3

Beaucoup de manières de le présenter :

- dans le syllabus : il est vu comme un algorithme de Josephy-Newton sur les conditions d'équilibre, interprété comme une inclusion fonctionnelle ou un problème de complémentarité

(c'est compliqué [beaucoup de notions non vues], mais c'est ce qui conduit au résultat de convergence locale le plus fort)

- ici (comme dans beaucoup de manuels) on suit une procédure "naturelle", une heuristique.

(A) Un algorithme à éviter

→ A ne pas faire : traiter (par l'algorithme de Newton) l'optimalité et l'admissibilité séparément

$$\bullet \min f(x) \xrightarrow{\text{Newton}} \begin{cases} \min_d f(x) + \nabla f(x)^T d + \frac{1}{2} d^T \nabla^2 f(x) d \\ x_+ = x + d \end{cases}$$

$$\bullet c(x) = 0 \rightarrow \begin{cases} c(x) + c'(x) d = 0 \\ x_+ = x + d \end{cases}$$

$$\bullet \begin{cases} \min f(x) \\ c(x) = 0 \end{cases} \rightarrow \begin{cases} \min_d \nabla f(x)^T d + \frac{1}{2} d^T \nabla^2 f(x) d \\ c(x) + c'(x) d = 0 \\ \text{puis } x_+ = x + d \end{cases} \quad (0)$$

↑
 un algorithme à éviter
 (il ne converge pas nécessairement localement)

→ Ce qu'il faut faire : appliquer Newton à un système qui prend en compte simultanément l'optimalité et l'admissibilité ⇒

appliquer Newton aux conditions d'optimalité

- notepad : c'est ce que l'on fait en optimisation SANS contrainte
- nouveau : algo en (x, d)
- découvert "seulement" ~ 1975

(B) C'algorithmique SQP / OQS

- On part de CN1 (\in KKT) qui est le système en (x, d)

$$(KKT) \begin{cases} \nabla f(x) + c'(x)^T d = 0 \\ c_E(x) = 0 \\ 0 \leq \frac{1}{I} \perp c_I(x) \leq 0 \end{cases}$$

et on linéarise toutes les fonctions qui y apparaissent (raisonnable ? dangereux pour la convergence ? \Rightarrow il faudra trouver une démonstration nouvelle) et on garde la structure.

- C'est une linéarisation en $(x, d) \in \mathbb{E} \times \mathbb{R}^m$: le nouvel état est donc

$$(x_+, d_+) = (x, d) + (d, \mu)$$

où (d, μ) est solution de

$$\begin{cases} \nabla_x f(x, d) + \nabla_{xx}^2 f(x, d) d + c'(x)^T \mu = 0 & (1a) \\ c_E(x) + c'_E(x) d = 0 & (1b) \\ 0 \leq \frac{1}{I} \perp (c_I(x) + c'_I(x) d) \leq 0 & (1c) \end{cases}$$

• Comment résoudre ce système ?

• Ça doit être les CN1 d'un problème quadratique !

- légère complication : ce n'est pas le même multiplicateur qui apparaît dans (1a) et (1c) ; mais (1a) peut se voir entièrement

$$(KKT') \begin{cases} \nabla f(x) + \nabla_{xx}^2 \ell(x;d) d + c'(x)^T (d+\mu) = 0 \\ c_E(x) + c'_E(x) d = 0 \\ 0 \leq (d+\mu)_I \perp (c_I(x) + c'_I(x) d) \leq 0 \end{cases} \quad \downarrow \text{QP}$$

$\Rightarrow d+\mu =$ multiplicateur associé aux contraintes linéarisées

- (KKT') sont des CNL du problème quadratique ou coléum suivant

$$(PQO) \begin{cases} \min_d \nabla f(x)^T d + \frac{1}{2} d^T \nabla_{xx}^2 \ell(x;d) d \\ c_E(x) + c'_E(x) d = 0 \\ c_I(x) + c'_I(x) d \leq 0 \end{cases} \rightarrow \text{mult } d^{PQ}$$

- Remarques

- ① le critère du PQO est hybride : $\nabla f(x)$ pour la partie linéaire, $\nabla_{xx}^2 \ell(x;d)$ pour la partie quadratique
- ② Les contraintes du PQO sont obtenues en linéarisant celle de (PEI)
- ③ ce qui manque à (c) par rapport à (PQO) c'est la courbure (= dérivées secondes) des contraintes
- ④ $d+\mu = d^{PQ} \xrightarrow{\nabla^2 f(x)} \nabla_{xx}^2 \ell(x;d)$

l'algorithme SQP / OQS

Consiste à résoudre une suite de PQ

$$(x, d) \rightarrow (x_+, d_+)$$

- 1) si (x, d) est satisfaisant, on s'arrête
- 2) résoudre le PQO en $(x, d) \rightarrow (d, d^{PQ})$
- 3) $x_+ = x + d$; $d_+ = d^{PQ}$

Remarques : • résoudre un PQ est plus simple que résoudre (PEI), mais c'est beaucoup plus coûteux que de résoudre un système linéaire

• si $\nabla_{un}^2 e(x, d) \neq 0$

\Rightarrow (PQO) est NP ardu

(PQO) peut avoir des solutions imparfaites

donc on approche souvent $\nabla_{un}^2 e(x, d)$ par une matrice $\Pi > 0$ (méthode de QN)

• le (PQO) peut être non borné

(En fait, il suffit d'avoir un point stationnaire du PQO, mais il n'y a pas d'algo spécialisé dans cette tâche)

(plus de problèmes si $\nabla_{un}^2 e(x, d) \sim \Pi > 0$)

• le (PQO) peut ne pas être réalisable

(\exists des techniques pour y faire face)

Il faut se rappeler qu'il n'y a pas d'algorithme pouvant résoudre tous les (PEI)!!

① Un résultat de convergence locale

8

théorème

- Si
- f, c sont C^2 , x^* proche de $x^* \in \text{sol}(P_{EI})$
 - \exists unique multiplicateur d^* associé à x^*
 - CS 2 est vérifiée en (x^*, d^*)

alors \exists vois V de (x^*, d^*) tel que si $(x_k, d_k) \in V$

alors

1) l'algorithme SQP peut générer une suite $\{(x_k, d_k)\} \subset V$ en calculant à chaque itération des points stationnaires de PQQ

2) $(x_k, d_k) \rightarrow (x^*, d^*)$ quadratiquement

Rang amélioré

Si il y a complémentarité stricte les contraintes actives en la solution sont celles des PQQ (pour V assez petit) \Rightarrow plus de combinatoire dans le PQQ et il n'y a plus qu'un seul SC à résoudre à chaque itération

III

Pénalisation exacte (§ 12.5)

A Motivation

- On cherche à "globaliser" l'algorithme SQP/OAS (c-à-d à forcer sa convergence même si (x_k, d_k) n'est pas proche d'une solution primal-dual), par exemple par recherche linéaire (les régions de confiance fonctionnent de la même manière avec quelques adaptations)

$$x_{k+1} = x_k + \alpha_k d_k$$

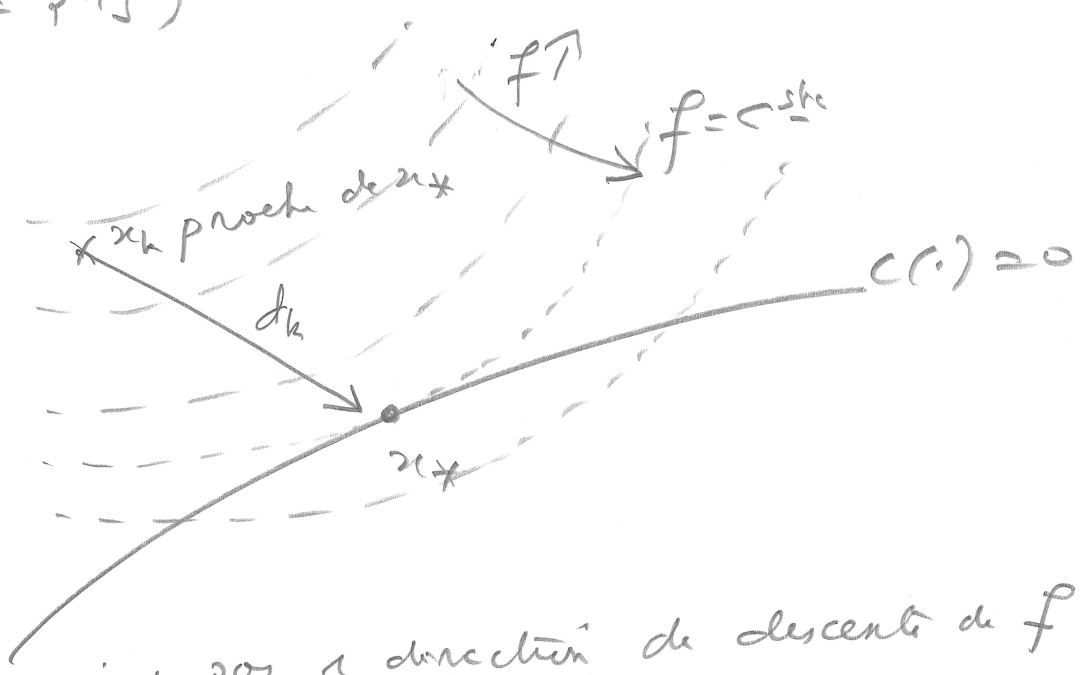
où d_k est la direction donnée par le PPO et $\alpha_k > 0$ est un pas.

Rmq : c'est 1 RL en variable primale, alors que SQP/OAS est en variable primal-dual, mais une RL en variable primal-dual n'est pas aisée.

- Comment déterminer α_k ?
- En utilisant quelle fonction ?

Ça ne peut pas être f :

(on suppose dans le dessin que $I = \mathbb{R}$ et $E = \mathbb{R}$)



d_k n'est pas a direction de descente de f en x_k !!

On a besoin d'une fonction prenant en compte les deux aspects du problème : optimality et admissibilité \Rightarrow fonction de pénalisation

Il faut que x_k soit a minimum local de cette fonction de pénalisation sinon la solution ci-dessus se représente (discutable, car on peut jouer avec le facteur de pénalisation) \Rightarrow besoin d'une fonction de pénalisation exacte


On prend $\Theta_\sigma : \mathbb{R} \rightarrow \mathbb{R}$ défini en $x \in \mathbb{R}$ par

$$\Theta_\sigma(x) = f(x) + \sigma \|C(x)\|^\#$$


où $\|\cdot\|$ est une norme arbitraire (pour σ constant)

Roguel

10'



Pénalisation quadratique




Pénalisation quadratique du lagrangien

③ Exactitude de $\mathcal{D}\sigma$

Norme duale $\|\cdot\|_{\mathcal{D}}$ de $\|\cdot\|$:

$$\|V\|_{\mathcal{D}} = \sup_{\|u\| \leq 1} V^T u$$



Pénalisation exacte non différentiable

La non différentiabilité crée un minimum local en x_* si σ est assez grand.

théor

- si
- x_* min local de (P_{σ})
 - f et c sont C^2 près de x_*
 - $c'(x_*)$ surjective (donc $\exists!$ λ_* optimal)
 - $C \leq 2$
 - $\sigma \geq \|\lambda_*\|_{\mathcal{D}}$

alors x_* est un min local strict de $\mathcal{D}\sigma$

lemme

Si • φ a des dérivées directionnelles (DD)
 • ψ a des DD et est lipschitz
 alors $\psi \circ \varphi$ a des DD

Dém Soit $x+h \in E$, $t > 0$

$$(\psi \circ \varphi)(x+th)$$

$$= \psi(\varphi(x+th))$$

$$= \psi(\varphi(x) + t\varphi'(x; h) + o(t))$$

$$= \psi(\varphi(x) + t\varphi'(x; h)) + o(t)$$

car ψ est lipschitz

$$= \psi(\varphi(x)) + \underbrace{t\psi'(\varphi(x); \varphi'(x; h))}_{(\psi \circ \varphi)'(x; h)} + o(t)$$


$$(\psi \circ \varphi)'(x; h)$$

□

Dém du théorème (lorsque $I = \emptyset$) (par l'absurde)

$$\Theta_\sigma(x) = f(x) + \sigma \|c(x)\| \stackrel{I = \emptyset}{=} f(x) + \sigma \|c(x)\|$$

- Si x_* n'est un min local strict de Θ_σ :
 il n'est pas vrai que $\exists V$ de x_* , $\forall x \in V \setminus \{x_*\}$
 on a $\Theta_\sigma(x) > \Theta_\sigma(x_*)$



$$\Rightarrow \exists (x_k) \rightarrow x_*, x_k \neq x_* : \Theta_\sigma(x_k) \leq \Theta_\sigma(x_*)$$

$$t_k = \|x_k - x_*\| \xrightarrow{\text{s. suit}} d \neq 0$$

$$\downarrow 0$$

$$\begin{aligned} x_k &= x_* + t_k d_k \\ &= x_* + t_k d + t_k (d_k - d) \\ &\stackrel{DD}{=} x_* + t_k d + o(t_k) \end{aligned}$$

- Θ_σ est lipschitz avec des

$$\Theta_\sigma(x_*) \geq \Theta_\sigma(x_k) = \Theta_\sigma(x_* + t_k d + o(t_k))$$

$$= \Theta_\sigma(x_* + t_k d) + o(t_k)$$

$$\Rightarrow \Theta'_\sigma(x_*; d) \leq 0$$

$$\parallel f'(x_*) \cdot d + \sigma (\| \cdot \| \circ c)'(x_*; d)$$

$$\| \cdot \|'(c(x_*); c'(x_*)d)$$

(lemme)

$$\lim_{t \rightarrow 0} \frac{1}{t} \left[\underbrace{\|c(x_*) + t c'(x_*)d\|}_{\parallel c'(x_*)d \parallel} - \|c(x_*)\| \right]$$

$$|\langle u, v \rangle| \leq \|u\| \|v\|_D$$

$$0 \geq f'(x_k) \cdot d + \sigma \|c'(x_k) \cdot d\|$$

$$= -d_k^T c'(x_k) d + \sigma \|c'(x_k) d\|$$

$$\sigma \|c'(x_k) d\| \leq d_k^T c'(x_k) d$$

$$\leq \|d_k\|_D \|c'(x_k) d\|$$

$$\underbrace{(\sigma - \|d_k\|_D)}_{> 0} \|c'(x_k) d\| \leq 0$$

$$\Rightarrow c'(x_k) d = 0$$

• CS2, $d_k \in \Lambda_k$:

$$d^T \nabla_{xx}^2 l(x_k, d_k) d \geq 0 \quad (d \neq 0, c'(x_k) d = 0)$$

$$l(x_k, d_k) = l(x_k, d_k) + \frac{t_k^2}{2} d^T \nabla_{xx}^2 l(x_k, d_k) d + o(t_k^2)$$

$$\rightarrow l(x_k, d_k) < l(x_k, d_k), \text{ the proof}$$

• Continuity deriv

$$\theta_f(x_k) \leq \theta_f(x_k) = f(x_k) = l(x_k, d_k)$$

$$\leq l(x_k, d_k) = f(x_k) + d_k^T c(x_k)$$

$$\leq f(x_k) + \underbrace{\|d_k\|_D}_{\leq \sigma} \|c(x_k)\|$$

$$\leq \theta_f(x_k)$$

continuity deriv



IV

Globolisation de l'OQS

(I = \phi)

On determine un pas \alpha_k tel que

\theta_{\sigma}(x_k + \alpha_k d_k) \le \theta_{\sigma}(x_k) + \omega \alpha_k \theta'_{\sigma}(x_k; d_k)

\omega \in]0, 1/2[(typiquement 10^{-4})

On se contente de montrer ici que d_k determinee par le (PQO) est une direction de descente de \theta_{\sigma} en x_k, c-a-d

- d_k est solution du (PQO) avec \tau_k > 0
 - \sigma > \|d_k^{QP}\|_D
 - x_k n'est pas un point stationnaire
- alors \theta'_{\sigma}(x_k; d_k) < 0

Donc \theta_{\sigma}(x) = f(x) + \sigma(1 - \|c\|)(x)

\theta'_{\sigma}(x_k; d_k) = \nabla f(x_k)^T d_k + \sigma(1 - \|c\|)'(c(x_k); c'(x_k) d_k)

(PQO) (KKT)

$$\begin{cases} \nabla f(x_k) + \tau_k d_k + c'(x_k)^T d_k = 0 \\ c(x_k) + c'(x_k) d_k = 0 \end{cases}$$

$$\begin{aligned} \lim_{t \rightarrow 0} \frac{1}{t} [\|c(x_k) + t c'(x_k) d_k\| - \|c(x_k)\|] \\ = - \|c(x_k)\| \end{aligned}$$



$$= \nabla f(x_k)^T d_k - \sigma \|c(x_k)\|$$

$$= -d_k^T M_k d_k - \underbrace{\left(\frac{\nabla P_Q}{d_k}\right)^T c'(x_k)}_1 d_k - \sigma \|c(x_k)\|$$

$$\leq \underbrace{\left(\frac{\nabla P_Q}{d_k}\right)^T c(x_k)}_{\leq \|d_k\|_D \|c(x_k)\|} - d_k^T M_k d_k - \sigma \|c(x_k)\|$$

$$\leq \underbrace{-d_k^T M_k d_k}_{\geq 0} + \underbrace{\left(\sigma - \|d_k\|_D\right)}_{< 0} \|c(x_k)\|$$

(M_k > 0)

$$\leq 0$$

Supposons que $\theta'(x_k; d_k) \geq 0$

$$\Rightarrow d_k = 0 \text{ ou } c(x_k) = 0$$

$$CO \text{ de } P_Q \Rightarrow \begin{cases} \nabla f(x_k) + c'(x_k)^T \lambda_k^{PQ} \geq 0 \\ c(x_k) = 0 \end{cases}$$

$\Rightarrow (x_k, \lambda_k)$ est stationnaire




Rmq sur les TP

① \exists de multiplier. (avec $d/2$)

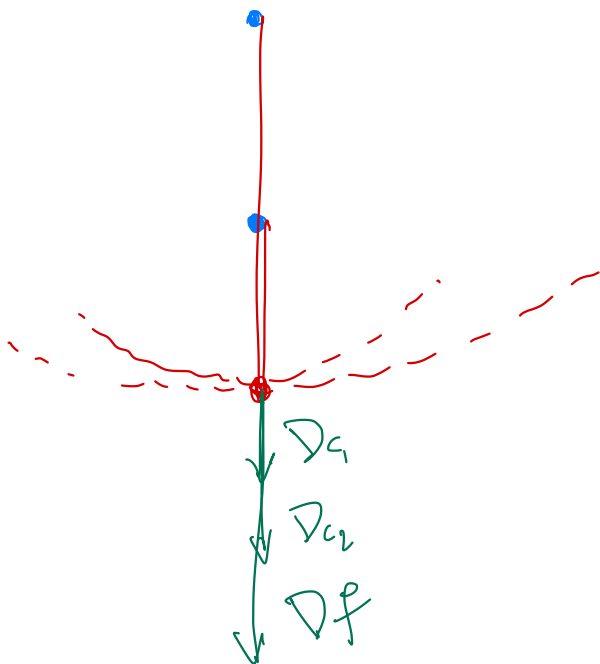
$C'(x_*)$ surjective \Rightarrow (conditions qualifiées) $\Rightarrow \exists \lambda_*$

Exemples



$$\nabla f(x) + \sum \lambda_i \nabla c_i(x) = 0$$

$$\nabla c(x) = \begin{pmatrix} 0 \\ 0 \\ x \\ x \\ x \end{pmatrix} = \begin{pmatrix} 0 \\ x \end{pmatrix}$$



②

$$x_x \text{ sol} \Rightarrow \text{CN2}$$

$$x_x \text{ sol.} \Leftrightarrow \text{CS2}$$

CS2

$L_x \succeq 0$ dans $N(C'(x_x))$

$$d^T L_x d \geq 0, \quad \underline{\forall d: C'(x_x) d = 0}$$

$$Z := \text{null}(C'(x_x)) \quad n-m$$

$$\Leftrightarrow \exists u \in \mathbb{R}^{n-m}$$

$$u^T \boxed{Z^T L_x Z} u \geq 0$$



il ne suffit pas de répondre à

$$(e^i)^T Z^T L_x Z e^i \geq 0, \quad \forall i$$

$$(e^i)^T \begin{pmatrix} \varepsilon & 1 \\ 1 & \varepsilon \end{pmatrix} e^i = \varepsilon > 0$$

3

$d_1 = ?$

$$\nabla f(x_k) + \underbrace{c'(x_k)^T}_{n \times m} \underbrace{d_k}_m \neq 0$$

$$\rightarrow d = - (c'(x) c'(x)^T)^{-1} c'(x) \nabla f(x)$$

$$\rightarrow \min \| \nabla f(x_k) + c'(x_k)^T d \|_2^2$$


$$d = -c'(x) \setminus \nabla f(x)$$

$$(N) \quad \nabla f(x) + \nabla^2 f(x) d = 0$$

$$\nabla^2 f(x) \rightarrow I \quad (\text{algorithme des gradients})$$

$$\nabla f(x) + d = 0 \Rightarrow d = -\nabla f(x)$$

Très lent
à cause de



Mais théoriquement
convergent