

Master MIMSE - Année 2

# **Optimisation Quadratique**

## **Optimisation quadratique avec contraintes**

### **Méthodes numériques**

# Algorithmes “extérieurs”

- On veut optimiser une fonction sous des contraintes.
- Si à l’optimum aucune contrainte n’est active, la solution aurait pu être trouvée au moyen d’une méthode d’optimisation sans contrainte.
- Sinon, à l’optimum une ou plusieurs contraintes sont actives.
- PL : identifier les contraintes actives mène à l’optimum.
- en général “dans un coin” ou facette optimale.
- PNL : optimum dans un coin, sur toute une “facette” ou au milieu d’une facette.
- Algos “extérieurs” qui “se baladent” le long de la frontière du domaine,
- qui “jonglent” avec l’ensemble actif (des contraintes actives)  
 $J(x) = \{j | g_j(x) = 0\}$ .

# Gradient projeté

- Cette méthode est une méthode qui combine deux idées :
  - une direction de descente (plus forte pente)
  - une direction tangentielle (rester à la frontière).
- Soit un point  $\boldsymbol{x}$  et  $\nabla g_j$  les gradients des fonctions des contraintes *actives* en  $\boldsymbol{x}$ .
- On cherche une direction de descente orthogonale aux  $\nabla g_j$ ,
- Projection de  $-\nabla f$  sur l'orthogonal de  $S = \text{Vect}\{\nabla g_j\}$ .

## Formule de projection

- En un point  $x$  sur la frontière,
- une direction  $s$  dans  $S$  est de la forme

$$s = \sum_{j \in J(x)} \mu_j \nabla g_j(x) = N\mu,$$

avec

$$N = \left( \begin{array}{c|c|c} \gamma_1 & \dots & \gamma_l \end{array} \right)$$

où les

$$\gamma_j = \frac{\nabla g_j(x)}{\|\nabla g_j(x)\|}$$

- Soit  $g = \nabla f(x)$
- $g = r + s$  avec  $s \in S$  et  $r \in O(S)$ .
- On utilisera  $-r$  comme direction.

## Projection 2

- On a  $g = r + N\mu$
- donc  $N^T g = N^T r + N^T N\mu$
- On suppose que les  $\gamma$  sont linéairement indépendants
- (sinon on aurait sélectionné une base de  $S$ )
- alors  $N^T N$  est inversible !
- donc  $\mu = (N^T N)^{-1} N^T g$
- d'où

$$r = (I - N(N^T N)^{-1} N^T)g.$$

- $r$  est tangente (dans  $O(S)$ )
- direction de descente.
- Si  $r = 0$ ?
- Point de KKT

# Algorithme

1. (Initialisation)  $X_1$  un point faisable,
2. (Itération k) Calculer  $g = \nabla f(X_k)$
3. Calculer  $d_k$  la projection sur  $O(S_k)$  (si pas de contraintes actives, on garde le gradient)
4. Si  $d_k = 0$  une relation de KKT est vérifiée
  - (a) Si les  $\mu_i$  satisfont KKT : fini,
  - (b) Sinon prendre un  $\mu_i$  de mauvais signe, enlever  $i$  de  $J(x)$  et réitérer.
5. Maximiser le long de la direction, tout en restant faisable,
6.  $X_{k+1}$
7. Réitérer
8. Si on sort du domaine faisable, calculer une direction de retour
  - (a)  $w$  vecteur du viol des contraintes,
  - (b) direction de retour  $s = N(N^T N)^{-1}w$

# Remarques

- Cette méthode marche très bien pour des contraintes linéaires.
- Peut résoudre un PL de façon analogue au simplexe.
- Mais peut aussi trouver l'optimum pour une fonction objectif non linéaire.
- Appliquée à des contraintes quadratiques, marche encore assez bien
- mais est pénalisée par les “sauts de faisabilité”
- en fait “linéarise” par morceaux la frontière
- Le calcul de  $(N^T N)^{-1}$  à chaque itération, est une faiblesse de la méthode,
- en fait on ajoute ou on retranche des hyperplans de l'ensemble actif
- Il existe des relations de récurrence pour *mettre à jour* la matrice plutôt que de la recalculer.
- Autres directions à projeter que  $-\nabla f$  ?

# Quasi-Newton avec contraintes d'égalité

- On peut incorporer les contraintes d'égalité linéaires dans une méthode DFP
- Contraintes d'inégalité actives  $\leftrightarrow$  égalités
- Contraintes d'inégalité non actives  $\leftrightarrow$  ignorées
- Si on n'a qu'une contrainte d'égalité  $a^T x = b$
- En l'absence de contraintes, on a trouvé une direction  $d_k = -H_k g_k$  par DFP, DFP complémentaire ou gradients conjugués.
- La "vraie" direction de recherche devient

$$d_{k1} = -H_{k1} g_k$$

avec

$$H_{k1} = H_k - \frac{H_k a a^T H_k}{a^T H_k a}$$

- Cette direction permet de vérifier la contrainte tout le long de la recherche linéaire :

$$\begin{aligned} a^T (X_k + \rho d_{k1}) &= a^T X_k - \rho a^T \left( H_k - \frac{H_k a a^T H_k}{a^T H_k a} \right) \\ &= b - \rho \left( a^T H_k - \frac{a^T H_k a a^T H_k}{a^T H_k a} \right) \\ &= b. \end{aligned}$$

- Les directions  $d_{k1}$  ont encore la propriété d'être mutuellement conjuguées,
- donc si  $f$  est quadratique, termine en  $n - 1$  itérations.

## $m$ contraintes d'égalité

- On range les vecteurs des contraintes d'égalité comme colonnes d'une matrice  $A$  telle que :

$$A^T x = b.$$

- La direction de recherche est donnée par une formule analogue :

$$d_{km} = -H_{km}g_k$$

avec

$$H_{km} = H_k - H_k A (A^T H_k A)^{-1} A^T H_k$$

- Cette direction permet de vérifier la contrainte tout le long de la recherche linéaire :

$$\begin{aligned} A^T (X_k + \rho d_{km}) &= A^T X_k \\ &\quad - \rho A^T (H_k - H_k A (A^T H_k A)^{-1} A^T H_k) \\ &= b - \rho A^T H_k \\ &\quad + \rho A^T H_k A (A^T H_k A)^{-1} A^T H_k \\ &= b. \end{aligned}$$

- Encore une fois, terminaison quadratique car directions conjuguées.
- On peut calculer  $H_{km}$  en calculant des  $H_{k1}$   $m$  fois, les uns à la suite des autres (pour  $a_1$  puis  $a_2$  puis  $a_3$  etc.)
- Evite de calculer  $(A^T H_k A)^{-1}$ .

# Inégalités linéaires

- A  $X_k$  inégalités actives traitées comme des égalités
- inégalités non actives ignorées.
- Si  $X_k + \rho^* d_k$  viole une inégalité non active en  $X_k$  on doit calculer  $X_{k+1}$  intersection de la droite de recherche et de la contrainte.
- Il faut alors incorporer cette nouvelle contrainte active dans le calcul de  $H_{k+1,m+1}$ .
- De même, on peut être amené à relâcher une contrainte pour chercher dans une direction où elle est non active (“changement de direction dans un coin”) :

$$H_k = H_{k1} + \frac{aa^T}{a^T a}$$

si on n’a qu’une égalité en tout, ou si on relâche *une* contrainte  $a_r$  parmi  $q$  formant la matrice  $A$  :

$$H_{k,q-1} = H_{k,q} + \frac{P_{q-1} a_r a_r^T P_{q-1}}{a_r^T P_{q-1} a_r}$$

avec

$$P_{q-1} = I - A_{q-1} (A_{q-1}^T A_{q-1})^{-1} A_{q-1}^T$$

où  $A_{q-1}$  est la matrice  $A$  privée de la  $r$ ème colonne  $a_r$ .

- Plusieurs contraintes à enlever en même temps : on peut faire l’opération successivement pour chaque contrainte.

## Revoilà Lagrange...

- Quand enlever une contrainte et laquelle ?
- A chaque point, calculer les coefficients de Lagrange

$$g_k = A\lambda$$

donc

$$\lambda = (A^T A)^{-1} A^T g_k$$

pour les contraintes actives.

- Si (pour un min) des  $\lambda$  sont négatifs,
- on relâche la contrainte correspondant au  $\lambda$  le plus négatif.
- Cette méthode revient à jongler avec les contraintes actives comme le gradient projeté.
- On traite des contraintes non linéaires en les approchant localement par un hyperplan tangent et avec des directions de retour.

# Algorithmes de points intérieurs

- Jusqu'ici, on se balade sur la frontière du domaine.
- Par contraste, les algorithmes de points intérieurs restent à l'intérieur du domaine des contraintes d'inégalité,
- et s'approchent de la frontière sans jamais l'atteindre (fonctions barrière)
- donc, pas de relaxation
- ou sont dissuadés de sortir trop du domaine faisable (pénalités simples)
- donc, relaxation.
- On supposera que

$\exists x$  tel que  $g(x) < 0$  pour toute contrainte  $g(x) \leq 0$ .

# Fonctions de pénalité

- Idée : trouver une fonction  $P(x)$  telle que l'optimum de

$$\min f(x), g_k(x) \leq 0$$

soit proche de l'optimum de

$$\min f(x) + P(x).$$

- Ne pas perturber  $f$  quand on est à la frontière,
- Pénaliser fortement quand on viole une contrainte.
- Le lagrangien

$$f(x) + \sum \lambda_k g_k(x)$$

est une forme *très* particulière de pénalité.

# Exemples de fonctions de pénalité usuelles

- Pour confiner une variable  $x$  dans  $[-X, X]$  :
  - $P(x) = k \left(\frac{x}{X}\right)^{2M}$  avec  $k > 0$  et  $M$  entier non nul.
  - $P(x) = -k \ln \left(-\cos \frac{\pi x}{X}\right)$
- Pour confiner  $x$  dans  $[X_1, X_2]$  :
  - $P(x) = k \left(\frac{2x-(X_1+X_2)}{X_2-X_1}\right)^{2M}$  avec  $k > 0$  et  $M$  entier non nul.
  - $P(x) = -k \ln \left(-\cos \frac{\pi[2x-(X_1+X_2)]}{X_2-X_1}\right)$
- Inégalités  $g_i(x) \geq 0$ 
  - $P(x) = \sum_i k_i [g_i(x)]^2$  avec  $k_i > 0$
  - $P(x) = \sum_i k_i [g_i(x)]^{2M}$  avec  $k_i > 0$

la somme étant prise sur les contraintes actives
- Egalités  $g_i(x) = 0$ 
  - *idem* que les inégalités
  - $P(x) = \sum_i k_i |g_i(x)|$  avec  $k_i > 0$

# Remarques

- Méthode simple,
- assez efficace,
- attention : on peut perturber fortement dans l'intérieur donc rester proche de la frontière
- de même perturbations parfois chaotiques "loin" à l'extérieur
- faire des petits pas ?
- Problème sans contraintes à résoudre par une technique d'optimisation sans contrainte.
- Mais fortement non linéaire, parfois même pas quadratique.
- Une contrainte est remplacée par une "crevasse"
- donc **attention** la méthode de plus forte pente risque de mal marcher.
- Efficacité dépend beaucoup des ajustements des  $k_i$  (qui peuvent varier d'une itération à l'autre).

# Ajustement des paramètres

- En posant

$$Z(\mathbf{x}) = f(\mathbf{x}) + \sum_i k_i g_i(\mathbf{x})^2$$

(contraintes d'égalité ou inégalités actives)

- on cherchera, quand on s'approche de l'optimum, à vérifier

$$\sum_j \left( \frac{\partial f}{\partial x_j} + 2 \sum_i k_i g_i \frac{\partial g_i}{\partial x_j} \right) \frac{\partial g_r}{\partial x_j} = 0.$$

- on résout ce système pour trouver les  $k_i$ .
- On peut aussi utiliser  $k'_i = \frac{|g_i|}{\varepsilon_i} k_i$  avec  $\varepsilon_i$  une certaine tolérance.
- En principe,  $k_i$  augmente à chaque itération
- $g_i \rightarrow 0$  quand  $k_i \rightarrow +\infty$ .
- Coûteux d'évaluer  $k_i$  ? Tâtonnements !

# Fonctions barrières

- Ajouter une pénalité qui empêche même d'atteindre la frontière.
- On part d'un point strictement faisable,
- on résout le problème perturbé sans contrainte,
- on a le nouveau point courant,
- on change les paramètres pour s'autoriser à approcher de la frontière
- on réitère.
  
- 2 types de fonctions couramment utilisées pour remplacer  $g(x) \leq 0$  :
  - Fonctions inverses :  $\frac{1}{g(x)}$ ,
  - Fonctions logarithmiques :  $\log |g(x)|$ .
- A chaque itération on doit rester faisable donc si on sort du domaine, on réajuste le pas.

# Méthode SUMT

- *Sequential Unconstrained Minimization Technique*, Carroll et Fiacco-McCormick.
- Pour une minimisation sous contraintes d'inégalité  $g_i(x) \geq 0$ .
- Algorithme :
  1. Point initial strictement faisable  $X_1$
  2. Déterminer des paramètres  $w_i$  et  $r_1$
  3. Itération courante :
    - (a)  $X_{k+1}$  minimise

$$Z_k(x, r_k) = f(x) + r_k \sum_i \frac{w_i}{g_i(x)}.$$

en partant de  $X_k$

- (b) Calculer  $r_{k+1}$
- (c) Si pas critère d'arrêt (ex. lié à la précision), reboucler.

# Convergence

- La méthode converge vers un unique minimum si on a :
  - L'ensemble  $R_0 = \{x : g_i(x) > 0\}$  est non vide
  - $f$  et  $-g_i$  sont  $c^2$  (OK) et convexes
  - Pour tout  $K$  fini, l'ensemble  $\{x \in R : f(x) \leq K\}$  est borné avec  $R$  fermeture de  $R_0$ .
  - pour tout  $r_k > 0$ ,  $Z_k(x, r_k)$  est strictement convexe.
- En pratique, converge souvent même si certaines de ces conditions sont violées !

## Choix des paramètres

- Les  $w_i$  sont calculés une fois pour toutes,
- ils déterminent l'importance relative de chaque contrainte
- “facteurs d'échelle”.
- Choisir  $w_i$  pour que les  $w_i/g_i(x)$  soient du même ordre de grandeur.
- Les  $r_k$  déterminent de combien on peut s'approcher de la frontière
- $r_k \rightarrow 0$  permettant  $g_i(x) \rightarrow +\infty$
- La valeur de  $r_1$  est assez importante et détermine le temps de calcul de l'algorithme,
- le schéma de décroissance des  $r_k$  importe peu :
- plus les  $r_k$  convergent vite vers 0,
- moins il y a d'itérations,
- mais plus les calculs sont longs à chaque itération.
- En pratique,  $r_{k+1} = r_k/10$ .
- On recommande :

$$r_1 = \left( \frac{\nabla f(x_1)^T [\nabla^2 P(x_1)]^{-1} \nabla f(x_1)}{\nabla P(x_1)^T [\nabla^2 P(x_1)]^{-1} \nabla P(x_1)} \right)^{1/2}$$

- ou par tâtonnements,
- en général  $0,5 \leq r_1 \leq 50$ .

# Remarques

- Méthode assez efficace,
- La précision des calculs joue un rôle vraiment important.
- Optimisation très non linéaire.
- On peut incorporer des contraintes d'égalité sous forme de pénalités simples :

$$r_k^{-1/2} \sum_i [g_i(\mathbf{x})]^2.$$

- Vers la fin, on voit très vite quelles sont les contraintes actives à l'optimum donc on peut arrêter les calculs et prendre une autre méthode.