

# Optimisation

mots clef Scilab: *chsolve, deff, function, optim, quapro, spec, plot, plot2d, plot3d, ...*

Soit  $J \in C^2(\Omega \subset \mathbb{R}^d, \mathbb{R})$ , le problème est de trouver  $X$  et (ou)  $J(X)$  tels que

$$J(X) = \min_{Y \in \Omega} J(Y). \quad (1)$$

Ce problème peut se ramener à la résolution d'un système non linéaire. Par exemple, si  $\Omega$  est un ouvert, on cherchera à résoudre :  $G(X) := \nabla J(X) = 0$ . Inversement, il arrive que la résolution d'un système peut se ramener à un problème d'optimisation.

On testera des algorithmes sur l'exemple clef suivant, où  $A$  est symétrique définie positive et  $B \in \mathbb{R}^d$ ,

$$J_0(X) = \frac{1}{2} \langle AX, X \rangle - \langle B, X \rangle, \quad A = \begin{pmatrix} 2 & -1 & 0 & 0 & \cdots & 0 \\ -1 & 2 & -1 & 0 & \cdots & 0 \\ 0 & -1 & 2 & -1 & 0 & 0 \\ \vdots & & & & & \vdots \\ 0 & 0 & -1 & 2 & -1 & 0 \\ 0 & \cdots & 0 & -1 & 2 & -1 \\ 0 & \cdots & \cdots & 0 & -1 & 2 \end{pmatrix}, \quad B = \begin{pmatrix} 1 \\ 1 \\ \vdots \\ \vdots \\ \vdots \\ 1 \\ 1 \end{pmatrix}. \quad (2)$$

et un exemple non quadratique  $J_1(x, y) := y^2 - x^2 + x^4/4$ .

## 1 Minimisation à une variable

On peut chercher à résoudre  $J'(x) = 0$  par des méthodes classiques de résolution approchée d'une équation non linéaires : méthode de la corde, du point fixe, de Newton, ..., voir le TP sur la résolution d'un système non linéaire.

1.  $\square$  **Algorithme de trichotomie** : ( voir Chambert Loir et Fermigier p. 215. ou Ciarlet, exo 8.4.4 p. 109 corrigé p.184) L'intérêt de cette méthode est de ne pas calculer de dérivée. Soit  $f$  une fonction convexe ( et dérivable) sur  $[a, d]$ .  $f$  atteint son minimum en  $\xi \in [a, d]$ . Soit  $a < b < c < d$ ,  $p(x, y) := (f(y) - f(x))/(x - y)$ ,  $p_1 := p(a, b)$ ,  $p_2 := p(b, c)$ ,  $p_3 := p(c, d)$ , alors on sait que  $f'$  est croissante sur  $[a, d]$  et

$$p_1 \leq f'(b) \leq p_2 \leq f'(c) \leq p_3.$$

Donc, si  $p_3 \leq 0$ ,  $f$  est décroissante sur  $[a, c]$  et  $\xi \in [c, d]$ , sinon, si  $p_2 \leq 0$ ,  $\xi \in [b, d]$ , sinon  $p_1 \leq 0$ ,  $\xi \in [a, c]$ , sinon  $p_1 > 0$ , et  $\xi \in [a, b]$ .

Implémenter cette algorithme en prenant  $b := (a + d)/2 - t(d - a)/4$ ,  $c := (a + d)/2 + t(d - a)/4$ .

**Cas test**:  $f(x) = x \ln(x)$ ,  $[a, d] = [0, 1]$ ,  $t = 0.2$ .

2. La minimisation d'une fonctionnelle à plusieurs variables peut se ramener à "plusieurs" minimisations de fonctions à une seule variable. C'est le cas pour la méthode du gradient à pas optimal, la méthode du gradient conjugué, la méthode de Relaxation.

La méthode de Relaxation : ( Ciarlet p. 201) soit  $(e_k)_{1 \leq k \leq d}$  la base canonique de  $\mathbb{R}^d$ ,  $X_0$  donné, on définit par récurrence sur  $n$  et sur  $k$  :  $X_{n,k}$  par :  $X_{n,0} = X_n$ , pour  $1 \leq k \leq d$ ,  $X_{n,k} = X_{n,k-1} + \rho_k e_k$  où  $\rho_k$  est donné par  $J(X_{n,k}) = \min_{\rho \in \mathbb{R}} J(X_{n,k-1} + \rho e_k)$ ,  $X_{n+1} = X_{n,d}$ .

Ainsi, on résoud à chaque étape  $d$  problèmes de minimisation de la forme  $j(\rho) = J(X + \rho e)$ .

Pour  $J = J_0$  on retombe sur la méthode de Gauss-Seidel, voir le TP sur la résolution des systèmes linéaires.

## 2 Méthodes de gradient

Elles sont de la forme  $X_{n+1} = X_n - \rho_n \nabla J(X_n)$ , avec un point de départ  $X_0$  et  $\rho_n > 0$  pour descendre dans la direction de plus grande pente.

1.  **La méthode du gradient à pas fixe** :  $\rho_n = \rho > 0$ .  
Tester cette méthode sur  $J_0$ , pour  $d = 3$ ,  $X_0 := 0_{\mathbb{R}^3}$ ,  $\rho = 0.1, 0.5, 0.7$ , ou 1 .
2. La méthode du gradient à pas optimal : voir Ciarlet p 189.  
 $j(\rho) = J(X + \rho \nabla J(X_n))$ ,  $j(\rho_n) = \min_{\rho \in \mathbb{R}} j(\rho)$ ,  $X_{n+1} = X_n - \rho_n \nabla J(X_n)$ . Pour  $J = J_0$  (et un choix "optimal" des directions de descente) on obtient la méthode du gradient conjugué : voir Ciarlet p 194-201.

## 3 Méthodes de Newton $X_{n+1} = X_n - (\nabla^2 J(X_n))^{-1} \nabla J(X_n)$

1. Que donne cette méthode pour la minimisation de  $J_0$  en une itération.
2.  Tester cette méthode sur  $J_1$ ,  $X_0 := [1, 1]$ .
3.  Comparer avec la méthode de gradient à pas fixe.

## 4 Exemples de Minimisation avec contraintes

1.  Utiliser des multiplicateurs de Lagrange pour minimiser  $J_0$  ( $B = 0$ ,  $d = 3$ ), sur  $x_1 + 2x_2 + 3x_3 = 10$ .
2.  **La méthode du gradient projeté** : voir Ciarlet p.203  
Soit  $\Omega$  un convexe fermé de  $\mathbb{R}^d$  et  $Proj$  le projecteur orthogonal de  $\mathbb{R}^d$  sur  $\Omega$ , on a l'algorithme suivant :

$$X_{n+1} = Proj(X_n - \rho_n \nabla J(X_n)) = X_n - \rho_n Proj(\nabla J(X_n))$$

Tester cette algorithme sur  $J(X) = -\langle AX, X \rangle$ ,  $\Omega$  la boule unité de  $\mathbb{R}^d$ ,  $X_0 \neq 0$ ,  $d = 3$ . Comparer le résultat obtenu avec les valeurs propres et les vecteurs propres de  $A$ .

### Références :

Chambert Loir et Fermigier, Exercices pour l'agrégation, 2  
Ciarlet, Introduction à l'analyse numérique matricielle et à l'optimisation,  
Ciarlet, Miara, Thomas, Exercices 'analyse numérique matricielle et d'optimisations avec solutions,  
Dumas, L'épreuve de modélisation à l'agrégation,  
Henrici, Elements of numerical analysis,  
Lax, Linear Algebra,  
Rouvière, Petit guide de calcul différentiel,  
Schatzman, analyse numérique : cours et exercices pour la licence,

= Corrigé en TP