

Chapitre 1

Notions Générales

Chapitre 1

Notions Générales

1.1 Introduction

L'optimisation est la recherche des valeurs x^* appartenant à un ensemble X qui minimisent¹ une fonction f définie sur X à valeurs réelles. C'est ce qu'on appelle un problème d'optimisation. On notera également ce problème comme suit

$$\min_{x \in X} f(x). \quad (1.1)$$

On dit que X est l'ensemble admissible du problème et un point de X est dit point admissible. La fonction f est appelée fonction objective ou fonction-coût. Nous supposons que X est une partie d'un espace vectoriel de dimension finie sur le corps des réels \mathbb{R} que l'on pourra identifier à \mathbb{R}^n et que la fonction f est assez régulière (au moins continue et si possible différentiable).

En dimension infinie on cherche plutôt une fonction qui représente une trajectoire optimale ou une forme optimale. Lorsque l'on veut résoudre ce type de problèmes, il est né-

1. on peut montrer sans difficulté que c'est aussi équivalent à maximiser

cessaire de passer par une phase de discrétisation qui, en utilisant une technique adéquat, construit un problème approché en dimension finie, qu'on pourra résoudre en utilisant des algorithmes spécifiques.

1.2 Notions d'algorithmes

Un algorithmes \mathcal{A} d'obtention de solutions des problèmes d'optimisation est un processus itératif qui, génère une suite de points $\{x_k\}_{k \in \mathbb{N}} \subset X^2$ en partant d'une valeur initiale $x_0 \in X$, plus précisément

Définition 1.1. *Un algorithme qui construit itérativement une suite*

$$x_0, x_1, \dots, x_k, \dots$$

est défini par une application multivoque \mathcal{A} de X dans $\mathcal{P}(X)$ et un ensemble de solutions désirées $\Omega \subset X$. De façon abstraite un algorithme est

1)

$$\begin{cases} x_{k+1} \in \mathcal{A}(x_k) & \text{si } x_k \notin \Omega, \\ x_{k+1} = x_k & \text{si } x_k \in \Omega. \end{cases}$$

2) Une fonction test $\alpha : X \rightarrow \mathbb{R}$ continue telle que :

$$x \notin \Omega \Rightarrow \alpha(y) < \alpha(x); \quad \forall y \in \mathcal{A}(x).$$

Remarque 1.1. *voici quelques exemples de l'ensemble des solutions*

- $\Omega = \{x \in X : \nabla f(x) = 0\}$,
- $\Omega = \{x \in X : x \text{ est une solution optimale du problème (1.1)}\}$,
- $\Omega = \{x \in X : f(x) < v + \varepsilon\}$, $\varepsilon > 0$ et v est la valeur minimal de la fonction objective.

2. X est incluse dans un espace au moins topologique

Le choix de la fonction test $\alpha(x)$ est souvent $f(x)$, $\|\nabla f(x)\|$ ou $\|x - x^*\|$ ($x^* \in \Omega$).

Définition 1.2. Soit \mathcal{A} une fonction multivoque dans X , \mathcal{A} est dite fermée en $x \in X$ si

$$\begin{cases} x_k \in X, & x_k \rightarrow x \\ y_k \in \mathcal{A}(x_k), & y_k \rightarrow y \end{cases} \Rightarrow y \in \mathcal{A}(x) \quad (1.2)$$

Théorème 1.1 (Zangwill, [42]). Si la fonction multivoque \mathcal{A} est localement bornée et fermée alors tout point d'accumulation de $\{x_k\}_{k \in \mathbb{N}}$ est dans Ω .

Démonstration. Soit K tel que $\lim_K x_k = x$. Alors $\lim_K \alpha(x_k) = \alpha(x)$ (α continue), $\{\alpha(x_k)\}_{k \in \mathbb{N}^*}$ est une suite décroissante puisque $x_k \in \Omega$ ce qui implique $x_{k+1} = x_k$ et donc $\alpha(x_{k+1}) = \alpha(x_k)$. D'autre part $x_k \notin \Omega$ conduit au fait que $x_{k+1} \in \mathcal{A}$, donc $\alpha(x_{k+1}) < \alpha(x_k)$. Puisque $\{\alpha(x_k)\}_{k \in \mathbb{N}}$ est décroissante, alors $\lim \alpha(x_k) = \alpha(x)$.

$\{x_k\}_{k \in K}$ bornée et \mathcal{A} localement bornée conduit au fait que $\{x_{k+1}\}_{k \in K}$ est bornée.

Soit $K' \subset K$ tel que $\lim_{K'} x_{k+1} = x'$, alors $\alpha(x') = \alpha(x)$.

Puisque \mathcal{A} est fermée, alors $x' \in \mathcal{A}(x)$. Si $x \notin \Omega$, alors $x' \in \mathcal{A}(x)$ donc $\alpha(x') < \alpha(x)$, qui est une contradiction \square

Remarque 1.2. Ce théorème a une valeur théorique, on verra plus loin que dans des cas spécifiques, une démonstration directe de convergence est plus facile en général.

1.3 Convergence

On dira qu'un algorithme \mathcal{A} converge globalement si une sous-suite des suites $\{x_k\}_{k \in \mathbb{N}}$ de valeurs qu'il engendre tendent vers un x^* appartenant à l'ensemble de solutions Ω . Il se pose alors le problème de comparer l'efficacité des algorithmes par l'examen des suites qu'il génèrent. La notion de vitesse de convergence permet de qualifier le comportement asymptotique d'une suite.

1.3.1 Vitesse de convergence en quotient

On s'intéresse à l'étude du quotient

$$q_k = \frac{\|x_{k+1} - x^*\|}{\|x_k - x^*\|}. \quad (1.3)$$

- Si $\limsup q_k = 1$, on dit que la convergence est sous-linéaire.
- Si $\limsup q_k = \alpha < 1$, on dit que la convergence est linéaire et α est le taux de convergence associé.
- Si $\lim q_k = 0$, on dit que la convergence est super-linéaire.
- Si $\exists \gamma > 1$ tel que $\limsup \frac{\|x_{k+1} - x^*\|}{\|x_k - x^*\|^\gamma} = M < +\infty$, on dit que la convergence est super-linéaire d'ordre γ . En particulier pour $\gamma = 2$ on parle de vitesse de convergence quadratique.

Remarque 1.3.

- *Une suite qui converge sous-linéairement vers sa limite en pratique est considérée comme ne convergeant pas du tout.*
- *Une suite convergeant super-linéairement est convergente linéairement.*

1.3.2 Vitesse de convergence en racine

On s'intéresse à l'étude du taux

$$r_k = \|x_k - x^*\|^{1/k}. \quad (1.4)$$

- Si $\limsup r_k = \alpha < 1$, on dit que la convergence est r-linéaire et α est le taux de convergence associé.
- Si $\limsup r_k = 1$, on dit que la convergence est r-sous-linéaire.

- Si $\lim r_k = 0$, on dit que la convergence est r-superlinéaire.

Remarque 1.4. Une suite convergente linéairement en quotient converge linéairement en racine.

1.4 Notations et définitions

On note $u^\top v$ le produit scalaire Euclidien des vecteurs u et v de \mathbb{R}^n .

1.4.1 Définitions et résultats classiques

Définition 1.3. pour tout $x = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$,

$$\|x\|_1 = \sum_{i=1}^n |x_i|, \quad \|x\|_2 = \sqrt{\sum_{i=1}^n |x_i|^2},$$

et

$$\|x\|_\infty = \max_{1 \leq i \leq n} |x_i|, \quad \|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}},$$

sont des normes vectorielles équivalentes sur \mathbb{R}^n .

Définition 1.4. Soit \mathcal{M}_n l'anneau des matrices carrées $n \times n$ dans \mathbb{R} . Une matrice $A \in \mathcal{M}_n$ est dite semi définie positive si

$$\forall x \in \mathbb{R}^n : x^\top A x \geq 0,$$

elle est dite définie positive si

$$\forall x \in \mathbb{R}_*^n : x^\top A x > 0.$$

Définition 1.5.

1. Le rayon spectral d'une matrice $A \in \mathcal{M}_n$ est le réel positif $\rho(A)$ défini par

$$\rho(A) = \max_{\lambda \in \sigma(A)} |\lambda|,$$

où $\sigma(A)$ est l'ensemble des valeurs propres de A (spectre de A).

2. La trace d'une matrice $A \in \mathcal{M}_n$ (notée $\text{Tr}(A)$) est la quantité

$$\text{Tr}(A) = \sum_{\lambda_i \in \sigma(A)} \lambda_i.$$

Théorème 1.2 (de Shur). Si A est symétrique, il existe une matrice orthogonale Q telle que $Q^{-1}AQ = Q^T A Q$ soit diagonale ce qui veut dire que toute matrice symétrique est diagonalisable.

Remarque 1.5.

- Une matrice symétrique est dite définie positive si et seulement si ses valeurs propres sont toutes positives, elle est dite semi définie positive si ses valeurs propres sont toutes non négatives, avec au moins l'une d'entre elles nulle.
- Soit $A \in \mathcal{M}_n$, si A est semi définie positive alors $\text{Tr}(A) \geq 0$.

Définition 1.6. On appelle norme matricielle subordonnée à une norme définie sur \mathbb{R}^n , la norme matricielle (également notée $\|\cdot\|$) définie par

$$\|A\| = \sup_{x \in \mathbb{R}_*^n} \frac{\|Ax\|}{\|x\|} = \sup_{x \in \mathbb{R}^n, \|x\| \leq 1} \|Ax\| = \sup_{x \in \mathbb{R}^n, \|x\|=1} \|Ax\|.$$

Par définition, on a pour toute norme matricielle subordonnée, la propriété très utile $\|Ax\| \leq \|A\| \|x\|$, l'égalité étant toujours possible pour au moins un vecteur x .

$$\|A\|_1 = \max_j \sum_i |a_{ij}|, \quad \|A\|_2 = \sqrt{\rho(A^T A)} = \sqrt{\rho(AA^T)} = \|A^T\|_2,$$

$$\|A\|_\infty = \max_i \sum_j |a_{ij}|, \quad \|A\|_S = \sqrt{\text{Tr}(A^T A)} = \left(\sum_{i=1, j=1}^n |a_{ij}|^2 \right)^{1/2} \quad (\text{norme de Schur}).$$

Sont des normes matricielles subordonnées aux normes vectorielles de même nom.

Remarque 1.6.

- On remarquera que $\|A\|_2^2$ est la plus grande valeur propre de $A^\top A$. D'autre part si A est symétrique, on a

$$\|A\|_2^2 = \rho(A). \quad (1.5)$$

- Si Q est une matrice symétrique définie positive alors elle engendre une norme sur \mathbb{R}^n (appelée norme de Froebinus) définie par

$$\|x\|_Q^2 = x^\top Q x.$$

Définition 1.7. Soit $A \in \mathcal{M}_n$, une matrice symétrique, on appelle quotient de Rayleigh de la matrice A en $x \in \mathbb{R}_*^n$, la quantité

$$\mathfrak{R}(x) = \frac{x^\top A x}{x^\top x}.$$

Ce quotient à une grande utilité dans le calcul des valeurs propres.

Théorème 1.3. Soit $A \in \mathcal{M}_n$, une matrice symétrique, et $\lambda_1 = \min \sigma(A)$, $\lambda_n = \max \sigma(A)$, alors

$$\lambda_1 \leq \mathfrak{R}(x) \leq \lambda_n,$$

$\forall x \in \mathbb{R}_*^n$.

Définition 1.8. Soit x, y deux vecteurs de \mathbb{R}^n , on définit le produit xy^\top par

$$\begin{aligned} xy^\top : \mathbb{R}^n &\rightarrow \mathbb{R}^n \\ d &\rightarrow (y^\top d) \cdot x \end{aligned}$$

appelé aussi produit tensorielle ou produit dyadique.

Proposition 1.1. Soit $x \in \mathbb{R}^n$ alors la matrice $A = xx^\top$ vérifie les propriétés suivantes

1. A est symétrique.
2. $\sigma(A) = \{0, x^\top x\}$.

3. x est un vecteur propre qui correspond à la valeur propre $x^\top x$.

4. $\text{Tr}(A) = x^\top x$.

1.4.2 Quelques résultats importants

On notera dans toute la suite, f la fonction objective, et s'il y a lieu g son gradient et H son hessien.

Formule de Taylor : Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$, une application de classe C^2 . Alors

$$f(x + d) = f(x) + g(x)^\top d + \frac{1}{2}d^\top H(x)d + o(\|d\|^2).$$

Formule de Taylor avec reste intégral : Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$, une application de classe C^1 , alors

$$f(x + d) = f(x) + \int_0^1 (g(x + td)^\top d) dt = f(x) + \int_x^{x+d} g(z)^\top dz. \quad (1.6)$$

Formule de la moyenne : Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$, une application de classe C^1 sur le segment $[x_1, x_2]$, alors il existe $\hat{x} \in [x_1, x_2]$ tel que

$$f(x_2) = f(x_1) + g(\hat{x})^\top (x_2 - x_1).$$

Il faut noter que les résultats précédents restent valables, si f est une fonction vectorielle.

1.5 Les méthodes numériques de résolution des systèmes d'équations non linéaires

On verra plus loin qu'un problème d'optimisation puisse être transformé en une recherche de solutions d'un système d'équations non linéaires, donc la première idée naturelle

est d'appliquer une méthode numérique de résolution de ces systèmes. Ce qui nous ramènes à étudier deux de telles méthodes : Gauss-Seidel et approximation successives, qui sont des méthodes de premier ordre.

1.5.1 Méthode de Gauss-Seidel

On veut résoudre le système non linéaire

$$\begin{cases} F(x) = 0, \\ F(x) = (F_1(x), F_2(x), \dots, F_i(x), \dots, F_n(x)); 1 \leq i \leq n, \\ x = (x_1, \dots, x_j, \dots, x_n); 1 \leq j \leq n, \end{cases} \quad (1.7)$$

où, $F : \mathbb{R}^n \rightarrow \mathbb{R}^n$ est une fonction vectorielle dans \mathbb{R}^n .

Algorithme 1.1.

Initialisation : $i = k = 0, (x_1^0, \dots, x_n^0) = (0, \dots, 0)$

(1) *Test d'arrêt* : Si $\|F(x_1^k, \dots, x_n^k)\| \simeq 0$, stop

Sinon $k \leftarrow k + 1$

(2) $i \leftarrow i + 1$

On résolve l'équation $F_i(x_1^{k+1}, \dots, x_{i-1}^{k+1}, x_i, x_{i+1}^k, \dots, x_n^k) = 0$ par rapport à x_i

$x_i^{k+1} \leftarrow x_i$

si $i < n$ aller à (2)

sinon

aller à (1)

Remarque 1.7.

- Cette méthode consiste à résoudre une équation (non linéaire) à une inconnue à chaque itération.
- La convergence est mal connue, donc la méthode est peut intéressante.

1.5.2 La méthode des approximations successives

Pour résoudre le système (1.7), on utilise le schéma itératif

$$x_{k+1} = x_k + t \cdot F(x_k); \quad t < 0, \quad (1.8)$$

t est un coefficient fixé.

Définition 1.9. Une fonction F est dite localement lipschitzienne sur un borné B si $\exists M > 0$, $\forall x, y \in B$

$$\|F(x) - F(y)\| \leq M \|x - y\|. \quad (1.9)$$

Elle est dite localement coercive si, Il existe $m > 0$ tels que, $\forall x, y \in B$

$$m \|x - y\|^2 \leq (F(x) - F(y))^\top (x - y). \quad (1.10)$$

Théorème 1.4. On suppose que F est localement lipschitzienne et coercive et soit x^* une solution de (1.7). Alors le schéma (1.8), converge si $t < 0$ suffisamment petit.

Démonstration.

Soit x_0 la première itération et $x^* \in \mathbb{R}^n$ une solution (i.e. $F(x^*) = 0$) et prenons $B = \bar{B}(x_0, \|x_0 - x^*\|)$ (la boule fermé de centre x_0 et de rayon $\|x_0 - x^*\|$). Puisque $x_1 = x_0 +$

$tF(x_0)$ et $F(x^*) = 0$, on a

$$\begin{aligned}
 \|x_1 - x^*\|^2 &= (x_1 - x^*)^\top (x_1 - x^*) \\
 &= x_1^\top x_1 + x^{*\top} x^* - 2x_1^\top x^* \\
 &= (x_0 + tF(x_0))^\top (x_0 + tF(x_0)) + (x_0 + tF(x_0))^\top x^* \\
 &= x_0^\top x_0 + x^{*\top} x^* - 2x_0^\top x^* + t^2 F(x_0)^\top F(x_0) + 2t(x_0 - x^*)^\top F(x_0) \\
 &= \|x_0 - x^*\|^2 + 2t(x_0 - x^*)^\top (F(x_0) - F(x^*)) + \\
 &\quad + t^2 \|F(x_0) - F(x^*)\|^2 \|x_0 - x^*\|^2.
 \end{aligned}$$

Prenons $t < 0$, alors d'après (1.9) et (1.10)

$$\|x_1 - x^*\|^2 \leq (1 + 2mt + M^2 t^2) \|x_0 - x^*\|^2. \quad (1.11)$$

Il suffit de prendre $t > -2\frac{m}{M^2}$ pour avoir

$$0 \leq K = 1 + 2mt + M^2 t^2 < 1.$$

On itère la formule (1.11) pour avoir

$$\|x_k - x^*\|^2 \leq K^k \|x_0 - x^*\|^2. \quad (1.12)$$

□

Remarque 1.8.

- On peut déduire de (1.11) que

$$\|x_{k+1} - x^*\| \leq K \|x_k - x^*\|,$$

avec $0 \leq K < 1$, donc $\{x_k\}$ converge linéairement vers x^* .

- La solution x^* est unique, car si \bar{x}^* est une autre solution on a une contradiction avec (1.10)

Exercices

Exercice 1.1. Calculer s'il y a lieux $g(x)$, $H(x)$, et $Jf(x)$ (le jacobien de la fonction f en x) pour

1. $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $x \mapsto f(x) = c^t x + \gamma$.
2. $f : \mathbb{R}^n \rightarrow \mathbb{R}^n$, $x \mapsto F(x) = Lx + b$, où $L \in M_{m,n}(\mathbb{R})$.
3. $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $x \mapsto f(x) = \frac{1}{2} x^t A x + d^t x + \delta$, où $L \in M_n(\mathbb{R})$.
4. $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $x \mapsto f(x) = \sum_{i=1}^m [r_i(x)]^2$, où les $r_i : \mathbb{R}^n \rightarrow \mathbb{R}$ sont deux fois différentiables.

Exercice 1.2. Montrer les propositions suivantes

1. Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$, différentiable en \bar{x} . Si \bar{x} est un minimum local, alors $g(\bar{x}) = 0$.
2. Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$, deux fois différentiable en \bar{x} et supposons que \bar{x} soit un minimum local, alors $g(\bar{x}) = 0$ et $H(\bar{x})$ est semi défini positif.
3. Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$, deux fois différentiable en \bar{x} . Si $g(\bar{x}) = 0$ et $H(\bar{x})$ est défini positif, alors \bar{x} est un minimum local strict.
4. Si f est convexe sur \mathbb{R}^n et si $g(\bar{x}) = 0$ alors \bar{x} est un minimum global.

Exercice 1.3. Soit $\{x_k\}$ une suite de vecteurs dans \mathbb{R}^n . Montrez que si x tend Q-linéairement vers x^* , alors pour tout $q > \limsup q_k$, il existe k_0 et $C > 0$ tels que

$$\|x_k - x^*\| \leq Cq^k \text{ pour tout } k \geq k_0.$$

où $q_k = \frac{\|x_{k+1} - x^*\|}{\|x_k - x^*\|}$.

Exercice 1.4. Montrer que la suite $x_k = \frac{1}{k}$ n'est pas convergente Q-linéairement vers 0.

Exercice 1.5. Montrer que la suite $x_k = 1 + (0.5)^{2^k}$ convergent Q-quadratiquement vers 1.

Exercice 1.6. Est-ce que la suite $\frac{1}{k!}$ converge Q-superlinéairement ? Q-quadratiquement ?

Exercice 1.7. Considérons la suite $\{x_k\}$ définie

$$x_k = \begin{cases} \left(\frac{1}{4}\right)^{2^k}, & k \text{ est pair} \\ \frac{x_{k-1}}{k}, & k \text{ est impaire} \end{cases}$$

Est-ce que la suite est Q-superlinéairement convergente ? Q-quadratiquement convergente ?
R-quadratiquement convergente ?

Exercice 1.8. Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$, une fonction continument différentiable. Soit x_0 tel que $f(x_0) = 0$.

1. Que représente $g(x_0)$ pour la surface de niveau

$$S := \{x \in \mathbb{R}^n : f(x) = f(x_0)\}.$$

2. Donner l'équation de l'hyperplan affine (de \mathbb{R}^{n+1}) tangent au graphe de f en $(x_0, f(x_0))$.

3. Donner à l'aide de $g(x_0)$ un vecteur normal à cet hyperplan.

Exercice 1.9. Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$, une fonction continument différentiable.

1. On suppose qu'il existe $L > 0$ tel que

$$\|g(x) - g(x')\| \leq L \|x - x_0\| \text{ pour tout } (x, x') \in \mathbb{R}^n \times \mathbb{R}^n.$$

2. Montrer qu'alors

$$|f(x+d) - f(x) - g(x)^t d| \leq \frac{L}{2} \|d\|^2 \text{ pour tout } (x, d) \in \mathbb{R}^n \times \mathbb{R}^n.$$

Bibliographie

- [1] L. Armijo. Minimization of functions having Lipschitz continuous first derivatives. Pacific Journal of Mathematics 16 (1966) 1-3
- [2] M. S. Bazara. H.D. Sherali, C.M Shetty. Nonlinear programming. J.W&S (1993)
- [3] J. F. Bonnans, J. C. Gilbert, C. Lemaréchal and C. A. Sagastizábal. Numerical optimization : theoretical and practical aspects. Springer Science & Business Media (2006).
- [4] C. G. Broyden. Quasi-Newton method and their application to function minimization, Mathematics of Computation, 21,(1967).
- [5] A. Bukley, A.Lenir. QN-like variable storage conjugate gradients. Math. Prog. 27,(1983)155-175.
- [6] R. Byrd and J. Nocedal. A tool for the analysis of quasi-Newton methods with application to unconstrained minimization, SIAM Journal on Numerical Analysis, 26 (1989) 727-739.
- [7] A. Cauchy. Méthodes générales pour la résolution des systèmes d'équations simultanées. Compte rendus Acad. Sc. Paris, Tome 25 (1847) 536-538.
- [8] F. Chatelin. Eigenvalues of Matrices, J.Wiley & S (1993).
- [9] W. C. Davidon. Variable metric methods for minimization, AEC Research Development, Report ANL-5990 (1959).

- [10] J. E. Denis, Jr., J.J. Moré. A characterisation of superlinear convergence and its application to quasi-Newton methods, *Mathematics of computation*, 28 (1974) 549-560.
- [11] J. E. Dennis, H. Wolkowicz. Sizing and Least Change Secant Methods, CORR Report 93-11 (1993).
- [12] R. Fletcher. A new approach to variable metric algorithms, *Computer Journal*, 13,(1970)317-322.
- [13] R. Fletcher, M.J.D. Powell. A Rapidly convergent descent method for minimisation, *Computer Journal* 6,(1963)163-168.
- [14] R. Fletcher. An overview of Unconstrained Optimization in Algorithms for Continuous Optimization, *The State of the Art*, E. Spedicato, ed., Kluwer academic Publishers, Boston, (1994)109-143.
- [15] A. A. Goldstein, J.F. Price. An effective algorithm for minimization. *Num. Math.* 10,(1967)184-189.
- [16] D. Goldfarb. A family of metric variable methods derived by variation means, *mathematics Of computation* 24,(1970)23-26.
- [17] A. Griewank, Ph.L. Toint. Local convergence analysis of partitioned quasi-Newton updates, *Numeric Mathematics* 39,(1982)429-448.
- [18] T.G. Kolda. Limited-Memory matrix methods with application, *Applied Mathematics program*, university of Maryland (1998).
- [19] A. S.Lewis. Convex analysis on the hermitian matrices, Technical report CORR 97-09, University of Waterloo (1994).
- [20] D. H. Li, M. Fukushima. A global convergence of BFGS methods for nonconvex unconstrained optimization problems, *SIAM Journal on Numerical Analysis*.7, (1999).
- [21] D. H. Li, M. Fukushima. A modified BFGS method and its global convergence in nonconvex minimization, Technical Report 98003, Département of Applied Mathematics and Physics, Kyoto University, (1998).

- [22] D. G. Luenberger. Linear and Nonlinear Programming, 2nd edition, Addison-Wesley (1984).
- [23] P. E. Gill, W. Murray. Conjugate gradient method for large-scale nonlinear optimization, Technical report SOL 79-15, Dept. of Operation Res. Stanford University, (1979).
- [24] J. J. Moré, B.S. Garbow, K.E. Hillstrome. Testing unconstrained optimization software, ACM Trans. Math. Software, 7, (1981)17-41.
- [25] L. . Conjugate gradient methods less dependent on conjugacy. SIAM Review 28,(1986)501-511.
- [26] Y. E. Nesterov. On the a approach to the construction of optimal methods of minimization of smooth convex function, *Economica I Matem.* 24, (1988)504-517.
- [27] J. Nocedal. Adapting quasi-Newton matrices with limited storage, *Mathematics of computation* 35, (1980)773-782.
- [28] J. Nocedal. Theory of algorithms for unconstrained optimization, *acta Numerica*, (1999)199-242.
- [29] J. Nocedal, J. W. Stephen. Numerical optimization. Springer (1999).
- [30] D. P. O'Leary. A discrete Newton algorithm for minimizing a function of many variable, *Math. Prog.* 23, (1982)20-30.
- [31] S. S. Oren, E. Spedicato, Optimal condition of self-scaling variable metric algorithms, *Math. Prg.*, 10, (1976)70-90.
- [32] J. M. Perry. A class of conjugate gradient with two-step variable-metric memory, Discussion paper 269, C.M.S.E.M.S. Northwestern University (Evanston, IL, 1977)
- [33] J. D. Pearson. Variable metric methods of minimization. *Computer Journal*, Vol 12, (1971)21-36.
- [34] M. J. D. Powell. On the convergence of the variable metric algorithm, *Journal of the Institute of Mathematics and its Applications*, (1971)21-36.

- [35] M. J. D. Powell. Some properties of the variable metric algorithm for minimization without exact line searches, in *Nonlinear Programming, SIAM-AMS Proceeding, Vol. IX*, R.W. Cottle, and C.E. Lemke, eds., SIAM, (1976)35-72.
- [36] L. Schwartz. *Analyse, topologie générale et analyse fonctionnelle*, Hermann (1970).
- [37] M. Sibony, J.C. Mardon. *Analyse Numérique. Systèmes linéaires et non linéaires*, HERMAN (1982).
- [38] D. F. Schanno. Conditionning of quasi-Newton methods for function minimization, *Mathematics of computation*, 24,(1970)641-656.
- [39] D. F. Schanno. On the convergence of new conjugate gradient algorithm, *SIAM Journal on numerical analysis*, 15,(1978a)1247-1257.
- [40] T. Steihaug. The conjugate gradient method and trust regions in large-scale optimization, *SIAM J. Num. Anal.* 20, (1983)626-637.
- [41] P. Wolfe. Convergence for ascent methods. *SIAM Rev.* 11,226-235, 1968.
- [42] W. I. Zangwill. *Nonlinear programming : a unified approach*, Prentice Hall, Englewood Cliffs, RI, 1969.
- [43] G. Zoutendijk. Non linear programming, computation programming. In J. Abadie (ed), *integer and non linear programming*. North Holland (1970)37-86.