

Optimisation

Ch 1: rappels mathématiques

1) - Définition d'un problème d'optimisation:

D'un point de vue mathématique, l'optimisation consiste à rechercher le minimum ou le maximum d'une fonction avec ou sans contraintes.

Un problème d'optimisation avec contrainte est défini comme suit:

a) - Problème de minimisation avec contrainte: recherche du minimum d'une fonction

$$PC_1 \left\{ \begin{array}{l} \text{Min } f(x) \cdot, x \in \mathbb{R}^n \\ \text{sous contraintes} \\ g_i(x) = 0 \quad ; i = 1, \dots, m \\ \quad \text{(contrainte)} \\ \quad \text{(d'égalité)} \\ h_j(x) \geq 0 \quad ; j = 1, \dots, p \\ \quad \text{(contrainte)} \\ \quad \text{(inégalité)} \end{array} \right.$$

Min $f(x)$: signifie le minimum de $f(x)$, on dit que l'on cherche à minimiser $f(x)$.

b) - Problème de maximisation avec contraintes: recherche du maximum d'une fonction.

$$PC_2 \left\{ \begin{array}{l} \text{Max } f(x) \quad ; x \in \mathbb{R}^n \\ \text{sous les contraintes} \\ g_i(x) = 0 \quad ; i = 1, \dots, m \\ h_j(x) \geq 0 \quad ; j = 1, \dots, p \end{array} \right.$$

Max $f(x)$: signifie le maximum de $f(x)$, on dit que l'on cherche à maximiser $f(x)$.

Dans les problèmes d'optimisation PC_1 et PC_2 la fonction $f(x)$ définit de D dans \mathbb{R}^n

(i.e: $f: D \rightarrow \mathbb{R}$) porte deux noms: fonction de coût, fonction objectif ou critère

$$x = (x_1, x_2, \dots, x_n) \in D \subset \mathbb{R}^n$$

les variables x_1, \dots, x_n sont appelées **variables de décision** D est appelé ensemble ou **domaine admissible** défini par l'ensemble des contraintes comme suit:

$$D = \{x \in \mathbb{R}^n / g_i(x) = 0, i = 1, \dots, m \text{ et } h_j(x) \geq 0, j = 1, \dots, p\}$$

Remarque 1: les problèmes PC1 et PC2, peuvent être écrits sous les formes simplifiées:

$$PC1 \begin{cases} \text{Min } f(x) \\ x \in D \subset \mathbb{R}^n \end{cases} \quad PC2 \begin{cases} \text{Max } f(x) \\ x \in D \subset \mathbb{R}^n \end{cases}$$

Remarque 2: en absence de contraintes $g_i(x) = 0, i = 1, \dots, m$ et $h_j(x) \geq 0, j = 1, \dots, p$, les problèmes PC1 et PC2 deviennent:

$$P_{1.1} \begin{cases} \text{Min } f(x) \\ x \in \mathbb{R}^n \end{cases} \quad P_{2.2} \begin{cases} \text{Max } f(x) \\ x \in \mathbb{R}^n \end{cases}$$

Dans ce cas $P_{1.1}$ et $P_{2.2}$ sont resp. des problèmes de minimisation et de maximisation sans contraintes.

Remarque 3: $\text{Min}_x (f(x)) = -\text{Max}_x (-f(x))$
 $\text{Max}_x (f(x)) = -\text{Min}_x (-f(x))$

Ainsi la recherche du maximum peut se ramener à la recherche du minimum et vice-versa.

2) Convexité:


a) ensemble convexe:

un ensemble $D \subset \mathbb{R}^n$ est dit convexe si pour tout couple $(x_1, x_2) \in D$ et $\forall \alpha \in [0, 1]$:

$$\text{on a : } \alpha x_1 + (1-\alpha)x_2 \in D$$

Cette définition peut être interprétée en disant que le segment reliant x_1 et x_2 doit être dans D .

et p: ensembles convexes:





ensembles non-convexes:



b) Fonction convexe = une fct: $f: D \rightarrow \mathbb{R}^n$ est convexe sssi: $\forall x_1, x_2 \in D, \forall \alpha \in [0, 1]$

$$f(\alpha x_1 + (1-\alpha)x_2) \leq \alpha f(x_1) + (1-\alpha)f(x_2)$$



La définition de fonction convexe s'interprète géométriquement comme suit: le graphe de la fonction est toujours en dessous du segment reliant les pts $(x_1, f(x_1))$ et $(x_2, f(x_2))$. On dira que f est strictement convexe dans D sssi:

$$\forall x_1, x_2 \in D, \forall \alpha \in [0, 1] \\ f(\alpha x_1 + (1-\alpha)x_2) < \alpha f(x_1) + (1-\alpha)f(x_2)$$

- Une fct est concave si $-f$ est convexe
 - la définit. de fct et ensemble se fait en inversant les inégalités + dans les définitions précédentes

28/09/2017

Definition:

Soit:

$$(P) \begin{cases} \text{Min ou Max } f(x) \\ x \in \mathbb{R}^n \\ \text{s.c. :} \\ g_i(x) = 0 \quad ; i = 1, \dots, m \\ h_j(x) \geq 0 \quad ; j = 1, \dots, p \end{cases}$$

Definition 1:

Tout vecteur x vérifiant l'ensemble des contraintes (i.e. $x \in D$) est appelé **solution admissible** ou **realisable** du problème d'optimisation (P).

Definition 2:


un optimum ou extremum d'une fonction f est soit un maximum soit un minimum i.e. la valeur la plus haute ou la plus faible que prend la fonction sur son ensemble de définition D .

Cet optimum est donné par $f(x^*)$.

Definition 3:

le point x^* où la fonction f possède un minimum (resp. maximum) est dit un point de minimum ou un minimiseur.

(resp. un point de maximum ou maximiseur). x^* est aussi appelé **solution optimale** du problème d'optimisation.



x_1^* : est un point de maximum

$f(x_1^*)$: maximum

x_2^* : est un point de minimum

$f(x_2^*)$: minimum

$f(x^*) = \min f(x)$ dans le cas d'un problème de minimisation

$\Rightarrow f(x^*)$: minimum

$f(x^*) = \max f(x)$ dans le cas d'un problème de maximisation

$\Rightarrow f(x^*) = \text{maximum}$

4) - Minima et Maxima d'une fonction :

Soit f est une fct de $D \subset \mathbb{R}^n$ dans \mathbb{R} ($f: D \rightarrow \mathbb{R}$).

a) - minimum ou maximum local : f admet un minimum (resp. maximum) local (ou relatif) en $x^* \in D$, si et seulement s'il existe un voisinage $V \in (x^*)$ de $x^* + \eta$:

$\forall x \in V \in (x^*) ; f(x^*) \leq f(x)$
(resp $f(x^*) \geq f(x)$).

On dit alors que $f(x^*)$ est un minimum local de la fct f sur D . x^* est un point de minimum local.

b) - minimum ou maximum local strict :


f admet un minimum (resp. maximum) local strict en $x^* \in D$, si ss :
 $\exists V \in (x^*)$ de $x^* + \eta$:

$\forall x \in V \in (x^*) ; x \neq x^* ; f(x^*) < f(x)$ (resp. $f(x^*) > f(x)$).

c) - Minimum ou Maximum global : f admet un minimum (resp. maximum) global (ou absolu) en $x^* \in D$ si :

$\forall x \in D, f(x^*) \leq f(x)$
(resp $f(x^*) \geq f(x)$)

si les inégalités sont strictes, on obtient la définition d'un minimum (resp. maximum) global strict.



5) Minima des fonctions convexes :

soit f une fonction :
 $f: D \rightarrow \mathbb{R}$ $D \subset \mathbb{R}^n$ est convexe.

f est convexe sur D alors tout minimum local est un minimum global.

- Si f est strictement convexe, alors tout minimum local devient non seulement global mais aussi unique.

2) - Gradient et Hessien d'une fonction:

- Gradient:

Soit: $f: \mathbb{R}^n \rightarrow \mathbb{R}$, le gradient de f noté $\nabla f(m)$ est donné par:

$$\nabla f(m) = \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \\ \vdots \\ \frac{\partial f}{\partial x_n} \end{bmatrix}$$

- Hessien ou Matrice Hessienne

d'Hessien de f noté $\nabla^2 f(m)$ est donné par:

$$\nabla^2 f(m) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \dots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix}$$

Remarque:

la matrice hessienne est la Jacobienne du gradient. la matrice Hessienne est symétrique.

- point stationnaire ou critique d'une fonction f : un point x^* vérifiant $\nabla f(x^*) = 0$ est appelé point stationnaire ou point critique de f .

25/10/2017

7) - Rappel sur les matrices définies semi-définies positives ou négatives.

i) - Déf: soit A une matrice symétrique $n \times n$.

On dit que A est semi-définie positive (resp. semi-définie négative) et on note $A \geq 0$ (resp. $A \leq 0$) quand:

$$x^T A x \geq 0 \quad (\text{resp. } x^T A x \leq 0) \quad \forall x \in \mathbb{R}^n$$

* On dit que A est définie positive (resp. déf. négative) et on note $A > 0$ (resp. $A < 0$) quand:

$$x^T A x > 0 \quad (\text{resp. } x^T A x < 0) \quad \forall x \in \mathbb{R}^n, x \neq 0$$

* On dit que A est indéfinie s'il $\exists x, y \in \mathbb{R}^n$ tq:
 $x^T A x > 0$ et $y^T A y < 0$

2). Critère pour connaître les matrices définies, semi-définies positive ou négative :

a) - les valeurs propres :

* A est semi-définie positive (resp. négative) ssi toutes ses valeurs propres sont ≥ 0 (resp. ≤ 0).

* A est définie positive (resp. négative) ssi toutes ses valeurs propres > 0 (resp. < 0)

* A est indéfinie ssi elle admet une valeur propre > 0 et une valeur propre < 0

Rq: pour les calculs des valeurs propres, il faut trouver les racines de l'eqt : $\det(\lambda I - A) = 0$.

b) - les mineurs principaux : les déterminants des sous-matrices.

Si $A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix}$

alors : $D_1 = a_{11}$

$D_2 = \begin{vmatrix} a_{11} & a_{12} \\ a_{12} & a_{22} \end{vmatrix} \dots D_n = \det(A)$

sont les mineurs principaux de A

* la matrice A est définie positive ssi $\dots D_k > 0, k=1 \dots n$

* A est définie négative ssi : $(-1)^k D_k > 0, k=1 \dots n$

* Si $D_k > 0, k=1 \dots n-1$ et $D_n = 0$ alors A est semi-définie positive

* si $(-1)^k D_k > 0, k=1 \dots n-1$ et $D_n = 0$ alors A est semi-définie négative.

* Si $D_n < 0$ et si " n " est paire alors A est indéfinie.

Rq: une matrice symétrique qui n'est ni définie positive ni semi positive ; définie ou semi-définie négative est indéfinie.

$E = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$ $D_1 = 1 > 0$ $D_2 = 3 > 0 \Rightarrow A$ déf positive

Contour d'une fonction :

Soit : $f : \mathbb{R}^n \rightarrow \mathbb{R}$

$y = f(x)$ définit une surface dans \mathbb{R}^{n+1}


* $f(x) = c$ avec c constant définit des courbes (lignes) de niveaux ou des contours de cette surface.

Un contour de niveau c est l'ensemble de points :

$$S(c) = \{ x \mid f(x) = c \}$$

ex: $f : \mathbb{R}^2 \rightarrow \mathbb{R}$

$$f(x) = x_1^2 + x_2^2 = c$$



- courbe de niveau (ou contour).

91- Classification des problèmes d'optimisation :

Un problème d'optimisation peut être classé suivant les propriétés de la fonction objectif et des contraintes. par ex: on parle :

le même chose pour MO

* Programmation linéaire :

lorsque la fct objectif et les contraintes sont linéaires.

* Programmation quadratique :

lorsque la fct objectif est quadratique et les contraintes sont linéaires.

* Programmation non-linéaire :

lorsque la fct obj et/ou les contraintes sont non-linéaires.

* Programmation convexe :

lorsque la fct obj et les contraintes sont convexes.

12/10/2017

101- Modélisation d'un problème d'optimisation :

Il consiste à représenter un problème d'optimisation mathématiquement, pour cela on distingue 3 étapes :

1- identification des variables de décision (vecteur x)

2- Définition d'une fct objectif : permettant d'évaluer l'état du système (gain, perte...)

3. Description des contraintes imposées aux variables de décision (le domaine).

La résolution d'un problème d'optimisation consiste à déterminer les variables de décision conduisant aux meilleures conditions de fonctionnement du système (ce qui revient à maximiser ou à minimiser la f obj.) tout en respectant les contraintes.

Ch 2: Optimisation sous Contraintes. Méthodes locales.

1. Introduction: dans ce chapitre nous allons étudier les méthodes de résolution d'un problème d'optimisation sans contraintes. Les méthodes sont qualifiées de méthodes locales, par souligner le fait que le minimum (ou le maximum) trouvé est local. Les méthodes d'optimisation qui seront présentées dans ce chapitre considèrent le problème de minimisation sans contraintes suivantes

$$P: \begin{cases} \min f(x) \\ x \in \mathbb{R}^n \end{cases}$$

où: $f: \mathbb{R}^n \rightarrow \mathbb{R}$ est une f donnée quant à la recherche d'un maximum d'une $f(x)$ il revient à chercher le minimum de $-f(x)$

- conditions suffisantes pour l'existence d'un minimum ou maximum.

soit $f: \mathbb{R}^n \rightarrow \mathbb{R}$ de classe C^2 , alors:

x^* est un point de minimum local si:

$$\begin{cases} \nabla f(x^*) = 0 \text{ (point critique)} \\ \text{(condition de 1^{er} ordre)} \\ \nabla^2 f(x^*) \text{ est définie positive } (> 0). \\ \text{(condition du 2^{es} ordre)} \end{cases}$$

x^* est un point de maximum local si:

$$\begin{cases} \nabla f(x^*) = 0 \text{ (point critique)} \\ \text{(c.d. 1^{er} ordre)} \\ \nabla^2 f(x^*) \text{ est définie négative } (< 0) \\ \text{(c.d. 2^{es} ordre)} \end{cases}$$

Si $\nabla f(x^*) = 0$ et si $f(x)$ est
 convexe (resp. strict convexe) alors
 x^* est un pt de minimum global
 (resp. global et unique).

* Si $\nabla f(x^*) = 0$ et si $f(x)$ est
 concave (resp. strict concave)
 alors x^* est un pt de maximum
 global (resp. global et unique)

* Si $\nabla f(x^*) = 0$ et $\nabla^2 f(x^*)$ est
 semi-définie positive (≥ 0)
 ou semi-définie négative (≤ 0)
 on ne peut rien conclure.

* Si $\nabla f(x^*) = 0$ et si $\nabla^2 f(x^*)$ est
 indéfinie, alors x^* est un pt
 selle ou pt col.

Req:

Dans le cas d'une fct d'une
 seule variable $f(x)$, les
 conditions ci-dessous suffisent:

+ Si $f'(x^*) = 0$ et $f''(x^*) > 0$
 $\Rightarrow x^*$ est un pt de minimum
 local.

+ Si $f'(x^*) = 0$ et $f''(x^*) < 0$
 $\Rightarrow x^*$ un point de maximum local.

+ Si $f'(x^*) = 0$ et $f''(x^*) = 0$,
 x^* peut être un pt d'inflexion

2- Methodes d'optimisation:

les problèmes d'optimisation
 peuvent être résolus analyti-
 quement ou avec des methodes
 numeriques iteratives.

1- methode analytique:

cette methode est basée sur
 le calcul des pts critiques
 et l'analyse de la matrice
 hessienne avec pts critiques.
 les etapes de cette methode
 sont:

1)- recherche des pts critiques

2)- pour chaque pt critique x^* :

* Si $\nabla^2 f(x^*)$ est définie positive
 (resp. négative):

x^* est un pt minimum (resp. pt
 de maximum local).

* Si $\nabla^2 f(x^*)$ est indéfinie, alors
 x^* est un pt selle ou pt col
 (x^* n'est pas un pt d'extremum)

* Si $\nabla^2 f(x^*)$ est semi-définie
 positive (resp. negative) alors
 on ne peut rien conclure.

exemple:

Determiner les extremums
 de la fct suivante:

$$f(x_1, x_2) = x_1^2 + x_2^3 - 2x_1x_2 - x_2$$

- calcul des pts critiques :

$$\nabla f(x_1, x_2) = \begin{bmatrix} 2x_1 - 2x_2 \\ 3x_2^2 - 2x_1 - 1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

on trouve 2 pts critiques :

$$\left(-\frac{1}{3}, -\frac{1}{3}\right) \text{ et } (1, 1)$$

- calcul de la matrice hessienne :

$$H(x_1, x_2) = \nabla^2 f(x_1, x_2) = \begin{bmatrix} 2 & -2 \\ -2 & 6x_2 \end{bmatrix}$$

$$H\left(-\frac{1}{3}, -\frac{1}{3}\right) = \begin{bmatrix} 2 & -2 \\ -2 & -2 \end{bmatrix}$$

$$D_1 = 2 > 0$$

$$\Delta_2 = \det\left(H\left(-\frac{1}{3}, -\frac{1}{3}\right)\right) = -8 < 0$$

$\Rightarrow H\left(-\frac{1}{3}, -\frac{1}{3}\right)$ est indéfinie.

$\Rightarrow \left(-\frac{1}{3}, -\frac{1}{3}\right)$ est un pt selle.

$$H(1, 1) = \begin{bmatrix} 2 & -2 \\ -2 & 6 \end{bmatrix}$$

$$D_1 = 2 > 0$$

$$\Delta_2 = \det\left(H(1, 1)\right) = 8 > 0$$

$\Rightarrow H(1, 1)$ est définie positive

$\Rightarrow (1, 1)$ est pt de minimum local

Le minimum de f est bien $f =$

19/11/20

2) - méthodes de descente
(méthodes numériques
itératives).

- Notion de direction de descente.

Soit $f: \mathbb{R} \rightarrow \mathbb{R}$ et $x \in \mathbb{R}^n$, le vecteur $d \in \mathbb{R}^n$ est une direction de descente pour f en x , s'il existe $\delta > 0$ tq :

$$f(x + \delta d) < f(x), \forall \delta \in]0, \delta[$$

Les méthodes de descente sont des méthodes numériques (algorithmes) permettant de trouver un minimum local d'une f et. Partant d'un point $x_0 \in \mathbb{R}^n$ arbitrairement choisi, les méthodes de descente génèrent une suite de points

$$x^0, x^1, x^2, \dots, x^k \text{ tq: } \forall k \in \mathbb{N}$$

$$f(x^{k+1}) \leq f(x^k)$$

avec :

$$x^{k+1} = x^k + d^k \delta^k \quad \delta^k > 0$$

Le vecteur d^k est la direction de descente de f en x^k , i.e. : la direction dans laquelle la valeur de f décroît.

$A \in \mathbb{R}^{m \times m}$

$x_B = (x_1, \dots, x_m, 0, \dots, 0), \quad \delta$

de descente

Proposition :

Soit $d \in \mathbb{R}^n$ vérifiant

$$\nabla f(x)^T d < 0$$

alors d est une direction de descente en x .

Démonstration :

on écrit le développement de Taylor de $f(x+d)$, $\alpha > 0$ (1^{er} ordre).

$$f(x+d) = f(x) + \alpha \nabla f(x)^T d + \alpha \varepsilon(\alpha)$$

avec : $\varepsilon(\alpha) \rightarrow 0$
 $\alpha \rightarrow 0$

Pour α suffisamment petit, on aura :

$$f(x+d) - f(x) < 0 \text{ si } \nabla f(x)^T d < 0$$

$\Rightarrow d$ est une direction de descente

- Méthode de descente :

a) méthode de gradient à pas fixe (ou à pas cte) :

à partir d'un $x^0 \in \mathbb{R}^n$, on construit la suite des points suivante :

$$k = 0, 1, \dots$$

$$x^{k+1} = x^k - \alpha \nabla f(x^k)$$

$$d^k = -\nabla f(x^k)$$

$\alpha > 0$: le pas de descente fixe a priori

b) - méthode de gradient à pas optimal :

partant d'un pt x^0 , l'algorithme de gradient à pas optimal est :

$$k = 0, 1, \dots$$

1 - Calculer le pas optimal α^k de $\min_{\alpha} f(x^k - \alpha \nabla f(x^k))$

$$2 - x^{k+1} = x^k - \alpha^k \nabla f(x^k)$$

critère d'arrêt :

un test d'arrêt devra être choisi pour garantir que l'algorithme s'arrête toujours après un nombre fini d'itérations et que le dernier point calculé soit suffisamment proche de point de minimum local de f .

soit $\varepsilon > 0$, la précision demandée plusieurs critères sont à notre disposition, on en distingue :

1 - $\|\nabla f(x^k)\| < \varepsilon$ (ce critère vient des conditions nécessaires d'optimalité du 1^{er} ordre) 6

2 - $\|x^{k+1} - x^k\| < \epsilon$ (stagnation de la solution).

donc l'un des critères ci-dessus peut être utilisé.

$\|\cdot\|$: norme euclidienne ($\|\cdot\|_2$)

$$\|x\| = \|x\|_2 = \sqrt{\sum_{i=1}^n x_i^2}, \quad x = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$$

Rq: 1

La méthode du gradient à pas optimal est également appelée méthode de la plus grande descente (ou pente)

Rq: 2

Dans cette méthode on a:
 $(x^{k+1} - x^k) \perp (x^k - x^{k-1})$

e) - méthode du gradient conjugué:

L'algorithme prend la forme suivante:

on se donne x^0 et on pose:

$$d^0 = -\nabla f(x^0)$$

$$k = 0, 1, \dots$$

1 - Calculer le pas α^k , la solution de $\min_{\alpha \geq 0} f(x^k + \alpha^k d^k)$

$$2 - x^{k+1} = x^k + \alpha^k d^k$$

$$3 - B^k = \frac{\|\nabla f(x^{k+1})\|^2}{\|\nabla f(x^k)\|^2}$$

$$4 - d^{k+1} = -\nabla f(x^{k+1}) + B^k d^k$$

Les critères d'arrêt sont les mêmes que précédemment, cette méthode converge rapidement que la méthode du gradient.

26-10-2014

d) - Méthode de Newton:

soit $f: \mathbb{R}^n \rightarrow \mathbb{R}$, $f \in C^2$

Le principe de la méthode de Newton est de calculer une approximation $p(x)$ de $f(x)$ autour d'un pt x^k par son développement de Taylor du second ordre.

$$f(x) \approx p(x) = f(x^k) + (x - x^k)^T \nabla f(x^k) + \frac{1}{2} (x - x^k)^T H(x^k) (x - x^k)$$

$H(x^k)$: est la matrice hessienne au point x^k $H(x^k) = \nabla^2 f(x^k)$

On calcule alors le nouveau pt x^{k+1} qui minimise $p(x)$.

$$f(x^{k+1}) = \nabla f(x^k) + H(x^k)(x - x^k) = 0$$

si la matrice Hessienne est inversible \Rightarrow

$$x^{k+1} = x^k - H^{-1}(x^k) \nabla f(x^k)$$

e/- Méthode de Newton Modifiée :

L'algorithme de cette méthode est comme suit :

$$x^{k+1} = x^k - \alpha^k H^{-1}(x^k) \nabla f(x^k)$$

avec :

α^k est la solution de :

$$\min_x f(x^k - \alpha H^{-1}(x^k) \nabla f(x^k))$$

f/- Méthode Quasi-Newton :

Pour des problèmes de grandes dimensions, le calcul de l'Hessienne et de son inverse sont trop coûteux, on peut alors utiliser des algorithmes dit Quasi-Newton

qui calculent une sur approximation

B^k de $H^{-1}(x^k)$ en fonction de B^{k-1} , $\nabla f(x^k)$, $\nabla f(x^{k-1})$, x^k et x^{k-1} , on trouve notamment 2 méthodes de calcul :

+ la méthode de Davidson - Fletcher - Powell (DFP)

+ 2 méthodes de Broyden - Fletcher - Goldfarb - Shanno (BFGS).

- Méthodes de recherche unidimensionnelle :

On s'intéresse dans cette partie à l'optimisation des fonctions monovariées (Fonction d'une seule variable). Plusieurs méthodes ont été proposées, on en distingue :

- méthode analytique :

soit x^* , le pt critique ($f'(x^*) = 0$)

$f''(x^*) > 0 \Rightarrow x^*$ pt de minimum local

$f''(x^*) < 0 \Rightarrow x^*$ pt de maximum local

$f''(x^*) = 0 \Rightarrow x^*$ pt d'inflexion

- méthode de descente :

Les méthodes de descente présentées précédemment peuvent être utilisées dans le cas d'une fonction monovariée.

- méthode de Dichotomie :

soit f une fct unimodale.

La 1^{ère} étape, consiste en la recherche de a et b tq :

on ait les 2 relations :

$$f'(a) < 0 \text{ et } f'(b) > 0$$

≠

Après cette étape, on pose :

$$x = \frac{1}{2}(a+b)$$

si : $f'(x) > 0$, on remplace b par x , si non on remplace a par x . On répète l'opération jusqu'à $b-a < \epsilon$

Rq:

on dit qu'une fonction est unimodale, s'il \exists un réel x^* pour lequel la fonction est strictement décroissante sur $]-a, x^*]$ et strictement croissante sur $[x^*, +\infty[$.

Ch3: Programmation linéaire

1) La programmation linéaire a pour objet, l'étude de la résolution des programmes linéaires (P.L)

2) Un programme linéaire : est un problème d'optimisation dont la fonction objectif et les contraintes sont exprimées de manière

La forme canonique (ou standard)

d'un P.L est :

$$P.L = \begin{cases} \text{Min } C^T x & (\text{ou Max } C^T x) \\ \text{s.c. :} \\ A \cdot x = b & \textcircled{1} \quad (3,1) \\ x \geq 0 \end{cases}$$

avec : $C^T \in \mathbb{R}^n$, $x \in \mathbb{R}^n$, $b \in \mathbb{R}^m$

avec $b \geq 0$, $A \in \mathbb{R}^{m \times n}$

Rq:

Les contraintes $\textcircled{1}$ peuvent être de type inégalité - i.e : $Ax \geq b$ et/ou $Ax \leq b$, et il est tjrs possible de revenir à la forme standard (3,1)

* Transformation sous forme standard :

considérons le P.L suivant

$$\begin{cases} \text{Min } x_1 + x_2 + x_3 \\ \text{s.c. :} \\ x_1 + x_2 - x_3 \geq 0 \\ 2x_1 + 3x_2 + 5x_3 = 4 \\ x_1 \geq 0, x_2 \geq 0, x_3 \geq 0 \end{cases} \quad \text{P.L 1}$$

en introduisant 2 variables d'écart x_4 et x_5 , le problème

Après cette étape, on pose :

$$x = \frac{1}{2}(a+b)$$

si : $f'(x) > 0$, on remplace b par x , si non on remplace a par x . on répète l'opération jusqu'à $b-a < \epsilon$

Rq:

on dit qu'une fonction est unimodale, s'il \exists un réel x^* pour lequel la fonction est strictement décroissante sur $]-\infty, x^*]$ et strictement croissante sur $[x^*, +\infty[$.

Ch 3: Programmation linéaire

1) La programmation linéaire a pour objet, l'étude de la résolution des programmes linéaires (P.L)

2) Un programme linéaire : est un problème d'optimisation dont la fonction objectif et les contraintes sont exprimées de manière linéaire.

$A \in \mathbb{R}^{m \times n}$

La forme canonique (ou standard) d'un P.L est :

$$P.L = \begin{cases} \text{Min } C^T x \quad (\text{ou Max } C^T x) \\ \text{s.c. :} \\ A \cdot x = b \quad (3.1) \\ x \geq 0 \end{cases}$$

avec : $C^T \in \mathbb{R}^n$, $x \in \mathbb{R}^n$, $b \in \mathbb{R}^m$
avec $b \geq 0$, $A \in \mathbb{R}^{m \times n}$

Rq:

Les contraintes (3.1) peuvent être de type inégalité. i.e : $Ax \leq b$ et/ou $Ax \geq b$, et il est toujours possible de revenir à la forme standard (3.1)

* Transformation sous forme standard :

considérons le P.L suivant

$$\begin{cases} \text{Min } x_1 + x_2 + x_3 \\ \text{s.c. :} \\ x_1 + x_2 - x_3 \geq 0 \\ 2x_1 + 3x_2 + 5x_3 = 4 \\ x_1 \geq 0, x_2 \geq 0, x_3 \geq 0 \end{cases} \quad \text{P.L 1}$$

en introduisant la variable d'écart x_4 et x_5 , le problème P.L 1 peut être écrit sous la

forme canonique suivante:

$$\text{Min } x_1 + x_2 + x_3 + 0x_4 + 0x_5$$

s.c

$$x_1 + x_2 - x_3 - x_4 = 2$$

$$2x_1 + 3x_2 + 5x_3 + x_5 = 4$$

$$x_1 \geq 0 \quad x_2 \geq 0 \quad x_3 \geq 0 \quad x_4 \geq 0 \quad x_5 \geq 0$$

$$\text{Min } [1 \ 1 \ 1] \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} [1 \ 1 \ 1 \ 0 \ 0] \begin{bmatrix} x_1 \\ \vdots \\ x_5 \end{bmatrix}$$

s.c :

$$\underbrace{\begin{bmatrix} 1 & -1 & -1 & 0 \\ 2 & 3 & 5 & 0 \end{bmatrix}}_A \underbrace{\begin{bmatrix} x_1 \\ \vdots \\ x_5 \end{bmatrix}}_x = \underbrace{\begin{bmatrix} 2 \\ 4 \end{bmatrix}}_b ; x \geq 0$$

Les variables x_1, x_2 et x_3 sont appelées variables principales ou fondamentales (variable de décision), les variables x_4 et x_5 sont appelées les variables d'écart.

3) Définition :

considérons le programme linéaire suivant :

$$\text{Max } C^T x$$

$$Ax = b \quad \textcircled{1}$$

$$x \geq 0 \quad \textcircled{2}$$

$$b \geq 0, \quad x \in \mathbb{R}^n, \quad b \in \mathbb{R}^m$$

$$A \in \mathbb{R}^{m \times n}$$

Déf 1 :

Tout vecteur x vérifiant les contraintes ① et ② est appelé solution admissible ou réalisable du problème posé

Déf 2 :

Un optimum ou extrémum d'une fct f est soit un maximum ou un minimum i.e. la valeur la plus faible que prend la fct sur son ensemble de définition D . cet optimum est donné par $f(x^*)$

Déf 3 :

une solution réalisable x^0 est optimal si : $C^T x^0 = \max(C^T x)$

Déf 4 :

une solution réalisable x est de base si $n-m$ de ses composants sont nulles et aux autres correspondent m vecteur linéairement indépendants.

expt :

$$A = [a_1 \ a_2 \ \dots \ a_m \ \dots \ a_n]$$

$$x = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$$

$$Ax = a_1 x_1 + a_2 x_2 + \dots + a_m x_m + \dots + a_n x_n = b$$

$$x_B = (x_1, \dots, x_m, 0, \dots, 0), \quad \delta$$

$$AB = [a_1 \dots a_m]$$

avec: $\det(AB) \neq 0$

$x_1 \dots x_m$: variables de base

$x_{m+1} \dots x_n$: variables hors base

02/11/2017

4) - Résolution géométrique d'un P.L à 2 variables:

La résolution géométrique d'un P.L consiste à représenter le domaine des solutions admissibles définies par les contraintes ensuite évaluer la fct aux différentes solutions au domaine.


expt: Résoudre géométriquement le P.L suivant:

$$\text{Min } 2x_1 - x_2$$

$$\text{s.c: } -3x_1 + 2x_2 \leq 2$$

$$2x_1 - 4x_2 \leq 3$$

$$x_1 + x_2 \leq 6 \quad 0 \leq x_1 \leq 6 \quad ; \quad x_2 \geq 0$$



- ① $-3x_1 + 2x_2 = 2$ (0,1) (-2,0)
- ② $2x_1 - 4x_2 = 3$ (0, -3/4) (3/2, 0)
- ③ $x_1 + x_2 = 6$ (0,6) (6,0)

on a 5 sommets:

$$D(0,0) \quad C(3/2, 0) \quad E(0,1)$$

$$A(2, 4) \quad B(9/2, 3/2)$$

remarque: la cgt ① et ③
l'opt ③ et ①

$$f(D) = 0 \quad f(C) = 3 \quad f(E) = -1$$

$$f(A) = 0 \quad f(B) = \frac{15}{2}$$

$$\Rightarrow \text{Min}(f) = f(E) = -1$$

donc la résolution optimale (point de minimum) est E(0,1)

Rq:

si le nbr de variable de P.L est supérieur à 2, on utilise la méthode de Simplexe.

5) - Méthode de Simplexe:

soit le programme linéaire sur la forme canonique:

$$\text{Max } c_1x_1 + c_2x_2 + \dots + c_nx_n$$

s.c:

$$a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n = b_1$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n = b_2$$

$$\vdots$$

$$a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mn}x_n = b_m$$

$$x_1 \geq 0 \quad x_2 \geq 0 \quad \dots \quad x_n \geq 0$$

$$\{x_j / j \in J = \{1, \dots, n\}\}$$

La méthode du simplexe est une méthode itérative, elle commence avec une solution réalisable de base.

étape 1:

choix de la solution réalisable de base de départ.

$$\text{on a : } J = \{1, \dots, n\} \quad J_B = \{1, 2, \dots, m\}$$

$$J_H = \begin{cases} x_{m+1} & x_n \\ m+1 & n \end{cases}$$

$$A_B = I_m = [A_1 A_2 \dots A_m]$$

J_B choisi pour avoir :

A_B : une matrice identité

$x_1 \dots x_m$: variables de base

$x_{m+1} \dots x_n$: hors base.

La solution réalisable de base de départ $x = (b_1, \dots, b_m, 0, \dots, 0)$

étape 2:

construction du Tableau de Simplexe et calcul des E_j

	θ_j	θ_1	θ_2			θ_m
C_n	A_n	a_{1n}	a_{2n}			a_{mn}
---	---					
C_{m+1}	A_{m+1}	$a_{1,m+1}$	$a_{2,m+1}$...		$a_{m,m+1}$
C_m	A_m	0	0	...		1
---	---					
C_2	A_2	0	1	0	...	0
C_1	A_1	1	0	0
C^T	b	b_1	b_2	...		b_m
	Valeurs de base	A_1	A_2	...		

$$E_j = C_B^T A_B^{-1} A_j - C_j ; C_B = \begin{bmatrix} C_1 \\ \vdots \\ C_m \end{bmatrix}$$

si $E_j \geq 0 ; j = 1, n \Rightarrow \text{Stop}$

$$x = [b_1, \dots, b_m, 0, 0]$$

étape 3:

a) - Détermination du vecteur sortant de la base :

le vecteur A_j sortant de la base est celui qui correspond à $E_j < 0$, avec :

$$E_j < 0, j \in J_H$$

par la division de l'ancienne ligne par l'élément pivot α .

09/11/2017

e) - détermination des autres lignes :

On cherche les combinaisons linéaires entre la nouvelle ligne et le reste des lignes de façon à rendre le vecteur entrant A_j un vecteur de base.

f) - calcul des E_j :

si $E_j \geq 0$, $j = 1, n \Rightarrow$ stop.

x est une solution optimale si non on refait l'étape 3.

$L_6 - 2L_1$

Vecteur de base	C^T	4	-2	2	0	0	0	
	b	A_1	A_2	A_3	A_4	A_5	A_6	e_j
L_4 A_4	6	1	-1	1	1	0	0	$6/1$
L_5 A_5	2	1	1	1	0	1	0	$2/1 \rightarrow$
L_6 A_6	4	2	2	1	0	0	1	$4/2$
E_j	-4	2	-2	0	0	0		
L_4 A_4	4	0	-2	0	1	-1	0	
L_1 A_1	2	1	1	1	0	1	0	
L_6 A_6	0	0	0	-1	0	-2	1	$L_4' = L_4 - L_1$
E_j	0	6	2	0	4	0		

$$E_j = C^T B \quad A_j - c_j \quad [0 \ 0 \ 0] \begin{bmatrix} -1 \\ 1 \\ 2 \end{bmatrix} + 2$$

$$E_1 = \underbrace{[0 \ 0 \ 0]}_{C^T B} \underbrace{\begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}}_{A_j} - \underbrace{4}_{c_j} = -4$$

$$L_1 = \frac{L_5}{2} = L_5 \quad L_4' = L_4 - L_1$$

$$C^T B = [c_4 \ c_1 \ c_6] = [0 \ 4 \ 0] \quad L_6' = L_6 - 2L_1$$

$y \geq 0 \Rightarrow x^* = (2 \ 0 \ 0 \ 4 \ 0 \ 0)$ est la solution optimale (pt de Max)

$$\text{Max } (f) = f(x^*) = 8$$

- Méthode des 2 phases de Simplex:

considérons le problème de programmation linéaire suivant:

$$(P) \begin{cases} \text{Max } C^T x \\ \text{s.c.} \\ Ax = b \\ x \geq 0 \quad x \in \mathbb{R}^n \quad b \in \mathbb{R}^m \quad C \in \mathbb{R}^n \quad b \geq 0 \end{cases}$$

Dans le cas où la solution de base de départ n'est pas évidente ou n'est pas réalisable on ajoute des variables artificielles.

Ainsi, la résolution du problème (P) sera faite en 2 phases.

a). Première phase:

La 1^{ère} phase de résolution du problème (P) consiste à résoudre le problème auxiliaire suivant par la méthode de Simplex:

$$(P) \begin{cases} \text{Max } \left(- \sum_{i=1}^m x_{n+i} \right) \\ \text{s.c.} \\ [Ax]_i + x_{n+i} = b_i \quad ; \quad i = \overline{1, m} \\ x \geq 0 \quad x_{n+i} \geq 0 \end{cases}$$

où les x_{n+i} sont appelées variables artificielles. Ainsi le problème (P.1) possède $n+m$ variables:

$$X = (x_1 \dots x_n \ x_{n+1} \dots x_{n+m})$$

$$\text{Soit } X^* = (x_1^* \dots x_n^* \ x_{n+1}^* \dots x_{n+m}^*)$$

La solution optimale de (P.1)

2 cas peuvent se produire :

1^{er} cas:

$$x_{n+i}^* \neq 0 \text{ pour au moins}$$

un indice, dans ce cas le problème (P) n'admet pas de solution.

2^{ème} cas:

$x_{n+i}^* = 0 \quad \forall i \Rightarrow$ on passe à la 2^{ème} phase.

b). 2^{ème} Phase:

Dans cette phase, on résout (P), en prenant $x^* = (x_1^* \dots x_n^*)$

comme solution de base de départ

expi: résoudre par Simplex le P.L suivant:

$$(P) \begin{cases} \text{Max } (x_1 - x_2 + 2x_3) \\ \text{s.c.} \\ \frac{1}{2}x_1 + x_2 + x_3 = 10, \quad b \\ x_1 - x_2 = 20 \\ x_j \geq 0 \quad j = \overline{1, 3} \end{cases}$$

16.11.2014

La variable de base n'est pas évidente dans la 2^{ème} contrainte donc on ajoute une variable artificielle x_4 et on passe à la 1^{ère} phase.

Phase 1: $\text{Max}(-x_4)$

$$\frac{1}{2}x_1 + x_2 + x_3 = 10$$

$$x_1 - x_2 + x_4 = 20$$

$$x_j \geq 0 \quad j = 1, 4$$

$$I_B = \{x_3, x_4\} = \{3, 4\}$$

$$I_H = \{x_1, x_2\} = \{1, 2\}$$

$x^* = (0 \ 0 \ 10 \ 20)$ est la solution de départ de base. (x si tous 0)

⇒ tableau de simplexe :

Vecteur de base	c^T	0	0	0	-1	θ_j
	b	A_1	A_2	A_3	A_4	
A_3	10	1/2	1	1	0	20
A_4	20	1	-1	0	1	20 →
E_j		-1	1	0	0	
A_3	0	0	3/2	1	-1/2	
A_1	20	1	-1	0	1	
E_j		0	0	0	1	

$E_j \geq 0 \Rightarrow x^* = (20 \ 0 \ 0 \ 0)$ la solution optimal.

$$C_B^T = (0 \ -1)$$

$$L_3 = L_3 - 1/2 L_1$$

$$L_1 = \frac{L_4}{2} = L_4$$

$$C_B^T = (0 \ 0)$$

Comme $x_4 = 0$ donc on passe à la 2^{ème} phase avec $x^* = (20 \ 0 \ 0)$ est la solution de base de départ de (P). on utilise donc le dernier tableau de la phase 1, en éliminant la variable artificielle x_4 .

	C^T	1	-1	2	
	b	A_1	A_2	A_3	
A_3	0	0	3/2	1	$C_B^T = (2 \ 1)$
A_1	20	1	-1	0	
E_j		0	3	0	

$E_j \geq 0 \Rightarrow x^* = (20 \ 0 \ 0)$ est la solution optimal (pt de max) de (P). $\text{Max}(f) = f(x^*) = 20$

- Problème dual d'un problème de programmation linéaire :

considérons le problème de programmation linéaire suivant

$$\begin{cases} \text{Max}(C^T x) \\ \text{s.c.} : Ax = b \\ x \geq 0 \end{cases} \quad (1)$$

Le problème ① est dit problème primal, son problème dual est donné par :

$$\begin{cases} \text{Min}(b^T y) \\ A^T y \geq c \\ y \in \mathbb{R}^m \end{cases} \quad (2)$$

Rq :

Le dual du dual est le primal

- Méthode de construction du dual :

Primal (Dual)	Dual (Primal)
fonction minimiser	fonction maximiser
contraintes : coefficients \geq	variable ≤ 0
" " \leq	" " ≥ 0
" " $=$	" " $\in \mathbb{R}$
variable ≥ 0	contrainte \geq
" " ≤ 0	" " \leq
" " $\in \mathbb{R}$	" " $=$

Propriétés de la dualité :

étant donné un problème primal ① et son dual ②

Théorème 1 : soit x^* et y^* solutions réalisables du primal et du dual respectivement : si $c^T x^* = b^T y^*$ alors x^* et y^*

sont des solutions optimales respectif du primal et du dual

Théorème de Kojima
complémentaires

2 solutions réalisables x^* et y^* respectif du primal et du dual sont optimales si et seulement si :

$$\left(\sum_{i=1}^m a_{ij} y_i^* - c_j \right) x_j^* = 0$$

$$\left(\sum_{j=1}^n a_{ij} x_j^* - b_i \right) y_i^* = 0$$

$$i = \overline{1, n} \quad j = \overline{1, m}$$

Théorème 2 : soit $X = \{x \in \mathbb{R}^n \mid Ax = b, x \geq 0\}$

si $X \neq \emptyset$ et si $C^T x \rightarrow +\infty$ alors les contraintes du dual sont contradictoires. De même, si l'ensemble des solutions réalisables du dual est non vide et si $b^T y \rightarrow -\infty$ alors les contraintes du primal sont contradictoires

Expl : écrire la forme duale du problème suivant

$$\text{Max } (2x_1 - 2x_2 + x_3)$$

$$3x_1 + 2x_2 - x_3 = 2$$

$$5x_1 - x_2 + x_3 = 3$$

$$x_1 \geq 0 \quad x_2 \geq 0 \quad x_3 \geq 0$$

$$\text{Dual Min } (b^T y) = [2 \ 3] \begin{bmatrix} y_1 \\ y_2 \end{bmatrix}$$

$$= 2y_1 + 3y_2$$

$$\text{s.c. : } 3y_1 + 5y_2 \geq 2$$

$$2y_1 - y_2 \geq -1$$

$$-y_1 + y_2 \geq 1$$

$$-y_1 \in \mathbb{R} \quad y_2 \in \mathbb{R}$$

30.11.2014

Ch 4: Programmation

non linéaire.

1. Introduction:

La programmation non linéaire consiste à résoudre des problèmes d'optimisation dont le fct objectif et/ou les contraintes sont non linéaires.

2. Problème avec contraintes d'égalité: méthode de multiplicateur de Lagrange

Soit le problème suivant:

$$\text{Min } f(x)$$

s.c.:

$$g_i(x) = 0 \quad i = 1, \dots, m$$

$$m \leq n \quad x \in \mathbb{R}^n$$

Soit la fonction de Lagrange (ou le Lagrangien) du problème

$$\mathcal{L}(x, \lambda) = f(x) + \sum_{i=1}^m \lambda_i g_i(x)$$

où: λ_i sont appelés "multiplicateur de Lagrange".

$$\text{Soit } g(x) = \begin{bmatrix} g_1(x) \\ \vdots \\ g_m(x) \end{bmatrix}$$

Le problème revient à trouver le min de \mathcal{L}

1. Conditions nécessaires et suffisantes pour un minimum ou un maximum local:

x^* est un pt de minimum local (resp maximum) de $f(x)$ sous les contraintes $g_i(x) = 0$; $i = 1, \dots, m$ si:

$$\left. \begin{array}{l} \nabla_x \mathcal{L}(x^*, \lambda^*) = 0 \\ g_i(x^*) = 0 = \nabla \lambda \mathcal{L}(x^*, \lambda^*) \end{array} \right\} \text{si}$$

$$2. \quad y^T \nabla_x^2 \mathcal{L}(x^*, \lambda^*) y > 0 \text{ (resp } < 0)$$

$$\forall y \neq 0 \quad / \quad \nabla g(x^*) y = 0$$

où : $\nabla_x \mathcal{L}(x, \lambda)$: gradient de \mathcal{L} par rapport à x .

$\nabla_x^2 \mathcal{L}(x, \lambda)$: hessien de \mathcal{L} / x

$\nabla g(x^*)$: matrice Jacobienne ($m \times n$) de $g(x)$.

$$\nabla g(x) = \begin{bmatrix} \frac{\partial g_1}{\partial x_1} & \frac{\partial g_1}{\partial x_2} & \dots & \frac{\partial g_1}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial g_m}{\partial x_1} & \frac{\partial g_m}{\partial x_2} & \dots & \frac{\partial g_m}{\partial x_n} \end{bmatrix}$$

$$= \begin{bmatrix} \nabla g_1(x)^T \\ \vdots \\ \nabla g_m(x)^T \end{bmatrix}$$

exempl:

$$\text{Min}(x_1^2 + x_2^2)$$

s.c :

$$g(x) = x_1^2 + 2x_2^2 - 1 = 0$$

Le fct de Lagrange :

$$\mathcal{L}(x, \lambda) = f(x) + \lambda g(x)$$

$$\mathcal{L}(x, \lambda) = x_1^2 + x_2^2 + \lambda(x_1^2 + 2x_2^2 - 1)$$

point critique :

$$\begin{cases} \nabla_x \mathcal{L}(x, \lambda) = 0 \\ g(x) = 0 = \nabla \lambda \mathcal{L}(x, \lambda) \end{cases}$$

$$\Rightarrow \begin{cases} 2x_1 + 2\lambda x_1 = 0 \\ 2x_2 + 4\lambda x_2 = 0 \\ x_1^2 + 2x_2^2 - 1 = 0 \end{cases}$$

$$\begin{cases} x_1(1 + \lambda) = 0 & \textcircled{1} \\ x_2(1 + 2\lambda) = 0 & \textcircled{2} \\ x_1^2 + 2x_2^2 - 1 = 0 & \textcircled{3} \end{cases}$$

$\textcircled{1} \Rightarrow x_1 = 0$ ou $\lambda = -1$

$\textcircled{2} \Rightarrow x_2 = 0$ ou $\lambda = -1/2$

$x_1 = 0 : \textcircled{3} \Rightarrow x_2 = \pm \frac{1}{\sqrt{2}}$

$\textcircled{2} \Rightarrow \lambda = -1/2$

pt₁ $(0, \frac{1}{\sqrt{2}}, -\frac{1}{2})$ pt₂ $(0, -\frac{1}{\sqrt{2}}, -\frac{1}{2})$

$\lambda = -1 : \textcircled{2} \Rightarrow x_2 = 0 ; \textcircled{3} \Rightarrow x_1 = \pm 1$

pt₃ $(1, 0, -1)$ pt₄ $(-1, 0, -1)$

$x_2 = 0, \textcircled{3} \Rightarrow x_1 = \pm 1$ $\textcircled{1} \Rightarrow \lambda = -1$

$\lambda = -1/2 ; \textcircled{1} \Rightarrow x_1 = 0 ; x_2 = \pm \frac{1}{\sqrt{2}}$

on a 4 pts critiques :

$x^0 = (0, \frac{1}{\sqrt{2}})$ avec $\lambda = -1/2$

$x^1 = (0, -\frac{1}{\sqrt{2}})$ avec $\lambda = -1/2$

$$x^2 = (1 \ 0) \text{ avec } \lambda = -1$$

$$x^3 = (-1 \ 0) \text{ avec } \lambda = -1$$

2°):

$$\nabla_x^2 \mathcal{L}(x, \lambda) = \begin{bmatrix} 2+2\lambda & 0 \\ 0 & 2+4\lambda \end{bmatrix}$$

$$\nabla g(x) = \begin{bmatrix} \frac{\partial g}{\partial x_1} & \frac{\partial g}{\partial x_2} \end{bmatrix}$$

$$\nabla g(x) = [2x_1 \quad 4x_2]$$

Nature du 1^{er} pt x^0 avec $\lambda = -1/2$

$$\nabla g(x^0) = [0 \quad 2\sqrt{2}]$$

$$\nabla g(x^0) y = 0 \Rightarrow [0 \quad 2\sqrt{2}] \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = 0$$

$$0 \cdot y_1 + 2\sqrt{2} y_2 = 0 \Rightarrow y = \begin{bmatrix} y_1 \\ 0 \end{bmatrix}$$

$$\nabla_x^2 \mathcal{L}(x^0, -1/2) = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}$$

$$y^T \nabla_x^2 \mathcal{L}(x^0, -1/2) y = y_1^2 \geq 0$$

x^0 est point de min. local.

$$x^0 = (0; \frac{+1}{\sqrt{2}})$$

Nature du 4^{ème} pt:

$$x^3 = (-1, 0) \quad \lambda = -1$$

$$\nabla g(x) = [-2 \ 0] \Rightarrow \begin{bmatrix} y_1 \\ y_2 \end{bmatrix}$$

nature du 3^{ème} point:

$$x^2 = (1 \ 0) \quad \lambda = -1$$

$$\nabla g(x) = [2 \ 0] \Rightarrow \nabla g(x^2) y = [2 \ 0]$$

$$= [2 \ 0] \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = 0$$

$$\Rightarrow y = \begin{bmatrix} 0 \\ y_2 \end{bmatrix}$$

$$\nabla_x^2 \mathcal{L}(x^2, -1) = \begin{bmatrix} 0 & 0 \\ 0 & -2 \end{bmatrix}$$

$$\Rightarrow y^T \nabla_x^2 \mathcal{L}(x^2, -1) y = -2y_2^2 < 0$$

$x^2 = (1 \ 0)$ est un point de max.

Nature du 2^{ème} point:

$$x^1 = (0, -\frac{1}{\sqrt{2}}) \quad \lambda = -1/2$$

$$\nabla g(x^1) = [0 \quad -2\sqrt{2}]$$

$$\nabla g(x^1) = [0 \quad -2\sqrt{2}] \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = 0$$

$$y = \begin{bmatrix} y_1 \\ 0 \end{bmatrix}$$

$$\nabla_x^2 \mathcal{L}(x^1, -1/2) = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

$$\Rightarrow y^T \nabla_x^2 \mathcal{L}(x^1, -1/2) y = y_1^2 > 0$$

$x^1 = (0 \ -\frac{1}{\sqrt{2}})$ est un pt de min local:

on a 2 pts de min:

$$\text{Min } f(x) = f(x^0)$$

$$\text{Min } f(x) = f(x^1)$$

Problème avec contraintes d'inégalité : conditions de Kuhn-Tucker

Soit le problème suivant :

$$\text{Min } f(x)$$

$$\text{s.c. : } h_j(x) \leq 0 \quad j=1, \dots, p$$

Req : les contraintes de type \geq peuvent être ramenées aux contraintes \leq .

Définition : une contrainte d'inégalité $h_j(x) \leq 0$ est active (ou saturée) en x si $h_j(x) = 0$. Elle est inactive si $h_j(x) < 0$

1/ conditions nécessaires et suffisantes pour un minimum ou maximum local : conditions de Kuhn-Tucker :

Soit la fct de Lagrange :

$$\mathcal{L}(x, u) = f(x) + \sum_{j=1}^p \mu_j h_j(x)$$

μ_j : multiplicateur de Lagrange

$$\text{Soit } h(x) = \begin{bmatrix} h_1(x) \\ \vdots \\ h_p(x) \end{bmatrix} ; \mu = \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_p \end{bmatrix}$$

x^* est un point de min (resp. max) local de $f(x)$ sous les contraintes $h_j(x) \leq 0 ; j=1, \dots, p$ si :

$$1) \begin{cases} \nabla_x \mathcal{L}(x^*, \mu^*) = 0 \\ \nabla \mu_j \mathcal{L}(x^*, \mu^*) = h_j(x^*) \leq 0 \\ \mu_j^* h_j(x^*) = 0 ; j=1, \dots, p \\ \mu_j^* \geq 0 ; j=1, \dots, p \text{ (resp } \mu_j^* \leq 0) \end{cases}$$

$$2) y^T \nabla_x^2 \mathcal{L}(x^*, \mu^*) y > 0 \text{ (resp } < 0) \forall y \neq 0 / y^T \nabla_x h_j(x^*) = 0 ; \forall j \in I(x^*)$$

$I(x^*)$ est l'ensemble des indices des contraintes actives

exemple :

$$\text{Min } (4x_1^2 + 5x_2^2)$$

$$\text{s.c. : } h(x) = x_1 - 1 \leq 0$$

La fonction de Lagrange (Lagrangien)

$$\mathcal{L}(x, \mu) = f(x) + \mu h(x) = 4x_1^2 + 5x_2^2 + \mu(x_1 - 1)$$

* conditions de Kuhn-Tucker :

$$\frac{\partial \mathcal{L}}{\partial x_1} = 8x_1 + \mu = 0 \quad \text{--- (1)}$$

$$\frac{\partial \mathcal{L}}{\partial x_2} = 10x_2 = 0 \quad \text{--- (2)}$$

$$x_1 - 1 \leq 0 \quad \text{--- (3)}$$

$$\mu(x_1 - 1) = 0 \quad \text{--- (4)}$$

$$\mu \geq 0 \quad \text{--- (5)}$$

$$(4) \Rightarrow \mu = 0 \text{ ou } x_1 = 1$$

1^{er} cas: $\mu = 0$ $x_1 \neq 1$ ($h < 0$)
 $\Rightarrow h$ inactive

$$\begin{cases} 8x_1 = 0 \\ x_2 = 0 \\ x_1 - 1 < 0 \Rightarrow -1 < 0 \\ \mu = 0 \end{cases}$$

Le 1^{er} pt critique (x_1^*, x_2^*, μ^*)
 $= (0 \ 0 \ 0)$

2^{eme} cas: $\mu \neq 0$ $x_1 = 1$ (h est active $\Rightarrow h = 0$)

$$8x_1 + \mu = 0 \Rightarrow \mu = -8x_1 = -8$$

$\mu < 0 \Rightarrow$ solution rejetée

on a trouvé un seul pt critique $x^* = (0 \ 0)$, $\mu^* = 0$

- Etude de la nature du pt critique: x^*

$$y^T \nabla^2_x \mathcal{L}(x^*, \mu^*) y > 0, \forall y \neq 0$$

$$\nabla^2_x \mathcal{L}(x, \mu) = \begin{bmatrix} 8 & 0 \\ 0 & 10 \end{bmatrix} \quad \text{--- } y^T \nabla^2_x \mathcal{L}(x) = 0$$

$$\Rightarrow \Delta_1 = 8 > 0$$

$$\Delta_2 = 80 > 0$$

$\Rightarrow \nabla^2_x \mathcal{L}(x^*, \mu^*) > 0 \Rightarrow x^*$ est un pt de min

$$e \text{Min}(f) = f(x^*) = 0$$

4. Problème avec contraintes d'égalité et d'inégalité: condition de Kuhn-Tucker

14-12-2017

Soit le problème suivant:

$$e \text{Min } f(x)$$

s.c

$$g_i(x) = 0 \quad i = 1, \dots, n$$

$$h_j(x) \leq 0 \quad j = 1, \dots, p$$

1) - condition nécessaire

et suffisante pour un min ou un max local - Kuhn-Tucker

Soit le fct de Lagrange:

$$L(x, \lambda, \mu) = f(x) + \sum_{i=1}^m \lambda_i g_i(x) + \sum_{j=1}^p \mu_j b_j(x)$$

λ_i, μ_j multiplicateurs de Lagrange.

Soit $g(x) = \begin{bmatrix} g_1(x) \\ \vdots \\ g_m(x) \end{bmatrix}$ $h(x) = \begin{bmatrix} h_1(x) \\ \vdots \\ h_p(x) \end{bmatrix}$

$\mu = \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_p \end{bmatrix}$ $\lambda = \begin{bmatrix} \lambda_1 \\ \vdots \\ \lambda_m \end{bmatrix}$

x^* est un pt de minimum (resp. max) local de $f(x)$, sous les contraintes $g_i(x) = 0 \quad i=1, \dots, m$ et $h_j(x) \leq 0 \quad j=1, \dots, p$ si :

$\Delta x L(x^*, \lambda^*, \mu^*) = 0$

$g_i(x^*) = 0 \quad i=1, \dots, m$
 $h_j(x^*) \leq 0 \quad j=1, \dots, p$
 $\mu_j^* h_j(x^*) = 0 \quad j=1, \dots, p$
 $\mu_j^* \geq 0 \quad j=1, \dots, p$
 (resp $\mu_j^* \leq 0$)

$y^T \nabla L(x^*, \lambda^*, \mu^*) y > 0$ (resp < 0)
 $\forall y \neq 0$

$$\begin{cases} \nabla L(x^*) y = 0 \\ y^T \nabla h_j(x^*) = 0 \quad \forall j \in I(x^*) \end{cases}$$

(ex: serie 3 et 3)

5- Methode de Lagrange-Newton pour des contraintes d'egalite :

Soit le probleme suivant :

Min $f(x)$

si :

$g_i(x) = 0 \quad i=1, \dots, m$

Soit la fonction de Lagrange

$L(x, \lambda) = f(x) + \sum_{i=1}^m \lambda_i g_i(x)$

Soit : $\lambda = \begin{bmatrix} \lambda_1 \\ \vdots \\ \lambda_m \end{bmatrix}$

Le probleme revient a chercher le min de $L(\cdot)$ en utilisant la methode iterative de Newton en partant d'un pt initial $\begin{bmatrix} x^0 \\ \lambda^0 \end{bmatrix}$

algorithme de Newton: (A04TD3) esp

$\begin{bmatrix} x^0 \\ \lambda^0 \end{bmatrix}$ pt initial $k=0, 1, \dots$

$\begin{bmatrix} x^{k+1} \\ \lambda^{k+1} \end{bmatrix} = \begin{bmatrix} x^k \\ \lambda^k \end{bmatrix} - \left[\nabla^2 L(x^k, \lambda^k) \right]^{-1} \nabla L(x^k, \lambda^k)$

$\nabla^2 L$: matrice Hessienne de L en x^k

6 - Autres méthodes.

Il y a d'autres méthodes destinées à la solution d'un programme non-linéaire, on en définit :

- * méthode de pénalisation
- * " de gradient projeté
- * " de Newton projeté
- * " de dualité (méthode d'UZAWA).

Ch 5: Optimisation sans contraintes. méthodes globales.

1 - Introduction:

contrairement à toutes les méthodes d'optimisation vus jus qu'ici, les méthodes d'optimisation globales permettent d'obtenir un optimum global d'une fonction. Parmi les méthodes globales, nous citons les

algorithmes génétiques (AG).

Un algorithme génétique est une méthode d'optimisation itérative aléatoire (stochastic) basée sur les probabilités.

Il utilise une population d'individus représentant les solutions potentielles du problème d'optimisation à résoudre. Cette population va évoluer de génération en génération à l'aide de différentes opérations: sélection, croisement, mutation. L'inconvénient majeur de AG réside dans le nbl important d'évaluation nécessaires et leur convergence.

2- Les étapes de l'optimisation avec les AG:

Soit le problème d'optimisation suivant:

$$\text{Min } f(x)$$

$$x = (x_1, \dots, x_n)$$

L'optimisation avec les AG se base sur les étapes suivantes

1. Génération d'une population initiale et codage :

Chaque x_i , $i=1, \dots, n$ correspond à une valeur réelle qui peut être codée à l'aide d'un alphabet.

L'alphabet le plus simple composé de 2 caractères, est l'alphabet binaire (composé de 0 et 1)

Ce nombre, une fois codé, est appelé chromosome.

Chaque caractère du chromosome (0 ou 1) est appelé gène ou (allèle). Le point de départ consiste en ajoutant bout à bout tous les codages des x_i . A l'aide de ce codage, on génère aléatoirement une population initiale de N individus.

Une fois les individus générés, les opérations de sélection, de croisement, de mutation peuvent être appliquées à cette population.


Exemple de codage :

une fonction à 5 variables

$$x = (x_1, \dots, x_5)$$

$$x_1 = 14, x_2 = 12, x_3 = 2$$

$$x_4 = 7, x_5 = 9 = x$$



taille de chromosome = 20 bits

21-12-2014

b) Evaluation des individus de la population :

Dans cette étape, les individus sont évalués par des tests d'adaptation (fit $f(x)$ à optimiser (fitness))

c) - Sélection :

cette étape permet de choisir les individus (Parents) sur lesquels vont s'appliquer les opérations de reproduction (croisement et mutation) pour la création de la future génération.

La sélection proportionnelle
 à la méthode de sélection la
 plus utilisée. Cette méthode
 consiste à choisir un nombre
 $d \in [0, 1]$ puis pour chaque
 individu x^i de la population
 on calcule la quantité
 suivante:

$$n_i = \frac{f(x^i)}{\sum_{j=1}^{N_p} f(x^j)}$$

N_p : nbr d'individus fait la
 population

$f(x)$: valeur d'adaptation
 de l'individu x .

n_i : le nbr de sélection opérée
 de l'individu

si $n_i > x$: sélectionner x^i et
 partir des éléments sélectionnés,
 on forme une nouvelle population
 dont la taille est la même
 que celle de la population
 initiale (N_p).

d/- Croisement:

L'idée du croisement, est de

créer des enfants. On choisit
 deux aléatoirement des indi-
 vides de la population
 2 à 2 afin de former des
 couples, chaque couple va
 donner naissance à 2 enfants
 comportant chacun des
 séquences chromosomiques
 de chaque parent.

exemple de croisement:
 (fct à 5 variables)

$$x = (x_1 \text{ --- } x_5)$$

population initiale:

parent ①:

$$\begin{array}{ccccc} \overset{11}{1110} & \overset{12}{1100} & \overset{2}{0010} & \overset{7}{0111} & \overset{9}{1001} \\ \hline x_1 & x_2 & x_3 & x_4 & x_5 \end{array}$$

parent ②:

$$\begin{array}{ccccc} \overset{5}{0101} & \overset{15}{1111} & \overset{11}{1011} & \overset{0}{0000} & \overset{10}{1010} \\ \hline & & & & \end{array}$$

Nouvelle population:

enfant ①:

$$\begin{array}{ccccc} \overset{14}{1110} & \overset{13}{1101} & \overset{11}{1011} & \overset{00}{0000} & \overset{10}{1010} \\ \hline & & & & \end{array}$$

enfant ②:

$$\begin{array}{ccccc} \overset{0101} & \overset{1100} & \overset{0010} & \overset{0111} & \overset{1001} \\ \hline & & & & \end{array}$$

e/- Mutation:

cette opération consiste à
 modifier aléatoirement
 certains gènes d'un individu

exemple de mutation :

ancien individu :

110 1100 0010 0111 1001

nouveau individu :

110 110 0010 011 1001

exemple :

considérons un problème de maximisation suivant :

$$\text{Max } x \rightarrow f(x)$$

s.c. :

$$0 \leq x \leq 31$$

où x est un entier.

1) - codage et choix de la population initiale :

nous utiliserons le codage binaire de x . Les séquences (chromosomes) contenant au max 5 bits, car 31 se note :

$$(31)_{10} \rightarrow (11111)_2$$

nous fixons la taille de la population initiale à $N_p = 4$ (4 individus). Supposons que nous avons choisi de façon aléatoire les individus suivants :

N°	chromosome	x
1	011101	13
2	111000	24
3	011000	8
4	110111	19

2) - évaluation des individus

N°	chromosome	x	$f(x)$	n_i
1	011101	13	169	0,141
2	111000	24	576	0,493
3	011000	8	64	0,054
4	110111	19	361	0,305

$$n_i = \frac{f(13)}{f(13) + f(24) + f(8) + f(19)}$$

3) - sélection des parents :

on va tirer 4 individus parmi la population en tenant compte de leur adaptation respective par esp.

- * 1 copie de l'individu ①
- * " " " " ④
- * 2 " " " " ②
- * aucune copie " " ③

N°	chromosome	χ
1	01101	13
2	11000	24
3	01000	8
4	10011	19

4/. Croisement:

Les parents, sont sélectionnés au hasard, nous supposons que l'individu 3 s'accouple avec 4, les chromosomes seront couplés au hasard

N°	Parent	Enfant
1	01101	01100
2	11000	11001
3	11000	11011
4	10011	10000

la nouvelle génération :

N°	chromosome	χ
1	01100	12
2	11001	25
3	11011	27
4	10000	16

et maintenant que la nouvelle génération (population) est entièrement créée nous pouvons de nouveau l'évaluer aléatoirement des individus suivants

N°	chromosome	χ
1	01101	13
2	11000	24
3	01000	8
4	10011	19