

Maîtrise d'informatique

2 001-02

ALGORITHMIQUE NUMÉRIQUE

Notes de Cours

Jean-Yves JAFFRAY

CHAPITRE

OPTIMISATION

OPTIMISATION

1 OPTIMISATION D'UNE FONCTION D'UNE VARIABLE

1.1 FONCTIONS UNIMODALES

Soit f une fonction à valeurs réelles définie dans un intervalle $[a, b]$ de \mathbb{R} .

On dit que f passe par un *minimum (global ou absolu)* en \hat{x} lorsque $x \in [a, b] \implies f(x) \geq f(\hat{x})$; ce minimum est *strict* lorsque $x \neq \hat{x} \implies f(x) > f(\hat{x})$;

et on dit que f passe par un *minimum local* en \hat{x} lorsqu'il existe un voisinage V de \hat{x} tel que $x \in V \implies f(x) \geq f(\hat{x})$; ce minimum local est *strict* lorsque $x \in V \setminus \{\hat{x}\} \implies f(x) > f(\hat{x})$.

[Rappelons que dans \mathbb{R} un voisinage V de \hat{x} est un ensemble contenant un intervalle ouvert $] \alpha, \beta [$ contenant lui-même x]

Une fonction f est *unimodale* lorsqu'il existe $\hat{x} \in [a, b]$ tel que :

$$x^1 < x^2 \leq \hat{x} \implies f(x^1) > f(x^2) ;$$

$$\hat{x} \leq x^1 < x^2 \implies f(x^1) < f(x^2).$$

Une fonction unimodale passe donc par un minimum strict en un point \hat{x} de $[a, b]$

Notons qu'une fonction unimodale peut ne pas être dérivable, ni même continue.

Exemples de fonctions unimodales

Une fonction f est dite *convexe* lorsque

$$\forall x, y \in [a, b], \forall \lambda \in [0, 1], f(\lambda x + (1 - \lambda)y) \geq \lambda f(x) + (1 - \lambda)f(y)$$

et *strictement convexe* lorsque

$$\forall x, y \in [a, b], \forall \lambda \in]0, 1[, f(\lambda x + (1 - \lambda)y) > \lambda f(x) + (1 - \lambda)f(y).$$

Toute fonction strictement convexe est unimodale. En revanche il existe des fonctions convexes non unimodales et des fonctions unimodales non convexes.

L'intérêt des fonctions unimodales tient à la propriété suivante :

Lemma 1 *Tout minimum local d'une fonction unimodale en est minimum global.*

Ce lemme, de même que le suivant, se démontre facilement (par l'absurde).

Lemma 2 *Soit $f : [a, b] \rightarrow \mathbb{R}$, unimodale. Soit x^G, x^D tels que $a < x^G < x^D < b$; alors :*

$$\begin{aligned} f(x^G) < f(x^D) &\implies \hat{x} \in [a, x^D] \\ f(x^G) > f(x^D) &\implies \hat{x} \in [x^G, b] \\ f(x^G) = f(x^D) &\implies \hat{x} \in [x^G, x^D]. \end{aligned}$$

Figure dans le 1^{er} cas

Nous utiliserons cette propriété pour localiser, avec une précision donnée, par une méthode itérative, le minimum d'une fonction unimodale.

Le calcul de la valeur d'une fonction f en un x donné peut être long (il faut par exemple sommer les premiers termes d'une série de somme $f(x)$). La méthode suivante ne demande qu'une évaluation à chaque itération.

1.2 MÉTHODE DE LA SUITE DE FIBONACCI

Rappel : La suite de FIBONACCI est donnée par la formule de récurrence :

$$F_0 = F_1 = 1; \quad F_{k+2} = F_k + F_{k+1}.$$

Ses premiers termes sont donc : 1, 1, 2, 3, 5, 8, 13, 21, 34, 55, 89, etc...

Le rapport de deux termes successifs a pour limite le *nombre d'or* :

$$\frac{F_{k+1}}{F_k} \rightarrow \tau = \frac{1+\sqrt{5}}{2} = 1,618\dots, \text{ solution positive de l'équation } \tau = 1 + \frac{1}{\tau}.$$

Méthode :

On se donne a priori N , nombre total de fois où l'on évaluera f en un point.

Itération k

On applique le lemme précédent à un intervalle $[a_k, b_k]$ avec les points intérieurs x_k^G, x_k^D donnés par :

$$x_k^G = a_k + \frac{F_{N-k}}{F_{N+2-k}}(b_k - a_k); \quad x_k^D = a_k + \frac{F_{N+1-k}}{F_{N+2-k}}(b_k - a_k),$$

qui sont situés symétriquement sur $[a_k, b_k]$, puisque $x_k^G - a_k = b_k - x_k^D$.

Selon le résultat de la comparaison de $f(x_k^G)$ et $f(x_k^D)$ on sera dans l'un des cas suivants :

cas (i) : $f(x_k^G) < f(x_k^D)$. Comme $\hat{x} \in [a_k, x_k^D]$, on prendra $a_{k+1} = a_k$ et $b_{k+1} = x_k^D$.

Comme

$$\begin{aligned} x_{k+1}^D &= a_{k+1} + \frac{F_{N+1-(k+1)}}{F_{N+2-(k+1)}}(b_{k+1} - a_{k+1}) = a_k + \frac{F_{N-k}}{F_{N+1-k}}(x_k^D - a_k) = \\ a_k + \frac{F_{N-k}}{F_{N+1-k}} \cdot \frac{F_{N+1-k}}{F_{N+2-k}}(b_k - a_k) &= a_k + \frac{F_{N-k}}{F_{N+2-k}}(b_k - a_k) = x_k^G, \end{aligned}$$

seule $f(x_{k+1}^G)$ aura à être évaluée à l'itération suivante.

Notons aussi que

$$b_{k+1} - a_{k+1} = x_k^D - a_k = \frac{F_{N+1-k}}{F_{N+2-k}}(b_k - a_k), \text{ d'où } \frac{b_{k+1} - a_{k+1}}{b_k - a_k} = \frac{F_{N+1-k}}{F_{N+2-k}}.$$

Cas(i)

cas (ii) : $f(x_k^G) > f(x_k^D)$. Comme $\hat{x} \in [x_k^G, b_k]$, on prendra $a_{k+1} = x_k^G$ et $b_{k+1} = b_k$.

Comme $x_{k+1}^G = x_k^D$ (calcul semblable à celui du cas(i)), seule $f(x_{k+1}^D)$ aura à être évaluée. Notons encore que $\frac{b_{k+1} - a_{k+1}}{b_k - a_k} = 1 - \frac{F_{N-k}}{F_{N+2-k}} = \frac{F_{N+1-k}}{F_{N+2-k}}$, comme dans le cas (i).

cas (iii) : $f(x_k^G) = f(x_k^D)$. Comme $\hat{x} \in [x_k^G, x_k^D]$, on prendra $a_{k+1} = x_k^G$ et $b_{k+1} = x_k^D$, d'où une réduction

$$\frac{b_{k+1} - a_{k+1}}{b_k - a_k} = \frac{F_{N+1-k} - F_{N-k}}{F_{N+2-k}} = \frac{F_{N-1-k}}{F_{N+2-k}} = \frac{F_{N-1-k}}{F_{N-k}} \cdot \left[\frac{F_{N-k}}{F_{N+1-k}} \cdot \frac{F_{N+1-k}}{F_{N+2-k}} \right],$$

supérieure à celle, $\left[\frac{F_{N-k}}{F_{N+1-k}} \cdot \frac{F_{N+1-k}}{F_{N+2-k}} \right]$, obtenue en deux itérations avec les cas (i) et (ii) ; en revanche, $f(x_{k+1}^D)$ et $f(x_{k+1}^G)$ devront toutes deux être évaluées.

Initialisation : elle se fait avec $a_1 = a$ et $b_1 = b$.

Arrêt : On s'arrête après avoir calculé la valeur de f en N points (dont deux à la 1^{ère} itération, ce qui peut faire moins de $(N - 1)$ itérations à cause du cas (iii)). La longueur de l'intervalle aura au total été réduite dans un rapport au moins égal à : $\prod_{k=1}^{N-1} \frac{F_{N+1-k}}{F_{N+2-k}} = \frac{1}{F_{N+1}}$.

Si l'on désire parvenir à localiser \hat{x} dans un intervalle de longueur inférieure à ε il faudra donc choisir N tel que : $F_{N+1} \geq \frac{b-a}{\varepsilon}$.

On démontre que la méthode de la suite de Fibonacci est optimale, en ce sens qu'on obtient un taux de réduction maximum à nombre d'itérations données.

1.2.1 VARIANTE : MÉTHODE DE LA SECTION D'OR

Elle a l'avantage de ne pas obliger à imposer a priori la valeur de N , mais a un taux de réduction inférieur à la méthode de Fibonacci (pour N grand, on perd environ 17%).

A chaque itération k , les points intérieurs divisent symétriquement et dans le même rapport le segment $[a_k, b_k]$:

$$x_k^G = a_k + \frac{\tau-1}{\tau}(b_k - a_k); \quad x_k^D = a_k + \frac{1}{\tau}(b_k - a_k)$$

où τ est le nombre d'or.

Ici encore, on conserve un des deux points intérieurs de l'itération précédente ; par exemple dans le cas (i) : $x_{k+1}^D = a_{k+1} + \frac{1}{\tau}(b_{k+1} - a_{k+1}) = a_k + \frac{1}{\tau}(x_k^D - a_k) =$

$$a_k + \frac{1}{\tau} \cdot \frac{1}{\tau}(b_k - a_k) = a_k + \frac{\tau-1}{\tau}(b_k - a_k) = x_k^G.$$

1.3 MÉTHODE DICHOTOMIQUE

Principe : A l'itération k interviennent trois points intérieurs, situés respectivement au quart, à la moitié et aux trois-quarts du segment $[a_k, b_k]$; à chaque itération l'intervalle est réduit de moitié, mais on doit calculer la valeur de f en deux nouveaux points.

En effet, dans l'intervalle $[a_k, b_k]$, on connaît par les calculs précédents les valeurs de f en a_k, b_k et $\frac{a_k+b_k}{2}$ et elles satisfont $f(\frac{a_k+b_k}{2}) \leq \text{MIN} \{f(a_k), f(b_k)\}$; on évalue alors de plus f en $\frac{3a_k+b_k}{4}$ et $\frac{a_k+3b_k}{4}$; puis on prend pour extrémités a_{k+1}, b_{k+1} et milieu $\frac{a_{k+1}+b_{k+1}}{2}$ du nouvel intervalle 3 points consécutifs (parmi les 5 points précédents) pour lesquels f vérifie la même inégalité.

1.4 FONCTIONS DÉRIVABLES

Soit f une fonction à valeurs réelles définie et dérivable dans un intervalle $[a, b]$ de \mathbb{R} . On note f' sa dérivée.

On dit que \hat{x} est un *point stationnaire* de f lorsque $f'(\hat{x}) = 0$.

Lemma 3 Une condition nécessaire pour que f , dérivable, passe par un minimum local en \hat{x} est que \hat{x} soit un point stationnaire de f .

Preuve : Par l'absurde : f , dérivable, est différentiable en \hat{x} :

$$f(\hat{x} + h) = f(\hat{x}) + h \cdot f'(\hat{x}) + o(h).$$

Si $f'(\hat{x}) > 0$, pour $h < 0$ assez petit, $h \cdot \left[f'(\hat{x}) + \frac{o(h)}{h} \right] < 0$ aussi et donc $f(\hat{x} + h) < f(\hat{x})$. Même chose, si $f'(\hat{x}) < 0$, pour $h > 0$ assez petit. ■

On peut montrer que lorsque f est, de plus, *convexe*, cette condition est aussi suffisante : en tout point où elle est stationnaire f passe par un minimum local et même global. En revanche l'unimodalité de f n'assure pas la suffisance de la condition.

1.5 METHODE DICHOTOMIQUE POUR LES FONCTIONS UNIMODALES DERIVABLES

Principe : A l'itération k interviennent les extrémités et le milieu du segment $[a_k, b_k]$; à chaque itération l'intervalle est réduit de moitié et on doit calculer la valeur de f' en un nouveau point.

En effet, dans l'intervalle $[a_k, b_k]$, on connaît par les calculs précédents les valeurs de f' en a_k, b_k et elles satisfont : $f'(a_k) < 0, f'(b_k) > 0$, ce qui suffit à assurer, f étant unimodale, que \hat{x} , où elle a son minimum, appartienne à $[a_k, b_k]$.

On évalue alors $f'(\frac{a_k+b_k}{2})$; si $f'(\frac{a_k+b_k}{2}) > 0$, on prend $a_{k+1} = a_k$ et $b_{k+1} = \frac{a_k+b_k}{2}$ de façon à retrouver les bons signes pour f' aux extrémités du nouveau segment; si $f'(\frac{a_k+b_k}{2}) < 0$, c'est $a_{k+1} = \frac{a_k+b_k}{2}$ et $b_{k+1} = b_k$ qu'il faut prendre; si $f'(\frac{a_k+b_k}{2}) = 0$, on peut s'arrêter!

1.6 MÉTHODE DE NEWTON

Soit $f : [a, b] \rightarrow \mathbb{R}$ de classe C^2 , c.-à-d. deux fois dérivable et de dérivée seconde continue. On note f' et f'' ses dérivées.

La méthode de Newton cherche à engendrer une suite de points (x^k) tendant vers un point stationnaire, c.-à-d. une solution de $f'(\hat{x}) = 0$, en procédant de la façon suivante :

À l'itération k , f' est remplacée par sa linéarisée en x^k :

$$l(x) = f'(x^k) + [x - x^k].f''(x^k),$$

et x^{k+1} est déterminée par $l(x^{k+1}) = 0$ d'où : $x^{k+1} = x^k - \frac{f'(x^k)}{f''(x^k)}$.

On connaît des *conditions suffisantes de convergence* de la méthode de Newton à partir d'un point initial x^0 quelconque de $[a, b]$:

f de classe C^3 ; $f'(a).f'(b) < 0$; $f''(x) > 0$ en tout x (ce qui entraîne la stricte convexité de f) ; $0 \leq 1 - \frac{d}{dx} \left[\frac{f'(x)}{f''(x)} \right] \leq q < 1$ en tout x .

Le *taux de convergence* est alors *quadratique*, en ce sens qu'il existe $\beta > 0$ tel que $\|x^{k+1} - \hat{x}\| \leq \beta \|x^k - \hat{x}\|^2$.

Ces conditions sont très restrictives ; on applique souvent la méthode de Newton dans des cas où elles ne sont pas satisfaites !

1.6.1 Variante : MÉTHODE DE LA SÉCANTE

On peut éviter le calcul de $f''(x^k)$ en le remplaçant par $\frac{f'(x^k) - f'(x^{k-1})}{x^k - x^{k-1}}$ (ce qui revient à approcher la tangente en $(x^k, f'(x^k))$ par une sécante) ; d'où

$$x^{k+1} = x^k - \frac{f'(x^k) \cdot [x^k - x^{k-1}]}{f'(x^k) - f'(x^{k-1})}.$$

Le taux de convergence n'est plus que *super-linéaire*:

$$\frac{\|x^{k+1} - \hat{x}\|}{\|x^k - \hat{x}\|^\tau} \rightarrow \text{limite } (\tau : \text{nombre d'or}).$$

2 OPTIMISATION D'UNE FONCTION DIFFÉRENTIABLE DE n VARIABLES

2.1 GRADIENT

Soit f une fonction à valeurs réelles définie dans un convexe ouvert C de \mathbb{R}^n :

$$f : x = \begin{bmatrix} x_1 \\ \dots \\ x_j \\ \dots \\ x_n \end{bmatrix} \mapsto f(x) = f(x_1, \dots, x_j, \dots, x_n).$$

On dit que f est *différentiable* en $x \in C$ si elle y possède des dérivées partielles $\frac{\partial f(x)}{\partial x_j}$, $j = 1, \dots, n$ et admet pour approximation du 1^{er} ordre la forme linéaire qu'elles définissent :

$$f(x+h) = f(x_1+h_1, \dots, x_j+h_j, \dots, x_n+h_n) = f(x) + \sum_{j=1}^n \frac{\partial f(x)}{\partial x_j} \cdot h_j + o(\|h\|)$$

On appelle *gradient de f en x* le vecteur noté $g(x) = \begin{bmatrix} \frac{\partial f(x)}{\partial x_1} \\ \frac{\partial f(x)}{\partial x_j} \\ \frac{\partial f(x)}{\partial x_n} \end{bmatrix}$ d'où :

$$f(x+h) = f(x) + {}^\tau g(x) \cdot h + o(\|h\|).$$

La variation de f est donc du 2^{eme} ordre lorsque ${}^\tau g(x) \cdot h = 0$.

Lorsque $g(x) \neq 0$, l'ensemble $\{y \mid f(y) = f(x) + {}^\tau g(x) \cdot [y - x]\}$ est, par définition,

l'hyperplan tangent en x à l'hypersurface de niveau $\{z \mid f(z) = f(x)\}$, il a donc $g(x)$ pour vecteur normal ; de plus, puisque

$$f(x + \lambda g(x)) = f(x) + \lambda {}^\tau g(x) \cdot g(x) = f(x) + \lambda \|g(x)\|^2 > f(x) \text{ pour } \lambda > 0,$$

il est dirigé du côté des points où f prend des valeurs plus élevées qu'en x .

Comme l'on cherchera à minimiser f , c'est la direction opposée $\delta = -g(x)$, dite direction de l'*anti-gradient* qui sera intéressante.

2.2 MINIMA ET POINTS STATIONNAIRES

Comme dans le cas $n = 1$, on dit que f passe par un *minimum (global ou absolu)* en \hat{x} lorsque $x \in C \implies f(x) \geq f(\hat{x})$ et que f passe par un *minimum local* en \hat{x} lorsqu'il existe un voisinage V de \hat{x} tel que $x \in V \implies f(x) \geq f(\hat{x})$.

Rappelons qu'un voisinage V de \hat{x} dans C est un sous-ensemble de C contenant une boule ouverte $\{y \mid \|y - \hat{x}\| < \epsilon\}$.

On dit que \hat{x} est un *point stationnaire* de f lorsque $g(\hat{x}) = 0$.

Lemma 4 Une condition nécessaire pour que f , différentiable, passe par un minimum local en \hat{x} est que \hat{x} soit un point stationnaire de f .

Preuve : Par l'absurde : f est différentiable en \hat{x} :

$$f(\hat{x} + h) = f(\hat{x}) + \sum_{j=1}^n \frac{\partial f(\hat{x})}{\partial x_j} \cdot h_j + o(\|h\|)$$

Si $\frac{\partial f(\hat{x})}{\partial x_{j_0}} \neq 0$, prenons h tel que $h_{j_0} = -\lambda \frac{\partial f(\hat{x})}{\partial x_{j_0}}$ ($\lambda > 0$) et $h_j = 0$ pour $j \neq j_0$; d'où

$$f(\hat{x} + h) = f(\hat{x}) - \lambda \left[\frac{\partial f(\hat{x})}{\partial x_{j_0}} \right]^2 + o(|\lambda|)$$

et donc, pour λ assez petit, $f(\hat{x} + h) < f(\hat{x})$. ■

Remarque. Si f est différentiable et convexe,

$$\forall x, \forall h, \quad f(x + h) \geq f(x) + \tau g(x) \cdot h.$$

$g(\hat{x}) = 0$ (\hat{x} stationnaire) est alors aussi condition *suffisante* d'optimalité.

2.3 MÉTHODE DU GRADIENT

Elle exploite la propriété suivante :

Proposition 5 La direction de l'anti-gradient est la direction de plus grande pente, en ce sens que :

$$\text{MAX}_{\{h \mid \|h\| = \|g(x)\|\}} \lim_{\lambda \downarrow 0} \frac{f(x) - f(x + \lambda h)}{\lambda \|h\|}$$

est atteint pour $h = -g(x)$.

Preuve. $f(x) - f(x + \lambda h) = -\lambda \tau g(x) \cdot h + o(\lambda \|h\|)$. D'où, pour $\|h\| = \|g(x)\|$,

$$\frac{f(x) - f(x + \lambda h)}{\lambda \|h\|} = \frac{-\lambda \tau g(x) \cdot h + o(\lambda \|g(x)\|)}{\lambda \|g(x)\|} = \frac{-\tau g(x) \cdot h}{\|g(x)\|} + \frac{o(\lambda)}{\lambda},$$

$$\text{et donc } \lim_{\lambda \downarrow 0} \frac{f(x) - f(x + \lambda h)}{\lambda \|h\|} = \frac{-\tau g(x) \cdot h}{\|g(x)\|},$$

où $-\tau g(x) \cdot h$ est maximum (sous $\|h\| = \|g(x)\|$) pour $h = -g(x)$.

2.3.1 Pas de la méthode du gradient

Les variations de f lorsque l'on part de x dans la direction de l'anti-gradient sont celles de la fonction d'une seule variable $\lambda \geq 0$:

$$\varphi : \lambda \mapsto \varphi(\lambda) = f(x - \lambda g(x)).$$

Cette fonction est dérivable de dérivée :

$$\varphi'(\lambda) = - \sum_{j=1}^n \frac{\partial f}{\partial x_j}(x - \lambda g(x)) \cdot g_j(x) = - \tau g(x - \lambda g(x)) \cdot g(x)$$

Notons en particulier que : $\varphi'(0) = - \tau g(x) \cdot g(x) = - \|g(x)\|^2 < 0$.

ϕ est donc strictement décroissante au voisinage de $\lambda = 0$.

Tant que $\varphi'(\lambda) > 0$, on continue à se déplacer et s'arrête en

$$x^\dagger = x - \lambda^\dagger g(x),$$

où λ^\dagger est la plus petite valeur de λ solution de $\varphi'(\lambda) = 0$ (si elle existe).

2.3.2 Méthode du gradient

Partant d'un point initial x^0 , on répète le pas $x \rightarrow x^\dagger$ précédent :

$$x^k \rightarrow x^{k+1} = (x^k)^\dagger$$

jusqu'à satisfaire un critère d'arrêt, qui peut être, par exemple,

$$\|g(x^k)\| < \epsilon$$

ou

$$|f(x^{k+1}) - f(x^k)| < \epsilon$$

(ce qui dans les deux cas indique que f est proche d'être stationnaire).

Cette méthode a un point faible : il résulte en effet de

$$\varphi'(\lambda^\dagger) = - \tau g(x^\dagger) \cdot g(x) = 0$$

que les gradients en x et x^\dagger sont orthogonaux, donc qu'à chaque pas on prend une direction orthogonale à la direction précédente : le cheminement se fait "en zigzag".

Pour éviter cela et accélérer la convergence, on peut avoir recours à l'un des procédés suivants :

- diminuer le pas, c.-à-d. ne pas aller jusqu'en x^\dagger . Par exemple, effectuer des pas prédéterminés en imposant une suite (λ^k) telle que $\lambda^k \downarrow 0$ et $\sum_k \lambda^k = +\infty$;

- toutes les m itérations, au lieu de partir dans la direction de l'anti-gradient en x^k , "couper" en partant dans la direction $\delta = x^k - x^{k-m}$;

- utiliser des directions "conjuguées" (voir ci-dessous).

Convergence de la méthode du gradient

Si f est continûment différentiable et si il existe c_0 tel que $\{x \mid f(x) < c_0\}$ soit non-vide et borné, alors la méthode du gradient converge vers un point stationnaire.

2.4 MÉTHODE DU GRADIENT CONJUGUÉ

2.4.1 DIRECTIONS CONJUGUÉES PAR RAPPORT À UNE FORME QUADRATIQUE DÉFINIE POSITIVE

Forme quadratique On appelle *forme quadratique définie positive* (de n variables) toute application

$$f : \mathbb{R}^n \rightarrow \mathbb{R} \quad \text{avec} \quad x \mapsto f(x) = \frac{1}{2} {}^\tau x.C.x + {}^\tau p.x$$

avec p $\begin{matrix} (n,1) \end{matrix}$ et où C $\begin{matrix} (n,n) \end{matrix}$ est une matrice *définie positive*, c.-à-d. :

i) C est symétrique : $C = {}^\tau C$ ($c_{jk} = c_{kj}$) ; et ii) ${}^\tau x.C.x > 0$ pour tout $x \neq 0$.

Sous forme développée, $f(x)$ s'écrit donc :

$$\begin{aligned} f(x_1, \dots, x_j, \dots, x_n) &= \frac{1}{2} \left[\sum_{j=1}^n x_j \left[\sum_{k=1}^n c_{jk} x_k \right] \right] + \sum_{j=1}^n p^j x_j \\ &= \frac{1}{2} \sum_{j=1}^n c_{jj} x_j^2 + \sum_{j=1}^n \sum_{k=1}^{j-1} c_{jk} x_j x_k + \sum_{j=1}^n p^j x_j. \end{aligned}$$

Caractérisation : La matrice C est définie positive ssi tous ses déterminants mineurs principaux sont positifs :

$$c_{11} > 0; \det \begin{bmatrix} c_{11} & c_{12} \\ c_{21} & c_{22} \end{bmatrix} > 0; \dots; \det \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1j} \\ c_{21} & c_{22} & \dots & c_{2j} \\ \dots & \dots & \dots & \dots \\ c_{j1} & c_{j2} & \dots & c_{jj} \end{bmatrix} > 0; \dots; \det C > 0.$$

0.

Noter que C est régulière.

Propriétés de f : On vérifie facilement que f est strictement convexe; il en résulte que f a un unique point stationnaire, où elle passe par un minimum global ; ce point est caractérisé par $g(x) = 0$, où $g(x)$ est le gradient de f en x :

$$g(x) = \begin{bmatrix} \frac{\partial f(x)}{\partial x_1} \\ \frac{\partial f(x)}{\partial x_j} \\ \frac{\partial f(x)}{\partial x_n} \end{bmatrix} = \begin{bmatrix} c_{11}x_1 + \sum_{k \neq 1} c_{1k}x_k + p^1 \\ \dots \\ c_{jj}x_j + \sum_{k \neq j} c_{jk}x_k + p^j \\ \dots \\ c_{nn}x_n + \sum_{k \neq n} c_{nk}x_k + p^n \end{bmatrix} = \begin{bmatrix} C_1 \cdot x + p^1 \\ \dots \\ C_j \cdot x + p^j \\ \dots \\ C_n \cdot x + p^n \end{bmatrix}$$

qui s'écrit encore : $g(x) = C \cdot x + p$;

Le point où f atteint son minimum est donc l'unique solution du système linéaire $C \cdot x + p = 0$, c.-à-d. le point : $\hat{x} = -C^{-1} \cdot p$.

La méthode des *directions conjuguées*, que nous allons voir maintenant, peut être considérée, quand on l'applique à une fonction quadratique, comme une méthode itérative de calcul de la solution \hat{x} du système précédent.

2.4.2 Directions conjuguées

Deux vecteurs $x, y \in \mathbb{R}^n \setminus \{0\}$ définissent des *directions conjuguées* par rapport à la forme quadratique f (ou : par rapport à la matrice C) lorsque

$${}^\tau x \cdot C \cdot y = 0 \quad (\iff {}^\tau y \cdot C \cdot x = 0).$$

Une direction donnée a une infinité de directions conjuguées, qui forment un espace vectoriel de dimension $(n - 1)$.

Cas particulier : Le vecteur gradient de f en x étant $g(x) = C \cdot x + p$ et le minimum de f étant atteint en \hat{x} tel que $p = -C \cdot \hat{x}$,

$${}^\tau y \cdot g(x) = {}^\tau y \cdot (C \cdot x + p) = {}^\tau y \cdot C \cdot x + {}^\tau y \cdot p = {}^\tau y \cdot C \cdot (x - \hat{x}).$$

Les directions conjuguées de la direction $(x - \hat{x})$ sont donc les directions orthogonales au gradient en x , c.-à-d. les directions situées dans l'hyperplan tangent en x à l'hypersurface de niveau $\{z \mid f(z) = f(x)\}$.

Exemple 6 $n = 2$; $C = \begin{bmatrix} 1 & \frac{1}{3} \\ \frac{1}{3} & \frac{3}{2} \end{bmatrix}$; $p = \begin{bmatrix} 1 \\ 3 \end{bmatrix}$;

$$f(x) = \frac{1}{2} {}^\tau x \cdot C \cdot x + {}^\tau p \cdot x = \frac{1}{2} [x_1^2 + \frac{3}{2}x_2^2] + \frac{1}{3}x_1x_2 + x_1 + 3x_2.$$

$$g(x) = \begin{bmatrix} x_1 + \frac{1}{3}x_2 + 1 \\ \frac{1}{3}x_1 + \frac{3}{2}x_2 + 3 \end{bmatrix}; \quad C^{-1} = \frac{18}{25} \begin{bmatrix} \frac{3}{2} & -\frac{1}{3} \\ -\frac{1}{3} & 1 \end{bmatrix};$$

$$\hat{x} = -C^{-1} \cdot p = -\frac{18}{25} \begin{bmatrix} \frac{3}{2} & -\frac{1}{3} \\ -\frac{1}{3} & 1 \end{bmatrix} \times \begin{bmatrix} 1 \\ 3 \end{bmatrix} = \begin{bmatrix} -\frac{9}{25} \\ -\frac{16}{25} \end{bmatrix}.$$

Soit $x = \begin{bmatrix} \frac{1}{5} \\ \frac{3}{5} \end{bmatrix}$; $\delta = x - \hat{x} = \begin{bmatrix} \frac{14}{25} \\ \frac{26}{25} \end{bmatrix}$ a pour conjuguée $y = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix}$ telle

$$\text{que : } {}^\tau \delta \cdot C \cdot y = \begin{bmatrix} \frac{14}{25} & \frac{26}{25} \end{bmatrix} \times \begin{bmatrix} y_1 + \frac{1}{3}y_2 \\ \frac{1}{3}y_1 + \frac{3}{2}y_2 \end{bmatrix} = 0 \iff 68y_1 + 131y_2 = 0.$$

2.4.3 Deux Lemmes

La méthode du gradient conjugué s'appuiera sur les deux lemmes suivants :

Lemma 7 *Soit C une matrice définie positive. A partir de n vecteurs linéairement indépendants $y^1, \dots, y^k, \dots, y^n$, on peut toujours construire n vecteurs $\delta^1, \dots, \delta^k, \dots, \delta^n$ également linéairement indépendants et, de plus, conjugués deux à deux, donnés par les formules :*

$$\begin{aligned} \delta^1 &= y^1; \\ \delta^2 &= y^2 - \left(\frac{\tau y^2 \cdot C \cdot \delta^1}{\tau \delta^1 \cdot C \cdot \delta^1} \right) \delta^1; \\ &\dots \\ \delta^k &= y^k - \sum_{l=1}^{k-1} \left(\frac{\tau y^k \cdot C \cdot \delta^l}{\tau \delta^l \cdot C \cdot \delta^l} \right) \delta^l \\ &\dots \end{aligned}$$

Preuve. L'indépendance linéaire des δ^k se déduit de ce que les y^k , pouvant eux-même s'exprimer (d'après les formules) comme combinaisons linéaires des δ^k , ne pourraient être linéairement indépendants si ceux-ci ne l'étaient pas.

En particulier, pour tout l , $\delta^l \neq 0$ d'où, C étant définie positive, $\tau \delta^l \cdot C \cdot \delta^l > 0$.

La vérification des conjugaisons se fait directement et par récurrence. ■

Lemma 8 *Soit f forme quadratique définie positive :*

$$f(x) = \frac{1}{2} \tau x \cdot C \cdot x + \tau p \cdot x.$$

Etant donné un point quelconque x^0 et n vecteurs $\delta^1, \dots, \delta^k, \dots, \delta^n$, linéairement indépendants et conjugués deux à deux, le minimum de f est atteint en

$$\hat{x} = x^0 + \sum_{k=1}^n \hat{\lambda}_k \delta^k,$$

où, pour tout k , $\hat{\lambda}_k = -\frac{\tau g(x^0) \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k}$ et minimise $\varphi_k(\lambda_k) = f(x^0 + \lambda_k \delta^k)$.

$\hat{\lambda}_k$ minimise également $\psi_k(\lambda_k) = f(x^{k-1} + \lambda_k \delta^k)$, où $x^{k-1} = x^0 + \sum_{l=1}^{k-1} \lambda_l \delta^l$,

et s'exprime aussi comme $\hat{\lambda}_k = -\frac{\tau g(x^{k-1}) \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k}$.

Preuve. Les δ^k étant linéairement indépendants, pour tout $x \in \mathbb{R}^n$ il existe des λ_k uniques tels que $x - x^0 = \sum_{k=1}^n \lambda_k \delta^k$.

Minimiser f dans \mathbb{R}^n est donc équivalent à minimiser, dans \mathbb{R}^n également, la fonction de n variables

$$F(\lambda_1, \dots, \lambda_k, \dots, \lambda_n) = f(x^0 + \sum_{k=1}^n \lambda_k \delta^k).$$

Mais par développement et réduction (on sait que $\tau \delta^k \cdot C \cdot \delta^l = 0$ pour $l \neq k$),

$$\begin{aligned} f(x^0 + \sum_{k=1}^n \lambda_k \delta^k) &= \frac{1}{2} \tau (x^0 + \sum_{k=1}^n \lambda_k \delta^k) \cdot C \cdot (x^0 + \sum_{k=1}^n \lambda_k \delta^k) + \\ \tau p \cdot (x^0 + \sum_{k=1}^n \lambda_k \delta^k) &= f(x^0) + \sum_{k=1}^n \left[\frac{1}{2} \lambda_k^2 \tau \delta^k \cdot C \cdot \delta^k + \lambda_k (\tau x^0 \cdot C + \tau p) \delta^k \right]. \end{aligned}$$

En particulier, en prenant $\lambda_k = 0$ pour tous les k sauf un, on voit que :

$$\frac{1}{2}\lambda_k^2 \tau \delta^k \cdot C \cdot \delta^k + \lambda_k (\tau x^0 \cdot C + p) \delta^k = f(x^0 + \lambda_k \delta^k) - f(x^0)$$

d'où

$$F(\lambda_1, \dots, \lambda_k, \dots, \lambda_n) = f(x^0 + \sum_{k=1}^n \lambda_k \delta^k) = f(x^0) + \sum_{k=1}^n [f(x^0 + \lambda_k \delta^k) - f(x^0)].$$

Le minimum de F s'obtient donc en minimisant indépendamment chacun des termes entre crochets par rapport à l'unique variable dont il dépend.

Le minimum de

$$f(x^{k-1} + \lambda_k \delta^k) - f(x^{k-1}) = \frac{1}{2}\lambda_k^2 \tau \delta^k \cdot C \cdot \delta^k + \lambda_k (\tau x^{k-1} \cdot C + \tau p) \cdot \delta^k,$$

polynôme du second degré en λ_k , est atteint en

$$\hat{\lambda}_k = -\frac{(\tau x^{k-1} \cdot C + \tau p) \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k} = -\frac{\tau g(x^{k-1}) \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k}.$$

De même

$$f(x^{k-1} + \lambda_k \delta^k) - f(x^{k-1}) = \frac{1}{2}\lambda_k^2 \tau \delta^k \cdot C \cdot \delta^k + \lambda_k (\tau x^{k-1} \cdot C + \tau p) \cdot \delta^k.$$

Or, puisque $\tau \delta^k \cdot C \cdot \delta^l = 0$ pour $l \neq k$,

$$\tau x^{k-1} \cdot C \cdot \delta^k = \tau (x^0 + \sum_{l=1}^{k-1} \lambda_l \delta^l) \cdot C \cdot \delta^k = \tau x^0 \cdot C \cdot \delta^k,$$

d'où

$$\tau g(x^{k-1}) \cdot \delta^k = [\tau x^{k-1} \cdot C + \tau p] \cdot \delta^k = [\tau x^0 \cdot C + \tau p] \cdot \delta^k = \tau g(x^0) \cdot \delta^k$$

et aussi

$f(x^{k-1} + \lambda_k \delta^k) - f(x^{k-1}) = f(x^0 + \lambda_k \delta^k) - f(x^0)$, ce qui montre que $\varphi_k(\lambda_k)$ et $\psi_k(\lambda_k)$ ont leur minimum au même point $\hat{\lambda}_k$. ■

2.4.4 Méthode du Gradient conjugué pour les fonctions quadratiques

Initialisation. Choix de x^0 , point initial et d'une direction $\delta^1 = -g(x^0)$.

k^{ème} étape.

Calcul de $\hat{\lambda}_k$ minimisant $\varphi_k(\lambda_k) = f(x^{k-1} + \lambda_k \delta^k)$:

$$\hat{\lambda}_k = -\frac{\tau g(x^{k-1}) \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k} = \frac{\tau g(x^{k-1}) \cdot g(x^{k-1})}{\tau \delta^k \cdot C \cdot \delta^k}.$$

$x^k = x^{k-1} + \hat{\lambda}_k \delta^k$. Calcul de $g(x^k)$.

si $g(x^k) = 0$, x^k est optimal **fin**; sinon

$$\delta^{k+1} = -g(x^k) + \beta^k \cdot \delta^k, \text{ avec } \beta^k = \frac{\tau g(x^k) \cdot C \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k} = \frac{\tau g(x^k) \cdot g(x^k)}{\tau g(x^{k-1}) \cdot g(x^{k-1})}.$$

$k \leftarrow k + 1$.

Proposition 9 *La méthode du gradient conjugué pour les fonctions quadratiques atteint le minimum en n itérations.*

Preuve. i) Posons $y^k = -g(x^{k-1})$, $k = 1, \dots, n$ et montrons que les $(y^k)_{1 \leq k \leq n}$ sont linéairement indépendants.

Un calcul semblable à celui fait dans la preuve du lemme 8 montre que $F_k(\lambda_1, \dots, \lambda_k) = f(x^0 + \sum_{l=1}^k \lambda_l \delta^l) = f(x^0) + \sum_{l=1}^k [f(x^0 + \lambda_l \delta^l) - f(x^0)]$ et donc que $F_k(\lambda_1, \dots, \lambda_k)$ a pour minimum $F_k(\hat{\lambda}_1, \dots, \hat{\lambda}_k) = f(x^k)$ et que $\frac{\partial F_k(\hat{\lambda}_1, \dots, \hat{\lambda}_k)}{\partial \lambda_l} = 0$, pour tout $l = 1, \dots, k$. Or, $\frac{\partial F_k(\hat{\lambda}_1, \dots, \hat{\lambda}_k)}{\partial \lambda_l} = \tau g(x^k) \cdot \delta^l$; $y^{k+1} = -g(x^k)$ est donc orthogonal à tous les $(\delta^l)_{l \leq k}$, donc à l'e.v. qu'ils engendrent, qui est aussi (même raison qu'au lemme ci-dessus) l'e.v. engendré par les $(y^l)_{1 \leq l \leq k} = [-g(x^{l-1})]_{1 \leq l \leq k}$. Si ceux-ci sont linéairement indépendants, les $(y^l)_{1 \leq l \leq k+1}$ le sont donc aussi ; par récurrence, ce sera vrai pour tous les $(y^k)_{1 \leq k \leq n}$.

ii) Vérifions que les $(\delta^k)_{1 \leq k \leq n}$ sont bien reliés aux $(y^k)_{1 \leq k \leq n}$ par les relations du lemme 7. De ce que $y^{k+1} = \delta^{k+1} - \frac{\tau g(x^k) \cdot C \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k} \cdot \delta^k$ et que les δ^k sont conjugués, il résulte que $\tau y^{k+1} \cdot C \cdot \delta^l = 0$ pour $l < k$. D'où

$$\begin{aligned} \delta^{k+1} &= y^{k+1} - \sum_{l=1}^k \left(\frac{\tau y^{k+1} \cdot C \cdot \delta^l}{\tau \delta^l \cdot C \cdot \delta^l} \right) \delta^l = y^{k+1} - \left(\frac{\tau y^{k+1} \cdot C \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k} \right) \delta^k \\ &= -g(x^k) + \frac{\tau g(x^k) \cdot C \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k} \cdot \delta^k. \end{aligned}$$

iii) Enfin $\hat{\lambda}_k = -\frac{\tau g(x^{k-1}) \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k}$ a bien l'une des expressions données au lemme 9.

On obtiendra donc $x^n = \hat{x}$.

iv) Montrons enfin la validité des secondes expressions de $\hat{\lambda}_k$ et β^k .

De ce que δ^k est la différence entre $y^k = -g(x^{k-1})$ et une c.l. de divers $y^l = -g(x^{l-1})$ tous orthogonaux à celui-ci, il résulte que

$$\tau g(x^{k-1}) \cdot \delta^k = \tau g(x^{k-1}) \cdot g(x^{k-1})$$

$$\text{d'où} \quad \hat{\lambda}_k = -\frac{\tau g(x^{k-1}) \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k} = \frac{\tau g(x^{k-1}) \cdot g(x^{k-1})}{\tau \delta^k \cdot C \cdot \delta^k}$$

D'autre part $\hat{\lambda}_k \cdot \delta^k = x^k - x^{k-1}$, d'où

$$C \cdot \delta^k = \frac{1}{\hat{\lambda}_k} C \cdot [x^k - x^{k-1}] = \frac{1}{\hat{\lambda}_k} [g(x^k) - g(x^{k-1})]$$

et

$$\tau g(x^k) \cdot C \cdot \delta^k = \frac{1}{\hat{\lambda}_k} \tau g(x^k) \cdot [g(x^k) - g(x^{k-1})] = \frac{1}{\hat{\lambda}_k} \tau g(x^k) \cdot g(x^k)$$

et donc

$$\beta^k = \frac{\tau g(x^k) \cdot C \cdot \delta^k}{\tau \delta^k \cdot C \cdot \delta^k} = \frac{\tau g(x^k) \cdot g(x^k)}{\tau g(x^{k-1}) \cdot g(x^{k-1})}. \blacksquare$$

2.4.5 Méthode du Gradient conjugué pour les fonctions quelconques

Fletcher et Reeves ont adapté l'algorithme précédent à une fonction différentiable quelconque:

Initialisation. Choix de x^0 , point initial et d'une direction $\delta^1 = -g(x^0)$

k^{eme} étape.

Calcul de $\hat{\lambda}_k$ minimisant $\varphi_k(\lambda_k) = f(x^{k-1} + \lambda_k \delta^k)$:

$x^k = x^{k-1} + \hat{\lambda}_k \delta^k$. Calcul de $g(x^k)$.

si $\|g(x^k)\| < \varepsilon$ **fin**;

sinon

$\delta^{k+1} = -g(x^k) + \beta^k \cdot \delta^k$, avec $\beta^k = \frac{\tau g(x^k) \cdot g(x^k)}{\tau g(x^{k-1}) \cdot g(x^{k-1})}$.

$k \leftarrow k + 1$.

3 OPTIMISATION SOUS CONTRAINTES

On appelle *programme différentiable* tout problème d'optimisation sous contraintes de la forme :

$$PDif \quad \left| \begin{array}{l} MIN f(x) \\ a_i(x) \leq 0, \quad i = 1, \dots, m \end{array} \right.$$

où f et les a_i sont des fonctions différentiables de n variables.

On notera respectivement $\frac{\partial f(x)}{\partial x}$ et $\frac{\partial a_i(x)}{\partial x}$ les transposés des vecteurs-gradients en x de f et des a_i :

$$\frac{\partial f(x)}{\partial x} = \left[\frac{\partial f(x)}{\partial x_1}, \dots, \frac{\partial f(x)}{\partial x_j}, \dots, \frac{\partial f(x)}{\partial x_n} \right];$$

$$\frac{\partial a_i(x)}{\partial x} = \left[\frac{\partial a_i(x)}{\partial x_1}, \dots, \frac{\partial a_i(x)}{\partial x_j}, \dots, \frac{\partial a_i(x)}{\partial x_n} \right] \quad (i = 1, \dots, m).$$

x est *solution réalisable* de *PDif* lorsque toutes les contraintes

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

sont satisfaites.

La i^{eme} contrainte est *serrée* en x lorsque $a_i(x) = 0$.

Soit x , réalisable et soit S l'ensemble des contraintes serrées en x . On dit que la *condition de qualification des contraintes* est satisfaite en x s'il existe une direction δ (c-à-d $\delta \in \mathbb{R}^n$ et $\delta \neq 0$) telle que :

$$\frac{\partial a_i(x)}{\partial x} \cdot \delta < 0 \quad \text{pour tout } i \in S.$$

Cette propriété implique que l'on peut s'éloigner de x dans la direction δ sans sortir immédiatement du domaine des réalisables (cf la preuve du lemme ci-dessous).

En x^* la condition de qualification n'est pas vérifiée

Lemma 10 Si \hat{x} est solution optimale de PDif alors il n'existe pas de vecteur δ de \mathbb{R}^n solution du système : $S1 \left| \begin{array}{l} \frac{\partial a_i(\hat{x})}{\partial x} \cdot \delta < 0, \quad i \in S \\ \frac{\partial f(\hat{x})}{\partial x} \cdot \delta < 0 \end{array} \right.$, où S désigne l'ensemble des contraintes serrées en \hat{x} .

Preuve. Par l'absurde. Soit δ solution de S1. De la différentiabilité des fonctions a_i et f , il résulte que :

$$a_i(\hat{x} + \lambda\delta) = a_i(\hat{x}) + \lambda \frac{\partial a_i(\hat{x})}{\partial x} \delta + o(\lambda), \quad i = 1, \dots, m$$

et

$$f(\hat{x} + \lambda\delta) = f(\hat{x}) + \lambda \frac{\partial f(\hat{x})}{\partial x} \delta + o(\lambda)$$

d'où l'on déduit que pour $\lambda > 0$ assez petit

$$a_i(\hat{x} + \lambda\delta) < 0, \quad \text{pour } i \in S \text{ comme pour } i \notin S,$$

et

$$f(\hat{x} + \lambda\delta) < f(\hat{x})$$

ce qui contredit l'optimalité de \hat{x} . ■

Lemma 11 (Théorème de FRITZ-JOHN) Si \hat{x} est solution optimale de PDif alors il existe un vecteur $v = [v^0, v^1, \dots, v^i, \dots, v^m]$ solution du système

$$S2 \left\{ \begin{array}{l} v \geq 0 \text{ avec } [v^0, v^S] > 0 \quad (1) \\ v^0 \frac{\partial f(\hat{x})}{\partial x} + \sum_{i=1}^m v^i \frac{\partial a_i(\hat{x})}{\partial x} = 0 \quad (2) \\ v^i a_i(\hat{x}) = 0 \quad \forall i = 1, \dots, m \quad (3) \end{array} \right.$$

Preuve. Par l'absurde. Si S2 n'a pas de solution, le système

$S'2 \left\{ \begin{array}{l} [v^0, v^S] > 0 \quad (1') \\ v^0 \frac{\partial f(\hat{x})}{\partial x} + \sum_{i \in S} v^i \frac{\partial a_i(\hat{x})}{\partial x} = 0 \quad (2') \end{array} \right.$ n'en a pas non plus (il suffirait de compléter une solution par $v^i = 0, i \notin S$, pour obtenir une solution de S2).

$$\text{Introduisant la matrice } A = \left[\begin{array}{cccccc} \tau \frac{\partial f(\hat{x})}{\partial x} & \tau \frac{\partial a_1(\hat{x})}{\partial x} & \dots & \tau \frac{\partial a_i(\hat{x})}{\partial x} & \dots & \tau \frac{\partial a_m(\hat{x})}{\partial x} \end{array} \right]$$

$$\text{et les vecteurs } c = [-1 \quad -1 \quad \dots \quad -1 \quad \dots \quad -1] \text{ et } x = \tau [v^0, v^S],$$

ceci équivaut à affirmer que :

il n'existe pas $x \geq 0$ tel que $c \cdot x < 0$ et que $A \cdot x = 0$.

Le théorème de l'alternative nous dit qu'alors :

il existe u tel que $u \cdot A \leq c$.

Posant $\delta = \tau u$, ceci s'écrit encore :

$$\left| \begin{array}{l} \frac{\partial f(\hat{x})}{\partial x} \cdot \delta < 0 \\ \frac{\partial a_i(\hat{x})}{\partial x} \cdot \delta < 0, \quad i \in S \end{array} \right. \quad , \text{ ce qui n'est autre que S1.}$$

Par le lemme précédent, sa compatibilité contredit l'optimalité de \hat{x} . ■

Theorem 12 (Conditions de KUHN et TUCKER). Des conditions nécessaires pour que \hat{x} , solution réalisable de PDif où la condition de qualification des contraintes est satisfaite, soit solution optimale de PDif sont qu'il existe un vecteur $\hat{u} = [\hat{u}^1, \dots, \hat{u}^i, \dots, \hat{u}^m]$ (les multiplicateurs de LAGRANGE) tel que

$$\left\{ \begin{array}{l} \hat{u} \geq 0 \quad (1) \\ \frac{\partial f(\hat{x})}{\partial x} + \sum_{i=1}^m \hat{u}^i \frac{\partial a_i(\hat{x})}{\partial x} = 0 \quad (2) \\ \hat{u}^i a_i(\hat{x}) = 0 \quad \forall i = 1, \dots, m \quad (3) \end{array} \right.$$

Preuve. Montrons d'abord, par l'absurde, que toute solution $v \geq 0$ de S2 du lemme précédent satisfait $v^0 > 0$.

Si $v^0 = 0$, v^S est solution du système

$$\left\{ \begin{array}{l} v^S > 0 \quad (1'') \\ \sum_{i \in S} v^i \frac{\partial a_i(\hat{x})}{\partial x} = 0 \quad (2'') \end{array} \right.$$

ce qui entraîne, par le théorème de l'alternative

$$\left(\begin{array}{l} \text{(introduire : } A = \left[\begin{array}{cccc} \tau \frac{\partial a_1(\hat{x})}{\partial x} & \dots & \tau \frac{\partial a_i(\hat{x})}{\partial x} & \dots & \tau \frac{\partial a_m(\hat{x})}{\partial x} \end{array} \right], \\ c = \left[\begin{array}{cccc} -1 & \dots & -1 & \dots & -1 \end{array} \right] \text{ et } x = \tau v^S) \end{array} \right.$$

l'incompatibilité du système :

$$\left| \frac{\partial a_i(\hat{x})}{\partial x} \cdot \delta < 0, \quad i \in S, \right.$$

contredisant l'hypothèse de qualification des contraintes en \hat{x} .

On obtient donc le vecteur \hat{u} cherché en prenant

$$\hat{u}^i = \frac{v^i}{v^0} \text{ pour tout } i = 1, \dots, m. \blacksquare$$

Les conditions de Kuhn et Tucker sont de plus des conditions *suffisantes* d'optimalité lorsque f et les a_i possèdent certaines propriétés de convexité ; plus précisément, il suffit que f soit *pseudo-convexe*, c-à-d que :

$$\begin{aligned} f(x) < f(y) &\implies \frac{\partial f(y)}{\partial x} \cdot (x - y) < 0 \\ \text{et que les } a_i \text{ soient } &\textit{quasi-convexes} \text{ c-à-d que :} \\ a_i(x) \leq a_i(y) &\implies \frac{\partial a_i(y)}{\partial x} \cdot (x - y) \leq 0. \end{aligned}$$

Theorem 13 (Suffisance des conditions de KUHN et TUCKER). Supposons f pseudo-convexe et les a_i quasi-convexes. Alors, des conditions suffisantes pour que \hat{x} , solution réalisable de PDif, en soit solution optimale sont qu'il existe un vecteur $\hat{u} = [\hat{u}^1, \dots, \hat{u}^i, \dots, \hat{u}^m]$ tel que

$$\left\{ \begin{array}{l} \hat{u} \geq 0 \quad (1) \\ \frac{\partial f(\hat{x})}{\partial x} + \sum_{i=1}^m \hat{u}^i \frac{\partial a_i(\hat{x})}{\partial x} = 0 \quad (2) \\ \hat{u}^i a_i(\hat{x}) = 0 \quad \forall i = 1, \dots, m \quad (3) \end{array} \right.$$

Preuve. Soit x réalisable.; a_i étant quasi-convexe, pour $i \in S$, on déduit de $a_i(x) \leq 0 = a_i(\hat{x})$ que $\frac{\partial a_i(\hat{x})}{\partial x} \cdot (x - \hat{x}) \leq 0$; d'où, utilisant le fait que $u^i = 0$ pour $i \notin S$,

$$\begin{aligned}
\frac{\partial f(\hat{x})}{\partial x} \cdot (x - \hat{x}) &= - \left[\sum_{i=1}^m \hat{u}^i \frac{\partial a_i(\hat{x})}{\partial x} \right] \cdot (x - \hat{x}) = - \left[\sum_{i \in S} \hat{u}^i \frac{\partial a_i(\hat{x})}{\partial x} \right] \cdot (x - \hat{x}) \\
&= - \sum_{i \in S} \hat{u}^i \left[\frac{\partial a_i(\hat{x})}{\partial x} \cdot (x - \hat{x}) \right] \geq 0.
\end{aligned}$$

Comme f est pseudo-convexe, on a nécessairement $f(x) \geq f(\hat{x})$. ■