



UNIVERSITÉ DE FRIBOURG SUISSE
UNIVERSITÄT FREIBURG SCHWEIZ

Otimisation numérique 3

Méthode de recherche par ligne
(chapitre 3.3 et 3.4 du livre)

Chiara PICCIOLI

Proséminaire
15 Octobre 2009

Table des matières

1	Taux de convergence	3
1.1	Introduction	3
1.2	Taux de convergence de la plus grande pente	3
1.3	Méthode quasi-Newton	5
1.4	Méthode de Newton	6
1.5	Méthode de descente coordonnée par coordonnée	8
2	Algorithme pour le choix de la longueur du pas	8
2.1	Interpolation	9
2.2	La longueur du pas initial	10
2.3	Algorithme de recherche pour la condition de Wolfe	10

1 Taux de convergence

1.1 Introduction

DÉFINITION 1. Un algorithme *converge globalement* ssi $\lim_{n \rightarrow \infty} \|\nabla f(x_k)\| = 0$.

Soit $\cos \Phi_k = \frac{-\nabla f_k^T p_k}{\|\nabla f_k\| \|p_k\|}$. Par la condition de Zoutendijk, pour la convergence globale, on doit avoir $\cos^2 \Phi_k \|\nabla f_k\| \rightarrow 0$ pour $k \rightarrow \infty$. À partir de cette conclusion, définir des algorithmes avec des bonnes propriétés de convergence peut paraître simple, car tout ce qu'il faut c'est d'assurer que p_k ne devient pas orthogonale à ∇f_k .

On peut donc simplement calculer $\cos \phi_k$ à chaque itération et tourner p_k vers la direction de la plus grande pente si \cos est plus petit qu'une certaine constante $\delta > 0$. Un test de ce genre assure une convergence globale, mais il n'est pas recommandé pour deux raisons :

1. il empêche une convergence rapide
2. les tests sur les angles détruisent les propriétés invariables des méthodes quasi-Newton.

Le but est donc de construire des algorithmes qui ont une bonne convergence globale et un bon taux de convergence. On commence notre étude sur les taux de convergence avec des méthodes de recherche linéaires : la méthode de la plus grande pente.

1.2 Taux de convergence de la plus grande pente

On considère le cas idéal où la fonction est quadratique et les lignes de recherche sont exactes. On suppose que

$$f(x) = \frac{1}{2}x^T Qx - b^T x \quad (1)$$

où Q est symétrique et positive. Le gradient est donné par $\nabla f(x) = Qx - b$ et x^* est la seule solution de $\nabla f(x) = 0$. On veut maintenant trouver la longueur du pas α_k qui minimise $f(x_k - \alpha \nabla f_k)$, simplement en dérivant cette dernière par rapport à α . On obtient donc

$$\alpha_k = \frac{\nabla f_k^T \nabla f_k}{\nabla f_k^T Q \nabla f_k} \quad (2)$$

En utilisant α_k , l'itération de la plus grande pente est donnée par

$$x_{k+1} = x_k - \frac{\nabla f_k^T \nabla f_k}{\nabla f_k^T Q \nabla f_k} \nabla f_k \quad (3)$$

Ce qu'on veut faire maintenant, c'est de quantifier le taux de convergence. Pour faire

ceci on a besoin de la norme $\|x\|_Q^2 = x^T Q x$. À l'aide de l'équation $Qx^* = b$ on peut tout simplement montrer que

$$\frac{1}{2}\|x - x^*\|_Q^2 = f(x) - f(x^*) \quad (4)$$

Cette norme mesure donc la différence qu'il y a entre la valeur courante de f et la valeur optimale. En utilisant la formule (3) et le fait que $\nabla f_k = Q(x_k - x^*)$, on peut dériver l'égalité

$$\|x_{k+1} - x^*\|_Q^2 = \left\{1 - \frac{(\nabla f_k^T \nabla f_k)^2}{(\nabla f_k^T Q \nabla f_k)(\nabla f_k^T Q^{-1} \nabla f_k)}\right\} \|x_k - x^*\|_Q^2 \quad (5)$$

Cette expression est intéressante pour voir l'exacte diminution de f à chaque itération, mais on peut bien s'imaginer que la parantèse est difficile à interpréter. Pour cette raison, il est mieux de se référer en termes de nombre de condition du problème.

THÉORÈME 1. *Si la méthode de la plus grande pente avec des lignes de recherche exactes (3) est appliquée à la fonction quadratique convexe (1) la norme de l'erreur satisfait*

$$\|x_{k+1} - x^*\|_Q^2 \leq \left(\frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1}\right)^2 \|x_k - x^*\|_Q^2 \quad (6)$$

avec $0 < \lambda_1 \leq \dots \leq \lambda_n$ qui sont les valeurs propres de Q .

On peut donc voir par cette inégalité et par la formule précédente (4) que les valeurs de f_k convergent linéairement vers f^* .

Si on prends le cas spécial où les valeurs propres sont tous les mêmes, on aura que Q est un multiple de la matrice identité et donc les lignes de niveau de $f(x)$ ne sont plus des ellipses mais des cercles, et de plus la direction de la plus grande pente converge vers la solution

THÉORÈME 2. *On suppose que $f : \mathbb{R}^n \rightarrow \mathbb{R}$ soit deux fois continuellement différentiable et que les itérés générés par la méthode de la plus grande pente avec des recherches linéaires exactes convergent vers x^* , où $\nabla^2 f(x^*)$ est définie positif. Soit r un scalaire qui satisfait la condition $r \in (\frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1}, 1)$ où $\lambda_1 \leq \dots \leq \lambda_n$ sont des valeurs propres de $\nabla^2 f(x^*)$. Alors pour chaque k suffisamment grand, on a*

$$f(x_{k+1}) - f(x^*) \leq r^2 [f(x_k) - f(x^*)].$$

En général on ne peut pas s'attendre que le taux de convergence devient meilleur si on utilise une recherche linéaire inexacte. Ce théorème montre donc que la méthode de la plus grande pente peut avoir un taux de convergence trop bas, même quand $\nabla^2 f(x^*)$ est bien conditionné.

Exemple 1. Si $k(Q) = 800$, $f(x_1) = 1$, et $f(x^*) = 0$ alors on aura que la valeurs de la fonction sera environ 0.08 après 1000 itération de la méthode de la plus grande pente.

1.3 Méthode quasi-Newton

On doit tout d'abord supposer que

$$p_k = -B_k^{-1}\nabla f_k \quad (7)$$

où B_k est une matrice symétrique positive. On suppose de plus que le pas de longueur α_k est calculé depuis une ligne de recherche inexacte qui satisfait la condition de Wolfe, avec une particularité : la recherche linéaire de l'algorithme essaye toujours d'abord avec $\alpha_k = 1$ et acceptera cette valeur de α_k , si elle satisfait les conditions de Wolfe. Ceci est naturellement fait pour augmenter le taux de convergence. Le résultat suivant nous montre que si la direction de recherche d'une méthode quasi-Newton satisfait la direction de Newton, alors la longueur du pas $\alpha_k = 1$ satisfait la condition de Wolfe quand les itérés convergent vers la solution.

THÉORÈME 3. *Soit $f : \mathbb{R}^n \rightarrow \mathbb{R}$ 2 fois continûment différentiable. On considère l'itération $x_{k+1} = x_k + \alpha_k p_k$, où p_k est la direction de pente et α_k satisfait la condition de Wolfe avec $c_1 \leq \frac{1}{2}$. Si la suite $\{x_k\}$ converge vers x^* , tel que $\nabla f(x^*) = 0$ et que $\nabla^2 f(x^*)$ soit défini positif, et si*

$$\lim_{k \rightarrow \infty} \frac{\|\nabla f_k + \nabla^2 f_k p_k\|}{\|p_k\|} = 0, \quad (8)$$

alors :

1. il existe k_0 tel que $\alpha_k = 1$ est acceptable pour chaque $k > k_0$
2. si $\alpha_k = 1 \forall k > k_0$, $\{x_k\}$ converge superlinéairement vers x^* .

On peut constater que si p_k est une direction de recherche de quasi-Newton de la forme (7), alors (8) se laisse écrire comme

$$\lim_{k \rightarrow \infty} \frac{\|(B_k + \nabla^2 f(x^*))p_k\|}{\|p_k\|} = 0 \quad (9)$$

Ce pas est très importante parce que nous permet de voir que si B_k ne converge pas vers $\nabla^2 f(x^*)$, une convergence superlinéaire peut arriver comme même ; il faut seulement que les B_k deviennent des bonnes approximations de $\nabla^2 f(x^*)$ dans la direction de p_k .

THÉORÈME 4. *Supposons que $f : \mathbb{R}^n \rightarrow \mathbb{R}$ 2 fois continument différentiable. On considère l'itération $x_{k+1} = x_k + p_k$ (donc la longueur du pas est toujours 1) et que p_k est donné par $p_k = -B_k^{-1}\nabla f_k$. On suppose même que $\{x_k\}$ converge vers un point x^* tel que $\nabla f(x^*) = 0$ et $\nabla^2 f(x^*)$ est défini positif. Alors $\{x_k\}$ converge superlinéairement si et seulement si (9) est vrai.*

Démonstration. On doit montrer tout d'abord que (9) est égal à

$$p_k - p_k^N = o(\|p_k\|)$$

où $p_k^N = -\nabla^2 f_k^{-1} \nabla f_k$ est le pas de Newton. Donc,

$$\begin{aligned} p_k - p_k^N &= \nabla^2 f_k^{-1} (\nabla^2 f_k p_k + \nabla f_k) \\ &= \nabla^2 f_k^{-1} (\nabla^2 f_k - B_k) p_k \\ &= O(\|(\nabla^2 f_k - B_k) p_k\|) \\ &= o(\|p_k\|) \end{aligned}$$

Ici on a utilisé le fait que $\|\nabla^2 f_k^{-1}\|$ est borné pour des x_k suffisamment proches de x^* , parce que l'Hessien $\nabla^2 f(x^*)$ est défini positif. L'inverse existe si on multiplie par $\nabla^2 f_k$ les deux cotés de $p_k - p_k^N = o(\|p_k\|)$. Pour la suite de la preuve on doit regarder la preuve du théorème 5, et en particulier on doit utiliser l'inégalité

$$\|x_k + p_k^N - x^*\| \leq L \|\nabla^2 f(x^*)^{-1}\| \|x_k - x^*\|^2 = \tilde{L} \|x_k - x^*\|^2.$$

A l'aide de $p_k - p_k^N = o(\|p_k\|)$.

On obtient donc que

$$\|x_k + p_k - x^*\| \leq \|x_k + p_k^N - x^*\| + \|p_k - p_k^N\| = O(\|x_k - x^*\|^2) + o(\|p_k\|)$$

Avec une simple manipulation de cette inégalité on obtient que $\|p_k\| = O(\|x_k - x^*\|)$, et donc on obtient que

$$\|x_k + p_k - x^*\| \leq o(\|x_k - x^*\|)$$

qui donne le résultat de convergence superlinéaire. □

1.4 Méthode de Newton

Dans ce cas on considère l'itération de Newton, où

$$p_k^N = -\nabla^2 f_k^{-1} \nabla f_k \tag{10}$$

À cause du fait que $\nabla^2 f_k$ peut ne pas être défini positif, p_k^N n'est pas nécessairement une direction de descente. Le théorème 3 ne pourra donc pas être appliquée aux idées vues dans ce chapitre.

Maintenant on veut discuter les propriétés des taux de convergence locales. Supposons que $\nabla^2 f(x)$ soit lipschitzien autour de x^* . Le $\nabla^2 f(x)$ est alors défini positif dans un voisinage de x^* et donc la méthode de Newton sera donc bien définie dans cette région et convergera quadratiquement à condition que le pas de longueur α_k soit toujours 1.

THÉORÈME 5. *On suppose que f soit 2 fois continûment différentiable et que $\nabla^2 f(x)$ est lipschitzienne et continue dans les environs de la solution x^* dans laquelle les conditions suffisantes (Thm 2.4 du livre) sont satisfaites. On considère l'itération $x_{k+1} = x_k + p_k^N$ où p_k^N est donné par (10). Alors*

1. *si le point de départ x_0 est suffisamment proche de la solution, $\{x_k\}$ converge vers x^**
2. *le taux de convergence de $\{x_k\}$ est quadratique*
3. *$\{\|\nabla f_k\|\}$ converge quadratiquement vers 0.*

Démonstration. A partir de la définition du pas de Newton et la condition d'optimalité $\nabla f_* = 0$ on a que

$$\begin{aligned} x_k + p_k^N - x^* &= x_k - x^* - \nabla^2 f_k^{-1} \nabla f_k \\ &= \nabla^2 f_k^{-1} [\nabla^2 f_k (x_k - x^*) - (\nabla f_k - \nabla f_*)] \end{aligned}$$

Car

$$\nabla f_k - \nabla f_* = \int_0^1 \nabla^2 f(x_k + t(x^* - x_k))(x_k - x^*) dt$$

on a

$$\begin{aligned} \|\nabla^2 f(x_k)(x_k - x^*) - (\nabla f_k - \nabla f(x^*))\| &= \left\| \int_0^1 [\nabla^2 f(x_k) - \nabla^2 f(x_k + t(x^* - x_k))](x_k - x^*) dt \right\| \\ &\leq \int_0^1 \|\nabla^2 f(x_k) - \nabla^2 f(x_k + t(x^* - x_k))\| \cdot \|x_k - x^*\| dt \\ &\leq \|x_k - x^*\|^2 \int_0^1 L dt \\ &= \frac{1}{2} L \|x_k - x^*\|^2, \end{aligned}$$

où L est une constant de Lipschitz pour $\nabla^2 f(x)$ pour x proche de x^* . A cause du fait que $\nabla^2 f(x^*)$ est non singulière, il existe un rayon $r > 0$ tel que $[\nabla^2 f_k]^{-1}$ existe et que $\|\nabla^2 f_k^{-1}\| \leq 2\|\nabla^2 f(x^*)^{-1}\|$ pour tout x_k avec $\|x_k - x^*\| \leq r$. On obtient

$$\|x_k + p_k^N - x^*\| \leq L \|\nabla^2 f(x^*)^{-1}\| \cdot \|x_k - x^*\|^2 = \tilde{L} \|x_k - x^*\|^2$$

avec $\tilde{L} = L\|\nabla^2 f(x^*)^{-1}\|$. En choisissant x_0 tel que $\|x_0 - x^*\| \leq \min(r, 1/(2L))$ on peut utiliser cette inégalité inductive pour déduire que la suite $\{x_k\}$ converge vers x^* , et que le taux de convergence est quadratique. En utilisant la relation $x_{k+1} - x_k = p_k^N$ et $\nabla f_k + \nabla^2 f_k p_k^N = 0$ on obtient que

$$\begin{aligned}
\|\nabla f(x_{k+1})\| &= \|\nabla f(x_{k+1}) - \nabla f_k - \nabla^2 f(x_k)p_k^N\| \\
&= \left\| \int_0^1 \nabla^2 f(x_k + tp_k^N)(x_{k+1} - x_k)dt - \nabla^2 f(x_k)p_k^N \right\| \\
&\leq \int_0^1 \|\nabla^2 f(x_k + tp_k^N) - \nabla^2 f(x_k)\| \cdot \|p_k^N\| dt \\
&\leq \frac{1}{2}L\|p_k^N\|^2 \\
&\leq \frac{1}{2}L\|\nabla^2 f(x_k)^{-1}\|^2\|\nabla f_k\|^2 \\
&\leq 2L\|\nabla^2 f(x^*)^{-1}\|^2\|\nabla f_k\|^2,
\end{aligned}$$

qui prouve que le gradient converge quadratiquement vers 0. \square

1.5 Méthode de descente coordonnée par coordonnée

Cette méthode consiste en utiliser cycliquement les n directions coordonnées e_1, e_2, \dots, e_n comme direction de recherche.

À l'itération k on cherche α_k qui minimise $f(X_K + \alpha_k e_k)$. Après n itération on retrouve la première variable et on répète le cycle. Dans la pratique cette méthode peut être inefficace pour une fonction quadratique de deux variables.

Un grand problème de cette méthode, c'est que cette méthode peut itérer infiniment sans jamais aborder un point où le gradient de la fonction disparaît. En plus, une recherche cyclique ne garantit pas une convergence globale. La difficulté consiste dans le fait que le gradient peut devenir toujours plus perpendiculaire aux coordonnées de direction de recherche, et donc le cosinus de l'angle devient toujours plus proche de 0. Il peut alors satisfaire la condition de Zoutendijk sans que le gradient tende vers 0. On peut encore constater que si cette méthode converge vers une solution, d'habitude elle converge plus lentement que la méthode de la plus grande pente.

Même si cette méthode possède tous ces défauts, elle peut être encore utile pour deux raisons :

1. on ne doit pas calculer le gradient de f ,
2. la vitesse de convergence peut être suffisamment acceptable si les variables sont faiblement dépendants, c'est-à-dire si $\nabla^2 f(x)$ est presque diagonal.

2 Algorithme pour le choix de la longueur du pas

9 On veut maintenant considérer les techniques pour trouver un minimum de la fonction

$$\phi(\alpha) = f(x_k + \alpha p_k) \tag{11}$$

ou bien pour trouver la longueur du pas α_k qui satisfait des conditions de Wolfe. On suppose que p_k soit une direction de descente, ce qui limite la recherche à des valeurs de α positives. Si f est une fonction quadratique $f(x) = \frac{1}{2}x^T Qx + b^T x + c$ alors son minimum, le long du rayon $x_k + \alpha p_k$ est donné par

$$\alpha_k = -\frac{\nabla f_k^T p_k}{p_k^T Q p_k}. \quad (12)$$

Pour les fonctions non linéaires, il est nécessaire d'utiliser une méthode itérative pour calculer α_k . Le choix d'une α_k acceptable a un impact majeur sur la robustesse et l'efficacité des méthodes d'optimisation non linéaires.

Le pas α_k est cherché sur les lignes données par la direction de descente p_k . D'où le nom de cette classe de méthodes " de recherche par ligne".

Une recherche demande une valeur initiale α_0 , et elle génère une séquence $\{\alpha_i\}$ soit converge vers un α qui satisfait les conditions de Wolfe, soit elle détermine que cette longueur n'existe pas. Une procédure typique consiste en deux phases : une "bracketing phase" qui trouve un intervalle $[a, b]$ qui contient des α acceptables, et une phase de sélection qui localise la longueur du pas finale. La phase de sélection d'habitude réduit l'intervalle, en interpolant des informations qu'on obtient dans les itérations précédentes.

2.1 Interpolation

Le but est de trouver une valeur de α qui satisfait la condition de Wolfe

$$f(x_k + \alpha_k p_k) \leq f(x_k) + c_1 \alpha_k \nabla f_k^T p_k.$$

On aura donc une séquence de valeurs décroissantes α_i tel que la valeur α_i ne soit pas trop plus petit de α_{i-1} . Si ceci arrive, on calcule $\alpha_1 = \alpha_{i-1}/2$. Ceci nous permet de faire des progrès à chaque itération et que l' α finale ne soit trop petit. On peut constater qu'on peut écrire la condition de Wolfe comme

$$\phi(\alpha_k) \leq \phi(0) + c_1 \alpha_k \phi'(0) \quad (13)$$

On propose un algorithme de recherche des α_k de façon qu'il calcule $\nabla f(x)$ le moins de fois possible. On suppose que α_0 est donnée. Si on a que

$$\phi(\alpha_0) \leq \phi(0) + c_1 \alpha_0 \phi'(0)$$

alors la recherche est terminée. Autrement, on sait que l'intervalle $[0, \alpha_0]$ contient des longueurs acceptables. Le pas suivant consiste en approximer ϕ par $\phi_q(\alpha)$, en interpolant $\phi(0)$, $\phi'(0)$ et $\phi(\alpha_0)$ pour obtenir :

$$\phi_q(\alpha) = \left(\frac{\phi(\alpha_0) - \phi(0) - \alpha_0 \phi'(0)}{\alpha_0^2} \right) \alpha^2 + \phi'(0) \alpha + \phi(0) \quad (14)$$

Le pas α_0 étant rejeté, on cherche le candidat suivant, α_1 , pour minimaliser approximativement $\phi(\alpha)$. En fait, au lieu de minimaliser $\phi(\alpha)$ (qui est en général non-linéaire), on minimise l'interpolant $\phi_q(\alpha)$. Le minimum est atteint dans

$$\alpha_1 = -\frac{\phi'(0)\alpha_0^2}{2[\phi(\alpha_0) - \phi(0) - \phi'(0)\alpha_0]} \quad (15)$$

qui est le minimiseur de notre fonction quadratique $\phi_q(\alpha)$. Si la condition (13) est satisfait, notre recherche est terminée. Autrement on continue en interpolant les valeurs de $\phi(0)$, $\phi'(0)$ et deux valeurs les plus récentes de ϕ (pour le prochaine passage ça serait $\phi(\alpha_0)$ et $\phi(\alpha_1)$).

2.2 La longueur du pas initial

Pour la méthode de Newton et de quasi-Newton on commence toujours avec la longueur du pas initial $\alpha_0 = 1$. Par contre, pour les méthodes qui ne produisent pas un pas de longueur optimal, on doit utiliser les informations du problème et les algorithmes pour trouver la longueur α_0 . Une stratégie populaire est de choisir α_0 tel que $\alpha_0 \nabla f_k^T p_k = \alpha_{k-1} \nabla f_{k-1}^T p_{k-1}$. On obtient donc que

$$\alpha_0 = \alpha_{k-1} \frac{\nabla f_{k-1}^T p_{k-1}}{\nabla f_k^T p_k}$$

Une autre stratégie est d'interpoler $f(x_{k-1})$, $f(x_k)$ et $\phi'(0) = \nabla f_{k-1}^T p_{k-1}$ pour un polynôme de degré 3 et de définir α_0 comme le minimiseur de l'interpolant. On obtient ainsi

$$\alpha_0 = \frac{2(f_k - f_{k-1})}{\phi'(0)} \quad (16)$$

On peut observer que si x_k converge superlinéairement vers x^* , alors la fraction (16) converge vers 1. Si on remplace dans (16) $\alpha_0 \leftarrow \min(1, 1.01\alpha_0)$, on trouve qu'on essaie et on accepte toujours $\alpha_0 = 1$, et on peut alors observer les propriétés de la convergence superlinéaire des méthodes de Newton et quasi-Newton.

2.3 Algorithme de recherche pour la condition de Wolfe

Dans cette section on veut décrire une procédure qui nous permet de trouver la longueur du pas pour la condition forte de Wolfe. D'abord on doit supposer que p est une direction de descente et que f est borné d'en bas le long de la direction p . L'algorithme qui nous permet de trouver α , est divisé en deux phases. Dans la première phase on estime α_1 , et on l'incrémente jusqu'à on trouve une longueur acceptable ou un intervalle qui contient la longueur désirée. La deuxième phase, par contre, est caractérisée par la fonction zoom, qui diminue la taille de l'intervalle jusqu'à ce qu'on converge vers un α_k qui vérifie les conditions de Wolfe.

Algorithme 1(Line Search Algorithm)

Set $a_0 \leftarrow 0$, choose $\alpha_1 > 0$ and α_{max}

$i \leftarrow 1$;

repeat

 Evaluate $\Phi(\alpha_i)$;

 if $\Phi(\alpha_i) > \Phi(0) + c_1\Phi'(0)$ or $[\Phi(\alpha_i) \geq \Phi(\alpha_{i-1})$ and $i > 1]$

$\alpha_* \leftarrow zoom(\alpha_{i-1}, \alpha_i)$ and stop;

 Evaluate $\Phi'(\alpha_i)$;

 if $|\Phi'(\alpha_i)| \leq -c_2\Phi'(0)$

 set $\alpha_* \leftarrow \alpha_i$ and stop;

 if $\Phi'(\alpha_i) \geq 0$

 set $\alpha_* \leftarrow zoom(\alpha_i, \alpha_{i-1})$ and stop;

 Choose $\alpha_{i+1} \in (\alpha_i, \alpha_{max})$ and stop;

$i \leftarrow i + 1$

end(repeat)

Cette algorithme utilise le fait que l'intervalle (α_{i-1}, α_i) contient des longueurs qui satisfont la condition forte de Wolfe si une des trois conditions est satisfait :

1. α_i ne satisfait pas la condition de Wolfe
2. $\phi(\alpha_i) \geq \phi(\alpha_{i-1})$
3. $\phi'(\alpha_i) \geq 0$

Le dernier passage de l'algorithme nous permet de trouver la prochaine valeur α_{i+1} . Pour incrementer ce pas, on peut utiliser différentes méthodes, comme l'interpolation ou simplement on peut multiplier α_i par une constante plus grande que 1. La seule chose importante est que la suite des pas $\{\alpha_i\}$ augmente suffisamment vite pour arriver à α_{max} en un nombre raisonnable d'opérations.

Maintenant on veut voir plus en détail la fonction $zoom$. L'ordre de ses inputs est telle que chaque evaluation possède la forme $zoom(\alpha_{lo}, \alpha_{hi})$ où :

1. $[\alpha_{lo}; \alpha_{hi}]$ ou $[\alpha_{hi}; \alpha_{lo}]$ contient une longueur du pas qui satisfait la condition forte de Wolfe ;
2. $\phi(\alpha_{lo}) < \phi(\alpha_{hi})$
3. α_{hi} est choisi tel que $\phi'(\alpha_{lo})(\alpha_{hi} - \alpha_{lo}) < 0$

Chaque itération de la fonction $zoom$ produit un α_j entre α_{lo} et α_{hi} et après il remplace un des deux points extrêmes de l'intervalle par α_j : si α_j satisfait la condition de diminution suffisante et possède une valeur de la fonction inférieure à α_{lo} , alors on remplace α_{lo} par α_j .

Algorithme 2($zoom(\alpha_{lo}, \alpha_{hi})$)

repeat

Interpolate (using quadratic, cubic, or bisection) to find a trial step length α_j
between α_{lo} and α_{hi} ;

Evaluate $\Phi(\alpha_j)$;

if $\Phi(\alpha_j) > \Phi(0) + c_1\alpha_j\Phi'(0)$ ou $\Phi(\alpha_j) \geq \Phi(\alpha_{lo})$

$\alpha_{hi} \leftarrow \alpha_j$;

else

Evaluate $\Phi'(\alpha_j)$

if $|\Phi'(\alpha_j)| \leq -c_2\Phi'(0)$

Set $\alpha_* \leftarrow \alpha_j$ and stop;

if $\phi'(\alpha_j)(\alpha_{hi} - \alpha_{lo}) \geq 0$

$\alpha_{hi} \leftarrow \alpha_{lo}$

$\alpha_{lo} \leftarrow \alpha_j$

end(repeat)