


Outils de Recherche opérationnelle en Génie MTH 8414

Programmation Non Linéaire

- Un programme non linéaire est similaire à un programme linéaire, car il est constitué:
 - D'une fonction objectif
 - Des contraintes et des bornes sur les variables
- Toutefois ces équations n'ont pas à être linéaires
- Elles sont généralement données comme des fonctions (analytiques)
- Il y a de nombreuses applications pratiques de la PNL:
 - Problème d'optimisation en finance
 - Problème d'optimisation en énergie
 - Problème d'optimisation en (pétro) chimie
 - ...
- Un PNL est toutefois beaucoup plus difficile à résoudre qu'un PL.
- Voyons pourquoi...

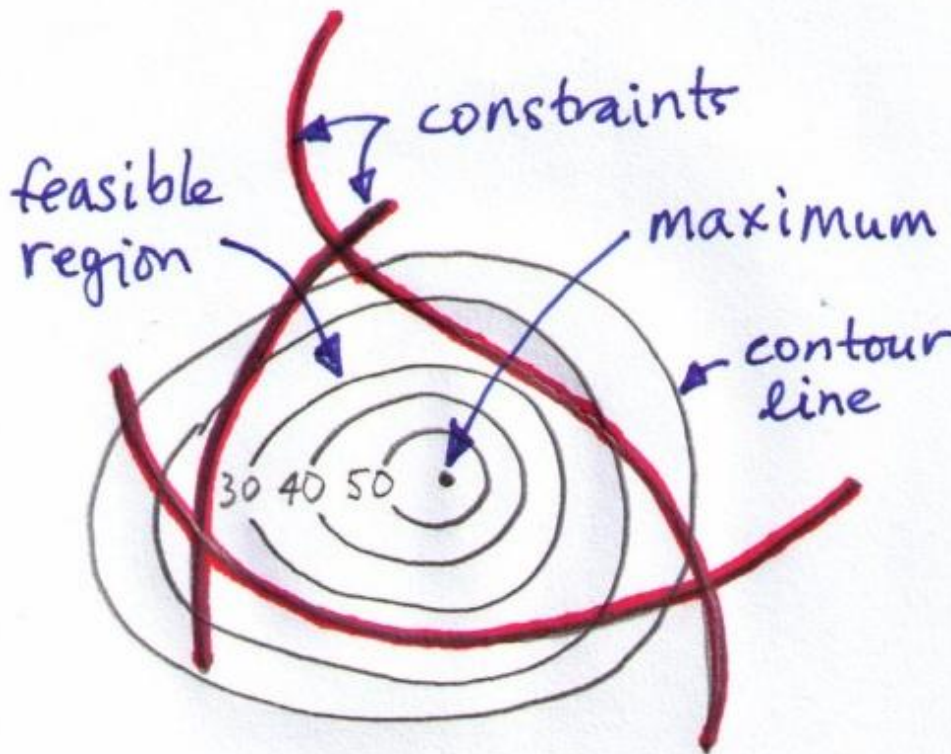
Raison 1: Local ou global cet optimum ?

- En l'absence de convexité (comme pour les PL) les méthodes de résolution de PNL ne peuvent garantir d'identifier la solution optimale
- Elles font généralement une recherche dans l'espace, basée sur:
 - Un point courant
 - La valeur de l'objectif à ce point
 - La valeur du gradient de la fonction objectif
 - La matrice Hessien (dérivée seconde) de la fonction objectif
- Ces informations permettent d'identifier un maximum (ou minimum) local, mais pas de dire s'il est global.




Raison 2: L'optimum et les points extrêmes.

- En PL, s'il existe une solution optimale, alors il existe un point extrême du polyèdre qui est optimal.
- En PNL, l'optimum peut se trouver n'importe où
 - En rouge les lignes de la région réalisables
 - En noir des courbes de niveau de la fonction objectif.



Raison 3: Régions réalisables déconnectées

- Rien ne garantit que l'espace des solutions réalisables est connecté.
- Donc, même si on trouve l'optimum d'une région, rien ne nous dit qu'il n'existe pas d'autres régions réalisables...



Raison 4: L'importance du point de départ


- Comme on ne peut pas garantir l'obtention d'un optimum global, le point d'où on débute la recherche joue un rôle important sur la solution que nous pouvons trouver.
- En effet la plupart des solveurs non linéaires font une recherche locale
 - À partir d'une solution de départ ou solution courante
 - On détermine la meilleure direction (avec le gradient)
 - On fait un « pas » dans cette direction
- Une des solutions est de redémarrer le solveur régulièrement à partir de points différents.

Raison 5: Trouver un point de départ

- Il peut être parfois difficile de trouver un point de départ réalisable.
- En PL, il existe une « phase 1 » qui permet toujours de trouver une solution initiale ou de montrer qu'il n'en existe aucun.
- En PNL, on commence en minimisant une distance vis-à-vis de la zone réalisable, comme le carré des violations par exemple.
- Donc si on optimise ce deuxième problème et on trouve une solution optimale dont le coût est 0, alors on a identifié une solution réalisable à notre problème d'origine
- Toutefois, ce deuxième problème est lui-même un problème NL...
- Dans ce cas, les solveurs peuvent donc rester pris dans un minimum local dont la valeur n'est pas 0... ce qui implique
 - Qu'on ne peut pas optimiser le problème
 - On ne peut pas prouver qu'il est irréalisable.

Raison 6: Dures égalités

- Si on a une courbe très « tordue » il peut s'avérer difficile de trouver un point qui tombe « pile » sur la courbe
- De plus, lors de l'optimisation (via recherche locale) il risque d'être encore plus difficile de rester sur cette courbe.



Raison 8: Un zoo de méthodologies


- La PNL regroupe sous une même bannière une vaste gamme de techniques associés à chaque type de fonctions (quadratiques, convexes, etc.)
- Face à un problème, quelle technique appliquée ?
- Les solveurs nécessitent parfois que les fonctions linéaires respectent des conditions particulières... Il peut donc être difficile d'identifier le bon solveur à utiliser.
- Il existe très peu d'outils permettant d'analyser un problème NL, d'identifier ses caractéristiques et de choisir un bon solveur.
- Différents solveurs vont donner différentes solutions...
- Différentes modélisations vont donner différentes solutions...

Raison 9: Difficulté d'usage

- Les solveurs disponibles ont généralement un très grand nombre de paramètres à ajuster (>50).
- Optimiser ces paramètres peut s'avérer une tâche complexe
 - Quel type d'optimisation locale, quelle tolérance, inversion de la base, etc.
- Souvent, on a besoin des dérivées des fonctions : elles peuvent être difficiles à trouver.
- Pas de standard pour l'entrée des données : difficile de passer d'un solveur à un autre.


Fonction objectif convexe

$$\lambda f(x_1) + (1-\lambda) f(x_2) \geq f(\lambda x_1 + (1-\lambda)x_2) \text{ avec } 0 \leq \lambda \leq 1$$



Fonction objectif concave

$$\lambda f(x_1) + (1 - \lambda) f(x_2) \leq f(\lambda x_1 + (1 - \lambda)x_2) \text{ avec } 0 \leq \lambda \leq 1$$



$$\max f(x)$$

$$s.t. \quad g_i(x) = b_i, \quad i = 1, \dots, m$$

conditions pour que x soit maximum local

$$\nabla f(x) = \sum_i^m v_i \nabla g_i(x)$$

$$v_i \geq 0, \quad i = 1, \dots, m$$

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

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

faisabilité duale

faisabilité primale

complémentarité

Programmation Quadratique

- $f(x)$ est quadratique i.e. inclus, les termes x_j^2 et $x_j x_k$ ($j \neq k$)
- Les contraintes sont toutes linéaires. $g_i(x)$

$$x = (x_1, x_2, \dots, x_n) \text{ t.q.}$$

$$(PQ) \left\{ \begin{array}{l} \text{Max } z = C^T X - \frac{1}{2} X^T Q X \\ \text{Sujet :} \\ \\ AX \leq b \\ \\ X \geq 0 \end{array} \right.$$

où $Q = [q_{ij}]$: symétrique, semi-définie positive.

Si z est concave (i.e. $X^T Q X \geq 0$) alors on a un optimum unique.

$$\begin{aligned} \min & \frac{1}{2} x^t Q x + c^t x \\ \text{s.c.} & Ax \alpha b \\ & l \leq x \leq u \end{aligned}$$

Avec α étant toute combinaison de $\{\leq, =, \geq\}$ pour les contraintes.
Q : matrice de coefficients des termes quadratiques.

CPLEX résoud : min obj convexe avec Q positif semi-défini

$$x^t Q x \geq 0$$

ou max obj. concave avec Q négatif semi-défini

$$x^t Q x \leq 0$$

$z = f(X)$ est concave (car on maximise)
chaque $g_i(X)$ est convexe.

Exemple:

$$(PC) \left\{ \begin{array}{l} \text{Max} \quad z = 32x_1 + 50x_2 - 10x_2^2 + x_2^3 - x_1^4 - x_2^4 \\ \text{Sujet :} \\ \quad 2x_1^2 + x_2 \leq 13 \\ \quad x_1^2 + x_2 \leq 9 \\ \quad x_1 \geq 0, \quad x_2 \geq 0 \end{array} \right.$$

- (max f concave, contraintes $g_i(x)$ convexes)
- Algorithmes de type « gradient »
 - par exemple : gradient réduit généralisé
 - Algorithmes d'optimisation non contraint séquentiels
 - transforme le problème contraint en envoyant les contraintes dans l'objectif (méthodes de pénalités ou de barrières)
 - Algorithmes d'approximations séquentielles
 - remplace l'objectif par une succession d'approximations linéaires ou quadratiques

$f(x)$ est concave et séparable i.e.

$$f(x) = f_1(x_1) + f_2(x_2) + \dots + f_n(x_n) = \sum_{j=1}^n f_j(x_j)$$

$g_i(x)$ est convexe et séparable pour chaque i

- On en a déjà discuté dans le cours sur la modélisation en PL

$f(x)$ et les fonctions contraintes sont de la forme $\sum_{j=1}^p \left(c_j \prod_{i=1}^n x_i^{a_{ij}} \right)$

et sont généralement ni convexes ni concaves, où les c_j et a_{ij} sont des constantes physiques dans les applications de problème d'ingénierie.

Exemple:

$$(PG) \left\{ \begin{array}{l} \text{Min} \quad f(x) = 2x_1^{-2}x_1^{-1} + x_1^{-1}x_2^{-2} \\ \text{sujet à :} \\ \\ 4x_1x_2 + x_1^2x_2^2 \leq 12 \\ x_1 \geq 0, \quad x_2 \geq 0. \end{array} \right.$$

$$f(x) = f_1(x)/f_2(x) \quad : \quad \text{ratio de } f_1(x) \text{ et } f_2(x)$$

$$\text{Max } f(x) = f_1(x)/f_2(x)$$

- **Exemple:**

$$(PF) \left\{ \begin{array}{l} \text{Max } f(x) = \frac{10x_1 + 20x_2 + 10}{3x_1 + 4x_2 + 20} \\ \text{Sujet :} \\ x_1 + 3x_2 \leq 50 \\ 3x_1 + 2x_2 \leq 80 \\ x_1 \geq 0, \quad x_2 \geq 0 \end{array} \right.$$

Tous problèmes de PNL qui ne remplissent pas les hypothèses des problèmes de programmation convexe.

- **Exemple:**

$$(PNC) \left\{ \begin{array}{l} \text{Max} \quad f(x) = 3x_1x_2 - 2x_2^1 - x_2^2 \\ \text{Sujet :} \\ \\ x_1^2 + 2x_2^2 \leq 4 \\ 2x_1 - x_2 \leq 0 \\ x_1x_2^2 + x_1^2x_2 = 2 \\ x_1 \geq 0, \quad x_2 \geq 0. \end{array} \right.$$

- On optimise les problèmes à une variables à l'aide des dérivées premières et secondes.
- Nous utiliserons les mêmes concepts pour les problèmes comportant plusieurs variables.
- Le gradient correspond à la dérivée première, alors que la matrice hessienne représente les dérivés secondes.

- Rappel sur le gradient (∇):
- Pour une fonction “ f ”, sur les variables x_1, x_2, \dots, x_n :

$$\nabla f = \left[\frac{\partial f}{\partial x_1} \quad \frac{\partial f}{\partial x_2} \quad \dots \quad \frac{\partial f}{\partial x_n} \right]$$

Exemple: $f = 15x_1 + 2(x_2)^3 - 3x_1(x_3)^2$

$$\nabla f = \left[15 - 3(x_3)^2 \quad 6(x_2)^2 \quad -6x_1x_3 \right]$$

La matrice hessienne

- La matrice hessienne (∇^2) de $f(x_1, x_2, \dots, x_n)$ est :

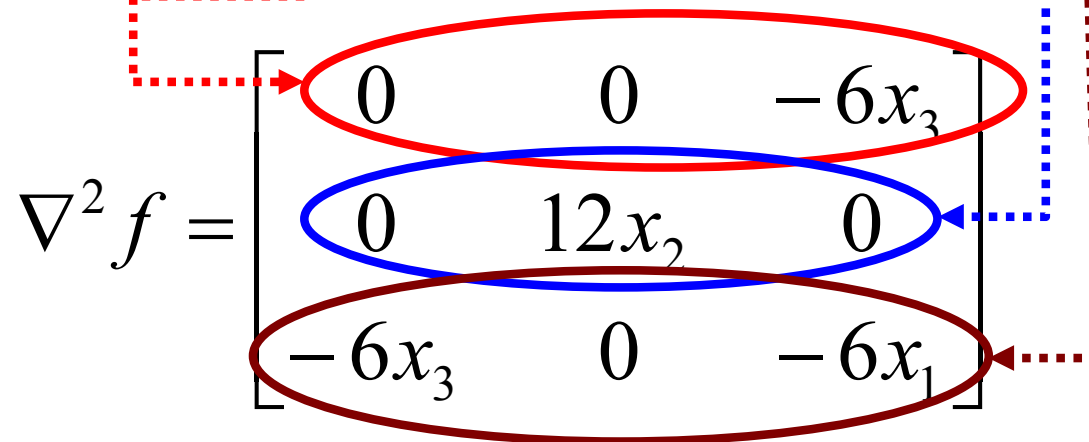
$$\nabla^2 f = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \cdots & \frac{\partial^2 f}{\partial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

Exemple de matrice hessienne

- Exemple (vue précédemment):

$$f = 15x_1 + 2(x_2)^3 - 3x_1(x_3)^2$$

$$\nabla f = \left[15 - 3(x_3)^2 \quad 6(x_2)^2 \quad -6x_1x_3 \right]$$

$$\nabla^2 f = \begin{bmatrix} 0 & 0 & -6x_3 \\ 0 & 12x_2 & 0 \\ -6x_3 & 0 & -6x_1 \end{bmatrix}$$


The diagram illustrates the relationship between the gradient components and the Hessian matrix entries. The Hessian matrix is shown with three rows and three columns. The entries are: 0 , 0 , $-6x_3$ in the first row; 0 , $12x_2$, 0 in the second row; and $-6x_3$, 0 , $-6x_1$ in the third row. The first row is circled in red, the second row in blue, and the third row in brown. Dotted lines with arrows indicate the following: a red arrow from the first element of the gradient, $15 - 3(x_3)^2$, points to the first row of the Hessian; a blue arrow from the second element, $6(x_2)^2$, points to the second row; and a brown arrow from the third element, $-6x_1x_3$, points to the third row.

- La procédure d'optimisation sur plusieurs variables fonctionne comme suit:
 1. Résoudre le problème qui consiste à trouver les points pour lesquels le gradient est nul.
 2. Calculer le Hessien de la fonction objectif et l'évaluer pour chacun des points obtenus en 1.
 - Si la matrice est "définie positive" alors le point est un minimum local.
 - Si la matrice est "définie négative" alors le point est un maximum local.

Positive/Negative Definite

- Une matrice est “**définie positive**” si toutes ces valeurs propres sont positives. (> 0)
- Une matrice est “**définie négative**” si toutes ces valeurs propres sont négatives. (< 0)
- Une matrice est “**semi-définie positive**” si toutes ces valeurs propres sont positives ou nulles. (≥ 0)
- Une matrice est “**semi-définie négative**” si toutes ces valeurs propres sont négatives nulles. (≤ 0)

Matrice Exemple

Soit la matrice A :

$$A = \begin{bmatrix} 2 & 4 & 5 \\ -5 & -7 & -1 \\ 1 & 1 & 2 \end{bmatrix}$$

Les valeurs propres de A sont:

$$\lambda_1 = -3.702 \quad \lambda_2 = -2 \quad \lambda_3 = 2.702$$

Cette matrice est définie négative

Un exemple de PNL sans contrainte

Consider the problem:

Minimiser $f(x_1, x_2, x_3) = (x_1)^2 + x_1(1 - x_2) + (x_2)^2 - x_2x_3 + (x_3)^2 + x_3$

D'abord, trouvons le gradient pour les x_i :

$$\nabla f = \begin{bmatrix} 2x_1 + 1 - x_2 \\ -x_1 + 2x_2 - x_3 \\ -x_2 + 2x_3 + 1 \end{bmatrix}$$

Un exemple de PNL sans contrainte

Ensuite, mettre le gradient = 0:

$$\nabla f = 0 \quad \Rightarrow \quad \begin{bmatrix} 2x_1 + 1 - x_2 \\ -x_1 + 2x_2 - x_3 \\ -x_2 + 2x_3 + 1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

Nous avons un système à trois équations et trois inconnues, que nous pouvons résoudre:

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} -1 \\ -1 \\ -1 \end{bmatrix}$$

Un exemple de PNL sans contrainte

Nous avons donc un candidat à valider

Trouvons la matrice hessienne:

$$\nabla^2 f = \begin{bmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{bmatrix}$$

Un exemple de PNL sans contrainte

Les valeurs propres de cette matrice sont:

$$\lambda_1 = 3.414 \quad \lambda_2 = 0.586 \quad \lambda_3 = 2$$

Comme toutes les valeurs propres sont > 0 , alors la matrice hessienne est définie positive.

Alors le point $\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} -1 \\ -1 \\ -1 \end{bmatrix}$ est un minimum


- Dans l'exemple précédent, on avait un système à trois équations linéaires et trois inconnus.
- Pour certains autres problèmes, nous pourrions obtenir des équations non linéaires.
- On doit alors résoudre un système d'équations non linéaires... ce qui n'est pas simple.
- Pour éviter ce problème, les PNL sont généralement résolus numériquement.

Lors de la résolution de $f'(x) = 0$ pour trouver un maximum ou un minimum, on peut faire utiliser les itérations suivantes:

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

- k est l'itération courante
- $|x^{k+1} - x^k| < e$ où e est une tolérance spécifiée

Diagramme de la méthode de Newton



La méthode de Newton approxime $f'(x)$ avec une droite au point x^k et on obtient le point (x^{k+1}) , qui est utilisé pour approximer la fonction au prochain point. Jusqu'à ce qu'on rapproche suffisamment de x^* .

- Il faut s'assurer que
 - $f(x^{k+1}) < f(x^k)$ pour trouver un minimum.
 - $f(x^{k+1}) > f(x^k)$ pour trouver un maximum.
- Désavantage:
 - Il faut calculer les dérivées premières et secondes
 - La solution initiale est importante, si elle est trop loin de l'optimum la méthode peut ne pas converger.

Méthode de Regula-Falsi


Cette méthode nécessite deux points x^a & x^b qui encadre la solution de l'équation $f'(x) = 0$.

$$x^c = x^b - \frac{f'(x^b) \cdot (x^b - x^a)}{f'(x^b) - f'(x^a)}$$

où x^c sera entre x^a & x^b .

Le prochain intervalle sera défini par x^c et soit x^a ou x^b , celui dont le signe sera différent de x^c .

Diagramme de Regula-Falsi



La méthode de Regula-Falsi approxime fonction $f'(x)$ avec une droite et utilise l'interpolation pour trouver la racine.

Commentaires sur Regula-Falsi



- Cette méthode nécessite la connaissance de deux points qui entourent la solution.
- Elle ne nécessite toutefois pas le calcul de la dérivée seconde.
- La méthode de Regula-Falsi nécessite toutefois un peu plus d'itération que la méthode de Newton.

- Considérons le cas avec plusieurs variables, sans contrainte.
- Pratiquement toutes les méthodes suivent la recette suivante:
 1. Choisir une direction de recherche \mathbf{d}^k
 2. Chercher le minimum dans cette direction afin de trouver le prochain point.

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

Où k est le numéro d'itération courante et α^k est un scalaire positif appelé le pas

- Le pas, α^k , est calculé de la manière suivante:
 - Nous voulons optimiser la fonction $f(\mathbf{x}^{k+1}) = f(\mathbf{x}^k + \alpha^k \mathbf{d}^k)$ où la seule variable est α^k parce que \mathbf{x}^k & \mathbf{d}^k sont connus.

- Nous posons $\frac{df(\mathbf{x}^k + \alpha^k \mathbf{d}^k)}{d\alpha^k} = 0$ et résolvons pour α^k en utilisant la méthode à une seule variable vue précédemment.

Méthode de la descente la plus rapide


- Cette méthode est très simple
 - Pour donner une direction, elle utilise le gradient (pour maximiser) ou le gradient négatif (pour minimiser)

$$\mathbf{d}^k = \begin{cases} + \\ - \end{cases} \nabla f(\mathbf{x}^k) \quad \text{pour} \quad \begin{cases} \text{max} \\ \text{min} \end{cases}$$

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

Méthode de la descente la plus rapide

- L'opposé du gradient nous indique la direction de descente la plus rapide.



Méthode de la descente la plus rapide

Les étapes sont:

1. Choisir un point initial \mathbf{x}^0
2. Calculer le gradient $\nabla f(\mathbf{x}^k)$ où k est un numéro d'itération
3. Calculer la direction de recherche: $\mathbf{d}^k = \pm \nabla f(\mathbf{x}^k)$
4. Calculer le prochain point \mathbf{x} :

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

en utilisant une méthode d'optimisation à une variable sur α^k .

Méthode de la descente la plus rapide

Pour déterminer la convergence, utiliser une tolérance ε_1 et arrêter:

$$\left| f(\mathbf{x}^{k+1}) - f(\mathbf{x}^k) \right| < \varepsilon_1$$

Où utiliser une tolérance ε_2 et arrêter:

$$\left\| \nabla f(\mathbf{x}^k) \right\| < \varepsilon_2$$

- Deux critères d'arrêt sont valides pour la majorité des méthodes d'optimisation à plusieurs variables.
- Rappelons que la norme d'un vecteur, $\|\mathbf{x}\|$ est donné par:

$$\|\mathbf{x}\| = \sqrt{\mathbf{x}^T \cdot \mathbf{x}} = \sqrt{(x_1)^2 + (x_2)^2 + \cdots + (x_n)^2}$$

Exemple

Minimiser $f(\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3) = (\mathbf{x}_1)^2 + \mathbf{x}_1(1 - \mathbf{x}_2) + (\mathbf{x}_2)^2 - \mathbf{x}_2\mathbf{x}_3 + (\mathbf{x}_3)^2 + \mathbf{x}_3$

Avec le point de départ $\mathbf{x}^0 = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$

Exemple

$$\nabla f(\mathbf{x}) = [2x_1 + (1 - x_2) \quad -x_1 + 2x_2 - x_3 \quad -x_2 + 2x_3 + 1]$$

$$\begin{aligned} \mathbf{d}^0 &= -\nabla f(\mathbf{x}^0) = -[2(0) + 1 - 0 \quad -0 + 0 - 0 \quad -0 + 0 + 1] \\ &= -[1 \quad 0 \quad 1] = [-1 \quad 0 \quad -1] \end{aligned}$$

$$\mathbf{x}^1 = [0 \quad 0 \quad 0] + \alpha^0 \cdot [-1 \quad 0 \quad -1]$$

Il faut maintenant trouver α^0

Exemple

$$\begin{aligned} f(\mathbf{x}^1) &= (\alpha^0)^2 + (-\alpha^0)(1) + 0 - 0 + (\alpha^0)^2 + (-\alpha^0) \\ &= 2(\alpha^0)^2 - 2(\alpha^0) \end{aligned}$$

$$\frac{df(\mathbf{x}^1)}{d\alpha^0} = 4(\alpha^0) - 2$$

On met =0 et on résout:

$$4(\alpha^0) = 2 \Rightarrow \alpha^0 = \frac{2}{4} = \frac{1}{2}$$

Exemple

$$\begin{aligned}\mathbf{x}^1 &= [0 \quad 0 \quad 0] + \alpha^0 \cdot [-1 \quad 0 \quad -1] \\ &= [0 \quad 0 \quad 0] + \left[-\frac{1}{2} \quad 0 \quad -\frac{1}{2} \right]\end{aligned}$$

$$\therefore \mathbf{x}^1 = \left[-\frac{1}{2} \quad 0 \quad -\frac{1}{2} \right]$$

Exemple

On choisit le gradient négatif comme prochaine direction de descente.

$$\mathbf{d}^1 = -\nabla f(\mathbf{x}^1) = -\left[-1 + 1 + 0 \quad \frac{1}{2} + 0 + \frac{1}{2} \quad 0 - 1 + 1 \right]$$

$$\therefore \mathbf{d}^1 = [0 \quad -1 \quad 0]$$

Exemple

On met à jour les données d'itération

$$\begin{aligned}\mathbf{x}^2 &= \begin{bmatrix} -\frac{1}{2} & 0 & -\frac{1}{2} \end{bmatrix} + \alpha^1 \cdot [0 \quad -1 \quad 0] \\ &= \begin{bmatrix} -\frac{1}{2} & -\alpha^1 & -\frac{1}{2} \end{bmatrix}\end{aligned}$$

Exemple

Insérez dans la fonction originale et dérivez pour trouver α^1 :

$$\begin{aligned} f(\mathbf{x}^2) &= \frac{1}{4} + \left(-\frac{1}{2}\right)(1 + \alpha^1) + (\alpha^1)^2 - (\alpha^1)\left(\frac{1}{2}\right) + \frac{1}{4} - \frac{1}{2} \\ &= (\alpha^1)^2 - \alpha^1 - \frac{1}{2} \end{aligned}$$

$$\frac{df(\mathbf{x}^1)}{d\alpha^1} = 2(\alpha^1) - 1$$

Exemple

Mettre la dérivée = 0 et résoudre pour α^1 :

$$2(\alpha^1) = 1 \Rightarrow \alpha^1 = \frac{1}{2}$$

Exemple

Calculez maintenant \mathbf{x}^2 :

$$\mathbf{x}^2 = \begin{bmatrix} -\frac{1}{2} & 0 & -\frac{1}{2} \end{bmatrix} + \alpha^1 \cdot \begin{bmatrix} 0 & -1 & 0 \end{bmatrix}$$

$$= \begin{bmatrix} -\frac{1}{2} & 0 & -\frac{1}{2} \end{bmatrix} + \begin{bmatrix} 0 & -\frac{1}{2} & 0 \end{bmatrix}$$

$$\therefore \mathbf{x}^2 = \begin{bmatrix} -\frac{1}{2} & -\frac{1}{2} & -\frac{1}{2} \end{bmatrix}$$

Exemple

$$\mathbf{d}^2 = -\nabla f(\mathbf{x}^2) = -\begin{bmatrix} -1+1+\frac{1}{2} & \frac{1}{2}-1+\frac{1}{2} & \frac{1}{2}-1+1 \\ \frac{1}{2}-1+\frac{1}{2} & \frac{1}{2}-1+\frac{1}{2} & \frac{1}{2}-1+1 \\ \frac{1}{2}-1+1 & \frac{1}{2}-1+1 & \frac{1}{2}-1+1 \end{bmatrix}$$

$$\therefore \mathbf{d}^2 = \begin{bmatrix} -\frac{1}{2} & 0 & -\frac{1}{2} \\ -\frac{1}{2} & 0 & -\frac{1}{2} \\ -\frac{1}{2} & 0 & -\frac{1}{2} \end{bmatrix}$$

$$\mathbf{x}^3 = \begin{bmatrix} -\frac{1}{2} & -\frac{1}{2} & -\frac{1}{2} \\ -\frac{1}{2} & -\frac{1}{2} & -\frac{1}{2} \\ -\frac{1}{2} & -\frac{1}{2} & -\frac{1}{2} \end{bmatrix} + \alpha^2 \cdot \begin{bmatrix} -\frac{1}{2} & 0 & -\frac{1}{2} \\ -\frac{1}{2} & 0 & -\frac{1}{2} \\ -\frac{1}{2} & 0 & -\frac{1}{2} \end{bmatrix}$$

$$= \begin{bmatrix} -\frac{1}{2}(\alpha^2 + 1) & -\frac{1}{2} & -\frac{1}{2}(\alpha^2 + 1) \\ -\frac{1}{2}(\alpha^2 + 1) & -\frac{1}{2} & -\frac{1}{2}(\alpha^2 + 1) \\ -\frac{1}{2}(\alpha^2 + 1) & -\frac{1}{2} & -\frac{1}{2}(\alpha^2 + 1) \end{bmatrix}$$

Exemple

Trouvez α^2 :

$$f(\mathbf{x}^3) = \frac{1}{2}(\alpha^2 + 1)^2 - \frac{3}{2}(\alpha^2 + 1) + \frac{1}{4}$$

$$\frac{df(\mathbf{x}^3)}{d\alpha^2} = (\alpha^2 + 1) - \frac{3}{2}$$

Mettre la dérivée = 0 et résoudre

$$(\alpha^2 + 1) = \frac{3}{2} \Rightarrow \alpha^2 = \frac{1}{2}$$

Exemple

Calculer \mathbf{x}^3 :

$$\mathbf{x}^3 = \begin{bmatrix} 1 & 1 & 1 \\ -\frac{1}{2} & -\frac{1}{2} & -\frac{1}{2} \end{bmatrix} + \alpha^2 \cdot \begin{bmatrix} -\frac{1}{2} & 0 & -\frac{1}{2} \end{bmatrix}$$

$$= \begin{bmatrix} 1 & 1 & 1 \\ -\frac{1}{2} & -\frac{1}{2} & -\frac{1}{2} \end{bmatrix} + \begin{bmatrix} -\frac{1}{4} & 0 & -\frac{1}{4} \end{bmatrix}$$

$$\therefore \mathbf{x}^3 = \begin{bmatrix} 3 & 1 & 3 \\ -\frac{3}{4} & -\frac{1}{2} & -\frac{3}{4} \end{bmatrix}$$

Exemple

Trouvez la prochaine direction:

$$\mathbf{d}^3 = -\nabla f(\mathbf{x}^3) = -\begin{bmatrix} 0 & \frac{1}{2} & 0 \end{bmatrix} = \begin{bmatrix} 0 & -\frac{1}{2} & 0 \end{bmatrix}$$

$$\mathbf{x}^4 = \begin{bmatrix} -\frac{3}{4} & -\frac{1}{2} & -\frac{3}{4} \end{bmatrix} + \alpha^3 \cdot \begin{bmatrix} 0 & -\frac{1}{2} & 0 \end{bmatrix}$$

$$= \begin{bmatrix} -\frac{3}{4} & -\frac{1}{2}(\alpha^3 + 1) & -\frac{3}{4} \end{bmatrix}$$

Exemple

Trouvez α^3 :

$$f(\mathbf{x}^4) = \frac{1}{4}(\alpha^3 + 1)^2 - \frac{3}{2}(\alpha^3) - \frac{3}{2}$$

$$\frac{df(\mathbf{x}^4)}{d\alpha^3} = \frac{1}{2}(\alpha^3 + 1) - \frac{9}{8} = 0$$

$$\Rightarrow \alpha^3 = \frac{5}{4}$$

Exemple

\mathbf{x}^4 devient:

$$\mathbf{x}^4 = \begin{bmatrix} -\frac{3}{4} & -\frac{1}{2} & -\frac{3}{4} \end{bmatrix} + \begin{bmatrix} 0 & -\frac{5}{8} & 0 \end{bmatrix}$$

$$\therefore \mathbf{x}^4 = \begin{bmatrix} -\frac{3}{4} & -\frac{9}{8} & -\frac{3}{4} \end{bmatrix}$$

La prochaine direction :

$$\mathbf{d}^4 = -\nabla f(\mathbf{x}^4) = -\begin{bmatrix} 5 & -3 & 5 \\ 8 & 4 & 8 \end{bmatrix} = \begin{bmatrix} -5 & 3 & -5 \\ 8 & 4 & 8 \end{bmatrix}$$

$$\begin{aligned} \mathbf{x}^5 &= \begin{bmatrix} 3 & 9 & 3 \\ 4 & 8 & 4 \end{bmatrix} + \alpha^4 \cdot \begin{bmatrix} -5 & 3 & -5 \\ 8 & 4 & 8 \end{bmatrix} \\ &= \begin{bmatrix} -\frac{1}{4}(3 + \frac{5}{2}\alpha^4) & -\frac{3}{4}(\frac{3}{2} - \alpha^4) & -\frac{1}{4}(3 + \frac{5}{2}\alpha^4) \\ \frac{3}{4}(3 + \frac{5}{2}\alpha^4) & \frac{3}{4}(\frac{3}{2} - \alpha^4) & \frac{3}{4}(3 + \frac{5}{2}\alpha^4) \end{bmatrix} \end{aligned}$$

Exemple

Trouvez α^4 :

$$f(\mathbf{x}^5) = \frac{73}{32} (\alpha^4)^2 - \frac{43}{32} \alpha^4 - \frac{51}{64}$$

$$\frac{df(\mathbf{x}^5)}{d\alpha^4} = \frac{73}{16} \alpha^4 - \frac{43}{32} = 0$$

$$\Rightarrow \alpha^4 = \frac{43}{146}$$

Exemple

Mettre à jour \mathbf{x}^5 :

$$\mathbf{x}^5 = \begin{bmatrix} -\frac{3}{4} & -\frac{9}{8} & -\frac{3}{4} \end{bmatrix} + \frac{43}{146} \cdot \begin{bmatrix} -\frac{5}{8} & \frac{3}{4} & -\frac{5}{8} \end{bmatrix}$$

$$\therefore \mathbf{x}^5 = \begin{bmatrix} -\frac{1091}{1168} & -\frac{66}{73} & -\frac{1091}{1168} \end{bmatrix}$$

Steepest Descent Example

Vérifions le critère de convergence sur $\|\nabla f(\mathbf{x}^5)\|$:

$$\nabla f(\mathbf{x}^5) = \begin{bmatrix} \frac{21}{584} & \frac{35}{584} & \frac{21}{584} \end{bmatrix}$$

$$\|\nabla f(\mathbf{x}^5)\| = \sqrt{\left(\frac{21}{584}\right)^2 + \left(\frac{35}{584}\right)^2 + \left(\frac{21}{584}\right)^2} = 0.0786$$

Steepest Descent Example

Puisque $||\nabla f(\mathbf{x}^5)|| = 0.0786$, est suffisamment proche de 0, nous décidons d'arrêter.

Noter que la réponse $\mathbf{x} = \begin{bmatrix} -\frac{1091}{1168} & -\frac{66}{73} & -\frac{1091}{1168} \end{bmatrix}$

Est très proche de la solution obtenue
analytiquement

$$\mathbf{x}^* = \begin{bmatrix} -1 & -1 & -1 \end{bmatrix}$$