

3.2 Méthodes numériques de minimisation

On désire calculer de manière numérique le minimum (ou les minima) d'une fonction $f: U \rightarrow \mathbb{R}$ définie sur un ouvert de \mathbb{R}^n

$$f(x) = \min_{y \in U} f(y)$$

Tout algorithme de minimisation devrait avoir les propriétés

1) $f(x_{k+1}) \leq f(x_k)$

2) $x_k \xrightarrow[k \rightarrow \infty]{} x = \text{le pt. minimisant}$

Les méthodes sont regroupées en deux familles

a) les méthodes de descente

$$\begin{cases} x_0 \in \mathbb{R}^n \text{ donné} \\ x_{k+1} = x_k + s_k d_k \end{cases}$$

où d_k est une direction de descente et $s_k > 0$ est choisi de sorte que $f(x_{k+1}) \leq f(x_k)$

b) les méthodes de type Newton

On résout le système non linéaire

$$\nabla f(x) = 0.$$

3.3 Méthodes de gradient

Considérons un algorithme de descente et utilisons Taylor pour développer $f(x_{k+1})$ autour du pt. x_k .

$$\begin{aligned} f(x_{k+1}) &= f(x_k + s_k d_k) \\ &= f(x_k) + s_k (\nabla f(x_k), d_k) + \frac{1}{2} s_k^2 (H d_k, d_k) \\ &\approx f(x_k) + s_k (\nabla f(x_k), d_k) \\ &\quad (\text{si on néglige le terme d'ordre 2}) \end{aligned}$$

Une façon d'assurer l'inégalité $f(x_{k+1}) \leq f(x_k)$ est de choisir

$$d_k = -\nabla f(x_k)$$

car

$$f(x_{k+1}) \approx f(x_k) - s_k \|\nabla f(x_k)\|^2 \leq f(x_k)$$

Ceci motive l'algorithme du gradient

$$\left\{ \begin{array}{l} x_0 \text{ donné et } s_k > 0 \\ x_{k+1} = x_k - s_k \nabla f(x_k) \end{array} \right.$$

On dit que l'algo. est à pas constant si $s_k = s$.

Quelques notes sur le critère d'arrêt.

On peut utiliser un (ou une combinaison) des critères suivants pour arrêter les calculs.

- 1) Etant donné que $\nabla f(x_k) \rightarrow \nabla f(x) = 0$

$$\left| \frac{\partial f}{\partial x_i}(x_k) \right| < \epsilon \quad \forall i=1, \dots, n$$

2) On a que $x_k \xrightarrow[k \rightarrow \infty]{} x$

$$\|x_{k+1} - x_k\| < \epsilon$$

3) La suite $f(x_k) \rightarrow f(x)$

$$\|f(x_{k+1}) - f(x_k)\| < \epsilon$$

Exemple:

$$f(x) = \frac{1}{2} (Ax, x) - (b, x)$$

$$\nabla f(x) = Ax - b$$

Alg. du gradient:

$$\begin{cases} x_0 \text{ donne'} \\ x_{k+1} = x_k + \beta_k (b - Ax_k) \end{cases}$$

Voici un résultat de convergence de l'algorithme du gradient.

Théorème: Soit $f: \mathbb{R}^n \rightarrow \mathbb{R}$ une fonction de classe C^2 , ^{convexe,} coercive et admettant un seul minimum.

De plus, on suppose qu'il existe $m > 0$ t.q.

$$(H_f(x) v, v) \leq M \|v\|^2 \quad \forall v \in \mathbb{R}^n$$

Si on choisit les β_k dans l'intervalle

$$0 < \beta_1 \leq \beta_k \leq \beta_2 < \frac{2}{M}$$

alors la méthode du gradient converge.

Preuve: On utilise Taylor autour de x_k

$$x_{k+1} = x_k - \beta_k \nabla f(x_k)$$

$$f(x_{k+1}) = f(x_k) + (\nabla f(x_k), x_{k+1} - x_k)$$

$$+ \frac{1}{2} (\text{H}(x_k), x_{k+1} - x_k)$$

=)

$$f(x_{k+1}) - f(x_k) = -\frac{1}{\beta_k} \|x_{k+1} - x_k\|^2 + \frac{1}{2} (\text{H}(x_k), x_{k+1} - x_k)$$

$$\leq -\frac{1}{\beta_k} \|x_{k+1} - x_k\|^2 + \frac{M}{2} \|x_{k+1} - x_k\|^2$$

$$(*) \leq \left(\frac{M}{2} - \frac{1}{\beta_k} \right) \|x_{k+1} - x_k\|^2 < 0$$

car $\beta_k < 2/M \Rightarrow \frac{M}{2} - \frac{1}{\beta_k} < 0$

Par conséquent, la suite $\{f(x_k)\}$ est strictement décroissante et minorée par le minimum

$$f(x) = \min_{y \in U} f(y) \leq f(x_k) \quad \forall k$$

Ceci signifie que la suite $f(x_k)$ est convergente.

Ceci indique que la suite $\{x_k\}$ est bornée car sinon il existerait une sous-suite $\|x_{p_k}\| \rightarrow \infty$ et par coercivité de f

$$\Rightarrow f(x_{p_k}) \rightarrow \infty$$

ce qui contredit le fait que la suite $f(x_k)$ est convergente.

Maintenant, on utilise le critère de Bolzano-Weierstrass pour conclure qu'il existe une sous-suite x_{p_k} qui converge (de la suite originale x_k)

$$x_{p_k} \xrightarrow[k \rightarrow \infty]{} x^*$$

f est de classe C^2

$$\Rightarrow f(x_{k+1}) \rightarrow f(x^*)$$

$$\nabla f(x_{k+1}) \rightarrow \nabla f(x^*)$$

Mais
$$\nabla f(x_k) = \frac{x_{k+1} - x_k}{-s_k} \rightarrow 0$$

à cause de (*)

$$\nabla f(x_k) \approx 0$$

$$\nabla f(x^*) = 0$$

Par le fait que f soit convexe et admet un seul minimum

$$\Rightarrow x^* = x = \text{le pt. minimisant de } f$$

Il reste à montrer que toute la suite $x_k \xrightarrow[k \rightarrow \infty]{} x$

Par le même argument ci-dessus, on montre que toutes les sous-suites ~~convergentes~~ ^{convergentes} de x_k convergent vers la même limite $= x$.

En utilisant le fait que la suite originale x_k est bornée, ceci est suffisant pour conclure que l'algo. converge

$$x_k \xrightarrow[k \rightarrow \infty]{} x$$

Voici une situation intéressante où le théorème précédent s'applique.

$$f(x) = \frac{1}{2} (Ax, x) - (b, x) \quad \text{où } A > 0 \text{ et } b \in \mathbb{R}^n$$

En effet, f est coercive, convexe, de classe C^2 . De plus, on a que:

$$H_f(x) = A.$$

La fonction

$$R_A(v) = \frac{(Av, v)}{(v, v)}$$

est continue dans $\mathbb{R}^n \setminus \{0\}$ et atteint son maximum car

$$\max_{v \neq 0} R_A(v) = \max_{\|v\|=1} R_A(v)$$

et que $\{v \in \mathbb{R}^n \mid \|v\|=1\}$ est un ensemble fermé et borné dans \mathbb{R}^n .

Par conséquent, $\exists M > 0$ t. q.

$$\frac{(Av, v)}{(v, v)} \leq M \quad \forall v \neq 0$$

$$\exists \epsilon \quad (Av, v) \leq M \|v\|^2 \quad \forall v \in \mathbb{R}^n$$

Par conséquent, l'algo. du gradient converge pour le calcul du minimum de la fonction quadratique $f(x)$.

Dans la pratique, l'algo. du gradient à pas constant ($\beta_k = \beta$) est lent au voisinage du pt. minimisant. En effet

$$\begin{aligned} \nabla f(x_k) &\approx 0 \\ \Rightarrow \beta \nabla f(x_k) &\approx 0 \\ \Rightarrow x_{k+1} &= x_k - \beta \nabla f(x_k) \approx x_k \end{aligned}$$

Pour remédier à cette situation, on fait appel à la méthode du gradient à pas optimaux


$$\left\{ \begin{array}{l} \beta_0 \text{ donné} \\ x_{k+1} = x_k - \beta_k \nabla f(x_k) \end{array} \right.$$

où β_k^{opt} est choisi de sorte que

$$\min_{\beta} f(x_k - \beta \nabla f(x_k))$$

Pour le choix de β_k l'algo. du gradient à pas optimaux possède la propriété particulière

$$\nabla f(x_{k+1}) \perp \nabla f(x_k)$$



En général, il n'est pas facile de calculer le S_K optimal.
Par contre, dans le cas quadratique, la situation est facile.

Posons $f(x) = \frac{1}{2} (Ax, x) - (b, x) \quad A > 0$
 $b \in \mathbb{R}^n$

On définit le résidu au point x par

$$r = -Df(x) = b - Ax$$

L'algo. du gradient s'écrit :

$$x_{K+1} = x_K - S_K Df(x_K) = x_K + S_K r_K$$

$$\Rightarrow Ax_{K+1} - b = Ax_K - b + S_K Ar_K$$

$$\Rightarrow r_{K+1} = r_K - S_K Ar_K$$

La condition d'optimalité pour S_K est :

$$Df(x_{K+1}) \perp Df(x_K)$$

$$\Leftrightarrow (r_{K+1}, r_K) = 0$$

$$\Leftrightarrow (Ar_K - S_K Ar_K, r_K) = 0$$

$$\Rightarrow S_K = \frac{\|r_K\|^2}{(Ar_K, r_K)}$$

Remarque :

$$(Ar_K, r_K) = 0 \Leftrightarrow r_K = 0 \text{ car } A > 0$$

$$\text{et } r_K = b - Ax_K = 0 \Leftrightarrow Ax_K = b$$

$$x_K = x$$

" Nous avons atteint le minimum "