

Algorithme du gradient à pas optimal

Mohamed NASSIRI

Référence :

Analyse numérique des équations aux dérivées partielles, Laurent Di Menza, p.208 → 212
Exercices de mathématiques : Oraux X-ENS, XXX, Serge Francinou, Hervé Gianella et Serge Nicolas, p.208 → 212

Recasage :

- 219 : Extremums : existence, caractérisation, recherche. Exemples et applications.
- 223 : Suites numériques. Convergence, valeurs d'adhérence. Exemples et applications.
- 226 : Suites vectorielles et réelles définies par une relation de récurrence $u_{n+1} = f(u_n)$. Exemples. Applications à la résolution approchée d'équations.
- 229 : Fonctions monotones. Fonctions convexes. Exemples et applications.
- 253 : Utilisation de la notion de convexité en analyse.
- 203 : Utilisation de la notion de compacité.

Résumé :

Les méthodes de gradient sont des méthodes itératives où l'on a remplacé un système linéaire par un problème de minimisation. L'algorithme du gradient à pas optimal consiste à déterminer un pas optimal minimisant une certaine fonction.

Prérequis :

Méthodes itératives - Convexité - Matrices symétriques définies positives -

Théorème : (i) Soient A une matrice symétrique définie positive, $b \in \mathbb{R}^n$ et $c \in \mathbb{R}$. Alors les problèmes

$$\text{Trouver } x \in \mathbb{R}^n \text{ tel que } Ax = b \quad (\dagger)$$

et

$$\text{Trouver } x \in \mathbb{R}^n \text{ tel que } f(x) = \min_{y \in \mathbb{R}^n} f(y) \text{ avec } f(y) = \frac{1}{2} \langle Ay, y \rangle - \langle b, y \rangle + c, \quad y \in \mathbb{R}^n \quad (\dagger\dagger)$$

sont équivalents.

(ii) Pour une matrice A symétrique définie positive, l'algorithme itératif

$$\begin{cases} x^0 \in \mathbb{R}^n, r^0 = b - Ax^0 \\ x^{k+1} = x^k + \alpha_k r^k \\ r^{k+1} = r^k - \alpha_k Ar^k \\ \alpha_k = \frac{\|r_k\|^2}{\langle Ar^k, r^k \rangle} \end{cases}$$

appelé *méthode du gradient à pas optimal*, converge pour tout matrice symétrique définie positive.

Démonstration.

Etape 1 - Equivalence des deux problèmes :

\Rightarrow : Soit $x \in \mathbb{R}^n$ solution de (\dagger) . Pour tout $h \in \mathbb{R}^n$, on a

$$\begin{aligned} f(x+h) &= \frac{1}{2} \langle A(x+h), x+h \rangle - \langle b, x+h \rangle + c \\ &= \frac{1}{2} \langle Ax, x \rangle + \frac{1}{2} \langle Ax, h \rangle + \frac{1}{2} \langle Ah, x \rangle + \frac{1}{2} \langle Ah, h \rangle - \langle b, x \rangle - \langle b, h \rangle + c \quad \text{or } A = {}^t A \\ &\stackrel{\blacklozenge}{=} f(x) + \frac{1}{2} \langle Ax, h \rangle + \frac{1}{2} \langle {}^t A h, x \rangle - \langle b, h \rangle + \frac{1}{2} \langle Ah, h \rangle \quad \text{or } \langle {}^t A h, x \rangle = \langle Ax, h \rangle \\ &= f(x) + \underbrace{\langle Ax - b, h \rangle}_{=0 \text{ (}\dagger\text{)}} + \frac{1}{2} \underbrace{\langle Ah, h \rangle}_{>0 \text{ si } h \neq 0} > f(x) \end{aligned}$$

Donc x est bien un minimum pour la fonction f .

\Leftarrow : Soit $x \in \mathbb{R}^n$ solution de $(\dagger\dagger)$. Alors la différentielle de la fonction f est nulle en x . Donc pour tout $h \in \mathbb{R}^n$, on a

$$0 = Df(x)(h) \stackrel{\blacklozenge}{=} \frac{1}{2} \langle Ax, h \rangle + \frac{1}{2} \langle {}^t A h, x \rangle - \langle b, h \rangle = \langle Ax - b, h \rangle$$

Comme cette égalité est valable pour tout $h \in \mathbb{R}^n$, on en déduit que $Ax - b = 0$. Donc x est bien solution de (\dagger) .

Etape 2 - Une relation de récurrence pour la suite $(\langle A^{-1}r^k, r^k \rangle)_{k \in \mathbb{N}}$:

On rappelle que la valeur de α_k est telle que $\langle r^k, r^{k+1} \rangle = 0$. En effet, x^{k+1} est calculé à partir de x^k de telle façon que $f(x^{k+1})$ soit minimal (*i.e.*) on souhaite donc minimiser la fonction, de la variable α ,

$$g(\alpha) := f(x^{k+1}) = f(x^k + \alpha r^k)$$

On obtient donc

$$\alpha_k = \frac{\|r^k\|^2}{\langle Ar^k, r^k \rangle}$$

Par suite, on a bien

$$\begin{aligned} \langle r^k, r^{k+1} \rangle &= \langle r^k, r^k - \alpha_k Ar^k \rangle = \underbrace{\langle r^k, r^k \rangle}_{=\|r^k\|^2} - \alpha_k \langle r^k, Ar^k \rangle = 0 \end{aligned}$$

Par conséquent, on a

$$\begin{aligned} \langle A^{-1}r^{k+1}, r^{k+1} \rangle &= \langle A^{-1}(r^k - \alpha_k Ar^k), r^{k+1} \rangle \\ &= \langle A^{-1}r^k, r^{k+1} \rangle - \alpha_k \underbrace{\langle r^k, r^{k+1} \rangle}_{=0} \\ &= \langle A^{-1}r^k, r^k - \alpha_k Ar^k \rangle \\ &= \langle A^{-1}r^k, r^k \rangle - \alpha_k \langle A^{-1}r^k, Ar^k \rangle \\ &= \langle A^{-1}r^k, r^k \rangle - \alpha_k \|r^k\|^2 \end{aligned}$$

Ainsi, on en déduit l'appétissante relation de récurrence :

$$\frac{\langle A^{-1}r^{k+1}, r^{k+1} \rangle}{\langle A^{-1}r^k, r^k \rangle} = 1 - \frac{\|r^k\|^4}{\langle Ar^k, r^k \rangle \langle A^{-1}r^k, r^k \rangle} \quad (\sharp)$$

Lemme : Inégalité de Kantorovitch

Soient A une matrice symétrique définie positive, de valeurs propres $0 < \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$. Alors, pour $x \in \mathbb{R}^n$, on a l'inégalité

$$\langle Ax, x \rangle \langle A^{-1}x, x \rangle \leq \frac{(\lambda_1 + \lambda_n)^2}{4\lambda_1\lambda_n} \|x\|^4$$

Démonstration :

En notant (x_1, \dots, x_n) les coordonnées de x dans une base orthonormale de vecteurs propres de A , et en se rappelant que $\sqrt{ab} \leq \frac{1}{2}(a+b)$ pour $a, b \geq 0$, on a

$$\begin{aligned} \sqrt{\langle Ax, x \rangle \langle A^{-1}x, x \rangle} &= \sqrt{\left(\sum_{i=1}^n \lambda_i x_i^2 \right) \left(\sum_{i=1}^n \frac{1}{\lambda_i} x_i^2 \right)} \\ &= \sqrt{\frac{\lambda_1}{\lambda_n} \left(\sum_{i=1}^n \frac{\lambda_i}{\lambda_1} x_i^2 \right) \left(\sum_{i=1}^n \frac{\lambda_n}{\lambda_i} x_i^2 \right)} \\ &= \frac{1}{2} \sqrt{\frac{\lambda_1}{\lambda_n} \left(\left(\sum_{i=1}^n \frac{\lambda_i}{\lambda_1} x_i^2 \right) + \left(\sum_{i=1}^n \frac{\lambda_n}{\lambda_i} x_i^2 \right) \right)} \\ &= \frac{1}{2} \sqrt{\frac{\lambda_1}{\lambda_n} \left(\sum_{i=1}^n \left(\frac{\lambda_i}{\lambda_1} + \frac{\lambda_n}{\lambda_i} \right) x_i^2 \right)} \end{aligned}$$

Pour aller plus loin, on va tenter de maximiser la fonction $\varphi : x \rightarrow \frac{x}{\lambda_1} + \frac{\lambda_n}{x}$ sur l'intervalle $[\lambda_1, \lambda_n]$. Cette fonction est décroissante sur $[\lambda_1, \sqrt{\lambda_1 \lambda_n}]$ et croissante sur $[\sqrt{\lambda_1 \lambda_n}, \lambda_n]$. Elle admet donc un maximum en λ_1 ou en λ_n , et on a $\varphi(\lambda_1) = \varphi(\lambda_n) = 1 + \frac{\lambda_n}{\lambda_1}$. Ainsi, on peut majorer

$$\begin{aligned} \sqrt{\langle Ax, x \rangle \langle A^{-1}x, x \rangle} &= \frac{1}{2} \sqrt{\frac{\lambda_1}{\lambda_n} \left(\sum_{i=1}^n \left(1 + \frac{\lambda_n}{\lambda_1} \right) x_i^2 \right)} \\ &= \frac{1}{2} \sqrt{\frac{\lambda_1}{\lambda_n} \left(1 + \frac{\lambda_n}{\lambda_1} \right) \sum_{i=1}^n x_i^2} \\ &= \frac{1}{2} \left(\sqrt{\frac{\lambda_1}{\lambda_n}} + \sqrt{\frac{\lambda_n}{\lambda_1}} \right) \|x\|^2 \end{aligned}$$

En élevant au carré, on obtient l'inégalité voulue.

□

Etape 3 - On termine ... :

Grâce à l'inégalité de Kantorovitch, on a donc, à partir de (#) :

$$\begin{aligned} \frac{\langle A^{-1}r^{k+1}, r^{k+1} \rangle}{\langle A^{-1}r^k, r^k \rangle} &= 1 - \frac{\|r^k\|^4}{\langle Ar^k, r^k \rangle \langle A^{-1}r^k, r^k \rangle} \leq 1 - \frac{4\lambda_1\lambda_n}{(\lambda_1 + \lambda_n)^2} \frac{1}{\|r^k\|^4} \\ &= \left(\frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1} \right)^2 \end{aligned}$$

Par récurrence, on obtient donc

$$\langle A^{-1}r^k, r^k \rangle \leq \left(\frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1} \right)^{2k} \langle A^{-1}r^0, r^0 \rangle := \xi^{2k} \langle A^{-1}r^0, r^0 \rangle$$

avec $\xi = \frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1} < 1$. On en déduit donc que

$$\langle A^{-1}r^k, r^k \rangle \xrightarrow[k \rightarrow +\infty]{} 0$$

Or, puisque $\langle A^{-1}r^k, r^k \rangle \geq \frac{1}{\lambda_n} \|r^k\|^2$, on a donc

$$\|r^k\| \xrightarrow[k \rightarrow +\infty]{} 0$$

□

Remarques :

- **Explications de la méthode :**
- **Illustration :**
- **Importance de la symétrie :**
- **Propriétés de f :** strictement cvx, coercive avec les 1/2 mais aussi les A-1
- **Différentielle de f :** $f(y) = \frac{1}{2}\langle Ay, y \rangle - \langle b, y \rangle + c$, $y \in \mathbb{R}^n$

$$f(x + h) = f(x) + \frac{1}{2}\langle Ax, h \rangle + \frac{1}{2}\langle {}^t Ah, x \rangle - \langle b, h \rangle + \frac{1}{2}\langle Ah, h \rangle$$

- **Minimum de g :** Dans la démonstration, on souhaitait minimiser la fonction, de la variable α ,

$$g(\alpha) := f(x^{k+1}) = f(x^k + \alpha r^k)$$

et on a affirmé que $g'(\alpha) = \langle A(x^k + \alpha r^k) - b, r^k \rangle$. En effet,

$$\begin{aligned} f(x^k + \alpha r^k) &= \frac{1}{2}\langle A(x^k + \alpha r^k), x^k + \alpha r^k \rangle - \langle b, x^k + \alpha r^k \rangle + c \\ &= \frac{1}{2}\langle Ax^k, x^k \rangle + \frac{\alpha}{2}\langle Ax^k, r^k \rangle + \frac{\alpha}{2}\langle Ar^k, x^k \rangle + \frac{\alpha^2}{2}\langle Ar^k, r^k \rangle - \langle b, x^k \rangle - \alpha\langle b, r^k \rangle + c \\ &= f(x^k) + \alpha \underbrace{\langle Ax^k - b, r^k \rangle}_{=-r^k} + \frac{\alpha^2}{2}\langle Ar^k, r^k \rangle \\ &= f(x^k) - \alpha\|r^k\|^2 + \frac{\alpha^2}{2}\langle Ar^k, r^k \rangle \end{aligned}$$

Il s'agit d'un bon vieux polynôme de degré 2 en α donc le coefficient dominant est positif puisque A est symétrique définie positive. Le minimum est donc atteint en

$$\alpha = \alpha_k = \frac{\|r^k\|^2}{\langle Ar^k, r^k \rangle}$$

- **Minoration pour Kantorovitch :** En notant (x_1, \dots, x_n) les coordonées de x dans une base orthonormale de vecteurs propres de A et en appliquant l'inégalité de Cauchy-Schwarz, on a

$$\langle Ax, x \rangle \langle A^{-1}x, x \rangle = \left(\sum_{i=1}^n \lambda_i x_i^2 \right) \left(\sum_{i=1}^n \frac{1}{\lambda_i} x_i^2 \right) \geq \left(\sum_{i=1}^n \frac{\sqrt{\lambda_i}}{\sqrt{\lambda_i}} x_i^2 \right)^2 = \|x\|^4$$

Théorème :

Démonstration :

□

