

Algorithme du gradient à pas optimal

Leçons concernées

- * **162** : Systèmes d'équations linéaires ; opérations élémentaires, aspects algorithmiques et conséquences théoriques.
- * **219** : Extremums : existence, caractérisation, recherche. 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.
- * **233** : Analyse numérique matricielle. Résolution approchée de systèmes linéaires, recherche d'éléments propres, exemples.
- * **229** : Fonctions monotones. Fonctions convexes. Exemples et applications.
- * **253** : Utilisation de la notion de convexité en analyse.

Remarque importante : Favorisez la partie "lemme de Kantorovitch" si vous voulez inclure ce développement dans les leçons 229 et 253.

Référence

- * *Bernis - Analyse pour l'agrégation de mathématiques*

Le but de ce développement est d'étudier l'*algorithme du gradient à pas optimal*, appliqué à la fonctionnelle quadratique $\phi(x) = \frac{1}{2}\|x\|_A^2 - \langle x, b \rangle$, où $A \in \mathcal{M}_n(\mathbb{R})$ est symétrique définie positive.

Théorème. *L'application ϕ atteint son minimum en un unique vecteur \bar{x} .*

Soit de plus, pour $a \in \mathbb{R}^n$ donné, la suite (x_k) définie par récurrence par les relations :

$$\begin{cases} x_0 & = & a \\ x_{k+1} & = & x_k & \text{si } \nabla\phi(x_k) = 0 \\ x_{k+1} & = & x_k - \alpha_k \nabla\phi(x_k) & \text{sinon, avec } \alpha_k = \operatorname{argmin}_{t>0} [\phi(x_k - t\nabla\phi(x_k))] \end{cases}$$

Alors (x_k) converge vers \bar{x} , et on a de plus l'estimation de la vitesse de convergence :

$$\forall k \in \mathbb{N}, \|x_{k+1} - \bar{x}\| \leq \sqrt{\frac{\lambda_{\max}}{\lambda_{\min}}} \left(\frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}} \right)^{k+1} \|x_0 - \bar{x}\|$$

où $\|\cdot\|$ désigne la norme euclidienne, λ_{\max} (resp. λ_{\min}) la plus grande (resp. petite) valeur propre de A

La preuve va s'appuyer sur le lemme suivant, que nous allons démontrer :

Lemme. (de Kantorovitch)

Pour tout x non nul de \mathbb{R}^n , on a :
$$\frac{\|x\|^4}{\|x\|_{A^{-1}}^2 \|x\|_A^2} \geq 4 \frac{\lambda_{max} \lambda_{min}}{(\lambda_{max} + \lambda_{min})^2}$$

Preuve du lemme : Par le théorème spectral, A admet une base orthonormée de vecteurs propres (e_1, \dots, e_n) associés aux valeurs propres strictement positives $(\lambda_1, \dots, \lambda_n)$. Ecrivons $x = \sum_{i=1}^n x_i e_i$. Alors :

$$\begin{aligned} \|x\|_A \|x\|_{A^{-1}} &= \sqrt{\sum_{i=1}^n \lambda_i x_i^2} \sqrt{\sum_{i=1}^n \frac{1}{\lambda_i} x_i^2} \\ &= \sqrt{\frac{\lambda_{max}}{\lambda_{min}}} \sqrt{\sum_{i=1}^n \frac{\lambda_i}{\lambda_{max}} x_i^2} \sqrt{\sum_{i=1}^n \frac{\lambda_{min}}{\lambda_i} x_i^2} \\ &\leq \frac{1}{2} \sqrt{\frac{\lambda_{max}}{\lambda_{min}}} \sum_{i=1}^n \left(\frac{\lambda_i}{\lambda_{max}} + \frac{\lambda_{min}}{\lambda_i} \right) x_i^2 \end{aligned}$$

en utilisant l'inégalité $ab \leq \frac{a^2+b^2}{2}$ valable pour tout réels a et b .

Or, $t \in [\lambda_{min}; \lambda_{max}] \rightarrow \frac{t}{\lambda_{max}} + \frac{\lambda_{min}}{\lambda_i}$ est une fonction convexe, en tant que somme de fonctions convexes. Donc, $\forall i, g(\lambda_i) \leq g(\lambda_{min}) = g(\lambda_{max}) = 1 + \frac{\lambda_{min}}{\lambda_{max}}$.

On a alors au final :

$$\|x\|_A \|x\|_{A^{-1}} \leq \frac{1}{2} \frac{\lambda_{max} + \lambda_{min}}{\sqrt{\lambda_{max} \lambda_{min}}} \|x\|^2$$

En élevant au carré, on retrouve alors le résultat.

Preuve du théorème : Tout d'abord, ϕ est continue coercive, donc admet un minimum. Ce minimum est en particulier un point critique. Or, $\forall x \in \mathbb{R}^n, \nabla \phi(x) = Ax - b$. Donc les points critiques sont solutions de $Ax = b$, et il n'y en a qu'une seule, que nous allons noter \bar{x} . En particulier, il n'y a qu'un seul minimum, et il ne peut être que \bar{x} , d'où l'intérêt de l'algorithme du gradient.

Soit $k \in \mathbb{N}$ tel que $\nabla \phi(x_k) \neq 0$.

Commençons par exprimer x_{k+1} en cherchant α_k . Soit f définie par : $\forall t \in \mathbb{R}, f(t) = \phi(x_k - t \nabla \phi(x_k))$. Alors un calcul direct donne $\forall t \in \mathbb{R}, f(t) = \phi(x_k) - t \langle Ax_k - b, \nabla \phi(x_k) \rangle + \frac{t^2}{2} \|\nabla \phi(x_k)\|_A^2$ soit $f(t) = \phi(x_k) - t \|\nabla \phi(x_k)\|^2 + \frac{t^2}{2} \|\nabla \phi(x_k)\|_A^2$. On en déduit que le minimum est atteint en $\alpha_k = \frac{\|\nabla \phi(x_k)\|^2}{\|\nabla \phi(x_k)\|_A^2}$. En particulier, $f'(\alpha_k) = 0$ soit $-\langle \nabla \phi(x_k - \alpha_k \nabla \phi(x_k)), \nabla \phi(x_k) \rangle = 0$ soit $\langle \nabla \phi(x_{k+1}), \nabla \phi(x_k) \rangle = 0$, ce qui sera utile par la suite.

Notons pour alléger $g_k = \nabla \phi(x_k)$. Estimons l'erreur en norme A :

$$\|x_{k+1} - \bar{x}\|_A^2 = \langle A(x_{k+1} - \bar{x}), x_{k+1} - x_k \rangle + \langle A(x_{k+1} - \bar{x}), x_k - \bar{x} \rangle$$

Or, $x_{k+1} - x_k = -\alpha_k g_k$ et $A(x_{k+1} - \bar{x}) = Ax_{k+1} - b = g_{k+1}$. Donc, g_k et g_{k+1} étant orthogonaux, le premier terme est nul.

Donc, en se rappelant que A est symétrique :

$$\begin{aligned}
\|x_{k+1} - \bar{x}\|_A^2 &= \langle A(x_{k+1} - x_k), x_k - \bar{x} \rangle + \langle A(x_k - \bar{x}), x_k - \bar{x} \rangle \\
&= \langle x_{k+1} - x_k, A(x_k - \bar{x}) \rangle + \|x_k - \bar{x}\|_A^2 \\
&= -\alpha_k \langle g_k, g_k \rangle + \|x_k - \bar{x}\|_A^2 \\
&= -\frac{\|g_k\|_A^4}{\|g_k\|_A^2} + \|x_k - \bar{x}\|_A^2
\end{aligned}$$

Or, $\|x_k - \bar{x}\|_A^2 = \langle A(x_k - \bar{x}), x_k - \bar{x} \rangle = \langle g_k, A^{-1}(Ax_k - b) \rangle = \|g_k\|_{A^{-1}}^2$. Au final :

$$\|x_{k+1} - \bar{x}\|_A^2 = \left(1 - \frac{\|g_k\|_A^4}{\|g_k\|_A^2 \|g_k\|_{A^{-1}}^2}\right) \|x_k - \bar{x}\|_A^2$$

On reconnaît un terme qui fait penser au lemme de Kantorovitch. On obtient ainsi :

$$\begin{aligned}
\|x_{k+1} - \bar{x}\|_A^2 &\leq \left(1 - 4 \frac{\lambda_{max} \lambda_{min}}{(\lambda_{max} + \lambda_{min})^2}\right) \|x_k - \bar{x}\|_A^2 \\
\|x_{k+1} - \bar{x}\|_A &\leq \left(\frac{\lambda_{max} - \lambda_{min}}{\lambda_{max} + \lambda_{min}}\right) \|x_k - \bar{x}\|_A \\
\|x_{k+1} - \bar{x}\|_A &\leq \left(\frac{\lambda_{max} - \lambda_{min}}{\lambda_{max} + \lambda_{min}}\right)^{k+1} \|x_0 - \bar{x}\|_A
\end{aligned}$$

Ceci suffit à prouver la convergence de l'algorithme du gradient. On va cependant affiner notre inégalité pour travailler, à la place, avec la norme euclidienne. On remarque tout d'abord, en décomposant dans la base de vecteur propre de A , que :

$$\sqrt{\lambda_{min}} \|\cdot\| \leq \|\cdot\|_A \leq \sqrt{\lambda_{max}} \|\cdot\|$$

Ceci donne alors :

$$\|x_{k+1} - \bar{x}\| \leq \sqrt{\frac{\lambda_{max}}{\lambda_{min}}} \left(\frac{\lambda_{max} - \lambda_{min}}{\lambda_{max} + \lambda_{min}}\right)^{k+1} \|x_0 - \bar{x}\|$$

Remarque : On peut observer l'influence du conditionnement de A sur la vitesse de convergence. Sachant que A est symétrique définie positive, on a alors $cond(A) = \frac{\lambda_{max}}{\lambda_{min}}$. L'inégalité devient ainsi :

$$\|x_{k+1} - \bar{x}\| \leq \sqrt{cond(A)} \left(\frac{cond(A) - 1}{cond(A) + 1}\right)^{k+1} \|x_0 - \bar{x}\|$$

On observe alors que plus le conditionnement de A est proche de 1, plus la convergence est rapide, et inversement.

Donnons un complément utile, car très proche de l'algorithme du gradient à pas optimal. Il existe un autre algorithme, assez analogue, appelé *algorithme du gradient conjugué*. Soit $r_k = b - Ax_k = -g_k$. Nous avons vu précédemment que pour tout k , $r_k \perp r_{k+1}$. On a donc une relation d'orthogonalité intéressante, mais que pour les résidus d'ordre k et $k+1$ à chaque étape k .

Soit $K_k = \text{Vect}(r_0, \dots, r_k)$. On peut, pour améliorer l'algorithme, demander à ce que x_{k+1} vérifie :

$$x_{k+1} \in (x_0 + K_k) \text{ et } r_{k+1} = b - Ax_{k+1} \perp K_k$$

Ceci définit l'algorithme du gradient conjugué. On constate alors que nous avons une relation d'orthogonalité plus forte que pour l'algorithme du gradient à pas optimal : cette fois-ci, r_{k+1} est orthogonal à la famille (r_0, \dots, r_k) ! En particulier, la famille des résidus est une famille libre de \mathbb{R}^n . Ceci garantit alors que cet algorithme converge en au plus n itérations, rang à partir duquel la suite devient constante égale à \bar{x} .

On peut démontrer que K_k est l'espace de Krylov associé à r_0 , c'est-à-dire $K_k = \text{Vect}(r_0, Ar_0, \dots, A^k r_0)$. On peut alors dans la pratique prendre une base orthogonale (p_k) de cet espace de Krylov, pour le produit scalaire $\langle \cdot, \cdot \rangle_A$. On parle alors de vecteurs *conjugués par rapport à A*, d'où le nom de l'algorithme.