

TD-TP4. Méthodes de gradient

**Rappels : Principe des méthodes de gradient.**

Soit  $A \in \mathcal{M}_n(\mathbb{R})$  une matrice symétrique définie positive. Résoudre  $Ax = b$  est équivalent à minimiser

$$f : x \in \mathbb{R}^n \mapsto \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle. \quad (1)$$

En effet, le minimiseur  $\bar{x}$  de  $f$  (qui existe et qui est unique puisque  $f$  est strictement convexe et coercive) vérifie  $\nabla f(\bar{x}) = 0$ . Or  $\nabla f(x) = Ax - b$ .

Une méthode de descente est une méthode itérative qui approche le minimiseur de  $f$  (et donc la solution de  $Ax = b$ ) en construisant la suite  $(x_k)_{k \in \mathbb{N}}$  :

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

Dans ce qui précède, pour  $k \in \mathbb{N}$ ,

- $\alpha_k > 0$  est le pas de la méthode,
- $d_k \in \mathbb{R}^n$  est une direction de descente, c'est-à-dire un vecteur de  $\mathbb{R}^n$  tel que  $\langle \nabla f(x_k), d_k \rangle \leq 0$ . Lorsque l'inégalité précédente est stricte, on parle de direction stricte de descente.
- On définira aussi le résidu  $r_k$  par  $r_k = \nabla f(x_k) = Ax_k - b$ .

**Exemples de méthodes de descente**

**Méthode de gradient à pas fixe**

Pour tout  $k \geq 0$ ,

- la direction de descente vaut  $d_k = -\nabla f(x_k) = b - Ax_k$
- le pas de descente est fixé :  $\alpha_k = \alpha > 0$

**Méthode de gradient à pas optimal**

Pour tout  $k \geq 0$ ,

- la direction de descente vaut  $d_k = -\nabla f(x_k) = b - Ax_k$
  - le pas de descente est choisi de manière optimale :  $\alpha_k = \operatorname{argmin}_{\alpha > 0} f(x_k - \alpha \nabla f(x_k))$ .
- Pour la fonction quadratique  $f$  définie par (1), on a  $\alpha_k = \frac{\langle r_k, r_k \rangle}{\langle Ar_k, r_k \rangle}$ .

**Méthode de gradient conjugué**

Pour tout  $k \geq 0$ ,

- la direction de descente vaut

$$d_k = -r_k + \frac{\langle Ar_k, d_{k-1} \rangle}{\langle Ad_{k-1}, d_{k-1} \rangle} d_{k-1}, \text{ avec l'initialisation } d_0 = -r_0 = b - Ax_0,$$

- le pas de descente est choisi de manière optimale :  $\alpha_k = \operatorname{argmin}_{\alpha > 0} f(x_k + \alpha d_k)$ .

Pour la fonction quadratique  $f$  définie par (1), on a  $\alpha_k = -\frac{\langle r_k, d_k \rangle}{\langle Ad_k, d_k \rangle}$ .

## 1 Compréhension des méthodes

**Exercice 1 : Questions de cours**

Méthode du gradient à pas fixe :

1. Montrer que  $d_k = -\nabla f(x_k)$  est une direction de descente stricte.

Méthode du gradient à pas optimal :

2. Montrer que, pour  $f$  définie par (1), le pas de descente vaut  $\alpha_k = \frac{\langle r_k, r_k \rangle}{\langle Ar_k, r_k \rangle}$ .

Méthode du gradient conjugué :

3. Montrer que les résidus vérifient la relation de récurrence suivante :  $r_{k+1} = r_k + \alpha_k Ad_k, \forall k \geq 0$ .
4. Montrer que, pour tout  $k \geq 0, \langle r_{k+1}, d_k \rangle = 0$ .
5. En déduire que  $d_k$  est une direction de descente stricte.

### Exercice 2 : Convergence de la méthode du gradient conjugué

On suppose que l'on n'a pas encore convergé à l'itération  $k$ , ce qui signifie que  $r_p \neq 0$  pour tout  $0 \leq p \leq k$ .

1. Montrer, par récurrence, que  $\langle r_k, d_p \rangle = 0$ , pour tout  $0 \leq p < k$  (on pourra se servir de la question (4) de l'exercice 1).
2. Montrer, par récurrence, que  $\langle r_k, r_p \rangle = 0$ , pour tout  $0 \leq p < k$  puis que  $\langle Ad_k, d_p \rangle = 0$ , pour tout  $0 \leq p < k$ .
3. En déduire que les  $(d_k)_{0 \leq k \leq n}$  forment une famille libre, tant que  $r_k \neq 0$ .
4. En déduire qu'il existe  $k_0 \leq n$  tel que  $r_{k_0} = 0$ , puis que la suite  $(x_k)_{k \in \mathbb{N}}$  converge. En combien d'itérations (au plus) la suite converge-t-elle ?
5. Remarque : Montrer que  $\frac{\langle Ar_k, d_{k-1} \rangle}{\langle Ad_{k-1}, d_{k-1} \rangle} = \frac{\|r_k\|^2}{\|r_{k-1}\|^2}$ . La direction de descente de la méthode du gradient conjugué peut donc être calculée par  $d_k = -r_k + \frac{\|r_k\|^2}{\|r_{k-1}\|^2} d_{k-1}$ , avec l'initialisation  $d_0 = -r_0$ .

### Exercice 3 : Méthode de Jacobi vue comme une méthode de descente

On considère la fonction

$$f : x \mapsto \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle$$

avec  $A$  une matrice de  $\mathcal{M}_n(\mathbb{R})$  symétrique définie positive et  $b$  un vecteur de  $\mathbb{R}^n$ .

1. Montrer que la méthode itérative de Jacobi (utilisée pour résoudre le système  $Ax = b$ ) peut s'écrire comme une méthode de descente à pas fixe pour la minimisation de  $f$ . On l'appellera la *méthode de descente de Jacobi*. Donner l'expression du pas de descente  $\alpha$  et de la direction de descente  $d_k$ .
2. Vérifier que ce  $d_k$  est bien une direction de descente (stricte) pour tout  $k \geq 0$ .
3. On souhaite améliorer la *méthode de descente de Jacobi* en prenant non plus un pas fixe  $\alpha$  dans l'algorithme mais un pas optimal, défini à l'itération  $k$  par

$$f(x_k + \alpha_k d_k) = \min_{\alpha > 0} f(x_k + \alpha d_k).$$

On conserve la même direction de descente  $d_k$  que pour la *méthode de descente de Jacobi*. On parlera dans la suite de *méthode de descente de Jacobi à pas optimal*.

- (a) Justifier l'existence et l'unicité de ce pas optimal  $\alpha_k$ .
  - (b) Donner son expression à chaque itération.
4. On suppose maintenant que la diagonale extraite de la matrice  $A$  s'écrit  $D = \beta I_n$ , avec  $I_n$  la matrice identité.
    - (a) Écrire la *méthode de descente de Jacobi* dans ce cas particulier et la *méthode de descente de Jacobi à pas optimal*.
    - (b) Quel(s) algorithme(s) de descente vu(s) en classe reconnaissez-vous ?

## 2 Implémentation python

### Exercice 4 : Méthode du gradient à pas fixe : illustration graphique

On va illustrer numériquement le principe de la méthode de gradient à pas fixe en s'assurant que la suite des itérées  $(x_k)_{k \in \mathbb{N}}$  converge bien vers le minimum de  $f : x \mapsto \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle$ .

1. Écrire une fonction python `GradientPasFixe`, qui à partir de  $A$  une matrice symétrique définie positive,  $b$  un vecteur de  $\mathbb{R}^n$ ,  $\alpha$  un pas de descente,  $x_0$  un vecteur initialisation,  $\varepsilon > 0$  la précision voulue et  $k_{max}$  le nombre maximal d'itérations renvoie la valeur approchée de la solution de  $Ax = b$ . On utilisera pour critère d'arrêt le critère suivant  
`arrêt lorsque  $\|Ax_k - b\| \leq \varepsilon$  ou  $k > k_{max}$ .`
2. Appliquer cette fonction à  $f(x, y) = 2x^2 + 3x + y^2$  et  $g(x, y) = x^2 + y^2 - 2y$ . On prendra soin d'explicitier les matrices  $A_f, A_g$  et les vecteurs  $b_f$  et  $b_g$  correspondants. On pourra par exemple prendre une précision de  $\varepsilon = 10^{-10}$ , un pas  $\alpha = 0.01$  et on pourra partir de  $x_0 = (7.5, 5)^t$ . Vérifier que le nombre total d'itérations n'atteint pas votre  $k_{max}$ .
3. Vérifier que le résultat fourni par votre fonction `GradientPasFixe` est bien le même que celui obtenu par une méthode itérative (Jacobi ou Gauss-Seidel par exemple).
4. On va visualiser graphiquement la suite  $(x_k)_{k \in \mathbb{N}}$  obtenue par la méthode de gradient à pas fixe.
  - (a) Créer une grille de taille  $[-10, 10] \times [-10, 10]$ . Les abscisses des nœuds de cette grille seront stockés dans un vecteur  $X$  et les ordonnées dans  $Y$ . Pour cela, on pourra utiliser le code  

```
X_bord = np.arange(-10, 10, 0.01)
Y_bord = np.arange(-10, 10, 0.01)
X, Y = np.meshgrid(X_bord, Y_bord)
```
  - (b) Tracer les lignes de niveau de la fonction  $f$  au moyen de la commande `plt.contour(X, Y, f(X, Y))`.
  - (c) Afficher, sur la figure, les points  $(x_k)_{k \in \mathbb{N}}$  au moyen d'un marqueur `o`. On pourra pour cela modifier notre fonction python `GradientPasFixe` pour qu'elle ressorte la liste des abscisses et des ordonnées des  $(x_k)_{k \in \mathbb{N}}$ . La figure est-elle conforme à nos attentes ?
  - (d) Dans une seconde figure, afficher la liste des itérées  $(x_k)_{k \in \mathbb{N}}$  et les lignes de niveau pour la fonction  $g$ .

### Exercice 5 : Matrice de Hilbert

On veut résoudre  $Ax = b$  pour  $A$  la matrice de Hilbert de terme général  $a_{i,j} = \frac{1}{i+j-1}$ , pour  $1 \leq i, j \leq N$ . On notera  $\bar{x}$  la solution.

1. Écrire une fonction `MatHilbert(N)` afin d'implémenter la matrice  $A$  en python (attention, les indices en python commencent à 0, il faut donc adapter la formule de  $a_{i,j}$ ).
2. Coder l'algorithme de gradient à pas optimal dans une fonction `GradientOptimal`, qui prend en argument une matrice  $A$  symétrique définie positive, un vecteur  $b$ , une initialisation  $x_0$ , une précision  $\varepsilon$  et un nombre maximal d'itérations  $k_{max}$  et qui redonne en sortie l'approximation de  $\bar{x}$  par la méthode du gradient à pas optimal ainsi que le nombre effectif d'itérations.
3. De même, coder une fonction `GradientConjugué` avec les mêmes arguments et les mêmes sorties que précédemment mais pour la méthode du gradient conjugué.
4. Comparer ces deux méthodes avec  $A$  la matrice de Hilbert de taille  $N = 10$ ,  $b = A^{-1}\bar{x}$  où  $\bar{x} = (1, 1, \dots, 1)^t$ . On pourra prendre une précision de  $\varepsilon = 10^{-10}$ . Quel est le résultat (théorique) attendu ? Quels sont les résultats numériques ? Comparer le nombre effectif d'itérations pour ces deux méthodes : pouvait-on prévoir un nombre maximal d'itérations pour la méthode du gradient conjugué (si oui, lequel) ?

### Exercice 6 : Comparaison des vitesses de convergence

On prendra dans cet exercice  $A = \begin{pmatrix} 1 & & & 0 \\ & 2 & & \\ & & 3 & \\ & & & \ddots \\ 0 & & & & N \end{pmatrix}$  et  $b$  tel que la solution  $\bar{x}$  recherchée soit

$$\bar{x} = (1 \ 1 \ \dots \ 1)^t.$$

1. Modifier vos fonctions `GradientPasFixe`, `GradientOptimal` et `GradientConjugué` pour qu'elles ressortent (en plus des sorties précédentes) la liste des erreurs  $\|\bar{x} - x_k\|$  pour  $k \geq 0$ . On pourra calculer  $\bar{x}$  avec la commande `np.linalg.solve(A,b)`.
2. Sur un même graphique, comparez les vitesses de convergence de ces trois méthodes pour  $N = 100$ . Pour cela, afficher les erreurs en fonction du nombre d'itérations (pour la méthode de gradient à pas fixe, on pourra prendre le pas  $\alpha = 0.01$ ). On affichera les courbes avec une échelle logarithmique en ordonnée au moyen de la commande `plt.yscale('log')`. Penser à mettre un titre, des légendes et des couleurs différentes à vos courbes.

## 3 Pour aller plus loin : minimisation sur un sous-espace vectoriel

### Exercice 7 : Minimisation d'une fonctionnelle quadratique

Soient  $A \in \mathcal{M}_n(\mathbb{R})$  une matrice symétrique définie positive et  $b, c, d$  trois vecteurs de  $\mathbb{R}^n$  avec  $d \neq 0$ . On cherche à minimiser  $f : x \mapsto \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle$  sur  $K = \{x \in \mathbb{R}^n, \langle d, x \rangle = c\}$ .

1. Montrer que l'ensemble  $K$  est non vide, fermé et convexe. En déduire que  $f$  admet un unique minimiseur sur  $K$ .
2. Montrer que si  $\bar{x}$  est le minimiseur de  $f$  sur  $K$  alors il existe  $\lambda \in \mathbb{R}$  tel que  $y = (\bar{x}, \lambda)^t$  soit l'unique solution du système  $\begin{pmatrix} A & d \\ d^t & 0 \end{pmatrix} y = \begin{pmatrix} b \\ c \end{pmatrix}$ .

### Exercice 8 : Applications concrètes de la minimisation

On cherche à maximiser l'aire d'un rectangle de périmètre  $\ell$  donné.

1. Montrer que ce problème peut se réécrire sous la forme d'un problème de minimisation sur un sous-espace vectoriel  $K$ .
2. À l'aide des multiplicateurs de Lagrange, résoudre ce problème d'optimisation.

On étudie maintenant le solide  $S$  constitué d'un cylindre de hauteur  $h$  et de rayon  $r$  et de deux demi-sphères de rayon  $r$  (voir figure 1). On cherche à minimiser sa surface pour un volume fixe de  $\frac{32}{3}\pi$ .

3. Réécrire ce problème sous la forme d'un problème d'optimisation sous contrainte et le résoudre au moyen d'un multiplicateur de Lagrange.




FIGURE 1 – Solide  $S$