

Optimisation quadratique

Table des matières

1	Existence et unicité d'un minimum	1
1.1	Notations	1
1.2	Problème	1
1.3	Existence	1
1.4	Convexité et unicité	1
1.4.1	Projection sur un convexe fermé	2
1.4.2	Propriété des fonctions convexes	2
2	Conditions d'optimalité	3
2.1	Cas général	3
2.2	Cas convexe	3
2.3	Contraintes d'égalité affines	4
2.4	Le lagrangien	4
2.5	Fonctionnelle quadratique et contraintes d'égalité affines	4
2.6	Contraintes d'inégalité affines	5
3	Algorithmes pour problèmes sans contraintes, fonctionnelle quadratique	5
3.1	Taux et vitesse de convergence	6
3.2	Méthode de descente	6
3.2.1	Pas optimal – fonctionnelle quadratique	6
3.2.2	Relaxation	6
3.2.3	Gradient à pas fixe	7
3.2.4	Méthode du gradient à pas optimal	7
3.2.5	Gradient conjugué	7
3.2.6	Méthodes itératives	8
4	Algorithme pour les problèmes contraints	9
4.1	Méthode du gradient projeté	9
4.2	Méthode d'UZAWA	9

1 Existence et unicité d'un minimum

1.1 Notations

On considère E l'espace vectoriel \mathbf{R}^n , k un sous-ensemble non vide de E et J une *fonctionnelle continue* définie sur K à valeur dans \mathbf{R} .

1.2 Problème

Trouver $u \in K$, tel que $J(u) = \inf_{v \in K} J(v)$.

1.3 Existence

Définition : Minimum local–global

$u \in K$ est un **point de minimum local** de J sur K si, et seulement si

$$\exists \eta > 0, \forall v \in K, \|v - u\| < \eta \Rightarrow J(u) \leq J(v)$$

$u \in K$ est un **minimum global** de J sur K si, et seulement si

$$\forall v \in K, J(u) \leq J(v)$$

Définition : Suite minimisante

On dit qu'une suite $(u_k)_{k \in \mathbb{N}}$ d'éléments de K est une **suite minimisante** si et seulement si

$$\lim_{k \rightarrow +\infty} J(u_k) = \inf_{v \in K} J(v)$$

Théorème : (rappel)

Si K est compact et J continue sur K , alors J atteint ses extrema.

Définition :

On dit qu'une fonctionnelle J est **infinie à l'infini** si, et seulement si :

$$\text{pour toute suite } (u_n)_n \in K^n, \lim_{n \rightarrow +\infty} \|u_n\| = +\infty \Rightarrow \lim_{n \rightarrow +\infty} J(u_n) = +\infty$$

Théorème : Existence d'un minimum global

Dans le cas où $E = \mathbb{R}^n$, si K est un fermé, et si J est continue et infinie à l'infini dans K , alors elle admet un **minimum global** sur K . De plus, de toute suite minimisante, on peut extraire une sous-suite qui converge vers un point de minimum.

1.4 Convexité et unicité

Définition : Ensemble convexe

On dit qu'un sous-ensemble K de E est convexe si, et seulement si, pour tout couple d'éléments (u, v) , le segment $[u, v]$ est inclus dans K :

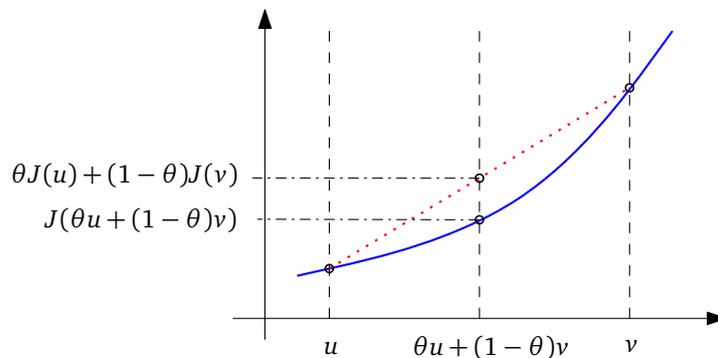
$$\forall (u, v) \in K^2, \forall t \in [0, 1], tv + (1 - t)u \in K$$

Définition : Fonctionnelle convexe

Soit J une fonctionnelle définie sur un sous-ensemble convexe non vide K de E , à valeurs dans \mathbb{R} . On dit que J est **convexe** si et seulement si :

$$\forall (u, v) \in K^2, u \neq v, \forall \theta \in]0, 1[, J(\theta u + (1 - \theta)v) \leq \theta J(u) + (1 - \theta)J(v)$$

Dans le cas d'une inégalité stricte, on dit que la fonctionnelle est **strictement convexe**.



Propriété

Soit J une fonctionnelle convexe définie sur un convexe non vide K :

- 1 si u et v sont deux points de minimum locaux, alors $J(u) = J(v)$;
- 2 si en plus, J est strictement convexe alors $u = v$.

Théorème :

Soit J une fonctionnelle convexe définie sur un convexe non vide K de E :

- 1 tout point de minimum local est un point de minimum globale ;
- 2 si de plus J est *strictement* convexe, le point de minimum, s'il existe, est *unique*.

1.4.1 Projection sur un convexe fermé

Définition :

Pour tout w de E , on définit sa projection sur un convexe fermé K $P_K(w)$ comme l'élément u tel que :

$$\|w - u\| = \min_{v \in K} \|w - v\|$$

Propriété

Si K est un convexe fermé, alors tout élément w de E admet une projection *unique* $P_K(w)$ sur K . De plus l'application $w \mapsto P_K(w)$ est *contractante*.

1.4.2 Propriété des fonctions convexes

Théorème :

Soit J une fonctionnelle différentiable sur un sous-ensemble K convexe non vide. Les assertions suivantes sont équivalentes :

- 1 J est convexe sur K .
- 2 $\forall (u, v) \in K^2, u \neq v$:
$$J(v) \geq J(u) + \langle \nabla J(u), v - u \rangle.$$
- 3 $\forall (u, v) \in K^2, u \neq v$:
$$\langle \nabla J(u) - \nabla J(v), u - v \rangle \geq 0.$$

Pour la stricte convexité, on a des inégalité strictes.

Théorème : classe \mathcal{C}^2

Soit J une fonctionnelle de E dans \mathbf{R} de classe \mathcal{C}^2 . Alors J est convexe si, et seulement si,

$$\forall (u, d) \in E^2, \langle \nabla^2 J(u)d, d \rangle \geq 0.$$

2 Conditions d'optimalité

2.1 Cas général

Définition : Cône des directions admissibles

Soit K un sous-ensemble non vide de E , et v un point de K . On appelle cône des directions admissibles l'ensemble \mathcal{T}_K des tangentes en v aux chemins inclus dans K et commençants en v .

Théorème :

Soient K un sous-ensemble non vide de E , u un point de K et J une fonctionnelle de K dans \mathbf{R} . On suppose que J est FRECHET-différentiable en u . Si u est un point de minimum local de J sur K , on a nécessairement :

$$\forall w \in \mathcal{T}_K, \quad \langle \nabla J(u), w \rangle \geq 0$$

Propriété

Si $K = E$ ou si le minimum u est intérieur à K alors l'inéquation ci-dessus devient :

$$\nabla J(u) = 0$$

2.2 Cas convexe

Ici on se place dans le cas où K est convexe.

Théorème : Inéquation d'Euler

Soient K un sous-ensemble convexe non vide de E , u un point de K et J une fonctionnelle de K dans \mathbf{R} . On suppose que J est différentiable en u . Si u est un point de minimum local de J sur K , on a nécessairement

$$\forall v \in K, \quad \langle \nabla J(u), v - u \rangle \geq 0$$

Théorème : J convexe

Soient K un sous-ensemble convexe non vide de E , u un point de K et J une fonctionnelle de K dans \mathbf{R} . On suppose que J est **convexe** et différentiable en u . Si u est un point de minimum local de J sur K **si, et seulement si**

$$\forall v \in K, \quad \langle \nabla J(u), v - u \rangle \geq 0$$

2.3 Contraintes d'égalité affines

On suppose ici que l'ensemble K est défini par :

$$K = \{v \in \mathbf{R}^n / Cv = f\}$$

où C est une matrice $p \times n$ et f un élément de \mathbf{R}^p (on suppose $K \neq \emptyset$). On remarque que K est un convexe non vide.

Théorème : (Karush, Kuhn et Tucker)

Soit $C \in \mathcal{M}_{p,n}(\mathbf{R})$ et $f \in \mathbf{R}^p$, K le sous-espace défini par $K = \{v \in \mathbf{R}^n / Cv = f\}$, u un point de K et J une fonctionnelle différentiable en u .

Si u est un point de minimum local de J sur K , on a **nécessairement** :

$$\begin{cases} \exists \lambda \in \mathbf{R}^p, & \nabla J(u) + {}^t C \lambda = 0 \\ Cu - f = 0 \end{cases}$$

2.4 Le lagrangien

Définition : Le lagrangien

On définit la fonctionnelle (appelée le *lagrangien* du système) :

$$\forall (v, \mu) \in e \times \mathbf{R}^p, \quad \mathcal{L}(v, u) = J(v) + \langle \mu C v - f \rangle$$

Les éléments μ de \mathbf{R}^p sont appelés les **multipliateurs de LAGRANGE**.

Propriété

Soit $C \in \mathcal{M}_{p,n}(\mathbf{R})$ et $f \in \mathbf{R}^p$, K le sous-espace défini par $K = \{v \in \mathbf{R}^n / C v = f\}$, u un point de K et J une fonctionnelle différentiable en u .

Si u est un point de *minimum local* de J sur K , on a **nécessairement** :

$$\exists \lambda \in \mathbf{R}^p, \text{ tel que } \begin{cases} \nabla_v \mathcal{L}(u, \lambda) = 0 \\ \nabla_\mu \mathcal{L}(u, \lambda) = 0 \end{cases}$$

2.5 Fonctionnelle quadratique et contraintes d'égalité affines

La fonctionnelle est ici quadratique en $v \in \mathbf{R}^n$:

$$\forall v \in \mathbf{R}^n, \quad J(v) = \frac{1}{2} \langle A v, v \rangle - \langle b, v \rangle + c$$

où A est une matrice **symétrique** de $\mathbf{R}^{n \times n}$, b un vecteur de \mathbf{R}^n et $c \in \mathbf{R}$.

On considère ses variations sur l'espace affine :

$$K = \{v \in \mathbf{R}^n / C v = f\}$$

où $C \in \mathbf{R}^{p \times n}$, et f un élément de \mathbf{R}^p .

D'après les théorèmes précédents, on a si u est un point de minimum de J sur K :

$$\exists \lambda \in \mathbf{R}^p, \text{ tel que } \begin{cases} A u + {}^t C \lambda = b \\ C u = f \end{cases}$$

Propriété

Soit J et K définis ci-dessus. Si u est un point de minimum de J sur K , alors il existe $\lambda \in \mathbf{R}^p$ tel que le couple (u, λ) de $\mathbf{R}^n \times \mathbf{R}^p$ soit solution du système linéaire :

$$\begin{pmatrix} A & {}^t C \\ C & 0 \end{pmatrix} \begin{pmatrix} u \\ \lambda \end{pmatrix} = \begin{pmatrix} b \\ f \end{pmatrix}$$

Théorème :

Si A est **symétrique positive**, le vecteur u est un point de minimum de J sur K **si, et seulement si**, il existe un élément λ de \mathbf{R}^p tel que le couple (u, λ) soit solution de :

$$\begin{pmatrix} A & {}^t C \\ C & 0 \end{pmatrix} \begin{pmatrix} u \\ \lambda \end{pmatrix} = \begin{pmatrix} b \\ f \end{pmatrix}$$

Si de plus A est **définie-positive** et C est **surjective** alors le système linéaire admet une **solution unique**.

2.6 Contraintes d'inégalité affines

Dans cette section on considère que l'ensemble des **contraintes** K est donné par :

$$K = \{v \in E / Cv \leq f\}$$

Théorème :

On considère K défini ci-dessus et J une fonctionnelle *différentiable* sur E dans \mathbf{R} . Si $u \in K$ est un minimum local de J sur K alors :

$$\exists \lambda \in \mathbf{R}^p, \lambda \geq 0, \quad \begin{cases} \nabla J(u) + {}^t C \lambda = 0 \\ \lambda_i [Cu - f]_i = 0 \\ Cu \leq f \end{cases}$$

De plus si J est *convexe*, alors ceci est une condition *suffisante* de minimalité.

3 Algorithmes pour problèmes sans contraintes, fonctionnelle quadratique

On étudie ici les algorithmes qui permettent de calculer **numériquement** la solution du problème de minimisation :

$$\text{Trouver } u \in \mathbf{R}^n \text{ tel que } J(u) = \min_{v \in \mathbf{R}^n} J(v).$$

Avec ici, J le fonctionnelle qui à v associe $J(v) = \frac{1}{2} \langle Av, v \rangle - \langle b, v \rangle$, avec A une matrice *symétrique définie positive* de $\mathbf{R}^{n \times n}$ et b un vecteur quelconque de \mathbf{R}^n .

Dans ce cas, la solution existe et est *unique*, et elle vérifie le système linéaire :

$$Au = b$$

Les algorithmes suivants consistent tous à choisir une condition initiale u_0 puis à construire une suite $(u_k)_{k \geq 1}$. Ces algorithmes doivent vérifier les deux propriétés suivantes :

La convergence de la suite (u_k) est assurée quel que soit le vecteur initiale.
La convergence doit être « suffisamment rapide ».

3.1 Taux et vitesse de convergence

Définition :

Soit $\|\cdot\|$ une norme matricielle *induite*. On appelle **conditionnement** d'une matrice réelle *invertible* $A \in \mathbf{R}^{n \times n}$, relatif à cette norme, la valeur définie par :

$$\text{cond}(A) = \|A\| \|A^{-1}\|$$

Définition :

Soit une méthode numérique produisant une suite d'itérés (u_k) . Soit $C > 0$ la plus *petite* constante telle que, pour tout $k \geq 0$: $\|u_{k+1} - u\| \leq C \|u_k - u\|$. C est appelé **taux de convergence**. On appellera **vitesse de convergence** $R = -\log C$.

3.2 Méthode de descente

Supposons l'itéré u_k connu, on choisit une direction dite de **descente** $d_k \neq 0$, et un **pas de descente** ρ_k . On construit alors l'itéré u_{k+1} par la formule :

$$u_{k+1} = u_k + \rho_k d_k$$

Remarque : Le choix de ρ_k et d_k se fait de manière à assurer que $J(u_{k+1}) < J(u_k)$.

Principe

3.2.1 Pas optimal – fonctionnelle quadratique

Dans le cas où la fonctionnelle est **quadratique**, on obtient une formule du pas optimal :

$$\rho_k = - \frac{\langle \nabla J(u_k), d_k \rangle}{\langle A d_k, d_k \rangle}$$

3.2.2 Relaxation

Définition :

On considère une base orthonormée $(e_i)_{1 \leq i \leq n}$ de \mathbf{R}^n . On choisit la suite des direction de descente $d_0 = e_1, \dots, d_n = e_1, \dots$, etc. et ainsi de suite. On choisit le *pas optimal* défini ci dessus. L'algorithme est alors :

Soit $l \geq 0$, on choisit $u_0 \in \mathbf{R}^n$ et une tolérance ϵ .

Pour $k = nl + i - 1$, on prend :

- ❶ $d_k = e_i$
- ❷ $\rho_k = - \frac{\langle \nabla J(u_k), d_k \rangle}{\langle A d_k, d_k \rangle}$
- ❸ $u_{k+1} = u_k + \rho_k e_i$

Propriété

Si A est **symétrique définie positive** alors la méthode de relaxation est **convergente**.

3.2.3 Gradient à pas fixe

Définition :

Ici, on cherche la direction dans laquelle la convergence sera la plus rapide.

Soit $u_0 \in \mathbf{R}^n$ une condition initiale, ρ un pas fixe.

Pour $k \in \mathbf{N}^+$

- ❶ $d_k = -\nabla J(u_k) = b - Au_k$
- ❷ $u_{k+1} = u_k + \rho d_k$

Propriété

Si A est **symétrique définie positive**, la méthode de gradient à pas fixe est convergente sous réserve que :

$$0 < \rho < \frac{2}{\lambda_{\max}(A)}$$

3.2.4 Méthode du gradient à pas optimal

Définition :

On procède ici comme avec la méthode du gradient à pas fixe, sauf que le pas ρ_k est ici :

$$\rho_k = -\frac{\langle \nabla J(u_k), d_k \rangle}{\langle Ad_k, d_k \rangle}$$

Soit $u_0 \in \mathbb{R}^n$ une condition initiale.
Pour $k \in \mathbb{N}^+$

- ❶ $d_k = -\nabla J(u_k) = b - Au_k$
- ❷ $u_{k+1} = u_k + \rho_k d_k$

Propriété

Si A est **symétrique définie positive**, la méthode de gradient à pas optimal est convergente.

3.2.5 Gradient conjugué

Le principe de la *méthode du gradient conjugué* est de construire une suite de *direction* de descente que l'on garde en mémoire, pour essayer d'éviter les retours.

Si u_1, \dots, u_k ont déjà été calculés, et si tous les gradients $g_l = \nabla J(u_l)$, on recherche u_{k+1} tel que :

$$J(u_{k+1}) = \min_{v \in u_k + G_k} J(v) \quad \text{avec} \quad G_k = \text{Vect}(g_0, \dots, g_k)$$

On a :

- ❶ g_{k+1} est orthogonale à G_k , i.e $\forall l \in \llbracket 0, k \rrbracket, \langle g_{k+1}, g_l \rangle = 0$
- ❷ La méthode du GC converge en au plus n étapes !
- ❸ (d_l) sont conjugués par rapport à A : $\forall k \neq l, \langle Ad_k, d_l \rangle = 0$.

Algorithme

initialisation : $k = 0$, on choisit u_0 , on calcul $g_0 = Au_0 - b$ et $d_0 = -g_0$.

tant que : $\|g_k\| > \epsilon$, itérer k

- Calculer $\beta_{k-1} = \frac{\langle g_{k-1}, d_{k-1} \rangle}{\langle Ad_{k-1}, d_{k-1} \rangle}$

- Calculer $u_k = u_{k-1} - \beta_{k-1} d_{k-1}$

- Nouvelle direction : $g_k = Au_k - b$ puis $\alpha_k = \frac{\|g_k\|^2}{\|g_{k-1}\|^2}$ et enfin $d_k = \alpha_k d_{k-1} - g_k$.

3.2.6 Méthodes itératives

On s'intéresse ici à des méthodes numériques de résolution du système linéaire :

$$J'(u) = Au - b = 0.$$

La solution de ce système est le minimum recherché de la fonctionnelle quadratique J sur \mathbb{R}^n .

Principe

- ❶ On décompose A sous la forme $A = M - N$ avec M inversible.
- ❷ Partant de $u_0 \in \mathbb{R}^n$, on construit $(u_k)_k$ par :

$$Mu_{k+1} = Nu_k - b \quad \text{i.e} \quad u_{k+1} = M^{-1}Nu_k - M^{-1}b.$$

Attention : Ces méthodes ne sont intéressantes que si le choix de M rend le calcul de u_{k+1} facile.

Propriété

Si $(u_k)_k$ converge alors c'est vers la solution du système linéaire $Au = b$.

Propriété

- ❶ La suite $(u_k)_k$ définie par la méthode itérative est *convergente* si et seulement si le *rayon spectrale* $\rho(M^{-1}N)$ vérifie : $\rho(M^{-1}N) < 1$.
- ❷ Si A est **symétrique définie positive** et si ${}^tM + N$ est aussi **définie positive**, alors

$$\rho(M^{-1}N) < 1$$

On note $D = \text{diag}A$, $-E = \text{tirang}_{\text{inf}}(A)$ et $-F = \text{tirang}_{\text{sup}}(A)$.

Définition : Méthode de Jacobi

Cette méthode consiste à choisir $M = D$ et $N = E + F$. On désigne par *matrice de Jacobi* la matrice $\mathcal{J} = M^{-1}N = D^{-1}(E + F)$. L'algorithme s'écrit alors :

- ❶ On choisit $u_0 \in \mathbf{R}^n$ et $\epsilon > 0$.
- ❷ Tant que $\|Au_k - b\| > \epsilon$, calculer $u_{k+1} = \mathcal{J}u_k + D^{-1}b$.

Définition : Méthode de Gauss-Seidel

Cette méthode consiste à choisir $M = D - E$ et $N = F$. On désigne par *matrice de Gauss-Seidel* la matrice $\mathcal{G} = M^{-1}N = (D - E)^{-1}F$. L'algorithme s'écrit alors :

- ❶ On choisit $u_0 \in \mathbf{R}^n$ et $\epsilon > 0$.
- ❷ Tant que $\|Au_k - b\| > \epsilon$, calculer $u_{k+1} = \mathcal{G}u_k + (D - E)^{-1}b$.

Théorème :

- ❶ Si A est **symétrique** et **définie-positive**, alors la méthode de GAUSS-SEIDEL **converge**.
- ❷ Si A est à diagonale **strictement dominante** alors les deux méthodes convergent.
- ❸ Si A est **tridiagonale**, alors $\rho(\mathcal{G}) = \rho(\mathcal{J})^2$.

4 Algorithme pour les problèmes contraints

Là encore nous nous intéressons au problème :

$$\text{Trouver } u \in K \text{ tel que } J(u) = \min_{v \in K} J(v).$$

où J est la fonctionnelle qui à $v \in K$ associe $J(v) = \frac{1}{2}\langle Av, v \rangle - \langle b, v \rangle$, $A \in \mathcal{M}_{n \times n}(\mathbf{R})$ est supposée *symétrique définie-positive*, b est un vecteur quelconque de \mathbf{R}^n et K est un *convexe fermé* de \mathbf{R}^n .

4.1 Méthode du gradient projeté

Rappel : Pour tout $w \in \mathbf{R}^n$, il existe une unique projection de w sur K , notée $P_K(w) \in K$, solution de :

$$\|P_K(w) - w\| = \min_{v \in K} \|v - w\|.$$

De plus la projection est caractérisée par :

$$\forall v \in K, \quad \langle P_K(w) - w, P_K(w) - v \rangle \leq 0$$

Propriété

Soit K un convexe fermé non vide de \mathbf{R}^n et $\rho > 0$. u est solution du problème contraint $J(u) = \min_{v \in K} J(v)$ si et seulement si :

$$u = P_K(u - \rho \nabla J(u)).$$

Algorithme

❶ Initialisation : $u_0 \in \mathbf{R}^n$, un pas $\rho > 0$ et une précision $\eta > 0$.

❷ Tant que : $\|u_k - u_{k+1}\| > \eta$,

$$u_{k+1} = P_K(u_k - \rho \nabla J(u_k))$$

Propriété

Dans les conditions évoquées ci-dessus et si K est non vide, si $0 < \rho < \frac{2}{\lambda_{\max}(A)}$, alors quel que soit $u_0 \in \mathbf{R}^n$, la suite $(u_k)_k$ définie par le gradient projeté converge vers le minimum u .

Propriété

Si $K = \prod_{i=1}^n [a_i, b_i]$, et $y = {}^t(y_1, \dots, y_n) \in \mathbf{R}^n$, la projection $x = P_K(y)$ a pour composantes :

$$x_i = \min(\max(a_i, y_i), b_i)$$

4.2 Méthode d'UZAWA

Supposons que l'ensemble

$$K = \{v \in \mathbf{R}^n / Cv = f\}$$

ou

$$K = \{v \in \mathbf{R}^n / Cv \leq f\}$$

où C est une matrice $p \times n$ et $f \in \mathbf{R}^p$.

Soit $u \in K$ le minimum de la fonctionnelle J sur K . Alors il existe $\lambda \in \mathbf{F}$ tel que :

$$\begin{cases} \nabla J(u) + {}^t C \lambda = 0 \\ Cu - f \leq 0 \\ \langle \lambda Cu - f \rangle = 0 \\ \langle \lambda - \mu, Cu - f \rangle \geq 0, \forall \mu \in \mathbf{F} \end{cases}$$

\mathbf{F} est si il y a contraintes d'égalité égal à \mathbf{R}^p , si il y a contraintes d'inégalité égal à \mathbf{R}^{+p} .

Propriété

Soit $\lambda \in \mathbf{R}^p$ tel que (u, λ) vérifie le système ci-dessus. Pour tout $\rho > 0$, on a :

$$\lambda = P_{\mathbf{F}}(\lambda + \rho(Cu - f))$$