

RESUME D'OPTIMISATION

Optim – Résumé

I. Dérivées

1. Ligne de niveau

$$N_c = \{x \in \mathbb{R}^n | J(x) = c\}$$

2. Dérivée première

a. Gradient

$$\nabla J(x_0) = \left[\frac{\partial J}{\partial x_1}, \dots, \frac{\partial J}{\partial x_n} \right]^T$$

Propriété : Au point x_0 , $\nabla J(x_0)$ est \perp à la ligne de niveau, son sens va dans le sens de J croissant.

b. Dérivée directionnelle

$$D_x J(x, d) = \lim_{\varepsilon \rightarrow 0} \frac{J(x + \varepsilon d) - J(x)}{\varepsilon} = \left. \frac{d \overbrace{J(x + \varepsilon d)}^{\varphi(\varepsilon)}}{d\varepsilon} \right|_{\varepsilon=0} = \varphi'(0) = \nabla J(x)^T d$$

c. Plan tangent

Passer par $(x_0, J(x_0))$ et vecteur directeur $\nabla J(x_0)$

Approximation locale de J

$$P = \{x \in \mathbb{R}^n | \nabla J(x_0)^T (x - x_0) = 0\}$$

$$J(x) \approx P(x) = J(x_0) + \nabla J(x_0)^T x$$

d. Développement limité au premier ordre

$$J(x) \approx J(x + \varepsilon d) = J(x) + \varepsilon \underbrace{\nabla J(x)^T d}_{D_x J(x, d)} + o(\varepsilon)$$

e. Règles de calcul pour la dérivée

$$\nabla(J_1 + \alpha J_2) = \nabla J_1 + \alpha \nabla J_2 \quad | \quad \nabla(J_1 J_2) = \nabla J_1 |_{x=J_2} \nabla J_2 \quad | \quad \nabla a^T x = a \quad | \quad \nabla x^T A x = (A + A^T)x$$

3. Dérivées secondes

a. Dérivée directionnelle au sens de Gâteaux

$$D^2 J(x, d) = \lim_{\varepsilon \rightarrow 0} \frac{D_x J(x + \varepsilon d) - D_x J(x)}{\varepsilon} = d^T \nabla D_x J(x)$$

b. Matrice Hessienne

$$H_J(x) = \begin{pmatrix} \frac{\partial^2 J(x)}{\partial x_1 \partial x_1} & \dots & \frac{\partial^2 J(x)}{\partial x_1 \partial x_j} & \dots & \frac{\partial^2 J(x)}{\partial x_1 \partial x_n} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \frac{\partial^2 J(x)}{\partial x_i \partial x_1} & \dots & \frac{\partial^2 J(x)}{\partial x_i \partial x_j} & \dots & \frac{\partial^2 J(x)}{\partial x_i \partial x_n} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \frac{\partial^2 J(x)}{\partial x_n \partial x_1} & \dots & \frac{\partial^2 J(x)}{\partial x_n \partial x_j} & \dots & \frac{\partial^2 J(x)}{\partial x_n \partial x_n} \end{pmatrix}$$

Calcul pratique :

A partir de la dérivée de

$$\varphi(\varepsilon) = D_x J(x + \varepsilon d)$$

Identifier H dans $\varphi'(0)$:

$$\varphi'(0) = d^T H_x(x)^T d$$

c. Développement limité au second ordre

$$J(x + d) = J(x) + D_x J(x, d) + \frac{1}{2} D_x^2 J(x, d) + o(\|d\|^2)$$

$$J(x + d) = J(x) + \nabla_x J(x)^T d + \frac{1}{2} d^T H d + o(\|d\|^2)$$

RESUME D'OPTIMISATION

Optim – Résumé

II. Moindres carrés

$$\hat{y} = X\theta + \varepsilon$$

Moindres carrés

$$\min_{\theta} \|\varepsilon\|_2^2 = \min_{\theta} (X\theta - y)^T (X\theta - y)$$

$$= \min_{\theta} \theta^T X^T X \theta - 2y^T X \theta + y^T y$$

$$\hat{\theta}_{MC} = (X^T X)^{-1} X^T y$$

Moindres carrés pondérés

$$\min_{\theta} \|W\varepsilon\|_2^2 = \min_{\theta} (X\theta - y)^T W (X\theta - y)$$

$$= \min_{\theta} \theta^T X^T W X \theta - 2y^T W X \theta + y^T W y$$

$$\hat{\theta}_{MC} = (X^T W X)^{-1} X^T W y$$

Moindres carrés récurrents

$$\hat{\theta} = \underbrace{(X_n^T X_n)^{-1}}_{P_n} \underbrace{X_n^T y_n}_{Q_n}$$

$$P_n = \left(\underbrace{P_{n-1}^{-1}}_A + \underbrace{x_n x_n^T}_B \right)^{-1} = P_{n-1} - k_n x_n^T P_{n-1}$$

$$Q_n = Q_{n-1} + x_n y_n$$

$$\hat{\theta}_n = \hat{\theta}_{n-1} + k_n (y_n - x_n^T \hat{\theta}_{n-1})$$

$$k_n = P_{n-1} x_n (1 + x_n^T P_{n-1} x_n)^{-1} \quad (A + BCD)^{-1} = A^{-1} - A^{-1} B (C^{-1} + D A^{-1} B)^{-1} D A^{-1}$$

III. Descente de gradient

1. Condition d'optimalité

1^{er} ordre	x_0 solution $\Rightarrow \nabla J(x_0) = 0$
2^{ème} ordre	x_0 solution $\Rightarrow \nabla J(x_0) = 0$ et $H(x_0)$ définie positive $\nabla J(x_0) = 0$ et $H(x_0)$ définie positive $\Rightarrow x_0$ solution locale
Convexité	J est convexe et x_0 respecte condition d'optimalité $\Rightarrow x_0 = x^*$ solution globale

2. Optimisation itérative

$$x_{k+1} = x_k + \rho_k d_k \quad \lim_{k \rightarrow \infty} x_k = x^* = \operatorname{argmin}_{x \in \mathbb{R}^n} J(x)$$

a. Direction de descente d ($\nabla J^T d < 0$)

- Gradient** : $d_k = -\nabla J$ $\mathcal{O}(n)$
- Gradient conjugué** : $d_k = -\nabla J + \beta_k d_{k-1}$ $\beta_k = \frac{\nabla J^T d_{k-1}}{d_{k-1}^T d_{k-1}}$ $\mathcal{O}(n^2)$
- Grad. conj. quad** : $d_k = -\nabla J + \beta_k d_{k-1}$ $\beta_k = \frac{\|\nabla J\|^2}{\|\nabla J_{k-1}\|^2}$ $\mathcal{O}(n^2)$
- Quasi-Newton** : $d_k = -B \nabla J$ (Ex : $B = \operatorname{diag}(H)^{-1}$) $\mathcal{O}(n^2)$
- Newton** : $d_k = -H^{-1} \nabla J$ $\mathcal{O}(n^3)$

b. Choix du pas ρ

- Pas fixe** : $\rho_k = c$ $\mathcal{O}(1)$
- Pas adaptatif** : $\rho_k = \begin{cases} \alpha \rho_{k-1} & \text{si } J \text{ diminue} \\ \alpha \rho_{k-1} & \text{si } J \text{ augmente} \end{cases}$ $\alpha = 1,15$ $\beta = 0,5$ $\mathcal{O}(1)$
- Pas grad. conjugué** : $\rho_k = \frac{-\nabla J^T d_k}{d_k^T d_k}$ $\mathcal{O}(1)$
- Pas quasi-optimal** : $\rho_k = \frac{-b}{2a} \mid a \rho_k^2 + b \rho_k + c \approx J(x_k + \rho_k d_k)$ $\mathcal{O}(1)$
- Pas optimal** : $\rho_k = \begin{cases} \operatorname{argmin}_{\rho \in \mathbb{R}^+} J(x + \rho d) \\ \frac{d^T d}{d^T H d} \end{cases}$ $\begin{cases} < \mathcal{O}(n^2) \\ \mathcal{O}(n^2) \end{cases}$

IV. Méthodes itératives globales

1. Recuit simulé

Selon une température T qui décroît, on tolère plus ou moins de conserver des solutions θ_{k+1} qui dégradent le critère ($J(\theta_{k+1}) > J(\theta_k)$).

Init : $\theta_0, T_0 > 0$

while (on a pas convergé)

$\theta'_k = f(\theta_k)$ // nouvelle solution hypothétique (potentiellement aléatoirement)

$\delta = J(\theta'_k) - J(\theta_k)$

if $\delta \leq 0$ or $U_{[0,1]} < e^{-\delta/T_k}$

$\theta_{k+1} = \theta'_k$


else

$\theta_{k+1} = \theta_k$

end

$T_{k+1} = g(T_k)$

end while



2. Méthodes évolutionnaires

• Sélection (Se) :

○ Roue de loterie (choix probabiliste) :

- $\mathbb{P}(x_i) = J(x_i), aJ(x_i) + b, J(x_k)^k$
- $\mathbb{P}(x_i) = nb + 1 - \text{rang } x_i$
- $\mathbb{P}(x_i) = \frac{J(x_i)}{m}$ (m pénalise les solutions avec voisins proches)

○ Tournois :

- Déterministes : $n \in [1, T]$ meilleurs parmi T
- Stochastique : Meilleur parmi n avec une proba t
- Evolutionnaire : $\forall x_i$, tournoi avec $T - 1$ concurrents

• Croisement (Cr) : $x_i^{new} = (1 - \alpha)x_i + \alpha x_j$ $\alpha = U_{[0,1]}$, $\alpha' = (1 + 2\alpha)U_{[0,1]} - \alpha$

• Mutation (Mu) : modification aléatoire des enfants

• Réduction (Re) :


- Générational : p enfants remplacent p parents
- Steady-state : chaque enfant remplace 1 de ses parents

3. Essais particuliers

$$v_i^{new} = \omega r_0 v_i + c_1 r_1 (p_{i,best} - x_i) + c_2 r_2 (p_{i,guide} - x_i)$$

$$x_i^{new} = x_i + \chi(v_i^{new})$$

- x_i position de la particule i
- v_i vitesse de la particule i
- $p_{i,best}$ meilleure pos. vue par i
- $p_{i,guide}$ position d'un guide
- r_k valeurs aléatoires
- c_1 facteur individuel
- c_2 facteur social
- ω facteur d'inertie
- $\chi(\cdot)$ modification de la vitesse (contraintes min/max, aléatoire, ...)



RESUME D'OPTIMISATION

Optim – Résumé

V. Optimisation multicritère

Une solution x domine une solution $y \Leftrightarrow x < y \Leftrightarrow \forall k, f_k(x) \leq f(y), \exists k, f_k(x) < f(y)$

1. Approches

- Méthodes monocritères (pondérées, lexicographiques, ϵ -contraintes)
- Méthodes « Pareto » à base population (génétique, essais, colonies de fourmis)

2. Méthodes monocritères

Méthode pondérée	Méthodes lexicographiques	Méthode ϵ contrainte
Critère combiné $J = \sum w_i J_i$. Variation des w_i .	Objectifs triés par ordre d'importance, optimisations successives sous contraintes.	Minimiser l'objectif principal. Autre objectifs exprimés comme contraintes $J_k \leq \epsilon_k$. Variation de ϵ_k .

3. Méthodes « Pareto »

- Utilisation de la notion de rang de dominance
- Utilisation d'une archive conservant les solutions non dominées
- Gestion de la diversité

VEGA	SPEA	NSGA-II	Essais
Algorithme génétique où parmi p parents, on fait une pré-sélection selon chaque critère. <i>Individus bons dans 1 domaine particulier \Rightarrow non-Pareto.</i>	Suppression des individus semblables dans l'archive. Force S_i , Fitness F_i $S_i = \frac{n_{dominés}}{n + 1}$ $F_i = 1 + \sum_{j \in dom^{ant}} S_j$	Fitness basé sur rang de non dominance. Distance de crowding pour préserver div. (taille max du cube contenant uniquement x_i)	Elimin. de l'archive si autre sol. proches (inclus dans la dom.). Sélection probabiliste du guide $\frac{1}{densité}$.

