

Optimisation

1. Optimisation sans contraintes
2. Optimisation sous contraintes
3. Analyse convexe et dualité

Convexité

L'ensemble X est convexe ssi pour tout x, y dans X , le segment $[x, y] := \{tx + (1 - t)y \mid t \in [0, 1]\}$ est inclus dans X

Une fonction $f : X \subset \mathbf{R}^n \rightarrow R$ est convexe ssi X est convexe et pour tout x, y dans X et pour tout $t \in [0, 1]$,

$$f(tx + (1 - t)y) \leq tf(x) + (1 - t)f(y).$$

Si l'inégalité est stricte pour $t \in]0, 1[$, la fonction est dite *strictement* convexe.

Convexité

Reconnaître une fonction convexe

- les fonctions linéaires sont convexes
- les combinaisons linéaires positives de fonctions convexes sont convexes
- le maximum (point par point) d'un ensemble de fonctions convexes est convexe
- ...

Si f est de classe C^2 , f est convexe si et seulement si $\nabla^2 f$ est semi-définie positive sur l'intérieur de X . Si $\nabla^2 f$ est définie positive sur l'intérieur de X , f est strictement convexe. ($X = \text{dom} f$)

Existence et unicité du minimum

Théorèmes

Si f est convexe et minorée, alors f admet un minimum global.

Si f est une fonction *strictement* convexe définie sur un ensemble convexe $X \subset \mathbf{R}^n$, alors f admet au plus un minimum global.

Si f est une fonction convexe définie sur un ensemble convexe $X \subset \mathbf{R}^n$, alors tout minimum local de f est aussi un minimum global de f . Si X est ouvert, alors $\nabla f(x^*) = 0$ est équivalent à x^* est un minimum global de f .

Dualité

Problème considéré

minimize $f(x)$

subject to $x \in X$, $g_j(x) \leq 0$, $j = 1, \dots, r$,

$$f : \mathbf{R}^n \rightarrow \mathbf{R}$$

$$g_j : \mathbf{R}^n \rightarrow \mathbf{R}$$

$$X \subset \mathbf{R}^n$$

$$f^* = \inf_{\substack{x \in X \\ g_j(x) \leq 0, j=1, \dots, r}} f(x).$$

$$-\infty < f^* < +\infty$$

Il existe x^* , tel que $f(x^*) = f^*$

Dualité

Lagrangien associé au problème

$$L(x, \mu) = f(x) + \sum_{j=1}^r \mu_j g_j(x) = f(x) + \mu' g(x).$$

Dualité

Fonction duale

$$q(\mu) = \inf_{x \in X} L(x, \mu).$$

Problème dual

$$\text{maximize } q(\mu)$$

$$\text{subject to } \mu \geq 0, \mu \in D,$$

$$D = \{\mu \mid q(\mu) > -\infty\}.$$

Résultats

Proposition 5.1.2: The domain D of the dual function q is convex and q is concave over D .

Proposition 5.1.3: (Weak Duality Theorem) We have

$$q^* \leq f^*.$$

Dualité

Dualité forte et qualification des contraintes

Exemple :

Si f est convexe et les contraintes g_j sont linéaires, alors il n'y a pas d'écart dual: $q^* = f^*$

Dualité

If conditions for strong duality are met and (x^*, μ^*) are such that $L(x^*, \mu^*) = f^* = q^*$, then (x^*, μ^*) is said to be an optimal solution Lagrange multiplier pair.

Proposition 5.1.5: (Optimality Conditions) (x^*, μ^*) is an optimal solution-Lagrange multiplier pair if and only if

$$x^* \in X, \quad g(x^*) \leq 0, \quad (\text{Primal Feasibility}), \quad (5.4)$$

$$\mu^* \geq 0, \quad (\text{Dual Feasibility}), \quad (5.5)$$

$$x^* = \arg \min_{x \in X} L(x, \mu^*), \quad (\text{Lagrangian Optimality}), \quad (5.6)$$

$$\mu_j^* g_j(x^*) = 0, \quad j = 1, \dots, r, \quad (\text{Complementary Slackness}). \quad (5.7)$$

Un mot sur l'optimisation non lisse

Statistique et probabilités

1. Motivation : estimation problems
2. Computing probabilities
3. Computing and controlling moments and tail probabilities

Problèmes d'estimation

Cadre général

Modèle statistique	\mathcal{P}
Distribution	$P \in \mathcal{P}$
Observations	$O \sim P$

- Estimation

Fonctionnelle $f : \mathcal{P} \rightarrow E$

Estimateur $\hat{f} : \mathcal{O} \rightarrow E$

But $\hat{f}(O) \approx f(P)$

Deux questions fondamentales pour un problème d'estimation

- A. Trouver un estimateur computationnellement efficace $\hat{f} : \mathcal{O} \rightarrow E$
- Dans le cas où on estime une distribution :
Implique des calculs de probabilités (e.g. méthode du maximum de vraisemblance)
- B. Evaluer sa qualité statistique $\hat{f}(O) \approx f(P)$
- Implique calcul ou contrôle de moments (e.g. biais, variance, risque espéré)

Exemple A

Estimateur du maximum de vraisemblance

Modèle statistique	\mathcal{P}	$\mathcal{P} = \{\text{all distributions}\}$
Distribution	$P \in \mathcal{P}$	
Observations	$O \sim P$	
Fonctionnelle	$f : \mathcal{P} \rightarrow E$	$f(P) = P$
Estimateur	$\hat{f} : \mathcal{O} \rightarrow E$	$\hat{f}_{\mathcal{H}} : O \mapsto P_{\arg \max_{w \in W} (p_w(O))}$

$\mathcal{H} = \{P_w \mid w \in W\}$: espace de recherche/d'hypothèse

p_w : densité de P_w (par rapport à une mesure fixe)

Exemple B

Qualité statistique d'un estimateur

- biais $b_P(\hat{f}) = E_{O \sim P}[\hat{f}(O)] - f(P)$ $\|b_P(\hat{f})\|_2$
- variance $\text{Var}_P(\hat{f}) = \text{Var}_{O \sim P}[\hat{f}(O)]$
- risque $R_P(\hat{f}) = E_{O \sim P}[\ell(f(P), \hat{f}(O))]$

ℓ Fonction de coût

Décomposition biais-variance du risque dans le cas $\ell : x, y \mapsto \|x - y\|_2^2$

$$R_P(\hat{f}) = \text{Var}_P(\hat{f}) + \|b_P(\hat{f})\|_2^2$$

Statistique et probabilités

1. Motivation : estimation problems
2. Computing probabilities
3. Computing and controlling moments and tail probabilities

Univers et mesure de probabilité

Univers Ω

Événement $A \subset \Omega$

Ensemble des événements (tribu) $\mathcal{F} \subset \mathcal{P}(\Omega)$ Stable par union dénombrable et par passage au complémentaire

Mesure de probabilité $P : \mathcal{F} \rightarrow \mathbf{R}$

$$\forall A \in \mathcal{F}, P(A) \geq 0$$

$$P(\Omega) = 1$$

Pour tout ensemble dénombrable d'événements **disjoints** $A_1, A_2, \dots,$

$$P \left(\bigcup_{i=1}^{+\infty} A_i \right) = \sum_{i=1}^{+\infty} P(A_i)$$

Variable aléatoire

Univers Ω

Ensemble des événements (tribu) $\mathcal{F} \subset \mathcal{P}(\Omega)$ Stable par union dénombrable et par passage au complémentaire

Mesure de probabilité $P : \mathcal{F} \rightarrow \mathbf{R}$

Variable aléatoire $X : \Omega \rightarrow E$

$\mathcal{T} \subset \mathcal{P}(E)$ Tribu sur l'espace d'arrivée

$\forall T \in \mathcal{T}, X^{-1}(T) \in \mathcal{F}$

Loi de X (mesure de probabilité induite sur E) $\forall T \in \mathcal{T}, P_X(T) = P(X^{-1}(T))$

Conditionnement, indépendance

Probabilité conditionnelle

$$P(A | B) := \frac{P(A \cap B)}{P(B)}$$

Indépendance mutuelle d'événements

$$\forall S \subset \{1, 2, \dots, n\}, \quad P\left(\bigcap_{i \in S} A_i\right) = \prod_{i \in S} P(A_i)$$

Loi de probabilité conditionnelle

$$X : \Omega \rightarrow E \quad Y : \Omega \rightarrow F \quad \mathcal{T} \subset \mathcal{P}(E) \quad \Sigma \subset \mathcal{P}(F)$$

Origine des dépendances : Omega !

Tribus sur les espaces d'arrivée

$$T \in \mathcal{T} \quad S \in \Sigma$$

$$P_{X|Y}(T|S) = P(X^{-1}(T) | Y^{-1}(S)) = \frac{P(X^{-1}(T) \cap Y^{-1}(S))}{P(Y^{-1}(S))}$$

Variables aléatoires indépendantes

$$\forall T \in \mathcal{T}, \quad \forall S \in \Sigma, \quad P_{X,Y}(T, S) = P_X(T)P_Y(S)$$

Variabliques aléatoires réelles

$$X : \Omega \rightarrow E \subset \mathbf{R}$$

$$p_X(x) = P_X(\{x\})$$

Fonction de masse

$$F_X(x) = P_X(\{y \mid y \leq x\})$$

Fonction de répartition

$$p_{dX} = \frac{dF_X}{dx}$$

Densité de probabilité

$$E[X] = \int x P_X(dx)$$

Espérance (intégrale de Lebesgue)


$$E[X] = \int x p_{dX}(x) dx$$

Cas continu

$$E[X] = \sum_x x p_X(x)$$

Cas discret

On a représenté sur le graphe ci-dessous la densité de probabilité d'une variable aléatoire réelle X .




- 1) La densité de probabilité de X prend une valeur supérieure 1 en $X = 0.4$. Cela vous parait-il normal? Justifiez votre réponse.

Soit x une réalisation de X .

- 2) Quelle est la probabilité d'avoir $x = 0.1$? Quelle est la probabilité d'avoir $x = 0.4$? Est-il plus probable d'observer $x = 0.4$ ou $x = 0.1$? A quel point (approximativement)?

On a représenté sur le graphe ci-dessous la densité de probabilité d'une variable aléatoire réelle X .




- 1) La densité de probabilité de X prend une valeur supérieure 1 en $X = 0.4$. Cela vous paraît-il normal? Justifiez votre réponse.

L'aire sous la courbe doit être égale à 1 mais la densité en un point particulier peut être supérieure et même arbitrairement grande.

Soit x une réalisation de X .

- 2) Quelle est la probabilité d'avoir $x = 0.1$? Quelle est la probabilité d'avoir $x = 0.4$? Est-il plus probable d'observer $x = 0.4$ ou $x = 0.1$? A quel point (approximativement)?

On a représenté sur le graphe ci-dessous la densité de probabilité d'une variable aléatoire réelle X .



- 1) La densité de probabilité de X prend une valeur supérieure 1 en $X = 0.4$. Cela vous paraît-il normal? Justifiez votre réponse.

L'aire sous la courbe doit être égale à 1 mais la densité en un point particulier peut être supérieure et même arbitrairement grande.

Soit x une réalisation de X .

- 2) Quelle est la probabilité d'avoir $x = 0.1$? Quelle est la probabilité d'avoir $x = 0.4$? Est-il plus probable d'observer $x = 0.4$ ou $x = 0.1$? A quel point (approximativement)?

La probabilité que x soit 0.1 ou 0.4 est 0. Par contre, il est environ 5 fois plus probable d'observer $X = 0.4$ que $x = 0.1$.

Plusieurs variables aléatoires réelles

$$\mathbf{X} = (X_1, X_2, \dots, X_n) : \Omega \rightarrow \mathbf{R}^n \quad \text{Origine des dépendances : Omega !}$$

$$p_{\mathbf{X}}(x_1, x_2, \dots, x_n) = P_{\mathbf{X}}(\{x_1, x_2, \dots, x_n\}) \quad \text{Fonction de masse (jointe)}$$

$$F_{\mathbf{X}}(x_1, x_2, \dots, x_n) = P_{\mathbf{X}}(\{y_1, y_2, \dots, y_n \mid y_1 \leq x_1, y_2 \leq x_2, \dots, y_n \leq x_n\})$$

Fonction de répartition (jointe)

$$p_{d\mathbf{X}} : x_1, x_2, \dots, x_n \mapsto \frac{\partial F_{\mathbf{X}}}{\partial x_1 dx_2 \dots dx_n}(x_1, x_2, \dots, x_n)$$

Densité de probabilité (jointe)

Espérance $f : \mathbf{R}^n \rightarrow \mathbf{R}$

Cas continu $E[f(\mathbf{X})] = \int_{x_1} \int_{x_2} \dots \int_{x_n} f(x_1, x_2, \dots, x_n) p_{d\mathbf{X}}(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_n$

Cas discret $E[f(\mathbf{X})] = \sum_{x_1} \sum_{x_2} \dots \sum_{x_n} f(x_1, x_2, \dots, x_n) p_{\mathbf{X}}(x_1, x_2, \dots, x_n)$

Modèles graphiques

$$p(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | X_{\pi_i})$$

Statistique et probabilités

1. Motivation : estimation problems
2. Computing probabilities
3. Computing and controlling moments and tail probabilities

Moments

Variance $\text{Var}[X] = E[(X - E[X])^2]$

Moment $E[X^k]$

Moment centré $E[(X - E[X])^k]$

Covariance $\text{Cov}(X, Y) = E[(X - E[X])(Y - E[Y])]$

Linéarité de l'espérance $E \left[\sum_{i=1}^n a_i X_i \right] = \sum_{i=1}^n a_i E(X_i)$

Bilinéarité de la covariance

$$\text{Cov} \left(\sum_{i=1}^n a_i X_i, \sum_{j=1}^m b_j Y_j \right) = \sum_{i=1}^n \sum_{j=1}^m a_i b_j \text{Cov}(X_i, Y_j)$$

Moments conditionnels

Espérance conditionnelle

$$f(y) = E[X|Y = y] = \int x P_{X|Y=y}(dx)$$

Variance conditionnelle

$$g(y) = \text{Var}[X|Y = y] = E[(X - E[X])^2|Y = y]$$

Loi de l'espérance totale

$$E[X] = E[E[X|Y]]$$

Loi de la covariance totale

$$\text{Cov}[X, Y] = \text{Cov}[E[X|Z], E[Y|Z]] + E[\text{Cov}[X, Y|Z]]$$

Statistique et probabilités

1. Motivation : estimation problems
2. Computing probabilities
3. Computing and controlling moments and tail probabilities