

Bayesian nonparametrics - An introduction

J. Rousseau

Oxford University & Dauphine

Applibugs

- 1 Introduction
 - Rappels sur le bayésien
- 2 Différentes familles de lois a priori
- 3 Processus de Dirichlet
 - Espace $\mathcal{M}(\mathcal{X})$
 - Quelques applications du processus de Dirichlet

- 1 Introduction
 - Rappels sur le bayésien
- 2 Différentes familles de lois a priori
- 3 Processus de Dirichlet
 - Espace $\mathcal{M}(\mathcal{X})$
 - Quelques applications du processus de Dirichlet

Introduction : notions générales en bayésien

- ▶ **Modèle** $X \sim P_\theta$, $\theta \in \Theta$, $X \in \mathcal{X}$
- ▶ **Proba a priori** : Proba sur Θ : $d\pi(\theta)$
- ▶ **Loi jointe**

$$d\lambda^\pi(X, \theta) = dP(X|\theta)d\pi(\theta) : \quad \lambda^\pi(A \times B) = \int_B P(A|\theta)d\pi(\theta), \quad A \subset \mathcal{X}, B \subset \Theta$$

- ▶ **Loi marginale de X**

$$dm_\pi(X) = \int dP(X|\theta)d\pi(\theta), \quad m_\pi(A) = \int P(A|\theta)d\pi(\theta), \quad A \subset \mathcal{X}$$

- ▶ **Loi a posteriori** version $d\pi(\theta|X)$ satisfaisant : pour tout $A \in \mathcal{X}$, $B \in \Theta$ mesurables

$$\int_B P(A|\theta)d\pi(\theta) = \int_A d\pi(B|X)dm_\pi(X)$$

Quelques exemples de problèmes non paramétriques

- **Distribution** $X \sim P$ avec $X \in \mathbb{R}$ et P inconnue. **modèle non dominé**

$$\Theta = \{P : \text{proba sur } \mathbb{R}\}$$

- **Densité** $X \sim P$ $P \ll \mu$ $f = dP/d\mu$ **modèle dominé** par μ

$$\Theta = \{f : \mathbb{R} \rightarrow \mathbb{R}^+, \int f d\mu = 1\}$$

- **Régression** $Y = f(X) + \epsilon$, f inconnue $X \in \mathcal{X}$ (ex $[0, 1]^d$, \mathbb{R}^d)

- **Survie** données censurées $X \in \mathbb{R}^+$ $C \in \mathbb{R}^+$, $X \sim F$, $C \sim G$. On observe (Y, δ) avec $Y = X \wedge C$ $\delta = \mathbb{I}_{C \leq X}$
Paramètre d'intérêt : Fonction de Hasard cumulée

$$dH(x) = P(X \in (x, x + dx) | X > x)$$

Quelques exemples de problèmes non paramétriques

- **Distribution** $X \sim P$ avec $X \in \mathbb{R}$ et P inconnue. **modèle non dominé**

$$\Theta = \{P : \text{proba sur } \mathbb{R}\}$$

- **Densité** $X \sim P$ $P \ll \mu$ $f = dP/d\mu$ **modèle dominé** par μ

$$\Theta = \{f : \mathbb{R} \rightarrow \mathbb{R}^+, \int f d\mu = 1\}$$

- **Régression** $Y = f(X) + \epsilon$, f inconnue $X \in \mathcal{X}$ (ex $[0, 1]^d$, \mathbb{R}^d)

- **Survie** données censurées $X \in \mathbb{R}^+$ $C \in \mathbb{R}^+$, $X \sim F$, $C \sim G$. On observe (Y, δ) avec $Y = X \wedge C$ $\delta = \mathbb{I}_{C \leq X}$
Paramètre d'intérêt : Fonction de Hasard cumulée

$$dH(x) = P(X \in (x, x + dx) | X > x)$$

Quelques exemples de problèmes non paramétriques

- **Distribution** $X \sim P$ avec $X \in \mathbb{R}$ et P inconnue. **modèle non dominé**

$$\Theta = \{P : \text{proba sur } \mathbb{R}\}$$

- **Densité** $X \sim P$ $P \ll \mu$ $f = dP/d\mu$ **modèle dominé** par μ

$$\Theta = \{f : \mathbb{R} \rightarrow \mathbb{R}^+, \int f d\mu = 1\}$$

- **Régression** $Y = f(X) + \epsilon$, f inconnue $X \in \mathcal{X}$ (ex $[0, 1]^d$, \mathbb{R}^d)

- **Survie** données censurées $X \in \mathbb{R}^+$ $C \in \mathbb{R}^+$, $X \sim F$, $C \sim G$. On observe (Y, δ) avec $Y = X \wedge C$ $\delta = \mathbb{I}_{C \leq X}$
Paramètre d'intérêt : Fonction de Hasard cumulée

$$dH(x) = P(X \in (x, x + dx) | X > x)$$

Quelques exemples de problèmes non paramétriques

- **Distribution** $X \sim P$ avec $X \in \mathbb{R}$ et P inconnue. **modèle non dominé**

$$\Theta = \{P : \text{proba sur } \mathbb{R}\}$$

- **Densité** $X \sim P$ $P \ll \mu$ $f = dP/d\mu$ **modèle dominé** par μ

$$\Theta = \{f : \mathbb{R} \rightarrow \mathbb{R}^+, \int f d\mu = 1\}$$

- **Régression** $Y = f(X) + \epsilon$, f inconnue $X \in \mathcal{X}$ (ex $[0, 1]^d$, \mathbb{R}^d)

- **Survie** données censurées $X \in \mathbb{R}^+$ $C \in \mathbb{R}^+$, $X \sim F$, $C \sim G$. On observe (Y, δ) avec $Y = X \wedge C$ $\delta = \mathbb{1}_{C \leq X}$
Paramètre d'intérêt : Fonction de Hasard cumulée

$$dH(x) = P(X \in (x, x + dx) | X > x)$$

- Modèles à données dépendantes
 - ▶ **Densité spectrale dans les modèles stationnaires**
 $Y = (Y_1, \dots, Y_n)$

$$\text{Cov}(Y_j, Y_{j+h}) = \gamma(h) = \int_{-\pi}^{\pi} f(\lambda) e^{i\lambda h} d\lambda$$

$f : [-\pi, \pi] \rightarrow \mathbb{R}^+$ paire.

- ▶ **Diffusions ergodiques**

$$dX(t) = b(X(t)) + \sigma(X(t))dB(t)$$

- ▶ **Chaines de Markov**

$$\mathcal{L}(X_n | X_j, j \leq n-1) = \mathcal{L}(X_n | X_{n-1})$$

$K(x|y)$ = densité du noyau de transition. A estimer.

Types de problèmes

- ▶ **Construction de lois de probabilités sur Θ** Ensembles de dimension infinie....contraintes de formes ou autres....
- ▶ **Etude de certaines propriétés probabilistes de ces lois**
- ▶ **Semi paramétrique**
- ▶ **Algorithmes d'implémentation**
- ▶ **Propriétés fréquentistes (asymptotiques) des procédures Bayésiennes**

Familles de lois a priori

- A priori sur des probabilités : Dirichlet Process et extensions
- A priori sur des densités : Mélanges nonparamétriques, Arbre de Polya, bases ou GP + transformations
- A priori sur des fonctions : GP , mélanges généralisés, utilisations de dictionnaires
- A priori sur des variétés ou autres objets : à partir de dictionnaires

Familles de lois a priori

- A priori sur des probabilités : Dirichlet Process et extensions
- A priori sur des densités : Mélanges nonparamétriques, Arbre de Polya, bases ou GP + transformations
- A priori sur des fonctions : GP , mélanges généralisés, utilisations de dictionnaires
- A priori sur des variétés ou autres objets : à partir de dictionnaires

Familles de lois a priori

- A priori sur des probabilités : Dirichlet Process et extensions
- A priori sur des densités : Mélanges nonparamétriques, Arbre de Polya, bases ou GP + transformations
- A priori sur des fonctions : GP , mélanges généralisés, utilisations de dictionnaires
- A priori sur des variétés ou autres objets : à partir de dictionnaires

Familles de lois a priori

- A priori sur des probabilités : Dirichlet Process et extensions
- A priori sur des densités : Mélanges nonparamétriques, Arbre de Polya, bases ou GP + transformations
- A priori sur des fonctions : GP , mélanges généralisés, utilisations de dictionnaires
- A priori sur des variétés ou autres objets : à partir de dictionnaires

- 1 Introduction
 - Rappels sur le bayésien
- 2 Différentes familles de lois a priori
- 3 Processus de Dirichlet**
 - Espace $\mathcal{M}(\mathcal{X})$**
 - Quelques applications du processus de Dirichlet

Espace $\mathcal{M}(\mathcal{X})$

$(\mathcal{X}, \mathcal{B})$: espace des observations .

$$\mathcal{M}(\mathcal{X}) = \{ \text{Probabilités sur } \mathcal{X} \}.$$

- ▶ **Mesurabilité** Typiquement par rapport à la tribu borélienne associée à la convergence faible.
- ▶ **Construction de Probabilités sur \mathcal{X}** : Exemple type processus de Dirichlet .

Definition (Processus de Dirichlet)

Soit α une mesure de probabilité sur \mathcal{X} et $M > 0$. On dit que $P \in \mathcal{M}(\mathcal{X})$ est distribué selon le processus de Dirichlet $DP(\alpha, M)$ si pour tout $k \in \mathbb{N}^*$ et toute partition $(B_j)_{j \leq k}$ de \mathbb{R}

$$(P(B_1), \dots, P(B_k)) \sim \mathcal{D}(M\alpha(B_1), \dots, M\alpha(B_k)).$$

Remarque : Pour toute mesure finie α et $M > 0$ il existe probabilité sur l'ensemble $\mathcal{M}(\mathcal{X})$ des probas sur \mathcal{X}

Propriétés du processus de Dirichlet et représentations

► **Représentation de Sethuraman** Si $P \sim DP(\alpha, M)$ alors presque sûrement

$$P(dx) = \sum_{j=1}^{\infty} p_j \delta_{(\theta_j)}, \quad \theta_j \stackrel{iid}{\sim} \alpha$$

et $(p_j)_j$: stick breaking

$$p_j = V_j \prod_{i < j} (1 - V_i), \quad V_i \stackrel{iid}{\sim} \text{Beta}(1, M)$$

- Si $P \sim DP(\alpha, M)$ alors P est discrète (p.s.)
- Généralisations possibles : Autres lois pour V_j ou pour (V_j, θ_j)
e.g. Pitman Yorr process

Marginalisation : Polya urn représentation et le processus du restaurant chinois

► Model

$$X_j | P \stackrel{iid}{\sim} P, i \leq n \quad P \sim DP(\alpha, M)$$

► Loi marginal de (X_1, \dots, X_n)

$$X_1 \sim \bar{\alpha},$$

$$X_2 | X_1 \sim \frac{M\alpha + \delta_{(X_1)}}{M + 1}$$

$$X_n | X_1, \dots, X_{n-1} \sim \frac{M\alpha + \sum_{i=1}^{n-1} \delta_{(X_i)}}{M + n - 1}$$

► Partition model on the observations (EPPF formula) Si α est une loi sans atomes

$$\mathbb{P}((C_1, \dots, C_k)) = \frac{M^k \Gamma(M) \prod_{j=1}^k \Gamma(n_j)}{\Gamma(M + n)}$$

Loi a posteriori et centrage

- ▶ **LE processus de Dirichlet est centrée sur α**

$$\forall A, \quad E[P(A)] = \alpha(A), \quad E\left(\int f(x)dP(x)\right) = \int f(x)\alpha(dx)$$

- ▶ **loi a posteriori**

Theorem

Si $X_i|P \stackrel{iid}{\sim} P$ et $P \sim DP(\alpha, M)$ alors la loi a posteriori de $P|(X_1, \dots, X_n)$ est un $DP((M\alpha + n\mathbb{P}_n)/(M + n), M + n)$

$$\mathbb{P}_n = \frac{1}{n} \sum_{i=1}^n \delta_{(x_i)}$$

Le Dirichlet Process est une famille conjuguée

- ▶ **Nombre de Clusters**

$$K_n \sim M \log n, \quad \text{as } n \rightarrow +\infty$$

Loi a posteriori et centrage

- ▶ **LE processus de Dirichlet est centrée sur α**

$$\forall A, \quad E[P(A)] = \alpha(A), \quad E\left(\int f(x)dP(x)\right) = \int f(x)\alpha(dx)$$

- ▶ **loi a posteriori**

Theorem

Si $X_i|P \stackrel{iid}{\sim} P$ et $P \sim DP(\alpha, M)$ alors la loi a posteriori de $P|(X_1, \dots, X_n)$ est un $DP((M\alpha + n\mathbb{P}_n)/(M + n), M + n)$

$$\mathbb{P}_n = \frac{1}{n} \sum_{i=1}^n \delta_{(x_i)}$$

Le Dirichlet Process est une famille conjuguée

- ▶ **Nombre de Clusters**

$$K_n \sim M \log n, \quad \text{as } n \rightarrow +\infty$$

Loi a posteriori et centrage

- ▶ **LE processus de Dirichlet est centrée sur α**

$$\forall A, \quad E[P(A)] = \alpha(A), \quad E\left(\int f(x)dP(x)\right) = \int f(x)\alpha(dx)$$

- ▶ **loi a posteriori**

Theorem

Si $X_i|P \stackrel{iid}{\sim} P$ et $P \sim DP(\alpha, M)$ alors la loi a posteriori de $P|(X_1, \dots, X_n)$ est un $DP((M\alpha + n\mathbb{P}_n)/(M + n), M + n)$

$$\mathbb{P}_n = \frac{1}{n} \sum_{i=1}^n \delta_{(x_i)}$$

Le Dirichlet Process est une famille conjuguée

- ▶ **Nombre de Clusters**

$$K_n \sim M \log n, \quad \text{as } n \rightarrow +\infty$$

- 1 Introduction
 - Rappels sur le bayésien
- 2 Différentes familles de lois a priori
- 3 Processus de Dirichlet**
 - Espace $\mathcal{M}(\mathcal{X})$
 - Quelques applications du processus de Dirichlet**

Estimation de la Probabilité

- ▶ **Convergence**
- ▶ **Fonction de répartition**

$$F(x) = P(X \leq x), \quad \alpha((-\alpha, x]) = A(x), \quad F_n(x) = \mathbb{P}_n((-\infty, x])$$

Si $X_1, \dots, X_n | P \stackrel{i.i.d}{\sim} P$ et si $P \sim \mathcal{D}(M, \alpha)$ alors $\forall x \in \mathbb{R}$

$$[F(x) | X_1, \dots, X_n] \sim \text{beta}(MA(x) + nF_n(x), M(1 - A(x)) + n(1 - F_n(x)))$$

Donc

$$E^\pi[F(x) | X^n] = \frac{M}{M+n} A(x) + \frac{n}{M+n} F_n(x) = F_n(x) + O_P(n^{-1}),$$

$$V^\pi[F(x) | X^n] \leq \frac{F_n(x)(1 - F_n(x))}{n} + O(n^{-2})$$

Clustering ou estimation de densité

► Principe

But trouver à quelle population appartient chacun des X_i .

Modèle standard : $[X_i|Z_i = j] \sim g_{\theta_j}$, Z_i : variable d'allocation. Si $j = 1, \dots, k$ k connu : mélange classique.

si k inconnu \Rightarrow Dirichlet Proc mixture

► Dirichlet Mixture : représentation hiérarchique

$$[X_i|\theta_j] \sim g_{\theta_j}, \quad \text{ex : } \mathcal{N}(\mu_j, \sigma_j^2)$$

$$\theta_j | P \stackrel{i.i.d}{\sim} P$$

$$P \sim DP(M, \alpha)$$

► Représentation Marginale

$$X_i \stackrel{iid}{\sim} f_P(x) = \sum_{j=1}^{\infty} p_j g_{\theta_j}(x)$$

► Estimation de densité

DP mixtures : posterior distribution

Il existe bcp d'algos pour simuler dans la loi a posteriori $[P|X^n]$
en particulier si $P \sim DP(\alpha, M)$

- Algorithmes marginaux : On récupère la loi a posteriori de $[(\theta_1, \dots, \theta_n)|X^n]$

$$L_n(X_1, \dots, X_n, d\theta_1, \dots, d\theta_n) = \prod_{i=1}^n g_{\theta_i}(X_i) \underbrace{m_n(d\theta_1, \dots, d\theta_n)}_{\text{Urne de Polya}}$$

On en déduit

$$\pi_i(d\theta_i | \theta_{-i}, X^n) = \sum_{j \neq i} q_{i,j}(X) \delta_{(\theta_j)}(d\theta_i) + q_{i,0} G_{b,i}(d\theta_i)$$

avec

$$q_{i,j}(X) \propto \begin{cases} g_{\theta_j}(X_i) & \text{si } j \neq i, j \geq 1 \\ \int_{\Theta} g_{\theta}(X_i) \alpha(\theta) d\theta & \text{si } j = 0 \end{cases}$$
$$G_{b,i}(\theta) \propto g_{\theta}(X_i) \alpha(\theta)$$

DP mixtures : posterior distribution II

Algorithmes conditionnels : basés sur la représentation
Stick-Breaking

$$L_n(X_1, \dots, X_n, P) = \prod_{i=1}^n \left(\sum_j p_j g_{\theta_j}(X_i) \right)$$

- Slice sampling : Walker , Kalli et al. Augmented approach

$$L_n(X_1, \dots, X_n, U_1, \dots, U_n, P) = \prod_{i=1}^n \left(\sum_j \mathbb{1}_{U_i \leq p_j} g_{\theta_j}(X_i) \right) \Rightarrow$$

$$L_n(X_1, \dots, X_n, \underbrace{U_1, \dots, U_n}_{\text{augmented}}, \underbrace{s_1, \dots, s_n}_{\text{allocations}}, P) = \prod_{i=1}^n \mathbb{1}_{U_i \leq p_{s_i}} g_{\theta_{s_i}}(X_i)$$

- Others : Neal, retrospective sampling (Roberts & Papaspiliopoulos)

DP mixtures : posterior distribution II

Algorithmes conditionnels : basés sur la représentation
Stick-Breaking

$$L_n(X_1, \dots, X_n, P) = \prod_{i=1}^n \left(\sum_j p_j g_{\theta_j}(X_i) \right)$$

- Slice sampling : Walker , Kalli et al. Augmented approach

$$L_n(X_1, \dots, X_n, U_1, \dots, U_n, P) = \prod_{i=1}^n \left(\sum_j \mathbb{1}_{U_i \leq p_j} g_{\theta_j}(X_i) \right) \Rightarrow$$

$$L_n(X_1, \dots, X_n, \underbrace{U_1, \dots, U_n}_{\text{augmented}}, \underbrace{s_1, \dots, s_n}_{\text{allocations}}, P) = \prod_{i=1}^n \mathbb{1}_{U_i \leq p_{s_i}} g_{\theta_{s_i}}(X_i)$$

- Others : Neal, retrospective sampling (Roberts & Papaspiliopoulos)

Variants and extensions

▶ **There are lots of variants to the DP**

- Extensions around the stick breaking (e.g. Pitman Yor and co)
- Extensions around the Polya Urn (e.g. Gibbs priors)
- Extensions around Normalized Gamma process : e.g. Normalized completely random measures
- DDP : dépendance

▶ **Variations around Feature allocation models** chaque indiv peut appartenir à plusieurs groupes : e.g. Indian Buffet process

Variants and extensions

▶ **There are lots of variants to the DP**

- Extensions around the stick breaking (e.g. Pitman Yor and co)
- Extensions around the Polya Urn (e.g. Gibbs priors)
- Extensions around Normalized Gamma process : e.g. Normalized completely random measures
- DDP : dépendance

▶ **Variations around Feature allocation models** chaque indiv peut appartenir à plusieurs groupes : e.g. Indian Buffet process

Variants and extensions

▶ **There are lots of variants to the DP**

- Extensions around the stick breaking (e.g. Pitman Yor and co)
- Extensions around the Polya Urn (e.g. Gibbs priors)
- Extensions around Normalized Gamma process : e.g. Normalized completely random measures
- DDP : dépendance

▶ **Variations around Feature allocation models** chaque indiv peut appartenir à plusieurs groupes : e.g. Indian Buffet process

Variants and extensions

- ▶ **There are lots of variants to the DP**
 - Extensions around the stick breaking (e.g. Pitman Yor and co)
 - Extensions around the Polya Urn (e.g. Gibbs priors)
 - Extensions around Normalized Gamma process : e.g. Normalized completely random measures
 - DDP : dépendance
- ▶ **Variations around Feature allocation models** chaque indiv peut appartenir à plusieurs groupes : e.g. Indian Buffet process

Gaussian Process

Une autre famille de loi a priori : Processus gaussiens

Definition (Processus Gaussien)

Soit \mathcal{X} et $W = (W(x), x \in \mathcal{X})$ est un processus gaussien centré ssi il existe $K(.,.)$ tq pour tout (x_1, \dots, x_n)

$$(W(x_1), \dots, W(x_n)) \sim \mathcal{N}(0, (K(x_i, x_j), i, j \leq n))$$

et $K(.,.)$ est symétrique et semi définie positive.

► Interprétation comme a priori Modèle NP

$$y_i = f(x_i) + \epsilon_i, \quad \epsilon_i \stackrel{iid}{\sim} \mathcal{N}(0, \sigma^2), \quad x_i \in [0, 1]$$

- Paramètre : (f, σ^2) , $f : [0, 1] \rightarrow \mathbb{R}$
- Prior sur (f, σ^2) : $\sigma^2 \sim \pi_\sigma$ et

$$f \sim GP(\mu, K), \quad \text{e.g. } \mu = 0$$

Gaussian Process

Une autre famille de loi a priori : Processus gaussiens

Definition (Processus Gaussien)

Soit \mathcal{X} et $W = (W(x), x \in \mathcal{X})$ est un processus gaussien centré ssi il existe $K(.,.)$ tq pour tout (x_1, \dots, x_n)

$$(W(x_1), \dots, W(x_n)) \sim \mathcal{N}(0, (K(x_i, x_j), i, j \leq n))$$

et $K(.,.)$ est symétrique et semi définie positive.

► Interprétation comme a priori Modèle NP

$$y_i = f(x_i) + \epsilon_i, \quad \epsilon_i \stackrel{iid}{\sim} \mathcal{N}(0, \sigma^2), \quad x_i \in [0, 1]$$

- Paramètre : (f, σ^2) , $f : [0, 1] \rightarrow \mathbb{R}$
- Prior sur (f, σ^2) : $\sigma^2 \sim \pi_\sigma$ et

$$f \sim GP(\mu, K), \quad \text{e.g. } \mu = 0$$

Gaussian Process

Une autre famille de loi a priori : Processus gaussiens

Definition (Processus Gaussien)

Soit \mathcal{X} et $W = (W(x), x \in \mathcal{X})$ est un processus gaussien centré ssi il existe $K(.,.)$ tq pour tout (x_1, \dots, x_n)

$$(W(x_1), \dots, W(x_n)) \sim \mathcal{N}(0, (K(x_i, x_j), i, j \leq n))$$

et $K(.,.)$ est symétrique et semi définie positive.

► Interprétation comme a priori Modèle NP

$$y_i = f(x_i) + \epsilon_i, \quad \epsilon_i \stackrel{iid}{\sim} \mathcal{N}(0, \sigma^2), \quad x_i \in [0, 1]$$

- Paramètre : (f, σ^2) , $f : [0, 1] \rightarrow \mathbb{R}$
- Prior sur (f, σ^2) : $\sigma^2 \sim \pi_\sigma$ et

$$f \sim GP(\mu, K), \quad \text{e.g. } \mu = 0$$

Choix du noyau ?

- K : Mvt Brownien $K(s, t) = s \wedge t$
- K : exponentiel $K(s, t) = e^{-\lambda(s-t)^2}$

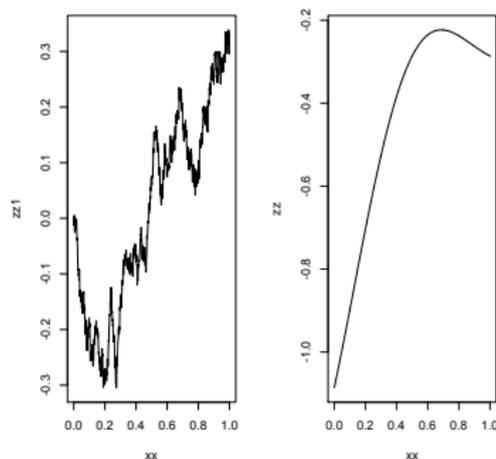


FIGURE: Gaussian processes : left : Brownian motion, right : exponential

Choix du noyau ?

- K : Mvt Brownien $K(s, t) = s \wedge t$
- K : exponentiel $K(s, t) = e^{-\lambda(s-t)^2}$

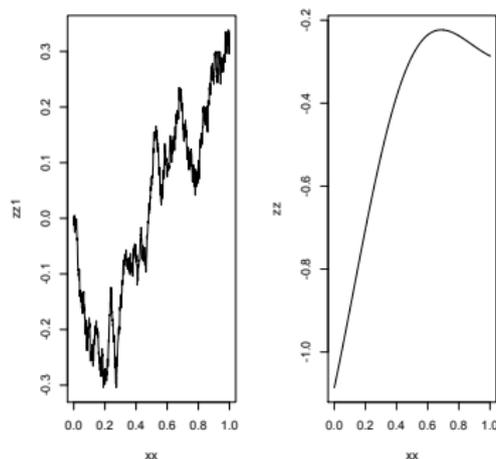


FIGURE: Gaussian processes : left : Brownian motion, right : exponential

Quelques exemples connus

- Brownien ou Riemann Liouville integrated B $\alpha > 0$

$$R^\alpha(t) = \int_0^t \frac{(t-s)^{\alpha-1/2}}{\Gamma(\alpha+1/2)} dB_s, \quad I_{0+}^k f(x) = \int_0^x \frac{(x-t)^{k-1}}{\Gamma(k)} f(t) dt$$

- Serie representation [Karhunen Loeve expansion] : Hilbert Space

$$f = \sum_{i=1}^{\infty} \theta_i \phi_i, \quad (\phi_i)_i = \text{BON} \quad \mathbb{H} \quad \theta_i \stackrel{\text{ind}}{\sim} \mathcal{N}(0, \tau_i^2), \quad \tau_i \downarrow 0$$

- Kriging/interpolation process .

$W = (W_x, x \in \mathcal{X}) = GP(0, K)$. Fixe x_1, \dots, x_N

$$W^*(x) = E[W_x | W_{x_1}, \dots, W_{x_N}] = \sum_{i=1}^N a_i(x) W_{x_i}, \quad a(x) = \Sigma^{-1} \sigma(x)$$

et

$$\Sigma = (K(x_i, x_j), i, j \leq N), \quad \sigma(x) = (K(x; x_i), i \leq N)^T$$

Quelques exemples connus

- Brownien ou Riemann Liouville integrated B $\alpha > 0$

$$R^\alpha(t) = \int_0^t \frac{(t-s)^{\alpha-1/2}}{\Gamma(\alpha+1/2)} dB_s, \quad I_{0+}^k f(x) = \int_0^x \frac{(x-t)^{k-1}}{\Gamma(k)} f(t) dt$$

- Serie representation [Karhunen Loeve expansion] : Hilbert Space

$$f = \sum_{i=1}^{\infty} \theta_i \phi_i, \quad (\phi_i)_i = \text{BON} \text{ III} \quad \theta_i \stackrel{\text{ind}}{\sim} \mathcal{N}(0, \tau_i^2), \quad \tau_i \downarrow 0$$

- Kriging/interpolation process .

$W = (W_x, x \in \mathcal{X}) = GP(0, K)$. Fixe x_1, \dots, x_N

$$W^*(x) = E[W_x | W_{x_1}, \dots, W_{x_N}] = \sum_{i=1}^N a_i(x) W_{x_i}, \quad a(x) = \Sigma^{-1} \sigma(x)$$

et

$$\Sigma = (K(x_i, x_j), i, j \leq N), \quad \sigma(x) = (K(x; x_i), i \leq N)^T$$

Quelques exemples connus

- Brownien ou Riemann Liouville integrated B $\alpha > 0$

$$R^\alpha(t) = \int_0^t \frac{(t-s)^{\alpha-1/2}}{\Gamma(\alpha+1/2)} dB_s, \quad I_{0+}^k f(x) = \int_0^x \frac{(x-t)^{k-1}}{\Gamma(k)} f(t) dt$$

- Serie representation [Karhunen Loeve expansion] : Hilbert Space

$$f = \sum_{i=1}^{\infty} \theta_i \phi_i, \quad (\phi_i)_i = \text{BON} \text{ III} \quad \theta_i \stackrel{\text{ind}}{\sim} \mathcal{N}(0, \tau_i^2), \quad \tau_i \downarrow 0$$

- Kriging/interpolation process .

$W = (W_x, x \in \mathcal{X}) = GP(0, K)$. Fixe x_1, \dots, x_N

$$W^*(x) = E[W_x | W_{x_1}, \dots, W_{x_N}] = \sum_{i=1}^N a_i(x) W_{x_i}, \quad a(x) = \Sigma^{-1} \sigma(x)$$

et

$$\Sigma = (K(x_i, x_j), i, j \leq N), \quad \sigma(x) = (K(x; x_i), i \leq N)^T$$

Comprendre W

- ▶ **Sample paths** $x \rightarrow W(x)$. Typiquement restreindre $W \in (\mathbb{B}, \|\cdot\|)$ banach séparable. e.g. prendre la version continue du Brownien sur $[0, 1]$.
- ▶ **Support** RKHS de W est relié

$$\mathbb{H} = \{h_H : \mathcal{X} \rightarrow \mathbb{R}; h_H(x) = E[W(x)H], \quad H \in \bar{\text{lin}}(W)\}$$

et

$$\langle h_{H_1}, h_{H_2} \rangle_{\mathbb{H}} = E[H_1 H_2]$$

alors

$$h(x) = \langle h, K(x, \cdot) \rangle_{\mathbb{H}}, \quad h \in \mathbb{H}$$

Remarque : $(\mathbb{H}, \langle \cdot, \cdot \rangle_{\mathbb{H}})$ est un espace de Hilbert

Support de $W \in (\mathbb{B}, \|\cdot\|)$ est $\bar{\mathbb{H}}$ pour la norme $\|\cdot\|$

Utilisations dans différents modèles

- Régression sur $[0, 1]^d$

$$f \sim GP(K)$$

- Classification : transformation dans $[0, 1]$: η

$$f(x) = \eta(W(x)), \quad x \in [0, 1]^d$$

- Densité

$$f(x) = \frac{e^{W(x)}}{\int_0^1 e^{W(y)} dy}, \quad \text{ou} \quad f(x) = \frac{g(x)F(h(x)W(x))}{\int_{\mathbb{R}} g(x)F(h(x)W(x)) dx}$$

- Gaussian processes on manifolds (e.g. Ghosal on the sphere, Castillo)
- Hierarchical Gaussian process to adapt over smoothness

$$W \sim GP(K), \quad f(x) = W(\tau x)$$

- $\tau > 1$ détend le temps : augmentation de la régularité
- $\tau < 1$ rétrécit le temps : dérégularise

Utilisations dans différents modèles

- Régression sur $[0, 1]^d$

$$f \sim GP(K)$$

- Classification : transformation dans $[0, 1]$: η

$$f(x) = \eta(W(x)), \quad x \in [0, 1]^d$$

- Densité

$$f(x) = \frac{e^{W(x)}}{\int_0^1 e^{W(y)} dy}, \quad \text{ou} \quad f(x) = \frac{g(x)F(h(x)W(x))}{\int_{\mathbb{R}} g(x)F(h(x)W(x)) dx}$$

- Gaussian processes on manifolds (e.g. Ghosal on the sphere, Castillo)
- Hierarchical Gaussian process to adapt over smoothness

$$W \sim GP(K), \quad f(x) = W(\tau x)$$

- $\tau > 1$ détend le temps : augmentation de la régularité
- $\tau < 1$ rétrécit le temps : dérégularise

Utilisations dans différents modèles

- Régression sur $[0, 1]^d$

$$f \sim GP(K)$$

- Classification : transformation dans $[0, 1]$: η

$$f(x) = \eta(W(x)), \quad x \in [0, 1]^d$$

- Densité

$$f(x) = \frac{e^{W(x)}}{\int_0^1 e^{W(y)} dy}, \quad \text{ou} \quad f(x) = \frac{g(x)F(h(x)W(x))}{\int_{\mathbb{R}} g(x)F(h(x)W(x))dx}$$

- Gaussian processes on manifolds (e.g. Ghosal on the sphere, Castillo)
- Hierarchical Gaussian process to adapt over smoothness

$$W \sim GP(K), \quad f(x) = W(\tau x)$$

- $\tau > 1$ détend le temps : augmentation de la régularité
- $\tau < 1$ rétrécit le temps : dérégularise

Utilisations dans différents modèles

- Régression sur $[0, 1]^d$

$$f \sim GP(K)$$

- Classification : transformation dans $[0, 1]$: η

$$f(x) = \eta(W(x)), \quad x \in [0, 1]^d$$

- Densité

$$f(x) = \frac{e^{W(x)}}{\int_0^1 e^{W(y)} dy}, \quad \text{ou} \quad f(x) = \frac{g(x)F(h(x)W(x))}{\int_{\mathbb{R}} g(x)F(h(x)W(x))dx}$$

- Gaussian processes on manifolds (e.g. Ghosal on the sphere, Castillo)

- Hierarchical Gaussian process to adapt over smoothness

$$W \sim GP(K), \quad f(x) = W(\tau x)$$

- $\tau > 1$ détend le temps : augmentation de la régularité
- $\tau < 1$ rétrécit le temps : dérégularise

Utilisations dans différents modèles

- Régression sur $[0, 1]^d$

$$f \sim GP(K)$$

- Classification : transformation dans $[0, 1]$: η

$$f(x) = \eta(W(x)), \quad x \in [0, 1]^d$$

- Densité

$$f(x) = \frac{e^{W(x)}}{\int_0^1 e^{W(y)} dy}, \quad \text{ou} \quad f(x) = \frac{g(x)F(h(x)W(x))}{\int_{\mathbb{R}} g(x)F(h(x)W(x)) dx}$$

- Gaussian processes on manifolds (e.g. Ghosal on the sphere, Castillo)
- Hierarchical Gaussian process to adapt over smoothness

$$W \sim GP(K), \quad f(x) = W(\tau x)$$

- $\tau > 1$ détend le temps : augmentation de la régularité
- $\tau < 1$ rétrécit le temps : dérégularise

Utilisations dans différents modèles

- Régression sur $[0, 1]^d$

$$f \sim GP(K)$$

- Classification : transformation dans $[0, 1]$: η

$$f(x) = \eta(W(x)), \quad x \in [0, 1]^d$$

- Densité

$$f(x) = \frac{e^{W(x)}}{\int_0^1 e^{W(y)} dy}, \quad \text{ou} \quad f(x) = \frac{g(x)F(h(x)W(x))}{\int_{\mathbb{R}} g(x)F(h(x)W(x))dx}$$

- Gaussian processes on manifolds (e.g. Ghosal on the sphere, Castillo)
- Hierarchical Gaussian process to adapt over smoothness

$$W \sim GP(K), \quad f(x) = W(\tau x)$$

- $\tau > 1$ détend le temps : augmentation de la régularité
- $\tau < 1$ rétrécit le temps : dérégularise

Utilisations dans différents modèles

- Régression sur $[0, 1]^d$

$$f \sim GP(K)$$

- Classification : transformation dans $[0, 1]$: η

$$f(x) = \eta(W(x)), \quad x \in [0, 1]^d$$

- Densité

$$f(x) = \frac{e^{W(x)}}{\int_0^1 e^{W(y)} dy}, \quad \text{ou} \quad f(x) = \frac{g(x)F(h(x)W(x))}{\int_{\mathbb{R}} g(x)F(h(x)W(x)) dx}$$

- Gaussian processes on manifolds (e.g. Ghosal on the sphere, Castillo)
- Hierarchical Gaussian process to adapt over smoothness

$$W \sim GP(K), \quad f(x) = W(\tau x)$$

- $\tau > 1$ détend le temps : augmentation de la régularité
- $\tau < 1$ rétrécit le temps : dérégularise