

# Performances statistiques d'un estimateur Bayésien

Michaël CHICHIGNOUD

LATP  
Université de Provence  
Aix-Marseille 1

Le Mont Dore, Mai 2010

# Plan

- 1 Modèle
  - Estimateur Bayésien
  - Condition sur la Densité  $g$
- 2 Adaptation
  - Idée de la preuve
- 3 Extensions

# Estimation de l'espérance d'une loi gaussienne

On observe  $(Y_1, \dots, Y_n)$  i.i.d. avec  $Y \sim \mathcal{N}(\theta, \sigma^2)$ . On cherche à estimer  $\theta$ . Ici, on connaît l'estimateur optimal (au sens des vitesses de convergences),

$$\hat{\theta}_n = \frac{1}{n} \sum_{i=1}^n Y_i \xrightarrow[n \rightarrow \infty]{1/\sqrt{n}} \theta,$$

On peut écrire ce modèle comme

$$Y_i = \theta + \varepsilon_i, \quad i = 1, \dots, n$$

avec  $\varepsilon \sim \mathcal{N}(0, \sigma^2)$ .

## Estimation de l'espérance d'une loi gaussienne

On observe  $(Y_1, \dots, Y_n)$  i.i.d. avec  $Y \sim \mathcal{N}(\theta, \sigma^2)$ . On cherche à estimer  $\theta$ . Ici, on connaît l'estimateur optimal (au sens des vitesses de convergences),

$$\hat{\theta}_n = \frac{1}{n} \sum_{i=1}^n Y_i \xrightarrow[n \rightarrow \infty]{1/\sqrt{n}} \theta,$$

On peut écrire ce modèle comme

$$Y_i = \theta + \varepsilon_i, \quad i = 1, \dots, n$$

avec  $\varepsilon \sim \mathcal{N}(0, \sigma^2)$ .

## Régression paramétrique avec bruit uniforme

$$Y_i = \theta + U_i, \quad i = 1, \dots, n$$

avec  $U_i \sim \mathcal{U}_{[-0.5, 0.5]}$  • On peut construire un estimateur basé sur la "moyenne"

$$\hat{\theta}_n = \frac{1}{n} \sum_{i=1}^n Y_i \xrightarrow[n \rightarrow \infty]{1/\sqrt{n}} \theta$$

• On peut trouver un estimateur plus rapide

$$\hat{\theta} = \max_{i=1, n} Y_i - \frac{1}{2} \xrightarrow[n \rightarrow \infty]{1/n} \theta$$

## Régression paramétrique avec bruit uniforme

$$Y_i = \theta + U_i, \quad i = 1, \dots, n$$

avec  $U_i \sim \mathcal{U}_{[-0.5, 0.5]}$  • On peut construire un estimateur basé sur la "moyenne"

$$\hat{\theta}_n = \frac{1}{n} \sum_{i=1}^n Y_i \xrightarrow[n \rightarrow \infty]{1/\sqrt{n}} \theta$$

• On peut trouver un estimateur plus rapide

$$\hat{\theta} = \max_{i=1, n} Y_i \xrightarrow[n \rightarrow \infty]{1/n} \theta$$

## Régression paramétrique avec bruit uniforme

$$Y_i = \theta + U_i, \quad i = 1, \dots, n$$

avec  $U_i \sim \mathcal{U}_{[-0.5, 0.5]}$  • On peut construire un estimateur basé sur la "moyenne"

$$\hat{\theta}_n = \frac{1}{n} \sum_{i=1}^n Y_i \xrightarrow[n \rightarrow \infty]{1/\sqrt{n}} \theta$$

• On peut trouver un estimateur plus rapide

$$\hat{\theta} = \max_{i=1, n} Y_i - \frac{1}{2} \xrightarrow[n \rightarrow \infty]{1/n} \theta$$

# Régression

On dispose d'un échantillon d'observations indépendantes

$$((X_1, Y_1), \dots, (X_n, Y_n))_{i=1, \dots, n}, \quad X \in [0, 1]^d, \quad Y \in \mathbb{R}$$

où

$$\mathbb{P}_{Y_i}(dx) = g(x, f(X_i)) dx, \quad i = 1, \dots, n, .$$

où  $f : [0, 1]^d \rightarrow \mathbb{R}$  avec  $f \in \mathbb{H}_d(\beta, L, M)$  isotrope et  $X_i \in \{1/n^{1/d}, 2/n^{1/d}, \dots, 1\}^d$  est le design régulier.

Exemples :

$$Y_i = f(X_i) + \varepsilon_i, \quad \varepsilon \sim \mathcal{N}(0, \sigma), \quad i = 1, \dots, n$$

$$Y_i = f(X_i) + U_i, \quad U_i \sim \mathcal{U}_{[-0.5, 0.5]}, \quad i = 1, \dots, n$$

$$Y_i = f(X_i) \times U_i, \quad U_i \sim \mathcal{U}_{[0, 1]}, \quad i = 1, \dots, n$$



# Régression

On dispose d'un échantillon d'observations indépendantes

$$((X_1, Y_1), \dots, (X_n, Y_n))_{i=1, \dots, n}, \quad X \in [0, 1]^d, \quad Y \in \mathbb{R}$$

où

$$\mathbb{P}_{Y_i}(dx) = g(x, f(X_i)) dx, \quad i = 1, \dots, n, .$$

où  $f : [0, 1]^d \rightarrow \mathbb{R}$  avec  $f \in \mathbb{H}_d(\beta, L, M)$  isotrope et  $X_i \in \{1/n^{1/d}, 2/n^{1/d}, \dots, 1\}^d$  est le design régulier.

**Exemples :**

$$Y_i = f(X_i) + \varepsilon_i, \quad \varepsilon \sim \mathcal{N}(0, \sigma), \quad i = 1, \dots, n$$

$$Y_i = f(X_i) + U_i, \quad U_i \sim \mathcal{U}_{[-0.5, 0.5]}, \quad i = 1, \dots, n$$

$$Y_i = f(X_i) \times U_i, \quad U_i \sim \mathcal{U}_{[0, 1]}, \quad i = 1, \dots, n$$

# Approche localement polynomiale

On cherche à estimer  $f$  en un point  $y \in [0, 1]^d$ .

**Idée** : Sur un voisinage de  $y$  de taille  $h^d$ , noté  $V_y(h)$ , on approche  $f$  par un polynôme  $f_\theta$ ,  $\theta \in \Theta = [-M, M]^{D_\beta}$ , tel que  $\forall x \in V_y(h)$

$$|f(x) - f_\theta(x)| \leq L d h^\beta.$$

L'estimateur Bayésien nous permet d'estimer les coefficients  $\theta$ .  
Définissons la pseudo Vraisemblance pour  $t \in \Theta$

$$L_h(t) = L_h(t, Y^{(n)}) = \prod_{X_i \in V_y(h)} g(Y_i, f_t(X_i))$$

# Approche localement polynomiale

On cherche à estimer  $f$  en un point  $y \in [0, 1]^d$ .

**Idée** : Sur un voisinage de  $y$  de taille  $h^d$ , noté  $V_y(h)$ , on approche  $f$  par un polynôme  $f_\theta$ ,  $\theta \in \Theta = [-M, M]^{D_\beta}$ , tel que  $\forall x \in V_y(h)$

$$|f(x) - f_\theta(x)| \leq L d h^\beta.$$

L'estimateur Bayésien nous permet d'estimer les coefficients  $\theta$ .  
Définissons la pseudo Vraisemblance pour  $t \in \Theta$

$$L_h(t) = L_h(t, Y^{(n)}) = \prod_{X_i \in V_y(h)} g(Y_i, f_t(X_i))$$

# Estimateur Bayésien

On définit

$$\hat{\theta} = \arg \min_{t \in \Theta} \pi_h(t), \quad \pi_h(t) = \int_{\Theta} \|t - u\|_1 (L_h(u))^{1/m} du, \quad t \in \Theta$$

Pour tout  $h \in (0, 1)$ , on peut définir l'estimateur Bayésien associé

$$\hat{f}^{(h)}(y) = f_{\hat{\theta}}(y),$$

**But** : A partir de cette famille d'estimateurs  $\{\hat{f}^{(h)}(y)\}_{h \in H}$ , on veut choisir le "meilleur" (la meilleure fenêtre).

- $\beta, L$  sont connues, Approche minimax
- $\beta, L$  inconnues, Adaptation au sens minimax.

# Estimateur Bayésien

On définit

$$\hat{\theta} = \arg \min_{t \in \Theta} \pi_h(t), \quad \pi_h(t) = \int_{\Theta} \|t - u\|_1 (L_h(u))^{1/m} du, \quad t \in \Theta$$

Pour tout  $h \in (0, 1)$ , on peut définir l'estimateur Bayésien associé

$$\hat{f}^{(h)}(y) = f_{\hat{\theta}}(y),$$

**But** : A partir de cette famille d'estimateurs  $\{\hat{f}^{(h)}(y)\}_{h \in H}$ , on veut choisir le "meilleur" (la meilleure fenêtre).

- $\beta, L$  sont connues, Approche minimax
- $\beta, L$  inconnues, Adaptation au sens minimax.

# Estimateur Bayésien

On définit

$$\hat{\theta} = \arg \min_{t \in \Theta} \pi_h(t), \quad \pi_h(t) = \int_{\Theta} \|t - u\|_1 (L_h(u))^{1/m} du, \quad t \in \Theta$$

Pour tout  $h \in (0, 1)$ , on peut définir l'estimateur Bayésien associé

$$\hat{f}^{(h)}(y) = f_{\hat{\theta}}(y),$$

**But** : A partir de cette famille d'estimateurs  $\{\hat{f}^{(h)}(y)\}_{h \in H}$ , on veut choisir le "meilleur" (la meilleure fenêtre).

- $\beta, L$  sont connues, Approche minimax
- $\beta, L$  inconnues, Adaptation au sens minimax.

Supposons que la vitesse minimax est  $\varphi_{n,\gamma}(\beta) = n^{-\frac{\beta}{\gamma\beta+d}}$ .  
Pour tout  $\theta \in \Theta$ , soit  $U_n = N_h [\Theta - \theta]$  avec  $N_h = (nh^d)^{1/\gamma}$  où  
 $\gamma > 0$  et  $\forall u \in U_n$

$$Z_{n,\theta}(u) = \frac{L_h(\theta + u N_h^{-1})}{L_h(\theta)},$$

## Conditions 1 et 2

On suppose qu'il existe des constantes  $\alpha > 0$ ,  $m \geq 1$  et  $c_1, c_2, c_3, C_1, C_2, s_1, s_2 > 0$  telle que  $\forall n > 1$ ,  $f \in \mathbb{H}_d(\beta, L, M)$ ,  $\theta \in \Theta$  et  $h \in \mathcal{H}_n$ , on a

$$(1) \quad \mathbb{E}_f \left[ 1 - Z_{n,\theta}^{1/m}(u) \right]_+ \leq C_1 \mathcal{E}_h^{c_1} \|u\|_1^\alpha, \quad u \in U_n : \|u\|_1 < s_1,$$

$$(2) \quad \mathbb{E}_f Z_{n,\theta}^{1/m}(u) \leq C_2 \mathcal{E}_h^{c_2} \exp \{-c_3 \|u\|_1^\gamma\}, \quad \forall u \in U_n : \|u\|_1 \geq s_2,$$

où  $a_+ = \max(a, 0)$ ,  $a \in \mathbb{R}$ . On a besoin de connaître explicitement les constantes  $c_3, s_2, m, \alpha$ .



## Méthode de Lepski (Lepski and al. '97)

On se place dans le cas où  $M$  est connue et  $\beta, L$  inconnues.

On construit une grille  $h^{(l)} = h_{\max} 2^{-l}$ ,  $\forall l = 0, \dots, M_n$ .

A partir de la famille d'estimateurs Bayésiens

$\{\hat{f}^l(y) = \hat{f}^{h^{(l)}}(y)\}_{l \in \mathbb{G}_n}$ , on veut trouver un estimateur qui atteint la vitesse adaptative

$$\phi_{n,\gamma}(\beta) = (n^{-1} \rho_{n,\gamma}(\beta))^{\frac{\beta}{\gamma\beta+d}}, \quad \rho_{n,\gamma}(\beta) = 1 + \ln \frac{\varphi_{n,\gamma}(\beta)}{\varphi_{n,\gamma}(b)} \sim (b-\beta) \ln n$$

pour tout  $\beta \in ]0, b]$  et  $L \in [l_*, l^*]$ .

## Méthode de Lepski (Lepski and al. '97)

On se place dans le cas où  $M$  est connue et  $\beta, L$  inconnues.

On construit une grille  $h^{(l)} = h_{\max} 2^{-l}$ ,  $\forall l = 0, \dots, M_n$ .

A partir de la famille d'estimateurs Bayésiens

$\{\hat{f}^{(l)}(y) = \hat{f}^{h^{(l)}}(y)\}_{l \in \mathbb{G}_n}$ , on veut trouver un estimateur qui atteint la vitesse adaptative

$$\phi_{n,\gamma}(\beta) = (n^{-1} \rho_{n,\gamma}(\beta))^{\frac{\beta}{\gamma\beta+d}}, \quad \rho_{n,\gamma}(\beta) = 1 + \ln \frac{\varphi_{n,\gamma}(\beta)}{\varphi_{n,\gamma}(b)} \sim (b-\beta) \ln n$$

pour tout  $\beta \in ]0, b]$  et  $L \in [l_*, l^*]$ .

## Procédure :

On définit la quantité suivante,  $\forall l = 0, \dots, M_n$  :

$$S_n(l) = \left[ \frac{1 + l \ln 2}{n (h(l))^d} \right]^{1/\gamma},$$

où  $M_n \sim \ln n$ . Soit

$$\rho = \left( s_2^\gamma \vee \frac{2^{|\nabla|+2\gamma+1} (2\gamma + 2dq)}{c_3 \gamma (1 \wedge \alpha D_b^{-1})} \right)^{\frac{1}{\gamma}}$$

Définissons l'indice adaptatif

$$\hat{k} = \min \left\{ k = 0, \dots, M_n : |\hat{f}^k(y) - \hat{f}^l(y)| \leq \rho S_n(l) \right. \\ \left. \forall l = k + 1, \dots, M_n \right\}.$$

## Procédure :

On définit la quantité suivante,  $\forall l = 0, \dots, M_n$  :

$$S_n(l) = \left[ \frac{1 + l \ln 2}{n (h(l))^d} \right]^{1/\gamma},$$

où  $M_n \sim \ln n$ . Soit

$$\rho = \left( s_2^\gamma \vee \frac{2^{|\nabla|+2\gamma+1} (2\gamma + 2dq)}{c_3 \gamma (1 \wedge \alpha D_b^{-1})} \right)^{\frac{1}{\gamma}}$$

Définissons l'indice adaptatif

$$\hat{k} = \min \left\{ k = 0, \dots, M_n : |\hat{f}^k(y) - \hat{f}^l(y)| \leq \rho S_n(l) \right. \\ \left. \forall l = k + 1, \dots, M_n \right\}.$$

## Procédure :

On définit la quantité suivante,  $\forall l = 0, \dots, M_n$  :

$$S_n(l) = \left[ \frac{1 + l \ln 2}{n (h(l))^d} \right]^{1/\gamma},$$

où  $M_n \sim \ln n$ . Soit

$$\rho = \left( s_2^\gamma \vee \frac{2^{|\nabla|+2\gamma+1} (2\gamma + 2dq)}{c_3 \gamma (1 \wedge \alpha D_b^{-1})} \right)^{\frac{1}{\gamma}}$$

Définissons l'indice adaptatif

$$\hat{k} = \min \left\{ k = 0, \dots, M_n : |\hat{f}^k(y) - \hat{f}^l(y)| \leq \rho S_n(l) \right. \\ \left. \forall l = k + 1, \dots, M_n \right\}.$$

## Théorème

Pour  $q \geq 1$  et  $\hat{f}^{\hat{k}}(y)$  l'estimateur choisi par la procédure,  
Alors  $\forall n \in \mathbb{N}^*$  et  $(\beta, L) \in J \times \mathcal{L}$  :

$$\sup_{f \in \mathbb{H}_d(\beta, L, M)} \mathbb{E}_f |\hat{f}^{\hat{k}}(y) - f(y)|^q \leq C^* \phi_{n, \gamma}^q(\beta),$$

où  $J = ]0, b]$ ,  $\mathcal{L} = [l_*, l^*]$  et  $C^* = C^*(q, \beta, L, M, \rho)$  est une constante qui ne dépend pas de  $n$ .

## Idée de la Preuve

## Théorème

Soit  $f \in \mathbb{H}_d(\vec{\beta}, L, M)$  et le vecteur  $h \in (0, 1)^d$ .  
Alors pour tout  $\varepsilon \geq \varepsilon_0(h)$ ,  $\forall n \in \mathbb{N}^*$  :

$$\mathbb{P}_f(|\hat{f}_h(y) - f(y)| \geq \frac{\varepsilon}{N_h}) \leq M_1 \varepsilon^D \exp\{-\varepsilon^\gamma\},$$

Ce théorème généralise un résultat disponible dans le livre de Ibragimov et Has'minskii ('83) *Statistical estimation*.

## Idée de la Preuve

## Théorème

Soit  $f \in \mathbb{H}_d(\vec{\beta}, L, M)$  et le vecteur  $h \in (0, 1)^d$ .  
Alors pour tout  $\varepsilon \geq \varepsilon_0(h)$ ,  $\forall n \in \mathbb{N}^*$  :

$$\mathbb{P}_f(|\hat{f}_h(y) - f(y)| \geq \frac{\varepsilon}{N_h}) \leq M_1 \varepsilon^D \exp\{-\varepsilon^\gamma\},$$

Ce théorème généralise un résultat disponible dans le livre de Ibragimov et Has'minskii ('83) *Statistical estimation*.



## Idée de la Preuve

## Théorème

Soit  $f \in \mathbb{H}_d(\vec{\beta}, L, M)$  et le vecteur  $h \in (0, 1)^d$ .  
Alors pour tout  $\varepsilon \geq \varepsilon_0(h)$ ,  $\forall n \in \mathbb{N}^*$  :

$$\mathbb{P}_f(|\hat{f}_h(y) - f(y)| \geq \frac{\varepsilon}{N_h}) \leq M_1 \varepsilon^D \exp\{-\varepsilon^\gamma\},$$

Ce théorème généralise un résultat disponible dans le livre de Ibragimov et Has'minskii ('83) *Statistical estimation*.

$$\begin{aligned}\mathbb{P}_f(|\hat{f}_h(y) - f(y)| \geq \frac{\varepsilon}{N_h}) &\leq \mathbb{P}_f(N_h \|\hat{\theta} - \theta\|_1 \geq \varepsilon) \\ &\leq \mathbb{P}_f\left(\inf_{N_h \|\hat{t} - \theta\|_1 \geq \varepsilon} \pi_h(\hat{t}) \leq \pi_h(\theta)\right).\end{aligned}$$

Ainsi après quelques lignes, on obtient

$$\begin{aligned}\mathbb{P}_f(|\hat{f}_h(y) - f(y)| \geq \frac{\varepsilon}{N_h}) &\leq \mathbb{P}_f\left\{\int_{U_n} Z_{n,\theta}^{1/m}(v) dv < \nu/2\right\} \\ &\quad + \mathbb{P}_f\left\{\int_{U_n \cap \{\|u\|_1 > \varepsilon\}} \|u\|_1 Z_{n,\theta}^{1/m}(u) du > \nu \varepsilon/12\right\}.\end{aligned}$$

$$\begin{aligned}\mathbb{P}_f(|\hat{f}_h(y) - f(y)| \geq \frac{\varepsilon}{N_h}) &\leq \mathbb{P}_f(N_h \|\hat{\theta} - \theta\|_1 \geq \varepsilon) \\ &\leq \mathbb{P}_f\left(\inf_{N_h \|\hat{t} - \theta\|_1 \geq \varepsilon} \pi_h(\hat{t}) \leq \pi_h(\theta)\right).\end{aligned}$$

Ainsi après quelques lignes, on obtient

$$\begin{aligned}\mathbb{P}_f(|\hat{f}_h(y) - f(y)| \geq \frac{\varepsilon}{N_h}) &\leq \mathbb{P}_f\left\{\int_{U_n} Z_{n,\theta}^{1/m}(v) dv < \nu/2\right\} \\ &\quad + \mathbb{P}_f\left\{\int_{U_n \cap \{\|u\|_1 > \varepsilon\}} \|u\|_1 Z_{n,\theta}^{1/m}(u) du > \nu \varepsilon/12\right\}.\end{aligned}$$

# Problèmes ouverts et extensions

- Restrictions sur Hölder isotropes,
- Approximation de  $f$  par  $f_\theta$  où  $\theta \in Cp^D$ ,
- Conditions 1 et 2 : lien avec la distance d'Hellinger,
- $Z(u) = \frac{L_h(\theta + u N_h^{-1})}{L_h(\theta)}$ ,
- Estimation de  $M$ ,
- Inégalité d'oracle,
- Hypothèse d'indépendance.

# Problèmes ouverts et extensions

- Restrictions sur Hölder isotropes,
- Approximation de  $f$  par  $f_\theta$  où  $\theta \in Cp^D$ ,
- Conditions 1 et 2 : lien avec la distance d'Hellinger,
- $Z(u) = \frac{L_h(\theta + u N_h^{-1})}{L_h(\theta)}$ ,
- Estimation de  $M$ ,
- Inégalité d'oracle,
- Hypothèse d'indépendance.

# Problèmes ouverts et extensions

- Restrictions sur Hölder isotropes,
- Approximation de  $f$  par  $f_\theta$  où  $\theta \in Cp^D$ ,
- Conditions 1 et 2 : lien avec la distance d'Hellinger,
- $Z(u) = \frac{L_h(\theta + u N_h^{-1})}{L_h(\theta)}$ ,
- Estimation de  $M$ ,
- Inégalité d'oracle,
- Hypothèse d'indépendance.

# Problèmes ouverts et extensions

- Restrictions sur Hölder isotropes,
- Approximation de  $f$  par  $f_\theta$  où  $\theta \in Cp^D$ ,
- Conditions 1 et 2 : lien avec la distance d'Hellinger,
- $Z(u) = \frac{L_h(\theta + u N_h^{-1})}{L_h(\theta)}$ ,
- Estimation de  $M$ ,
- Inégalité d'oracle,
- Hypothèse d'indépendance.

## Problèmes ouverts et extensions

- Restrictions sur Hölder isotropes,
- Approximation de  $f$  par  $f_\theta$  où  $\theta \in Cp^D$ ,
- Conditions 1 et 2 : lien avec la distance d'Hellinger,
- $Z(u) = \frac{L_h(\theta + u N_h^{-1})}{L_h(\theta)}$ ,
- Estimation de  $M$ ,
- Inégalité d'oracle,
- Hypothèse d'indépendance.



## Problèmes ouverts et extensions

- Restrictions sur Hölder isotropes,
- Approximation de  $f$  par  $f_\theta$  où  $\theta \in Cp^D$ ,
- Conditions 1 et 2 : lien avec la distance d'Hellinger,
- $Z(u) = \frac{L_h(\theta + u N_h^{-1})}{L_h(\theta)}$ ,
- Estimation de M,
- Inégalité d'oracle,
- Hypothèse d'indépendance.

# Problèmes ouverts et extensions

- Restrictions sur Hölder isotropes,
- Approximation de  $f$  par  $f_\theta$  où  $\theta \in Cp^D$ ,
- Conditions 1 et 2 : lien avec la distance d'Hellinger,
- $Z(u) = \frac{L_h(\theta + u N_h^{-1})}{L_h(\theta)}$ ,
- Estimation de M,
- Inégalité d'oracle,
- Hypothèse d'indépendance.

## Problèmes ouverts et extensions

- Restrictions sur Hölder isotropes,
- Approximation de  $f$  par  $f_\theta$  où  $\theta \in Cp^D$ ,
- Conditions 1 et 2 : lien avec la distance d'Hellinger,
- $Z(u) = \frac{L_h(\theta + u N_h^{-1})}{L_h(\theta)}$ ,
- Estimation de M,
- Inégalité d'oracle,
- Hypothèse d'indépendance.

MERCI pour votre attention !!!