

Introduction à la statistique bayésienne

Anne Philippe

Université de Nantes, LMJL 2020

plan du cours

1. Modélisation bayésienne
2. Estimation et prévision bayésienne
3. Construction des lois a priori

Chapitre 1


Modélisation bayésienne

Définitions et exemples

Exemple et
rappels sur le calcul des lois conditionnelles

Exemple du billard

- On lance une bille qui s'arrête à un point $\theta \in [0,1]$ uniformément distribué.
- Question comment déterminer la valeur de θ sans effectuer de mesures ?
- On répète la même expérience N fois de façon indépendante et on note X le nombre de fois où elle s'arrête à gauche du point d'arrêt
- Comment estimer θ à partir de X ?



Approche fréquentiste

- X suit une loi binomiale $\mathcal{B}(N, \theta)$ où θ est un paramètre inconnu
- La vraisemblance s'écrit $V(\theta, X) = \binom{N}{X} \theta^X (1 - \theta)^{N-X}$
- L'estimateur du MV est égal à $\hat{\theta}_N^{MV} = \frac{X}{N}$
- Cet estimateur n'utilise pas la 1er expérience aléatoire.

Alternative

- θ est une v.a. distribuée
- La loi de θ est la loi uniforme sur $[0,1]$
- La loi binomiale $\mathcal{B}(N, \theta)$ est la loi conditionnelle de X sachant θ
- Quelle est la loi de θ sachant X ?

Conditionnement

Soit (X, Y) un couple de variables aléatoires discrètes.
La loi marginale de Y s'écrit

$$P(Y = y) = \sum_x P(X = x, Y = y)$$

La loi conditionnelle de X sachant Y est donnée par la formule de Bayes :

$$P(X = x | Y = y) = \frac{P(X = x, Y = y)}{P(Y = y)}$$

Conditionnement

Soit (X, Y) un couple de variables aléatoires continues.
On note f la densité du couple (X, Y) .

La loi marginale de Y admet une densité égale à

$$f_Y(y) = \int f(x, y) dx$$

La loi conditionnelle de X sachant Y admet une densité définie par

$$f_{X|Y}(x|y) = \frac{f(x, y)}{f_Y(y)}$$

Formule de BAYES

Soit (X, Y) un couple de variables aléatoires

La formule de Bayes est donnée par

$$P(X \in A, Y \in B) = \begin{cases} \int_B P(X \in A | Y = y) f_Y(y) dy & \text{si } Y \text{ est continue} \\ \sum_{y \in B} P(X \in A | Y = y) P(Y = y) & \text{si } Y \text{ est discrète} \end{cases}$$

C'est l'outil central pour calculer les lois conditionnelles.

Exemple du billard (cont.)

• On connaît

$\theta \sim U(0, 1)$ et on note sa densité : $\pi(\vartheta) = I_{[0, 1]}(\vartheta)$

la loi conditionnelle $P(X = x | \theta = \vartheta) = \binom{N}{x} \vartheta^x (1 - \vartheta)^{N-x}$

• Formule de BAYES :

$$P(X = x, \theta \in B) = \int_B P(X = x | \theta = \vartheta) \pi(\vartheta) d\vartheta = \int_B \binom{N}{x} \vartheta^x (1 - \vartheta)^{N-x} I_{[0, 1]}(\vartheta) d\vartheta$$

$$P(X = x, \theta \in B) = P(\theta \in B | X = x) P(X = x)$$

Exemple du billard (cont.)

• La loi marginale de X est

$$P(X = x) = P(X = x, \theta \in [0, 1]) = \binom{N}{x} \int_0^1 \vartheta^x (1 - \vartheta)^{N-x} d\vartheta$$


• En appliquant la formule de Bayes, on obtient

$$\begin{aligned} P(\theta \in B | X = x) &= \frac{P(X = x, \theta \in B)}{P(X = x)} \\ &= \frac{\int_B \vartheta^x (1 - \vartheta)^{N-x} d\vartheta}{\int_0^1 \vartheta^x (1 - \vartheta)^{N-x} d\vartheta} \\ &= \int_B \pi(\vartheta | X = x) d\vartheta \end{aligned}$$

$$\pi(\vartheta | X = x) = \frac{\vartheta^x (1 - \vartheta)^{N-x}}{\int_0^1 \vartheta^x (1 - \vartheta)^{N-x} d\vartheta}$$

c'est la loi beta de paramètres $(x+1, N-x+1)$

expériences numériques



Représentation des lois conditionnelles de θ sachant les N observations

N	5	10	50	100
X	3	5	31	68
MV	0.6	0.5	0.62	0.68

Loi	mean	quantile 2.5%	quantile 97.5 %
(prior) π	.50	.03	.98
$\pi(\cdot X)$ posteriori	N = 5	.57	.88
	N = 10	.50	.77
	N = 50	.62	.74
	N=100	.68	.76

Définition du modèle bayésien

Loi a priori

Modèle paramétrique bayésien

- On considère $P_\theta^n(\cdot), \theta \in \Theta$ une famille de lois indexées par θ .
On note $X = (X_1, \dots, X_n)$ Les observations.
- On suppose que θ est une **VARIABLE ALÉATOIRE**
- La loi $P_\theta^n(\cdot)$ est interprété comme la loi conditionnelle de $X = (X_1, \dots, X_n)$ sachant le paramètre θ

$$P_\theta^n(\cdot) = P^n(\cdot | \theta)$$

Définition :

La Loi du paramètre θ est appelée « Loi a priori »

- cette loi est construite à partir des informations disponibles sur le paramètre θ avant de collecter des données
- L'information (dite a priori) provient
 - d'avis d'expert
 - de résultats d'expériences précédentes dont les résultats sont supposé similaires
 - des propriétés physiques

Exemple du billard :

On sait que θ est la position du point d'arrêt de la première boule. D'après l'expert ce point est uniformément distribué

Fréquentiste vs Bayésien

- X_1, \dots, X_n observations
- il existe $\theta_0 \in \Theta$ inconnu
- $P_{\theta_0}^n(\cdot)$ est la loi des observations
- X_1, \dots, X_n observations
- θ variable aléatoire
- $P_{\theta}^n(\cdot) = P^{(n)}(\cdot | \theta)$ est la loi conditionnelle des observations sachant θ

Inférence

estimateur $\hat{\theta}(X_1, \dots, X_n) \xrightarrow{P-ps-L^p} \theta_0$
intervalle de confiance

?

Inférence

Loi a posteriori

Inférence

- L'objectif est de mettre à jour la loi a priori sur θ à partir des observations.
- En combinant la loi a priori et la loi des observations sachant le paramètre θ , on peut calculer
 - La loi jointe de $(X_1, \dots, X_n, \theta)$
 - La loi marginale de (X_1, \dots, X_n) appelée loi prédictive a priori
 - La loi conditionnelle de θ sachant (X_1, \dots, X_n)

Définition :

La loi conditionnelle du paramètre θ sachant les observations est appelée « loi a posteriori »

calcul de la loi a posteriori continue/continue

- π : densité de la loi a priori
- $f^{(n)}(x_1, \dots, x_n | \theta)$: densité la loi de (X_1, \dots, X_n) sachant θ
- La loi jointe : $g_n(x_1, \dots, x_n, \vartheta) = \pi(\vartheta) f^{(n)}(x_1, \dots, x_n | \vartheta)$
- La loi marginale : $m_n(x_1, \dots, x_n) = \int_{\Theta} \pi(\vartheta) f^{(n)}(x_1, \dots, x_n | \vartheta) d\vartheta$
- La loi a posteriori : $\pi(\vartheta | x_1, \dots, x_n) = \frac{\pi(\vartheta) f^{(n)}(x_1, \dots, x_n | \vartheta)}{m_n(x_1, \dots, x_n)}$

calcul de la loi a posteriori : discrète / discrète

⊙ $\Theta = \{\theta_1, \dots, \theta_p\}$ la loi a priori est définie par $\pi_i = P(\theta = \theta_i)$

⊙ $P^{(n)}(X_1 = x_1, \dots, X_n = x_n | \theta)$: loi de (X_1, \dots, X_n) sachant θ

⊙ La loi marginale :

$$P^{(n)}(X_1 = x_1, \dots, X_n = x_n) = \sum_1^p \pi_i P^{(n)}(X_1 = x_1, \dots, X_n = x_n | \theta = \theta_i)$$

⊙ La loi a posteriori :

$$P(\theta = \theta_i | X_1 = x_1, \dots, X_n = x_n) = \frac{\pi_i P^{(n)}(X_1 = x_1, \dots, X_n = x_n | \theta = \theta_i)}{P^{(n)}(X_1 = x_1, \dots, X_n = x_n)}$$

calcul de la loi a posteriori : continue/discrète

⊙ π : densité de la loi a priori

⊙ La loi de (X_1, \dots, X_n) sachant θ est discrète

⊙ La loi marginale :

$$P_n(X_1 = x_1, \dots, X_n = x_n) = \int_{\Theta} \pi(\vartheta) P^{(n)}(X_1 = x_1, \dots, X_n = x_n | \vartheta) d\vartheta$$

⊙ La loi a posteriori :

$$\pi(\vartheta | x_1, \dots, x_n) = \frac{\pi(\vartheta) P^{(n)}(X_1 = x_1, \dots, X_n = x_n | \vartheta)}{P_n(X_1 = x_1, \dots, X_n = x_n)}$$



calcul de la loi a posteriori : discrète / continue

⊙ $\Theta = \{\theta_1, \dots, \theta_p\}$ la loi a priori est définie par $\pi_i = P(\theta = \theta_i)$

⊙ $f^{(n)}(x_1, \dots, x_n | \theta)$: densité la loi de (X_1, \dots, X_n) sachant θ

⊙ La loi marginale : $m_n(x_1, \dots, x_n) = \sum_1^p \pi_i f^{(n)}(x_1, \dots, x_n | \theta_i)$

⊙ La loi a posteriori : $P(\theta = \theta_i | X_1, \dots, X_n) = \frac{\pi_i f^{(n)}(X_1, \dots, X_n | \theta_i)}{m_n(X_1, \dots, X_n)}$



Remarque

⊙ A partir de la loi a priori et la conditionnelle de X sachant θ on connaît la loi a posteriori à une constante multiplicative près.

⊙ par exemple si θ est une va continue on a

$$\pi(\vartheta | x_1, \dots, x_n) \propto \pi(\vartheta) f^{(n)}(x_1, \dots, x_n | \vartheta)$$

ou

$$\pi(\vartheta | x_1, \dots, x_n) \propto \pi(\vartheta) P^{(n)}(X_1 = x_1, \dots, X_n = x_n | \vartheta)$$

⊙ Comme on cherche une loi de probabilité, la loi a posteriori est bien définie à partir des expressions de droite

Chapitre 2

Estimation et prévision bayésienne

Estimation bayésienne = estimation probabiliste

- a partir du modèle bayésien, on obtient une loi de probabilité sur le paramètre : la loi a posteriori
- cette loi résume l'information provenant des données $X = (X_1, \dots, X_n)$ et de l'information a priori



Estimation par intervalle

crédibilité

intervalle de crédibilité


- On fixe $\alpha \in]0, 1/2[$,
on cherche un intervalle $[l(X); u(X)] \subset \Theta$ tel que

$$P(\theta \in [l(X); u(X)] | X) = 1 - \alpha$$

- Interprétation : Ayant observé X , l'intervalle contient le paramètre θ avec une probabilité $1 - \alpha$

- exemple :
 $l(X) = q(\alpha/2, X)$ et $u(X) = q(1 - \alpha/2, X)$

où $q(\alpha, X)$ quantile d'ordre α de la loi a posteriori




intervalles de crédibilité

- Il n'y a pas unicité des intervalles,
- tous les intervalles de la forme suivante sont des intervalles de crédibilité

$$[q(\beta, X); q(1 - \alpha + \beta, X)] \text{ avec } 0 \leq \beta \leq \alpha$$

- On cherche le plus court intervalle : on cherche la valeur de β qui minimise la longueur


$$q(1 - \alpha + \beta, X) - q(\beta, X)$$



défauts des IC

- Soit $[l(X), u(X)]$ le plus court intervalle de crédibilité de niveau $1 - \alpha$

$[a, b] \subset [l(X), u(X)]$ vérifie $P(\theta \in [a, b] | X_1, \dots, X_n) \approx 0$



$\Rightarrow [l(X), a] \cup [b, u(X)]$ est une région de niveau $1 - \alpha$ plus courte que IC optimal

- La généralisation en dimension supérieure est difficile


Région Highest Posterior Density (HPD)

- On cherche la plus petite région $H \subset \Theta$ telle que $P(\theta \in H | X_1, \dots, X_n) = 1 - \alpha$

- ces régions sont de la forme

$$H(K) = \{\theta : \pi(\theta | X_1, \dots, X_n) > K\}$$

- On choisit la valeur $K := K_{1-\alpha}(X)$ telle que $P(\theta \in H(K_{1-\alpha}(X)) | X_1, \dots, X_n) = 1 - \alpha$



La région $\{\theta : \pi(\theta | X_1, \dots, X_n) > K_{1-\alpha}(X)\}$ est appelé région HPD de niveau $1 - \alpha$

Propriétés

- La définition est indépendante de la dimension de Θ
- En dimension 1 si la distribution est unimodale alors la région HPD est un intervalle qui coïncide avec le plus court intervalle de crédibilité
- La définition se généralise aux lois discrètes en prenant $H(K) = \{\vartheta : P(\theta = \vartheta | X_1, \dots, X_n) > K\}$

Exemple

On modélise X_1, \dots, X_n le nombre de pannes par une loi de poisson de paramètre $\theta > 0$

La loi priori est la loi exponentielle de paramètre 1

Calcul de la loi a posteriori

$$P(X_1 = x_1, \dots, X_n = x_n | \theta) = e^{-n\theta} \theta^{\sum x_i} \frac{1}{x_1! \dots x_n!}$$


$$\pi(\theta) \propto e^{-\theta} I_{\theta > 0}$$

$$\pi(\theta | x_1, \dots, x_n) \propto e^{-(n+1)\theta} \theta^{\sum x_i} I_{\theta > 0}$$

On observe $n = 10$ et $\sum X_i = 20$

loi unimodale : IC et HPD coïncident

Loi gamma (21,11)





En utilisant R

`qgamma` quantile de la loi gamma
`which.min` recherche du min

(1) on calcule et représente la longueur en fonction de β

(2) on détermine la valeur de β qui minimise la longueur

(3) on en déduit le plus court intervalle de crédibilité qui coïncide avec la région HPD



Lien avec les intervalles de confiance.

un intervalle de confiance de niveau $1 - \alpha$ est un intervalle aléatoire $[a(X), b(X)]$ tel que, pour tout θ :

$$P_{\theta}([a(X), b(X)] \ni \theta) = 1 - \alpha$$

$1 - \alpha$ % des intervalles de confiance contiennent la vraie valeur du paramètre

un intervalle de crédibilité de niveau $1 - \alpha$ est un intervalle $[l(X), u(X)]$ tel que

$$P(\theta \in [l(X), u(X)] | X) = 1 - \alpha$$

Après avoir observé X , le paramètre appartient à l'intervalle avec une probabilité $1 - \alpha$

Probabilité fréquentiste d'un intervalle de crédibilité

Soit $[l(X), u(X)]$ un intervalle de crédibilité de niveau $1 - \alpha$

Pour le modèle $\{P_{\theta}, \theta \in \Theta\}$, sa probabilité fréquentiste est égale à

$$P_{\theta}([l(X), u(X)] \ni \theta) = \beta(\theta, n)$$

⚡ En général $\beta(\theta, n) \neq 1 - \alpha$

Exemple : le modèle exponentiel

- conditionnellement à θ , X_1, \dots, X_n iid suivant une loi exponentielle $\theta > 0$

- La loi priori est la gamma de paramètre (a, b)

1. La loi a posteriori est la loi gamma $(a + n, b + \sum X_i)$

2. Pour tout $\beta \in (0, \alpha)$: $\left[\frac{g_{n+a}(\beta)}{b + \sum X_i}, \frac{g_{n+a}(1 - \alpha + \beta)}{b + \sum X_i} \right]$ est un intervalle de crédibilité de niveau $1 - \alpha$

Notation : $g_a(\beta)$ est le quantile d'ordre β et G_a la fonction de répartition de la loi gamma $(a, 1)$



Le niveau fréquentiste est $\beta(n, \theta) = G_n(g_{n+a}(1 - \alpha + \beta) - b\theta) - G_n(g_{n+a}(\beta) - b\theta)$

A n fixé, quand $a \rightarrow 0$ et $b \rightarrow 0$ alors le niveau fréquentiste converge vers $1 - \alpha$

Approximation de la loi gamma

Quand $n \rightarrow \infty$, on a $g_n(\beta) \sim q_\beta \sqrt{n} + n$

Si $x_n \sim \sqrt{nx} + n$ avec $x \neq 0$ alors $G_n(x_n) \sim \Phi(x)$ quand $n \rightarrow \infty$

A (a, b) fixés, le niveau fréquentiste converge vers $1 - \alpha$ quand $n \rightarrow \infty$. L'intervalle de crédibilité de niveau $1 - \alpha$ est un intervalle de confiance asymptotiquement de niveau $1 - \alpha$

Notation : q_β est le quantile d'ordre β et Φ la fonction de répartition de la loi gaussienne $N(0, 1)$



Crédibilité d'une hypothèse

On considère le test statistique

$$H_0 : \theta \in \Theta_0 \text{ contre } H_1 : \theta \in \Theta_1$$

On suppose que $P(\theta \in \Theta_i) \neq 0$ pour $i=1,2$

Règle de décision Bayésienne :

On calcule les probabilités a posteriori des hypothèses :

$$P(\theta \in \Theta_i | X) \text{ pour } i=1,2$$

On dit que H_0 est plus crédible que H_1 si

$$P(\theta \in \Theta_0 | X) \geq P(\theta \in \Theta_1 | X)$$

La valeur de la probabilité a posteriori quantifie la crédibilité de l'hypothèse.

Exemple : modèle exponentiel (cont.)



La loi a posteriori est la loi gamma $(n + a, b + \sum X_i)$

On prend $a=b=1$

On veut tester $\theta \leq 1$ contre $\theta > 1$

On évalue la probabilité a posteriori de l'hypothèse nulle, c'est à dire

$$P(\theta \leq 1 | X) = G_{n+a}(b + \sum X_i) (= 83 \%)$$




Prévision Bayésienne

Prévision en loi

Loi prédictive

- Objectif : on veut prévoir X_{n+1} à partir des observations passées (X_1, \dots, X_n) dans le modèle bayésien



Définition : La loi prédictive est la loi conditionnelle de X_{n+1} sachant (X_1, \dots, X_n) .

Calcul de la loi prédictive

- La loi prédictive s'écrit :

$$p(x_{n+1} | x_1, \dots, x_n) = \begin{cases} \int_{\Theta} p(x_{n+1} | \vartheta, x_1, \dots, x_n) \pi(\vartheta | x_1, \dots, x_n) d\theta & \text{continue} \\ \sum_{\vartheta \in \Theta} p(x_{n+1} | \vartheta, x_1, \dots, x_n) P(\vartheta = \vartheta | x_1, \dots, x_n) & \text{discrète} \end{cases}$$

- Où $p(x_{n+1} | \vartheta, x_1, \dots, x_n)$ est la densité de la loi conditionnelle de X_{n+1} sachant ϑ et le passé X_1, \dots, X_n :

$$p(x_{n+1} | \vartheta, x_1, \dots, x_n) = \frac{f(x_1, \dots, x_{n+1} | \vartheta)}{f(x_1, \dots, x_n | \vartheta)}$$

La loi prédictive est un mélange de loi.



- A partir de la loi prédictive on construit

- Un intervalle de prévision de niveau $1 - \alpha$, c'est un intervalle $[P_1; P_2]$ tel que

$$P(X_{n+1} \in [P_1; P_2] | X_1, \dots, X_n) = 1 - \alpha$$

- Un prédicteur ponctuel : Pour l'erreur L^2 , la meilleure approximation de X_{n+1} par une fonction de X_1, \dots, X_n est l'espérance conditionnelle

$$\hat{X}_{n+1} = E(X_{n+1} | X_1, \dots, X_n)$$

Exemple : observations iid suivant $f(\cdot | \theta)$

- L'indépendance conditionnellement à θ implique que

$$p(x_{n+1} | \vartheta, x_1, \dots, x_n) = f(x_{n+1} | \vartheta)$$

- D'où la loi prédictive

$$p(x_{n+1} | x_1, \dots, x_n) = \int_{\Theta} f(x_{n+1} | \vartheta) \pi(\vartheta | x_1, \dots, x_n) d\vartheta$$

- Le prédicteur ponctuel est $\hat{X}_{n+1} = \int_{\Theta} E(X_{n+1} | \vartheta) \pi(\vartheta | X_1, \dots, X_n) d\vartheta$



Exemple : regression linéaire suivant $X = \theta t + \epsilon$ ϵ iid $N(0, \sigma^2)$

- L'indépendance conditionnellement à θ implique que

$$p(x_{n+1} | \vartheta, x_1, \dots, x_n) = f(x_{n+1} | \vartheta)$$

c'est la densité de la loi gaussienne de moyenne θt_{n+1} et de variance σ^2

- D'où la loi prédictive

$$p(x_{n+1} | x_1, \dots, x_n) = \int_{\Theta \times \mathbb{R}^+} \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2\sigma^2}(x_{n+1} - \theta t_{n+1})^2} \pi(\sigma^2, \vartheta | x_1, \dots, x_n) d\vartheta d\sigma^2$$

- Le prédicteur ponctuel est égal à $\hat{X}_{n+1} = E(\theta | X_1, \dots, X_n) t_{n+1}$



Estimateurs de Bayes

Construction d'estimateurs à partir de la loi a posteriori

Estimateurs de Bayes

- Soit L une fonction de coût :
elle permet évaluer la qualité d'un estimateur $\delta := \delta(X)$ du paramètre θ

Exemple :

$$L_2(\delta, \theta) = (\delta - \theta)^2 \text{ coût/erreur quadratique } L^2$$
$$L_1(\delta, \theta) = |\delta - \theta| \text{ coût/erreur absolue } L^1$$

plus généralement c'est une fonction positive $L: \Theta \times \Theta \rightarrow \mathbb{R}^+$ telle que
 $L(\delta; \theta) = 0 \Leftrightarrow \delta = \theta$

- Le risque bayésien d'un estimateur δ du paramètre θ est

$$r(\delta, \pi) = E(L(\delta(X), \theta)) = \int L(\delta(x), \vartheta) g_n(x, \vartheta) dx_1 \dots dx_n d\vartheta$$
$$= \int L(\delta(x), \vartheta) \pi(\vartheta | x) d\vartheta m_n(x_1, \dots, x_n) dx_1 \dots dx_n$$

Définition : Un estimateur δ^π est un estimateur de Bayes sous coût L , s'il minimise le risque bayésien c'est à dire $r(\delta^\pi, \pi) \leq r(\delta, \pi)$ pour estimateur δ

Construction des estimateurs de Bayes

On définit $\rho(\delta) = \int_{\Theta} L(\delta, \vartheta) \pi(\vartheta | X_1, \dots, X_n) d\vartheta$

Théorème :

$\delta^\pi(X) = \operatorname{argmin}_{\delta} \rho(\delta)$ est un estimateur de Bayes

Cas particulier

Coût quadratique : l'estimateur de Bayes est l'espérance de la loi a posteriori

$$\delta^\pi(X) = E(\theta | X_1, \dots, X_n)$$

Coût absolue : l'estimateur de Bayes est la médiane de la loi a posteriori



Propriétés asymptotiques

Contexte

on suppose que le modèle $\{P_\theta^n = P^n(\cdot | \theta) \theta \in \Theta\}$ est régulier

Sous ces hypothèses : l'estimateur du maximum de vraisemblance θ_n^{MV} converge presque sûrement et θ_n^{MV} est asymptotiquement efficace

On suppose que les observations sont iid suivant f_{θ_0} où θ_0 appartient à l'intérieur de Θ

Théorème 1

si π_1, π_2 sont deux lois a priori telles que $\pi_i(\theta) > 0, \forall \theta \in \Theta$ alors pour tout $A \subset \Theta$:

$$\int_A |\pi_1(\vartheta | X) - \pi_2(\vartheta | X)| d\vartheta \xrightarrow[n \rightarrow \infty]{p.s.} 0$$

Théorème 2

Si π est une loi a priori telle que $\pi(\theta) > 0, \forall \theta \in \Theta$ et π est C^1 sur Θ alors

1) Pour tout intervalle ouvert U contenant θ_0
on a $P(\theta \in U | X) \xrightarrow[n \rightarrow \infty]{p.s.} 1$

2) $E(\theta | X) \xrightarrow[n \rightarrow \infty]{p} \theta_0$

3) $\operatorname{Var}(\theta | X) \xrightarrow[n \rightarrow \infty]{p} 0$

Théorème 3

Si π est une loi a priori telle que $\pi(\theta) > 0, \forall \theta \in \Theta$ et π est C^2 sur

Θ
alors

- 1) On peut approcher la loi a posteriori par la loi gaussienne de moyenne $E(\theta|X)$ et de variance $Var(\theta|X)$
- 2) On peut approcher la loi a posteriori par la loi gaussienne de moyenne θ_n^{MV} et de variance $n^{-1}I^{-1}(\theta_n^{MV})$
où I est l'information de Fisher apportée par une observation
- 3) On a $\sqrt{n}(E(\theta|X) - \theta_n^{MV}) \xrightarrow[p]{} 0$

Conséquence du théorème 3

- 1) L'estimateur de Bayes sous coût quadratique c'est à dire $\delta^\pi(X) = E(\theta|X_1, \dots, X_n)$ est asymptotiquement efficace

On applique le théorème de Slutski
 $\sqrt{n}(E(\theta|X) - \theta_0) = \sqrt{n}(E(\theta|X) - \theta_n^{MV}) + \sqrt{n}(\theta_n^{MV} - \theta_0)$
Le premier terme converge vers 0 en proba et le confond en loi vers $N(0, I^{-1}(\theta_0))$

- 4) Le niveau fréquentiste des intervalles de crédibilité de niveau $1 - \alpha$ converge vers $1 - \alpha$

$$\beta(\theta, n) \xrightarrow[n \rightarrow \infty]{} 1 - \alpha$$

Chapitre 3

Loi a priori

Lois informatives

Loi discrète

- On suppose que le paramètre appartient à un ensemble fini $\Theta = \{\theta_1, \dots, \theta_p\}$ avec les probabilités π_1, \dots, π_p c'est à dire $P(\theta = \theta_i) = \pi_i$
- Source d'information :
 - Les résultats d'études précédentes supposées similaires
 - Les avis de p experts et la proba représente la confiance accordée à chaque expert.

- La loi a posteriori est aussi une loi discrète à valeurs dans Θ



- Pour tout $i=1\dots p$, on a

$$P(\theta = \theta_i | X) = \frac{f_n(X | \theta_i) \pi_i}{\sum_{j=1}^p \pi_j f_n(X | \theta_j)}$$


- Si $X \sim P_{\theta_0}$ avec $P(\theta = \theta_0) = 0$ alors la loi a posteriori ne se concentre pas autour de la vraie valeur c'est à dire il existe un intervalle U tel que $\theta_0 \in U$ et $P(\theta \in U | X) \rightarrow 1$

Illustration

- La loi a priori est uniforme sur $\{0, 1/2, 1, 3/2, 2\}$
- Les observations sont simulées suivant la loi exponentielle de paramètre 0.75



Evolution des probabilités a posteriori en fonction de n



On représente la loi a posteriori en fonction de n pour 3 échantillons.

Illustration (cont.)


- Les observations sont simulées suivant la loi exponentielle de paramètre 1

- On a $P(\theta = 1) = 1/5$

- On observe que

$$P(\theta = 1 | X) \rightarrow 1$$

Evolution des probabilités a posteriori en fonction de n



Histogramme

- On relaxe la contrainte de finitude de $\Theta = \{\theta_1, \dots, \theta_p\}$ en prenant comme support un intervalle
- On ordonne les valeurs $\theta_i, i = 1, \dots, p$
- on ajoute une borne inférieure : $\theta_0 < \theta_1 < \theta_2 < \dots < \theta_p$
- On construit l'histogramme

$$\pi(\theta) = \sum_{i=1}^p \frac{\pi_i}{\theta_i - \theta_{i-1}} 1_{[\theta_{i-1}, \theta_i[}(\theta)$$

- Cette loi vérifie $P(\theta \in [\theta_{i-1}, \theta_i]) = \pi_i$
- $\pi(\theta) > 0$ pour tout $\theta \in [\theta_0, \theta_p[$

- La loi a posteriori s'écrit

$$\pi(\theta | X_1, \dots, X_n) \propto \sum_{i=1}^p \frac{\pi_i}{\theta_i - \theta_{i-1}} f(X_1, \dots, X_n | \theta) 1_{[\theta_{i-1}, \theta_i[}(\theta)$$


D'où

$$\pi(\theta | X_1, \dots, X_n) = \frac{\sum_{i=1}^p \frac{\pi_i}{\theta_i - \theta_{i-1}} f(X_1, \dots, X_n | \theta) 1_{[\theta_{i-1}, \theta_i[}(\theta)}{\sum_{i=1}^p \frac{\pi_i}{\theta_i - \theta_{i-1}} \int_{\theta_{i-1}}^{\theta_i} f(X_1, \dots, X_n | \theta) d\theta}$$


Illustration (cont.)

- les observations sont simulées suivant la loi exponentielle de paramètre .75.

A priori uniforme



A priori non uniforme



Famille de lois conjuguées

- On considère $\mathcal{P} = \{\pi_\lambda, \lambda \in \Lambda\}$ une famille paramétrique de lois sur Θ .
- Définition
On dit que \mathcal{P} est une famille conjuguée avec $\mathcal{F} = \{f_n(\cdot | \theta), \theta \in \Theta\}$ si la loi a priori appartient à \mathcal{P} alors la loi a posteriori appartient aussi à \mathcal{P} .

Autrement dit

$\forall \lambda \in \Lambda$ si $\theta \sim \pi_\lambda$ alors $\exists \lambda(X) \in \Lambda$ tel que $\pi(\theta | X) = \pi_{\lambda(X)}(\theta)$

Exemple de Famille de Lois conjuguées

- \mathcal{F} est la famille des lois exponentielles

$$f(x_1, \dots, x_n | \theta) = \theta^n e^{-\theta n \bar{X}_n}$$

- La famille des lois Gamma est une famille de lois conjuguées :

$$\pi(\theta) = b^a \frac{1}{\Gamma(a)} e^{-b\theta} \theta^{a-1} \mathbb{1}_{\theta > 0} \quad a > 0 \text{ et } b > 0.$$

$$\text{On a } \lambda = (a, b) \rightarrow \lambda(X) = (n + a, b + n\bar{X}_n)$$



- \mathcal{F} est la famille des lois uniformes sur $[0, \theta]$

$$f(x_1, \dots, x_n | \theta) = \frac{1}{\theta^n} \mathbb{1}_{M_n \leq \theta} \text{ avec } M_n = \max(X_1, \dots, X_n)$$

- La famille des lois de Pareto est une famille de lois conjuguées :

$$\pi(\theta) = a \frac{b^a}{\theta^{a+1}} \mathbb{1}_{\theta > b} \text{ avec } a > 0 \text{ et } b > 0.$$

$$\text{On a } \lambda = (a, b) \rightarrow \lambda(X) = (n + a, \max(b, M_n))$$



Choix de l'hyperparamètre λ

- on fixe la valeur de λ à partir de l'information disponible a priori
- Exemple 1. Information a priori : θ est autour de 1
 - On choisit λ tel que $E(\theta) = \int \vartheta \pi_\lambda(\vartheta) d\vartheta = 1$. En fonction de la dimension de Λ on pourra aussi ajouter une contrainte sur la variance de θ qui traduit la confiance accordée à l'information
- Exemple 2. Information a priori : $\theta \in A$ (avec une forte probabilité)
 - On fixe λ tel que $P(\theta \in A) = \int_A \pi_\lambda(\vartheta) d\vartheta = 95\% \text{ ou } 80\%, 99\% \dots$ en fonction de la confiance accordée à l'information

Mélange d'experts a priori

- Proposition : Soit $\mathcal{P} = \{\pi_\lambda, \lambda \in \Lambda\}$ une famille de lois conjuguées, la famille des mélanges de lois de \mathcal{P} forme aussi une famille de lois conjuguées

Rappel : un mélange s'écrit $\sum_{j=1}^k p_j \pi_{\lambda_j}(\theta)$ avec $(\lambda_1, \dots, \lambda_k) \in \Lambda^k$,

$$(p_1, \dots, p_k) \in [0, 1]^k \text{ et } \sum_{j=1}^k p_j = 1$$

- Application : on peut prendre en compte différentes sources d'information et accorder des poids différents en fonction de la fiabilité des sources

Illustration : modèle exponentiel

Expert 1 : $\theta = 1 \pm .5$

$$\frac{a}{b} = 1 \quad \frac{a}{b^2} = .5^2$$

A priori $\Gamma(4, 4)$

A posteriori $\Gamma(n + 4, n\bar{X}_n + 4)$


Expert 2 : $\theta = 2 \pm .5$

$$\frac{a}{b} = 2 \quad \frac{a}{b^2} = .5^2$$

A priori $\Gamma(16, 8)$


A posteriori $\Gamma(n + 16, n\bar{X}_n + 8)$

Mélange
1/2 - 1/2



A priori

$n = 10$



A posteriori

Lois non informatives

Loi a priori impropre

On considère $\pi : \Theta \mapsto \mathbb{R}^+$ telle que $\begin{cases} \sum_{\vartheta \in \Theta} \pi(\vartheta) = \infty & \text{discrète} \\ \int_{\Theta} \pi(\vartheta) d\vartheta = \infty & \text{continue} \end{cases}$

π ne définit pas une loi de probabilité sur Θ

Définition

on dit que $\pi : \Theta \mapsto \mathbb{R}^+$ est une loi impropre pour le modèle $\mathcal{F} = \{f_n(\cdot | \theta), \theta \in \Theta\}$ si

$$\int_{\Theta} \pi(\vartheta) f_n(x_1, \dots, x_n | \vartheta) d\vartheta < \infty \text{ presque sûrement.}$$

Si π est une loi impropre alors la loi a posteriori est bien définie par

$$\pi(\theta | X) = \frac{\pi(\theta) f_n(X | \theta)}{\int_{\Theta} \pi(\vartheta) f_n(X | \vartheta) d\vartheta}$$

Si π est une loi impropre alors pour tout $C > 0$, $\nu(\theta) = C\pi(\theta)$ est aussi une loi impropre. A partir de ces deux lois impropres, on obtient la même loi a posteriori

Exemple : modèle exponentiel

On considère $\pi(\theta) = 1_{\mathbb{R}^+}(\theta)$

on a

$$\int_{\mathbb{R}^+} \pi(\vartheta) d\vartheta = \infty$$

$$\int_{\Theta} \pi(\vartheta) f_n(x_1, \dots, x_n | \vartheta) d\vartheta = \int_{\mathbb{R}^+} \vartheta^n e^{-\vartheta n \bar{X}_n} d\vartheta < \infty \Leftrightarrow (n > 1 \text{ et } \bar{X}_n > 0).$$

La fonction π définit donc une loi impropre si et seulement $n > 1$

Pour $n > 1$, la loi a posteriori est la loi gamma $\Gamma(n + 1, n\bar{X}_n)$

Loi a priori de Laplace

Si Θ est un ensemble fini ou de mesure de Lebesgue finie

($\int_{\Theta} d\vartheta < \infty$) alors la loi a priori de Laplace est la loi uniforme sur Θ

Si $\begin{cases} \Theta \text{ infini dénombrable} \\ \sum_{\vartheta \in \Theta} f_n(X | \vartheta) < \infty \end{cases}$ ou $\begin{cases} \int_{\Theta} d\vartheta = \infty \\ \int_{\Theta} f_n(X | \vartheta) d\vartheta < \infty \end{cases}$

alors la loi a priori de Laplace est une loi impropre définie par

$$\pi(\theta) \propto 1_{\Theta}(\theta).$$

Proposition : Si la loi a priori de Laplace existe alors la loi a posteriori vérifie $\pi(\theta | X) \propto f_n(X | \theta)$

Loi Non informative de Jeffreys

- On suppose que le modèle $\mathcal{F} = \{f_n(\cdot | \theta), \theta \in \Theta\}$ est régulier
- Soit I_n l'information de Fisher et $|I_n|$ son déterminant
- Si $\int_{\Theta} \sqrt{|I_n(\vartheta)|} d\vartheta < \infty$
ou
si $\int_{\Theta} \sqrt{|I_n(\vartheta)|} d\vartheta = \infty$ et $\int_{\Theta} \sqrt{|I_n(\vartheta)|} f_n(X | \vartheta) d\vartheta < \infty$
alors la loi de Jeffreys est définie par $\pi(\vartheta) \propto \sqrt{|I_n(\vartheta)|}$

Loi Non informative de Jeffreys

- La loi de Jeffreys favorise les régions où l'information de Fisher prend des grandes valeurs c'est à dire les régions où les données apportent plus d'information sur le paramètre
- La loi de Jeffreys est invariante par reparamétrisation

Exemple : modèle exponentiel

- On considère n variables aléatoires iid suivant la loi exponentielle
- L'information de Fisher est donnée par $\frac{n}{\theta^2}$
- $\int_0^{\infty} \frac{1}{\vartheta} d\vartheta = \infty$ et $\int_0^{\infty} \vartheta^{n-1} e^{-n\theta\bar{X}_n} d\vartheta < \infty$ ps car $n > 0$ et $\bar{X}_n > 0$ ps
- La loi de Jeffreys est une loi impropre définie $\pi(\theta) \propto \frac{1}{\theta} 1_{R^+}(\theta)$
- La loi a posteriori est la loi gamma $\Gamma(n, n\bar{X}_n)$

