

# Modélisation Bayésienne

Anne Philippe

Nantes Université, LMJL 2024

## plan du cours

1. Modélisation bayésienne
2. Estimation et prévision bayésienne
3. Construction des lois a priori
4. Algorithme MCMC
5. Modèle Hiérarchique

## 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  $\theta$  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  $\theta$  à partir de  $X$  ?



## Approche fréquentiste

- $X$  suit une loi binomiale  $\mathcal{B}(N, \theta)$  où  $\theta$  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

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

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  $\theta$  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) $\pi$		.50	.03	.98
$\pi(\cdot   X)$ posteriori	N = 5	.57	.22	.88
	N = 10	.50	.24	.77
	N = 50	.62	.48	.74
	N=100	.68	.58	.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  $\theta$ .  
On note  $X = (X_1, \dots, X_n)$  les observations.
- On suppose que  $\theta$  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  $\theta$

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

### Définition :

La loi du paramètre  $\theta$  est appelée « loi a priori »

- cette loi est construite à partir des informations disponibles sur le paramètre  $\theta$  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  $\theta$  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
- $\theta$  variable aléatoire
- $P_{\theta}^n(\cdot) = P^n(\cdot | \theta)$  est la loi conditionnelle des observations sachant  $\theta$

### Inférence

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

?

## Inférence

Loi a posteriori

## Inférence

- L'objectif est de mettre à jour la loi a priori sur  $\theta$  à partir des observations.
- En combinant la loi a priori et la loi des observations sachant le paramètre  $\theta$ , 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 ou la vraisemblance Marginale
  - La loi conditionnelle de  $\theta$  sachant  $(X_1, \dots, X_n)$

### Définition :

La loi conditionnelle du paramètre  $\theta$  sachant les observations est appelée « loi a posteriori »

## calcul de la loi a posteriori continue/continue

- $\pi$  : densité de la loi a priori
- $f^{(n)}(x_1, \dots, x_n | \theta)$  : densité la loi de  $(X_1, \dots, X_n)$  sachant  $\theta$
- 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  $\theta$

• 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

•  $\pi$  : densité de la loi a priori

• La loi de  $(X_1, \dots, X_n)$  sachant  $\theta$  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  $\theta$

• 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  $\theta$  on connaît la loi a posteriori à une constante multiplicative près.

• par exemple si  $\theta$  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

## Choix de modèle : Facteur de Bayes :

- On veut comparer deux modèles bayésien  $M_1$  et  $M_2$
- On note  $m_n^1$  et  $m_n^2$  les vraisemblances marginales
- On définit le facteur de Bayes de  $M_1$  contre  $M_2$ 
$$B_{1/2} = \frac{m_n^1(x)}{m_n^2(x)}$$
- Si  $B_{1/2} > 1$  alors le modèle  $M_1$  est meilleur que  $M_2$
- C'est le modèle le plus vraisemblable entre  $M_1$  et  $M_2$

## 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  $\theta$  avec une probabilité  $1 - \alpha$

- exemple :

$$l(X) = q(\alpha/2, X) \text{ et } u(X) = q(1 - \alpha/2, X)$$

où  $q(\alpha, X)$  quantile d'ordre  $\alpha$  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  $\beta$  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  $\Theta$
- 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

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


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

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

- 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

- on calcule et représente la longueur en fonction de  $\beta$
- on détermine la valeur de  $\beta$  qui minimise la longueur
- 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  $\theta$  :

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

- $1 - \alpha$  % 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

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

- Ayant 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  $\theta$ ,  $X_1, \dots, X_n$  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  $\beta$  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  $1 - \alpha$

Notation :  $q_\beta$  est le quantile d'ordre  $\beta$  et  $\Phi$  la fonction de répartition de la loi gaussienne  $N(0, 1)$

- 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  $1 - \alpha$



## Crédibilité d'une hypothèse

- On considère le test statistique  $H_0 : \theta \in \Theta_0$  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 :  $P(\theta \in \Theta_i | X)$  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

Loi a priori

Loi conditionnelle des observations sachant le paramètre



Loi a posteriori



Loi prédictive

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 :

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

• Où  $p(x_{n+1} | \vartheta, x_1, \dots, x_n)$  est la densité de la loi conditionnelle de  $X_{n+1}$  sachant  $\vartheta$  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

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

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

2. 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  $\theta$  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 $X = \theta t + \epsilon$ $\epsilon$ iid $N(0, \sigma^2)$

• L'indépendance conditionnellement à  $\theta$  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  $\theta t_{n+1}$  et de variance  $\sigma^2$

• 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  $\theta$

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  $L: \Theta \times \Theta \rightarrow R^+$  telle que  $L(\delta; \theta) = 0 \Leftrightarrow \delta = \theta$

- Le risque bayésien d'un estimateur  $\delta$  du paramètre  $\theta$  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  $\delta^\pi$  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  $\delta$

## 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 hypothèse : l'estimateur du maximum de vraisemblance  $\theta_n^{MV}$  converge presque sûrement et  $\theta_n^{MV}$  est asymptotiquement efficace
- On suppose que les observations sont iid suivant  $f_{\theta_0}$  où  $\theta_0$  appartient à l'intérieur de  $\Theta$
- Théorème 1**  
si  $\pi_1, \pi_2$  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  $\pi$  est une loi a priori telle que  $\pi(\theta) > 0, \forall \theta \in \Theta$  et  $\pi$  est  $C^1$  sur  $\Theta$  alors

1) Pour tout intervalle ouvert  $U$  contenant  $\theta_0$   
on a  $P(\theta \in U | X) \xrightarrow[n \rightarrow \infty]{ps} 1$

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

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

## Théorème 3

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

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  $\theta_n^{MV}$  et de variance  $n^{-1}I^{-1}(\theta_n^{MV})$   
où  $I$  est l'information de Fisher apportée par une observation

3) On a  $\sqrt{n}(E(\theta | X) - \theta_n^{MV}) \xrightarrow[n \rightarrow \infty]{P} 0$

## 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  $\pi_1, \dots, \pi_p$  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  $\Theta$




- 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



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

Evolution des probabilités a posteriori en fonction de  $n$



## 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 le 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  $\Theta$ .
  - 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 :  
 $\pi(\theta) = b^a \frac{1}{\Gamma(a)} e^{-b\theta} \theta^{a-1} 1_{\theta > 0}$  avec  $a > 0$  et  $b > 0$ .  
 On a  $\lambda = (a, b) \rightarrow \lambda(X) = (n + a, b + n \bar{X}_n)$
- $\mathcal{F}$  est la famille des lois uniformes sur  $[0, \theta]$   
 $f(x_1, \dots, x_n | \theta) = \frac{1}{\theta^n} 1_{M_n \leq \theta}$  avec  $M_n = \max(X_1, \dots, X_n)$ 
  - La famille des lois de Pareto est une famille de lois conjuguées :  
 $\pi(\theta) = a \frac{b^a}{\theta^{a+1}} 1_{\theta > b}$  avec  $a > 0$  et  $b > 0$ .  
 On a  $\lambda = (a, b) \rightarrow \lambda(X) = (n + a, \max(b, M_n))$

## Choix de l'hyperparamètre $\lambda$

- on fixe la valeur de  $\lambda$  à partir de l'information disponible a priori
- Exemple 1. Information a priori :  $\theta$  est autour de 1**
  - On choisit  $\lambda$  tel que  $E(\theta) = \int \theta \pi_\lambda(\theta) d\theta = 1$ . En fonction de la dimension de  $\Lambda$  on pourra aussi ajouter une contrainte sur la variance de  $\theta$  qui traduit la confiance accordée à l'information
- Exemple 2. Information a priori :  $\theta \in A$  (avec une forte probabilité)**
  - On fixe  $\lambda$  tel que  $P(\theta \in A) = \int_A \pi_\lambda(\theta) d\theta = 95\%$  ou  $80\%$ ,  $99\%$  ... 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  $(\lambda_1, \dots, \lambda_k) \in \Lambda^k$ ,  
 $(p_1, \dots, p_k) \in [0, 1]^k$  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  $\Gamma(n+4, n\bar{X}_n+4)$




A priori

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

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

A priori  $\Gamma(16,8)$

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



A posteriori

Mélange  
1/2 -1/2

$n=10$

## Lois non informatives

## Loi a priori impropre

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

$\pi$  ne définit pas une loi de probabilité sur  $\Theta$

**Définition**

on dit que  $\pi : \Theta \rightarrow R^+$  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  $\pi$  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  $\pi$  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  $\pi(\theta) = 1_{R^+}(\theta)$

on a

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

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

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

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

## Loi a priori de Laplace

- Si  $\Theta$  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  $\Theta$
- 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  $\Gamma(n, n\bar{X}_n)$

