

# Statistiques mathématiques : cours 9

Guillaume Lécué

17 septembre 2018

# Aujourd'hui

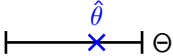
## Présentation des statistiques Bayésiennes

# Fréquentistes / Bayésiens

Donnée :  $X$

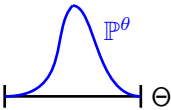
Modèle :  $\{\mathbb{P}_\theta : \theta \in \Theta\}$

1. **fréquentistes** (ce que nous avons fait jusqu'ici) : à une donnée  $X$  est renvoyée un **élément de**  $\Theta$ , appelé estimateur.

$$X \rightsquigarrow \hat{\theta} = \hat{\theta}(X) \in \Theta$$


The diagram shows a horizontal line representing the parameter space  $\Theta$ . A blue cross is placed on the line, with the label  $\hat{\theta}$  above it, indicating a specific point estimate within the space.

2. **Bayésiens** (programme d'aujourd'hui) : à une donnée  $X$  est renvoyée une **mesure de probabilité sur**  $\Theta$ .


$$X \rightsquigarrow \mathbb{P}^\theta = \hat{\mathbb{P}}(X)^\theta = \text{distribution sur } \Theta$$


The diagram shows a horizontal line representing the parameter space  $\Theta$ . A blue bell-shaped curve is drawn above the line, representing a probability distribution. The label  $\mathbb{P}^\theta$  is placed to the right of the curve, indicating the distribution over the space.


# Statistiques Bayésiennes : interprétation

- ▶ Les Bayésien utilisent les données pour construire une distribution  $\mathbb{P}^\theta$  sur  $\Theta$ .
- ▶ Comment interpréter un résultat sous forme de mesure de probabilité ?

Les Bayésiens peuvent ne renvoyer qu'une seule valeur d'estimation de  $\theta$  : le **Maximum a posteriori (MAP)** ou la **moyenne a posteriori** ou la **médiane a posteriori**, etc.



mais en plus ils peuvent donner des niveaux d'incertitude



# Statistiques Bayésiennes : formalisme

L'objectif est de munir l'espace  $\Theta$  d'une mesure de probabilité  $\Rightarrow$

Le paramètre  $\theta$  devient donc une variable aléatoire

On dispose alors d'un couple de variable aléatoires

$$(X, \theta) = (\text{donnée}, \text{paramètre})$$

ayant deux marginales (naturelles) :

- ▶  $\mathbb{P}^{X|\theta} = \mathbb{P}_\theta$  : à  $\theta$  fixé la loi de  $X$  est donnée par la loi du modèle  $\{\mathbb{P}_\theta : \theta \in \Theta\}$  pour cette valeur de  $\theta$  ! cette marginale est donc donnée par le modèle.
- ▶  $\mathbb{P}^{\theta|X}$  : loi du paramètre  $\theta$  étant donnée l'observation  $X \rightsquigarrow$  c'est la loi qu'on cherche à construire sur  $\Theta$  ! Pour la connaître, il faut soit connaître la loi du couple  $(X, \theta)$  ou connaître les loi  $\mathbb{P}^{X|\theta}$  et  $\mathbb{P}^\theta$  et appliquer la [formule de Bayes](#).

## Formule de Bayes (1/2)

Etant donné deux événements  $A$  et  $B$ , on a (par définition)

$$\mathbb{P}[A|B] = \frac{\mathbb{P}[A \cap B]}{\mathbb{P}[B]}$$

De même,

$$\mathbb{P}[B|A] = \frac{\mathbb{P}[A \cap B]}{\mathbb{P}[A]}$$

On en déduit la **formule de Bayes** :

$$\mathbb{P}[A|B] = \frac{\mathbb{P}[B|A]\mathbb{P}[A]}{\mathbb{P}[B]}$$

Ecrire pour des lois admettant des densités, on a

$$\mathcal{L}(\theta|X = x_0)(\theta_0) = \frac{\mathcal{L}(X|\theta = \theta_0)(x_0) \cdot \mathcal{L}(\theta)(\theta_0)}{\mathcal{L}(X)(x_0)}$$

où  $\mathcal{L}(Z)(z)$  est “la valeur” de la densité de la loi de  $Z$  en  $z$ .

## Formule de Bayes (2/2)

$$\mathcal{L}(\theta|X = x_0)(\theta_0) = \frac{\mathcal{L}(X|\theta = \theta_0)(x_0) \cdot \mathcal{L}(\theta)(\theta_0)}{\mathcal{L}(X)(x_0)}$$

- ▶  $\mathcal{L}(X|\theta = \theta_0)(x_0)$  est connue : c'est la valeur de la densité de la loi  $\mathbb{P}_{\theta_0}$  en  $x_0$  du modèle  $\{\mathbb{P}_{\theta} : \theta \in \Theta\}$ ,
- ▶  $\mathcal{L}(\theta)(\theta_0)$  est inconnue : on va devoir se donner cette valeur a priori,
- ▶  $\mathcal{L}(X)(x_0)$  (terme indépendant de  $\theta_0$ ) est vu comme une constante de normalisation de la densité

$$\theta_0 \rightarrow \mathcal{L}(\theta|X = x_0)(\theta_0) \propto \mathcal{L}(X|\theta = \theta_0)(x_0) \cdot \mathcal{L}(\theta)(\theta_0)$$

donnée par

$$\mathcal{L}(X)(x_0) = \int_{\Theta} \mathcal{L}(X|\theta = \theta_0)(x_0) \cdot \mathcal{L}(\theta)(\theta_0) d\theta_0$$

(donc calculable à partir de  $\mathcal{L}(X|\theta)$  et  $\mathcal{L}(\theta)$ ).

# Loi a priori et loi a posteriori

## Definition

Une loi **a priori** est une mesure de probabilité  $\mathbb{P}^\theta$  sur l'espace  $\Theta$  qui est choisie avant l'observation des données.

En statistiques Bayésiennes, on se donne donc (avant toute observation) :

- ▶ un modèle  $\{\mathbb{P}^{X|\theta} : \theta \in \Theta\}$  ( $\underline{\Delta}$  :  $\mathbb{P}^{X|\theta}$  est une loi conditionnelle car  $\theta$  est maintenant une variable aléatoire en statistiques Bayésiennes)
- ▶ une loi a priori  $\mathbb{P}^\theta$  sur  $\Theta$ .

Une fois l'observation  $X = x_0$  observée, on calcul la loi  $\mathbb{P}^{\theta|X=x_0}$  (grâce à la formule de Bayes) :

$$\mathcal{L}(\theta|X = x_0)(\theta_0) \propto \underbrace{\mathcal{L}(X|\theta = \theta_0)(x_0)}_{\text{vraisemblance}} \cdot \underbrace{\mathcal{L}(\theta)(\theta_0)}_{\text{loi a priori}} .$$


## Definition

La loi  $\mathcal{L}(\theta|X)$  est appelée **loi a posteriori**.




# Méthode en statistiques Bayésiennes

1. On se donne une **loi a priori** sur  $\Theta$



2. On observe une **donnée**  $X$
3. On modifie notre a priori sur la loi suivie par le paramètre  $\theta$  en munissant  $\Theta$  d'une nouvelle loi : la **loi a posteriori**



Une fois la loi a posteriori calculée (généralement à la constante absolue près  $\mathcal{L}(X)(X)$  – où le “deuxième  $X$ ” est la donnée alors que  $\mathcal{L}(X)$  est la loi de  $X$ ), on peut faire de l'inférence sur  $\theta$ .

# Calcul de loi a posteriori : exemple (1/2)

On considère :

1. le modèle  $\{\mathbb{P}^{X|\theta} : \theta \in \mathbb{R}\}$  où  $\mathbb{P}^{X|\theta} = \mathcal{N}(\theta, \sigma^2)$ ,
2. la loi a priori  $\mathbb{P}^\theta = \mathcal{N}(\mu, \tau^2)$ .


► Montrer que la loi a posteriori est

$$\mathcal{L}(\theta|X) \sim \mathcal{N}\left(\frac{\tau^2 X + \sigma^2 \mu}{\tau^2 + \sigma^2}, \frac{\sigma^2 \tau^2}{\tau^2 + \sigma^2}\right)$$

► Montrer que le *Maximum a posteriori*, la moyenne a posteriori et la médiane a posteriori sont tous égaux à

$$\frac{\tau^2 X + \sigma^2 \mu}{2(\tau^2 + \sigma^2)}$$

Quand  $\tau = \sigma$  :



## Calcul de loi a posteriori : exemple (2/2)

On considère :

1. le modèle d'échantillonnage  $X_1|\theta, \dots, X_n|\theta \sim_{i.i.d.} X|\theta$  où la loi de  $X$  sachant  $\theta$  a sa loi dans le modèle  $\{\mathbb{P}^{X|\theta} : \theta \in \mathbb{R}\}$  où  $\mathbb{P}^{X|\theta} = \mathcal{N}(\theta, 1)$ ,
  2. la loi a priori  $\mathbb{P}^\theta = \mathcal{N}(0, 1)$ .
- la loi a posteriori est

$$\mathcal{L}(\theta|X_1, \dots, X_n) \sim \mathcal{N}\left(\frac{X_1 + \dots + X_n}{n+1}, \frac{1}{n+1}\right)$$

- le *Maximum a posteriori*, la *moyenne a posteriori* et la *médiane a posteriori* sont tous égaux à

$$\frac{X_1 + \dots + X_n}{n+1}.$$

- un *intervalle de confiance Bayésien* à 95% est donné par

$$\left[ \frac{X_1 + \dots + X_n}{n+1} - \frac{1.96}{\sqrt{n+1}}, \frac{X_1 + \dots + X_n}{n+1} + \frac{1.96}{\sqrt{n+1}} \right]$$

# Propriétés asymptotiques de la loi a posteriori I

**Rappels (fréquentistes)** : Dans le modèle d'échantillonnage associé à un modèle régulier on a :

1. **L'EMV est consistant** : pour tout  $\theta \in \Theta$ ,

$$\hat{\theta}_n^{\text{mv}} \xrightarrow{\mathbb{P}_\theta} \theta.$$

2. **l'EMV est asymptotiquement normal** : pour tout  $\theta \in \Theta$ ,

$$\sqrt{n}(\hat{\theta}_n^{\text{mv}} - \theta) \xrightarrow{d} \mathcal{N}\left(0, \frac{1}{\mathbb{I}(\theta)}\right)$$

où  $\mathbb{I}(\theta) = \mathbb{E}_\theta [(\partial_1 \log f(\theta, X))^2]$  s'appelle **l'information de Fisher** de la famille  $\{\mathbb{P}_\theta = f(\theta, \cdot) \cdot \mu : \theta \in \Theta\}$  au point  $\theta$ .

Il existe des notions similaires en Statistiques Bayésiennes.

# Propriétés asymptotiques de la loi a posteriori II

Dans le modèle d'échantillonnage :

1.  $(X_n|\theta)_n$  une suite de variables aléatoires i.i.d. distribuées selon  $X|\theta$  dont la loi (de  $X$  conditionnellement à  $\theta$ ) est dans le modèle  $\{\mathbb{P}^{X|\theta} : \theta \in \Theta\}$
2.  $\mathbb{P}^\theta$  une loi a priori sur  $\Theta$  (de densité  $\mathcal{L}(\theta)$ )
3. la loi a posteriori  $\Pi(\cdot|(X_i)_{i=1}^n)$  a pour densité

$$\begin{aligned}\theta_0 \rightarrow \mathcal{L}(\theta|(X_i)_{i=1}^n)(\theta_0) &\propto \text{vraisemblance} \times \text{loi a priori} \\ &\propto \mathcal{L}((X_i)_{i=1}^n|\theta = \theta_0) ((X_i)_{i=1}^n) \times \mathcal{L}(\theta)(\theta_0).\end{aligned}$$

## Definition

On dit que la suite de loi a posteriori  $(\Pi(\cdot|(X_i)_{i=1}^n))_n$  est **consistante** quand pour tout  $\theta \in \Theta$  et tout voisinage  $U$  de  $\theta$ , on a, sous  $\mathbb{P}_\theta$ ,

$$\Pi(\theta \in U|(X_i)_{i=1}^n) \xrightarrow{\text{P.S.}} 1.$$

Rem. : Dans cette définition les  $X_i$  sont supposés de loi  $\mathbb{P}_\theta$  pour un  $\theta$  fixé (càd après avoir calculé la loi a posteriori, on revient au modèle fréquentiste en supposant que  $X_i \sim \mathbb{P}_\theta$ ).

## Exemple de consistance

1. Modèle d'échantillonnage de binomiale :  $\mathbb{P}^{X|\theta} = \text{Bin}(\theta)$  pour  $\theta \in \Theta = (0, 1)$
2. Loi a priori sur  $\Theta = [0, 1]$  est une  $\text{Beta}(\alpha, \beta)$ , càd de densité

$$\theta_0 \rightarrow \mathcal{L}(\theta)(\theta_0) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \theta_0^{\alpha-1} (1 - \theta_0)^{\beta-1}.$$

Montrer que

1. la loi a posteriori suit une  $\text{Beta}(S_n + \alpha, n - S_n + \beta)$  où  $S_n = \sum_{i=1}^n X_i$ , càd, pour  $X_1^n = (X_i)_{i=1}^n$  de densité

$$\theta_0 \rightarrow \mathcal{L}(\theta|X_1^n)(\theta_0) = \frac{\Gamma(n+2)}{\Gamma(S_n+1)\Gamma(n-S_n+1)} \theta_0^{S_n} (1 - \theta_0)^{n-S_n}.$$

2. les moyenne et variance a posteriori vérifient

$$\mathbb{E}[\theta|X_1^n] = \frac{S_n + \alpha}{n + \alpha + \beta} \text{ et } \text{var}(\theta|X_1^n) = \frac{(S_n + \alpha)(n - S_n + \beta)}{(n + \alpha + \beta)^2(n + \alpha + \beta + 1)}.$$

3. la suite des loi a posteriori est consistante.

## Propriétés asymptotiques de la loi a posteriori III

Dans le modèle d'échantillonnage,  $(X_n)_n$  une suite de variables aléatoires i.i.d. distribuées selon une loi dans le modèle  $\{\mathbb{P}^{X|\theta} : \theta \in \Theta\}$

- ▶  $\pi_1$  une loi a priori associée à la loi a posteriori  $\Pi_1(\cdot | (X_i)_{i=1}^n)$
- ▶  $\pi_2$  une loi a priori associée à la loi a posteriori  $\Pi_2(\cdot | (X_i)_{i=1}^n)$

Si  $(\Pi_1(\cdot | (X_i)_{i=1}^n))_n$  et  $(\Pi_2(\cdot | (X_i)_{i=1}^n))_n$  sont consistants alors pour tout  $\theta \in \Theta$ , sous  $\mathbb{P}_\theta$ ,

$$\sup_A |\Pi_1(A | (X_i)_{i=1}^n) - \Pi_2(A | (X_i)_{i=1}^n)| \xrightarrow{\text{p.s.}} 0.$$

Asymptotiquement le choix de la loi a priori n'a pas d'importance

# Propriétés asymptotiques de la loi a posteriori IV

Dans un modèle régulier la loi a posteriori se comporte asymptotiquement comme

$$\Pi(\cdot | (X_i)_{i=1}^n) \approx \hat{\theta}_n^{\text{mv}} + \frac{1}{\sqrt{n}} \mathcal{N}\left(0, \mathbb{I}(\hat{\theta}_n^{\text{mv}})^{-1}\right) \underset{\text{sous } \mathbb{P}_{\theta_0}}{\approx} \theta_0 + \frac{1}{\sqrt{n}} \mathcal{N}\left(0, \mathbb{I}(\theta_0)^{-1}\right)$$

où

- ▶  $\hat{\theta}_n^{\text{mv}} \in \operatorname{argmax}_{\theta_1 \in \Theta} \mathcal{L}((X_i)_{i=1}^n | \theta = \theta_1)$
- ▶  $\mathbb{I}(\hat{\theta}_n^{\text{mv}})$  est l'information de Fisher en  $\hat{\theta}_n^{\text{mv}}$  pour une observation.

## Théorème

*Dans un modèle régulier et pour une loi a priori continue et positive en  $\theta_0 \in \Theta \subset \mathbb{R}$ , on a*

$$\int_{\mathbb{R}} \left| \mathcal{L}(\sqrt{n}(\theta - \hat{\theta}_n^{\text{mv}}) | X_1^n)(t) - \sqrt{\frac{\mathbb{I}(\hat{\theta}_n^{\text{mv}})}{2\pi}} \exp(-t^2 \mathbb{I}(\hat{\theta}_n^{\text{mv}})/2) \right| dt \xrightarrow{\text{P.S.}} 0$$



# Estimateur de Bayes

Etant donné une fonction de perte

$$\ell : \Theta \times \Theta \rightarrow \mathbb{R}^+$$

(par exemple,  $\ell(\theta, \beta) = (\theta - \beta)^2$ ), l'estimateur de Bayes est

$$\hat{\theta}_b(x) \in \operatorname{argmin}_{\beta \in \Theta} \int_{\theta \in \Theta} \ell(\theta, \beta) d\mathbb{P}^{\theta|X=x}(\theta)$$

Par exemple, pour la perte quadratique, l'estimateur de Bayes est la moyenne a posteriori :

$$\hat{\theta}_b(x) = \mathbb{E}[\theta|X = x].$$