

# STA305 : Partie I

## Approche bayésienne

Boris Hejblum

*ISPED M2 Biostatistique, Université de Bordeaux  
Inserm BPH U1219 / Inria BSO, équipe SISTM*

[boris.hejblum@u-bordeaux.fr](mailto:boris.hejblum@u-bordeaux.fr)  
<https://borishejblum.science>

12 novembre 2019





# Objectifs du cours

## Se **familiariser** avec l'approche **bayésienne** :

- 1 être capable de proposer une modélisation bayésienne adéquate face à un problème concret
- 2 savoir calculer la distribution *a posteriori* dans le cas de relations de conjugaison
- 3 comprendre l'impact de la loi *a priori* et la notion d'*a priori* faiblement-informatif
- 4 comprendre la notion de MAP et de moyenne *a posteriori*, d'intervalle de crédibilité ainsi que la différence avec un intervalle de confiance
- 5 comprendre les notions de risques et de coûts, et leurs implications dans la théorie de la décision

# Objectifs du cours

## Se **familiariser** avec l'approche **bayésienne** :

- 1 être capable de proposer une modélisation bayésienne adéquate face à un problème concret
- 2 savoir calculer la distribution *a posteriori* dans le cas de relations de conjugaison
- 3 comprendre l'impact de la loi *a priori* et la notion d'*a priori* faiblement-informatif
- 4 comprendre la notion de MAP et de moyenne *a posteriori*, d'intervalle de crédibilité ainsi que la différence avec un intervalle de confiance
- 5 comprendre les notions de risques et de coûts, et leurs implications dans la théorie de la décision

**NB** : ces notes ne se veulent en aucun cas exhaustives, et l'on renverra le lecteur curieux aux ouvrages bien plus complets que sont *Le choix bayésien* de C. Robert et *Le raisonnement bayésien* de E. Parent & J. Bernier..



## La statistique :

- Une science **mathématique**
- **décrire** ce qui s'est produit
- faire des **projections** quant à ce qu'il **peut** advenir dans le **futur**
- s'appuie sur l'**observation** de phénomènes naturels pour en proposer une interprétation, souvent à travers des **modèles probabilistes**

## La statistique :

- Une science **mathématique**
- **décrire** ce qui s'est produit
- faire des **projections** quant à ce qu'il **peut** advenir dans le **futur**
- s'appuie sur l'**observation** de phénomènes naturels pour en proposer une interprétation, souvent à travers des **modèles probabilistes**

## La statistique « fréquentiste » :

- Neyman & Pearson
- paramètres vu comme **déterministes**
- Estimation par le **Maximum de Vraisemblance**
- **théorie des tests** statistiques & **intervalle de confiance**













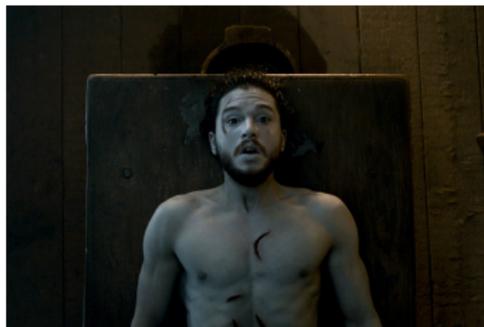






# Bayésiens vs. Fréquentistes : point historique

- 1 **Bayes + Laplace**  $\Rightarrow$  développement de la Statistique aux **XVIII-XIX<sup>e</sup> siècles**
- 2 Galton & Pearson, puis Fisher & Neymann  $\Rightarrow$  théorie **fréquentiste** devenue dominante au cours du **XX<sup>e</sup> siècle**
- 3 au tournant du **XXI<sup>e</sup> siècle** : avènement de l'ordinateur moderne  $\Rightarrow$  **comeback du bayésien**



# Bayésiens vs. Fréquentistes : un débat dépassé

Fisher rejetait fermement le raisonnement bayésien

⇒ communauté divisée en 2 au XX<sup>e</sup> siècle















# Trois composants

# Trois composants

## 1 La question

La première étape dans la construction d'un modèle est toujours d'identifier la question à laquelle on souhaite répondre

## 2 Le modèle d'échantillonnage

## 3 La distribution *a priori*

# Trois composants

## 1 La question

La première étape dans la construction d'un modèle est toujours d'identifier la question à laquelle on souhaite répondre

## 2 Le modèle d'échantillonnage

Quelles **observations** sont disponibles pour répondre à cette question ?  
Comment peuvent-elles être **décrites** ?

## 3 La distribution *a priori*



# Le modèle d'échantillonnage

$\mathbf{y}$  : les observations disponibles

⇒ **modèle probabiliste** (paramétrique) **génératif** :

$$Y_i \stackrel{iid}{\sim} f(y|\theta)$$

# La distribution *a priori*

Dans la modélisation bayésienne, par rapport à la modélisation fréquentiste, on ajoute une loi de probabilité sur les paramètres  $\theta$  :

$$\theta \sim \pi(\theta)$$

$$Y_i|\theta \stackrel{iid}{\sim} f(y|\theta)$$

$\theta$  sera ainsi traité comme une variable aléatoire,  
mais qui n'est jamais observée !

# Retour à l'exemple historique de Laplace

- 1 La question
- 2 Modèle d'échantillonnage
- 3 Distribution *a priori*

# Retour à l'exemple historique de Laplace

## ① La question

...

## ② Modèle d'échantillonnage

...

## ③ Distribution *a priori*

...

# Retour à l'exemple historique de Laplace

## ① La question

Quand un enfant naît, est-il plus probable que ce soit une fille plutôt qu'un garçon ?

## ② Modèle d'échantillonnage

...

## ③ Distribution *a priori*

...

# Retour à l'exemple historique de Laplace

## 1 La question

Quand un enfant naît, est-il plus probable que ce soit une fille plutôt qu'un garçon ?

## 2 Modèle d'échantillonnage

Distribution de Bernoulli :  $Y_i = 1$  si le nouveau né  $i$  est une fille, 0 si c'est un garçon

$$Y_i \sim \text{Bernoulli}(\theta) \quad \theta \in [0, 1]$$

## 3 Distribution *a priori*

...

# Retour à l'exemple historique de Laplace

## 1 La question

Quand un enfant naît, est-il plus probable que ce soit une fille plutôt qu'un garçon ?

## 2 Modèle d'échantillonnage

Distribution de Bernoulli :  $Y_i = 1$  si le nouveau né  $i$  est une fille, 0 si c'est un garçon

$$Y_i \sim \text{Bernoulli}(\theta) \quad \theta \in [0, 1]$$

## 3 Distribution *a priori*

Un *a priori* uniforme sur  $\theta$  (la probabilité qu'un nouveau né soit une fille plutôt qu'un garçon) :

$$\theta \sim \mathcal{U}_{[0,1]}$$

## Distribution *a posteriori*

L'objet de la modélisation bayésienne : **inférer la distribution *a posteriori* des paramètres**

- **Loi *a posteriori*** : la loi de  $\theta$  conditionnellement aux observations  $p(\theta|Y)$

## Distribution *a posteriori*

L'objet de la modélisation bayésienne : **inférer la distribution *a posteriori* des paramètres**

- **Loi *a posteriori*** : la loi de  $\theta$  conditionnellement aux observations  $p(\theta|Y)$

**Théorème de Bayes :**

$$p(\theta|\mathbf{y}) = \frac{f(\mathbf{y}|\theta)\pi(\theta)}{f(\mathbf{y})}$$

où  $f(\mathbf{y}) = \int_{\Theta} f(\mathbf{y}|\theta)\pi(\theta) d\theta$  est la loi marginale des données

## Distribution *a posteriori*

L'objet de la modélisation bayésienne : **inférer la distribution *a posteriori* des paramètres**

- **Loi *a posteriori*** : la loi de  $\theta$  conditionnellement aux observations  $p(\theta|Y)$

**Théorème de Bayes :**

$$p(\theta|\mathbf{y}) = \frac{f(\mathbf{y}|\theta)\pi(\theta)}{f(\mathbf{y})}$$

où  $f(\mathbf{y}) = \int_{\Theta} f(\mathbf{y}|\theta)\pi(\theta) d\theta$  est la loi marginale des données

La distribution *a posteriori* est calculée à partir :

- 1 du modèle d'échantillonnage  $f(\mathbf{y}|\theta)$  – qui donne la vraisemblance  $f(\mathbf{y}|\theta)$  pour l'ensemble des observations
- 2 de la loi *a priori*  $\pi(\theta)$

# Application à l'exemple historique

- 1 La vraisemblance
- 2 La loi *a priori*
- 3 La distribution *a posteriori*

# Application à l'exemple historique

## ① La vraisemblance

...

## ② La loi *a priori*

...

## ③ La distribution *a posteriori*

...

# Application à l'exemple historique

## ① La vraisemblance

$$f(\mathbf{y}|\theta) = \prod_{i=1}^n \theta^{y_i} (1-\theta)^{(1-y_i)} = \theta^S (1-\theta)^{n-S} \quad \text{où } S = \sum_{i=1}^n y_i$$

## ② La loi *a priori*

...

## ③ La distribution *a posteriori*

...

# Application à l'exemple historique

## ① La vraisemblance

$$f(\mathbf{y}|\theta) = \prod_{i=1}^n \theta^{y_i} (1-\theta)^{(1-y_i)} = \theta^S (1-\theta)^{n-S} \quad \text{où } S = \sum_{i=1}^n y_i$$

## ② La loi *a priori*

Uniforme :  $\pi(\theta) = 1$

## ③ La distribution *a posteriori*

...

# Application à l'exemple historique

## ① La vraisemblance

$$f(\mathbf{y}|\theta) = \prod_{i=1}^n \theta^{y_i} (1-\theta)^{(1-y_i)} = \theta^S (1-\theta)^{n-S} \quad \text{où } S = \sum_{i=1}^n y_i$$

## ② La loi *a priori*

Uniforme :  $\pi(\theta) = 1$

## ③ La distribution *a posteriori*

$$p(\theta|\mathbf{y}) = \frac{\theta^S (1-\theta)^{n-S}}{f(\mathbf{y})} = p(\theta|\mathbf{y}) = \binom{n}{S} (n+1) \theta^S (1-\theta)^{n-S}$$

# Application à l'exemple historique

## 1 La vraisemblance

$$f(\mathbf{y}|\theta) = \prod_{i=1}^n \theta^{y_i} (1-\theta)^{(1-y_i)} = \theta^S (1-\theta)^{n-S} \quad \text{où } S = \sum_{i=1}^n y_i$$

## 2 La loi *a priori*

Uniforme :  $\pi(\theta) = 1$

## 3 La distribution *a posteriori*

$$p(\theta|\mathbf{y}) = \frac{\theta^S (1-\theta)^{n-S}}{f(\mathbf{y})} = p(\theta|\mathbf{y}) = \binom{n}{S} (n+1) \theta^S (1-\theta)^{n-S}$$

Pour répondre à notre question d'intérêt, on peut alors calculer : ...

# Application à l'exemple historique

## 1 La vraisemblance

$$f(\mathbf{y}|\theta) = \prod_{i=1}^n \theta^{y_i} (1-\theta)^{(1-y_i)} = \theta^S (1-\theta)^{n-S} \quad \text{où } S = \sum_{i=1}^n y_i$$

## 2 La loi *a priori*

Uniforme :  $\pi(\theta) = 1$

## 3 La distribution *a posteriori*

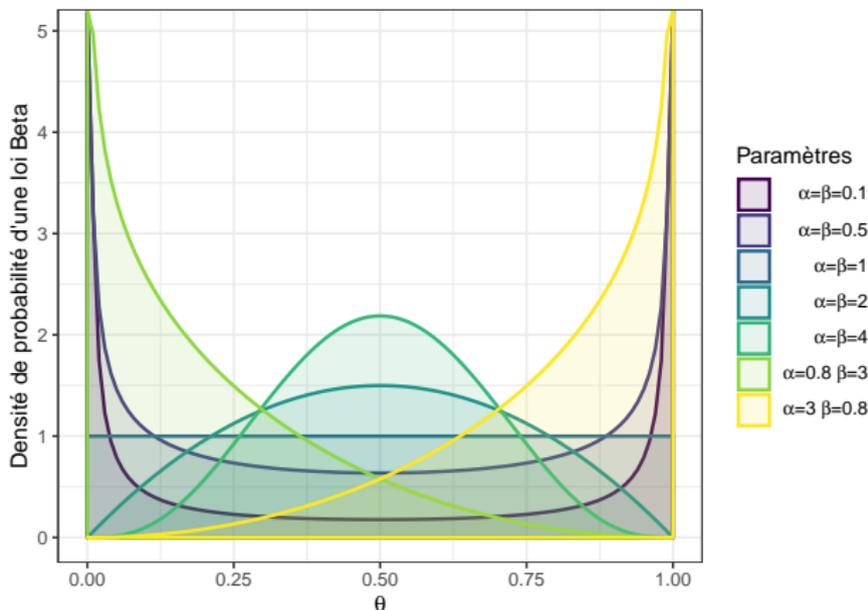
$$p(\theta|\mathbf{y}) = \frac{\theta^S (1-\theta)^{n-S}}{f(\mathbf{y})} = p(\theta|\mathbf{y}) = \binom{n}{S} (n+1) \theta^S (1-\theta)^{n-S}$$

Pour répondre à notre question d'intérêt, on peut alors calculer :

$$P(\theta \geq 0.5|\mathbf{y}) = \int_{0.5}^1 p(\theta|\mathbf{y}) = \binom{n}{S} (n+1) \int_{0.5}^1 \theta^S (1-\theta)^{n-S} d\theta \approx 1.15 \cdot 10^{-42}$$

# La distribution Beta

$$f(\theta) = \frac{(\alpha + \beta - 1)!}{(\alpha - 1)! (\beta - 1)!} \theta^{\alpha-1} (1 - \theta)^{\beta-1} \text{ pour } \alpha > 0 \text{ et } \beta > 0$$



Exemples de paramétrisations pour la distribution Beta



# Conjugaison de la distribution Beta

***a priori* Beta** :  $\pi = \text{Beta}(\alpha, \beta)$

**Loi *a posteriori* associée** : ...

# Conjugaison de la distribution Beta

***a priori* Beta** :  $\pi = \text{Beta}(\alpha, \beta)$

**Loi *a posteriori* associée** :  $p(\theta|\mathbf{y}) \propto \theta^{\alpha+S-1} (1-\theta)^{\beta+(n-S)-1}$

...

Le signe  $\propto$  signifie « proportionnel à »

# Conjugaison de la distribution Beta

***a priori* Beta** :  $\pi = \text{Beta}(\alpha, \beta)$

**Loi *a posteriori* associée** :  $p(\theta|\mathbf{y}) \propto \theta^{\alpha+S-1} (1-\theta)^{\beta+(n-S)-1}$

$\Rightarrow \theta|\mathbf{y} \sim \text{Beta}(\alpha + S, \beta + (n - S))$

Le signe  $\propto$  signifie « proportionnel à »

# Conjugaison de la distribution Beta

***a priori*** Beta :  $\pi = \text{Beta}(\alpha, \beta)$

**Loi *a posteriori*** associée :  $p(\theta|\mathbf{y}) \propto \theta^{\alpha+S-1} (1-\theta)^{\beta+(n-S)-1}$

$\Rightarrow \theta|\mathbf{y} \sim \text{Beta}(\alpha + S, \beta + (n - S))$

On parle alors de **distributions conjuguées** car les distributions ***a posteriori*** et ***a priori*** appartiennent à la **même famille paramétrique**

Le signe  $\propto$  signifie « proportionnel à »

Impact du choix de l'*a priori*

Interprétation de l' <i>a priori</i>	Paramètres de la distribution Beta	$P(\theta \geq 0,5 y)$
#garçons > #filles	$\alpha = 0,1; \beta = 3$	$1,08 \cdot 10^{-42}$
#garçons < #filles	$\alpha = 3; \beta = 0,1$	$1,19 \cdot 10^{-42}$
#garçons = #filles	$\alpha = 4; \beta = 4$	$1,15 \cdot 10^{-42}$
#garçons $\neq$ #filles	$\alpha = 0,1; \beta = 0,1$	$1,15 \cdot 10^{-42}$
non-informatif	$\alpha = 1; \beta = 1$	$1,15 \cdot 10^{-42}$

Pour 493 472 nouveaux-nés dont 241 945 filles

Impact du choix de l'*a priori*

Interprétation de l' <i>a priori</i>	Paramètres de la distribution Beta	$P(\theta \geq 0,5 \mathbf{y})$
#garçons > #filles	$\alpha = 0, 1; \beta = 3$	$1,08 \cdot 10^{-42}$
#garçons < #filles	$\alpha = 3; \beta = 0, 1$	$1,19 \cdot 10^{-42}$
#garçons = #filles	$\alpha = 4; \beta = 4$	$1,15 \cdot 10^{-42}$
#garçons $\neq$ #filles	$\alpha = 0, 1; \beta = 0, 1$	$1,15 \cdot 10^{-42}$
non-informatif	$\alpha = 1; \beta = 1$	$1,15 \cdot 10^{-42}$

Pour 493 472 nouveaux-nés dont 241 945 filles

Interprétation de l' <i>a priori</i>	Paramètres de la distribution Beta	$P(\theta \geq 0,5 \mathbf{y})$
#garçons > #filles	$\alpha = 0,1, \beta = 3$	0.39
#garçons < #filles	$\alpha = 3, \beta = 0,1$	0.52
#garçons = #filles	$\alpha = 4, \beta = 4$	0.46
#garçons $\neq$ #filles	$\alpha = 0,1, \beta = 0,1$	0.45
non-informatif	$\alpha = 1, \beta = 1$	0.45

Pour 20 nouveaux-nés dont 9 filles

# Impact de différent *a priori* Beta pour 20 naissances observées

## *a priori* : pour & contre

Avoir une distribution *a priori* :

- 😊 donne de la **flexibilité**
- 😄 permet d'incorporer de la **connaissance extérieure**
- 😞 ajoute nécessairement de la **subjectivité**

⇒ le choix (élicitation) de la distribution *a priori* est un point sensible !

# Propriété de la distribution *a priori*

- 1 Le support de la loi *a posteriori* doit être inclus dans celui de la distribution *a priori* :  
si  $\pi(\theta) = 0$ , alors  $p(\theta|\mathbf{y}) = 0$
- 2 Les différents paramètres sont indépendants *a priori*

# Élicitation de la loi *a priori*

**Stratégies pour communiquer** avec des experts non-statisticiens

⇒ transformer leurs **connaissances *a priori*** en **distributions *a priori***

- La **méthode des histogrammes** : demander aux experts de donner des poids à des intervalles de valeurs  
⚠ peuvent donner une probabilité *a priori* nulle pour des valeurs plausible des paramètres
- Choisir une **famille de distributions paramétriques**  $p(\theta|\eta)$  en **accord avec les experts** (e.g. pour certains quantiles ou moments) – permet de résoudre le problème du support, mais l'impact de la famille paramétrique choisie est important
- Éliciter les lois *a priori* à partir de la **littérature** scientifique
- ...

# La quête des *a priori* non-informatifs

Parfois, on a **aucune connaissance *a priori***

Quelle loi *a priori* utiliser ?



# La quête des *a priori* non-informatifs

Parfois, on a **aucune connaissance *a priori***

⇒ la loi Uniforme, un **a priori non-informatif** ?

# La quête des *a priori* non-informatifs

Parfois, on a **aucune connaissance *a priori***

⇒ la loi Uniforme, un **a priori non-informatif** ?

2 difficultés majeures :

① **Lois impropres**  $\int_{\Theta} \pi(\theta) d\theta = \infty$

# La quête des *a priori* non-informatifs

Parfois, on a **aucune connaissance *a priori***

⇒ la loi Uniforme, un **a priori non-informatif** ?

2 difficultés majeures :

- 1 **Lois impropres**  $\int_{\Theta} \pi(\theta) d\theta = \infty$
- 2 **Lois non-invariantes**

# Non invariance de la loi uniforme : détail

Soit  $F_X(x) = P(X < x)$

# Non invariance de la loi uniforme : détail

Soit  $F_X(x) = P(X < x)$

Si  $Y = g(X)$ , alors

$$F_Y(y) = P(Y < y) = P(g(X) < y) = P(X < g^{-1}(y))$$

## Non invariance de la loi uniforme : détail

Soit  $F_X(x) = P(X < x)$

Si  $Y = g(X)$ , alors

$$F_Y(y) = P(Y < y) = P(g(X) < y) = P(X < g^{-1}(y))$$

En dérivant par rapport à  $y$ , on obtient :

$$f_Y(y) = \frac{\partial g^{-1}(y)}{\partial y} f_X(g^{-1}(y))$$

## Non invariance de la loi uniforme : détail

Soit  $F_X(x) = P(X < x)$

Si  $Y = g(X)$ , alors

$$F_Y(y) = P(Y < y) = P(g(X) < y) = P(X < g^{-1}(y))$$

En dérivant par rapport à  $y$ , on obtient :

$$f_Y(y) = \frac{\partial g^{-1}(y)}{\partial y} f_X(g^{-1}(y)) \neq f_X(g^{-1}(y)) = f_X(x)$$

**NB** : La formule s'étend au cas multidimensionnel où  $|J|$  désigne le déterminant de la matrice jacobienne  $J$  (matrice des dérivées partielles)

# La quête des *a priori* non-informatifs

Parfois, on a **aucune connaissance *a priori***

⇒ la loi Uniforme, un **a priori non-informatif** ?

2 difficultés majeures :

① **Lois impropres**  $\int_{\Theta} \pi(\theta) d\theta = \infty$

② **Lois non-invariantes**

*Autres solutions ?*

# La loi *a priori* de Jeffreys

⇒ Un a priori **faiblement informatif**, invariant par re-paramétrisation

- *a priori* unidimensionnel de Jeffreys :

$$\pi(\theta) \propto \sqrt{I(\theta)} \quad \text{où } I \text{ est la matrice d'information de Fisher}$$

- *a priori* multidimensionnel de Jeffreys :

$$\pi(\boldsymbol{\theta}) \propto \sqrt{|I(\boldsymbol{\theta})|}$$

En pratique, il est généralement plus facile (et commun) de considérer les paramètres indépendants *a priori*

# La loi *a priori* de Jeffreys : application à l'exemple historique

$$f(y|\theta) = \theta^y(1 - \theta)^{(1-y)}$$

La loi *a priori* de Jeffreys : application à l'exemple historique

$$f(y|\theta) = \theta^y(1-\theta)^{(1-y)}$$

$$\pi(\theta) \propto \sqrt{I(\theta)}$$

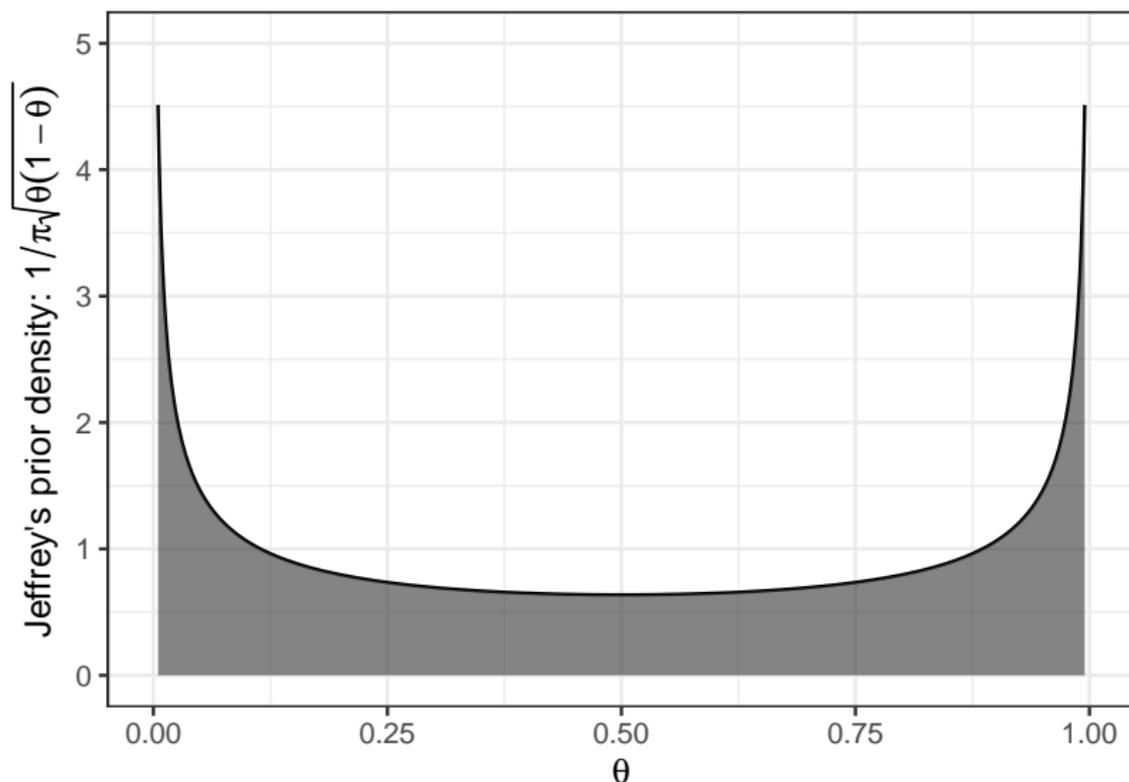
$$\propto \sqrt{-\mathbb{E}_{Y|\theta} \left[ \frac{d^2 \log(f(y|\theta))}{d\theta^2} \right]}$$

$$\propto \dots$$

La loi *a priori* de Jeffreys : application à l'exemple historique

$$f(y|\theta) = \theta^y(1-\theta)^{(1-y)}$$

$$\begin{aligned} \pi(\theta) &\propto \sqrt{I(\theta)} \\ &\propto \sqrt{-\mathbb{E}_{Y|\theta} \left[ \frac{d^2 \log(f(y|\theta))}{d\theta^2} \right]} \\ &\propto \sqrt{\mathbb{E}_{Y|\theta} \left[ \frac{y}{\theta^2} + \frac{1-y}{(1-\theta)^2} \right]} \\ &\propto \sqrt{\theta \left( \frac{1}{\theta^2} \right) + (1-\theta) \left( \frac{1}{(1-\theta)^2} \right)} \\ &\propto \sqrt{\frac{1}{\theta} + \frac{1}{1-\theta}} \\ &\propto \frac{1}{\sqrt{\theta(1-\theta)}} \end{aligned}$$

Loi *a priori* de Jeffreys : illustration dans l'exemple historique

# Hyper-priors & modèles hiérarchiques

Niveaux hiérarchiques :

①  $\pi(\theta)$

②  $f(\mathbf{y}|\theta)$

# Hyper-priors & modèles hiérarchiques

Niveaux hiérarchiques :

①  $\eta \sim h(\eta)$

②  $\pi(\theta|\eta)$

③  $f(\mathbf{y}|\theta)$

# Hyper-priors & modèles hiérarchiques

- Niveaux hiérarchiques :**
- 1  $\eta \sim h(\eta)$
  - 2  $\pi(\theta|\eta)$
  - 3  $f(\mathbf{y}|\theta)$

$$p(\theta|\mathbf{y}) = \frac{f(\mathbf{y}|\theta)\pi(\theta)}{f(\mathbf{y})} = \frac{\int f(\mathbf{y}|\theta, \eta)\pi(\theta|\eta)h(\eta)d\eta}{f(\mathbf{y})}$$

# Hyper-priors & modèles hiérarchiques

- Niveaux hiérarchiques :**
- ①  $\eta \sim h(\eta)$
  - ②  $\pi(\theta|\eta)$
  - ③  $f(\mathbf{y}|\theta)$

$$p(\theta|\mathbf{y}) = \frac{f(\mathbf{y}|\theta)\pi(\theta)}{f(\mathbf{y})} = \frac{\int f(\mathbf{y}|\theta, \eta)\pi(\theta|\eta)h(\eta)d\eta}{f(\mathbf{y})} = \frac{f(\mathbf{y}|\theta)\int \pi(\theta|\eta)h(\eta)d\eta}{f(\mathbf{y})}$$

**NB :** 3 niveaux hiérarchiques  $\Leftrightarrow$  2 niveaux avec  $\pi(\theta) = \int \pi(\theta|\eta)h(\eta)d\eta$

# Hyper-priors & modèles hiérarchiques

- Niveaux hiérarchiques :
- 1  $\eta \sim h(\eta)$
  - 2  $\pi(\theta|\eta)$
  - 3  $f(\mathbf{y}|\theta)$

$$p(\theta|\mathbf{y}) = \frac{f(\mathbf{y}|\theta)\pi(\theta)}{f(\mathbf{y})} = \frac{\int f(\mathbf{y}|\theta, \eta)\pi(\theta|\eta)h(\eta)d\eta}{f(\mathbf{y})} = \frac{f(\mathbf{y}|\theta)\int \pi(\theta|\eta)h(\eta)d\eta}{f(\mathbf{y})}$$

**NB** : 3 niveaux hiérarchiques  $\Leftrightarrow$  2 niveaux avec  $\pi(\theta) = \int \pi(\theta|\eta)h(\eta)d\eta$

$\Rightarrow$  peut **faciliter la modélisation** & l'**élicitation** des lois *a priori*

# Utilisation d'hyper-priors dans l'exemple historique

Exemple historique du sexe à la naissance avec un *a priori* Beta

...

## Utilisation d'hyper-priors dans l'exemple historique

Exemple historique du sexe à la naissance avec un *a priori* Beta

⇒ 2 hyper-priors Gamma pour  $\alpha$  et  $\beta$  :

$$\alpha \sim \text{Gamma}(4; 0,5)$$

$$\beta \sim \text{Gamma}(4; 0,5)$$

$$\theta | \alpha, \beta \sim \text{Beta}(\alpha; \beta)$$

$$Y_i | \theta \stackrel{iid}{\sim} \text{Bernoulli}(\theta)$$

# Bayésien empirique

Élicitation de la loi *a priori* d'un paramètre d'après sa loi marginale empirique

# Bayésien empirique

Élicitation de la loi *a priori* d'un paramètre d'après sa loi marginale empirique

⇒ nécessite d'estimer cet *a priori* à partir des données

# Bayésien empirique

Élicitation de la loi *a priori* d'un paramètre d'après sa loi marginale empirique

⇒ nécessite d'estimer cet *a priori* à partir des données

- 1 hyper-paramètres  $\eta$
- 2 estimés par  $\hat{\eta}$  grâce à des méthodes fréquentistes (e.g. Max de Vraisemblance ou Méthode des Moments)
- 3 injectés dans la loi *a priori* :  $\pi(\theta|\hat{\eta})$
- 4 ⇒ loi *a posteriori* :  $p(\theta|\mathbf{y}, \hat{\eta})$

# Bayésien empirique

Élicitation de la loi *a priori* d'un paramètre d'après sa loi marginale empirique

⇒ nécessite d'estimer cet *a priori* à partir des données

- 1 hyper-paramètres  $\eta$
  - 2 estimés par  $\hat{\eta}$  grâce à des méthodes fréquentistes (e.g. Max de Vraisemblance ou Méthode des Moments)
  - 3 injectés dans la loi *a priori* :  $\pi(\theta|\hat{\eta})$
  - 4 ⇒ loi *a posteriori* :  $p(\theta|\mathbf{y}, \hat{\eta})$
- Combine les approches bayésienne et fréquentiste
  - Distribution *a posteriori* concentrée (variance ↘), mais biais ↗ (données utilisées 2x !)
  - Approximation d'une approche totalement bayésienne











## Bayes séquentiel : application à l'exemple historique

Imaginons que l'on commence par observer 20 naissances  $\mathbf{y}_{1:20}$  début 1745, dont 9 filles, et que l'on ait un *a priori* uniforme sur  $\theta$  :

$$\theta | \mathbf{y}_{1:20} \sim \text{Beta}(10, 12)$$

On observe ensuite  $\mathbf{y}_{21:493472}$  les 493 452 naissances restantes entre 1745 et 1770, dont 241 936 filles, et on utilise alors cet *a priori* Beta(10, 12) sur  $\theta$  :

$$\theta | \mathbf{y}_{1:20}, \mathbf{y}_{21:493472} \sim \dots$$

## Bayes séquentiel : application à l'exemple historique

Imaginons que l'on commence par observer 20 naissances  $\mathbf{y}_{1:20}$  début 1745, dont 9 filles, et que l'on ait un *a priori* uniforme sur  $\theta$  :

$$\theta | \mathbf{y}_{1:20} \sim \text{Beta}(10, 12)$$

On observe ensuite  $\mathbf{y}_{21:493472}$  les 493 452 naissances restantes entre 1745 et 1770, dont 241 936 filles, et on utilise alors cet *a priori* Beta(10, 12) sur  $\theta$  :

$$\begin{aligned} \theta | \mathbf{y}_{1:20}, \mathbf{y}_{21:493472} &\sim \text{Beta}(10 + 241\,936, 12 + 251\,516) \\ &\sim \text{Beta}(241\,946, 251\,528) \end{aligned}$$

On retrouve la distribution *a posteriori* avec l'ensemble des observations







# Théorie de la décision

Contexte : estimation d'un paramètre inconnu  $\theta$

Décision : choix d'un estimateur ponctuel  $\hat{\theta}$  « optimal »

**fonction de coût** : représente la pénalité associée au choix d'un  $\hat{\theta}$  particulier

Pour choisir le  $\hat{\theta}$  optimal, on minimise la fonction de coût choisie

un grand nombre de fonctions de coût différentes sont possibles : chacune d'entre elle résulte en un estimateur ponctuel optimal différent

# Estimateurs ponctuels

- **Espérance *a posteriori*** :  $\mu_P = \mathbb{E}(\theta|\mathbf{y}) = \mathbb{E}_{\theta|\mathbf{y}}(\theta)$   
pas toujours facile car nécessite le calcul d'une intégrale...  
⇒ minimise le coût quadratique  
...

# Estimateurs ponctuels

- **Espérance *a posteriori*** :  $\mu_P = \mathbb{E}(\theta|\mathbf{y}) = \mathbb{E}_{\theta|\mathbf{y}}(\theta)$   
pas toujours facile car nécessite le calcul d'une intégrale...  
⇒ minimise le coût quadratique
- **Maximum *A Posteriori* (MAP)** :  
plus facile à calculer : une simple maximisation de  $f(\mathbf{y}|\theta)\pi(\theta)$

# Estimateurs ponctuels

- **Espérance *a posteriori*** :  $\mu_P = \mathbb{E}(\theta|\mathbf{y}) = \mathbb{E}_{\theta|\mathbf{y}}(\theta)$   
pas toujours facile car nécessite le calcul d'une intégrale...  
⇒ minimise le coût quadratique
- **Maximum *A Posteriori* (MAP)** :  
plus facile à calculer : une simple maximisation de  $f(\mathbf{y}|\theta)\pi(\theta)$
- **Median *a posteriori*** : la médiane de  $p(\theta|\mathbf{y})$

# Estimateurs ponctuels

- **Espérance *a posteriori*** :  $\mu_P = \mathbb{E}(\theta|\mathbf{y}) = \mathbb{E}_{\theta|\mathbf{y}}(\theta)$   
pas toujours facile car nécessite le calcul d'une intégrale. . .  
⇒ minimise le coût quadratique
- **Maximum *A Posteriori* (MAP)** :  
plus facile à calculer : une simple maximisation de  $f(\mathbf{y}|\theta)\pi(\theta)$
- **Median *a posteriori*** : la médiane de  $p(\theta|\mathbf{y})$

⚠ L'approche bayésienne fournit, au delà de l'estimation ponctuelle, une caractérisation complète de la distribution *a posteriori*

# MAP sur l'exemple historique

Calcul du Maximum *A Posteriori* dans l'exemple historique des naissances féminines à Paris avec un *a priori* uniforme :

$$p(\theta|\mathbf{y}) = \binom{n}{S} (n+1)\theta^S(1-\theta)^{n-S}$$

avec  $n = 493\,472$  et  $S = 241\,945$

$$\hat{\theta}_{MAP} = \dots$$

## MAP sur l'exemple historique

Calcul du Maximum *A Posteriori* dans l'exemple historique des naissances féminines à Paris avec un *a priori* uniforme :

$$p(\theta|\mathbf{y}) = \binom{n}{S} (n+1)\theta^S(1-\theta)^{n-S}$$

avec  $n = 493\,472$  et  $S = 241\,945$

$$\hat{\theta}_{MAP} = \frac{S}{n} = 0,4902912$$

Espérance *a posteriori* sur l'exemple historique

Calcul de l'espérance *a posteriori* dans l'exemple historique des naissances féminines à Paris avec un *a priori* uniforme :

$$p(\theta|\mathbf{y}) = \binom{n}{S} (n+1)\theta^S(1-\theta)^{n-S}$$

avec  $n = 493\,472$  et  $S = 241\,945$

$$E(\theta|\mathbf{y}) = \int_0^1 \theta p(\theta|\mathbf{y}) d\theta$$

$\tilde{\theta} = \dots$

## Espérance *a posteriori* sur l'exemple historique

Calcul de l'espérance *a posteriori* dans l'exemple historique des naissances féminines à Paris avec un *a priori* uniforme :

$$p(\theta|\mathbf{y}) = \binom{n}{S} (n+1)\theta^S(1-\theta)^{n-S}$$

avec  $n = 493\,472$  et  $S = 241\,945$

$$E(\theta|\mathbf{y}) = \int_0^1 \theta p(\theta|\mathbf{y}) d\theta$$

$$\tilde{\theta} = \binom{n}{S} (n+1) \frac{S+1}{\binom{n}{S} (n+1)(n+2)} = \frac{S+1}{n+2} = 0,4902913$$

# Rappel sur l'Intervalle de confiance

Quelle est l'interprétation d'un intervalle de confiance fréquentiste au niveau 95% ?

...

## Rappel sur l'Intervalle de confiance

Quelle est l'interprétation d'un intervalle de confiance fréquentiste au niveau 95% ?

*95% des intervalles calculés sur l'ensemble des échantillons possibles (tous ceux qu'il est possible d'observer) contiennent la vraie valeur  $\theta$*

**Attention :** on ne peut pas interpréter une réalisation d'un intervalle de confiance en terme probabiliste ! C'est une erreur qui est souvent commise. . .

## Intervalle de crédibilité

L'**intervalle de crédibilité** s'interprète lui bien plus naturellement que l'intervalle de confiance :

C'est un intervalle qui a 95% de chance de contenir  $\theta$   
(pour un niveau de 95%, évidemment)

Défini comme un intervalle avec une forte probabilité *a posteriori*.

Par exemple, un **intervalle de crédibilité à 95%** est un intervalle  $[t_{inf}; t_{sup}]$  tel que  $\int_{t_{inf}}^{t_{sup}} p(\theta|y) d\theta = 0.95$

**NB** : en général on s'intéresse à l'intervalle de crédibilité à 95% le plus étroit possible (*Highest Density Interval*).

# Distribution prédictive

**distribution prédictive** : distribution d'une nouvelle observation  $Y_{n+1}$  sachant les observations précédentes  $\mathbf{y}$ , marginalement par rapport à  $\theta$  :

$$\begin{aligned} f_{Y_{n+1}}(\mathbf{y}|\mathbf{y}) &= \int_{\Theta} f_{Y_{n+1}}(y, \theta | \mathbf{y}) d\theta \\ &= \int_{\Theta} f_{Y_{n+1}}(y|\theta, \mathbf{y}) p(\theta | \mathbf{y}) d\theta \\ &= \int_{\Theta} f_{Y_{n+1}}(y|\theta) p(\theta | \mathbf{y}) d\theta \end{aligned}$$

**NB** : on remarque le lien avec la distribution marginale

$$f_Y(y) = \int_{\Theta} f_Y(y|\theta) \pi(\theta) d\theta$$



# Bernstein-von Mises : approximation normale

**Théorème de Bernstein-von Mises (ou théorème limite central bayésien) :** Pour  $n$  grand, la distribution *a posteriori* peut être approximée par une loi normale

$$p(\theta|\mathbf{y}) \underset{n \rightarrow +\infty}{\approx} \mathcal{N}(\hat{\theta}, I(\hat{\theta})^{-1})$$

## Conséquences :

- Méthodes bayésiennes et procédures fréquentistes basées sur le maximum de vraisemblance donnent, pour  $n$  suffisamment grand, des résultats très proches
- on peut approximer la loi *a posteriori* par une loi normale dont les paramètres se calcule simplement avec le MAP









# Usage pratique

L'approche bayésienne est un outil statistique pour l'analyse de données (parmi d'autres)

Particulièrement **utile quand** :

- peu d'observations sont disponibles
- on dispose de connaissances *a priori* importantes



