

Rappels de statistique mathématique  
*Réponses question par question des travaux dirigés n° 4*

Guillaume Lacôte  
Bureau **E03**  
✉ [Guillaume.Lacote@ensae.fr](mailto:Guillaume.Lacote@ensae.fr)  
☞ <http://ensae.no-ip.com/SE222/>

Exercice corrigé 1

Soit  $f$  la densité de la loi exponentielle de paramètre  $\frac{1}{\theta}$  translatée de  $\alpha$

$$f(x) = \frac{1}{\theta} \exp\left[-\frac{x-\alpha}{\theta}\right] \mathbb{1}_{[\alpha, +\infty[}(x)$$

☞ Q1 Donner les e.m.v.  $\hat{\alpha}$  et  $\hat{\theta}$  de  $\alpha$  et  $\theta$ .

On obtient :  $\hat{\alpha} = \min x_i$ ,  $\hat{\theta} = \bar{x} - \min x_i$ .

☞ Q2 Calculer la loi (à distance finie) de  $n(\hat{\alpha} - \alpha)$ .

On a :

$$\mathbb{P}(n(\hat{\alpha} - \alpha) \geq t) = \mathbb{P}(\min x_i \geq \alpha + t/n) = (\exp^{-t/n\theta})^n = \exp(-t/\theta)$$

et donc  $n(\hat{\alpha} - \alpha) \rightsquigarrow \mathcal{E}(\frac{1}{\theta})$ .

☞ Q3 Déterminer la loi limite de  $\sqrt{n}(\hat{\theta} - \theta)$ .

On ne peut pas appliquer le théorème de la normalité asymptotique à  $\hat{\theta}$ , car  $\hat{\theta}$  n'est que l'une des deux composantes de l'estimateur du maximum de vraisemblance  $(\hat{\alpha}, \hat{\theta})$  dont les composantes ne sont pas indépendantes, et qui dans ce cas particulier ne vérifie pas les conditions de régularité habituelles (notamment dérivabilité de la log-vraisemblance).

Il faut retrouver la loi limite d'une autre façon. Ici :

$$\sqrt{n}(\hat{\theta} - \theta) = \sqrt{n}(\bar{x} - (\theta + \alpha)) + \sqrt{n}(\alpha - \hat{\alpha})$$

Comme  $\mathbb{E}(X) = \theta + \alpha$ ,  $\mathbb{V}(X) = \theta^2$ , il vient d'après le théorème central limite :

$$\sqrt{n}(\bar{x} - (\theta + \alpha)) \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, \theta^2)$$

De plus,

$$\sqrt{n}(\alpha - \hat{\alpha}) = \frac{-1}{\sqrt{n}} n(\hat{\alpha} - \alpha) \xrightarrow{P} 0$$

puisque  $n(\hat{\alpha} - \alpha) \rightsquigarrow \mathcal{E}(\frac{1}{\theta})$ . Rappelons que :

$$X_n \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} X, Y_n \xrightarrow{P} a: X_n + Y_n \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} X + a$$

si  $a$  est une constante. Donc :

$$\sqrt{n}(\hat{\theta} - \theta) \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, \theta^2)$$

Rappeler l'expression de la loi de la statistique d'ordre  $(X_{(1)}, \dots, X_{(n)})$  en fonction de  $f$ . En déduire la loi du  $n$ -uplet

$$(nX_{(1)}, (n-1)(X_{(2)} - X_{(1)}), \dots, 2(X_{(n-1)} - X_{(n-2)}), X_{(n)} - X_{(n-1)})$$

En déduire que  $\hat{\theta}$  et  $\hat{\alpha}$  sont indépendants (à distance finie).

La densité de l'échantillon ordonné  $Y = (X_{(1)}, \dots, X_{(n)})$  s'écrit

$$f_Y(y_1, \dots, y_n) = n!f(y_1)\dots f(y_n)\mathbb{1}_{y_1 < \dots < y_n}$$

En d'autres termes,

$$\begin{aligned} f_{X_{(1)}, \dots, X_{(n)}}(y_1, \dots, y_n) &= n! \mathbb{1}_{y_1 < \dots < y_n} \frac{1}{\theta^n} \left( \prod_{i=1}^n e^{-\frac{y_i - \alpha}{\theta}} \right) \mathbb{1}_{\min_i y_i \geq \alpha} \\ &= \frac{n!}{\theta^n} \mathbb{1}_{\alpha \leq y_1 < \dots < y_n} e^{-\sum_{i=1}^n \frac{y_i - \alpha}{\theta}} \end{aligned}$$

Soit alors

$$\phi : \begin{pmatrix} \mathbb{R}^n & \rightarrow & \mathbb{R}^n \\ (y_1, \dots, y_n) & \mapsto & (ny_1, (n-1)(y_2 - y_1), \dots, (y_n - y_{n-1})) \end{pmatrix}$$

Alors  $\phi$  est de classe  $C^\infty$  et en outre

$$f_{\phi(Y)}(z_1, \dots, z_n) = |Jac\phi^{-1}| f_Y(\phi^{-1}(z_1, \dots, z_n))$$

(ceci se montre en effectuant le changement de variable  $z = \phi(y)$  dans l'intégrale  $\int_A f_Y(y)$ , pour toute partie mesurable  $A$  de  $\mathbb{R}^n$ ).

Or  $\phi(Y)_1 = nY_1$ , donc

$$\begin{aligned} \frac{\partial \phi(\cdot)_1}{\partial Y_1} &= n \\ \frac{\partial \phi(\cdot)_1}{\partial Y_i} &= 0, \quad \forall i \geq 2 \end{aligned}$$

puis  $\phi(Y)_2 = (n-1)(Y_2 - Y_1)$ , et donc

$$\begin{aligned} \frac{\partial \phi(\cdot)_2}{\partial Y_1} &= -(n-1) \\ \frac{\partial \phi(\cdot)_2}{\partial Y_2} &= (n-1), \quad \forall i \geq 2 \\ \frac{\partial \phi(\cdot)_2}{\partial Y_i} &= 0, \quad \forall i \geq 3 \end{aligned}$$

de sorte qu'en définitive

$$Jac(\phi) = \begin{pmatrix} n & 0 & 0 & \dots & 0 & 0 \\ -(n-1) & (n-1) & 0 & \dots & 0 & 0 \\ 0 & -(n-2) & (n-2) & \dots & 0 & 0 \\ \vdots & \vdots & \ddots & \dots & \vdots & \vdots \\ 0 & 0 & \dots & \dots & -1 & 1 \end{pmatrix}$$

En conséquence,  $|Jac(\phi^{-1})| = |Jac(\phi)^{-1}| = |Jac(\phi)|^{-1} = \frac{1}{n!}$

D'autre part,  $\mathbb{1}_{y_1 \geq \alpha} = \mathbb{1}_{\phi(y)_1 \geq n\alpha}$ , puis pour  $i \geq 2$ ,  $\mathbb{1}_{y_i < y_{i+1}} = \mathbb{1}_{\phi(y)_i > 0}$ .

Enfin, une récurrence immédiate montre que  $\forall i \in \llbracket 1, n \rrbracket$ ,  $\phi^{-1}(z)_i = \sum_{j=1}^i \frac{z_j}{n-j+1}$ , de sorte que

$$f_Z(z_1, \dots, z_n) = \theta^{-n} \exp^{-\sum z_i - n\alpha/\theta} \mathbb{1}_{z_1 \geq n\alpha} \mathbb{1}_{z_2 > 0} \dots \mathbb{1}_{z_n > 0}$$

Autrement dit, les  $Z_i$  sont indépendants, avec  $Z_1 \sim n\alpha + \mathcal{E}(\frac{1}{\theta})$ , et  $Z_i \sim \mathcal{E}(\frac{1}{\theta})$  pour  $i \geq 2$ .  
Finalement, constatant que  $\hat{\alpha} = \frac{1}{n}Z_1$  et  $\hat{\theta} = \frac{1}{n} \sum_{i=2}^n Z_i$ , on conclut que  $\hat{\alpha}$  et  $\hat{\theta}$  sont indépendants.

### Exercice corrigé 2

Cet exercice présente les bases de l'estimation bayésienne.

Q1

Soit  $(\Omega, \mathcal{A}, \mathbb{P})$  un espace probabilisé,  $A$  un événement non-vidé et  $(H_1, \dots, H_n)$  un système complet d'hypothèses incompatibles non-vides (c'est-à-dire une partition de  $\Omega$ ).

Exprimer  $\mathbb{P}(H_i|A)$  en fonction des probabilités de  $H_1, \dots, H_n$ , de celles de  $A$  conditionnellement à  $H_i$  et inversement, mais pas de  $\mathbb{P}(A)$ .

On a par définition de la probabilité conditionnelle

$$\forall i \in \llbracket 1, n \rrbracket, \mathbb{P}(A|H_i) = \frac{\mathbb{P}(A \cap H_i)}{\mathbb{P}(H_i)}$$

et donc

$$\begin{aligned} \mathbb{P}(A) &= \mathbb{P}(A \cap \Omega) \\ &= \mathbb{P}(A \cap (\cup_{i=1}^n H_i)) \quad \text{car } (H_1, \dots, H_n) \text{ est complet} \\ &= \sum_{i=1}^n \mathbb{P}(A \cap H_i) \quad \text{car } (H_1, \dots, H_n) \text{ est disjoint} \\ &= \sum_{i=1}^n \mathbb{P}(A|H_i) \mathbb{P}(H_i) \quad \text{car chaque } H_i \text{ est non-vidé} \end{aligned}$$

(cette formule est dite *des probabilités totales*).

Par ailleurs on a

$$\mathbb{P}(A|H_i) \mathbb{P}(H_i) = \mathbb{P}(A \cap H_i) = \mathbb{P}(H_i|A) \mathbb{P}(A)$$

et donc

$$\mathbb{P}(H_i|A) = \frac{\mathbb{P}(H_i) \mathbb{P}(A|H_i)}{\mathbb{P}(A)}$$

$$= \frac{\mathbb{P}(H_i) \mathbb{P}(A|H_i)}{\sum_{i=1}^n \mathbb{P}(H_i) \mathbb{P}(A|H_i)}$$

Cette relation exprime la probabilité d'un événement  $H_i$ , une fois connue la réalisation de  $A$ , en fonction de sa probabilité a priori.

Q2

Soit  $(X_1, \dots, X_n) \stackrel{iid}{\sim} \mathcal{L}_\theta$ , de paramètre inconnu  $\theta \in \Theta$ .  
 On suppose que  $\theta$  suit une loi a priori de densité  $\pi_0$  sur  $\Theta$ .  
 Donner la densité  $\pi_{\cdot|x}$  de la loi a posteriori de  $\theta$  conditionnellement à l'observation de  $X = x$ .

Dans le cas où  $\Theta = \{\theta_i / i \in \mathbb{N}\}$  est dénombrable il suffit d'appliquer le résultat précédent à  $A = \{\theta_1, \dots, \theta_n\}$  et  $\forall i \in \mathbb{N}, H_i = \{\theta_i\}$ .

Dans le cas général le calcul est similaire : la formule des probabilités totales s'écrit pour toute  $\mathcal{A} \subset \mathbb{R}^n$  mesurable

$$\mathbb{P}(X \in \mathcal{A}) = \int_{\Theta} \mathbb{P}(X \in \mathcal{A} | \theta = \theta_0) \mathbb{P}(\theta = \theta_0) d\theta_0$$

et par suite pour toute  $\mathcal{B} \subset \Theta$  mesurable, à supposer que  $\mathbb{P}(X \in \mathcal{A}) \neq 0$

$$\mathbb{P}(\theta \in \mathcal{B} | X \in \mathcal{A}) = \frac{\mathbb{P}(\theta \in \mathcal{B}) \mathbb{P}(X \in \mathcal{A} | \theta \in \mathcal{B})}{\mathbb{P}(X \in \mathcal{A})}$$

et donc

$$\pi_{\cdot|x}(\theta | X = x) = \frac{f_{\mathcal{L}_\theta^{\otimes n}}(x_1, \dots, x_n) \pi_0(\theta)}{\int_{\Theta} f_{\mathcal{L}_\theta^{\otimes n}}(x_1, \dots, x_n) \pi_0(\theta) d\theta}$$

Définissons pour tout estimateur  $\hat{\theta}(x)$  de  $\theta$  la fonction de risque quadratique

$$R_\nu(\hat{\theta}) = \int_{\Theta} \mathbb{E}_\theta (\hat{\theta}(X) - \theta)^2 d\nu(\theta)$$

Q3

où  $\nu$  désigne une loi quelconque sur  $\Theta$  (par exemple  $d\nu = \pi_0 d\lambda$ ).  
 On appelle *estimateur bayésien* de  $\theta$  l'estimateur  $\hat{\theta}$  qui minimise le risque associé.  
 Montrer que l'estimateur bayésien de  $\theta$  associé au risque  $R_{\pi_0}$  est

$$\hat{\theta}(x) = \mathbb{E}_{\pi_{\cdot|x}}(\theta) = \int_{\Theta} \theta \pi_{\cdot|x}(\theta) d\theta$$

Attention aux notations :  $\mathbb{E}_\theta(\dots \hat{\theta}(X) \dots)$  désigne l'espérance sur la variable  $X$ , espérance qui dépend de  $\theta$ , et non pas une espérance sur la variable  $\theta$ . En outre l'énoncé suppose ici que  $\Theta$  est de dimension 1 (sans quoi il faudrait noter  $\mathbb{E}_\theta \|\hat{\theta}(x) - \theta\|^2$ ).

Soit  $\mathcal{X} = \mathbb{R}^n$ .

Première méthode :

On cherche l'élément  $T : \mathcal{X} \rightarrow \Theta$  (qui est une fonction) qui minimise

$$\begin{aligned} R_{\pi_0}(T) &= \int_{\Theta} \int_{\mathcal{X}} (T(x) - \theta)^2 f_{\mathcal{L}_\theta}(x) \pi_0(\theta) dx d\theta \\ &= \int_{\mathcal{X}} \left( \int_{\Theta} (T(x) - \theta)^2 f_{\mathcal{L}_\theta}(x) \pi_0(\theta) d\theta \right) dx \quad \text{d'après Fubini} \end{aligned}$$

Or la fonction

$$\phi : \begin{pmatrix} \mathcal{X}^2 & \rightarrow & \Theta \\ (x, t) & \mapsto & \int_{\Theta} (t - \theta)^2 f_{\mathcal{L}_\theta}(x) \pi_0(\theta) d\theta \end{pmatrix}$$

est positive, donc il suffit de minimiser point-par-point :

$$\hat{\theta} = \operatorname{argmin}_{T: \mathcal{X} \rightarrow \Theta} \int_{\mathcal{X}} \phi(T(x)) dx = \begin{pmatrix} \mathcal{X} & \rightarrow & \Theta \\ x & \mapsto & \operatorname{argmin}_{t \in \Theta} \phi(x, t) \end{pmatrix}$$

Soit donc  $x \in \mathcal{X}$  fixé, et calculons le nombre  $\hat{\theta}(x) = \operatorname{argmin}_{t \in \Theta} \phi(x, t)$ . On a

$$\begin{aligned} \phi(x, t) &= \int_{\Theta} (t - \theta)^2 f_{\mathcal{L}_\theta}(x) \phi_0(\theta) d\theta \\ &= \underbrace{\left( \int_{\Theta} f_{\mathcal{L}_\theta}(x) \phi_0(\theta) d\theta \right)}_{a>0} t^2 + \underbrace{\left( -2 \int_{\Theta} \theta f_{\mathcal{L}_\theta}(x) \phi_0(\theta) d\theta \right)}_b t + \underbrace{\left( \int_{\Theta} \theta^2 f_{\mathcal{L}_\theta}(x) \phi_0(\theta) d\theta \right)}_c \end{aligned}$$

Donc  $\phi(x, t) = at^2 + bt + c$  est une parabole en  $t$  (à  $x$  fixé), et est donc extrême en - comme  $a > 0$  elle est *minimale* en  $-\frac{b}{2a}$  et donc

$$\begin{aligned} \operatorname{argmin}_{t \in \Theta} \phi(x, t) &= -\frac{b}{2a} \\ &= \frac{\int_{\Theta} \theta f_{\mathcal{L}_\theta}(x) \phi_0(\theta) d\theta}{\int_{\Theta} f_{\mathcal{L}_\theta}(x) \phi_0(\theta) d\theta} \\ &= \int_{\Theta} \theta \frac{f_{\mathcal{L}_\theta}(x) \phi_0(\theta)}{\int_{\Theta} f_{\mathcal{L}_\theta}(x) \phi_0(\theta) d\theta} d\theta \end{aligned}$$

Par conséquent,

$$\forall x \in \mathcal{X}, \hat{\theta}(x) = \int_{\Theta} \theta \pi_{\cdot|x}(\theta) d\theta$$

Q4

Donner l'estimateur bayésien de  $\theta \in [a, b]$  lorsque  $\pi_0 = \mathcal{U}_{[a,b]}$  en fonction de la densité de la loi  $\mathcal{L}_\theta$  de  $X$ .

Expliciter cet estimateur lorsque  $\mathcal{L}_\theta$  est la loi exponentielle  $\mathcal{E}(\theta)$  de paramètre inconnu  $\theta > 0$

Dans le cas d'une loi a priori uniforme on a simplement

$$\begin{aligned} \hat{\theta}(x) &= \int_{[a,b]} \theta \pi_{\cdot|x}(\theta) d\theta \\ &= \int_{[a,b]} \theta \frac{f_{\mathcal{L}_\theta}(x_1, \dots, x_n) \frac{1}{b-a}}{\int_{[a,b]} f_{\mathcal{L}_\theta}(x_1, \dots, x_n) \frac{1}{b-a} d\theta} d\theta \\ &= \frac{\int_{[a,b]} \theta f_{\mathcal{L}_\theta}(x) d\theta}{\int_{[a,b]} f_{\mathcal{L}_\theta}(x) d\theta} \end{aligned}$$

Dans le cas où  $\mathcal{L}_\theta = \mathcal{E}(\theta)$  la densité de l'échantillon indépendant  $(X_1, \dots, X_n)$  est

$$\begin{aligned} f_{\mathcal{E}(\theta)^{\otimes n}}(X_1 = x_1, \dots, X_n = x_n) &= \prod_{i=1}^n (\theta e^{-\theta x_i} \mathbf{1}_{x_i \geq 0}) \\ &= \theta^n e^{-\theta(x_1 + \dots + x_n)} \mathbf{1}_{\min_i x_i \geq 0} \end{aligned}$$

et donc pour  $(x_1, \dots, x_n) \in (\mathbb{R}^+)^n$  il vient

$$\begin{aligned} \hat{\theta}(x) &= \frac{\int_{[a,b]} \theta^{n+1} e^{-\theta(x_1 + \dots + x_n)} d\theta}{\int_{[a,b]} \theta^n e^{-\theta(x_1 + \dots + x_n)} d\theta} \\ &= \frac{\left[ \theta^{n+1} \frac{e^{-\theta \sum_{i=1}^n x_i}}{-\sum_{i=1}^n x_i} \right]_a^b - \int_{[a,b]} (n+1) \theta^n \frac{e^{-\theta \sum_{i=1}^n x_i}}{-\sum_{i=1}^n x_i} d\theta}{\int_{[a,b]} \theta^n e^{-\theta(x_1 + \dots + x_n)} d\theta} \quad \text{par parties} \\ &= \frac{1}{\sum_{i=1}^n x_i} \left( n+1 - \frac{b^{n+1} e^{-b \sum_{i=1}^n x_i} - a^{n+1} e^{-a \sum_{i=1}^n x_i}}{\int_{[a,b]} \theta^n e^{-\theta(x_1 + \dots + x_n)} d\theta} \right) \end{aligned}$$

Ainsi  $\hat{\theta}(x) = \frac{1}{\sum_{i=1}^n x_i} \left( n+1 - \frac{\bar{\theta}^{n+1} e^{-\bar{\theta} \sum_{i=1}^n x_i}}{\int_{[0, \bar{\theta}]} \theta^n e^{-\theta(x_1 + \dots + x_n)} d\theta} \right)$  lorsque  $\Theta = [0, \bar{\theta}]$  par exemple.

L'estimateur du maximum de vraisemblance de  $\theta$ , par comparaison, est  $\hat{\theta}^{emv}(x) = \frac{n}{\sum_{i=1}^n x_i}$ .

**Exercice corrigé 3**

Un des premiers exemples d'utilisation de la Statistique Bayésienne remonte à Laplace, en 1786. Celui-ci décida de répondre à la question suivante : au regard du nombre observé  $n_g$  de naissances masculines parmi  $n$  naissances à Paris, peut-on dire si la probabilité  $p$  qu'un enfant qui naisse soit un garçon est supérieure à  $\frac{1}{2}$  ?

Q1 Laplace munit le paramètre  $p$  d'une loi a priori uniforme sur l'intervalle  $[0, 1]$ . Ce choix vous semble-t-il naturel ?

Laplace considère en fait de ne pas détenir d'information sur  $p$  autre que celle apportée par les observations : en d'autres termes, il n'a pas d'"a priori" sur  $p$ , ce qu'il modélise par une loi a priori uniforme. Cela revient intuitivement à donner une "probabilité égale" à toutes les valeurs possibles de  $p$ . Mais cette intuition est en fait trompeuse : si on change la paramétrisation du modèle (en remplaçant  $p$  par  $q = p^2$  par exemple), on se rend compte alors que la loi a priori sur  $q$  n'est plus uniforme ! Cette reparamétrisation ne nous a pourtant apporté aucune information supplémentaire. Ce paradoxe illustre la difficulté de bien choisir une loi a priori, surtout dans un cadre non-informatif (c'est à dire lorsqu'aucune information n'est disponible a priori). Cependant, nous verrons en 4) qu'il est assez simple de se restreindre au moins à un choix limité de lois a priori raisonnables.

Exprimer alors la loi a posteriori de  $p$ , puis exprimer la probabilité  $\mathbb{P}(p > \frac{1}{2} | N_g = n_g)$  sous forme d'un rapport d'intégrales.  
 Q2 Remarque : Laplace, obtint, pour  $n = 493472$  et  $n_g = 251527$ , une probabilité  $\mathbb{P}(p > \frac{1}{2} | N_g = n_g) \simeq 1 - 1.15 \cdot 10^{-42}$  et en conclut que  $p$  était très vraisemblablement plus grand que  $\frac{1}{2}$ .

La densité de la loi a posteriori  $\pi(\theta | x_1, \dots, x_n)$  du paramètre  $\theta$  s'écrit sous la forme (voir l'exercice 2) :

$$\pi(\theta | x_1, \dots, x_n) = \frac{\pi(\theta) \mathbb{P}(x_1, \dots, x_n | \theta)}{\int_{\Theta} \pi(\theta) \mathbb{P}(x_1, \dots, x_n | \theta) d\theta}$$

Il vient

$$\begin{aligned} \pi(p | N_g = n_g) &= \frac{\pi(p) \mathbb{P}(N_g = n_g | p)}{\int_0^1 \pi(p) \mathbb{P}(N_g = n_g | p) dp} \\ &= \frac{p^{n_g} (1-p)^{n-n_g}}{\int_0^1 p^{n_g} (1-p)^{n-n_g} dp} \end{aligned}$$

Par conséquent

$$\begin{aligned} \mathbb{P}(p > \frac{1}{2} | N_g = n_g) &= \frac{\int_{\frac{1}{2}}^1 \pi(p) \mathbb{P}(N_g = n_g | p) dp}{\int_0^1 \pi(p) \mathbb{P}(N_g = n_g | p) dp} \\ &= \frac{\int_{\frac{1}{2}}^1 p^{n_g} (1-p)^{n-n_g} dp}{\int_0^1 p^{n_g} (1-p)^{n-n_g} dp} \end{aligned}$$

Donner l'espérance et la variance de la loi a posteriori en fonction de la vraie valeur  $p_0$  du paramètre  $p$ . Quelles sont leurs limites lorsque  $n \rightarrow +\infty$  ?

Rappel : la loi Beta  $\mathcal{B}(\alpha, \beta)$  de paramètres  $\alpha > 0, \beta > 0$  admet pour densité :

Q3 
$$f_{\alpha, \beta}(x) = \frac{x^{\alpha-1} (1-x)^{\beta-1}}{B(\alpha, \beta)} \mathbf{1}_{[0,1]}(x)$$

où  $B(\alpha, \beta) = \int_0^1 x^{\alpha-1} (1-x)^{\beta-1} dx$ .

Son espérance est  $\mathbb{E}(X) = \frac{\alpha}{\alpha+\beta}$  et sa variance  $\mathbb{V}(X) = \frac{\alpha\beta}{(\alpha+\beta)^2(\alpha+\beta+1)}$ .

Notons  $\pi_p$  la densité de la loi a posteriori :  $\pi_p$  est la densité de la loi  $\mathcal{B}(n_g + 1, n - n_g + 1)$ . Son espérance et sa variance sont donc :

$$\begin{aligned} \mathbb{E}_{\pi_p}[p] &= \frac{n_g + 1}{n + 2} \\ \mathbb{V}_{\pi_p}[p] &= \frac{(n_g + 1)(n - n_g + 1)}{(n + 2)^2(n + 3)} \end{aligned}$$

Or  $n_g = \sum_{i=1}^n g_i$  où  $g_i = \mathbf{1}_{\text{enfant } i \text{ est un garçon}} \stackrel{iid}{\sim} \mathcal{B}(1, p_0)$ .

Donc en vertu de la loi forte des grands nombres  $\frac{n_g}{n} = \frac{1}{n} \sum_{i=1}^n g_i \xrightarrow[n \rightarrow +\infty]{p.s.} p_0$  et donc

$$\begin{aligned} \mathbb{E}_{\pi_p}[p] &\xrightarrow[n \rightarrow +\infty]{p.s.} p_0 \\ \mathbb{V}_{\pi_p}[p] &\underset{\sim}{\xrightarrow[n \rightarrow +\infty]{p.s.}} \frac{p_0(1-p_0)}{n} \end{aligned}$$

En d'autres termes, lorsque  $n \rightarrow +\infty$  la loi a posteriori se "rétrécit" (sa variance tend vers 0) et se concentre autour de la vraie valeur  $p_0$ . Ce résultat est intuitif : plus on dispose d'observations, plus faible est l'incertitude sur la valeur du paramètre  $p$ .

☞ Q4 Ces limites sont-elles modifiées si on choisit pour loi a priori sur  $p$  une loi  $\mathcal{B}(\alpha, \beta)$  quelconque ? Pourquoi est-il judicieux malgré tout de se restreindre au moins à la classe des lois a priori telles que  $\alpha = \beta$  ?

Si on change la loi a priori uniforme (qui correspond d'ailleurs à une loi  $\mathcal{B}(1, 1)$ ) pour une loi a priori plus générale  $\mathcal{B}(\alpha, \beta)$ , on obtient une loi a posteriori :

$$\begin{aligned} \pi(p|N_g = n_g) &\propto p^{\alpha-1}(1-p)^{\beta-1}p^{n_g}(1-p)^{n-n_g}\mathbf{1}_{[0,1]}(p) \\ &\propto p^{\alpha+n_g-1}(1-p)^{\beta+n-n_g-1}\mathbf{1}_{[0,1]}(p) \end{aligned}$$

(où  $\propto$  signifie "proportionnel à")

La loi a posteriori est donc une loi  $\mathcal{B}(n_g + \alpha, n - n_g + \beta)$ . On vérifie alors facilement que  $\mathbb{E}_{\pi_p}[p]$  et  $\mathbb{V}_{\pi_p}[p]$  conservent le même comportement asymptotique que dans le cas précédent. En effet, plus grand est le nombre d'observations, plus le poids de l'a priori est faible, et ce poids devient nul asymptotiquement.

Cependant, la Statistique Bayésienne ne repose pas sur des justifications asymptotiques. A distance finie (c'est à dire pour un nombre fini d'observations), une loi a priori mal choisie peut sérieusement déformer la loi a posteriori, et mener à une inférence complètement erronée. Ainsi, au vu du problème posé (situer  $p$  dans l'un des deux intervalles  $[0, \frac{1}{2}]$  ou  $[\frac{1}{2}, 1]$ ), on n'a aucune raison de favoriser *a priori* l'une de ces deux régions, seules les observations pouvant nous permettre de les départager. Il est donc naturel de se restreindre au moins aux lois a priori symétriques ( $\alpha = \beta$ ). Parmi celles-ci, on peut aussi écarter les lois de très faible variance (ie telles que  $\alpha$  prend de fortes valeurs, ex :  $\mathcal{B}(10, 10)$ ), qui privilégient inutilement un voisinage trop restreint du point  $\frac{1}{2}$ .

Finalement, la loi a priori uniforme proposée par Laplace semble donc un choix raisonnable parmi d'autres, au moins pour le problème posé. Il est en fait possible de proposer une loi plus satisfaisante (dite loi a priori de Jeffreys, ici  $\mathcal{B}(1/2, 1/2)$ ) qui permette de s'affranchir du paradoxe de la reparamétrisation présenté en 1).