

Exercice 1 : Estimation

On considère n variables aléatoires X_1, \dots, X_n indépendantes suivant la même loi de densité

$$f(x; \sigma^2) = \frac{x}{\sigma^2} \exp\left[-\frac{x^2}{2\sigma^2}\right] I_{\mathbb{R}^+}(x)$$

avec $\sigma > 0$ et où $I_{\mathbb{R}^+}(x)$ est la fonction indicatrice sur \mathbb{R}^+ ($I_{\mathbb{R}^+}(x) = 1$ si $x \in \mathbb{R}^+$ et $I_{\mathbb{R}^+}(x) = 0$ si $x \notin \mathbb{R}^+$). Cette loi est appelée loi de Rayleigh et on utilisera la notation habituelle $X_k \sim \mathcal{R}(\sigma^2)$. On admettra que les premiers moments des résultats suivants

$$E[X_k] = \sigma\sqrt{\frac{\pi}{2}}, E[X_k^2] = 2\sigma^2, E[X_k^3] = \left(3\sqrt{\frac{\pi}{2}}\right)\sigma^3 \text{ et } E[X_k^4] = 8\sigma^4.$$

Estimateur du Maximum de Vraisemblance

1) La vraisemblance de (x_1, \dots, x_n) est définie par

$$\begin{aligned} L(x_1, \dots, x_n; \theta) &= \prod_{i=1}^n f(x_i; \theta), \\ &= \prod_{i=1}^n \frac{x_i}{\theta} \exp\left[-\frac{x_i^2}{2\theta}\right] I_{\mathbb{R}^+}(x_i), \\ &= \frac{\prod_{i=1}^n x_i}{\theta^n} \exp\left[-\frac{1}{2\theta} \sum_{i=1}^n x_i^2\right] \prod_{i=1}^n I_{\mathbb{R}^+}(x_i). \end{aligned}$$

On a alors

$$\ln L(x_1, \dots, x_n; \theta) = -n \ln \theta + \sum_{i=1}^n \ln(x_i) - \frac{1}{2\theta} \sum_{i=1}^n x_i^2.$$

En étudiant le signe de $\frac{\partial \ln L(x_1, \dots, x_n; \theta)}{\partial \theta}$, on obtient :

$$\begin{aligned} \frac{\partial \ln L(x_1, \dots, x_n; \theta)}{\partial \theta} &\geq 0 \iff -\frac{n}{\theta} + \frac{1}{2\theta^2} \sum_{i=1}^n x_i^2 \geq 0, \\ &\iff \theta \leq \frac{1}{2n} \sum_{i=1}^n x_i^2. \end{aligned}$$

La vraisemblance possède donc un maximum global unique obtenu pour $\theta = \frac{1}{2n} \sum_{i=1}^n x_i^2$ d'où

$$\hat{\theta}_{\text{MV}} = \frac{1}{2n} \sum_{i=1}^n X_i^2.$$

2) La moyenne de l'estimateur $\widehat{\theta}_{\text{MV}}$ est

$$\begin{aligned} E \left[\widehat{\theta}_{\text{MV}} \right] &= \frac{1}{2n} \sum_{i=1}^n E \left[X_i^2 \right] \\ &= \frac{1}{2n} \sum_{i=1}^n (2\sigma^2) \\ &= \sigma^2 = \theta \end{aligned}$$

L'estimateur $\widehat{\theta}_{\text{MV}}$ est donc un estimateur non biaisé de θ . La variance de l'estimateur $\widehat{\theta}_{\text{MV}}$ est

$$\begin{aligned} \text{var} \left[\widehat{\theta}_{\text{MV}} \right] &= \frac{1}{4n^2} \text{var} \left[\sum_{i=1}^n X_i^2 \right], \\ &= \frac{1}{4n} \text{var} \left(X_1^2 \right), \\ &= \frac{1}{4n} \left(E \left[X_1^4 \right] - E \left[X_1^2 \right]^2 \right), \\ &= \frac{1}{4n} (8\sigma^4 - 4\sigma^4) \\ &= \frac{\sigma^4}{n} \end{aligned}$$

L'estimateur $\widehat{\theta}_{\text{MV}}$ est un estimateur non biaisé de θ tel que

$$\lim_{n \rightarrow \infty} \text{var} \left[\widehat{\theta}_{\text{MV}} \right] = 0$$

donc l'estimateur $\widehat{\theta}_{\text{MV}}$ est convergent.

3) La borne de Cramer-Rao pour les estimateurs non biaisés du paramètre θ est définie par

$$\begin{aligned} \text{BCR}(\theta) &= \frac{-1}{E \left[\frac{\partial \ln L(X_1, \dots, X_n; \theta)}{\partial \theta^2} \right]}, \\ &= -E \left[\frac{\partial}{\partial \theta} \left[\frac{-n}{\theta} + \frac{1}{2\theta^2} \sum_{i=1}^n X_i^2 \right] \right]^{-1}, \\ &= -E \left[\frac{n}{\theta^2} - \frac{2}{2\theta^3} \sum_{i=1}^n X_i^2 \right]^{-1} \\ &= \left[-\frac{n}{\theta^2} + \frac{1}{\theta^3} (2n\theta) \right]^{-1} = \frac{\theta^2}{n} \end{aligned}$$

Puisque $\widehat{\theta}_{\text{MV}}$ est un estimateur non biaisé de θ et que $\text{var} \left[\widehat{\theta}_{\text{MV}} \right] = \text{BCR}(\theta)$, l'estimateur $\widehat{\theta}_{\text{MV}}$ est l'estimateur efficace de θ .

Estimation Bayésienne

On suppose désormais qu'on dispose d'une information a priori sur le paramètre θ résumée dans la loi inverse-gamma $IG(\alpha, \beta)$ de densité

$$f(\theta) = \frac{\beta^\alpha}{\Gamma(\alpha)} \frac{1}{\theta^{\alpha+1}} \exp\left(-\frac{\beta}{\theta}\right) I_{\mathbb{R}^+}(\theta)$$

1) La loi a posteriori de $\theta | x_1, \dots, x_n$ s'écrit

$$\begin{aligned} f(\theta | x_1, \dots, x_n) &\propto f(x_1, \dots, x_n | \theta) f(\theta) \\ &\propto \frac{1}{\theta^n} \exp\left[-\frac{1}{2\theta} \sum_{i=1}^n x_i^2\right] \frac{1}{\theta^{\alpha+1}} \exp\left(-\frac{\beta}{\theta}\right) I_{\mathbb{R}^+}(\theta) \\ &\propto \frac{1}{\theta^{n+\alpha+1}} \exp\left\{-\frac{1}{\theta} \left[\frac{1}{2} \sum_{i=1}^n x_i^2 + \beta\right]\right\} I_{\mathbb{R}^+}(\theta) \end{aligned}$$

Cette densité est la densité d'une loi inverse-gamma

$$\theta | x_1, \dots, x_n \sim IG\left(n + \alpha, \frac{1}{2} \sum_{i=1}^n x_i^2 + \beta\right)$$

2) L'estimateur du maximum a posteriori du paramètre θ noté $\hat{\theta}_{\text{MAP}}$ est obtenu en maximisant le logarithme de la loi a posteriori $f(\theta | x_1, \dots, x_n)$. Mais

$$\ln[f(\theta | x_1, \dots, x_n)] = C - (n + \alpha + 1) \ln \theta - \frac{1}{\theta} \left[\frac{1}{2} \sum_{i=1}^n x_i^2 + \beta \right]$$

d'où

$$\begin{aligned} \frac{\partial \ln[f(\theta | x_1, \dots, x_n)]}{\partial \theta} &\geq 0 \iff -\frac{n + \alpha + 1}{\theta} + \frac{1}{\theta^2} \left[\frac{1}{2} \sum_{i=1}^n x_i^2 + \beta \right] \geq 0 \\ &\iff \theta \leq \frac{1}{n + \alpha + 1} \left[\frac{1}{2} \sum_{i=1}^n x_i^2 + \beta \right] \end{aligned}$$

La loi a posteriori $f(\theta | x_1, \dots, x_n)$ possède donc un unique maximum global, d'où

$$\hat{\theta}_{\text{MAP}} = \frac{1}{n + \alpha + 1} \left[\frac{1}{2} \sum_{i=1}^n X_i^2 + \beta \right]$$

On peut exprimer $\hat{\theta}_{\text{MAP}}$ en fonction de $\hat{\theta}_{\text{MV}}$ puisque

$$\begin{aligned} \hat{\theta}_{\text{MAP}} &= \frac{1}{1 + \frac{\alpha+1}{n}} \left[\frac{1}{2n} \sum_{i=1}^n X_i^2 + \frac{\beta}{n} \right] \\ &= \frac{1}{1 + \frac{\alpha+1}{n}} \hat{\theta}_{\text{MV}} + \frac{\beta}{n + \alpha + 1} \end{aligned}$$

L'estimateur $\hat{\theta}_{\text{MAP}}$ se comporte donc $\hat{\theta}_{\text{MV}}$ comme lorsque $n \rightarrow \infty$. Lorsqu'on a beaucoup d'observations, on fait confiance à ces observations et donc l'effet de la loi a priori est négligeable.

Méthode des Moments

1) La moyenne d'une loi de Rayleigh est

$$E[X] = \sigma \sqrt{\frac{\pi}{2}}$$

donc

$$\theta = \sigma^2 = \frac{2}{\pi} [E[X]]^2$$

L'estimateur des moments résultant de cette dernière égalité est

$$\hat{\theta}_M = \frac{2}{\pi} \left[\frac{1}{n} \sum_{i=1}^n X_i \right]^2$$

2) La moyenne de l'estimateur $\hat{\theta}_M$ est

$$\begin{aligned} E[\hat{\theta}_M] &= \frac{2}{\pi n^2} E \left[\sum_{i=1}^n X_i \sum_{j=1}^n X_j \right] \\ &= \frac{2}{\pi n^2} \sum_{i,j} E[X_i X_j] \\ &= \frac{2}{\pi n^2} [nE[X_i^2] + (n^2 - n) E[X_i]^2] \\ &= \frac{2}{\pi n^2} \left[2n\theta + (n^2 - n) \frac{\pi}{2} \theta \right] \\ &= \frac{4 + \pi(n-1)}{\pi n} \theta \end{aligned}$$

On en déduit un estimateur non-biaisé du paramètre θ

$$\hat{\theta}^* = \frac{\pi n}{4 + \pi(n-1)} \hat{\theta}_M = \frac{2n}{4 + \pi(n-1)} \left[\frac{1}{n} \sum_{i=1}^n X_i \right]^2$$

Exercice 2 : Test de Neyman-Pearson

1) Le test de Neyman-Pearson est défini par

$$\text{Rejet de } H_0 \text{ si } \frac{L(x_1, \dots, x_n; \theta_1)}{L(x_1, \dots, x_n; \theta_0)} > k_\alpha.$$

Mais

$$\begin{aligned} \frac{L(x_1, \dots, x_n; \theta_1)}{L(x_1, \dots, x_n; \theta_0)} > S_\alpha &\Leftrightarrow \frac{\frac{\prod_{i=1}^n x_i}{\theta_1^n} \exp\left[-\frac{1}{2\theta_1} \sum_{i=1}^n x_i^2\right]}{\frac{\prod_{i=1}^n x_i}{\theta_0^n} \exp\left[-\frac{1}{2\theta_0} \sum_{i=1}^n x_i^2\right]} > k_\alpha, \\ &\Leftrightarrow \left(\frac{1}{\theta_0} - \frac{1}{\theta_1}\right) \sum_{i=1}^n x_i^2 > k'_\alpha \end{aligned}$$

Pour $\theta_1 > \theta_0$, on a $\frac{1}{\theta_0} - \frac{1}{\theta_1} > 0$ et donc on en déduit le test équivalent

$$\text{Rejet de } H_0 \text{ si } \sum_{i=1}^n X_i^2 > s_\alpha.$$

Pour $\theta_1 < \theta_0$, on a $\frac{1}{\theta_0} - \frac{1}{\theta_1} < 0$ et donc le test s'écrit

$$\text{Rejet de } H_0 \text{ si } \sum_{i=1}^n X_i^2 < s_\alpha.$$

La statistique du test de Neyman-Pearson est donc

$$T_n = \sum_{i=1}^n X_i^2.$$

La région critique de ce test est définie par

- Si $\theta_1 > \theta_0$

$$\left\{ x \in \mathbb{R}^n \mid \sum_{i=1}^n x_i^2 > s_\alpha \right\}.$$

- Si $\theta_1 < \theta_0$

$$\left\{ x \in \mathbb{R}^n \mid \sum_{i=1}^n x_i^2 < s_\alpha \right\}.$$

2) Le changement de variables $Y_k = \frac{X_k^2}{\sigma^2}$ est bijectif de \mathbb{R}^+ dans \mathbb{R}^+ . De plus

$$y_k = \frac{x_k^2}{\sigma^2} \iff x_k = \sigma \sqrt{y_k}$$

Le Jacobien de la transformation est donc

$$J = \frac{dx_k}{dy_k} = \frac{\sigma}{2\sqrt{y_k}}$$

La densité de Y_k est donc

$$g(y_k) = \frac{\sigma\sqrt{y_k}}{\sigma^2} \exp\left(-\frac{y_k}{2}\right) \frac{\sigma}{2\sqrt{y_k}} I_{\mathbb{R}^+}(y_k)$$

soit

$$g(y_k) = \frac{1}{2} \exp\left(-\frac{y_k}{2}\right) I_{\mathbb{R}^+}(y_k)$$

On en déduit que $Y_k = \frac{X_k^2}{\sigma^2}$ suit une loi du χ^2_2 à deux degrés de liberté. La fonction caractéristique de $\frac{T_n}{\sigma^2}$ est

$$\begin{aligned} \phi(u) &= E\left[e^{iu\frac{T_n}{\sigma^2}}\right] \\ &= E\left[e^{iu\sum_{k=1}^n \frac{X_k^2}{\sigma^2}}\right] \\ &= E\left[\prod_{k=1}^n e^{iuY_k}\right] \end{aligned}$$

En utilisant le fait que les variables aléatoires Y_k sont indépendantes, on obtient

$$\begin{aligned} \phi(u) &= \prod_{k=1}^n \phi_{Y_k}(u) \\ &= \prod_{k=1}^n \frac{1}{1-2iu} \\ &= \frac{1}{(1-2iu)^n} \end{aligned}$$

On en déduit que $\frac{T_n}{\sigma^2}$ suit une loi du khi-deux à $2n$ degrés de liberté

$$\frac{T_n}{\sigma^2} \sim \chi^2_{2n}$$

3) Le risque de première espèce α est défini par

$$\begin{aligned} \alpha &= P[\text{Rejeter } H_0 \mid H_0 \text{ vraie}], \\ &= P\left[\sum_{i=1}^n X_i^2 > s_\alpha \mid \theta = \theta_0\right], \\ &= P\left[\frac{T_n}{\sigma_0^2} > \frac{s_\alpha}{\sigma_0^2} \mid \sum_{i=1}^n \frac{X_i^2}{\sigma_0^2} \sim \chi^2_{2n}\right], \\ &= G_{2n}\left(\frac{s_\alpha}{\sigma_0^2}\right). \end{aligned}$$

De la même façon

$$\begin{aligned}\beta &= P[\text{Rejeter } H_1 \mid H_1 \text{ vraie}], \\ &= P\left[\sum_{i=1}^n X_i^2 \leq s_\alpha \mid \theta = \theta_1\right], \\ &= 1 - P\left[\frac{T_n}{\sigma_1^2} > \frac{s_\alpha}{\sigma_1^2} \mid \sum_{i=1}^n \frac{X_i^2}{\sigma_1^2} \sim \chi_{2n}^2\right], \\ &= 1 - G_{2n}\left(\frac{s_\alpha}{\sigma_1^2}\right).\end{aligned}$$

4) Les courbes caractéristiques opérationnelles du récepteur (courbes COR) expriment la puissance du test $\pi = 1 - \beta$ en fonction de α . Dans le cas présent, on a

$$\begin{aligned}\pi &= G_{2n}\left(\frac{s_\alpha}{\sigma_1^2}\right), \\ &= G_{2n}\left[\frac{\sigma_0^2}{\sigma_1^2} G_{2n}^{-1}(\alpha)\right].\end{aligned}$$

On voit donc que la performance du test dépend des variances σ_0^2 et σ_1^2 uniquement via la quantité $\frac{\sigma_0^2}{\sigma_1^2}$ (la puissance dépend aussi de α bien entendu). Si on fixe σ_0^2 et le risque α , plus σ_1^2 est grand, plus $\frac{\sigma_0^2}{\sigma_1^2}$ est petit et donc plus la puissance du test est grande.

Exercice 3 : Test d'ajustement

1) Nous allons effectuer un test du χ^2 construit à partir des 6 classes suivantes

$$C_1 = \{1\}, C_2 = \{2\}, C_3 = \{3\}, C_4 = \{4\}, C_5 = \{5\}, C_6 = \{6\}$$

Les deux hypothèses sont définies par

H_0 : le dé est non truqué

H_1 : le dé est truqué

L'hypothèse H_0 est caractérisée par

$$P(C_i) = p_i = \frac{1}{6}, \quad \forall i = 1, \dots, 6$$

tandis que pour l'hypothèse H , au moins une des probabilités p_i est différente de $\frac{1}{6}$. La statistique du test du χ^2 est

$$\begin{aligned} \phi &= \sum_{i=1}^6 \frac{(N_i - np_i)^2}{np_i} \\ &= \frac{6}{n} \sum_{i=1}^6 \left(N_i - \frac{n}{6}\right)^2 \\ &= \frac{1}{20} [4 + 4 + 4 + 1 + 0 + 9] \\ &= \frac{22}{20} = 1.1 \end{aligned}$$

La règle de décision du test du χ^2 est

Rejet de l'hypothèse H_0 si $\phi > s_\alpha$,

avec

$$\begin{aligned} \alpha &= P[\text{Rejeter } H_0 \mid H_0 \text{ vraie}], \\ &= P[\phi > s_\alpha \mid H_0 \text{ vraie}]. \\ &= P[\phi > s_\alpha \mid \phi \sim \chi_5^2]. \end{aligned}$$

On sait que ϕ est distribuée suivant une loi du χ_{K-1}^2 sous l'hypothèse H_0 , où $K = 6$ est le nombre de classes. Si $g_n(u)$ est la densité d'une loi du χ_n^2 , on pose

$$\int_x^\infty g_n(u) du = G_n(x),$$

et on obtient

$$\alpha = G_3(s_\alpha) \implies s_\alpha = G_3^{-1}(\alpha).$$

Pour $\alpha = 0.05$, les tables de la loi du χ_5^2 donnent

$$s_\alpha = 11.071$$

On observe que

$$\phi < s_{0.05}$$

et donc on accepte l'hypothèse que le dé est parfait avec le risque $a = 0.05$.

2) L'application du théorème de la limite centrale donne

$$\frac{\frac{1}{n} \sum_{i=1}^n X_i - E[X_i]}{\sqrt{\text{var}[X_i]/n}} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1)$$

Pour n grand, on peut donc approcher la loi de $\frac{1}{n} \sum_{i=1}^n X_i$ par la loi normale

$$\mathcal{N}\left(E[X_i], \frac{\text{var}[X_i]}{n}\right)$$

Pour une loi uniforme sur l'ensemble $\{1, \dots, 6\}$ (ce qui correspond à l'hypothèse H_0), on a

$$\begin{aligned} E[X_i] &= \frac{1 + \dots + 6}{6} = \frac{7}{2} \\ \text{var}[X_i] &= E[X_i^2] - E[X_i]^2 = \frac{1^2 + \dots + 6^2}{6} - \frac{49}{4} = \frac{35}{21} = \nu^2 \end{aligned}$$

donc

$$U_n = \frac{\frac{1}{n} \sum_{i=1}^n X_i - \frac{7}{2}}{\nu/\sqrt{n}} \simeq \mathcal{N}(0, 1)$$

où \simeq signifie asymptotiquement distribué. On en déduit

$$\begin{aligned} \alpha &= P[\text{Rejeter } H_0 \mid H_0 \text{ vraie}], \\ &= P\left[\left(\frac{1}{n} \sum_{i=1}^n X_i - \frac{7}{2}\right)^2 > s_\alpha \mid H_0 \text{ vraie}\right], \\ &= P\left[\frac{\nu^2}{n} U_n^2 > s_\alpha \mid H_0 \text{ vraie}\right], \\ &= P\left[U_n^2 > \frac{n}{\nu^2} s_\alpha \mid U_n^2 \sim \chi_1^2\right], \\ &= G_1\left(\frac{n}{\nu^2} s_\alpha\right) \end{aligned}$$

On en déduit

$$s_\alpha = \frac{\nu^2}{n} G_1^{-1}(\alpha).$$