

TD - Probabilités et Chaînes de Markov

Dans toute la suite, $(\Omega, \mathcal{F}, \mathbb{P})$ désigne un espace probabilisé.

Rappel 1 (Loi forte des grands nombres). Soit (X_n) une suite de variables aléatoires indépendantes identiquement distribuées (i.i.d.) intégrables (i.e. $\mathbb{E}[|X_1|] < +\infty$). La moyenne empirique converge presque sûrement vers $\mathbb{E}[X_1]$:

$$\overline{X_n} = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow[n \rightarrow \infty]{p.s.} \mathbb{E}[X_1].$$

Exercice 1 (Illustrations LGN). Expliciter le résultat de la LGN ci-dessus pour les lois classiques suivantes :

- (i) la loi de Bernoulli $b(p)$ de paramètre $p \in]0, 1[$
- (ii) la loi binomiale $B(n, p)$ de paramètres $n \in \mathbb{N}^*$ et $p \in]0, 1[$
- (iii) la loi géométrique $\mathcal{G}(p)$ de paramètre $p \in]0, 1[$
- (iv) la loi uniforme $\mathcal{U}([0, 1])$
- (v) la loi exponentielle $\mathcal{E}(\alpha)$ de paramètre $\alpha > 0$
- (vi) la loi normale $\mathcal{N}(m, \sigma^2)$ de paramètres $m \in \mathbb{R}$ et $\sigma > 0$
- (vii) la loi de Cauchy, de densité $x \mapsto \frac{1}{\pi} \frac{1}{1+x^2}$ sur \mathbb{R} .

Illustrer numériquement (avec le module `stats` de Python par exemple) les résultats obtenus ici.

Exercice 2 (Méthode de Monte-Carlo). Soient f une fonction et (X_n) une suite de variables aléatoires réelles i.i.d. de loi μ . Justifier le principe suivant, appelé méthode de Monte-Carlo :

$$\frac{1}{n} \sum_{i=1}^n f(X_i) \xrightarrow[n \rightarrow \infty]{p.s.} \mathbb{E}[f(X_1)] = \int_{\mathbb{R}} f d\mu.$$

Appliquer cette méthode pour déterminer numériquement une valeur approchée des intégrales suivantes :

$$\int_3^5 x^2 \ln x dx, \quad \int_0^1 4\sqrt{1-x^2} dx, \quad \int_{\mathbb{R}} e^{-x^2} \sin x dx, \quad \int_{[-1,1]^3} \mathbf{1}_{x^2+2y^2+3z^2 \leq 1} dx dy dz.$$

Rappel 2 (Théorème Central Limite). Soit (X_n) une suite de variables aléatoires indépendantes identiquement distribuées (i.i.d.) de carré intégrable (i.e. $\mathbb{E}[X_1^2] < +\infty$). Pour $m = \mathbb{E}[X_1]$ et $\sigma = \sqrt{\text{Var}(X_1)}$:

$$\sqrt{n} \frac{\overline{X_n} - \mathbb{E}[X_1]}{\sigma} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

Autrement dit, pour les fonctions de répartition :

$$\forall x \in \mathbb{R}, \quad \mathbb{P} \left(\sqrt{n} \frac{\overline{X_n} - \mathbb{E}[X_1]}{\sigma} \leq x \right) \xrightarrow[n \rightarrow \infty]{} F_{\mathcal{N}(0,1)}(x).$$

Exercice 3 (TCL). Illustrer numériquement le résultat ci-dessus pour les lois proposées dans le premier exercice. On représentera pour cela la distribution empirique sous forme d'un histogramme auquel on superposera la densité de la loi.

Rappel 3 (Intervalle de confiance). Soit $\alpha \in]0, 1[$ donné. On appelle intervalle de confiance de niveau $1 - \alpha$ pour un paramètre θ tout intervalle I tel que :

$$\forall \theta \in \Theta, \quad \mathbb{P}_{\theta}(\theta \in I) \geq 1 - \alpha.$$

Exercice 4 (Intervalles de confiance : Cas gaussien). Soient X_1, \dots, X_n des variables aléatoires i.i.d. de loi $\mathcal{N}(\theta, 1)$. L'objectif de l'exercice est de donner un intervalle de confiance de niveau 0.95 pour le paramètre θ (inconnu).

(i) Justifier que, pour tout θ réel et X_1, \dots, X_n i.i.d. de loi $\mathcal{N}(\theta, 1)$:

$$\sqrt{n} \left(\frac{1}{n} \sum_{i=1}^n X_i - \theta \right) \sim \mathcal{N}(0, 1).$$

(ii) Pour $Y \sim \mathcal{N}(0, 1)$, on sait que $\mathbb{P}(|Y| \leq 1.96) \geq 0.95$. Expliquer pourquoi l'intervalle suivant est bien un intervalle de confiance de niveau 0.95 :

$$\left[\bar{X}_n - \frac{1.96}{\sqrt{n}}, \bar{X}_n + \frac{1.96}{\sqrt{n}} \right].$$

(iii) Dans le cas plus général où la loi est $\mathcal{N}(\theta, \sigma)$ avec σ connu, justifier de la même manière que l'intervalle suivant est bien un intervalle de confiance de niveau 0.95 :

$$\left[\bar{X}_n - \frac{\sigma x_{1-\frac{\alpha}{2}}}{\sqrt{n}}, \bar{X}_n + \frac{\sigma x_{1-\frac{\alpha}{2}}}{\sqrt{n}} \right]$$

où l'on a choisi $x_{1-\frac{\alpha}{2}}$, tel que si $Y \sim \mathcal{N}(0, 1)$, alors $\mathbb{P}(|Y| \leq x_{1-\frac{\alpha}{2}}) = 1 - \alpha$.

Rappel 4 (Intervalle de confiance asymptotique). Soit $\alpha \in]0, 1[$ donné. On appelle intervalle de confiance asymptotique de niveau $1 - \alpha$ pour un paramètre θ tout intervalle I_n tel que :

$$\forall \theta \in \Theta, \mathbb{P}_\theta(\theta \in I_n) \xrightarrow[n \rightarrow \infty]{} 1 - \alpha.$$

Exercice 5 (Intervalles de confiance asymptotiques). Tracer les intervalles de confiance asymptotiques, de la forme (1) obtenus pour les exemples de l'exercice 1 :

$$\left[\bar{X}_n - \frac{1.96\sigma}{\sqrt{n}}, \bar{X}_n + \frac{1.96\sigma}{\sqrt{n}} \right]. \quad (1)$$

Exercice 6 (Cas d'une proportion). Soient X_1, \dots, X_n i.i.d. de loi de Bernoulli de paramètre θ inconnu. Déterminons un intervalle de confiance de niveau $1 - \alpha$ pour θ . Le théorème central limite assure que :

$$\sqrt{n} \frac{\bar{X}_n - \theta}{\sqrt{\theta(1-\theta)}} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

On peut montrer que cet argument mène à un intervalle de confiance asymptotique de la forme suivante :

$$\left[\frac{\bar{X}_n + \frac{r^2}{2n} - \frac{r}{\sqrt{n}} \sqrt{\frac{r^2}{4n} + \bar{X}_n(1-\bar{X}_n)}}{1 + \frac{r^2}{n}}, \frac{\bar{X}_n + \frac{r^2}{2n} + \frac{r}{\sqrt{n}} \sqrt{\frac{r^2}{4n} + \bar{X}_n(1-\bar{X}_n)}}{1 + \frac{r^2}{n}} \right]$$

où $r = x_{1-\frac{\alpha}{2}}$ comme précédemment. Une autre méthode, s'appuyant notamment sur le lemme de Slutsky, consiste à s'intéresser à la convergence en loi suivante :

$$\sqrt{n} \frac{\bar{X}_n - \theta}{\sqrt{\bar{X}_n(1-\bar{X}_n)}} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

Justifier que l'on obtient alors un intervalle de confiance asymptotique de la forme (mêmes notations) :

$$\left[\bar{X}_n - r \sqrt{\frac{\bar{X}_n(1-\bar{X}_n)}{n}}, \bar{X}_n + r \sqrt{\frac{\bar{X}_n(1-\bar{X}_n)}{n}} \right]$$

Exercice 7. Posons $\mu = \frac{1}{2}\delta_1 + \frac{1}{2}\delta_{-1}$ et considérons X_1, \dots, X_n des variables aléatoires i.i.d. de loi μ .

(i) Calculer $L_X(t) = \mathbb{E}[e^{tx}]$ et montrer que $\ln L_X(t) \leq \frac{t^2}{2}$.

(ii) Montrer que pour tout $\lambda > 0$,

$$\mathbb{P}(|\overline{X}_n - \mathbb{E}[X_1]| \geq r) = 2\mathbb{P}(\overline{X}_n \geq r) \leq 2 \exp(-n(\lambda r + \ln L_X(\lambda))).$$

(iii) En déduire un intervalle de confiance (non asymptotique) pour le paramètre θ dans le modèle :

$$\mathbb{P}_\theta = \frac{1}{2}\delta_{\theta-1} + \frac{1}{2}\delta_{\theta+1}$$

Exercice 8 (Transformée de Laplace et Inégalité de Chernov). On s'intéresse dans cet exercice à la transformée de Laplace de variables aléatoires. Si X est une variable réelle, on pose $L_X(t) = \mathbb{E}[e^{tX}]$.

(i) Montrer que le domaine de définition de la transformée ci-dessus est un intervalle contenant 0. Peut-il être réduit à $\{0\}$?

(ii) Calculer les transformées de Laplace (lorsque c'est possible) pour les lois $b(p)$, $\mathcal{E}(\lambda)$, $\mathcal{N}(m, \sigma^2)$.

(iii) Soit μ une loi fixée. Considérons X_1, \dots, X_n variables aléatoires i.i.d. de loi μ . Montrer que :

$$\mathbb{P}\left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbb{E}[X_1] \geq r\right) \leq \exp\left(-n \sup_{\lambda > 0} \{\lambda(r + \mathbb{E}[X_1]) - \ln L_X(\lambda)\}\right).$$

En particulier, on a montré le *principe de grandes déviations* suivant :

$$\limsup_{n \rightarrow \infty} \frac{1}{n} \ln \mathbb{P}\left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbb{E}[X_1] \geq r\right) \leq \sup_{\lambda > 0} \{\lambda(r + \mathbb{E}[X_1]) - \ln L_X(\lambda)\}.$$

Rappel 5 (Chaînes de Markov). Soit E un espace d'états. Une suite (X_n) à valeurs dans E est une chaîne de Markov si elle satisfait la propriété suivante :

$$\forall n \in \mathbb{N}, \forall i_1, \dots, i_{n+1}, \mathbb{P}(X_{n+1} = i_{n+1} \mid X_n = i_n, \dots, X_0 = i_0) = \mathbb{P}(X_{n+1} = i_{n+1} \mid X_n = i_n).$$

Autrement dit, le futur ne dépend que du présent. La chaîne est dite homogène si :

$$\mathbb{P}(X_{n+1} = j \mid X_n = i) = \mathbb{P}(X_n = j \mid X_{n-1} = i).$$

La loi de X_0 est appelée loi initiale de la chaîne et, pour une chaîne de Markov homogène, $(p(i, j) = \mathbb{P}(X_n = j \mid X_{n-1} = i))$ est appelée matrice de transition.

On rappelle que, par récurrence, si μ désigne la loi initiale de la chaîne et p la matrice de transition :

$$\mathbb{P}(X_0 = i_0, \dots, X_n = i_n) = \mu(i_0)p(i_0, i_1) \dots p(i_{n-1}, i_n).$$

De même, on montre par récurrence que pour un espace d'états E fini, en notant μ_n la mesure de probabilité de X_n en ligne :

$$\mu_n = \mu_0 P^n.$$

Exercice 9 (Critère). Soient (Y_n) une suite de variables aléatoires i.i.d. à valeurs dans un espace F , X_0 une variable aléatoire indépendante de Y et $f : E \times F \rightarrow E$ une application mesurable. Montrer que la relation de récurrence suivante :

$$X_0 \text{ donné et } X_{n+1} = f(X_n, Y_{n+1})$$

définit une chaîne de Markov (X_n) à valeurs dans E .

Exercice 10 (Lien Matrices-Graphe). Donner les graphes des chaînes de Markov homogènes données par les matrices de transition ci-dessous :

$$\begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}, \begin{pmatrix} 3/10 & 1/10 & 6/10 \\ 0 & 1 & 0 \\ 1/2 & 1/4 & 1/4 \end{pmatrix}, \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \end{pmatrix}.$$

Exercice 11 (Mesure invariante). Déterminer l'unique mesure de probabilité invariante de la matrice de transition suivante :

$$P = \begin{pmatrix} 1 - \alpha & \alpha \\ \alpha & 1 - \alpha \end{pmatrix}.$$

Exercice 12 (Mesure réversible). Montrer que toute mesure m vérifiant $m_i p(i, j) = m_j p(j, i)$ pour tout (i, j) , est invariante.