

Théorème central limite et intervalle de confiance

Lemme 1. Pour tout $z \in \mathbb{C}$, on a $|e^z - (1 + \frac{z}{n})^n| \leq e^{|z|} - (1 + \frac{|z|}{n})^n$.

Démonstration.

En posant $\alpha_n^k = 1 - \frac{n!}{(n-k)!n^k} \mathbb{1}_{k \leq n} \in [0, 1]$, on a :

$$\left| e^z - \left(1 + \frac{z}{n}\right)^n \right| = \left| \sum_{k \geq 0} \frac{z^k}{k!} - \sum_{k=0}^n \frac{z^k}{n^k} \right| = \left| \sum_{k=0}^n \frac{z^k}{k!} \alpha_n^k \right| \leq \sum_{k=0}^n \frac{|z|^k}{k!} \alpha_n^k = e^{|z|} - \left(1 + \frac{|z|}{n}\right)^n$$

□

Théorème 2 (Théorème central limite). Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de variables aléatoires indépendantes, identiquement distribuées et de carré intégrable. Alors :

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

Démonstration.

Si les $(X_n)_{n \in \mathbb{N}^*}$ sont constantes presque sûrement, le résultat est clair. On va donc les supposer non constantes presque sûrement. De plus, quitte à remplacer X_i par $\frac{X_i - \mathbb{E}[X_i]}{\sqrt{\text{Var}(X_i)}}$, on peut supposer que $\mathbb{E}[X_i] = 0$ et $\text{Var}(X_i) = 1$ pour tout $i \in \mathbb{N}^*$. Posons alors $S_n = \sum_{i=1}^n X_i$.

Fixons $t \in \mathbb{R}$. Par indépendance et équidistribution, on a alors :

$$\varphi_{\frac{S_n}{\sqrt{n}}}(t) = \mathbb{E} \left[e^{it \frac{S_n}{\sqrt{n}}} \right] = \prod_{i=1}^n \mathbb{E} \left[e^{it \frac{X_i}{\sqrt{n}}} \right] = \varphi_{X_1} \left(\frac{t}{\sqrt{n}} \right)^n$$

X_1 étant de carré intégrable, φ_{X_1} est deux fois dérivable sur \mathbb{R} , avec :

$$\varphi'_{X_1}(0) = i\mathbb{E}[X_1] = 0 \quad \text{et} \quad \varphi''_{X_1}(0) = -\mathbb{E}[X_1^2] = -\text{Var}(X_1) = -1$$

On obtient alors le développement de Taylor-Young à l'ordre 2 en 0 de φ_{X_1} :

$$\varphi_{X_1} = 1 - \frac{u^2}{2} + o(u^2)$$

On a donc :

$$\varphi_{\frac{S_n}{\sqrt{n}}}(t) = \left(1 - \frac{t^2}{2n} + o\left(\frac{1}{n}\right) \right)^n = \left(1 + \frac{z_n}{n} \right)^n \quad \text{où} \quad z_n = -\frac{t^2}{2} \left(1 + o(1) \right) \in \mathbb{C}$$

On a de plus :

$$e^{|z_n|} - \left(1 + \frac{|z_n|}{n} \right)^n = e^{\frac{t^2}{2}|1+o(1)|} - e^{|z_n|(1+o(1))} \xrightarrow[n \rightarrow +\infty]{} e^{\frac{t^2}{2}} - e^{\frac{t^2}{2}} = 0$$

Ainsi, par le Lemme 1, on a :

$$\varphi_{\frac{S_n}{\sqrt{n}}}(t) \underset{n \rightarrow +\infty}{\sim} e^{z_n} \xrightarrow[n \rightarrow +\infty]{} e^{-\frac{t^2}{2}}$$

Le théorème de Lévy permet alors de conclure que $\frac{S_n}{\sqrt{n}} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, 1)$.

□

Application 3. Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de variables aléatoires indépendantes, identiquement distribuées et de loi $\mathcal{B}(p)$ pour $p \in [0, 1]$ inconnu. Le théorème central limite donne un intervalle de confiance asymptotique de niveau α pour p en fonction de la moyenne empirique $\widehat{p}_n = \frac{1}{n} \sum_{k=1}^n X_k$. Il s'agit de :

$$IC_\alpha = \left[\widehat{p}_n \pm \frac{q_{1-\frac{\alpha}{2}}}{2\sqrt{n}} \right]$$

où q_t est le quantile d'ordre t de $\mathcal{N}(0, 1)$.

Démonstration.

Les $(X_n)_{n \in \mathbb{N}^*}$ satisfont les hypothèses du théorème central limite, avec $\mathbb{E}[X_1] = p$ et $\text{Var}(X_1) = p(1-p)$. Ainsi :

$$\frac{\sqrt{n}}{\sqrt{p(1-p)}}(\widehat{p}_n - p) = \frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{X_i - p}{\sqrt{p(1-p)}} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, 1)$$

La fonction de répartition de $\mathcal{N}(0, 1)$ étant continue, on a, pour tous $a, b \in \mathbb{R}$:

$$\mathbb{P}\left(a \leq \frac{\sqrt{n}}{\sqrt{p(1-p)}}(\widehat{p}_n - p) \leq b\right) \xrightarrow[n \rightarrow +\infty]{} \mathbb{P}(a \leq \mathcal{N}(0, 1) \leq b)$$

En prenant $a = q_{\frac{\alpha}{2}}$ et $b = q_{1-\frac{\alpha}{2}}$, on a $a = -b$, et donc :

$$\mathbb{P}\left(\left| \frac{\sqrt{n}}{\sqrt{p(1-p)}}(\widehat{p}_n - p) \right| \leq q_{1-\frac{\alpha}{2}}\right) \xrightarrow[n \rightarrow +\infty]{} \mathbb{P}(q_{\frac{\alpha}{2}} \leq \mathcal{N}(0, 1) \leq q_{1-\frac{\alpha}{2}}) = 1 - \alpha$$

Ce que l'on réécrit comme :

$$\mathbb{P}\left(p \in \left[\widehat{p}_n \pm q_{1-\frac{\alpha}{2}} \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right]\right) \xrightarrow[n \rightarrow +\infty]{} 1 - \alpha$$

On en déduit le résultat annoncé en remarquant que $p(1-p) \leq \frac{1}{4}$. □

Références

[BL07] Philippe Barbe and Michel Ledoux. *Probabilité*. EDP Sciences, 2007