

Comportement asymptotique de la variance empirique.

Soient (X_1, \dots, X_n) un n -échantillon d'une variable aléatoire X , telle que $\mathbb{E}[X^4] < \infty$. On notera $\mu = \mathbb{E}[X]$, $\sigma^2 = \mathbb{V}(X)$ et $\mathbb{V} = \mathbb{V}((X - \mu)^2)$. On considère les statistiques suivantes :

$$\begin{aligned}\bar{X}_n &= \frac{1}{n} \sum_{i=1}^n X_i \\ V_n &= \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 \\ S_n^2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2\end{aligned}$$

On notera que V_n est la variance empirique dans le cas où l'espérance est connue mais est incalculable. Le but de l'exercice est de montrer que V_n et S_n^2 ont le même comportement asymptotique.

1°. Montrer que

$$\sqrt{n}(V_n - \sigma^2) \rightsquigarrow \mathcal{N}(0, \mathbb{V})$$

Les $(X_i - \mu)_i$ sont des v.a.i.d et par conséquent les $((X_i - \mu)^2)_i$ le sont aussi. Comme les X_i ont un moment d'ordre 4, les $X_i - \mu$ sont de carré intégrable et l'on peut donc appliquer le TLC. $\sqrt{n}(V_n - \sigma^2)$ est asymptotiquement normal et la loi limite a pour variance \mathbb{V} .

2°. Montrer que $S_n^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}_n^2$

Il s'agit de la formule de König-Huygens. On développe l'expression :

$$\begin{aligned}S_n^2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 \\ &= \frac{1}{n} \sum_{i=1}^n (X_i^2 - 2X_i\bar{X}_n + \bar{X}_n^2) \\ &= \frac{1}{n} \sum_{i=1}^n X_i^2 - 2\bar{X}_n^2 + \bar{X}_n^2 \\ &= \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}_n^2\end{aligned}$$

3°. Montrer que $S_n^2 \xrightarrow[n \rightarrow \infty]{\mathbb{P}} \sigma^2$.

D'après la loi forte des grands nombres, \bar{X}_n^2 converge presque sûrement vers $\mathbb{E}[X_i^2] = \sigma^2 + \mu^2$ et \bar{X}_n converge presque sûrement vers $\mathbb{E}[X_i] = \mu$ (les X_i sont i.i.d et ont un moment d'ordre 1). D'après le théorème de l'application continue, on en déduit que \bar{X}_n^2 converge presque sûrement vers $\mathbb{E}[X_i^2] = \sigma^2 + \mu^2$. Enfin, la convergence presque sûre est stable par addition et par conséquent $S_n^2 = \bar{X}_n^2 - \bar{X}_n^2$ converge presque sûrement vers $\sigma^2 + \mu^2 - \mu^2 = \sigma^2$.

La convergence presque sûre implique la convergence en probabilité, d'où la réponse.

4°. On suppose $\mathbb{E}[X] = 0$, quitte à travailler sur les variables centrées. Montrer, grâce au théorème de Slutsky, que

$$\sqrt{n}(S_n^2 - \sigma^2) \rightsquigarrow \mathcal{N}(0, \mathbb{V})$$

Nous avons vu que $V_n - \sigma^2$ converge vers 0 presque sûrement. En factorisant à partir de leur expression on voit facilement que $S_n^2 - V_n = -(\bar{X}_n - \mu)^2$. Ainsi :

$$\sqrt{n}(S_n^2 - \sigma^2) = \sqrt{n}(S_n^2 - V_n) + \sqrt{n}(V_n - \sigma^2) \quad (1)$$

$$= -\sqrt{n}(\bar{X}_n - \mu)^2 + \sqrt{n}(V_n - \sigma^2) \quad (2)$$

$$= -\sqrt{n}(\bar{X}_n - \mu)(\bar{X}_n - \mu) + \sqrt{n}(V_n - \sigma^2) \quad (3)$$

$(\bar{X}_n - \mu)$ tend presque-sûrement vers 0, donc également en probabilité. $\sqrt{n}(\bar{X}_n - \mu)$ converge en loi vers une loi normale centrée (d'après le TLC). D'après le lemme de Slutsky, le produit des deux termes converge en loi vers le produit des limites, à savoir 0. Cette convergence en loi a lieu vers une constante, elle est donc équivalente à une convergence en probabilité.

En appliquant à nouveau le lemme de Slutsky à la somme des deux termes de (3), comme $\sqrt{n}(S_n^2 - V_n)$ converge vers 0 en probabilité et $\sqrt{n}(V_n - \sigma^2)$ converge vers une loi normale, la somme des deux converge en loi vers la limite de $\sqrt{n}(V_n - \sigma^2)$ qui est une loi $\mathcal{N}(0, \mathbb{V})$.

5°. En travaillant sur le TCL appliqué au couple aléatoire (\bar{X}_n, \bar{X}_n^2) et en utilisant la delta-méthode, retrouver le résultat précédent.

Les vecteurs $(X_i, X_i^2)^T$ sont des v.a.i.d de carré intégrable (car les X_i ont des moments d'ordre 4 par hypothèse). On peut donc appliquer la LFGN et le théorème de la limite centrale (en dimension 2) à leur moyenne empirique $(\bar{X}_n, \bar{X}_n^2)^T$:

$$\left(\begin{pmatrix} \bar{X}_n \\ \bar{X}_n^2 \end{pmatrix} - \begin{pmatrix} \mu \\ \mu^2 + \sigma^2 \end{pmatrix} \right) \rightsquigarrow \mathcal{N}(0, \mathbb{C})$$

où \mathbb{C} est la matrice de covariance du couple (X_i, X_i^2) . Posons maintenant $\psi(x, y) = y - x^2$. Il s'agit d'une fonction polynomiale, donc en particulier de classe C^1 dans \mathbb{R}^2 . La valeur absolue de son déterminant jacobien est $2|x|$ et l'on peut appliquer la méthode delta à cette fonction. On a alors $S_n^2 = \bar{X}_n^2 - \bar{X}_n^2 = \psi(\bar{X}_n, \bar{X}_n^2)$ et

$$\left(\psi(\bar{X}_n, \bar{X}_n^2) - \psi(\mu, \mu^2 + \sigma^2) \right) \rightsquigarrow \mathcal{N}(0, J^T J)$$

où J est la matrice jacobienne de ψ . Nous n'avons même pas à calculer ce produit matriciel puisque l'on veut juste retrouver le résultat de la question 4° : la limite est une variable gaussienne univariée de moyenne $\psi(\mu, \mu^2 + \sigma^2) = \mu^2 + \sigma^2 - \mu^2 = \sigma^2$. Dans le cours, vous avez une autre version corrigée de cette question.

6°. Construire un intervalle de confiance à 95% pour σ^2 .

Remarques

- Il est important de bien voir que l'on ne peut pas utiliser directement la LFGN ou le TLC à S_n^2 car les variables $(X_i - \bar{X})^2$ ne sont pas indépendantes.
- Bien se souvenir des propriétés de la convergence presque sûre : elle est stable par toutes les opérations usuelles et par application d'une fonction continue.
- On rappelle que le lemme de Slutsky assure que si $(X_n)_n$ et $(Y_n)_n$ sont deux suites de va convergeant respectivement en loi vers X et c où c est une constante, alors $(X_n + Y_n) \rightsquigarrow (X + c)$, $X_n Y_n \rightsquigarrow cX$.
- Enfin, la converge en loi vers une constante est équivalente à la convergence en probabilité vers une constante.