

Modélisation statistique

#1.b Théorème central limite

Dr. Léo Belzile
HEC Montréal

Loi nulle

Lorsqu'on effectue un test statistique, on doit connaître son comportement sous l'hypothèse nulle afin de tirer une conclusion (rejeter/ne pas rejeter H_0).

La statistique de test est souvent

- + une statistique de Wald (test- t , estimateur du maximum de vraisemblance)
- + racine du test du rapport de vraisemblance

Dans ces cas, sous des hypothèses de régularité et pour n suffisamment grand, la loi nulle qui sert de référence est approximativement normale. Pourquoi?

Théorème central limite (informel)

Si Y_1, \dots, Y_n est un échantillon aléatoire simple d'une population

- + d'espérance μ ,
- + de variance σ^2 finie.

Alors la loi de la moyenne empirique \bar{Y}_n est approximativement normale centrée en μ et de variance σ^2/n .

$$\bar{Y}_n \sim \text{No}(\mu, \sigma^2/n)$$

Théorème central limite (formel)


Soit Y_1, \dots, Y_n des variables aléatoires indépendantes et identiquement distribuées de loi F de variance finie et $\bar{Y}_n = n^{-1} \sum_{i=1}^n Y_i$.

Alors, la moyenne empirique converge en distribution pour tout $y \in \mathbb{R}$,


$$\lim_{n \rightarrow \infty} P\left(\sqrt{n} \frac{\bar{Y}_n - \mu}{\sigma} \leq y\right) = \Phi(y)$$

où $\Phi(y)$ est la fonction de répartition de $N_0(0, 1)$.

Représentons graphiquement le théorème central limite en tirant des échantillons de la loi suivante (tronquée à gauche, multimodale, etc.)




Tirons 20 échantillons aléatoires de taille $n = 10$ de cette loi.




Répartition des $n = 10$ observations et moyenne empirique (trait rouge)

Si on augmente la taille de l'échantillon à $n = 100$, la variabilité de la moyenne diminue.




Répartition des $n = 100$ observations et moyenne empirique (trait rouge)

La même chose, avec $n = 1000$ observations par échantillon.




Répartition des $n = 1000$ observations et moyenne empirique (trait rouge)

Si on fait un histogramme des moyennes (traits rouges), qu'est-ce qu'on obtient?




Distribution empirique et approximation normale de la moyenne de $n = 10$ observations.

L'approximation fournie par le théorème central limite est meilleure quand la taille de l'échantillon n augmente.




Distribution empirique et approximation normale de la moyenne de $n = 100$ observations.

La convergence est plus rapide au centre de la loi que dans la queue.



Distribution empirique et approximation normale de la moyenne de $n = 1000$ observations.

La variance de la moyenne \bar{Y}_n quand $\text{Va}(Y_i) = \sigma^2$ est σ^2/n .



Approximation normale pour différentes tailles d'échantillons.