

Tests Statistiques

Master 1: 2020-2021

Prof. Abdelhakim Necir

Département de Mathématiques (Univ. Biskra)

Lundi 14 Décembre 2020

- **Estimation nonparamétrique:** aucune paramétrisation sur la loi de probabilité.
- **Estimation paramétrique:** la loi de probabilité est paramétrisée.

- Estimation de loi de probabilité F ou sa densité $f = F'$
- Estimation des paramètres statistiques: $\mu := \mathbf{E}[X]$, $\sigma^2 := \mathbf{V}[X]$, Q_α (quantile d'ordre α), le mode, l'étendue,...

- Soit X une va ayant une loi de probabilité $F(x) = P(X \leq x)$.
Supposons qu'on possède un échantillon aléatoire X_1, \dots, X_n de X .
- Donner un estimateur de F noté \hat{F}_n
- Réponse: la fonction de répartition empirique

$$\hat{F}_n(x) = F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}(X_i \leq x).$$

Nous avons déjà évoquer que

$$\mathbf{E}[F_n(x)] = F(x).$$

En d'autre termes F_n est **estimateur sans biais** de F .

Pour tout x fixé,

$$F_n(x) \xrightarrow{P} F(x) \text{ quand } n \rightarrow \infty.$$

En d'autre termes F_n est estimateur convergent de F ou **estimateur consistant**.

Pour tout x fixé,

$$\frac{\sqrt{n}(F_n(x) - F(x))}{\sqrt{F(x)(1-F(x))}} \xrightarrow{\mathcal{D}} \mathcal{N}(0,1), \text{ quand } n \rightarrow \infty.$$

En d'autre termes F_n est **estimateur asymptotiquement normal** (gaussien).

Estimateur de la moyenne μ est:

$$\hat{\mu} = \bar{X}.$$

Nous avons:

$$\mathbf{E} [\hat{\mu}] = \mathbf{E} [\bar{X}] = \mathbf{E} [X] = \mu.$$

Donc $\hat{\mu}$ est estimateur sans biais de μ . En outre, d'après la loi des grands nombres

$$\hat{\mu} \xrightarrow{p} \mu,$$

c'est à dire $\hat{\mu}$ est **un estimateur consistant de μ** .

De plus d'après le théorème central limite

$$\sqrt{n} \frac{\hat{\mu} - \mu}{\sigma} \xrightarrow{\mathcal{D}} \mathcal{N}(0, 1),$$

C'est à dire que $\hat{\mu}$ est **asymptotiquement normal**. Pour n assez grand,

$$\sqrt{n} \frac{\hat{\mu} - \mu}{\sigma} \rightsquigarrow \mathcal{N}(0, 1).$$

Rappel:

$$X \rightsquigarrow \mathcal{N}(a, b^2), b > 0 \iff \frac{X - a}{b} \rightsquigarrow \mathcal{N}(0, 1).$$

Donc pour n assez grand:

$$\sqrt{n} \frac{\hat{\mu} - \mu}{\sigma} \rightsquigarrow \mathcal{N}(0, 1) \iff \hat{\mu} \rightsquigarrow \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right).$$

Pus généralement, pour une fonction g donnée, un estimateur de $\mu_g = g(X_i)$ est:

$$\hat{\mu}_g = \frac{1}{n} \sum_{i=1}^n g(X_i).$$

En particulier un estimateur de le moment d'ordre 2 $\mu^{(2)} = \mathbf{E}[X^2]$ est

$$\hat{\mu}^{(2)} = \frac{1}{n} \sum_{i=1}^n X_i^2.$$

Estimation de la variance:

Nous avons

$$\sigma^2 = \mathbf{Var} [X] = \mathbf{E} [X - \mu]^2 = \mu^{(2)} - \mu^2.$$

Donc un estimateur $\hat{\sigma}^2$ est

$$\begin{aligned}\hat{\sigma}^2 &= \hat{\mu}^{(2)} - \hat{\mu}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \left(\frac{1}{n} \sum_{i=1}^n X_i \right)^2 \\ &= \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X}_n)^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 =: \tilde{S}_n^2.\end{aligned}$$

Estimation de la variance:

On démontre que

$$\mathbf{E} \left[\widehat{\sigma}^2 \right] = \mathbf{E} \left[\widetilde{S}_n^2 \right] = \sigma^2 - \frac{1}{n} \sigma^2.$$

En d'autre termes \widetilde{S}_n^2 est un **estimateur biaisé** de σ^2 .

Correction de biais: on remarque que

$$\mathbf{E} \left[\tilde{S}_n^2 \right] = \left(1 - \frac{1}{n} \right) \sigma^2 = \frac{n-1}{n} \sigma^2,$$

ce qui implique

$$\mathbf{E} \left[\frac{n}{n-1} \tilde{S}_n^2 \right] = \sigma^2.$$

On pose

$$S_n^2 =: \frac{n}{n-1} \tilde{S}_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2,$$

avec $\mathbf{E} [S_n^2] = \sigma^2$. En d'autres termes S_n^2 est estimateur sans biais de σ^2 .

On pose

$$S_n^2 = \frac{n-1}{n} \left[\frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}_n^2 \right],$$

Nous avons $\frac{n-1}{n} \rightarrow 1$, et d'après la loi des grands nombres

$$\frac{1}{n} \sum_{i=1}^n X_i^2 \xrightarrow{P} \mathbf{E}[X^2] = \mu_2 \text{ et } \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{P} \mathbf{E}[X] = \mu$$

et par conséquent

$$S_n^2 \xrightarrow{P} \mu_2 - \mu^2 = \sigma^2.$$

Donc S_n^2 **un estimateur consistant** de σ^2 .

Supposons que $\mu_4 := \mathbf{E} [X - \mu]^4 < \infty$, alors

$$\sqrt{n} (S_n^2 - \sigma^2) \xrightarrow{D} \mathcal{N} (0, \mu_4 - \sigma^4) .$$

En d'autres termes S_n^2 est un **asymptotiquement normal** de σ^2 .

Théorème central limite multidimensionnel

Soit Y_1, \dots, Y_n une suite de vecteurs aléatoires de dimension $d \geq 1$ iid. Supposons que $\mathbf{E} [Y_i^2] < \infty$, alors

$$\frac{1}{\sqrt{n}} (Y_1 + \dots + Y_n - n\mathbf{E} [Y_i]) \xrightarrow{\mathcal{D}} \mathcal{N} (0, \Sigma),$$

où Σ est la matrice de variance-covariance de Y_1 .

Théorème de Slutsky

Soit $Z, Z_1, Z_2, \dots, W_1, W_2, \dots$ des v.a. définies dans un même espace de probabilité. Supposons que $Z_n \xrightarrow{\mathcal{D}} Z$ et $W_n \xrightarrow{P} c$ où c est une constante finie. Alors

$$Z_n + W_n \xrightarrow{\mathcal{D}} Z + c.$$

Théorème central limite multidimensionnel (TCLM)

Application: Nous avons

$$\begin{aligned}\tilde{S}_n^2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - (\bar{X} - \mu)^2 \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - \left(\frac{1}{n} \sum_{i=1}^n (X_i - \mu) \right)^2.\end{aligned}$$

Soit $Y_i = (X_i - \mu, (X_i - \mu)^2)$, $i = 1, 2, \dots, n$. Par définition $\mathbf{E}[(V, W)] := (\mathbf{E}[V], \mathbf{E}[W])$. Nous avons

$$\mathbf{E}[Y_i] = (0, \sigma^2) \text{ et } \mathbf{E}[Y_i^2] = \left(\sigma^2, \mathbf{E}[(X_i - \mu)^4] \right).$$

Théorème central limite multidimensionnel (TCLM)

D'après le TCLM, si $\mu_4 := \mathbf{E} \left[(X_i - \mu)^4 \right] < \infty$ on a

$$\frac{1}{\sqrt{n}} \left(\sum_{i=1}^n \left(X_i - \mu, (X_i - \mu)^2 \right) - n(0, \sigma^2) \right) \xrightarrow{\mathcal{D}} \mathcal{N}(0, \Sigma),$$

où Σ est la matrice de variance-covariance de Y_i :

$$\Sigma = \begin{pmatrix} \mathbf{Var} [X_i - \mu] & \mathbf{Cov} [X_i - \mu, (X_i - \mu)^2] \\ \mathbf{Cov} [(X_i - \mu)^2, X_i - \mu] & \mathbf{Var} [X_i - \mu]^2 \end{pmatrix}.$$

Théorème central limite multidimensionnel (TCLM)

Nous avons

$$\mathbf{Var} [X_i - \mu] = \sigma^2,$$

$$\mathbf{Cov} [X_i - \mu, (X_i - \mu)^2] = \mathbf{E} [X_i - \mu]^3,$$

et

$$\mathbf{Var} [X_i - \mu]^2 = \mu_4 - \sigma^4.$$

Donc en particulier

$$\frac{1}{\sqrt{n}} \left(\sum_{i=1}^n (X_i - \mu) \right) \xrightarrow{\mathcal{D}} \mathcal{N} (0, \sigma^2) \quad (1)$$

et

$$\frac{1}{\sqrt{n}} \left(\sum_{i=1}^n (X_i - \mu)^2 - n\sigma^2 \right) \xrightarrow{\mathcal{D}} \mathcal{N} (0, \mu_4 - \sigma^4). \quad (2)$$

Théorème central limite multidimensionnel (TCLM)

Les limites (1) et (2) peuvent être réécrites comme suit:

$$\sqrt{n}(\bar{X} - \mu) \xrightarrow{\mathcal{D}} \mathcal{N}(0, \sigma^2)$$

et

$$\sqrt{n} \left(\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - \sigma^2 \right) \xrightarrow{\mathcal{D}} \mathcal{N}(0, \mu_4 - \sigma^4). \quad (3)$$

On en déduit que $\sqrt{n}(\bar{X}_n - \mu)$ est bornée en probabilité et que $\bar{X}_n - \mu \xrightarrow{P} 0$. Donc

$$\sqrt{n}(\bar{X}_n - \mu)^2 \xrightarrow{P} 0.$$

Théorème central limite multidimensionnel (TCLM)

En utilisant le théorème **Slutsky**, avec

$$Z_n = \sqrt{n} \left(\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - \sigma^2 \right) \text{ et } W_n = \sqrt{n} (\bar{X}_n - \mu)^2 \xrightarrow{P} 0,$$

on obtient

$$\sqrt{n} \left(\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - \sigma^2 \right) - \sqrt{n} (\bar{X}_n - \mu)^2 \xrightarrow{\mathcal{D}} \mathcal{N} \left(0, \mathbf{E} [X_i - \mu]^4 - \sigma^4 \right).$$

En d'autres termes

$$\sqrt{n} \left(\tilde{S}_n^2 - \sigma^2 \right) \xrightarrow{\mathcal{D}} \mathcal{N} \left(0, \mathbf{E} [X_i - \mu]^4 - \sigma^4 \right).$$

Théorème central limite multidimensionnel (TCLM)

Remarquons que

$$\tilde{S}_n^2 = \frac{n-1}{n} S_n^2.$$

Alors

$$\sqrt{n} \left(\frac{n-1}{n} S_n^2 - \sigma^2 \right) \xrightarrow{\mathcal{D}} \mathcal{N} \left(0, \mathbf{E} [X_i - \mu]^4 - \sigma^4 \right).$$

Ce qui implique que

$$\frac{n-1}{n} \sqrt{n} \left(S_n^2 - \frac{n}{n-1} \sigma^2 \right) \xrightarrow{\mathcal{D}} \mathcal{N} \left(0, \mathbf{E} [X_i - \mu]^4 - \sigma^4 \right).$$

En d'autres termes

$$\sqrt{n} \left(S_n^2 - \sigma^2 - \frac{1}{n-1} \sigma^2 \right) \xrightarrow{\mathcal{D}} \mathcal{N} \left(0, \mathbf{E} [X_i - \mu]^4 - \sigma^4 \right).$$

Théorème central limite multidimensionnel (TCLM)

En appliquant encore une fois le théorème **Slutsky**, avec

$$Z_n = \sqrt{n} (S_n^2 - \sigma^2) \text{ et } W_n = \frac{\sqrt{n}}{n-1} \sigma^2 \rightarrow 0,$$

on obtient

$$\sqrt{n} (S_n^2 - \sigma^2) \xrightarrow{\mathcal{D}} \mathcal{N} \left(0, \mathbf{E} [X_i - \mu]^4 - \sigma^4 \right).$$