

Cours Statistiques

n° 4.

Estimation: obtenir une valeur (au que faire se peut approchée) d'une caractéristique (ou d'une grandeur) statistique de la population en exploitant un échantillon.

Estimateur: θ de la caractéristique qu'on cherche

θ la valeur inconnue de la caractéristique de la population.

$$\hat{\theta} = g(x_1, \dots, x_m) \text{ estimateur de } \theta$$

$$\hat{\theta} = g(x_1, \dots, x_m) \text{ estimation de } \theta$$

Moynenne μ_x de la population: $\mu_x = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n x_k$

$$\theta: \mu_x \quad \theta = \mu_x$$

$$\hat{\theta}_m = g(x_1, \dots, x_m) = \frac{1}{m} \sum_{k=1}^m x_k \text{ estimateur de la v.a.}$$

$$\hat{\theta} = g(x_1, \dots, x_m) = \frac{1}{m} \sum_{k=1}^m x_k$$

Critères de qualité de l'estimateur

1° Estimateur sans biais

$$E(\hat{\theta}) = \theta$$

$$B_{\theta}(\hat{\theta}) = \hat{\theta} - \theta$$

$$E(\hat{\theta}_m) = \theta$$

$$B_{\theta}(\hat{\theta}_m) = E(\hat{\theta}_m) - \theta$$

Si on prend plusieurs échantillons et on calcule

$$\frac{1}{N} \sum_{p=1}^N \hat{\theta}_p \xrightarrow{N \rightarrow \infty} \theta$$

2° $V(\hat{\theta}_m)$ doit être minimale

$V(\hat{\theta})$ doit être minimale :

Estimateur sans biais de variance minimale

3° Estimateur convergent

$$\lim_{m \rightarrow \infty} V(\hat{\theta}_m) = 0$$

Précision ou risque d'un estimateur

$$\begin{aligned} R_{\theta}(\hat{\theta}_m) &= E[(\hat{\theta}_m - \theta)^2] \\ &= V(\hat{\theta}_m) + (E(\hat{\theta}_m) - \theta)^2 \\ R_{\theta}(\hat{\theta}_m) &= V(\hat{\theta}_m) + B_{\theta}^2(\hat{\theta}_m) \end{aligned}$$

minimale 0

Le risque est petit \rightarrow la précision grande

Exemples d'estimateurs

Esérance E de la population $E(X) = \mu_x = \theta$

Esérance empirique $\bar{X} = m_x = \frac{1}{m} \sum_{k=1}^m X_k = \hat{\theta}$

tirage $(x_1 \dots x_m)$ $\hat{\theta}_m = \bar{x}_m = \frac{1}{m} \sum_{k=1}^m x_k$

$E(\bar{X}_m) = E(X) = \mu_x = \theta \Rightarrow$ sans biais

$V(\bar{X}_m) = \frac{\sigma_x^2}{m}$ variance minimale (démon en TD)

Variance $\theta = V(X) = \sigma_x^2$

1° La moyenne de la population est connue μ_x

$\hat{\theta} = T_m^2 = \frac{1}{m} \sum_{k=1}^m (X_k - \mu_x)^2$

$(x_1 \dots x_m)$ $\hat{\theta} = t_m^2 = \frac{1}{m} \sum_{k=1}^m (x_k - \mu_x)^2$

$$E(\hat{\theta}) = E(T_m^2) = \theta = \sigma_x^2 \Rightarrow \text{sans biais}$$

$$V(\hat{\theta}) = V(T_m^2) = \frac{\mu_x^4 - \sigma_x^4}{m} \xrightarrow{m \rightarrow \infty} 0$$

2° La moyenne de la population est inconnue. On l'estime par $\bar{X}_m = \frac{1}{m} \sum_{k=1}^m X_k$

$$\hat{\theta} = S_m^2 = \frac{1}{m} \sum_{k=1}^m (X_k - \bar{X}_m)^2$$

$$(x_1 \dots x_m): \hat{\theta} = S_m^2 = \frac{1}{m} \sum_{k=1}^m (x_k - \bar{x})^2$$

$$E(\hat{\theta}) = E(S_m^2) = \frac{m-1}{m} \sigma_x^2 \rightarrow \text{avec biais}$$

$$V(\hat{\theta}) = V(S_m^2) = \frac{m-1}{m^3} [(m-1)\mu_x^4 - (m-3)\sigma_x^4]$$

Variance corrigée

$$\hat{\theta} = S_m^2 = \frac{1}{m-1} \sum (X_k - \bar{X})^2$$

$$E(\hat{\theta}) = E(S_m^2) = \sigma_x^2 \text{ sans biais}$$

$$V(\hat{\theta}) = V(S_m^2) = \frac{2}{m} \left(\mu_x^4 - \frac{m-3}{m-1} \sigma_x^4 \right)$$

Corrélation entre deux variables X et Y

$$\hat{\theta} = r_m(X, Y) = \frac{\sum_{k=1}^m (X_k - \bar{X}_m)(Y_k - \bar{Y}_m)}{\sqrt{\sum_{k=1}^m (X_k - \bar{X}_m)^2 \sum_{k=1}^m (Y_k - \bar{Y}_m)^2}} \in [-1; 1]$$