

# Échantillonnage

# Problème d'échantillonnage

On connaît la loi et les paramètres de la loi suivie par la population mère .

## Type des Problèmes à résoudre :

Vérifier si l'échantillon donné appartient à cette population et avec quelle probabilité de se tromper.

C.à.d : Avec quel risque, et ce risque sera noté  $\alpha$ .

Pour répondre on se fonde sur l'observation des échantillons.

**Def :** On appelle *échantillon* de taille  $n$ , ou  *$n$ -échantillon* de la v.a.  $X$ , toute suite de v.a.  $(X_1, X_2, \dots, X_n)$  indépendantes et de même loi que  $X$ .

On note :

- $(X_1, X_2, \dots, X_n)$  l'échantillon (la suite des v.a.i.i.d.)
- $(x_1, x_2, \dots, x_n)$  une réalisation de l'échantillon.

# Les caractéristiques de l'échantillon

## 1.1. *Moyenne empirique ou expérimentale :*

$$\bar{X} = \frac{1}{n} \sum_{k=1}^n X_k$$

Propriétés de  $\bar{X}$  :

- $E(\bar{X}) = E\left(\frac{1}{n} \sum_{k=1}^n X_k\right) = E(X) = \mu_X$
- $V(\bar{X}) = \frac{\sigma_X^2}{n}$

## 1.2. *Variance Empirique ou Expérimentale*

- *Variance empirique* :  $S^2 = \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X})^2$
- *Variance empirique corrigée ou sans biais* :  
 $S'^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X})^2$

Propriétés de la variance empirique :

- $nS^2 = (n - 1)S'^2$
- $E(S^2) = \frac{n - 1}{n} \sigma_X^2$
- $E(S'^2) = \sigma_X^2$

## 2. Distributions d'échantillonnage

On appelle *distributions d'échantillonnage* les lois suivies par les caractéristiques de l'échantillon, c.à.d. la loi de la :

- Moyenne empirique  $\bar{X}$
- Variance empirique  $S^2$ .
- Fréquence dans l'échantillon  $f_n = \frac{X}{n}$

Pour étudier ces lois on doit d'abord définir les lois dites *dérivées de la loi normale*, car elles se fondent sur la loi normale.

# 1. Loïs dérivées de la loi normale

La loi du  $\chi^2(\nu)$  (**chi deux**) ;  $\nu$  degrés de liberté, noté d.d.l.

Soient  $X_i \sim \mathcal{N}(\mu_i, \sigma_i^2)$  ;  $i = 1, 2, \dots, n$ .

La somme des carrées des v.a. normales centrées et réduites,

$$U = \sum_{i=1}^m \left( \frac{X_i - \mu_i}{\sigma_i} \right)^2 \sim \chi^2(\nu)$$

La variable aléatoire  $U$  suit la loi du **chi deux** avec  $\nu = n$  d.d.l.

On a :

$$E(U) = \nu; \quad V(U) = 2\nu$$

# Loi de Student (ou t-distribution)

On suppose que :

$$Z \sim \mathcal{N}(0, 1) \text{ et } U \sim \chi^2(\nu)$$

alors la v.a.

$$T = \frac{Z}{\sqrt{U / \nu}}$$

suit une loi de student  $T \sim t(\nu)$  .

$$E(T) = 0; \quad V(T) = \frac{\nu}{\nu-2}$$

## Loi de Fisher (loi f)

Soient  $U_1 \sim \chi^2(\nu_1)$  et  $U_2 \sim \chi^2(\nu_2)$  alors la v.a.

$$F = \frac{U_1/\nu_1}{U_2/\nu_2}$$

suit une loi de Fisher, notée  $F \sim F(\nu_1, \nu_2)$ .

**Rq** : La table de cette loi fournit les valeurs  $F(p; \nu_1, \nu_2)$  pour  $p \leq 0.5$

Si  $p > 0.5$  on peut utiliser la même table car

$$F(p; \nu_1, \nu_2) = \frac{1}{F(1 - p; \nu_2, \nu_1)}$$

# Lois suivies par les caractéristiques de l'échantillon ou distributions d'échantillonnage

On va étudier les cas de :

- I Échantillons grands
- II Échantillons petits mais la loi suivie dans l'échantillon est la loi normale.

**Rappel :**

**Théorème 1. Th. central limite.**

*Soit la suite  $(X_n)_n$  de v.a.i.i.d.*

$$\text{On pose : } S_n = \sum_{k=1}^n X_k \quad \text{et} \quad Z = \frac{S_n - E(S_n)}{\sigma_{S_n}}$$

$$\text{Alors : } Z \sim \mathcal{N}(0, 1)$$

# I. Échantillons grands

1.1 Loi suivie par  $\bar{X}$  quand la variance  $V(X)$  de la population-mère est connue

$$\bar{X} = \frac{1}{n} \sum_{k=1}^n X_k ; \quad \text{quand } n \rightarrow \infty$$

On pose :  $S_n = \frac{1}{n} \sum_{k=1}^n X_k$

$$\text{On a : } E(S_n) = \mu ; \quad \text{Var}(S_n) = \sigma_{S_n}^2 = \frac{\sigma^2}{n}$$

En appliquant le **TCL** :

$$\frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim \mathcal{N}(0, 1)$$

ou bien

$$\bar{X} \sim \mathcal{N}\left(\mu, \sigma_{\bar{X}}^2\right), \quad \sigma_{\bar{X}}^2 = \frac{\sigma^2}{n}$$

# I. Échantillons grands (suite)

## 1.2 Loi suivie par $\bar{X}$ quand la variance $\sigma^2$ de la population-mère est inconnue

On utilisera la loi de Student.

On montre que

$$T = \sqrt{n-1} \frac{\bar{X} - \mu_X}{S} \sim t(\nu); \quad \nu = n - 1; \quad S^2 = \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X})^2$$

Ou bien

$$T = \sqrt{n} \frac{\bar{X} - \mu_X}{S'} \sim t(\nu); \quad \nu = n - 1; \quad S'^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X})^2$$

**Rq** : les démonstrations se feront en TD

On démontre aussi que  $\bar{X}$  et  $S^2$  sont des variables aléatoires indépendantes.

# I. Échantillons grands (suite)

## 2. Loi suivie par la variance empirique $S^2$

On démontre que :

$$(n) \frac{S^2}{\sigma^2} \sim \chi^2(n - 1)$$

Ou bien

$$(n - 1) \frac{S'^2}{\sigma^2} \sim \chi^2(n - 1)$$

**Rq** : Les démonstrations se feront en TD.

# I. Échantillons grands (fin)

## 3. La loi de la fréquence $f_n$ .

Soient les *v.a.*  $X_i \sim b(p)$  et  $S_n = X = X_1 + X_2 + \dots + X_n$ .

On note  $f_n = \frac{X}{n}$  la fréquence dans l'échantillon.

On a :

$$E(f_n) = p \text{ et } V(f_n) = \frac{p(1-p)}{n}$$

Par le T.C.L. on obtient :

$$\frac{f_n - E(f_n)}{\sqrt{V(f_n)}} = \frac{f_n - p}{\sqrt{\frac{p(1-p)}{n}}}$$

et donc :

$$f_n \sim \mathcal{N}\left(p, \frac{p(1-p)}{n}\right) \quad \sigma_{f_n}^2 = \frac{p(1-p)}{n}$$

## II. Échantillons petits

- On sait résoudre le problème si la loi suivie dans l'échantillon est la loi normale.  
On utilise les lois dérivées de la loi normale.
- Si la loi n'est pas la loi normale on ne connaît pas toujours les lois des caractéristiques de l'échantillon.

## Étapes à suivre

1. On définit le risque  $\alpha$
2. On identifie la loi suivie par la v.a.  $X$  dans l'échantillon
3. On se place dans les cas des grands ou petits échantillons.
4. On justifie la loi de  $\bar{X}$
5. On établit une fourchette, une règle, dans laquelle  $\bar{X}$  doit se trouver avec un risque  $1 - \alpha$
6. On observe l'échantillon :
  - On calcule  $\bar{x}$ , (une réalisation de  $\bar{X}$ ).
  - On calcule  $s^2$ , (une réalisation de  $S^2$ ).

7. On vérifie si  $\bar{x}$  appartient à l'intervalle, (la fourchette calculée).
8. Si oui, on décide que l'échantillon est conforme à la population-mère avec un risque  $\alpha$ , sinon on décide que l'échantillon ne peut pas appartenir à la population en question.

## Exemple

On prélève 50 pièces dans la production.

On avait réglé la machine à un diamètre de  $\mu = 10$  cm et un écart-type de  $\sigma^2 = 4$ cm.

Pb : Est-ce que la machine produit toujours des pièces conformes aux normes ?

### Étapes

1. On définit le risque  $\alpha = 0.05$
2.  $n = 50$ , on utilisera le T.C.L.
3. On se place dans les cas des grands échantillons,  $\sigma^2$  connu.
4.  $\frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim \mathcal{N}(0, 1)$

$$5. P(a \leq \bar{X} \leq b) = P\left(\frac{a-\mu}{\sigma}\sqrt{n} \leq \frac{\bar{X}-\mu}{\sigma}\sqrt{n} \leq \frac{b-\mu}{\sigma}\sqrt{n}\right) = 1 - \alpha$$

Donc  $F\left(\frac{b-\mu}{\sigma}\sqrt{n}\right) - F\left(\frac{a-\mu}{\sigma}\sqrt{n}\right) = 2F(t) - 1 = 0.95$

On a posé  $t_1 = \frac{b-\mu}{\sigma}\sqrt{n}$  et  $t_2 = \frac{a-\mu}{\sigma}\sqrt{n}$ ,  $t_2 = -t_1$ ,  
 (la loi normale étant symétrique)

$$F(t) = (1 + 0.95)/2, \text{ par la table de la loi normale } t = 1.64$$

$$\text{On obtient : } \mu - 1.64\frac{\sigma}{\sqrt{n}} \leq \bar{X} \leq \mu + 1.64\frac{\sigma}{\sqrt{n}}$$

$$\Rightarrow 9.34 \leq \bar{X} \leq 10.66$$

6. On observe l'échantillon : Sur 50 pièces on a calculé  $\bar{x} = 9.02$

7. Décision : La machine continue à produire des pièces de moyenne  $\mu = 10\text{cm}$   
 avec un risque de  $\alpha = 0.05$

## Faire la différence entre :

Modèle Théorique paramètres de la loi (valeurs certaines)	et	Échantillon Il s'agit des v.a.
$\mu = E(X)$		$\bar{X}$
$V(X)$		$S^2$
$E(X) = p$		$f_n$