

# Ch. 6 INFÉRENCE

# Introduction

## Rappel :

Le but de la statistique est de déterminer un modèle probabiliste ou bien certains paramètres du modèle à partir des observations.

**Faire l'inférence** sur les paramètres ou la loi suivie par un phénomène physique.

## Deux types de problèmes

- La loi suivie est totalement inconnue  $\Rightarrow$  **Statistique non - paramétrique.**
- La loi suivie est connue mais les paramètres de la loi sont inconnus  $\Rightarrow$  **Statistique paramétrique.**

## Statistique paramétrique.

Exemple : La loi suivie est une loi Normale mais les paramètres  $\sigma^2$  et/ou  $\mu$  sont inconnus.

On note :

$\theta$  le paramètre inconnu ou  $\underline{\theta}$  les paramètres inconnus.

## Problème du statisticien :

Connaître la vraie valeur de  $\theta$

**Solution** Il fera des observations sur un échantillon et ensuite il va essayer de voir par quelle fonction, qui résulte des ces observations, pourra estimer au **mieux** les paramètres inconnus.

Il fera donc une **inférence** .

## Estimation du paramètre $\theta = [\theta_1, \dots, \theta_m]^T$

- **L'estimation ponctuelle :**  
A partir des  $n$  v.a.  $X_1, \dots, X_n$  on calcule une seule valeur pour estimer le paramètre  $\theta$ .
- **Estimation par *Intervalle De Confiance* :** On associe au paramètre  $\theta$  un Intervalle, dit de *confiance*, dans lequel se trouve la vraie valeur de  $\theta$  avec une probabilité fixée d'avance.

# Modélisation

**Définition :** . Soit une v.a.  $X$  définie sur  $(\Omega, \mathcal{A}, P)$  de densité  $f(x, \boldsymbol{\theta})$  avec  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_r)^T \in \Theta$  . On définit la *famille des fonctions de densité* quand  $\boldsymbol{\theta}$  varie dans  $\Theta$  :  $\mathcal{F}(\Theta) = \{f(\cdot, \boldsymbol{\theta}) \mid \boldsymbol{\theta} \in \Theta\}$ .

**Définition :** . On appelle *modèle statistique* la donnée d'un espace  $(\Omega, \mathcal{A})$  probabilisable et d'une famille de densités  $(P_{\theta})_{\theta \in \Theta}$  quand  $\boldsymbol{\theta}$  varie dans  $\Theta$  .

**Définition :** . 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 qui suivent la même loi que  $X$

On note :

- $\underline{\theta} = [\theta_1, \theta_2, \dots, \theta_k]$  les paramètres inconnus.
- On notera  $\mathcal{L}(\underline{\theta})$  la loi connue de paramètre  $\theta$
- $(X_1, X_2, \dots, X_n)$  un n- échantillon
- $(x_1, x_2, \dots, x_n)$  une réalisation de l'échantillon.

**Définition :** . Soit  $(X_1, X_2, \dots, X_n)$  un  $n$  -échantillon.

On appelle *statistique* toute v.a.  $U$  de la forme  $U = \phi(X_1, X_2, \dots, X_n)$  où  $\phi$  est une application mesurable de

$$\mathbb{R}^n \rightarrow \mathbb{R}$$

qui ne dépend pas de  $\theta$

**Pb :**

- Comment choisir la "meilleure" statistique pour estimer les paramètres
- Comment déterminer la fonction de perte.  
C.à.d. Estimer l'erreur commise par l'estimation ?

**Définition :** On appelle *estimateur* de  $\theta$ , (ou  $\alpha(\theta)$ ), toute statistique  $U$ , notée aussi  $\hat{\theta}$ , dont la valeur observée sur l'échantillon  $(X_1, \dots, X_n)$  est utilisée pour estimer le paramètre inconnu  $\theta$  (ou une fonction de  $\theta$ ,  $\alpha(\theta)$ ).

## Problème : Comment choisir un Estimateur ?

On doit étudier ses propriétés.

# 1. Propriétés à distance finie des estimateurs

On considère un échantillon de la v.a.  $X$  qui suit une loi de paramètre  $\theta$ .

## 1.1 Estimateur non biaisé

**Définition** L'estimateur  $U_n(X_1, \dots, X_n)$  est *sans biais* pour le paramètre  $\theta \in \Theta$ , (ou pour une fonction de  $\theta$ ,  $\alpha(\theta)$ ) si :

$$E_{\theta}[U_n] = \theta \quad (\text{ou } E_{\theta}[U_n] = \alpha(\theta)) \quad \forall \theta \in \Theta \subset \mathbb{R}$$

$$b = E_{\theta}[U_n] - \theta; \quad b : \text{est le biais de l'estimateur.}$$

Rq :

- Le biais est l'erreur systématique due au fait que  $U$  varie autour de  $E(U)$  et pas autour de  $\theta$ .
- Cette propriété n'est pas invariante par rapport à une transformation.  
Si  $T$  est sans biais pour  $\theta$ ,  $h(U)$  n'est pas en général sans biais pour  $h(\theta)$  sauf dans le cas d'une transformation linéaire.

## 1.2 Risque quadratique d'un estimateur

**Définition :** On appelle *risque quadratique* d'un estimateur  $U_n$  de  $\theta$ , (ou de  $\alpha(\theta)$ ) le nombre :

$$R_{\theta}(U) = E_{\theta}(U - \theta)^2$$

ou

$$R_{\theta}(U) = E_{\theta}(U - \alpha(\theta))^2$$

. On dit que  $U$  est *préférable* à  $V$  si :

$$R_{\theta}(U) \leq R_{\theta}(V) , \forall \theta \in \Theta$$

Rq :

–  $R_{\theta}(U) = V(U) + b^2$

car  $E_{\theta}(U - \theta)^2 = V(U) + [E(U) - \theta]^2$

– Le risque quadratique de l'estimateur exprime la variation autour de  $\theta$ .

### 1.3 Efficacité relative des deux estimateurs

**Définition :** Soient  $T$  et  $U$  deux estimateurs sans biais de  $\alpha(\theta)$ .

L'estimateur  $T$  est dit plus *efficace* que  $U$  si :

$$V(T) \leq V(U) \quad \forall \theta \in \Theta$$

Rq :

- Cette définition exprime que  $T$  présente des variations plus petites que  $U$
  - Cette notion concerne les estimateurs sans biais
-

## 2. Propriétés asymptotiques des estimateurs

2.1 Définition : L'estimateur  $U_n(X_1, \dots, X_n)$  est un *estimateur asymptotiquement sans biais* pour le paramètre  $\theta \in \Theta$  ( ou  $\alpha(\theta)$ ) si :

$$E_{\theta} [U_n] \xrightarrow{n \rightarrow \infty} \theta \quad (\text{ ou } E_{\theta} [U_n])$$

**2.2 Définition :** L'estimateur  $U_n(X_1, \dots, X_n)$  est un estimateur *convergent* si :

$$U_n$$

**2.3 Proposition.** Si  $\lim_{n \rightarrow \infty} R_\theta(U_n) = 0$  alors  $U_n$  est **convergent et asymptotiquement sans biais**.

**2.2 Définition** : Un estimateur  $U$  de  $\theta$  est dit *asymptotiquement normal* si

$$\sqrt{n}(U - \theta) \sim \mathcal{N}(0, \sigma^2)$$

ou bien

$$(U - \theta) \sim \mathcal{N}\left(0, \frac{\sigma^2}{n}\right)$$

Exemple :  $\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$  est asymptotiquement normal.

## Remarques :

- Un estimateur sans biais n'est pas toujours meilleur au sens du risque quadratique qu'un estimateur avec biais.
- Deux estimateurs ne sont pas toujours comparables.
- Entre deux estimateurs sans biais, le plus précis est celui qui a la plus petite variance.

**Pb** : Comment améliorer un estimateur ?

- Méth.1 : À partir d'un estimateur  $T$  on essaie de "construire" un autre  $U$  préférable à  $T$  en réduisant sa variance.
- Méth.2 : Transformer un estimateur  $T$  pour réduire son biais.