

## Chapitre 2 : Estimation

Said, El Melhaoui

Faculté des Sciences Juridiques, Économiques et Sociales Oujda

<http://said-el-melhaoui.e-monsite.com>

## Outline

### 1 Exemple introductif

### 2 Méthodes d'estimation

- Définitions et notations
- Méthode des moments
- Méthode du maximum de vraisemblance

### 3 Propriétés d'un estimateur

- Estimateur sans biais
- Efficacité relative et absolue
- Convergence

### 4 Intervalle de confiance

- Généralités
- Intervalle de confiance pour la moyenne
- Intervalle de confiance pour la variance
- Intervalle de confiance pour la proportion
- Précision d'une estimation par intervalle de confiance

## Exemple introductif

### 1 Population $U$

$X \sim \mathcal{N}(\mu, 1)$ , où  $\mu$  est un paramètre inconnu appartenant à un espace de paramètres  $\Theta$  (par exemple,  $\Theta = \mathbb{R}$ )

### 2 Objectif

On veut estimer  $\mu$

### 3 Échantillon aléatoire $\{X_1, X_2, \dots, X_n\}$

Les  $X_i$  sont supposées i.i.d (issu par un ESAR)

**Rappel :**  $X_i$  désigne la v. a. et  $x_i$  la valeur prise par celle-ci

### 4 Loi de $X_i$

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2}} \quad x \in \mathbb{R}$$

$\Rightarrow f(x) = f(x, \mu)$  : la loi dépend de  $\mu$

## Exemple introductif (suite)

### 5 Loi du vecteur $\{X_1, X_2, \dots, X_n\}$

Les  $X_i$  sont des v.a. i.i.d.  $\Rightarrow$  la loi jointe du vecteur est

$$f(x_1, \dots, x_n) = \prod_{i=1}^n f(x_i)$$

Notation:  $\prod_{i=1}^n a_i = \prod_{i=1}^n a_i = a_1 \times a_2 \dots \times a_n$

$$\begin{aligned} f(x_1, \dots, x_n) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} e^{-\frac{(x_i - \mu)^2}{2}} \\ &= \frac{1}{(2\pi)^{n/2}} e^{-\frac{1}{2} \sum_{i=1}^n (x_i - \mu)^2} \\ \Rightarrow f(x_1, \dots, x_n) &= f(x_1, \dots, x_n; \mu) \end{aligned}$$

## Exemple introductif (suite)

### 6 Comment estimer $\mu$ ?

Estimateur:  $\hat{\mu} = \hat{\mu}(X_1, X_2, \dots, X_n)$

Exemples:

- $\hat{\mu}_1 = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$
- $\hat{\mu}_2 = \frac{1}{k} \sum_{i=1}^k X_i \quad k \in \{1, \dots, n\}$
- $\hat{\mu}_3 = X_i \quad i \in \{1, \dots, n\}$
- $\hat{\mu}_4 = X_{1/2}$  (la médiane)

Comment choisir un estimateur? Quelles sont ses propriétés?

**N. B.** La v. a.  $\hat{\mu}(X_1, \dots, X_n)$  est un estimateur de  $\mu$   
 la valeur observée  $\hat{\mu}(x_1, \dots, x_n)$  est une estimation de  $\mu$

## Définitions et notations

- Population  $U$  : v. a.  $X$  où la loi-type est donnée:
  - a. Cas discret:  $\{(x, p_x), x \in \mathbb{N}\}$
  - b. Cas continu :  $f(x), x \in \mathbb{R}$
- Paramètres à estimer :  $\theta_1, \dots, \theta_K$  ( $\theta_k \in \Theta_k$ )  
**N. B.** L'ensemble des paramètres est noté  $\theta$  ( $\theta \in \Theta$ )
- Échantillon aléatoire  $\{X_1, X_2, \dots, X_n\}$  où la loi de  $X_i$  dépend de  $\theta$ :
  - a. Cas discret:  $p_{x_i} = p_{x_i}(\theta)$
  - b. Cas continu :  $f(x_i) = f(x_i; \theta)$**N. B.** Les  $X_i$  sont supposées i.i.d.

## Méthode des moments: Rappel

- Moments simples de la loi de  $X$ :

$$\mu_k = E(X^k) = \mu_k(\theta_1, \dots, \theta_K) \text{ où } k = 1, \dots, K$$

- Moments simples (empiriques) de l'échantillon:

$$m_k = \frac{1}{n} \sum_{i=1}^n X_i^k \text{ où } k = 1, \dots, K$$

## Méthode des moments : Définition des estimateurs

### Définition

Les estimateurs  $\hat{\theta}_1, \dots, \hat{\theta}_K$  des paramètres  $\theta_1, \dots, \theta_K$  sont déterminés en résolvant le système de  $K$  équations à  $K$  inconnus:

$$\begin{cases} \mu_1(\theta_1, \dots, \theta_K) & = m_1 \\ \mu_2(\theta_1, \dots, \theta_K) & = m_2 \\ \vdots & \vdots \\ \mu_K(\theta_1, \dots, \theta_K) & = m_K \end{cases}$$

## Méthode des moments: Exemple 1

- Population :  $X \sim \mathcal{P}(\lambda)$ ,  $\lambda \in \mathbb{R}^{+*}$   
On désire estimer  $\lambda$  (un seul paramètre inconnu)
- Moment population :  $\mu_1(\lambda) = E(X) = \lambda$   
Moment échantillon :  $m_1 = \bar{X}$
- Équation:

$$\mu_1(\lambda) = m_1 \Leftrightarrow \hat{\lambda} = \bar{X}$$

- Conclusion : L'estimateur du paramètre inconnu  $\lambda$  obtenu par la méthode des moments est donné par  $\hat{\lambda} = \bar{X}$

## Méthode des moments : Exemple 2

- Population :  $X \sim \mathcal{N}(\mu, \sigma^2)$ ,  $\mu \in \mathbb{R}$ ,  $\sigma^2 \in \mathbb{R}^{+*}$   
On désire estimer  $\mu$  et  $\sigma^2$  (2 paramètres inconnus)
- Moments population :

$$\mu_1(\mu, \sigma^2) = E(X) = \mu$$

$$\mu_2(\mu, \sigma^2) = E(X^2) = \sigma^2 + \mu^2$$

Moments échantillon :

$$m_1 = \bar{X}$$

$$m_2 = s^2 + \bar{X}^2$$

$$\text{Rappel: } s^2 = \frac{1}{n} \sum_i X_i^2 - \bar{X}^2 = m_2 - \bar{X}^2$$

## Méthode des moments : Exemple 2 (suite)

- Équations:

$$\begin{cases} \mu_1(\mu, \sigma^2) = m_1 \\ \mu_2(\mu, \sigma^2) = m_2 \end{cases} \Leftrightarrow \begin{cases} \mu = \bar{X} \\ \sigma^2 + \mu^2 = s^2 + \bar{X}^2 \end{cases}$$

- Conclusion : Les estimateur des paramètres inconnus  $\mu$  et  $\sigma^2$  obtenus par la méthode des moments sont donnés par

$$\begin{cases} \hat{\mu} = \bar{X} \\ \hat{\sigma}^2 = s^2 \end{cases}$$

## Idée de la méthode du maximum de vraisemblance

- Supposons devoir estimer  $\theta \in \Theta$
- Pour estimer  $\theta$  on choisit dans  $\Theta$  la valeur qui assure à l'échantillon la plus grande '**vraisemblance**': apparence de vérité ; crédibilité ; probabilité d'apparence (de réalisation)
- Loi de l'échantillon  $\{X_1, X_2, \dots, X_n\}$

a. Cas discret:

$$p(x_1, \dots, x_n; \theta) = \prod_i p_{x_i}(\theta)$$

Fonction de vraisemblance :

$$L(\theta) = p(x_1, \dots, x_n; \theta)$$

b. Cas continu :

$$f(x_1, \dots, x_n; \theta) = \prod_i f(x_i)$$

Fonction de vraisemblance :

$$L(\theta) = f(x_1, \dots, x_n; \theta)$$

## Méthode du maximum de vraisemblance

### Définition des estimateurs MV

Valeur  $\hat{\theta} \in \Theta$  telle que  $L(\hat{\theta}) = \max_{\theta \in \Theta} L(\theta)$

Équation du maximum de vraisemblance : Si  $L(\theta)$  est différentiable et possède au point  $\hat{\theta}$  un maximum sur  $\Theta$ ,  $\hat{\theta}$  est solution de l'équation du M. V. :

$$\frac{dL(\theta)}{d\theta} \Big|_{\theta=\hat{\theta}} = 0$$

### Remarque

Si  $\hat{\theta}$  correspond au maximum de  $L(\theta)$ , il correspond aussi au maximum de  $L^*(\theta) = \log(L(\theta))$  obtenu en résolvant l'équation:

$$\frac{d \log(L(\theta))}{d\theta} \Big|_{\theta=\hat{\theta}} = 0$$

## Exemple 1

- **Population** :régie par une loi normale  
 $X \sim \mathcal{N}(\mu, 1)$ , où  $\mu \in \mathbb{R}$
- **Échantillon aléatoire**:  $\{X_1, X_2, \dots, X_n\}$
- **Loi de  $X_i$**

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2}} \quad x \in \mathbb{R}$$

- **Fonction de vraisemblance**:

$$\begin{aligned} L(\mu) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} e^{-\frac{(x_i-\mu)^2}{2}} \\ &= \frac{1}{(2\pi)^{n/2}} e^{-\frac{1}{2} \sum_{i=1}^n (x_i - \mu)^2} \end{aligned}$$

## Exemple 1 (suite)

- Fonction de log-vraisemblance:

$$L^*(\mu) = -\frac{n}{2} \log(2\pi) - \frac{1}{2} \sum_i (x_i - \mu)^2$$

- Équation du M. V. :  $\frac{d \log(L(\mu))}{d\mu} \Big|_{\mu=\hat{\mu}} = 0$

$$\sum_i (x_i - \hat{\mu}) = 0 \Leftrightarrow \sum_i x_i - n\hat{\mu} = 0$$

$\Rightarrow$  Estimateur du M. V. :  $\hat{\mu} = \frac{1}{n} \sum_i X_i = \bar{X}$

**N. B.** Maximum car  $\frac{d^2 L^*(\mu)}{d\mu^2} = -n < 0$

## Exemple 2

- **Population:** régie par une loi uniforme

$$X \sim \mathcal{U}_{[0, \theta]}, \text{ où } 0 < \theta < +\infty$$

- **Loi de  $X_j$  :**

$$f(x) = \begin{cases} \frac{1}{\theta} & 0 \leq x < \theta \\ 0, & \text{ailleurs} \end{cases}$$

- **Fonction de vraisemblance:**

$$L(x_1, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i) = \begin{cases} \frac{1}{\theta^n} & \text{si tous les } x_i \in [0, \theta] \\ 0, & \text{ailleurs} \end{cases}$$

- **Équation du M. V. :**  $\frac{dL(\theta)}{d\theta} = \frac{-n}{\theta^{n+1}} < 0$

$\Rightarrow$  La plus grande valeur de  $L(\theta)$  est donnée par la plus petite valeur possible de  $\theta$ ; comme  $\theta \geq x_i, \forall i = 1, \dots, n$ , l'estimateur du M. V. est

$$\hat{\theta} = X_{(n)} = \max_i X_i$$

## Existence et unicité de l'estimateur du M. V.

### Propriété

Un estimateur MV n'existe pas toujours, n'as pas nécessairement une forme explicite et n'est pas nécessairement unique

## Estimateur sans biais

### Définition

$\hat{\theta}$  est un estimateur sans biais de  $\theta$  si

$$E[\hat{\theta}] = \theta \quad \forall \theta \in \Theta$$

- **Exemple:**  $\hat{\mu} = \bar{X}$  comme estimateur de  $\mu$  la moyenne de  $X$ :  
 $E(\hat{\mu}) = E(\bar{X}) = \mu$

- **Biais d'un estimateur:**

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

- **Estimateur asymptotiquement sans biais:** Estimateur  $\hat{\theta}_n$  de  $\theta$  tel que

$$\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta$$

## Mesure de précision d'un estimateur: MSE

### Définition

Erreur quadratique moyenne [Mean Squared Error (MSE)] d'un estimateur  $\hat{\theta}$  d'un paramètre  $\theta$  est:

$$\text{MSE}(\hat{\theta}) = E [(\hat{\theta} - \theta)^2]$$

#### ● MSE=Biais et variance:

$$\begin{aligned} \text{MSE}(\hat{\theta}) &= E [(\hat{\theta} - \theta)^2] = E [(\hat{\theta} - E(\hat{\theta}) + E(\hat{\theta}) - \theta)^2] \\ &= E [(\hat{\theta} - E(\hat{\theta}))^2] + [E(\hat{\theta}) - \theta]^2 \\ &\quad - 2 [E(\hat{\theta}) - \theta] \underbrace{E [(\hat{\theta} - E(\hat{\theta}))]}_0 \\ &= V(\hat{\theta}) + B^2(\hat{\theta}) \end{aligned}$$

## MSE (suite)

- Cas d'un estimateur sans biais:

$$\text{MSE}(\hat{\theta}) = V(\hat{\theta})$$

- Mesure de précision d'un estimateur:

$$\frac{1}{\text{MSE}(\hat{\theta})}$$

## Efficacité relative

- **Efficacité relative:** Si  $\hat{\theta}_1$  et  $\hat{\theta}_2$  sont des estimateurs quelconque de  $\theta$ , l'efficacité relative de  $\hat{\theta}_1$  par rapport à  $\hat{\theta}_2$  est définie par

$$E_r(\hat{\theta}_1, \hat{\theta}_2) = \frac{\text{MSE}(\hat{\theta}_2)}{\text{MSE}(\hat{\theta}_1)}$$

- $\hat{\theta}_1$  est plus efficace que  $\hat{\theta}_2$  si

$$E_r(\hat{\theta}_1, \hat{\theta}_2) \geq 1$$

- **Exemple:** (estimateurs d'une moyenne  $\mu$ )

$$\left. \begin{array}{l} \hat{\mu}_1 = \bar{X} \quad : \quad \text{MSE}(\bar{X}) = \frac{\sigma^2}{n} \\ \hat{\mu}_2 = X_1 \quad : \quad \text{MSE}(X_1) = \sigma^2 \end{array} \right\} \Rightarrow E_r(\hat{\mu}_1, \hat{\mu}_2) = n$$

$\bar{X}$  est plus efficace que  $X_1$

## Efficacité absolue

- **Objectif poursuivi:** Rechercher un estimateur sans biais  $\hat{\theta}^*$  d'un paramètre  $\theta$  tel que

$$V(\hat{\theta}^*) \leq V(\hat{\theta})$$

pour tout  $\hat{\theta}$  estimateur sans biais de  $\theta$

⇒ Recherche d'un estimateur sans biais de variance minimum (SBVM)

- **Borne de Cramer-Rao:** On suppose remplies certaines conditions de régularités de la fonction  $L(\theta)$  alors :

$$V(\hat{\theta}) \geq \frac{1}{E \left[ \left( \frac{d \log L(\theta)}{d\theta} \right)^2 \right]}$$

## Efficacité absolue (suite)

- **Information de Fisher:**

$$I_n(\theta) = E \left[ \left( \frac{d \log L(\theta)}{d\theta} \right)^2 \right]$$

- **Estimateur efficace (SBVM):** Si  $\hat{\theta}^*$  est un estimateur sans biais de  $\theta$ , il est efficace si

$$V(\hat{\theta}^*) = \frac{1}{I_n(\theta)}$$

- **N. B.**

$$I_n(\theta) = E \left( \frac{-d^2 \log L(\theta)}{d\theta^2} \right)$$

## Exemple 1

- **Population** : régie par une loi normale  
 $X \sim \mathcal{N}(\mu, 1)$ , où  $\mu \in \mathbb{R}$  et  $\hat{\mu} = \bar{X}$
- **Échantillon aléatoire**:  $\{X_1, X_2, \dots, X_n\}$
- Fonction de log-vraisemblance:

$$L^*(\mu) = -\frac{n}{2} \log(2\pi) - \frac{1}{2} \sum_i (x_i - \mu)^2$$

- $\frac{d \log(L(\mu))}{d\mu} = \sum_i (x_i - \mu)$

## Exemple 1 (suite)

- L'information de Fisher :

$$\begin{aligned} I_n(\mu) &= E \left[ \left( \frac{d \log L(\mu)}{d\mu} \right)^2 \right] = E \left[ \left( \sum_i (x_i - \mu) \right)^2 \right] \\ &= \sum_i E (x_i - \mu)^2 \text{ car } X_i \text{ indépendants} \\ &= \sum_i \underbrace{E [(x_i - \mu)^2]}_{\sigma^2=1} = n \end{aligned}$$

- Or  $V(\hat{\mu}) = \sigma^2/n = 1/n = 1/I_n(\mu) \Rightarrow$  cet estimateur est SBVM (efficace)

## Estimateur convergent

### Définition

Soit  $\hat{\theta}_n$  un estimateur de  $\theta$ , il est convergent si

$$\lim_{n \rightarrow +\infty} P\left(|\hat{\theta}_n - \theta| < \varepsilon\right) = 1$$

Notation:  $\hat{\theta}_n \xrightarrow{P} \theta$

### Propriété : CS de convergence

Si  $\hat{\theta}_n$  est un estimateur de  $\theta$  tel que

$$\lim_{n \rightarrow +\infty} E(\hat{\theta}) = \theta \text{ et } \lim_{n \rightarrow +\infty} V(\hat{\theta}) = 0$$

alors :  $\hat{\theta}_n \xrightarrow{P} \theta$

## Exemple

- $X \sim \mathcal{N}(\mu, \sigma^2)$
- Échantillon :  $\{X_1, X_2, \dots, X_n\}$
- $\hat{\mu} = \bar{X}$
- $E(\hat{\mu}) = \mu$
- $V(\hat{\mu}) = \sigma^2/n \xrightarrow{n} 0$

$$\Rightarrow \bar{X} \xrightarrow{P} \mu$$

## Exercice

Soit l'estimateur  $s^2$  de la variance  $\sigma^2$  défini par:

$$s^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

- 1 Montrer que l'estimateur  $s^2$  est biaisé, mais asymptotiquement sans biais
- 2 Montrer qu'un estimateur sans biais et convergent de  $\sigma^2$  est:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

## Intervalle de confiance

- **Objectif:** Rechercher un intervalle  $\hat{\Theta} \subset \Theta$  tel que la probabilité  $P(\theta \in \hat{\Theta})$  soit fixé a priori à un niveau 'élevé'
- **Niveau de confiance:**
  - Soit un seuil d'incertitude  $\alpha \in ]0, 1[$ , alors

$$P(\theta \notin \hat{\Theta}) = \alpha \Leftrightarrow P(\theta \in \hat{\Theta}) = 1 - \alpha$$

$\Rightarrow 1 - \alpha =$  niveau de confiance

- Niveaux de confiance usuels: 0.90; 0.95 ; 0.99
- **Intervalle de confiance:** Soit un paramètre  $\theta \in \Theta \subset \mathbb{R}$ . On désire construire un intervalle  $(\ell_1, \ell_2)$  tel que

$$P(\ell_1 \leq \theta \leq \ell_2) = 1 - \alpha$$

où  $1 - \alpha$  est un niveau de confiance choisi a priori

## Intervalle de confiance

### Remarques

- $l_1$  et  $l_2$  sont des variables aléatoires
- L'intervalle peut être bilatéral ou unilatéral
  - Cas bilatéral : on impose que

$$P(\theta < l_1) = \alpha/2 \text{ et } P(l_2 < \theta) = \alpha/2$$

- Cas unilatéral :

$$l_2 = +\infty \text{ et } P(l_1 > \theta) = \alpha$$

$$l_1 = -\infty \text{ et } P(l_2 < \theta) = \alpha$$

## Intervalle de confiance pour la moyenne: Cas des petits échantillons

- Soit  $X \sim \mathcal{N}(\mu, \sigma^2)$  où  $\mu \in \mathbb{R}$  et  $\sigma^2 \in \mathbb{R}^{*+}$
- Échantillon :  $\{X_1, X_2, \dots, X_n\}$ , où la taille  $n < 30$
- Estimateur de  $\mu$  :  $\hat{\mu} = \bar{X}$
- Loi de  $\hat{\mu}$ :  $\bar{X} \sim \mathcal{N}(\mu, \sigma^2/n)$
- Loi centrée réduite :

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

- La distribution dépend de  $\sigma$ , on distingue alors deux cas selon  $\sigma$  connu ou inconnue

## I. C. pour moyenne: Cas des petits échantillons avec $\sigma$ connu

Construction un intervalle de confiance de  $\mu$  au degré de confiance  $(1 - \alpha)$ :  $IC_{1-\alpha}(\mu)$

- **Rappel:** si  $Z \sim \mathcal{N}(0, 1)$  alors

$$P(Z \leq z_{1-\alpha/2}) = 1 - \frac{\alpha}{2}$$

Il en résulte que

$$P(-z_{1-\alpha/2} \leq Z \leq z_{1-\alpha/2}) = 1 - \alpha$$

**N. B.**  $-z_{1-\alpha/2} = z_{\alpha/2}$

## I. C. pour moyenne: Cas des petits échantillons avec $\sigma$ connu

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

$$\Rightarrow P(-z_{1-\alpha/2} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq z_{1-\alpha/2}) = 1 - \alpha$$

$$\Leftrightarrow P(-z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \bar{X} - \mu \leq z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$$

$$\Leftrightarrow P(-\bar{X} - z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} \leq -\mu \leq -\bar{X} + z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$$

$$\Leftrightarrow P(\underbrace{\bar{X} - z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}}_{\ell_1} \leq \mu \leq \underbrace{\bar{X} + z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}}_{\ell_2}) = 1 - \alpha$$

$$\Rightarrow IC_{1-\alpha}(\mu) = \left[ \bar{X} - z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} \right]$$

## I. C. pour moyenne: Cas des petits échantillons avec $\sigma$ inconnu

- Puisque  $\sigma^2$  est inconnu, il faut l'estimer par  $\hat{\sigma}^2$
- Soit la variance empirique :

$$s^2 = \frac{1}{n} \sum_i (X_i - \bar{X})^2$$

On montre que  $E(s^2) = \frac{n-1}{n} \sigma^2 \neq \sigma^2$ , le  $s^2$  est biaisé

- Ajustons le afin d'éliminer le biais, soit

$$\begin{aligned} S^2 &= \frac{n}{n-1} s^2 \\ &= \frac{1}{n-1} \sum_i (X_i - \bar{X})^2 \end{aligned}$$

Il est clair que  $E(S^2) = \frac{n}{n-1} E(s^2) = \sigma^2$ , le  $S^2$  est sans biais

- Remplaçons donc  $\sigma/\sqrt{n}$  par  $S/\sqrt{n}$  ou par  $s/\sqrt{n-1}$

## I. C. pour moyenne: Cas des petits échantillons avec $\sigma$ inconnu

La substitution de  $\sigma$  change la loi de la statistique:  $\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{n-1}$

$$\Rightarrow P(-t_{1-\alpha/2} \leq \frac{\bar{X} - \mu}{S/\sqrt{n}} \leq t_{1-\alpha/2}) = 1 - \alpha$$

$$\Leftrightarrow P(-t_{1-\alpha/2} \frac{S}{\sqrt{n}} \leq \bar{X} - \mu \leq t_{1-\alpha/2} \frac{S}{\sqrt{n}}) = 1 - \alpha$$

$$\Leftrightarrow P(-\bar{X} - t_{1-\alpha/2} \frac{S}{\sqrt{n}} \leq -\mu \leq -\bar{X} + t_{1-\alpha/2} \frac{S}{\sqrt{n}}) = 1 - \alpha$$

$$\Leftrightarrow P(\underbrace{\bar{X} - t_{1-\alpha/2} \frac{S}{\sqrt{n}}}_{\ell_1} \leq \mu \leq \underbrace{\bar{X} + t_{1-\alpha/2} \frac{S}{\sqrt{n}}}_{\ell_2}) = 1 - \alpha$$

$$\Rightarrow IC_{1-\alpha}(\mu) = \left[ \bar{X} - t_{1-\alpha/2; n-1} \frac{S}{\sqrt{n}}, \bar{X} + t_{1-\alpha/2; n-1} \frac{S}{\sqrt{n}} \right]$$

## Exercice

- **Énoncé:** Un échantillon de taille 17, provenant d'une population normale, a les caractéristiques suivantes :  $\bar{x} = 4.7$  et  $S^2 = 5.76$ . Déterminons un I.C de  $\mu$  au niveau de confiance 95%
- **Solution:** Il s'agit du cas des petit échantillon, avec  $\sigma$  inconnu, ainsi

$$\begin{aligned} IC_{1-\alpha}(\mu) &= \left[ \bar{x} \pm t_{1-\alpha/2} \frac{S}{\sqrt{n}} \right] \\ &= \left[ 4.7 \pm t_{0.975;16} \frac{\sqrt{5.76}}{\sqrt{17}} \right] \\ &= [3.47, 5.93] \quad (t_{0.975;16} = 2.12) \end{aligned}$$

## Intervalle de confiance pour la moyenne: Cas des grands échantillons

- Soit  $X \sim \mathcal{L}(\mu, \sigma^2)$  où  $\mu \in \mathbb{R}$  et  $\sigma^2 \in \mathbb{R}^{*+}$
- Échantillon :  $\{X_1, X_2, \dots, X_n\}$ , où la taille  $n \geq 30$
- Estimateur de  $\mu$  :  $\hat{\mu} = \bar{X}$
- Loi de  $\hat{\mu}$  (TCL):  $\bar{X} \approx \mathcal{N}(\mu, \sigma^2/n)$
- Loi centrée réduite :

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

## I. C. pour moyenne: Cas des grands échantillons (suite)

- **Cas  $\sigma$  connu:** Comme  $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \approx \mathcal{N}(0, 1)$  alors

$$IC_{1-\alpha}(\mu) = \left[ \bar{X} - z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} \right]$$

- **Cas  $\sigma$  inconnu:** puisque  $S^2$  est sans biais et convergeant vers  $\sigma^2$  alors

$$IC_{1-\alpha}(\mu) = \left[ \bar{X} - z_{1-\alpha/2} \frac{S}{\sqrt{n}}, \bar{X} + z_{1-\alpha/2} \frac{S}{\sqrt{n}} \right]$$

## Intervalle de confiance pour la variance: Cas des petits échantillons

- Soit  $X \sim \mathcal{N}(\mu, \sigma^2)$  où  $\mu \in \mathbb{R}$  et  $\sigma^2 \in \mathbb{R}^{*+}$
- Échantillon :  $\{X_1, X_2, \dots, X_n\}$ , où la taille  $n < 30$
- Le choix de l'estimateur de  $\sigma^2$  diffère selon que  $\mu$  soit connu ou inconnu

## I. C. pour la variance : Cas des petits échantillons avec $\mu$ connu

- Estimateur de  $\sigma^2$  :

$$\hat{\sigma}^2 = \frac{1}{n} \sum_i (X_i - \mu)^2$$

- Loi de  $\hat{\sigma}^2$ :

$$\begin{aligned} \frac{n\hat{\sigma}^2}{\sigma^2} &= \sum_i \left( \frac{X_i - \mu}{\sigma} \right)^2 \\ &= \sum_{i=1}^n Z_i^2 \sim \chi_n^2 \quad (\sum \text{ v.a normales standards indépendantes}) \end{aligned}$$

## I. C. pour la variance : Cas des petits échantillons avec $\mu$ connu

- **Rappel:** si  $Y \sim \chi_n^2$  alors

$$P(Y \leq \chi_{n;\alpha/2}^2) = \alpha/2$$

$$P(Y \geq \chi_{n;1-\alpha/2}^2) = \alpha/2$$

Il en résulte que

$$P\left(\chi_{n;\alpha/2}^2 \leq Y \leq \chi_{n;1-\alpha/2}^2\right) = 1 - \alpha$$

## I. C. pour moyenne: Cas des petits échantillons avec $\mu$ connu

Construction un intervalle de confiance de  $\sigma^2$  au degré de confiance  $(1 - \alpha)$ :

$$\begin{aligned}
 P\left(\chi_{n;\alpha/2}^2 \leq \frac{n\hat{\sigma}^2}{\sigma^2} \leq \chi_{n;1-\alpha/2}^2\right) &= 1 - \alpha \\
 \Leftrightarrow P\left(\underbrace{\frac{n\hat{\sigma}^2}{\chi_{n;1-\alpha/2}^2}}_{l_1} \leq \sigma^2 \leq \underbrace{\frac{n\hat{\sigma}^2}{\chi_{n;\alpha/2}^2}}_{l_2}\right) &= 1 - \alpha \\
 \Rightarrow IC_{1-\alpha}(\sigma^2) &= \left[ \frac{n\hat{\sigma}^2}{\chi_{n;1-\alpha/2}^2}, \frac{n\hat{\sigma}^2}{\chi_{n;\alpha/2}^2} \right]
 \end{aligned}$$

## I. C. pour moyenne: Cas des petits échantillons avec $\mu$ inconnu

- Estimateur de  $\sigma^2$  :

$$\hat{\sigma}^2 = S^2 = \frac{1}{n-1} \sum_i (X_i - \bar{X})^2$$

- Loi de  $S^2$ :

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

- L'intervalle de confiance

$$IC_{1-\alpha}(\sigma^2) = \left[ \frac{(n-1)S^2}{\chi_{n-1;1-\alpha/2}^2}, \frac{(n-1)S^2}{\chi_{n-1;\alpha/2}^2} \right]$$

## IC pour la variance : Cas des grands échantillons $n \geq 50$

- Soit  $X \sim \mathcal{L}(\mu, \sigma^2)$  où  $\mu \in \mathbb{R}$  et  $\sigma^2 \in \mathbb{R}^{*+}$  ;  $n \geq 50$
- Estimateur de  $\mu$  :  $\hat{\sigma}^2 = S^2$
- Loi centrée réduite (TCL):

$$\frac{S^2 - \sigma^2}{\sqrt{(\hat{\mu}_4 - S^4)/n}} \approx \mathcal{N}(0, 1)$$

avec

$$\hat{\mu}_4 = \frac{1}{n} \sum_i (X_i - \bar{X})^4$$

- L'intervalle de confiance :

$$IC_{1-\alpha}(\sigma^2) = \left[ S^2 - z_{1-\alpha/2} \sqrt{(\hat{\mu}_4 - S^4)/n}, S^2 + z_{1-\alpha/2} \sqrt{(\hat{\mu}_4 - S^4)/n} \right]$$

**N. B** Puisque  $n$  est assez grand on a  $S^2 \simeq s^2 \simeq \sigma^2$  et  $\hat{\mu}_4 \simeq \mu_4$

## Exercice

**Énoncé:** Une assurance s'intéresse à la distance moyenne parcourue par les voitures qu'elle assure, ainsi qu'à la variance des distances parcourues. Elle a observée 900 de ces véhicules les résultats sont :  $\bar{x} = 15u$ ,  $S = 5u$  et  $\hat{\mu}_4 = 800u^4$  où  $u = 10^3$  km. Déterminez les un I.C. de  $\mu$  et  $\sigma^2$  au niveau de confiance 95%

## Intervalle de confiance pour la proportion

- Soit  $X$  une v.a. qui suit une loi de Bernoulli  $B(p)$  où  $p$  est le paramètre d'intérêt
- $p$  présente la proportion d'individus possédant une certaine modalité d'intérêt 'A'
- Soit un échantillon ESAR  $\{X_1, X_2, \dots, X_n\}$  de  $X$ 
  - $X_i = \begin{cases} 1, & \text{si } i \text{ possède la modalité A} \\ 0, & \text{sinon.} \end{cases}$
  - $n_A =$  nombre des élément de l'échantillon possédant la modalité A

$$n_A = \sum_{i=1}^n X_i$$

- $n_A \sim \mathcal{B}(n, p)$

$$\implies E(n_A) = np ; V(n_A) = np(1 - p)$$

## Intervalle de confiance pour la proportion (suite)

- Estimation de  $p$ :

$$\hat{p} = \frac{n_A}{n} = \bar{X} := \bar{p}$$

$$\implies E(\bar{p}) = p ; \quad V(\bar{p}) = \frac{p(1-p)}{n}$$

**N. B.**  $\bar{p}$  est la solution unique de l'équation M.V. et il est SBMV (efficace)

- Loi de  $\bar{p}$ :

- Loi exacte :  $n\bar{p} \sim \mathcal{B}(n, p)$
- Loi asymptotique ( $n \geq 30$ )

$$\frac{\bar{p} - p}{\sqrt{\frac{p(1-p)}{n}}} \approx \mathcal{N}(0, 1)$$

**N. B.** Loi valable si  $np(1-p) \geq 10$  ou

$$n \geq 20, \quad np \geq 10, \quad n(1-p) \geq 10$$

## I. C. pour proportion: Cas des grands échantillons

- Construction de  $I.C_{1-\alpha}$  pour  $p$ , Comme

$$\frac{\bar{p} - p}{\sqrt{\frac{p(1-p)}{n}}} \approx \mathcal{N}(0, 1)$$

$$\Rightarrow P\left(-z_{1-\alpha/2} \leq \frac{\bar{p} - p}{\sqrt{\frac{p(1-p)}{n}}} \leq z_{1-\alpha/2}\right) = 1 - \alpha$$

$$\Leftrightarrow P\left(\underbrace{\bar{p} - z_{1-\alpha/2}\sqrt{\frac{p(1-p)}{n}}}_{\ell_1} \leq p \leq \underbrace{\bar{p} + z_{1-\alpha/2}\sqrt{\frac{p(1-p)}{n}}}_{\ell_2}\right) = 1 - \alpha$$

## I. C. pour proportion: Cas des grands échantillons (suite)

- Valeurs approchées de  $l_1$  et  $l_2$  :

$$l_1 \simeq l_1^* = \bar{p} - z_{1-\alpha/2} \sqrt{\frac{\bar{p}(1-\bar{p})}{n}}$$

$$l_2 \simeq l_1^* = \bar{p} + z_{1-\alpha/2} \sqrt{\frac{\bar{p}(1-\bar{p})}{n}}$$

- L'intervalle de confiance pour  $p$  de confiance  $I.C_{1-\alpha}$  pour  $p$

$$\Rightarrow IC_{1-\alpha}(p) = \left[ \bar{p} - z_{1-\alpha/2} \sqrt{\frac{\bar{p}(1-\bar{p})}{n}}, \bar{p} + z_{1-\alpha/2} \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} \right]$$

## Précision d'une estimation par intervalle de confiance

### 1. Incertitude absolue $l_a$

- C'est le rayon (demi longueur) de l'intervalle de confiance bilatérale  $(l_1, l_2)$  :

$$l_a = \frac{l_2 - l_1}{2} = \text{Rayon de I.C.}$$

- **Exemple:** pour l'estimation de la moyenne  $\mu$  de  $X \sim \mathcal{N}(\mu, \sigma^2)$

$$l_a = z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}$$

## Précision d'une estimation par intervalle de confiance (suite)

### 2. Incertitude relative $I_r$

- Elle est obtenue en divisant l'incertitude relative par l'estimation du paramètre

$$I_r = \frac{I_a}{\hat{\theta}} = \frac{\ell_2 - \ell_1}{\ell_2 + \ell_1}$$

- **Exemple:** pour l'estimation de la moyenne  $\mu$  de  $X \sim \mathcal{N}(\mu, \sigma^2)$

$$I_r = \frac{z_{1-\alpha/2} \sigma / \sqrt{n}}{\bar{X}}$$

### Remarque

L'incertitude est proportionnelle à l'écart-type-population  $\sigma$  et à au degré de confiance  $1 - \alpha$  et inversement proportionnelle à la racine de la taille échantillon  $n$

## Taille d'un échantillon aléatoire

- **Problème:** Comment déterminer la taille  $n$  en fonction d'une incertitude maximale souhaitée?

- **Exemples:**

- Estimation d'une moyenne: Si on veut que  $I_a \leq \Delta\mu$  il faut que

$$z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \Delta\mu \Leftrightarrow n \geq (z_{1-\alpha/2} \sigma / \Delta\mu)^2$$

- Estimation d'une proportion: Si on veut que  $I_a \leq \Delta p$  il faut que

$$z_{1-\alpha/2} \sqrt{\frac{p(1-p)}{n}} \leq \Delta p$$

$$\Leftrightarrow n \geq \frac{z_{1-\alpha/2}^2 p(1-p)}{(\Delta p)^2}$$

Comme  $p(1-p) \leq \frac{1}{4}$ , il suffit de choisir

$$n \geq (z_{1-\alpha/2} / 2\Delta p)^2$$

## Exercice

Un comptable pense que les problèmes de liquidité d'une entreprise sont une conséquence directe de l'encaissement lent des comptes fournisseurs. Le comptable prétend qu'au moins 70% des comptes fournisseurs datent de plus de deux mois. Un échantillon de 120 comptes fournisseurs a révélé que 88 dataient de plus de deux mois

- 1 Quelle est l'estimation ponctuelle de la proportion  $p$  de comptes fournisseurs datant de plus de deux mois
- 2 Donnez un intervalle de confiance à 99% pour la vraie proportion  $p$  de comptes fournisseurs datant de plus de deux mois
- 3 Déterminez la taille minimum  $n$  de l'échantillon à prélevé pour que l'incertitude absolue de l'estimation (au niveau de confiance 99%) soit inférieur à 0.03.

## Solution

1. L'estimation ponctuelle de la proportion  $p$  de comptes fournisseurs ... est  $\hat{p}$  la proportion de comptes fournisseurs ... dans l'échantillon :

$$\bar{p} = 88/120 = 0.73.$$

2. Puisque  $n = 120 \gg 30$ , on est dans le cas d'un grand échantillon :

$$\frac{\bar{p} - p}{\sqrt{\frac{\bar{p}(1-\bar{p})}{n}}} \approx N(0, 1)$$

$$\Rightarrow P[-z_{1-\alpha/2} \leq \frac{\bar{p} - p}{\sqrt{\frac{\bar{p}(1-\bar{p})}{n}}} \leq z_{1-\alpha/2}] = 1 - \alpha$$

$$\Rightarrow P[\bar{p} - \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} 2.58 \leq p \leq \bar{p} + \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} 2.58] = 0.99$$

## Solution (suite)

Donc

$$\begin{aligned}
 I_{0.99}(p) &= \left[ \bar{p} - \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} 2.58; \bar{p} + \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} 2.58 \right] \\
 &= [0.73 - 2.58 * 0.04; 0.73 + 2.58 * 0.04] = [\mathbf{0.63}; \mathbf{0.84}]
 \end{aligned}$$

3. Soit  $I_a$  l'incertitude absolue (le rayon de l'intervalle de confiance).

$$\begin{aligned}
 I_a &\leq 0.03 \\
 \sqrt{\frac{p(1-p)}{n}} z_{1-\alpha/2} &\leq 0.03 \\
 n &\geq \frac{z_{1-\alpha/2}^2}{4 * (0.03)^2} \quad \text{car } p(1-p) \leq 1/4, \forall p \\
 n &\geq \mathbf{1849}.
 \end{aligned}$$