

# Estimation

## Intervalle de Confiance

Pr Roch Giorgi

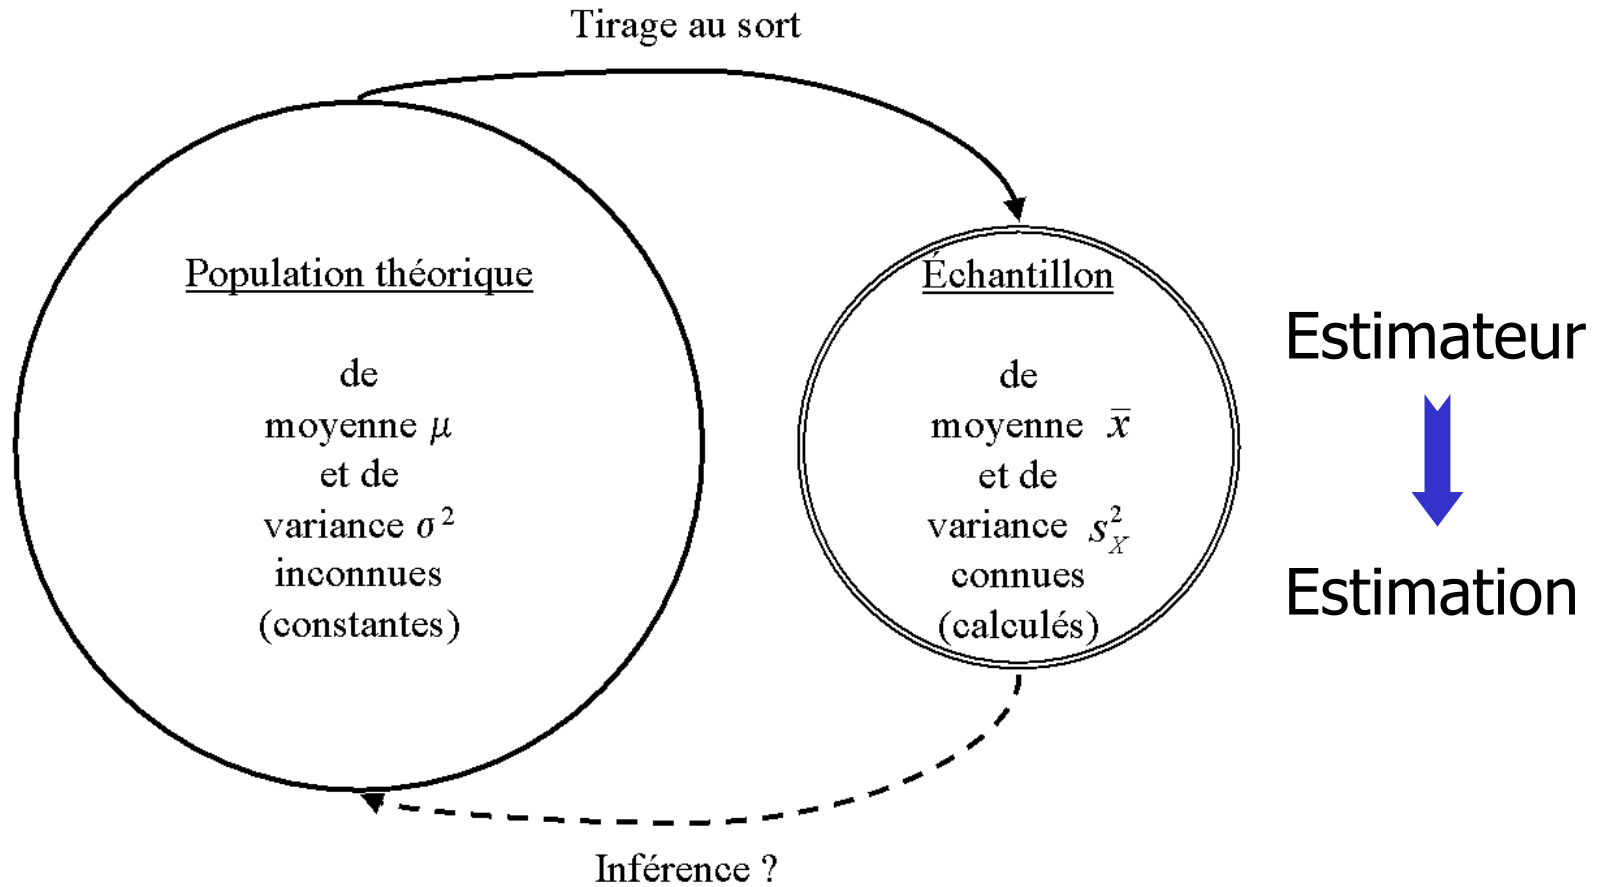
 [roch.giorgi@univ-amu.fr](mailto:roch.giorgi@univ-amu.fr)

# Introduction

---


- Connaître des valeurs de certaines grandeurs grâce à des observations réalisées sur un échantillon
  - ✓ Fréquence de la survenue du mélanome malin ?
  - ✓ Fréquence des infections nosocomiales ?
  - ✓ Valeur de la glycémie d'un patient ?
  - ✓ Variance de la glycémie mesurée chez ce patient ?
- ▶ Valeur la plus vraisemblable : **estimation ponctuelle**
- ▶ Intervalle de valeurs possibles, compatibles avec les observations : **intervalle de confiance**

# Estimateur - Estimation



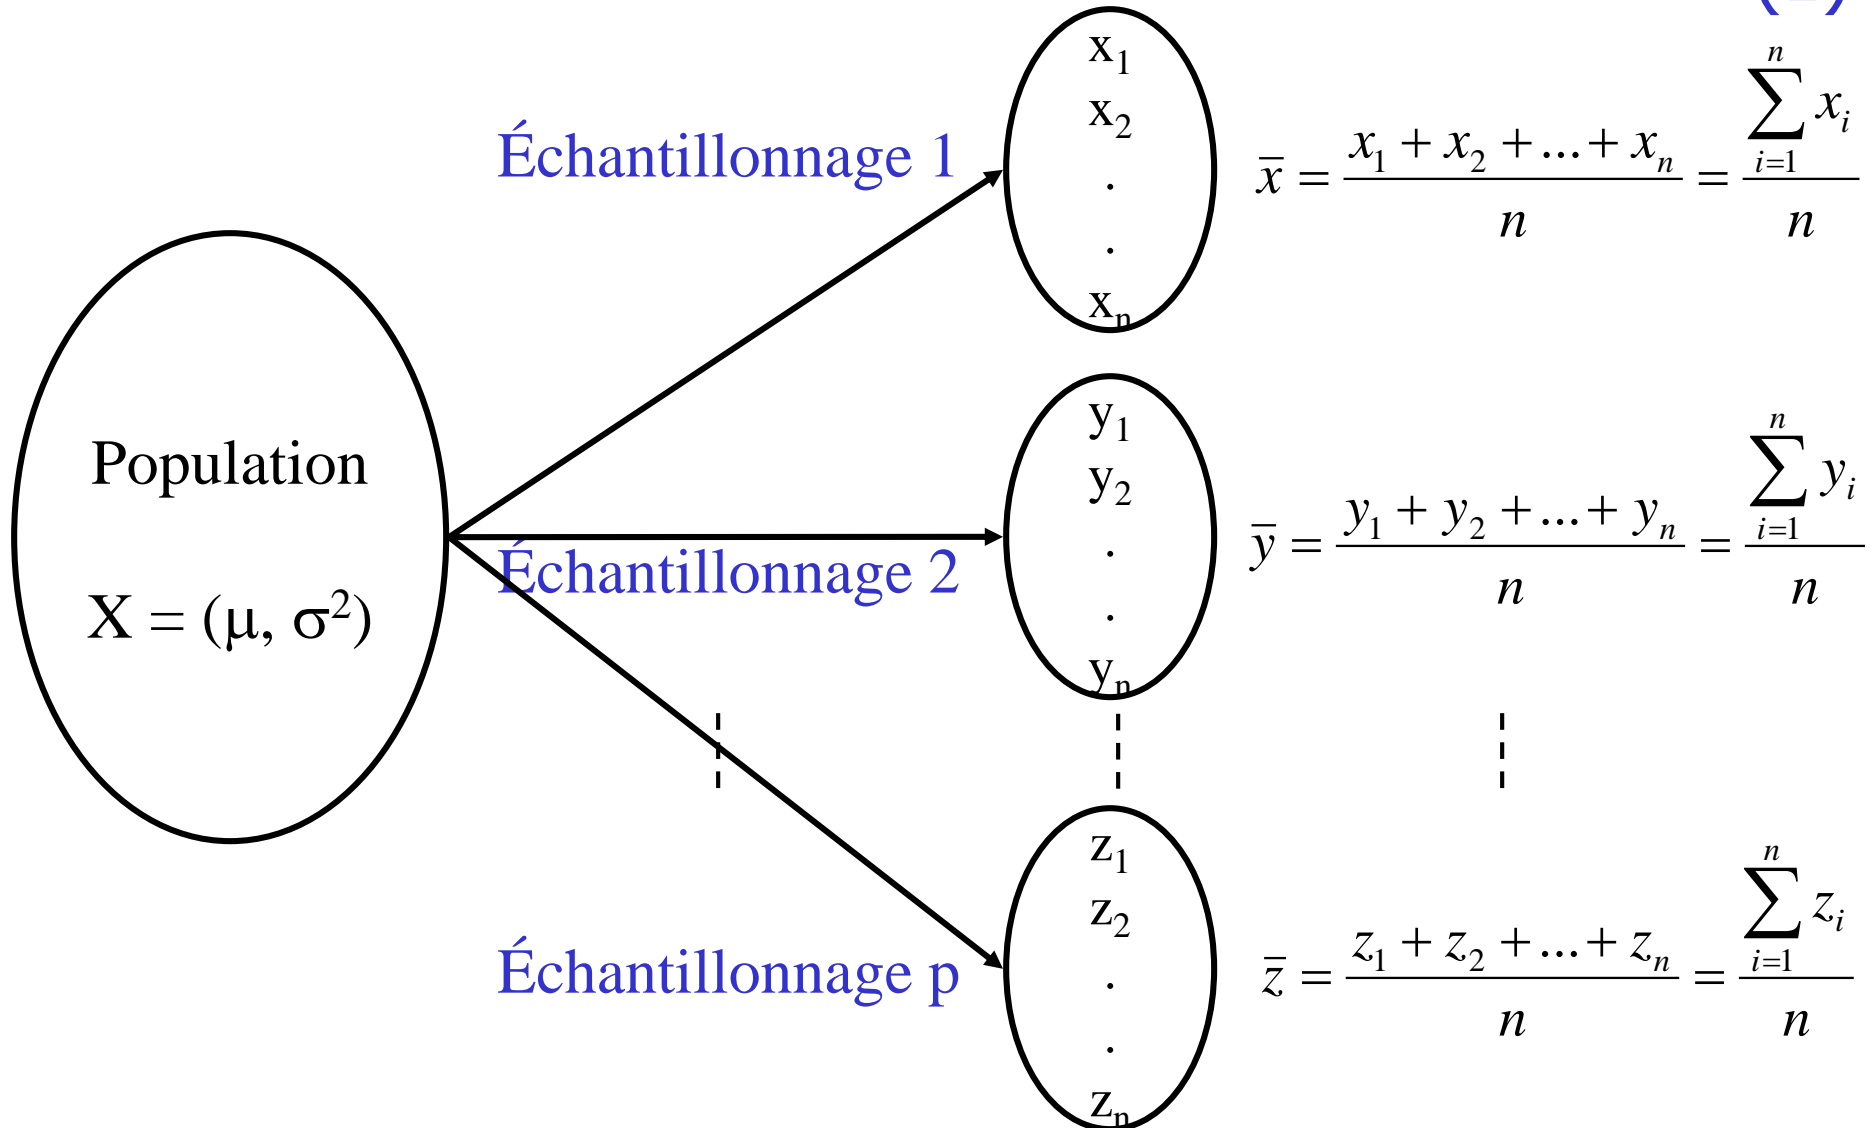
# Qualité d'un Estimateur

- $U$  : estimateur sans biais de  $\theta$  si  $E(U) = \theta$
- $U$  : estimateur biaisé de  $\theta$  si  $E(U) \neq \theta$  et le biais =  $E(U) - \theta$



# Estimation de la Moyenne d'une Population

(1)



# Estimation de la Moyenne d'une Population

## (2)

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n} = \frac{\sum_{i=1}^n X_i}{n}$$

$\bar{X}$  est l'estimateur de  $\mu$

C'est un estimateur sans biais car  $E(\bar{X}) = \mu$

$$E(\bar{X}) = \frac{1}{n} E(X_1 + X_2 + \dots + X_n) = \frac{1}{n} [E(X_1) + E(X_2) + \dots + E(X_n)]$$

Comme l'espérance de la moyenne arithmétique des  $n$  variables est la moyenne arithmétique des espérances

$E(\bar{X}) = \mu$  et est **sans biais**

# Estimation de la Variance d'une Population

- Soit  $x_1, x_2, \dots, x_n$  un échantillon tiré au hasard, d'effectif  $n$  et de moyenne  $\bar{x} = \sum x_i / n$
- L'estimation de la variance de la population est

$$s_x^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}$$

- $s_x^2$  est un estimateur sans biais convergent de  $\sigma^2$
- $s_x$  est une bonne estimation de l'écart-type de la population

# Estimation d'une Proportion d'une Population

- Soit  $k$  le nombre de fois où un caractère donné est présent dans un échantillon tiré au hasard d'effectif  $n$
- Soit  $p$  la proportion inconnue du caractère étudié dans la population
- Fréquence  $f$  du caractère étudié dans l'échantillon

$$f = \frac{k}{n}$$

- On montre que  $E(F) = p$



# Estimation de la Variance d'une Proportion

---

$$\text{Var}(F) = \frac{p \cdot (1 - p)}{n}$$

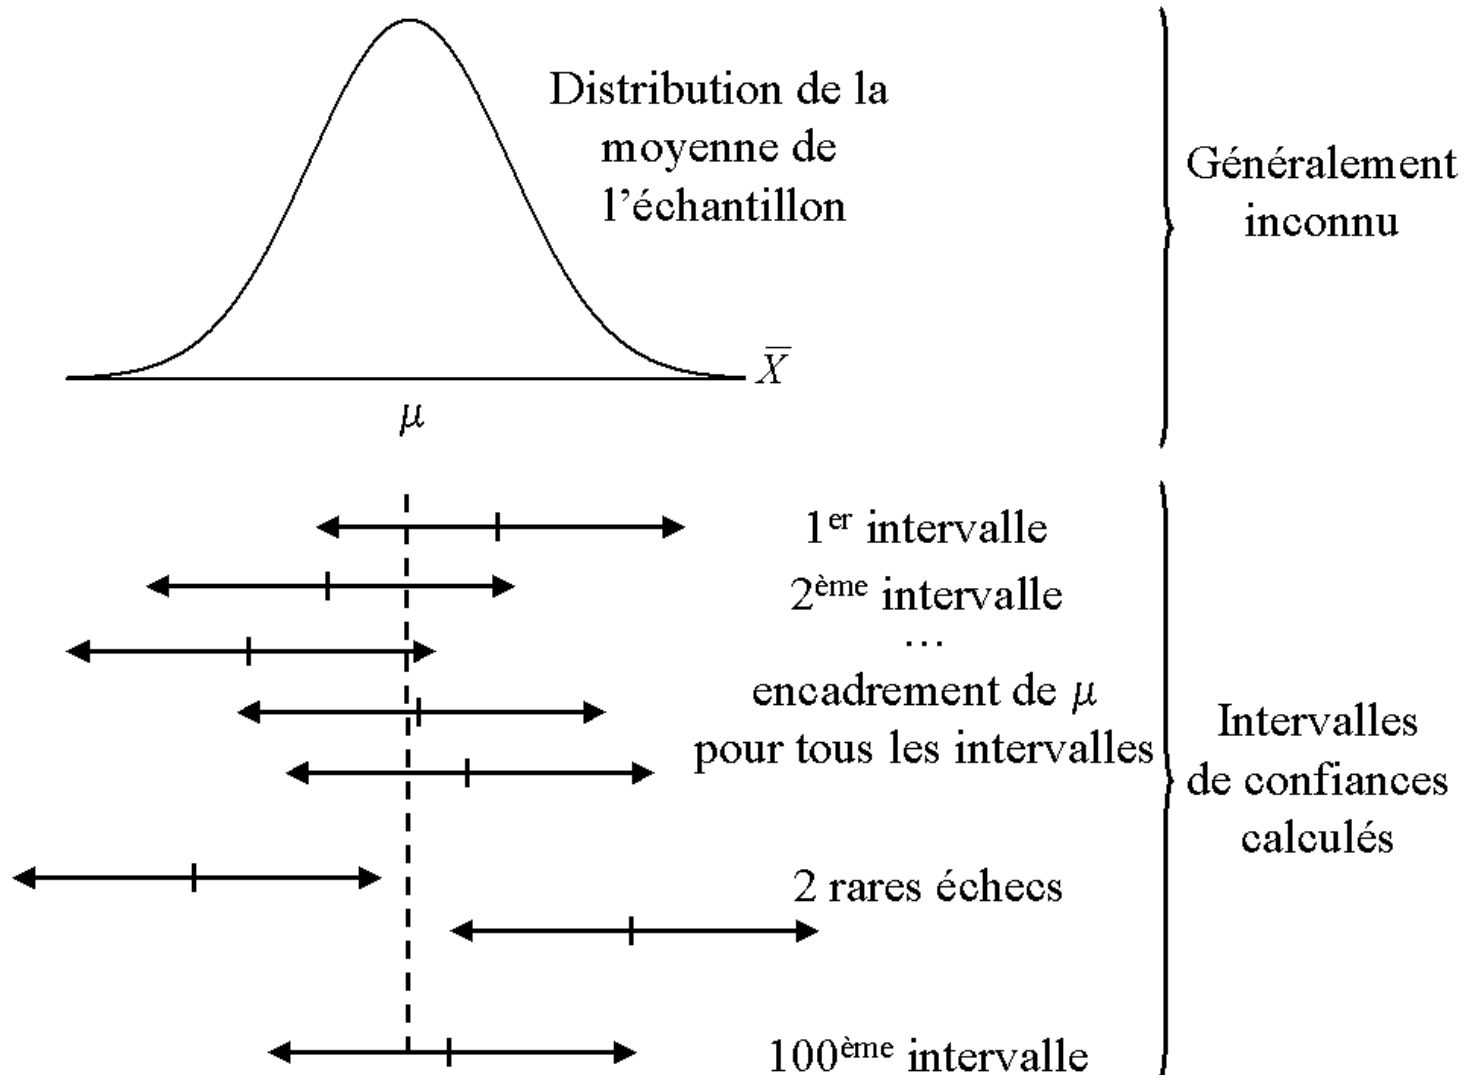
- $F$  est un estimateur convergent de  $p$
- On estime la variance  $p \cdot (1 - p)/n$  par  $f \cdot (1 - f)/n$

# Estimation par Intervalle (1)

---

- Soit  $\Sigma$  un paramètre inconnu (une moyenne ou une proportion) estimé à partir d'un échantillon au hasard par  $\theta$
- On souhaite avoir un degré de confiance acceptable comme quoi  $\theta$  approche bien  $\Sigma$
- **Intervalle de confiance** : déterminé à partir des données d'un échantillon dans lequel on peut parier, avec un risque de se tromper qui soit acceptable, que se situe réellement  $\Sigma$  dans la population

# Estimation par Intervalle (2)



# Estimation par Intervalle (3)

---

- Risque ( $\alpha$ ) généralement = 0,05 ; il correspond aux erreurs d'échantillonnages jugées acceptables
- Intervalle de confiance de  $\Sigma$  est de la forme  
 $\theta - \text{erreur d'échantillonnage}$  ;  $\theta + \text{erreur d'échantillonnage}$
- Interprétation
  - ✓ On accepte qu'il y ait  $\alpha.100$  chances sur cent de se tromper en disant que  $\Sigma$  appartient à l'intervalle
  - ✓ On accepte qu'il y ait  $(1-\alpha).100$  chances sur cent de ne pas se tromper en disant que  $\Sigma$  appartient à l'intervalle

# Intervalle de Confiance d'une Moyenne

$$\bar{x} - L_{\alpha} \cdot \frac{s_x}{\sqrt{n}} \quad ; \quad \bar{x} + L_{\alpha} \cdot \frac{s_x}{\sqrt{n}}$$

- Si  $n \geq 30$  alors,  $L_{\alpha} = N_{\alpha}$  ( $N_{\alpha=5\%} = 1,96$ )
- Si  $n < 30$  et la loi de distribution de la variable dans la population est Normale alors,  $L_{\alpha} = t_{\alpha, \nu}$

# Intervalle de Confiance d'une Proportion

- Si  $f = k/n$  n'est pas voisin de 1 ou de 0
- Si  $f \cdot n \geq 5$  et  $(1 - f) \cdot n \geq 5$

$$f - N_{\alpha} \cdot \sqrt{\frac{f \cdot (1 - f)}{n}} \quad ; \quad f + N_{\alpha} \cdot \sqrt{\frac{f \cdot (1 - f)}{n}}$$

# Estimation de la Prévalence

- Mesure du risque de maladie dans la population
- Proportion de malades présents ( $M^+$ ) dans la population ( $N$ ) à un instant donné

$$P = \frac{M^+}{N}$$

- ✓ C'est une probabilité
- ✓ Intègre la notion de durée de la maladie ( $\nearrow$  durée maladie  $\Rightarrow \nearrow$  nombre de  $M^+ \Rightarrow \nearrow$  prévalence)
- ✓ Intègre la notion de vitesse d'apparition des nouveaux  $M^+$  ( $\nearrow$  vitesse d'apparition  $\Rightarrow \nearrow$  prévalence)

# Estimation de l'Incidence

- Quantifie la production de nouveaux cas de maladie dans la population dans un certain intervalle de temps

$$I = \frac{\text{nb nouveaux cas pendant } \Delta t}{N \cdot \Delta t}$$



# Estimation de l'Effet d'un Facteur Pronostique

---

- **Risque** = probabilité d'apparition d'un événement, d'une maladie
  - ✓ Risque d'infarctus du myocarde
  - ✓ Risque de récurrence d'un cancer après rémission
- La probabilité d'apparition est-elle modifiée par la présence ou l'absence d'un **facteur (pronostique)** ?

# Risque Relatif

- Considérons le cas où la maladie (M) est présente (M+) ou absente (M-) avec un seul facteur (F) qui peut être présent (F+) ou absent (F-)
  - ✓ Risque d'apparition de la maladie chez les exposés au facteur F :  $P(M+/F+)$
  - ✓ Risque d'apparition de la maladie chez les non exposés au facteur F :  $P(M+/F-)$
- **Risque relatif** : indicateur de l'influence du facteur

$$RR = \frac{P(M+ / F+)}{P(M+ / F-)}$$

Le RR varie de 0 à l'infini

# Interprétation du Risque Relatif

- Si  $RR > 1$ 
  - ✓  $\Leftrightarrow P(M+/F+) > P(M+/F-)$
  - ✓ La présence du facteur F « favorise la maladie » =  
facteur de risque
- Si  $RR < 1$ 
  - ✓  $\Leftrightarrow P(M+/F+) < P(M+/F-)$
  - ✓ La présence du facteur F « favorise la non maladie » =  
facteur protecteur
- Si  $RR = 1$ 
  - ✓  $\Leftrightarrow P(M+/F+) = P(M+/F-)$
  - ✓ Le facteur F n'a pas d'effet sur la maladie

# Estimation du Risque Relatif (1)

	M+	M-	Total
F+	a	b	$m_1$
F-	c	d	$m_2$
Total	$n_1$	$n_2$	N

$$P(M + / F +) = a/m_1$$

$$P(M + / F -) = c/m_2$$

$$RR = \frac{a/m_1}{c/m_2}$$

# Estimation du Risque Relatif (2)

---

- Le RR peut être estimé
  - ✓ Dans les enquêtes sur un seul échantillon au hasard
  - ✓ Dans les enquêtes exposés / non exposés
- Le RR ne peut pas être estimé
  - ✓ Dans les enquêtes cas-témoins. Dans ce cas on peut estimer un Odds Ratio,  $(a.d)/(b.c)$ , qui s'interprète qualitativement comme le RR par rapport à 1
- En plus de l'estimation ponctuelle du RR il est nécessaire de calculer son intervalle de confiance