

## Statistique : Intervalles de confiance et tests

### Intervalles de confiance

Théorèmes limites

### Tests d'hypothèses

Joseph Salmon



## Statistique : Intervalles de confiance et tests

Joseph Salmon

Septembre 2014

# Plan du cours

Statistique : Intervalles de confiance et tests

Intervalles de confiance

Théorèmes limites

Tests d'hypothèses

Intervalles de confiance

Théorèmes limites

Tests d'hypothèses

Joseph Salmon



# Intervalle de confiance

Statistique : Intervalles de confiance et tests

Intervalles de confiance

Théorèmes limites

Tests d'hypothèses

Joseph Salmon



- ▶ Contexte : on a une estimation  $\hat{g}(y_1, \dots, y_n)$  d'une grandeur  $g(\theta)$ . On veut un intervalle  $\hat{I}$  autour de  $\hat{g}$  qui contient  $g$  avec une grande probabilité.
- ▶ On construit  $\hat{I} = [A, B]$  à partir des observations  $(y_1, \dots, y_n)$  : l'intervalle est une variable aléatoire

$$\mathbb{P}(\hat{I} \text{ contient } g) = \mathbb{P}(A \leq g \text{ et } B \geq g) = 95\%$$

Statistique : Intervalles de confiance et tests

## Intervalles de confiance

Théorèmes limites

## Tests d'hypothèses

### Intervalle de confiance

Un intervalle de confiance de niveau  $\alpha$  pour la grandeur  $g = g(\theta)$  est une fonction de l'échantillon

$$\hat{I} : (y_1, \dots, y_n) \mapsto \hat{I} = [A(y_1, \dots, y_n), B(y_1, \dots, y_n)]$$

telle que, quelle que soit le paramètre  $\theta \in \Theta$ ,

$$\mathbb{P} \left[ g(\theta) \in \hat{I}(y_1, \dots, y_n) \right] \geq 1 - \alpha \quad \text{lorsque } y_i \sim \mathbb{P}_\theta$$

Rem: des choix classiques sont  $\alpha = 5\%, 1\%, 0.1\%$ , etc.

Joseph Salmon



# Exemple : sondage

- ▶ Sondage d'une élection à deux candidats :  $A$  et  $B$ . Le choix du  $i$ -ème sondé suit une loi de Bernoulli de paramètre  $p$ ,  $y_i = 1$  s'il vote  $A$ , 0 sinon. Ainsi,

$$\Theta = [0, 1] \text{ et } \theta = p.$$

- ▶ but : estimer  $g(\theta) = p$ .
- ▶ échantillon de taille  $n$  : un estimateur raisonnable est alors

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n y_i = \bar{y}_n$$

intervalle de confiance pour  $p$  ?

## Statistique : Intervalles de confiance et tests

### Intervalles de confiance

Théorèmes limites

### Tests d'hypothèses

Joseph Salmon



## Sondage : intervalle de confiance

- ▶ Chercher un intervalle  $\hat{I} = [\hat{p} - \delta, \hat{p} + \delta]$  tel que  
 $\mathbb{P}(p \in \hat{I}) \geq 0.95 \Leftrightarrow$  chercher  $\delta$  tel que  
 $\mathbb{P}[|\hat{p} - p| > \delta] \leq 0.05$
- ▶ Ingrédient : inégalité de **Tchebyschev** (si  $\mathbb{E}(X^2) < +\infty$ )

$$\forall \delta > 0, \quad \mathbb{P}(|X - \mathbb{E}(X)| > \delta) \leq \frac{\text{Var}(X)}{\delta^2}$$

Pour  $X = \hat{p} = \frac{1}{n} \sum_{i=1}^n Y_i$  on a  $\mathbb{E}(\hat{p}) = p$  et  $\text{Var}(\hat{p}) = \frac{p(1-p)}{n}$  :

$$\forall p \in (0, 1), \forall \delta > 0, \quad \mathbb{P}(|\hat{p} - p| > \delta) \leq \frac{p(1-p)}{n\delta^2} \leq \frac{1}{4n\delta^2}$$

Application numérique : pour un intervalle de confiance à 95%,  
on peut choisir  $\delta$  tel que  $\frac{1}{4n\delta^2} = 0.05$ , i.e.,  $\delta = \sqrt{\frac{1}{4 \times 0.05 \times n}}$ .  
Si  $n = 1000$  et  $\hat{p} = 55\%$ , on obtient

$$\delta = 0.07 ; \quad \hat{I} = [0.48, 0.62]$$

Joseph Salmon

# Théorème central limite

- ▶  $y_1, y_2, \dots$ , des variables aléatoires *i.i.d.* de carré intégrable.
- ▶  $\mu$  et  $\sigma$  leur espérance et écart-type théoriques.

Statistique : Intervalles de confiance et tests

Intervalles de confiance

Théorèmes limites

Tests d'hypothèses

## Théorème central limite (TCL)

La loi de la moyenne empirique renormalisée

$$\sqrt{n} \left( \frac{\bar{y}_n - \mu}{\sigma} \right)$$

converge vers une loi normale centrée réduite  $\mathcal{N}(0, 1)$

- ▶ Reformulation : La moyenne empirique se comporte approximativement comme une loi normale  $\mathcal{N}(\mu, \sigma^2/n)$

Joseph Salmon



# Intervalles de confiance asymptotiques

- Exemple du sondage :  $\hat{p} = 0.55$ ,  $n = 1000$
- On suppose que  $n$  est suffisamment grand pour que

$$\sqrt{n} \frac{\frac{1}{n} \sum_{i=1}^n y_n - p}{\sqrt{p(1-p)}} \sim \mathcal{N}(0, 1) \quad \text{rappel : } p(1-p) = \text{Var}(Y)$$

- On connaît les quantiles de la loi normale (numériquement)
- D'après le TCL, et l'approximation des quantiles gaussiens

$$\mathbb{P} \left[ -1.96 < \sqrt{n} \frac{0.55 - p}{\sqrt{p(1-p)}} < 1.96 \right] \approx 0.95$$

On résout en  $p$  (équations de degré deux) :

$$\mathbb{P}[0.52 < p < 0.58] = 0.95$$

nouvel intervalle de confiance :  $\hat{I} = [0.52, 0.58]$  : meilleur !

Joseph Salmon



# Tests d'hypothèses pour le “Pile ou face”

Statistique : Intervalles de confiance et tests

Intervalles de confiance

Théorèmes limites

Tests d'hypothèses

- ▶ On veut tester une hypothèse sur le paramètre  $\theta$ .
- ▶ On l'appelle **hypothèse nulle**  $\mathcal{H}_0$   
**Exemple:** ‘la pièce est non biaisée’ :  $\mathcal{H}_0 = \{p = 0.5\}$ .  
**Exemple:** ‘la pièce est peu biaisée’,  $\mathcal{H}_0 = \{0.45 \leq p \leq 0.55\}$
- ▶ L'**hypothèse alternative**  $\mathcal{H}_1$  est (souvent) le contraire de  $\mathcal{H}_0$ .  
**Exemple:**  $\mathcal{H}_1 = \{p \neq 0.5\}$   
**Exemple:**  $\mathcal{H}_1 = \{p \notin [0.45, 0.55]\}$
- ▶ « Faire un test » : déterminer si les données permettent de **rejeter** l'hypothèse  $\mathcal{H}_0$ . On cherche une région  $R$  pour laquelle si  $(y_1, \dots, y_n) \in R$  on rejette l'hypothèse  $\mathcal{H}_0$ .  $R$  est la région de **rejet**.

Joseph Salmon



Statistique : Intervalles de confiance et tests

Intervalles de confiance

Théorèmes limites

Tests d'hypothèses

Joseph Salmon



## Présomption d'innocence en faveur de $\mathcal{H}_0$

Même si  $\mathcal{H}_0$  n'est pas rejetée par le test, on ne peut en général pas conclure que  $\mathcal{H}_0$  est vraie !

Rejeter  $\mathcal{H}_1$  est souvent impossible car  $\mathcal{H}_1$  est trop générale.  
e.g.,  $\{p \in [0, 0.5] \cup [0.5, 1]\}$  ne peut pas être rejetée !

- ▶  $\mathcal{H}_0$  s'écrit sous la forme  $\{\theta \in \Theta_0\}$ , avec  $\Theta_0 \subset \Theta$
- ▶  $\mathcal{H}_1$  s'écrit sous la forme  $\{\theta \in \Theta_1\}$ , avec  $\Theta_1 \subset \Theta$

Rem:  $\{\theta \in \Theta_0\}$  et  $\{\theta \in \Theta_1\}$  sont disjoints.

# Risques de première et de seconde espèce

	$\mathcal{H}_0$	$\mathcal{H}_1$
Non rejet de $\mathcal{H}_0$	Juste	Faux (acceptation à tort)
Rejet de $\mathcal{H}_0$	Faux (Rejet à tort)	Juste

Statistique : Intervalles de confiance et tests

Intervalles de confiance

Théorèmes limites

Tests d'hypothèses

- ▶ Risque de première espèce : probabilité de rejeter à tort

$$\alpha = \sup_{\theta \in \Theta_0} \mathbb{P}_{\theta}((y_1, \dots, y_n) \in R)$$

- ▶ Risque de seconde espèce

$$\beta = \sup_{\theta \in \Theta_1} \mathbb{P}_{\theta}((y_1, \dots, y_n) \notin R)$$

Joseph Salmon



Statistique : Intervalles de confiance et tests

Intervalles de confiance

Théorèmes limites

Tests d'hypothèses

Joseph Salmon



## Niveau du test

$1 - \alpha$  = probabilité d'« accepter » à raison (si  $\mathcal{H}_0$  est valide)

## Puissance du test

$1 - \beta$  = probabilité de rejeter  $\mathcal{H}_0$  à raison (si  $\mathcal{H}_1$  est valide)

En général, lorsqu'on parle de « test à 95% » on parle d'un test de niveau  $1 - \alpha \geq 95\%$ .

## Statistique : Intervalles de confiance et tests

### Intervalles de confiance

Théorèmes limites

### Tests d'hypothèses

Objectif classique : construire un test de niveau  $1 - \alpha$

- ▶ On cherche une fonction des données  $T_n(y_1, \dots, y_n)$  dont on connaît la loi si  $\mathcal{H}_0$  est vraie :  $T_n$  est appelée *statistique de test*.
- ▶ On définit une **région de rejet** ou **région critique** de niveau  $\alpha$ , une région  $R$  telle que, sous  $\mathcal{H}_0$ ,

$$\mathbb{P}(T_n(y_1, \dots, y_n) \in R) \leq \alpha$$

- ▶ Règle de rejet de  $\mathcal{H}_0$  : on rejette si  $T_n(y_1, \dots, y_n) \in R$

# Exemple gaussien : nullité de la moyenne

Statistique : Intervalles de confiance et tests

Intervalles de confiance

Théorèmes limites

Tests d'hypothèses

Joseph Salmon



- ▶ Modèle :  $\Theta = \mathbb{R}$ ,  $\mathbb{P}_\theta = \mathcal{N}(\theta, 1)$ .
- ▶ Hypothèse nulle :  $\mathcal{H}_0 : \{\theta = 0\}$
- ▶ Sous  $\mathcal{H}_0$ ,  $T_n(y_1, \dots, y_n) = \frac{1}{\sqrt{n}} \sum_i y_i \sim \mathcal{N}(0, 1)$
- ▶ **Région critique pour  $T_n$  ? Quantiles gaussiens : sous  $H_0$ ,**

$$\mathbb{P}(T_n \in [-1.96, 1.96]) = 0.95$$

On prend  $R = [-1.96, 1.96]^C = ]-\infty, -1.96[ \cup ]1.96, +\infty[$ .

- ▶ **Exemple numérique** : si  $T_n = 1.5$ , on ne rejette **PAS**  $\mathcal{H}_0$  au niveau 95%