

MA101

Statistique

Maxime Ossonce

ENSTA – 1A

2018/2019

Introduction

Outline

1. Introduction

1.1 Population

1.2 Estimateurs

1.3 Convergences de variables aléatoires

2. Estimation

3. Vecteurs gaussiens

4. Intervalles de confiance

5. Tests d'hypothèse

6. Suppléments

Bibliographie

- ▷ J. Pagès. Statistique générales pour utilisateurs. Presses Universitaires de Rennes, 2005.
- ▷ A. Monfort. Cours de statistique mathématique. Economica, 1997.
- ▷ S. Morgenthaler. Introduction à la statistique. PPUR, 2013.

Inférence statistique

Le terme **statistique** a plusieurs acceptions :

- ▷ observation et description d'un échantillon (statistique descriptive) ;
- ▷ recueil et interprétation des données ;
- ▷ discipline mathématique (**inférence statistique**) ;
- ▷ objet mathématique servant à l'estimation.

Inférence statistique

Les caractéristiques (**variables**) de la populations sont régies par un modèle (*cf.* cours de probabilités) partiellement connu.

- ▷ Parmi les lois de probabilités *possibles* appartenant à \mathcal{P} , laquelle régit la population ?
- ▷ Exemple : sondage pour prédire le résultat d'une élection.
- ▷ Estimation paramétrique, pour $\Theta \subset \mathbb{R}^p$: $\mathcal{P} = (\mathbb{P}_\theta)_{\theta \in \Theta}$.
 - ▷ Exemple : $\Theta = \mathbb{R} \times \mathbb{R}_+$ et \mathcal{P} est l'ensemble de lois à densité gaussienne sur \mathbb{R} .

Population

Une **population** est un ensemble d'**individus** sur lequel on observe les **variables**.

- ▷ Si la population est finie de taille N , on effectue soit un recensement, soit un **sondage**, avec ou sans remise.
- ▷ L'**échantillonnage** est le procédé d'extraction d'un sous-ensemble de la population.
- ▷ Quand $N \gg 1$, l'échantillonnage avec ou sans remise sont équivalents.

Echantillon

Un **n -échantillon** est un vecteur $X = (X_1, \dots, X_n)$ de n variables aléatoires (v.a.) indépendantes et identiquement distribuées (i.i.d.)

- ▷ La loi \mathbb{P} de X_1 est appelée loi **parente** de l'échantillon.
- ▷ $(X_1, \dots, X_n) \sim \mathbb{P}^{\otimes n}$.
- ▷ Une **série statistique** est une réalisation de X :

$$(x_1, \dots, x_n) = (X_1(\omega), \dots, X_n(\omega)).$$

- ▷ Le **modèle statistique paramétrique**, noté $(\mathbb{R}, \mathcal{R}, (\mathbb{P}_\theta)_{\theta \in \Theta})^n$ est

$$\left(\mathbb{R}^n, \mathcal{R}^n, (\mathbb{P}_\theta^{\otimes n})_{\theta \in \Theta} \right).$$

Statistique

Etant donné un n -échantillon, une **statistique** T_n est une fonction mesurable de $(\mathbb{R}^n, \mathcal{R}^n)$ dans $(\mathbb{R}^k, \mathcal{R}^k)$.

- ▷ T_n est une v.a. sur $(\mathbb{R}^n, \mathcal{R}^n)$.
- ▷ $T_n(X_1, \dots, X_n)$ est une v.a. sur (Ω, \mathcal{F}) .
- ▷ Exemple, la moyenne empirique de l'échantillon :

$$T_n: (\mathbb{R}^n, \mathcal{R}^n) \rightarrow (\mathbb{R}, \mathcal{R})$$

$$(x_1, \dots, x_n) \rightarrow \bar{x}_n = \frac{1}{n} \sum_{k=1}^n x_k.$$

- ▷ \bar{X}_n est une v.a.

Estimation

Un estimateur sera une statistique dont l'objet sera de se faire une idée de la loi parente \mathbb{P} élément de \mathcal{P} .

- ▷ Si le modèle est paramétrique, l'estimation sera dite paramétrique.
- ▷ Si une valeur estimée de θ est souhaitée, on parlera d'estimation ponctuelle (par exemple, par maximum de vraisemblance).
- ▷ Si un ensemble de valeurs est souhaitée, on aura affaire à une estimation par **intervalle de confiance**.
- ▷ Les tests d'hypothèse permettent de répondre à la question : la *vraie* valeur de θ est-elle dans l'ensemble $\Theta_0 \subset \Theta$ ou dans $\Theta \setminus \Theta_0$?

Convergence presque sûre

On dit que la suite de variable aléatoire réelle (v.a.r.) (X_n) converge presque sûrement vers une v.a.r. X , et on note $X_n \xrightarrow{\text{p.s.}} X$, si il existe $N \in \mathcal{F}$ négligeable tel que

$$X_n(\omega) \rightarrow X(\omega) ; \quad \forall \omega \in N^c.$$

Convergence en probabilité

On dit que la suite de v.a.r. (X_n) converge en probabilité vers une v.a.r. X , et on note $X_n \xrightarrow{\mathbb{P}} X$, si on a

$$\lim_n \mathbb{P}(|X_n - X| > \epsilon) = 0 ; \quad \forall \epsilon > 0.$$

- ▷ La convergence en probabilité est plus *faible* que la convergence presque sûrement (p.s.) :

$$X_n \xrightarrow{\text{p.s.}} X \Rightarrow X_n \xrightarrow{\mathbb{P}} X.$$

- ▷ La réciproque est fausse.

Convergence dans \mathcal{L}^1

On dit que la suite de v.a.r. **intégrables** (X_n) converge dans \mathcal{L}^1 vers une v.a.r. X intégrable, et on note $X_n \xrightarrow{\mathcal{L}^1} X$, si

$$\mathbb{E}[|X_n - X|] \rightarrow 0.$$

- ▷ La convergence en probabilité est plus *faible* que la convergence dans \mathcal{L}^1 :

$$X_n \xrightarrow{\mathcal{L}^1} X \Rightarrow X_n \xrightarrow{\mathbb{P}} X.$$

- ▷ Si on a $X_n \xrightarrow{\text{p.s.}} X$ et $|X_n| \leq g$ pour tout n avec g intégrable alors X_n est intégrable pour tout n et $X_n \xrightarrow{\mathcal{L}^1} X$.

Convergence en loi

On dit que la suite de v.a.r. (X_n) converge en loi vers une v.a.r. X , et on note $X_n \xrightarrow{\mathcal{L}} X$, si pour toute fonction **continue bornée** φ à valeurs dans \mathbb{R} on a :

$$\lim \mathbb{E}[\varphi(X_n)] = \mathbb{E}[\varphi(X)].$$

- ▷ Pour une suite de v.a.r., la convergence en loi est équivalente à la convergence ponctuelle des fonctions de répartition F_{X_n} vers F_X aux points de continuité de F_X .
- ▷ La v.a. X peut ne pas être définie sur le même espace probabilisé que (X_n) .
- ▷ La convergence en loi est plus *faible* que la convergence en probabilité :

$$X_n \xrightarrow{\mathbb{P}} X \Rightarrow X_n \xrightarrow{\mathcal{L}} X.$$

Loi faible des grands nombres

La loi des grands nombres (LGN) sera utilisée pour construire des estimateurs.

Théorème 1.1

Si (X_n) est une suite de v.a.r. i.i.d. d'espérance μ , alors la variable aléatoire $\bar{X}_n = \frac{X_1 + \dots + X_n}{n}$ converge en probabilité vers μ :

$$\mathbb{P} (|\bar{X}_n - \mu| > \epsilon) \xrightarrow[n \rightarrow \infty]{} 0 ; \quad \forall \epsilon > 0.$$

TCL

Le théorème de la limite centrale (TCL) permet contrôler la rapidité de convergence dans la loi faible des grands nombres.

Théorème 1.2 (TCL)

Si (X_n) est une suite de v.a.r. i.i.d. d'espérance μ et de variance σ^2 alors la variable aléatoire

$$Z_n = \frac{\sqrt{n}}{\sigma} \cdot (\bar{X}_n - \mu)$$

converge en **loi** vers $Z \sim \mathcal{N}(0, 1)$.

▷ On a donc $\lim_{n \rightarrow \infty} \mathbb{P}(Z_n \leq z) = \Phi(z)$.

Lemme de Slutsky

X_n et Y_n sont des suites de v.a. à valeurs respectivement dans \mathbb{R}^n et \mathbb{R}^p .

Théorème 1.3 (Lemme de Slutsky)

Si $X_n \xrightarrow{\mathcal{L}} X$ et $Y_n \xrightarrow{\mathcal{L}} c$ alors

$$(X_n, Y_n) \xrightarrow{\mathcal{L}} (X, c).$$

▷ Remarque : il y a équivalence entre convergence en loi et en probabilité quand la limite est une constante.

Outline

1. Introduction

2. Estimation

2.1 Définition

2.2 Biais, risque et convergence

2.3 Comportement asymptotique

2.4 Construction d'un estimateur

3. Vecteurs gaussiens

4. Intervalles de confiance

5. Tests d'hypothèse

6. Suppléments

Estimateur

On se donne g fonction définie sur Θ à valeurs dans \mathbb{R}^k .

- ▷ Un **estimateur** T_n du paramètre $g(\theta)$ est une statistique à valeurs dans \mathbb{R}^k .
- ▷ Exemple, $\hat{\theta}_n = \bar{X}_n$ est un estimateur **non-biaisé** de $\mu = \mathbb{E}[X_1]$.

Premier exemple

On cherche à connaître μ l'espérance de la loi parente \mathbb{P} . On a à disposition un n -échantillon (X_1, \dots, X_n) .

- ▷ On peut prendre $\hat{\theta}_n = \bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$.
- ▷ On note que $\mathbb{E}[\hat{\theta}_n] = \mu$.
- ▷ On dira que l'estimateur est sans **biais**.

Biais

Soit $\hat{\nu}_n$ un estimateur de $\nu(\theta)$, on notera $b_\theta(\hat{\nu}_n)$ le **biais** de l'estimateur :

$$b_\theta(\hat{\nu}_n) := \mathbb{E}[\hat{\nu}_n] - \nu(\theta).$$

- ▷ $b_\theta(\hat{\nu}_n)$ est une fonction de θ .
- ▷ Si $b_\theta(\hat{\nu}_n) = 0$ alors l'estimateur est dit non biaisé.
- ▷ Si $\lim_{n \rightarrow +\infty} b_\theta(\hat{\nu}_n) = 0$ alors l'estimateur est asymptotiquement sans biais.

Risque quadratique

Le risque **quadratique** de l'estimateur $\hat{\nu}_n$ de $\nu(\theta)$ est :

$$R_\theta(\hat{\nu}_n) := \mathbb{E} [(\hat{\nu}_n - \nu(\theta))^2].$$

- ▷ Le risque quadratique est associé à la fonction de perte quadratique.
- ▷ Décomposition biais-variance (exercice 1 du sujet 1) :

$$R_\theta(\hat{\nu}_n) = b_\theta^2(\hat{\nu}_n) + \text{Var}(\hat{\nu}_n).$$

Relation d'ordre

L'estimateur $\hat{\theta}_n$ sera dit meilleur que $\tilde{\theta}_n$, et on notera $\hat{\theta}_n \preceq \tilde{\theta}_n$ ssi :

$$R_\theta(\hat{\theta}_n) \leq R_\theta(\tilde{\theta}_n) ; \quad \forall \theta \in \Theta$$

- ▷ \preceq n'est pas une relation d'ordre total sur l'ensemble des estimateurs de $g(\theta)$ (voir exercice 8 du sujet 1).
- ▷ Un estimateur $\hat{\theta}_n$ sera **admissible** si aucun autre estimateur n'est strictement meilleur que lui *i.e.* il n'existe pas d'estimateur $\tilde{\theta}_n$ tel que $\tilde{\theta}_n \preceq \hat{\theta}_n$ et $\exists \theta R_\theta(\tilde{\theta}_n) < R_\theta(\hat{\theta}_n)$.

Convergence

On dit que T_n est **consistant** pour $g(\theta)$ si il converge en probabilité vers $g(\theta)$:

$$T_n \xrightarrow{\mathbb{P}} g(\theta).$$

- ▷ Si T_n est un estimateur (asymptotiquement) sans biais de $g(\theta)$ et si $\text{Var}(T_n) \rightarrow 0$ quand $n \rightarrow \infty$ alors T_n est un estimateur consistant pour $g(\theta)$.
- ▷ Si la convergence de T_n vers $g(\theta)$ est p.s. alors l'estimateur sera fortement consistant.

Application du TCL

La **loi** de la moyenne empirique d'un n -échantillon de loi parente de variance finie peut être approximée par une loi **normale** :

$$\bar{X}_n \underset{\text{appr}}{\sim} \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right).$$

Par exemple si $X \sim \mathcal{B}(\theta)$, $\sigma^2 = \theta(1 - \theta)$

$$\bar{X}_n \underset{\text{appr}}{\sim} \mathcal{N}\left(\theta, \frac{\theta(1 - \theta)}{n}\right)$$

$$\sqrt{n} \frac{\bar{X}_n - \theta}{\sqrt{\theta(1 - \theta)}} \underset{\text{appr}}{\sim} \mathcal{N}(0, 1).$$

Vitesse de convergence

Un estimateur $\hat{\nu}_n$ de $\nu(\theta)$ a un comportement **asymptotiquement normal** à la **vitesse** v_n si $v_n \uparrow +\infty$ et

$$v_n \cdot (\hat{\nu}_n - \nu) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma).$$

- ▷ L'estimateur de la moyenne empirique converge à la vitesse \sqrt{n} (TCL).
- ▷ On peut avoir des convergences vers d'autres lois à d'autres vitesses (exercice 5 du sujet 2).

Construire un estimateur

Trois méthodes :

- ▷ Méthode empirique.
- ▷ Méthode des moments

$$\hat{\mu}_n(p) := \frac{1}{n} \sum_{k=1}^n X_k^p.$$

- ▷ Maximum de vraisemblance : le n -échantillon a une densité

$$f_\theta(x_1, \dots, x_n).$$

Moments

Le moment d'ordre p , $\mathbb{E}[X^p]$, est une fonction de θ .

- ▷ On suppose $\mathbb{E}[|X|^p] < \infty$
- ▷ On suppose $\mu_\theta(p) := \mathbb{E}[X^p] = f(\theta)$ avec f une fonction inversible continue.

On pose $\hat{\theta}_n := f^{-1}(\hat{\mu}_n(p))$.

- ▷ $\hat{\theta}_n \xrightarrow{\mathbb{P}} \theta$.
- ▷ $\hat{\theta}_n$ est un estimateur convergent de θ .

Delta méthode

La delta méthode permet d'établir la vitesse de convergence de l'estimateur $\hat{\theta}_n = f^{-1}(\hat{\mu}_n(p))$.

- ▷ On suppose que $\mathbb{E}[|X|^{2p}] < +\infty$ et $f \in \mathcal{C}^1(\Theta, \mathbb{R})$

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{\mathcal{L}} \mathcal{N}\left(0, \frac{\text{Var}(X^p)}{|f'(\theta)|^2}\right)$$

- ▷ On note $\hat{\sigma}_n^2(p)$ l'estimateur empirique de $\text{Var}(X^p)$.

$$\frac{\sqrt{n}(\hat{\theta}_n - \theta)}{\hat{\sigma}_n(p)} \xrightarrow{\mathcal{L}} \mathcal{N}\left(0, \frac{1}{|f'(\theta)|^2}\right).$$

En dimension supérieure

On suppose un estimateur $\hat{\theta}_n$ de θ asymptotiquement normal à la vitesse v_n :

$$v_n \cdot (\hat{\theta}_n - \theta) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma).$$

Alors, pour $\nu : \Theta \rightarrow \mathbb{R}^d$ une fonction **différentiable**, $\hat{\nu}_n = \nu(\hat{\theta}_n)$ est un estimateur asymptotiquement normal de $\nu(\theta)$;

$$v_n \cdot (\hat{\nu}_n - \nu) \xrightarrow{\mathcal{L}} \mathcal{N}(0, D_\nu \Sigma D_\nu^\top).$$

▷ D_ν est le jacobien de ν au point θ : $D_{\nu ij} = \frac{\partial \nu_i}{\partial \theta_j}(\theta)$

Généralisation de la méthode des moments

On suppose :

$$\nu(\theta) = \phi(\mu_\theta(1), \dots, \mu_\theta(q)).$$

▷ L'estimateur des moments est

$$\hat{\nu}_n = \phi(\hat{\mu}_n(1), \dots, \hat{\mu}_n(q))$$

▷ Si $\mathbb{E}[|X|^q] < \infty$, l'estimateur des moments est consistant.

▷ Extension : $\mu_\theta(p) = \mathbb{E}[g_p(X)]$ et $\hat{\mu}_\theta(p) = \frac{1}{n} \sum_{k=1}^n g_p(X_k)$.

Modèle dominé

On suppose que les lois $(\mathbb{P}_\theta)_{\theta \in \Theta}$ admettent une **densité** f_θ par rapport à une mesure commune, *e.g.* :

- ▷ la mesure de comptage μ ,
- ▷ la mesure de Lebesgue λ .

La densité f_θ est :

- ▷ la distribution de probabilité dans le cas d'une domination par μ ,
 $f_\theta(x_1, \dots, x_n) = \mathbb{P}_\theta(X = x)$.
- ▷ la fonction de densité dans le cas où $\mathbb{P}_\theta \ll \lambda$.

Définition 2.1 (Vraisemblance)

Dans un modèle **paramétrique dominé**, la vraisemblance est une fonction de la variable θ définie pour toute réalisation du n -échantillon $x = (x_1, \dots, x_n)$ et qui à θ associe la valeur $f_\theta(x_1, \dots, x_n)$:

$$\theta \mapsto L_n(\theta; x_1, \dots, x_n) = f_\theta(x_1, \dots, x_n)$$

- ▷ La vraisemblance est une fonction du paramètre θ .
- ▷ La densité est, elle, une fonction de la variable x .
- ▷ Log-vraisemblance : $\ell_n(\theta; x) = \sum_{k=1}^n \log f_\theta(x_i)$.




FIGURE – Densité de probabilité d'un n -échantillon de loi parente $\mathcal{B}(\theta^*)$ pour $\theta^* = 0,18$, $n = 20$ et vraisemblance pour $\sum_{k=1}^n x_k = 4$.

Définition 2.2 (Estimateur du maximum de vraisemblance)

On considère un modèle paramétrique dominé. L'EMV est la v.a. $\hat{\theta}_n$ maximisant la vraisemblance :

$$\hat{\theta}_n \in \arg \max_{\theta \in \Theta} \{L_n(\theta; X)\}.$$

▷ Exemple, $\mathbb{P}_\theta = \mathcal{N}(\mu, \sigma^2)$, $\theta = (\mu, \sigma^2)$:

$$\triangleright \ell_n(\theta; x_1, \dots, x_n) = -\frac{n}{2} \log(2\pi\sigma^2) - \sum_{k=1}^n \frac{(x_k - \mu)^2}{2\sigma^2}.$$

$$\triangleright \hat{\theta}_n = \left(\bar{X}_n, \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X}_n)^2 \right).$$

Outline

1. Introduction
2. Estimation
- 3. Vecteurs gaussiens**
4. Intervalles de confiance
5. Tests d'hypothèse
6. Suppléments

Moyenne empirique

La méthode des moments fait intervenir, $\bar{X}_n, \hat{\sigma}_n^2$.

▷ Loi de \bar{X}_n ?

▷ Loi de $\hat{\sigma}_n^2$?

TCL : $\sqrt{n} \frac{\bar{X}_n - \mathbb{E}[X]}{\hat{\sigma}_n} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1)$.

▷ Loi non asymptotique ?

Définition 3.1 (Vecteur gaussien)

Un *vecteur aléatoire* X à valeurs dans \mathbb{R}^d est dit *gaussien* si toute combinaison linéaire de ses coordonnées est une v.a.r. suivant une loi normale.

- ▷ Les coordonnées d'un vecteur gaussien sont des v.a.r. gaussiennes.
- ▷ La réciproque est fausse.

Loi du vecteur gaussien

La loi d'un vecteur gaussien est déterminée par :

- ▷ son espérance $\mu = (\mu_1, \dots, \mu_d)$;
- ▷ sa matrice de variance-covariance Σ .

On note $X \sim \mathcal{N}(\mu, \Sigma)$.

- ▷ Un n -échantillon gaussien **centré réduit** est un vecteur aléatoire $Z \sim \mathcal{N}(0, I_d)$.
- ▷ La matrice de variance-covariance d'un n -échantillon gaussien est de la forme $\sigma^2 I_d$.

Si Σ est inversible alors X est à densité et

$$f(x) = \frac{1}{\sqrt{(2\pi)^n \det \Sigma}} \exp \left(-\frac{1}{2} (x - \mu)^\top \Sigma^{-1} (x - \mu) \right).$$

Application linéaire

- ▷ Si $X \sim \mathcal{N}(\mu, \Sigma)$ alors $Y := AX \sim \mathcal{N}(A\mu, A\Sigma A^\top)$.
- ▷ Si $X \sim \mathcal{N}(0, \sigma^2 I_d)$ et A est orthonormale alors

$$Y = AX \sim \mathcal{N}(0, \sigma^2 I_d).$$

- ▷ Si X est un n -échantillon gaussien (*i.e.* $X_1 \sim \mathcal{N}(0, \sigma^2)$) alors

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

Loi du khi-deux

Soit Z un n -échantillon gaussien **centré réduit**.

Définition 3.2

La loi du carré de la norme euclidienne du vecteur est appelée loi du khi-deux (centré) à n degrés de liberté. On note

$$\|Z\|^2 = \sum_{k=1}^n Z_k^2 \sim \chi^2(n).$$

Son espérance est n , sa variance $2n$.

- ▷ Si $Z \sim \mathcal{N}(\mu, I_n)$ alors $\|Z\|^2$ suit une loi du khi-deux décentré notée $\chi^2(n, \|\mu\|^2)$.
- ▷ Son espérance est $n + \|\mu\|^2$, sa variance $2(n + 2\|\mu\|^2)$.

n -échantillon

Soit X un n -échantillon gaussien. $X_1 \sim \mathcal{N}(\mu, \sigma^2)$. On a

$$\sum_{k=1}^n \left(\frac{X_k - \mu}{\sigma} \right)^2 \sim \chi^2(n).$$

▷ Loi de l'estimateur empirique de la variance à espérance connue.

Variance empirique

Soit X un n -échantillon gaussien. $X_1 \sim \mathcal{N}(\mu, \sigma^2)$. On a

$$\sum_{k=1}^n \left(\frac{X_k - \bar{X}_n}{\sigma} \right)^2 \sim \chi^2(n-1).$$

▷ Loi de l'estimateur **sans biais** de la variance :

$$\hat{\sigma}_n^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X}_n)^2 \sim \frac{\sigma^2}{n-1} \chi^2(n-1).$$

▷ Les v.a.r. \bar{X}_n et $\hat{\sigma}_n^2$ sont **indépendantes**.

▷ \bar{X}_n et $X - \bar{X}_n$ sont des projections orthogonales sur deux sous-espaces orthogonaux (Cochran).

Loi de Student

Z et K **indépendantes** avec $Z \sim \mathcal{N}(0, 1)$ et $K \sim \chi^2(p)$ alors
 $T := \frac{Z}{\sqrt{K/p}}$ suit une loi de **Student** à p degrés de liberté, notée $\mathcal{T}(p)$.

▷ Permet de calculer des intervalles de confiance sur \bar{X}_n :

$$T_n := \sqrt{n} \frac{\bar{X}_n - \mu}{\hat{\sigma}_n}.$$

- ▷ $T_n \sim \mathcal{T}(n - 1)$ est appelée **statistique de student** de l'échantillon.
- ▷ $T_n^2 \sim \mathcal{F}(1, n)$.
- ▷ La loi de Fisher $\mathcal{F}(m, n)$ est la loi de $\frac{K_1 n_2}{K_2 n_1}$ quand $K_i \sim \chi^2(n_i)$ et K_1 et K_2 indépendantes.

Outline

1. Introduction
2. Estimation
3. Vecteurs gaussiens
- 4. Intervalles de confiance**
5. Tests d'hypothèse
6. Suppléments

Comportements asymptotiques

Estimation **ponctuelle** de $\nu(\theta)$

- ▷ $\mathbb{E}[\widehat{\nu}_n] \xrightarrow[n \rightarrow +\infty]{} \nu$;
- ▷ $\widehat{\nu}_n \xrightarrow{\mathbb{P}} \nu$;
- ▷ $R_\theta(\widehat{\nu}_n) \xrightarrow[n \rightarrow +\infty]{} 0$;
- ▷ $v_n (\widehat{\nu}_n - \nu) \xrightarrow{\mathcal{L}} \mu_\nu$.
 - ▷ v_n est la vitesse de convergence ;
 - ▷ si μ est indépendante de ν : loi **pivotale**.

Définition 4.1 (Intervalle de confiance)

Un intervalle de confiance (IC) de niveau de confiance $1 - \alpha$ pour θ est un intervalle dont les bornes sont des **statistiques** telles que :

$$\mathbb{P} \left(\left[\widehat{\theta}_n^-, \widehat{\theta}_n^+ \right] \ni \theta \right) \geq 1 - \alpha.$$

- ▷ $\mathbb{P} \left(\left[\widehat{\theta}_n^-, \widehat{\theta}_n^+ \right] \ni \theta \right) = \mathbb{P}(\{\widehat{\theta}_n^- \leq \theta\} \cap \{\widehat{\theta}_n^+ \geq \theta\})$.
- ▷ α est un **risque** de première espèce.

Quantiles

Le **quantile** q_α d'ordre $\alpha \in [0, 1]$ d'une loi réelle μ est le réel tel que, si $X \sim \mu$,

$$\mathbb{P}(X \leq q_\alpha) = \alpha.$$

- ▷ q_α est la fonction réciproque de la fonction de répartition F ,
- ▷ obtenue par interpolation linéaire dans le cas discret.
- ▷ Lorsque la loi est symétrique :

$$\mathbb{P}(|X| > q_{1-\alpha/2}) = \alpha.$$

- ▷ On note q_α^* le quantile de $\mathcal{N}(0, 1)$.

Exemple gaussien I

X un n -échantillon gaussien, $X_1 \sim \mathcal{N}(\mu, \sigma^2)$ à espérance et variance inconnues.

$$T_n = \sqrt{n} \frac{\bar{X} - \mu}{\hat{\sigma}_n} \sim \mathcal{T}(n - 1).$$

Exemple gaussien II

On note t_n le quantile de $\mathcal{T}(n-1)$ d'ordre $1 - \frac{\alpha}{2}$.

$$\begin{aligned} 1 - \alpha &= \mathbb{P}(-t_n \leq T_n \leq t_n) \\ &= \mathbb{P}\left(-\frac{\hat{\sigma}_n t_n}{\sqrt{n}} \leq \mu - \bar{X}_n \leq \frac{\hat{\sigma}_n t_n}{\sqrt{n}}\right) \\ &= \mathbb{P}\left(\bar{X}_n - \frac{\hat{\sigma}_n t_n}{\sqrt{n}} \leq \mu \leq \bar{X}_n + \frac{\hat{\sigma}_n t_n}{\sqrt{n}}\right). \end{aligned}$$

▷ Pour $\alpha = 0,01$, $t_{20} = 2,83$, $t_{40} = 2,70$.

▷ Il s'agit de l'IC de Student.

Définition 4.2 (Intervalle de confiance asymptotique)

Un IC *asymptotique* de niveau de confiance $1 - \alpha$ pour θ est une suite d'intervalles dont les bornes sont des **statistiques** telles que :

$$\mathbb{P}\left(\left[\hat{\theta}_n^-, \hat{\theta}_n^+\right] \ni \theta\right) \xrightarrow[n \rightarrow +\infty]{} 1 - \alpha.$$

▷ Dans le cas **non gaussien** on construira l'IC asymptotique pour l'espérance par le TCL.

▷ On considérera $\mathbb{P}(I_n \ni \theta) \approx 1 - \alpha$ pour $n \geq 30$.

Exemple




FIGURE – Exemples d'IC obtenus pour $\alpha = 0,1$ et un modèle statistique de Bernoulli ($\theta = 0,4$, $n = 100$).

Outline

1. Introduction
2. Estimation
3. Vecteurs gaussiens
4. Intervalles de confiance
- 5. Tests d'hypothèse**
 - 5.1 Tests paramétriques
 - 5.2 Tests du χ -deux
6. Suppléments

Principe

Choix entre deux hypothèses sur le paramètre θ dans le cadre d'un modèle statistique paramétrique :

- ▷ hypothèse **nulle** (H_0);
- ▷ hypothèse **alternative** (H_1).
- ▷ Exemple :
 - ▷ (H_0) : $\mu = \mu_0$
 - ▷ (H_1) : $\mu \neq \mu_0$.

L'hypothèse (H_0) est supposée vraie : α , le **risque** de première espèce est la probabilité de **rejeter** à tort (H_0).

Construction

Lors de la construction d'un test, on définit :

- ▷ le modèle;
- ▷ les hypothèses;
- ▷ une statistique $T(X)$;
- ▷ α le risque de première espèce et la **région critique** :

$$\mathbb{P}_{(H_0)}(T_n \in \mathcal{R}_\alpha) = \alpha.$$

Puissance

La **puissance** du test est sa capacité à détecter l'hypothèse alternative.

▷ Le risque de **deuxième** espèce est noté β :

$$\mathbb{P}_{(H_1)}(T_n \in \mathcal{R}_\alpha^c) = \beta$$

▷ La puissance du test est $\pi = 1 - \beta$.

Exemple

X n -échantillon gaussien. Test d'hypothèse sur l'espérance.

▷ $(H_0) : \mu = \mu_0, (H_1) : \mu \neq \mu_0$.

▷ $T_n \sim_{(H_0)} \mathcal{T}(n-1)$.

▷ $\mathcal{R}_\alpha^c = [-t_n^*, t_n^*]$.

▷ $\mathbb{P}_{(H_0)}(T_n \in \mathcal{R}_\alpha) = \alpha$.

(H_0) est conservée si $t_n \in [-t_n^*, t_n^*]$.

▷ La puissance $\pi(\mu)$ du test est une fonction de μ .

$$\pi(\mu) = \mathbb{P}_{(H_1)}(T_n \notin [-t_n^*, t_n^*])$$

Hypothèses composites

Un hypothèse composite porte sur un sous-ensemble de Θ :

- ▷ test **bilatère** pour hypothèse nulle simple, hypothèse alternative composite $(H_0) : \theta = \theta_0$ contre $(H_1) : \theta \neq \theta_0$
- ▷ test **unilatère** pour hypothèse nulle composite, hypothèse alternative composite $(H_0) : \theta < \theta_0$ contre $(H_1) : \theta \geq \theta_0$

Pour un test à hypothèse nulle composite, la **taille** du test est $\sup_{\theta \in \Theta_0} \alpha(\theta)$.

- ▷ Le test est de niveau α si $\sup_{\theta \in \Theta_0} \alpha(\theta) \leq \alpha$.

Biais et consistance

- ▷ Un test est dit sans biais si $\pi \geq \alpha$.
- ▷ Un test est dit consistant si $\pi \xrightarrow[n \rightarrow +\infty]{} 1$.

Test UPP

Un test est dit **uniformément plus puissant (UPP)** si il est plus puissant que tout autre test de même niveau pour toute valeur du paramètre θ .

Rapport de vraisemblance

Théorème 5.1 (Neyman-Pearson)

Dans le cas de deux hypothèses simples $\theta = \theta_0$ contre $\theta = \theta_1$ un test UPP est de la forme :

$$\mathcal{R}_\alpha = \left\{ x \in \mathbb{R}^n : \frac{L(\theta_1; x)}{L(\theta_0; x)} > k_\alpha \right\}.$$

- ▷ Pour des tests composites unilatères ($\theta = \theta_0$ contre $\theta > \theta_0$) le test UPP est test le du rapport de vraisemblance si \mathcal{R}_α ne dépend pas de θ_1 dans le test à hypothèses simples.

p -value

- ▷ La p -value est calculée à partir de l'observation t_n de la statistique du test.
- ▷ C'est le plus petit α qui rejette (H_0) étant donné t_n observé.
- ▷ Si $\theta_1 > \theta_0$, c'est $\mathbb{P}_{(H_0)}(T_n \geq t_n)$.

Tests d'adéquation

Les tests du khi-deux sont des tests asymptotiques non paramétriques. Ils sont construits avec une statistique $K_n \sim_{(H_0)} \chi^2(p)$:

- ▷ test d'ajustement ;
- ▷ test d'homogénéité ;
- ▷ test d'indépendance.

Loi multinomiale

On considère une loi catégorielle à K catégories caractérisée par la distribution de probabilités (d.d.p.) $\pi = (\pi_1, \dots, \pi_n)$.

- ▷ On note $O = (O_1, \dots, O_K)$ le vecteur du décompte de chacune des catégories au sein d'un n -échantillon X de cette loi.

$$O_k = \sum_{i=1}^n \mathbb{1}_{X_i=k}.$$

- ▷ $O \sim \mathcal{M}(n, \pi)$.
- ▷ $\mathbb{P}(O = o) = n! \prod_{k=1}^K \frac{\pi_k}{n_k!}$.

Ajustement

$$k_n = \sum_{i=1}^p \frac{(o_i - e_i)^2}{e_i}.$$

- ▷ o_i effectif observé de la catégorie i
- ▷ e_i effectif théorique de la catégorie i
- ▷ Sous (H_0) , $K_n \xrightarrow{\mathcal{L}} \chi^2(p-1)$.
- ▷ Loi asymptotique admise si $\min_i e_i > 5$.
- ▷ Si $k_n > q_{1-\alpha}$ alors l'hypothèse nulle (d'ajustement) est rejetée.

Homogénéité

$$k_n = \sum_{i=1}^p \sum_{j=1}^m \frac{(o_{ij} - e_{ij})^2}{e_{ij}}.$$

- ▷ On dispose de m échantillons (de n_j individus).
- ▷ o_{ij} effectif observée de la catégorie i dans l'échantillon j .
- ▷ e_{ij} effectif théorique de la catégorie i dans l'échantillon j :

$$e_{ij} = \frac{\sum_{j=1}^m o_{ij} \sum_{i=1}^p o_{ij}}{N}$$

- ▷ $K_n \sim_{(H_0)} \chi^2((p-1)(m-1))$.
- ▷ Si $k_n > q_{1-\alpha}$ alors l'hypothèse nulle est rejetée.

Indépendance

Deux variables à p et m modalités.

$$k_n = \sum_{i=1}^p \sum_{j=1}^m \frac{(o_{ij} - e_{ij})^2}{e_{ij}}.$$

- ▷ o_{ij} effectif observée de la catégorie i et j .
- ▷ e_{ij} effectif théorique de la catégorie i et j :

$$e_{ij} = \frac{\sum_{j=1}^m o_{ij} \sum_{i=1}^p o_{ij}}{N}$$

- ▷ $K_n \sim_{(H_0)} \chi^2((p-1)(m-1))$.

Si $k_n > q_{1-\alpha}$ alors l'hypthèse nulle est rejetée.

Outline

1. Introduction
2. Estimation
3. Vecteurs gaussiens
4. Intervalles de confiance
5. Tests d'hypothèse
- 6. Suppléments**
 - 6.1 Statistique bayésienne
 - 6.2 Estimation non paramétrique

Motivation

- ▷ En statistique fréquentiste, θ est une constante inconnue.
- ▷ En statistique bayésienne l'inconnu sur θ est formalisé par une v.a.r.
- ▷ La densité de θ résume l'information sur θ .

Lois à densité

$$\pi(\theta|x) = \frac{\pi(\theta)f(x|\theta)}{f(x)}.$$

- ▷ $\pi(\theta|x)$ est la probabilité **a posteriori**.
- ▷ $\pi(\theta)$ est l'**a priori** sur θ .
- ▷ $f(x|\theta)$ est la **vraisemblance**.
- ▷ $f(x)$ n'intervient pas lors de l'estimation par maximum a posteriori (MAP).

Estimation ponctuelle

- ▷ $L(d, \theta)$ est la fonction de **coût** – conséquences de considérer d plutôt que θ .
- ▷ L'estimation ponctuelle minimise le coût moyen :

$$\delta(x) = \min_d \int_{\Theta} \pi(\theta|x)L(d, \theta) d\theta.$$

- ▷ Si la fonction de coût est quadratique :

$$\delta(x) = \int_{\Theta} \pi(\theta|x)\theta d\theta$$

Région de crédibilité

$$\mathcal{R}_k(x) = \{\theta : \pi(\theta|x) \geq k\}$$

- ▷ Permet de créer des régions de volume minimal.

Facteur de Bayes

Deux modèles concurrents, \mathcal{M}_1 et \mathcal{M}_2 .

- ▷ Un a priori différent par modèle.
- ▷ Une vraisemblance par modèle.
- ▷ On construit le facteur de Bayes :

$$B_{12} = \frac{\mathbb{P}(\mathcal{M}_1|x)\mathbb{P}(\mathcal{M}_2)}{\mathbb{P}(\mathcal{M}_2|x)\mathbb{P}(\mathcal{M}_1)}$$

On dispose d'un n -échantillon X .

- ▷ On souhaite connaître la densité f de X .
- ▷ Estimation paramétrique : $f \in \{f(x, \theta) : \theta \in \Theta \subset \mathbb{R}^k\}$.
- ▷ Estimation non paramétrique : $f \in \mathcal{F}$.

Fonction de répartition

$$\widehat{F}_n(y) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{x_i \leq y} \xrightarrow{\text{p.s.}} F(y) = \mathbb{P}(X_1 \leq y)$$

Densité

La densité est

$$f(y) = F'(y) \approx \frac{F(y+h) - F(y)}{h}.$$

▷ Estimateur de Rosenblatt :

$$\hat{f}_n(y) = \frac{1}{nh} \sum_{i=1}^n \mathbb{1}_{y \leq x_i < y+h}.$$

▷ Estimateur à noyau :

$$\hat{f}_n(y) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{y - x_i}{h}\right).$$