

Modélisation Statistique (MAP-STA1)

M1-Mathématiques Appliquées 1ère partie: Modélisation statistique Cours 1: Introduction et rappels

Christine Keribin

¹Laboratoire de Mathématiques d'Orsay
Université Paris-Saclay

2021-2022



Introduction

Rappels

Introduction

Rappels

- Modèle
- Estimation ponctuelle
- Propriétés
- Tests
- IC

- ▶ On dispose d'un échantillon de 6 relevés du temps de trajet (en min) domicile/bureau d'un employé

$x = (15, 17, 15, 18, 16, 15)$

$$\bar{x} = \frac{1}{6} \sum_i x_i = 16$$

1. Quelle est la durée moyenne d'un trajet sur l'année ?
2. Peut-on affirmer avec peu de risque que la durée moyenne d'un trajet est supérieure à 15 min ?
3. La durée d'un trajet a-t-elle augmenté d'une année sur l'autre ?
4. Y a-t-il des facteurs qui influencent la durée de trajet ?
5. Quelle sera la durée d'un trajet demain ?

- ▶ **Population** : ensemble d'objets "équivalents" (**individus, unités statistiques**), sur lesquels on observe des caractéristiques (**variables** qualitatives ou quantitatives)
 - ▶ finie : recensement
 - ▶ infinie : sondage
- ▶ Étude de la **variabilité**
- ▶ Statistique **exploratoire** / statistique **inférentielle**

- ▶ **Probabilité** : étudier les propriétés d'une loi connue
 - ▶ **Statistique** : à partir d'un ensemble d'**observations** d'une loi inconnue, **inférer** des propriétés de cette loi pour répondre à une question
- ↔ résoudre un problème inverse
- ▶ Modéliser
 - ▶ Estimer
 - ▶ Utiliser à des fins explicatives ou prédictives

Quelques objectifs de la statistique inférentielle

- ▶ **estimation** : valeur d'un paramètre d'intérêt, **intervalle de confiance**
- ▶ **test** : comparaison à une situation de référence, de deux échantillons, ...
- ▶ **prédiction** pour une nouvelle unité non encore observée
- ▶ **classification** dans un groupe

Problématiques :

- ▶ construction, comparaison, choix des procédures
- ▶ fiabilité (**risque**) de l'information obtenue ?

Être capable, en utilisant les bases de la statistique mathématique, de :

- ▶ définir une modélisation adaptée à un jeu de données
- ▶ construire des estimateurs (MV, MC)
 - ▶ étudier le risque, l'efficacité et l'asymptotique
- ▶ construire des tests et ICs (Wald, RV)
- ▶ travailler avec le modèle linéaire
- ▶ estimer un modèle statistique (linéaire) avec un logiciel (R) et interpréter les résultats obtenus
- ▶ prendre en compte le risque de toute décision statistique.

Le cours STA201 est un prérequis des cours

- ▶ STA202 (séries chronologiques), dans lequel seront développés les modèles d'observations non indépendantes
- ▶ STA203 (apprentissage statistique), dans lequel seront développés les modèles de régression non linéaires, logistique, ... et la prédiction (↔ machine learning)

$$\text{Note} = (\text{PR} + \text{EX}) / 2$$

- ▶ EX : examen qui pourra comporter des questions théoriques et des questions pratiques d'interprétation de résultats.
- ▶ PR : projet à rendre par binôme

Chargés de TDs : Jérémie Capitao-Miniconi, Olivier Coudray, Guillermo Durand, Zacharie Naulet, Christine Keribin

documents, bibliographie, ... : moodle e-campus

Introduction

Rappels

Modèle

Estimation ponctuelle

Tests

IC

Modéliser l'expérience, c'est proposer une loi théorique pour l'échantillon $X = (X_1, \dots, X_n)$.

- ▶ **Modèle** : $\mathcal{M} = (\mathcal{X}^n, \mathcal{A}^n, \mathcal{P})$
 - ▶ espace mesurable $(\mathcal{X}^n, \mathcal{A}^n)$
 - ▶ muni d'une famille de lois de proba $\mathcal{P} = (\mathbb{P}_\theta^n)_{\theta \in \Theta}$

Quand il existe $d \in \mathbb{N}^*$ tel que $\Theta \subset \mathbb{R}^d$, le modèle est dit *paramétrique*

- ▶ Une **observation** est une variable aléatoire X à valeur dans \mathcal{X}^n et dont la loi appartient à $(\mathbb{P}_\theta^n)_{\theta \in \Theta}$
- ▶ Un **n -échantillon i.i.d.** est une observation $X = (X_1, \dots, X_n)$ de n variables aléatoires de même loi η_θ et indépendantes. Alors, $\mathbb{P}_\theta^n = (\eta_\theta)^{\otimes n}$
- ▶ Les **données** sont les réalisations (valeurs) x_1, \dots, x_n prises par l'échantillon X_1, \dots, X_n

Exemples de modèles (simples)

- ▶ Etude de la moyenne (espérance) d'un temps de trajet :
 $\mathcal{M} = (\mathbb{R}^n, \mathcal{A}^n, \mathbb{P}_\theta^{\otimes n}, \theta \in \Theta)$

$$X_i \sim_{i.i.d.} \mathbb{P}(\mu, \sigma^2)$$

- ▶ Comparaison du rendement de maïs sous deux conditions de culture

$$X \sim \mathcal{N}^{\otimes n}(\mu_x, \sigma_x^2) \text{ et } Y \sim \mathcal{N}^{\otimes m}(\mu_y, \sigma_y^2) \text{ indépendants}$$

- ▶ Estimation d'une proportion par sondage
 $\mathcal{M} = (\{0, 1\}^n, \mathcal{A}^n, \mathbb{B}_\pi^{\otimes n}, \pi \in [0; 1])$

$$X_i \sim_{i.i.d.} \mathcal{B}(1, \pi)$$

Régression linéaire (simple)

$$Y_i|X_i=x_i = \alpha + \beta x_i + \varepsilon_i \text{ où } \varepsilon_i|X=x \sim i.i.d. \mathcal{L}(0, \sigma^2 I_n).$$

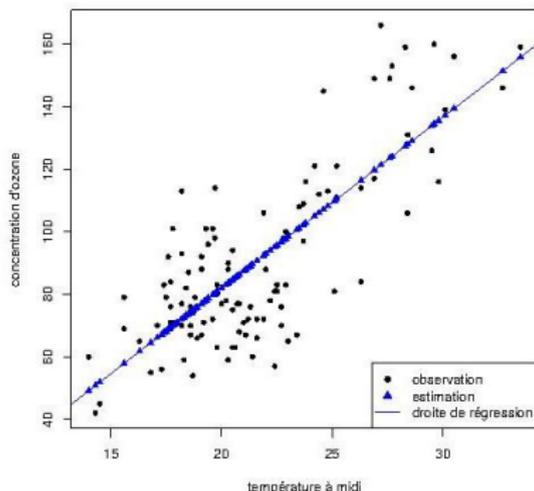


Figure – source des données : Cornillon et Matzner-Løber, 2007

Définition

Un modèle à paramétrage dans Θ est *identifiable* si

$$\forall \theta, \theta' \in \Theta, \mathbf{P}_\theta = \mathbf{P}_{\theta'} \Rightarrow \theta = \theta'$$

A partir des données d'un n -échantillon, déduire -ou inférer- certaines propriétés du modèle inconnu

1. Acquérir et **préparer** les données
2. Définir un **modèle** adapté à la situation observée.
3. **Estimer** les paramètres du modèle grâce aux observations.
4. Vérifier l'**adéquation** de l'estimation aux observations
5. **Choisir** entre des modèles
6. **Utiliser** le modèle à des fins de décision ou de prédiction.

Estimation ponctuelle

Un objet mathématique : l'estimateur

Soit $\theta \in \Theta \in \mathbb{R}$ le paramètre d'une loi \mathbb{P}_θ et soit $X = (X_1, \dots, X_n)$ un n -échantillon issu de cette loi

Définition

Une *statistique* est une *variable aléatoire* T_n , fonction mesurable de l'échantillon et calculable à partir de l'échantillon

$$T_n = t(X_1, \dots, X_n).$$

Un *estimateur* est une statistique utilisée pour estimer un paramètre ou une quantité d'intérêt $\nu(\theta)$

- ▶ Notation $T_n = \hat{\nu}_n$ ou $T_n = \hat{\nu}$.
- ▶ Exemples : estimateur empirique de l'espérance, de la variance

Performance en moyenne

Soit $\hat{\nu}_n$ un estimateur de $\nu(\theta)$, fonction du paramètre d'une loi \mathbb{P}_θ :

- ▶ On appelle **biais** de $\hat{\nu}_n$ pour $\nu(\theta)$ la valeur

$$b_\theta(\hat{\nu}_n) = \mathbb{E}_\theta(\hat{\nu}_n) - \nu(\theta)$$

Si $b_\theta(\hat{\nu}_n) = 0$ pour tout $\theta \in \Theta$, T_n est **sans biais** pour $\nu(\theta)$

- ▶ On appelle **variance** de $\hat{\nu}_n$ la valeur

$$\text{var}_\theta(\hat{\nu}_n) = \mathbb{E}_\theta\left(\left(\hat{\nu}_n - \mathbb{E}_\theta(\hat{\nu}_n)\right)^2\right)$$

- ▶ On appelle **risque quadratique** de $\hat{\nu}_n$ la valeur

$$R_\theta(\hat{\nu}_n) = \mathbb{E}_\theta\left(\left(\hat{\nu}_n - \nu(\theta)\right)^2\right)$$

Décomposition du risque quadratique

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

Définition

Un estimateur δ_1 de $\nu(\theta)$ **domine** l'estimateur δ_2 si, pour tout $\theta \in \Theta$,

$$R_{\theta}(\delta_1) \leq R_{\theta}(\delta_2),$$

cette inégalité étant stricte pour au moins une valeur de θ .

Un estimateur est **admissible** s'il n'existe aucun estimateur le dominant.

- Soit $\theta_0 \in \Theta$. L'estimateur constant $\hat{\nu}_n = \theta_0$ est-il admissible ?

Il n'existe en général pas d'estimateur dominant tous les autres \leftrightarrow Recherche d'estimateurs **UVMB**

Performance asymptotique

Soit $\hat{\nu}_n$ un estimateur de $\nu(\theta)$, défini à partir d'une observation de loi \mathbb{P}_θ :

- ▶ $\hat{\nu}_n$ est **asymptotiquement sans biais** pour $\nu(\theta)$:

$$\forall \theta \in \Theta, \lim_{n \rightarrow \infty} b_\theta(\hat{\nu}_n) = 0$$

- ▶ $\hat{\nu}_n$ est **consistant** : $\hat{\nu}_n$ tend en probabilité vers $\nu(\theta)$ quand $n \rightarrow \infty$:

$$\forall \theta \in \Theta, \forall \epsilon, \lim_{n \rightarrow \infty} \mathbb{P}_\theta(|\hat{\nu}_n - \nu(\theta)| > \epsilon) = 0$$

- ▶ $\hat{\nu}$ est **fortement consistant** ssi

$$\forall \theta \in \Theta, \mathbb{P}_\theta(\lim_{n \rightarrow \infty} \hat{\nu}_n = \nu(\theta)) = 1$$

- ▶ $\hat{\nu}$ est **consistant en moyenne quadratique** :

$$\forall \theta \in \Theta, \lim_{n \rightarrow \infty} R_\theta(\hat{\nu}_n) = 0$$

Vitesse de convergence

Définition

Si un estimateur $\hat{\nu}_n$ de $\nu \in \mathbb{R}^p$ de variance $\text{var}(\hat{\nu}_n) = V_n$ a un comportement asymptotique tel que

$$V_n^{-1/2}(\hat{\nu}_n - \nu) \xrightarrow{\mathcal{L}} \mathcal{N}_p(0, Id_p)$$

on dit que l'estimateur est **asymptotiquement normal**. Si $nV_n \rightarrow V_0$ où $V_0 > 0$ est finie, on dit que la **vitesse** de l'estimateur est en \sqrt{n}

↔ Un estimateur est d'autant meilleur que sa vitesse de convergence est rapide et sa loi limite concentrée autour de 0.

↔ Il existe des estimateurs consistants non asymptotiquement normaux

L'approche **test**

L'approche test : exemple du test de Student

Choisir entre deux hypothèses (H_0) et (H_1), en calibrant le **risque de première espèce** α (5%, 10%,...) de choisir (H_1) à tort

1. Définir le modèle : $X \sim \mathcal{M}$ (par exemple, $\mathcal{N}^{\otimes n}(\mu, \sigma^2)$)
2. Définir les hypothèses
 - ▶ Hypothèse **nulle** (H_0) : $\mu = \mu_0 = 15$
 - ▶ Hypothèse **alternative** (H_1) : $\mu = \mu_1 > \mu_0$
3. Définir une statistique de test T , sa loi sous (H_0),

$$T = \sqrt{n} \frac{\bar{X} - \mu_0}{\hat{\sigma}} \sim \mathcal{T}(n-1)$$

avec $\bar{X} = \sum X_i/n$ et $\hat{\sigma}^2 = \sum (X_i - \bar{X})^2/(n-1)$

L'approche test (suite)

4. Définir la **règle de décision** en calibrant la région de rejet \mathcal{R} suivant le **niveau** α choisi a priori :

$$\delta(T) = \mathbb{1}\{T \in \mathcal{R}\}, \text{ tel que}$$

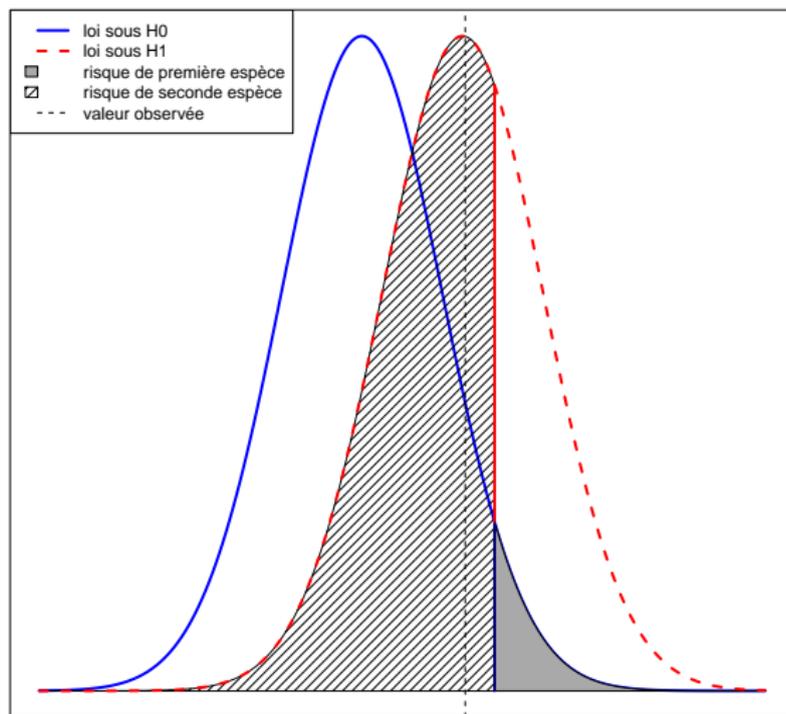
$$\alpha = \mathbb{P}_{(H_0)} \left(\underbrace{T > q_{1-\alpha}^{\mathcal{T}(n-1)}}_{\mathcal{R}: \text{Région de rejet}} \right)$$

5. Décider

- ▶ si T est dans la région de rejet, on **rejette** H_0
- ▶ sinon, on **conserve** (ou **accepte**) (H_0) faute de preuves suffisantes

- ▶ Hypothèse **nulle** (H_0) : $\mu = \mu_0 = 15$
- ▶ Hypothèse **alternative** (H_1) : $\mu = \mu_1 > \mu_0$
- ▶ Risque $\alpha = 0.1$
- ▶ Données observées : $\bar{x} = 16$,
 $s^2 = \sum_{i=1}^6 (x_i - \bar{x})^2 / 5 = 1.6$
- ▶ statistique de test observée : $t_{obs} = 1.88$
- ▶ quantiles : $q_{0.90}^{\mathcal{T}(5)} = 1.48$; $q_{0.95}^{\mathcal{T}(5)} = 2.02$
- ▶ décision ? risque ?

Les risques d'un test



Les risques d'un test

Soit \mathcal{R}_α la région de rejet du test de niveau α .

- ▶ Risque de **1ère espèce** : probabilité de rejeter (H_0) à tort :

$$\theta_0 \in \Theta_0, \alpha(\theta_0) = \mathbb{P}_{\theta_0}(\{T \in \mathcal{R}\})$$

- ▶ Risque de **2nde espèce** : probabilité de conserver (H_0) à tort

$$\theta_1 \in \Theta_1, \beta(\theta_1) = \mathbb{P}_{\theta_1}(\{T \notin \mathcal{R}\}).$$

- ▶ **Puissance du test** : probabilité de refuser (H_0) à raison :

$$\theta_1 \in \Theta_1, \pi(\theta_1) = \mathbb{P}_{\theta_1}(\{T \in \mathcal{R}\}) = 1 - \beta(\theta_1).$$

- ▶ le test est sans biais si $\pi > \alpha$; consistant si $\lim_{n \rightarrow \infty} \pi_n = 1$

Les risques d'un test

A l'issue d'un test, les quatre situations suivantes sont possibles

	Choix (H_0)	Choix (H_1)
(H_0) vraie	$1 - \alpha$ bonne décision	$\alpha = \mathbb{P}(T \in \mathcal{R} (H_0))$ erreur première espèce mauvaise décision
(H_1) vraie	$\beta = \mathbb{P}(T \notin \mathcal{R} (H_1))$ erreur seconde espèce mauvaise décision	$\pi = 1 - \beta$ puissance bonne décision

- ▶ Le rejet de (H_0) assure-t-il que (H_1) est vraie ?
- ▶ L'acceptation de (H_0) assure-t-elle que (H_0) est vraie ?
- ▶ Du point de vue du risque de la décision, est-il préférable de conserver (H_0) ?

p-value

- ▶ C'est le plus petit niveau qui fait rejeter (H_0) au vu des données
- ▶ C'est une variable aléatoire

$$\text{p-value} = \alpha(\omega) = \inf\{\alpha \in [0, 1]; T(\omega) \in \mathcal{R}_\alpha\}$$

Si $\{T_n > q_\alpha\}$ est de niveau α

$$\text{p-value} = \inf\{\alpha \in [0, 1]; T_n(\omega) > q_\alpha\} = \mathbb{P}_{\theta_0}\{T_n > T_n(\omega)\}.$$

Dans un test de niveau α , (H_0) est rejetée si $\alpha > \text{p-value}$, conservée si $\alpha < \text{p-value}$:

- ▶ si $0.05 > \text{p-value} > 0.01$, le test est significatif,
- ▶ si $0.01 > \text{p-value} > 0.001$, le test est très significatif,
- ▶ si $0.001 > \text{p-value}$, le test est hautement significatif.

- ▶ Hypothèse **nulle** (H_0) : $\mu = \mu_0 = 15$
- ▶ Hypothèse **alternative** (H_1) : $\mu = \mu_1 > \mu_0$
- ▶ Risque $\alpha = 0.1$
- ▶ Données observées : $\bar{x} = 16$,
 $s^2 = \sum_{i=1}^6 (x_i - \bar{x})^2 / 5 = 1.6$
- ▶ statistique de test observée : $t_{obs} = 1.88$
- ▶ quantiles : $q_{0.90}^{\mathcal{T}(5)} = 1.48$; $q_{0.95}^{\mathcal{T}(5)} = 2.02$
- ▶ décision ? risque ?

p-value = 0.059

L'approche test : région de rejet bilatérale

1. Même modèle que précédemment
2. $(H_0) : \mu = \mu_0$ contre $(H_1) : \mu \neq \mu_0$
3. statistique de test :

$$T = \sqrt{n} \frac{\bar{X} - \mu_0}{\hat{\sigma}} \underset{(H_0)}{\sim} \mathcal{T}(n-1)$$

4. Région de rejet

$$\alpha = \mathbb{P}_{(H_0)} \left(\underbrace{|T| > q_{1-\alpha/2}^{\mathcal{T}(n-1)}}_{\mathcal{R}: \text{Région de rejet}} \right)$$

Estimation par intervalle de confiance

L'approche Intervalle de confiance

Sous les mêmes hypothèses que précédemment, on peut aussi écrire, avec $q = q_{1-\alpha/2}^{\mathcal{T}(n-1)}$

$$1 - \alpha = \mathbb{P}_{(H_0)}\left(\bar{X} - q \frac{\hat{\sigma}}{\sqrt{n}} < \mu < \bar{X} + q \frac{\hat{\sigma}}{\sqrt{n}}\right) = \mathbb{P}_{(H_0)}(IC \ni \mu)$$

Définition

Soit $X = (X_1, \dots, X_n)$ un n -échantillon de loi \mathbb{P}_θ . Un **intervalle de confiance** de **niveau** $1 - \alpha$ pour $\theta \in \mathbb{R}$ est un intervalle $IC = [\hat{\theta}_{inf}(X), \hat{\theta}_{sup}(X)]$ dont les bornes sont **aléatoires**, telles que, pour tout $\theta \in \Theta$

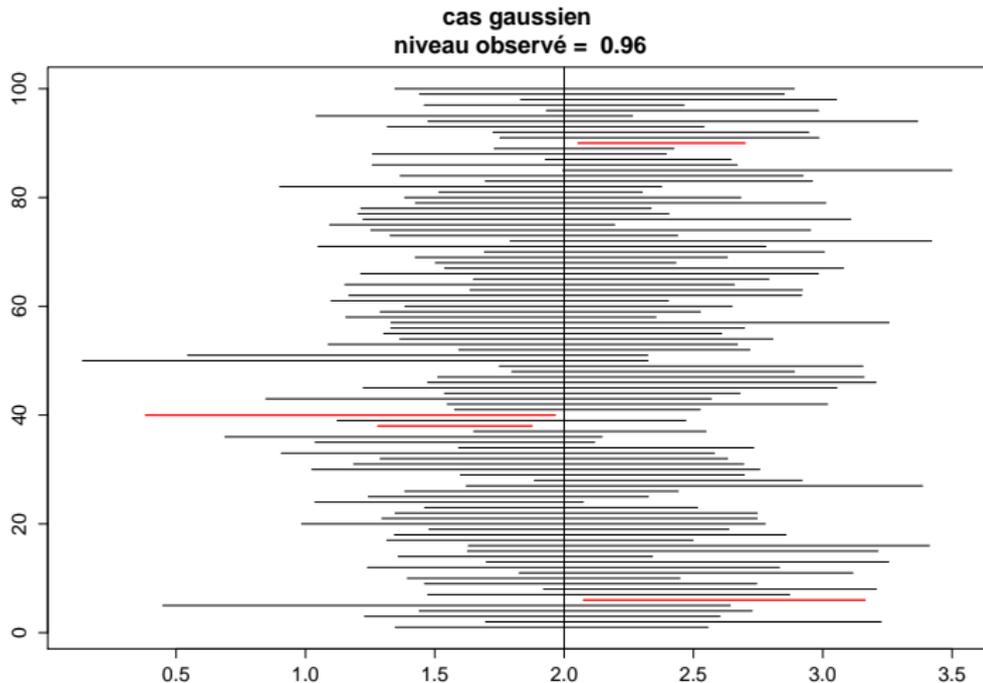
$$P_\theta(IC \ni \theta) \geq 1 - \alpha.$$

où α est "petit".

Une réalisation $[\hat{\theta}_{inf}(x), \hat{\theta}_{sup}(x)]$ est obtenue à partir des données $x = (x_1, \dots, x_n)$.

L'approche Intervalle de confiance (suite)

Fournir un **intervalle** (**fourchette**) permet de prendre en compte la fluctuation d'échantillonnage plutôt que de donner une valeur ponctuelle $\hat{\theta}$



ICs et tests paramétriques classiques

- ▶ Test de Student de l'espérance d'une loi (ou test de la moyenne)
- ▶ Test de la variance d'une loi gaussienne
- ▶ Test de comparaison des espérances de deux lois gaussiennes
 - ▶ avec même variance
 - ▶ avec variance différents
 - ▶ cas des échantillons appariés
- ▶ Test de comparaison des variances de deux lois gaussiennes
- ▶ Test sur le paramètre de proportion d'une loi de Bernoulli
- ▶ Test de comparaison des paramètres de deux lois de Bernoulli

Remarque : tests non paramétriques : adéquation à une loi, indépendance