

Statistique inférentielle et estimation de paramètre

- L'estimation

En stat descriptive le point de départ, ce sont des données x_1, \dots, x_n

On en fait des graphiques, ou des indicateurs statistiques

Mais on ne se préoccupe pas du modèle probabiliste sous-jacent à ces données

En stat inférentielle, on va au contraire chercher à caractériser le modèle probabiliste associé

On va plus exactement chercher la loi de probabilité P telle que les données x_1, \dots, x_n sont des réalisations indépendantes d'une v.a de loi P

$$x_1, \dots, x_n \rightarrow P$$

1° idée : on cherche P parmi toutes les lois de probabilités qui existent

➔ P_b : la famille est infinie : le pb est très difficile, le cadre non paramétrique

2° idée : on cherche P au sein d'une famille restreinte de la loi de proba, et cette famille est caractérisée par un paramètre

$$P \in \{P_\theta, \theta \in \Theta\}$$

Ex :

- on peut se restreindre à la famille des lois exponentielles :

$$\{P_\theta, \theta \in \Theta\} = \{\mathcal{E}(\theta), \theta > 0\}$$

- on peut se restreindre au cadre des lois normales

$$\{P_\theta, \theta \in \Theta\} = \{\mathcal{N}(n, \sigma^2), (n, \sigma^2) \in \mathbb{R} * \mathbb{R}^2_x\}$$

➔ cadre paramétrique (beaucoup plus simple)

$$(x_1, \dots, x_n) \rightarrow \theta$$

Remarque : en général, $\theta \in \mathbb{R}^p$

Déterminer θ revient à faire de l'estimation

2 manières :

- estimation partielle : à partir d'un jeu de données, on va fournir une valeur approchée de θ . Cette valeur sera notée $\hat{\theta}$
- estimation par intervalle de confiance : à partir d'un jeu de données, on fournit un intervalle dans lequel θ a α % de chance d'être réellement

I. Estimation ponctuelle

Qu'est-ce qu'un estimateur et qu'est-ce qu'une estimation ?

- Un estimateur est une v.a, autrement dit une fonction
- Une estimation est la valeur de l'estimation sur un point

Ex : on souhaite connaître l'opinion politique quand au président

→ Un sondage

On note A l'ensemble des personnes favorables au président

$$X(w) \begin{cases} 0 & \text{si } w \notin A \\ 1 & \text{si } w \in A \end{cases} \text{ avec } w \text{ une personne}$$

→ La loi de X, notée P, appartient à la famille des lois de Bernouilli

$$P \in \{B(p), p \in [0, 1]\}$$

Pb : estimer le paramètre p de la loi

On dispose pour cela d'observation x_1, \dots, x_n qui sont des réalisations des v.a X_1, \dots, X_n où X_1, \dots, X_n sont des v.a indépendantes et de même type que X

Remarque : $P = P(X = 1) = P(A)$

P peut être approché par $\frac{1}{n} * \underbrace{\sum_{i=1}^n x_i}_{\text{une observation}}$

→ Un estimateur \hat{p} de p est donnée par

$$\hat{p} = \frac{1}{n} * \sum_{i=1}^n X_i \rightarrow \text{estimateur}$$

Un estimateur de θ est une fonction T_n définie sur E^n à calculer dans F qui à un échantillon (X_1, \dots, X_n) de la loi P_θ associe $T_n(X_1, \dots, X_n)$ une v.a dont on peut connaître la loi

Remarque : $E = X(\Omega)$ $F = \Theta$

Remarque : Si $\theta = E[X]$

Un estimateur évident de θ , obtenu par la loi des grands nombres, est

$$\theta^n = \sum_{i=1}^n X_i = \bar{X}_n$$

Si $\theta = V[X]$

Un estimateur évident est $\frac{1}{n} * \sum_{i=1}^n (X_i - \bar{X}_n)^2$

Mais, on n'a pas toujours $\theta = E[X]$ ou $\theta = V[X]$

Comment faire alors ?

2 méthodes :

- Méthode des moments
- Méthode du maximum de vraisemblance

a) Méthode des « moments »

Rappel :

Soit $k \in \mathbb{N}^*$ et X une v.a

Le moment d'ordre k de X est $m_k(X) = E[X^k]$

Le moment centré d'ordre k de X est $\mu_k(X) = E[(X - E[X])^k]$

La version empirique de ces moments est respectivement

$$\hat{m}_k(X) = \frac{1}{n} * \sum_{i=1}^n X_i^k \quad \text{et} \quad \hat{\mu}_k(X) = \frac{1}{n} * \sum_{i=1}^n (X_i - \bar{X}_n)^k$$

Sous l'hypothèse que $X \sim P_\theta$, alors $m_k(X)$ est une fonction de θ , de même que $\mu_k(X)$

$$\rightarrow m_k(X) = m_k(\theta) \quad \text{et} \quad \mu_k(X) = \mu_k(\theta)$$

Principe de la méthode

On cherche le paramètre valeur de k , notre k , pour laquelle $m_k(\theta)$ (ou $\mu_k(\theta)$) dépend réellement de θ

On résout l'équation en θ

$$m_k(\theta) = \frac{1}{n} * \sum_{i=1}^n X_i^k \quad \text{ou} \quad \mu_k(\theta) = \frac{1}{n} * \sum_{i=1}^n (X_i - \bar{X}_n)^k$$

Remarque : généralisation

S'il existe 2 fonction f et g tel que

$$g(\theta) = E[f(X)]$$

$$\hat{\theta} \text{ estimateur de } \theta \text{ est solution de } g(\hat{\theta}) = \frac{1}{n} * \sum_{i=1}^n f(X_i)$$

Ex : X_1, \dots, X_n des v.a indépendante et de même loi que X avec $X \sim \mathcal{E}(\theta)$ avec θ inconnue ($\theta > 0$)

On sait que $E[X] = \frac{1}{\theta}$

Par la méthode des moments, on sait qu'un estimateur $\hat{\theta}$ de θ est solution de

$$\frac{1}{\hat{\theta}} = \frac{1}{n} * \sum_{i=1}^n x_i \rightarrow \hat{\theta} = \frac{n}{\sum_{i=1}^n X_n} = \frac{1}{\bar{X}_n}$$

Remarque : On sait que $V[X] = 1/\theta^2$

Un estimateur de $\hat{\theta}_k$ de θ est donc solution de

$$\frac{1}{\hat{\theta}_2^2} = \frac{1}{n} * \sum_{i=1}^n (X_i - \bar{X}_n)^2 \rightarrow \hat{\theta}_2 = \sqrt{\frac{n}{\sum (X_i - \bar{X}_n)^2}}$$

b) la méthode des maximums de vraisemblance

idée : la vraisemblance $L(\theta, X_1, \dots, X_n)$ est la probabilité d'observé, à θ fini, le n couplet (X_1, \dots, X_n)

Dans notre situation, on connaît (X_1, \dots, X_n) et on cherche la valeur de θ la plus probable

La valeur de θ cherché est approché par la valeur de $\hat{\theta}$ qui maximise, à (X_1, \dots, X_n) fixé, la vraisemblance

Principe des maux de vraisemblance

Soit X une v.a de la loi P_θ

Soit (X_1, \dots, X_n) un n échantillon de même loi que X

Un estimateur $\hat{\theta}$, par la méthode des maux de vraisemblance, est tel que

$$L(\hat{\theta}, X_1, \dots, X_n) = \max L(\theta, X_1, \dots, X_n)$$

Def : soit (X_1, \dots, X_n) un échantillon de loi P

$$L(\theta, X_1, \dots, X_n) = \begin{cases} P(X_i = x_i) \text{ et } P(X_n = x_n) \text{ si } P \text{ est une loi droite} \\ f(x_1)xf(x_n) \text{ si } P \text{ est une loi continue (f fonction de droite associé)} \end{cases}$$