

Chap: Introduction: échantillonnage

Donnés: X_1, \dots, X_n : iid (indép de m loi) \Rightarrow échantillon

\rightarrow but: estimer la loi de X

- Types de statistiques:

1) Stat paramétrique

\rightarrow supposer que seulement un ou des paramètres $\theta \in (\mathbb{R}^d) \subseteq \mathbb{R}^d$ que sont connus de la loi (ex: μ, σ^2) (il s'agit de types connus).

(Par exemple la loi de X Bernoulli $B(1, p)$ ou G inconnu)

2) Stat non paramétrique

but: la loi est connue (à estimer)

3. Fonction de vraisemblance

= loi de (X_1, \dots, X_n)

$f(x_1, \dots, x_n)$
 \downarrow
Labels: x_i

si indép

$P(X_1=x_1, \dots, X_n=x_n)$, on les loi est discrète
 $f(x_1, \dots, x_n)$, \rightarrow loi continue

si indép

$$= \prod_{i=1}^n P(X_i = x_i)$$

Log - vraisemblance

log d (x_1, \dots, x_n)

ex: $X_i \sim B(p)$

est fait

$$l(x_1, \dots, x_n) = \prod_{i=1}^n P(X_i = x_i)$$
$$= \begin{cases} p^{\sum x_i} (1-p)^{n-\sum x_i} \\ = p^{\sum x_i} (1-p)^{n-\sum x_i} \end{cases}$$

I. Une - statistique - Un estimateur

Une stat st une fct de (X_i) (mais pas de paramètres θ)

peut se: $S(x_1, \dots, x_n) = \begin{cases} x_1 - x_n \\ e^{x_1} \cos(x_2 x_3) \end{cases}$

Un estimateur : T est un stat θ (1) (fon de valeurs ce paramètre)

ex: $(X_i) \sim B(\theta)$, $X_1 + X_2 + \dots + X_n$ est un stat

$\frac{X_1 + X_2 + \dots + X_n}{n}$ est un estimateur de θ (CB(1))

c'est un V.I. (fon de (X_i))

III. Statistique exhaustive (ou "suffisante")

Par def: Une stat $T(X_1, \dots, X_n)$ est exhaustive pour θ sachant $T(X_1, \dots, X_n)$ ne dépend pas de θ

cad: $P(X_1, \dots, X_n | T=t)$ ne dépend pas de θ

\Rightarrow (T contient toute l'information sur θ)
 ex: $T = \sum_{i=1}^n X_i$, $T = \prod X_i$, $T = \text{schwaiss}$
 \Rightarrow résument l'échantillon par la connaissance de θ
 réduisent la dimension

ex: $P_i \sim B(\theta)$, $X_i \sim B(\theta)$

mg: $T = \sum_{i=1}^n X_i$ est un stat. exhaustive pour θ ?

$$d(x_1, \dots, x_n | \sum_{i=1}^n X_i = t) = P(X_1 = x_1, \dots, X_n = x_n | \sum_{i=1}^n X_i = t)$$

$$= \frac{P(X_1 = x_1, \dots, X_n = x_n, \sum_{i=1}^n X_i = t)}{P(\sum_{i=1}^n X_i = t)}$$

$$= \frac{P(X_1 = x_1, \dots, X_n = x_n) \cdot \mathbb{1}_{\sum_{i=1}^n x_i = t}}{P(\sum_{i=1}^n X_i = t)}$$

$\sum_{i=1}^n X_i$ est de loi binom $B(n, \theta)$

$$\Rightarrow P(\sum_{i=1}^n X_i = t) = C_n^t \theta^t (1-\theta)^{n-t}$$

$$= d(x_1, \dots, x_n | \sum_{i=1}^n X_i = t) = \frac{\theta^t (1-\theta)^{n-t} \mathbb{1}_{\sum x_i = t}}{C_n^t \theta^t (1-\theta)^{n-t}}$$

$= \frac{\mathbb{1}_{\sum_{i=1}^n x_i = t}}{C_n^t} \Rightarrow (\sum_{i=1}^n X_i)$ est un stat exhaustive pour θ
 = le nb ou la proportion de p les est suffisant pour θ

Def: Une stat exhaustive T est minimale si la stat exhaustive S est fct de T . ($S = g(T)$)

Ex: trouver une stat. sch. min
 → difficile, mais possible pour une classe de loi. La famille exponentielle
 est peut-être la plus facile de x.

loi de $X_i = e^{-\langle a(\theta), \phi(x) \rangle + b(\theta) + c(x)}$
 où $\phi(x)$ est la fonction

Exemple: Si $X_i \sim \text{Exp}(\theta)$
 $f_{X_i}(x) = \theta e^{-\theta x} \mathbb{1}_{x>0} = e^{-\theta x + \log(\theta)} \mathbb{1}_{x>0}$ si $\theta = \lambda$
 $= e^{-\lambda(x) + b(\lambda)}$

Ex 2: $X_i \sim B(\theta)$
 $P(X_i = x) = \binom{n}{x} \theta^x (1-\theta)^{n-x}$
 $= e^{x \log \theta + (n-x) \log(1-\theta)}$
 $= e^{x \log(\theta) - \log(1-\theta)} + \log(1-\theta)$

Ex. lois binom, multin, ...

Théorème: Si famille exponentielle, alors $\sum_{i=1}^n \phi(x_i)$ est une stat. exhaustive minimale pour θ .
 (soit le modèle exponentiel)

Ex: $X_i \sim B(\theta)$, on a trouvé $\phi(x) = x$ ⇒ $\sum_{i=1}^n X_i$ est une stat. sch. min
 famille exponentielle → $\sum_{i=1}^n \phi(x_i)$ est une stat. exhaustive minimale pour θ

Plus généralement:

Une stat $T(x_1, \dots, x_n)$ est exhaustive ssi: \exists fct g et h telles que
 $\int_{(x_1, \dots, x_n)} p(\theta; x_1, \dots, x_n) = g(\theta; T(x_1, \dots, x_n)) \cdot h(x_1, \dots, x_n)$ (Thm de factorisation)
 "Suffisance" ⇒ dérivé de (x_1, \dots, x_n)
 Sachant $T(x_1, \dots, x_n)$