

Université de Strasbourg
UFR de Mathématiques et d'Informatique
Han-Ping LI

Année 2018/2019
Statistique
Etude de cas L3

Chapitre 1

Notions statistiques

1.1 Variables aléatoires

Variables aléatoires : notions mathématiques utilisées pour modéliser les phénomènes complexes :

- Impossible de prédire sa valeur exacte
- Possible d'avancer des propositions probabilistes sur ses valeurs

Exemple 1

$n = 20$ réalisations d'une variable aléatoire X de loi de Bernoulli $B(1, p)$ avec $p = 0.3$:

0, 0, 0, 1, 1, 1, 0, 1, 0, 1, 1, 0, 0, 0, 0, 0, 1, 0, 0

Exemple 2



n= 20 réalisations d'une variable aléatoire X de loi binomiale $B(5, p)$ avec $p = 0.3$:

1, 3, 0, 2, 2, 2, 1, 1, 2, 1, 1, 1, 0, 1, 1, 3, 3, 3, 1, 2

n=10000 réalisations d'une v. a. X de la loi binomiale $B(5, 0.3)$:

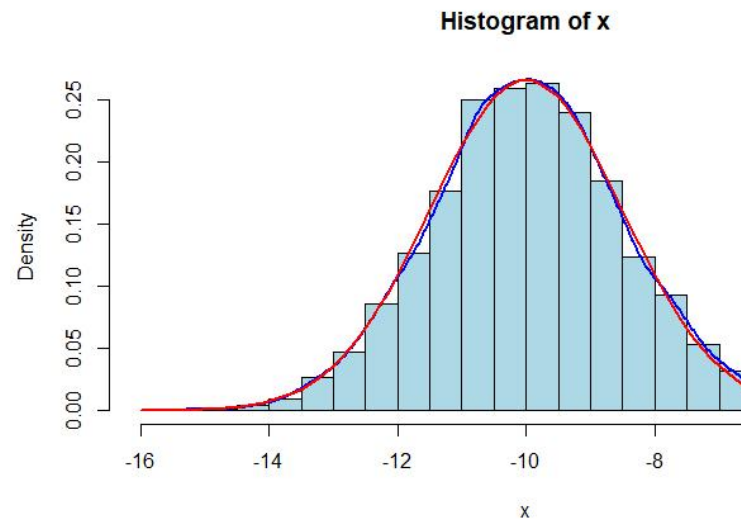
TABLE 1.1 – Proportion

X	0	1	2	3	4	5
proportion	0.1628	0.3654	0.3099	0.1302	0.0294	0.0023
probabilité	0.16807	0.36015	0.30870	0.13230	0.02835	0.00243



Exemple 3


5000 réalisations d'une variable aléatoire X de loi gaus-



sienne $N(\mu, \sigma^2)$ avec $\mu = -10, \sigma = 1.5$:

Exemple 4

On s'intéresse à la largeur des anneaux de croissance des arbres. le fichier "treering" dans la librairie "data-sets" avec $N = 7980$.



On prélève au hasard une valeur X dans cet ensemble de 7980 valeurs : $x = 1.004$.

Rem On note souvent X ou (Y) une variable aléatoire et x (ou y une des ses réalisations. (souvent une infinité!)

1.2 Modélisation statistique :

Modéliser, c'est structurer et simplifier, choisir quoi identifier et quoi différencier, ce qui est important et ce qui est accessoire, relier entre eux les évènements.

Population : l'ensemble des individus dont une ou plusieurs variables sont prises en considération dans l'étude.

La répartition des valeurs d'une variable est associée à une loi de probabilité :

$$\text{Population} \iff \mathbb{P}_\theta, (\theta \in \Theta)$$

Attention : un sous-ensemble de n individus ne peut pas être "représentatif" de la population ($n \ll N$).

Echantillon \iff n individus choisis au hasard dans la population. X_1, \dots, X_n n variables aléatoires indép. de même loi.

Exemples :

1. On prélève 3 boules dans une urne contenant 7 de valeurs $5^{-1}, 10^{-1}, \dots, 5^5$ euros.

Avec remise : $7^3 (=343)$

Sans remise : `choose(7,3) (=56)`

`L= 5-1:5`

`L=1 :7 ; combn(L, 3)`


`for (i in 1 :10){ print (sample(L, 3, replace=T))}`

2. les résultats après avoir lancé un dé $n = 20$ fois.

`sample(6, 20, replace=T)`

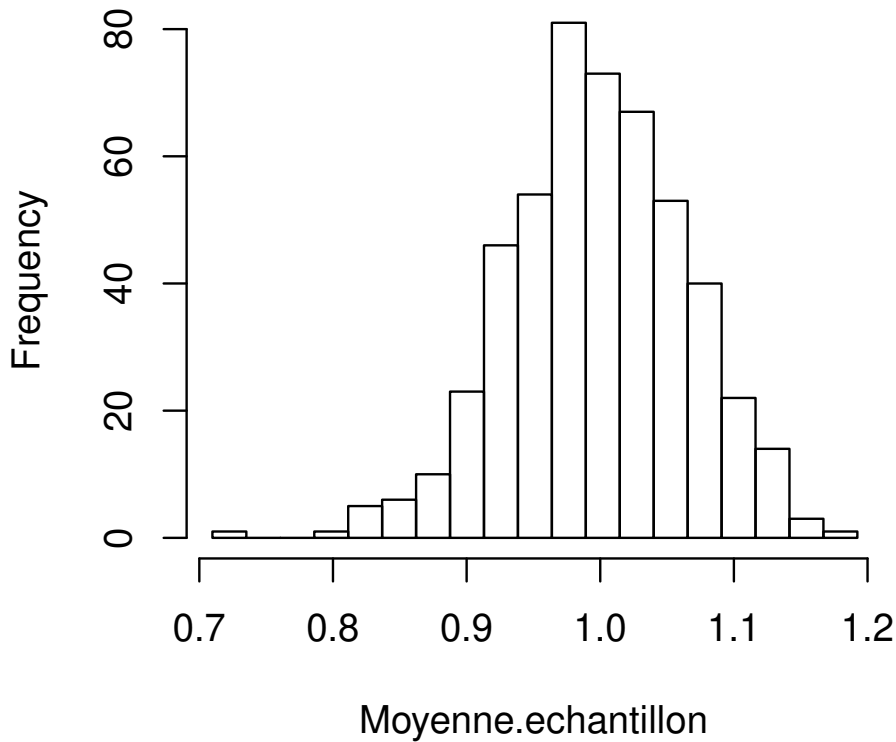
3. les poids de $n = 10$ étudiants choisis au hasard en France

4. On s'intéresse à la largeur des anneaux de croissance des arbres. le fichier "treering" dans la librairie "data-sets" avec $n = 7980$.



On simule $M=500$ réalisations d'un échantillon de taille $n=20$ et on constate

Histogram of Moyenne.echantillon



Données : x_1, \dots, x_n

Modèle : $\mathbf{x} = (x_1, \dots, x_n)$ une réalisation d'un échantillon

$\mathbf{X} = (X_1, \dots, X_n)$ (n v.a. i.i.d.) de loi $\mathbb{P}_\theta, \theta \in \Theta$ paramètre inconnu.

Paramètres

Paramètres de position : nombre autour duquel se re-

partissent les valeurs.

- Espérance de la variable X sous la loi \mathbb{P}_θ que on appelle aussi la moyenne théorique :

$$\mu = \mathbb{E}_\theta(X) = \begin{cases} \sum_k x_k \mathbb{P}_\theta(X = x_k) & \text{cas discret} \\ \int_{-\infty}^{\infty} x f_\theta(x) dx & \text{cas absolument continu} \end{cases}$$

- Médiane de la variable X sous la loi \mathbb{P}_θ que on appelle aussi la médiane théorique :

$$m_\theta = \mathbf{M} \mathbf{d} \mathbf{i} \mathbf{a} \mathbf{n} \mathbf{e}_\theta(X) \text{ t. q. } \mathbb{P}_\theta(X \leq m_\theta) \geq \frac{1}{2} \text{ et } \mathbb{P}_\theta(X \geq m_\theta) \geq \frac{1}{2}$$

.

Paramètres de dispersion : nombre indiquant le degré d'éparpillement des valeurs.

- Variance de la variable X sous la loi \mathbb{P}_θ que on appelle aussi la variance théorique (l'écart-type, resp.) :

$$\sigma^2 = \mathbb{V} \mathbf{a} \mathbf{r}_\theta(X) = \mathbb{E}_\theta(X - \mu)^2, \quad \sigma = \sqrt{\mathbb{V} \mathbf{a} \mathbf{r}_\theta(X)}$$

- écart-type de la variable X

$$\sigma = \sqrt{\text{Var}_\theta(X)}.$$

Paramètre de forme Paramètre d'asymétrie :

$$\gamma_1 = \frac{\mathbb{E}_\theta(X - \mu)^3}{\sigma^3}$$

Si $\gamma_1 < 0 \implies$ étalée vers gauche

Si $\gamma_1 > 0 \implies$ étalée vers droite

Rem Il est important de différencier trois sortes de grandeurs :

1) Grandeurs théoriques : ce sont des paramètres dépendant de la loi \mathbb{P}_θ donc inconnues, par exemple :

$$\mu = \mathbb{E}_\theta(X), \mathbf{Mdiane}_\theta(X), \sigma^2 = \text{Var}_\theta(X) \text{ et } \text{skewness}(X).$$

2) Grandeurs d'échantillon : v.a. calculées à partir de l'échantillon $\mathbf{X} = (X_1, \dots, X_n)$. Ce sont des Statistiques (v.a.) . Par exemple :

- La moyenne de l'échantillon

$$\bar{X} = \frac{1}{n} \sum_{j=1}^n X_j.$$

- La médiane de l'échantillon

On note $X_{(1)} = \min_{1 \leq j \leq n} (X_j)$, $X_{(2)} = \min_{1 \leq j \leq n, j \neq (1)} (X_j) \dots$, $X_{(n)} = \max_{1 \leq j \leq n} (X_j)$

$$\text{mediane}(X) = \begin{cases} X_{\left(\frac{n+1}{2}\right)} & \text{si } n \text{ est impair} \\ \frac{X_{\left(\frac{n}{2}\right)} + X_{\left(\frac{n}{2}+1\right)}}{2} & \text{si } n \text{ est pair} \end{cases}$$

- La variance (corrigée) de l'échantillon,

$$S_c^2 = \frac{1}{n-1} \sum_{j=1}^n (X_j - \bar{X})^2.$$

- L'écart-type (corrigé)

$$S_c = \sqrt{S_c^2}$$

$$\frac{\sum_{j=1}^n (X_j - \bar{X})^3 / n}{(S_c)^3}.$$

3) Grandeurs observés : calculées à partir des observations $\mathbf{x} = (x_1, \dots, x_n)$. Ce sont des réalisations des Statistiques. Par exemple :

$$\bar{x} = \frac{1}{n} \sum_{j=1}^n x_j, \quad s_c^2 = \frac{1}{n-1} \sum_{j=1}^n (x_j - \bar{x})^2, \quad \dots$$

Propriétés

Soit $\mathbf{X} = (X_1, \dots, X_n)$ un échantillon aléatoire de taille n provenant d'une population $f(x)$ avec variance finie σ^2 . Alors,

$$\mathbb{E}_\theta(\bar{X}) = \mu, \quad \text{Var}_\theta(\bar{X}) = \frac{\sigma^2}{n};$$

$$\mathbb{E}_\theta(S_c^2) = \sigma^2.$$

Propriétés au cas d'un échantillon normal

Soit $\mathbf{X} = (X_1, \dots, X_n)$ un échantillon provenant d'une population $\mathcal{N}(\mu, \sigma^2)$. Alors,

- a. \bar{X} et S_n^2 sont indépendantes.
- b. \bar{X} suit une loi $\mathcal{N}(\mu, \frac{\sigma^2}{n})$
- c. $\frac{(n-1)S_c^2}{\sigma^2}$ suit une loi de khi-deux à $(n-1)$ degré de liberté $\chi_{(n-1)}^2$.
- d. $\frac{\sqrt{n}(\bar{X} - \mu)}{S_c}$ suit une loi de Student à $(n-1)$ degré

de liberté.

1.3 Inférences

Objectifs généraux : Extraire d'informations essentielles contenues dans des données ayant des éléments inconnus et intrinsèquement imprévisibles et les interpréter. On s'intéresse par exemple aux Estimations, aux tests, aux vérifications de modèle.

- *Estimer* au mieux θ
- *Tester* l'hypothèse nulle $\mathbf{H}_0 : \theta \in \Theta_0$ contre $\mathbf{H}_1 : \theta \in \Theta_1$
- *Vérifier* le modèle :
existe-t-il un $\theta^* \in \Theta$, tel que \mathbb{P}_{θ^*} modélise bien les données?

Statistique (statistic) : Une statistique $T(\mathbf{X})$ est une fonction de l'échantillon, qui ne doit contenir aucun paramètre inconnu. Comme un échantillon est n variables aléatoires, une statistique, elle aussi, est une variable aléatoire.

Chapitre 2

Estimations

On estime un paramètre θ en utilisant une fonction de l'échantillon bien choisie : une "bonne" statistique $T(\mathbf{X})$.

2.1 critère

Critères pour choisir les estimateurs :

- Biais de l'estimateur : $b(\theta) = \mathbb{E}_\theta(T(\mathbf{X})) - \theta$

$T(\mathbf{X})$ est dit sans biais si $b(\theta) = 0 \forall \theta \in \Theta$

- Erreur quadratique $\mathbb{E}_\theta(T(\mathbf{X}) - \theta)^2 = \text{Var}_\theta(T(\mathbf{X})) + b(\theta)^2$

l' estimateur des Erreurs quadratiques uniformément les plus petites

parmi les estimateurs sans biais :

\implies sans biais de variances unit minimales

- Vitesse de convergence $(T(\mathbf{X}) - \theta) \longrightarrow 0.$

2.2 Méthode du maximum de vraisemblance

La méthode du maximum de vraisemblance est la technique la plus populaire pour obtenir des estimateurs, souvent les meilleures dans les cas classiques.

Exemple 1 : loi de Bernoulli

Un frère dispute d'un précieux tableau à sa soeur. La soeur propose d'utiliser la lancer d'une pièce pour désigner l'heureux héritier.

X une variable aléatoire de loi de Bernoulli $B(1, p)$

$$\mathbf{P}(X = k) = p^k(1 - p)^{1-k}, \quad k \in \{0, 1\}.$$

Soit (x_1, \dots, x_n) une réalisation d'un échantillon (X_1, \dots, X_n) de loi de Bernoulli.


$$\begin{aligned} & \mathbf{P}(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n) \\ &= \mathbf{P}(X_1 = x_1)\mathbf{P}(X_2 = x_2) \cdots \mathbf{P}(X_n = x_n) \\ &= p^{x_1}(1 - p)^{1-x_1}p^{x_2}(1 - p)^{1-x_2} \cdots p^{x_n}(1 - p)^{1-x_n} \\ &= p^{\sum_{j=1}^n x_j}(1 - p)^{n - \sum_{j=1}^n x_j}. \end{aligned}$$

donc $\mathbf{P}(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n) = p^{\sum_{j=1}^n x_j}(1 - p)^{n - \sum_{j=1}^n x_j}$.

Cette dernière quantité est une fonction de p , appelée fonction de vraisemblance $L(p|x_1, \dots, x_n)$:

$$L(p|x_1, \dots, x_n) = p^{\sum_{j=1}^n x_j}(1 - p)^{n - \sum_{j=1}^n x_j}.$$

avec le graphique suivant :



Si on étudie son logarithme :

$$l(p|x_1, \dots, x_n) = \log L = \sum_{j=1}^n x_j \log(p) + (n - \sum_{j=1}^n x_j) \log(1-p).$$

$$\frac{\partial}{\partial p} l(p|x_1, \dots, x_n) = 0 \implies p = \frac{1}{n} \sum_{j=1}^n x_j \implies \hat{p} = \bar{X} = \frac{1}{n} \sum_{j=1}^n X_j.$$

$$\text{Comme } \frac{\partial^2}{\partial p^2} l(p|x_1, \dots, x_n) = -\frac{\sum_{j=1}^n X_j}{p} - \frac{n - \sum_{j=1}^n X_j}{1-p}$$

$$\implies \frac{\partial^2}{\partial p^2} l(\hat{p}|x_1, \dots, x_n) = -\frac{\sum_{j=1}^n X_j}{\hat{p}} - \frac{n - \sum_{j=1}^n X_j}{1-\hat{p}} = -2n < 0.$$

Rappels :

Lorsque les lois de probabilités sont discrètes, on a

$$\mathbf{P}(X_i = x_i) = \mathbf{P}_\theta(x_i).$$

Par contre, si les lois sont absolument continues, on a

$$\mathbf{P}(a < X_i \leq b) = \int_a^b f_\theta(x) dx .$$

La fonction de **vraisemblance** est définie par

$$\theta \longrightarrow L(\theta|\mathbf{x}) = L(\theta|x_1, \dots, x_n)$$

$$\text{où } \begin{cases} L(\theta|x_1, \dots, x_n) = \prod_{j=1}^n \mathbf{P}_\theta(x_j) & \text{si discret} \\ L(\theta|x_1, \dots, x_n) = \prod_{j=1}^n f_\theta(x_j) & \text{si absolument continu} \end{cases}$$

On introduit donc estimateur du maximum de vraisemblance comme la fonction de \mathbf{X} (l'échantillon) tel que

$$\hat{\theta}(\mathbf{x}) = \text{Argmax}_{\theta \in \Theta} L(\theta|\mathbf{x}), \quad \forall \mathbf{x}$$

ou de manière équivalente :

$$\hat{\theta}(\mathbf{x}) = \text{Argmax}_{\theta \in \Theta} l(\theta|\mathbf{x}), \quad \forall \mathbf{x}$$

Exemple 2 : loi de Poisson

Soit (x_1, \dots, x_n) une réalisation d'un échantillon (X_1, \dots, X_n) de loi de Poisson $P(\lambda)$. On a

$$\mathbf{P}(X = x_j) = \frac{\lambda^{x_j}}{x_j!} \exp(-\lambda) \implies$$

$$L(\lambda|x_1, \dots, x_n) = \frac{\lambda^{\sum_{j=1}^n x_j}}{\prod_{j=1}^n x_j!} \exp(-n\lambda)$$

$$l(\lambda|x_1, \dots, x_n) = \left(\sum_{j=1}^n x_j \right) \log(\lambda) - \sum_{j=1}^n \log(x_j!) - n\lambda$$

$$\frac{\partial}{\partial \lambda} l(\lambda|x_1, \dots, x_n) = \frac{\left(\sum_{j=1}^n x_j \right)}{\lambda} - 0 - n.$$

L'équation $\frac{\partial}{\partial \lambda} l(\lambda|x_1, \dots, x_n) = 0 \implies \lambda(\mathbf{x}) = \frac{1}{n} \sum_{j=1}^n x_j, \forall \mathbf{x}$

Comme $\frac{\partial^2}{\partial \lambda^2} l(\lambda|x_1, \dots, x_n) = -\frac{\left(\sum_{j=1}^n x_j \right)}{\lambda^2} < 0, \forall \lambda$

On en déduit $\hat{\lambda}_{MV} = \bar{X} = \frac{1}{n} \sum_{j=1}^n X_j.$

Exemple 3 : loi gaussienne

Soit (x_1, \dots, x_n) une réalisation d'un échantillon (X_1, \dots, X_n) de loi gaussienne $N(\mu, \sigma^2)$.

Si on note $v = \sigma^2$, on a alors

$$\mathbf{P}(a < X \leq b) = \int_a^b \frac{1}{2\pi\sqrt{v}} \exp\left(-\frac{1}{2v}(t - \mu)^2\right) dt$$

$$L(\theta|x_1, \dots, x_n) = \frac{1}{(2\pi)^{n/2}v^{n/2}} \exp\left(-\frac{1}{2v} \sum_{j=1}^n (x_j - \mu)^2\right)$$

$$l(\theta|x_1, \dots, x_n) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(v) - \frac{1}{2v} \sum_{j=1}^n (x_j - \mu)^2$$

$$\frac{\partial}{\partial \mu} l((\mu, v)|x_1, \dots, x_n) = -0 - 0 - \left(-\frac{1}{2v} \sum_{j=1}^n (x_j - \mu)\right)$$

$$\frac{\partial}{\partial v} l((\mu, v)|x_1, \dots, x_n) = -0 - \frac{n}{2v} + \frac{1}{2v^2} \sum_{j=1}^n (x_j - \mu)^2$$

$$\frac{\partial}{\partial \mu} l((\mu, v)|x_1, \dots, x_n) = 0 \implies \hat{\mu}_{MV} = \bar{X} = \frac{1}{n} \sum_{j=1}^n X_j$$

$$\frac{\partial}{\partial v} l((\mu, v)|x_1, \dots, x_n) = 0 \implies \hat{v} = \frac{1}{n} \sum_{j=1}^n (X_j - \hat{\mu})^2.$$

$$\text{C'est-à-dire } \widehat{\sigma}_{MV}^2 = \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X})^2.$$

Ce dernier est un estimateur biaisé, alors que l'estimateur sans biais et de variance minimale est donné par

$$\widehat{\sigma}^2 = \frac{1}{n-1} \sum_{j=1}^n (X_j - \bar{X})^2.$$

3.3 Comparaison des estimateurs

Exemple 4, autrement Estimation de μ (la moyenne théorique) de largeur d'anneaux)

On s'intéresse à la largeur des anneaux de croissance des arbres. On prend le fichier "treering" dans la librairie "datasets" avec $N = 7980$ (fini) comme étant le cardinal de la population. On note $\mu = 0.9968$ la moyenne (théorique) de la population.

```
Echantillon=matrix(NA, nrow=M,ncol=n) # NA : sans
valeur
```

```
# pour stocker M réalisations de l'échantillon de taille n
```

```
Moyenne.echantillon=rep(NA,M);
```

```
# pour stocker M réalisations de la moyenne d'échantillon
```

```
for (j in 1:M) {
```

```
  Echantillon[j, ] = sample(Population, n, replace = T)
```

```
  Moyenne.echantillon[j] = mean(Echantillon[j, ]) }
```

```
Echantillon; Moyenne.echantillon
```

et on souhaite avoir une idée sur la grandeur du paramètre μ . Pour ce faire, on va construire $M = 100$ réalisations, basé sur un échantillon de taille $n = 65$, de l'intervalle de confiance à 95% sur le paramètre π en utilisant la méthode de Wald.

- 1) Sauvegarder ces 7980 valeurs dans un vecteur nommé **Population**.
- 2) Générer $M = 500$ réalisations de l'échantillon (X_1, \dots, X_n) de taille $n = 65$.
- 3) Appliquer la formule de l'intervalle de confiance à 95% (la méthode de Wald) sur le paramètre π (c.f. TD 5, exo-7) sur les 50 réalisations de l'échantillon pour obtenir $M = 50$ réalisations de l'intervalle de confiance à 95 %.
- 4) Calculer la vraie valeur de π en utilisant la totalité des 7980 valeurs de la population, puis déterminer la proportion des IC contenant cette valeur π . Commenter vos résultats.

La méthode du maximum de vraisemblance est la technique la plus populaire pour obtenir des estimateurs, souvent les meilleures dans les cas classiques.

Exemple 1 : loi de Bernoulli

Un frère dispute d'un précieux tableau à sa soeur. La soeur propose d'utiliser la lancer d'une pièce pour désigner l'heureux héritier.

X une variable aléatoire de loi de Bernoulli $B(1, p)$

$$\mathbb{P}(X = k) = p^k(1 - p)^{1-k}, \quad k \in \{0, 1\}.$$

Soit (x_1, \dots, x_n) une réalisation d'un échantillon (X_1, \dots, X_n) de loi de Bernoulli.

$$\begin{aligned} & \mathbb{P}(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n) \\ &= \mathbb{P}(X_1 = x_1) \mathbb{P}(X_2 = x_2) \cdots \mathbb{P}(X_n = x_n) \\ &= p^{x_1} (1 - p)^{1-x_1} p^{x_2} (1 - p)^{1-x_2} \cdots p^{x_n} (1 - p)^{1-x_n} \\ &= p^{\sum_{j=1}^n x_j} (1 - p)^{n - \sum_{j=1}^n x_j}. \end{aligned}$$

$$\text{donc } \mathbb{P}(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n) = p^{\sum_{j=1}^n x_j} (1 - p)^{n - \sum_{j=1}^n x_j}.$$

Cette dernière quantité est une fonction de p , appelée fonction de vraisemblance $L(p|x_1, \dots, x_n)$:

$$L(p|x_1, \dots, x_n) = p^{\sum_{j=1}^n x_j} (1-p)^{n-\sum_{j=1}^n x_j}.$$

avec le graphique suivant :

Si on étudie son logarithme :

$$l(p|x_1, \dots, x_n) = \log L = \sum_{j=1}^n x_j \log(p) + (n - \sum_{j=1}^n x_j) \log(1-p).$$

$$\frac{\partial}{\partial p} l(p|x_1, \dots, x_n) = 0 \implies p = \frac{1}{n} \sum_{j=1}^n x_j \implies \hat{p} = \bar{X} = \frac{1}{n} \sum_{j=1}^n X_j.$$

$$\text{Comme } \frac{\partial^2}{\partial p^2} l(p|x_1, \dots, x_n) = -\frac{\sum_{j=1}^n X_j}{p} - \frac{n - \sum_{j=1}^n X_j}{1-p}$$

$$\implies \frac{\partial^2}{\partial p^2} l(\hat{p}|x_1, \dots, x_n) = -\frac{\sum_{j=1}^n X_j}{\hat{p}} - \frac{n - \sum_{j=1}^n X_j}{1-\hat{p}} = -2n < 0.$$

Rappels :

Lorsque les lois de probabilités sont discrètes, on a

$$\mathbb{P}(X_i = x_i) = \mathbb{P}_\theta(x_i).$$

Par contre, si les lois sont absolument continues, on a

$$\mathbb{P}(a < X_i \leq b) = \int_a^b f_\theta(x) dx.$$

La fonction de **vraisemblance** est définie par

$$\theta \longrightarrow L(\theta|\mathbf{x}) = L(\theta|x_1, \dots, x_n)$$

$$\text{où } \begin{cases} L(\theta|x_1, \dots, x_n) = \prod_{j=1}^n \mathbb{P}_\theta(x_j) & \text{si discret} \\ L(\theta|x_1, \dots, x_n) = \prod_{j=1}^n f_\theta(x_j) & \text{si absolument continu} \end{cases}$$

On introduit donc estimateur du maximum de vraisemblance comme la fonction de \mathbf{X} (l'échantillon) tel que

$$\hat{\theta}(\mathbf{x}) = \operatorname{Argmax}_{\theta \in \Theta} L(\theta|\mathbf{x}), \forall \mathbf{x}$$

ou de manière équivalente :

$$\hat{\theta}(\mathbf{x}) = \operatorname{Argmax}_{\theta \in \Theta} l(\theta|\mathbf{x}), \forall \mathbf{x}$$

Exemple 2 : loi de Poisson

Soit (x_1, \dots, x_n) une réalisation d'un échantillon (X_1, \dots, X_n) de loi de Poisson $P(\lambda)$. On a

$$\mathbf{P}(X = x_j) = \frac{\lambda^{x_j}}{x_j!} \exp(-\lambda) \implies$$

$$L(\lambda|x_1, \dots, x_n) = \frac{\lambda^{\sum_{j=1}^n x_j}}{\prod_{j=1}^n x_j!} \exp(-n\lambda)$$

$$l(\lambda|x_1, \dots, x_n) = \left(\sum_{j=1}^n x_j \right) \log(\lambda) - \sum_{j=1}^n \log(x_j!) - n\lambda$$

$$\frac{\partial}{\partial \lambda} l(\lambda|x_1, \dots, x_n) = \frac{\left(\sum_{j=1}^n x_j \right)}{\lambda} - 0 - n.$$

L'équation $\frac{\partial}{\partial \lambda} l(\lambda|x_1, \dots, x_n) = 0 \implies \lambda(\mathbf{x}) = \frac{1}{n} \sum_{j=1}^n x_j, \forall \mathbf{x}$

Comme $\frac{\partial^2}{\partial \lambda^2} l(\lambda|x_1, \dots, x_n) = -\frac{\left(\sum_{j=1}^n x_j \right)}{\lambda^2} < 0, \forall \lambda$

On en déduit $\hat{\lambda}_{MV} = \bar{X} = \frac{1}{n} \sum_{j=1}^n X_j.$

Exemple 3 : loi gaussienne

Soit (x_1, \dots, x_n) une réalisation d'un échantillon (X_1, \dots, X_n) de loi gaussienne $N(\mu, \sigma^2)$.

Si on note $v = \sigma^2$, on a alors

$$\mathbf{P}(a < X \leq b) = \int_a^b \frac{1}{2\pi\sqrt{v}} \exp\left(-\frac{1}{2v}(t - \mu)^2\right) dt$$

$$L(\theta|x_1, \dots, x_n) = \frac{1}{(2\pi)^{n/2} v^{n/2}} \exp\left(-\frac{1}{2v} \sum_{j=1}^n (x_j - \mu)^2\right)$$

$$l(\theta|x_1, \dots, x_n) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(v) - \frac{1}{2v} \sum_{j=1}^n (x_j - \mu)^2$$

$$\frac{\partial}{\partial \mu} l((\mu, v)|x_1, \dots, x_n) = -0 - 0 - \left(-\frac{1}{2v} \sum_{j=1}^n (x_j - \mu)\right)$$

$$\frac{\partial}{\partial v} l((\mu, v)|x_1, \dots, x_n) = -0 - \frac{n}{2v} + \frac{1}{2v^2} \sum_{j=1}^n (x_j - \mu)^2$$

$$\frac{\partial}{\partial \mu} l((\mu, v)|x_1, \dots, x_n) = 0 \implies \mu_{\hat{M}V} = \bar{X} = \frac{1}{n} \sum_{j=1}^n X_j$$

$$\frac{\partial}{\partial v} l((\mu, v)|x_1, \dots, x_n) = 0 \implies \hat{v} = \frac{1}{n} \sum_{j=1}^n (X_j - \hat{\mu})^2.$$

$$\text{C'est-à-dire } \widehat{\sigma_{MV}^2} = \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X})^2.$$

Ce dernier est un estimateur biaisé, alors que l'estimateur sans biais et de variance minimale est donné par

$$\text{UMVNB } \hat{\sigma}^2 = \frac{1}{n-1} \sum_{j=1}^n (X_j - \bar{X})^2.$$

2.3 Comparaison des estimateurs