

Ex1

1

1) on a $E[\tilde{m}_n] = \frac{1}{n} \sum_{k=1}^n \frac{1}{k} E[X_k] = m$ donc \tilde{m}_n est un estimateur non biaisé de m

$$\text{Var}(\tilde{m}_n) = \frac{1}{n^2} \sum_{k=1}^n \frac{1}{k^2} \underbrace{\text{Var}(X_k)}_{\sigma^2} = \frac{\sigma^2}{n^2} \sum_{k=1}^n \frac{1}{k^2}$$

les variables X_k sont indépendantes

Mais $\sum_{k=1}^n \frac{1}{k^2} = 1 + \frac{1}{2^2} + \frac{1}{3^2} + \dots + \frac{1}{n^2} < n$ donc $\text{Var}(\tilde{m}_n) < \frac{\sigma^2}{n}$

ce qui signifie qu'on a $\lim_{n \rightarrow +\infty} \text{Var}(\tilde{m}_n) = 0$ Comme

\tilde{m}_n estimateur non biaisé de m

$$\text{Var}(\tilde{m}_n) \xrightarrow[n \rightarrow +\infty]{} 0$$

alors \tilde{m}_n est un estimateur convergent de m

2) La vraisemblance de (x_1, \dots, x_n) s'écrit

$$L(x; m) = \prod_{i=1}^n \frac{1}{\sqrt{2\sigma^2}} \exp\left(-\frac{(x_i - im)^2}{2\sigma^2}\right) \\ = \frac{1}{(2\sigma^2)^{n/2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - im)^2\right)$$

avec $x = (x_1, \dots, x_n)$. Donc la log-vraisemblance est


$$\ln L = -\frac{n}{2} \ln(2\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - im)^2$$

$$\frac{\partial \ln L}{\partial m} \geq 0 \Leftrightarrow -\frac{1}{2\sigma^2} \sum_{i=1}^n \left\{ (x_i - im) (-i) \right\} \geq 0$$

$$\Leftrightarrow \frac{1}{2\sigma^2} \left[\sum_{i=1}^n i x_i - m \sum_{i=1}^n i^2 \right] \geq 0$$

$$\Leftrightarrow m \leq \frac{\sum_{k=1}^n k x_k}{\sum_{k=1}^n k^2} = \frac{6}{n(n+1)(2n+1)} \sum_{k=1}^n k x_k = \hat{m}_{nr}$$

On a donc le tableau de variation



\hat{m}_{nr} est donc le maximum global unique de la vraisemblance

On en déduit l'estimateur du max de vraisemblance de m

(2)

$$\hat{m}_{MV} = \frac{6}{n(n+1)(2n+1)} \sum_{k=1}^n k X_k$$

$$3) E[\hat{m}_{MV}] = \frac{6}{n(n+1)(2n+1)} \sum_{k=1}^n k \underbrace{E(X_k)}_{km} = m$$

$$\text{Var}(\hat{m}_{MV}) = \left[\frac{6}{n(n+1)(2n+1)} \right]^2 \sum_{k=1}^n k^2 \sigma^2$$

$$= \left[\frac{6 \sigma^2}{n(n+1)(2n+1)} \right] \xrightarrow[n \rightarrow +\infty]{} 0$$

donc \hat{m}_{MV} estimateur convergent de m

$$\text{Comme } \text{Var}(\hat{m}_{MV}) \sim \frac{6 \sigma^2}{2n^3} = \frac{3 \sigma^2}{n^3}$$

La variance de \hat{m}_{MV} tend vers 0 lorsque $n \rightarrow +\infty$ avec une vitesse très rapide de l'ordre de $\frac{1}{n^3}$. Cette vitesse "spectaculaire" par le fait que les variables X_1, \dots, X_n n'ont pas la même loi. Cette propriété ne serait pas vérifiée si (X_1, \dots, X_n) était un échantillon.

$$4) \text{ On a vu } \frac{\partial \ln L}{\partial m} = \frac{1}{\sigma^2} \left[\sum_{k=1}^n k x_k - m \sum_{k=1}^n k^2 \right]$$

$$\text{donc } \frac{\partial^2 \ln L}{\partial m^2} = -\frac{1}{\sigma^2} \sum_{k=1}^n k^2 = -\frac{1}{\sigma^2} \frac{n(n+1)(2n+1)}{6}$$

$$\text{d'où } E\left[\frac{\partial^2 \ln L}{\partial m^2}\right] = -\frac{1}{\sigma^2} \frac{n(n+1)(2n+1)}{6}$$

La borne de Cramér-Rao pour un estimateur non-biaisé du paramètre m est

$$\text{BCR}(m) = \frac{6 \sigma^2}{n(n+1)(2n+1)}$$

\hat{m}_{MV} estimateur non biaisé de m et $\text{Var}[\hat{m}_{MV}] = \text{BCR}(m)$ donc \hat{m}_{MV} est l'estimateur efficace de m . que l'on préférera à \hat{m}_n

5) La loi a posteriori du paramètre m possède la densité

$$P(m | x_1, \dots, x_n) \propto \underbrace{P(x_1, \dots, x_n | m) P(m)}_{\text{proportionnel à}}$$

avec $P(m) = \frac{1}{\sqrt{2\pi\sigma_0^2}} \exp\left(-\frac{1}{2\sigma_0^2}(m-m_0)^2\right)$

et

$$P(x_1, \dots, x_n | m) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left[-\frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - km)^2\right]$$

On en déduit

$$\ln P(m | x_1, \dots, x_n) = \text{cte} - \frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - km)^2 - \frac{1}{2\sigma_0^2} (m - m_0)^2$$

C'est une fonction quadratique de m qui admet un maximum global unique vérifiant

$$\frac{\partial \ln P}{\partial m} = 0 \iff \frac{1}{\sigma^2} \sum_{k=1}^n k(x_k - km) - \frac{1}{\sigma_0^2} (m - m_0) = 0$$

Soit $\frac{1}{\sigma^2} \sum_{k=1}^n kx_k + \frac{m_0}{\sigma_0^2} = m \left[\frac{1}{\sigma_0^2} + \sum_{k=1}^n \frac{k^2}{\sigma^2} \right]$

Pour simplifier les notations, on note $S_n = \sum_{k=1}^n k^2 = \frac{n(n+1)(2n+1)}{6}$

On en déduit

$$\sum_{k=1}^n kx_k + \frac{m_0}{\sigma_0^2} = m \left[\frac{1}{\sigma_0^2} + \frac{S_n}{\sigma^2} \right]$$

$$= m \left[\frac{\sigma^2 + \sigma_0^2 S_n}{\sigma^2 \sigma_0^2} \right]$$

d'où $m = \frac{\sigma_0^2}{\sigma^2 + \sigma_0^2 S_n} \sum_{k=1}^n kx_k + \frac{\sigma^2}{\sigma^2 + \sigma_0^2 S_n} m_0$

On a donc

$$m_{MAP}^n = \frac{\sigma_0^2 S_n}{\sigma^2 + \sigma_0^2 S_n} m_{MV} + \frac{\sigma^2}{\sigma^2 + \sigma_0^2 S_n} m_0$$

avec $\beta(n) = \frac{\sigma_0^2 S_n}{\sigma^2 + \sigma_0^2 S_n}$

On remarque que $\beta(n) \xrightarrow[n \rightarrow \infty]{} 1$ ce qui signifie que \hat{m}_{MAP} et \hat{m}_{ML} ont des comportements asymptotiques similaires, ce qui est un résultat très général (4)

quand $n \rightarrow \infty$, on a $\beta(n) \approx 1$ donc \hat{m}_{MAP} se comporte comme la moyenne a priori m_0

Ex2 1) Le théorème de Neyman Pearson indique que H_0 est rejetée si $\frac{P(x_1, \dots, x_n; m_1)}{P(x_1, \dots, x_n; m_0=0)} > \text{seuil}$

c'est à dire qu'on rejette H_0 si

$$\frac{\exp\left[-\frac{1}{2\sigma^2} \sum_{k=1}^n (x_k - k m_1)^2\right]}{\exp\left[-\frac{1}{2\sigma^2} \sum_{k=1}^n x_k^2\right]} > \text{seuil}$$

soit en prenant le logarithme

$$-\frac{1}{2\sigma^2} \left[\sum_{k=1}^n x_k^2 - 2 m_1 \sum_{k=1}^n k x_k + n \sum_{k=1}^n k^2 m_1^2 \right] + \frac{1}{2\sigma^2} \sum_{k=1}^n x_k^2 > \text{seuil}$$

soit $\frac{m_1}{\sigma^2} \sum_{k=1}^n k x_k > \text{seuil}$

Comme $m_1 < 0$ on en déduit

$$\left\{ \text{Rejet de } H_0 \text{ si } \sum_{k=1}^n k x_k < S \right.$$

La statistique de test est donc $T_n = \sum_{k=1}^n k x_k$ et la région critique du test est

$$\left\{ (x_1, \dots, x_n) / \sum_{k=1}^n k x_k < S \right\}$$

2) Comme x_1, \dots, x_n sont des variables aléatoires indépendantes, $\begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$ est un vecteur gaussien et $\sum_{k=1}^n k x_k = [1 \ 2 \ \dots \ n] \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = A \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$ est une variable aléatoire gaussienne car A est une matrice de rang 1. On en déduit

$$\begin{array}{l} \text{Sous } H_0 \quad T_n \sim (0, \sigma^2 S_n) \quad \text{avec } S_n = \sum_{k=1}^n k^2 = \frac{n(n+1)(2n+1)}{6} \\ \text{Sous } H_1 \quad T_n \sim (S_n m_1, \sigma^2 S_n) \end{array}$$

$$\begin{aligned} 3) \quad \alpha &= P[\text{Rejeter } H_0 \mid H_0 \text{ vraie}] = P(T_n < S \mid m=0) \\ &= P\left[\frac{T_n}{\sqrt{S_n} \sigma} < \frac{S}{\sqrt{S_n} \sigma} \mid \frac{T_n}{\sqrt{S_n} \sigma} \sim N(0,1) \right] \end{aligned}$$

donc $\alpha = F\left[\frac{S}{\sqrt{S_n} \sigma} \right]$

$$\begin{aligned} \beta &= P[\text{Rejeter } H_1 \mid H_1 \text{ vraie}] = 1 - P(T_n < S \mid m=m_1) \\ &= 1 - P\left[\frac{T_n - m_1 S_n}{\sqrt{S_n} \sigma} < \frac{S - m_1 S_n}{\sqrt{S_n} \sigma} \mid m=m_1 \right] \end{aligned}$$

donc $\beta = 1 - F\left[\frac{S - m_1 S_n}{\sqrt{S_n} \sigma} \right]$

4) Les courbes COR expriment $\pi = 1 - \beta$ en fonction de α . Elles sont définies par

$$\pi = 1 - \beta = F\left[\frac{S - m_1 S_n}{\sigma \sqrt{S_n}} \right] \quad \text{avec } S = \sqrt{S_n} \sigma F^{-1}(\alpha)$$


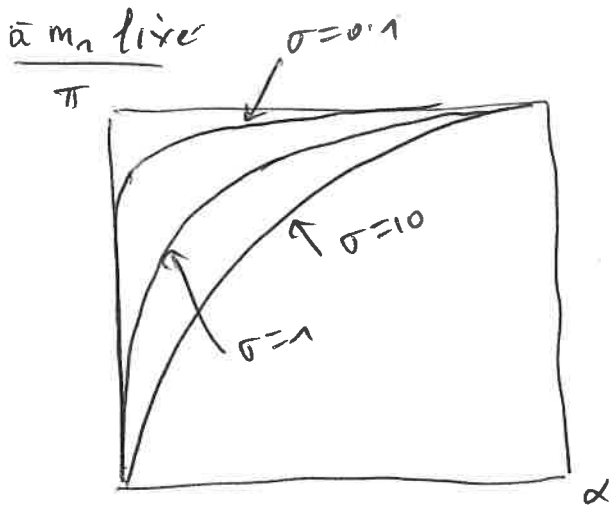
donc

$$\pi = F\left[F^{-1}(\alpha) - \frac{m_1 \sqrt{S_n}}{\sigma} \right]$$

Comme $m_1 < 0$, on a $-m_1 \sqrt{S_n} > 0$ donc si $\sigma \nearrow \Rightarrow \frac{-m_1 \sqrt{S_n}}{\sigma} \nearrow$ donc $\pi \nearrow$ ce qui est logique, car plus la variance σ^2 est faible, plus il est facile de tester $m=0$ contre $m=m_1$.

Si $m_1 \searrow \rightarrow -\frac{m_1 \sqrt{s_n}}{\sigma} \nearrow$ donc $\pi \nearrow$, a qui est aussi logique =
 plus m_1 est "faible" ("grand" par valeur négative) plus il est facile
 car $m_1 < 0$
 de distinguer $m = m_1$ de $m = 0$

Allures des courbes COR



5) Dans le cas de $k=4$ classes, on découpe \mathbb{R} en 4 intervalles
 $] -\infty, -a]$ $] -a, 0]$ $] 0, a]$ $] a, +\infty [$ équiprobables, i.e., tels

que $P(Y_k \in] -\infty, -a]) = F(-a) = \frac{1}{4}$

d'où $a = -\bar{F}^{-1}(1/4)$ 40r

7

On va compter combien d'observations y_1, \dots, y_n font
 appartiennent à chaque intervalle - soit z_1, z_2, z_3 et z_4
 les nombres d'observations dans les 4 intervalles $]-\infty, -a)$
 $] -a, 0[$ $] 0, a[$ et $[a, +\infty[$ - On forme la statistique
 du test du χ^2

$$\phi = \sum_{k=1}^4 \frac{(z_k - n p_k)^2}{n p_k} \quad (1)$$

avec $p_k = \frac{1}{4}$ et n le nombre total d'observations

On se fixe ensuite un risque α (par exemple $\alpha = 0.101$)

$$\alpha = P[\phi > s_2 \mid \phi \sim \chi_4^2] = 1 - F_4(s_2)$$

où F_4 est la fonction de répartition d'une loi du χ_4^2

$$\text{Soit } \boxed{s_2 = F_4^{-1}(1 - \alpha)}$$

Si $\phi > s_2$ on rejette H_0 avec le risque α choisi et
 on en conclut que les variables aléatoires Y_1, \dots, Y_4 ne
 respectent pas l'hypothèse $X_k \sim N(k\mu, \sigma^2)$.

si $\phi < s_2$, on accepte H_0 avec le risque α choisi et
 donc on en conclut que l'hypothèse $X_k \sim N(k\mu, \sigma^2)$
 est correcte