

Analyse Statistique  
Examen 1<sup>re</sup> session 2012  
Durée : 2h

Exercice 1 (8 points)

On dispose d'un échantillon de 10 observations extrait d'une loi normale  $N(m, \sigma)$  dont les paramètres  $m, \sigma$  sont inconnus. Les observations  $(x_1, x_2, \dots, x_{10})$  sont : 2.95, 3, 2.8, 3.15, 3.20, 3.05, 3.1, 3.29, 3.30, 2.9

1. Construire un intervalle de confiance à 95% pour  $m$ .
2. Même question pour  $\sigma^2$
3. Soit le test suivant :

$$\begin{cases} H_0 : m = 3 \\ H_1 : m > 3 \end{cases}$$

- (a) Donner la variable statique  $Z$  pour construire la région critique  $R$ .
- (b) Déterminer la forme de la région critique pour un risque  $\alpha$ . Ce test est-il UPP ?
- (c) Pour un risque  $\alpha = 5\%$ , définir la règle de décision et conclure.
- (d) Calculer la puissance  $\eta$  de ce test pour  $m = \underline{3,089}$

Exercice 2 (12 points)

On considère la population des étudiants de l'Université de Cergy-Pontoise et on désigne par  $p$  la proportion des étudiants possédant un iPhone. On tire au hasard et avec remise dans cette population un échantillon de  $n$  étudiants. On désigne par  $X_i$  ( $i = 1, \dots, n$ ) la variable aléatoire de Bernoulli valant 1 si le  $i^{\text{e}}$  étudiant a un iPhone et 0 sinon.

1. Quelle est la loi de la variable aléatoire  $Y = \sum_{i=1}^n X_i$  ? Calculer  $E(Y)$  et  $V(Y)$ .
2. On note par  $\bar{X}_n$  la proportion d'étudiants ayant un iPhone dans un échantillon de taille  $n$ . Déduire de (1)  $E(\bar{X}_n)$  et  $V(\bar{X}_n)$ .
3. On suppose  $n$  grand :
  - (a) Énoncer le théorème central limite en choisissant des notations correspondant à l'exercice.

- (b) On suppose que  $n = 100$  et  $p = 0,5$ .
- Calculer la probabilité que  $\bar{X}_n$  soit supérieure à  $0,525$ .
  - Calculer la probabilité que  $\bar{X}_n$  soit inférieure à  $0,4875$ .
  - Déterminer  $a$  pour que  $P(|\bar{X}_n - 0,5| > a) = 0,10$
4. On suppose maintenant que  $p$  est inconnu et on cherche à l'estimer.
- (a) Déterminer un estimateur de  $p$  par la méthode du maximum de vraisemblance et préciser ses propriétés.
- (b) On a trouvé dans un échantillon de taille 100 que 49.5% des étudiants ont un iPhone. Donner un intervalle de confiance pour le paramètre  $p$  au seuil 5% .

### CORRIGE DE L'EXAMEN DU LA SESION 1 2012

1)

$\bar{X} = \frac{\sum_{i=1}^{10} X_i}{10}$  et  $S^2 = \frac{\sum_{i=1}^{10} (X_i - \bar{X})^2}{9}$  sont des estimateurs sans biais de  $m$  et de

$\frac{\bar{X} - m}{\frac{S}{\sqrt{10}}}$  suit une loi de Student à 9 degrés de liberté.

Etant donné  $\alpha$ , on lit dans la table de Student la valeur de  $t_\alpha$ , telle que

$$P\left[\left|\frac{\bar{X} - m}{\frac{S}{\sqrt{10}}}\right| < t_\alpha\right] = 1 - \alpha \text{ ce qui s'écrit } P\left[\bar{X} - t_\alpha \frac{S}{\sqrt{10}} < m < \bar{X} + t_\alpha \frac{S}{\sqrt{10}}\right] = 1 - \alpha$$

d'où l'intervalle de confiance :  $IC(m) = \left[\bar{x} - t_\alpha \frac{s}{\sqrt{10}}, \bar{x} + t_\alpha \frac{s}{\sqrt{10}}\right]$

Ici  $1 - \alpha = 95\%$  donc  $\alpha = 0.05$  et par suite  $t_\alpha = 2.262$

$$\bar{x} = \frac{\sum_{i=1}^{10} x_i}{10} = 3.074 \text{ et}$$

$$s^2 = \frac{\left(\sum_{i=1}^{10} x_i^2\right) - 10(\bar{x})^2}{9} = \frac{99,7416 - 94,49476}{9} = 0,0274 \text{ soit } s = 0.1656$$

Ce qui donne comme intervalle de confiance :

$$IC(m) = [3.074 - 0.118, 3.074 + 0.118] = [2,956, 3,192]$$

2) On sait que  $9 \frac{S^2}{\sigma^2}$  suit une loi de chi deux à 9 degrés de liberté. Etant

donné  $\alpha$ , on lit dans la table les deux valeurs  $k_1$  et  $k_2$  telles que

$$P(\chi_9^2 > k_2) = \frac{\alpha}{2} \text{ et } P(\chi_9^2 < k_1) = \frac{\alpha}{2} \text{ d'où } P\left[k_1 < \left(\frac{9S^2}{\sigma^2}\right) < k_2\right] = 1 - \alpha \text{ ce}$$

qui s'écrit encore :

$$P\left[\frac{9S^2}{k_2} < \sigma^2 < \frac{9S^2}{k_1}\right] = 1 - \alpha \text{ d'où l'intervalle de confiance pour } \sigma^2$$

$$IC(\sigma^2) = \left[\frac{9s^2}{k_2}, \frac{9s^2}{k_1}\right] = \left[\frac{0,2466}{k_2}, \frac{0,2466}{k_1}\right]$$



Ici  $\alpha=0.05$  donc  $P(\chi_9^2 > k_2) = \frac{\alpha}{2} = 0.025 \Rightarrow k_2 = 19.0$  et

$P(\chi_9^2 > k_1) = 1 - \frac{\alpha}{2} = 0.975 \Rightarrow k_1 = 2,70$  ce qui donne comme intervalle à 95% pour  $\sigma^2$   $IC(\sigma^2) = [0,013, 0,0913]$

3)

a) C'est un test qui porte sur la moyenne d'une variable suivant une loi normale  $N(m, \sigma)$  (variance inconnue) donc on va s'appuyer sur la statistique

$$Z = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \text{ qui est un estimateur sans biais de } m.$$

la région critique sera définie par la statistique  $\bar{X}_n$  qui suit la loi normale  $N$

$\left(3, \frac{\sigma}{\sqrt{n}}\right)$  sous l'hypothèse  $H_0$  mais  $\sigma$  est inconnu. Donc on va remplacer

estimer  $\sigma^2$  par son estimateur sans biais

$$S_n^2 = \frac{\sum_{i=1}^n (X_i - \bar{X}_n)^2}{n-1}. \text{ On sait alors que sous l'hypothèse } H_0 \text{ la variable}$$

$$T_0 = \frac{\bar{X}_n - 3}{\frac{S_n}{\sqrt{10}}} \text{ suit une loi de Student à 9 ddl.}$$

b) La région critique est de la forme :  $\bar{X}_n \geq k$  et  $k$  est tel que

$$\alpha = P(\bar{X}_n \geq k / H_0) = P(T_0 \geq t_\alpha / T_0 \sim St_9)$$

On trouve dans une table de Student la valeur  $t_\alpha$  et on en déduit :

$$k = m_0 + t_\alpha \frac{s}{\sqrt{n}} \text{ et la région critique (R) est définie par } \bar{X}_n \geq m_0 + t_\alpha \frac{s}{\sqrt{n}}$$

Cette région critique est indépendante des valeurs de  $m$  de l'hypothèse  $H_1$ .

donc ce test est UPP

c) Pour  $\alpha = 5\%$  on trouve dans une table de Student la valeur  $t_\alpha = 1,833$  et on en déduit :

$$k = m_0 + t_\alpha \frac{s}{\sqrt{n}} = 3 + 1,833 \frac{0,1656}{\sqrt{10}} = 3,0953$$

et la région critique (R) est définie par  $\bar{X}_n \geq 3,0953$

D'où la règle de décision suivante : Si  $\bar{x} \geq 3,0953$  on rejette l'hypothèse  $m = 3$

Décision :  $\bar{x} = 3,074 \notin (R)$  donc on accepte l'hypothèse  $m = 3$

d) **attention : on a changé  $m_1=4$  en  $m_1=3.089$**

Pour  $m_1 = 3,089$

$$\eta = P(\bar{X}_n \geq k / m = 3,089) = P\left(T_1 \geq \frac{3,0953 - 3,089}{\frac{s_n}{\sqrt{10}}}\right)$$

$$= P(T_1 \geq 0,120 / T_1 \sim St_9) = \frac{0,90}{2} = 0,45$$

Exercice 2 :

1) Les  $X_i$  étant  $n$  variables de Bernoulli indépendantes de paramètres  $p$  la variable  $Y = \sum_{i=1}^n X_i$  suit une loi binomiale de paramètre  $n$  et  $p$   $B(n, p)$

2) On sait que  $E(Y) = np$  et  $V(Y) = np(1-p)$

$$\bar{X}_n = \frac{\sum_{i=1}^n X_i}{n} = \frac{Y}{n} \Rightarrow E(\bar{X}_n) = E\left(\frac{Y}{n}\right) = \frac{E(Y)}{n} = \frac{np}{n} = p$$

$$V(\bar{X}_n) = V\left(\frac{\sum_{i=1}^n X_i}{n}\right) = \frac{V(Y)}{n^2} = \frac{np(1-p)}{n^2} = \frac{p(1-p)}{n}$$

3)  $\frac{\sum_{i=1}^n X_i - np}{\sqrt{np(1-p)}}$  converge en loi vers la variable normale centrée réduite  $U$

ou encore  $\frac{\bar{X}_n - p}{\sqrt{\frac{p(1-p)}{n}}}$  converge en loi vers la variable normale centrée

réduite  $U$  quand  $n$  tend vers  $+\infty$

Si  $n = 100$  et  $p = 0,5$   $\sqrt{\frac{p(1-p)}{100}} = \frac{0,5}{10} = 0,05$  et  $\frac{\bar{X}_n - 0,5}{0,05} \rightarrow N(0,1)$

$$a) P[\bar{X}_n > 0,525] = P\left[\frac{\bar{X}_n - 0,5}{0,05} > 0,5\right] = 1 - \Pi(0,5) = 1 - 0,6915 = 0,3085$$

b)

$$P[\bar{X}_n < 0,4875] = P\left[\frac{\bar{X}_n - 0,5}{0,05} < -0,25\right] = \Pi(-0,25)$$

$$= 1 - \Pi(0,25) = 1 - 0,5987 = 0,4013$$

c)



$$P\left[|\bar{X}_n - 0.5| > a\right] = P\left[\frac{|\bar{X}_n - 0.5|}{0.05} > \frac{a}{0.05}\right] = P\left[|U| > \frac{a}{0.05}\right] = 0.10$$

$$\Rightarrow \frac{a}{0.05} = 1.6449 \Rightarrow a \approx 0.0822$$

4)

a)  $P(X_i = k_i) = p^{k_i} (1-p)^{1-k_i}$  pour  $k_i = 0$  ou  $1$

car chaque variable  $X_i$  suit une loi de Bernoulli de paramètre  $p$

La vraisemblance de l'échantillon  $L(k_1, k_2, \dots, k_n) = P(X_1=k_1, X_2=k_2, \dots, X_n=k_n)$

Les variables étant indépendantes on a :

$$L(k_1, k_2, \dots, k_n) = P(X_1=k_1, X_2=k_2, \dots, X_n=k_n) = P(X_1=k_1)P(X_2=k_2) \dots P(X_n=k_n)$$

$$D'où L(k_1, k_2, \dots, k_n) = \prod_{i=1}^n p^{k_i} (1-p)^{1-k_i} = p^{\sum_{i=1}^n k_i} (1-p)^{\sum_{i=1}^n (1-k_i)} = p^k (1-p)^{n-k} \text{ où } k = \sum_{i=1}^n k_i$$

L'estimateur de  $p$  par la méthode du maximum de vraisemblance

s'obtient en résolvant en  $p$  l'équation suivante :  $\frac{\partial \text{Log}L}{\partial p} = 0$

$$\text{Log}L(k_1, k_2, \dots, k_n) = \text{Log}(p^k (1-p)^{n-k}) = k \text{Log}p + (n-k) \text{Log}(1-p)$$

$$\frac{\partial \text{Log}L}{\partial p} = \frac{k}{p} - \frac{(n-k)}{(1-p)} = \frac{k(1-p) - p(n-k)}{p(1-p)} = \frac{k - np}{p(1-p)} = 0 \Leftrightarrow p = \frac{k}{n}$$

Ce qui donne comme estimateur de  $p$   $\bar{X}_n = \frac{\sum_{i=1}^n X_i}{n} = \frac{Y}{n}$

Cet estimateur est sans biais car  $E(\bar{X}_n) = p$

Elle est convergente car  $E(\bar{X}_n) = p$  et  $V(\bar{X}_n) = \frac{p(1-p)}{n} \rightarrow 0$  quand  $n \rightarrow +\infty$

En notant par  $X$  la variable de Bernoulli générique la quantité d'information de Fisher associée à l'échantillon de taille  $n$

$$I(p) = nV\left(\frac{\partial \text{Log}\left[p^X (1-p)^{1-X}\right]}{\partial p}\right)$$

$$\text{Log}p^X (1-p)^{1-X} = X \text{Log}p + (1-X) \text{Log}(1-p) \Rightarrow$$

$$\frac{\partial \text{Log}\left[p^X (1-p)^{1-X}\right]}{\partial p} = \frac{X}{p} - \frac{(1-X)}{(1-p)} = \frac{X-p}{p(1-p)} \Rightarrow$$

$$V\left(\frac{\partial \text{Log}\left[p^X (1-p)^{1-X}\right]}{\partial p}\right) = V\left(\frac{X-p}{p(1-p)}\right) = \frac{V(X)}{p^2(1-p)^2} = \frac{p(1-p)}{p^2(1-p)^2} = \frac{1}{p(1-p)}$$

Ce qui donne  $I(p) = \frac{n}{p(1-p)} \Rightarrow V(\bar{X}_n) = \frac{1}{I(p)}$  donc  $\bar{X}_n$  est un estimateur efficace de  $p$

b) Déterminons dans la table de la loi normale la valeur  $t$  telle que :

$$P\left(\left|\frac{\bar{X}_n - p}{\sqrt{\frac{p(1-p)}{n}}}\right| < t\right) = 0.95 \Rightarrow \Pi(t) = 0.975 \Rightarrow t = 1.96$$

**1<sup>ère</sup> méthode** : on peut majorer le  $p$  du dénominateur par  $\frac{1}{2}$  donc

$$p \in \left(0.495 - 1.96\sqrt{\frac{1}{400}}, 0.495 + 1.96\sqrt{\frac{1}{400}}\right) \text{ Donc } p \text{ se trouve dans}$$

$IC(p) = [0.397 ; 0.593]$  avec une confiance de 95%

**2<sup>ème</sup> méthode** : on remplace  $\sqrt{\frac{p(1-p)}{n}}$  par  $\sqrt{\frac{\bar{x}_n(1-\bar{x}_n)}{n}}$ . le calcul donne le même résultat