

CORRIGE PARTIEL BLANC

L3-AES

Décembre 2011

Math et Stat; appliquées

1 EXERCICE-1

- On note respectivement μ et σ la moyenne et l'écart-type de la population. La moyenne de l'échantillon constitue une bonne estimation de μ , donc la moyenne de la population est estimée à 29.68cm, et une bonne estimation de l'écart-type de la population est : $s_n = \sqrt{\frac{n}{n-1}}\sigma_{ech}$, donc une estimation de σ est : $s_n = \sqrt{\frac{50}{49}} * 0.06 \simeq 6.06 \times 10^{-2}$
- On sait que la moyenne d'échantillon suit approximativement la loi normale de moyenne μ et d'écart-type $\frac{\sigma}{\sqrt{n}}$ (approximation valable dès que $n \geq 30$). L'intervalle de confiance au seuil $1 - \alpha$ est donné par :

$$I = \left] \bar{x}_n - t \frac{s_n}{\sqrt{n}} ; \bar{x}_n + t \frac{s_n}{\sqrt{n}} \right[$$
 avec $2F(t) - 1 = 1 - \alpha$, Z suivant la loi $\mathcal{N}(0; 1)$; à 95%, on sait que $t = 1.96$,
ce qui donne : $I = \left] 29.68 - 1.96 \frac{6.06 \times 10^{-2}}{\sqrt{50}} ; 29.68 + 1.96 \frac{6.06 \times 10^{-2}}{\sqrt{50}} \right[$: soit $I =]29.66; 29.70[$. Il y a une probabilité de 95% pour que cet intervalle contienne la longueur moyenne d'une feuille.

2 EXERCICE-2

Si l'on note X_i la variable aléatoire versée à l'assuré i , $i \in [1; 120]$, on a : $m = E(X_i) = 50$ et $\sigma = \sigma(X_i) = 30$. La somme totale X versée par la compagnie d'assurance est la variable aléatoire définie par : $X = \sum_{i=1}^{120} X_i$, peut être assimilée à une loi normale en vertu du théorème central limite, comme somme de variables aléatoires indépendantes et de même loi (iid). On a : $E(X) = 120m = 120 * 50 = 6000$ et $\sigma(X) = \sigma\sqrt{n} = 30\sqrt{120} = 60\sqrt{30} = 328.63$; la loi de X est assimilable à $\mathcal{N}(6000; 328.63)$, et celle de Z à $\mathcal{N}(0; 1)$, en notant $Z = \frac{X - 6000}{328.63}$. On a donc :

$$P(X \leq 6500) = P\left(Z \leq \frac{6500 - 6000}{328.63}\right) = P(Z \leq 1.52) \simeq \boxed{0.9357}$$
.

3 EXERCICE-3

Dans le tableau de gauche, figurent les effectifs calculés (théoriques) sous l'hypothèse H_0 , c'est à dire les effectifs attendus s'il y avait absence de liaison entre la nationalité et la réponse et la perception. Il suffit en fait de calculer ceux correspondant aux deux cases manquantes ; on trouve par exemple pour les français ayant répondu non (B) : $\frac{1539 * 905}{6133} \simeq 227.10$ et ensuite pour la contribution au Khi^2 : $\frac{(302 - 227.10)^2}{227.10} \simeq 24.70$.

C_i	A	B	C	Total
Chine	965.41	221.64	314.95	1502
France	989.20	227.10	322.71	1539
Inde	986.62	226.51	321.87	1535
USA	1000.77	229.75	326.48	1557
Total	3942	905	1286	6133

Contributions au Khi^2	A	B	C	Total
Chine	17.13	23.16	10.30	50.58
France	28.26	24.70	26.40	79.36
Inde	66.10	19.53	110.82	196.45
USA	46.95	17.41	72.19	136.55
	Khi²			462.94

On a complété le tableau en utilisant la formule $\chi_{cal}^2 = \frac{(O_1 - C_1)^2}{C_1} + \frac{(O_2 - C_2)^2}{C_2} + \dots + \frac{(O_n - C_n)^2}{C_n}$, ce qui donne en

ajoutant les 12 contributions au Khi^2 : $\chi_{calc}^2 = 462.94$:

1. Formulation des hypothèses :

H_0 : absence de liaison entre la nationalité et la réponse et la perception .

H_1 : l'hypothèse alternative : il y a une liaison significative entre la nationalité et la réponse et la perception

2. Choix du seuil de signification : 5%

3. Calcul des effectifs théoriques ou calculés que nous noterons C_i (avec comme condition que chaque C_i doit être au moins égal à 5) et calcul du Khi^2 . $\chi^2 = \sum \frac{(O_i - C_i)^2}{C_i}$; on trouve : $\chi_{calc}^2 \simeq \boxed{462.94}$

4. Déterminer le ddl (degré de liberté) : $\nu = (c - 1) * (l - 1)$ où l et c désignent respectivement le nombre de lignes et de colonnes des données de l'échantillon, c'est à dire le nombre de modalités de chaque caractère. Ici $\nu = (4 - 1) (3 - 1) = 6$.

5. Lire dans la table $\text{Khi}^2_{(0.05; 6)} \simeq \boxed{12.59}$; cette valeur est dite "critique", cela signifie que sous l'hypothèse d'indépendance, si l'on prenait tous les échantillons de taille 100 de notre population, on aurait une probabilité de 5%, d'obtenir un Khi^2 supérieur à 12.59.

6. Règle de décision :

Si le Khi^2 calculé est inférieure ou égale au Khi^2 de la table (valeur critique : seuil limite de la région de non rejet de H_0), on ne peut rejeter H_0 , par contre si $\chi_{calc}^2 > \chi_{(2;0.05)}^2$, on rejettera l'hypothèse d'indépendance statistique des deux caractères.

7. Décision : ici $\chi_{calc}^2 > \chi_{(0.05;6)}^2$; on conclut qu'au seuil de 5%, l'hypothèse H_0 d'absence de liaison entre les caractères est très clairement rejetée, donc on accepte l'hypothèse alternative H_1 ; au niveau de confiance de 5%, l'écart entre les effectifs observés et les effectifs calculés est significatif, il y a un lien statistique avéré entre les nationalités et les réponses.

4 EXERCICE-4

1. La calculatrice donne :

	X	Y
MOY	2,21	0,03
V	1,94	0,52
σ	1,39	0,72

2. cf tableau ci-dessus.

3. La calculatrice donne : $\begin{cases} \hat{b} = 0.8028 \\ \hat{a} = -0.3509 \end{cases}$ soit $\hat{Y} = -0.3509X + 0.8028$

4. $e_8 = y_8 - \hat{y}_8 = 0.49 - (-0.3509 * 2.06 + 0.8028) = 0.4101$

5. \hat{a} donne une estimation de la variation de Y suite à une augmentation d'une unité de X : si le taux de croissance du PIB augmente de 1 point, on peut estimer que la variation du taux de chômage baisse de 0.35 points.

6. On trouve $R^2 \simeq 0.4625$, $R^2 = \frac{SCE}{SCT}$, il mesure le pourcentage de la variance de Y expliquée par le modèle, c'est-à-dire expliquée par la variation de X .

7. Estimation ponctuelle de la variation du taux de chômage : $\hat{Y}(2.52) = -0.3509 * 2.52 + 0.8028 = -0.08$.

8. $SCT = SCE + SCR$; donc $SCR = SCT - SCE = SCT - R^2 (SCT) = SCT (1 - R^2) = nV(y) (1 - R^2) = 17 * 0.52 * (1 - 0.4625) = 4.75$

10. On calcule l'erreur type de a ; on a : $S_{\hat{a}}^2 = \frac{S_{\varepsilon}^2}{i=n} = \frac{SCR/(n-2)}{nV(X)} = \frac{4.75/15}{17*1.94} = 9.6 \times 10^{-3}$ ce qui donne :

$$S_{\hat{a}} = \sqrt{9.6 \times 10^{-3}} = 9.798 \times 10^{-2} \text{ et } t_{\hat{a}} = \frac{\hat{a}}{S_{\hat{a}}} = \frac{-0.3509}{9.798 \times 10^{-2}} = -3.58.$$

$\frac{\hat{a} - a}{S_{\hat{a}}}$ suit une loi de Student avec $(n - 2)$ degrés de liberté, soit ici un ddl de 15.

Nous allons donc tester si X contribue à expliquer Y en testant l'hypothèse nulle $a = 0$ contre l'hypothèse alternative $a \neq 0$:

$\begin{cases} H_0 : a = 0 \text{ (} X \text{ n'influence pas } Y \text{)} \\ H_1 : a \neq 0 \end{cases}$. Sous l'hypothèse H_0 , $t_{\hat{a}} = \frac{\hat{a}}{S_{\hat{a}}}$, le ratio de Student, suit une distribution de Student avec $(n - 2)$ degrés de liberté ; ici $t_{\hat{a}} = -3.58$; le seuil de signification est $\alpha = 0.05$; il reste à comparer ce quotient avec la valeur lue dans la table de Student, de $t_{\alpha/2, n-2}$ soit ici : $t_{0.025; 15} = 2.1315$; $|t_{\hat{a}}| > t_{\alpha/2; n-2}$, on rejette H_0 , au seuil de $100\alpha\%$; \hat{a} est suffisamment différent de zéro pour affirmer que a est significativement différent de zéro. On en conclut que X est significative et contribue à l'explication de Y .