

**Corrigé de l'examen de janvier 2005**

**Exercice 1**

$\mathcal{P}_1 = \{\text{familles ayant donné naissance à un prématuré présentant un risque périnatal élevé}\}$ ,

$\mathcal{P}_2 = \{\text{familles ayant donné naissance à un prématuré présentant un risque périnatal très faible}\}$ ,

$X = \text{score de réactions post-traumatiques chez la mère, variable quantitative}$

$X_1 = \text{score de réactions post-traumatiques chez la mère dans } \mathcal{P}_1 \text{ de moyenne } \mu_1 \text{ et d'écart-type } \sigma_1 \text{ inconnus dans } \mathcal{P}_1$

$X_2 = \text{score de réactions post-traumatiques chez la mère dans } \mathcal{P}_2 \text{ de moyenne } \mu_2 \text{ et d'écart-type } \sigma_2 \text{ inconnus dans } \mathcal{P}_2$

On observe :

un échantillon de  $X_1$  issu de  $\mathcal{P}_1$  de taille  $n_1=14$  pour lequel

le score moyen  $\mu_1$  est estimé par  $\bar{x}_1 = 30,24$  et l'écart-type du score  $\sigma_1$  est estimé par  $s_1=12,11$  (estimation biaisée)

un échantillon de  $X_2$  issu de  $\mathcal{P}_2$  de taille  $n_2=12$  pour lequel

le score moyen  $\mu_2$  est estimé par  $\bar{x}_2 = 12,31$  et l'écart-type du score  $\sigma_2$  est estimé par  $s_2=9,42$  (estimation biaisée)

L'hypothèse que les mères de prématurés à risque périnatal élevé présentent des réactions post-traumatiques plus fortes que celles de prématurés à risque très faible se traduit par le fait que le score moyen des premières  $\mu_1$  est supérieur à celui des secondes  $\mu_2$  :  $\mu_1 > \mu_2$ . Tester l'hypothèse émise revient donc à comparer les deux moyennes  $\mu_1$  et  $\mu_2$  à partir de deux échantillons indépendants en utilisant le test unilatéral de l'hypothèse nulle  $H_0 : \mu_1 = \mu_2$  contre l'hypothèse alternative  $H_1 : \mu_1 > \mu_2$  au risque  $\alpha=5\%$ .

Test de comparaison de deux moyennes  $\mu_1$  et  $\mu_2$  à partir de deux échantillons indépendants :

test de l'hypothèse nulle  $H_0 : \mu_1 = \mu_2$  contre l'hypothèse alternative  $H_1 : \mu_1 > \mu_2$  au risque unilatéral  $\alpha=5\%$ .

Les variables  $X_1$  et  $X_2$  étant normales dans  $\mathcal{P}_1$  et  $\mathcal{P}_2$  et de variances inconnues égales ( $n_1=14 < 30$  et  $n_2=12 < 30$ ) ce test est basé sur la statistique de test de Student :

$$T = \frac{\bar{X}_1 - \bar{X}_2}{S^* \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \text{ qui suit une loi de Student } T_{n_1+n_2-2} = T_{24} \text{ sous } H_0.$$

Sous l'hypothèse alternative unilatérale  $H_1 : \mu_1 > \mu_2$  les valeurs de  $\bar{X}_1$  ont tendance à être supérieures à celles de  $\bar{X}_2$  donc les valeurs de  $T$  ont tendance à être positives, c'est-à-dire que la région de rejet du test est à droite du domaine de variation de  $T$ .

La région de rejet du test unilatéral au risque  $\alpha=5\%$  :  $RC_{5\%} = ]t_{0,95} ; +\infty[ = ]1,711 ; +\infty[$

où  $t_{0,95} = 1,711$  est le quantile d'ordre  $1-\alpha=0,95$  de la loi  $T_{24}$  ( $v=24$  et  $P=0,10$ ).

L'écart-type observé biaisé de  $X_1$  dans  $\mathcal{P}_1$  :  $s_1=12,11$  et l'écart-type observé biaisé de  $X_2$  dans  $\mathcal{P}_2$  :  $s_2=9,42$

La variance commune  $\sigma^2$  de  $X_1$  dans  $\mathcal{P}_1$  et de  $X_2$  dans  $\mathcal{P}_2$  est estimée par la variance observée sans biais :

$$s^{*2} = \frac{n_1 s_1^2 + n_2 s_2^2}{n_1 + n_2 - 2} = \frac{14 \times 12,11^2 + 12 \times 9,42^2}{14 + 12 - 2} = 129,915 \text{ d'où } s^* = 11,398 \approx 11,4$$

$$\text{La valeur observée de la statistique de test } T : t = \frac{\bar{x}_1 - \bar{x}_2}{s^* \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} = \frac{30,24 - 12,31}{11,398 \sqrt{\frac{1}{14} + \frac{1}{12}}} = \frac{17,93}{4,48} = 3,999$$

(calcul approché  $s^*=11,4$   $t=3,998$ )

**règle de décision**

- on rejette  $H_0$  en faveur de  $H_1$  au risque  $\alpha=5\%$  si la valeur observée de  $T$ ,  $t$  appartient à  $RC_{5\%} = ]1,711 ; +\infty[$  la région de rejet du test unilatéral au risque  $\alpha=5\%$  et

- on conserve  $H_0$  (on rejette  $H_1$ ) au seuil  $\alpha=5\%$  sinon, c'est-à-dire si  $t$  n'appartient pas à  $RC_{5\%}$ .

**décision**

La valeur observée  $t$  appartient à la région de rejet de  $H_0$  : on rejette donc  $H_0$  en faveur de  $H_1$  au risque  $\alpha=5\%$ .

➔ Le score moyen des mères de prématurés à risque périnatal élevé est supérieur à celui des mères de prématurés à risque très faible au risque  $\alpha=5\%$ , ce qui confirme l'hypothèse de réactions post-traumatiques plus fortes chez les mères de prématurés à risque périnatal élevé, au risque  $\alpha=5\%$ .

## Exercice 2

$\mathcal{P} = \{\text{joueurs adeptes du jeu de rôle en ligne Everquest}\}$

$X = \text{âge}$ , définie sur  $E = \{\text{adolescent, adulte}\}$  variable qualitative à 2 modalités,

$Y = \text{durée hebdomadaire de jeu}$ , définie sur  $F = \{\text{moins de 15h, entre 15h et 30h, plus de 30h}\}$  variable qualitative à 3 modalités.

1. Test du khi-deux d'indépendance :  $\begin{cases} H_0: X \text{ et } Y \text{ indépendantes} \\ H_1: X \text{ et } Y \text{ liées} \end{cases}$  bilatéral au risque  $\alpha=1\%$ .

Sur deux échantillons appariés de  $X$  et de  $Y$  issus de  $\mathcal{P}$  de taille  $n=518$ , les effectifs observés  $n_{ij}$  et les effectifs théoriques sous  $H_0$  (attendus sous  $H_0$ )  $e_{ij}$  sont notés entre parenthèses dans le tableau suivant, puisque  $e_{11}=142 \times 82 / 518 = 22,48$  et  $e_{22}=254 \times 436 / 518 = 213,79$  d'où  $e_{12}=142 - 22,48 = 119,52$   $e_{21}=254 - 213,79 = 40,21$   $e_{31}=82 - (22,48 + 40,21) = 19,31$  et  $e_{32}=436 - (119,52 + 213,79) = 102,69$  (les  $e_{ij}$  sont notés entre parenthèses) :

X durée de jeu	Y âge		total
	adolescent	adulte	
moins de 15 heures	23 (22,5)	119 (119,5)	142
entre 15 et 30 heures	38 (40,2)	216 (213,8)	254
plus de 30 heures	21 (19,3)	101 (102,7)	122
total	82	436	<b>n=518</b>

Sous  $H_0$ , la statistique de test  $Q^2 = \sum \frac{(N_{ij} - e_{ij})^2}{e_{ij}}$  suit approximativement une loi du khi-deux à 2 ddl car  $n=518 \geq 30$  et tous les  $e_{ij}$  sont supérieurs à 5.

La valeur observée de  $Q^2$  vaut :

$$q^2 = \frac{(23-22,5)^2}{22,5} + \frac{(119-119,5)^2}{119,5} + \frac{(38-40,2)^2}{40,2} + \frac{(216-213,8)^2}{213,8} + \frac{(21-19,3)^2}{19,3} + \frac{(101-102,7)^2}{102,7}$$

$$= \frac{0,5^2}{22,5} + \frac{(-0,5)^2}{119,5} + \frac{(-2,2)^2}{40,2} + \frac{2,2^2}{213,8} + \frac{1,7^2}{19,3} + \frac{(-1,7)^2}{102,7} = 0,334$$

### règle de décision

- on rejette  $H_0$  en faveur de  $H_1$  au risque  $\alpha=5\%$  si la valeur observée de  $Q^2$ ,  $q^2$  appartient à  $RC_{1\%}$ , la région de rejet du test au risque  $\alpha=1\%$  :  $RC_{1\%} = ]q_{0,99}^2; +\infty[ = ]9,210; +\infty[$  car  $q_{0,99}^2 = 9,210$  est le quantile d'ordre 0,99 de la loi  $\chi_2^2$  ( $v=2$  et  $P=0,01$ ), et

- on conserve  $H_0$  (on rejette  $H_1$ ) au seuil  $\alpha=1\%$  sinon, c'est-à-dire si  $q^2$  n'appartient pas à  $RC_{1\%}$ .

### décision

$q^2=0,334$  n'appartient pas à  $RC_{1\%}$  donc on ne rejette pas  $H_0$  (conserve  $H_0$  ou on rejette  $H_1$ ) au seuil  $\alpha=1\%$ .

► On ne peut pas accepter l'hypothèse d'un lien entre la durée hebdomadaire de jeu et l'âge des joueurs, au seuil  $\alpha=1\%$  et au risque d'erreur de 2<sup>d</sup> espèce  $\beta$  inconnu.

2.  $\mathcal{P} = \{\text{adolescents joueurs adeptes du jeu de rôle en ligne Everquest}\}$

$X = \text{durée hebdomadaire de jeu}$  définie sur  $E = \{\text{moins de 30h, plus de 30h}\}$  variable qualitative à 2 modalités ou

$X = \text{jouer plus de 30 heures par semaine}$ , définie sur  $E = \{\text{oui, non}\}$  variable qualitative à 2 modalités avec

$p = \text{proportion d'adolescents jouant plus de 30 heures par semaine}$ , inconnue dans  $\mathcal{P}$  ( $q=1-p = \text{proportion}$

d'adolescents jouant moins de 30 heures par semaine, inconnue dans  $\mathcal{P}$ ).

On dispose d'un échantillon de  $X$  issu de la population  $\mathcal{P}$ , de taille  $n=23+38+21=82$  sur lequel on estime  $p$  par

$$f = \frac{21}{82} = 0,256.$$

L'hypothèse que plus de 25% des adolescents jouent plus de 30 heures par semaine correspond au fait que dans la population des adolescents, la proportion de ceux qui jouent plus de 30 heures par semaine  $p$  est supérieure à  $p_0=25\%$ .

C'est un test de comparaison d'une proportion à la proportion théorique  $p_0=25\%=0,25$  :

$$H_0 : p = p_0 = 0,25$$

contre  $H_1 : p > p_0 = 0,25$  alternative unilatérale droite, au risque  $\alpha=5\%$ .

Sous  $H_0$ , puisque  $n=82 \geq 30$ ,  $np_0=82 \times 0,25=20,5 \geq 5$  donc  $n(1-p_0) = 82 \times 0,75 (=61,5) \geq 5$ , ce test est basé sur la statistique de test :

$$\textcircled{1} Z = \frac{(F_n - p_0)\sqrt{n}}{\sqrt{p_0(1-p_0)}} = \frac{(F_n - 0,25)\sqrt{82}}{\sqrt{0,25(1-0,25)}} \text{ qui suit approximativement une loi } \mathcal{N}(0,1) \text{ sous } H_0$$

Sous l'hypothèse alternative unilatérale  $H_1 : p > p_0=0,25$  les valeurs de  $F_n$  ont tendance à être supérieures à  $p_0=0,25$  donc les valeurs de  $Z$  ont tendance à être positives, c'est-à-dire que la région de rejet du test est à droite du domaine de variation de  $Z$ .

La région de rejet du test unilatéral droit au risque  $\alpha=5\%$  :  $RC_{5\%} = ]z_{1-\alpha} ; +\infty[ = ]z_{0,95} ; +\infty[ = ]1,645 ; +\infty[$  car la valeur critique  $z_{1-\alpha}=z_{0,95}=1,645$  est le quantile d'ordre  $1-\alpha=0,95$  de la loi  $\mathcal{N}(0,1)$ .

règle de décision

- on rejette  $H_0$  en faveur de  $H_1$  au risque  $\alpha=5\%$  si la valeur observée de  $Z$ ,  $z$  appartient à la région de rejet du test unilatéral droit au risque  $\alpha=5\%$  :  $RC_{5\%} = ]z_{1-\alpha} ; +\infty[ = ]z_{0,95} ; +\infty[ = ]1,645 ; +\infty[$  et
- on conserve  $H_0$  (on rejette  $H_1$ ) au seuil  $\alpha=5\%$  sinon, c'est-à-dire si  $z$  n'appartient pas à  $RC_{5\%}$ .

décision

La valeur observée de la statistique de test  $Z : z = \frac{(f - p_0)\sqrt{n}}{\sqrt{p_0(1-p_0)}} = \frac{(0,256 - 0,25)\sqrt{82}}{\sqrt{0,25 \times 0,75}} = \frac{0,0552}{0,433} = 0,1275$

(calcul approché  $f=0,256$   $z=0,125$ )

Puisque  $z$  n'appartient pas à la région de rejet de  $H_0$  on conserve donc  $H_0$  (on rejette  $H_1$ ) au seuil  $\alpha=5\%$ .

$$\textcircled{2} F_n \text{ qui suit approximativement une loi normale } \mathcal{N}\left(p_0, \sqrt{\frac{p_0(1-p_0)}{n}}\right) \text{ sous } H_0$$

Sous l'hypothèse alternative unilatérale  $H_1 : p > p_0=0,25$  les valeurs de  $F_n$  ont tendance à être supérieures à  $p_0=0,25$ , c'est-à-dire que la région de rejet du test est à droite de  $p_0=0,25$ .

La région de rejet du test unilatéral droit au risque  $\alpha=5\%$  :  $RC_\alpha = ]p_0 + z_{1-\alpha}\sqrt{\frac{p_0(1-p_0)}{n}} ; +\infty[$  d'où

$$RC_{5\%} = ]0,25 + z_{0,95} \times 0,0478 ; +\infty[ = ]0,25 + 1,645 \times 0,0478 ; +\infty[ = ]0,25 + 0,07866 ; +\infty[ = ]0,329 ; +\infty[$$

où  $z_{1-\alpha} = z_{0,95} = 1,645$  est le quantile d'ordre  $1-\alpha=0,95$  de la loi  $\mathcal{N}(0,1)$ .

règle de décision

- on rejette  $H_0$  (on accepte  $H_1$  ou on valide  $H_1$ ) au risque  $\alpha=5\%$  si la valeur observée de  $F_n$ ,  $f$  appartient à la région de rejet du test unilatéral droit au risque  $\alpha=5\%$  :  $RC_{5\%} = ]0,329 ; +\infty[$  et
- on conserve  $H_0$  (on rejette  $H_1$ ) au seuil  $\alpha=5\%$  sinon, c'est-à-dire si  $z$  n'appartient pas à  $RC_{5\%}$ .

décision

La valeur observée de la statistique de test  $F_n : f = 0,256$

Puisque  $f$  n'appartient pas à la région de rejet de  $H_0$  on conserve donc  $H_0$  (on rejette  $H_1$ ) au seuil  $\alpha=5\%$ .

► On ne peut pas accepter l'hypothèse que plus de 25% des adolescents jouent plus de 30 heures par semaine, au seuil  $\alpha=5\%$  et au risque de seconde espèce  $\beta$  inconnu.

Le risque minimum pour accepter  $H_1$  (ou pour rejeter  $H_0$ ) est le degré de signification  $\alpha_{obs}$  :

c'est la probabilité d'obtenir sous  $H_0$  une valeur de  $Z$  au moins aussi élevée que celle observée  $z$ , c'est à dire que  $\alpha_{obs} = P(Z \geq z) = P(Z \geq 0,1275) = 1 - F_Z(0,1275) \approx 1 - F_Z(0,13) = 1 - 0,5517 = 0,4483$ .

On accepterait  $H_1$  (rejetterait  $H_0$ ) pour un risque maximum  $\alpha \geq \alpha_{obs} \approx 45\%$  risque minimum.

$$(\alpha_{obs} = P_{H_0}(F_n \geq f) = P_{H_0}(F_n \geq 0,256) = P(Z \geq z) = P(Z \geq 0,1275) \approx 1 - F_Z(0,13) = 0,4483).$$

### Exercice 3

$\mathcal{P} = \{\text{rats soumis au renforcement (avec récompense : boulette de viande)}\}$

$X = \text{temps mis pour atteindre une case d'arrivée à partir d'une case de départ, variable quantitative de moyenne } \mu \text{ et d'écart-type } \sigma, \text{ inconnus dans } \mathcal{P}.$

On dispose d'un échantillon de  $X$  issu de la population  $\mathcal{P}$  de taille  $n=39$  sur lequel

on estime  $\mu$  par  $\bar{x}=23$  sec et  $\sigma$  par  $s=4,2$  sec (estimation biaisée).

L'hypothèse que le renforcement favorise l'apprentissage correspond au fait que avec renforcement, le temps moyen des rats est inférieur au temps moyen sans renforcement, c'est-à-dire que la moyenne  $\mu$  dans la population  $\mathcal{P}$  est inférieure à celle trouvée dans les études antérieures sans renforcement  $\mu_0=25$  sec.

C'est un test de comparaison d'une moyenne à la valeur théorique  $\mu_0 = 25$

test unilatéral gauche de l'hypothèse nulle  $H_0 : \mu = \mu_0 = 25$  contre l'hypothèse alternative  $H_1 : \mu < \mu_0 = 25$  au risque  $\alpha = 1\%$ .

Puisque  $X$  est une variable quelconque,  $\sigma$  est inconnu et  $n=39 \geq 30$ , ce test est basé sur la statistique de test :

$$\textcircled{1} Z = \frac{(\bar{X}_n - \mu_0)\sqrt{n}}{S_n^*} \text{ qui suit approximativement une loi } \mathcal{N}(0,1) \text{ sous } H_0$$

Sous l'hypothèse alternative unilatérale  $H_1 : \mu < \mu_0 = 25$  les valeurs de  $\bar{X}_n$  ont tendance à être inférieures à  $\mu_0 = 25$  donc les valeurs de  $Z$  ont tendance à être négatives, c-à-d que la région de rejet du test est à gauche du domaine de variation de  $Z$ .

La région de rejet du test unilatéral gauche au risque  $\alpha = 1\%$  est  $RC_{1\%} = ]-\infty ; -2,325[$  où la valeur critique  $z_{0,01} = -z_{1-\alpha} = -z_{0,99} = -2,325$  est le quantile d'ordre  $\alpha = 0,01$  (ou  $z_{1-\alpha} = z_{0,99} = 2,325$  quantile d'ordre  $1-\alpha = 0,99$ ) de la loi  $\mathcal{N}(0,1)$ .

La valeur observée de la statistique de test  $Z : z = \frac{(\bar{x} - \mu_0)\sqrt{n}}{s^*} = \frac{(23 - 25)\sqrt{39}}{4,255} = -2,935$  car  $s^* = \sqrt{\frac{39}{38}} \cdot 4,2 = 4,255$ .

#### règle de décision

- on rejette  $H_0$  en faveur de  $H_1$  au risque  $\alpha = 1\%$  si la valeur observée de  $Z$ ,  $z$  appartient à  $RC_{1\%} = ]-\infty ; -2,325[$

- on conserve  $H_0$  (on rejette  $H_1$ ) au seuil  $\alpha = 1\%$  sinon, c'est-à-dire si  $z$  n'appartient pas à  $RC_{1\%}$ .

#### décision

La valeur observée  $z$  appartient à la région de rejet de  $H_0$  : on rejette donc  $H_0$  en faveur de  $H_1$  au risque  $\alpha = 1\%$ .

$$\textcircled{2} \bar{X}_n \text{ qui suit approximativement sous } H_0 \text{ une loi normale de moyenne } \mu_0 = 25 \text{ et d'écart-type } \frac{\sigma}{\sqrt{n}} \approx \frac{s^*}{\sqrt{n}}.$$

Sous l'hypothèse alternative unilatérale  $H_1 : \mu < \mu_0 = 25$  les valeurs de  $\bar{X}_n$  ont tendance à être inférieures à  $\mu_0 = 25$ , c'est-à-dire que la région de rejet du test est à gauche de  $\mu_0 = 25$ .

La région de rejet du test unilatéral gauche au risque  $\alpha = 1\%$  est l'ensemble des valeurs de  $\bar{X}_n$  inférieures à la valeur

$\mu_0 - z_{1-\alpha} \frac{s^*}{\sqrt{n}}$  où  $-z_{1-\alpha} = -z_{0,99} = -2,325$  est le quantile d'ordre  $1-\alpha = 0,99$  de la loi  $\mathcal{N}(0,1)$  :

$$RC_{\alpha} = ]-\infty ; \mu_0 - z_{1-\alpha} \frac{s^*}{\sqrt{n}}[ \text{ d'où } RC_{1\%} = ]-\infty ; 25 - 2,325 \frac{4,255}{\sqrt{39}}[ = ]-\infty ; 25 - 2,325 \times 0,681[ = ]-\infty ; 25 - 1,58[$$

$$RC_{1\%} = ]-\infty ; 23,42[$$

#### règle de décision

- on rejette  $H_0$  en faveur de  $H_1$  au risque  $\alpha = 1\%$  si la valeur observée de  $\bar{X}_n$ ,  $\bar{x}$  appartient à  $RC_{1\%} = ]-\infty ; 23,42[$  et

- on conserve  $H_0$  (on rejette  $H_1$ ) au seuil  $\alpha = 1\%$  sinon, c'est-à-dire si  $\bar{x}$  n'appartient pas à  $RC_{1\%}$ .

#### décision

La valeur observée de la statistique de test  $\bar{X}_n$  est  $\bar{x} = 23$  et appartient à la région de rejet de  $H_0$  : on rejette donc  $H_0$  en faveur de  $H_1$  au risque  $\alpha = 1\%$ .

► Le temps moyen des rats avec renforcement est inférieur à celui des rats sans renforcement au risque  $\alpha = 1\%$  ce qui confirme l'hypothèse que le renforcement favorise l'apprentissage, au risque  $\alpha = 1\%$ .

Le niveau de signification ou degré de signification  $\alpha_{\text{obs}}$  du test unilatéral gauche est la probabilité d'obtenir sous  $H_0$  une valeur de la statistique de test au moins aussi faible que celle observée, c'est à dire que :

① si  $Z$  est la statistique de test

$$\alpha_{\text{obs}} = P(Z \leq z) = P(Z \leq -2,935) = 1 - P(Z \geq 2,935) = 1 - F_Z(2,935) \approx 1 - F_Z(2,94) = 1 - 0,9984 = 0,0016$$

② si  $\bar{X}_n$  est la statistique de test

$$\alpha_{\text{obs}} = P_{H_0}(\bar{X}_n \leq \bar{x}) = P\left(Z \leq \frac{(\bar{x} - \mu_0)\sqrt{n}}{s^*}\right) = P\left(Z \leq \frac{(23 - 25)\sqrt{39}}{4,255}\right) = P(Z \leq -2,935) = 1 - F_Z(2,935) \approx 0,0016$$

➔ Le niveau (ou degré) de signification  $\alpha_{\text{obs}}$  du test  $\alpha_{\text{obs}} \approx 0,16\%$  : on peut rejeter l'hypothèse nulle tant que le risque maximum  $\alpha$  est supérieur à  $\alpha_{\text{obs}} \approx 0,16\%$  ( $\alpha_{\text{obs}}$  est le risque minimum pour rejeter  $H_0$ ).