

Corrigé Partiel 13 juin 2000

Exercice 1

$$Y_1, \dots, Y_{36} \sim i.i.d. N[m; 6.25] \Rightarrow \bar{Y} \sim N\left[m; \frac{6.25}{36}\right]$$

- $P[|N(0.1)| \leq 1.960] = 0.95 \Rightarrow P\left[\bar{Y} - 1.96 \frac{2.5}{6} \leq m \leq \bar{Y} + 1.96 \frac{2.5}{6}\right] = 0.95$
 $P[\bar{Y} - 0.8167 \leq m \leq \bar{Y} + 0.8167] = 0.95$
- Pour $\bar{Y} = 11.26$, l'intervalle de confiance à 95% pour m est $10.443 \leq m \leq 12.077$.
- On suppose que $Y_{Fred} \sim N[m; 6.25]$ indépendant des 36 notes déjà observées. La meilleure prévision ponctuelle de Y_{Fred} serait m si on le connaissait, c'est donc \bar{Y} . L'erreur de prévision $Y_{Fred} - \bar{Y}$ a pour loi $N\left[0; 6.25\left(1 + \frac{1}{36}\right)\right]$.
 $P[|N(0.1)| \leq 2.326] = 0.98 \Rightarrow P\left[\bar{Y} - 2.326 * 2.5 \sqrt{1 + \frac{1}{36}} \leq Y_{Fred} \leq \bar{Y} + 2.326 * 2.5 \sqrt{1 + \frac{1}{36}}\right] = 0.98$
 $P[\bar{Y} - 5.895 \leq Y_{Fred} \leq \bar{Y} + 5.8952] = 0.98$
Numériquement, l'intervalle de prévision à 98% pour Y_{Fred} est $5.365 \leq Y_{Fred} \leq 17.155$.

Exercice 2

Comparaison de deux échantillons normaux indépendants : $X_1, \dots, X_{16} \sim i.i.d. N[m_1; \sigma_1^2]$ et $X_{17}, \dots, X_{36} \sim i.i.d. N[m_2; \sigma_2^2]$.

- Comparaison des variances = Test de $\{\sigma_1^2 = \sigma_2^2\}$ contre $\{\sigma_1^2 \neq \sigma_2^2\}$ (test bilatéral)
 - Refus de $\{\sigma_1^2 = \sigma_2^2\}$ si $\left\{ \frac{S_1^2}{S_2^2} > A \text{ ou } \frac{S_2^2}{S_1^2} > B \right\}$ où S_1^2 et S_2^2 sont les variances empiriques des deux échantillons.
 - Sous Ho, $\frac{S_1^2}{S_2^2} \sim FISHER(15; 19)$ et $\frac{S_2^2}{S_1^2} \sim FISHER(19; 15)$. En mettant 5% de probabilité de chaque côté, on lit dans la table de FISHER à 5% les valeurs de A et B : $P[FISHER(15; 19) > 2.23] = 5\%$ et $P[FISHER(19; 15) > 2.34]$.
 - On observe $\frac{S_2^2}{S_1^2} = \frac{12.083}{5.811} = 2.079 < 2.34$, donc les observations sont en dehors de la région critique
 - Conclusion : au seuil de 10%, on ne peut refuser l'hypothèse d'égalité des variances des notes dans les deux sections.
- Comparaison des moyennes : on suppose ici que les variances sont égales. La meilleure prévision de la variance commune est alors : $S^2 = \frac{15S_1^2 + 19S_2^2}{15+19}$. On teste $\{m_1 = m_2\}$ contre $\{m_1 < m_2\}$ (test unilatéral).
 - Refus de $\{m_1 = m_2\}$ si $Z = \frac{\bar{X}_2 - \bar{X}_1}{\sqrt{S^2(1/16+1/20)}} > A$.
 - Sous Ho, $Z \sim STUDENT(34)$. La table de Student nous fournit (colonne 0.20) $P[STUDENT(\infty) > 1.281] = 10\%$, et donc $A = 1.28$.
Remarque : l'énoncé autorise l'utilisation de la loi Normale (student(∞)), et le calcul exact, non disponible sur la table fournie, aurait donné $A = 1.307$. On voit en fait que $A = 1.3$ serait tout à fait exact.
 - On observe $S^2 = \frac{15*5.811+19*12.083}{34} = 9.316$ et $z = \frac{11.247-9.222}{\sqrt{9.316(36/320)}} = 1.98$
 - Conclusion : au seuil de 10%, on décide que les notes dans la section S2 ont une espérance mathématique supérieure à celle des notes dans la section S1.

Exercice 3

- Le modèle est linéaire, car $E(Y_i) = a_1x_{1i} + b_1e_{1i} + a_2x_{2i} + b_2e_{2i}$ est combinaison linéaire de (a_1, b_1, a_2, b_2) , en posant de façon usuelle $e_{1i} = 1$ si $i \in S1$ et 0 sinon, $e_{2i} = 1$ si $i \in S2$ et 0 sinon, $x_{1i} = x_i e_{1i}$ et $x_{2i} = x_i e_{2i}$.
Pour que le modèle soit de plus standard, il faut de plus que $\sigma_1^2 = \sigma_2^2$, car l'absence d'autocorrélations est déjà acquise (les individus sont indépendants).
- Comparaison de variances : on teste $\{\sigma_1^2 = \sigma_2^2\}$ contre $\{\sigma_1^2 \neq \sigma_2^2\}$.
 - Refus de $\{\sigma_1^2 = \sigma_2^2\}$ si $\left\{ \frac{S_1^2}{S_2^2} > A \text{ ou } \frac{S_2^2}{S_1^2} > B \right\}$ où $S_1^2 = \frac{SCR1}{14}$ et $S_2^2 = \frac{SCR2}{18}$ sont les variances résiduelles des deux régressions.

- Sous H_0 , $\frac{s_1^2}{s_2^2} \sim FISH(14; 18)$ et $\frac{s_2^2}{s_1^2} \sim FISH(18; 14)$. En mettant 5% de probabilité de chaque côté, on lit dans la table de FISHER à 5% les valeurs de A et B : $P[FISH(14; 18) > 2.29] = 5\%$ et $P[FISH(18; 14) > 2.41]$.
 - On observe $s_1^2 = \frac{0.4394}{14} = 0.0314$ et $s_2^2 = \frac{0.7008}{18} = 0.0389$
 $\frac{s_2^2}{s_1^2} = \frac{0.7008/18}{0.4394/14} = 1.24 < 2.41$, donc les observations sont en dehors de la région critique
 - Conclusion : au seuil de 10%, on peut accepter l'hypothèse d'égalité des variances des perturbations dans les deux sections.
3. modèle contraint :
- a. égalité des paramètres entre les deux sections : $\{a_1 = a_2, b_1 = b_2\}$.
 - b. Test de sous hypothèse linéaire = test simultané des deux contraintes. La SCR non contrainte est la somme des SCR des deux régressions partielles : SCR1 + SCR2 avec $14 + 18 = 32$ degrés de liberté, la régression sous contrainte étant celle effectuée sur toutes les données, donnant SCR.
 - refus de H_0 si $F = \frac{(SCR - SCR1 - SCR2)/2}{(SCR1 + SCR2)/32} > A$.
 - Sous H_0 , $F \sim FISH(2; 32)$. On lit dans la table de FISHER à 5% la valeur de A : $P[FISH(2; 32) > 3.30] = 5\%$
 - On observe $F = \frac{(1.1707 - 0.4394 - 0.7008)/2}{(0.4394 + 0.7008)/32} = 0.428 < 3.3$
 - Conclusion : au seuil de 5%, les observations ne permettent pas de déceler un changement des paramètres entre les deux sections.
4. Régression (II) $y = 0.788x + 3.105e + \hat{u}$,
- a. les variances covariances du couple (\hat{a}, \hat{b}) sont données par $\sigma^2(X'X)^{-1}$, où $X = \begin{pmatrix} x & e \end{pmatrix}$:
 $Var(\hat{a}) = 0.331\sigma^2$, $Var(\hat{b}) = 0.00283\sigma^2$, $Cov(\hat{a}, \hat{b}) = -0.0293\sigma^2$
 On acceptera également la version $Var(\hat{a}) = 0.00283\sigma^2$, $Var(\hat{b}) = 0.331\sigma^2$, $Cov(\hat{a}, \hat{b}) = -0.0293\sigma^2$ qui correspond à l'interprétation $X = \begin{pmatrix} e & x \end{pmatrix}$, puisque les résultats numériques sont données en mettant la constante d'abord.
 - b. $\hat{\sigma}^2 = \frac{SCR}{36-2} = \frac{1.1707}{34} = 0.0344$
 - c. On en déduit : $Var(\hat{a}) = 0.011397$, $Var(\hat{b}) = 9.74 * 10^{-5}$, $Cov(\hat{a}, \hat{b}) = -0.00101$
 Variante acceptée : $Var(\hat{b}) = 0.011397$, $Var(\hat{a}) = 9.74 * 10^{-5}$, $Cov(\hat{a}, \hat{b}) = -0.00101$
5. Test de $\{a = 0\}$ contre $\{a \neq 0\}$: test de student bilatéral.
- refus de H_0 si $\left| \frac{\hat{a}}{\hat{\sigma}_a} \right| > A$, où $\hat{\sigma}_a = \sqrt{Var(\hat{a})}$.
 - Sous H_0 , $\frac{\hat{a}}{\hat{\sigma}_a} \sim STUDENT(34)$. On choisit de faire un test de seuil 5%. On lit dans la table de Student (colonne 0.05) : $P[STUDENT(34) > 2.0] = 5\%$.
 - On observe $\left| \frac{\hat{a}}{\hat{\sigma}_a} \right| = \frac{3.105}{\sqrt{0.0114}} = 29.1 > 2...$ Variante acceptée : $\left| \frac{\hat{a}}{\hat{\sigma}_a} \right| = \frac{3.105}{\sqrt{0.0000974}} = 314.6 > 2$.
 - Conclusion : au seuil de 5%, la note moyenne annuelle explique les variations de la note du bac.
6. Prédiction de Y_{Fred} : la meilleure prédiction sachant que $x_{Fred} = 11$ est $\hat{Y} = 11\hat{a} + \hat{b}$, indépendante de Y_{Fred} . L'erreur de prédiction $Y_{Fred} - \hat{Y} \sim N[0, V]$ où
 $V = \left(\sigma^2 + (11)^2 Var(\hat{a}) + 2 * 11 Cov(\hat{a}, \hat{b}) + Var(\hat{b}) \right) = \sigma^2(1 + 40.409)$ est estimée par $41.409\hat{\sigma}^2$.
 Variante acceptée :
 $(11)^2 Var(\hat{a}) + 2 * 11 Cov(\hat{a}, \hat{b}) + Var(\hat{b}) = \sigma^2(121 * 0.00283 - 11 * 0.0293 + 0.331) = 0.3511\sigma^2$
 $\frac{Y_{Fred} - \hat{Y}}{\sqrt{\hat{\sigma}^2 41.41}} \sim STUDENT(34)$ et $P[|STUDENT(34)| < 2.33] = 98\%$
 L'intervalle de prédiction à 98% pour Y_{Fred} est donc :
 $P\left[11\hat{a} + \hat{b} - 2.33 * \sqrt{\hat{\sigma}^2 41.41} \leq Y_{Fred} \leq 11\hat{a} + \hat{b} + 2.33 * \sqrt{\hat{\sigma}^2 41.41} \right] = 0.98$
 Sa réalisation est ici : $8.991 \leq Y_{Fred} \leq 14.555$
 Variante acceptée : $11.517 \leq Y_{Fred} \leq 12.029$

Exercice 4

1. Test de $\{\lambda = 1\}$ contre $\{\lambda = 2\}$, avec $X_1, \dots, X_4 \sim i.i.d. POISSON(\lambda)$
 - a. Le test le plus puissant parmi ceux de seuil 10% exactement est celui de région critique $\sum_{i=1}^4 X_i > A$,
 (car $2 > 1$), où A est déterminé par $P\left[\sum_{i=1}^4 X_i > A \mid \lambda = 1 \right] = 0.10$

Or sous H_0 , $\sum_{i=1}^4 X_i \sim \text{POISSON}(4)$. Il n'existe pas de réel A qui corresponde exactement au seuil de 10% : on passe directement de 0.1106 à 0.0511, puisque la variable de Poisson prend des valeurs entières.

b. Le test le plus puissant sera celui de seuil maximal, parmi ceux de seuil inférieur à 10%. On prendra donc la règle de refuser $\{\lambda = 1\}$ si $\sum_{i=1}^4 X_i \geq 8$.

c. Le seuil exact de ce test est $P\left[\sum_{i=1}^4 X_i \geq 8 \mid \lambda = 1\right] = 0.0511$

d. La puissance de ce test est $P\left[\sum_{i=1}^4 X_i \geq 8 \mid \lambda = 2\right] = 0.5471$, lu dans loi de Poisson de paramètre $2 \cdot 4 = 8$.

2. Le test ainsi défini ne dépend pas de la valeur de λ dans l'alternative, tant que cette valeur reste supérieure à 1 : il est donc uniformément le plus puissant pour $\{\lambda = 1\}$ contre $\{\lambda > 1\}$.

3. On regarde dans la table entre les colonnes $\lambda = 4$ et $\lambda = 8$:

$$P[Z \geq 7 \mid \lambda = 1] = 0.1106 \quad P[Z \geq 7 \mid \lambda = 2] = 0.6867 < 1 - 0.1106 = 0.8894$$

$$P[Z \geq 6 \mid \lambda = 1] = 0.2148 \quad P[Z \geq 7 \mid \lambda = 2] = 0.8088 > 1 - 0.2148 = 0.7852$$

Il faut donc prendre $\alpha = 21.5\%$ pour que la puissance en $\lambda = 2$ soit supérieure à $1 - \alpha$.