



NOM PRÉNOM :

N° Carte d'étudiant :

Signature :

- **Durée** : 2 heures. Calculatrice autorisée. Téléphone portable interdit.

**Exercice 1**

Une enquête concernant l'usage d'internet (en dehors du travail) a été menée dans 4 pays  $P_1$ ,  $P_2$ ,  $P_3$  et  $P_4$ . Pour chaque personne participant à l'enquête, on a notamment relevé son pays de résidence ( $P_1$ ,  $P_2$ ,  $P_3$  ou  $P_4$ ), et mesuré le temps hebdomadaire (exprimé en heures) qu'elle passe sur internet.

1. Quelles sont les variables étudiées ici et leur nature?

$X = Pays$  (*qualitative nominale*)

$Y = Temps$  hebdomadaire passé sur internet (*numérique continue*)

Pour les personnes résidant dans le pays  $P_1$ , on a le tableau contenant les informations suivantes:

Effectif	450
1 <sup>er</sup> décile	2.4 h
Temps médian	11.2 h
Ecart inter-quartile	11.3 h
3 <sup>ème</sup> quartile	19.1 h
Temps moyen	13.6 h
Ecart-type	8.2 h

2. Proposer (en précisant les valeurs correspondantes) :

- a) Deux indices de dispersion.

$Ecart\text{-}type = 8.2$

$Ecart\ inter\text{-}quartile = 11.3$

- b) Deux indices de tendance centrale.

$Moyenne = 13.6$

$Médiane = 11.2$

3. Quelle est la proportion de personnes du pays  $P_1$  passant au plus 19.1 heures (par semaine) sur internet? Pourquoi?

75% car 3<sup>ème</sup> quartile = 19.1

4. 75% des personnes du pays  $P_1$  passent au moins 8.8 heures (par semaine) sur internet. Cette affirmation est-elle vraie? Sinon corriger la en justifiant.

*Non, l'affirmation correcte est: 75% des personnes du pays  $P_1$  passent au moins 7.8 heures car:*

$$1^{er} \text{ quartile} = Q_1 = Q_3 - EIQ = 19.1 - 11.3 = 7.8$$

Parmi les personnes résidant dans le pays  $P_2$ , on a la répartition suivante: 30% passent entre 0 et 5 heures (par semaine) sur internet, 25% passent entre 5 et 10 heures, 20% entre 10 et 20 heures, et le reste entre 20 et 40 heures.

5. A partir des variables identifiées à la question 1., indiquer précisément quelle distribution est représentée ci-dessus.

*Distribution conditionnelle de Y sachant X =  $P_2$ .*

6. Sachant que l'échantillon comprend 500 personnes résidant dans le pays  $P_2$ , calculer les effectifs de la distribution mentionnée à la question précédente.

Classes Y	[0, 5[	[5, 10[	[10, 20[	[20, 40[
Eff.	150	125	100	125

*Exemple de calcul: 30% \* 500 = 150.*

7. Calculer le temps hebdomadaire moyen (passé sur internet) pour les personnes du pays  $P_2$ .

*Moyenne:*

$$\bar{y}_2 = \frac{150 * 2.5 + 125 * 7.5 + 100 * 15 + 125 * 30}{500} = 13.125 \text{ h}$$

8. Calculer la proportion de personnes du pays  $P_2$  passant moins de 17 heures sur internet.

$$\text{proportion} = 30 + 25 + (17 - 10) * \frac{20}{20 - 10} = 69\%$$

On s'intéresse à présent uniquement aux pays  $P_3$  et  $P_4$ . On dispose des résultats suivants : pour le pays  $P_3$ , l'effectif est de 540 personnes, la moyenne 10.3 heures et la variance 105.6, alors que pour le pays  $P_4$ , l'effectif est de 460 personnes, la moyenne 12.7 heures et la variance 115.3.

9. Calculer le temps moyen passé sur internet pour l'ensemble des personnes des pays  $P_3$  et  $P_4$ .

$$Tps\ moyen = \frac{540 * 10.3 + 460 * 12.7}{1000} = 11.404\ h$$

10. Calculer la variance intra.

$$Var\ intra = \frac{540 * 105.6 + 460 * 115.3}{1000} = 110.06$$

11. Calculer la variance inter.

$$Var\ inter = \frac{540 * (10.3 - 11.4)^2 + 460 * (12.7 - 11.4)^2}{1000} = 1.43$$

12. En déduire la variance globale du "temps passé sur internet" (pour les pays  $P_3$  et  $P_4$ ).

$$Variance\ globale = 110.06 + 1.43 = 111.49$$

13. Comparer les moyennes par l'analyse de la variance. On prendra  $\alpha = 0.1\%$  pour faire le test. Pour les quantiles associés à une distribution théorique du  $\chi^2$ , on donne:  $q_{99.9\%}(1) = 10.83$  (ddl = 1),  $q_{99.9\%}(2) = 13.82$  (ddl = 2) et  $q_{99.9\%}(3) = 16.27$  (ddl=3).

*Hypothèse H: "Les 2 moyennes sont identiques".*

*Calcul:*

$$\begin{aligned} t &= (1000 - 2) * \frac{Var\ inter}{Var\ intra} \\ &= 998 * \frac{1.43}{110.06} \\ &= 12.97 \end{aligned}$$

*ddl = 2 - 1 = 1 donc seuil du test:  $q_{99.9\%}(1) = 10.83$*

*Comme  $t > 10.83$  alors conclusion du test: rejet de l'hypothèse H (les moyennes ne sont pas identiques).*

**Exercice 2** (les 2 questions sont indépendantes)

1. Si la variance d'une variable numérique  $Y$  est égale à 0, que peut-on dire sur la valeur de la médiane par rapport à celle du 3<sup>ème</sup> quartile?

*Elles sont identiques.*

2. Compléter le tableau de contingence en effectifs ci-dessous de telle sorte que la variance inter soit nulle.

<b>X \ Y</b>	[0, 2[	[2, 4[	[4, 6[	<b>Total X</b>
Groupe 1	<b>4</b>	<b>0</b>	1	5
Groupe 2	<b>3</b>	2	<b>0</b>	
<b>Total Y</b>				<b>n = 10</b>

car  $\bar{y}_1 = \frac{4*1+1*5}{5} = \frac{9}{5}$  et  $\bar{y}_2 = \frac{3*1+2*3}{5} = \frac{9}{5}$ .

**Exercice 3:** Une étude portant sur 10 étudiants en 2ème année de licence de psychologie a relevé le nombre d'heures (par semaine) passées devant la télévision (variable notée  $\mathbf{X}$ ) et la note (sur 20) obtenue en statistique sur l'ensemble de l'année (variable notée  $\mathbf{Y}$ ) pour chacun des 10 étudiants.

$\mathbf{X}$	13	9	17	6	24	8	14	12	3	20
$\mathbf{Y}$	8.4	5.4	1.5	15.4	2.5	13.6	9.0	11.1	16.7	10.0

1. Calculer le nombre moyen d'heures passées devant la télévision et la note moyenne obtenue en statistique (pour l'ensemble des 10 étudiants).

$$\bar{x} = \frac{13 + \dots + 20}{10} = 12.6 \text{ h}$$

et

$$\bar{y} = \frac{8.4 + \dots + 10}{10} = 9.36$$

2. Calculer la variance puis l'écart-type de  $\mathbf{X}$ .

$$\sigma^2(x) = \frac{13^2 + \dots + 20^2}{10} - 12.6^2 = 37.64$$

et

$$\sigma(x) = \sqrt{37.64} = 6.14$$

3. Quelles conséquences aurait la multiplication de toutes les notes par 1.2 sur la moyenne et sur la variance de  $\mathbf{Y}$ ?

*Moyenne multipliée par 1.2 et variance multipliée par  $(1.2)^2 = 1.44$*

4. Calculer la covariance du couple  $(\mathbf{X}, \mathbf{Y})$ .

$$\begin{aligned} Cov(x, y) &= \frac{13 * 8.4 + \dots + 20 * 10}{10} - (12.6 * 9.36) \\ &= 95.38 - 117.94 \\ &= -22.56 \end{aligned}$$

5. Sachant que l'écart-type de  $\mathbf{Y}$  est égal à 4.9, en déduire la valeur du coefficient de corrélation linéaire  $r(\mathbf{x}, \mathbf{y})$ . Commenter.

$$r(x, y) = \frac{Cov(x, y)}{\sigma(x) * \sigma(y)} = \frac{-22.56}{6.14 * 4.9} = -0.75$$

*r assez proche de  $-1$  donc corrélation linéaire négative (assez forte) entre X et Y.*

*De plus, X et Y évoluent en moyenne dans le sens opposé.*