

HAI205X Probas stats - Correction

Assurez-vous de présenter vos réponses de manière claire et lisible. Les exercices peuvent être traités dans le désordre. La calculatrice est autorisée. Les valeurs numériques seront arrondies à deux décimales. Le barème est donné à titre indicatif. Vous avez 1 heure. Bon courage !

Exercice 1 (12.5 points)

1. (2.5 points) Le temps journalier devant les écrans pour 50 étudiants de licence d'informatique sont donnés dans le tableau suivant:

| Temps journalier (heures) | [0; 2[| [2; 4[| [4; 6[| [6; 8[| [8; 10[|
|---------------------------|--------|--------|--------|--------|---------|
| Nombre d'étudiants | 2 | 5 | 13 | 19 | 11 |

- (a) (0.5 points) Calculer le temps moyen passé, par jour, devant les écrans pour ces étudiants.

Solution: $\bar{X} = \frac{1}{50}(2 \times 1 + 5 \times 3 + 13 \times 5 + 19 \times 7 + 11 \times 9) = 6.28$

- (b) (1 point) Déterminer, par le calcul, la médiane. **Solution:** $Me = \frac{25-20}{39-20} \times 2 + 6 = 6.53$

| Temps journalier (heures) | [0; 2[| [2; 4[| [4; 6[| [6; 8[| [8; 10[|
|---------------------------|--------|--------|--------|--------|---------|
| Nombre d'étudiants | 2 | 5 | 13 | 19 | 11 |
| Cumulé | 2 | 7 | 20 | 39 | 50 |

- (c) (1 point) Déterminer, par le calcul, l'intervalle interquartile. **Solution:** $Q_1 = \frac{13-7}{20-7} \times 2 + 4 = 4.92$ et $Q_3 = \frac{38-20}{39-20} \times 2 + 6 = 7.89$ donc $IQR = Q_3 - Q_1 = 7.89 - 4.92 = 2.97$

2. (10 points) Le temps journalier devant les écrans pour 50 étudiants de licence de mathématiques sont donnés dans le tableau suivant:

| Temps journalier (heures) | [0; 2[| [2; 4[| [4; 6[| [6; 8[| [8; 10[|
|---------------------------|--------|--------|--------|--------|---------|
| Nombre d'étudiants | 6 | 12 | 21 | 8 | 3 |

- (a) (5.5 points) A l'aide d'un graphique, dont vous donnerez le nom, comparer les deux distributions. Commenter le résultat. **Solution:** On calcule les effectifs cumulés (ou fréquences cumulées): On calcule la moyenne, la médiane, Q_1 , Q_3 et l'intervalle interquartile. $\bar{X} = \frac{1}{50}(6 \times 1 + 12 \times 3 + 21 \times 5 + 8 \times 7 + 3 \times 9) = 4.60$, $Me = \frac{25-18}{39-18} \times 2 + 4 = 4.67$, $Q_1 = \frac{13-6}{18-6} \times 2 + 2 = 3.17$, $Q_3 = \frac{38-18}{39-18} \times 2 + 4 = 5.90$ et $IQR = 5.90 - 3.17 = 2.73$. On regroupe les informations sous forme de boxplot.

| | | | | | |
|---------------------------|--------|--------|--------|--------|---------|
| Temps journalier (heures) | [0; 2[| [2; 4[| [4; 6[| [6; 8[| [8; 10[|
| Nombre d'étudiants | 6 | 12 | 21 | 8 | 3 |
| Cumulé | 6 | 18 | 39 | 47 | 50 |

- (b) (4.5 points) Evaluer la dispersion relative du temps d'écran des deux groupes d'étudiant. En déduire le groupe le plus homogène **Solution:** On calcule le coefficient de variation et le coefficient de dissymétrie de Pearson. $C_v(info) = \frac{\sigma}{\bar{X}} = \frac{\sqrt{4.44}}{6.28} = \frac{2.11}{6.28} = 0.34$ et $C_v(math) = \frac{\sqrt{4.32}}{4.60} = \frac{2.08}{4.60} = 0.45$. La dispersion chez les matheux est plus légèrement plus grande. $S(info) = \frac{\bar{X}-Mode}{\sigma} = \frac{6.28-7}{2.11} = -0.34$ et $S(math) = \frac{\bar{X}-Mode}{\sigma} = \frac{4.60-5}{2.08} = -0.19$ les séries sont étalées à gauche. On remarque que le temps d'écran est plus grand en moyenne chez les informaticiens, mais les valeurs sont plus dispersés chez les matheux.

Exercice 2 (5.5 points)

On s'intéresse au développement de la myopie chez les étudiants. Le niveau de dioptrie (mesure allant de 0 à 20) est mesuré sur 8 étudiants pendant leur cursus universitaire.

| | | | | | | | | |
|--------------------------|------|------|------|------|------|------|------|------|
| Numéro i de l'étudiant | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 |
| Dioptrie | 0.50 | 0.25 | 2.10 | 1.90 | 2.90 | 3.50 | 4.30 | 5.90 |
| Temps d'étude | 0.50 | 1 | 2 | 2 | 2.50 | 3.50 | 3.50 | 4.50 |

- (2 points) Calculer la covariance et le coefficient de corrélation. Commenter. **Solution:** Soit X le temps d'étude et Y la mesure de dioptrie. $\bar{X} = \frac{1}{8}(0.5 + 1 + 2 + 2 + 2.5 + 3.5 + 3.5 + 4.5) = 2.44$, $\bar{Y} = \frac{1}{8}(0.5 + 0.25 + 2.10 + 1.90 + 2.90 + 3.50 + 4.30 + 5.90) = 2.67$ et $\bar{XY} = \frac{1}{8}(0.5 \times 0.5 + 1 \times 0.25 + 2 \times 2.10 + 2 \times 1.90 + 2.5 \times 2.90 + 3.5 \times 3.50 + 3.5 \times 4.30 + 4.5 \times 5.90) = 8.70$ $Cov(X, Y) = \bar{XY} - \bar{X}\bar{Y} = 8.70 - 2.44 \times 2.67 = 2.18$. $\sigma_X = \sqrt{\frac{1}{8}(0.5^2 + 1^2 + 2^2 + 2^2 + 2.5^2 + 3.5^2 + 3.5^2 + 4.5^2) - 2.44^2} = \sqrt{1.58} = 1.26$ et $\sigma_Y = \sqrt{\frac{1}{8}(0.5^2 + 0.25^2 + 2.10^2 + 1.90^2 + 2.90^2 + 3.5^2 + 4.30^2 + 5.90^2) - 2.67^2} = \sqrt{3.16} = 1.78$, le coefficient de corrélation est $r_{X,Y} = \frac{Cov(X,Y)}{\sigma_X\sigma_Y} = \frac{2.18}{1.26 \times 1.78} = 0.97$ Le coefficient de corrélation de Pearson est proche de 1 donc la dioptrie est positivement corrélé linéaire avec le temps d'étude. Ici la régression optimale est donc linéaire.
- (2 points) Déterminer par la méthode des moindres carrés le coefficient de régression de la courbe. **Solution:** On a $Y = aX + b$. On estime $a = \frac{Cov(X,Y)}{V(X)} = \frac{2.18}{1.58} = 1.38$. On peut maintenant estimer $b = \bar{Y} - a\bar{X} = 2.67 - 1.38 \times 2.44 = -0.70$.
- (1.5 points) Un étudiant rejoint l'étude après 4 année d'étude universitaire. Estimer sa dioptrie. Interpréter les résultats. (indication : une dioptrie inférieur à 3.25 correspond à une myopie légère, inférieure à 6.75 à une myopie moyenne et au delà à un myopie forte. **Solution:** On a $\hat{Y} = 1.38 \times 4 - 0.70 = 4.82$. Après 4 année d'étude universitaire, l'étudiant aura, d'après le modèle posé, une dioptrie de 4.82, ce qui correspond à une myopie moyenne.

Exercice 3 (4 points)

Il s'agit d'un questionnaire à choix multiple. La justification de certains calculs serait appréciée.

1. (1 point) Quand les amplitudes sont inégales, pour dessiner l'histogramme:
 - (a) On calcule l'étendu
 - (b) On corrige les effectifs
 - (c) On calcule les effectifs cumulés
 - (d) On calcule la densité des fréquences

Solution: b, d

2. (1 point) La représentation graphique d'une variable quantitative discrète est
 - (a) Un diagramme en bâton
 - (b) Un histogramme
 - (c) Une courbe de fréquences cumulées
 - (d) Le polygone de fréquences

Solution: a, c, d

3. (1 point) A partir de la Table 1, quelles affirmations sont vraies ?

| X \ Y | [0; 3[| [3; 6[| [6; 9[|
|----------|--------|--------|--------|
| [0; 20[| 18 | 2 | 0 |
| [20; 40[| 8 | 10 | 2 |
| [40; 60[| 4 | 10 | 6 |
| [60; 80[| 2 | 8 | 10 |

Table 1: Répartition des mesures de dioptrie en fonction de l'âge.

- (a) Les fréquences marginales de Y sont $f_{[0;3[}(y) = 0.40$, $f_{[3;6[}(y) = 0.37$ et $f_{[6;9[}(y) = 0.23$.
- (b) Les fréquences marginales de X sachant $Y = [0; 3[$ sont $f_{[0;20[}(x) = 0.56$, $f_{[20;40[}(x) = 0.25$, $f_{[40;60[}(x) = 0.12$ et $f_{[60;80[}(x) = 0.07$.
- (c) La moyenne marginale de X est 40.
- (d) La formule de la variance conditionnelle de Y sachant $X = [20; 40[$ est $V_{X=[20;40[}(Y) = \frac{1}{20}(8 \times 0^2 + 10 \times 3^2 + 2 \times 6^2) - \bar{Y}_{X=[20;40[}^2$, où $\bar{Y}_{X=[20;40[}$ est la moyenne conditionnelle de Y sachant $X = [20; 40[$.

Solution: a, c $\bar{X} = \frac{1}{80}(20 \times 10 + 20 \times 30 + 20 \times 50 + 20 \times 70) = 40$. **Pour la variance conditionnelle il faut utiliser les centres de classes.**

4. (1 point) A partir de la Table 1, quelles affirmations sont vraies ?
 - (a) Il y a une corrélation positive entre âge et mesure de dioptrie.
 - (b) Il y a une corrélation négative entre âge et mesure de dioptrie.
 - (c) Le coefficient de corrélation linéaire est $r_{X,Y} = 0.81$.

(d) Le coefficient de corrélation linéaire est $r_{X,Y} = 0.31$.

Solution: a, d $r_{X,Y} = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$.

$$Cov(X, Y) = \bar{XY} - \bar{X}\bar{Y} = \frac{1}{80}(18 \times 10 \times 1.5 + \dots + 10 \times 70 \times 7.5) - 40 \times 3.97 = 31.7$$

$$\sigma_X = \sqrt{500} = 22.36 \text{ et } \sigma_Y = \sqrt{21.15} = 4.60$$

$$\text{donc } r_{X,Y} = \frac{31.7}{22.36 \times 4.60} = 0.31.$$