


TD n°2 de Statistiques : médiane et quartiles

I] Exemple des séries 1 et 2 du cours

a) Compléter ces deux tableaux qui correspondent à deux séries statistiques différentes

| valeurs | [0 ; 100[| [100 ; 200[| [200 ; 300[| [300 ; 400[| [0 ; 100[| [100 ; 200[| [200 ; 300[| [300 ; 400[|
|--------------------------------|-----------|-------------|-------------|-------------|-----------|-------------|-------------|-------------|
| effectifs | 5 | 12 | 20 | 7 | 6 | 96 | 143 | 12 |
| Cumul croissant des effectifs | 5 | 17 | 37 | 44 | 6 | 102 | 245 | 257 |
| fréquences | 11% | 27% | 45% | 16% | 2% | 37% | 56% | 5% |
| Cumul croissant des fréquences | 11% | 38% | 83% | 99% | 2% | 39% | 95% | 100% |

b) Tracer les courbes polygonales donnant les cumuls croissants des fréquences pour ces deux séries. Cette courbe permet de répondre à la question : « quel pourcentage de la population a une valeur inférieure ou égale à x ? ». Le tracé polygonal suppose une *répartition homogène* des valeurs dans chaque classe.



c) Lire graphiquement les valeurs de la médiane M , des 1^{er} et 3^{ème} quartiles Q_1 et Q_3 pour les 2 séries.
 Série n°1 : $M= 225$ $Q_1= 150$ $Q_3= 280$; Série n°2 : $M= 220$ $Q_1= 160$ $Q_3= 260$

d) Calculer, en utilisant le théorème de Thalès, les valeurs précises de la médiane et des quartiles.

D'après les valeurs du tableau pour la Série n°1, le théorème de Thalès conduit à :

$$\frac{M-200}{300-200} = \frac{50-39}{95-39} \text{ soit } \frac{M-200}{100} = \frac{12}{45} \text{ et donc } M = 200 + 100 \times \frac{12}{45} \approx 226,67$$

$$\text{De même pour } Q_1 = 100 + 100 \times \frac{25-11}{27} \approx 151,85 \text{ et } Q_3 = 200 + 100 \times \frac{75-38}{45} \approx 282,22 .$$

D'après les valeurs du tableau pour la Série n°2, le théorème de Thalès conduit à :

$$\frac{M-200}{300-200} = \frac{50-39}{96-39} \text{ soit } \frac{M-200}{100} = \frac{11}{56} \text{ et donc } M = 200 + 100 \times \frac{11}{56} \approx 219,64$$

$$\text{De même pour } Q_1 = 100 + 100 \times \frac{25-2}{37} \approx 162,16 \text{ et } Q_3 = 200 + 100 \times \frac{75-39}{56} \approx 264,29 .$$

e) L'écart inter-quartile *absolu* est $Q_3 - Q_1$. Il mesure la dispersion absolue des valeurs (exprimée dans la même unité que la valeur). L'écart inter-quartile *relatif* est $\frac{Q_3 - Q_1}{Q_2}$. Il mesure la dispersion relative des valeurs (sans unité). Calculer les écarts inter-quartiles relatifs des deux séries, et commentez alors la différence de dispersion des deux séries (lorsqu'une série est très dispersée cet écart est grand, on dit aussi qu'elle est peu concentrée, dispersion et concentration variant en sens inverse).

$$\text{Série n°1 : } \frac{Q_3 - Q_1}{Q_2} = \frac{282,22 - 151,85}{226,67} \approx 0,575 \quad ; \quad \text{Série n°2 : } \frac{Q_3 - Q_1}{Q_2} = \frac{264,29 - 162,16}{219,64} \approx 0,465 .$$

Commentaires : La série n°1 est (beaucoup) plus dispersée que la série n°2, l'écart inter-quartile représentant plus de 57% de la médiane dans la série n°1 contre 46% seulement dans la série n°2.

Prolongements : On peut définir les déciles D_1, D_2, \dots, D_9 de la même manière qu'on a défini les quartiles (ou les centiles C_1, \dots, C_{99}). Lire graphiquement les déciles D_1 et D_9 pour les deux séries ainsi que les écarts inter-déciles absolus $D_9 - D_1$ et relatifs des deux séries $\frac{D_9 - D_1}{D_5}$ (remarque : $D_5 = Q_2 = M$).

D'après les valeurs du tableau pour la série n°1 on a $D_1 = 0 + 100 \times \frac{10-0}{11} \approx 90,91$ et $D_9 = 300 + 100 \times \frac{90-83}{16} = 343,75$ alors que dans la série n°2 on a $D_1 = 100 + 100 \times \frac{10-2}{37} \approx 121,62$ et $D_9 = 200 + 100 \times \frac{90-39}{56} \approx 291,07$. Ces valeurs conduisent aux indicateurs relatifs $\frac{D_9 - D_1}{M} = \frac{343,75 - 90,91}{226,67} \approx 1,115$

pour la série n°1 et $\frac{D_9 - D_1}{M} = \frac{291,07 - 121,62}{219,64} \approx 0,771$ pour la série n°1 qui confirment notre remarque précédente, l'écart entre les 2 séries s'amplifiant lorsqu'on considère une plus grande masse centrale (80% de considérés ici entre D_1 et D_9 alors qu'entre Q_1 et Q_3 , on ne considère que 50% de la population centrale) : l'écart inter-décile représentant plus de 111% de la médiane dans la série n°1 contre 77% seulement dans la série n°2.

II] Autre exemple

On voudrait comparer les répartitions des salaires mensuels dans deux entreprises A et B données par le tableau ci-contre.

a) Calculer la moyenne des deux séries (prendre pour les deux classes extrêmes une amplitude égale à celle des autres classes).

Pour l'entreprise A, la moyenne des salaires est de 1517,4 euros, alors que pour l'entreprise B, elle est de 1471,5 euros.


Pour les calculs des moyennes, nous avons fait un tableau dans lequel nous avons calculé le total des salaires (somme des produits $f_i \cdot x_i$ où f_i est la fréquence de la classe i est x_i est le centre de cette classe) que nous avons divisé ensuite par le total des fréquences (100%).

| Salaire (en euros) | Fréquence A (%) | Fréquence B (%) |
|--------------------|-----------------|-----------------|
| moins de 900 | 5,4 | 5,0 |
| De 900 à 1200 | 15,7 | 14,0 |
| De 1200 à 1500 | 32,3 | 37,0 |
| De 1500 à 1800 | 22,2 | 27,0 |
| De 1800 à 2100 | 15,0 | 14,0 |
| De 2100 à 2400 | 7,5 | 2,5 |
| plus de 2400 | 1,9 | 0,5 |

| | 600-900 | 900-1200 | 1200-1500 | 1500-1800 | 1800-2100 | 2100-2400 | 2400-2700 | Total | Moyenne |
|------------------------------|---------|----------|-----------|-----------|-----------|-----------|-----------|--------|---------|
| Entreprise A f_i | 5,4 | 15,7 | 32,3 | 22,2 | 15 | 7,5 | 1,9 | 100 | |
| Centres de classe x_i | 750 | 1050 | 1350 | 1650 | 1950 | 2250 | 2550 | | |
| Entreprise A $f_i \cdot x_i$ | 4050 | 16485 | 43605 | 36630 | 29250 | 16875 | 4845 | 151740 | 1517,4 |
| Entreprise B f_i | 5 | 14 | 37 | 27 | 14 | 2,5 | 0,5 | | |
| Entreprise B $f_i \cdot x_i$ | 3750 | 14700 | 49950 | 44550 | 27300 | 5625 | 1275 | 147150 | 1471,5 |

b) Construire les courbes de répartition des deux séries (polygones des fréquences cumulées en croissant) et déterminer la médiane, les quartiles et l'écart inter-quartile relatif pour chacune de ces séries.

Répartitions salaires



D'après les valeurs du tableau pour l'entreprise A, on a $M = 1200 + 300 \times \frac{50 - 21,1}{32,3} \approx 1468,42$

De même pour $Q_1 = 1200 + 300 \times \frac{25 - 21,1}{32,3} \approx 1236,22$ et $Q_3 = 1500 + 300 \times \frac{75 - 53,4}{22,2} \approx 1791,89$.

On en déduit l'écart inter-quartile relatif pour l'entreprise A $\frac{Q_3 - Q_1}{Q_2} = \frac{1791,89 - 1236,22}{1468,42} \approx 0,378$

| Entreprise B | 600 | 900 | 1200 | 1500 | 1800 | 2100 | 2400 | 2700 |
|--------------|-----|-----|------|------|------|------|------|------|
| | 0 | 5 | 19 | 56 | 83 | 97 | 99,5 | 100 |

D'après les valeurs du tableau pour l'entreprise B, on a $M = 1200 + 300 \times \frac{50 - 19}{37} \approx 1451,35$

De même pour $Q_1 = 1200 + 300 \times \frac{25 - 19}{37} \approx 1248,65$ et $Q_3 = 1500 + 300 \times \frac{75 - 56}{27} \approx 1711,11$.

On en déduit l'écart inter-quartile relatif pour l'entreprise B $\frac{Q_3 - Q_1}{Q_2} = \frac{1711,11 - 1248,65}{1451,35} \approx 0,319$

c) Conclusion.

L'entreprise A a des salaires plus élevés que l'entreprise B (il y a un écart de 45,9 euros entre les salaires moyens de ces entreprises) et la dispersion des salaires dans cette entreprise A est plus grande que dans la B. Cela veut dire qu'il y aura un plus grand écart de salaire entre ceux qui gagnent beaucoup (25% gagnent plus de 1791 euros) et ceux qui gagnent moins (25% gagnent moins de 1468 euros) : près de 38% du salaire médian. Dans l'entreprise B cet écart représente moins de 32%.