

Thème : Statistiques I, § 1 Statistique descriptive d'une variable discrète

Lien vers les énoncés des exercices:

https://www.deleze.name/marcel/sec2/applmaths/csud/statistique_1/1-stat_I.pdf

Corrigés des exercices du § 0

Corrigé ex 0 - 1

- a) variable continue
(les données sont groupées en classes d'amplitude 1).
- b) variable qualitative
(on ne donne pas de critère quantitatif pour classer les oeufs).
- c) variable discrète
(s'il existe une classe d'amplitude infinie, la variable n'est pas continue).
- d) variable continue
(les données ont été groupées en trois classes).

Corrigé ex 0 - 2

- a) variable discrète
(il y a une session d'examens par année).
- b) variable continue

Corrigés des exercices du § 1

Packages de l'auteur

- On peut consulter le mode d'emploi du package **Statistique**:
<https://www.deleze.name/marcel/sec2/applmaths/packages/aide/Statistique.pdf>
- Avant d'utiliser le package, il faut le charger en donnant son adresse web:

```
Needs["Statistique`",  
  |nécessite  
  "https://www.deleze.name/marcel/sec2/applmaths/packages/Statistique.m"]
```

Voici la liste des instructions disponibles :

```
Names["Statistique`*"]
```

```
|noms
```

```
{amplitudes, densiteContinue, densites, diagrammeBatons,  
  diagrammeCumulatif, distributionContinue, distributionLisee, fctDensite,  
  fctFrequenceCumulee, frequenceCumuleeContinue, frequenceCumuleeLisee,  
  histogramme, InterpolatedQuantile, noeudsPolygonaux, polygoneDeDensite,  
  quantileC, quantileLisse, sommesCumulees, StandardDeviationMLE, VarianceMLE}
```

- Le package **Tableaux** contient des commandes qui facilitent la présentation des données et résultats sous la forme de tableaux:

```
Needs ["Tableaux`",
[nécessite
"https://www.deleze.name/marcel/sec2/applmaths/packages/Tableaux.m"]
```

```
Names ["Tableaux`*"]
```

```
[noms
```

```
{afficheTableau, afficheTableauTitre, arrondis, fusionneColonnes,
fusionneLignes, fusionneTableaux, prodCart, prodCartTrans, tableauGraph}
```

- On peut consulter le mode d'emploi du package **Tableaux**:

<https://www.deleze.name/marcel/sec2/applmaths/packages/aide/Tableaux.pdf>

Pour ne pas oublier d'exécuter ces instructions au début de chaque session de travail, il est conseillé de déclarer les instructions **Needs** comme étant des cellules d'initialisation. Pour ce faire, sélectionnez les cellules voulues puis passez par le menu

Cell / Cell properties / Initialization cell

Corrigé de l'exercice 1 - 1

Modalités


$$c_1 = 4000; \quad c_2 = 50\,000$$


Effectif total

$$n = 9 + 1 = 10$$

Fréquences

$$f_1 = \frac{9}{10}; \quad f_2 = \frac{1}{10}$$





Quantiles

$$Q_{0.25} = 4000;$$

$$Q_{0.5} = 4000;$$

$$Q_{0.75} = 4000$$

Mesures de tendance centrale

Moyenne

$$m = c_1 f_1 + c_2 f_2 = \frac{9 * 4000 + 1 * 50000}{10} = 8600$$

Médiane : classons les 10 personnes par ordre de salaire croissant; le salaire du 5-ème est

$$Me = Q_{0.5} = 4000$$

Mode : le salaire le plus fréquent est

$$Mo = 4000$$

Mesures de dispersion

$$\text{etendue} = 50000 - 4000 = 46000$$

Ecart-type

$$s = \sqrt{(c_1 - m)^2 f_1 + (c_2 - m)^2 f_2} = \sqrt{(4000 - 8600)^2 \frac{9}{10} + (50000 - 8600)^2 \frac{1}{10}} = 13800$$

Ecart interquartile

$$\text{interQuart} = Q_{0.75} - Q_{0.25} = 4000 - 4000 = 0$$

Commentaires

La moyenne est sensible aux valeurs extrêmes tandis que la médiane l'est beaucoup moins.

Malgré que beaucoup de personnes aient le même salaire, les écarts à la moyenne sont grands ($s = 13800$).

Plus de la moitié des personnes ont le salaire médian (interQuart = 0).

Corrigé de l'exercice 1 - 2

Valeurs

$$c_1 = 1, \quad c_2 = 2, \quad c_3 = 3, \quad c_4 = 4, \quad c_5 = 5, \quad c_6 = 6, \quad c_7 = 7$$

Taille de l'échantillon = effectif total

$$n = 48 + 72 + 96 + 64 + 39 + 25 + 3 = 347$$

Fréquences


$$f_1 = \frac{48}{347}, \quad f_2 = \frac{72}{347}, \quad f_3 = \frac{96}{347},$$

$$f_4 = \frac{64}{347}, \quad f_5 = \frac{39}{347}, \quad f_6 = \frac{25}{347}, \quad f_7 = \frac{3}{347}$$

$$f_1 \approx 0.138, \quad f_2 \approx 0.207, \quad f_3 \approx 0.277,$$

$$f_4 \approx 0.184, \quad f_5 \approx 0.112, \quad f_6 \approx 0.072, \quad f_7 \approx 0.009$$

Diagramme à bâtons



Fréquences cumulées

$$F_1 = f_1 = \frac{48}{347} \approx 0.138$$

$$F_2 = f_1 + f_2 = F_1 + f_2 = \frac{48}{347} + \frac{72}{347} = \frac{120}{347} \approx 0.346$$

$$F_3 = f_1 + f_2 + f_3 = F_2 + f_3 = \frac{120}{347} + \frac{96}{347} = \frac{216}{347} \approx 0.622$$


$$F_4 = f_1 + f_2 + f_3 + f_4 = F_3 + f_4 = \frac{216}{347} + \frac{64}{347} = \frac{280}{347} \approx 0.807$$

$$F_5 = F_4 + f_5 = \frac{280}{347} + \frac{39}{347} = \frac{319}{347} \approx 0.919$$

$$F_6 = F_5 + f_6 = \frac{319}{347} + \frac{25}{347} = \frac{344}{347} \approx 0.991$$

$$F_7 = F_6 + f_7 = \frac{344}{347} + \frac{3}{347} = 1$$

Diagramme cumulatif



Moyenne arithmétique

$$m = \sum_{j=1}^k c_j f_j = c_1 f_1 + c_2 f_2 + c_3 f_3 + c_4 f_4 + c_5 f_5 + c_6 f_6 + c_7 f_7 =$$

$$1 \frac{48}{347} + 2 \frac{72}{347} + 3 \frac{96}{347} + 4 \frac{64}{347} + 5 \frac{39}{347} + 6 \frac{25}{347} + 7 \frac{3}{347} = \frac{1102}{347} \approx 3.17579$$

Mode (voir le diagramme à bâtons)

$$Mo = 3$$

Médiane (voir le diagramme cumulatif)

$$Me = Q_{\frac{1}{2}} = 3$$

Etendue (voir les valeurs données)

$$7 - 1 = 6$$

Variance (moyenne arithmétique des carrés des écarts à la moyenne)

$$s^2 = \sum_{j=1}^k (c_j - m)^2 f_j = (c_1 - m)^2 f_1 + (c_2 - m)^2 f_2 +$$

$$(c_3 - m)^2 f_3 + (c_4 - m)^2 f_4 + (c_5 - m)^2 f_5 + (c_6 - m)^2 f_6 + (c_7 - m)^2 f_7 =$$

$$\left(1 - \frac{1102}{347}\right)^2 \frac{48}{347} + \left(2 - \frac{1102}{347}\right)^2 \frac{72}{347} + \left(3 - \frac{1102}{347}\right)^2 \frac{96}{347} + \left(4 - \frac{1102}{347}\right)^2 \frac{64}{347} +$$

$$\left(5 - \frac{1102}{347}\right)^2 \frac{39}{347} + \left(6 - \frac{1102}{347}\right)^2 \frac{25}{347} + \left(7 - \frac{1102}{347}\right)^2 \frac{3}{347} = \frac{258958}{120409} \approx 2.15065$$

Ecart-type (moyenne quadratique des écarts à la moyenne = racine carrée de la variance)

$$s = \sqrt{\frac{258958}{120409}} \approx 1.46651$$

Premier quartile (dans le diagramme cumulatif, valeur qui correspond à la fréquence cumulée $\frac{1}{4}$)

$$Q_{\frac{1}{4}} = 2$$

Troisième quartile (dans le diagramme cumulatif, valeur qui correspond à la fréquence cumulée $\frac{3}{4}$)

$$Q_{\frac{3}{4}} = 4;$$

Intervalle interquartile

$$Q_{\frac{3}{4}} - Q_{\frac{1}{4}} = 2$$

Corrigé de l'exercice 1 - 3. Première version avec données groupées

```
c = Range[1, 7]
```

```
  |plage
```

```
{1, 2, 3, 4, 5, 6, 7}
```

```
eff = {48, 72, 96, 64, 39, 25, 3}
```

```
{48, 72, 96, 64, 39, 25, 3}
```

```
n = Apply[Plus, eff]
```

```
  |remplir |plus
```

```
347
```

```
freq =  $\frac{\text{eff}}{n}$ 
```

```
{ $\frac{48}{347}$ ,  $\frac{72}{347}$ ,  $\frac{96}{347}$ ,  $\frac{64}{347}$ ,  $\frac{39}{347}$ ,  $\frac{25}{347}$ ,  $\frac{3}{347}$ }
```

```
N[freq]
```


```
  |valeur numérique
```

```
{0.138329, 0.207493, 0.276657, 0.184438, 0.112392, 0.0720461, 0.00864553}
```

```
diagrammeBatons[c, freq, AxesLabel -> {None, "Fréquence"}]
```

```
  |titre d'axe
```

```
  |aucun
```



```
freqCumulees = Accumulate[freq]
```

```
  |accumule
```


```
{ $\frac{48}{347}$ ,  $\frac{120}{347}$ ,  $\frac{216}{347}$ ,  $\frac{280}{347}$ ,  $\frac{319}{347}$ ,  $\frac{344}{347}$ , 1}
```

```
N[freqCumulees]
```

```
  |valeur numérique
```

```
{0.138329, 0.345821, 0.622478, 0.806916, 0.919308, 0.991354, 1.}
```

```
diagrammeCumulatif[c, freq, AxesLabel -> {None, "Fréquence cumulée"}]
  [titre d'axe] [aucun]
```



Taille de l'échantillon

n

347

Moyenne arithmétique

m = freq.c

1102

347

N[m]

[valeur numérique]

3.17579

Mode : Il s'agit de repérer, dans la liste des fréquences, le(s) rang(s) de celle(s) qui est (sont) maximale(s).

Mo = Position[freq, Max[freq]]

[position] [maximum]

{{3}}

Mo = Mo[[1]][[1]]

3

Médiane Il s'agit de repérer, dans la liste des fréquences cumulées, le rang de la première qui atteint ou dépasse $\frac{1}{2}$. Pour ce faire, cherchons la position de la première valeur non négative dans la liste (freqCumulees - $\frac{1}{2}$).

Me = Position[Negative[freqCumulees - $\frac{1}{2}$], False][[1]][[1]]

[position] [négatif?] [faux]

3

Étendue

etendue = Max[c] - Min[c]
maximum minimum

6

Variance

var = freq. (c - m)²

258 958

120 409

N[var]

valeur numérique

2.15065

Ecart-type

s = $\sqrt{\text{var}}$;

N[s]

valeur numérique

1.46651

Premier quartile Il s'agit de repérer, dans la liste des fréquences cumulées, le rang de la première qui atteint ou dépasse $\frac{1}{4}$. Pour ce faire, cherchons la position de la première valeur non négative dans la liste (freqCumulees - $\frac{1}{4}$).

q1 = Position[Negative[freqCumulees - $\frac{1}{4}$], False] [[1]] [[1]]
position négatif? faux

2

Troisième quartile Il s'agit de repérer, dans la liste des fréquences cumulées, le rang de la première qui atteint ou dépasse $\frac{3}{4}$. Pour ce faire, cherchons la position de la première valeur non négative dans la liste (freqCumulees - $\frac{3}{4}$).

q3 = Position[Negative[freqCumulees - $\frac{3}{4}$], False] [[1]] [[1]]
position négatif? faux

4

Intervalle interquartile

q3 - q1

2

Corrigé de l'exercice 1 - 3. Deuxième version avec données brutes

c = Range[1, 7]

plage

{1, 2, 3, 4, 5, 6, 7}

eff = {48, 72, 96, 64, 39, 25, 3}

{48, 72, 96, 64, 39, 25, 3}


```
var = VarianceMLE[x];
```

```
N[var]
```

```
[valeur numérique]
```

```
2.15065
```

Ecart-type

```
s = StandardDeviationMLE[x];
```

```
N[s]
```

```
[valeur numérique]
```

```
1.46651
```

Premier quartile

```
q1 = Quantile[x, 1/4]
```

```
[quantile]
```

```
2
```

Troisième quartile

```
q3 = Quantile[x, 3/4]
```

```
[quantile]
```

```
4
```

Intervalle interquartile

```
q3 - q1
```

```
2
```

Corrigé de l'exercice 1 - 4

$$\begin{aligned}
 V &= \frac{1}{n} \sum_{i=1}^n (x_i - m)^2 = \frac{1}{n} \sum_{i=1}^n (x_i^2 - 2 x_i m + m^2) \\
 &= \left(\frac{1}{n} \sum_{i=1}^n x_i^2 \right) + \left(\frac{1}{n} \sum_{i=1}^n (-2 x_i m) \right) + \left(\frac{1}{n} \sum_{i=1}^n m^2 \right) = \left(\frac{1}{n} \sum_{i=1}^n x_i^2 \right) - 2 m \left(\frac{1}{n} \sum_{i=1}^n x_i \right) + (m^2) \\
 &= \left(\frac{1}{n} \sum_{i=1}^n x_i^2 \right) - 2 m (m) + (m^2) = \left(\frac{1}{n} \sum_{i=1}^n x_i^2 \right) - m^2
 \end{aligned}$$