

Supplément facultatif du § 2.1

Lien vers la page mère: Distribution empirique d'une variable continue

https://www.deleze.name/marcel/sec2/applmaths/csud/statistique_1/2-stat_1.pdf

Polygone de densité

La représentation de la densité par un histogramme n'est pas satisfaisante dans le cas où on désire arriver à une densité continue. Par exemple, lorsque la forme de la distribution théorique est inconnue, on peut s'intéresser à améliorer la distribution empirique.

Nous poursuivons l'exemple "*Masses corporelles d'étudiants*" sur les données déjà groupées (voir *Statistique I*, § 2.1).

```
Needs["Statistique`",
  |nécessite
  "C:\\Program Files\\Wolfram Research\\Mathematica\\perso\\Statistique.m"]
  |constante C
```

$b = \{44.5, 54.5, 59.5, 64.5, 69.5, 74.5, 79.5, 89.5\};$

$\text{freq} = \left\{ \frac{1}{28}, \frac{1}{10}, \frac{33}{140}, \frac{47}{140}, \frac{13}{70}, \frac{13}{140}, \frac{1}{70} \right\};$

Le polygone de densité


Dans le cas où les classes ont la même amplitude a , excepté peut-être les deux classes extrêmes,

$$b_2 - b_1 = b_3 - b_2 = \dots = b_{k-1} - b_{k-2} = a$$

$$b_1 - b_0 > \frac{a}{2} \quad \text{et} \quad b_k - b_{k-1} > \frac{a}{2}$$

on peut aisément poursuivre la construction dans le but d'obtenir une densité continue.

L'histogramme est remplacé par une ligne polygonale de telle manière que les fréquences sur certains intervalles soient conservées.



$\text{aire}(A1) = \text{aire}(B1), \text{aire}(A2) = \text{aire}(B2), \text{aire}(A3) = \text{aire}(B3), \dots$

Pour réaliser cet objectif, on définit une liste de nombres w_0, \dots, w_{k+1} définis comme suit. Des

classes centrales de même largeur, on retient les centres de classes

$$w_2 = c_2 = \frac{b_1 + b_2}{2}, \dots, w_{k-1} = c_{k-1} = \frac{b_{k-2} + b_{k-1}}{2}$$

Aux extrémités, on définit les nouvelles valeurs telles que $w_2 - b_1 = \frac{a}{2} = b_1 - w_1$, $w_1 - b_0 = b_0 - w_0$,

...

$$w_1 = b_1 - \frac{a}{2}$$

$$w_0 = 2 b_0 - w_1$$

$$w_k = b_{k-1} + \frac{a}{2}$$


$$w_{k+1} = 2 b_k - w_k$$

La fonction ainsi obtenue s'appelle le *polygone des densités*. Cette densité est *continue*.


L'aire de la surface délimitée par la densité vaut 1.

Show[polygoneDeDensite[b, freq]]

[montre](#)



Dans le but d'interpréter le graphique précédent, répondons à la question : "Quelle est la fréquence de l'événement *la masse appartient à l'intervalle [61; 63]*".



Conformément à la relation *fréquence = densité moyenne * amplitude*, on a

$$f[61; 63] = \frac{h(61) + h(63)}{2} (63 \text{ kg} - 61 \text{ kg})$$

Du point de vue géométrique, pour le trapèze marqué en noir,


$$\text{aire} = \text{hauteur moyenne} * \text{largeur}$$

L'aire en noir représente donc la fréquence de l'événement *la masse appartient à l'intervalle [61; 63]*.

La fréquence cumulée lissée

La fonction de distribution qui correspond à la densité continue, notée $F_f : \mathbb{R} \rightarrow \mathbb{R}$, est nommée *fréquence cumulée lissée*. Le calcul de F_f se ramène à la somme d'aires de trapèzes. La fonction F_f est un polynôme de degré 2 par morceaux.

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



Les paramètres empiriques de cette distribution peuvent différer un peu de ceux qui proviennent de l'histogramme (voir § 2.1); par exemple, pour la médiane

`quantileLisse[b, freq, $\frac{1}{2}$]`

66.4043