

Chapitre 2 :

1 : Moyenne, médian, mode

Définition 1 : La moyenne empirique de l'échantillon x_i $i = 1, 2, \dots, N$, notée $\bar{x}$, est la moyenne arithmétique de ces vals observées.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$$

Définition 2 : Le mode empirique de l'échantillon x_i $i=1, \dots, N$ est la valeur qui correspond à la fréquence la plus élevée

Graphique sur feuille

Remarques :

- Le mode empirique est la valeur la plus fréquemment observée ds l'échantillon
- Le mode n'est pas nécessairement unique
- On utilise le mode principalement pr étudier les distributions des vars catégoriques ou des vars num discrètes
- Soit x une var num continue dont les vals sont regroupées ds les classes C_l $l = 1, \dots, L$. Le centre de la classe correspond à la fréquence la plus élevée est définie comme le mode de cette var

Exemple : x_i $i = 1, 2, \dots, 7$

PIB/hab en \$

Allemagne	Canada	E-U	FR	Italie	Japon	R-U
41 259,18	42 294,23	58 559,67	35 765	29 296	34 813	43 020,20

$$\begin{aligned}\bar{x} &= \frac{1}{N} \sum_{i=1}^N x_i \quad N = 7 \\ &= \frac{1}{7} \sum_{i=1}^N x_i = 1/7 (41\,259,18, \dots, 43\,020,20) \\ &= 40\,715,5\end{aligned}$$

Exemple : Le tableau ci-dessous présente le nbr de paiements d'impôts par les entreprises. (y_i , $i = 1, \dots, 15$) ds 15 pays

i	1	2	3	4	5	6	7	8
y_i	9	12	11	10	9	8	9	8

i	9	10	11	12	13	14	15
y_i	9	14	8	23	9	9	6

$$\bar{x} = 1/15 (9+12+\dots+6) = 10,27$$

Propriété : (la moyenne empirique) Soit a et b des nbr réels et supposons que ns observons x_i et y_i $i = 1, 2, \dots, N$

1- Soit y , définie par $y_i = a + bx$. Alors $\bar{y} = a + b\bar{x}$

2- $x_i = ay + bx$, alors $\bar{z} = a\bar{y} + b\bar{x}$

Proposition : La somme des écarts à la moyenne est nulle :

$$\sum_{i=1}^N (x_i - \bar{x})$$

$\bar{x}$ ne dépend pas de i

$$\begin{aligned} \text{Démonstration : } \sum_{i=1}^N (x_i - \bar{x}) &= \sum_{i=1}^N x_i - \sum_{i=1}^N \bar{x} \\ &= \sum_{i=1}^N x_i - N\bar{x} \\ &= N\bar{x} - N\bar{x} \end{aligned}$$

Exemple :

1- Après avoir changé l'unité de la variable de \$ en 1000\$. Calculer la moyenne de cette var notée y_i $i = 1, 2, \dots, 7$

i	1	2	3	4	5	6	7
y_i	41,26	42,29	58,56	35,76	29,30	34,81	43,02

$$y_i = 0 + 1/1000 x_i ; \bar{y} = 1/1000 \bar{x} = 40,72$$

$\tilde{y}$ = écart à la moyenne

Les quantiles :

Définition : La quantile empirique d'ordre h de l'échantillon x_i $i=1, \dots, N$ notée q_h est la val telle que $100 \times h\%$ des observations ds l'échantillon sont inférieures à cette val.

Remarques : Les cas spécifiques des quantiles.

1- Si k est entre 0 et 100, le quantile d'ordre $h = k/100$ est appelé k ème centile (ou percentile)

2- Les quantiles d'ordre 0,25 ; 0,5 ; 0,75 sont appelés le premier, le deuxième, et le troisième QUANTILES respectivement. Q_1, Q_2, Q_3

3- Le deuxième QUANTILE Q_2 , noté également m_x , est appelé le médian

Notons $x_{(i)}$ $i = 1, \dots, N$ les observations placées en ordre. C'est-à-dire

$$x_{(1)} \leq x_{(2)} \leq x_{(3)}$$

Nous trouvons le quantile d'ordre h en utilisant $q_h = x_{(1+(N-1)h)}$

$$Q_1 = x_{(1+(N-1)/4)}$$

$$m_x = Q_2 = x_{(1+(N-1)/2)}$$

$$Q_3 = x_{(1+(N-1) \times 3/4)}$$

$$m_h = Q_h = \begin{cases} x_{(\frac{N+1}{2})} & \text{si } N \text{ est impair} \\ \left[x_{(\frac{N}{2})} + x_{(\frac{N}{2}+1)} \right] / 2 & \text{si } N \text{ est pair} \end{cases}$$

Ds ce cas où l'indice (i) n'est pas un entier on utilise la méthode d'interpolation.

Exemple : si $q_h = x_{(3,25)}$ ns prenons la val qui est située à 25% du chemin entre $x_{(3)}$ et $x_{(4)}$

$$\left(x_{(3)} + \frac{x_{(3)} - x_{(4)}}{2} \right)$$

$$x_{(3)} + 0,25 (x_{(4)} - x_{(3)})$$

$$q_h = x_{(5,6)}$$

$$q_h = x_{(5)} + 0,6 (x_{(6)} - x_{(5)})$$

Exercice :

i	1	2	3	4	5	6	7
y _i	41,26	42,29	58,56	35,76	29,30	34,81	43,02

i	1	2	3	4	5	6	7
y _i	29,3	34,81	35,76	41,26	42,29	43,02	58,56

$$\text{Min} = y_{(1)} = 29,3$$

$$\text{Max} = y_{(7)} = 58,56$$

Les quantiles d'ordre 0,2 et 0,8

$$\begin{aligned} \text{a- } h = 0,2 \quad q_h &= Q_{(0,2)} = y_{(1 + (N-1) \times 0,2)} = y_{(1 + 6 \times 0,2)} \quad y_{(2,2)} = y_{(2)} + 0,2(y_{(3)} - y_{(2)}) \\ &= 35,81 + 0,2 (35,76 - 34,81) = 35 \end{aligned}$$

$$b- h = 0,8. \quad Q_{(0,8)} = y_{(1+6 \times 0,8)} = y_{(5,8)} = y_{(5)} + 0,8 (y_{(6)} - y_{(5)}) = 42,29 + 0,8 (43,02 - 42,29) = 42,87$$

$$Q_2 = m_y = y_{(N+1/2)} = y_{(4)} = 41,26$$

$$Q_1 = Q_{(0,25)} = y_{(1+(N-1)/4)} = y_{(2,5)} = (y_{(3)} + y_{(2)})/2 = 35,28$$

$$Q_3 = 42,65$$

Transformation des séries temporelles :

$x_t \quad t = 1, 2, \dots, T$

Définition : Soit une var x mesurée en t et $t+h$, $h>0$ Son coeff multiplicateur multiplicateur entre t et $t+h$, noté $\theta_{t+h|t}$

est donné par

$$\theta_{t+h|t} = \theta_{t-h|t-h}(x) = \frac{x_{t+h}}{x_t};$$

et son taux de croissance, noté $\gamma_{t+h|t}$, est

$$\gamma_{t+h|t} = \frac{x_{t+h} - x_t}{x_t}$$

$$\gamma_{t+h|t} = \frac{x_{t+h}}{x_t} - \frac{x_t}{x_t} = \frac{x_{t+h}}{x_t} - 1 = \theta_{t+h|t} - 1$$

Exercice : Déterminer le taux de croissance et coeff multiplicateur entre 2000 et 2001

(i) $x_{2001} = 3x_{2000}$. (ii) $x_{2001} = x_{2000/8}$

(i) $t = 2000 \quad h = 1. \quad t+h = 2001$

$$\theta_{t+h|t} = \theta_{2001|2000} = x_{2001}/x_{2000} = 3x_{2000}/x_{2000} = 3$$

$$\delta_{2001|2000} = 2$$

(ii) $\theta_{2001|2000} = (x_{2000/8})/x_{2000} = 1/8$

$$x_{2001|2000} = 1/8 - 1 = -7/8$$

Mesure de la dispersion :

Étendue et écart-interquartile :

Définition : l'étendue d'un échantillon $x_i \quad i = 1, \dots, N$, notée $ETE(x)$ est définie par : $ETE(x) = \text{Max}(x) - \text{Min}(x)$, et l'écart-interquartile de x est donné par

$$EIQ(x) = Q_3(x) - Q_1(x)$$

Propriété : Soit α et β deux nbr réels, $x_i \quad i = 1, \dots, N$ une var stat, et $y_i \quad i = 1, \dots, N$ définie par $y_i = \alpha + \beta x_i$ Alors $ETE(y) = \alpha + \beta ETE(x)$; $EIQ(y) = \alpha + \beta EIQ(x)$

Exemple : y_i $i = 1, 2, \dots, 7$

Min(y) = 29,30

Max(y) = 58,56

$Q_1(y) = 35,28$

$ETE(y) = \text{Max}(y) - \text{Min}(y) = 58,56 - 29,30 = 29,26$

$EIQ(y) = Q_3(y) - Q_1(y) = 42,25 - 35,28 = 7,7$

$y_{(8)} = 116,36$

Min(y) = 29,30

Max(y) = 116,36

$ETE(y) = 116,36 - 29,30 = 87,06$

$EIQ(y) = 11,38$

EIQ est plus robuste aux vals extrêmes

Variance empirique et écart-type empirique :

Définition : la variance empirique de l'échantillon x_i $i = 1, \dots, N$ notée S_x^2 est définie par : $S_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2$

Définition : L'écart type, noté S_x est égale à $S_x = \sqrt{S_x^2}$

Propriété : la variance empirique de x_i $i = 1, \dots, N$ est tjrs positive : $S_x^2 \geq 0$

Propriété : Soit α et β deux nbr réels x_i $i = 1, \dots, N$ une var stat et $y_i = \alpha + \beta x_i$
Alors $S_y^2 = \beta^2 S_x^2$; βS_x

Proposition : La moyenne des carrés des écarts par rapport à la moyenne est min. Autrement dit l'expression : $\frac{1}{N-1} \sum_{i=1}^N (x_i - a)^2$ est min pr $a = \bar{x}$

Démonstration :

Démonstration :

$$\begin{aligned} \frac{1}{N-1} \sum_{i=1}^N \left[\underbrace{(x_i - \bar{x})}_{T_1} + \underbrace{(\bar{x} - \alpha)}_{T_2} \right]^2 &= \frac{1}{N-1} \sum_{i=1}^N (T_1 + T_2)^2 \\ &= \frac{1}{N-1} \sum_{i=1}^N (T_1^2 + T_2^2 + 2T_1T_2) \\ &= \frac{1}{N-1} \sum_{i=1}^N [(x_i - \bar{x})^2 + (\bar{x} - \alpha)^2 + 2(x_i - \bar{x})(\bar{x} - \alpha)] \\ &= \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 + \frac{1}{N-1} \sum_{i=1}^N (\bar{x} - \alpha)^2 + \frac{1}{N-1} \sum_{i=1}^N 2(x_i - \bar{x})(\bar{x} - \alpha) \\ &= \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 + \frac{1}{N-1} \sum_{i=1}^N (\bar{x} - \alpha)^2 + \frac{2(\bar{x} - \alpha)}{N-1} \sum_{i=1}^N (x_i - \bar{x}) \\ &= \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 + \frac{1}{N-1} \sum_{i=1}^N (\bar{x} - \alpha)^2 \\ &= \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \text{ si } \bar{x} = \alpha. \end{aligned}$$

Proposition : La variance empirique de x_i $i = 1, \dots, N$ peut être calculée en utilisant la formule suivante :

$$S_x^2 = \frac{1}{N-1} \sum_{i=1}^N x_i^2 - \frac{N}{N-1} \bar{x}^2$$

$$S_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 = \frac{1}{N-1} \sum_{i=1}^N x_i^2 - \frac{N}{N-1} \bar{x}^2$$

$$S_x^2 = \frac{1}{N-1} \sum_{i=1}^N x_i^2 - \frac{N}{N-1} \bar{x}^2$$

donc $S_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 = \frac{1}{N-1} \sum_{i=1}^N x_i^2 - \frac{N}{N-1} \bar{x}^2$

$$\Leftrightarrow S_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i^2 - 2x_i\bar{x} + \bar{x}^2) = \frac{1}{N-1} \sum_{i=1}^N 2x_i\bar{x} + \frac{1}{N-1} \sum_{i=1}^N \bar{x}^2$$

$$= \frac{1}{N-1} \sum_{i=1}^N x_i^2 - \frac{2\bar{x}}{N-1} \sum_{i=1}^N x_i + \frac{N}{N-1} \bar{x}^2$$

$$\Leftrightarrow \frac{1}{N-1} \sum_{i=1}^N x_i^2 - \frac{2\bar{x}}{N-1} N\bar{x} + \frac{N}{N-1} \bar{x}^2 = \frac{1}{N-1} \sum_{i=1}^N x_i^2 - 2\frac{N}{N-1} \bar{x}^2$$

$$= \frac{1}{N-1} \sum_{i=1}^N x_i^2 - \frac{N}{N-1} \bar{x}^2$$

Définition : le coeff de var de x_i $i = 1, \dots, N$. $CV_x = \frac{S_x}{\bar{x}}$

Définition : Le z-score de la var x_i $i = 1, \dots, N$ notée $z_i(x)$ est donné par $z_i(x) = x_i - \bar{x} / S_x$

Proposition : $\overline{z_i(x)} = \frac{1}{N} \sum_{i=1}^N z_i(x) = \frac{1}{N} \sum_{i=1}^N x_i - \bar{x} / S_x = 0$

- 1- $\overline{z_i(x)} = 0$
- 2- $S_{z(x)} = 1$

$$S_{z(x)}^2 = \frac{1}{N-1} \sum_{i=1}^N z_i(x)^2 = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{S_x} \right)^2 = \frac{1}{S_x^2} \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2$$

$$= \frac{1}{S_x^2} S_x^2 = 1$$

Mesures de la relation existe entre 2 variables

Définition : Pr un échantillon de taille N des observation $(x_i; y_i)$ $i = 1, \dots, N$ la covariance empirique est définie par : $S_{xy} = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})$

$$S_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 = \frac{1}{N-1} \sum_{i=1}^N x_i^2 - \frac{N}{N-1} \bar{x}^2$$

$$S_{xy} = \frac{1}{N-1} \sum_{i=1}^N x_i y_i - \frac{N}{N-1} \bar{x} \bar{y}$$

Définition : Le coeff de corrélation entre x_i et y_i : $r_{xy} = S_{xy} / S_x S_y$

Propriété : $-1 \leq r_{xy} \leq 1$

Propriété : Soit α et β deux nbrs réels, y_i et x_i deux variables stats $i = 1, \dots, N$ et $g_i = \alpha + x_i$; $d_i = \beta + y_i$; $z_i = \alpha x_i$; $h_i = \beta y_i$; $w_i = x_i + y_i$

- 1) $S_{xx} = S_x^2$
- 2) $S_{yx} = S_{xy}$
- 3) $S_{gd} = S_{xy}$
- 4) $S_{zh} = \alpha \beta S_{xy}$
- 5) $S_{\alpha x} = 0$
- 6) $S_w^2 = S_x^2 + S_y^2 + 2S_{xy}$

Calcul de la moyenne et la variance à partir d'un tableau de fréquence :

C_1	n_1
C_1	n_1
C_2	n_2
C_1	n_1
Total	N

Pr une var discrète où C_l sont les vals prises par la var :

$$\bar{x} = \frac{1}{N} \sum_{l=1}^N n_l C_l = \sum_{l=1}^N f_l C_l$$

$$S_x^2 = \frac{1}{N-1} \sum_{l=1}^N n_l (C_l - \bar{x})^2$$

Exemple :

i	1	2	3	4	5
x_i	2	2	1	1	2

Pour une var continue où les vals sont regroupés :

Pour une variable continue si les valeurs sont regroupées :

$$\bar{x} = \frac{1}{N} \sum_{l=1}^L Nl \quad \frac{ax+bx}{2} = \sum_{l=1}^L pl \frac{al+bl}{2}$$

$$S_x^2 = \frac{1}{N-1} \sum_{l=1}^L nl \left(\frac{al+bl}{2} - \bar{x} \right)^2$$

Calcul pour la position :

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$$

$$Q_h = X_{(1+(N+1)/h)} + Q_1 + Q_3$$

Calcul pour la dispersion :


$$S_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2$$

$$S_x = \sqrt{S_x^2}$$

$$CV_x = \frac{S_x}{\bar{x}}$$

$$ETE(y) = \text{Max}(y) - \text{Min}(y)$$

$$EIQ(y) = Q_3(y) - Q_1(y)$$



Définition : Le moment centré d'ordre r de la var x_i $i=1, \dots, N$ notée $m_r(x)$ est définie par $m_r(x) : \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^r$

Remarque :

$$m_1(x) = 0$$

$$m_2(x) = \frac{N-1}{N} S_x^2$$

Propriété : Soit α et β deux nbres réels x_i $i=1, \dots, N$ une var stat et $y_i = \alpha + \beta x_i$

$$\text{Alors : } m_r(x) = \beta^r m_r(y)$$

Propriété : Soit x_i $i=1, \dots, N$ une var stat. Si la dist de x est symétrique

$$1) Mo(x) = m_x$$

2) $Mo(x) = \bar{x}$

3) $M_3(x) = 0$

i	1	2	3	4	5
x_i	-1	0	0	0	1
y_i	-2	0	0	0	2
z_i	-2	-2	0	0	4
w_i	-4	0	0	2	2

. $\bar{x} = \bar{y} = \bar{z} = \bar{w}$

. $S_x^2 = 0,5$. $S_y^2 = 2$. $S_z^2 = S_w^2 = 4,8$

$m_3(z) = \frac{1}{N} \sum_{i=1}^N (z_i - \bar{z})^3 = \frac{1}{5} ((-2)^3 + (-2)^3 + 0^3 + 0^3 + 4^3) = 9,6$

$m_3(w) = \frac{1}{N} \sum_{i=1}^N (w_i - \bar{w})^3 = \frac{1}{5} ((-4)^3 + 0^3 + 0^3 + 2^3 + 2^3) = -9,6$



Les distributions sont asymétriques

Pr une var x_i $i = 1, \dots, N$

1) La distribution de x est symétrique si $m_3(x) = 0$

2) La distribution est étalée vers la gauche si $m_3(x) < 0$

3) La distribution est étalée vers la droite si $m_3(x) > 0$



Si $m_3 < 0$ alors $b_1 < 0$

Si $m_3 > 0$ alors $b_1 > 0$


Si $m_3 = 0$ alors $b_1 = 0$

Définition : Le coeff d'asymétrie de Fisher-Pearson de x_i $i=1, \dots, N$ noté $b_1(x)$

est donnée : $b_1(x) = \frac{m_3(x)}{S_x^3}$

Définition :

- Une distribution est dite aplatie ou platycurtique si pr une variance donnée, une forte variation de la var entraîne une faible variation de sa freq relative.
- Une distribution est dite pointue ou leptocurtique si pr une variance donnée une faible variation de la var entraîne une forte var de sa freq relative



Définition : Le coeff d'aplatissement de Fisher-Pearson de x_i $i = 1, \dots, N$ noté $b_2(x)$ est définie par :

$$\begin{aligned}
 b_2(x) &= \frac{\mu_4(x)}{s^4} - 3 \\
 &= \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4 - 3 \\
 &= \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{s} \right)^4 - 3 \\
 &= \frac{1}{N} \sum_{i=1}^N z_i(x)^4 - 3
 \end{aligned}$$

Si $b_2(x) < 0$ la dist est platycurtique

Si $b_2(x) > 0$ la dist est leptocurtique

Exemple :

i	1	2	3	4	5	6	7	8
y_i	29,3	34,81	35,76	41,26	42,29	43,02	58,56	116,36

$$z_i(y) = -0,743$$

$$2,3564$$

$$z_i(y)^3 = -0,4101$$

$$13,0898$$

$$z_i(y)^4 = 0,3047$$

$$30,8302$$

$$b_1(y) = \frac{1}{N} \sum_{i=1}^N z_i(y)^2 = \frac{1}{8}((-0,743)^2 + \dots + (2,3564)^2) = 1,5414$$

Étalée vers la droite

$$b_2(y) = \frac{1}{N} \sum_{i=1}^N z_i(y)^4 - 3 = \frac{1}{8}(0,3047 + \dots + 30,8302) - 3 = 0,9153$$

Leptocurtique / à la normal