

Statistique

I. Statistique Descriptive :

Meilleure de Tendance centrale et De Dispersion.

↳ Collecte Des Données ↳ Traitement Des données - collectés

↳ Interprétation des données.

Effectif: c'est le nombre total des éléments constituant cette population "N"

Fréquence: c'est le nombre d'individus possédant ce caractère divisé par l'effectif total de la population : N_p

	Échantillon	Population
Moyenne	\bar{x}	μ
Variance	s^2	σ^2
Ecart-type	s	σ
Covariance	s_{xy}	σ_{xy}
Corrélation	r_{xy}	p_{xy}

Échantillon

Population

Moyenne :

$$\bar{x} = \frac{\sum n_i}{n}$$

$$\mu = \frac{\sum n_i}{N}$$

Médiane: il s'agit de la valeur centrale de l'ensemble des données, classées en ordre croissant.

Mode: défini comme la valeur de l'observation la plus fréquente.

Percentile: au moins p pour cent des observations ont cette valeur

Quartile: 25^e, 50^e, 75^e \Rightarrow mesure de Tendance centrale

Meilleure de Dispersion:

Tendue: égale à la différence entre la plus grande et la plus petite valeurs.

Tendue Interquartile: (TIQ) : égale à la différence entre le 3^{ème} et la 1^{ère} quartile.

Variance: basé sur les écarts au carré des observations par rapport à la moyenne :

$$s^2 = \frac{\sum (n_i - \bar{x})^2}{n-1}$$

Écart type e

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

$$\sigma^2 = \frac{\sum (n_i - \mu)^2}{N}$$

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

Bcoefficient de variations Mesure de Dispersion relative, égale au rapport de l'écart type à la moyenne, multiplié par 100,

$$\frac{\text{Ecart type}}{\text{Moyenne}} \times 100$$

Valeur singulière, Observat anormalement grande ou petite.

Degré d'asymétrie + Des données biaisées à gauche sont caractérisé par un degré d'asy négatif

+ Des Données bi à drt sont " positive .

Variable -centrée réduite $z_i = \frac{x_i - \bar{x}}{s}$

$$\begin{aligned} \text{Variance} &= 4 + 100 + 4 + 4 + 144 \\ &= \frac{256}{4} = 64 \end{aligned}$$

$$\text{Ecart type} = \sqrt{s} = 8$$

	Ecart par rapport à la moyenne	v. de la vari. centrée réduite
46	0,25	0,25
54	10/8	1,25
42	-2/8	-0,25
46	2/8	0,25
32	12/8	-1,50

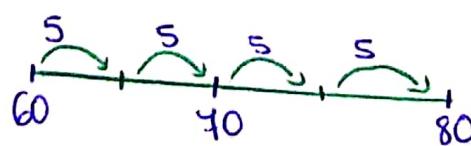
Théorème de Chebyshew

Théo utilisé pour réduire le pourcentage d'Observat qui se situe dans un intervalle de z écart type de part et d'autre de la Moyenne.

⇒ Au Moins $(1 - \frac{1}{z^2})$ des Observat doivent se situer au plus à $|z|$ écart type de part et d'autres de la Moyenne
c'est dans l'intervalle $[\bar{x} - z_s, \bar{x} + z_s]$ avec $z > 1 \gg$.

Exple e Supposons que la Moyenne des notes de 100 Étudiants de l'ENGT soit égale à 70 et que l'Ecart type = 5;

Combien d'étudiants ont obtenu une note entre 60 et 80?



$$[70 - 2s; 70 + 2s] \Rightarrow 1 - \frac{1}{2^2} = 75\%$$

75% des étudiants ont obtenu une note entre 60 et 80.

⇒ On peut pas l'utiliser 1s;

Règle Empirique: Règle qui donne le % d'Observations situées dans des intervalles 1, 2, 3 écarts type autour de la moyenne, pour une Distribution en forme de cloche (Distribution normale).



- Environ 68% des Observations se situent dans $[\bar{x} - s; \bar{x} + s]$
- Environ 95% des Observations se situent dans $[\bar{x} - 2s; \bar{x} + 2s]$
- presque toutes les Observations se situent dans $[\bar{x} - 3s; \bar{x} + 3s]$

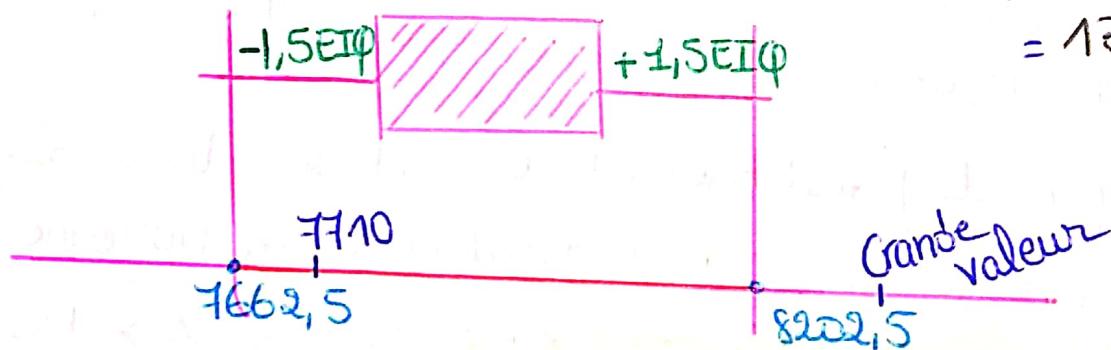
Résumé en 5 chiffres: Technique d'analyse Exploratoire des données qui utilise 5 chiffres pour résumer les données, la plus Grande valeur, le 1^{er} quartile, la médiane, le 3^{er} quartile et La plus Grande valeur, Explorer

7710 - 7755 7850 7880 7890 7920 7940 7950 8050
- 8130 8325

$$1/7710 \quad 2/\Phi_1 = 7865 \quad 3/\Phi_2 = 7905 \\ 4/ \quad 8000 \quad 5/ \quad 8325$$

$$EI\varphi = Q_3 - Q_1$$

$$= 135$$



$$\Phi_1 - 1,5EI\varphi = 7662,25$$

$$\Phi_3 + 1,5EI\varphi = 8202,5$$

Donc 8325 est une Valeur Singulière

II - Statistique Bivariée:

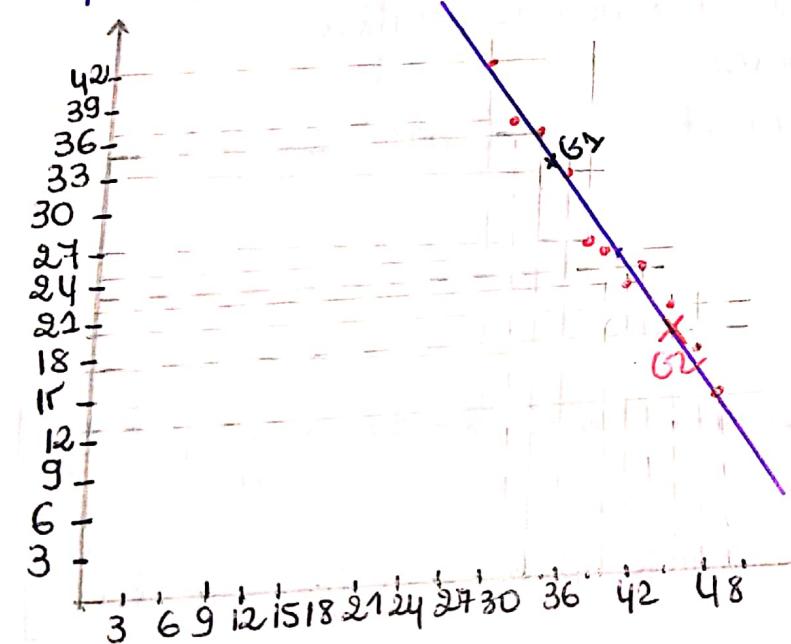
Nuage des pts:

Exple : Une chaîne franchisé Désire Déterminer le prix idéal, puis il a proposé les prix différents... à relever le % des clt intéressé par cette prestation.

Prix proposé	30	32	34	36	38	40	42	44	46	48	50
% des clt intéressé	42	37	35	33	27	25	22	23	20	17	13

- 1/ Présenter Graphiquement puis tracer la droite d'ajustement.
- 2/ Le prix pour avoir 30% des clt intéressés ?

Méthode De Mayer



$$G_1 = (35, 33, 16)$$

$$G_2 = (46, 19)$$

$$y = ax + b$$

$$a = \frac{y_{G_2} - y_{G_1}}{x_{G_2} - x_{G_1}} = \frac{19 - 33,16}{46 - 35} = -1,28$$

$$b = y - ax \Rightarrow 33,16 - (-1,28 \times 35) = 78,25$$

$$y = -1,28x + 78,25$$

$$\text{d'où } x = \frac{30 - 78,25}{-1,28} = 34,69 \Rightarrow \text{Le prix pour avoir } 30\% \text{ des clt intéressés est } 34,69 \text{ dh.}$$

clt intéressé est : 34,69 dh.

Mesure par la Covariance :

Mesure de la relâche linéaire entre deux variables.

Covariance population : $\sigma_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{N}$

Covariance échantillon : $s_{xy} = \frac{\sum (m_i - \bar{m})(y_i - \bar{y})}{n-1}$

Coefficient de corrélation : Mesure de la relâche linéaire entre deux variables, dont les valeurs sont comprises entre -1 et +1

$$r_{xy} = \frac{s_{xy}}{s_x s_y} \quad \text{ou} \quad r_{xy} = \frac{\sigma_{xy}}{\sigma_x \sigma_y}$$

- proche de +1 \Rightarrow forte relâche linéaire positive
- " -1 \Rightarrow forte relâche " négative
- proche de 0 \Rightarrow absence de relâche linéaire

Estimation Ponctuelle :

$$\hat{\sigma}_x = \frac{\sigma}{\sqrt{n}}$$

Estimation de la $\rightarrow \hat{\sigma}_{\text{connu}} \mu \in [\bar{x} - z_{\alpha/2} \times \frac{\sigma}{\sqrt{n}}, \bar{x} + ..]$

Moyenne $\rightarrow \hat{\sigma}_{\text{inconnu}} \mu \in [\bar{x} - t_{\alpha/2} \times \frac{\sigma}{\sqrt{n}}, \bar{x} + ..]$

Distribution D'échantillonnage par \bar{p} :

population finie $\rightarrow \sqrt{\frac{N-n}{N-1} \times \sqrt{\frac{P(1-P)}{n}}}$

population infinie $\rightarrow \sqrt{\frac{P(1-P)}{n}}$

\rightarrow si $\frac{N}{n} < 0,05$

La marge d'erreur $m = \frac{(z_{\alpha/2})^2 \times \sigma^2}{E^2}$

Chapitre III : Régression linéaire simple

$$y = \beta_0 + \beta_1 x + \varepsilon$$

y : variable à expliquer

x : variable explicative (indépendante).

β_0 et β_1 sont les paramètres du modèle

ε est une aléatoire appelée « terme d'erreur », ce terme prend en compte la variabilité de y qui n'est pas expliquée par la relation linéaire entre x et y, ce terme regroupe 3 erreurs :

→ E de spécification : le fait que la seule variable explicative n'est pas suffisante pour rendre complète la totalité du phénomène expliqué.

→ E de mesure : les données ne représentent pas exactement le phénomène.

→ E. fluctuation d'échantillonnage : d'un échantillon à l'autre les observations, et donc les estimations sont légèrement différentes.

$$E(y) = \beta_0 + \beta_1 x$$

En pratique la valeur du paramètre n'est pas connue et doit être estimé en utilisant les données d'un échantillon : $\hat{y} = b_0 + b_1 x$.

Méthode Des Moindres Carrés : est une procédure qui permet d'utiliser les données de l'échantillon pour estimer l'équation de la régression (b_0 et b_1). Elle consiste à minimiser la somme des écarts au carré :

$$\min \sum (y_i - \hat{y}_i)^2$$

$$\text{Or: } b_1 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} \quad \text{et} \quad b_0 = \bar{y} - b_1 \bar{x}$$

Exemple Restaurant:

x_i	y_i	$x_i - \bar{x}$	$y_i - \bar{y}$	$\hat{y}_i = 60 + 5x_i$	$(y_i - \hat{y}_i)$	$(y_i - \hat{y}_i)^2$	$(x_i - \bar{x})^2$
2	58	-12	-72	70	-12	144	144
6	105	-8	-25	90	15	225	64
8	88	-6	-42	100	-12	144	36
8	148	-6	-12	100	18	324	32
12	144	-2	-13	120	-3	9	4
16	137	2	7	140	-3	9	4
20	157	6	27	160	-3	9	36
20	169	6	39	160	9	81	36
22	149	8	19	170	-21	441	64
26	202	12	72	190	12	144	144

$$\bar{x} = \frac{140}{40} = 14 \quad \text{et} \quad \bar{y} = 130 \quad ; \quad b_1 = 5 \quad ; \quad b_0 = 60$$

donc $\hat{y}_i = 60 + 5x_i$

+ $S_{\text{res}} = \sum (y_i - \hat{y}_i)^2 \rightarrow \text{erreur}$

+ $S_{\text{reg}} = \sum (\hat{y}_i - \bar{y})^2 \rightarrow \text{la partie expliquée}$

$$\left\{ \begin{array}{l} S_{\text{CT}} = \sum (y_i - \bar{y})^2 \\ S_{\text{res}} = \sum (y_i - \hat{y}_i)^2 \\ S_{\text{reg}} = \sum (\hat{y}_i - \bar{y})^2 \end{array} \right.$$

$$S_{\text{CT}} = S_{\text{res}} + S_{\text{reg}}$$

Coeff détermination : $\frac{S_{\text{reg}}}{S_{\text{CT}}} = 1 \Rightarrow \text{Meilleure situation}$

Coeff de corrélation : $\rho_{xy} = (\text{signe de } b_1) \sqrt{r^2}$

On a $r = \frac{S_{\text{reg}}}{S_{\text{CT}}} = \frac{14200}{11700} = 0,9027$

en d'autre terme 90,27% de la variation des ventes mensuelle peut s'expliquer par la relation linéaire de la pop et ventes, une telle adéquation de l'équation estimée de la reg est satisfaisante

IV - hypothèse du Modèle

H_0 = Hypothèse nulle \rightarrow il faut l'a rejetté.

H_a = hyp alternatif

\rightarrow test uni infé

①

$$H_0: \mu \geq 2$$

$$H_a: \mu < 2$$

test uni supé

②

$$H_0: \mu \leq 2$$

$$H_a: \mu > 2$$

Test Bilatéral

③

$$H_0: \mu = 2$$

$$H_a: \mu \neq 2$$

Seuil de signification = est la probabilité de faire une erreur de 1^{ère} espèce lorsque l'hypothèse nulle est vraie et satisfaite avec égalité.

$$Z = \frac{\bar{x} - \mu_0}{\sigma / \sqrt{n}} ; \text{ Rejet de } H_0 \text{ si } \begin{cases} \textcircled{1} & z \leq -z_{\alpha/2} \\ \textcircled{2} & z \geq z_{\alpha/2} \end{cases}$$

$$\textcircled{3} z \leq -z_{\alpha/2} \text{ ou } z \geq z_{\alpha/2}$$

I - Estimation du σ^2

$$S^2 = MCres = \frac{Scres}{n-2} \Rightarrow S = \sqrt{\frac{Scres}{n-2}}$$

$$\text{Espérance: } E(b_i) = \beta_1 \text{ et } \sigma_{b_i} = \frac{\sigma}{\sqrt{\sum(x_i - \bar{x})^2}}$$

$$Mcreg = \frac{Screg}{\text{Nbr de V. Indép}}$$

$$F = \frac{Mcreg}{MCres} ; \text{ suit une loi de Fisher avec 1 ddf en numé} \\ \text{ et } n-2 \text{ ddf en Dénom}$$