

Statistique descriptive:

Mesures de tendance centrale:

Moyenne d'échantillon: $\bar{X} = \frac{\sum u_i}{N}$

de population: $\bar{\mu} = \frac{\sum m_i}{N}$

Mediane: $i = \frac{N}{2}$
 décimal \rightarrow entier \rightarrow $\frac{i+(i+1)}{2}$
 prendre $> \frac{N}{2}$

Mode: la valeur la plus fréquente: i tel que f_i est max

Percentile: ex: 75% d'observat°

travailler avec les virgules \rightarrow $\frac{75}{100} \times (N) \rightarrow$ Nombre d'observat°

décimal \rightarrow Entier \rightarrow $\frac{i+(i+1)}{2}$
 la valeur entier suivantes

ex: 10, 2 \rightarrow 11^{ème} obsv
 ex: 6 \rightarrow on prend la moy de 6^{ème} et 7^{ème} obsv/2

Quartile: 25°, 50° et 75°
 les 25% dans l'observation

$i = \frac{25}{100} \times N \rightarrow$ même chose pour les autres

Mesures de dispersion:

Etendue: plus grand valeur - plus petite valeur

Etendue interquartile: $(E - I) \times Q$

3^{ème} Quartile - 1^{er} Quartile

La variance:

De population: $V(x) = \frac{\sum (x_i - \bar{\mu})^2}{n}$

De échantillon: $s^2 = \frac{\sum (u_i - \bar{X})^2}{n-1}$

On interprète $V(x)$ ou s^2 "écart type" non

la variance $V(x)$ ou (s^2) car $V(x)$ est au

carre, d'où le résultat sans sans ex. élevé

sans sens

L'écart-type: $s = \sqrt{s^2}$ ou $\sigma = \sqrt{\sigma^2}$

Coefficient de variance: $\frac{s^2}{\text{moyenne}} \times 100$

ex: 20% $\rightarrow s^2$ correspond à 20% de la moyenne

Mesure la dispersion relative de rapport de écart-type à la moyenne $\times 100$

Détection des valeurs singulières:

Forme d'une distribution: Degré d'asymétrie sert à détecter les valeurs singulières

Les données à gauche sont d'un asymétrie négative
 Les données à droite sont d'un asymétrie positive

$\gamma_1 = \frac{M_3 - 3M_2 + 3M_1 - M_0}{\sigma^3}$ avec $\mu_3 = \frac{1}{n} \sum u_i^3$

Variable centrée réduite: Z

$z_i = \frac{u_i - \bar{\mu}}{s}$ mesure la distance entre s et $(u_i - \bar{\mu})$ appliqué pour tout les i

Théorème de Chebyshev: permet de déduire le pourcentage d'obs. hors intervalle

$(1 - \frac{1}{z^2})$ avec $[\bar{\mu} - z s; \bar{\mu} + z s]$ avec $z > 1$

ex: $\bar{\mu} = 70; s = 5; [60; 80]$

$z \times s = 10 \Rightarrow z = 2$
 $70 - z \times s = 2$ $70 + z \times s = 2$
 d'où $z = 2$
 $1 - \frac{1}{z^2} = 1 - \frac{1}{4} = 0,75$ obsv.

75% d'étudiant obtenu une note entre 60 et 80

appliquer selon la loi normale
 Règle empirique: 1 dév. \rightarrow 68% pour 2 dév. \rightarrow 95%

Analyse exploratoire de données: Résumé

en utilisant la plus petite, 1^{er} quartile, médiane,

3^{ème} quartile et la plus grand valeur

50% des obs	ET	ET	ET
75%	ET	ET	ET
75%	ET	ET	ET

• échantillon:

→ $P = \frac{n}{N} \Rightarrow$ proportion de populat°

→ Type d'échantillon: - Aléatoire:

• Aléatoire stratifié: divise la pop. en sous-groupes homogènes.

ex:

1 ^{ère} année	} des sous-grps homogènes
2 ^{ème} année	
3 ^{ème} année	
5 ^{ème} année	

• Par grappe: chaque grappe est une mini-population, contient toutes les caractéristiques de la pop. ≠ homogène.

ex: 100 avions.
Chaque avion contient des jeunes, des vieux, femmes, hommes, éco-classe, business class, moyen class.

• Systematique!

ex: pop: 5000, n=50.

1. - Calculer $K = \frac{N}{n} = \frac{5000}{50} = 100$.

2. - Choisir un valeur aléatoire $0 \leq r < 50$

3. - Compter de nb choisit 100 jusqu'à le 50^{ème} nombre. $\Rightarrow 20, 120, \dots, n$

- Non aléatoire: Raisonnable

• De commodité: des échantillons disponibles

• Subjectif: un échantillon le plus représentatif de la pop.

ex: un thème politique → échantillon des gens politiques.

• Participat° volontaire: Par volonté.

⇒ Estimation ponctuelle:

- Distribution:

D'après TD.

• Distribution d'échantillon \bar{x} :

1. l'espérance mathématique; Moyen

$$\bar{x} = \mu$$

2. l'écart-type.

• Pop finie: $\sigma_{\bar{x}} = \sqrt{\frac{N-n}{N-1}} \left(\frac{\sigma}{\sqrt{n}} \right)$

• Pop infinie: $\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$

A: Pop infinie lorsque:

$$-\frac{M}{N} \leq 0,05; n \leq 5/N$$

- Aucun info sur la pop.

• Distribution de la moyenn d'échant.

1. $\bar{p} = \frac{n}{n}$

2. $E(\bar{p}) = p$

3. l'écart-type.

• Pop finie: $\sigma_{\bar{p}} = \sqrt{\frac{N-n}{N-1}} \sqrt{\frac{p(1-p)}{n}}$

• Pop infinie: $\sigma_{\bar{p}} = \sqrt{\frac{p(1-p)}{n}}$

la probabilité:

• La probabilité que \bar{x} s'écarte de μ de la μ

$$\mu - y \leq \bar{x} \leq \mu + y$$

$$\frac{\mu - y - \mu}{\sigma} \leq \frac{\bar{x} - \mu}{\sigma} \leq \frac{\mu + y - \mu}{\sigma}$$

• La probabilité que \bar{x} s'écarte de μ de y et z

$$P(y \leq \bar{x} \leq z)$$

$$\frac{y - \mu}{\sigma} \leq \frac{\bar{x} - \mu}{\sigma} \leq \frac{z - \mu}{\sigma}$$

⇒ Pour agrandir la probabilité soit grandir la condition ex: Soit, soit diminuer $\sigma_{\bar{x}}$, soit agrandir la taille, pour avoir des résultats pertinents.

Estimation en fait intervalle:

De la moyenne de pop:

$$\bar{X} \pm Z_{\frac{\alpha}{2}} \times \frac{\sigma}{\sqrt{n}} \Rightarrow \sigma \text{ connu de pop}$$

$$\bar{X} \pm Z_{\frac{\alpha}{2}} \times \frac{s}{\sqrt{n}} \Rightarrow \sigma \text{ inconnu.}$$

La marge d'erreur: en cherchant pour $(n-1)$

$$E = Z_{\frac{\alpha}{2}} \times \frac{\sigma}{\sqrt{n}}$$

$1-\alpha$ = coefficient de confiance.

De la proportion de pop:

$$\bar{p} \pm Z_{\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}}$$

Table d'échantillon:

Pour moyenne:

$$n = \frac{(Z_{\alpha/2})^2 \times \sigma^2}{E^2}$$

Pour proportion:

$$n = \frac{(Z_{\alpha/2})^2 \times p^0(1-p^0)}{E^2}$$

$$p^0 = p(1-p) = 0,25$$

Peut être con 0 , s'est le max.

Coeff de détermination:

$$\frac{SC_{reg}}{SCT} = \frac{\sum (\hat{y} - \bar{y})^2}{\sum (y - \bar{y})^2 + \sum (y_i - \hat{y})^2}$$

Coeff de corrélat^o:

$$r_{xy} = \text{signe de } b_1 \sqrt{r^2}$$

$$r^2 = (r_{xy})^2 = \left(\frac{cov}{\sigma_x \sigma_y} \right)^2$$

$$cov = \frac{\sum (n - \bar{x})(y - \bar{y})}{n}$$

Régression linéaire:

$$Y = \beta_0 + \beta_1 x + \sum \text{erreur}$$

$$y = a x + b$$

$$\hat{y} = b_0 + b_1 x$$

Pour la méthode moindres carrés

$$b_1 = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sum (x_i - \bar{x})^2}$$

$$b_0 = \bar{y} - b_1 \bar{x}$$

$$SC_{res} = \sum (y_i - \hat{y}_i)^2$$

Coeff de détermination: fournit une mesure de l'adéquation de l'équation estimée de la régression.

$$SCT = \sum (y_i - \bar{y})^2 \quad SC_{res} = \sum (y - \hat{y})^2$$

$$SC_{reg} = \sum (\hat{y} - \bar{y})^2$$

Coeff de corrélation:

$$r_{xy} = (\text{signe de } b_1) \sqrt{r^2}$$

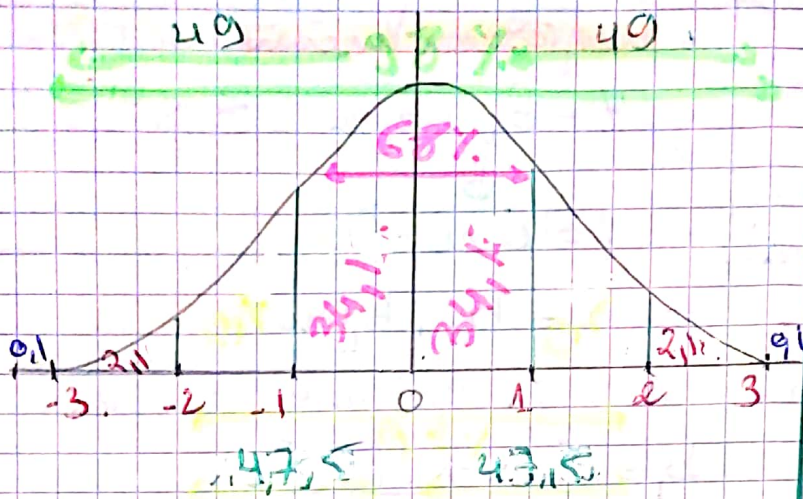
$$SCT = SC_{reg} + SC_{res}$$

↳ Cas idéal $SCT = 0$, sans variance ou des écarts.

Hypothèse:

$$\sigma_u = \sqrt{\frac{\sum (u - \bar{x})^2}{n}}$$

$$a = \frac{\sum (u - \bar{x})(y - \bar{y})}{\sum (u - \bar{x})^2}$$



Loi binomiale

$$n p \gg 5$$

$$n(1-p) \gg 5$$

Hypothèse du modèle

Terme d'erreur ϵ

- $E(\epsilon) = 0 \Rightarrow E(Y) = \beta_0 + \beta_1 x$
- La variance de ϵ notée σ^2 est la même pour toutes les valeurs de x
- Les valeurs de ϵ sont indépendantes entre elles
- Le terme d'erreur ϵ est une v.a. normale distribuée (et donc gaussienne).

Test de signification

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

$$\beta_1 = 0 \quad E(Y) = \beta_0 \quad (\text{avec } \beta_1 \neq 0)$$

H_0 : A rejeter l'opposé

H_1 : Hypothèse α a été validée.

Test unilatéral test supérieur test inférieur test bilatéral

$$Z < -Z_{\alpha} \quad Z > Z_{\alpha} \quad Z < -Z_{\frac{\alpha}{2}} \text{ ou } Z > Z_{\frac{\alpha}{2}}$$

avec σ connu si on a fait la même chose mais avec la loi de Student.

$$Z = \frac{\bar{X} - \mu_0}{\frac{\sigma}{\sqrt{n}}} \quad \text{Statistique de test}$$

1. Test de Student

Concernant β_1

$$H_0 = \beta_1 = 0 ; H_a : \beta_1 \neq 0$$

avec β_1 et β_0 sont échantillonnage, avec leur propre distribution d'échantillon.

- Espérance: $E(b_1) = \beta_1$

$$- \sigma_{b_1} = \sigma_{b_1} = \frac{\sigma}{\sqrt{\sum (x_i - \bar{x})^2}}$$

Si σ non connue:

$$s_{b_1} = \frac{s}{\sqrt{\sum (x_i - \bar{x})^2}}$$

Estimation de σ^2 :

$$s^2 = \frac{MC_{res}}{n-2} = \frac{SC_{res}}{n-2}$$

une estimation sans biais

Erreur type d'estimation:

$$s = \frac{MC_{res}}{n-2} = \frac{SC_{res}}{n-2}$$

$$\text{Statistique de test} = t = \frac{b_1}{s_{b_1}}$$

$$b_1 = \Delta y = b_1 x + b_0$$

Rejet de H_0

App. par VL critique $-t_{\frac{\alpha}{2}} < t < t_{\frac{\alpha}{2}}$

Intervalle de confiance pour β_1 :

$$\beta_1 \in [b_1 \pm t_{\frac{\alpha}{2}} \times s_{b_1}]$$

2. Test de Fisher

F: Statistique du Test = $\frac{MC_{reg}}{MC_{res}}$

avec: $MC_{reg} = \frac{SC_{reg}}{1 - D \text{ Nb de ddl}}$

$MC_{res} = \frac{SC_{res}}{N-2}$

Rejet de H_0

$F > F_{\alpha}$ -> Table Fisher

Loi binomiale

$$E(x) = n \times p \rightarrow \text{Moyenne}$$

$$\sigma^2 = n p (1-p)$$