

Psy1004 – Section 2:

Statistiques descriptives

Plan du cours:

- Varia
- 2.0: Vers une synthèse de données
- 2.1: Tendances centrale
- 2.2: Variabilité
- 2.3: Asymétrie
- 2.4: Kurtose
- 2.5: Erreur type
- Survol de SPSS

Disponible sur: <http://mapageweb.umontreal.ca/cousined/home/course/PSY1004>

Varia

- La page web du cours (ou en dépôt à la bibliothèque EPC)
<http://mapageweb.umontreal.ca/cousined/home/course/PSY1004/>
- Le TP1 est maintenant disponible sur ce site.
 - à remettre dans deux semaines;
 - à faire seul, à deux, ou exceptionnellement à trois.
- La séance de formation pratique sur SPSS aura lieu ce jeudi, le 18 septembre, au A332, à 13h00:
 - Formation pour apprendre à se débrouiller avec un ordinateur;
- Important pour le prochain cours :
 - Imprimer les tables statistiques disponibles sur le site web.
- Questions sur la section 1?

2.0: Vers une synthèse de données (1/2)

Soit les trois échantillons:

- $X = \{86, 87, 88, 92, 93, 95, 96, 96, 97, 97, 98, 99, 101, 101, 102, 102, 102, 103, 103, 103, 103, 104, 104, 105, 107, 108, 108, 110, 113, 114\}$
- $Y = \{91, 91, 92, 92, 93, 93, 93, 94, 94, 95, 95, 96, 96, 97, 98, 98, 98, 98, 98, 100, 101, 104, 106, 107, 114, 118, 119, 121, 131\}$
- $Z = \{87, 88, 89, 89, 90, 90, 91, 91, 92, 93, 94, 94, 95, 96, 96, 96, 97, 97, 99, 99, 100, 100, 100, 101, 101, 103, 104, 107, 107, 111\}$

Tracez le graphique des fréquences d'un de ces échantillons en utilisant des classes de tailles 5 partant à 75 (i.e. de 75 à 80, de 80 à 85, de 85 à 90, etc.).


2.0: Vers une synthèse de données (2/2)

On remarque que:

- Le centre de gravité est à peu près le même dans les trois cas...
- La variabilité est aussi comparable...
- Certaines distributions de valeurs sont asymétriques...

Parfois, on utilise une courbe idéale pour représenter ces échantillons:

Des statistiques informatives doivent quantifier ces aspects.



2.0: Note sur la nomenclature (1/2)

- On note un échantillon avec une lettre majuscule de la fin de l'alphabet, tel **X**, **Y** ou **Z** (en gras);
- On note une statistique (une description) sur un échantillon par la lettre de l'échantillon avec un signe par dessus: \bar{X}

Par exemple:

- La moyenne des échantillons est: $\bar{X}, \bar{Y}, \bar{Z}$
- L'écart type (qu'on verra plus loin): $\bar{X}, \bar{Y}, \bar{Z}$
- D'autres symboles sont possibles: $\bar{X}, \bar{Y}, \bar{Z}$

2.0: Note sur la nomenclature (2/2)

- Dans le passé, il y avait confusion pour le signe d'écart type, s vs. S ou encore s_{n-1} vs. s_n .

- Pour éviter cela, \bar{X}

- Comme il y a deux façon de calculer l'écart type, j'utilise une étiquette:

divise par n


- Nous remplaçons donc:

s	s_{n-1}	σ_{n-1}		$n-1$	\bar{X}
S	s_n	σ_n		n	\bar{X}


Est le plus utilisé

2.1: Tendance centrale (1/3)

"Où est la distribution?"
(le centre de gravité de la distribution, donné par la moyenne arithmétique);
facile si symétrique →



Plus dur si asymétrique →
Pour une distribution asymétrique,
on peut utiliser le mode \tilde{X} (bruyant)



Pour pondérer moins les valeurs
d'un extrême (quand \bar{X} est très
loin du mode \tilde{X}), utiliser:

- la médiane X° ou
- la moyenne géométrique \bar{X} .

2.1: Tendance centrale (2/3)

- Les autres mesures de la tendance centrale sont rarement utilisées en psychologie (moyenne harmonique, géométrique, médiane, mode);
- La médiane est utile quand on sait que la distribution est **très** asymétrique (telle les revenus des ménages);
- La moyenne harmonique va être utilisée dans un test à la section 9.

2.1: Tendance centrale (3/3)

Soit les trois échantillons:

- $X = \{86, 87, 88, 88, 92, 93, 95, 96, 96, 97, 97, 98, 99, 101, 101, 102, 102, 102, 103, 103, 103, 103, 104, 104, 105, 107, 108, 108, 110, 113, 114\}$
- $Y = \{91, 91, 92, 92, 93, 93, 93, 94, 94, 95, 95, 96, 96, 97, 98, 98, 98, 98, 98, 100, 101, 104, 106, 107, 114, 118, 119, 121, 131\}$
- $Z = \{87, 88, 89, 89, 90, 90, 91, 91, 92, 93, 94, 94, 95, 96, 96, 96, 97, 97, 99, 99, 100, 100, 100, 101, 101, 103, 104, 107, 107, 111\}$

Calculer la moyenne arithmétique d'un de ces échantillons.

Solution: $\bar{X} = 100.6$

$\bar{Y} = 100.7$


$\bar{Z} = 96.6$

2.2: Variabilité (1/3)

"Quelle est l'étendue de la distribution?"

- L'écart moyen au centre → mais! vaut toujours zéro...

$$\begin{aligned}\frac{1}{n} \sum_i (x_i - \bar{x}) &= \frac{1}{n} \sum_i x_i - \frac{1}{n} \sum_i \bar{x} \\ &= \bar{x} - \frac{1}{n} n \bar{x} \\ &= \bar{x} - \bar{x} = 0\end{aligned}$$



- L'écart **carré** moyen au centre: $\frac{1}{n} \sum_i (x_i - \bar{x})^2$
- L'écart **carré** moyen au centre corrigé pour le biais : $\frac{1}{n-1} \sum_i (x_i - \bar{x})^2$

2.2: Variabilité (2/3)

- La racine carrée de la variance s'appelle l'écart type.
- Signification de l'écart type: "En prenant une donnée au hasard, elle a toute les chances d'être à \pm un écart type de la moyenne des données."
- Autrement dit, l'écart type est l'écart typique entre une donnée et sa moyenne.

2.2: Variabilité (3/3)

Soit les trois échantillons:

- $\mathbf{X} = \{86, 87, 88, 92, 93, 95, 96, 96, 97, 97, 98, 99, 101, 101, 102, 102, 102, 103, 103, 103, 103, 104, 104, 105, 107, 108, 108, 110, 113, 114\}$
- $\mathbf{Y} = \{91, 91, 92, 92, 93, 93, 93, 94, 94, 95, 95, 96, 96, 97, 98, 98, 98, 98, 98, 100, 101, 104, 106, 107, 114, 118, 119, 121, 131\}$
- $\mathbf{Z} = \{87, 88, 89, 89, 90, 90, 91, 91, 92, 93, 94, 94, 95, 96, 96, 96, 97, 97, 99, 99, 100, 100, 100, 101, 101, 103, 104, 107, 107, 111\}$

Calculer l'écart type non biaisé d'un de ces échantillons.

Rappel: $\bar{\mathbf{X}} = 100.6$

Solution: $\bar{\bar{\mathbf{X}}} = 7.0$

$\bar{\mathbf{Y}} = 100.7$

$\bar{\bar{\mathbf{Y}}} = 10.2$

$\bar{\mathbf{Z}} = 96.6$

$\bar{\bar{\mathbf{Z}}} = 6.1$


2.3: Asymétrie (1/2)

- Si la moyenne correspond à la médiane ou au mode, la distribution n'est pas asymétrique →
- Si la moyenne diffère du mode, la distribution est asymétrique:
 - Négative si le mode est à droite de la moyenne
 - Positive si le mode est à gauche de la moyenne →

Par ex.: Revenu, Temps de réponses, des mesures qui peuvent être proches de zéro, mais non négatives.

- Pour quantifier l'asymétrie (*skewness*):

$$\hat{\gamma}_1 = \frac{1}{n} \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}}$$



2.4: Kurtose (1/2)

Quelle est l'épaisseur des "queues" par rapport au centre?


Si les queues sont plus importantes: Kurtose > 0

Ci-contre, les kurtoses sont de 3, 9.0, et 3.2 resp.

Pour la distribution Normale (qui sert de référence), la kurtose = 3.

Pour calculer la kurtose:

$$\hat{\gamma}_2 = \frac{1}{n} \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}^2}$$



2.3 & 2.4: Skewness et Kurtose (2/2)

Soit les trois échantillons:

- $\mathbf{X} = \{86, 87, 88, 92, 93, 95, 96, 96, 97, 97, 98, 99, 101, 101, 102, 102, 102, 103, 103, 103, 103, 104, 104, 105, 107, 108, 108, 110, 113, 114\}$
- $\mathbf{Y} = \{91, 91, 92, 92, 93, 93, 93, 94, 94, 95, 95, 96, 96, 97, 98, 98, 98, 98, 98, 100, 101, 104, 106, 107, 114, 118, 119, 121, 131\}$
- $\mathbf{Z} = \{87, 88, 89, 89, 90, 90, 91, 91, 92, 93, 94, 94, 95, 96, 96, 96, 97, 97, 99, 99, 100, 100, 100, 101, 101, 103, 104, 107, 107, 111\}$

Calculer l'asymétrie et la kurtose d'un de ces échantillons.

Rappel: $\bar{X} = 100.6$ $\bar{X} = 7.0$ Solution: $\hat{\gamma}_1 = -0.26$ $\hat{\gamma}_2 = 2.71$

$\bar{Y} = 100.7$ $\bar{Y} = 10.2$ $\hat{\gamma}_1 = 1.48$ $\hat{\gamma}_2 = 4.33$

$\bar{Z} = 96.6$ $\bar{Z} = 6.1$ $\hat{\gamma}_1 = 0.43$ $\hat{\gamma}_2 = 2.53$

2.5: Erreur type (1/3)

Signification de l'écart type: "En prenant une donnée au hasard, elle a *toute les chances* d'être à \pm un écart type de la moyenne des données."

Supposons que vous soyez très riche et collectiez un très grand nombre M d'échantillons indépendants, vous obtenez un ensemble de moyennes $\{\bar{X}_1, \bar{X}_2, \dots, \bar{X}_M\}$.

Évidemment, si $M \gg$, la moyenne des moyennes est la vraie moyenne de la population (μ)

2.5: Erreur type (2/3)

Nous voudrions alors connaître l'erreur type: "En prenant une moyenne au hasard, elle a *toute les chances* d'être à \pm un erreur type de la moyenne des moyennes."

Appelons erreur type (*Standard error* parfois traduit *erreur standardisée*):

$$SE_{\bar{X}} = \frac{\sqrt{s^2}}{\sqrt{n}}$$

Nous avons alors *toutes les chances* que:


$$\bar{X} - SE_{\bar{X}} < \mu < \bar{X} + SE_{\bar{X}} \quad (\bar{X} \pm SE_{\bar{X}})$$

$$|\mu - \bar{X}| < SE_{\bar{X}}$$

2.5: Erreur type (3/3)

■ L'erreur type devrait toujours être présent sur un graphe des moyennes

- (peut être fait automatiquement avec SPSS, à la main avec EXCEL):
- Elle donne une indication de la variabilité de chaque groupe;
- Permet de savoir si la différence entre deux moyennes est importante;
- A un lien important avec plusieurs tests sur la moyenne (cf. section 5).





Survol de SPSS

- Comment entrer des données à la main;
 - Démarrer SPSS et l'utiliser comme un chiffrier

- Comment exécuter une analyse sur ces données;
 - Ouvrir une fenêtre de syntaxe, écrire une commande, et l'exécuter

- Comment ouvrir un fichier de données déjà existant.
 - Ouvrir une fenêtre de syntaxe (ou utiliser celle existante), écrire la commande d'ouverture de fichier et l'exécuter
