

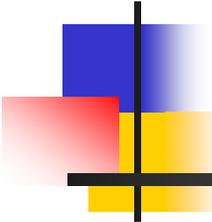
Psy1004 – Section 2:

Statistiques descriptives

Plan du cours:

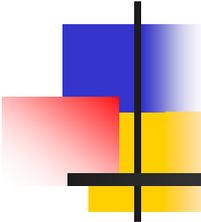
- Varia
- 2.0: Vers une synthèse de données
- 2.1: Tendances centrale
- 2.2: Variabilité
- 2.3: Asymétrie
- 2.4: Kurtose
- 2.5: Erreur type
- Survol de SPSS

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:

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

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.).

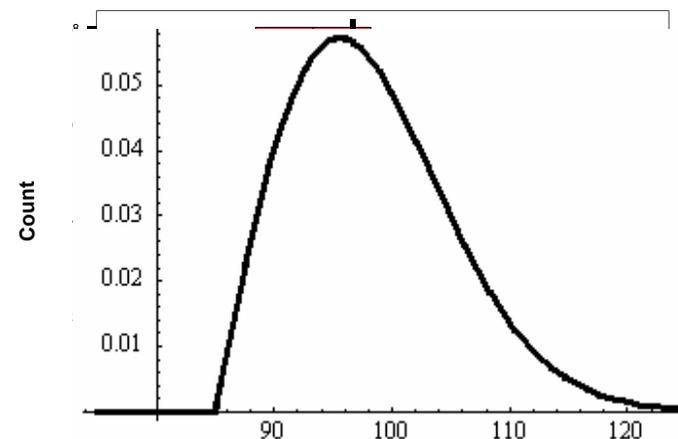
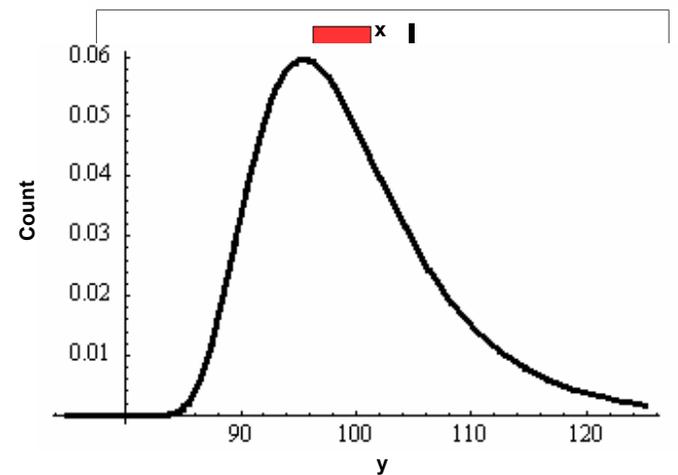
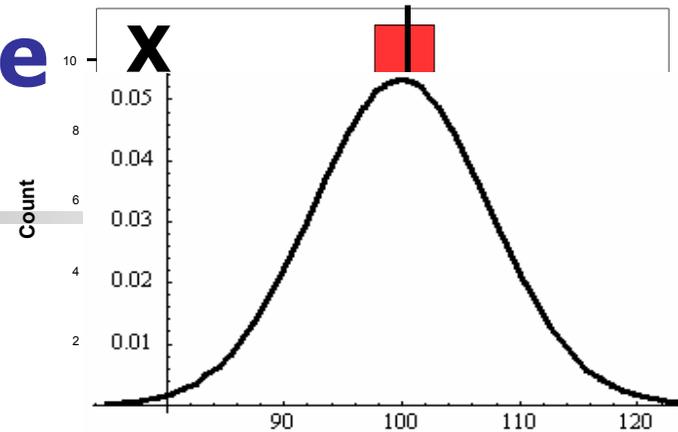
2.0: Vers une synthèse de données (2/2)

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:

dessus: $\overset{?}{\mathbf{X}}$

- Par exemple:

- La moyenne des échantillons est:

$\bar{\mathbf{X}}, \bar{\mathbf{Y}}, \bar{\mathbf{Z}}$

- L'écart type (qu'on verra plus loin):

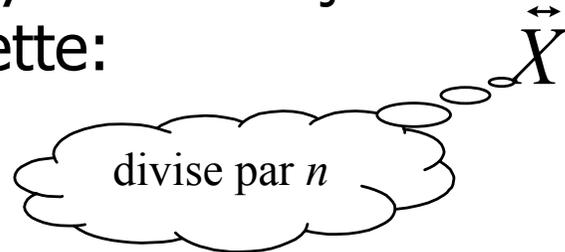
$\overset{\leftrightarrow}{\mathbf{X}}, \overset{\leftrightarrow}{\mathbf{Y}}, \overset{\leftrightarrow}{\mathbf{Z}}$

- D'autres symboles sont possibles:

$\overset{\circ}{\mathbf{X}}, \tilde{\mathbf{Y}}, \overset{\smile}{\mathbf{Z}}$

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, $\overset{\leftrightarrow}{\mathbf{X}}$
- Comme il y a deux façon de calculer l'écart type, j'utilise une étiquette:



- Nous remplaçons donc:

s	s_{n-1}	σ_{n-1}	par:	$n-1$	$\overset{\leftrightarrow}{\mathbf{X}}$
S	s_n	σ_n		n	$\overset{\leftrightarrow}{\mathbf{X}}$

Est le plus utilisé

2.1: Tendance centrale (1/3)

"Où est la distribution?"

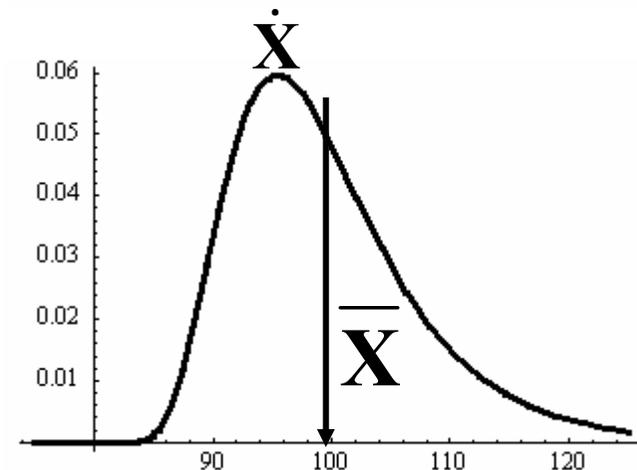
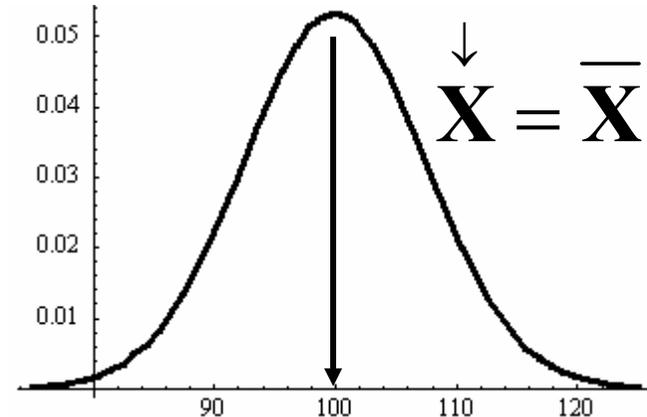
(le centre de gravité de la distribution, donné par la moyenne arithmétique);
facile si symétrique →

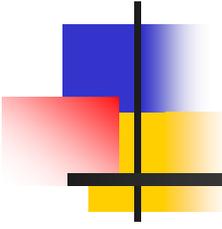
Plus dur si asymétrique →

Pour une distribution asymétrique,
on peut utiliser le mode $\dot{\bar{X}}$ (bruyant)

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

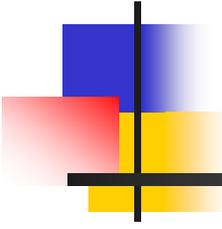
- la médiane \bar{X} ou \circ
- la moyenne géométrique \bar{X} .





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:

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

Calculer la moyenne arithmétique d'un de ces échantillons.

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

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

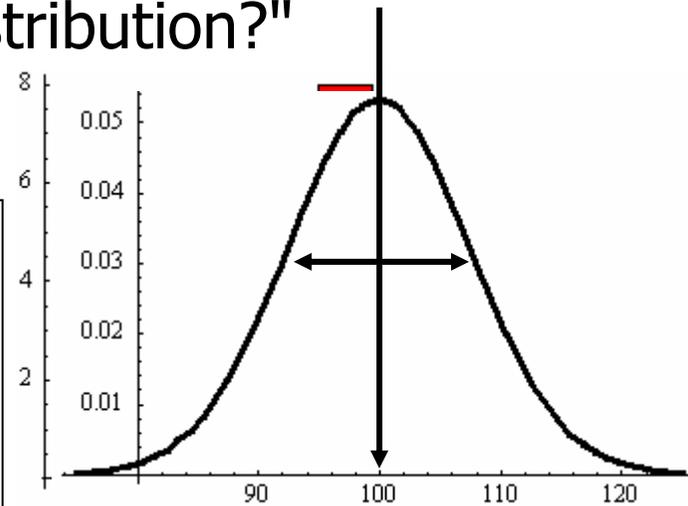
$$\bar{\mathbf{Z}} = 96.6$$

2.2: Variabilité (1/3)

"Quelle est l'étendue de la distribution?"

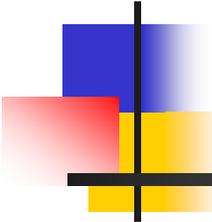
- L'écart moyen au centre →
mais! vaut toujours zéro...

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



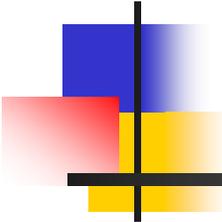
- L'écart **carré** moyen au centre: ${}_n \overleftrightarrow{\mathbf{X}}^2 = \frac{1}{n} \sum_i (\mathbf{x}_i - \bar{\mathbf{X}})^2$

- L'écart **carré** moyen au centre corrigé pour le biais : ${}_{n-1} \overleftrightarrow{\mathbf{X}}^2 = \frac{n}{n-1} {}_n \overleftrightarrow{\mathbf{X}}^2 = \frac{1}{n-1} \sum_i (\mathbf{x}_i - \bar{\mathbf{X}})^2$



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

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

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

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

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

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

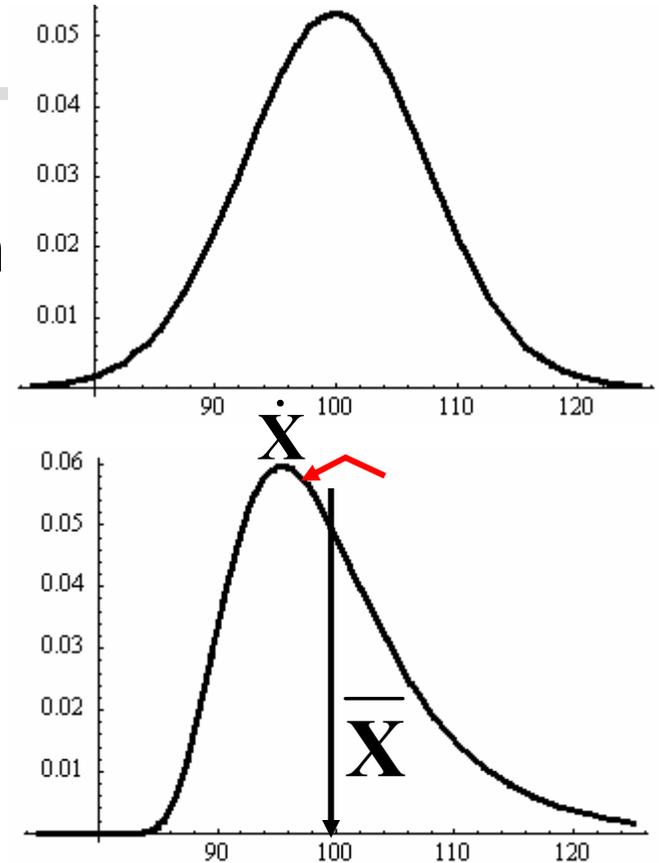
2.3: Asymétrie (1/2)

- 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*):

$$\overset{\curvearrowright}{\mathbf{X}} = \frac{1}{n} \frac{\sum_i (\mathbf{x}_i - \bar{\mathbf{X}})^3}{\overset{\leftrightarrow}{n \mathbf{X}}^3}$$



2.4: Kurtose (1/2)

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

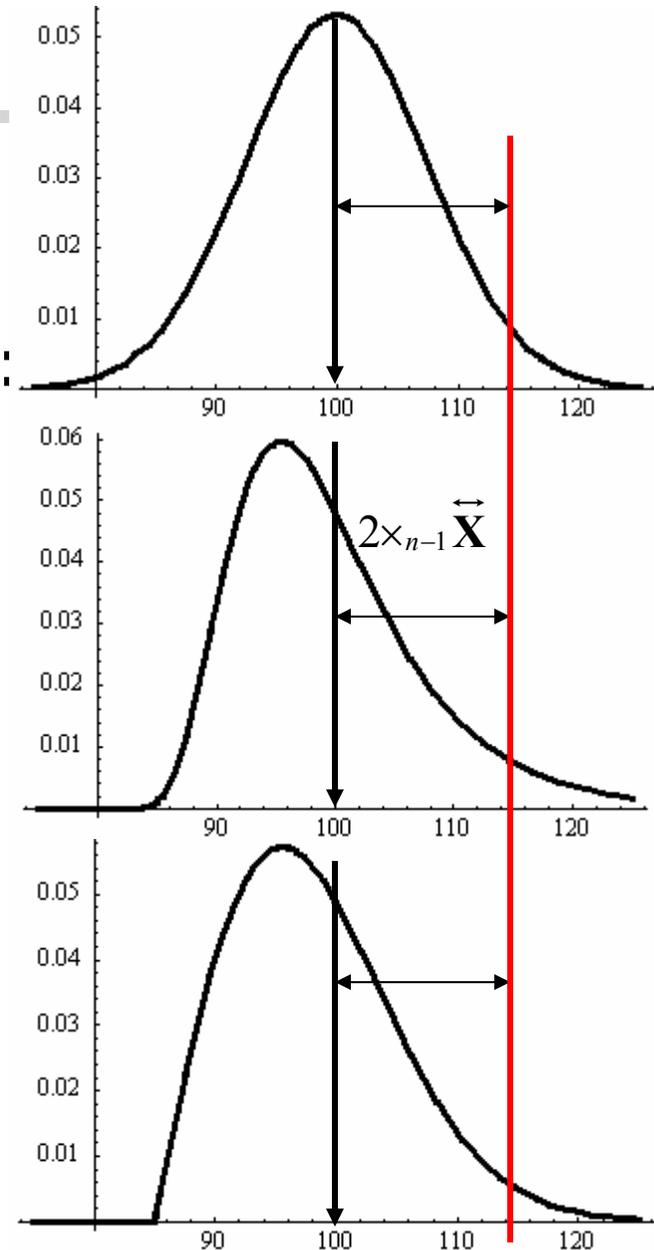
Si les queues sont plus importantes:
Kurtose > 0

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:

$$\overleftrightarrow{\mathbf{X}} = \frac{1}{n} \frac{\sum_i (\mathbf{x}_i - \bar{\mathbf{X}})^4}{\overleftrightarrow{\mathbf{X}}^4}$$



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

Soit les trois échantillons:

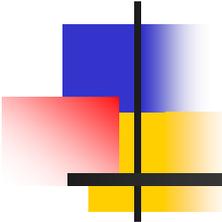
- $\mathbf{X} = \{86, 87, 88, 92, 93, 95, 96, 96, 97, 97, 98, 99, 101, 101, 102, 102, 102, 103, 103, 103, 103, 104, 104, 105, 107, 108, 108, 110, 113, 114\}$
- $\mathbf{Y} = \{91, 91, 92, 92, 93, 93, 93, 94, 94, 95, 95, 96, 96, 97, 98, 98, 98, 98, 98, 100, 101, 104, 106, 107, 114, 118, 119, 121, 131\}$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

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

Rappel: $\bar{\mathbf{X}} = 100.6$ $\vec{\mathbf{X}} = 7.0$ Solution: $\swarrow \mathbf{X} = -0.26$ $\nwarrow \mathbf{X} = 2.71$

$\bar{\mathbf{Y}} = 100.7$ $\vec{\mathbf{Y}} = 10.2$ $\swarrow \mathbf{Y} = 1.48$ $\nwarrow \mathbf{Y} = 4.33$

$\bar{\mathbf{Z}} = 96.6$ $\vec{\mathbf{Z}} = 6.1$ $\swarrow \mathbf{Z} = 0.43$ $\nwarrow \mathbf{Z} = 2.53$

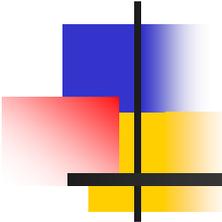


2.5: Erreur type (1/3)

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*):

$$SE_{\bar{X}} = \frac{\sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}}{\sqrt{n}}$$

Nous avons alors *toutes les chances* que:

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

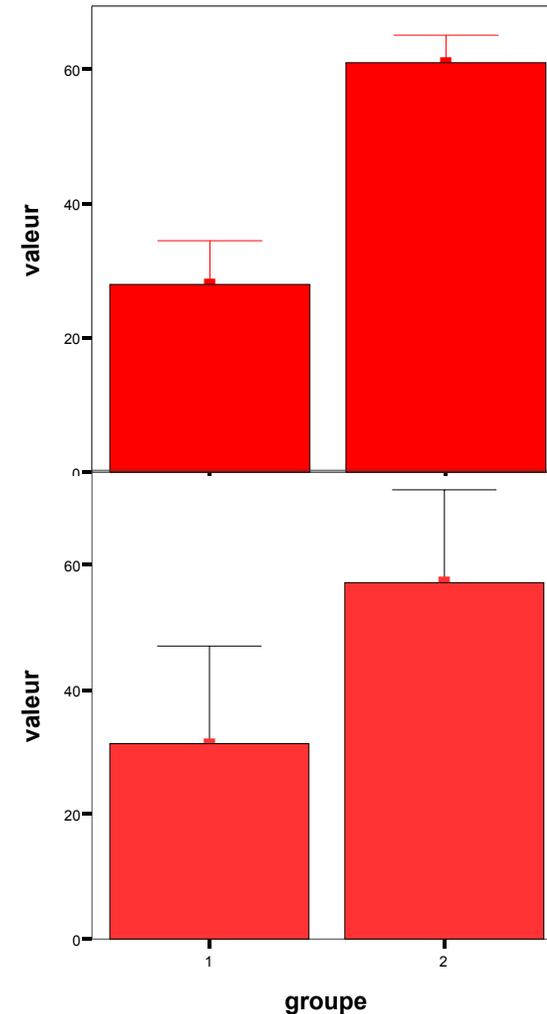
$$\left| \mu - \bar{X} \right| < SE_{\bar{X}}$$

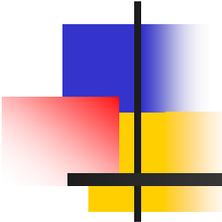
2.5: Erreur type (3/3)

- 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).

Nombre de membres de la famille rappelés en trois minutes en fonction du groupe ethnique

fait avec -Bar chart-





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