

Introduction aux statistiques pour les archéologues

Josef Wilczek

Masarykova univerzita, Brno
L'univesité de Bourgogne, Dijon
josef.wilczek@hotmail.com

Statistiques descriptives

- 1) Tables des fréquences
- 2) Méthodes graphiques
- 3) Les tendances centrales**
- 4) Les tendances de la variabilité (dispersion)
- 5) Distributions

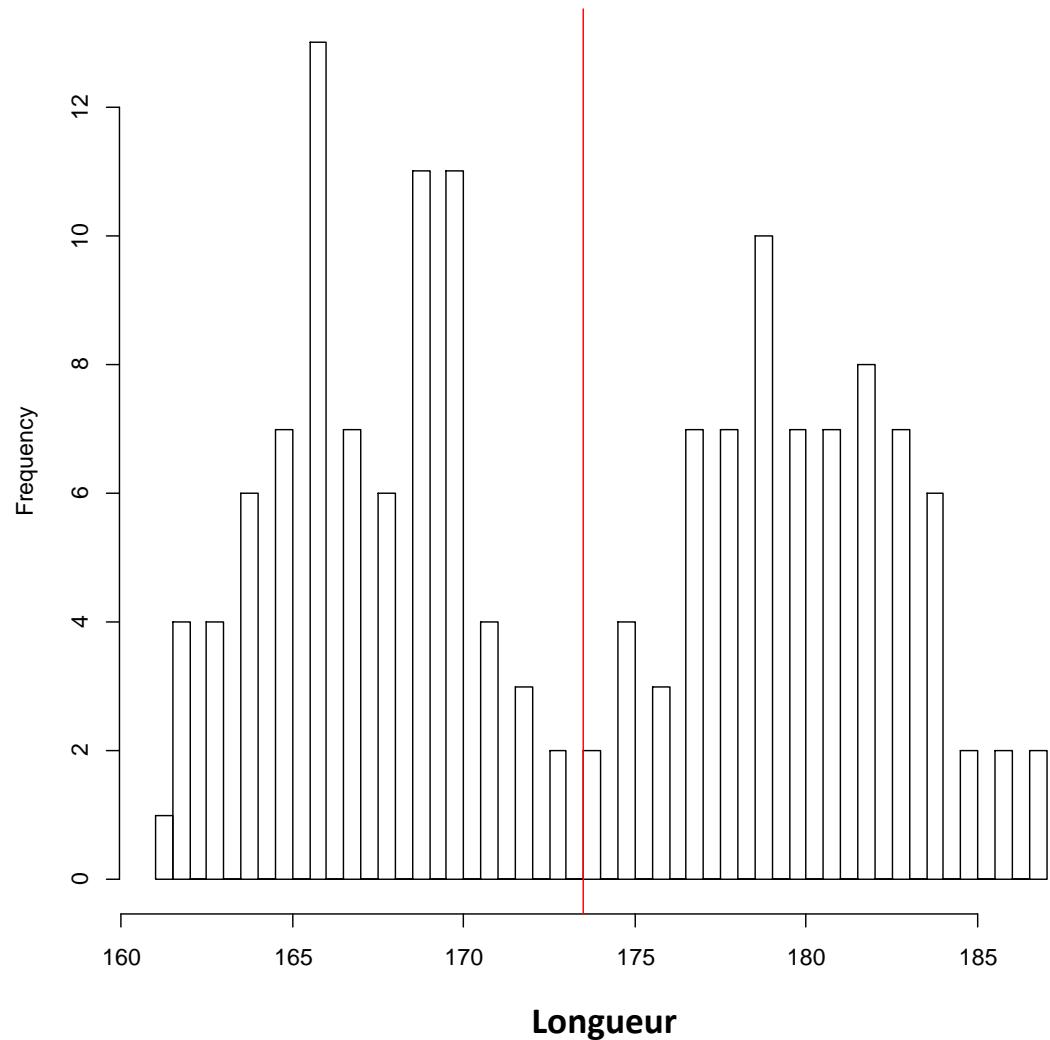
Les tendances centrales

- Il s'agit des valeurs autour lesquels les autres valeurs se concentrent
- **Moyenne** – pour les données **quantitatives**
- **Médiane** – pour les données **quantitatives** et **qualitatives** sur une échelle ordinale
- **Mode** – pour les données **quantitatives** et **qualitatives**

Moyenne (variables continues)

- Plusieurs moyennes
- La moyenne est plus sensible aux valeurs extrêmes (« outliers »)
- **Moyenne arithmétique**
- **Moyenne arithmétique pondérée**

Histogramme des longueurs des haches (en cm)



Moyenne (variables continues)

- Plusieurs moyennes
- La moyenne est plus sensible aux valeurs extrêmes (« outliers »)
- **Moyenne arithmétique**
 - $\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$

Quelle est la moyenne des bières bu par 10 étudiants ?

Moyenne (variables continues)

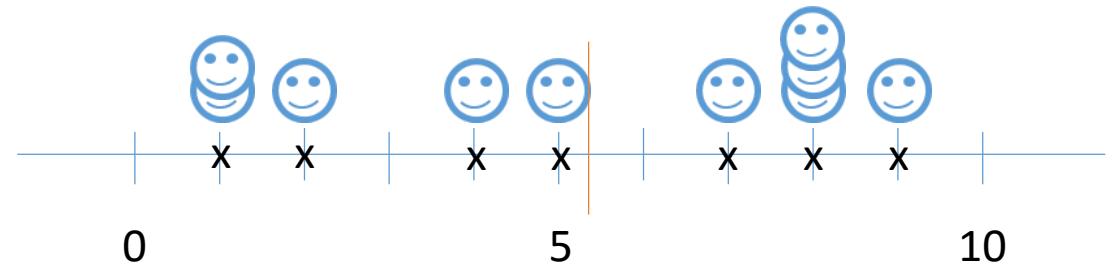
- Plusieurs moyennes
- La moyenne est plus sensible aux valeurs extrêmes (« outliers »)

$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$
$$n = 10$$



Moyenne arithmétique

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



$$\bar{x} = \frac{1 + 1 + 2 + 4 + 5 + 7 + 8 + 8 + 8 + 9}{10} = 5.3$$

Quelle est la moyenne des bières bu par 10 H et 7 F?

Moyenne (variables continues)

- Plusieurs moyennes
- La moyenne est plus sensible aux valeurs extrêmes (« outliers »)

Moyenne arithmétique

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



$$H = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9 \quad F = 1, 1, 1, 2, 2, 3, 5$$

$$n(H) = 10$$

$$n(F) = 7$$

$$\bar{x} = \frac{53 + 15}{10 + 7} = \frac{68}{17} = 4$$

Moyenne (variables continues)



- Plusieurs moyennes
- La moyenne est plus sensible aux valeurs extrêmes (« outliers »)

$H =$

$F =$

$$n(H) = 10$$

$$n(F) = 7$$

$$\overline{x(H)} = 5.3$$

$$\overline{x(F)} = 2.14$$

Moyenne arithmétique

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

Mais comment on va calculer la moyenne si le lendemain, personne ne se souvient de rien?

- 1) On sait seulement que 10H ont bu en moyenne 5.3 et 7F 2.14
- 2) Quelle est la moyenne par une personne ?

$$5.3 + 2.14 \neq 4$$

Moyenne (variables continues)



- Plusieurs moyennes
- La moyenne est plus sensible aux valeurs extrêmes (« outliers »)

$H =$

$n(H) = 10$

$\overline{x(H)} = 5.3$

$F =$

$n(F) = 7$

$\overline{x(F)} = 2.14$

• Moyenne arithmétique

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

• Moyenne arithmétique pondérée

- Dans le cas qu'on veut calculer la moyenne des deux échantillons
- Dans le cas que les valeur dans l'échantillon ont l'importance (le poids) différents

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

Mais comment on va calculer la moyenne si le lendemain, personne ne se souvient de rien?

- 1) On sait seulement que 10H ont bu en moyenne 5.3 et 7F 2.14
- 2) Quelle est la moyenne par une personne ?

$$5.3 + 2.14 \neq 4$$

Moyenne (variables continues)



- Plusieurs moyennes
- La moyenne est plus sensible aux valeurs extrêmes (« outliers »)

$H =$

$F =$

$$n(H) = 10$$

$$n(F) = 7$$

$$\overline{x(H)} = 5.3$$

$$\overline{x(F)} = 2.14$$

• Moyenne arithmétique

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

• Moyenne arithmétique pondérée

- Dans le cas qu'on veut calculer la moyenne des deux échantillons
- Dans le cas que les valeur dans l'échantillon ont l'importance (le poids) différents

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

Mais comment on va calculer la moyenne si le lendemain, personne ne se souvient de rien?

- 1) On sait seulement que 10H ont bu en moyenne 5.3 et 7F 2.14
- 2) Quelle est la moyenne par une personne ?

$$5.3 + 2.14 \neq 4$$

On va utiliser le nombre des H et F comme des poids :

$$w_H = 10$$

$$w_F = 7$$

$$\bar{x} = \frac{10 * 5.3 + 7 * 2.14}{10 + 7} = \frac{53 + 14.98}{17} = \frac{67,98}{17} = 4$$

Moyenne (variables quantitatives discrètes)

- Pour les variables en classes
- Ex : On veut définir la taille des haches qui sont dans l'intervalles de 5 cm

$$\bar{x} = \frac{\sum_{i=1}^p n_i m_i}{\sum_{i=1}^p n_i} = \frac{\text{Somme (Fréquence de chaque class *centre de classe)}}{\text{Somme des individus}}$$

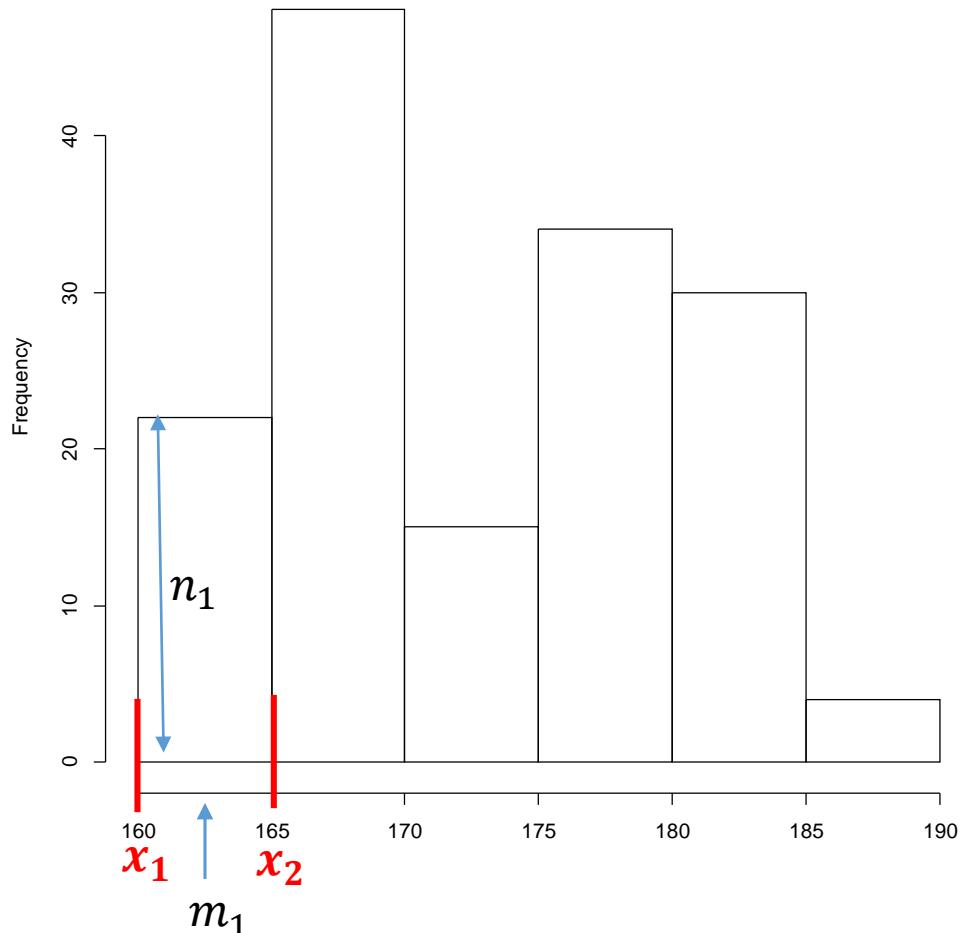
- $m_i = \frac{x_i + x_{i+1}}{2}$ - centre de classe i = la moyenne de deux limites de la classe i

Comment

- Pour chaque classe
 - On calcule la fréquence et centre
 - On multiplie ces deux valeurs
- On fait la somme de ces valeurs
- ... et on la divise par la somme totale des fréquences

Taille	Fréquence	Centre	Fréquence * Centre
160-165	22	162,5	
165-170	48	167,5	
170-175	15	172,5	
175-180	34	177,5	
180-185	30	182,5	
185-190	4	187,5	
Total	153		

Histogramme des tailles des haches (en cm)



Moyenne (variables quantitatives discrètes)

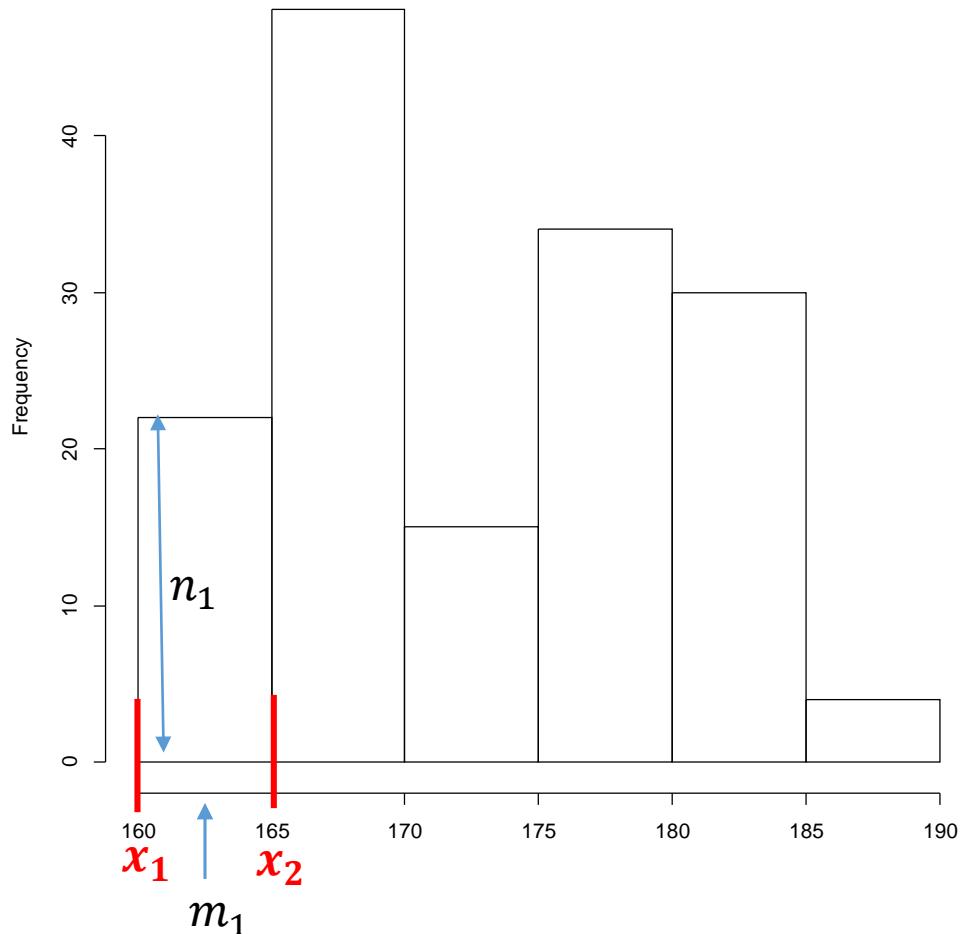
- Pour les variables en classes
- Ex : On veut définir la taille des haches qui sont dans l'intervalles de 5 cm
- $\bar{x} = \frac{\sum_{i=1}^p n_i m_i}{\sum_{i=1}^p n_i} = \frac{\text{Somme (Fréquence de chaque class *centre de classe)}}{\text{Somme des individus}}$
 - $m_i = \frac{x_i + x_{i+1}}{2}$ - centre de classe i = la moyenne de deux limites de la classe i

Comment

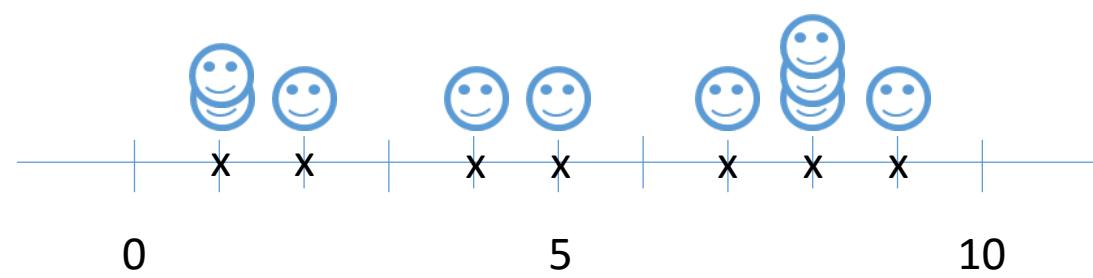
- 1) Pour chaque classe
 - 1) On calcule la fréquence et centre
 - 2) On multiplie ces deux valeurs
- 2) On fait la somme de ces valeurs
- 3) ... et on la divise par la somme totale des fréquences

Taille	Fréquence	Centre	Fréquence * Centre
160-165	22	162,5	3575
165-170	48	167,5	8040
170-175	15	172,5	2587,5
175-180	34	177,5	6035
180-185	30	182,5	5475
185-190	4	187,5	750
Total	153		26462,5

Histogramme des tailles des haches (en cm)



$$\bar{x} = \frac{26462,5}{153} = 172,96$$



Médiane

- La valeur qui divise l'échantillon en deux parties
- La valeur pour laquelle la fréquence cumulative est 0.50
- Moins sensible aux valeurs extrêmes

- **Comment calculer ?**

- 1) On ordonne les valeurs de la plus petit a la plus grande
- 2) On trouve médiane
 - Pour n impair – c'est la valeur au milieu
 - $med = x_{\left(\frac{n+1}{2}\right)}$

Q: Quelle est le médiane de ces valeurs :

$$x = 5, 3, 1, 6, 1, 3, 4$$
$$n = 7$$

$$x(\text{ordonées}) = 1, 1, 3, 3, 4, 5, 6$$

$$med(x) = x_{\left(\frac{7+1}{2}\right)} = x_{(4)} = 3$$

Médiane

- La valeur qui divise l'échantillon en deux parties
- La valeur pour laquelle la fréquence cumulative est 0.50
- Moins sensible aux valeurs extrêmes

• Comment calculer ?

- 1) On ordonne les valeurs de la plus petit a la plus grande
- 2) On trouve médiane
 - Pour n impair – c'est la valeur au milieu
 - $med = x_{(\frac{n+1}{2})}$
 - Pour n pair – c'est la moyenne arithmétique des deux valeurs qui sont le plus au milieu
 - $med = \frac{x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}}{2}$

Q: Quelle est le médiane de ces valeurs :

$$x = 5, 3, 1, 6, 1, 3, 4$$
$$n = 7$$

$$x(\text{ordonées}) = 1, 1, 3, 3, 4, 5, 6$$

$$med(x) = x_{(\frac{7+1}{2})} = x_{(4)} = 3$$

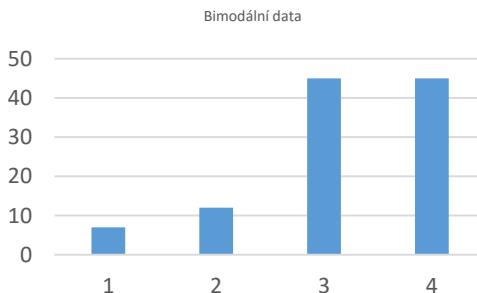
Q: Quelle est le médiane de ces valeurs :

$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$
$$n = 10$$

$$med(x) = \frac{x_{(\frac{10}{2})} + x_{(\frac{10}{2}+1)}}{2} = \frac{x_{(5)} + x_{(6)}}{2} = \frac{5+7}{2} = 6$$

Mode

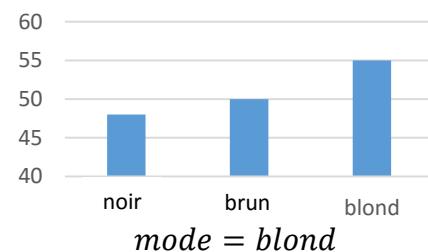
- La valeur/classe la plus fréquente
- Une distribution peut avoir un ou plusieurs modes
 - Uni, Bi, Tri-modale



- Avantages
 - pas sensible aux valeurs extrêmes
 - bon indicateur des populations hétérogènes
- Désavantage
 - Il n'est pas toujours la valeur centrale d'une distribution
 - Il peut changer si on change l'intervalle de la classe

Classe	Fréquence absolue
Blond	55
Noir	48
Brun	50

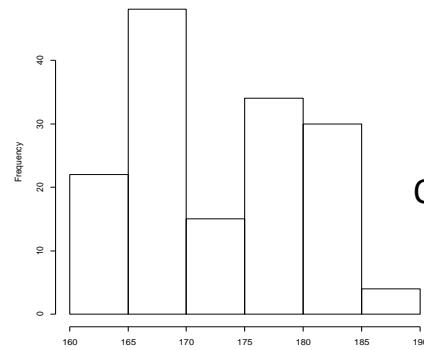
La couleur des cheveux



Qualitatives

Taille	Fréquence absolue
160-165	22
165-170	48
170-175	15
175-180	34
180-185	30
185-190	4

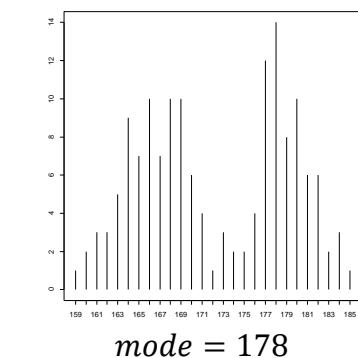
Histogramme des tailles des haches



Quantitatives discrètes

Individu	Taille
Hache 1	174
Hache 2	168
Hache 3	158
...	...
Hache 152	179
Hache 153	173

Continuels



Statistiques descriptives

- 1) Tables des fréquences
- 2) Méthodes graphiques
- 3) Les tendances centrales
- 4) Les tendances de la variabilité (dispersion)**
- 5) Distributions

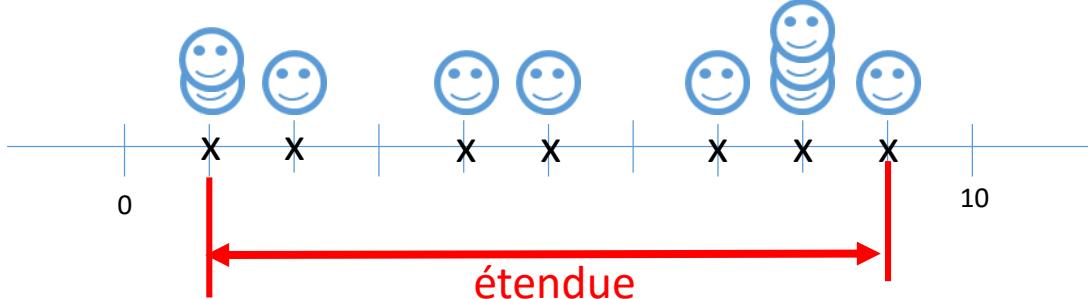
Variabilité

- Montre comment les valeurs sont différents
 - un par rapport des autres
 - d'après une certain valeur (surtout de la moyenne et médiane)
- Variabilité est exprimé par
 - Etendue
 - Ecart de la moyenne
 - La variance
 - Ecarte type
 - Quantiles

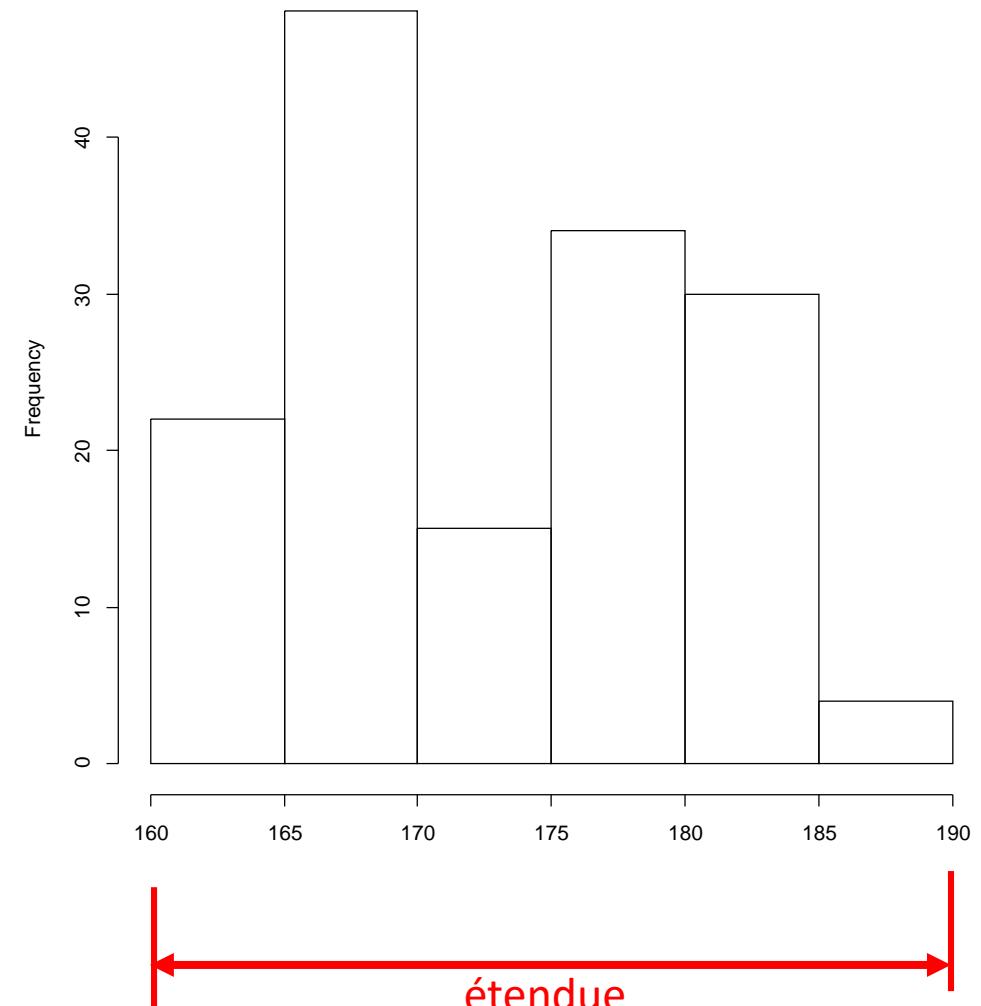
Etendue

- La différence entre la valeur la plus grande et la plus petite
- $x_{Etendue} = x_{max} - x_{min}$

$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$



Histogramme des tailles des haches



Ecart moyen et Ecart médian

- Le plus simple à comprendre
 - Représentent les distances moyennes des valeurs de la moyenne/médiane
-
- $Ecart moyen = \frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$
 - $Ecart médian = \frac{\sum_{i=1}^n |x_i - med|}{n}$

$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

Ecart moyen et Ecart médian

- Le plus simple à comprendre
- Représente les distances moyennes des valeurs de la moyenne/médiane

$$\bullet \text{ Ecart moyen} = \frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$$

$$\bullet \text{ Ecart médian} = \frac{\sum_{i=1}^n |x_i - \text{med}|}{n}$$

$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

Ecart moyen et Ecart médian

- Le plus simple à comprendre
- Représente les distances moyennes des valeurs de la moyenne/médiane
- $Ecart moyen = \frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$
- $Ecart médian = \frac{\sum_{i=1}^n |x_i - med|}{n}$

$$EM = \frac{|1 - 5.3| + |1 - 5.3| + |2 - 5.3| + \dots + |9 - 5.3|}{10} = \frac{27}{10} = 2.7$$

$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

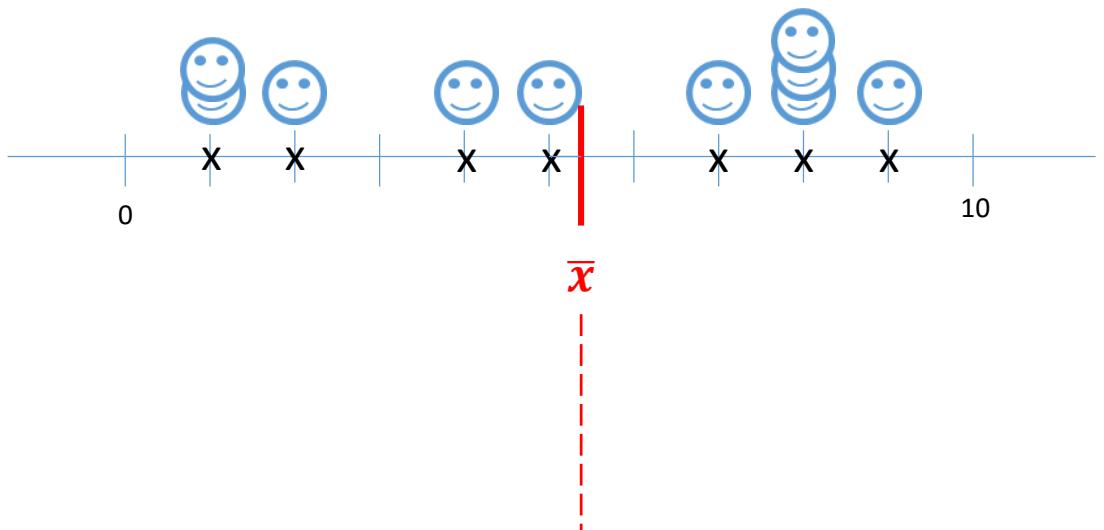
$$\bar{x} = 5.3$$

$$n = 10$$

Ecart moyen et Ecart médian

- Le plus simple à comprendre
 - Représente les distances moyennes des valeurs de la moyenne/médiane
-
- *Ecart moyen* = $\frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$
 - *Ecart médian* = $\frac{\sum_{i=1}^n |x_i - med|}{n}$

$$EM = \frac{|1 - 5.3| + |1 - 5.3| + |2 - 5.3| + \dots + |9 - 5.3|}{10} = \frac{27}{10} = 2.7$$



$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

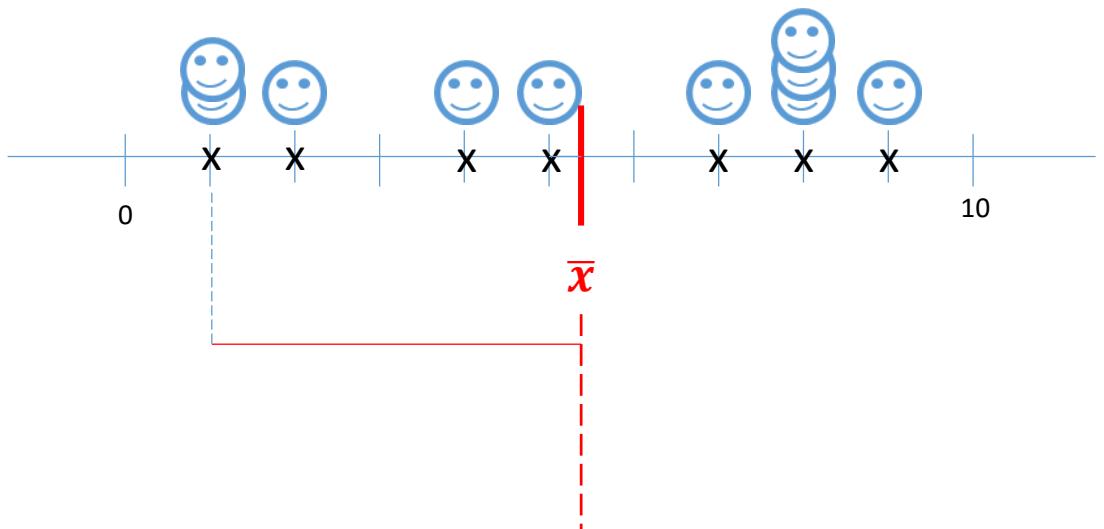
$$\bar{x} = 5.3$$

$$n = 10$$

Ecart moyen et Ecart médian

- Le plus simple à comprendre
 - Représente les distances moyennes des valeurs de la moyenne/médiane
-
- *Ecart moyen* = $\frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$
 - *Ecart médian* = $\frac{\sum_{i=1}^n |x_i - med|}{n}$

$$EM = \frac{|1 - 5.3| + |1 - 5.3| + |2 - 5.3| + \dots + |9 - 5.3|}{10} = \frac{27}{10} = 2.7$$



$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

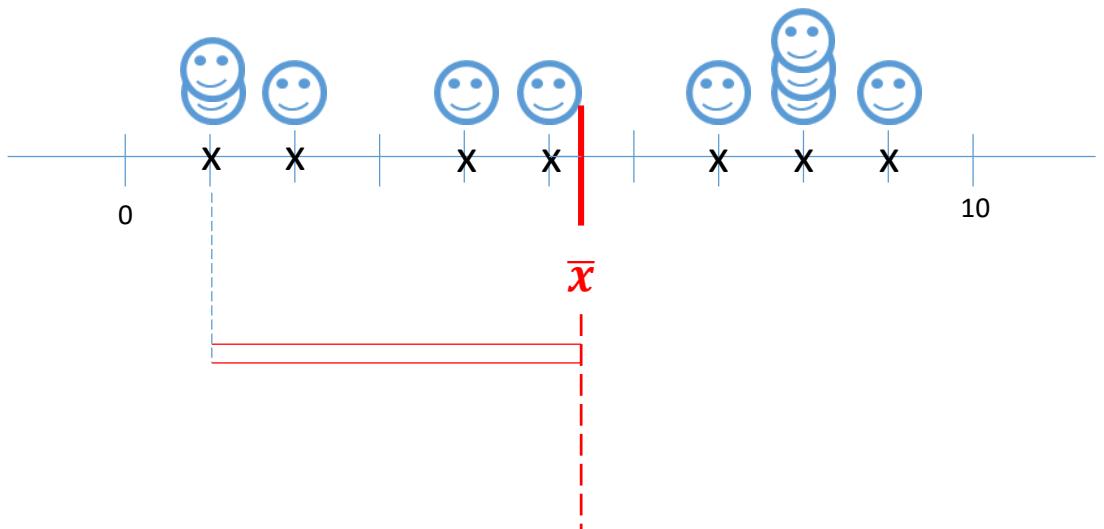
$$\bar{x} = 5.3$$

$$n = 10$$

Ecart moyen et Ecart médian

- Le plus simple à comprendre
 - Représente les distances moyennes des valeurs de la moyenne/médiane
-
- *Ecart moyen* = $\frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$
 - *Ecart médian* = $\frac{\sum_{i=1}^n |x_i - med|}{n}$

$$EM = \frac{|1 - 5.3| + |1 - 5.3| + |2 - 5.3| + \dots + |9 - 5.3|}{10} = \frac{27}{10} = 2.7$$



$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

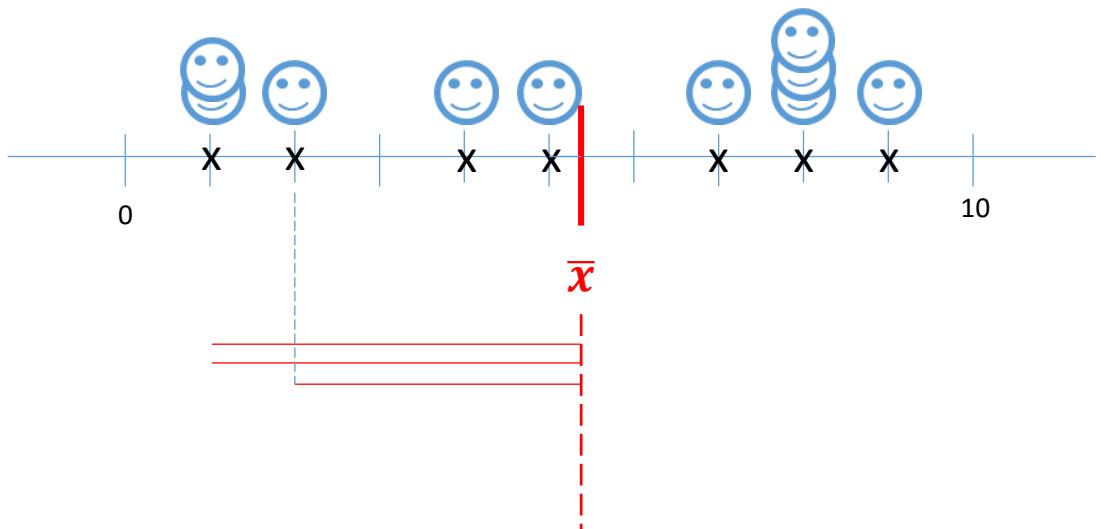
$$\bar{x} = 5.3$$

$$n = 10$$

Ecart moyen et Ecart médian

- Le plus simple à comprendre
 - Représente les distances moyennes des valeurs de la moyenne/médiane
-
- *Ecart moyen* = $\frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$
 - *Ecart médian* = $\frac{\sum_{i=1}^n |x_i - med|}{n}$

$$EM = \frac{|1 - 5.3| + |1 - 5.3| + |2 - 5.3| + \dots + |9 - 5.3|}{10} = \frac{27}{10} = 2.7$$



$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

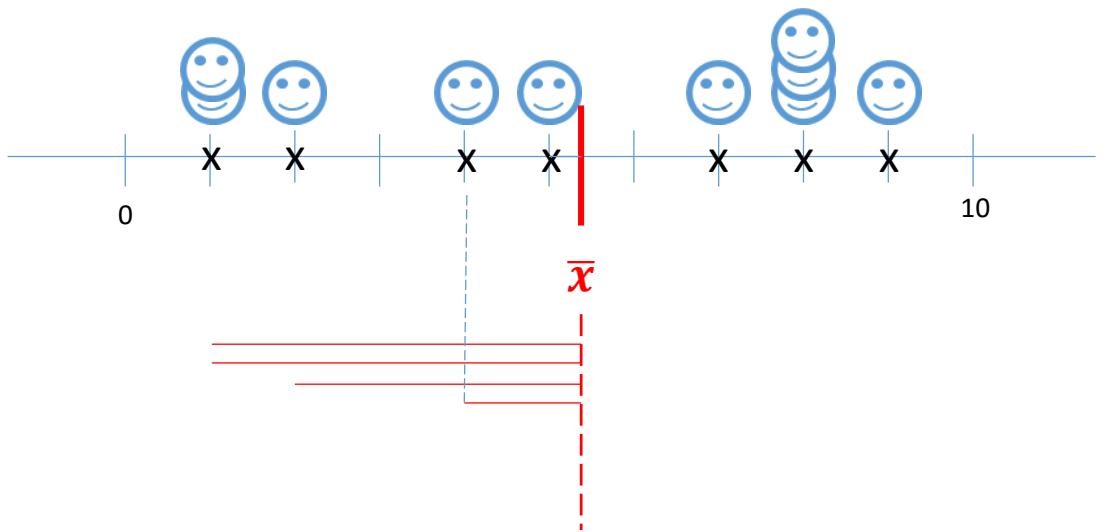
$$\bar{x} = 5.3$$

$$n = 10$$

Ecart moyen et Ecart médian

- Le plus simple à comprendre
 - Représente les distances moyennes des valeurs de la moyenne/médiane
-
- *Ecart moyen* = $\frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$
 - *Ecart médian* = $\frac{\sum_{i=1}^n |x_i - med|}{n}$

$$EM = \frac{|1 - 5.3| + |1 - 5.3| + |2 - 5.3| + \dots + |9 - 5.3|}{10} = \frac{27}{10} = 2.7$$



$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

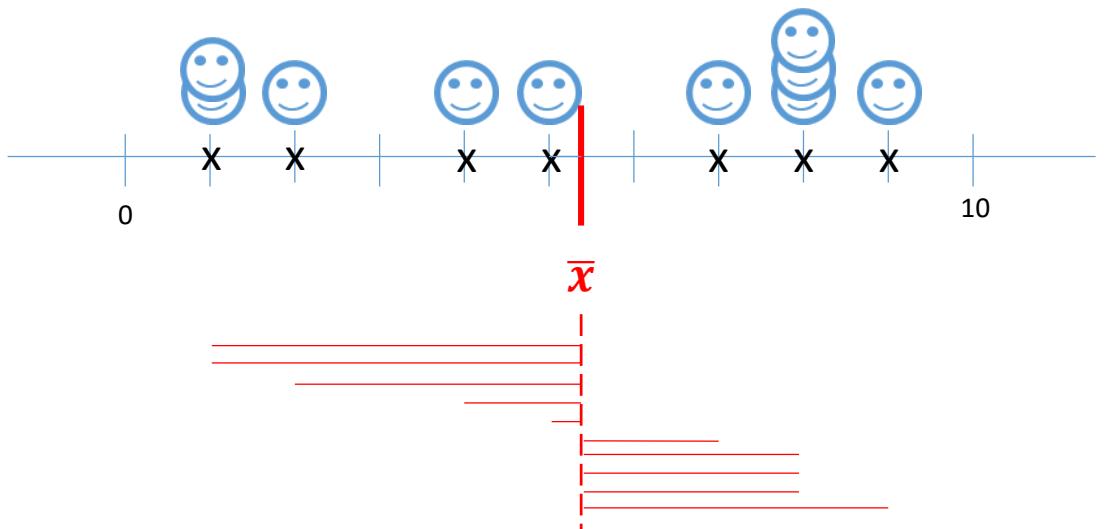
$$\bar{x} = 5.3$$

$$n = 10$$

Ecart moyen et Ecart médian

- Le plus simple à comprendre
 - Représente les distances moyennes des valeurs de la moyenne/médiane
-
- *Ecart moyen* = $\frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$
 - *Ecart médian* = $\frac{\sum_{i=1}^n |x_i - med|}{n}$

$$EM = \frac{|1 - 5.3| + |1 - 5.3| + |2 - 5.3| + \dots + |9 - 5.3|}{10} = \frac{27}{10} = 2.7$$



$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

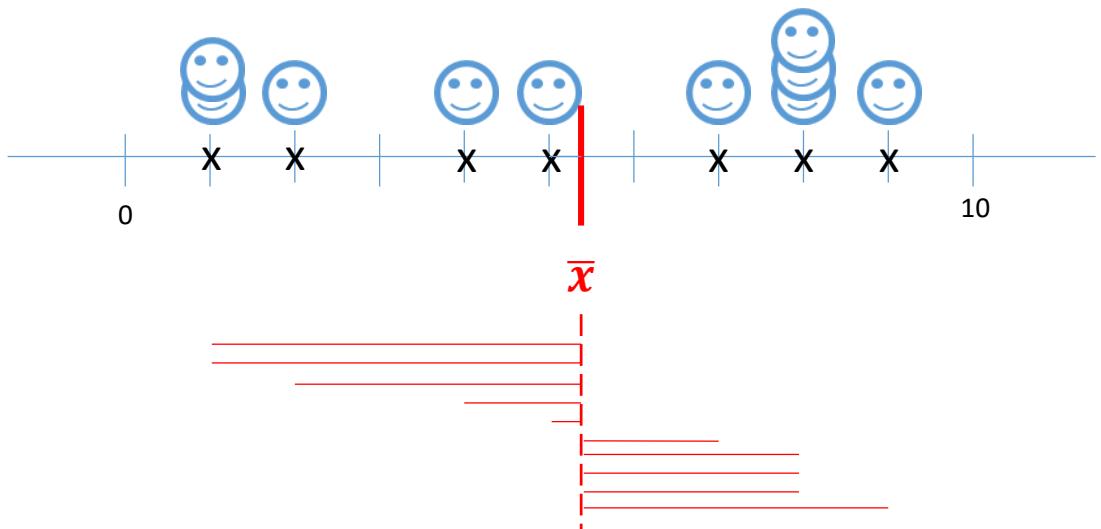
$$\bar{x} = 5.3$$

$$n = 10$$

Ecart moyen et Ecart médian

- Le plus simple à comprendre
 - Représente les distances moyennes des valeurs de la moyenne/médiane
-
- *Ecart moyen* = $\frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$
 - *Ecart médian* = $\frac{\sum_{i=1}^n |x_i - med|}{n}$

$$EM = \frac{|1 - 5.3| + |1 - 5.3| + |2 - 5.3| + \dots + |9 - 5.3|}{10} = \frac{27}{10} = 2.7$$



$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

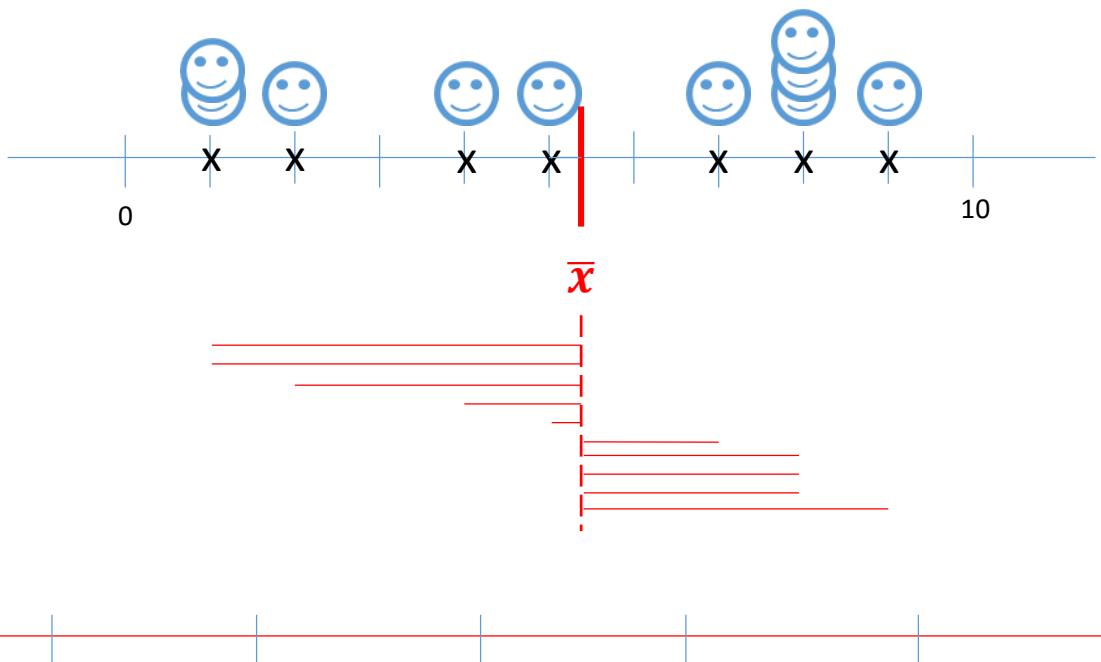
$$\bar{x} = 5.3$$

$$n = 10$$

Ecart moyen et Ecart médian

- Le plus simple à comprendre
 - Représente les distances moyennes des valeurs de la moyenne/médiane
-
- *Ecart moyen* = $\frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$
 - *Ecart médian* = $\frac{\sum_{i=1}^n |x_i - med|}{n}$

$$EM = \frac{|1 - 5.3| + |1 - 5.3| + |2 - 5.3| + \dots + |9 - 5.3|}{10} = \frac{27}{10} = 2.7$$



$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

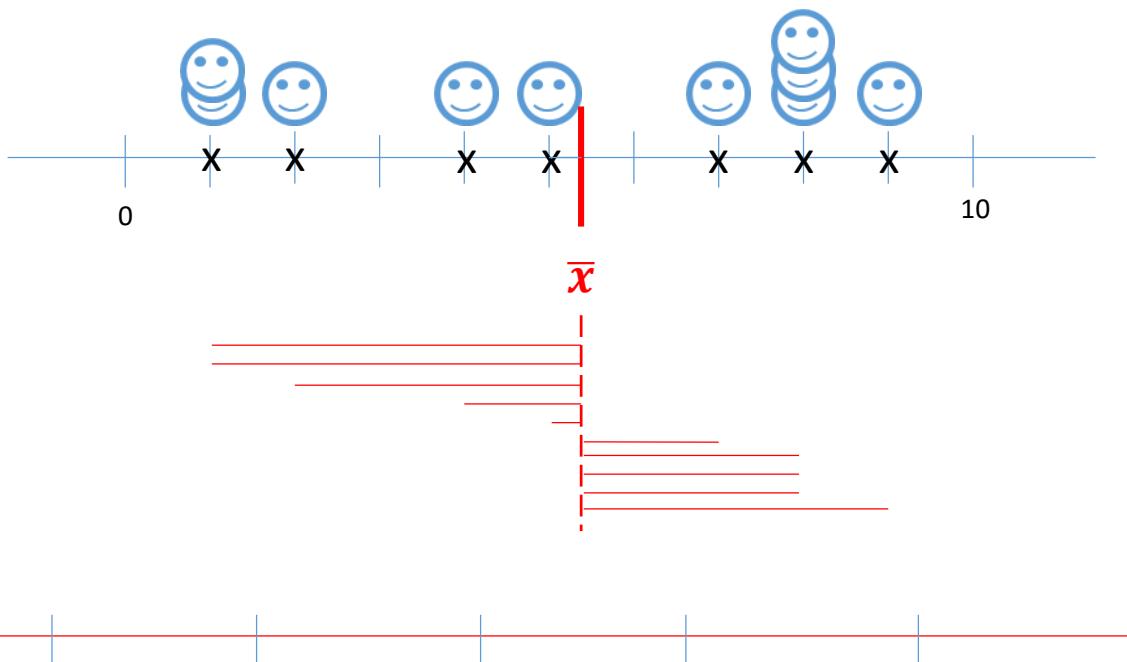
$$\bar{x} = 5.3$$

$$n = 10$$

Ecart moyen et Ecart médian

- Le plus simple à comprendre
 - Représente les distances moyennes des valeurs de la moyenne/médiane
-
- *Ecart moyen* = $\frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$
 - *Ecart médian* = $\frac{\sum_{i=1}^n |x_i - med|}{n}$

$$EM = \frac{|1 - 5.3| + |1 - 5.3| + |2 - 5.3| + \dots + |9 - 5.3|}{10} = \frac{27}{10} = 2.7$$



$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$med = 6$$

$$n = 10$$

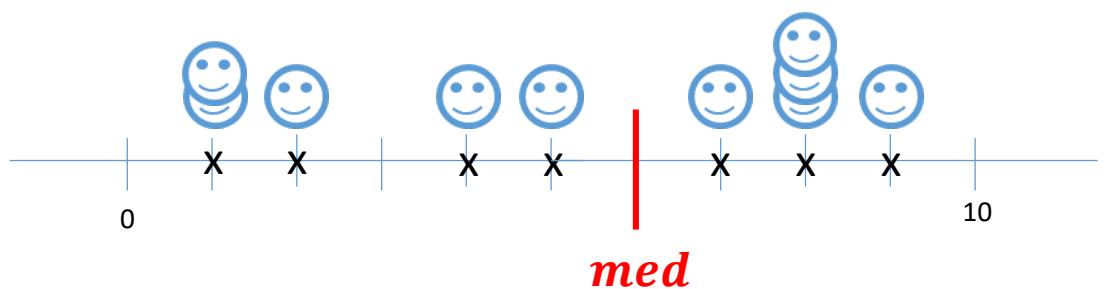
Ecart moyen et Ecart médian

- Le plus simple à comprendre
- Représentent les distances moyennes des valeurs de la moyenne/médiane

$$\text{Ecart moyen} = \frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$$

$$\text{Ecart médian} = \frac{\sum_{i=1}^n |x_i - med|}{n}$$

$$EMED = \frac{|1 - 6| + |1 - 6| + |2 - 6| + \dots + |9 - 6|}{10} = \frac{27}{10} = 2.7$$



Variance

- Presque la même chose que EM, mais au lieu de calculer les distances, on calcule les distances carrées
- On peut la imaginer comme le carré moyen

- **Pour population :**

- $\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{N}$

- **Pour l'échantillon :**

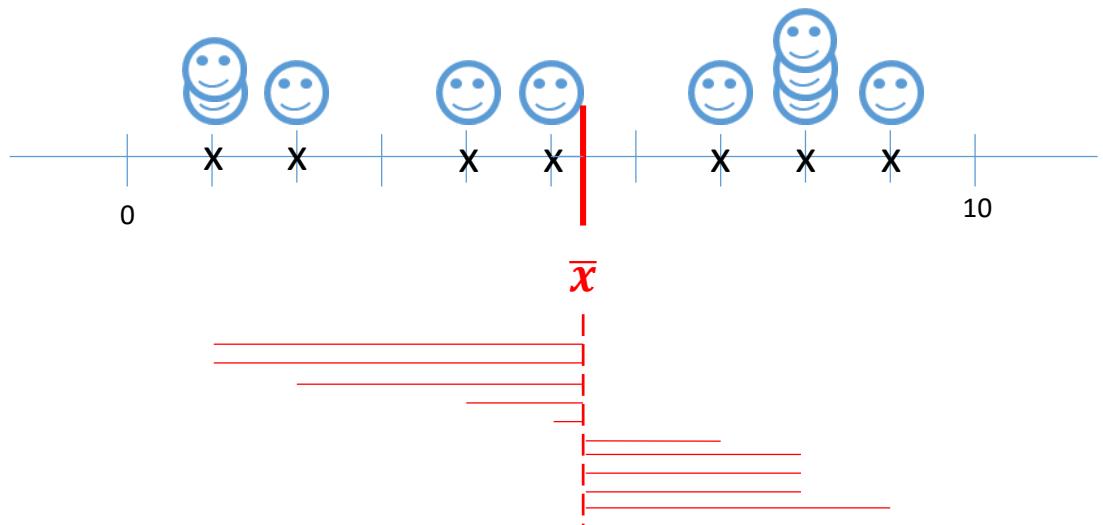
- $s_x^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}$

$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

$$s_x^2 = \frac{(1 - 5.3)^2 + (1 - 5.3)^2 + (2 - 5.3)^2 + \dots + (9 - 5.3)^2}{10 - 1} = \frac{88.1}{9} = 9.79$$



Variance

- Presque la même chose que EM, mais au lieu de calculer les distances, on calcule les distances carrées
- On peut la imaginer comme le carré moyen

- **Pour population :**

- $\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{N}$

- **Pour l'échantillon :**

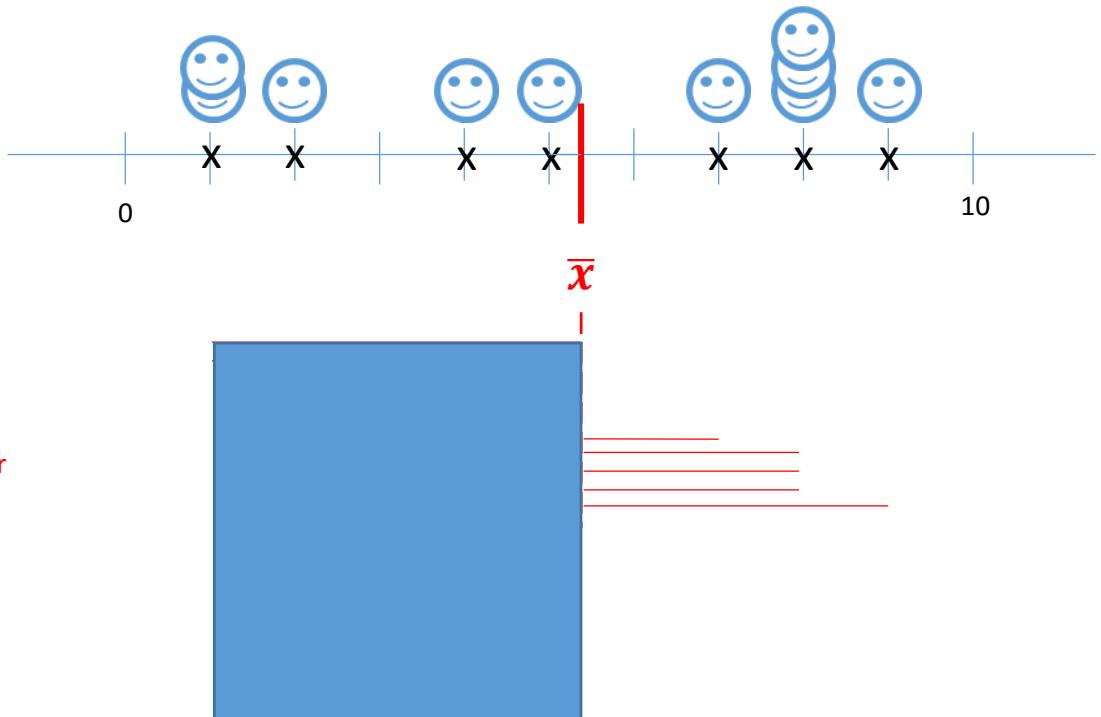
- $s_x^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}$

$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

$$s_x^2 = \frac{(1 - 5.3)^2 + (1 - 5.3)^2 + (2 - 5.3)^2 + \dots + (9 - 5.3)^2}{10 - 1} = \frac{88.1}{9} = 9.79$$



Variance

- Presque la même chose que EM, mais au lieu de calculer les distances, on calcule les distances carrées
- On peut la imaginer comme le carré moyen

- **Pour population :**

- $\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{N}$

- **Pour l'échantillon :**

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

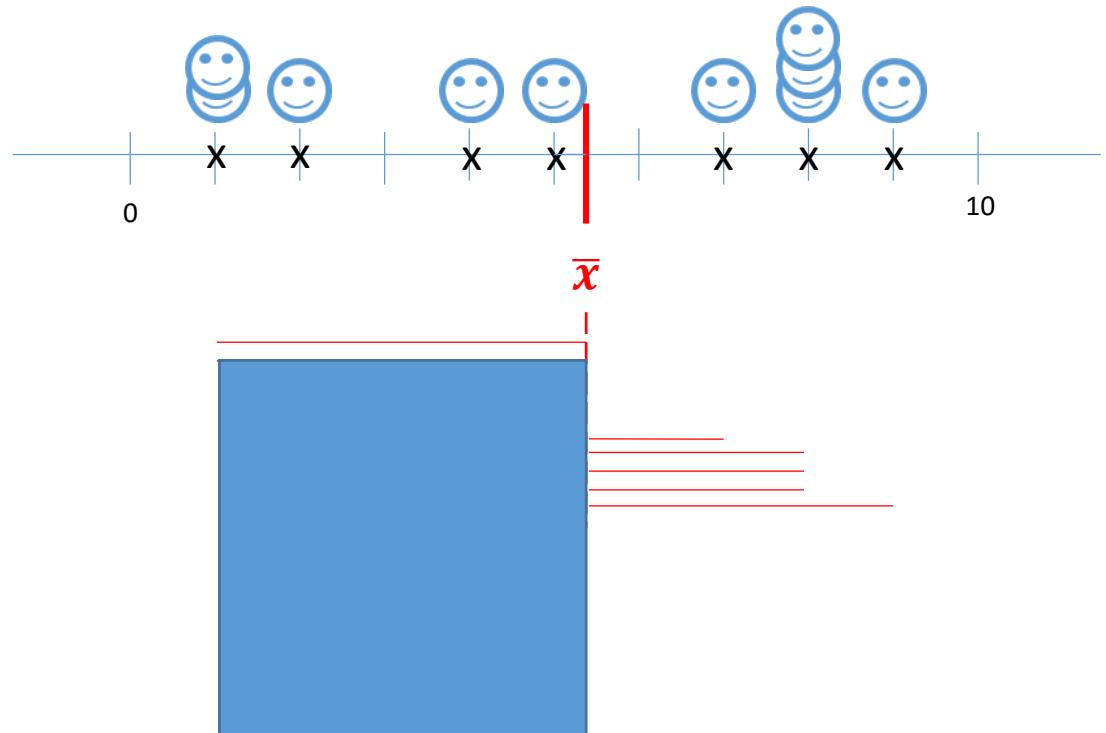
2x

$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

$$s_x^2 = \frac{(1 - 5.3)^2 + (1 - 5.3)^2 + (2 - 5.3)^2 + \dots + (9 - 5.3)^2}{10 - 1} = \frac{88.1}{9} = 9.79$$



Variance

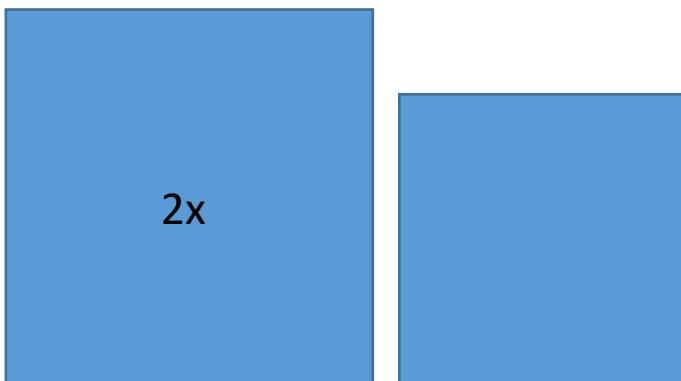
- Presque la même chose que EM, mais au lieu de calculer les distances, on calcule les distances carrées
- On peut la imaginer comme le carré moyen

- **Pour population :**

- $\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{N}$

- **Pour l'échantillon :**

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

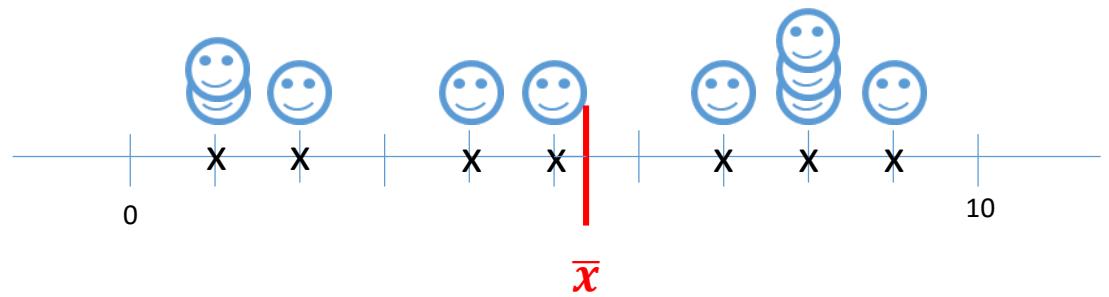


$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

$$s_x^2 = \frac{(1 - 5.3)^2 + (1 - 5.3)^2 + (2 - 5.3)^2 + \dots + (9 - 5.3)^2}{10 - 1} = \frac{88.1}{9} = 9.79$$



Variance

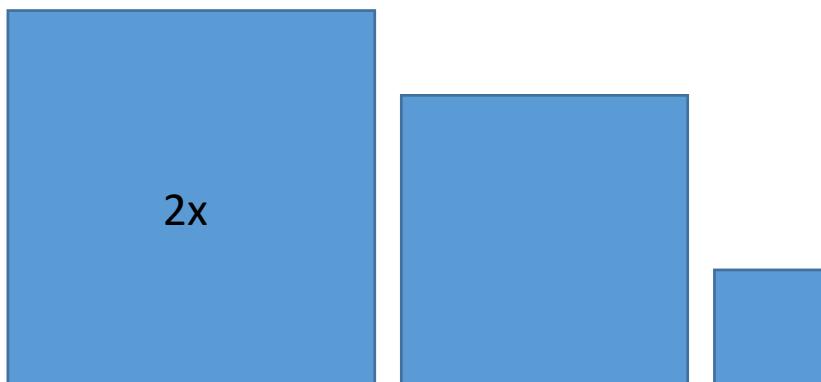
- Presque la même chose que EM, mais au lieu de calculer les distances, on calcule les distances carrées
- On peut la imaginer comme le carré moyen

- Pour population :

- $\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{N}$

- Pour l'échantillon :

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

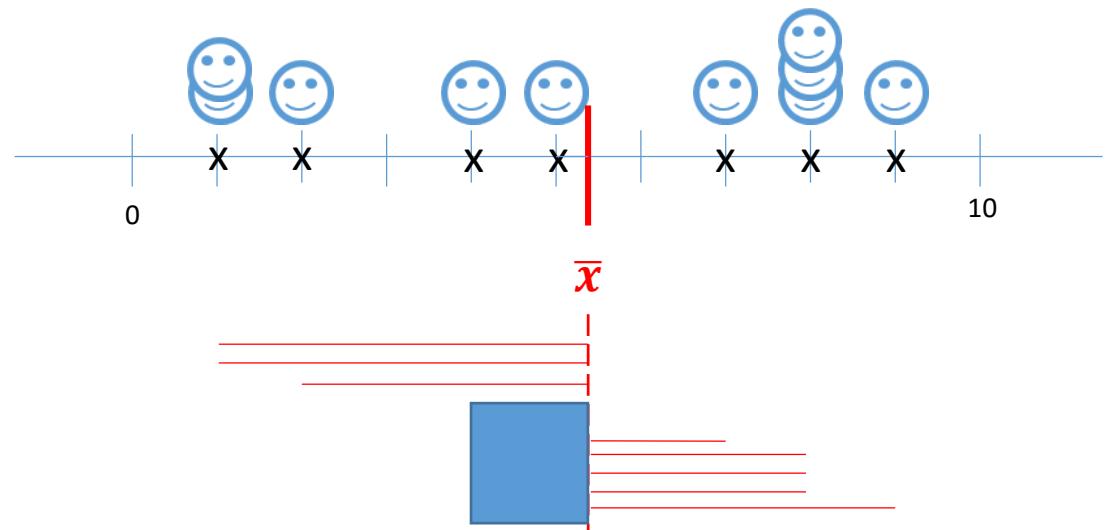


$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

$$s_x^2 = \frac{(1 - 5.3)^2 + (1 - 5.3)^2 + (2 - 5.3)^2 + \dots + (9 - 5.3)^2}{10 - 1} = \frac{88.1}{9} = 9.79$$



Variance

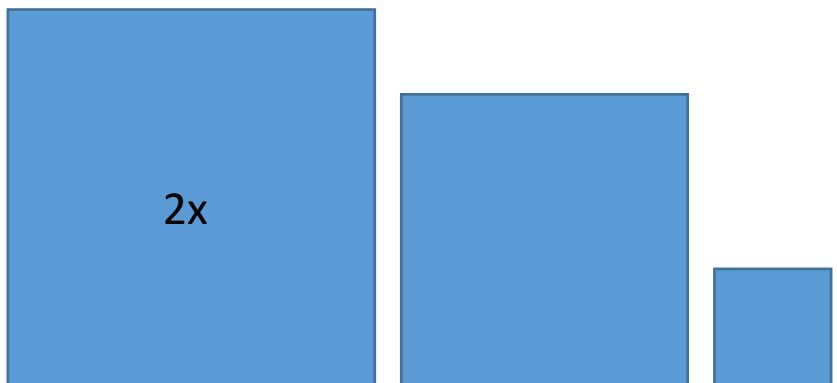
- Presque la même chose que EM, mais au lieu de calculer les distances, on calcule les distances carrées
- On peut la imaginer comme le carré moyen

- Pour population :

- $\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{N}$

- Pour l'échantillon :

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

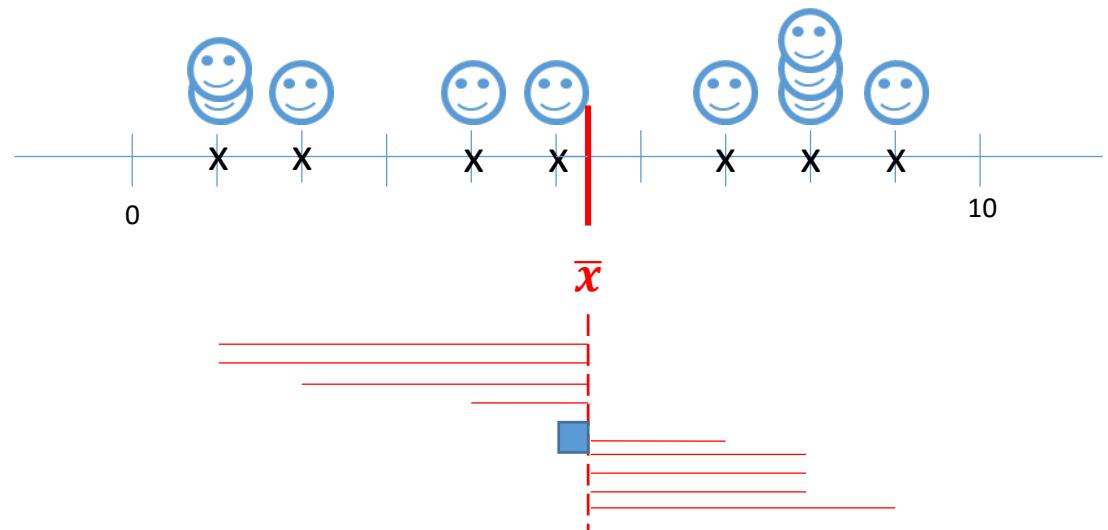


$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

$$s_x^2 = \frac{(1 - 5.3)^2 + (1 - 5.3)^2 + (2 - 5.3)^2 + \dots + (9 - 5.3)^2}{10 - 1} = \frac{88.1}{9} = 9.79$$



Variance

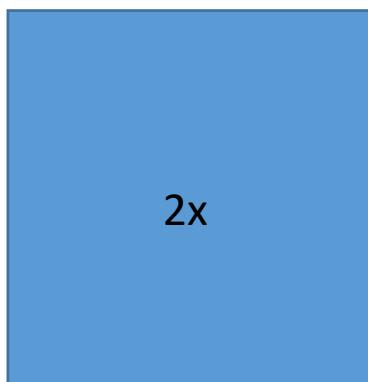
- Presque la même chose que EM, mais au lieu de calculer les distances, on calcule les distances carrées
- On peut la imaginer comme le carré moyen

- Pour population :

- $\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{N}$

- Pour l'échantillon :

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

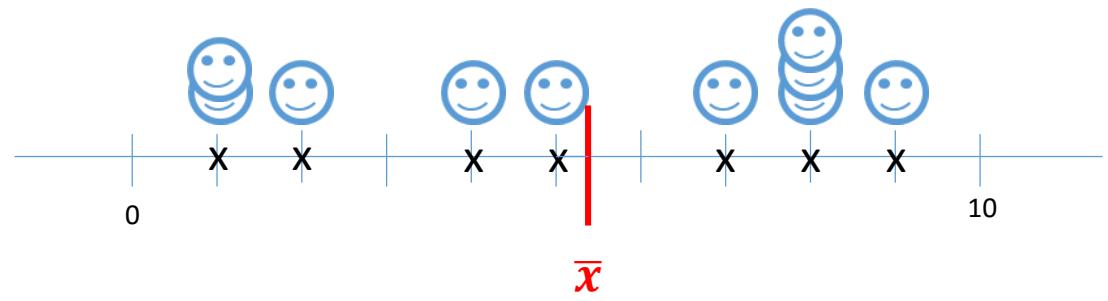


$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

$$s_x^2 = \frac{(1 - 5.3)^2 + (1 - 5.3)^2 + (2 - 5.3)^2 + \dots + (9 - 5.3)^2}{10 - 1} = \frac{88.1}{9} = 9.79$$



Variance

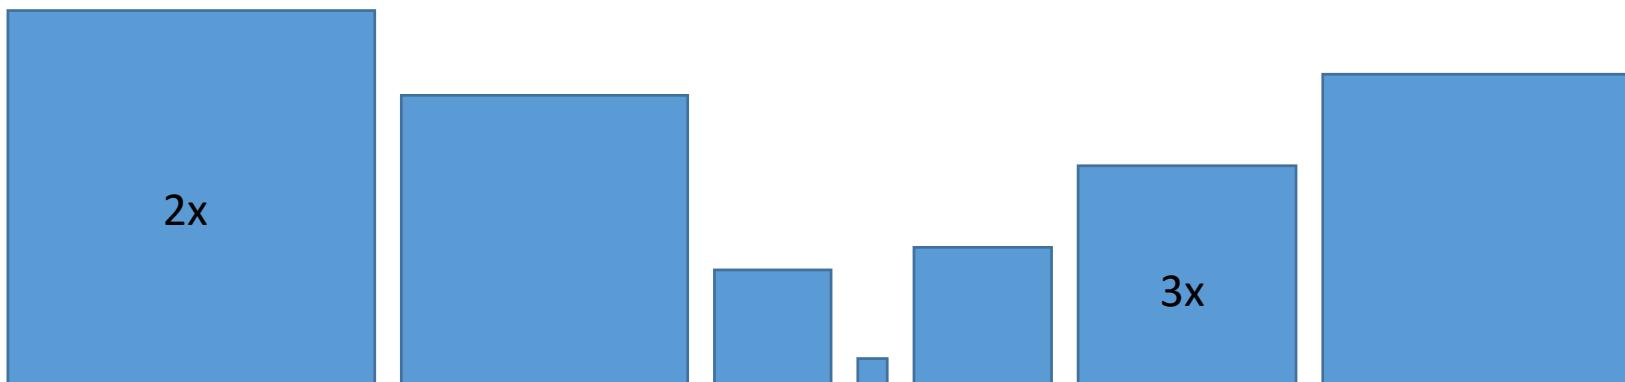
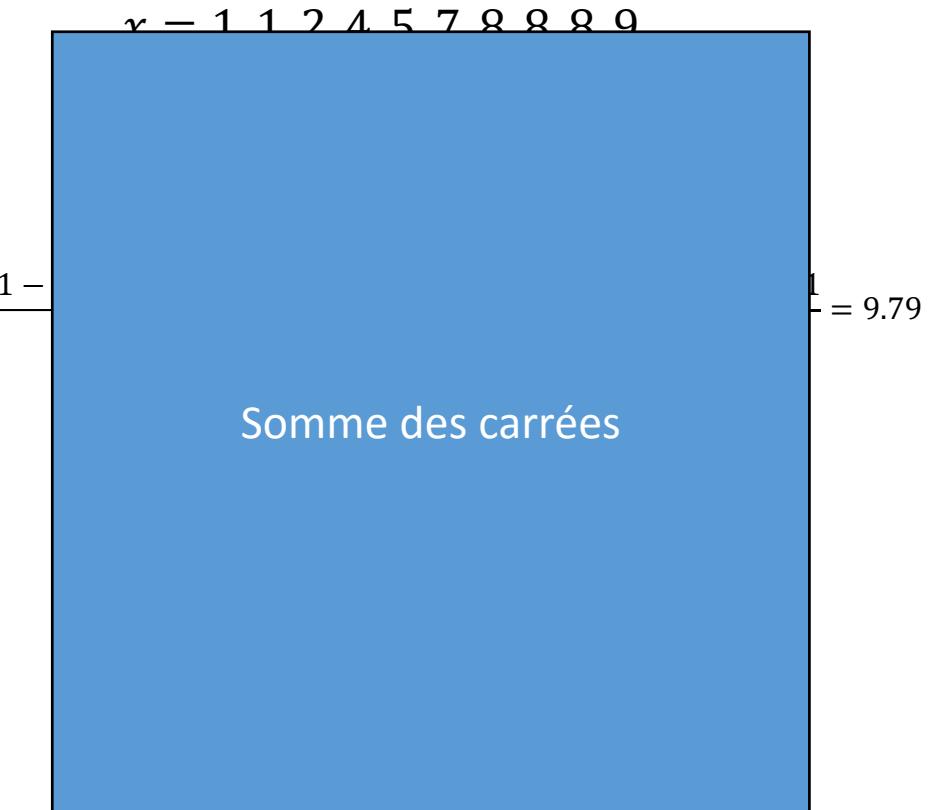
- Presque la même chose que EM, mais au lieu de calculer les distances, on calcule les distances carrées
- On peut la imaginer comme le carré moyen

- **Pour population :**

- $$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{N}$$

- **Pour l'échantillon :**

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



Variance

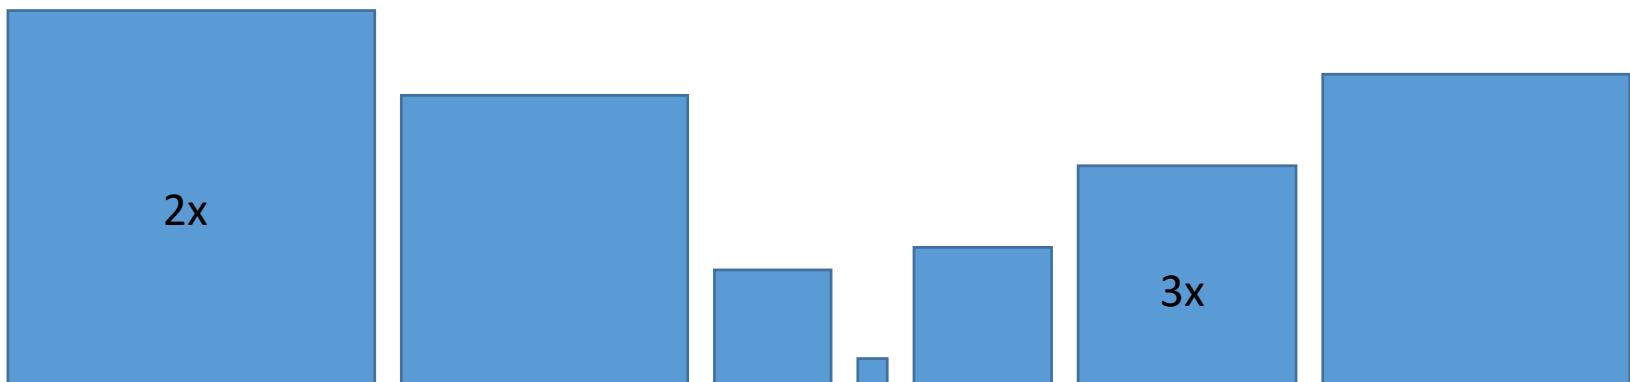
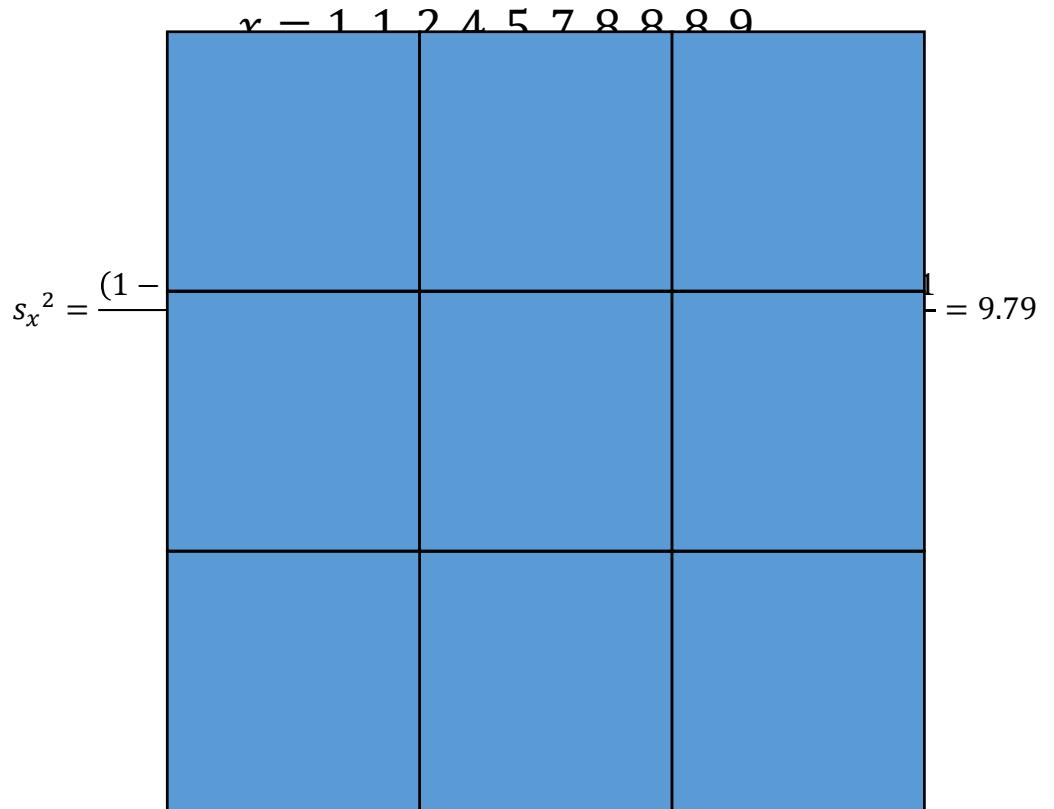
- Presque la même chose que EM, mais au lieu de calculer les distances, on calcule les distances carrées
- On peut la imaginer comme le carré moyen

- **Pour population :**

- $$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{N}$$

- **Pour l'échantillon :**

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



Variance

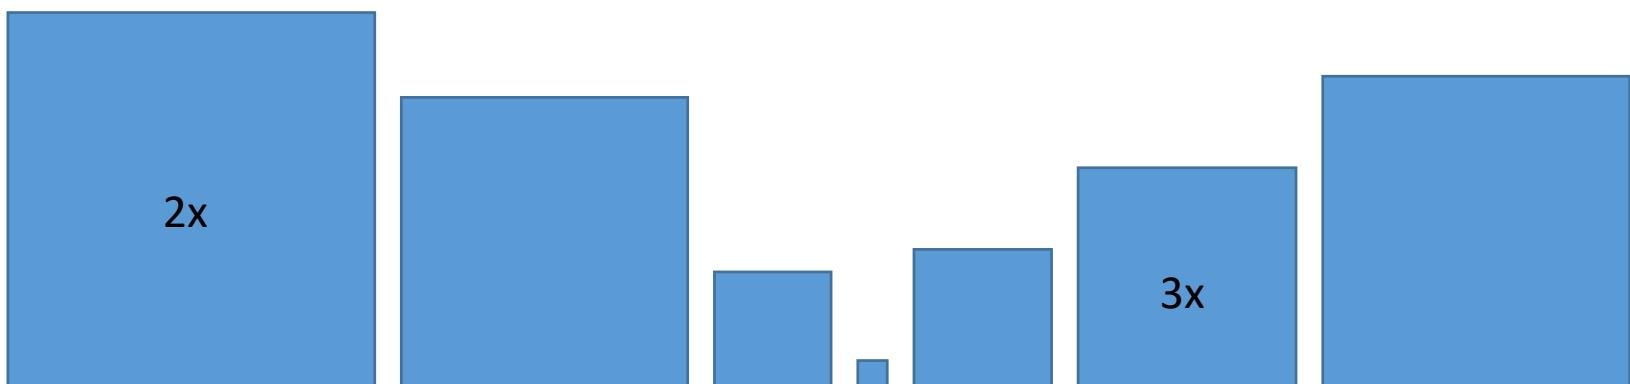
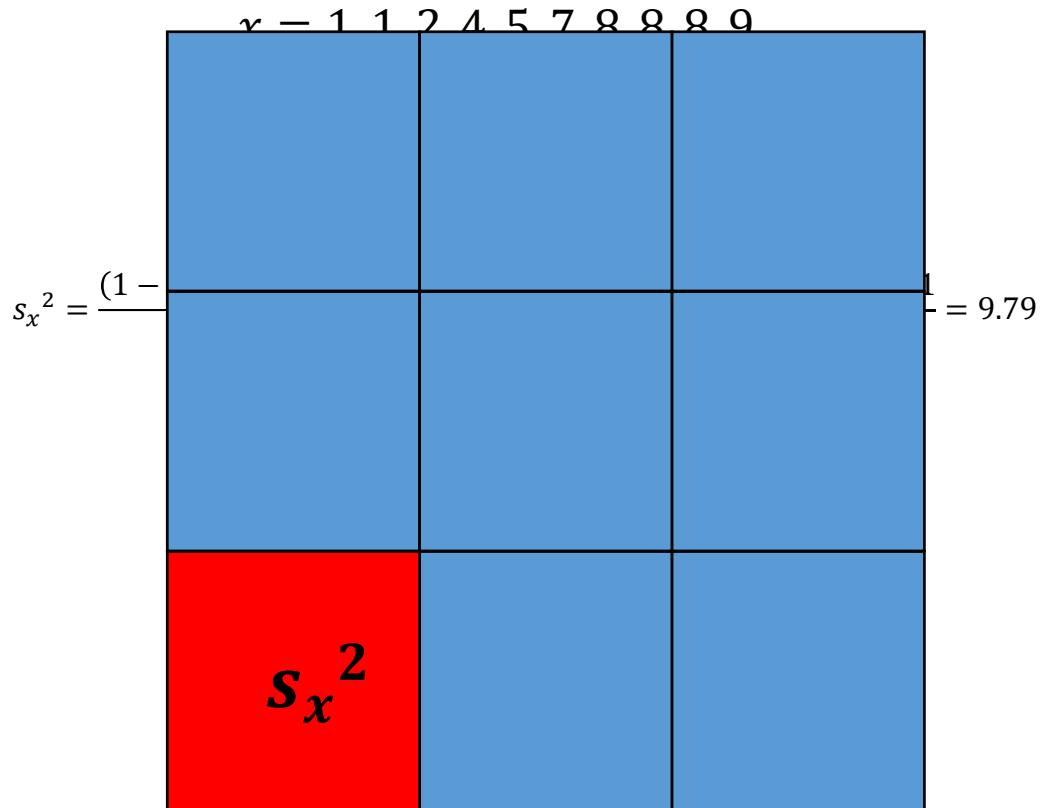
- Presque la même chose que EM, mais au lieu de calculer les distances, on calcule les distances carrées
- On peut la imaginer comme le carré moyen

- **Pour population :**

- $\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{N}$

- **Pour l'échantillon :**

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



Variance

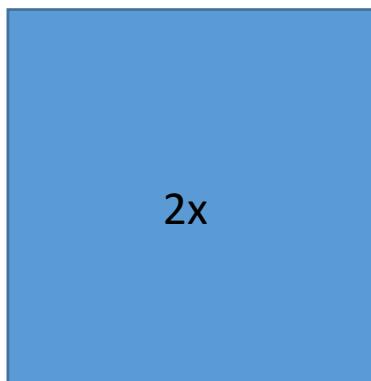
- Presque la même chose que EM, mais au lieu de calculer les distances, on calcule les distances carrées
- On peut la imaginer comme le carré moyen

- Pour population :

- $\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{N}$

- Pour l'échantillon :

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

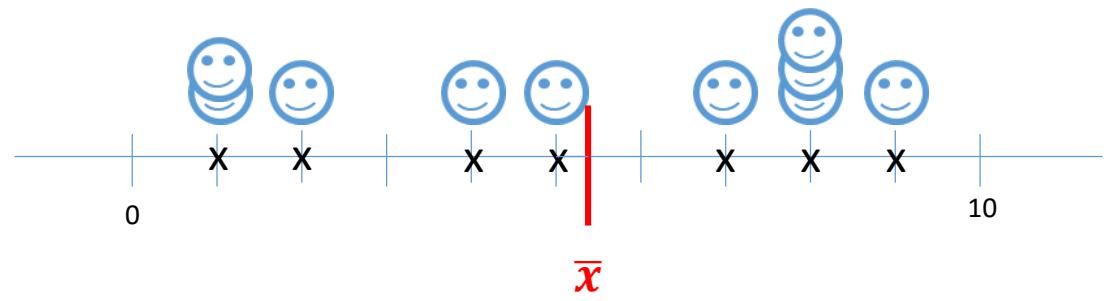


$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

$$s_x^2 = \frac{(1 - 5.3)^2 + (1 - 5.3)^2 + (2 - 5.3)^2 + \dots + (9 - 5.3)^2}{10 - 1} = \frac{88.1}{9} = 9.79$$



$$s_x^2 = 9.79 \text{ bieres}^2$$

Ecart type

- Exprime la variabilité moyenne des données
- Égale à la racine carré de la variance => un coté d'un « carré moyen »
- Pour population: $\sigma = \sqrt{\sigma^2}$
- Pour échantillon: $s_x = \sqrt{s_x^2}$
- Plus l'écart type est grand, plus les valeurs sont éloignées (dispersées) autour de la moyenne
- Les unités sont le même que pour les données

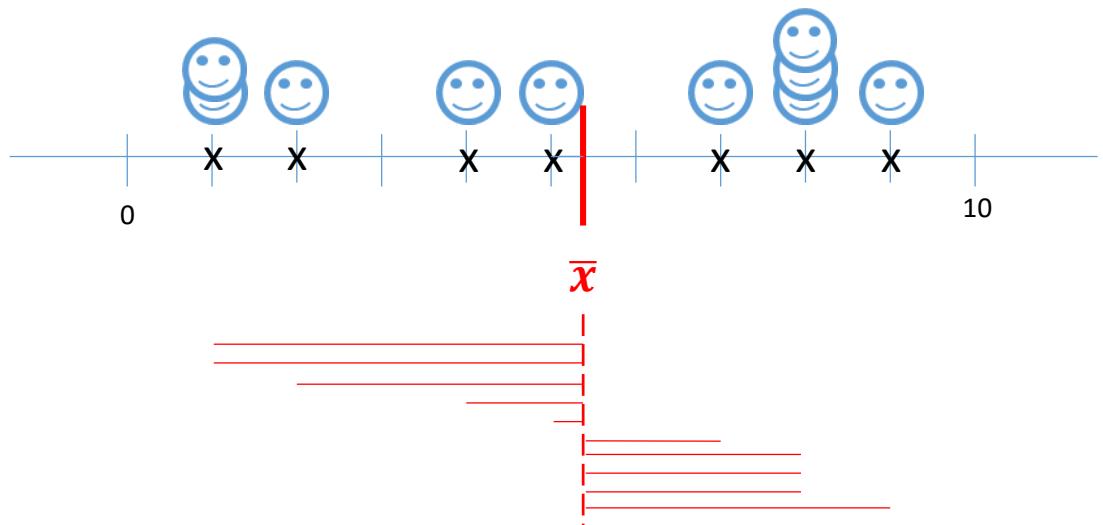
$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

$$s_x^2 = 9.79$$

$$s_x = \sqrt{9.79} = 3.13$$



Ecart type

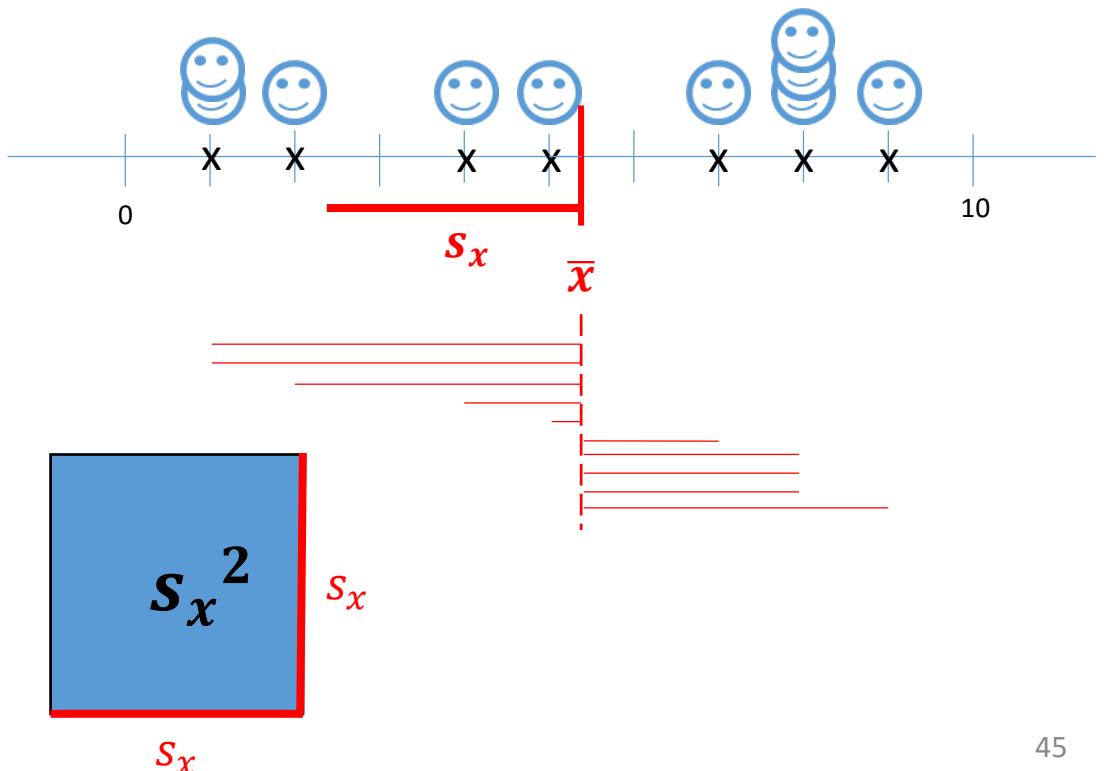
- Exprime la variabilité moyenne des données
- Égale à la racine carré de la variance => un coté d'un « carré moyen »
- Pour population: $\sigma = \sqrt{\sigma^2}$
- Pour échantillon: $s_x = \sqrt{s_x^2}$
- Plus l'écart type est grand, plus les valeurs sont éloignées (dispersées) autour de la moyenne
- Les unités sont le même que pour les données

$$x = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$\bar{x} = 5.3$$

$$n = 10$$

$$s_x^2 = 9.79$$
$$s_x = \sqrt{9.79} = 3.13$$



Le coefficient de variation

- Pour les variables continues
- Pourquoi ? – Pour comparer les données
 - qui ont les moyennes très différents
 - qui sont dans les unités différents
- *Ex: Pour comparer la variance entre la taille des haches et des fibules*
- *Ex: Pour comparer la variance entre le poids des bracelets en verre et la quantité du bronze dans les épingle*s
- Comment ?
- $c_v = \frac{s_x}{|x|}$ Ratio entre l'écart type et la valeur absolue de la moyenne
- Si on veut avoir la valeur du CV en pourcentage, on multiplie par 100
- $c_v = \frac{100 * s_x}{|x|}$ (%)

Comparaison de la variabilité des bières et la taille des haches.

Le coefficient de variation

- Pour les variables continues
- Pourquoi ? – Pour comparer les données
 - qui ont les moyennes très différents
 - qui sont dans les unités différents
- Ex: Pour comparer la variance entre la taille des haches et des fibules
- Ex: Pour comparer la variance entre le poids des bracelets en verre et la quantité du bronze dans les épingle
- Comment ?
- $c_v = \frac{s_x}{|x|}$ Ratio entre l'écart type et la valeur absolue de la moyenne
- Si on veut avoir la valeur du CV en pourcentage, on multiplie par 100
- $c_v = \frac{100 * s_x}{|x|} (\%)$

$$x(biere) = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$n = 10$$

$$\bar{x} = 5.3 \text{ biere}$$

$$s_x(biere) = 3.13 \text{ biere}$$

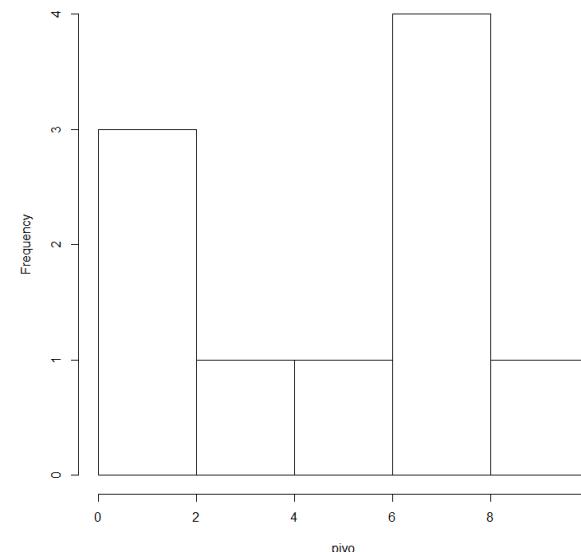
$$x(taille) = 164, 169, 168, 164, 167, \dots, 169$$

$$n = 153$$

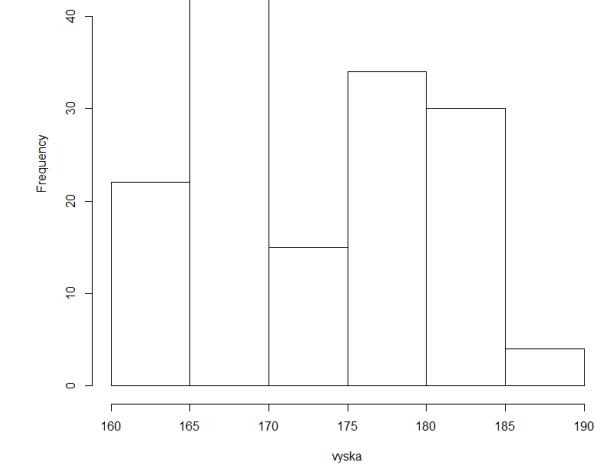
$$\bar{x} = 173.5 \text{ cm}$$

$$s_x(taille) = 51.5 \text{ cm}$$

Histogramme des bières



Histogramme des tailles des haches



Comparaison de la variabilité des bières et la taille des haches.

Le coefficient de variation

- Pour les variables continues
- Pourquoi ? – Pour comparer les données
 - qui ont les moyennes très différents
 - qui sont dans les unités différents
- Ex: Pour comparer la variance entre la taille des haches et des fibules
- Ex: Pour comparer la variance entre le poids des bracelets en verre et la quantité du bronze dans les épingle
- Comment ?
- $c_v = \frac{s_x}{|x|}$ Ratio entre l'écart type et la valeur absolue de la moyenne
- Si on veut avoir la valeur du CV en pourcentage, on multiplie par 100
- $c_v = \frac{100 * s_x}{|x|} (\%)$

$$x(\text{biere}) = 1, 1, 2, 4, 5, 7, 8, 8, 8, 9$$

$$n = 10$$

$$\bar{x} = 5.3 \text{ biere}$$

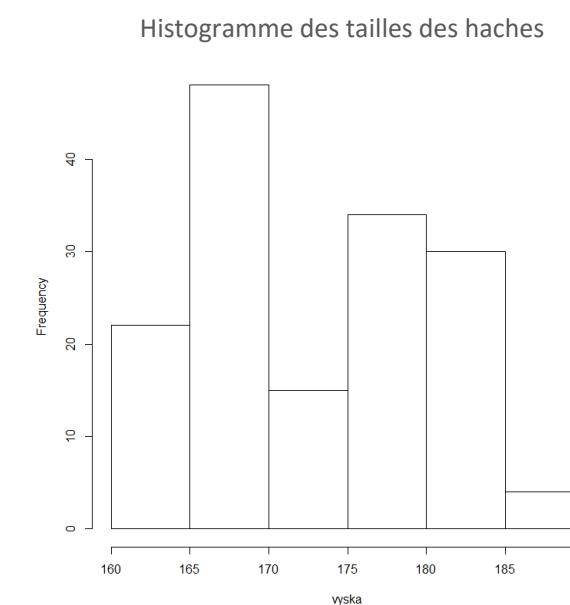
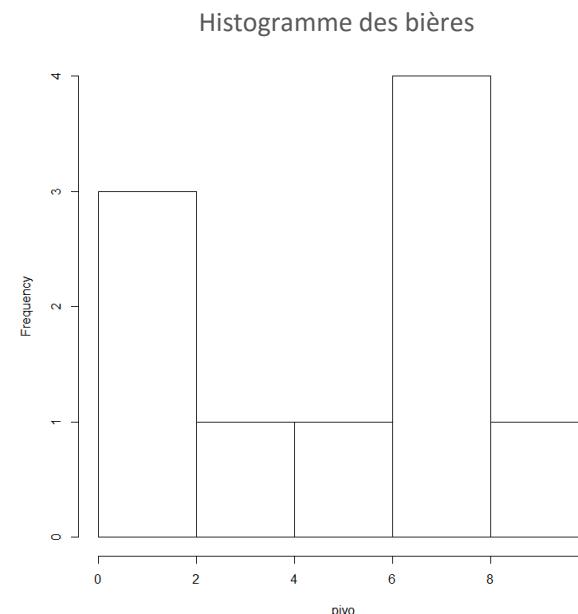
$$s_x(\text{biere}) = 3.13 \text{ biere}$$

$$x(\text{taille}) = 164, 169, 168, 164, 167, \dots, 169$$

$$n = 153$$

$$\bar{x} = 173.5 \text{ cm}$$

$$s_x(\text{taille}) = 51.5 \text{ cm}$$



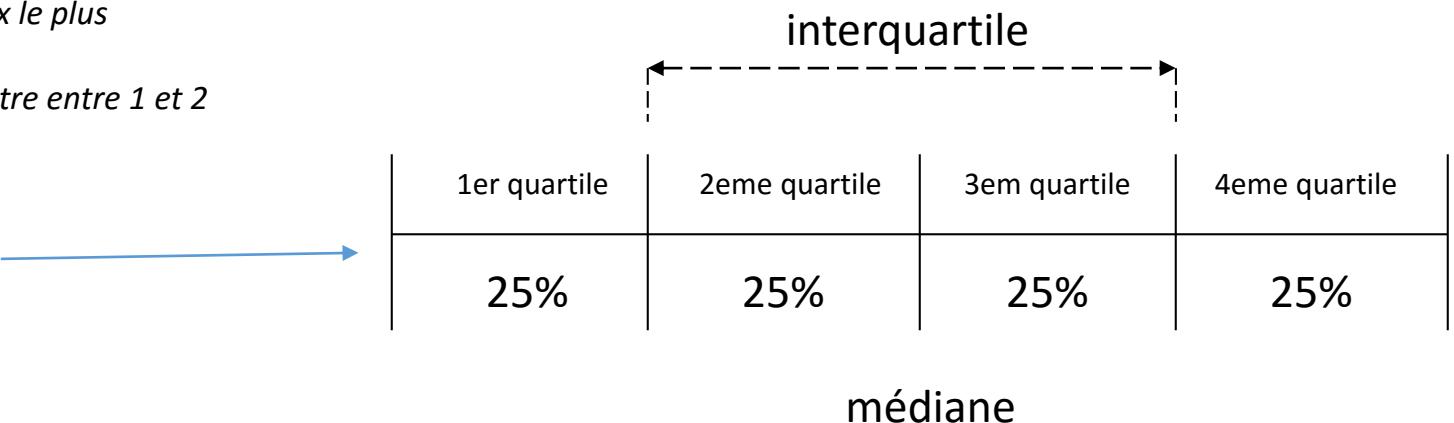
$$c_v(\text{biere}) = \frac{100 * 3.13}{5.3} = 59.1\%$$

$$c_v(\text{taille}) = \frac{100 * 51.5}{153} = 29.7\%$$

La variabilité des bières est plus élevé que celle de la taille des haches.

Quantiles

- Valeurs, qui séparent les données sur quelques parties qui sont plus ou moins égales
- Pour variables quantitatives continus et discrètes
- Pourquoi ?
 - On peut voir où les données se concentrent
 - Pour trouver intervalle comprenant 50 % des observations les plus au centre de la distribution
- Ex: On peut trouver que 50% des volumes des tonneaux le plus caractéristiques se trouvent entre 1.3 et 1.7 L.
- Ex: La plupart des fibules ont les spirales avec le diamètre entre 1 et 2 cm.
- D'après le nombre des parties, on peut distinguer :
 - Quartiles : Séparent la distribution sur 4 parties égales
 - Quintiles : 5
 - Déciles : 10
 - Centiles : 100
 - Médiane : 2



Quantiles pour les variables continues

- **Comment?**
- Ordonner les valeurs de plus petit au plus grand
- Appliquer : $\frac{n \cdot p}{100} \leq z \leq \left(\frac{n \cdot p}{100} + 1 \right)$
 - où le nombre z donne l'indice du quantile avec p – pourcents



Quantiles pour les variables continu

- **Comment?**
- Ordonner les valeurs de plus petit au plus grand
- Appliquer : $\frac{n \cdot p}{100} \leq z \leq \left(\frac{n \cdot p}{100} + 1\right)$
 - où le nombre z donne l'indice du quantile avec p – pourcents

Trouvez les quartiles pour la taille des haches.

$$x = 164, 169, 168, 164, 167, \dots, 169$$

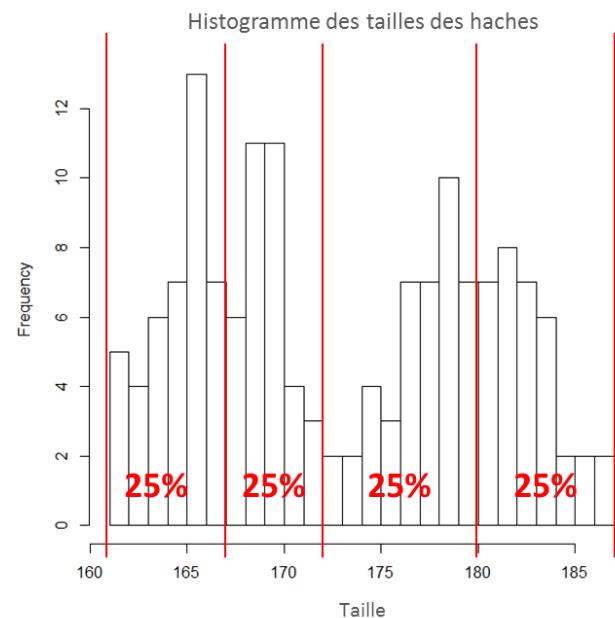
$$n = 153$$

<C:\Users\josef\Desktop\L3 - BDD - 2016\Haches.xlsx>



Quantiles pour les variables continues

- Comment?
- Ordonner les valeurs de plus petit au plus grand
- Appliquer : $\frac{n \cdot p}{100} \leq z \leq \left(\frac{n \cdot p}{100} + 1\right)$
 - où le nombre z donne l'indice du quantile avec p – pourcents



Trouvez les quartiles pour la taille des haches.

$$x = 164, 169, 168, 164, 167, \dots, 169$$

$$n = 153$$

<C:\Users\josef\Desktop\L3 - BDD - 2016\Haches.xlsx>

$$x(\text{ord}) = 159, 160, 160, 161, \dots, 186$$

$$\frac{n \cdot p}{100} \leq z \leq \left(\frac{n \cdot p}{100} + 1\right)$$

$$p = 25\%$$

$$\frac{153 \cdot 25}{100} \leq z \leq \frac{153 \cdot 25}{100} + 1$$

$$38.25 \leq z \leq 39.25$$

$$z = 39$$

$$x[39] = 167$$

$$p = 50\%$$

$$\frac{153 \cdot 50}{100} \leq z \leq \frac{153 \cdot 50}{100} + 1$$

$$76.5 \leq z \leq 77.5$$

$$z = 77$$

$$x[77] = 170$$

$$p = 75\%$$

$$\frac{153 \cdot 75}{100} \leq z \leq \frac{153 \cdot 75}{100} + 1$$

$$114.75 \leq z \leq 115.75$$

$$z = 115$$

$$x[75] = 179$$