

# Statistiques, cours, première S

F.Gaudon

19 novembre 2009

## Table des matières

<b>1</b>	<b>Quantiles d'une série statistique</b>	<b>2</b>
<b>2</b>	<b>Caractéristiques de dispersion</b>	<b>3</b>
<b>3</b>	<b>Transformation affine de valeurs</b>	<b>4</b>

# 1 Quantiles d'une série statistique

**Définition :**

- Le *premier quartile* noté  $Q_1$  de la série statistique est la plus petite valeur telle qu'au moins 25% des valeurs lui soient inférieures ou égales ;
- Le *troisième quartile* noté  $Q_3$  de la série est la plus petite valeur telle qu'au moins 75% des valeurs lui soient inférieures ou égales.

**Détermination pratique :**

On suppose la série ordonnée dans l'ordre croissant des valeurs du caractère. Soit  $N$  l'effectif total.

- Si  $\frac{N}{4}$  est un entier alors  $Q_1$  est la valeur de rang  $\frac{N}{4}$  et  $Q_3$  est la valeur de rang  $\frac{3N}{4}$  ;
- si  $\frac{N}{4}$  n'est pas entier, alors  $Q_1$  est la valeur dont le rang suit  $\frac{N}{4}$  et  $Q_3$  la valeur dont le rang suit  $\frac{3N}{4}$ .

**Remarque :**

Il existe d'autres définitions des quartiles. En particulier, on peut définir le premier quartile comme la médiane de la sous série formée des valeurs inférieures ou égales à la médiane et le troisième quartile comme la médiane de la sous série formée des valeurs supérieures ou égales à la médiane.

**Définition :**

Le  $n^{\text{e}}$  *décile* est la plus petite valeur telle que  $n \times 10 \%$  des effectifs au moins lui soient inférieurs ou égales.

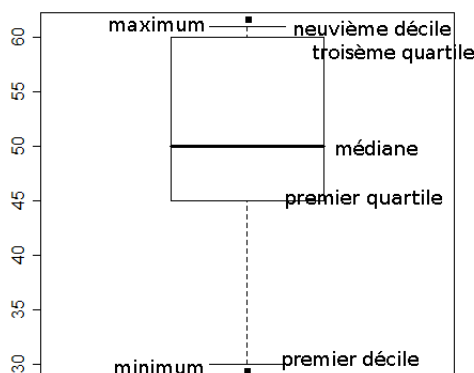
**Définition :**

Un *diagramme* en boîte représente les caractéristiques statistiques suivantes :

- minimum et maximum ;
- médiane ;
- le premier et le troisième quartile ;
- le premier et le neuvième décile.

**Remarque :**

On fait parfois figurer le minimum et le maximum de la série au lieu des premier et neuvième déciles.



## 2 Caractéristiques de dispersion

On considère une série statistique  $(n_i; x_i)_{i=1}^p$  d'effectif total  $N = \sum_{i=1}^p n_i$ .

**Définition :**

La *variance* de la série est le nombre noté  $V$  défini par :

$$V = \frac{n_1(x_1 - \bar{x})^2 + n_2(x_2 - \bar{x})^2 + \dots + n_p(x_p - \bar{x})^2}{N}$$

**Propriété :**

$$V = \frac{n_1x_1^2 + n_2x_2^2 + \dots + n_px_p^2}{N} - \bar{x}^2$$

**Preuve :**

$$\begin{aligned} V &= \frac{n_1(x_1 - \bar{x})^2 + \dots + n_p(x_p - \bar{x})^2}{N} \\ V &= \frac{1}{N}(n_1(x_1^2 - 2 \times x_1 \times \bar{x} + \bar{x}^2) + \dots + n_p(x_p^2 - 2 \times x_p \times \bar{x} + \bar{x}^2)) \\ V &= \frac{1}{N}(n_1x_1^2 + \dots + n_px_p^2 - 2 \times \bar{x}(x_1 + \dots + x_p) + \bar{x}^2 + \dots + \bar{x}^2) \\ V &= \frac{n_1x_1^2 + \dots + n_px_p^2}{N} - 2 \times \bar{x}^2 \times \frac{x_1 + \dots + x_p}{N} + \frac{\bar{x}^2 + \dots + \bar{x}^2}{N} \\ V &= \frac{n_1x_1^2 + \dots + n_px_p^2}{N} - 2 \times \bar{x}^2 + \frac{N \times \bar{x}^2}{N} \\ V &= \frac{n_1x_1^2 + \dots + n_px_p^2}{N} - 2 \times \bar{x}^2 + \bar{x}^2 \\ V &= \frac{n_1x_1^2 + n_2x_2^2 + \dots + n_px_p^2}{N} - \bar{x}^2 \end{aligned}$$

**Propriété :**

Pour tout réel  $x$ , on a :

$$\sum_{i=1}^p n_i(x_i - x)^2 \geq \sum_{i=1}^p n_i(x_i - \bar{x})^2$$

La variance minimise donc la distance des valeurs du caractère à la moyenne, c'est donc un indicateur approprié pour mesurer la dispersion des valeurs autour de la moyenne.

**Preuve :**

Soit  $f$  définie par  $f(x) = \sum_{i=1}^p n_i(x_i - x)^2$  pour tout réel  $x$ .  $f$  est dérivable sur  $\mathbb{R}$ .

On a  $f'(x) = -\sum_{i=1}^p 2n_i(x_i - x) = -2\sum_{i=1}^p n_ix_i + 2x\sum_{i=1}^p n_i = -2\sum_{i=1}^p n_ix_i + 2Nx$ .

Donc  $f'(x) \leq 0 \Leftrightarrow -\sum_{i=1}^p n_ix_i + aN \leq 0 \Leftrightarrow x \leq \frac{1}{N} \sum_{i=1}^p n_ix_i \Leftrightarrow x \leq \bar{x}$ . Donc  $f$  est décroissante sur  $] -\infty; \bar{x}]$  et croissante sur  $[\bar{x}; +\infty[$  donc minimale pour  $x = \bar{x}$ .

**Définition :**

*L'écart-type* de la série statistique est le nombre noté  $\sigma$  défini par :

$$\sigma = \sqrt{V}$$

**Définition :**

On appelle *intervalle inter quartile* l'intervalle  $[Q_1; Q_2]$  et *écart inter quartile* le nombre  $Q_3 - Q_1$ .

### 3 Transformation affine de valeurs

**Propriété :**

Soient  $a$  et  $b$  deux réels et  $x_i$  pour  $i$  allant de 1 à  $p$  les valeurs non nécessairement distinctes d'une série statistique.

On note  $\bar{x}$  sa moyenne,  $s$  son écart type,  $V$  sa variance,  $M_e$ ,  $Q_1$  et  $Q_3$  sa médiane et ses quartiles.

On définit alors une nouvelle série en posant  $X_i = ax_i + b$ .

La moyenne de la nouvelle série est alors  $a\bar{x} + b$ , sa variance  $a^2V$ , son écart type  $|a|s$  et, si  $a > 0$ , son premier quartile est  $aQ_1 + b$ , sa médiane  $aM_e + b$ , son troisième quartile  $aQ_3 + b$  et son écart inter quartile est  $a(Q_3 - Q_1)$ .

**Preuve :**

$$\begin{aligned} \bar{X} &= \frac{(ax_1 + b) + (ax_2 + b) + \dots + (ax_p + b)}{N} \\ &= \frac{a(x_1 + x_2 + \dots + x_p) + Nb}{N} \\ &= a \frac{x_1 + x_2 + \dots + x_p}{N} + \frac{Nb}{N} \\ &= a\bar{x} + b \end{aligned}$$

D'autre part,

$$\begin{aligned} \frac{\sum_{i=1}^p (X_i - \bar{X})^2}{N} &= \frac{\sum_{i=1}^p (ax_i + b - a\bar{x} + b)^2}{N} \\ &= \frac{\sum_{i=1}^p (a(x_i - \bar{x}))^2}{N} \\ &= a^2 \frac{\sum_{i=1}^p (x_i - \bar{x})^2}{N} \\ &= a^2V \end{aligned}$$

D'où l'écart type de la série des  $X_i$  est donnée par  $\sqrt{a^2V} = |a| \sqrt{V} = |a| s$ .

Les propriétés de la médiane et des quartiles découlent directement de la définition et de la conservation de l'ordre puisque  $a > 0$ .