

# Nature des variables et description mono-variable

## I. Nature et description des variables


- **Quantitative** : Modalités comparables entre elles
  - **Discrète / continue** : modalités dénombrable / indénombrables
- **Qualitative**
  - **Binaire / Multimodale** : deux modalités / plus de 2.
  - **Ordinale (ou non)** : existence d'un ordre
- **Population** : Ensemble d'évènements possibles
- **Echantillon** : Sous-ensemble de la population
- **Domaine** : Ensemble des valeurs que peut prendre la variable

Définition		Formule		Qualitative binaire	Qualitative multimodale	Qualitative ordinale	Quantitative discrète	Quantitative continue
• <b>Modalités</b> : Ensemble des valeurs distinctes que peut prendre la variable		$m_i$		X	X	X	X	X
• <b>Effectif <math>n_i</math></b> : Nombre d'apparitions d'une modalité		$n_i$		X	X	X	X	X
• <b>Effectif cumulé <math>N_i</math></b>		$N_i = \sum_{j, m_j \leq m_i} n_j$					X	X
• <b>Fréquence <math>\hat{f}_i</math></b>		$\hat{f}_i = \frac{n_i}{n}$		X	X	X	X	X
• <b>Probabilité</b>		$\mathbb{P}(x = m_i) = \lim_{n \rightarrow +\infty} \hat{f}_i$		X	X	X	X	X
• <b>Fréquence cumulée <math>\hat{F}_i</math></b>		$\hat{F}_i = \sum_{j, m_j \leq m_i} \hat{f}_j$					X	X
• <b>Fonction de répartition empirique <math>\hat{F}_X</math> (cas discret)</b>		$\hat{F}_X(x_i) = \hat{\mathbb{P}}(X \leq m_i) = \hat{F}_i$					X	
• <b>Fonction de répartition empirique <math>\hat{F}_X</math> (cas continu)</b>		$\hat{F}_X(x) = \hat{F}_i^c + (\hat{F}_i - \hat{F}_{i-1}^c) \frac{x - x_{i-1}}{x_i - x_{i-1}}$ $\hat{F}_i^c = \hat{F}_i - \frac{1}{2}(\hat{F}_i - \hat{F}_{i-1})$						X
• <b>Fonction de répartition <math>F_X</math></b>		$F_X(m_i) = \mathbb{P}(X \leq m_i) = \lim_{n \rightarrow +\infty} \hat{F}_i$					X	X
• <b>Moyenne <math>\bar{x}</math></b>	$\min_{\bar{x} \in \mathbb{R}} \sum_{i=1}^n (x_i - \bar{x})^2$	<i>Moyenne empirique :</i> $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \sum_{i=1}^n \hat{f}_i x_i$		<i>Espérance :</i> $\mathbb{E}(X) = \lim_{n \rightarrow \infty} \bar{x}$			X	X
• <b>Médiane <math>M</math></b>	$\min_{M \in \mathbb{R}} \sum_{i=1}^n  x_i - M $	$\hat{F}_X(M) = \frac{1}{2}$		$\mathbb{P}(X \leq M) = \frac{1}{2}$		X		X
• <b>Mode</b>		$\operatorname{argmax}_{i \in [1, n]} f_i$		$\operatorname{argmax}_{x \in \Omega} \mathbb{P}(x)$		X		X
• <b>Variance <math>S</math></b>	$\hat{S}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2$	$\hat{S} = \sqrt{\hat{S}^2}$ Ecart type	$S^2 = \mathbb{E}(X - \mathbb{E}^2(X))$			X	X	X
• <b>Usage de la variance</b>	$\mathbb{P}( X - \bar{x}  \geq k\sigma) \geq \sigma$	<i>Pire des cas : Tchebychev</i> $\mathbb{P}( X - \bar{x}  \geq \varepsilon) \leq \frac{\sigma^2}{\varepsilon^2} \quad k = \frac{1}{\sqrt{\alpha}}$		<i>Cas Gaussien :</i> $\mathbb{P}( X - \bar{x}  \geq u_{\alpha/2}\sigma) \leq \alpha$		X	X	X
• <b>Fractile et quartile</b>	$\hat{F}_X(\hat{\phi}_p) = p$	$\hat{Q}_1 = \hat{\phi}_{\frac{1}{4}}$	$\hat{Q}_3 = \hat{\phi}_{\frac{3}{4}}$	$DIQ = \hat{Q}_3 - \hat{Q}_1$	$MAD = \operatorname{mediane}( x_i - \hat{M} )$		X	X
• <b>Moment et moment centré</b>	$\hat{m}_k = \frac{1}{n} \sum_{i=1}^n x_i^k$	$\hat{m}\hat{c}_k = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^k$	$\bar{x} = \hat{m}_1$ Moyenne	$\hat{S}^2 = \hat{m}\hat{c}_2$ Variance	$\frac{\hat{m}\hat{c}_3}{\hat{S}^3}$ Dissymétrie	$\frac{\hat{m}\hat{c}_4}{\hat{S}^4}$ Aplatissement	X	X


X : peut être utilisé / x : peut être utilisé mais pas toujours très approprié

## II. Représentation des variables

### 1. Camemberts (variables qualitatives)




### 2. Boîtes à moustache (variables quantitatives)



### 3. Histogramme

#### Discrétisation d'une variable continue



On doit choisir  $p$  bornes  $b_i$ . On associe ensuite une hauteur à chaque intervalle  $[b_i; b_{i+1}[$ .

**Choix du nombre  $p$  d'intervalles pour  $n$  observations :**

$$p \geq 1 + \log n$$

règle de Sturges

$$p = \frac{3,5\hat{\sigma}}{\sqrt[3]{n}}$$

règle de Scott

$$p = \frac{2 DIQ}{\sqrt[3]{n}}$$

règle de Freedman Diaconis

**Choix des  $b_i$  :** équirépartition des individus ou des intervalles.