

# Probabilités et Statistiques 2

M. BOUTAHAR

# 1. Loi de probabilité discrète

## 1. Variables aléatoires

### Définitions

Soit  $\Omega$  un espace (ou ensemble), soit  $\mathcal{F}$  une famille de sous-ensembles de  $\Omega$ .

#### Definition

On dit que  $\mathcal{F}$  est une **algèbre** sur  $\Omega$  si les conditions suivantes sont satisfaites:

- i.  $\emptyset$  et  $\Omega$  sont dans  $\mathcal{F}$ ,
- ii. si  $A$  est dans  $\mathcal{F}$ , alors  $A^c$  est dans  $\mathcal{F}$ , où  $A^c$  est le complémentaire de  $A$  dans  $\Omega$ .
- iii. si  $A$  et  $B$  sont dans  $\mathcal{F}$ , alors  $A \cup B$  est dans  $\mathcal{F}$ .

# 1. Loi de probabilité discrète

Exemple.

$$\Omega = \{1, 2, 3\},$$

$\mathcal{F} = \mathcal{P}(\Omega) = \{\emptyset, \{1\}, \{2\}, \{3\}, \{1, 2\}, \{1, 3\}, \{2, 3\}, \{1, 2, 3\}\}$   
est une algèbre.

## Definition

On dit que  $\mathcal{F}$  est une **tribu** (ou  $\sigma$ -**algèbre**) sur  $\Omega$  si les conditions de la définition précédente sont satisfaites avec iii) remplacée par:

iii'. si  $(A_n, n \geq 1)$  est dans  $\mathcal{F}$ , alors  $\bigcup_{n=1}^{\infty} A_n$  est dans  $\mathcal{F}$ .

# 1. Loi de probabilité discrète

Exemple.

$$\Omega = \{1, 2, 3\},$$

$\mathcal{F} = \mathcal{P}(\Omega) = \{\emptyset, \{1\}, \{2\}, \{3\}, \{1, 2\}, \{1, 3\}, \{2, 3\}, \{1, 2, 3\}\}$   
est une algèbre.

## Definition

On dit que  $\mathcal{F}$  est une **tribu** (ou  **$\sigma$ -algèbre**) sur  $\Omega$  si les conditions de la définition précédente sont satisfaites avec iii) remplacée par:

iii'. si  $(A_n, n \geq 1)$  est dans  $\mathcal{F}$ , alors  $\bigcup_{n=1}^{\infty} A_n$  est dans  $\mathcal{F}$ .

# 1. Loi de probabilité discrète

## Espace de probabilité

### Definition

On appelle **loi de probabilité** sur  $(\Omega, \mathcal{F})$ , toute application  $P : \Omega \rightarrow [0, 1]$ , qui vérifie:

- i.  $P(\Omega) = 1$ ,
- ii.  $\forall (A_n, n \geq 1) \subset \mathcal{F}$  telle que  $A_k \cap A_l = \emptyset$  si  $k \neq l$ ,

$$P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n).$$

# 1. Loi de probabilité discrète

## Espace de probabilité

### Definition

On appelle **loi de probabilité** sur  $(\Omega, \mathcal{F})$ , toute application  $P : \Omega \rightarrow [0, 1]$ , qui vérifie:

- i.  $P(\Omega) = 1$ ,
- ii.  $\forall (A_n, n \geq 1) \subset \mathcal{F}$  telle que  $A_k \cap A_l = \emptyset$  si  $k \neq l$ ,

$$P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n).$$

# 1. Loi de probabilité discrète

## Espace de probabilité

### Definition

On appelle **loi de probabilité** sur  $(\Omega, \mathcal{F})$ , toute application  $P : \Omega \rightarrow [0, 1]$ , qui vérifie:

- i.  $P(\Omega) = 1$ ,
- ii.  $\forall (A_n, n \geq 1) \subset \mathcal{F}$  telle que  $A_k \cap A_l = \emptyset$  si  $k \neq l$ ,

$$P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n).$$

# 1. Loi de probabilité discrète

## Definition

$(\Omega, \mathcal{F}, P)$  est appelé **espace de probabilité** si:

- $\Omega$  est un espace,
- $\mathcal{F}$  est une tribu,
- $P$  est une **loi de probabilité**

## Variable aléatoire

### Definition

Une **variable aléatoire** réelle  $X$  est une application de  $(\Omega, \mathcal{F}) \rightarrow (\mathbb{R}, \mathcal{B})$  **mesurable** : c'est à dire pour tout ouvert  $C \subset \mathbb{R}$ , on a  $X^{-1}(C) = \{\omega, X(\omega) \in C\} \in \mathcal{F}$ . ( $\mathcal{B}$  est la tribu borélienne contenant les ouverts de  $\mathbb{R}$ ).

# 1. Loi de probabilité discrète

## Definition

$(\Omega, \mathcal{F}, P)$  est appelé **espace de probabilité** si:

- $\Omega$  est un espace,
- $\mathcal{F}$  est une tribu,
- $P$  est une **loi de probabilité**

## Variable aléatoire

### Definition

Une **variable aléatoire** réelle  $X$  est une application de  $(\Omega, \mathcal{F}) \rightarrow (\mathbb{R}, \mathcal{B})$  **mesurable** : c'est à dire pour tout ouvert  $C \subset \mathbb{R}$ , on a  $X^{-1}(C) = \{\omega, X(\omega) \in C\} \in \mathcal{F}$ . ( $\mathcal{B}$  est la tribu borélienne contenant les ouverts de  $\mathbb{R}$ ).

# 1. Loi de probabilité discrète

## Definition

$(\Omega, \mathcal{F}, P)$  est appelé **espace de probabilité** si:

- $\Omega$  est un espace,
- $\mathcal{F}$  est une tribu,
- $P$  est une **loi de probabilité**

## Variable aléatoire

### Definition

Une **variable aléatoire** réelle  $X$  est une application de  $(\Omega, \mathcal{F}) \rightarrow (\mathbb{R}, \mathcal{B})$  **mesurable** : c'est à dire pour tout ouvert  $C \subset \mathbb{R}$ , on a  $X^{-1}(C) = \{\omega, X(\omega) \in C\} \in \mathcal{F}$ . ( $\mathcal{B}$  est la tribu borélienne contenant les ouverts de  $\mathbb{R}$ ).

# 1. Loi de probabilité discrète

## Definition

$(\Omega, \mathcal{F}, P)$  est appelé **espace de probabilité** si:

- $\Omega$  est un espace,
- $\mathcal{F}$  est une tribu,
- $P$  est une **loi de probabilité**

## Variable aléatoire

### Definition

Une **variable aléatoire** réelle  $X$  est une application de  $(\Omega, \mathcal{F}) \rightarrow (\mathbb{R}, \mathcal{B})$  **mesurable** : c'est à dire pour tout ouvert  $C \subset \mathbb{R}$ , on a  $X^{-1}(C) = \{\omega, X(\omega) \in C\} \in \mathcal{F}$ . ( $\mathcal{B}$  est la tribu borélienne contenant les ouverts de  $\mathbb{R}$ ).

# 1. Loi de probabilité discrète

## Definition

$(\Omega, \mathcal{F}, P)$  est appelé **espace de probabilité** si:

- $\Omega$  est un espace,
- $\mathcal{F}$  est une tribu,
- $P$  est une **loi de probabilité**

## Variable aléatoire

### Definition

Une **variable aléatoire** réelle  $X$  est une application de  $(\Omega, \mathcal{F}) \rightarrow (\mathbb{R}, \mathcal{B})$  **mesurable** : c'est à dire pour tout ouvert  $C \subset \mathbb{R}$ , on a  $X^{-1}(C) = \{\omega, X(\omega) \in C\} \in \mathcal{F}$ . ( $\mathcal{B}$  est la tribu borélienne contenant les ouverts de  $\mathbb{R}$ ).

# 1. Loi de probabilité discrète

## Definition

Soit  $X$  une variable aléatoire à valeurs dans  $E \subset \mathbb{R}$ , si  $E$  est dénombrable, alors on dit que  $X$  est une variable aléatoire **discrète**.

Soit  $X$  une variable discrète à valeur dans  $E = \{x_1, x_2, \dots\}$ .

Posons  $p_k = P(\omega, X(\omega) = x_k) = P(X = x_k)$ . On a

$$\begin{aligned} P(\Omega) &= \sum_{k=1}^{\infty} P(\omega, X(\omega) = x_k) \\ &= \sum_{k=1}^{\infty} P(X = x_k) \\ &= \sum_{k=1}^{\infty} p_k = 1 \end{aligned}$$

# 1. Loi de probabilité discrète

## 2. Espérance mathématique

Soit  $g$  une application de  $E = \{x_1, x_2, \dots\}$ . dans  $\mathbb{R}$ .

### Definition

On définit l'espérance mathématique de  $g(X)$  par:

$$E(g(X)) = \sum_{k=1}^{\infty} g(x_k) p_k$$

En particulier:

-Pour  $g(x) = x$ , on définit l'espérance mathématique de  $X$  par:

# 1. Loi de probabilité discrète

## 2. Espérance mathématique

Soit  $g$  une application de  $E = \{x_1, x_2, \dots\}$ . dans  $\mathbb{R}$ .

### Definition

On définit l'espérance mathématique de  $g(X)$  par:

$$E(g(X)) = \sum_{k=1}^{\infty} g(x_k) p_k$$

En particulier:

-Pour  $g(x) = x$ , on définit l'espérance mathématique de  $X$  par:

# 1. Loi de probabilité discrète

$$\begin{aligned} E(X) &= \sum_{k=1}^{\infty} x_k P(X = x_k) \\ &= \sum_{k=1}^{\infty} x_k p_k \end{aligned}$$

-Pour  $g(x) = x^2$ , on définit l'espérance mathématique de  $X^2$  par:

$$E(X^2) = \sum_{k=1}^{\infty} x_k^2 p_k.$$

# 1. Loi de probabilité discrète

$$\begin{aligned} E(X) &= \sum_{k=1}^{\infty} x_k P(X = x_k) \\ &= \sum_{k=1}^{\infty} x_k p_k \end{aligned}$$

-Pour  $g(x) = x^2$ , on définit l'espérance mathématique de  $X^2$  par:

$$E(X^2) = \sum_{k=1}^{\infty} x_k^2 p_k.$$

# 1. Loi de probabilité discrète

On définit alors:

-La variance de  $X$  par

$$\begin{aligned} \text{var}(X) &= E(X^2) - (E(X))^2 \\ &= \sum_{k=1}^{\infty} x_k^2 p_k - \left( \sum_{k=1}^{\infty} x_k p_k \right)^2. \end{aligned}$$

-L'écart-type de  $X$  par

$$\sigma(X) = \sqrt{\text{var}(X)}.$$

# 1. Loi de probabilité discrète

Si  $E$  est fini  $E = \{x_1, x_2, \dots, x_r\}$ . Alors

$$E(g(X)) = \sum_{k=1}^r g(x_k) p_k$$

$$E(X) = \sum_{k=1}^r x_k p_k$$

$$\text{var}(X) = \sum_{k=1}^r x_k^2 p_k - \left( \sum_{k=1}^r x_k p_k \right)^2.$$

# 1. Loi de probabilité discrète

## Propriétés de l'espérance et la variance

Soit  $X$  et  $Y$  deux variables aléatoires discrètes à valeurs dans  $E$ .

Posons  $p_k = P(X = x_k)$ ,  $q_k = P(Y = y_k)$ .

Soient  $a, b$  et  $c$  des constantes réelles.

Soit

$$\text{cov}(X, Y) = E(XY) - E(X)E(Y)$$

la covariance entre  $X$  et  $Y$ .

# 1. Loi de probabilité discrète

## Theorem

$$E(c) = c, \quad (1)$$

$$E(aX + bY) = aE(X) + bE(Y), \quad (\text{linéarité}) \quad (2)$$

$$\text{var}(aX) = a^2 \text{var}(X), \quad (3)$$

$$\text{var}(aX + bY) = a^2 \text{var}(X) + 2abcov(X, Y) + b^2 \text{var}(Y). \quad (4)$$

# 1. Loi de probabilité discrète

## 3. Inégalités classiques

### 3.1. Inégalité de Markov

#### Theorem

*Soit  $X$  une variable aléatoire à valeurs dans un espace dénombrable  $E$  avec  $E \subset \mathbb{R}$ , alors pour tout  $a > 0$ ,*

$$P(|f(X)| \geq a) \leq \frac{E(|f(X)|)}{a}. \quad (5)$$

# 1. Loi de probabilité discrète

**Preuve:** On a

$$\begin{aligned} E(|f(X)|) &= \sum_{x_k \in E} |f(x_k)| p_k \\ &= \sum_{x_k \in A} |f(x_k)| p_k + \sum_{x_k \in A^c} |f(x_k)| p_k, \end{aligned}$$

où  $A = \{x_k \in E, |f(x_k)| \geq a\}$ , et  $A^c$  est le complémentaire de  $A$  dans  $E$ . Donc

$$\begin{aligned} E(|f(X)|) &\geq \sum_{x_k \in A} |f(x_k)| p_k \\ &\geq \sum_{x_k \in A} a p_k, \end{aligned}$$

de plus  $\sum_{x_k \in A} p_k = P(X \in A) = P(|f(X)| \geq a)$ .  $\square$

# 1. Loi de probabilité discrète

## 3.2. Inégalité de Bienaymé-Tchebyshev

### Theorem

Soit  $X$  une variable aléatoire à valeurs dans  $E$ , alors pour tout  $\varepsilon > 0$

$$P(|X - E(X)| \geq \varepsilon) \leq \frac{\sigma_X^2}{\varepsilon^2}. \quad (6)$$

**Preuve** : On applique l'inégalité de Markov (5) avec  $f(t) = |t - E(X)|^2$ ,  $a = \varepsilon^2$ .  $\square$

# 1. Loi de probabilité discrète

## 4. Indépendance

### 4.1. Variables indépendantes

#### Definition

Soit  $X$  et  $Y$  deux variables aléatoires. On dit que  $X$  et  $Y$  sont indépendantes si

$$P(\{X \in A\} \cap \{Y \in B\}) = P(X \in A)P(Y \in B). \quad (7)$$

### 4.2 Distributions marginales

Soit  $E_1 \times E_2$  et le couple aléatoire  $X = (X_1, X_2)'$ , où chaque  $X_i$  est à valeurs dans  $E_i$ . La **distribution marginale** de la variable  $X_i$  est définie par  $P_i(A) = P(X_i \in A), \forall A \in \mathcal{F}$ .

# 1. Loi de probabilité discrète

## 4. Indépendance

### 4.1. Variables indépendantes

#### Definition

Soit  $X$  et  $Y$  deux variables aléatoires. On dit que  $X$  et  $Y$  sont indépendantes si

$$P(\{X \in A\} \cap \{Y \in B\}) = P(X \in A)P(Y \in B). \quad (7)$$

### 4.2 Distributions marginales

Soit  $E_1 \times E_2$  et le couple aléatoire  $X = (X_1, X_2)'$ , où chaque  $X_i$  est à valeurs dans  $E_i$ . La **distribution marginale** de la variable  $X_i$  est définie par  $P_i(A) = P(X_i \in A), \forall A \in \mathcal{F}$ .

# 1. Loi de probabilité discrète

## Theorem

*Soit  $X$  et  $Y$  deux variables aléatoires discrètes à valeurs dans  $E_1$  et  $E_2$ , et indépendantes, soit  $f : E_1 \rightarrow \mathbb{R}$ , et  $g : E_2 \rightarrow \mathbb{R}$ , alors*

$$E(f(X)g(Y)) = E(f(X))E(g(Y)) \quad (8)$$

# 1. Loi de probabilité discrète

**Preuve** : Posons  $Z = (X, Y)$  et  $h(Z) = f(X)g(Y)$ , alors  $Z$  est à valeurs dans  $E = E_1 \times E_2$ , de plus d'après l'hypothèse d'indépendance  $P((X, Y) = (x, y)) = P(X = x)P(Y = y)$ .

Donc

$$\begin{aligned} E(h(Z)) &= \sum_{z_k \in E} h(z_k)P(Z = z_k) \\ &= \sum_{x_k, y_l} f(x_k)g(y_l)P(X = x_k)P(Y = y_l) \\ &= \sum_{x_k} f(x_k)P(X = x_k) \sum_{y_l} g(y_l)P(Y = y_l). \square \end{aligned}$$

# 1. Loi de probabilité discrète

## Theorem

Soit  $X_1$  et  $X_2$  deux variables aléatoires indépendantes, alors

$$\text{var}(X_1 + X_2) = \text{var}(X_1) + \text{var}(X_2). \quad (9)$$

Preuve :

$$\text{var}(X_1 + X_2) = \text{var}(X_1) + \text{var}(X_2) + 2 \text{cov}(X_1, X_2),$$

où  $\text{cov}(X_1, X_2) = E(X_1 X_2) - EX_1 EX_2$  est la covariance de  $X_1$  et  $X_2$ , mais d'après (8) on a  $E(X_1 X_2) = EX_1 EX_2$ .  $\square$

**Remarque:** Si deux variables aléatoires  $X$  et  $Y$  sont indépendantes alors elles sont non **covariées** ( $\text{cov}(X, Y) = 0$ ).

# 1. Loi de probabilité discrète

## Theorem

Soit  $X_1$  et  $X_2$  deux variables aléatoires indépendantes, alors

$$\text{var}(X_1 + X_2) = \text{var}(X_1) + \text{var}(X_2). \quad (9)$$

**Preuve :**

$$\text{var}(X_1 + X_2) = \text{var}(X_1) + \text{var}(X_2) + 2 \text{cov}(X_1, X_2),$$

où  $\text{cov}(X_1, X_2) = E(X_1 X_2) - EX_1 EX_2$  est la covariance de  $X_1$  et  $X_2$ , mais d'après (8) on a  $E(X_1 X_2) = EX_1 EX_2$ .  $\square$

**Remarque:** Si deux variables aléatoires  $X$  et  $Y$  sont indépendantes alors elles sont non **covariées** ( $\text{cov}(X, Y) = 0$ ).

# 1.Loi de probabilité discrète

## 5.Lois usuelles

### 5.1. Loi de Bernoulli

#### Definition

On dit que  $X$  suit une loi de Bernoulli de paramètre  $p$ , noté  $X \rightsquigarrow B(p)$ , si  $E = \{x_1, x_2\}$  avec  $P(X(\omega) = x_1) = p$ , et  $P(X(\omega) = x_2) = 1 - p$ .

Exemple : On lance une pièce de monnaie,  $X$  est le résultat obtenu,  $P(X = \text{pile}) = P(X = \text{face}) = 1/2$ .

# 1.Loi de probabilité discrète

## 5.Lois usuelles

### 5.1. Loi de Bernoulli

#### Definition

On dit que  $X$  suit une loi de Bernoulli de paramètre  $p$ , noté  $X \rightsquigarrow B(p)$ , si  $E = \{x_1, x_2\}$  avec  $P(X(\omega) = x_1) = p$ , et  $P(X(\omega) = x_2) = 1 - p$ .

Exemple : On lance une pièce de monnaie,  $X$  est le résultat obtenu,  $P(X = \text{pile}) = P(X = \text{face}) = 1/2$ .

# 1. Loi de probabilité discrète

## 5.2. Loi Binomiale

### Definition

Soit  $Y_i, 1 \leq i \leq n$ , une suite de variables aléatoires de Bernoulli indépendantes à valeurs dans  $\{0, 1\}$  avec  $P(Y_k(\omega) = 1) = p$ , alors la variable  $X = \sum_{k=1}^n Y_k$  suit une loi Binomiale, noté  $X \rightsquigarrow B(n, p)$ , dans ce cas

$$E = \{0, 1, \dots, n\}$$

et

$$P(X(\omega) = k) = C_n^k p^k (1-p)^{n-k}, 0 \leq k \leq n,$$

$$C_n^k = \frac{n!}{k!(n-k)!}.$$

# 1. Loi de probabilité discrète

## 5.3. Loi de Poisson

### Definition

On dit que  $X$  suit une loi de Poisson de paramètre  $\lambda$ , noté  $X \rightsquigarrow \mathcal{P}(\lambda)$ , si  $E = \mathbb{N}$  et  $P(X(\omega) = k) = e^{-\lambda} \frac{\lambda^k}{k!}$ ,  $\lambda$  est un réel positif.

Exemple:  $N(t)$  représente le nombre de clients qui arrivent dans une agence (ou le nombre de voitures qui arrivent sur un péage d'autoroute) pendant la période d'observation  $[0, t]$ , alors on montre que

$$P(N(t) = k) = e^{-\lambda t} \frac{(\lambda t)^k}{k!},$$

avec  $\lambda$  l'intensité d'arrivage.

# 1. Loi de probabilité discrète

## 5.3. Loi de Poisson

### Definition

On dit que  $X$  suit une loi de Poisson de paramètre  $\lambda$ , noté  $X \rightsquigarrow \mathcal{P}(\lambda)$ , si  $E = \mathbb{N}$  et  $P(X(\omega) = k) = e^{-\lambda} \frac{\lambda^k}{k!}$ ,  $\lambda$  est un réel positif.

Exemple:  $N(t)$  représente le nombre de clients qui arrivent dans une agence (ou le nombre de voitures qui arrivent sur un péage d'autoroute) pendant la période d'observation  $[0, t]$ , alors on montre que

$$P(N(t) = k) = e^{-\lambda t} \frac{(\lambda t)^k}{k!},$$

avec  $\lambda$  l'intensité d'arrivage.

## 2. Loi de probabilité continue

Soit  $X$  une variable à valeurs dans  $E \subset \mathbb{R}$ , si  $E$  est non dénombrable, alors on dit que  $X$  est une variable **continue**.

### 1. Densité de probabilité, moments

Soit  $X$  une variable aléatoire à valeurs dans  $\mathbb{R}$ , et soit  $f_X$  une fonction de  $\mathbb{R}$  dans  $\mathbb{R}^+$  intégrable et telle que

$$\int_{\mathbb{R}} f_X(x) dx = 1. \quad (10)$$

#### Definition

On dit que  $X$  admet la densité de probabilité  $f_X$  si pour tout  $A \subset \mathbb{R}$

$$P(X \in A) = \int_A f_X(x) dx.$$

## 2. Loi de probabilité continue

Soit  $X$  une variable à valeurs dans  $E \subset \mathbb{R}$ , si  $E$  est non dénombrable, alors on dit que  $X$  est une variable **continue**.

### 1. Densité de probabilité, moments

Soit  $X$  une variable aléatoire à valeurs dans  $\mathbb{R}$ , et soit  $f_X$  une fonction de  $\mathbb{R}$  dans  $\mathbb{R}^+$  intégrable et telle que

$$\int_{\mathbb{R}} f_X(x) dx = 1. \quad (10)$$

#### Definition

On dit que  $X$  admet la densité de probabilité  $f_X$  si pour tout  $A \subset \mathbb{R}$

$$P(X \in A) = \int_A f_X(x) dx.$$

## 2.Loi de probabilité continue

### Definition

Soit  $g : \mathbb{R} \rightarrow \mathbb{R}$ , telle que  $\int_{\mathbb{R}} |g(x)| f_X(x) dx < \infty$ , alors on définit l'espérance mathématique de  $g(X)$  par

$$E(g(X)) = \int_{\mathbb{R}} g(x) f_X(x) dx. \quad (11)$$

En particulier: -Pour  $g(x) = x$ , on définit l'espérance mathématique de  $X$  par

$$E(X) = \int_{\mathbb{R}} x f_X(x) dx.$$

## 2.Loi de probabilité continue

### Definition

Soit  $g : \mathbb{R} \rightarrow \mathbb{R}$ , telle que  $\int_{\mathbb{R}} |g(x)| f_X(x) dx < \infty$ , alors on définit l'espérance mathématique de  $g(X)$  par

$$E(g(X)) = \int_{\mathbb{R}} g(x) f_X(x) dx. \quad (11)$$

En particulier: -Pour  $g(x) = x$ , on définit l'espérance mathématique de  $X$  par

$$E(X) = \int_{\mathbb{R}} x f_X(x) dx.$$

## 2. Loi de probabilité continue

- Pour  $g(x) = x^2$ , on définit l'espérance mathématique de  $X^2$  par:

$$E(X^2) = \int_{\mathbb{R}} x^2 f_X(x) dx.$$

On définit alors la variance de  $X$  par

$$\begin{aligned} \text{var}(X) &= E(X^2) - (E(X))^2 \\ &= \int_{\mathbb{R}} x^2 f_X(x) dx - \left( \int_{\mathbb{R}} x f_X(x) dx \right)^2 \end{aligned}$$

et l'écart-type de  $X$  par

$$\sigma(X) = \sqrt{\text{var}(X)}.$$

## 2. Loi de probabilité continue

### Couple aléatoire

Soit  $X = (X_1, X_2)$  un couple aléatoire à valeurs dans  $\mathbb{R}^2$ , et soit  $f_X$  une fonction de  $\mathbb{R}^2$  dans  $\mathbb{R}^+$  intégrable et telle que

$$\int_{\mathbb{R}^2} f_X(x) dx = 1. \quad (12)$$

#### Definition

On dit que  $X$  admet la densité de probabilité  $f_X$  si pour tout  $A \subset \mathbb{R}^2$

$$P(X \in A) = \int_A f_X(x) dx.$$

## 2. Loi de probabilité continue

### Couple aléatoire

Soit  $X = (X_1, X_2)$  un couple aléatoire à valeurs dans  $\mathbb{R}^2$ , et soit  $f_X$  une fonction de  $\mathbb{R}^2$  dans  $\mathbb{R}^+$  intégrable et telle que

$$\int_{\mathbb{R}^2} f_X(x) dx = 1. \quad (12)$$

#### Definition

On dit que  $X$  admet la densité de probabilité  $f_X$  si pour tout  $A \subset \mathbb{R}^2$

$$P(X \in A) = \int_A f_X(x) dx.$$

## 2. Loi de probabilité continue

Soit  $g : \mathbb{R}^2 \rightarrow \mathbb{R}$ , telle que  $\int_{\mathbb{R}^2} |g(x)| f_X(x) dx < \infty$ , alors on définit l'espérance mathématique de  $g(X)$  par

$$E(g(X)) = \int_{\mathbb{R}^2} g(x) f_X(x) dx, \quad (13)$$

en particulier: • Si  $g(x_1, x_2) = g_i(x) = x_i, 1 \leq i \leq 2$ , alors on définit l'espérance mathématique du couple  $X$  par

$$E(X) = \begin{pmatrix} E(X_1) \\ E(X_2) \end{pmatrix} = \begin{pmatrix} \int_{\mathbb{R}^2} x_1 f_X(x) dx \\ \int_{\mathbb{R}^2} x_2 f_X(x) dx \end{pmatrix}.$$

• Si  $g(x_1, x_2) = x_1 x_2$ , on définit

$$E(X_1 X_2) = \int_{\mathbb{R}^2} x_1 x_2 f_X(x) dx.$$

# 2. Loi de probabilité continue

## 2. Indépendance

### 2.1. Distributions marginales

#### Definition

Soit  $X$  et  $Y$  deux variables aléatoires à valeurs dans  $\mathbb{R}$  tels que  $(X, Y)$  admette la densité  $f_{X,Y}(x, y)$ . Alors on définit les **densités marginales** de  $X$  et de  $Y$  par

$$f_X(x) = \int_{\mathbb{R}} f_{X,Y}(x, y) dy$$

et

$$f_Y(y) = \int_{\mathbb{R}} f_{X,Y}(x, y) dx.$$

## 2. Loi de probabilité continue

### 2.2. Variables indépendantes

#### Definition

Soit  $X$  et  $Y$  deux variables aléatoires à valeurs dans  $\mathbb{R}$ . On dit que  $X$  et  $Y$  sont indépendantes si

$$P(X \in A, Y \in B) = P(X \in A)P(Y \in B). \quad (14)$$

## 2. Loi de probabilité continue

En utilisant les mêmes arguments que le théorème 12 on obtient le théorème

### Theorem

*Soit  $X$  et  $Y$  deux variables aléatoires à valeurs dans  $\mathbb{R}$  indépendantes, soit  $f : \mathbb{R} \rightarrow \mathbb{R}$ , et  $g : \mathbb{R} \rightarrow \mathbb{R}$  EndExpansion, alors*

$$E(f(X)g(Y)) = E(f(X))E(g(Y)) \quad (15)$$

## 2. Loi de probabilité continue

### Theorem

*(admi) Soit  $X = (X_1, X_2)$  de densité  $f_X(x)$ , et tel que les  $X_i, 1 \leq i \leq 2$ , soient des variables aléatoires indépendantes. On a alors*

$$f_X(x_1, x_2) = f_{X_1}(x_1)f_{X_2}(x_2), \quad (16)$$

*où  $f_{X_i}$  est la densité marginale de la variable  $X_i$ .*

*Réciproquement, si  $f_X$  a la forme (16) où les  $f_{X_i}, 1 \leq i \leq 2$  sont des densités de probabilité, alors les  $X_i, 1 \leq i \leq 2$ , sont indépendantes et les  $f_{X_i}$  sont les densités des  $X_i$ .*

## 2. Loi de probabilité continue

### 3. Fonction de répartition

Cas d'une variable aléatoire

#### Definition

Soit  $X$  une variable aléatoire de densité  $f(x)$ , la fonction de **répartition** de  $X$  est définie par :  $F : \mathbb{R} \rightarrow [0, 1]$  et

$$F(t) = P(X \leq t) = \int_{-\infty}^t f(x) dx.$$

**Remarque** :  $F$  est une fonction non décroissante telle que  $F(-\infty) = 0$ ,  $F(+\infty) = 1$  et  $F'(t) = f(t)$ .

## 2. Loi de probabilité continue

Cas d'un couple aléatoire

Soit  $X = (X_1, X_2)$  un couple aléatoire de densité  $f(x)$ , la fonction de répartition de  $X$  est définie par :  $F : \mathbb{R}^2 \rightarrow [0, 1]$  et si  $t = (t_1, t_2)$  alors

$$F(t) = P(X_1 \leq t_1, X_2 \leq t_2) = \int_{-\infty}^{t_1} \int_{-\infty}^{t_2} f(x_1, x_2) dx_1 dx_2.$$

On a aussi

$$f(t_1, t_2) = \frac{\partial^2 F(t_1, t_2)}{\partial t_1 \partial t_2}.$$

## 2. Loi de probabilité continue

### 4. Lois usuelles

#### 4.1 Loi uniforme

##### Definition

On dit que  $X$  suit une loi uniforme sur  $[a, b]$ , noté  $X \rightsquigarrow U[a, b]$ , si elle admet la densité

$$f(x) = \frac{1}{b-a} \mathbf{1}_{[a,b]}(x) = \begin{cases} \frac{1}{b-a} & \text{si } x \in [a, b] \\ 0 & \text{sinon.} \end{cases} \quad (17)$$

On montre que

$$E(X) = (a+b)/2, V(X) = (b-a)^2/12.$$

## 2. Loi de probabilité continue

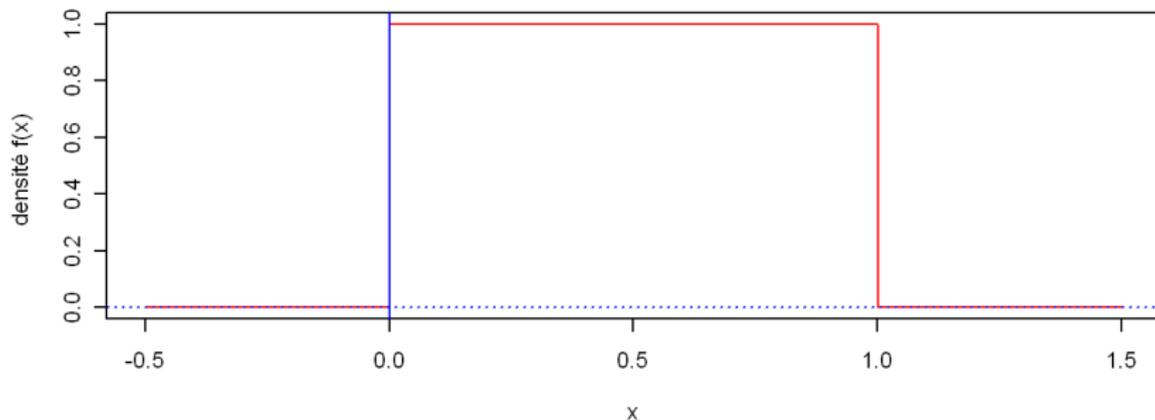


Figure: Densité de la loi uniforme  $U[0,1]$

## 2.Loi de probabilité continue

### 4.2. Loi de Gauss

#### Definition

On dit que  $X$  suit une loi de Gauss de moyenne  $m$  et de variance  $\sigma^2$ , noté  $X \rightsquigarrow N(m, \sigma^2)$ , si elle admet la densité

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-m)^2}{2\sigma^2}}, \forall x \in \mathbb{R}. \quad (18)$$

On montre que  $E(X) = m, V(X) = \sigma^2$ .

## 2.Loi de probabilité continue

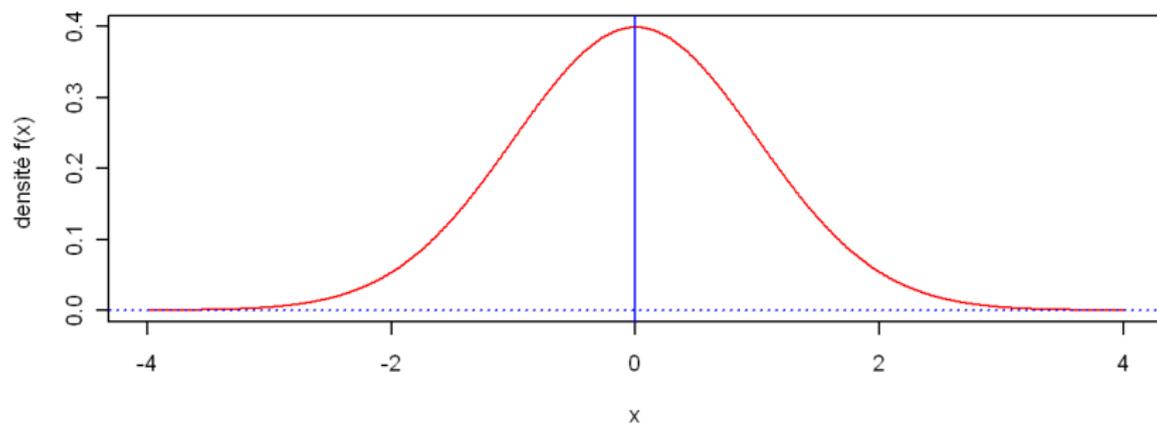


Figure: Densité de la loi Gauss  $N(0,1)$

## 2. Loi de probabilité continue

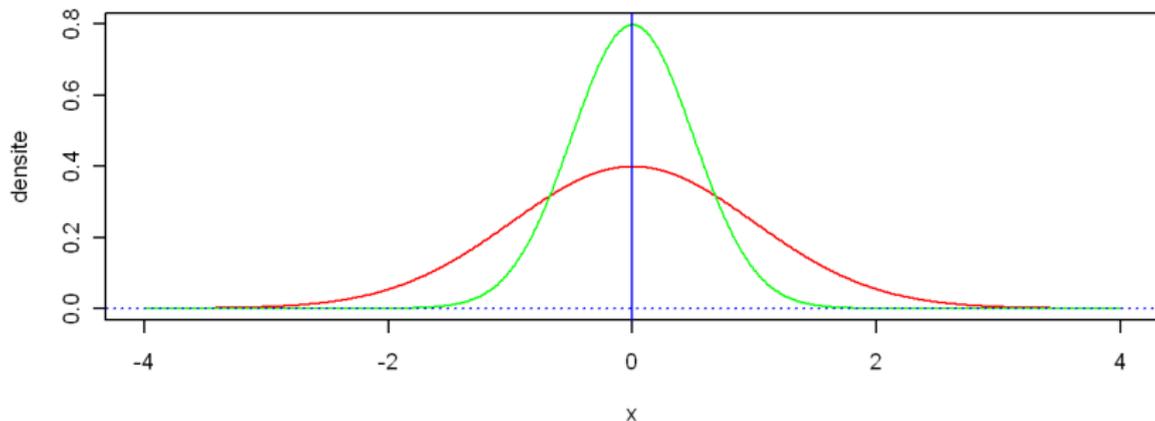


Figure: Densités Gaussiennes, rouge:  $N(0, 1)$ , vert:  $N(0, \frac{1}{2})$ .

### 4.3. Loi exponentielle

#### Definition

On dit que  $X$  suit une loi exponentielle de paramètre  $\lambda > 0$ , noté  $X \rightsquigarrow E(\lambda)$ , si elle admet la densité

$$f(x) = \begin{cases} \lambda e^{-\lambda x} & \text{si } x \geq 0 \\ 0 & \text{sinon.} \end{cases} \quad (19)$$

On montre que  $E(X) = \frac{1}{\lambda}$ ,  $V(X) = \frac{1}{\lambda^2}$ .

## 2. Loi de probabilité continue

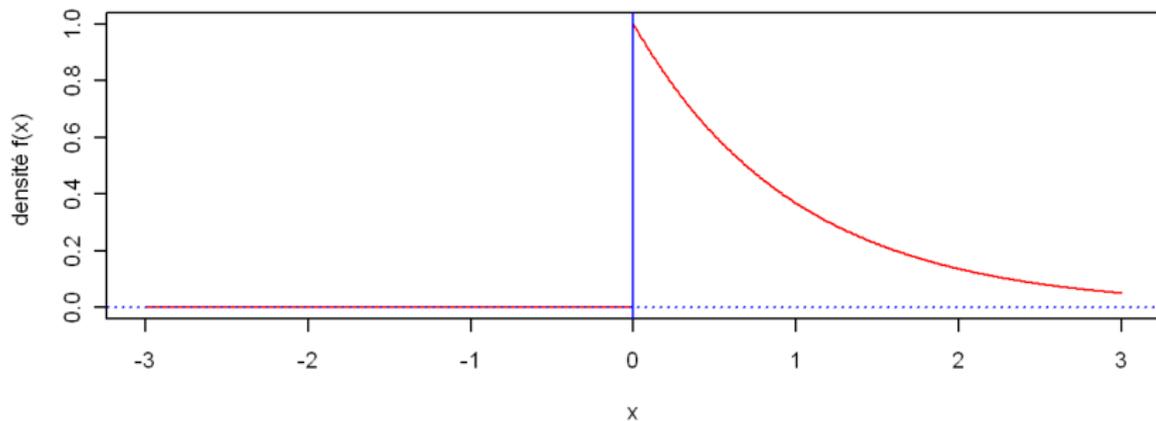


Figure: Densité de la loi exponentielle  $E(1)$

### 4.4. Loi gamma

#### Definition

On dit que  $X$  suit une loi gamma de paramètres  $\alpha > 0$  et  $\beta > 0$ , noté  $X \rightsquigarrow \Gamma(\alpha, \beta)$ , si elle admet la densité

$$f(x) = \begin{cases} \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x} & \text{si } x \geq 0 \\ 0 & \text{sinon,} \end{cases} \quad (20)$$

où  $\Gamma(\alpha) = \int_0^\infty t^{\alpha-1} e^{-t} dt$ .

On montre que  $E(X) = \frac{\alpha}{\beta}$ ,  $V(X) = \frac{\alpha}{\beta^2}$ .

## 2. Loi de probabilité continue

### 5. Transformation des variables aléatoires

#### 5.1 Cas discret

Exemple : Soit  $X$  la variable aléatoire définie par

$x_i$	0	1	-1	2
$P(X(\omega) = x_i)$	0.25	0.2	0.25	0.3

On définit la variable aléatoire  $Y = X(X + 1)$ , alors  $Y$  prend ses valeurs dans  $\{0, 2, 6\}$  avec la loi de probabilité suivante:

$y_i$	0	2	6
$P(Y(\omega) = y_i)$	0.5	0.2	0.3

## 2.Loi de probabilité continue

### Theorem

*Si  $X$  est une variable aléatoire discrète à valeurs dans  $E$ , et  $g$  une application, alors  $Y = g(X)$  est une variable aléatoire discrète à valeurs dans  $g(E)$  telle que:*

- *Si  $g$  est injective alors  $Y$  a la même loi de probabilité que  $X$  :  $P(Y(\omega) = y_i) = P(X(\omega) = x_i), y_i = g(x_i)$ .*
- *Si  $g$  est non injective alors  $Y$  a loi de probabilité suivante:*

$$P(Y(\omega) = y_i) = \sum_{x_i \text{ tels que } y_i=g(x_i)} P(X(\omega) = x_i).$$

## 2. Loi de probabilité continue

### 5.2. Cas continu

Soit  $Y = X^2$ , où  $X \rightsquigarrow N(0, 1)$  donc  $Y$  est à valeurs dans  $\mathbb{R}^+$  donc  $f_Y(y) = 0 \forall y \leq 0$ . Si  $y \geq 0$ , on a  $F_Y(y) = P(Y \leq y) = P(-\sqrt{y} \leq X \leq \sqrt{y}) = \frac{1}{\sqrt{2\pi}} \int_{-\sqrt{y}}^{\sqrt{y}} e^{-\frac{x^2}{2}} = \frac{2}{\sqrt{2\pi}} \int_0^{\sqrt{y}} e^{-\frac{x^2}{2}}$  donc  $f_Y(y) = F'_Y(y) = \frac{1}{\sqrt{2\pi y}} e^{-\frac{y^2}{2}}$ , c'est à dire que  $Y \rightsquigarrow \mathcal{X}^2(1)$ . Si la transformation  $g$  n'est pas bijective, on utilise souvent la fonction de répartition pour calculer la loi de  $Y = g(X)$ . Cependant si  $g$  est bijective on a le théorème

## 2. Loi de probabilité continue

### Theorem

*Soit  $X$  une variable aléatoire de densité  $f_X$ , et soit  $g$  une application de  $\mathbb{R}$  dans  $\mathbb{R}$ . On définit la transformée de  $X$  par  $g: Y = g(X)$ . On suppose que  $g$  est continûment dérivable sur  $\mathbb{R}$ , et que sa dérivée  $g'$  ne s'annule pas. Alors  $Y$  admet une densité  $f_Y$  donnée par*

$$f_Y(y) = \frac{f_X(x)}{|g'(x)|}, \quad x = g^{-1}(y). \quad (21)$$

## 2. Loi de probabilité continue

**Exemple**  $Y = g(X) = aX + b, a \neq 0$ . On a  
 $y = g(x) = ax + b$  donc  $x = \frac{y-b}{a} = g^{-1}(y)$ , donc

$$f_Y(y) = \frac{f_X(x)}{|g'(x)|} = \frac{f_X\left(\frac{y-b}{a}\right)}{|a|}.$$

### 6. Suite de variables aléatoires

#### 6.1. Loi de Khi-deux

##### Definition

On dit que  $X$  suit une loi Khi-deux à  $n$  degrés de liberté, noté  $X \rightsquigarrow \mathcal{X}^2(n)$ , si  $X \rightsquigarrow \Gamma\left(\frac{n}{2}, \frac{1}{2}\right)$ .

$X = \sum_{k=1}^n Z_k^2$  où  $(Z_k, 1 \leq k \leq n)$  est une suite de variables aléatoires indépendantes et identiquement distribuées (i.i.d.) suivant une loi gaussienne  $N(0, 1)$ .

## 2.Loi de probabilité continue

### 6.2. Loi de Student

#### Definition

On dit que  $X$  suit une loi Student à  $n$  degrés de liberté , noté  $X \rightsquigarrow t(n)$ , si  $X = \frac{Z}{\sqrt{Y/n}}$ ,  $Z \rightsquigarrow N(0, 1)$ ,  $Y \rightsquigarrow \mathcal{X}^2(n)$ , et  $Z$  et  $Y$  sont indépendantes.

### 6.3. Loi de Fisher

#### Definition

On dit que  $X$  suit une loi Fisher à  $(n_1, n_2)$  degrés de liberté , noté  $X \rightsquigarrow F(n_1, n_2)$ , si  $X = \frac{Y_1/n_1}{Y_2/n_2}$  ,  $Y_i \rightsquigarrow \mathcal{X}^2(n_i)$ ,  $i = 1, 2$  et  $Y_1$  et  $Y_2$  sont indépendantes.

## 2.Loi de probabilité continue

### 6.2. Loi de Student

#### Definition

On dit que  $X$  suit une loi Student à  $n$  degrés de liberté , noté  $X \rightsquigarrow t(n)$ , si  $X = \frac{Z}{\sqrt{Y/n}}$ ,  $Z \rightsquigarrow N(0, 1)$ ,  $Y \rightsquigarrow \mathcal{X}^2(n)$ , et  $Z$  et  $Y$  sont indépendantes.

### 6.3. Loi de Fisher

#### Definition

On dit que  $X$  suit une loi Fisher à  $(n_1, n_2)$  degrés de liberté , noté  $X \rightsquigarrow F(n_1, n_2)$ , si  $X = \frac{Y_1/n_1}{Y_2/n_2}$  ,  $Y_i \rightsquigarrow \mathcal{X}^2(n_i)$ ,  $i = 1, 2$  et  $Y_1$  et  $Y_2$  sont indépendantes.

# 4. Description d'une série statistique

## 4.1 Généralités, Définitions

- **La statistique**: C'est l'étude des phénomènes préalablement exprimés sous forme numérique.
- **L'unité statistique (ou individu)** :C'est l'élément de l'ensemble que l'on veut étudier, exemple: un étudiant est une unité statistique lorsque l'on étudie une classe.
- **Le caractère**: C'est l'aspect de l'unité statistique que l'on retient dans l'analyse.

# 4. Description d'une série statistique

## 4.1 Généralités, Définitions

- **La statistique**: C'est l'étude des phénomènes préalablement exprimés sous forme numérique.
- **L'unité statistique (ou individu)** :C'est l'élément de l'ensemble que l'on veut étudier, exemple: un étudiant est une unité statistique lorsque l'on étudie une classe.
- **Le caractère**: C'est l'aspect de l'unité statistique que l'on retient dans l'analyse.

# 4. Description d'une série statistique

## 4.1 Généralités, Définitions

- **La statistique**: C'est l'étude des phénomènes préalablement exprimés sous forme numérique.
- **L'unité statistique (ou individu)** :C'est l'élément de l'ensemble que l'on veut étudier, exemple: un étudiant est une unité statistique lorsque l'on étudie une classe.
- **Le caractère**: C'est l'aspect de l'unité statistique que l'on retient dans l'analyse.

## 4. Description d'une série statistique

- **L'échantillon:** C'est un sous-ensemble d'une population statistique.
- **La variable statistique:** C'est l'expression numérique du caractère observé sur les unités statistiques considérées, exemple, taille, poids, note en proba-stat.... de l'étudiant.

## 4. Description d'une série statistique

- **L'échantillon:** C'est un sous-ensemble d'une population statistique.
- **La variable statistique:** C'est l'expression numérique du caractère observé sur les unités statistiques considérées, exemple, taille, poids, note en proba-stat.... de l'étudiant.

## 4. Description d'une série statistique

- La variable statistique  $x$  est dite **discrète** lorsqu'elle ne peut prendre que des valeurs isolées :

$$x_1, x_2, \dots, x_k, \quad \text{où } x_1 < x_2 < \dots < x_k.$$

Exemple : le nombre de chevaux fiscaux d'une voiture; le nombre d'enfants dans une famille,...

- La variable statistique  $x$  est dite **continue** lorsqu'elle peut prendre n'importe quelle valeur d'un intervalle  $[a, b]$ .

Exemple : la durée en minute d'une conversation téléphonique.

## 4. Description d'une série statistique

- La variable statistique  $x$  est dite **discrète** lorsqu'elle ne peut prendre que des valeurs isolées :

$$x_1, x_2, \dots, x_k, \quad \text{où } x_1 < x_2 < \dots < x_k.$$

Exemple : le nombre de chevaux fiscaux d'une voiture; le nombre d'enfants dans une famille,...

- La variable statistique  $x$  est dite **continue** lorsqu'elle peut prendre n'importe quelle valeur d'un intervalle  $[a, b]$ .

Exemple : la durée en minute d'une conversation téléphonique.

## 4. Description d'une série statistique

Dans ce cas l'intervalle des valeurs possibles est divisé en  $k$  classes

$$[a_0, a_1[, [a_1, a_2[, \dots, [a_{k-1}, a_k],$$

avec

$$a_0 = a < a_1 < \dots < a_{k-1} < a_k = b.$$

$a_{h-1}$  et  $a_h$  sont les frontières de la  $h$ -ième classe,  $x_h = \frac{a_{h-1} + a_h}{2}$  est le centre de celle-ci.

## 4. Description d'une série statistique

**La série statistique:** C'est à la fois :

- **L'ensemble des valeurs**  $\{x_1, x_2, \dots, x_k\}$  (resp. des classes de valeurs

$$\{[a_0, a_1[, [a_1, a_2[, \dots, [a_{k-1}, a_k]\})$$

de la variable  $x$ .

- **Le nombre d'observation** associé à chaque valeur  $x_i$  (resp. à chaque classe), qu'on appelle **effectif**.

## 4. Description d'une série statistique

**La série statistique:** C'est à la fois :

- **L'ensemble des valeurs**  $\{x_1, x_2, \dots, x_k\}$  (resp. des classes de valeurs

$$\{[a_0, a_1[, [a_1, a_2[, \dots, [a_{k-1}, a_k]\})$$

de la variable  $x$ .

- **Le nombre d'observation** associé à chaque valeur  $x_i$  (resp. à chaque classe), qu'on appelle **effectif**.

# 4. Description d'une série statistique

## 2. Distribution des fréquences

### 2.1 Cas discret

- Si dans une série statistique résultant de  $n$  observations, on a trouvé  $n_i$  fois la valeur  $x_i$ ,  $n_i$  représente **l'effectif** de cette valeur et le rapport  $f_i = \frac{n_i}{n}$  représente sa **fréquence**.
- L'expression  $\sum_{i=1}^j n_i$  est appelée **effectif cumulé** des valeurs de  $x$  inférieures ou égales à  $x_j$ .
- L'expression  $\sum_{i=1}^j f_i$  est appelée **fréquence cumulée** des valeurs de  $x$  inférieures ou égales à  $x_j$ .

# 4. Description d'une série statistique

## 2. Distribution des fréquences

### 2.1 Cas discret

- Si dans une série statistique résultant de  $n$  observations, on a trouvé  $n_i$  fois la valeur  $x_i$ ,  $n_i$  représente **l'effectif** de cette valeur et le rapport  $f_i = \frac{n_i}{n}$  représente sa **fréquence**.
- L'expression  $\sum_{i=1}^j n_i$  est appelée **effectif cumulé** des valeurs de  $x$  inférieures ou égales à  $x_j$ .
- L'expression  $\sum_{i=1}^j f_i$  est appelée **fréquence cumulée** des valeurs de  $x$  inférieures ou égales à  $x_j$ .

# 4. Description d'une série statistique

## 2. Distribution des fréquences

### 2.1 Cas discret

- Si dans une série statistique résultant de  $n$  observations, on a trouvé  $n_i$  fois la valeur  $x_i$ ,  $n_i$  représente l'**effectif** de cette valeur et le rapport  $f_i = \frac{n_i}{n}$  représente sa **fréquence**.
- L'expression  $\sum_{i=1}^j n_i$  est appelée **effectif cumulé** des valeurs de  $x$  inférieures ou égales à  $x_j$ .
- L'expression  $\sum_{i=1}^j f_i$  est appelée **fréquence cumulée** des valeurs de  $x$  inférieures ou égales à  $x_j$ .

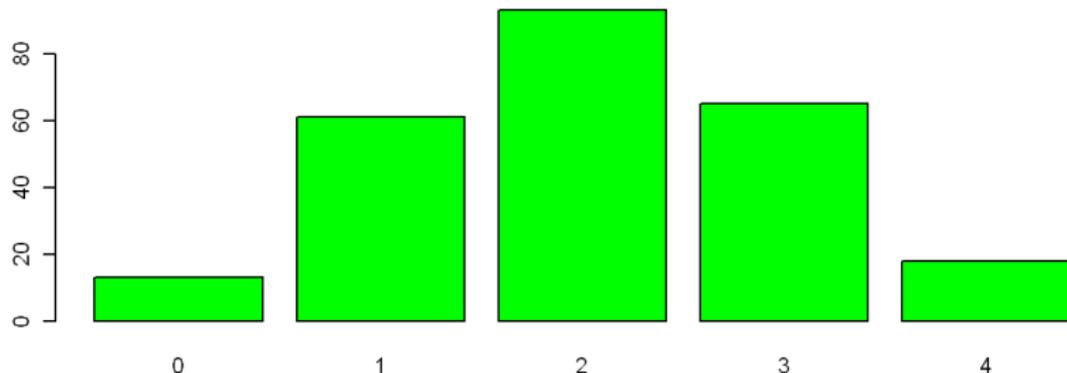
## 4. Description d'une série statistique

Exemple : L'unité statistique (ou individu) étant la famille de quatre enfants dont l'aîné a moins de 16 ans, on s'intéresse au nombre  $x$  de garçons qui la compose. L'étude statistique suivante porte sur un échantillon de 250 familles.

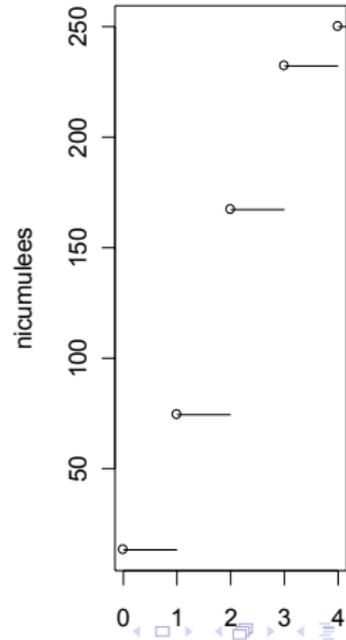
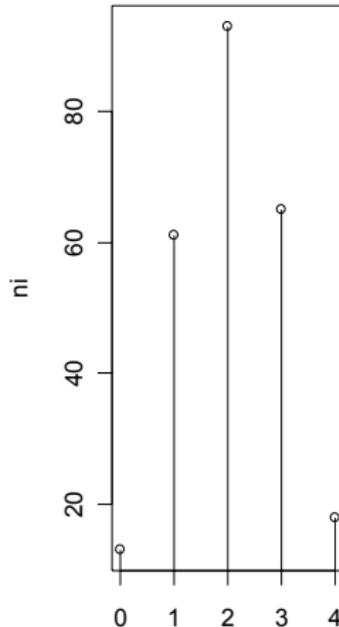
Valeurs de $x$	0	1	2	3	4
Effectif $n_i$	13	61	93	65	18
Fréquence $f_i$	0,052	0,244	0,372	0,260	0,072
Effectif cumulé	13	74	167	232	250
Fréquence cumulée	0,052	0,296	0,668	0,928	1

## 4. Description d'une série statistique

Valeurs de $x$	0	1	2	3	4
Effectif $n_i$	13	61	93	65	18



# 4. Description d'une série statistique



# 4. Description d'une série statistique

## 2.2 Cas continu

- On appelle **effectif** de la  $h$ ème classe la nombre  $n_h$  d'observations dont les valeurs appartiennent à cette classe. Le nombre  $f_h = \frac{n_h}{n}$  représente la **fréquence** de la  $h$ ème classe.
- L'expression  $\sum_{i=1}^h n_i$  est appelée **effectif cumulé** des  $h$  premières classes.
- L'expression  $\sum_{i=1}^h f_i$  est appelée **fréquence cumulée** des  $h$  premières classes.

# 4. Description d'une série statistique

## 2.2 Cas continu

- On appelle **effectif** de la  $h$ ème classe la nombre  $n_h$  d'observations dont les valeurs appartiennent à cette classe. Le nombre  $f_h = \frac{n_h}{n}$  représente la **fréquence** de la  $h$ ème classe.
- L'expression  $\sum_{i=1}^h n_i$  est appelée **effectif cumulé** des  $h$  premières classes.
- L'expression  $\sum_{i=1}^h f_i$  est appelée **fréquence cumulée** des  $h$  premières classes.

## 4. Description d'une série statistique

Exemple : On s'intéresse à la durée  $x$  de service d'un guichet de la poste qui peut servir au plus un client à la fois. On a relevé la durée de service de 1000 clients consécutifs. L'unité de temps est la seconde, les résultats sont résumés par le tableau suivant:

Classes des valeurs de $x$	[0,30[	[30,60[	[60,90[	[90,120[	[120,150[	[150,180[	[180,240[
Effectifs $n_h$	369	251	148	98	65	43	26
Fréquences $f_h$	0,369	0,251	0,148	0,098	0,065	0,043	0,026
Effectifs cumulés	369	620	768	866	931	974	1000
Fréquences cumulées	0,369	0,620	0,768	0,866	0,931	0,974	1

# 4. Description d'une série statistique

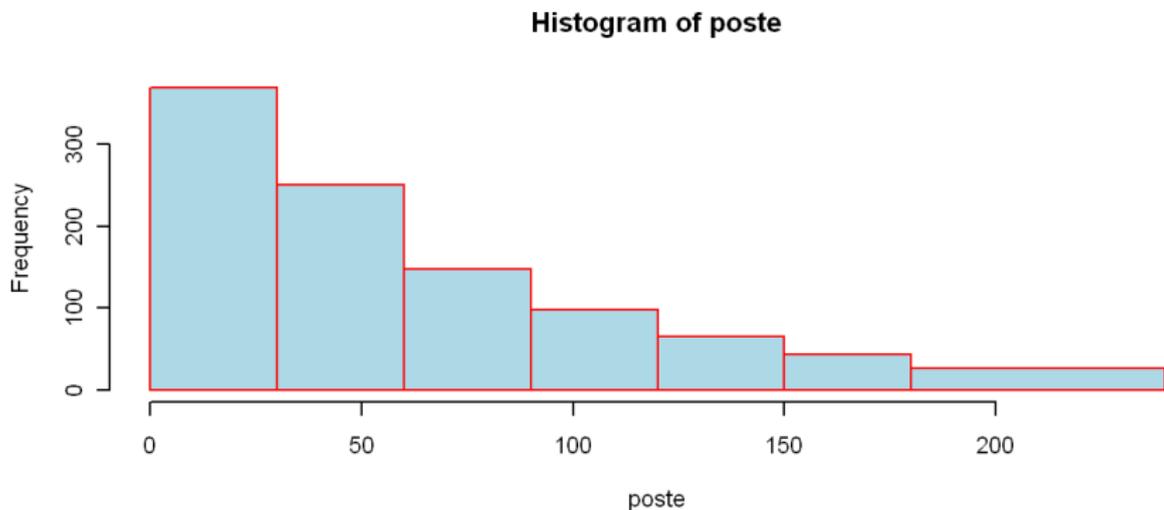


Figure: Effectifs des 7 classes

# 4. Description d'une série statistique

## 2.3 Distribution des fréquences

L'ensemble des  $k$  valeurs  $x_i$  (resp. des  $k$  classes) et les effectifs  $n_i$  correspondants, constitue la distribution des fréquences de la variable  $x$ .

### Représentation graphique des distributions des fréquences

On place en ordonnée les effectifs. Dans le cas discret on obtient un diagramme en bâtons. Dans le cas continu, on construit un histogramme des fréquences, l'aire de chaque classe devant être proportionnelle à son effectif correspondant.

# 4. Description d'une série statistique

## 3. Caractéristiques de tendance centrale

**3.1. Définition:** Ce sont des indicateurs qui permettent de synthétiser l'ensemble de la série statistique en faisant ressortir une position centrale de la valeur du caractère étudié.

- **La médiane :** C'est la valeur  $x_m$  de la variable  $x$  qui partage les éléments de la série statistique, préalablement classés par ordre de valeurs croissantes, en deux groupes d'effectifs égaux : 50 % des valeurs observées sont inférieures à  $x_m$  et 50 % sont supérieures.

## 4. Description d'une série statistique

Dans le cas continu, elle est donnée par

$$x_m = a_{j-1} + \frac{a_j - a_{j-1}}{n_j} \left( \frac{n}{2} - \sum_{i=1}^j n_i \right),$$

sachant que  $x_m$  appartient à  $[a_{j-1}, a_j[$ .

- **Le mode :**

Variable discrète : c'est la valeur pour laquelle la fréquence est maximale.

Variable continue : la classe modale est celle pour laquelle la fréquence est maximale.

Lorsqu'il y a une seule valeur ou classe modale, la distribution est dite **unimodale**.

## 4. Description d'une série statistique

- **La moyenne.**

-La moyenne  $\bar{x}$  de  $k$  valeurs distinctes  $x_1, \dots, x_k$ , et d'effectifs  $n_1, \dots, n_k$  :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k n_i x_i, \quad n = \sum_{i=1}^k n_i.$$

-La moyenne  $\bar{x}$  de  $n$  valeurs distribuées en  $k$  classes  $[a_0, a_1[, \dots, [a_{k-1}, a_k[$  et d'effectifs  $n_1, \dots, n_k$  :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k n_i x_i, \quad x_i = \frac{a_{i-1} + a_i}{2}.$$

## 4. Description d'une série statistique

- **La moyenne.**

-La moyenne  $\bar{x}$  de  $k$  valeurs distinctes  $x_1, \dots, x_k$ , et d'effectifs  $n_1, \dots, n_k$  :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k n_i x_i, \quad n = \sum_{i=1}^k n_i.$$

-La moyenne  $\bar{x}$  de  $n$  valeurs distribuées en  $k$  classes  $[a_0, a_1[, \dots, [a_{k-1}, a_k[$  et d'effectifs  $n_1, \dots, n_k$  :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k n_i x_i, \quad x_i = \frac{a_{i-1} + a_i}{2}.$$

# 4. Description d'une série statistique

## 4. Caractéristiques de dispersion

Deux séries de même nature peuvent présenter des caractéristiques de tendance centrale voisines, mais être différentes quant à la dispersion de leurs valeurs par rapport à la tendance centrale.

### 4.1. La dispersion en termes d'intervalles

- **Intervalle de variation ou étendue** : C'est la différence entre les valeurs extrêmes de la variable ou entre les centres des classes extrêmes  $x_k - x_1$ .

## 4. Description d'une série statistique

- **L'intervalle interquartile** : Si l'on peut diviser  $x_1, \dots, x_k$  en quatre classes  $[x_1, Q_1[$ ,  $[Q_1, Q_2[$ ,  $[Q_2, Q_3[$ ,  $[Q_3, x_k]$  ayant toutes la même fréquence  $\frac{n}{4}$ , alors  $Q_1$ ,  $Q_2$ , et  $Q_3$  sont appelés respectivement premier, deuxième et troisième quartiles. Dans le cas continu

$$Q_1 = a_{j-1} + \frac{a_j - a_{j-1}}{n_j} \left( \frac{n}{4} - \sum_{i=1}^j n_i \right),$$

$$Q_3 = a_{j-1} + \frac{a_j - a_{j-1}}{n_j} \left( \frac{3n}{4} - \sum_{i=1}^j n_i \right).$$

$[Q_1, Q_3]$  est l'intervalle interquartile.

# 4. Description d'une série statistique

## 4.2. La dispersion en termes d'écart

Les écarts ne traduiront la dispersion que si l'on considère leurs valeurs absolues ou leurs puissances paires.

- **Les écarts absolus :**

-L' écart absolu par rapport à la médiane

$e_M = \frac{1}{n} \sum_{i=1}^k n_i |x_i - M|$ ,  $M$  est la médiane de la série.

-L' écart absolu par rapport à la moyenne arithmétique

$e_{\bar{x}} = \frac{1}{n} \sum_{i=1}^k n_i |x_i - \bar{x}|$ .

- **Variance, écart-type:**

-Variance:  $V(x) = \hat{\sigma}_x^2 = \frac{1}{n} \sum_{i=1}^k n_i (x_i - \bar{x})^2$ .

-Ecart-type :  $\hat{\sigma}_x$ .

# 4. Description d'une série statistique

## 4.2. La dispersion en termes d'écart

Les écarts ne traduiront la dispersion que si l'on considère leurs valeurs absolues ou leurs puissances paires.

- **Les écarts absolus :**

-L' écart absolu par rapport à la médiane

$e_M = \frac{1}{n} \sum_{i=1}^k n_i |x_i - M|$ ,  $M$  est la médiane de la série.

-L' écart absolu par rapport à la moyenne arithmétique

$e_{\bar{x}} = \frac{1}{n} \sum_{i=1}^k n_i |x_i - \bar{x}|$ .

- **Variance, écart-type:**

-Variance:  $V(x) = \hat{\sigma}_x^2 = \frac{1}{n} \sum_{i=1}^k n_i (x_i - \bar{x})^2$ .

-Ecart-type :  $\hat{\sigma}_x$ .

# 4. Description d'une série statistique

## 4.2. La dispersion en termes d'écart

Les écarts ne traduiront la dispersion que si l'on considère leurs valeurs absolues ou leurs puissances paires.

- **Les écarts absolus :**

-L' écart absolu par rapport à la médiane

$e_M = \frac{1}{n} \sum_{i=1}^k n_i |x_i - M|$ ,  $M$  est la médiane de la série.

-L' écart absolu par rapport à la moyenne arithmétique

$e_{\bar{x}} = \frac{1}{n} \sum_{i=1}^k n_i |x_i - \bar{x}|$ .

- **Variance, écart-type:**

-Variance:  $V(x) = \hat{\sigma}_x^2 = \frac{1}{n} \sum_{i=1}^k n_i (x_i - \bar{x})^2$ .

-Ecart-type :  $\hat{\sigma}_x$ .

# 4. Description d'une série statistique

## 4.2. La dispersion en termes d'écart

Les écarts ne traduiront la dispersion que si l'on considère leurs valeurs absolues ou leurs puissances paires.

- **Les écarts absolus :**

-L' écart absolu par rapport à la médiane

$e_M = \frac{1}{n} \sum_{i=1}^k n_i |x_i - M|$ ,  $M$  est la médiane de la série.

-L' écart absolu par rapport à la moyenne arithmétique

$e_{\bar{x}} = \frac{1}{n} \sum_{i=1}^k n_i |x_i - \bar{x}|$ .

- **Variance, écart-type:**

-Variance:  $V(x) = \hat{\sigma}_x^2 = \frac{1}{n} \sum_{i=1}^k n_i (x_i - \bar{x})^2$ .

-Ecart-type :  $\hat{\sigma}_x$ .

## 4. Description d'une série statistique

### Theorem

*pour tout  $a \in \mathbb{R}$ , on a*

$$V(a + x) = V(x), V(ax) = a^2 V(x),$$

*et*

$$V(x) = \frac{1}{n} \sum_{i=1}^k n_i x_i^2 - (\bar{x})^2.$$

## 4. Description d'une série statistique

**Exemple 1.** La distribution des salaires annuels dans une population contenant  $n = 14890442$  actifs, ( le nombre d'individus  $N_i$  touchant le salaire  $s_i$  exprimé en euros) est distribuée comme suit:

$s_i$ (en euro )	$N_i$
10000	11583265
20000	2045372
30000	683240
40000	349740
50000	183280
100000	36250
200000	7975
500000	1015
1000000	305

# 4. Description d'une série statistique

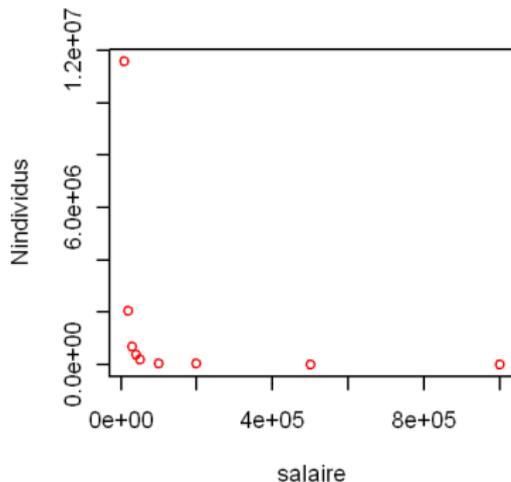


Figure: Distribution des salaires

## 4. Description d'une série statistique

Le salaire moyen est donné par

$$\bar{s} = \frac{1}{n} \sum_{i=1}^9 N_i s_i = 13862.81 \text{ euros ,}$$

la variance et l'écart-type sont donnés par:

$$V(s) = \frac{1}{n} \sum_{i=1}^9 N_i (s_i - \bar{s})^2 = 133496156, \hat{\sigma}_s = 11554.05,$$

le premier, deuxième et troisième quartiles sont

$$Q_1 = 10435.56, Q_2 = 14338.53 \text{ et } Q_3 = 18241.5.$$

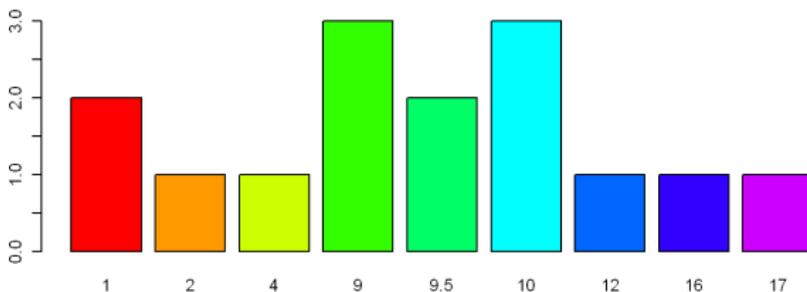
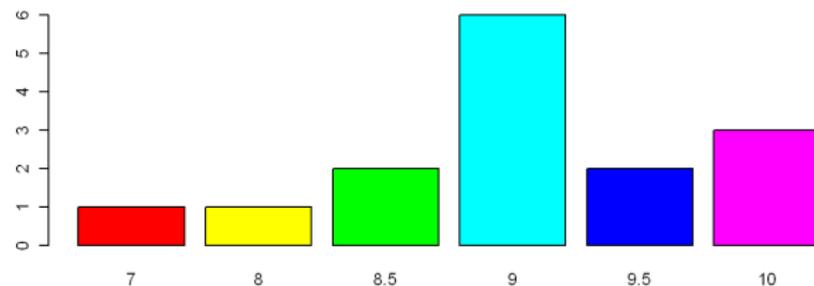
Remarque. Le salaire médian qui est égal à  $s_m = Q_2$  est différent du salaire moyen  $\bar{s}$ .

## 4. Description d'une série statistique

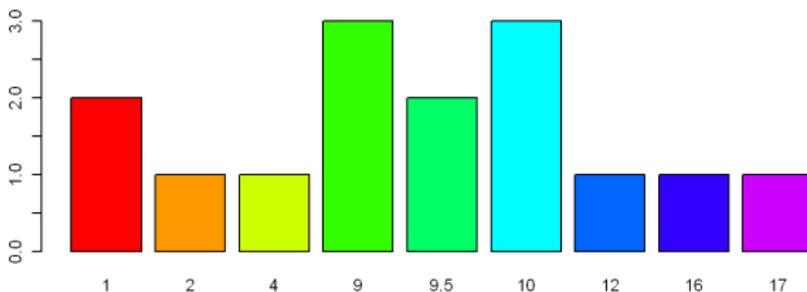
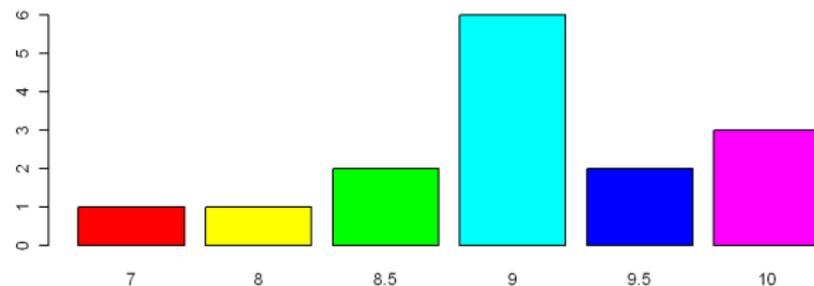
Exemple 2. Dans une classe constituée de deux groupes G1 et G2, la note obtenue dans l'examen de statistique est distribuée comme suit:

Groupe 1	9	10	9	9	8.5	9.5	10	10	7	9	9	9	8.5
	9.5	8											
Groupe 2	2	10	1	9	4	9.5	10	10	7	9	9	17	12
	9.5	16											

# 4. Description d'une série statistique



# 4. Description d'une série statistique



## 4. Description d'une série statistique

La moyenne de la classe est égale à  $\bar{x} = 9$ .

La moyenne du groupe 1 est égale à  $\bar{x}_{G1} = 9$ , et la moyenne du groupe 2 est aussi égale à  $\bar{x}_{G2} = 9$ . Cependant les deux groupes, même s'ils ont la même moyenne, sont complètement différents. En effet dans le groupe 1, la plupart des notes tournent autour de la moyenne globale 9, les étudiants ont presque le même niveau. Le groupe 2 est plus hétérogène, il y a des étudiants faibles (notes: 1, 2 et 4) et des étudiants forts (notes: 12, 16 et 17). Si on calcule la variance de chaque groupe on trouve

$V_{G1} = 0.6428571$ ,  $V_{G2} = 19.10714$ .  $V_{G2} > V_{G1}$ , en conclusion plus la variance est grande plus l'échantillon est hétérogène.

## 4. Description d'une série statistique

### 5. Moments

#### Definition

Le moment d'ordre  $r$  de la variable  $x$  par rapport à l'origine  $x_0$  est défini par

$$m_r(x_0) = \frac{1}{n} \sum_{i=1}^k n_i (x_i - x_0)^r.$$

Si  $x_0 = 0$  les moments sont dits simples et notés  $m_r$ .

Si  $x_0 = \bar{x}$  les moments sont dits centrés et notés  $\mu_r$ .

#### Theorem

$$\mu_2 = m_2 - m_1^2, \mu_3 = m_3 - 3m_1 m_2 + 3m_1^3,$$

$$\mu_4 = m_4 - 4m_1 m_3 + 6m_1^3 m_2 - 3m_1^4.$$

## 4. Description d'une série statistique

### 5. Moments

#### Definition

Le moment d'ordre  $r$  de la variable  $x$  par rapport à l'origine  $x_0$  est défini par

$$m_r(x_0) = \frac{1}{n} \sum_{i=1}^k n_i (x_i - x_0)^r.$$

Si  $x_0 = 0$  les moments sont dits simples et notés  $m_r$ .

Si  $x_0 = \bar{x}$  les moments sont dits centrés et notés  $\mu_r$ .

#### Theorem

$$\mu_2 = m_2 - m_1^2, \mu_3 = m_3 - 3m_1m_2 + 3m_1^3,$$

$$\mu_4 = m_4 - 4m_1m_3 + 6m_1^2m_2 - 3m_1^4.$$

# 5. Liaisons entre variables statistiques

## Definition

Une série double à deux indices est définie par l'observation de  $n$  couples de valeurs tels que:

- **Cas discret:**  $x$  prends les valeurs  $x_1, \dots, x_p$  et  $y$  prends les valeurs  $y_1, \dots, y_r$ , et à chaque couple de valeurs  $(x_i, y_j)_{1 \leq i \leq p; 1 \leq j \leq r}$  on associe:
  - **Son effectif**  $n_{i,j}$  qui est le nombre de fois où  $(x, y) = (x_i, y_j)$ .
  - **Sa fréquence**  $f_{i,j} = \frac{n_{i,j}}{n}$ .
- **Cas continu :** Les valeurs observées pour  $x$  et pour  $y$  sont regroupées respectivement en  $p$  et  $r$  classes  $[a_0, a_1[, [a_1, a_2[, \dots, [a_{p-1}, a_p]$ , resp.  $[b_0, b_1[, [b_1, b_2[, \dots, [b_{r-1}, b_r]$ , et  $n_{i,j}$  est le nombre d'observations pour lesquelles  $a_{i-1} \leq x \leq a_i$ , et  $b_{j-1} \leq y \leq b_j$ .

## 5. Liaisons entre variables statistiques

Exemple : sur 200 personnes de même âge et de même sexe on en dénombre 25 dont la taille  $y$  est comprise entre 165 et 167 cm et le poids  $x$  entre 60 et 65 kg ; 30 dont la taille entre 167 et 169 et le poids entre 60 et 65 kg ; le reste est tel que  $55 \leq x \leq 60$  et  $160 \leq y \leq 165$ . On peut représenter les données par le tableau

$y$ (taille)	160 – 165	165-167	167 – 169	Totaux partiels
$x$ (poids)				
55 – 60	145	0	0	145
60 – 65	0	25	30	55
Totaux partiels	145	25	30	200

# 5. Liaisons entre variables statistiques

Présentation sous forme d'un tableau à double entrée(ou matrice):

y	$y_1$	...	$y_j$	...	$y_r$	Totaux partiels
x						
$x_1$	$n_{1,1}$	...	$n_{1,j}$	...	$n_{1,r}$	$n_{1,\bullet}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$x_j$	$n_{i,1}$	...	$n_{i,j}$	...	$n_{i,r}$	$n_{i,\bullet}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$x_p$	$n_{p,1}$	...	$n_{p,j}$	...	$n_{p,r}$	$n_{p,\bullet}$
Totaux partiels	$n_{\bullet,1}$	...	$n_{\bullet,j}$	...	$n_{\bullet,r}$	$n$

$$n_{i,\bullet} = \sum_{j=1}^r n_{i,j}, n_{\bullet,j} = \sum_{i=1}^p n_{i,j}, n = \sum_{i=1}^p \sum_{j=1}^r n_{i,j}$$

# 5. Liaisons entre variables statistiques

## 6. La distribution marginale

### Definition

La distribution **marginale** de  $x$  se lit sur la dernière colonne du tableau; elle concerne les effectifs de  $x$  considérés isolément: le nombre d'observations pour lesquelles  $x = x_i$  (resp.  $x$  appartient à la classe  $[a_{i-1}, a_i[$ ) est

$$n_{i,\bullet} = \sum_{j=1}^r n_{i,j}.$$

De même, les effectifs de la distribution marginale de  $y$  se lisent dans la dernière ligne du tableau.

# 5. Liaisons entre variables statistiques

On définit:

- **Les moyennes marginales**  $\bar{x}$  et  $\bar{y}$  :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^p n_{i,\bullet} x_i \text{ et } \bar{y} = \frac{1}{n} \sum_{j=1}^r n_{\bullet,j} y_j.$$

- **Les variances marginales**

$$\sigma_x^2 = \frac{1}{n} \sum_{i=1}^p n_{i,\bullet} (x_i - \bar{x})^2 \text{ et } \sigma_y^2 = \frac{1}{n} \sum_{j=1}^r n_{\bullet,j} (y_j - \bar{y})^2.$$

# 5. Liaisons entre variables statistiques

On définit:

- **Les moyennes marginales**  $\bar{x}$  et  $\bar{y}$  :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^p n_{i,\bullet} x_i \text{ et } \bar{y} = \frac{1}{n} \sum_{j=1}^r n_{\bullet,j} y_j.$$

- **Les variances marginales**

$$\sigma_x^2 = \frac{1}{n} \sum_{i=1}^p n_{i,\bullet} (x_i - \bar{x})^2 \text{ et } \sigma_y^2 = \frac{1}{n} \sum_{j=1}^r n_{\bullet,j} (y_j - \bar{y})^2.$$

# 5. Liaisons entre variables statistiques

## 7. La distribution conditionnelle

A chaque valeur fixée  $x_i$  correspond la distribution conditionnelle de  $y$  sachant  $x = x_i$  d'effectifs  $n_{i,1}, \dots, n_{i,r}$ .

On définit:

- **La moyenne conditionnelle de  $y$  sachant  $x = x_i$  :**

$$\bar{y}_i = \frac{1}{n_{i,\bullet}} \sum_{j=1}^r n_{i,j} y_j.$$

- **La variance conditionnelle de  $y$  sachant  $x = x_i$  :**

$$\hat{\sigma}_{x_i}^2(y) = \frac{1}{n_{i,\bullet}} \sum_{j=1}^r n_{i,j} (y_j - \bar{y}_i)^2.$$

# 5. Liaisons entre variables statistiques

## 7. La distribution conditionnelle

A chaque valeur fixée  $x_i$  correspond la distribution conditionnelle de  $y$  sachant  $x = x_i$  d'effectifs  $n_{i,1}, \dots, n_{i,r}$ .

On définit:

- **La moyenne conditionnelle de  $y$  sachant  $x = x_i$  :**

$$\bar{y}_i = \frac{1}{n_{i,\bullet}} \sum_{j=1}^r n_{i,j} y_j.$$

- **La variance conditionnelle de  $y$  sachant  $x = x_i$  :**

$$\hat{\sigma}_{x_i}^2(y) = \frac{1}{n_{i,\bullet}} \sum_{j=1}^r n_{i,j} (y_j - \bar{y}_i)^2.$$

## 5. Liaisons entre variables statistiques

De même on définit :

- **la moyenne conditionnelle de x sachant  $y = y_j$**  :

$$\bar{x}_j = \frac{1}{n_{\bullet j}} \sum_{i=1}^p n_{i,j} x_i.$$

- **la variance conditionnelle de x sachant  $y = y_j$**  :

$$\hat{\sigma}_{y_j}^2(x) = \frac{1}{n_{\bullet j}} \sum_{i=1}^p n_{i,j} (x_i - \bar{x}_j)^2.$$

## 5. Liaisons entre variables statistiques

De même on définit :

- **la moyenne conditionnelle de x sachant  $y = y_j$**  :

$$\bar{x}_j = \frac{1}{n_{\bullet,j}} \sum_{i=1}^p n_{i,j} x_i.$$

- **la variance conditionnelle de x sachant  $y = y_j$**  :

$$\hat{\sigma}_{y_j}^2(x) = \frac{1}{n_{\bullet,j}} \sum_{i=1}^p n_{i,j} (x_i - \bar{x}_j)^2.$$

# 6.L'ajustement, régression simple

## 6.1 Coefficient de corrélation linéaire

### Definition

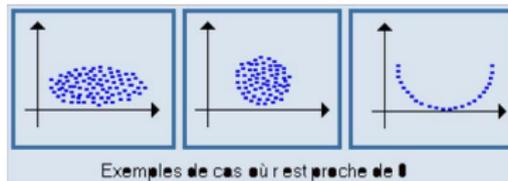
C'est un nombre sans dimension destiné à mesurer l'intensité de liaison entre les variations de  $x$  et celles de  $y$ . Il a pour expression

$$r = r(x, y) = \frac{\text{cov}(x, y)}{\sigma_x \sigma_y},$$

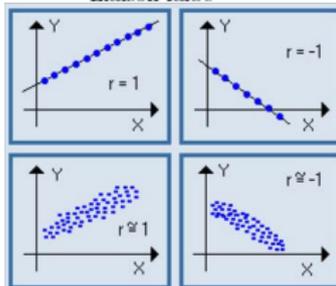
où

$$\text{cov}(x, y) = \frac{1}{n} \sum_{i=1}^p \sum_{j=1}^r n_{i,j} (x_i - \bar{x})(y_j - \bar{y}).$$

# 6.L'ajustement, régression simple

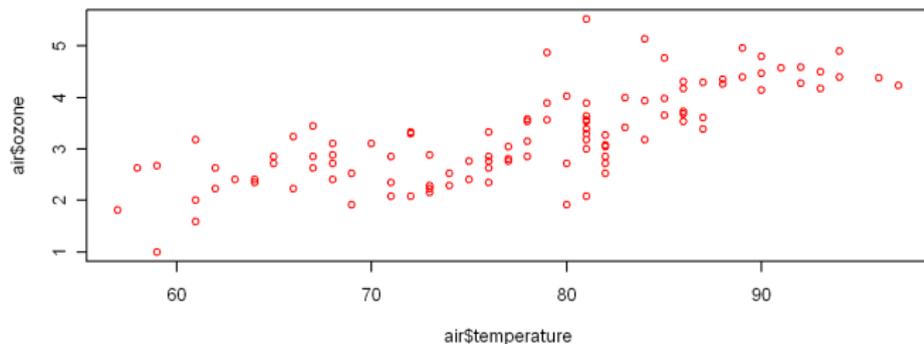


Liaison faible



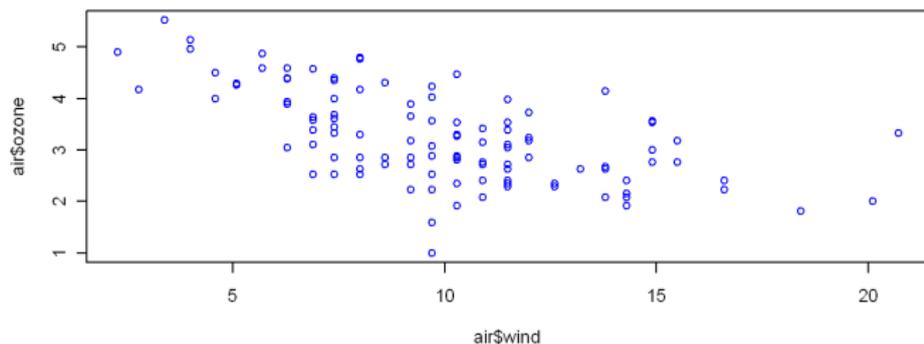
Liaison forte

## 6.L'ajustement, régression simple



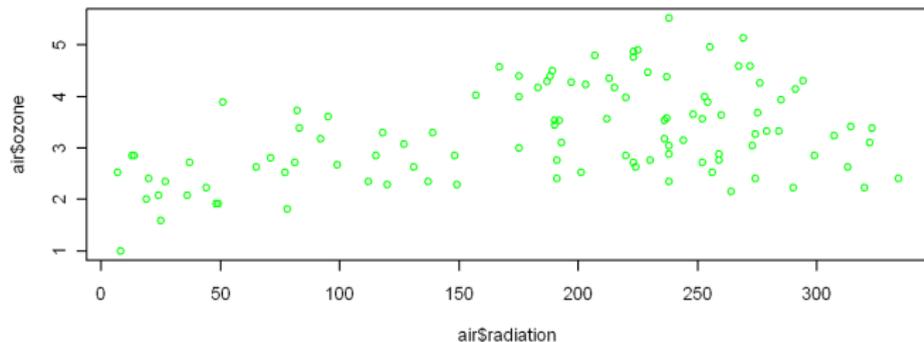
$r=0.7531038$

## 6.L'ajustement, régression simple



$$r = -0.5989278$$

## 6.L'ajustement, régression simple



$r=0.422013$

# 6.L'ajustement, régression simple

## 6.2 L'ajustement

### Definition

Etant donné un ensemble de points de coordonnées  $(x_i, y_i), 1 \leq i \leq n$  formant un nuage dans le plan  $XOY$ , l'ajustement consiste à choisir une courbe continue qui résume le nuage. Cette courbe a pour but d'expliquer comment  $y$  varie en fonction de  $x$ .

### Ajustement par la méthode des **moindres carrés**

Le type d'ajustement étant préalablement choisi, la courbe d'ajustement de  $y$  en  $x$ , d'équation  $y = f(x)$ , est dite des moindres carrés si  $f$  est telle que  $\sum_{i=1}^n d_i^2$  soit minimale où  $d_i = y_i - f(x_i)$

## 6.L'ajustement, régression simple

### **l'ajustement linéaire: droite des moindres carrés**

Lorsque le nuage est rectiligne on choisit  $f(x) = ax + b$ . La droite des moindres carrés est donnée par  $y = \hat{a}x + \hat{b}$ , où

$$\hat{a} = \frac{\text{cov}(x, y)}{\sigma_x^2}, \hat{b} = \bar{y} - \hat{a}\bar{x},$$

$$\text{cov}(x, y) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}),$$

$$\sigma_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2, \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i.$$

# 6. L'ajustement, régression simple

## Qualité d'ajustement

Pour juger de la bonne qualité de l'ajustement on définit

$$R^2 = \frac{\sigma_y^2 - SSR/n}{\sigma_y^2}, \quad SSR = \sum_{i=1}^n e_i^2,$$

$SSR$  est la somme des carrés des résidus, avec

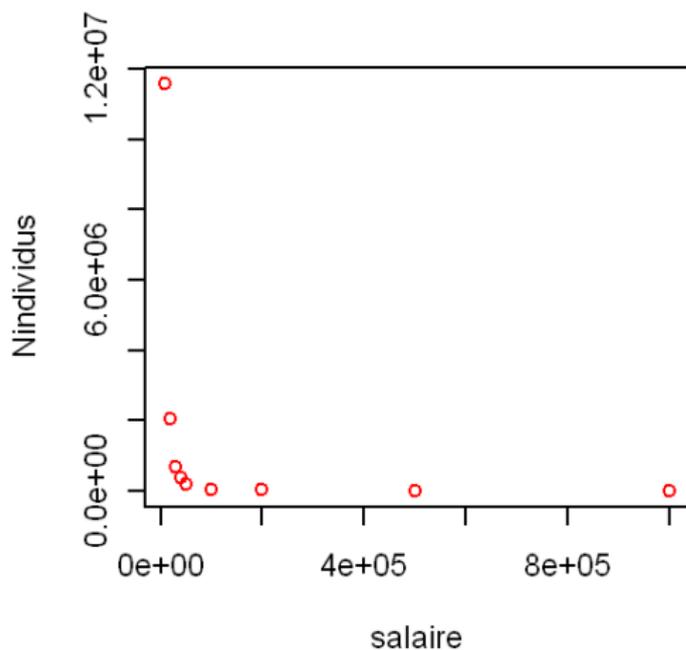
$e_i = y_i - (\hat{b} + \hat{a}x_i)$  le résidu qui correspond à l'observation  $y_i$ .

$R^2$  est un réel toujours inférieur à 1.

- Si  $R^2$  est proche de 1 alors l'ajustement est de bonne qualité.
- Si  $R^2$  est proche de 0 alors l'ajustement est de mauvaise qualité.

## 6.L'ajustement, régression simple

**Exemple** On reprend la distribution des salaires,

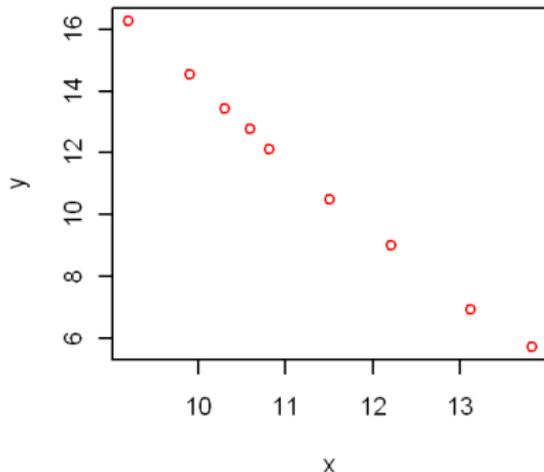


## 6.L'ajustement, régression simple

Le graphique nous suggère que le nombre d'individus décroît lorsque le salaire croit, le rythme de décroissance est exponentiel. On peut donc déduire que le coefficient de corrélation linéaire est négatif; en effet on trouve  $r = -0.3005368$ .

Pour expliquer  $N$  en fonction de  $s$ , nous allons faire une transformation logarithmique. En effet en posant  $y = \ln(N)$  et  $x = \ln(s)$ ,

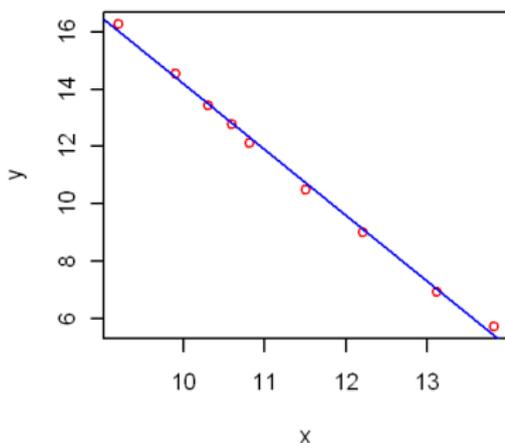
## 6.L'ajustement, régression simple



Le graphique montre qu'il y a une relation linéaire en y et x.

## 6.L'ajustement, régression simple

Le coefficient de corrélation linéaire est  $r = -0.998564$ . Un ajustement linéaire de  $y$  en  $x$  est bien justifié. On trouve  $\hat{b} = 37.241$  et  $\hat{a} = -2.305$ . La droite des moindres carrés est donnée par  $y = -2.305x + 37.241$ .



## 6.L'ajustement, régression simple

La somme des carrés des résidus  $SSR = 0.2012$  est très faible.

Le coefficient  $R^2 = 0.9971$  est proche de 1, on peut donc affirmer que l'ajustement est de bonne qualité.

En résumé, on peut donc supposer que le nombre d'individus  $N$  est lié au salaire  $s$  par la relation

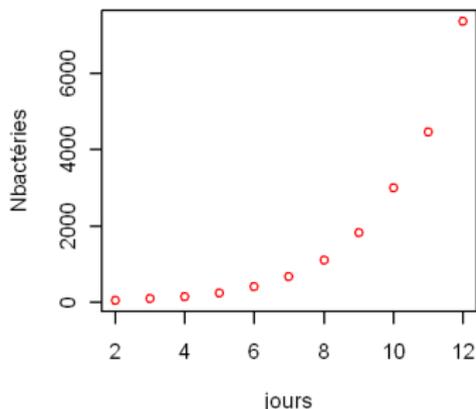
$$N(s) = e^{-2.305 \ln(s) + 37.241} = 1.491286 \times (10^{16})s^{-2.305}.$$

**Exemple 2.** En l'absence de mortalité, on souhaite décrire l'évolution dans le temps de la croissance d'une population de bactéries. Des numérations faites tous les jours à partir du 2<sup>e</sup> donne les résultats suivants:

# 6.L'ajustement, régression simple

$t_i$ (jours)	2	3	4	5	6	7	8	9	10
$N_i$ (bactéries)	55	90	135	245	403	665	1100	1810	3000

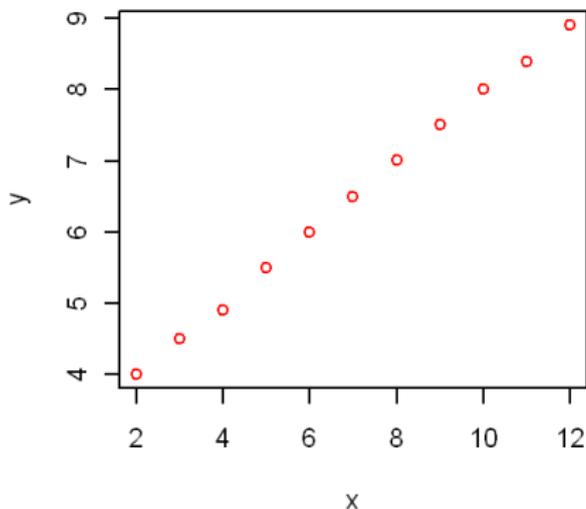
$t_i$ (jours)	11	12
$N_i$ (bactéries)	4450	7350



## 6.L'ajustement, régression simple

Le nombre de bactéries croît de manière rapide (exponentielle). On peut donc déduire que le coefficient de corrélation linéaire entre le nombre de bactéries  $N$  et la variable temps  $t$  est positif; en effet on trouve  $r = 0.8596725$ . Pour expliquer  $N$  en fonction de  $t$ , nous allons faire une transformation logarithmique seulement de la variable  $N$  (car c'est la variable qui a des valeurs très grandes). En effet en posant  $y = \ln(N)$ ,  $x = t$  (jours) on obtient

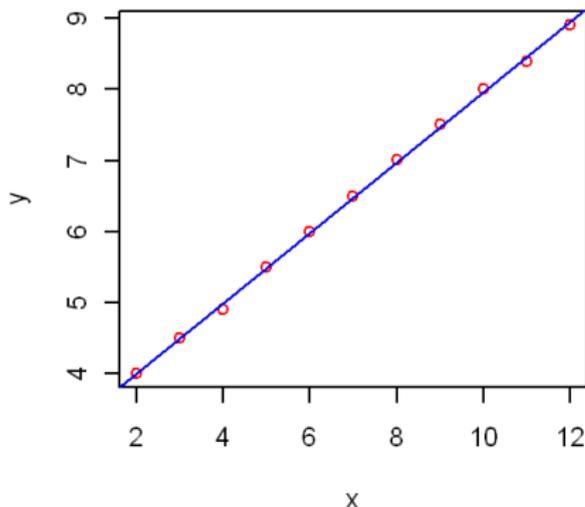
## 6.L'ajustement, régression simple



Le coefficient de corrélation linéaire est  $r = 0.9916918$ . Un ajustement linéaire de  $y$  en  $x$  est bien justifié.

## 6.L'ajustement, régression simple

On trouve  $\hat{b} = 3.014$  et  $\hat{a} = 0.494$ . La droite des moindres carrés est donnée par  $y = 0.494x + 3.014$ .



## 6.L'ajustement, régression simple

La somme des carrés des résidus  $SSR = 0.04499$  est très faible.

Le coefficient  $R^2 = 0.9993$  est très proche de 1, on peut donc affirmer que l'ajustement est de très bonne qualité.

En résumé, on déduit que l'évolution du nombre de bactéries en fonction des jours suit l'équation

$$N(t) = e^{0.494t+3.014} = 20.36871e^{0.494t}.$$

# 7. Estimation statistique

L'estimation a pour but de chercher, à travers l'examen d'un échantillon, une information quantitative à propos d'un paramètre.

## Definition

L'estimation est dite **ponctuelle** lorsque l'on se propose de substituer à la valeur  $\theta$  un nombre unique  $\hat{\theta}$  construit à partir d'un échantillonnage.

Exemple:  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  est un estimateur ponctuel de la moyenne  $m$ .

# 7. Estimation statistique

## Definition

L' estimation est dite par **intervalle de confiance** lorsque l'on se propose de construire à partir de l'échantillon un intervalle  $[a, b]$  qui peut contenir  $\theta$  avec une probabilité  $1 - \alpha$

$$P(a \leq \theta \leq b) = 1 - \alpha,$$

$\alpha$  fixé à l'avance. On dit alors que  $[a, b]$  est un **intervalle de confiance au niveau  $\alpha$**  pour  $\theta$ .

# 7. Estimation statistique

## 7.1 Estimation ponctuelle des paramètres

### Estimateur d'une proportion

Soit une population de taille  $N$  constituée de deux catégories A (atteints d'une maladie M) et B (non atteints de la maladie M) d'individus dans des proportions  $p$  et  $q$  respectivement, avec  $p$  et  $q$  sont inconnues. Comme  $p + q = 1$  il n'y a qu'un seul paramètre pour caractériser la structure de cette population. On identifie par exemple  $p$ . Pour cela on prélève dans la population un échantillon aléatoire de taille  $n$ ; si  $n_1$  est le nombre d'individu présentant le caractère A.  $f = \frac{n_1}{n}$  est la proportion du caractère A dans l'échantillon (ou effectif relatif).

## 7. Estimation statistique

L'entier  $n_1$  est l'observation d'une variable aléatoire  $X$  et  $f$  est l'observation de la variable aléatoire  $Y = \frac{X}{n}$ . On suppose l'échantillon non exhaustive (tirage avec remise), donc  $X$  suit une loi binomiale  $B(n, p)$ .

Donc

$$E(Y) = p$$
$$\sigma(Y) = \sqrt{\frac{p(1-p)}{n}}.$$

C'est à dire que la variable aléatoire fluctue autour de  $p$  avec un écart type qui tend vers 0 lorsque  $n$  tend vers l'infini.

## 7. Estimation statistique

Dans ce cas on dit que  $Y$  est un estimateur consistant de  $p$  et que l'observation  $f$  de  $Y$  est une estimation consistante de  $p$  et on écrit

$$\hat{p} = f = \frac{n_1}{n}.$$

Remarque. Si l'échantillon est exhaustive (tirage sans remise) on montre que

$$E(Y) = p$$

$$\sigma(Y) = \sqrt{\frac{N-n}{N-1} \frac{p(1-p)}{n}}.$$

# 7. Estimation statistique

## 7.2 Estimation par intervalle de confiance

Soit  $\hat{\theta}$  un estimateur de  $\theta$ , la construction d'un intervalle de confiance est basée sur un **pivot**  $p_V = f(\hat{\theta})$ , dont la loi ne dépend pas de  $\theta$ .

### 1. Intervalle de confiance d'une proportion

On suppose que  $n \geq 100$  et que  $p$  n'est pas proche de 0 ni de 1 ( $0.1 \leq p \leq 0.9$ ). Dans ce cas  $X$  est assimilée à une variable de **Gauss**, il en est de même pour  $Y$ .

Les deux variables

$$Z = \frac{Y - p}{\sqrt{\frac{p(1-p)}{n}}} \text{ et } T = \frac{Y - p}{\sqrt{\frac{f(1-f)}{n}}}.$$

sont assimilées à une loi centré réduite de **Gauss**  $N(0,1)$ .

On fixe  $\alpha$  (**0.01** ou **0.05**) et on lit dans la table de **Gauss**  $u_{1-\alpha/2}$  tel que  $P(|N(0,1)| \leq u_{1-\alpha/2}) = 1 - \alpha$ , c'est dire que

$P(|T| \leq u_{1-\alpha/2}) = 1 - \alpha$  ou encore

$$P\left(Y - u_{1-\alpha/2} \sqrt{\frac{f(1-f)}{n}} \leq p \leq Y + u_{1-\alpha/2} \sqrt{\frac{f(1-f)}{n}}\right) = 1 - \alpha$$

# 7. Estimation statistique

Par conséquent l'intervalle de confiance de  $p$  au niveau de signification  $\alpha$  est donné par

$$I_p = \left[ f - u_{1-\alpha/2} \sqrt{\frac{f(1-f)}{n}}, f + u_{1-\alpha/2} \sqrt{\frac{f(1-f)}{n}} \right].$$

2. Intervalle de confiance pour la moyenne d'une population gaussienne

On suppose que  $X_i \rightsquigarrow N(m, \sigma^2)$ ,  $1 \leq i \leq n$ .

•  $\sigma$  connu

Le pivot est donné par  $p_v = \sqrt{n} \frac{\bar{X} - m}{\sigma}$ , avec  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ .

## 7. Estimation statistique

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \rightsquigarrow N(m, \sigma^2/n), \text{ donc } pv \rightsquigarrow N(0, 1).$$

On lit alors dans la table de Gauss le quantile  $u_{1-\frac{\alpha}{2}}$  tel que

$$P(N(0, 1) \in [-u_{1-\frac{\alpha}{2}}, u_{1-\frac{\alpha}{2}}]) = 1 - \alpha \text{ donc}$$

$$P(pv \in [-u_{1-\frac{\alpha}{2}}, u_{1-\frac{\alpha}{2}}]) = 1 - \alpha, \text{ par conséquent}$$

$$P(m \in [\bar{X} - u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}, \bar{X} + u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}]) = 1 - \alpha.$$

Donc l' **intervalle de confiance au niveau  $\alpha$  pour  $m$**  est donné par

$$I_\alpha = \left[ \bar{x} - u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}, \bar{x} + u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \right]. \quad (22)$$

# 7. Estimation statistique

- $\sigma$  inconnu

L'intervalle ci-dessus est inutilisable car il dépend de  $\sigma$ , donc il faut estimer ce dernier, le pivot est donné par  $p_v = \sqrt{n} \frac{\bar{X} - m}{S}$ , où  $S^2 = \frac{1}{n-1} \sum_1^n (X_i - \bar{X})^2$ , qui est un estimateur empirique et sans biais de la variance  $\sigma^2$ .

On a  $\frac{(n-1)S^2}{\sigma^2} \rightsquigarrow \chi^2(n-1)$ , et donc  $p_v \rightsquigarrow t(n-1)$ , loi de Student à  $(n-1)$  degrés de liberté. On lit alors dans la table de Student  $t_{1-\frac{\alpha}{2}}$  tel que  $P(t(n-1) \in [-t_{1-\frac{\alpha}{2}}, t_{1-\frac{\alpha}{2}}]) = 1 - \alpha$ ;

l'intervalle de confiance au niveau  $\alpha$  pour  $m$  est alors donné par

$$I'_\alpha = \left[ \bar{X} - t_{1-\frac{\alpha}{2}} \frac{S}{\sqrt{n}}, \bar{X} + t_{1-\frac{\alpha}{2}} \frac{S}{\sqrt{n}} \right]. \quad (23)$$

# 7. Estimation statistique

## 3. Intervalle de confiance pour la variance d'une population gaussienne

On a le pivot  $p_v = \frac{(n-1)S^2}{\sigma^2} \rightsquigarrow \chi^2(n-1)$ , loi de Khi-deux à  $(n-1)$  degrés de liberté. On lit alors dans la table de Khi-deux  $x_a$  et  $x_b$  tels que  $P(x_a \leq \chi^2(n-1) \leq x_b) = 1 - \alpha$ .

L'intervalle de confiance au niveau  $\alpha$  pour  $\sigma^2$  est donné par

$$I_v = \left[ \frac{(n-1)s^2}{x_b}, \frac{(n-1)s^2}{x_a} \right].$$

# 8. Tests d'hypothèses

## Definition

Les tests d'hypothèses servent à valider une caractéristique d'une population à travers l'examen d'un échantillon, ils sont aussi utilisés pour comparer des caractéristiques entre plusieurs populations.

## 8.1 Test de conformité

1. **Test de conformité d'une proportion:** Il s'agit de comparer une proportion théorique  $p_0$  à une proportion observée. On effectue le test suivant

$$\left\{ \begin{array}{l} H_0 : p_0 \text{ est la proportion des individus de la population} \\ \quad \text{de la catégorie A} \\ \text{contre} \\ H_1 : \text{non } H_0 \end{array} \right.$$

# 8. Tests d'hypothèses

ou encore

$$\left\{ \begin{array}{l} H_0 : p = p_0 \\ \text{contre} \\ H_1 : p \neq p_0 \end{array} \right.$$

On prélève un échantillon aléatoire non exhaustive de taille  $n$  dans lequel la proportion des individus de la catégorie A est  $f = \frac{n_1}{n}$ .

$$\text{Sous } H_0 : \frac{Y - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} \rightsquigarrow N(0, 1).$$

On fixe  $\alpha$  (0.01 ou 0.05) et on lit dans la table de Gauss  $u_{1-\alpha/2}$  tel que

## 8. Tests d'hypothèses

$$P(|N(0, 1)| > u_{1-\alpha/2}) = \alpha.$$

l'intervalle critique au seuil  $\alpha$  est donné par

$$I_c = ]-\infty, p_0 - u_{1-\alpha/2} \sqrt{\frac{p_0(1-p_0)}{n}}] \cup [p_0 + u_{1-\alpha/2} \sqrt{\frac{p_0(1-p_0)}{n}}, +\infty[$$

Décision : si  $f \in I_c$  on rejette  $H_0$ .

# 8. Tests d'hypothèses

## 2. Test de conformité d'une moyenne

On attribue la valeur  $m_0$  pour moyenne du caractère dans une population et on veut juger le bien fondé de cette hypothèse en se basant sur un échantillon. On effectue alors le test d'hypothèse:

$$\left\{ \begin{array}{l} H_0 : m = m_0 \\ \text{contre} \\ H_1 : m \neq m_0 \end{array} \right.$$

où  $m$  est la moyenne théorique.

On considère alors  $\sqrt{n} \frac{\bar{X} - m_0}{S}$  qui suit, sous  $H_0$ , une loi de Student à  $(n-1)$  degrés de liberté.

# 8. Tests d'hypothèses

Soit le quantile  $t_{1-\frac{\alpha}{2}}$  tel que

$$P(t(n-1) \in [-t_{1-\frac{\alpha}{2}}, t_{1-\frac{\alpha}{2}}]) = 1 - \alpha.$$

Si  $\left| \sqrt{n} \frac{\bar{X} - m_0}{S} \right| \leq t_{1-\frac{\alpha}{2}}$  alors on ne peut pas refuser  $H_0$  au seuil de signification  $\alpha$ .

## 3. Test de conformité d'une variance

C'est la comparaison d'une **variance théorique** et d'une **variance observée**: on **attribue** la valeur  $\sigma_0^2$  pour variance du caractère dans une population et on veut **juger** le bien fondé de cette hypothèse en se basant sur un échantillon. On effectue alors le test d'hypothèse:

# 8. Tests d'hypothèses

$\left\{ \begin{array}{l} H_0 : \text{ la variance du caractère dans la population est } \sigma_0^2 \\ \text{contre} \\ H_1 : \text{ non } H_0. \end{array} \right.$

Sous  $H_0$ ,  $\frac{(n-1)S^2}{\sigma_0^2} \rightsquigarrow \chi^2(n-1)$  donc

si  $\frac{(n-1)S^2}{\sigma_0^2} \in [x_a, x_b]$  alors on ne peut pas refuser l'hypothèse  $H_0$ .

# 8. Tests d'hypothèses

## 8.2 Tests d'homogénéité

### 1. Comparaison de deux proportions:

Il s'agit de **comparer deux proportions observées**. Soit deux échantillons aléatoire  $E_1$  et  $E_2$  extraits des deux populations  $P_1$  et  $P_2$  constituées des individus des deux seules catégories A et B. Soit  $f_1 = \frac{k_1}{n_1}$  et  $f_2 = \frac{k_2}{n_2}$  les proportions des individus de la catégorie A dans  $E_1$  et  $E_2$  respectivement. En général  $f_1 \neq f_2$ ; il s'agit d'expliquer cette différence.

## 8. Tests d'hypothèses

On effectue le test d'hypothèse suivant:

$$\left\{ \begin{array}{l} H_0 : \text{Dans } P_1 \text{ et } P_2 \text{ il y a la même proportion } p_0 \\ \text{(inconnue) d'individus de la catégorie A} \\ \text{contre} \\ H_1 : \text{non } H_0 \end{array} \right.$$

On considère  $D = Y_1 - Y_2$ , avec  $f_i$  est l'observation de la variable aléatoire  $Y_i$ .

Sous  $H_0$   $\frac{Y - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} D \rightsquigarrow N(0, \sigma_D^2)$  où

$$\sigma_D^2 = p_0(1 - p_0) \left( \frac{1}{n_1} + \frac{1}{n_2} \right). \quad (24)$$

## 8. Tests d'hypothèses

Mais  $p_0$  est inconnue et on peut l'estimer par

$$\frac{k_1 + k_2}{n_1 + n_2} = \frac{n_1 f_1 + n_2 f_2}{n_1 + n_2},$$

ainsi  $\sigma_D^2$  est estimée par

$$\begin{aligned}\hat{\sigma}_D^2 &= \frac{n_1 f_1 + n_2 f_2}{n_1 + n_2} \left(1 - \frac{n_1 f_1 + n_2 f_2}{n_1 + n_2}\right) \left(\frac{1}{n_1} + \frac{1}{n_2}\right) \\ &= \frac{(n_1 f_1 + n_2 f_2)(n_1(1 - f_1) + n_2(1 - f_2))}{(n_1 + n_2)n_1 n_2}.\end{aligned}$$

On fixe  $\alpha$  (0.01 ou 0.05) et on lit dans [la table de Gauss](#)

$u_{1-\alpha/2}$  tel que  $P(|N(0, 1)| > u_{1-\alpha/2}) = \alpha$ ;

Décision : Si  $\frac{|D|}{\hat{\sigma}_D} = \frac{|f_1 - f_2|}{\hat{\sigma}_D} \geq u_{1-\alpha/2}$  on rejette  $H_0$ .

# 8. Tests d'hypothèses

## 2. Comparaison des moyennes de deux échantillons indépendants

Soient deux échantillons aléatoires d'observations provenant de deux populations  $P_1$  et  $P_2$  et de moyenne  $\bar{X}$  et  $\bar{Y}$  respectivement. En général  $\bar{X} \neq \bar{Y}$ , il s'agit d'expliquer cette différence.

On suppose que  $X \rightsquigarrow N(m_x, \sigma_x^2)$ ,  $Y \rightsquigarrow N(m_y, \sigma_y^2)$ ,  $X$  et  $Y$  sont deux échantillons indépendants, on désire effectuer le test

$$\left\{ \begin{array}{l} H_0 : m_x = m_y \\ \text{contre} \\ H_1 : m_x \neq m_y. \end{array} \right.$$

## 8. Tests d'hypothèses

On utilise  $D = \bar{X} - \bar{Y}$ , qui est un bon indicateur de l'écart entre les deux moyennes.

- Cas  $\sigma_x^2$  et  $\sigma_y^2$  connues:

Sous  $H_0$  :  $\frac{D}{\sqrt{\frac{\sigma_x^2}{n_x} + \frac{\sigma_y^2}{n_y}}} \rightsquigarrow N(0, 1)$ , on fixe  $\alpha$  (0.01 ou 0.05) et on

lit dans la **table de Gauss**  $u_{1-\alpha/2}$  tel que

$P(|N(0, 1)| > u_{1-\alpha/2}) = \alpha$ , l'intervalle critique au seuil  $\alpha$  est donné par

$$I_m = ] -\infty, -u_{1-\alpha/2} \sqrt{\frac{\sigma_x^2}{n_x} + \frac{\sigma_y^2}{n_y}} ] \cup [ u_{1-\alpha/2} \sqrt{\frac{\sigma_x^2}{n_x} + \frac{\sigma_y^2}{n_y}}, +\infty [,$$

décision : si  $d = \bar{x} - \bar{y} \in I_m$  on rejette  $H_0$ .

# 8. Tests d'hypothèses

- Cas  $\sigma_x^2$  et  $\sigma_y^2$  inconnues:

On suppose que les échantillons sont grands ( $n_x \geq 30$  et  $n_y \geq 30$ ) : On peut remplacer  $\sigma_x^2$  (resp.  $\sigma_y^2$ ) par

$S_x^2 = \frac{1}{n_x-1} \sum_1^{n_x} (X_i - \bar{X})^2$  (resp.  $S_y^2$ ), et donc l'intervalle critique au seuil  $\alpha$  est donné par

$$I_m = ] - \infty, -u_{1-\alpha/2} \sqrt{\frac{s_x^2}{n_x} + \frac{s_y^2}{n_y}} \cup [u_{1-\alpha/2} \sqrt{\frac{s_x^2}{n_x} + \frac{s_y^2}{n_y}}, \infty[, \quad (25)$$

décision : si  $d = \bar{x} - \bar{y} \in I_m$  on rejette  $H_0$ .

# 8. Tests d'hypothèses

## 3. Comparaison des moyennes de deux séries appariées

Soient deux séries de  $n$  observations  $X_1, \dots, X_n$  de moyenne  $\bar{X}$  et  $Y_1, \dots, Y_n$  de moyenne  $\bar{Y}$ . Ici l'observation  $X_i$  est appariée à  $Y_i$ . On pose

$$D_i = X_i - Y_i, S_D^2 = \frac{1}{n-1} \sum_{i=1}^n (D_i - \bar{D})^2, \bar{D} = \frac{1}{n} \sum_{i=1}^n D_i.$$

Pour tester

$$\left\{ \begin{array}{l} H_0 : m_x = m_y \\ \text{contre} \\ H_1 : m_x \neq m_y, \end{array} \right.$$

on considère  $T = \sqrt{n} \frac{\bar{D}}{S_D}$ .

## 8. Tests d'hypothèses

Si  $n$  est grand, disons supérieur à 30,  $T$  est assimilée à une variable centrée réduite de Gauss; si  $n$  est petit et si  $D$  suit une loi de Gauss,  $T$  suit une loi de Student à  $(n - 1)$  degrés de liberté.

# 8. Tests d'hypothèses

## 4. Comparaison des variances de deux échantillons indépendants

On veut tester

$$\left\{ \begin{array}{l} H_0 : \sigma_x^2 = \sigma_y^2 \\ \text{contre} \\ H_1 : \sigma_x^2 \neq \sigma_y^2. \end{array} \right.$$

On calcule les rapports  $\frac{S_x^2}{S_y^2}$  et  $\frac{S_y^2}{S_x^2}$  et on considère le plus grand parmi les deux:

## 8. Tests d'hypothèses

- Si  $\frac{S_x^2}{S_y^2} > \frac{S_y^2}{S_x^2}$ , on décidera à l'aide du rapport  $\frac{S_x^2}{S_y^2}$ , comme suit:  
on a sous  $H_0$  :  $\frac{S_x^2}{S_y^2} \rightsquigarrow F(n_x - 1, n_y - 1)$ , loi de Fisher-Snédecor à  $(n_x - 1, n_y - 1)$  degrés de liberté, donc l'intervalle critique au seuil  $\alpha$  est donné par

$$I_\alpha = [f_\alpha, \infty[, \text{ avec } P(F(n_x - 1, n_y - 1) > f_\alpha) = \alpha, \quad (26)$$

décision : si  $\frac{S_x^2}{S_y^2} \in I_\alpha$  on rejette  $H_0$ .

## 8. Tests d'hypothèses

- Si  $\frac{S_x^2}{S_y^2} \leq \frac{S_y^2}{S_x^2}$ , on décidera à l'aide du rapport  $\frac{S_y^2}{S_x^2}$ , comme suit:  
on a sous  $H_0 : \frac{S_y^2}{S_x^2} \rightsquigarrow F(n_y - 1, n_x - 1)$ , loi de Fisher-Snédecor à  $(n_y - 1, n_x - 1)$  degrés de liberté, donc l'intervalle critique au seuil  $\alpha$  est donné par

$$I_\alpha = [f_\alpha, +\infty[, \text{ avec } P(F(n_y - 1, n_x - 1) > f_\alpha) = \alpha,$$

décision : si  $\frac{S_y^2}{S_x^2} \in I_\alpha$  on rejette  $H_0$ .