

## 2.3 Valeurs caractéristiques

# Mesure de tendance centrale

**Définition:** L'**espérance** d'une variable aléatoire  $X$  est

$$\mathbb{E}(X) = \begin{cases} \sum_i x_i f_X(x_i), & X \text{ discrète,} \\ \int_{-\infty}^{\infty} x f_X(x) dx, & X \text{ continue,} \end{cases}$$

si la somme/intégrale converge

**Propriétés :**

- si  $X_1, \dots, X_n$  sont des variables aléatoires et  $a, b_1, \dots, b_n$  des constantes, alors

$$\mathbb{E} \left( a + \sum_{i=1}^n b_i X_i \right) = a + \sum_{i=1}^n b_i \mathbb{E}(X_i)$$

- pour  $g$  fonction 'raisonnable',  $\mathbb{E}\{g(X)\} = \begin{cases} \sum_i g(x_i) f_X(x_i), & X \text{ discrète} \\ \int_{-\infty}^{\infty} g(x) f_X(x) dx, & X \text{ continue} \end{cases}$
- Si  $X, Y$  sont des variables aléatoires on définit  $\mathbb{E}[g(X, Y)]$  de la même manière à l'aide de  $f_{X,Y}$
- si  $X, Y$  sont indépendantes et  $g, h$  des fonctions 'raisonnables', alors

$$\mathbb{E}\{g(X)h(Y)\} = \mathbb{E}\{g(X)\}\mathbb{E}\{h(Y)\}$$

## Exemple binomial

**Exemple** Pour  $X \sim \mathcal{B}(m, p)$ , trouver  $\mathbb{E}(X)$ .

## Exemple Poisson

**Exemple** Pour  $X \sim \text{Poiss}(\lambda)$ , trouver  $\mathbb{E}(X)$  et  $\mathbb{E}\{X(X - 1)\}$ .

## Exemples

**Exemple** Soit  $X \sim \mathcal{N}(\mu, \sigma^2)$ , trouver  $\mathbb{E}(X)$ .

# Mesure de dispersion

**Définition:** La **variance** d'une variable aléatoire  $X$  est définie comme

$$\text{var}(X) = \mathbb{E}[\{X - \mathbb{E}(X)\}^2] = \dots = \mathbb{E}(X^2) - \mathbb{E}(X)^2$$

**Propriétés :**

- Interprétation physique : variance  $\equiv$  moment d'inertie relatif au centre de masse
- $\text{var}(X) \geq 0$ , et  $\text{var}(X) = 0$  implique que  $X$  est constante
- la **déviatiion standard** de  $X$  est définie comme  $\text{sd}(X) = \sqrt{\text{var}(X)} \geq 0$
- si  $a, b$  sont des constantes, alors  $\text{var}(a + bX) = b^2 \text{var}(X)$
- si  $X_1, \dots, X_n$  sont indépendantes et  $a, b_1, \dots, b_n$  des constantes, alors

$$\text{var} \left( a + \sum_{i=1}^n b_i X_i \right) = \sum_{i=1}^n b_i^2 \text{var}(X_i)$$

**Exemple** Si  $X \sim \text{Pois}(\lambda)$ , montrer que  $\text{var}(X) = \lambda$ .

**Exemple** Si  $X \sim \mathcal{B}(m, p)$ , montrer que  $\text{var}(X) = m p(1 - p)$ .

**Exemple** Si  $X \sim \mathcal{N}(\mu, \sigma^2)$ , montrer que  $\text{var}(X) = \sigma^2$ .

## Exemples : variance

**Exemple** Si  $X \sim \text{Poiss}(\lambda)$ , montrer que  $\text{var}(X) = \lambda$ .

**Exemple** Si  $X \sim \mathcal{B}(m, p)$ , montrer que  $\text{var}(X) = m p(1 - p)$ .

## Exemple variance loi normale

**Exemple** Si  $X \sim \mathcal{N}(\mu, \sigma^2)$ , montrer que  $\text{var}(X) = \sigma^2$ .

# Covariance

**Définition:** La **covariance** des variables aléatoires  $X, Y$  est

$$\text{cov}(X, Y) = \mathbb{E}[\{X - \mathbb{E}(X)\}\{Y - \mathbb{E}(Y)\}] = \dots = \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y).$$

**Interprétation :** C'est une mesure de dépendance **linéaire** entre  $X$  et  $Y$

**Propriétés :**

- la covariance dépend des unités dont on mesure  $X, Y$
- $\text{cov}(X, Y) = \text{cov}(Y, X)$
- $\text{cov}(X, X) = \text{var}(X)$
- $\text{cov}(X + Y, Z + W) = \text{cov}(X, Z) + \text{cov}(Y, Z) + \text{cov}(X, W) + \text{cov}(Y, W)$
- si  $a, b, c, d$  sont des constantes, alors  
 $\text{cov}(aX + b, cY + d) = ac \text{cov}(X, Y)$
- $\text{var}(X \pm Y) = \text{var}(X) + \text{var}(Y) \pm 2\text{cov}(X, Y)$
- si  $X$  et  $Y$  sont indépendantes, alors  $\text{cov}(X, Y) = 0$ . Mais attention, l'inverse **n'est pas vraie** en général !

## Exemple

**Exemple** (voir diapositive 123) Soient  $X$  et  $Y$  de densité conjointe

$$f_{X,Y}(x,y) = \begin{cases} x+y & \text{si } 0 < x < 1, 0 < y < 1, \\ 0 & \text{sinon.} \end{cases}$$

Trouver  $\text{Var}(X)$ ,  $\text{Var}(Y)$ , et  $\text{Cov}(X, Y)$ .

# Corrélation

**Définition:** La **corrélation** de  $X$  et  $Y$  est

$$\rho_{X,Y} = \rho(X, Y) = \text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{\sqrt{\text{var}(X)\text{var}(Y)}}$$

(zéro si une des variances est zéro).

**Propriétés :**

- $\rho_{X,Y}$  mesure la dépendance **linéaire** (et seulement linéaire !) entre  $X$  et  $Y$
- $\rho(a + bX, c + dY) = \text{sign}(bd)\rho(X, Y)$
- $\text{corr}(X, Y) = \text{corr}(Y, X)$
- $\text{corr}(X, X) = 1$  (si  $X$  n'est pas constante)
- $\text{corr}(X, -X) = -1$  (si  $X$  n'est pas constante)
- $-1 \leq \text{corr}(X, Y) \leq 1$  (inégalité de Cauchy-Schwarz)
- si  $X$  et  $Y$  sont indépendantes, alors  $\text{corr}(X, Y) = 0$ , mais la réciproque est faux !
- corrélation  $\neq$  causalité !


## Corrélation empirique

Version empirique (si  $\Pr((X = x_i, Y = y_i) = 1/n$  pour  $i = 1, \dots, n$ )

$$\frac{n^{-1} \sum_{j=1}^n (x_j - \bar{x})(y_j - \bar{y})}{\left\{ n^{-1} \sum_{j=1}^n (x_j - \bar{x})^2 \times n^{-1} \sum_{j=1}^n (y_j - \bar{y})^2 \right\}^{1/2}},$$



## Exemple : ozone atmosphérique

Prof. Isabelle Bey (SIE) : observations de la concentration d'ozone au Jungfraujoch de janvier 1987 à décembre 2005 (quelques valeurs manquantes), et résultats d'une modélisation.



La modélisation vous paraît-elle bonne ?

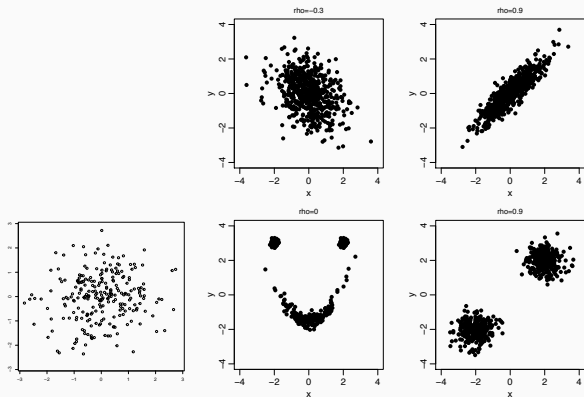
## Exemple : ozone atmosphérique



La corrélation empirique est  $\rho = 0.707$ .



# Limitations de la corrélation

- $\rho$  mesure la dépendance linéaire (panneaux supérieurs)
- On peut avoir  $\rho \approx 0$ , mais dépendance forte mais non-linéaire (en bas au milieu)
- Une corrélation pourrait être forte mais **specieuse**, comme en bas à droite, où deux sous-groupes, chacun sans corrélation, sont combinés
- Une corrélation entre deux variables n'implique pas une causalité entre elles



## Corrélation $\neq$ causalité

Deux variables peuvent être très corrélées sans lien de causalité. Le graphique à gauche ici montre une corrélation forte entre le nombre de naissances et les mâts de communication dans les villes anglaises ...



## Danger !

- Les espérances/variances/covariances/corrélations ne sont pas définies si les intégrales/sommes ne convergent pas
- Ceci est notamment le cas lorsque la distribution de  $X$  a des **queues lourdes** : la densité de  $X$  décroît trop lentement vers zéro, et  $X$  a une probabilité élevée de prendre des valeurs énormes.

### Exemple

- Considérons la fonction de densité  $f(x) = \alpha x^{-1-\alpha}$  sur  $[1, \infty)$  et  $f(x) = 0$  pour  $x < 1$  (loi **Pareto**). Pour  $r \in \mathbb{R}$  on a

$$\mathbb{E}(X^r) = \alpha \int_1^{\infty} x^{r-1-\alpha} dx = \begin{cases} \frac{\alpha}{\alpha-r} & r < \alpha \\ \infty & r \geq \alpha \end{cases}$$

- En particulier,  $\mathbb{E}(X) < \infty$  si et seulement si  $\alpha > 1$ , et  $\text{var}(X) < \infty$  si et seulement si  $\alpha > 2$
- Pour  $\alpha$  petit la densité tend lentement vers zéro

## Espérance d'une variable aléatoire mixte

**Théorème de l'espérance totale** Pour une partition  $A_1, A_2, \dots$

$$\mathbb{E}(X) = \sum_i \mathbb{E}(X|A_i)\Pr(A_i)$$

**Exemple : pluie (diapositive 112)** La probabilité qu'il pleuve pendant la journée est 0.2. S'il pleut, la quantité de pluie qui tombe suit une loi exponentielle de paramètre  $\lambda = 0.05\text{mm}^{-1}$ . Trouver l'espérance de la quantité de pluie journalière.

**Définition:** Soit  $0 < p < 1$ . On définit le  $p$ ième **quantile** d'une fonction de répartition  $F$  par

$$x_p = \inf\{x : F(x) \geq p\}$$

- Pour des variables aléatoires continues,  $F(x_p) = p$ , donc  $x_p$  est tel que  $\Pr(X \leq x_p) = p$
- Pour la plupart des variables aléatoires continues, ceci implique que  $x_p = F^{-1}(p)$ , où  $F^{-1}$  est la fonction inverse de  $F$
- "La plupart" : celles ayant une fonction de densité strictement positive (sur  $\{x : 0 < F(x) < 1\}$ )
- Pour des variables aléatoires discrètes la situation est plus complexe
- Les quantiles empiriques (diapositive 35) sont des estimations (cf les prochains cours) des quantiles à partir des données à disposition.

En particulier, on appelle le 0.5ème quantile la **médiane** de  $F$



## Exemple quantiles

**Exemple** Calculer les quantiles des lois (a)  $U(a, b)$ , (b) Pareto  
(diapositive [141](#))