

Statistiques, séance n° 2

EPITA

Mars Avril 2020

Objectif de ce cours

- Description de données en deux dimension
- Cf. le support en R

Données numériques

- **Exemples, données extraites de victimes d'un infarctus du myocarde arrivant dans un service de cardiologie, (G. Saporta, données de J.P. Nakache)**
- **Variables observées**
 - Fréquence cardiaque
 - Index cardiaque
 - Index systolique
 - Pression diastolique
 - Pression artérielle pulmonaire
 - Pression ventriculaire
 - Résistance pulmonaire

Matrices de variance – covariance et de corrélation

- Pour des échantillons (x_i) et (y_i)

- Ecart types :

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

$$s_y^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2$$

- Covariance (observée !)

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

- Coefficient de corrélation linéaire

$$r_{xy} = \frac{1}{ns_x s_y} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

Caractère représentatif du coefficient de corrélation mesuré

- On suppose que X et Y sont deux V.A. indépendantes
- On observe (x_i) et (y_i) l'indice i représentant une même observation « simultanée » des deux variables
- On suppose qu'il y a plus de 100 observations ($n \geq 100$)
- Le coefficient de corrélation linéaire est alors une V.A. qui suit, approximativement, une loi normale, de moyenne 0 et d'écart type $\frac{1}{\sqrt{n-1}}$

Tableaux de contingence

- Cf. démonstration en R