

Rappel :

## 5. Ajustement, corrélation et régression

### a. Ajustement linéaire – Droites de régression

Méthode des moindres carrés:

1<sup>er</sup> cas :

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

et

$$b = \bar{y} - a\bar{x}$$

2<sup>ème</sup> cas :

$$a' = \frac{\text{cov}(x, y)}{\sigma_x^2}$$

et

$$b' = \bar{x}' - a'\bar{y}$$

Angle entre D et D':

D :  $y = ax + b$       a: coeff de régression de y en x

D' :  $y = a'y + b'$       a': coeff de régression de x en y

ou encore :

$$y = \frac{1}{a'}x - \frac{b'}{a'}$$

on a :  $\theta = \text{Arctan}\left(\frac{1}{a'}\right) - \text{Arctan}(a)$

⇒

$$\tan \theta = \frac{1 - aa'}{a + a'}$$

On va considérer 2 cas limites :

- Si x et y sont indépendantes :  $\text{cov}(x, y) = 0$

donc  $a = a' \Rightarrow aa' = 0$

d'où  $\tan \theta = +\infty \Rightarrow \theta = 90^\circ$

Donc si x et y indépendantes alors D et D' sont perpendiculaires.

- Si x et y sont liées par un fonction de type linéaire :

alors les points  $(x_i, y_i)$  sont sur la droite qui est donc D et D', dans ce cas là :

$\frac{a}{a'} = a$  car c'est la même pente.      ⇒       $aa' = 1$

Règle générale :

$$0 \leq aa' \leq 1$$

Alors  $aa'$  sera la coefficient de corrélation linéaire.

### b. Coefficient de corrélation linéaire :

On a vu dans le chapitre sur les ajustements :

$\sigma_y^2 = \text{variance expliquée (VE)} + \text{variance résiduelle (VR)}$

On va partir de la variance de y :

$$\sigma_y^2 = \frac{1}{n} \sum_i \sum_j n_{ij} (y_j - \bar{y})^2$$

$$\sigma_y^2 = \frac{1}{n} \sum_i \sum_j n_{ij} ((y_j - y'_i) + (y'_i - \bar{y}))^2$$

$$\sigma_y^2 = \underbrace{\frac{1}{n} \sum_i \sum_j n_{ij} (y_j - y'_i)}_{VR} + \underbrace{\frac{1}{n} \sum_i \sum_j n_{ij} (y'_i - \bar{y})^2}_{VE} + \underbrace{\frac{2}{n} \sum_i \sum_j n_{ij} (y_j - y'_i)(y'_i - \bar{y})}_C$$

On veut montrer que  $\sigma y^2 = VR + VE$

Donc que  $C=0$  ?

On a

$$C = \frac{2}{n} \sum_i \sum_j nij (y_j - y'_i)(y'_i - \bar{y})$$
$$C = \frac{2}{n} \sum_i \sum_j nij (y_j - ax_i - b)(ax_i + b - \bar{y})$$

car  $y'_i = ax_i + b$

d'où

$$C = \frac{2a}{n} \sum_i \sum_j nij (y_j - ax_i - b)xi + \frac{2}{n}(b - \bar{y}) \sum_i \sum_j nij (y_j - ax_i - b)$$

$$\Rightarrow \frac{df(a,b)}{da} = 0 \qquad \Rightarrow \frac{df(a,b)}{db} = 0$$

donc  $C = 0$

De plus,

$$VE = \frac{1}{n} \sum_i \sum_j nij (y'_i - \bar{y})^2$$
$$VE = \frac{1}{n} \sum_i \sum_j nij (ax_i + b - a\bar{x} - b)^2$$
$$VE = \frac{1}{n} \sum_i \sum_j nij a^2(xi - \bar{x})^2 = \frac{a^2}{n} \sum_i \sum_j nij (xi - \bar{x})^2 = a^2 \sigma^2 x$$

On va poser :

$$R^2 = \frac{VE}{\sigma y^2} = \frac{a^2 \sigma x^2}{\sigma y^2}$$

Or :

$$a = \frac{cov(x, y)}{\sigma x^2}$$

donc :

$$R^2 = \frac{cov^2(x, y)}{\sigma x^4} * \frac{\sigma x^2}{\sigma y^2} = \frac{cov^2(x, y)}{\sigma x^2 \sigma y^2}$$

Remarques :

Si  $|R| \geq 0,9$  , on a alors une corrélation linéaire entre x et y (le nuage de points utilisé dans la représentation de y par rapport à x correspond à une droite)

On a :

$$aa' = \frac{cov(x, y)}{\sigma x^2}$$
$$\frac{cov(x, y)}{\sigma x^2} = \frac{cov^2(x, y)}{\sigma x^2 \sigma y^2} = R^2$$

Extension faible au cas non linéaire après un changement de variable de type log.

## Chapitre 4 : Séries chronologiques


### 1. Ajustement, corrélation et régression

#### a. Ajustement linéaire – Droites de régression

Une série chronologique correspond à une suite d'observations d'une variable quantitative ordonnées dans le temps.

Exemple: indices statistiques, prix du pétrole, production d'automobiles, consommation d'électricité ...

Représentation :



Notation :  $y_t$  ou  $y_i$  ou  $y=f(t)$

Temps doit correspondre à des intervalles réguliers.

Remarque : Il s'agit d'une série à caractère double  $(y_i, t_i)$  avec une seule valeur de  $y_i$  par  $t_i$

#### b. Composante d'une série chronologique

cf graphe sur le formulaire

On distingue 4 composantes:

1. Tendence générale (trend):

- c'est la courbe qui lisse la série
- donne l'équation à très long terme des phénomènes observés

2. Cycle :

- variation de type sinusoïdale autour de la tendance générale
- cela traduit la succession de phases sur un temps long : prospérité, crise, dépression, reprise...

On assimile le trend + cycle à des mouvements extra-saisonniers ou conjoncturel (noté  $C_t$ )

3. Variations saisonnières :  $S_t$

- mouvements courts de pics et de creux qui se répètent périodiquement
- dues aux saisons, congés, aux inégalités des différents mois.

4. Variations accidentelles :  $\varepsilon_t$

- dues à des circonstances imprévisibles : grèves, krach financiers
- c'est ce qui n'est pas expliqué par le mouvement conjoncturel

On parle aussi de variations résiduelles.