


Chapitre 3 : Ajustement de séries statistiques


On se donne une série statistique de valeurs x_i , (i variant de 1 à p), d'effectifs n_i .
 Cette série peut être discrète ou continue.
 On peut représenter ces séries sur des graphes :

Cas 1:



ou

Cas 2:



Problème : -identifier la forme de la courbe d'ajustement : droite ou parabole?
 -déterminer les équations de la courbe d'ajustement :

$$n_i = f(x_i) \quad \rightarrow \quad n_i = a \cdot x_i + b$$

$$\quad \quad \quad \rightarrow \quad n_i = a \cdot x_i^2 + b \cdot x_i + c$$

Ceci permet : -de remplacer les $2p$ valeurs (x_i, n_i) par seulement 2 ou 3 paramètres
 -de calculer des n_i par d'autres valeurs de x_i

Remarque :

On notera les effectifs par y_i pour revenir à la notation classique $y_i = f(x_i)$

1. Méthode de lissage

Ce n'est pas réellement une méthode d'ajustement car on ne donne pas directement l'équation de la courbe d'ajustement.

Cela permet de réduire les variations de la courbe (x_i, n_i) pour éventuellement faciliter ensuite la détermination de la courbe d'ajustement.

Il existe plusieurs méthodes : nous n'en voyons que deux

a. Méthode des points médians

Exemple : On a un phénomène économique qui a été observé sur 20 mois consécutifs.

Méthode : -tracer x_i, y_i

-déterminer les maxima locaux : A,B,C,D,E et F et on construit l'enveloppe supérieure

-déterminer les minima locaux : G,H,I,J,K et L et on construit l'enveloppe inférieure

-tracer un segment vertical pour chaque x_i

-déterminer les points médians entre les points supérieurs et inférieurs

Les variations de la courbe ainsi obtenues sont plus faibles par comparaison avec la courbe initiale.

Remarque : aspect subjectif selon la détermination des points minimaux et maximaux.

b. Méthode de la moyenne mobile

Méthode : on va remplacer y_i par :

$$y'_i = \frac{y_{i-1} + y_i + y_{i+1}}{3}$$

(Si on effectue une moyenne sur 3 points)

Sauf pour le premier point :

$$y'_i = \frac{y_1 + y_2}{2}$$

et le dernier point :

$$y'_p = \frac{y_{p-1} + y_p}{2}$$

Sur l'exemple du formulaire correspond au cours III les variations de y'_i sont plus faibles que celles de y_i .

Remarque : -choix subjectif à faire sur le nombre de points considérés (3,5,7,...)

-possibilité de pondérer ces moyennes :

$$y'_i = \frac{1 * y_{i-1} + 2 * y_i + 1 * y_{i+1}}{4}$$

2. Méthode d'ajustement

a. Méthode graphique

- Essentiellement pour un ajustement linéaire
- Méthode : on peut tracer une droite sur un papier calque et positionner cette droite pour avoir autant de points au dessus de la droite qu'en dessous. Ensuite, si on connaît deux points de cette droite, on peut en déduire l'équation de cette dernière.

Remarque : méthode subjective.

b. Méthode des moindres carrés

Méthode :

- Sur la courbe d'ajustement, on note y'_i les valeurs ajustées de y_i
- L'écart de y_i par rapport à cette courbe est dessiné par la quantité suivante:

$$\sum_{i=1}^p (y_i - y'_i)^2$$

- Une fois la forme de la courbe d'ajustement (droite, parabole, exponentielle...), on va chercher les paramètres de l'équation considérée qui minimise la quantité $\sum_{i=1}^p (y_i - y'_i)^2$.

Remarque : - Pas de subjectivité de la méthode (tous les logiciels vont donner le même résultat).

- Notation : $\sum_{i=1}^p (y_i)$ est notée $\sum_y y_i$ et dans certains cas $\sum y$

Rappels : - $\sum_y y_i = p\bar{y}$

$$- \sum_i (y_i - \bar{y})^2 = p \sigma^2 = \sum_i (y_i)^2 - \frac{1}{p} (\sum_i y_i)^2$$

On va exposer la méthode sur 4 exemples simples mais la méthode des moindres carrés peut se généraliser à des fonctions plus compliquées.

α) Ajustement à l'aide d'une parabole

Problème : Courbe ajustée est une droite d'équation $y = ax + b$

Ici, on notera $y'_i = ax_i + b$

On va chercher à minimiser la quantité :

$$\sum_i (y_i - ax_i - b)^2$$

(on veut trouver a et b pour que cette quantité soit la plus petite possible.)
 La quantité $\sum_i (y_i - ax_i - b)^2$ dépend de a et de b \Rightarrow fonction de a et de b $\Rightarrow f(a,b)$.

Méthode :

$$\begin{aligned} \Rightarrow & \frac{df}{db} = 0 \\ \Rightarrow & \sum_i (y_i - ax_i - b) = 0 \\ \Rightarrow & \sum_i y_i = a \sum_i x_i + \sum_i b \\ \Rightarrow & \sum_i y_i = a \sum_i x_i + pb \end{aligned} \quad (1)$$

On divise (1) par p :

$$(1) \Rightarrow \bar{y} = a\bar{x} + b \quad (2)$$

(2) indique que le point (\bar{x}, \bar{y}) appartient à la droite ajustée

$$\begin{aligned} \Rightarrow & \frac{df}{db} = 0 \\ \Rightarrow & \sum_i (y_i - ax_i - b) x_i = 0 \\ \Rightarrow & \sum_i x_i y_i = a \sum_i x_i^2 + b \sum_i x_i \end{aligned} \quad (3)$$

$$\Rightarrow p \sum_i x_i y_i = ap (\sum_i x_i^2) + pb \sum_i x_i$$

d'où

$$a = \frac{p \sum_i x_i y_i - \sum_i x_i \sum_i y_i}{p \sum_i x_i^2 - (\sum_i x_i)^2} \quad (4)$$

et

$$b = \bar{y} - a\bar{x} \quad (5)$$

Autres écritures de a :

$$\begin{aligned} \Rightarrow & 4 * \frac{\frac{1}{p^2}}{\frac{1}{p^2}} \\ a &= \frac{\frac{1}{p} + \sum_i x_i y_i - \frac{\sum_i x_i}{p} * \frac{\sum_i y_i}{p}}{\frac{1}{p} \sum_i x_i^2 - \left(\frac{\sum_i x_i}{p}\right)^2} \\ a &= \frac{\bar{x}\bar{y} - \bar{x}\bar{y}}{x^2 - (\bar{x})^2} \end{aligned} \quad (6)$$

Autres façons d'écrire a :

$$\begin{aligned} \sum_i (x_i - \bar{x})(y_i - \bar{y}) &= \sum_i (x_i y_i - x_i \bar{y} - \bar{x} y_i + \bar{x} \bar{y}) \\ &= \sum_i (x_i y_i) - \bar{y} \underbrace{\sum_i (x_i)} - \bar{x} \sum_i (y_i) + \bar{x} \bar{y} p \\ &= \sum_i (x_i y_i) - \frac{1}{p} \sum_i (x_i) - \bar{x} \sum_i (y_i) * \sum_i (x_i - \bar{x}^2) \end{aligned}$$

Au plus haut :

$$= \sum_i (x_i^2) - \frac{1}{p} \left(\sum_i (x_i) \right)^2$$

alors d'après (4)

$$a = \frac{p + \sum_i (x_i - \bar{x})(y_i - \bar{y})}{p \sum_i (x_i - \bar{x})^2}$$

⇒

$$a = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sum_i (x_i - \bar{x})^2} \quad (4)$$

- Qualité de l'ajustement :

$$\begin{aligned} \sum_i (y_i - \bar{y})^2 &= \sum_i (y_i - y'_i + y'_i - \bar{y})^2 = \sum_i (y_i - y'_i)^2 + \sum_i (y'_i - \bar{y})^2 \\ &\quad + 2 \sum_i (y_i - y'_i)(y'_i - \bar{y}) \end{aligned}$$

⇒ et on va démontrer que $\Delta=0$

$$\Delta = \sum_i (y_i - y'_i)(y'_i - \bar{y})$$

$$\Delta = \sum_i (y_i - ax_i - b)(ax_i + (b - \bar{y}))$$

$$\Delta = a \sum_i (y_i - ax_i - b)xi + (b - \bar{y}) \sum_i (y_i - ax_i - b) - \frac{df(a,b)}{db} = 0$$

$$\Rightarrow \Delta=0 \quad \frac{df(a,b)}{db} = 0$$

donc

$$\sum_i (y_i - \bar{y})^2 = \sum_i (y_i - y'_i)^2 + \sum_i (y'_i - \bar{y})^2$$

Cela représente l'écart total entre y_i et \bar{y}

Ecart résiduel de y_i par rapport à la valeur estimée y_i

Ecart expliqué entre $y_i = ax_i + b$ et \bar{y} . Il ne dépend que de x_i , pas des y_i

d'où le coefficient de corrélation:

$$R^2 = \frac{\text{écart expliqué}}{\text{écart total}} = \frac{\sum_i (y'_i - \bar{y})^2}{\sum_i (y_i - \bar{y})^2}$$

et R^2 varie de 0 à 1.

Si ajustement idéal : écart résiduel = $\sum_i y_i - y'_i = 0$

donc $\sum_i (y_i - \bar{y})^2 = \sum_i (y'_i - \bar{y})^2$

donc $R^2 = 1$

Autres expressions de R :

Ecart expliqué :

$$\sum_i (y'_i - \bar{y})^2 = \sum_i (ax_i + b - a\bar{x} - b)^2 = a^2 \sum_i (x_i - \bar{x})^2$$

donc

$$\begin{aligned} R^2 &= \frac{a \sum_i (x_i - \bar{x})^2}{\sum_i (y_i - \bar{y})^2} = R \\ R &= |a| \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{\sum_i (y_i - \bar{y})^2}} = |a| \frac{\sigma_x}{\sigma_y} \end{aligned}$$

Exemple :
Ajustement à l'aide d'une droite.

	x_i	y_i	x_i^2	$x_i y_i$	y_i^2
Données experimentales	2
	3

Somme :	25	26	151	163	182

Formule pour calculer a, b et R

$$a = \frac{p \sum xy - \sum x \sum y}{p \sum x^2 - (\sum x)^2} = \frac{5.163 - 25.26}{5.151 - 25^2} = \frac{33}{26} = 1,2692$$

$$b = \frac{\sum y}{p} - a \frac{\sum x}{p} = \frac{26}{5} - 1,2692 * \frac{25}{5} = -\frac{149}{130} = -1,1462$$

Valeurs obtenues sont identiques à celles obtenues avec un logiciel

$$R = \frac{\sum xy - \frac{1}{p} \sum x \sum y}{\sqrt{\left(\sum x^2 - \frac{1}{p} (\sum x)^2\right) \left(\sum y^2 - \frac{1}{p} (\sum y)^2\right)}} = \frac{\left(163 - \frac{1}{5} * 25 * 26\right)}{\sqrt{\left(151 - \frac{1}{5} * 25^2\right) \left(182 - \frac{1}{5} * 26^2\right)}} = \frac{11\sqrt{5}}{26}$$

$$= 0,9460$$

β) Ajustement à l'aide d'une parabole

Courbe ajustée est une parabole d'équation, $y = ax^2 + bx + c$

Avec notre notation, on aura:

$$y'_i = ax_i^2 + b x_i + c$$

On va chercher le minimum de $\sum_i (y_i - y'_i)^2$

$$\text{Ici, } \sum_i (y_i - y'_i)^2 = \sum_i (y_i - ax_i^2 - b x_i + c)^2 = f(a, b, c)$$

Méthode:

$$\frac{df}{dc} = 0 \Rightarrow -2 \sum_i (y_i - ax_i^2 - b x_i + c) = 0$$

$$\Rightarrow \sum_i y_i = a \sum_i x_i^2 + b \sum_i x_i + \sum_i c \quad (1)$$

$$\Rightarrow \bar{y} = a \bar{x}^2 + b \bar{x} + c$$

$$\sum_i y_i = a \sum_i x_i^2 + b \sum_i x_i + p c \quad (1)$$

$$\frac{df}{db} = 0 \Rightarrow -2 \sum_i (y_i - ax_i^2 - b x_i + c) x_i = 0$$

$$\Rightarrow \sum_i x_i y_i = a \sum_i x_i^3 + b \sum_i x_i^2 + c \sum_i x_i \quad (2)$$

$$\frac{df}{da} = 0 \Rightarrow -2 \sum_i (y_i - ax_i^2 - b x_i + c) x_i^2 = 0$$

$$\Rightarrow \sum_i x_i^2 y_i = a \sum_i x_i^4 + b \sum_i x_i^3 + c \sum_i x_i^2 \quad (3)$$

On reprend le formulaire:

	xi	yi	xi ²	xi ³	xi ⁴	xiyi	xi ² yi	yi ²
Données experimentales

Somme :	18	25	88	504	3124	100	560	155

d'où :

$$\left. \begin{aligned} (1): 25 &= 88a + 18b + 5c \\ (2): 100 &= 504a + 88b + 18c \\ (3): 560 &= 3124a + 504b + 88c \end{aligned} \right\}$$

avec (1) et (2) $\Rightarrow 936a + 116b = 50$
 (1) et (3) $\Rightarrow 7876a + 936b = 600$

$$\Rightarrow a = \frac{285}{469} = 0,6077$$

$$\Rightarrow b = \frac{4195}{938} = -4,4723$$

$$\Rightarrow c = \frac{4880}{469} = 10,4051$$

Calcul du coefficient de corrélation dans le cas d'une parabole :

On a vu que $R^2 = \frac{\sum_i (y'_i - \bar{y})^2}{\sum_i (y_i - \bar{y})^2} = \frac{N}{D}$

On a : $D = \sum_i y_i^2 - \frac{1}{p} (\sum y_i)^2$ Déjà vu

On a

$$N = \sum_i (y'_i - \bar{y})^2 = \sum_i (ax + bxi + c - a\bar{x}^2 - b\bar{x} - c)^2$$

$$= a^2 \sum_i (xi^2 - \bar{x}^2)^2 + b^2 \sum_i (xi - \bar{x})^2 + 2ab \sum_i (xi^2 - \bar{x}^2) (xi - \bar{x})$$

Dans l'exemple retenu :

On aura:

$$N = (0,6077)^2 \left[3124 - \frac{1}{5} * 88 \right] + (4,4723)^2 \left[88 - \frac{1}{5} * 18^2 \right] - 2 * 0,6077$$

$$* 4,4723 \left[504 - \frac{1}{5} * 18 * 88 \right] = \dots = 28,203$$

et

$$D = 155 - \frac{1}{5} * 25^2 = 30$$

donc

$$R^2 = \frac{N}{D} = 0,9401 \Rightarrow R = 0,9695$$

δ) Ajustement à l'aide d'une exponentielle : y=ba^x

Si y=b ba^x $\Rightarrow \log y = \log b + x \log a = x \log a + \log b$

ou encore y=Ax + B

où : Y=log (y)

A=log (a)

B=log (b)

On aura:

$$A = p \sum xiYi - \frac{\sum xi \sum Yi}{p \sum_i xi^2 (\sum_i xi)^2}$$

et $B = \bar{Y} - A\bar{x}$

δ) Ajustement à l'aide d'une fonction puissance $y = bx^a$

donc $\log y = a \log x + \log b$

$\Rightarrow Y = aX + B$

où : $Y = \log(y)$

$A = \log(a)$

$B = \log(b)$

et on aura :

$$a = \frac{p \sum_i X_i Y_i - \sum_i X_i \sum_i Y_i}{p \sum_i X_i^2 - (\sum_i X_i)^2}$$

et $B = \bar{Y} - a\bar{X}$

Chapitre 4 : Indices statistiques

Ces indices statistiques servent à suivre l'évolution d'une grandeur au cours du temps

- indice des prix à la consommation (IPC)

- indice de la production (IPI)

- indice du coût de la construction (ICC)

On distingue deux notions d'indice :

- indice simple si une seule grandeur est étudiée

- indice synthétique si plusieurs grandeurs sont étudiées

1. Indice simple (ou élémentaire)

On va partir d'un exemple :

Si un matériel coûte 50€ en 2004 et 54€ en 2005, on peut comparer ces prix avec :

- l'augmentation : $54 - 50 = 4€$ mais cela ne donne pas l'importance de l'augmentation

- l'augmentation en pourcent : $\frac{54-50}{100} = 0,08 = 8\%$

- le rapport des prix : $\frac{54}{50} = 1,08$

Intérêt de ce rapport : calcul facile pour estimer le prix final ($50 * 1,08 = 54$)

D'où la définition de l'indice simple

$$\frac{54}{50} * 100 = 108$$

Définition :

Soit p_0 la valeur à une date t_0 (de base ou référence) d'un grandeur.

Soit p_1 la valeur à une date t_1 d'un grandeur.

Alors l'indice simple de la grandeur à la date t_1 calculé sur la base 100 à la date t_0 est :

$$I_{Y_0} = \frac{p_1}{p_0} * 100$$

Remarques :

- on multiplie par 100 pour éviter les décimales

- on note $i_{1/0} = \frac{p_1}{p_0}$ avec i en minuscule

Propriétés :

- un indice simple est réversible :

on a $i_{0/t} * i_{t/0} = 1$

ou encore :

$$\frac{i_{0/t}}{100} = \frac{1}{\frac{i_{t/0}}{100}}$$

- indice transférable :

qlq soit t_0, t_1, t_2 : $i_{2/1} * i_{1/0} = i_{2/0}$

ou

$$\frac{i_{2/1}}{100} * \frac{i_{1/0}}{100} = \frac{i_{2/0}}{100}$$

Remarque:

2 hausses de suite de 8% donnent une hausse de 16,64% et par de 16% car :

$$1,08 * 1,08 = 1,1664.$$