



Chapitre III : Ajustement de séries statistiques

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



Problème: identifier la forme de la courbe d'ajustement: 1) droite
 2) parabole.

- déterminer les équations de la courbe d'ajustement:

$$m_i = f(x_i) \begin{cases} \rightarrow m_i = a x_i \\ \rightarrow m_i = a x_i^2 + b x_i + c \\ \dots \end{cases}$$

Ceci permet de remplacer les 2 p valeurs (x_i, m_i) par seulement 2 ou 3 paramètres.
 de calculer des m_i pour d'autres valeurs de x_i

② 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, m_i) pour éventuellement faciliter ensuite la détermination de la courbe d'ajustement.

a) Méthode des points médians

ex: 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 sup.
 - idem avec les minima.
 - tracer un segment vertical par chaque x_i
 - déterminer les points médians entre les points supérieurs et inférieurs.

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

Ⓐ aspect subjectif selon la détermination des pts max et min.

b) Méthode de la moyenne mobile

méthode: on va remplacer y_i par $\hat{y}_i = \frac{y_{i-1} + y_i + y_{i+1}}{3}$

(si on effectue une moyenne sur 3 pts) sauf pour le premier point: $\hat{y}_1 = \frac{y_1 + y_2}{2}$

et le dernier point: $\hat{y}_n = \frac{y_{n-1} + y_n}{2}$

Sur l'exemple du formulaire correspondant au cours III
Les variations de \hat{y}_i sont plus faibles que celles de y_i .

Ⓐ

- doit subjectif à faire sur le nombre de points considérés (3, 5, 7, ...)
- possibilité de pondérer ces moyennes: $\hat{y}_i = \frac{y_{i-1} + 2y_i + y_{i+1}}{4}$

2) Méthodes 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 au moins deux points au dessus de la droite qu'un dessous.

Ensuite, si on connaît 2 pts de cette droite, on peut en déduire son équation

③ 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 des y_i par rapport à cette courbe est donné par la quantité suivante:

$$\sum_{i=1}^n (y_i - y_i')^2$$

• Une fois choisie la forme de la courbe d'ajustement (droite, parabole, exp, ...)
 On va chercher les paramètres de l'équation considérée et qui minimisent la quantité:

$$\sum_{i=1}^n (y_i - y_i')^2$$

④ - Pas de subjectivité de la méthode (les logiciels donnent le même résultat).

- notation: $\sum_{i=1}^n x_i$ est noté $\sum_n x_i$ et les certains cas $\sum y$

Rapports: $\sum_i y_i = n\bar{y}$ $\sum_i (y_i - \bar{y})^2 = n\sigma_y^2 = \sum_i (y_i^2 - 2\bar{y}y_i + \bar{y}^2)$

$$= \sum_i y_i^2 - 2\bar{y} \sum_i y_i + \bar{y}^2 \sum_i 1$$

$$= \sum_i y_i^2 - 2n\bar{y}^2 + n\bar{y}^2 = \sum_i y_i^2 - n\bar{y}^2 = \sum_i y_i^2 - \frac{1}{n} \left(\sum_i y_i \right)^2$$

On va exposer la méthode sur le exemple simple mais la méthode des moindres carrés peut se généraliser à des fonctions plus compliquées.

a) ajustement à l'aide d'une droite

pb: Courbe ajustée et sa droite d'équation $y = ax + b$

Tu on notera $y'_i = ax_i + b$

On va chercher à minimiser la quantité: $\sum_i (y_i - ax_i - b)^2$
(On cherche a et b pour que cette quantité soit la + petite possible).

La quantité $\sum_i (y_i - ax_i - b)^2$ dépend de a et $b \Rightarrow f(a, b)$

méthode: $\frac{df}{db} = 0 \Rightarrow -2 \sum_i (y_i - ax_i - b) = 0$

$$\sum_i y_i = a \sum_i x_i + nb \quad \dots \quad (1)$$

On divise (1) par n : $\bar{y} = a\bar{x} + b \quad \dots \quad (2)$

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

$$\frac{df}{da} = 0 \Rightarrow -2 \sum_i (y_i - ax_i - b)x_i = 0 \Rightarrow \sum_i x_i y_i = a \sum_i x_i^2 + b \sum_i x_i \quad \dots \quad (3)$$

$$(3) \times n - (1) \times \left(\sum_i x_i \right) \Rightarrow \begin{cases} n \sum_i x_i y_i = a n \sum_i x_i^2 + n b \sum_i x_i \\ - \sum_i x_i \sum_i y_i = -a \left(\sum_i x_i \right)^2 - nb \sum_i x_i \end{cases}$$

$$\text{à mi} \quad a = \frac{\uparrow \sum_i x_i y_i - \sum_i x_i \sum_1 y_i}{\uparrow \sum_i x_i^2 - \left(\sum_i x_i\right)^2} \dots \dots (4)$$

$$\text{or } b = \bar{y} - a \bar{x} \dots \dots (5)$$

$$\text{autres indices de: } (4) \times \frac{1/n^2}{1/n^2} \Rightarrow a = \frac{1/n \sum_i x_i y_i - \frac{\sum_i x_i}{n} \frac{\sum_i y_i}{n}}{1/n \sum_i x_i^2 - \left(\frac{\sum_i x_i}{n}\right)^2}$$

$$a = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{x^2} - (\bar{x})^2} \dots \dots (6)$$

$$\begin{aligned} \text{OU BIEN: } \sum_i (x_i - \bar{x})(y_i - \bar{y}) &= \sum_i (x_i y_i - x_i \bar{y} - \bar{x} y_i + \bar{x} \bar{y}) \\ &= \sum_i x_i y_i - \bar{y} \sum_i x_i - \bar{x} \sum_i y_i + \bar{x} \bar{y} n \\ &= \sum_i x_i y_i - \frac{1}{n} \sum_i x_i \sum_i y_i \end{aligned}$$

$$\bullet \sum_i (x_i - \bar{x})^2 = \sum_i x_i^2 - \frac{1}{n} \left(\sum_i x_i\right)^2 \leftarrow \text{vu plus tôt.}$$

$$\text{des détails: } a = \frac{\uparrow \sum_i (x_i - \bar{x})(y_i - \bar{y})}{\uparrow \sum_i (x_i - \bar{x})^2} \Rightarrow a = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sum_i (x_i - \bar{x})^2} \dots (7)$$

Qualité de l'ajustement.

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

On va montrer que $\Delta = 0$:

$$\begin{aligned} \Delta &= \sum_i (y_i - \hat{y}_i)(y_i - \bar{y}) = \sum_i (y_i - ax_i - b)(ax_i + b - \bar{y}) = a \sum_i (y_i - ax_i - b)x_i \\ &\quad \rightarrow + \sum_i (b - \bar{y})(y_i - ax_i - b) \end{aligned}$$

$$\frac{dL(a,b)}{da} = 0 \quad \frac{dL(a,b)}{db} = 0$$

$$\Delta = a \sum_i (y_i - ax_i - b)x_i + (b - \bar{y}) \sum_i (y_i - ax_i - b) = 0$$

$$\text{donc } \sum_i (y_i - \bar{y})^2 = \sum_i (y_i - \hat{y}_i)^2 + \left(\sum_i y_i - \bar{y} \right)^2$$

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

écart résiduel de y_i par rapport à la valeur estimée \hat{y}_i

écart expliqué entre y_i et \bar{y} . Il ne dépend que de x_i et pas des y_i

d'où le coefficient de corrélation :

$$R^2 = \frac{\text{écart expliqué}}{\text{écart total}} = \frac{\sum_i (\hat{y}_i - \bar{y})^2}{\sum_i (y_i - \bar{y})^2} \quad \text{et } R^2 \text{ de } 0 \text{ à } 1$$

L'ajustement est idéal si l'écart résiduel est nul et donc que $R^2 = 1$

autres expressions de R^2 :

$$\text{écart expliqué : } \sum_i (\hat{y}_i - \bar{y})^2 = \sum_i (ax_i + b - a\bar{x} - b)^2 = a^2 \sum_i (x_i - \bar{x})^2$$

$$\text{donc } R^2 = \frac{a^2 \sum_i (x_i - \bar{x})^2}{\sum_i (y_i - \bar{y})^2} \Rightarrow R = |a| \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{\sum_i (y_i - \bar{y})^2}} = |a| \frac{\sigma_x}{\sigma_y}$$

$$\text{OU ENCORE : à partir de (7) : } R = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_i (x_i - \bar{x})^2 \sum_i (y_i - \bar{y})^2}}$$

Exemple: Ajustement à l'aide d'une droite (voir formule ci-dessus)

Formule pour calculer a, b, R

$$a = \frac{\uparrow \sum xy - \sum x \cdot \sum y}{\uparrow \sum x^2 - (\sum x)^2} = \frac{5 \times 163 - 25 \times 26}{5 \times 151 - (25)^2} = \frac{33}{26} = 1,2692$$

$$b = \frac{\sum y}{\uparrow} - a \frac{\sum x}{\uparrow} = \frac{26}{5} - 1,2692 \times \frac{25}{5} = -\frac{149}{100} = -1,4692$$

Les valeurs obtenues sont identiques à celles obtenues avec un logiciel.

$$R = \frac{\sum xy - \frac{1}{n} \sum x_i \sum y_i}{\sqrt{\left(\sum x_i^2 - \frac{1}{n} (\sum x_i)^2\right) \left(\sum y_i^2 - \frac{1}{n} (\sum y_i)^2\right)}}$$

$$= \frac{163 - \frac{1}{5} \times 25 \times 26}{\left[\left(151 - \frac{1}{5} \times 25^2\right) \left(189 - \frac{1}{5} \times 26^2\right)\right]^{1/2}} = \frac{11\sqrt{5}}{26} = 0,94603$$

B) ajustement à l'aide d'une parabole

La courbe ajustée est une parabole d'équation $y = ax^2 + bx + c$
Avec notre notation, on a: $y_i = ax_i^2 + bx_i + c$

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

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

$$\text{méthode: } \frac{df}{dc} = 0 \Rightarrow -2 \sum_i (y_i - ax_i^2 - bx_i - c) = 0$$

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

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

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

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

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

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

exemple: fontaine:

(1)	$25 = 88a + 18b + 5c$
(2)	$106 = 504a + 88b + 18c$
(3)	$566 = 3124a + 504b + 88c$

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

d'où $a = \frac{285}{469} = 0,6077$ $b = -\frac{4195}{938} = -4,4723$ et $c = \frac{6880}{469} = 14,605$

$$R^2 = \frac{\sum_i (y_i - \bar{y})^2}{\sum_i (y_i - \bar{y})^2} = \frac{N}{D} \quad \text{ou } D = \sum_i y_i^2 - \frac{1}{n} (\sum_i y_i)^2$$

$$\text{ou } N = \sum_i (y_i - \bar{y})^2 = \sum_i (ax_i + bx_i^2 + c - a\bar{x} - b\bar{x}^2 - c)^2$$

$$\Rightarrow N = a^2 \sum (x_i - \bar{x})^2 + b^2 \sum (x_i - \bar{x})^2 + 2ab \sum (x_i - \bar{x})(x_i - \bar{x})$$

$$N = a^2 \left[\sum x_i^2 - \frac{1}{n} (\sum x_i)^2 \right] + b^2 \left[\sum x_i^2 - \frac{1}{n} (\sum x_i)^2 \right] + 2ab \left[\sum x_i^2 - \frac{1}{n} (\sum x_i)^2 \right]$$

Donc l'erreur on aura $N = 28,203$ et $D = 155 - \frac{1}{9} \times 25^2 = 30$

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

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

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

on écrit $Y = Ax + B$ on $Y = \log y$ $B = \log b$ $A = \log a$

On aura: $A = \frac{\sum x_i Y_i - \sum x_i \sum Y_i}{\sum x_i^2 - (\sum x_i)^2}$ et $B = \bar{Y} - A\bar{x}$

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

$y = bx^a$ $\log y = a \log x + \log b$

$Y = aX + B$ on $Y = \log y$ $X = \log x$ $B = \log(b)$

Chapitre IV : Indics statistiques

Les indices statistiques servent à suivre l'évol^o d'un produit au cours du temps.

- indice des prix à la consommation (IPC)
- indice de la product^o industrielle (IPI)
- " du coût de la construct^o (ICC)

On distingue deux notions d'indices :

- indice simple si une seule grandeur est étudiée
- indice synthétique si plusieurs grandeurs sont étudiées

① Indice simple (ou élémentaire)

On peut donner un exemple :

Si 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 \uparrow
- l' \uparrow en % $\frac{54 - 50}{50} = 8\%$
- le rapport des prix : $\frac{54}{50} = 1,08$

L'intérêt de ce rapport est évident facile pour estimer le prix final ($50 \times 1,08 = 54$)

- d'où la définition de l'indice simple $\frac{54}{50} \times 100 = 108$

def: Soit p_0 la valeur à la date t_0 (de base ou référence) d'une grandeur.
Soit p_t " " " " t_1

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

$$I_{p_0} = \frac{p_t}{p_0} \times 100$$

- ①
- on multiplie par 100 pour éviter les décimales
 - on note $i_{1/10} = \frac{pa}{100}$ avec i en pourcentage.

propriété: un indice simple est réversible: $i_{1/10} \times i_{10/1} = 1$

on écrit $\frac{I_{10/1}}{100} = \frac{1}{\frac{I_{1/10}}{100}}$

- indice transposable: $\forall k_0, k_1, k_2: i_{k_1/k_2} \times i_{k_2/k_0} = i_{k_1/k_0}$

- ② 2 hausses de suite de 8% donne une hausse de 16,64% et pas de 16%
car $1,08 \times 1,08 = 1,1664$