

Décomposition de la variance :

Considérons la régression linéaire multiple :

$$Y = X\beta + U \dots (*)$$

On se pose la question est ce que les facteurs x_1, x_2, \dots, x_k expliquent bien y dans le modèle (*).

La phrase "explique bien" signifie que le modèle (*) doit donner des résultats sur y très proches des valeurs des expériences si on répète de nouveau les expériences :

$$y \approx X\hat{\beta}_n$$

Posons :

$$\hat{y}_i = (X\hat{\beta}_n)_i : \text{Prévision de } y_i.$$

On a :

$$\begin{aligned} \sum_{i=1}^n (y_i - \bar{y})^2 &= \sum_{i=1}^n (y_i - \hat{y}_i + \hat{y}_i - \bar{y}_n)^2 \\ &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y}_n)^2 + 2 \sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}_n) \end{aligned}$$

or, puisque \hat{y} est la projection de y sur $\mathcal{E}(X)$ alors :

$$\sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}_n) = \langle y - \hat{y}, \hat{y} - \bar{y}_n \rangle = 0$$

Par suite :

$$\sum (y_i - \bar{y}_n)^2 = \|\hat{U}\|^2 + \sum (\hat{y}_i - \bar{y}_n)^2 \text{ où } \hat{U} = y - \hat{y}.$$

Définitions :

* La quantité $\sum_{i=1}^n (y_i - \bar{y})^2$ est appelée la variance totale.

* $\|\hat{U}\|^2$ est appelée le résidu de la régression linéaire.

* $S_{\text{reg}} = \sum (\hat{y}_i - \bar{y}_n)^2$ est appelée variance de la régression linéaire.

Rappels d'algèbre linéaire.

- Une matrice A ($n \times n$) est une matrice de projection orthogonale si $A^t = A$ et $A^2 = A$.

- Soit A une matrice de projection orthogonale. Alors :
 $\text{rang}(A) = \sum_{i=1}^n a_{ii} = r$ et il existe une matrice orthogonale B , ($n \times n$) tels que :

$$A = B^t \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} B$$

où I_r est la matrice identité de \mathbb{R}^r .

Proposition :

Soit $X = (x_1, x_2, \dots, x_n)^t$ un vecteur gaussien avec $E(X) = 0$ et $C_X = I$.

Soit A une matrice de projection ($n \times n$).

On pose : $q_A(x) = x^t A x$; $x \in \mathbb{R}^n$.

Alors :

$$Y = q_A(X) \hookrightarrow \mathcal{N}_r^c$$

où $r = \text{rang}(A)$.

Preuve :

D'après le rappel, il existe une matrice orthogonale B telle que :

$$A = B^t \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} B$$

$$\text{posons } Z = BX = B \begin{pmatrix} x_1, x_2, \dots, x_n \end{pmatrix}^t$$

On a :

$$Y = q_A(X) = X^t A X = X^t B^t \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} B X$$

D'où :

$$Y = Z^t \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} Z$$

D'autre part :

$$Z = BX \Leftrightarrow N(0, B C_X B^t)$$

$$\text{or : } B C_X B^t = B I B^t = B B^t = B B^{-1} = I.$$

Ainsi :

$$Z \Leftrightarrow N(0, I)$$

Donc

$$Y = q_A(X) = Z^t \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} Z = \sum_{i=1}^r Z_i^2$$

Comme $Z \Leftrightarrow N(0, I)$, alors $Z_i \Leftrightarrow N(0, 1)$ et les (Z_i) sont indépendantes.

D'où :

$$Y \Leftrightarrow \chi_r^2$$

Proposition : Soit (X_1, X_2, \dots, X_n) un échantillon de loi $N(m, \sigma^2)$.

$$\text{Soit } \bar{X}_n = \frac{1}{n} \sum X_i \text{ et } S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2.$$

On a :

$$1) \bar{X}_n \Leftrightarrow N\left(m, \frac{\sigma^2}{n}\right).$$

$$2) \frac{n-1}{\sigma^2} S_n^2 \Leftrightarrow \chi_{n-1}^2.$$

3) \bar{X}_n et S_n^2 sont indépendantes.

$$4) \sqrt{n} \frac{\bar{X}_n - m}{S_n} \Leftrightarrow T \text{ (loi de Student).}$$

Preuve :

1) On a :

$$E(\bar{X}_n) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \cdot n \cdot \mu = \mu$$

et

$$\text{Var}(\bar{X}_n) = \frac{1}{n^2} \text{Var}\left(\sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \frac{1}{n^2} \cdot n \cdot \sigma^2 = \frac{\sigma^2}{n}$$

Comme \bar{X}_n est une combinaison linéaire des X_i et (X_1, X_2, \dots, X_n) est un vecteur gaussien, alors \bar{X}_n est gaussien.

c) On a :

$$\begin{aligned} \frac{n-1}{\sigma^2} S_n^2 &= \sum_{i=1}^n \left(\frac{X_i - \bar{X}_n}{\sigma} \right)^2 \\ &= \sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma} - \frac{\bar{X}_n - \mu}{\sigma} \right)^2 \\ &= \sum_{i=1}^n (Y_i - \bar{Y}_n)^2 \quad \text{pu } Y_i = \frac{X_i - \mu}{\sigma} \\ &= \sum_{i=1}^n Y_i^2 - 2\bar{Y}_n \left(\sum_{i=1}^n Y_i \right) + n\bar{Y}_n^2 \\ &= \sum_{i=1}^n Y_i^2 - 2\bar{Y}_n \cdot n\bar{Y}_n + n\bar{Y}_n^2 \\ &= \sum_{i=1}^n Y_i^2 - n\bar{Y}_n^2 \end{aligned}$$

Posons $z = (1, 1, \dots, 1)^t$ et $A = I_n - \frac{1}{n} z z^t$.

On peut écrire :

$$\begin{aligned} Y^t A Y &= Y^t I_n Y - \frac{1}{n} Y^t z z^t Y \\ &= \sum_{i=1}^n Y_i^2 - \frac{1}{n} \left(\sum_{i=1}^n Y_i \right)^2 \\ &= \sum_{i=1}^n Y_i^2 - \frac{1}{n} (n\bar{Y}_n)^2 \\ &= \sum_{i=1}^n Y_i^2 - n\bar{Y}_n^2 \\ &= \frac{n-1}{\sigma^2} S_n^2 \end{aligned}$$

D'autre part, il est facile de voir que $A^t = A$. De plus :

$$\begin{aligned}
 A^2 &= \left(I - \frac{1}{n} Z Z^t\right) \left(I - \frac{1}{n} Z Z^t\right) \\
 &= I - \frac{2}{n} Z Z^t + \frac{1}{n^2} (Z Z^t)^2 \\
 &= I - \frac{2}{n} Z Z^t + \frac{1}{n^2} (n Z Z^t) \\
 &= I - \frac{1}{n} Z Z^t \\
 &= A
 \end{aligned}$$

Il en découle que A est une matrice de projection orthogonale.
 En utilisant la proposition précédente et puisque :

$$\frac{n-1}{\sigma^2} S_n^2 = q_A(X)$$

alors $\frac{n-1}{\sigma^2} S_n^2 \xrightarrow{L} \chi_r^2$ avec :

$$r = \text{rang}(A) = \text{tr}(A) = n \left(1 - \frac{1}{n}\right) = n - 1.$$

3) Posons $G_i = \frac{X_i - \bar{X}_n}{\sigma}$.

$$\text{On a : } S_n^2 = \frac{1}{n-1} \sum_{i=1}^n G_i^2.$$

Le vecteur $(\bar{X}_n, G_1, G_2, \dots, G_n)$ est gaussien car toute combinaison linéaire de $\bar{X}_n, G_1, G_2, \dots, G_n$ est une combinaison linéaire de X_1, X_2, \dots, X_n .

D'autre part :

$$\text{Cov}(\bar{X}_n, G_i) = \text{Cov}\left(\bar{X}_n, \frac{X_i}{\sigma} - \frac{\bar{X}_n}{\sigma}\right)$$

$$= \text{Cov}\left(\bar{X}_n, \frac{X_i}{\sigma}\right) - \text{Cov}\left(\bar{X}_n, \frac{\bar{X}_n}{\sigma}\right)$$

On a :

$$\text{Cov}\left(\bar{X}_n, \frac{X_i}{\sigma}\right) = \frac{1}{\sigma} \text{Cov}\left(\frac{1}{n} \sum_{j=1}^n X_j, X_i\right)$$

$$\begin{aligned}
&= \frac{1}{n\sigma} \operatorname{cov}(X_1 + X_2 + \dots + X_n, X_i) \\
&= \frac{1}{n\sigma} [\operatorname{cov}(X_1, X_i) + \dots + \operatorname{cov}(X_i, X_i) + \dots + \operatorname{cov}(X_n, X_i)] \\
&= \frac{1}{n\sigma} \operatorname{var}(X_i) \\
&= \frac{\sigma}{n}
\end{aligned}$$

et :

$$\operatorname{cov}\left(\frac{\bar{X}_n}{\sigma}, \frac{X_n}{\sigma}\right) = \frac{1}{\sigma} \operatorname{cov}(\bar{X}_n, X_n) = \frac{1}{\sigma} \operatorname{var}(\bar{X}_n) = \frac{\sigma^2}{n\sigma} = \frac{\sigma}{n}$$

Donc $\operatorname{cov}(\bar{X}_n, G_i) = 0$

Ainsi \bar{X}_n et (G_1, G_2, \dots, G_n) sont indépendantes

Finalement \bar{X}_n est indépendante de $S_n^2 = h(G_1, G_2, \dots, G_n)$

4) On a :

$$\frac{\sqrt{n}(\bar{X}_n - \mu)}{S_n} = \sqrt{n-1} \frac{\frac{\sqrt{n}(\bar{X}_n - \mu)}{\sigma}}{\sqrt{(n-1) \frac{S_n^2}{\sigma^2}}}$$

Puisque $\frac{\sqrt{n}(\bar{X}_n - \mu)}{\sigma} \hookrightarrow N(0, 1)$ et $\frac{(n-1)S_n^2}{\sigma^2} \hookrightarrow \chi_{n-1}^2$

alors $\frac{\sqrt{n}(\bar{X}_n - \mu)}{S_n} \hookrightarrow T_{n-1}$ où T_{n-1} est la loi

de Student avec $(n-1)$ degré de liberté.


Chapitre 2. Modèles avec saisonnalité

Introduction :

On considère une série chronologique $(Y_t)_{t \in T}$ avec $T = \mathbb{N}$ ou \mathbb{Z} qui se présente comme résultat de différentes composantes fondamentales.

Le choix des éléments qui constituent les composantes fondamentales est très important pour expliquer les variations (les valeurs) de Y_t . Parmi ces composantes, on peut citer :

a) **La tendance T_t (trend)** : Elle représente l'évolution "globale" de la variable Y_t (phénomène Y_t), ou encore le comportement moyen de l'évolution de Y_t .



b) **La saisonnalité S_t** : Elle correspond à mettre en évidence un phénomène saisonnier. La saison naturelle est un cycle de temps qui se répète périodiquement. Ainsi la saison S_t représente les fluctuations périodiques (variations) de Y_t dues aux saisons (ou encore des facteurs de la société : les fêtes, les week-end...).

S_t est une fonction périodique de t et de période p .

c) **Le résidu U_t** : représente les fluctuations qui sont en général imprévisibles.

On retient le modèle suivant (modèle additif):

$$Y_t = T_t + S_t + U_t$$

On fait les hypothèses suivantes (conditions sur le modèle):

$$\sum_{j=1}^p S_j = 0 \quad \text{et} \quad \sum_{j=1}^n U_j = 0$$

où n est le nombre d'observations.

Remarque: Il existe d'autres modèles comme le modèle multiplicatif

$$Y_t = T_t S_t + U_t \quad \text{ou encore} \quad Y_t = T_t S_t U_t$$

2) Détermination des composantes T_t, S_t :

• Décomposition de Y_t : Il existe plusieurs modèles de décomposition avec un choix de T_t (déterministe):

1. Tendances linéaire: $T_t = b + at$
2. Tendances polynômiale: $T_t = a_0 + a_1 t + \dots + a_p t^p$
3. Tendances exponentielle: $T_t = C + a e^{bt}$
4. Tendances logarithmique: $T_t = b + a \log t$
5. Tendances hyperbolique: $T_t = \frac{1}{b + at}$
6. Tendances logistique: $T_t = \frac{1}{c + b e^{-at}}$

Les exemples de tendances précédents sont appliqués aux données là où on arrive à déceler la tendance. Si on arrive pas à mettre en évidence un choix de T_t , il existe des méthodes qui permettent de le faire.

Méthodes désaisonnalité (enlever les saisons): Parmi ces méthodes:

- Moyennes mobiles (méthode de lissage - Smoothing):

Définition: On appelle moyenne mobile des observations (Y_t)

la quantité:

Exemples:

1) $b=1, m=3$.

$$M_3(Y_t) = \frac{1}{3} (Y_{t-1} + Y_t + Y_{t+1})$$

2) $b=1, m=2$.

$$M_2(Y_t) = \frac{1}{2} \left(\frac{1}{2} Y_{t-1} + Y_t + \frac{1}{2} Y_{t+1} \right)$$

On obtient donc une nouvelle série $\tilde{Y}_t = M_m(Y_t), t=1, 2, \dots, T$.

On va montrer que dans cette nouvelle série \tilde{Y}_t , l'effet saisonnier "disparaît".

En effet, à partir de $Y_t = T_t + S_t + U_t$, on applique la moyenne mobile d'ordre m , M_m .

$$M_m(Y_t) = M_m(T_t + S_t + U_t).$$

M_m est un opérateur linéaire, donc :

$$M_m(Y_t) = M_m(T_t) + M_m(S_t) + M_m(U_t).$$

Sous la condition $\sum_{j=1}^p S_j = 0$, on a :

• Si $p=m=2b+1$:

$$M_m(S_t) = \frac{1}{m} (S_{t-b} + S_{t-b+1} + \dots + S_{t+b})$$

or $t-b, t-b+1, \dots, t+b$ sont $m=2b+1$ termes consécutifs et S_t est de période p , donc

$$S_{t-b} + S_{t-b+1} + \dots + S_{t+b} = S_1 + S_2 + \dots + S_p = 0.$$

D'où $M_m(S_t) = 0$.

• Si $p=m=2b$:

$$M_m(S_t) = \frac{1}{m} \left(\frac{1}{2} S_{t-b} + S_{t-b+1} + \dots + S_{t+b-1} + \frac{1}{2} S_{t+b} \right)$$

$$= \frac{1}{m} (S_{t-b} + S_{t-b+1} + \dots + S_{t+b-1}) \text{ car } S_{t-b} = S_{t+b}$$

or $t-b, t-b+1, \dots, t+b-1$ sont $m=2b$ entiers consécutifs



Exemples:

1) $b=1, m=3$.

$$M_3(Y_t) = \frac{1}{3} (Y_{t-1} + Y_t + Y_{t+1})$$

2) $b=1, m=2$.

$$M_2(Y_t) = \frac{1}{2} \left(\frac{1}{2} Y_{t-1} + Y_t + \frac{1}{2} Y_{t+1} \right)$$

On obtient donc une nouvelle série $\tilde{Y}_t = M_m(Y_t), t=1, 2, \dots, T$.

On va montrer que dans cette nouvelle série \tilde{Y}_t , l'effet saisonnier "disparaît".

En effet, à partir de $Y_t = T_t + S_t + U_t$, on applique la moyenne mobile d'ordre m , M_m .

$$M_m(Y_t) = M_m(T_t + S_t + U_t).$$

M_m est un opérateur linéaire, donc:

$$M_m(Y_t) = M_m(T_t) + M_m(S_t) + M_m(U_t).$$

Sous la condition $\sum_{j=1}^p S_j = 0$, on a:

• Si $p=m=2b+1$:

$$M_m(S_t) = \frac{1}{m} (S_{t-b} + S_{t-b+1} + \dots + S_{t+b})$$

or $t-b, t-b+1, \dots, t+b$ sont $m=2b+1$ termes consécutifs et S_t est de période p , donc

$$S_{t-b} + S_{t-b+1} + \dots + S_{t+b} = S_1 + S_2 + \dots + S_p = 0.$$

D'où $M_m(S_t) = 0$.

• Si $p=m=2b$:

$$M_m(S_t) = \frac{1}{m} \left(\frac{1}{2} S_{t-b} + S_{t-b+1} + \dots + S_{t+b-1} + \frac{1}{2} S_{t+b} \right)$$

$$= \frac{1}{m} (S_{t-b} + S_{t-b+1} + \dots + S_{t+b-1}) \text{ car } S_{t-b} = S_{t+b}$$

or $t-b, t-b+1, \dots, t+b-1$ sont $m=2b$ entiers consécutifs



et S_t est de période p donc

$$S_{t-p} + S_{t-p+1} + \dots + S_{t-1} + S_t + \dots + S_{t+p-1} = S_1 + S_2 + \dots + S_p = 0$$

Ceci donne $M_m(S_t) = 0$.

On obtient donc pour $m = p$:

$$M_m(Y_t) = M_m(T_t) + M_m(U_t)$$

Posons $\tilde{Y}_t = M_m(Y_t)$; $\tilde{U}_t = M_m(U_t)$ et $\tilde{T}_t = M_m(T_t)$

$$\text{On a } \tilde{Y}_t = \tilde{T}_t + \tilde{U}_t.$$

(\tilde{Y}_t) est une série chronologique sans effet "saison".

On a donc "désaisonné (Y_t) ". Après, on doit retirer S_t par une autre opération.

Exemple:

t	Y_t	$M_2(Y_t)$	$M_3(Y_t)$
1	5	—	—
2	3	3,75	4
3	4	3,625	3,5
4	3,5	3,75	3,83
5	4	3,875	3,83
6	4	—	—

$$M_2(Y_t) = \frac{1}{2} \left(\frac{1}{2} Y_{t-1} + Y_t + \frac{1}{2} Y_{t+1} \right)$$

$$M_3(Y_t) = \frac{1}{3} \left(Y_{t-1} + Y_t + Y_{t+1} \right)$$