Université A. Mira -Bejaia
Faculté des Sciences de Gestions, commerciales et économiques
Département des Sciences économiques

Niveau : *L3 EMB*

BERKAI née MECHERI Kheira

Chapitre 1 : Régression Linéaire simple

L'objectif de la régression linéaire simple est d'établir un lien entre une variable dépendante Y et une variable indépendante X , ce qui va nous permettre de faire ensuite des prévisions de Y lorsque X est mesurée.

0.1 *Présentation du modèle*

Un modèle de régression linéaire simple est défini par :

$$Y_t = B_0 + B_1 X_t + \varepsilon_t, \quad t = 1 \dots n \quad (1)$$

où

- Y_t est la variable dépendante ou endogène (une variable à expliquer) au temps t .
- B_0, B_1 sont les coefficients de la régression.
- X_t est la variable indépendante ou exogène (variable explicative).
- ε_t est une erreur aléatoire.
- n est le nombre d'observations.

Ce modèle doit satisfaire certaines conditions :

H_1 : Le modèle est linéaire en X_t .

H_2 : Les valeurs de X_t sont des grandeurs numériques mesurées sans erreur.

H_3 : Les ε_t sont i.i.d. (indépendants et identiquement distribués).

H_4 : La moyenne des erreurs s'annulent, le modèle est bien spécifié, $E(\varepsilon_t) = 0$.

H_5 : La variance de l'erreur est constante et ne dépend pas de l'observation : homoscedasticité, $Var(\varepsilon_t) = \sigma_\varepsilon^2$.

H_6 : L'erreur est indépendante de la variable exogène, $COV(\varepsilon_t, X_t) = 0$.

H_7 : Indépendance des erreurs, les erreurs relatives à 2 observations sont indépendantes (on dit aussi que les erreurs sont non corrélées), $COV(\varepsilon_t, \varepsilon_s) = 0$.

H_8 : ε_t suit une loi normale, $\varepsilon_t \rightsquigarrow N(0, \sigma_\varepsilon^2)$

0.2 Estimation des paramètres par la méthode Moindres carrés ordinaires (MCO)

Dans la réalité les valeurs de B_0 et B_1 sont inconnus, on doit les estimer. Leurs estimateurs sont donnés par $\widehat{B}_0$ et $\widehat{B}_1$ qui sont obtenus par la méthode Moindres carrés ordinaires (MCO). Cette méthode consiste à minimiser la somme des carrés des erreurs.

$$\min \sum_{t=1}^n \varepsilon_s^2 = \min \sum_{t=1}^n (Y_t - B_0 - B_1 X_t)^2 = \min S(B_0, B_1) \quad (2)$$

Pour minimiser $S(B_0$ et $B_1)$, il suffit de trouver $\widehat{B}_0$ et $\widehat{B}_1$.

$$\begin{cases} \frac{\partial S(B_0, B_1)}{\partial B_0} = 0 \\ \frac{\partial S(B_0, B_1)}{\partial B_1} = 0 \end{cases}$$

Par conséquent, on obtient

$$\begin{cases} -2 \sum_{t=1}^n (Y_t - \widehat{B}_0 - \widehat{B}_1 X_t) = 0 \\ -2 \sum_{t=1}^n X_t (Y_t - \widehat{B}_0 - \widehat{B}_1 X_t) = 0 \end{cases}$$

Et après calculs que,

$$\begin{cases} \widehat{B}_1 = \frac{\sum_{t=1}^n X_t Y_t - n \bar{X} \bar{Y}}{\sum_{t=1}^n X_t^2 - n \bar{X}^2} = \frac{\sum_{t=1}^n (X_t - \bar{X})(Y_t - \bar{Y})}{\sum_{t=1}^n (X_t - \bar{X})^2} \\ \widehat{B}_0 = \bar{Y} - \widehat{B}_1 \bar{X} \end{cases} \quad (3)$$

Remarque

1. Si B_0 est constant, alors

$$\widehat{B}_1 = \frac{\sum_{t=1}^n X_t Y_t}{\sum_{t=1}^n X_t^2} \quad (4)$$

2. Les estimateurs peuvent s'écrire :

$$\begin{cases} \widehat{B}_1 = B_1 + \frac{\sum_{t=1}^n (X_t - \bar{X}) \varepsilon_t}{\sum_{t=1}^n (X_t - \bar{X})^2} \\ \widehat{B}_0 = B_0 - (\widehat{B}_1 - B_1) \bar{X} + \bar{\varepsilon} \end{cases} \quad (5)$$

0.3 Propriétés des estimateurs $\widehat{B}_0$ et $\widehat{B}_1$

D'après la remarque précédente, nous allons montrer que ces estimateurs sont sans biais et convergents :

Les estimateurs sont sans biais

Nous savons que les bruits ε_t sont aléatoires, et puisqu'ils sont centrés, et D'après la formule précédente de $\widehat{B}_1$, on déduit bien que $E[\widehat{B}_1] = B_1$ ($\widehat{B}_1$ est sans biais) .

Pour $\widehat{B}_0$, on a : $E[\widehat{B}_0] = B_0 - E[(\widehat{B}_1 - B_1)]\bar{X}$, et comme $\widehat{B}_1$ est sans biais, on déduit alors : $E[\widehat{B}_0] = B_0$, donc $\widehat{B}_0$ est sans biais.

Les estimateurs sont convergents

$$\begin{aligned} Var(\widehat{B}_1) &= E \left(\widehat{B}_1 - B_1 \right)^2 = E \left[\frac{\sum_{t=1}^n (X_t - \bar{X}) \varepsilon_t}{\sum_{t=1}^n (X_t - \bar{X})^2} \right]^2 \\ Var(\widehat{B}_1) &= \frac{\sum_{t=1}^n (X_t - \bar{X})^2}{\left(\sum_{t=1}^n (X_t - \bar{X})^2 \right)^2} E[\varepsilon_t]^2 + \sum_{t < s} \left[\frac{(X_t - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2} \right] \left[\frac{(X_s - \bar{X})}{\sum_{s=1}^n (X_s - \bar{X})^2} \right] E[\varepsilon_t \varepsilon_s] \\ Var(\widehat{B}_1) &= \frac{E[\varepsilon_t]^2}{\sum_{t=1}^n (X_t - \bar{X})^2} \text{ car les erreurs sont non corrélées.} \end{aligned}$$

$$Var(\widehat{B}_1) = \frac{\sigma_\varepsilon^2}{\sum_{t=1}^n (X_t - \bar{X})^2} \quad (6)$$

$$\begin{aligned} Var(\widehat{B}_0) &= Var(B_0) + Var(\widehat{B}_1)\bar{X}^2 + Var(B_1)\bar{X}^2 + Var(\bar{\varepsilon}) = Var(\widehat{B}_1)\bar{X}^2 + Var(\bar{\varepsilon}), \\ \text{car } Var(B_0) &= Var(B_1) = 0 \end{aligned}$$

$$Var(\widehat{B}_0) = \frac{1}{n} \sigma_\varepsilon^2 + \frac{\bar{X}^2 \sigma_\varepsilon^2}{\sum_{t=1}^n (X_t - \bar{X})^2} = \sigma_\varepsilon^2 \left[\frac{1}{n} + \frac{\bar{X}^2}{\sum_{t=1}^n (X_t - \bar{X})^2} \right] \quad (7)$$

Les deux estimateurs des moindres carrés sont convergents lorsque le nombre d'observations est important ou lorsque les valeurs de variable explicative sont très dispersées autour de la moyenne.

Remarque

$$Cov(\widehat{B}_1, \widehat{B}_0) = -\bar{X} Var(\widehat{B}_1) = -\frac{\sigma_\varepsilon^2 \bar{X}}{\sum_{t=1}^n (X_t - \bar{X})^2}.$$

0.4 Analyse de la variance

Les estimateurs $\widehat{B}_0$ et $\widehat{B}_1$ des coefficients B_0 et B_1 permettent de calculer pour chaque observation la réponse estimée. Celle-ci sera comparée à la valeur observée de Y_t par l'intermédiaire des résidus e_t ,

où $e_t = Y_t - \widehat{Y}_t$, avec

- $E[e_t] = 0$

car $\sum_{t=1}^n e_t = 0$

- $Var(e_t) = \sum_{t=1}^n e_t^2$

$$Var(e_t) = \sum_{t=1}^n (Y_t - \widehat{Y}_t)^2 = (n-2)\sigma_\varepsilon^2.$$

Ce qui nous permet de déduire que :

$$\widehat{\sigma}_\varepsilon^2 = \frac{\sum_{t=1}^n e_t^2}{(n-2)} = \frac{SCR}{(n-2)} \quad (8)$$

Alors les estimateurs des variances des deux paramètres $\widehat{B}_1$ et $\widehat{B}_0$ sont donnés par

$$\left\{ \begin{array}{l} Var(\widehat{B}_1) = \frac{\widehat{\sigma}_\varepsilon^2}{\sum_{t=1}^n (x_t - \bar{x})^2}, \\ Var(\widehat{B}_0) = \widehat{\sigma}_\varepsilon^2 \left[\frac{1}{n} + \frac{\bar{x}^2}{\sum_{t=1}^n (x_t - \bar{x})^2} \right], \end{array} \right. \quad (9)$$

0.4.1 Décomposition de la variance

L'objectif de la régression est de minimiser $\sum_{t=1}^n e_t^2$ et ce qui nous permet de juger la qualité de l'ajustement de ce modèle.

$$\sum_{t=1}^n (Y_t - \bar{Y})^2 = \sum_{t=1}^n (Y_t - \widehat{Y}_t + \widehat{Y}_t - \bar{Y})^2 = \sum_{t=1}^n (Y_t - \widehat{Y}_t)^2 + \sum_{t=1}^n (\widehat{Y}_t - \bar{Y})^2 + 2 \underbrace{\sum_{t=1}^n (Y_t - \widehat{Y}_t)(\widehat{Y}_t - \bar{Y})}_{=0}$$

$$\underbrace{\sum_{t=1}^n (Y_t - \bar{Y})^2}_{SCT} = \underbrace{\sum_{t=1}^n (Y_t - \widehat{Y}_t)^2}_{SCR} + \underbrace{\sum_{t=1}^n (\widehat{Y}_t - \bar{Y})^2}_{SCE} \quad (10)$$

SCT : somme des carrés totaux (variabilité totale)

SCE : somme des carrés expliqués par le modèle (variabilité expliquée)

SCR : somme des carrés résiduels, non expliqués par le modèle (variabilité résiduelle)

Les estimateurs sont d'autant plus précis lorsque la variance de l'erreur est faible et quand la dispersion des X est forte.

Tableau d'analyse de la variance (ANOVA)

Source de variation	Somme des carrés	Degrés de liberté	Carré moyen
Régression (expliquée)	$SCE = \sum_{t=1}^n (\hat{Y}_t - \bar{Y})^2$	1	SCE
Résiduelle	$SCR = \sum_{t=1}^n (Y_t - \hat{Y}_t)^2$	$n - 2$	$\frac{SCR}{n-2}$
Totale	$SCT = \sum_{t=1}^n (Y_t - \bar{Y})^2$	$n - 1$	

Le coefficient de détermination R^2

Le coefficient de détermination R^2 , nous donne une idée sur la qualité de l'ajustement et il est meilleur lorsque la variabilité expliquée est très proche de la variabilité totale ($c - \hat{a} - d R^2$ est très proche de 1) qui est donné par la formule suivante :

$$R^2 = \frac{\sum_{t=1}^n (\hat{Y}_t - \bar{Y})^2}{\sum_{t=1}^n (Y_t - \bar{Y})^2} = 1 - \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (11)$$

ou

$$R^2 = \frac{SCE}{SCT} = 1 - \frac{SCR}{SCT} = 1 - \frac{\sum_{t=1}^n e_t^2}{SCT} \quad (12)$$

Remarque

Le coefficient de corrélation linéaire simple est défini par

$$r = \rho = R = \frac{\sum_{t=1}^n (Y_t - \bar{Y}) (X_t - \bar{X})}{\sqrt{\sum_{t=1}^n (X_t - \bar{X})^2} \sqrt{\sum_{t=1}^n (Y_t - \bar{Y})^2}} \quad (13)$$

0.5 Tests de significativités du modèle

0.5.1 Test de significativité globale du modèle (Fisher)

Le test de Fisher nous permet de tester la significativité de la régression, ce test est défini par les deux hypothèses suivantes :

$H_0 : B_1 = 0$, Le modèle n'explique pas la variable Y

$H_1 : B_1 \neq 0$, Le modèle est pertinent (globalement significatif)

Pour cela, nous devons calculer la statistique de Fisher empirique F_c afin de la comparer à celle lu sur la table $F_{\frac{\alpha}{2}}(1, n - 2)$, où $(1, n - 2)$ sont les degrés de liberté la statistique de Fisher au seuil $\frac{\alpha}{2}$.

$$F_c = \frac{SCE/1}{SCR/(n - 2)} = \frac{R^2/1}{(1 - R^2)/(n - 2)} \quad (14)$$

Alors :

- si $F_c > F_{\frac{\alpha}{2}}(1, n - 2)$, alors le modèle est globalement significatif.
- si $F_c < F_{\frac{\alpha}{2}}(1, n - 2)$, alors le modèle n'est pas globalement significatif, et que la variable X n'est pas explicative (nous acceptons l'hypothèse H_0).

0.5.2 Test de Student

D'après l'hypothèse H_8 , les erreurs suivent une loi normale, ce qui nous permet de vérifier que :

$$\left\{ \begin{array}{l} \frac{\widehat{B}_0 - B_0}{\sigma_{\widehat{B}_0}^2} \rightsquigarrow N(0, 1), \\ \frac{\widehat{B}_1 - B_1}{\sigma_{\widehat{B}_1}^2} \rightsquigarrow N(0, 1), \\ \frac{\sum_{t=1}^n e_t^2}{\sigma_\varepsilon^2} = \frac{(n-2)\widehat{\sigma}_\varepsilon^2}{\sigma_\varepsilon^2} \rightsquigarrow \chi_{(n-2)}^2, \end{array} \right. \quad \text{où } \chi_{(n-2)}^2 \text{ est le khi-deux à } (n - 2) \text{ degrés de liberté.}$$

$$\text{ET } \left\{ \begin{array}{l} \frac{\widehat{B}_0 - B_0}{\widehat{\sigma}_{\widehat{B}_0}^2} \rightsquigarrow t_{\frac{\alpha}{2}}(n - 2), \\ \frac{\widehat{B}_1 - B_1}{\widehat{\sigma}_{\widehat{B}_1}^2} \rightsquigarrow t_{\frac{\alpha}{2}}(n - 2), \end{array} \right.$$

où $t_{\frac{\alpha}{2}}(n - 2)$ est la Student à $(n - 2)$ degrés de liberté.

Par conséquent, nous pouvons mettre en place des tests statistiques pour voir si les paramètres sont significatifs ?

Test bilatéral

$H_0 : B_1 = 0$ contre $H_1 : B_1 \neq 0$. Dans un premier, nous devons calculer la statistique de Student empirique t_c afin de la comparer à celle lu sur la table $t_{\alpha/2}(n - 2)$, où $(n - 2)$ est le degré de liberté la statistique de Student au seuil $\alpha/2$, avec

$$t_c = \left| \frac{\widehat{B}_1 - B_1}{\widehat{\sigma}_{\widehat{B}_1}^2} \right| \quad (15)$$

Alors :

- si $t_c > t_{\alpha/2}(n-2)$, alors B_1 est significatif.
- si $F_c < t_{\alpha/2}(n-2)$, alors B_1 n'est pas significatif, et que la variable X n'est pas explicative (nous acceptons l'hypothèse H_0).

De la même manière, nous pouvons vérifier si B_0 est significatif ou non ?

Intervalle de confiance

Nous pouvons aussi donner un intervalle de confiance pour chaque paramètre. Dans la plus part des cas σ_ε est inconnu, alors

L'intervalle de confiance pour B_0 (I_{cB_0})

$$B_0 = \widehat{B}_0 \pm t_{\alpha/2}(n-2) \widehat{\sigma}_{\widehat{B}_0} \quad (16)$$

où $t_{\alpha/2}(n-2)$ est la valeur de la statistique de Student au seuil $\alpha/2$ à $(n-2)$ est le degré de liberté lu sur la table.

Remarque

$H_0 : B_0 = 0$ contre $H_1 : B_0 \neq 0$.

- si $0 \notin I_{cB_0}$, alors B_0 est significatif.
- si $0 \in I_{cB_0}$, alors B_0 n'est pas significatif, et que ce modèle ne contient de constante. La même chose pour l'intervalle de confiance pour B_1 , si $0 \in I_{cB_1}$, alors B_1 n'est pas significatif, et que la variable X n'est pas explicative (nous acceptons l'hypothèse H_0). Sinon, nous acceptons l'hypothèse H_1 et que la variable X est une variable explicative pour la variable endogène Y .

0.6 Prévision

L'un des buts de la régression est de proposer des prévisions pour la variable endogène Y . Une fois le modèle est validé, nous pouvons faire des prévisions pour une valeur non observée X_{n+h} . Dans un premier temps, nous devons calculer Y_{n+h} qui est donné par

$$Y_{n+h} = B_0 + B_1 X_{n+h} + \varepsilon_{n+h} \quad (17)$$

avec $E[\varepsilon_{n+h}] = 0$ et $Cov(\varepsilon_{n+h}, \varepsilon_t) = 0$ et $Var(\varepsilon_{n+h}^2) = \sigma_\varepsilon^2$.

- La variance de l'erreur de prévision est donnée par

$$Var(\widehat{\varepsilon}_{n+h}) = Var(B_0 - \widehat{B}_0) + Var(B_1 - \widehat{B}_1)X_{n+h}^2 + 2X_{n+h}Cov(\widehat{B}_0, \widehat{B}_1) + Var(\varepsilon_{n+h})$$

$$Var(\widehat{\varepsilon}_{n+h}) = Var(\widehat{B}_0) + Var(\widehat{B}_1)X_{n+h}^2 + Var(\varepsilon_{n+h})$$

$$Var(\widehat{\varepsilon}_{n+h}) = \frac{\sigma_\varepsilon^2}{n} + (X_{n+h} - \bar{X})^2 \frac{\sigma_\varepsilon^2}{\sum_{t=1}^n (X_t - \bar{X})^2} + \sigma_\varepsilon^2$$

$$Var(\widehat{\varepsilon}_{n+h}) = \sigma_\varepsilon^2 \left[\frac{1}{n} + \frac{(X_{n+h} - \bar{X})^2}{\sum_{t=1}^n (X_t - \bar{X})^2} + 1 \right] \quad (18)$$

- La variance de l'erreur de prévision est fonction de l'écart quadratique entre la variable exogène prévue et la moyenne de la même variable. Donc plus la valeur prévue s'éloigne de cette moyenne, plus le risque d'erreur est important.

Remarque

D'après l'hypothèse H_8 , nous déduisons que :

$$\widehat{\varepsilon}_{n+h} \rightsquigarrow N \left(0, \sigma_\varepsilon^2 \left[\frac{1}{n} + \frac{(X_{n+h} - \bar{X})^2}{\sum_{t=1}^n (X_t - \bar{X})^2} + 1 \right] \right).$$

- La valeur de prévision correspondante au modèle estimé est défini par

$$\widehat{Y}_{n+h} = \widehat{B}_0 + \widehat{B}_1 X_{n+h} \quad (19)$$

Et sa variance est donnée par

$$Var(\widehat{Y}_{n+h}) = \widehat{\sigma}_\varepsilon^2 \left[\frac{1}{n} + \frac{(X_{n+h} - \bar{X})^2}{\sum_{t=1}^n (X_t - \bar{X})^2} + 1 \right] \quad (20)$$

- L'intervalle de prédiction est défini par

$$Y_{n+h} = \widehat{Y}_{n+h} \pm t_{\frac{\alpha}{2}}(n-2) \widehat{\sigma}_\varepsilon \sqrt{\left[\frac{1}{n} + \frac{(X_{n+h} - \bar{X})^2}{\sum_{t=1}^n (X_t - \bar{X})^2} + 1 \right]}. \quad (21)$$

0.7 Exemple

Soit le modèle : $Y_i = B_0 + B_1X_i + \varepsilon_i$, $i = \overline{1,8}$

Avec les données suivantes :

X_i	11.2	13.2	16	16	16.8	17.2	18.6	19
Y_i	28	33	30.4	34	32.2	38	40	36.4

1. Représenter le nuage de points.
2. Déterminer les estimateurs B_0 , B_1 et étudier la significativité de chaque paramètre.
3. Calculer le SCE , SCT , SCR et le coefficient de détermination. Conclusion ?
4. Donner la prévision à la date 9 sachant que $X_9 = 19.5$
5. Donner le tableau de l'analyse de la variance.

Corrigé 1.

1. Représentation du nuage de points

Figure 1 - Nuage de points X_t et Y_t

D'après la figure, nous constatons que le nuage de points ne donne pas une idée claire sur le type de relation qu'il existe entre les deux variables, et que la droite de régression ne passe par l'origine.

$\widehat{B}_0$ et $\widehat{B}_1$ sont les quantités qui minimisent les distances verticales entre les observations Y_t et la droite de régression théorique $Y_t = B_0 + B_1 X_t + \varepsilon_t$, et la droite de régression estimée est donnée par :

$$\widehat{Y}_t = \widehat{B}_0 + \widehat{B}_1 X_t.$$

Afin de caculer les estimateurs des coefficients de régression, nous réalisons le tableau suivant :

n	X_i	Y_i	$X_i Y_i$	X_i^2	Y_i^2	$\widehat{Y}_i$	$e_i = Y_i - \widehat{Y}_i$	e_i^2
1	11.2	28	313.6000	125.44	784.0000	28.309359	-0.309359	0.095703
2	13.2	33	435.6000	174.24	1089.0000	30.680460	2.319540	5.380265
3	16	30.4	486.4000	256.0000	924.1600	33.999999	-3.599999	12.960002
4	16	34	544.0000	256.0000	1156.0000	34.000000	0.000000	0.000000
5	16.8	32.2	540.9600	282.2400	1036.8400	34.000000	-2.748440	7.553924
6	17.2	38	653.6000	295.8400	1444.0000	34.948440	2.577339	6.6426795
7	18.6	40	744.0000	345.9600	1600.0000	35.422660	2.917569	8.512211
8	19	36.4	691.6000	361.0000	1324.9600	37.556650	-1.156650	1.337840
Σ	128	272	4409.7600	2096.7200	9358.9600		0	42.48263

$$\bar{X} = \frac{128}{8} = 16 \text{ et } \bar{Y} = \frac{272}{8} = 34$$

$$\widehat{B}_1 = \frac{\sum_{t=1}^n X_t Y_t - n \bar{X} \bar{Y}}{\sum_{t=1}^n X_t^2 - n \bar{X}^2} = \frac{4409.76 - 8(16)(34)}{2096.72 - 8(16)^2} = 1.18555008$$

$$\widehat{B}_0 = \bar{Y} - \widehat{B}_1 \bar{X} = 34 - 1.18555008(16) = 15.031199$$

On écrit

$$\widehat{Y}_i = 15.031199 + 1.18555008 X_i \quad (22)$$

2. ♣ On a $\sum_{t=1}^n e_t^2 = 42.48263$. Et $\widehat{\sigma}_\varepsilon^2 = \frac{\sum_{t=1}^n e_t^2}{(n-2)} = \frac{42.48263}{8-2} = 7.080438$

$$\clubsuit \text{Var}(\widehat{B}_1) = \frac{\widehat{\sigma}_\varepsilon^2}{\sum_{t=1}^n (X_t - \bar{X})^2} = \frac{7.080438}{2096.7200 - 8(16)^2} = 0.145329$$

d'ou

$$\widehat{\sigma}_{\widehat{B}_1} = 0.381220$$

$$\clubsuit \text{Var}(\widehat{B}_0) = \widehat{\sigma}_\varepsilon^2 \left[\frac{1}{n} + \frac{\bar{X}^2}{\sum_{t=1}^n (X_t - \bar{X})^2} \right]$$

$$\text{Var}(\widehat{B}_0) = 7.08044 \left[\frac{1}{8} + \frac{(16)^2}{2096.7200 - 8(16)^2} \right] = 38.089324$$

$$\widehat{\sigma}_{\widehat{B}_0} = 6.171655$$

♣ On utilise le test de Student pour la significativité de B_0 , qui est définie par :

$$H_0 : B_0 = 0 \text{ contre } H_1 : B_0 \neq 0$$

Pour cela, on doit calculer $t_{c_{B_0}}$

$$t_{c_{B_0}} = \left| \frac{\widehat{B}_0 - B_0}{\widehat{\sigma}_{\widehat{B}_0}} \right| = \frac{15.03120 - 0}{6.171655} = 2.435522 \quad (23)$$

D'après la valeur de la Statistique de Student calculer pour B_0 ($t_{c_{B_0}} = 2.435522$) est inférieure à $t_T(6, 0.025) = 2.447$ ($t_T(6, 0.025)$ est la valeur de la statistique de Student lu sur la table avec 6 est degré de liberté et 0.025 est le seuil de confiance). on conclut donc que le paramètre n'est pas significatif.

♣ De même pour étudier la significativité de B_1 . Le test de Student est défini par :

$$H_0 : B_1 = 0 \text{ contre } H_1 : B_1 \neq 0$$

Pour cela, on doit calculer $t_{c_{B_1}}$

$$t_{c_{B_1}} = \left| \frac{\widehat{B}_1 - B_1}{\widehat{\sigma}_{\widehat{B}_1}} \right| = \frac{1.185550 - 0}{0.381221} = 3.109879 \quad (24)$$

D'après la valeur de la Statistique de Student calculer pour B_0 ($t_{c_{B_1}} = 3.109879$) est supérieure à $t_T(6, 0.025) = 2.447$ ($t_T(6, 0.025)$ est la valeur de la statistique de Student lu sur la table avec 6 est degré de liberté et 0.025 est le seuil de confiance). on conclut donc que le paramètre est significatif.

3. Le calcul SCT , SCE et R^2

♣ On sait que : $SCR = \sum_{t=1}^n e_t^2 = 42.48263$

♣

$$SCT = \sum_{t=1}^n [Y_t - \bar{Y}]^2 = \sum_{t=1}^n Y_t^2 - n\bar{Y}^2 = 9358.96000 - 8(34)^2 = 110.96000 \quad (25)$$

♣ On a $SCT = SCE + SCR$, donc

$$SCE = SCT - SCR = 110.960000 - 42.48263 = 68.47737 \quad (26)$$

Remarque

On peut également calculer SCE en utilisant la formule suivante :

$$SCE = \sum_{t=1}^n [\widehat{Y}_t - \bar{Y}]^2 = \widehat{\beta}_1^2 \left[\sum_{t=1}^n X_t^2 - n\bar{X}^2 \right] = 1.185550^2(48.72) = 68.477363 \quad (27)$$

♣

$$R^2 = \frac{SCE}{SCT} = \frac{68.47737}{110.960000} = 0.617136. \quad (28)$$

D'après la valeur de R^2 , le modèle est moyennement significatif

4. Le calcul de la prévision à la date 9 sachant que $X_9 = 19.5$

D'après la Statistique de Student calculer pour chaque paramètre calculer précédemment est supérieure à $t_T(6, 0.05) = 1.943$ ($t_T(6, 0.05)$ est la valeur de la statistique de Student lu sur la table avec 6 est degré de liberté et 0.05 est le seuil de confiance). on conclut donc que les deux paramètres sont significatifs. Ce qui nous permis de dire que ce modèle est validé et de calculer la prévision à la date 9 .

♣ La valeur de prévision correspondante au modèle estimé est défini par

$$\widehat{Y}_{n+1} = \widehat{B}_0 + \widehat{B}_1 X_{n+1} \quad (29)$$

Donc

$$\widehat{Y}_9 = 15.03120 + 1.185550X_9 = 15.03120 + 1.185550(19.5) = 38.149425$$

♣ La variance de l'erreur de prévision $Var(\widehat{\varepsilon}_{n+h})$ est donnée par :

$$Var(\widehat{\varepsilon}_{n+h}) = \widehat{\sigma}_\varepsilon^2 \left[\frac{1}{n} + \frac{(X_{n+1} - \bar{X})^2}{\sum_{t=1}^n (X_t - \bar{X})^2} + 1 \right] \quad (30)$$

$$Var(\widehat{\varepsilon}_9) = \widehat{\sigma}_\varepsilon^2 \left[\frac{1}{8} + \frac{(X_9 - \bar{X})^2}{\sum_{t=1}^n (X_t - \bar{X})^2} + 1 \right] = 2.660909 \left[\frac{1}{8} + \frac{(19.5 - 16)^2}{48.72} + 1 \right] = 3.662569$$

Alors $\sigma_{\widehat{\varepsilon}_9} = 1.913784$

♣ L'intervalle de prédiction est défini par :

$$Y_{n+1} = \hat{Y}_{n+1} \pm t_{\frac{\alpha}{2}}(n-2) \sqrt{Var(\hat{\varepsilon}_{n+1})}. \quad (31)$$

$$Y_9 = \hat{Y}_9 \pm t_{0.05}(6) \sigma_{\hat{\varepsilon}_9} = 38.149425 \pm 1.943(1.913784) = [34.43094 ; 41.86791]$$

5. Le tableau de l'analyse de la variance

Source de variation	Somme des carrés	Degrés de liberté	Carré moyen
Régression X_1	$SCE = 68.47737$	1	$\frac{SCE}{1} = 68.47737$
Résiduelle	$SCR = 42.48263$	$n - 2 = 8 - 2 = 6$	$\frac{SCR}{n-2} = \frac{42.48263}{6} = 7.08044$
Totale	$SCT = 110.96$	$n - 1 = 8 - 1 = 7$	