Compléments sur la régression linéaire simple
Anova et inférence sur les paramètres

Frédéric & Myriam Bertrand[1]

[1]IRMA, Université Louis Pasteur
Strasbourg, France

Master 1ère Année 30-01-2008

Test et analyse de variance de la régression
Distribution des paramètres
Tests et intervalles de confiance sur les paramètres
Distribution et intervalle de confiance
Un exemple

Ce cours s'appuie essentiellement sur les deux ouvrages suivants :

- "Analyse de régression appliquée" de Y. Dodge et V. Rousson, Dunod.
- "Régression non linéaire et applications" de A. Antoniadis, J. Berruyer, R. Carmona, Economica.

- Il existe plusieurs démarches pour tester la validité de la linéarité d'une régression simple.
- On montre l'équivalence de ces différents tests.
- Conséquence : Cela revient à faire **le test du coefficient de corrélation linéaire**, appelé aussi le coefficient de Bravais-Pearson.

Remarque : On peut consulter sur le site un cours sur le coefficient de corrélation linéaire (Cours de L3).

Frédéric & Myriam Bertrand | Compléments sur la régression linéaire simple
Test et analyse de variance de la régression
Distribution des paramètres
Tests et intervalles de confiance sur les paramètres
Distribution et intervalle de confiance
Un exemple
Test

On désire tester l'hypothèse nulle :

$$\mathcal{H}_0 : \rho = 0$$

contre l'hypothèse alternative :

$$\mathcal{H}_1 : \rho \neq 0$$

où

$$\rho = \frac{Cov(X, Y)}{\sqrt{Var[X]Var[Y]}},$$

avec

$$Cov(X, Y) = \mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y] = Cov(Y, X),$$

$$Var[X] = \mathbb{E}\left[X^2\right] - \mathbb{E}^2[X] \quad \text{et} \quad Var[Y] = \mathbb{E}\left[Y^2\right] - \mathbb{E}^2[Y].$$

La méthode que nous allons employer ici est :

la méthode de l'ANOVA

utilisée par les logiciels de statistique.

Remarque : ANOVA pour ANalysis Of VAriance ou encore analyse de la variance.

Remarque : On peut consulter sur le site un cours sur le test du coefficient de corrélation linéaire (Cours de L3).

On a établi précédemment :

Somme des Carrés Totale = Somme des Carrés Expliquée + Somme des Carrés Résiduelle

ce qui s'écrit mathématiquement par :

$$\sum_{i=1}^{n}(y_i-\overline{y})^2=\sum_{i=1}^{n}(y_i-\hat{y}_i)^2+\sum_{i=1}^{n}(\hat{y}_i-\overline{y})^2.$$

À chaque somme de carrés est associé son nombre de degrés de liberté (*ddl*.) Ces *ddl* sont présents dans le tableau de l'ANOVA.

Source de variation	SC	*ddl*	CM
régression SCE	$\sum_{i=1}^{n}(\hat{y}_i-\overline{y})^2$	1	SCE/1
résiduelle SCR	$\sum_{i=1}^{n}(y_i-\hat{y}_i)^2$	$n-2$	SCR/$(n-2)$
totale SCT	$\sum_{i=1}^{n}(y_i-\overline{y})^2$	$n-1$	

Remarques :

- Le **coefficient de détermination**

$$R^2=\frac{\text{SCE}}{\text{SCT}}$$

mesure le pourcentage d'explication du modèle par la régression linéaire.

- Le rapport

$$s^2=\frac{\text{SCR}}{n-2}$$

est l'**estimation de la variance résiduelle**.

À partir du tableau de l'ANOVA, on effectue **le test de la linéarité de la régression** en calculant **la statistique de Fisher** F qui suit une loi de Fisher $F(1, n-2)$.

Cette variable aléatoire F se réalise en :

$$F_{obs} = \frac{\text{SCE}/1}{\text{SCR}/(n-2)} = (n-2)\frac{\text{SCE}}{\text{SCR}}.$$

Si

$$F_{obs} \geq F_\alpha(1, n-2),$$

alors on rejette l'hypothèse nulle $\mathcal{H}_0$ au risque α, c'est-à-dire qu'il existe une liaison linéaire significative entre X et Y.

Si

$$F_{obs} < F_\alpha(1, n-2),$$

alors on accepte l'hypothèse nulle $\mathcal{H}_0$, c'est-à-dire qu'il n'existe pas de liaison linéaire entre X et Y.

Remarque : En effet, si l'hypothèse nulle $\mathcal{H}_0$ est vérifiée alors cela implique que $\rho = 0$ c'est-à-dire $Cov(X, Y) = 0$. Donc il n'existe aucune liaison linéaire entre X et Y.

Le modèle de régression linéaire simple est

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

où les ε_i sont des variables aléatoires inobservables, appelées **les erreurs**.

Conséquence : Les y_i sont des variables aléatoires.

Première hypothèse : $\mathbb{E}[\varepsilon_i] = 0$.
Conséquence : $\mathbb{E}[y_i] = \beta_0 + \beta_1 x_i$.

D'autre part, on a :

$$Var[y_i] = Var[\varepsilon_i].$$

Les trois hypothèses indispensables pour construire la théorie :

1. La variance des variables aléatoires ε_i est égale à σ^2 (inconnue) ne dépendant pas de x_i.
   On a donc pour tout $i = 1, \cdots, n$:
   $$Var[\varepsilon_i] = Var[y_i] = \sigma^2.$$
2. Les variables aléatoires ε_i sont indépendantes.
3. Les variables aléatoires ε_i sont normalement distribuées.

Ces trois hypothèses sont équivalentes à :

les variables aléatoires ε_i sont indépendantes et identiquement distribuées selon une loi normale de moyenne nulle et de variance σ^2.

On note :

$$\varepsilon_i \quad \text{i.i.d.} \sim \mathcal{N}(0, \sigma^2).$$

Conséquences importantes :

- La normalité des variables aléatoires ε_i implique la normalité des variables aléatoires y_i.
- L'indépendance des variables aléatoires ε_i implique l'indépendance des variables aléatoires y_i.
  En effet, on montre en calculant que :

$$\begin{aligned} Cov[y_i, y_j] &= Cov[\beta_0 + \beta_1 x_i + \varepsilon_i, \beta_0 + \beta_1 x_j + \varepsilon_j] \\ &= Cov[\varepsilon_i, \varepsilon_j] \\ &= 0. \end{aligned}$$

On a :

$$\hat{\beta}_1 = \frac{\sum (x_i - \overline{x}) y_i}{\sum (x_i - \overline{x})^2},$$

où

$$\overline{x} = \frac{\sum x_i}{n}.$$

Il en résulte que :

- $\hat{\beta}_1$ **est une variable aléatoire** car $\hat{\beta}_1$ dépend des variables y_i qui sont des variables aléatoires.
- $\hat{\beta}_1$ **est une fonction linéaire des variables** y_i.
- Comme les variables y_i par hypothèse sont normalement distribuées, alors $\hat{\beta}_1$ **est normalement distribuée**.

Il reste donc à calculer ces deux valeurs pour caractériser l'estimateur $\hat{\beta}_1$:

- $\mathbb{E}\left[\hat{\beta}_1\right]$
- $Var\left[\hat{\beta}_1\right]$.

Par calcul, on montre que :

$$\begin{aligned}
\mathbb{E}\left[\hat{\beta}_1\right] &= \mathbb{E}\left[\frac{\sum(x_i-\overline{x})y_i}{\sum(x_i-\overline{x})^2}\right] \\
&= \frac{\sum(x_i-\overline{x})\mathbb{E}[y_i]}{\sum(x_i-\overline{x})^2} \\
&= \frac{\sum(x_i-\overline{x})(\beta_0+\beta_1 x_i)}{\sum(x_i-\overline{x})^2} \\
&= \frac{\beta_0\sum(x_i-\overline{x})+\beta_1\sum(x_i-\overline{x})x_i}{\sum(x_i-\overline{x})^2} \\
&= \frac{0+\beta_1\sum(x_i-\overline{x})x_i}{\sum(x_i-\overline{x})^2}.
\end{aligned}$$

En effet, on montre que :

$$\sum(x_i-\overline{x})=0.$$

De plus, comme on a :

$$\sum(x_i-\overline{x})^2=\sum(x_i-\overline{x})x_i$$

alors on obtient :

$$\mathbb{E}\left[\hat{\beta}_1\right]=\beta_1.$$

Donc la variable aléatoire $\hat{\beta}_1$ est **un estimateur sans biais** du coefficient β_1.

D'autre part, on calcule la variance de $\hat{\beta}_1$ ainsi :

$$\begin{aligned}
Var\left[\hat{\beta}_1\right] &= Var\left[\frac{\sum(x_i-\overline{x})y_i}{\sum(x_i-\overline{x})^2}\right] \\
&= \frac{\sum(x_i-\overline{x})^2 Var[y_i]}{\left(\sum(x_i-\overline{x})^2\right)^2} \\
&= \frac{\sum(x_i-\overline{x})^2\sigma^2}{\left(\sum(x_i-\overline{x})^2\right)^2} \\
&= \frac{\sigma^2}{\sum(x_i-\overline{x})^2},
\end{aligned}$$

ce qui achève la caractérisation de $\hat{\beta}_1$.

On a :

$$\hat{\beta}_0=\overline{y}-\hat{\beta}_1\overline{x}$$

où

$$\overline{x}=\frac{\sum x_i}{n} \quad \text{et} \quad \overline{y}=\frac{\sum y_i}{n}.$$

- $\hat{\beta}_0$ **est une variable aléatoire** car $\hat{\beta}_0$ dépend de $\hat{\beta}_1$ qui est une variable aléatoire.
- $\hat{\beta}_0$ **est une fonction linéaire de** $\hat{\beta}_1$.
- Comme $\hat{\beta}_1$ est normalement distribuée, alors $\hat{\beta}_0$ **est normalement distribuée**.

Il reste donc à calculer ces deux valeurs pour caractériser l'estimateur $\hat{\beta}_0$:

- $\mathbb{E}\left[\hat{\beta}_0\right]$
- $Var\left[\hat{\beta}_0\right]$.

Par calcul, on montre que :

$$\begin{aligned}\mathbb{E}\left[\hat{\beta}_0\right] &= \mathbb{E}\left[\overline{y} - \hat{\beta}_1\overline{x}\right] \\ &= \mathbb{E}\left[\overline{y}\right] - \overline{x}\mathbb{E}\left[\hat{\beta}_1\right] \\ &= \mathbb{E}\left[\overline{y}\right] - \overline{x}\beta_1,\end{aligned}$$

car on vient de démontrer que $\hat{\beta}_1$ est un estimateur sans biais du coefficient β_1.

Il reste à calculer la valeur :

$$\mathbb{E}\left[\overline{y}\right].$$

Or on a :

$$\begin{aligned}\mathbb{E}\left[\overline{y}\right] &= \mathbb{E}\left[\frac{\sum y_i}{n}\right] \\ &= \frac{\sum \mathbb{E}[y_i]}{n} \\ &= \frac{\sum(\beta_0 + \beta_1 x_i)}{n} \\ &= \frac{n\beta_0 + \beta_1 \sum x_i}{n} \\ &= \beta_0 + \overline{x}\beta_1.\end{aligned}$$

On obtient donc :

$$\begin{aligned}\mathbb{E}\left[\hat{\beta}_0\right] &= \mathbb{E}\left[\overline{y}\right] - \overline{x}\beta_1 \\ &= (\beta_0 + \overline{x}\beta_1) - \overline{x}\beta_1 \\ &= \beta_0.\end{aligned}$$

Donc la variable aléatoire $\hat{\beta}_0$ est **un estimateur sans biais** du coefficient β_0.

D'autre part, on calcule la variance de $\hat{\beta}_0$ ainsi :

$$\begin{aligned} Var\left[\hat{\beta}_0\right] &= Var\left[\overline{y} - \hat{\beta}_1 \overline{x}\right] \\ &= Var[\overline{y}] + \overline{x}^2\, Var\left[\hat{\beta}_1\right] - 2\,\overline{x}\, Cov\left[\overline{y}, \hat{\beta}_1\right]. \end{aligned}$$

Il reste donc à calculer la valeur :

$$Cov\left[\overline{y}, \hat{\beta}_1\right].$$

Par les calculs, on montre que :

$$\begin{aligned} Cov\left[\overline{y}, \hat{\beta}_1\right] &= Cov\left[\frac{\sum y_i}{n}, \frac{\sum (x_j - \overline{x}) y_j}{\sum (x_i - \overline{x})^2}\right] \\ &= \frac{\sum_i \sum_j (x_j - \overline{x}) Cov[y_i, y_j]}{n \sum (x_i - \overline{x})^2} \\ &= \frac{\sum_i (x_i - \overline{x}) Var[y_i]}{n \sum (x_i - \overline{x})^2} \\ &= \frac{\sigma^2 \sum_i (x_i - \overline{x})}{n \sum (x_i - \overline{x})^2} \\ &= 0. \end{aligned}$$

Comme

$$Var[\overline{y}] = \frac{\sigma^2}{n},$$

on obtient :

$$\begin{aligned} Var\left[\hat{\beta}_0\right] &= Var[\overline{y}] + \overline{x}^2 Var\left[\hat{\beta}_1\right] \\ &= \frac{\sigma^2}{n} + \frac{\overline{x}^2 \sigma^2}{\sum (x_i - \overline{x})^2} \\ &= \frac{\sigma^2 \left(\sum (x_i - \overline{x})^2 + n\overline{x}^2\right)}{n \sum (x_i - \overline{x})^2}. \end{aligned}$$

En rappelant que :

$$\sum (x_i - \overline{x})^2 = \sum x_i^2 - n\overline{x}^2,$$

on a finalement :

$$Var\left[\hat{\beta}_0\right] = \frac{\sigma^2 \sum x_i^2}{n \sum (x_i - \overline{x})^2}.$$

On rappelle que :

$$\hat{\beta}_1 \sim \mathcal{N}(\beta_1; \sigma^2(\hat{\beta}_1))$$

où

$$\sigma^2(\hat{\beta}_1) = \frac{\sigma^2}{\sum(x_i - \overline{x})^2}.$$

On obtient alors :

$$\frac{\hat{\beta}_1 - \beta_1}{\sigma(\hat{\beta}_1)} \sim \mathcal{N}(0; 1).$$

Problème :

On ne connait pas le paramètre σ^2, c'est-à-dire la variance des variables aléatoires ε_i.

Que peut-on faire alors pour résoudre ce problème ?

Solution : Estimer ce paramètre !

- On estime d'abord σ^2 par s^2 l'estimateur sans biais de σ^2 :

$$s^2 = \frac{||\varepsilon||^2}{n-2} = \frac{\sum(y_i - \hat{y}_i)^2}{n-2}.$$

- On estime ensuite $\sigma^2(\hat{\beta}_1)$ par :

$$s^2(\hat{\beta}_1) = \frac{s^2}{\sum(x_i - \overline{x})^2}.$$

- On montre alors que :

$$\frac{\hat{\beta}_1 - \beta_1}{s(\hat{\beta}_1)} \sim T_{n-2},$$

où T_{n-2} désigne une variable aléatoire de Student avec $(n-2)$ *ddl*.

On désire tester l'hypothèse nulle :

$$\mathcal{H}_0 : \beta_1 = 0$$

contre l'hypothèse alternative :

$$\mathcal{H}_1 : \beta_1 \neq 0.$$

On utilise la statistique :

$$t_{obs} = \frac{\hat{\beta}_1}{s(\hat{\beta}_1)}$$

pour décider de l'acceptation ou du rejet de l'hypothèse nulle $\mathcal{H}_0$.

Deux conclusions sont possibles :

On rejette l'hypothèse nulle $\mathcal{H}_0$ au seuil de signification α si

$$|t_{obs}| > t_{(\alpha/2,n-2)}$$

où la valeur critique $t_{(\alpha/2,n-2)}$ est le $(1-\alpha/2)$-quantile d'une loi de Student avec $(n-2)$ *ddl*.

Dans ce cas, on dit que la relation linéaire entre X et Y est significative au seuil α.

On accepte l'hypothèse nulle $\mathcal{H}_0$ au seuil de signification α si

$$|t_{obs}| < t_{(\alpha/2,n-2)}$$

où la valeur $t_{(\alpha/2,n-2)}$ est le $(1-\alpha/2)$-quantile d'une loi de Student avec $(n-2)$ *ddl*.

Dans ce cas, Y ne dépend pas linéairement de X. Le modèle devient alors :

$$y_i = \beta_0 + \varepsilon_i$$

Le modèle proposé $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$ est inadéquat. On teste alors un nouveau modèle.

Un intervalle de confiance au niveau $(1-\alpha)$ pour le coefficient inconnu β_1 est défini par

$$\left[\hat{\beta}_1 - t_{(\alpha/2,n-2)} \times s(\hat{\beta}_1)\,;\ \hat{\beta}_1 + t_{(\alpha/2,n-2)} \times s(\hat{\beta}_1)\right].$$

Cet intervalle de confiance est construit de telle sorte qu'il contienne le coefficient inconnu β_1 avec une probabilité égale à $(1-\alpha)$.

On rappelle que :

$$\hat{\beta}_0 \sim \mathcal{N}(\beta_0; \sigma^2(\hat{\beta}_0))$$

où

$$\sigma^2(\hat{\beta}_0) = \frac{\sigma^2 \sum x_i^2}{n\sum(x_i - \overline{x})^2}.$$

On obtient alors :

$$\frac{\hat{\beta}_0 - \beta_0}{\sigma(\hat{\beta}_0)} \sim \mathcal{N}(0;1).$$

Problème :

On ne connait pas le paramètre σ^2, c'est-à-dire la variance des variables aléatoires ε_i.

Que peut-on faire alors pour résoudre ce problème ?

Solution : Estimer ce paramètre !

- On estime d'abord σ^2 par s^2 l'estimateur sans biais de σ^2 et s^2 :

$$s^2 = \frac{||\varepsilon||^2}{n-2} = \frac{\sum(y_i - \hat{y}_i)^2}{n-2}.$$

- On estime ensuite $\sigma^2(\hat{\beta}_0)$ par

$$s^2(\hat{\beta}_0) = \frac{s^2 \sum x_i^2}{n\sum(x_i - \overline{x})^2}.$$

- On montre alors que :

$$\frac{\hat{\beta}_0 - \beta_0}{s(\hat{\beta}_0)} \sim T_{n-2},$$

où T_{n-2} désigne une variable aléatoire de Student avec $(n-2)$ *ddl*.

On désire tester l'hypothèse nulle

$$\mathcal{H}_0 : \beta_0 = 0$$

contre l'hypothèse alternative

$$\mathcal{H}_1 : \beta_0 \neq 0.$$

On utilise la statistique

$$t_{obs} = \frac{\hat{\beta}_0}{s(\hat{\beta}_0)}$$

pour décider de l'acceptation ou du rejet de l'hypothèse nulle $\mathcal{H}_0$.

Deux conclusions sont possibles :

On rejette l'hypothèse nulle $\mathcal{H}_0$ au seuil de signification α si :

$$|t_{obs}| > t_{(\alpha/2,n-2)}$$

où la valeur critique $t_{\alpha/2,n-2}$ est le $(1-\alpha/2)$-quantile d'une loi de Student avec $(n-2)$ ddl.

Dans ce cas, le coefficient β_0 du modèle est dit significatif au seuil α.

On accepte l'hypothèse nulle $\mathcal{H}_0$ au seuil de signification α si

$$|t_{obs}| < t_{(\alpha/2,n-2)}$$

où la valeur critique $t_{(\alpha/2,n-2)}$ est le $(1-\alpha/2)$-quantile d'une loi de Student avec $(n-2)$ *ddl*.

Dans ce cas, l'ordonnée de la droite de regréssion passe par l'origine.

$$y_i = \beta_1 x_i + \varepsilon_i$$

Un intervalle de confiance au niveau $(1-\alpha)$ pour le coefficient inconnu β_0 est défini par :

$$\left[\hat{\beta}_0 - t_{(\alpha/2,n-2)} \times s(\hat{\beta}_0)\,;\ \hat{\beta}_0 + t_{(\alpha/2,n-2)} \times s(\hat{\beta}_0)\right].$$

Cet intervalle de confiance est construit de telle sorte qu'il contienne le coefficient inconnu β_0 avec une probabilité égale à $(1-\alpha)$.

On va voir comment trouver un intervalle de confiance pour

$$\mu_Y(x) = \beta_0 + \beta_1 x,$$

c'est-à-dire pour l'ordonnée du point d'abscisse x se trouvant sur la droite de régression.

L'estimateur de $\beta_0 + \beta_1 x$ est donné par la droite des moindre carrés :

$$\hat{y}(x) = \hat{\beta}_0 + \hat{\beta}_1 x,$$

où

- $\hat{y}(x) \sim \mathcal{N}\left(\beta_0 + \beta_1 x; \sigma^2(\hat{y}(x))\right)$

où

$$\sigma^2(\hat{y}(x)) = \sigma^2\left(\frac{1}{n} + \frac{(x-\bar{x})^2}{\sum(x_i-\bar{x})^2}\right).$$

Ce qui peut s'écrire aussi :

- $\dfrac{\hat{y}(x) - \mu_Y(x)}{\sigma(\hat{y}(x))} \sim \mathcal{N}(0;1).$

Problème : La variance σ^2 est inconnue.
Solution :

- On estime d'abord σ^2 par s^2.
- On estime ensuite $\sigma^2(\hat{y}(x))$ par :

$$s^2(\hat{y}(x)) = s^2\left(\frac{1}{n} + \frac{(x-\bar{x})^2}{\sum(x_i-\bar{x})^2}\right).$$

- Ainsi on obtient :

$$\frac{\hat{y}(x) - \mu_Y(x)}{s(\hat{y}(x))} \sim T_{n-2}.$$

Un intervalle de confiance au niveau $(1-\alpha)$ pour le paramètre inconnu $\mu_Y(x)$ est défini par :

$$\left[\hat{y}(x) - t_{(\alpha/2;n-2)} \times s(\hat{y}(x)) \,;\, \hat{y}(x) + t_{(\alpha/2;n-2)} \times s(\hat{y}(x))\right].$$

Cet intervalle de confiance est construit de telle sorte qu'il contienne le paramètre inconnu $\mu_Y(x)$ avec une probabilité égale à $(1-\alpha)$.

Observations i	Pays	Taux d'urbanisation x_i	Taux de natalité y_i	Valeurs estimées $\hat{y}_i$	Résidus e_i
1	Canada	55,0	16,2	21,05	−4,85
2	Costa Rica	27,3	30,5	32,10	−1,60
3	Cuba	33,3	16,9	29,71	−12,81
4	E.U.	56,5	16,0	20,45	−4,45
5	El Salvador	11,5	40,2	38,40	1,80
6	Guatemala	14,2	38,4	37,33	1,07
7	Haïti	13,9	41,3	37,45	3,83

Observations i	Pays	Taux d'urbanisation x_i	Taux de natalité y_i	Valeurs estimées $\hat{y}_i$	Résidus e_i
8	Honduras	19,0	43,9	35,41	8,49
9	Jamaïque	33,1	28,3	29,79	−1,49
10	Mexique	43,2	33,9	25,76	8,14
11	Nicaragua	28,5	44,2	31,62	12,58
12	Trinidade	6,8	24,6	40,28	−15,68
13	Panama	37,7	28,0	27,95	0,05
14	Rép. Dom.	37,1	33,1	28,19	4,91

Le tableur Excel donne successivement :

$$\hat{\beta}_1 = -0,3989,$$

$$\hat{\beta}_0 = 42,991$$

et enfin

$$s^2 = 66,24.$$

Test sur la pente β_1.

$$\mathcal{H}_0 : \beta_1 = 0$$

contre

$$\mathcal{H}_1 : \beta_1 \neq 0.$$

On calcule

$$t_{obs} = \frac{\hat{\beta}_1}{s(\hat{\beta}_1)} = \frac{-0,3989}{\sqrt{0,021}} = -2,75.$$

Or la valeur critique est égale à pour un seuil $\alpha = 0,050$:

$$t_{(0,025,12)} = 2,179.$$

Comme

$$|t_{obs}| > t_{(\alpha/2,n-2)},$$

on rejette l'hypothèse nulle $\mathcal{H}_0$ pour décider l'hypothèse alternative $\mathcal{H}_1$.

En conclusion : La relation linéaire entre le taux de natalité et le taux d'urbanisation est significative.

Un intervalle de confiance pour le coefficient inconnu β_1 au niveau $(1 - \alpha) = 0,95$ s'obtient en calculant :

$$\hat{\beta}_1 \pm t_{(\alpha/2,n-2)} \times s(\hat{\beta}_1) = -0,3989 \pm 2,179 \times \sqrt{0,021}.$$

On a donc après simplification :

$$[-0,715; -0,083]$$

qui contient la vraie valeur du coefficient inconnu β_1 avec une probabilité de $0,95$. On remarque que 0 n'est pas compris dans cet intervalle.

Test sur l'ordonnée β_0.

$$\mathcal{H}_0 : \beta_0 = 0$$

contre

$$\mathcal{H}_1 : \beta_0 \neq 0.$$

On calcule

$$t_{obs} = \frac{\hat{\beta}_0}{s(\hat{\beta}_0)} = \frac{42,991}{\sqrt{23,373}} = 8,89.$$

Or la valeur critique est égale à pour un seuil $\alpha = 0,050$:

$$t_{0,025,12} = 2,179.$$

Test et analyse de variance de la régression
Distribution des paramètres
Tests et intervalles de confiance sur les paramètres
Distribution et intervalle de confiance
Un exemple

Comme

$$|t_{obs}| > t_{\alpha/2,n-2},$$

on rejette l'hypothèse nulle $\mathcal{H}_0$ pour décider de l'hypothèse alternative $\mathcal{H}_1$.

En conclusion : La droite de régression ne passe pas par l'origine.

Test et analyse de variance de la régression
Distribution des paramètres
Tests et intervalles de confiance sur les paramètres
Distribution et intervalle de confiance
Un exemple

Un intervalle de confiance pour le coefficient inconnu β_0 au niveau $(1 - \alpha) = 0,95$ s'obtient en calculant :

$$\hat{\beta}_0 \pm t_{\alpha/2,n-2} \times s(\hat{\beta}_0) = 42,991 \pm 2,179 \times \sqrt{23,373}.$$

On a donc après simplification :

$$[32,456; 53,526]$$

qui contient la vraie valeur du coefficient inconnu β_0 avec une probabilité de $0,95$. On remarque que 0 n'est pas compris dans l'intervalle.