

Compléments sur la régression linéaire simple

Anova et inférence sur les paramètres

Frédéric Bertrand¹

¹IRMA, Université de Strasbourg
France

ESIEA 4ème Année 06-04-2010

Ce chapitre s'appuie essentiellement sur deux livres :

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

Sommaire

- 1 Test et analyse de variance de la régression
- 2 Distribution des paramètres
 - Modèle de régression linéaire simple
 - Distribution de la pente du modèle
 - Distribution de l'ordonnée à l'origine
- 3 Tests et intervalles de confiance sur les paramètres
 - Test sur la pente
 - Intervalle de confiance pour la pente
 - Test sur l'ordonnée à l'origine
 - Intervalle de confiance pour l'ordonnée à l'origine
- 4 Distribution et intervalle de confiance pour une prévision
- 5 Exemple

- Il existe plusieurs démarches pour tester la validité de la linéarité d'une régression simple.
- Nous montrons 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

Nous pouvons consulter sur le site un cours sur le coefficient de corrélation linéaire (Cours de 3A).

Problème

Nous souhaitons tester l'hypothèse nulle :

$$\mathcal{H}_0 : \rho(X, Y) = 0$$

contre l'hypothèse alternative :

$$\mathcal{H}_1 : \rho(X, Y) \neq 0$$

où

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

avec

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

Solution

La méthode que nous allons employer ici est :

la méthode de l'ANOVA

utilisée par les logiciels de statistique.

Remarques

- 1 ANOVA pour ANalysis Of VAriance ou encore analyse de la variance.
- 2 Nous pouvons consulter sur le site un cours sur le test du coefficient de corrélation linéaire (Cours de 3A).

Remarque

Nous avons établi dans le cours numéro 6 :

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

ce qui s'écrit mathématiquement par :

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

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

Tableau de l'ANOVA

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

Remarques

1 Le coefficient de détermination

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

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

2 Le rapport

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

est l'estimation de la variance résiduelle.

À partir du tableau de l'ANOVA, nous effectuons **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 :

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

Décision

Si

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

alors nous décidons de rejeter l'hypothèse nulle \mathcal{H}_0 et par conséquent d'accepter l'hypothèse alternative \mathcal{H}_1 au risque α , c'est-à-dire qu'il existe une liaison linéaire significative entre X et Y .

Si

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

alors nous décidons de ne pas rejeter l'hypothèse nulle \mathcal{H}_0 et par conséquent de l'accepter, c'est-à-dire nous concluons 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 $\rho(X, Y) = 0$ c'est-à-dire $Cov(X, Y) = 0$. Donc il n'existe aucune liaison linéaire entre X et Y .

Sommaire

- 1 Test et analyse de variance de la régression
- 2 Distribution des paramètres**
 - Modèle de régression linéaire simple
 - Distribution de la pente du modèle
 - Distribution de l'ordonnée à l'origine
- 3 Tests et intervalles de confiance sur les paramètres
 - Test sur la pente
 - Intervalle de confiance pour la pente
 - Test sur l'ordonnée à l'origine
 - Intervalle de confiance pour l'ordonnée à l'origine
- 4 Distribution et intervalle de confiance pour une prévision
- 5 Exemple

Modélisation

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 variables Y_i sont aléatoires.

Première hypothèse : $\mathbb{E}[\varepsilon_i] = 0$.

Conséquence : $\mathbb{E}[Y_i] = \beta_0 + \beta_1 x_i$.

D'autre part, nous avons :

$$\text{Var}[Y_i] = \text{Var}[\varepsilon_i].$$

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 .

Nous avons donc pour tout $i = 1, \dots, n$:

$$\text{Var}[\varepsilon_i] = \text{Var}[Y_i] = \sigma^2.$$

- 2 Les variables aléatoires ε_i sont indépendantes.
- 3 Les variables aléatoires ε_i sont normalement distribuées.

Résumons-nous

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 .

Nous notons :

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

Conséquences importantes :

- 1 La normalité des variables aléatoires ε_i implique la normalité des variables aléatoires Y_i .
- 2 L'indépendance des variables aléatoires ε_i implique l'indépendance des variables aléatoires Y_i .
En effet, nous montrons en calculant que :

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

Nous avons :

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

où

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

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 aléatoires** Y_i .
- Comme les variables aléatoires 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 $\hat{\beta}_1$:

1 $\mathbb{E} \left[\hat{\beta}_1 \right]$

2 $Var \left[\hat{\beta}_1 \right]$.

Par calcul, nous montrons que :

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

En effet, nous montrons que :

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

De plus, comme nous avons :

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

alors nous obtenons :

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

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

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

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

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

Nous avons :

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$$

où

$$\bar{X} = \frac{\sum x_i}{n} \quad \text{et} \quad \bar{Y} = \frac{\sum Y_i}{n}.$$

- $\hat{\beta}_0$ 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 $\hat{\beta}_0$:

1 $\mathbb{E} \left[\hat{\beta}_0 \right]$

2 $Var \left[\hat{\beta}_0 \right]$.

Par calcul, nous montrons que :

$$\begin{aligned}\mathbb{E}[\widehat{\beta}_0] &= \mathbb{E}[\overline{Y} - \widehat{\beta}_1 \overline{X}] \\ &= \mathbb{E}[\overline{Y}] - \overline{X} \mathbb{E}[\widehat{\beta}_1] \\ &= \mathbb{E}[\overline{Y}] - \overline{X} \beta_1,\end{aligned}$$

car nous venons de démontrer que $\widehat{\beta}_1$ est un estimateur sans biais du coefficient β_1 .

Il reste à calculer la valeur :

$$\mathbb{E}[\overline{Y}].$$

Or nous avons :

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

Nous obtenons donc :

$$\begin{aligned}\mathbb{E} [\hat{\beta}_0] &= \mathbb{E} [\bar{Y}] - \bar{X}\beta_1 \\ &= (\beta_0 + \bar{X}\beta_1) - \bar{X}\beta_1 \\ &= \beta_0.\end{aligned}$$

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

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

$$\begin{aligned} \text{Var} [\hat{\beta}_0] &= \text{Var} [\bar{Y} - \hat{\beta}_1 \bar{x}] \\ &= \text{Var} [\bar{Y}] + \bar{x}^2 \text{Var} [\hat{\beta}_1] - 2 \bar{x} \text{Cov} [\bar{Y}, \hat{\beta}_1]. \end{aligned}$$

Il reste donc à calculer la valeur :

$$\text{Cov} [\bar{Y}, \hat{\beta}_1].$$

Par les calculs, nous montrons que :

$$\begin{aligned}
 \text{Cov} \left[\bar{Y}, \hat{\beta}_1 \right] &= \text{Cov} \left[\frac{\sum Y_i}{n}, \frac{\sum (x_j - \bar{x}) Y_j}{\sum (x_i - \bar{x})^2} \right] \\
 &= \frac{\sum_i \sum_j (x_j - \bar{x}) \text{Cov}[Y_i, Y_j]}{n \sum (x_i - \bar{x})^2} \\
 &= \frac{\sum_i (x_i - \bar{x}) \text{Var}[Y_i]}{n \sum (x_i - \bar{x})^2} \\
 &= \frac{\sigma^2 \sum_i (x_i - \bar{x})}{n \sum (x_i - \bar{x})^2} \\
 &= 0.
 \end{aligned}$$

Comme nous avons que

$$\text{Var} [\bar{Y}] = \frac{\sigma^2}{n},$$

nous obtenons, alors :

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

En rappelant que :

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

nous avons finalement :

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

Sommaire

- 1 Test et analyse de variance de la régression
- 2 Distribution des paramètres
 - Modèle de régression linéaire simple
 - Distribution de la pente du modèle
 - Distribution de l'ordonnée à l'origine
- 3 Tests et intervalles de confiance sur les paramètres**
 - Test sur la pente
 - Intervalle de confiance pour la pente
 - Test sur l'ordonnée à l'origine
 - Intervalle de confiance pour l'ordonnée à l'origine
- 4 Distribution et intervalle de confiance pour une prévision
- 5 Exemple

Nous rappelons que :

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

où

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

Nous obtenons alors :

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

Problème

Nous ne connaissons pas le paramètre σ^2 , c'est-à-dire la variance des variables aléatoires ε_j .

Que pouvons-nous faire alors pour résoudre ce problème ?

Solution

Estimer ce paramètre !

- Nous estimons d'abord σ^2 par s^2 l'estimateur sans biais de σ^2 :

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

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

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

- Nous montrons alors que :

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

où T_{n-2} désigne une v.a. de Student avec $(n-2)$ ddl.

Nous souhaitons tester l'hypothèse nulle :

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

contre l'hypothèse alternative :

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

Nous utilisons alors la statistique de Student suivante :

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

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

Décision

Nous décidons de rejeter l'hypothèse nulle \mathcal{H}_0 et donc d'accepter l'hypothèse alternative \mathcal{H}_1 au seuil de signification α si

$$|t_{obs}| \geq t_{(1-\alpha/2, n-2)}$$

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

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

Décision - Suite et fin

Nous décidons d'accepter l'hypothèse nulle \mathcal{H}_0 au seuil de signification α si

$$|t_{obs}| < t_{(1-\alpha/2, n-2)}$$

où la valeur $t_{(1-\alpha/2, n-2)}$ 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. Nous testons alors un nouveau modèle.

IC pour β_1

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

$$\left[\hat{\beta}_1 - t_{(1-\alpha/2, n-2)} \times s(\hat{\beta}_1); \hat{\beta}_1 + t_{(1-\alpha/2, n-2)} \times s(\hat{\beta}_1) \right].$$

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

Nous rappelons que :

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

où

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

Nous obtenons alors :

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

Problème

Nous ne connaissons pas le paramètre σ^2 , c'est-à-dire la variance des variables aléatoires ε_j .

Que pouvons-nous faire alors pour résoudre ce problème ?

Solution

Estimer ce paramètre !

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

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

- Nous estimons ensuite $\sigma^2(\hat{\beta}_0)$ par

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

- Nous montrons alors que :

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

où T_{n-2} désigne une v.a. de Student avec $(n-2)$ ddl.

Nous souhaitons tester l'hypothèse nulle

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

contre l'hypothèse alternative

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

Nous utilisons la statistique de Student suivante :

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

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

Décision

Nous décidons de refuser l'hypothèse nulle \mathcal{H}_0 et d'accepter l'hypothèse alternative \mathcal{H}_1 au seuil de signification α si :

$$|t_{obs}| \geq t_{(1-\alpha/2, n-2)}$$

où la valeur critique $t_{1-\alpha/2, n-2}$ 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 .

Décision - Suite et fin

Nous décidons de ne pas refuser et donc d'accepter l'hypothèse nulle \mathcal{H}_0 au seuil de signification α si

$$|t_{obs}| < t_{(1-\alpha/2, n-2)}$$

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

Dans ce cas, l'ordonnée de la droite de régression passe par l'origine :

$$Y_i = \beta_1 x_i + \varepsilon_i.$$

IC pour β_0

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

$$\left[\hat{\beta}_0 - t_{(1-\alpha/2, n-2)} \times s(\hat{\beta}_0) ; \hat{\beta}_0 + t_{(1-\alpha/2, n-2)} \times s(\hat{\beta}_0) \right].$$

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

Sommaire

- 1 Test et analyse de variance de la régression
- 2 Distribution des paramètres
 - Modèle de régression linéaire simple
 - Distribution de la pente du modèle
 - Distribution de l'ordonnée à l'origine
- 3 Tests et intervalles de confiance sur les paramètres
 - Test sur la pente
 - Intervalle de confiance pour la pente
 - Test sur l'ordonnée à l'origine
 - Intervalle de confiance pour l'ordonnée à l'origine
- 4 **Distribution et intervalle de confiance pour une prévision**
- 5 Exemple

Nous allons 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 moindres carrés :

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

où

- $\hat{Y}(x) \sim \mathcal{N}(\beta_0 + \beta_1 x, \sigma^2(\hat{Y}(x)))$

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 :

- $\frac{\hat{Y}(x) - \mu_Y(x)}{\sigma(\hat{Y}(x))} \sim \mathcal{N}(0, 1).$

Problème

La variance σ^2 est inconnue.

Solution

- Nous estimons d'abord σ^2 par s^2 .
- Nous estimons 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 nous obtenons :

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

Intervalle de prévision

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

$$[\hat{y}(x) - t_{(1-\alpha/2, n-2)} \times s(\hat{y}(x)) ; \hat{y}(x) + t_{(1-\alpha/2, n-2)} \times s(\hat{y}(x))] .$$

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

Sommaire

- 1 Test et analyse de variance de la régression
- 2 Distribution des paramètres
 - Modèle de régression linéaire simple
 - Distribution de la pente du modèle
 - Distribution de l'ordonnée à l'origine
- 3 Tests et intervalles de confiance sur les paramètres
 - Test sur la pente
 - Intervalle de confiance pour la pente
 - Test sur l'ordonnée à l'origine
 - Intervalle de confiance pour l'ordonnée à l'origine
- 4 Distribution et intervalle de confiance pour une prévision
- 5 Exemple

Exemple

| 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 |

Exemple - Suite et fin

| 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 | Trinitade | 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 logiciel R donne successivement :

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

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

et enfin

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

Test sur la pente β_1 .

Nous testons

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

contre

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

Nous calculons

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

Or la valeur critique est égale à pour un seuil $\alpha = 0,05$:

$$t_{(0,975,12)} = 2,179.$$

Décision

Comme

$$|t_{obs}| \geq t_{(1-\alpha/2, n-2)},$$

nous décidons de refuser l'hypothèse nulle \mathcal{H}_0 et par conséquent d'accepter l'hypothèse alternative \mathcal{H}_1 , au seuil de signification $\alpha = 5\%$.

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

IC pour β_1

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

$$\hat{\beta}_1 \pm t_{(1-\alpha/2, n-2)} \times s(\hat{\beta}_1) = -0,3989 \pm 2,179 \times \sqrt{0,021}.$$

Nous avons donc après simplification :

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

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

Test sur l'ordonnée β_0

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

contre

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

Nous calculons

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

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

$$t_{0,975,12} = 2,179.$$

Décision

Comme

$$|t_{obs}| \geq t_{1-\alpha/2, n-2},$$

nous décidons de refuser l'hypothèse nulle \mathcal{H}_0 et par conséquent d'accepter l'hypothèse alternative \mathcal{H}_1 .

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

IC pour β_0

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

$$\hat{\beta}_0 \pm t_{1-\alpha/2, n-2} \times s(\hat{\beta}_0) = 42,991 \pm 2,179 \times \sqrt{23,373}.$$

Nous avons donc après simplification :

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

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