

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

Frédéric & Myriam Bertrand¹

¹IRMA, Université Louis Pasteur
Strasbourg, France

Master 1ère Année 28-01-2009

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).

On désire tester l'hypothèse nulle :

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

contre l'hypothèse alternative :

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

où

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

avec

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

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

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 :

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

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

- Le coefficient de détermination

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

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

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

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 :

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

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 :

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

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 .
On a 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.

Ces trois hypothèses sont équivalentes à :

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

On note :

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

Conséquences importantes :

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

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

On a :

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

où

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

Il en résulte que :

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

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

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

Par calcul, on montre que :

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

En effet, on montre que :

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

De plus, comme on a :

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

alors on obtient :

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

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

D'autre part, on calcule 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 $\hat{\beta}_1$.

On a :

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

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.

Problème :

On rappelle que :

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

où

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

On obtient alors :

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

On ne connaît 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 :

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

- 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.

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

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

On obtient alors :

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

Problème :

On ne connaît 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

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

- 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 régression passe par l'origine.

$$Y_i = \beta_1 X_i + \varepsilon_i$$



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.



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 $(1 - \alpha)$.

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

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

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 :

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

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 :

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

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	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

Test sur la pente β_1 .

Le tableur Excel donne successivement :

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

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

et enfin

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

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

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 $\alpha = 0,050$:

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

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.

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.