

Rappel : Intervalles de confiance & tests d'hypothèse

Qu'est-ce qu'une régression ?

- Etude de la dépendance d'une variable par rapport à une ou plusieurs autre(s) variables.
- Objectif = estimer ou prédire la valeur moyenne (population) à partir de valeurs connues ou fixées prises par des variables explicatives.

⇒

Objectif = estimer la fonction de régression population à partir de la fonction de régression échantillon.

$$\text{FRP} = Y_i = \beta_1 + \beta_2 X_i + u_i$$

avec $E(Y_i | X_i) = \beta_1 + \beta_2 X_i$

$$\text{FRE} = Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_i + \hat{u}_i$$

avec $\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_i$

Rem : \hat{Y}_i estimateur de $E(Y|X_i)$.

$\hat{\beta}_1$ estimateur de β_1 .

$\hat{\beta}_2$ estimateur de β_2 .

Les moindres carrés ordinaires (MCO)

On choisit la fonction de régression échantillon qui minimise la somme des carrés des résidus :

$$\begin{aligned} \min_{\hat{\beta}_1, \hat{\beta}_2} \sum a_i^2 &= \min_{\hat{\beta}_1, \hat{\beta}_2} \sum (y_i - \hat{y}_i)^2 \\ &\equiv \min_{\hat{\beta}_1, \hat{\beta}_2} \sum (y_i - \hat{\beta}_1 - \hat{\beta}_2 x_i)^2 \end{aligned}$$

$$\hat{\beta}_1 = \bar{Y} - \hat{\beta}_2 \bar{X}$$

$$\hat{\beta}_2 = \frac{\sum x_i y_i}{\sum x_i^2}$$

où \bar{X} et \bar{Y} sont les moyennes échantillon de X et Y .

$$x_i = (X_i - \bar{X})$$

$$y_i = (Y_i - \bar{Y})$$

Les valeurs prises par les estimateurs $\hat{\beta}_1$ et $\hat{\beta}_2$ dépendent des données de l'échantillon. Comme les données varient d'un échantillon à l'autre, les valeurs prises par les estimateurs varient d'un échantillon à l'autre.

- > Comment juge-t-on de la précision d'une estimation ?
- > Comment peut-on savoir si la valeur de l'estimation est proche de celle du paramètre population ?

La précision d'un estimateur se mesure par son "écart standard" ("standard error"), c'est par l'écart-type de la distribution d'échantillonnage de l'estimateur.

- Sous les hypothèses du modèle de régression linéaire classique :

$$\text{var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_i^2}$$

$$\Rightarrow \text{s.e.}(\hat{\beta}_2) = \frac{\sigma}{\sqrt{\sum x_i^2}}$$

$$\text{var}(\hat{\beta}_1) = \frac{\sum x_i^2}{n \sum x_i^2} \cdot \sigma^2$$

$$\Rightarrow \text{s.e.}(\hat{\beta}_1) = \sqrt{\frac{\sum x_i^2}{n \sum x_i^2} \cdot \sigma^2}$$

où $\left\{ \begin{array}{l} \text{var} = \text{variance}, x_i = X_i - \bar{X}, y_i = Y_i - \bar{Y} \\ \text{s.e.} = \text{standard error} \\ \sigma^2 = \text{variance homoscélastique du terme d'erreur } u_i \\ (= \text{var}(u_i/x_i)) \end{array} \right.$

L'estimateur des MCO de σ^2 (paramètre pop. inconnu) est donné par :

$$\hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{n-2}$$

où $\left\{ \begin{array}{l} (n-2) = \text{nombre de degrés de liberté (df)} \\ \sum \hat{u}_i^2 = \text{somme des carrés des résidus.} \end{array} \right.$

$df = \text{nombre d'obs} - \text{nombre de paramètres à estimer}$
 (nombre de paramètres auquel l'indicateur est basé).

- Pour faire de l'inference statistique, il est nécessaire de spécifier la distribution de probabilité du terme d'erreur (car estimateurs $\hat{\beta}_1$ et $\hat{\beta}_2$ sont des fonctions linéaires de Y ... qui dépend linéairement de u_i)

Autrement dit, pour faire de l'inference statistique, il faut qu'on connaisse la distribution d'échantillonnage exacte des estimateurs.

- si terme d'erreur suit distribution normale (+ les hyp. du modèle de régression linéaire classique) :

a) $\hat{\beta}_1 \sim N(\beta_1, \sigma_{\hat{\beta}_1}^2)$

b) $\hat{\beta}_2 \sim N(\beta_2, \sigma_{\hat{\beta}_2}^2)$

c) $(n-2) (\hat{\tau}^2 / \tau^2)$ suit une dist. de χ^2 à $(n-2)$ degrés de liberté

(car fact° linéaire d'une v.a. suivant loi normale = v.a. suivant loi normale)

ou encore :

a) $\frac{\hat{\beta}_1 - \beta_1}{\sigma_{\hat{\beta}_1}} \sim N(0,1)$

b) $\frac{\hat{\beta}_2 - \beta_2}{\sigma_{\hat{\beta}_2}} \sim N(0,1)$

c) $\hat{\tau}^2$ suit distrib. de χ^2

\Rightarrow ces propriétés peuvent être utilisées pour juger de la précision d'une estimation, calculer des intervalles de confiance et faire des tests d'hyp.

3.1. Les intervalles de confiance

La précision d'une estimation peut (aussi) être déterminée en calculant un intervalle de confiance pour le paramètre inconnu.

- Supposons que nous soyons intéressés par la proximité de $\hat{\beta}_2$ et β_2 . Pour cela on pourrait essayer de trouver 2 nombres α et δ , compris de 0 et 1, tq la probabilité que l'intervalle aléatoire $(\hat{\beta}_2 - \delta, \hat{\beta}_2 + \delta)$ contienne la vraie valeur du paramètre β_2 soit égale à $1-\alpha$ (ou $(1-\alpha)\%$).

\Rightarrow Trouver 2 nombres α et $\delta \in (0, 1)$ tq :

$$\boxed{\Pr(\hat{\beta}_2 - \delta \leq \beta_2 \leq \hat{\beta}_2 + \delta) = 1-\alpha} \quad (1)$$

\equiv Intervalle de confiance au niveau de probabilité $(1-\alpha)$

- Caractéristiques ?

- Il s'agit d'un intervalle "aléatoire".
- La probabilité qui y est associée doit être considérée dans le contexte d'une distribution d'échantillonnage.
- Pour un échantillon particulier, l'intervalle de confiance est fixe : la probabilité que l'intervalle recouvre la vraie valeur du paramètre population vaut 0 ou 1.

* L'expression (1) indique que si on procède à des tirages répétés d'échantillons et que pour chacun d'entre eux on construit un intervalle de confiance au niveau de prob. $1-\alpha$, en moyenne $(1-\alpha)\%$ de ces intervalles couvrent la vraie valeur du paramètre population.

• Comment construit-on un intervalle de confiance pour β_2 ?

$$Z = \frac{\hat{\beta}_2 - \beta_2}{\text{se}(\hat{\beta}_2)} = \frac{(\hat{\beta}_2 - \beta_2) \sqrt{\sum x_i^2}}{\sigma} \sim N(0, 1)$$

σ généralement inconnue.

$$\hat{\sigma} = \sqrt{\frac{\sum \hat{u}_i^2}{n-2}}$$

\Rightarrow


$$t = \frac{(\hat{\beta}_2 - \beta_2) \sqrt{\sum x_i^2}}{\hat{\sigma}} \quad (2)$$

Cette statistique t suit une loi de Student à $(n-2)$ degrés de liberté.

Si α est un niveau de probabilité (compris entre 0 et 1) et t est une variable aléatoire suivant une loi de Student, on trouve que :

$$\Pr(t_{1-\alpha/2} \leq t \leq t_{\alpha/2}) = 1-\alpha \quad (3)$$

où $t_{\alpha/2}$ et $1-\alpha/2$ sont les valeurs critiques de la distribution de Student.



Comme la distribution de Student est symétrique autour de sa moyenne ($= 0$) :

$$\boxed{\Pr(-t_{\alpha/2} \leq t \leq t_{\alpha/2}) = 1-\alpha} \quad (4)$$

En substituant la valeur de la statistique t dans l'expression (4) :

$$\boxed{\Pr\left(-t_{\alpha/2} \leq \frac{\hat{\beta}_2 - \beta_2}{se(\hat{\beta}_2)} \leq t_{\alpha/2}\right) = 1-\alpha} \quad (5)$$

\Rightarrow

$$\boxed{\Pr(\hat{\beta}_2 - t_{\alpha/2} \cdot se(\hat{\beta}_2) \leq \beta_2 \leq \hat{\beta}_2 + t_{\alpha/2} \cdot se(\hat{\beta}_2)) = 1-\alpha} \quad (6)$$

$\Rightarrow [\hat{\beta}_2 \pm t_{\alpha/2} \cdot se(\hat{\beta}_2)]$ recouvre la vraie valeur (7)

du paramètre β_2 avec une probabilité égale à $1-\alpha$ (ou $(1-\alpha)\%$)

- Comment construit-on un IC pour β_1 ?

1^{er}me raisonnement :

$\Rightarrow [\hat{\beta}_1 \pm t_{\alpha/2} \cdot se(\hat{\beta}_1)]$ recouvre vraie valeur du (8) paramètre β_1 avec prob. $(1-\alpha)$

- Remarque :

La largeur de l'IC de β_1 (et β_2) est proportionnelle à l'erreur standard de l'estimateur. Lorsque l'erreur standard ↑, l'incertitude // valeur du paramètre pop. ↑.

Table 3.2.

Dépenses de cons. et revenus en \$ de 10 ménages

Dép. de cons. Y	Revenus X
70	80
65	100
90	120
95	140
110	160
115	180
120	200
140	220
155	240
150	260

- Résultats par réco :

$$\hat{\beta}_1 = 24,4545 \quad \hat{\beta}_2 = 0,5091$$

$$se(\hat{\beta}_1) = 6,4138 \quad se(\hat{\beta}_2) = 0,0357$$

$$\hat{\sigma}^2 = 42,1591 \quad \text{cov}(\hat{\beta}_1, \hat{\beta}_2) = -0,2172$$

$$R^2 = 0,9621$$

- IC pour β_1 et β_2 ?

Valeurs critique pour une distribution de Student à 8 df pour $\alpha = 0,05$:

$$t_{\alpha/2} = t_{0,025} = 2,306$$

$$\begin{aligned} \text{IC pour } \beta_1 : [\hat{\beta}_1 \pm t_{\alpha/2} \cdot se(\hat{\beta}_1)] &= 24,4545 \pm 2,306 \cdot 6,4138 \\ &= [24,4545 \pm 14,7902] \end{aligned}$$

$$\Rightarrow [39,6643 \leq \beta_1 \leq 39,2448]$$

$$\begin{aligned} \text{IC pour } \beta_2 : [\hat{\beta}_2 \pm t_{\alpha/2} \cdot se(\hat{\beta}_2)] &= 0,5091 \pm 2,306 \cdot 0,0357 \\ &= [0,5091 \pm 0,0823] \end{aligned}$$

$$\Rightarrow [0,4268 \leq \beta_2 \leq 0,5914]$$

- Comment construit-on un IC pour σ^2 ?

Sous l'hypothèse de normalité du terme d'erreur, la statistique :

$$\boxed{X^2 = (n-2) \left(\frac{\hat{\sigma}^2}{\sigma^2} \right)} \quad (1)$$

suit une distribution de Chi - carré à $(n-2)$ degrés de liberté.

$$\Pr(X_{1-\alpha/2}^2 \leq X^2 \leq X_{\alpha/2}^2) = 1-\alpha \quad (2)$$

où $X_{1-\alpha/2}^2$ et $X_{\alpha/2}^2$ sont les valeurs critiques de la distribution de Chi - carré.

En substituant la valeur de la statistique X^2 dans l'expression (2) :

$$\Pr(X_{1-\alpha/2}^2 \leq (n-2) \left(\frac{\hat{\sigma}^2}{\sigma^2} \right) \leq X_{\alpha/2}^2) = 1-\alpha$$

$$\Rightarrow \Pr\left(\frac{(n-2) \hat{\sigma}^2}{X_{\alpha/2}^2} \leq \frac{\sigma^2}{\hat{\sigma}^2} \leq \frac{(n-2) \hat{\sigma}^2}{X_{1-\alpha/2}^2}\right) = 1-\alpha$$

Exemple : 10 familles dont on connaît dép. de cons et revenu.

Résultats MCO : $\hat{\beta}_1 = 24,4545$, $\hat{\beta}_2 = 0,5091$
 $se(\hat{\beta}_1) = 6,4138$, $se(\hat{\beta}_2) = 0,0357$

$$\hat{\sigma}^2 = 42,1591, \text{cov}(\hat{\beta}_1, \hat{\beta}_2) = -0,2172$$

$$R^2 = 0,9621$$

- Soit $\alpha = 0,05$ (coefficient de confiance de 95%).
 Pour une chi - carré à 8 degrés de liberté ($8=10-2$)
 on trouve les valeurs critiques suivantes : $\begin{cases} \chi^2_{0,025} = 17,5346 \\ \chi^2_{0,975} = 2,1797 \end{cases}$




FIGURE 5.1 The 95% confidence interval for τ^2 (8 df).

- IC à 95% pour τ^2 : $\left[(n-2) \frac{\hat{\tau}^2}{\chi^2_{\alpha/2}} ; (n-2) \frac{\hat{\tau}^2}{\chi^2_{1-\alpha/2}} \right] = 0,95$

$$\Rightarrow \left[8 \cdot \left(\frac{42,1591}{17,5346} \right) ; 8 \cdot \left(\frac{42,1591}{2,1797} \right) \right]$$

$$\Rightarrow [19,2347 ; 154,7336]$$

$$\Rightarrow [19,2347 \leq \tau^2 \leq 154,7336] = 0,95$$

La probabilité que la vraie valeur du paramètre population τ^2 soit comprise dans cet IC est de 95%.

3. 2. Tests d'hypothèses

En pratique, on désire vérifier si un résultat est "compatible" avec une valeur (choisie a priori) pour un paramètre population inconnu.

"Compatible" signifie que le résultat est suffisamment proche de la valeur hypoth. pop., pour que l'hyp. concernant la valeur du paramètre pop. ne soit pas rejetée.

H_0 : hypothèse nulle

H_1 : hypothèse alternative

On appelle l'hypothèse nulle, la proposition qui contredit la proposition de recherche. L'hypothèse nulle doit donc être énoncée de telle manière que son rejet entraîne l'acceptation de l'hypothèse alternative, c'ds. la proposition de recherche.

Pour décider si une hyp. nulle peut être rejetée ou non, on utilise les tests de significativité.

Deux éléments centraux : a) la statistique de test,
b) la distribution de cette stat. de test sous H_0 .

Règle de décision basée sur valeur de la stat. de test (calculée à partir de l'échantillon).

3.2.1. Tests relatifs aux coeff. de régression

- sous l'hyp. de normalité, $t = \frac{\hat{\beta}_2 - \beta_2}{se(\hat{\beta}_2)} = \frac{(\hat{\beta}_2 - \beta_2) \sqrt{\sum x_i^2}}{\hat{\sigma}}$

suit une loi de Student à $(n-2)$ degrés de liberté.

- $\Pr \left(-t_{\alpha/2} \leq \frac{\hat{\beta}_2 - \beta_2^*}{se(\hat{\beta}_2)} \leq t_{\alpha/2} \right) = 1-\alpha$

où $\begin{cases} \beta_2^* = \text{valeur de } \beta_2 \text{ sous } H_0 \\ -t_{\alpha/2} \text{ et } t_{\alpha/2} = \text{valeurs crit. de Student à } (n-2) \text{ df.} \end{cases}$

$$\Rightarrow \boxed{\Pr (\beta_2^* - t_{\alpha/2} \cdot se(\hat{\beta}_2) \leq \hat{\beta}_2 \leq \beta_2^* + t_{\alpha/2} \cdot se(\hat{\beta}_2)) = 1-\alpha}$$

Intervalle dans lequel l'estimation $\hat{\beta}_2$ se situe avec une probabilité de $(1-\alpha)\%$ sous l'hypothèse nulle, c.à.d. lorsque $\beta_2 = \beta_2^*$.

= "Zone d'acceptation" de l'hyp. nulle

Zone qui se situe en dehors de cet interval =
"Région critique"

- Règle de décision pour α fixé:

- si l'estimation $\hat{\beta}_2$ se situe de la zone d'acceptation, l'hyp. nulle ne peut pas être rejetée au niveau de prob. α .
- si l'estimation $\hat{\beta}_2$ se situe dans la région critique, on rejette l'hyp. nulle au niveau de probabilité α .

Exemple :

Revenus - dépenses de cons. de ménages.

On a que : $\hat{\beta}_2 = 0,5091$, $se(\hat{\beta}_2) = 0,0357$, $df = 8$

Soit $\alpha = 0,05 \rightarrow t_{\alpha/2} = 2,306$

Soit $\begin{cases} H_0 : \beta_2 = 0,3 \\ H_1 : \beta_2 \neq 0,3 \end{cases}$

Sous l'hyp. nulle, l'intervalle de confiance :

$$Pr(0,3 - 2,306 \cdot 0,0357 \leq \beta_2 \leq 0,3 + 2,306 \cdot 0,0357) = 0,95$$

$$Pr(0,2177 \leq \beta_2 \leq 0,3823) = 0,95$$

$\hat{\beta}_2 = 0,5091 \rightarrow$ l'estimation se situe dans la région critique \rightarrow on rejette H_0




FIGURE 5.3 The 95% confidence interval for $\hat{\beta}_2$ under the hypothesis that $\beta_2 = 0,3$.

- En pratique, il n'est pas nécessaire de calculer explicitement l'ID sous l'hyp. nulle.

Plus simple : calculer $t = \frac{\hat{\beta}_2 - \beta_2^*}{\text{se}(\hat{\beta}_2)}$ (où $\beta_2^* = \beta_2$ sous H_0)

et vérifier si elle est comprise tel $-t_{\alpha/2}$ et $t_{\alpha/2}$.

Dans notre exemple :

$$t = \frac{(0,5091 - 0,3)}{0,0357} = 5,86 \quad \text{et} \quad t_{\alpha/2} = 2,306 \quad (\text{pour } \alpha = 0,05)$$

Statistique de test se situe dans région critique : RH_0




FIGURE 5.4 The 95% confidence interval for $t(8 \text{ df})$.

- Remarque : @plus la statistique t est grande en valeur absolue, plus la probabilité de rejeter l'hypothèse nulle sera importante.

⑥ Un test est significatif lorsque la valeur de la stat de test se situe dans la région critique. Dans ce cas l'hyp. nulle est rejetée.


⑦ test d'hypothèse „bilatéral” car $H_1: \beta_2 \neq 0,3$
(si H_0 est fausse, β_2 peut être $> 0,3$ ou $< 0,3$)

Test unilatéral à droite

Exemple : $\beta_2 > 0,3$?

$$\Rightarrow H_0 : \beta_2 \leq 0,3$$

$$H_1 : \beta_2 > 0,3$$



Test unilatéral "à droite": on utilise uniq. la valeur critique supérieure, c'qd t_α .

Règle de décision: si la t stat est inférieure à t_α on ne rejette pas H_0 , sinon RH_0 .

Dans notre exemple :

$$t = \frac{0,5091 - 0,3}{0,0357} = 5,86 > t_{0,05} = 1,860$$

\Rightarrow on rejette H_0 à 5%.

Test unilatéral à gauche


Exemple : $\beta_2 < 0,3$?

$$H_0 : \beta_2 \geq 0,3$$

$$H_1 : \beta_2 < 0,3$$

On utilise uniq. la valeur critique inférieure $-t_\alpha$.

Règle de décision : si la t stat est supérieure à la valeur critique on ne rejette pas H_0 , sinon RH_0



"
 $-t_{0,05}$ pour $df = 8$

Dans notre cas :

$$t = 5,86 > -1,860$$

\Rightarrow on ne rejette pas H_0 .

En résumé :

Le test "t" de significativité

Type d'hyp.	H_0	H_1	Règle de décision : RH_0 si
Bilatéral	$\beta_2 = \beta_2^*$	$\beta_2 \neq \beta_2^*$	$ t > t_{\alpha/2, df}$
Unilatéral à droite	$\beta_2 \leq \beta_2^*$	$\beta_2 > \beta_2^*$	$t > t_{\alpha, df}$
Unilatéral à gauche	$\beta_2 \geq \beta_2^*$	$\beta_2 < \beta_2^*$	$t < -t_{\alpha, df}$

3.2.2. Tests relatifs à la variance des erreurs σ^2

- Sous l'hypothèse de normalité du terme d'erreur, la variable :

$$\chi^2 = (n-2) \left(\frac{\hat{\sigma}^2}{\sigma^2} \right)$$

suit une distribution de chi-caré à $(n-2)$ degrés de liberté.

- $\Pr(\chi_{1-\alpha/2}^2 \leq \chi^2 \leq \chi_{\alpha/2}^2) = 1-\alpha$

$$\Rightarrow \boxed{\Pr(\chi_{1-\alpha/2}^2 \leq (n-2) \left(\frac{\hat{\sigma}^2}{\sigma^2} \right) \leq \chi_{\alpha/2}^2) = 1-\alpha}$$

- Exemple : revenus - dép. de cons. des ménages

$$\hat{\sigma}^2 = 42,1591, df = 8$$

$$\text{Soit } \alpha = 0,05 \longrightarrow \begin{cases} \chi_{1-\alpha/2}^2 = \chi_{0,975}^2 = 2,1797 \\ \chi_{\alpha/2}^2 = \chi_{0,025}^2 = 17,5346 \end{cases}$$

$$\text{Soit } \begin{cases} H_0 : \sigma^2 = 85 \\ H_1 : \sigma^2 \neq 85 \end{cases}$$

- Règle de décision : si la stat. de test ($\chi^2 = (n-2) \frac{\hat{\sigma}^2}{\sigma^2}$) sous l'hyp. nulle (càd pour $\sigma^2 = 85$) est comprise entre les 2 valeurs critiques de la chi-caré, on ne rejette pas H_0 , sinon on R H_0 .

- Dans notre exemple :

$$\chi^2 = 8 \cdot \left(\frac{42,1591}{85} \right) = 3,97 > \chi_{0,975}^2 = 2,1797$$

$$< \chi_{0,025}^2 = 17,5346$$

1.5% \Rightarrow on ne rejette pas H_0 (illustrat. test "bilatéral")

Test bilatéral car $H_0: \sigma^2 = 85$ (on admet que si H_0 est fausse, σ^2 peut être supérieur ou inférieur à 85).

En résumé: Le test de χ^2

Type d'hyp.	H_0	H_1	Règle de décision: R_{H_0} si
Bilatéral	$\sigma^2 = \sigma_0^2$	$\sigma^2 \neq \sigma_0^2$	$df \cdot (\hat{\sigma}^2 / \sigma_0^2) > \chi^2_{\alpha/2, df}$ ou $df \cdot (\hat{\sigma}^2 / \sigma_0^2) < \chi^2_{(1-\alpha/2), df}$
Unilatéral à droite	$\sigma^2 \leq \sigma_0^2$	$\sigma^2 > \sigma_0^2$	$df \cdot (\hat{\sigma}^2 / \sigma_0^2) > \chi^2_{\alpha, df}$
Unilatéral à gauche	$\sigma^2 \geq \sigma_0^2$	$\sigma^2 < \sigma_0^2$	$df \cdot (\hat{\sigma}^2 / \sigma_0^2) < \chi^2_{1-\alpha, df}$

où df = nombre de degrés de liberté

3.2.3. Tests d'hypothèses : quelques aspects pratiques

a) La signification d'accepter ou de rejeter une hypothèse

Si on ne rejette pas H_0 , cela ne signifie pas que H_0 est vraie.

Pourquoi ?

Exemple revenus - dép. de cons. des ménages.

$$i) H_0: \beta_2 = 0,5$$

$$H_1: \beta_2 \neq 0,5$$

$$\hat{\beta}_2 = 0,5091, se(\hat{\beta}_2) = 0,0357, df = 8$$

$$t = \frac{0,5091 - 0,5}{0,0357} = 0,25$$

La t stat est non significative au niveau de prob $\alpha = 0,05$.

En effet : $|t| = 0,25 < t_{0,025} = 2,306$

\Rightarrow on ne peut pas rejeter l'hyp. que $\beta_2 = 0,5$.

ii) $H_0 : \beta_2 = 0,48$

$H_1 : \beta_2 \neq 0,48$

$$t = \frac{0,5091 - 0,48}{0,0357} = 0,82 (< 2,306)$$

La t stat est non significative.

\Rightarrow on ne peut pas rejeter l'hyp. que $\beta_2 = 0,48$.

b) L'hypothèse nulle "zéro"

En pratique, on teste sur si un coeff. de régression est significativement \neq de zéro.

Par exemple, $H_0 : \beta_2 = 0$.

Lorsque $df \geq 20$ et $\alpha = 0,05$, l'hyp. nulle $\beta_2 = 0$ peut être rejetée si $|t| > 2$ (où $t = \frac{\hat{\beta}_2}{se(\hat{\beta}_2)}$)

c) Choisir le degré de significativité α

La décision de rejeter H_0 dépend de la valeur de α
 α = risque de première espèce
= prob. rejeter H_0 alors qu'elle est vraie.

Lorsqu'on fixe le risque première espèce, on fixe le risque de seconde espèce (β), où
 β = prob. d'accepter une hyp. fausse.

\Rightarrow Il faut faire un arbitrage (et α et β).

En pratique, on fixe la valeur de α et on choisit une stat. de test qui minimise le risque de 2nd espèce (β).

$(1-\beta)$ = puissance du test

$\Rightarrow \min \beta \equiv \max (1-\beta)$: on maximise la prob. de rejeter une hypothèse fausse.

Problématique concernant choix de α peut être évitée en utilisant la „p-value”.

d) Le degré de significativité exact : la „p-value”

„p-value” = prob. exacte que la distrib. d'éch. de la stat. de test prenne une valeur sup. ou égale à la valeur de la stat. de test obtenue pour l'éch.

„p-value” = prob. exacte de commettre une erreur de première espèce.

Exemple : revenus - dép. de cons. des ménages.

Nous savons que $t = \frac{\hat{\beta}_2 - \beta_2}{\text{se}(\hat{\beta}_2)} = 5,86$ sous

l'hypothèse nulle que $\beta_2 = \hat{\beta}_2 = 0,3$.

Pour $df = 8 \rightarrow$ p-value associée à $5,86 = 0,000189$
 \rightarrow prob. de H_0 alors que H_0 est vraie est de +/- 2 pour 10000.

3.3. Analyse de la variance (ANOVA)

- L'hypothèse nulle „zéro” peut être abordé comme un problème d'analyse de la variance.

$$\sum y_i^2 = \sum \hat{y}_i^2 + \sum \hat{u}_i^2 = \hat{\beta}_2^2 \sum x_i^2 + \sum \hat{u}_i^2$$

$$\Rightarrow SCT = SCE + SCR$$

- Nbre de degrés de liberté? (=nbre de valeurs qu'on peut choisir arbitrairement)

i) $SCT \rightarrow (n-1) \text{ df}$

Pourquoi?

On perd 1 df en calculant \bar{Y}

On peut choisir librement $(n-1)$ valeurs librement mais la n -ème est déterminée par la condition suivante : $\sum y_i = 0$

$$\begin{aligned} \text{En effet, } \sum y_i &= \sum (y_i - \bar{Y}) = \sum y_i - n\bar{Y} \\ &= n\left(\frac{1}{n} \sum y_i\right) - n\bar{Y} \\ &= n\bar{Y} - n\bar{Y} \\ &= 0 \end{aligned}$$

ii) $SCR \rightarrow (n-2) \text{ df}$

Pourquoi?

L'utilisation des MCO impose 2 conditions aux résidus (\hat{u}_i):

$$\sum \hat{u}_i = 0 \text{ et } \sum \hat{u}_i x_i = 0$$

iii) $SCE \rightarrow 1 \text{ df}$

Pourquoi?

$\sum x_i^2$ est connue, SCE dépend uniq. de $\hat{\beta}_2$

Table 5.3. Tableau ANOVA pour un modèle de régression à deux variables

Source de la variation	Somme des carres ¹	Somme des carres moyens ²	df ³
Due à la * régression (SCE)	$\sum \hat{y}_i^2 = \hat{\beta}_2^2 \sum x_i^2$	$(\hat{\beta}_2^2 \sum x_i^2) / 1$	1
Due aux résidus (SCR)	$\sum \hat{u}_i^2$	$(\sum \hat{u}_i^2) / (n-2)$	$n-2$
Totale (SCT)	$\sum y_i^2$	$(\sum y_i^2) / (n-1)$	$n-1$

1 : sum of squares (ss)

2 : mean sum of squares (MSS) = ss / df

3 : degrees of freedom (df)

* : variation due à la variable X

$$F = \frac{SCE / 1}{SCR / (n-2)} = \frac{\hat{\beta}_2^2 \sum x_i^2}{\sum \hat{u}_i^2 / (n-2)} = \frac{\hat{\beta}_2^2 \sum x_i^2}{\hat{\tau}^2} \quad (1)$$

Si u_i suivent une loi normale, sous l'hyp nulle que $\beta_2 = 0$, F suit une loi de Fisher à 1 degré de liberté au numérateur et $(n-2)$ degrés de liberté au dénominateur.

A quoi cette variable F peut-elle servir ?

$$E(\hat{\beta}_2^2 \sum x_i^2) = \sigma^2 + \beta_2^2 \sum x_i^2 \quad (2)$$

$$E\left(\frac{\sum \hat{u}_i^2}{n-2}\right) = E(\hat{\tau}^2) = \sigma^2 \quad (3)$$

- > Si $\beta_2 = 0$, (2) & (3) fournissent une estimation identique de $\sigma^2 \rightarrow X n'a pas d'influence linéaire sur Y$
- > Si $\beta_2 \neq 0$, (2) & (3) sont $\neq \rightarrow$ une partie de la variat de Y sera attribuable à X.

⇒ la variable F permet de tester l'hyp nulle que $\beta_2 = 0$.

Exemple: Revenus et dép. de cons. des ménages.

Table 5.4. ANOVA pour exemple rev. - dép. cons.

Source de variation	Somme des carres	df	Somme des carres moyen
Due à la régression (SCE)	8552,73	1	8552,73
Due aux résidus (SCR)	337,27	8	42,159
Totale (SCT)	8890,00	9	

$$\Rightarrow F = \frac{8552,73}{42,159} = 202,87$$

$$p\text{-value} = 0,0000001 \quad (\alpha = \frac{1}{10.000.000})$$

On rejette H_0 (ou rejette l'hyp nulle que le revenu n'a pas d'influence significative sur les dép. de cons. des ménages).

Pour un modèle de rég. à 2 variables, test de Fisher est équivalent à un test en t. Pour régressions multiples, test de Fisher offre bcp d'œ possibilités.