

Introduction à la régression

cours n°3

Influence d'un prédicteur


ENSM.SE – 1A
Olivier Roustant

Objectif du cours

- Utiliser les résultats théoriques sur l'estimation des paramètres pour savoir si un prédicteur d'un modèle linéaire est influent

Influent ou non influent ?



$$y_i = \beta_0 + \beta_1 x_i + e_i \text{ avec } e_1, \dots, e_4 \text{ i.i.d } N(0, 0.04^2)$$



En fait ici, l'erreur d'estimation sur $\beta_1 = |\beta_1| !! (=0.2)$

Influent ou non influent (suite)

Le même ex., mais en planifiant mieux les expériences





Cette fois, l'erreur d'estimation sur la pente = 0.0536

Exercice

- Vous pouvez réaliser n expériences pour estimer un phénomène linéaire sur $[a,b]$ impliquant 1 prédicteur
 - Comment répartir les expériences dans le domaine expérimental $[a,b]$ de façon à ce que l'estimation soit la plus précise possible ?

Influent ou non influent (suite)

Le même exemple, planification optimale (voir diapo. 26)



L'erreur d'estimation sur la pente = 0.04

Influent ou non influent ?

Morale de l'exemple

- Prendre en compte l'erreur d'estimation d'un paramètre pour savoir s'il est important ou pas
→ Décision en milieu incertain : **test statistique**

- L'impossibilité de décider peut venir d'une mauvaise **planification des expériences**

Formalisation

- Considérons le modèle linéaire

$$y_i = \beta_0 + \beta_1 x_{1,i} + \dots + \beta_p x_{p,i} + e_i$$

avec e_1, \dots, e_n i.i.d $N(0, \sigma^2)$

- Le prédicteur x_i est influent si $\beta_i \neq 0$
 - Test statistique opposant les hypothèses
$$\{\beta_i = 0\} \quad \text{et} \quad \{\beta_i \neq 0\}$$

Construction du test statistique

- 1ère étape : hypothèse H_0
 - On veut contrôler le risque de décider qu'un prédicteur est influent alors qu'il ne l'est pas.
Quelle est l'hypothèse H_0 ?

$$H_0 = \{\beta_i = 0\}$$

- Autre raison : pouvoir faire les calculs !

Construction du test (suite)

- 2ème étape : choix d'une statistique de décision
 - On part de l'estimateur des moindres carrés (EMC) de β_i
 - Matriciellement, on vérifie qu'on a :
 $(Y - X\beta)'(Y - X\beta)$ minimum ssi $X'(Y - X\beta) = 0$
ssi $(X'X)\beta = X'Y$

D'où

$$\hat{\beta} = (X'X)^{-1}X'Y$$

Construction du test (suite)

- 2ème étape (suite) : loi de l'EMC sous H_0 ?
 - Une combinaison linéaire de v.a. de lois normales indépendantes est encore de loi normale (admis)
 - Ici, $\hat{\beta} = (X' X)^{-1} X' Y = (X' X)^{-1} X' (X\beta + e)$
d'où $\boxed{\hat{\beta} = \beta + (X' X)^{-1} X' e}$
 - Chaque $\hat{\beta}_i$ est donc une combinaison linéaire des e_i , centrée sur $\beta_i \Rightarrow$ **loi normale centré sur β_i**

Construction du test (suite)

- 2ème étape (suite)
 - Exercice. Pour un vecteur u , $n \times 1$, on définit la **matrice de covariance** par $\text{cov}(u) = (\text{cov}(u_i, u_j))_{1 \leq i, j \leq n}$
 - a) $M_q \text{Cov}(u) = E((u-m)(u-m)'),$ avec $m=E(u)$ (vect. $n \times 1$)
 - b) $M_q \text{Cov}(e) = \sigma^2 I_n$
 - c) Déduire de a) et b) que $\boxed{\text{cov}(\hat{\beta}) = \sigma^2 (X' X)^{-1}}$
puis que $\boxed{\text{var}(\hat{\beta}_i) := \sigma_i^2 = \sigma^2 ((X' X)^{-1})_{ii}}$
- Conclusion : sous H_0 , l'EMC est de loi **$N(0, \sigma_i^2)$**

Construction du test (suite)

➤ 2ème étape (suite)

- La loi de l'estimateur dépend des paramètres
- Intuitivement, sous H_0 :

$$\hat{\beta}_i \sim N(0, \sigma^2((X'X)^{-1})_{ii}) \quad \Rightarrow \quad \frac{\hat{\beta}_i}{\hat{\sigma}\sqrt{((X'X)^{-1})_{ii}}} \approx N(0,1)$$

- Résultat exact : remplacer la loi $N(0,1)$ par la **loi de Student t_{n-p-1}** .

➤ Conclusion : choix de la statistique

$$T = \frac{\hat{\beta}_i}{\hat{\sigma}\sqrt{((X'X)^{-1})_{ii}}}$$

 Ecole Nationale
Supérieure des Mines
SAINT-ETIENNE

Construction du test (suite)

➤ 2ème étape (résumé)

- Choix de la statistique de décision
- Interprétation : **estimation du paramètre rapporté à son écart-type d'estimation**
- Vocabulaire : T est appelé **t-ratio** (à cause de la loi de Student, notée **t**)
 - Propriété : T est de loi de Student t_{n-p-1}
 - En pratique, dès que $n-p-1 \geq 20$, on approche t_{n-p-1} par $N(0,1)$

$$T = \frac{\hat{\beta}_i}{\hat{\sigma} \sqrt{((X'X)^{-1})_{ii}}}$$

Construction du test (suite)

➤ 3ème étape : détermination d'un seuil

- Notation : $T_{obs} = \frac{\hat{\beta}_{i,obs}}{\hat{\sigma}_{obs} \sqrt{((X'X)^{-1})_{ii}}}$
- Au niveau 5%, on rejette H_0
 - $n-p-1 \geq 20$: si T_{obs} dépasse 1.96 en valeur absolue
 - $n-p-1 < 20$: utiliser les tables de la loi de Student
 - Mieux (dans tous les cas) : utiliser la **p-valeur**

Construction du test (fin)

- 3ème étape : p-valeur
 - On appelle p-valeur la probabilité d'obtenir pire que ce qu'on a :

$$p\text{-valeur} = P_{H_0}(|T| > |T_{obs}|)$$
- Permet de ne pas avoir à calculer de seuil :
 - $p\text{-valeur} < 5\% \Rightarrow$ rejet au niveau 5%
 - $p\text{-valeur} < 1\% \Rightarrow$ rejet au niveau 1%
 - ...


Test de signification : pratique

- En pratique, les logiciels donnent le tableau suivant :

coefficient	estimation	erreur d'estimation	t – ratio	p – valeur
β_i	$\hat{\beta}_{i,obs}$	$\hat{\sigma}_{i,obs}$	$T_{obs} = \frac{\hat{\beta}_{i,obs}}{\hat{\sigma}_{i,obs}}$	$P_{H_0}(T > T_{obs})$

Exemple 1

Données de pollution (cf cours 1)



Régression avec R

Le fichier de données : NO3 SO4
(format .txt) 0,45 0,78
0,09 0,25
1,44 2,39
... ...

lm :
linear model

```
> pollution <- read.table("pollution.txt", header=TRUE, dec=",", sep="\t")
> modele_degre_1 <- lm(log(NO3)~log(SO4), data=pollution)
> summary(modele_degre_1)
> modele_degre_2 <- lm(log(NO3)~log(SO4)+I(log(SO4)^2), data=pollution)
> summary(modele_degre_2)
```

Sorties à commenter

Call:

`lm(formula = log(NO3) ~ log(SO4))`

Comme $n-p-1 > 20$, on peut aussi se baser sur le fait que $|t\text{-ratio}| > 2$ ou que l'erreur d'estimation est < la moitié de l'estimation

Residuals:

Min	1Q	Median	3Q
-0.80424	-0.14485	-0.01087	0.

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-0.43642	0.03679	-11.86	<2e-16 ***
log(SO4)	0.92168	0.03356	27.47	<2e-16 ***

Signif. codes: 0 ‘***’ 0.001 ‘*

p-valeur < 0.05
 ⇒ paramètres significatifs au niveau 5%
 (on est même très large : p=2e-16 !)

Residual standard error: 0.2417

Multiple R-Squared: 0.8205,

Adjusted R-squared: 0.8195

F-statistic: 754.4 on 1 and 165 DF, p-value: < 2.2e-16

Call:

`lm(formula = log(NO3) ~ log(SO4))`

Comme $n-p-1 \geq 20$, on peut aussi se baser sur le fait que $|t\text{-ratio}| < 2$

ou

que l'erreur d'estimation est
> la moitié de l'estimation

Residuals:

Min	1Q	Median	3Q
-0.79819	-0.14085	-0.01470	0.16

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-0.42918	0.03955	-10.852	<2e-16 ***
log(SO4)	0.95337	0.07098	13.432	<2e-16 ***
I(log(SO4)^2)	0.01886	0.03720	0.507	0.613

Signif. codes: 0 ‘***’ 0.001 ‘**’

Residual standard error: 0.2423 on 164 degrees of freedom

Multiple R-Squared: 0.8208,

F-statistic: 375.7 on 2 and 164 DF


p-valeur > 0.05

⇒ paramètre non significatif au niveau 5%

Exemple 2

Retour sur les simulations (cf transp. n°3)

$$y_i = \beta_0 + \beta_1 x_i + e_i \text{ avec } e_1, \dots, e_4 \text{ i.i.d } N(0, 0.04^2)$$



Call:
`lm(formula = ysim ~ experience)`

Residuals:

1	2	3	4
0.038612	-0.038612	0.000000	0.000000

Coefficients:

	Estimate	Std. Error	t value	$\Pr(> t)$
(Intercept)	1.1404	0.0987	11.554	0.00741 **
experience	-0.4099	0.1936	-2.118	0.16838

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.038

Multiple R-Squared: 0.6916,

F-statistic: 4.485 on 1 and 2 D

La t-valeur est > 1.96 en valeur absolue,

Pourtant on ne rejette pas H_0

Cela est dû au fait qu'on ne peut pas utiliser
l'approximation normale (ici $n=4 << 20$)

La p-valeur est calculée à partir de la loi de Student

Moralité : la pente de la droite est négative,


Mais l'erreur d'estimation est trop importante

Et le paramètre est statistiquement non significatif au niveau 5% ...rassurant !

Exemple 2 (suite)

Retour sur les simulations (cf transp. n°6)

$$y_i = \beta_0 + \beta_1 x_i + e_i \text{ avec } e_1, \dots, e_4 \text{ i.i.d } N(0, 0.04^2)$$



Call:

lm(formula = ysim ~ experiences)

Residuals:

1	2	3	4
0.01300	-0.01300	0.03190	

Moralité : la pente de la droite est négative,
 Cette fois l'erreur d'estimation est assez faible
 Et le paramètre est statistiquement
significatif au niveau 5% (mais pas 1%)

Coefficients:

	Estimate	Std. Error	t value	Pr(> t >= t)
(Intercept)	0.97956	0.02436	40.22	0.000618 ***
experiences	-0.26142	0.03444	-7.59	0.016921 *

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residu

Standard error: 0.03444 on 2 degrees of freedom

Fstat: 161.06 on 1 and 2 DF, p-value: 0.000618 ***

Adjusted R-squared: 0.9497

Root mean square error: 0.01692

Remarque : la pente réelle (inconnue) est
 -0.2

Exercice : planification des expériences en dimension 1

- Vérifier que, en dimension 1

$$X'X = n \begin{bmatrix} 1 & \bar{x} \\ \bar{x} & \bar{x}^2 \end{bmatrix} \quad \text{puis} \quad (X'X)^{-1} = \frac{1}{n} \frac{1}{\bar{x}^2 - \bar{x}^2} \begin{bmatrix} \bar{x}^2 & -\bar{x} \\ -\bar{x} & 1 \end{bmatrix}$$

$$\text{puis} \quad \text{var}(\hat{\beta}_1) = \text{cov}(\hat{\beta}_1, \hat{\beta}_1) = (\sigma^2 (X'X)^{-1})_{11} = \frac{\sigma^2}{n} \frac{1}{\bar{x}^2 - \bar{x}^2}$$

- En déduire que pour minimiser l'erreur d'estimation de la pente, il faut que la variance empirique des x_i soit la plus grande possible
- Prenons n pair, et considérons le domaine expérimental $[-1,1]$. Montrer que le maximum est atteint lorsque la moitié des points est placée sur le bord gauche (en $x = -1$), et l'autre moitié sur le bord droit ($x = 1$)