

# Régression linéaire multiple

Frédéric Bertrand<sup>1</sup>

<sup>1</sup>IRMA, Université de Strasbourg  
Strasbourg, France


Master 1 MCB 02-06-2010

## Exemple : Issu du livre « Statistiques avec R »

- **Problème** : Étude de la concentration d'ozone dans l'air.
- **Modèle** : La température (v.a.  $X$ ) et la concentration d'ozone (v.a.  $Y$ ) sont liées de manière linéaire :

$$Y = \beta_0 + \beta_1 X + \varepsilon.$$

- **Observations** :  $n = 10$  mesures de la température et de la concentration d'ozone.
- **But** : Estimer  $\beta_0$  et  $\beta_1$  afin de prédire la concentration d'ozone connaissant la température.



## Affiner le modèle

Souvent la régression linéaire est trop simpliste. Il faut alors utiliser d'autres modèles plus réalistes mais parfois plus complexes :

- Utiliser d'autres fonctions que les fonctions affines comme les fonctions polynômiales, exponentielles, logarithmiques. . .
- Considérer plusieurs variables explicatives.

**Exemple :** La température **et** la vitesse du vent

## Régression linéaire multiple

Le principe de la régression linéaire multiple est simple :

- Déterminer la variable expliquée  $Y$ .

**Exemple :** La concentration d'ozone.

- Déterminer  $(p - 1)$  variables explicatives  $X_1, \dots, X_{p-1}$

**Exemple :**  $X_1$  température,  $X_2$  vitesse du vent, ...

- Il ne reste plus qu'à appliquer un modèle linéaire :

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_{p-1} X_{p-1} + \varepsilon.$$

Dans un échantillon de  $n$  individus, nous mesurons  $y_i, x_{i,1}, \dots, x_{i,p-1}$  pour  $i = 1, \dots, n$ .

Observations	$Y$	$X_1$	$\dots$	$X_{p-1}$
1	$y_1$	$x_{1,1}$	$\dots$	$x_{1,p-1}$
2	$y_2$	$x_{2,1}$	$\dots$	$x_{2,p-1}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$n$	$y_n$	$x_{n,1}$	$\dots$	$x_{n,p-1}$

## Remarque

Les variables  $x_{i,j}$  sont fixes tandis que les variables  $Y_i$  sont aléatoires.

## Problème

Il faut estimer les paramètres  $\beta_0, \dots, \beta_{p-1}$  du modèle de régression et ce de manière optimale.

## Solution

Utiliser la méthode des moindres carrés. Cette méthode revient à minimiser la quantité suivante :

$$\min_{\beta_0, \dots, \beta_{p-1}} \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_{i,1} + \dots + \beta_{p-1} x_{i,p-1}))^2.$$

Le système peut se réécrire :

$$\begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{1,1} & \cdots & x_{1,p-1} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n,1} & \cdots & x_{n,p-1} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \vdots \\ \beta_{p-1} \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

$$\mathbf{y} = \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

**Vecteur des résidus :  $\boldsymbol{\varepsilon} = \mathbf{y} - \hat{\mathbf{y}} = \mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}$ .**



## Remarque

Les variables  $\mathbf{y}$  et  $\mathbf{X}$  sont mesurées tandis que l'estimateur  $\hat{\beta}$  est à déterminer.

La méthode des moindres carrés consiste à trouver le vecteur  $\hat{\beta}$  qui minimise  $\|\varepsilon\|^2 = {}^t\varepsilon\varepsilon$ .

## Les calculs

$$\begin{aligned}\|\varepsilon\|^2 &= {}^t(\mathbf{y} - \mathbf{X}\hat{\beta})(\mathbf{y} - \mathbf{X}\hat{\beta}) \\ &= {}^t\mathbf{y}\mathbf{y} - {}^t\hat{\beta}^t\mathbf{X}\mathbf{y} - {}^t\mathbf{y}\mathbf{X}\hat{\beta} + {}^t\hat{\beta}^t\mathbf{X}\mathbf{X}\hat{\beta} \\ &= {}^t\mathbf{y}\mathbf{y} - 2{}^t\hat{\beta}^t\mathbf{X}\mathbf{y} + {}^t\hat{\beta}^t\mathbf{X}\mathbf{X}\hat{\beta}\end{aligned}$$

car  ${}^t\hat{\beta}^t\mathbf{X}\mathbf{y}$  est un scalaire. Donc il est égal à sa transposée.

La dérivée par rapport à  $\hat{\beta}$  est alors égale à :

$$-2{}^t\mathbf{X}\mathbf{y} + 2{}^t\mathbf{X}\mathbf{X}\hat{\beta}.$$

## Problème

Nous cherchons  $\hat{\beta}$  qui annule cette dérivée. Donc nous devons résoudre l'équation suivante :

$${}^t\mathbf{X}\mathbf{X}\hat{\beta} = {}^t\mathbf{X}\mathbf{y}.$$

## Solution

Nous trouvons après avoir inversé la matrice  ${}^t\mathbf{X}\mathbf{X}$  (il faut naturellement vérifier que  ${}^t\mathbf{X}\mathbf{X}$  est carrée et inversible c'est-à-dire qu'aucune des colonnes qui compose cette matrice ne soit proportionnelle aux autres colonnes)

$$\hat{\beta} = ({}^t\mathbf{X}\mathbf{X})^{-1}{}^t\mathbf{X}\mathbf{y}.$$

## Remarque

Retrouvons les résultats de la régression linéaire simple ( $p = 2$ )

$${}^t\mathbf{XX} = \begin{pmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{pmatrix}; \quad {}^t\mathbf{Xy} = \begin{pmatrix} \sum y_i \\ \sum x_i y_i \end{pmatrix}.$$

Donc :

$$\begin{aligned} ({}^t\mathbf{XX})^{-1} &= \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{pmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & n \end{pmatrix} \\ &= \frac{1}{\sum (x_i - \bar{x})^2} \begin{pmatrix} \sum x_i^2 / n & -\bar{x} \\ -\bar{x} & 1 \end{pmatrix}. \end{aligned}$$

## Suite et fin de la remarque

Finalement nous retrouvons bien :

$$\hat{\beta} = \begin{pmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{pmatrix} = \begin{pmatrix} \frac{\bar{Y} \sum x_i^2 - \bar{x} \sum x_i Y_i}{\sum (x_i - \bar{x})^2} \\ \frac{\sum x_i Y_i - n \bar{x} \bar{Y}}{\sum (x_i - \bar{x})^2} \end{pmatrix}$$

ce qui correspond aux estimateurs de la régression linéaire simple que nous avons déjà rencontrés dans le cours 6.

## Exemple avec le logiciel R

```
> a <- lm(max03 ~ T12 + VX)
> summary(a)
```

Call:

```
lm(formula = max03 ~ T12 + VX)
```

Residuals:

```
Min 1Q Median 3Q Max
-47.860 -10.561  5.119 10.645 26.506
```

Coefficients:

```
Estimate Std. Error t value Pr(>|t|)
(Intercept) 36.6520 26.5324 1.381 0.210
T12 2.6623 1.4202 1.875 0.103
VX 0.5431 0.7775 0.699 0.507
Residual standard error: 24.78 on 7 degrees of freedom
Multiple R-Squared: 0.3351, Adjusted R-squared: 0.1452
F-statistic: 1.764 on 2 and 7 DF, p-value: 0.2396
```


## Résultats préliminaires

- 1  $\sum \hat{y}_i^2 = \sum \hat{y}_i y_i$  ou (forme matricielle)  ${}^t\hat{\mathbf{y}}\hat{\mathbf{y}} = {}^t\mathbf{y}\mathbf{y}$
- 2  $\sum \hat{y}_i = \sum y_i$

## Propriété des moindres carrés

$$\begin{array}{rcl} \sum (y_i - \bar{y})^2 & = & \sum (\hat{y}_i - \bar{y})^2 + \sum (y_i - \hat{y}_i)^2 \\ \text{SC}_{tot} & = & \text{SC}_{reg} + \text{SC}_{res} \end{array}$$

## Représentation graphique de la relation fondamentale





## Rappel sur le coefficient de détermination

Le **coefficient de détermination** est défini par :

$$R^2 = \frac{SC_{reg}}{SC_{tot}}.$$

Intuitivement ce coefficient de détermination quantifie la capacité du modèle à expliquer les variations de  $Y$ .

- Si  $R^2$  est proche de 1 alors le modèle est proche de la réalité.
- Si  $R^2$  est proche de 0 alors le modèle explique très mal la réalité. Il faut alors trouver un meilleur modèle.

## Les hypothèses indispensables pour réaliser les tests

Nous faisons les hypothèses suivantes :

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon$$

où le vecteur aléatoire  $\varepsilon$  suit une loi *multinormale* qui vérifie les hypothèses suivantes :

- $\mathbb{E}[\varepsilon] = 0$
- $\text{Var}[\varepsilon] = \sigma^2 \mathbf{I}_n$ ,

où  $\sigma^2$  est la variance de la population et  $\mathbf{I}_n$  est la matrice identité de taille  $n$ .

## Conséquences

Les hypothèses précédentes impliquent

- $\mathbb{E}[\mathbf{y}] = \mathbf{X}\beta$
- $\text{Var}[\mathbf{y}] = \sigma^2 \mathbf{I}_n$ .

Nous pouvons alors démontrer, **sous ces hypothèses** :

- $\mathbb{E}[\hat{\beta}] = \beta$ . Ce qui signifie que le vecteur  $\hat{\beta}$  est un estimateur sans biais de  $\beta$ .
- $\text{Var}[\hat{\beta}] = \sigma^2 (\mathbf{X}^t \mathbf{X})^{-1}$ .

## Problème

La variance  $\sigma^2$  est inconnue. Donc il faut estimer  $\sigma^2$  !

## Construction d'un estimateur de $\sigma^2$

Un estimateur sans biais de la variance  $\sigma^2$  est défini par :

$$s^2 = \frac{\sum (y_i - \hat{y}_i)^2}{n - p} = \frac{SC_{res}}{n - p} = \frac{SC_{tot} - SC_{reg}}{n - p}$$

où

- $n$  est le nombre d'individus/d'observations,
- $p$  est le nombre de variables explicatives.

Nous rappelons que la quantité  $(n - p)$  est **le nombre de degrés de liberté associé à  $SC_{res}$** .

## Test de Fisher

Tester l'hypothèse nulle :

$$\mathcal{H}_0 : \beta_1 = \beta_2 = \cdots = \beta_{p-1} = 0$$

contre l'hypothèse alternative :

$$\mathcal{H}_1 : \exists j \text{ pour lequel } \beta_j \neq 0 \text{ où } j \text{ varie de } 1 \text{ à } p-1.$$

## Remarque

Si l'hypothèse nulle  $\mathcal{H}_0$  est vérifiée alors le modèle s'écrit :

$$Y_i = \beta_0 + \varepsilon_i.$$

## Tableau de l'analyse de la variance

Source de variation	$SC$	$ddl$	$CM$	$F_{obs}$
Régression	$SC_{reg} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$	$p - 1$	$\frac{SC_{reg}}{p - 1}$	$\frac{CM_{reg}}{CM_{res}}$
Résiduelle	$SC_{res} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$	$n - p$	$\frac{SC_{res}}{n - p}$	
Totale	$SC_{tot} = \sum_{i=1}^n (y_i - \bar{y})^2$	$n - 1$		

## Méthode

- 1 Calculer la statistique

$$F_{obs} = \frac{CM_{reg}}{CM_{res}}.$$

- 2 Lire la valeur critique  $F_{1-\alpha, p-1, n-p}$  où  $F_{1-\alpha, p-1, n-p}$  est le  $(1 - \alpha)$ -quantile d'une loi de Fisher avec  $(p - 1)$  et  $(n - p)$  degrés de liberté, car si l'hypothèse nulle  $\mathcal{H}_0$  est vraie, alors  $F_{obs}$  suit une loi de Fisher avec  $(p - 1)$  et  $(n - p)$  degrés de liberté.
- 3 Comparer la valeur observée et la valeur critique.

## Règle de décision

- Nous décidons de rejeter l'hypothèse nulle  $\mathcal{H}_0$  et d'accepter l'hypothèse alternative  $\mathcal{H}_1$ , au seuil  $\alpha = 5\%$ , si

$$|F_{obs}| \geq F_{(1-\alpha, p-1, n-p)}.$$

- Nous décidons de ne pas rejeter l'hypothèse nulle  $\mathcal{H}_0$  et donc de l'accepter si

$$|F_{obs}| < F_{(1-\alpha, p-1, n-p)}.$$



## Tests de Student

Tester l'hypothèse nulle

$$\mathcal{H}_0 : \beta_j = b_j \quad \text{pour } j = 0, \dots, p-1$$

contre l'hypothèse alternative

$$\mathcal{H}_1 : \beta_j \neq b_j \quad \text{pour un certain } j \text{ entre } 0 \text{ et } p-1.$$

## Méthode

- 1 Calculer la statistique

$$t_{obs} = \frac{\hat{\beta}_j - b_j}{s(\hat{\beta}_j)}$$

où  $s^2(\hat{\beta}_j)$  est l'élément diagonal d'indice  $j$  de  $s^2(t\mathbf{XX})^{-1}$ .

- 2 Lire la valeur critique  $t_{(1-\alpha/2, n-p)}$  où  $t_{(1-\alpha/2, n-p)}$  est le  $(1 - \alpha/2)$ -quantile d'une loi de Student avec  $(n - p)$  degrés de liberté, car si l'hypothèse nulle  $\mathcal{H}_0$  est vraie, alors  $t_{obs}$  suit une loi de Student avec  $(n - p)$  degrés de liberté.
- 3 Comparer la valeur observée et la valeur critique.

## Règle de décision

- Nous décidons de rejeter l'hypothèse nulle  $\mathcal{H}_0$  et d'accepter l'hypothèse alternative  $\mathcal{H}_1$ , au seuil  $\alpha = 5\%$ , si

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

- Nous décidons de ne pas rejeter l'hypothèse nulle  $\mathcal{H}_0$  et donc de l'accepter si

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

## Cas particulier

Tester l'hypothèse nulle

$$\mathcal{H}_0 : \beta_j = 0 \quad \text{pour } j = 0, \dots, p-1$$

contre l'hypothèse alternative

$$\mathcal{H}_1 : \beta_j \neq 0 \text{ pour un certain } j \text{ entre } 0 \text{ et } p-1.$$

## Méthode

- 1 Calculer la statistique

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

- 2 Lire la valeur critique  $t_{(1-\alpha/2, n-p)}$  où  $t_{(1-\alpha/2, n-p)}$  est le  $(1 - \alpha/2)$ -quantile d'une loi de Student avec  $(n - p)$  degrés de liberté, car si l'hypothèse nulle  $\mathcal{H}_0$  est vraie, alors  $t_{obs}$  suit une loi de Student avec  $(n - p)$  degrés de liberté.
- 3 Comparer la valeur observée et la valeur critique.

## Règle de décision

- Nous décidons de rejeter l'hypothèse nulle  $\mathcal{H}_0$  et d'accepter l'hypothèse alternative  $\mathcal{H}_1$ , au seuil  $\alpha = 5\%$ , si

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

- Nous décidons de ne pas rejeter l'hypothèse nulle  $\mathcal{H}_0$  et donc de l'accepter si

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

## IC pour $\beta_j$

Un intervalle de confiance au niveau  $(1 - \alpha)$  où  $\alpha$  est la probabilité d'erreur pour  $\beta_j$  est défini par

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

## Remarque

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

## Test de Fisher partiel

La nullité d'un certain nombre  $r$  de paramètres dans un modèle de  $p$  paramètres.

l'hypothèse nulle  $\mathcal{H}_0$  : *modèle réduit* avec  $(p - r)$  paramètres  
contre

l'hypothèse alternative  $\mathcal{H}_1$  : *modèle complet* avec  $p$  paramètres.



## Exemples

- Tester la nullité d'un paramètre, par exemple :  $\beta_1$ .

$$\mathcal{H}_0 : Y_i = \beta_0 + \beta_2 x_{i2} + \cdots + \beta_p x_{ip} + \varepsilon_i \text{ contre}$$

$$\mathcal{H}_1 : Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_p x_{ip} + \varepsilon_i.$$

- Tester la nullité de plusieurs paramètres, par exemple les pairs :  $\beta_{2j}$ .

$$\mathcal{H}_0 : Y_i = \beta_1 x_{i1} + \beta_3 x_{i3} + \cdots + \beta_{p-1} x_{ip-1} + \varepsilon_i \text{ contre}$$

$$\mathcal{H}_1 : Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_p x_{ip} + \varepsilon_i \text{ avec } p \text{ pair.}$$

## Méthode

- 1 Calculer les valeurs estimées  $\hat{y}_i$  en utilisant la méthode des moindres carrés pour chacun des 2 modèles définis par  $\mathcal{H}_0$  et  $\mathcal{H}_1$ , notées :  $\hat{y}_i(\mathcal{H}_0)$  et  $\hat{y}_i(\mathcal{H}_1)$ .
- 2 Calculer ensuite  $SC_{res}(\mathcal{H}_0)$  et  $SC_{res}(\mathcal{H}_1)$ .
- 3 Calculer la statistique

$$F_{obs} = \frac{SC_{res}(\mathcal{H}_0) - SC_{res}(\mathcal{H}_1)}{SC_{res}(\mathcal{H}_1)} \times \frac{n - p}{r}.$$

## Méthode - Suite et fin

- 4 Lire la valeur critique  $F_{1-\alpha, r, n-p}$  où  $F_{1-\alpha, r, n-p}$  est le  $(1 - \alpha)$ -quantile d'une loi de Fisher avec  $r$  et  $(n - p)$  degrés de liberté, car si l'hypothèse nulle  $\mathcal{H}_0$  est vraie, alors  $F_{obs}$  suit une loi de Fisher avec  $r$  et  $(n - p)$  degrés de liberté.
- 5 Comparer la valeur observée et la valeur critique.

## Règle de décision

- Nous décidons de rejeter l'hypothèse nulle  $\mathcal{H}_0$  et par conséquent d'accepter l'hypothèse alternative  $\mathcal{H}_1$ , au seuil  $\alpha = 5\%$ , si

$$F_{obs} \geq F_{1-\alpha, r, n-p}.$$

- Nous décidons de ne pas rejeter l'hypothèse nulle  $\mathcal{H}_0$  et donc de l'accepter si

$$F_{obs} < F_{1-\alpha, r, n-p}.$$