

# Régression linéaire multiple

Frédéric et Myriam Bertrand<sup>1</sup>


<sup>1</sup>IRMA, Université Louis Pasteur  
Strasbourg, France

Master 2ème Année 9-11-2006

- **Problème** : Étude de la concentration d' $O_3$  dans l'air.
- **Modèle** : La température (v.a.  $X$ ) et la concentration d' $O_3$  (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' $O_3$ .
- **But** : Estimer  $\beta_0$  et  $\beta_1$  afin de prédire la concentration d'ozone connaissant la température.



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

Le principe de la régression linéaire multiple est simple :

- Déterminer la variable expliquée  $Y$ .  
**Exemple** : La concentration d' $O_3$ .
- 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 :

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

## But :

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

**Méthode** : La méthode des moindres carrés. Cette méthode revient à minimiser la quantité suivante :

$$\sum_{i=1}^n \left( y_i - \left( \hat{\beta}_0 + \hat{\beta}_1 X_{i,1} + \dots + \hat{\beta}_{p-1} X_{i,p-1} \right) \right)^2$$

Dans un échantillon de  $n$  individus, on mesure  $y_i, X_{i,1}, \dots, X_{i,p-1}$  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.

Le système peut se réécrire :

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

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

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

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

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

- **Problème :** On cherche  $\hat{\beta}$  qui annule cette dérivée. Donc on doit résoudre l'équation suivante :

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

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 :

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

- **Solution :** On trouve 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)

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

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

$${}^t\mathbf{X}\mathbf{X} = \begin{pmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{pmatrix}; \quad {}^t\mathbf{X}\mathbf{y} = \begin{pmatrix} \sum y_i \\ \sum x_i y_i \end{pmatrix}$$

Donc :

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

Finalement on retrouve 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 2.

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

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

```
Residuals:
Min 10 Median 30 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 :

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

### Propriété des moindres carrés :

$$\sum (y_i - \bar{y})^2 = \sum (\hat{y}_i - \bar{y})^2 + \sum (y_i - \hat{y}_i)^2$$

$$SC_{tot} = SC_{reg} + SC_{res}$$



Le coefficient de détermination est défini par :

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

Intuitivement ce coefficient 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.



