

# Modèles linéaires

## Régressions simples et multiples

Denis Laloë  
GABI - PSGen

27 septembre 2016




# Un exemple simple. Modélisation par une constante

$$\mathbf{Y} = \beta_0 \mathbf{1} + \mathbf{E}; \mathbf{Y} \text{ à valeurs dans } \mathbb{R}^2$$

$\mathbf{y}$  est une réalisation de  $\mathbf{Y}$

Projection de  $\mathbf{y}$  sur la droite engendrée par  $\mathbf{1} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$


3



## Quelle projection ?

$$\mathbf{Y} = \beta_0 \mathbf{1} + \mathbf{E}$$


## Quelle projection ?



## Quelle projection

$$\mathbf{Y} = \beta_0 \mathbf{1} + \mathbf{E}$$

Projection minimisant la longueur de  $\|\mathbf{y} - \hat{\mathbf{y}}\|$



## Projection orthogonale

$$\mathbf{Y} = \beta_0 \mathbf{1} + \mathbf{E}$$

Projection orthogonale minimisant la longueur de  $\|\mathbf{y} - \hat{\mathbf{y}}\|$


$$y - \hat{y} \perp 1$$

$$\mathbf{1}^t(\mathbf{y} - \hat{\mathbf{y}}) = 0$$

$$\mathbf{1}^t(\mathbf{y} - \mathbf{1}\hat{\beta}_0) = 0$$

$$1^t v = 1^t 1 \hat{\beta}_0$$

$$\hat{\beta}_0 = (\mathbf{1}^t \mathbf{1})^{-1} \mathbf{1}^t \mathbf{y}$$



# Moindres carrés ordinaires


$$\hat{\beta}_0 = (\mathbf{1}^t \mathbf{1})^{-1} \mathbf{1}^t \mathbf{y}$$

$$\mathbf{1}^t \mathbf{y} = y_1 + y_2$$

$$\mathbf{1}^t \mathbf{1} = 2$$


$$(\mathbf{1}^t \mathbf{1})^{-1} = \frac{1}{2}$$

$$\hat{\beta}_0 = \frac{y_1 + y_2}{2}$$



# La régression

- On a une variable aléatoire  $\mathbf{Y}$ , une réalisation de cette variable, composée de  $n$  valeurs,  $y_i, i = 1, \dots, n$
  - On regroupe ces  $n$  valeurs dans un vecteur  $\mathbf{y}$ , appartenant à  $\mathbb{R}^n$
  - On modélise  $\mathbf{y}$  en fonction d'une constante et de  $p$  variables explicatives
- $$\mathbf{x} : \mathbf{Y} = \beta_0 + \beta_1 \mathbf{x}^{(1)} + \dots + \beta_p \mathbf{x}^{(p)} + \mathbf{E}$$
- Ces variables engendrent un espace à  $p+1$  dimensions.



# Le modèle linéaire général

## Modèle : Constante

$$\mathbf{Y} = \mathbf{1}\beta_0 + \mathbf{\epsilon}$$

$$\mathbf{Y} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} \beta_0 + \mathbf{\epsilon}$$

## Modèle général

$$\mathbf{Y} = \mathbf{X}\beta + \mathbf{\epsilon}$$

$$\mathbf{Y} = \begin{bmatrix} 1 & x_1^{(1)} & x_1^{(2)} & \dots & x_1^{(p)} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_n^{(1)} & x_n^{(2)} & \dots & x_n^{(p)} \end{bmatrix} \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \\ \vdots \\ \beta_p \end{bmatrix} + \mathbf{\epsilon}$$

## Résolution

$$\hat{\beta}_0 = (\mathbf{1}^t \mathbf{1})^{-1} \mathbf{1}^t \mathbf{y}$$

## Résolution

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

# La régression simple. Le modèle et son écriture matricielle

$$\mathbf{Y} = \mathbf{X}\beta + \mathbf{\epsilon}$$

$$\mathbf{Y} = \begin{bmatrix} 1 & x_1 \\ : & : \\ 1 & x_n \end{bmatrix} \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix} + \mathbf{\epsilon}$$

$$\mathbf{X}^t \mathbf{X}$$

$$\mathbf{X}^t \mathbf{X} = \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_n \end{bmatrix} \begin{bmatrix} 1 & x_1 \\ : & : \\ 1 & x_n \end{bmatrix} = \begin{bmatrix} n & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{bmatrix} = \begin{bmatrix} n & s_x \\ s_x & s_{x^2} \end{bmatrix}$$

$$\mathbf{X}^t \mathbf{Y}$$

$$\mathbf{X}^t \mathbf{Y} = \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_n \end{bmatrix} \begin{bmatrix} Y_1 \\ : \\ Y_n \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n x_i Y_i \end{bmatrix} = \begin{bmatrix} s_Y \\ s_{XY} \end{bmatrix}$$

# La régression simple. La résolution

$$(\mathbf{X}^t \mathbf{X})^{-1}$$

$$\mathbf{X}^t \mathbf{X} = \begin{bmatrix} n & s_x \\ s_x & s_{x^2} \end{bmatrix}$$

$$(\mathbf{X}^t \mathbf{X})^{-1} = \frac{1}{ns_{x^2} - s_x^2} \begin{bmatrix} s_{x^2} & -s_x \\ -s_x & n \end{bmatrix}$$

$$(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{Y}$$

$$(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{Y} = \frac{1}{ns_{x^2} - s_x^2} \begin{bmatrix} s_{x^2} & -s_x \\ -s_x & n \end{bmatrix} \begin{bmatrix} s_Y \\ s_{XY} \end{bmatrix} = \frac{1}{ns_{x^2} - s_x^2} \begin{bmatrix} s_{x^2} s_Y - s_x s_{XY} \\ n s_{XY} - s_x s_Y \end{bmatrix}$$

## Solution

$$\hat{\beta}_1 = \frac{ns_{XY} - s_x s_Y}{ns_{x^2} - s_x^2} = \frac{s_{(x-\bar{x})(Y-\bar{Y})}}{s_{(x-\bar{x})^2}}$$

$$\hat{\beta}_0 = m_Y - \hat{\beta}_1 m_x$$

# Propriétés de l'estimateur

## Propriétés

- Justification géométrique (hors hypothèses de distribution)
- Equivalence avec l'estimateur du maximum de vraisemblance  
 $E \sim \mathbb{N}(0, \sigma^2)$
- Sans biais
- Variance minimale
- convergent


## Prédiction

- $\hat{\beta} \sim \mathbb{N}(\beta, (\mathbf{X}^t \mathbf{X})^{-1} \sigma^2)$
- $\hat{Y} = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{Y} = \mathbf{H} \mathbf{Y}$ ,
- $\mathbf{H}$  encore appelée "hat matrix".

# Estimateur de la variance résiduelle

- $\hat{\sigma}^2 = \frac{\sum(Y_i - \hat{Y}_i)^2}{n - p - 1}$
- Sans biais
- Variance minimale (*parmi les estimateurs quadratiques sans biais*)
- $\frac{(n - p - 1)\hat{\sigma}^2}{\sigma^2} \sim \chi_{n-p}^2$

# Interprétation des coefficients



- Signification de  $\beta_0$  ?
- $x \rightarrow x - \bar{x}$

# La régression simple. Une autre paramétrisation

$$\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}'\mathbf{y}$$

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

$$\mathbf{X} = \begin{pmatrix} 1 & x_1 - \bar{x} \\ 1 & x_2 - \bar{x} \\ \vdots & \vdots \\ 1 & x_{n-1} - \bar{x} \\ 1 & x_n - \bar{x} \end{pmatrix}$$

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} 1 & 1 & \dots & 1 & 1 \\ x_1 - \bar{x} & x_2 - \bar{x} & \dots & x_{n-1} - \bar{x} & x_n - \bar{x} \end{pmatrix} \begin{pmatrix} 1 & x_1 - \bar{x} \\ 1 & x_2 - \bar{x} \\ \vdots & \vdots \\ 1 & x_{n-1} - \bar{x} \\ 1 & x_n - \bar{x} \end{pmatrix}$$

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} n & \sum x_i - n\bar{x} \\ \sum x_i - n\bar{x} & \sum (x_i - \bar{x})^2 \end{pmatrix}$$

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} n & 0 \\ 0 & \sum (x_i - \bar{x})^2 \end{pmatrix}$$

# La régression simple. Une autre paramétrisation

$$\mathbf{X}'\hat{\mathbf{B}} = \mathbf{X}'Y$$

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

$$\mathbf{X}'Y = \begin{pmatrix} 1 & 1 & \cdots & 1 & 1 \\ x_1 - \bar{x} & x_2 - \bar{x} & \cdots & x_{n-1} - \bar{x} & x_n - \bar{x} \end{pmatrix} \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_{n-1} \\ Y_n \end{pmatrix}$$

$$\mathbf{X}'Y = \begin{pmatrix} \sum Y_i \\ \sum (x_i - \bar{x})Y_i \end{pmatrix}$$

$$\mathbf{X}'\hat{\mathbf{B}} = \begin{pmatrix} n & \mathbf{0} \\ \mathbf{0} & \sum (x_i - \bar{x})^2 \end{pmatrix} \begin{pmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{pmatrix}$$

$$\hat{\beta}_0 = \frac{\sum Y_i}{n}$$

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



# La régression simple. Une autre paramétrisation

$$\hat{\beta}_0 = \frac{\sum Y_i}{n}$$

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

- $\hat{\beta}_1$  inchangé
- $\hat{\beta}_0$  égal à la moyenne des  $Y$

# La régression simple. Une autre paramétrisation



- La covariance entre les estimateurs est nulle
- Colinéarité...

# Estimateur de la variance résiduelle

- $\hat{\sigma}^2 = \frac{\sum(Y_i - \hat{Y}_i)^2}{n - p - 1}$
- Sans biais
- Variance minimale (*parmi les estimateurs quadratiques sans biais*)
- $\frac{(n - p - 1)\hat{\sigma}^2}{\sigma^2} \sim \chi_{n-p}^2$

# Lois liées à la loi normale

## Loi du $\chi^2$

Soient  $X_1, \dots, X_n$  des v.a. indépendantes de même loi  $\mathbb{N}(0, 1)$ , et  $Z = \sum_{i=1}^n X_i^2$ .  $Z$  suit une loi du khi-deux à  $n$  degrés de liberté  $\chi^2(n)$

## Loi de Student

Soient  $X \sim \mathbb{N}(0, 1)$ ,  $Y \sim \chi^2(n)$ , et  $T = \frac{X}{\sqrt{\frac{Y}{n}}}$ .  $T$  suit une loi de Student à  $n$  degrés de liberté ( $T(n)$ ,  $Student(n)$ ).

## Loi de Fisher-Snedecor

Soient deux variables indépendantes  $X \sim \chi^2(n)$ ,  $Y \sim \chi^2(m)$ , et  $T = \frac{X}{Y/m}$ .  $T$  suit une loi de Fisher-Snedecor  $F(n, m)$ .

# Décomposition de la variance


## Somme des carrés

$$\sum(Y_i - \bar{Y})^2 = \sum(\hat{Y}_i - \bar{Y})^2 + \sum(Y_i - \hat{Y}_i)^2$$
$$SCT = SCE + SCR$$

- SCT : Somme des carrés totale
- SCE : Somme des carrés expliquées
- SCR : Somme des carrés résiduelles

# Somme des carrés $R^2$

- SCT : Somme des carrés totale
- SCE : Somme des carrés expliquées
- SCR : Somme des carrés résiduelles
- $R^2 = \frac{SCE}{SCT} = \cos^2(Y, \hat{Y})$



# Hypothèses

## Inférence sur le modèle

- SCR :  $\sum(Y_i - \hat{Y}_i)^2 \sim \chi^2_{n-p-1}$
- SCE et SCR sont indépendantes
- Le modèle explique-t-il quelque chose ?
- H0 :  $\beta = 0$ 
  - SCE :  $\sum(\hat{Y}_i - \bar{Y})^2 \sim \chi^2_p$
  - $\frac{\text{SCE}}{\frac{SCR}{n-p-1}} \sim F(p, n-p-1)$

## Table d'analyse de la variance


Source de variation	d.d.l	Somme des carrés	Carrés moyens	F
Modèle	p	SCE	CME=SCE/p	CME/CMR
Erreur	n-p-1	SCR	CMR=SCR/n-p-1	
Total	n-1	SCT		

# Hypothèses

## • Inférence sur le modèle

- Le modèle explique-t-il quelque chose
- $H_0 : \beta=0$

$$\frac{SCE}{SCR} \sim F(p, n - p - 1)$$




Distribution de Fisher(1,10)  
 $\alpha=0.05$   
 $f_{0.95}=4.96$   
 $H_0$  rejeté si  $F > f_{0.95}$

# Hypothèses

## • Inférence sur UN coefficient


- Distribution d'un coefficient  $\frac{\hat{\beta}_i - \beta_i}{\hat{\sigma}_i} \sim t(n - p)$
- Hypothèse  $H_0 : \beta_j = a$
- Construction d'un intervalle de

$$\left[ \hat{\beta}_i - t_{1-\alpha/2} \hat{\sigma}_i, \hat{\beta}_i + t_{1-\alpha/2} \hat{\sigma}_i \right]$$



# Un modèle de régression simple


- Fichier *cats*, du package R MASS
- 144 chats, sur lesquels on a mesuré les poids du corps et du cœur.  
Les variables ont également été transformées (logarithme)



# Passage aux logarithmes

Normalité du logarithme du poids du cœur

## 1. Graphiques



## 2. Test de normalité de Shapiro-Wilk (shapiro.test)

p=0.83. Normalité acceptée

*p.m, le test de Shapiro sur le poids du cœur non transformé conduit à rejeter l'hypothèse de normalité*


# fonction lm du package R

## **fic.lm=lm(y x,data=fic)**

- `summary(fic.lm)` : Résumé
- `coefficients(fic.lm)` : Coefficients du modèle
- `confint(fic.lm, level=0.95)` : Intervalles de confiance
- `fitted(fic.lm)` : valeurs prédites
- `residuals(fic.lm)` : résiduelles
- `anova(fic.lm)` : Table d'analyse de variance
- `vcov(fic.lm)` : Matrice de covariance des paramètres
- `plot (fic.lm)` : Diagnostics
- `influence (fic.lm)`
- `drop1, add1, anova (modèle1,modèle2)` comparaison de modèles

# La droite de régression

$$\log(Hwt) = \beta_0 + \beta_1 \log(Bwt) + E$$



# Analyse de variance.1

$$\logHwt = \beta_0 + \beta_1 \logBwt$$

```
dat.lm<-lm(logHwt~logBwt,data=dat)  
anova(dat.lm)
```

## Analysis of Variance Table

Response: logHwt

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
logBwt	1	4.4802	4.4802	246.45	< 2.2e-16 **
Residuals	142	2.5814	0.0182		

---

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

# Analyse de variance.2

$$\text{logHwt} = \beta_0 + \beta_1 \text{logBwt}$$

```
dat.lm<-lm(logHwt~logBwt,data=dat)
summary(dat.lm)
```

Call:

```
lm(formula = logHwt ~ logBwt, data = dat)
```

Residuals:

Min	1Q	Median	3Q	Max
-0.38614	-0.09404	0.00065	0.09354	0.30337

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	1.34246	0.06446	20.83	<2e-16 ***
logBwt	1.01001	0.06434	15.70	<2e-16 ***

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.1348 on 142 degrees of freedom

Multiple R-squared: 0.6344,      **Adjusted R-squared:** 0.6319

F-statistic: 246.5 on 1 and 142 DF, p-value: < 2.2e-16

# Student / Fisher


Distribution de Fisher à 1 et m d.d.l

=


Carré d'une dist. Student à m d.d.l

$T\text{-value}=15.7$

$F\text{-value}=246.45$



$$t_{1-\alpha/2} = f_{1-\alpha}$$



# Intervalles de confiance

summary(dat.lm)

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	1.34246	0.06446	20.83	<2e-16 ***
logBwt	1.01001	0.06434	15.70	<2e-16 ***

...

F-statistic: 246.5 on 1 and 142 DF, p-value: < 2.2e-16

Intervalle de confiance de  $\beta_1$


confint(dat.lm, "logBwt", .95)

2.5 % 97.5 %

logBwt 0.8828261 1.13719


# Diagnostics-1

- `plot(data.lm)`
- Courbure
- Hétéroscédasticité
- Outliers




## Diagnostics-2

- `plot(data.lm)`
  - Normalité
  - Hétéroscédasticité
  - Outliers




# Diagnostics-3

- `plot(data.lm)`
- Normalité
- Hétéroscédasticité
- Outliers




# Diagnostics-4

- `plot(data.lm)`
- Données influentes
- Outliers
- Courbes isocook (*non visibles*)








# Développement musculaire bovins allaitants








# Développement musculaire bovins allaitants

## Histogrammes (hist)








# Développement musculaire bovins allaitants

## Boxplot (boîtes à moustache) (boxplot)



# Développement musculaire bovins allaitants

## QQplots (qqnorm)



# Dessus d'épaule en fonction des 4 autres notes

dm.lm=lm(DE DO+AC+LC+EP,data=dm)

**summary(dm.lm)**

Call:

lm(formula = DE ~ DO + AC + LC + EP, data = dm)

Residuals:

Min	1Q	Median	3Q	Max
-5.8511	-0.4172	0.0580	0.4324	3.8045

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	1.476796	0.016180	91.275	<2e-16 ***
DO	0.541977	0.002753	196.852	<2e-16 ***
AC	0.029739	0.003142	9.464	<2e-16 ***
LC	0.137821	0.003045	45.262	<2e-16 ***
EP	0.090902	0.002667	34.081	<2e-16 ***

---

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

Residual standard error: 0.6182 on 86522 degrees of freedom

Multiple R-squared: 0.5753, Adjusted R-squared: 0.5753

F-statistic: 2.93e+04 on 4 and 86522 DF, p-value: < 2.2e-16

# Dessus d'épaule en fonction des 4 autres notes

```
dm.lm=lm(DE DO+AC+LC+EP,data=dm)
```

**anova(dm.lm)**

Analysis of Variance Table

Response: DE

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
DO	1	42469	42469	111142.4	< 2.2e-16 ***
AC	1	822	822	2150.7	< 2.2e-16 ***
LC	1	1053	1053	2756.6	< 2.2e-16 ***
EP	1	444	444	1161.5	< 2.2e-16 ***
Residuals	86522	33061	0		

---

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

# Dessus d'épaule en fonction des 4 autres notes

`dm.lm=lm(DE DO+AC+LC+EP,data=dm)`

