



Modèle Linéaire

Qualité du
modèle

Analyse de la
variance

Validation

Application

Modèle Linéaire - Régression

Qualité du modèle

Thierry Dhorne

Institut Universitaire de Technologie de Vannes
Université de Bretagne Sud

Année Universitaire 2014-2015



Somme des carrés des écarts totaux

Modèle Linéaire

Qualité du
modèle

Analyse de la
variance

Validation

Application

- la variabilité **totale** de Y est quantifiée par

$$SCET = \sum_{r=1}^n (Y_r - \bar{Y})^2$$

- cette variabilité peut être décomposée par l'intermédiaire du modèle

→ pour chaque observation, on décompose l'écart total

$$Y_r - \bar{Y}$$

→ en faisant intervenir \hat{Y}_r le prédicteur de Y_r

- on a alors

$$Y_r - \bar{Y} = (Y_r - \hat{Y}_r) + (\hat{Y}_r - \bar{Y})$$



Décomposition de la SCET

Modèle Linéaire

Qualité du
modèle

Analyse de la
variance

Validation

Application

- on a donc

$$\begin{aligned} SCET &= \sum_{r=1}^n (Y_r - \bar{Y})^2 \\ &= \sum_{r=1}^n [(Y_r - \hat{Y}_r) + (\hat{Y}_r - \bar{Y})]^2 \\ &= \sum_{r=1}^n [(Y_r - \hat{Y}_r)^2 + (\hat{Y}_r - \bar{Y})^2 + 2(Y_r - \hat{Y}_r)(\hat{Y}_r - \bar{Y})] \\ &= \sum_{r=1}^n (Y_r - \hat{Y}_r)^2 + \sum_{r=1}^n (\hat{Y}_r - \bar{Y})^2 + 2 \sum_{r=1}^n (Y_r - \hat{Y}_r)(\hat{Y}_r - \bar{Y}) \end{aligned}$$



Décomposition de la SCET

Somme des (doubles) produits

Modèle Linéaire

Qualité du modèle

Analyse de la variance

Validation

Application

$$\begin{aligned}\sum_{r=1}^n (Y_r - \hat{Y}_r)(\hat{Y}_r - \bar{Y}) &= \sum_{r=1}^n (Y_r - B_0 - B_1 x_r)(B_0 + B_1 x_r - \bar{Y}) \\ &= \sum_{r=1}^n (Y_r - B_0 - B_1 x_r)(B_0 + B_1 x_r - (B_0 + B_1 \bar{x})) \\ &= \sum_{r=1}^n (Y_r - B_0 - B_1 x_r) B_1 (x_r - \bar{x}) \\ &= B_1 \sum_{r=1}^n Y_r - \bar{Y} + \bar{Y} - B_0 - B_1 x_r)(x_r - \bar{x}) \\ &= B_1 \sum_{r=1}^n (Y_r - \bar{Y} - B_1(\bar{x} - x_r))(x_r - \bar{x}) \\ &= B_1 \sum_{r=1}^n (Y_r - \bar{Y})(x_r - \bar{x}) - B_1^2 \sum_{r=1}^n (\bar{x} - x_r)^2 \\ &= B_1 \sum_{r=1}^n (Y_r - \bar{Y})(x_r - \bar{x}) - B_1 \sum_{r=1}^n (\bar{Y} - Y_r)(x_r - \bar{x}) \\ &= 0\end{aligned}$$

- la somme des produits s'annule



Équation d'analyse de la variance

Modèle Linéaire

Qualité du
modèle

Analyse de la
variance

Validation

Application

- on a donc l'égalité suivante

$$\sum_{r=1}^n (Y_r - \bar{Y})^2 = \sum_{r=1}^n (\hat{Y}_r - \bar{Y})^2 + \sum_{r=1}^n (Y_r - \hat{Y}_r)^2$$

- ➔ qui s'appelle *équation d'analyse de la variance*
- ➔ qui s'écrit sous forme synthétique

$$SCET = SCEM + SCER$$

- ▶ $SCET = \sum_{r=1}^n (Y_r - \bar{Y})^2$ est la somme des carrés des écarts totaux
- ▶ $SCEM = \sum_{r=1}^n (\hat{Y}_r - \bar{Y})^2$ est la somme des carrés des écarts (expliqués par le) modèle
- ▶ $SCER = \sum_{r=1}^n (Y_r - \hat{Y}_r)^2$ est la somme des carrés des écarts résiduels



Validation du modèle

Critère du R^2

Modèle Linéaire

Qualité du
modèle

Analyse de la
variance

Validation

Application

- le modèle est il explicatif ?
- ➔ le choix de x comme prédicteur est il justifié ?

- principe
- ➔ $SCEM$ du même ordre que $SCET$
- ➔ $SCER$ le plus petit possible

- critère du R^2

$$R^2 = \frac{SCEM}{SCET}$$

- ➔ si R^2 est proche (?) de 1, le modèle est « intéressant »
- ★ simple mais peu fiable



Validation du modèle

Test de Fisher

Modèle Linéaire

Qualité du
modèle

Analyse de la
variance

Validation

Application

- le test de validation de Fisher basé sur la statistique

→ $F = \frac{SCEM/1}{SCER/(n-2)}$

→ le plus grand possible ? ? ? ?

- le F suit (sous H_0) un loi de Fisher $\mathcal{F}_{1,n-2}$

→ significatif (presque toujours ?)

★ sérieux mais peu efficace



Application

Données moules

Modèle Linéaire

Qualité du
modèle

Analyse de la
variance

Validation

Application

```
          Df Sum Sq Mean Sq F value Pr(>F)
ptotal    1  34.32   34.32   207.1 <2e-16 ***
Residuals 57   9.45    0.17
---
Signif. codes :  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```