



# Régression linéaire

David Causeur

*Laboratoire de Mathématiques Appliquées*

*Agrocampus Rennes*

*IRMAR CNRS UMR 6625*

*<http://www.agrocampus-rennes.fr/math/causeur/>*

# Plan de la présentation

- 1 Introduction
- 2 Approche exploratoire
  - Graphiques
  - Coefficient de corrélation linéaire
- 3 Approche inférentielle
  - Le modèle de régression linéaire simple
  - Test du lien entre  $x$  et  $Y$
  - Estimation des paramètres
  - Prédiction
- 4 Ouverture

# Problématique

## Etude du lien entre 2 variables quantitatives

- L'appréciation globale dépend-t'elle de l'amertume perçue ?

# Problématique

## Etude du lien entre 2 variables quantitatives

- L'appréciation globale dépend-t'elle de l'amertume perçue ?
- Peut-on prévoir le chiffre de ventes du mois prochain ?

# Problématique

## Etude du lien entre 2 variables quantitatives

- L'appréciation globale dépend-t'elle de l'amertume perçue ?
- Peut-on prévoir le chiffre de ventes du mois prochain ?
- La note au bac est-elle liée à celle du 3ème trimestre ?
- ...




## Un problème de prédiction


	$x = \text{Épaisseur de gras (mm)}$	$y = \text{Teneur en viande maigre (kg/quintal)}$
1	12	56.52
2	13	57.58
3	11	55.89
4	10	61.82
5	9	62.96
6	10	54.58
7	7	67.09
8	15	55.00
9	10	60.49
⋮	⋮	⋮

# Plan de la présentation

- 1 Introduction
- 2 Approche exploratoire
  - Graphiques
  - Coefficient de corrélation linéaire
- 3 Approche inférentielle
  - Le modèle de régression linéaire simple
  - Test du lien entre  $x$  et  $Y$
  - Estimation des paramètres
  - Prédiction
- 4 Ouverture

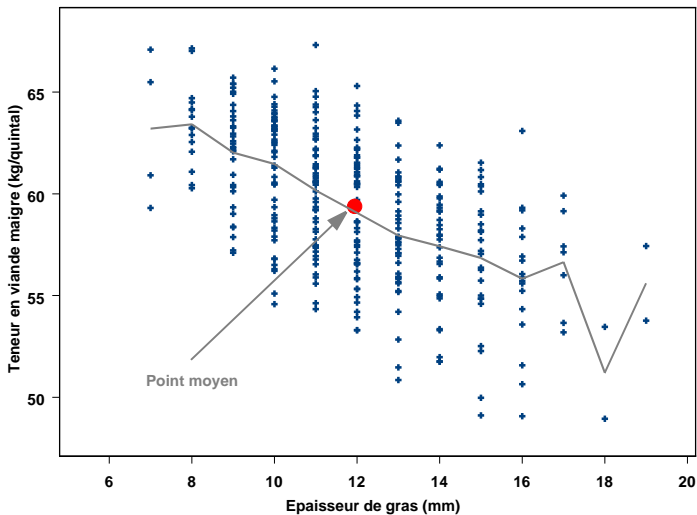


# Nuage de points






## Forme de la relation



# Lien linéaire parfait



Les variations de  $y$  sont proportionnelles à celles de  $x$

$$(y_i - \bar{y}) = k(x_i - \bar{x})$$






# Intensité du lien linéaire



**Intuition :**


le lien *Teneur en viande maigre*  $\times$  *Ép. de gras*  
est plus fort que

le lien *Teneur en viande maigre*  $\times$  *Ép. de muscle*



# Mesure de la corrélation linéaire


**Objectif** : mesurer l'intensité du lien linéaire



# Mesure de la corrélation linéaire

**Objectif** : mesurer l'intensité du lien linéaire

**Propriété** : mesure indépendante des unités de mesure




## Mesure de la corrélation linéaire

**Objectif** : mesurer l'intensité du lien linéaire

**Propriété** : mesure indépendante des unités de mesure


**Idée ...** : mesurer les variations en nombres d'écart-types

Variable	Valeur observée	Écart à la moyenne	Écart à la moyenne (en nb d'écart-types)
$x$	$x_i$	$x_i - \bar{x}$	$\frac{x_i - \bar{x}}{S_x}$
$y$	$y_i$	$y_i - \bar{y}$	$\frac{y_i - \bar{y}}{S_y}$



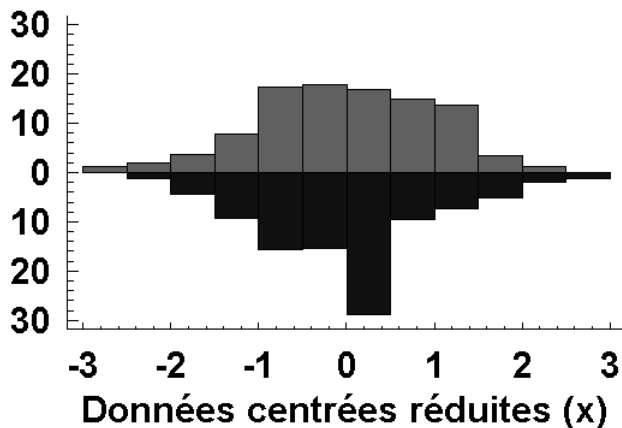
## Données centrées-réduites

	$x = \text{Épaisseur de gras}$		$y = \text{Teneur en viande maigre}$	
	Donnée (mm)	Donnée centrée-réduite	Donnée (kg/quintal)	Donnée centrée-réduite
1	12	0.03	56.52	-0.79
2	13	0.45	57.58	-0.50
3	11	-0.40	55.89	-0.97
4	10	-0.82	61.82	0.68
5	9	-1.24	62.96	1.00
6	10	-0.82	54.58	-1.33
7	7	-2.08	67.09	2.14
⋮	⋮	⋮	⋮	⋮

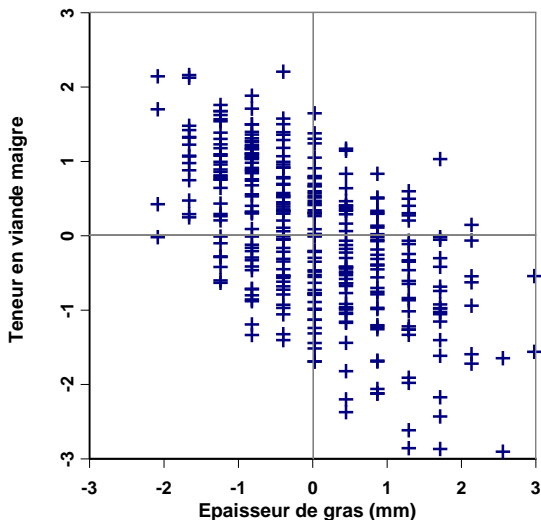


# Répartition des données centrées réduites

## Données centrées réduites (y)



# Nuage des données centrées réduites





## Coefficient de corrélation linéaire $r(x, y)$

$$\begin{aligned} r(x, y) &= \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{S_x} \right) \left( \frac{y_i - \bar{y}}{S_y} \right), \\ &= \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n S_x S_y} = \frac{S_{xy}}{S_x S_y} \end{aligned}$$



## Coefficient de corrélation linéaire $r(x, y)$

$$\begin{aligned}r(x, y) &= \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{S_x} \right) \left( \frac{y_i - \bar{y}}{S_y} \right), \\ &= \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n S_x S_y} = \frac{S_{xy}}{S_x S_y}\end{aligned}$$

### Propriétés

- $-1 \leq r(x, y) \leq 1$

# Coefficient de corrélation linéaire $r(x, y)$

$$\begin{aligned}
 r(x, y) &= \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{S_x} \right) \left( \frac{y_i - \bar{y}}{S_y} \right), \\
 &= \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n S_x S_y} = \frac{S_{xy}}{S_x S_y}
 \end{aligned}$$

## Propriétés

- $-1 \leq r(x, y) \leq 1$
- $r(x, y) > 0 \Rightarrow$  relation linéaire croissante



## Coefficient de corrélation linéaire $r(x, y)$

$$\begin{aligned}r(x, y) &= \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{S_x} \right) \left( \frac{y_i - \bar{y}}{S_y} \right), \\ &= \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n S_x S_y} = \frac{S_{xy}}{S_x S_y}\end{aligned}$$

### Propriétés

- $-1 \leq r(x, y) \leq 1$
- $r(x, y) > 0 \Rightarrow$  relation linéaire croissante
- $r(x, y) < 0 \Rightarrow$  relation linéaire décroissante

# Coefficient de corrélation linéaire $r(x, y)$

$$\begin{aligned}r(x, y) &= \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{S_x} \right) \left( \frac{y_i - \bar{y}}{S_y} \right), \\ &= \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n S_x S_y} = \frac{S_{xy}}{S_x S_y}\end{aligned}$$

## Propriétés

- $-1 \leq r(x, y) \leq 1$
- $r(x, y) > 0 \Rightarrow$  relation linéaire croissante
- $r(x, y) < 0 \Rightarrow$  relation linéaire décroissante
- $r(x, y) = 0 \Rightarrow$  pas de relation linéaire

# Coefficient de corrélation linéaire $r(x, y)$


$$\begin{aligned}
 r(x, y) &= \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{S_x} \right) \left( \frac{y_i - \bar{y}}{S_y} \right), \\
 &= \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n S_x S_y} = \frac{S_{xy}}{S_x S_y}
 \end{aligned}$$


## Propriétés

- $-1 \leq r(x, y) \leq 1$
- $r(x, y) > 0 \Rightarrow$  relation linéaire croissante
- $r(x, y) < 0 \Rightarrow$  relation linéaire décroissante
- $r(x, y) = 0 \Rightarrow$  pas de relation linéaire
- $r(x, y) = \pm 1 \Rightarrow y = \beta_0 + \beta_1 x$





# Relation linéaire croissante







# Relation linéaire décroissante







## Pas de relation linéaire







# Attention à l'interprétation !







# Attention à l'interprétation !







# Attention à l'interprétation !





# Attention à l'interprétation !





# Matrice de corrélation

	Maths				Philosophie			
	1er t.	2ème t.	3ème t.	Bac	1er t.	2ème t.	3ème t.	Bac
M <sub>1</sub>	1.00	0.77	0.72	0.58	0.19	0.22	0.16	0.24
M <sub>2</sub>	0.77	1.00	0.81	0.66	0.20	0.25	0.22	0.30
M <sub>3</sub>	0.72	0.81	1.00	0.68	0.22	0.26	0.24	0.30
M <sub>bac</sub>	0.58	0.66	0.68	1.00	0.17	0.23	0.21	0.28
P <sub>1</sub>	0.19	0.20	0.22	0.17	1.00	0.64	0.61	0.42
P <sub>2</sub>	0.22	0.25	0.26	0.23	0.64	1.00	0.69	0.43
P <sub>3</sub>	0.16	0.22	0.24	0.21	0.61	0.69	1.00	0.47
P <sub>bac</sub>	0.24	0.30	0.30	0.28	0.42	0.43	0.47	1.00

# Plan de la présentation

- 1 Introduction
- 2 Approche exploratoire
  - Graphiques
  - Coefficient de corrélation linéaire
- 3 Approche inférentielle
  - Le modèle de régression linéaire simple
  - Test du lien entre  $x$  et  $Y$
  - Estimation des paramètres
  - Prédiction
- 4 Ouverture

# Approche inférentielle

## Objectifs

- Tester l'existence d'une relation entre  $x$  et  $y$

# Approche inférentielle

## Objectifs

- Tester l'existence d'une relation entre  $x$  et  $y$
- Construire une équation de prédiction de  $y$  par  $x$

# Approche inférentielle

## Objectifs

- Tester l'existence d'une relation entre  $x$  et  $y$
- Construire une équation de prédiction de  $y$  par  $x$
- Calculer un intervalle de confiance (d'estimation, de prédiction, ...)

# Le modèle de régression linéaire simple

$Y$  : variable à expliquer (à prédire, endogène, réponse, dépendante) quantitative

$x$  : variable explicative (prédictrice, exogène, covariable, indépendante) quantitative

# Le modèle de régression linéaire simple

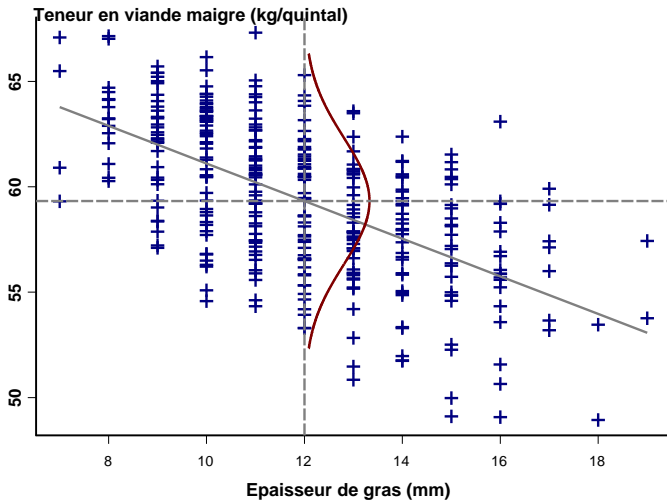
$Y$  : variable à expliquer (à prédire, endogène, réponse, dépendante) quantitative

$x$  : variable explicative (prédictrice, exogène, covariable, indépendante) quantitative

Pour un  $x$  fixé,  $Y$  est une variable aléatoire



# Le modèle de régression linéaire simple



# Le modèle de régression linéaire simple

$Y$  : variable à expliquer (à prédire, endogène, réponse, dépendante) quantitative

$x$  : variable explicative (prédictrice, exogène, covariable, indépendante) quantitative

Pour un  $x$  fixé,  $Y$  est une variable aléatoire

$$Y = \underbrace{\beta_0 + \beta_1 x}_{\text{Variations imputables à } x} + \underbrace{\varepsilon}_{\text{Variations non-imputables à } x}$$

$$\varepsilon \sim \mathcal{N}(0; \sigma)$$




# Paramètres du modèle

- Coefficients du modèle :
  - $\beta_0$  ordonnée à l'origine
  - $\beta_1$  pente



## Paramètres du modèle

- Coefficients du modèle :
  - $\beta_0$  ordonnée à l'origine
  - $\beta_1$  pente
- Écart-type résiduel :  $\sigma$



## Existence d'un lien entre $x$ et $Y$

$H_0$  : il n'y a pas de lien entre  $x$  et  $Y$

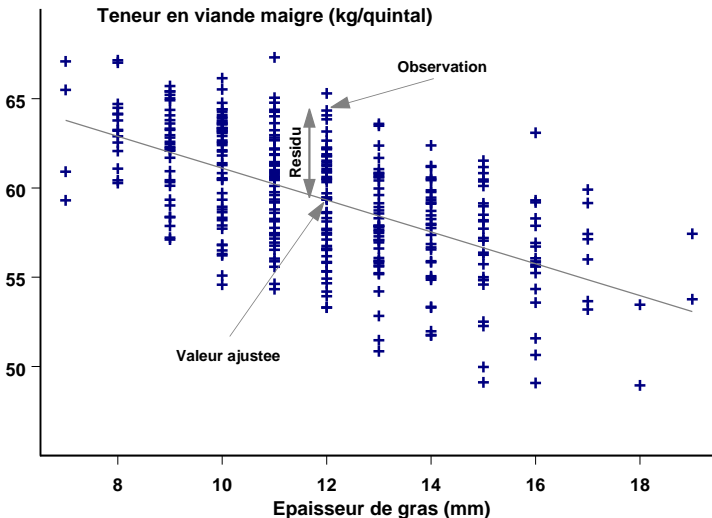
$H_1$  : il y a un lien entre  $x$  et  $Y$

ou encore ...

$H_0$  :  $\beta_1 = 0$  ,

$H_1$  :  $\beta_1 \neq 0$

# Décomposition de la variabilité de Y



# Décomposition de la variabilité de $Y$

## Equation d'«analyse de la variance»

$$\underbrace{\sum_{i=1}^n (Y_i - \bar{Y})^2}_{\text{SCET}} = \underbrace{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}_{\text{SCEM}} + \underbrace{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}_{\text{SCER}}$$

# Décomposition de la variabilité de $Y$

## Equation d'«analyse de la variance»

$$\underbrace{\sum_{i=1}^n (Y_i - \bar{Y})^2}_{\text{SCET}} = \underbrace{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}_{\text{SCEM}} + \underbrace{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}_{\text{SCER}}$$


**Problème** : ajustement du modèle ( $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$ )

# Ajustement par la méthode des moindres carrés

**Une mesure de l'adéquation entre modèle et données : le critère des moindres carrés  $SC(\beta_0, \beta_1)$**

$$SC(\beta_0, \beta_1) = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$

# Ajustement par la méthode des moindres carrés



# Ajustement par la méthode des moindres carrés

**Une mesure de l'adéquation entre modèle et données : le critère des moindres carrés  $SC(\beta_0, \beta_1)$**

$$SC(\beta_0, \beta_1) = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$

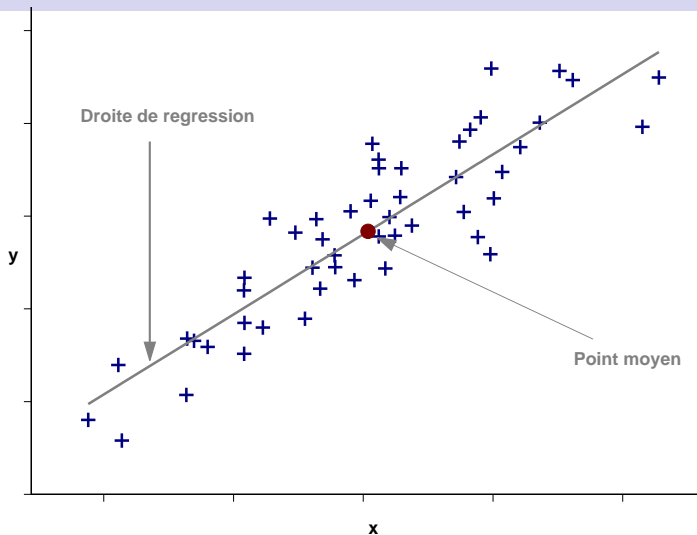
Les estimateurs  $\hat{\beta}_0$  et  $\hat{\beta}_1$  minimisent  $SC(\beta_0, \beta_1)$

$x \mapsto \hat{\beta}_0 + \hat{\beta}_1 x$  droite de régression

# Minimisation du critère des moindres carrés

$$\begin{aligned}\frac{\partial SC}{\partial \beta_0}(\hat{\beta}_0, \hat{\beta}_1) &= 0 \\ -2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) &= 0 \\ \bar{Y} - \hat{\beta}_0 - \hat{\beta}_1 \bar{x} &= 0 \\ \bar{Y} &= \hat{\beta}_0 + \hat{\beta}_1 \bar{x}\end{aligned}$$

# Minimisation du critère des moindres carrés



# Minimisation du critère des moindres carrés

$$\begin{aligned}\frac{\partial SC}{\partial \beta_0}(\hat{\beta}_0, \hat{\beta}_1) &= 0 \\ -2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) &= 0 \\ \bar{Y} - \hat{\beta}_0 - \hat{\beta}_1 \bar{x} &= 0 \\ \bar{Y} &= \hat{\beta}_0 + \hat{\beta}_1 \bar{x}\end{aligned}$$

Le point moyen  $(\bar{x}, \bar{Y})$  est sur la droite de régression

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x}$$



## Estimation de la pente

$$SC(\hat{\beta}_0, \beta_1) = \sum_{i=1}^n \left( [Y_i - \bar{Y}] - \hat{\beta}_1 [x_i - \bar{x}] \right)^2$$

D'où :

## Estimation de la pente

$$SC(\hat{\beta}_0, \hat{\beta}_1) = \sum_{i=1}^n \left( [Y_i - \bar{Y}] - \hat{\beta}_1 [x_i - \bar{x}] \right)^2$$

D'où :

$$\frac{\partial SC}{\partial \beta_1}(\hat{\beta}_0, \hat{\beta}_1) = 0$$

## Estimation de la pente

$$SC(\hat{\beta}_0, \hat{\beta}_1) = \sum_{i=1}^n \left( [Y_i - \bar{Y}] - \hat{\beta}_1 [x_i - \bar{x}] \right)^2$$

D'où :

$$\frac{\partial SC}{\partial \beta_1}(\hat{\beta}_0, \hat{\beta}_1) = 0$$

$$-2 \sum_{i=1}^n [x_i - \bar{x}] \left( [Y_i - \bar{Y}] - \hat{\beta}_1 [x_i - \bar{x}] \right) = 0$$

## Estimation de la pente

$$SC(\hat{\beta}_0, \hat{\beta}_1) = \sum_{i=1}^n \left( [Y_i - \bar{Y}] - \hat{\beta}_1 [x_i - \bar{x}] \right)^2$$

D'où :

$$\frac{\partial SC}{\partial \beta_1}(\hat{\beta}_0, \hat{\beta}_1) = 0$$

$$-2 \sum_{i=1}^n [x_i - \bar{x}] \left( [Y_i - \bar{Y}] - \hat{\beta}_1 [x_i - \bar{x}] \right) = 0$$

$$S_{xy} - \hat{\beta}_1 S_x^2 = 0$$

## Estimation de la pente

$$SC(\hat{\beta}_0, \beta_1) = \sum_{i=1}^n \left( [Y_i - \bar{Y}] - \hat{\beta}_1 [x_i - \bar{x}] \right)^2$$

D'où :

$$\frac{\partial SC}{\partial \beta_1}(\hat{\beta}_0, \hat{\beta}_1) = 0$$

$$-2 \sum_{i=1}^n [x_i - \bar{x}] \left( [Y_i - \bar{Y}] - \hat{\beta}_1 [x_i - \bar{x}] \right) = 0$$

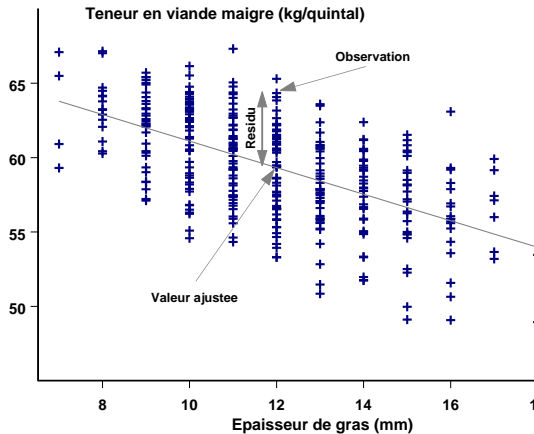
$$S_{xy} - \hat{\beta}_1 S_x^2 = 0$$

$$\hat{\beta}_1 = \frac{S_{xy}}{S_x^2}$$

# Valeurs ajustées et résidus d'ajustement

## ● Valeurs ajustées

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$$



# Valeurs ajustées et résidus d'ajustement


## ● Valeurs ajustées

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$$

## ● Résidus

$$\hat{\epsilon}_i = Y_i - \hat{Y}_i$$

$$\frac{1}{n} \sum_{i=1}^n \hat{\epsilon}_i = 0$$



# Valeurs ajustées et résidus d'ajustement

## ● Valeurs ajustées

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$$


## ● Résidus

$$\hat{\epsilon}_i = Y_i - \hat{Y}_i$$

$$\frac{1}{n} \sum_{i=1}^n \hat{\epsilon}_i = 0$$

## ● Décomposition

$$Y_i = \hat{Y}_i + \hat{\epsilon}_i$$



## Part de variabilité de $Y$ imputable à $x$

### Equation d'«analyse de la variance»

$$\underbrace{\sum_{i=1}^n (Y_i - \bar{Y})^2}_{\text{SCET}} = \underbrace{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}_{\text{SCEM}} + \underbrace{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}_{\text{SCER}}$$

## Part de variabilité de $Y$ imputable à $x$


### Equation d'«analyse de la variance»

$$\underbrace{\sum_{i=1}^n (Y_i - \bar{Y})^2}_{\text{SCET}} = \underbrace{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}_{\text{SCEM}} + \underbrace{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}_{\text{SCER}}$$

### Part de variabilité expliquée par le modèle

$$\begin{aligned} R^2 &= \frac{\text{SCEM}}{\text{SCET}} = 1 - \frac{\text{SCER}}{\text{SCET}} \\ &= [r(x, y)]^2 \end{aligned}$$

# Part de variabilité de Y imputable à x



# Test du lien entre $x$ et $Y$

## Equation d'«analyse de la variance»

$$\underbrace{\sum_{i=1}^n (Y_i - \bar{Y})^2}_{\text{SCET}} = \underbrace{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}_{\text{SCEM}} + \underbrace{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}_{\text{SCER}}$$

## Test du lien entre $x$ et $Y$

### Equation d'«analyse de la variance»

$$\underbrace{\sum_{i=1}^n (Y_i - \bar{Y})^2}_{\text{SCET}} = \underbrace{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}_{\text{SCEM}} + \underbrace{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}_{\text{SCER}}$$

### Sous l'hypothèse d'absence de lien

$$F = \frac{\frac{\text{SCEM}}{2-1}}{\frac{\text{SCER}}{n-2}} = \frac{\text{CMF}}{\text{CMR}} \sim \mathcal{F}_{1, n-2}$$

# Illustration

## Table d'analyse de la variance

	Degrés de liberté	SC	CM	F	Probabilité critique
Epaisseur de gras	1	1535.53	1535.53	181.04	0.00
Résiduelle	342	2900.69	8.48		

# Estimation des coefficients

- $\hat{\beta}_0, \hat{\beta}_1$  sont sans biais

# Estimation des coefficients

- $\hat{\beta}_0, \hat{\beta}_1$  sont sans biais
- **Variance d'estimation :**

$$\text{Var}(\hat{\beta}_1) = \frac{1}{n} \frac{\sigma^2}{S_x^2}$$

## Estimation des coefficients

- $\hat{\beta}_0, \hat{\beta}_1$  sont sans biais
- **Variance d'estimation :**

$$\text{Var}(\hat{\beta}_1) = \frac{1}{n} \frac{\sigma^2}{S_x^2}$$

- **Estimation de la variance d'estimation :**

$$\widehat{\text{Var}}(\hat{\beta}_1) = \frac{1}{n} \frac{\hat{\sigma}^2}{S_x^2}$$

# Estimation de $\sigma$

$\sigma^2$ , variance résiduelle

$$\hat{\sigma}^2 = \frac{1}{n-2} \underbrace{\sum_{i=1}^n [Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i]^2}_{\text{SCER}}$$

**Nombre de degrés de liberté de SCER**

$$\text{ddl}_r = n - 2$$




## Exemple

	Coefficients	Écart-type	Statistique t	Probabilité critique
Constante	70,03	0,81	86,75	6,02E-235
Variable X 1	-0,89	0,07	-13,46	2,05E-33

	Limite inférieure (seuil de confiance = 95%)	Limite supérieure
Constante	68,45	71,62
Variable X 1	-1,02	-0,76

**Écart-type résiduel : 2.91**



# Tous différents de 0 !

	Maths				Philosophie			
	1er t.	2ème t.	3ème t.	Bac	1er t.	2ème t.	3ème t.	Bac
$M_1$	1.00	0.77	0.72	0.58	0.19	0.22	0.16	0.24
$M_2$	0.77	1.00	0.81	0.66	0.20	0.25	0.22	0.30
$M_3$	0.72	0.81	1.00	0.68	0.22	0.26	0.24	0.30
$M_{\text{bac}}$	0.58	0.66	0.68	1.00	0.17	0.23	0.21	0.28
$P_1$	0.19	0.20	0.22	0.17	1.00	0.64	0.61	0.42
$P_2$	0.22	0.25	0.26	0.23	0.64	1.00	0.69	0.43
$P_3$	0.16	0.22	0.24	0.21	0.61	0.69	1.00	0.47
$P_{\text{bac}}$	0.24	0.30	0.30	0.28	0.42	0.43	0.47	1.00

# Problématique

**On connaît  $x_0$  mais pas  $Y_0$**

**Prédicteur**

$$\hat{Y}_0 = \hat{\beta}_0 + \hat{\beta}_1 x_0$$


**Erreur de prédiction**

$$\begin{aligned}\hat{\varepsilon}_0 &= Y_0 - \hat{Y}_0 \\ \mathbb{E}(\hat{\varepsilon}_0) &= 0\end{aligned}$$



## Variance de prédiction

Teneur en viande maigre (kg/quintal)



# Plan de la présentation

- 1 Introduction
- 2 Approche exploratoire
  - Graphiques
  - Coefficient de corrélation linéaire
- 3 Approche inférentielle
  - Le modèle de régression linéaire simple
  - Test du lien entre  $x$  et  $Y$
  - Estimation des paramètres
  - Prédiction
- 4 Ouverture

# Ouverture

- Extension à plusieurs variables explicatives (Module suivant)

# Ouverture

- Extension à plusieurs variables explicatives (Module suivant)
- Extensions non-linéaires (Microbiologie, Economie, ...)

# Ouverture

- Extension à plusieurs variables explicatives (Module suivant)
- Extensions non-linéaires (Microbiologie, Economie, ...)
- **Prise en compte de variables explicatives quantitatives et qualitatives (Analyse de la covariance)**