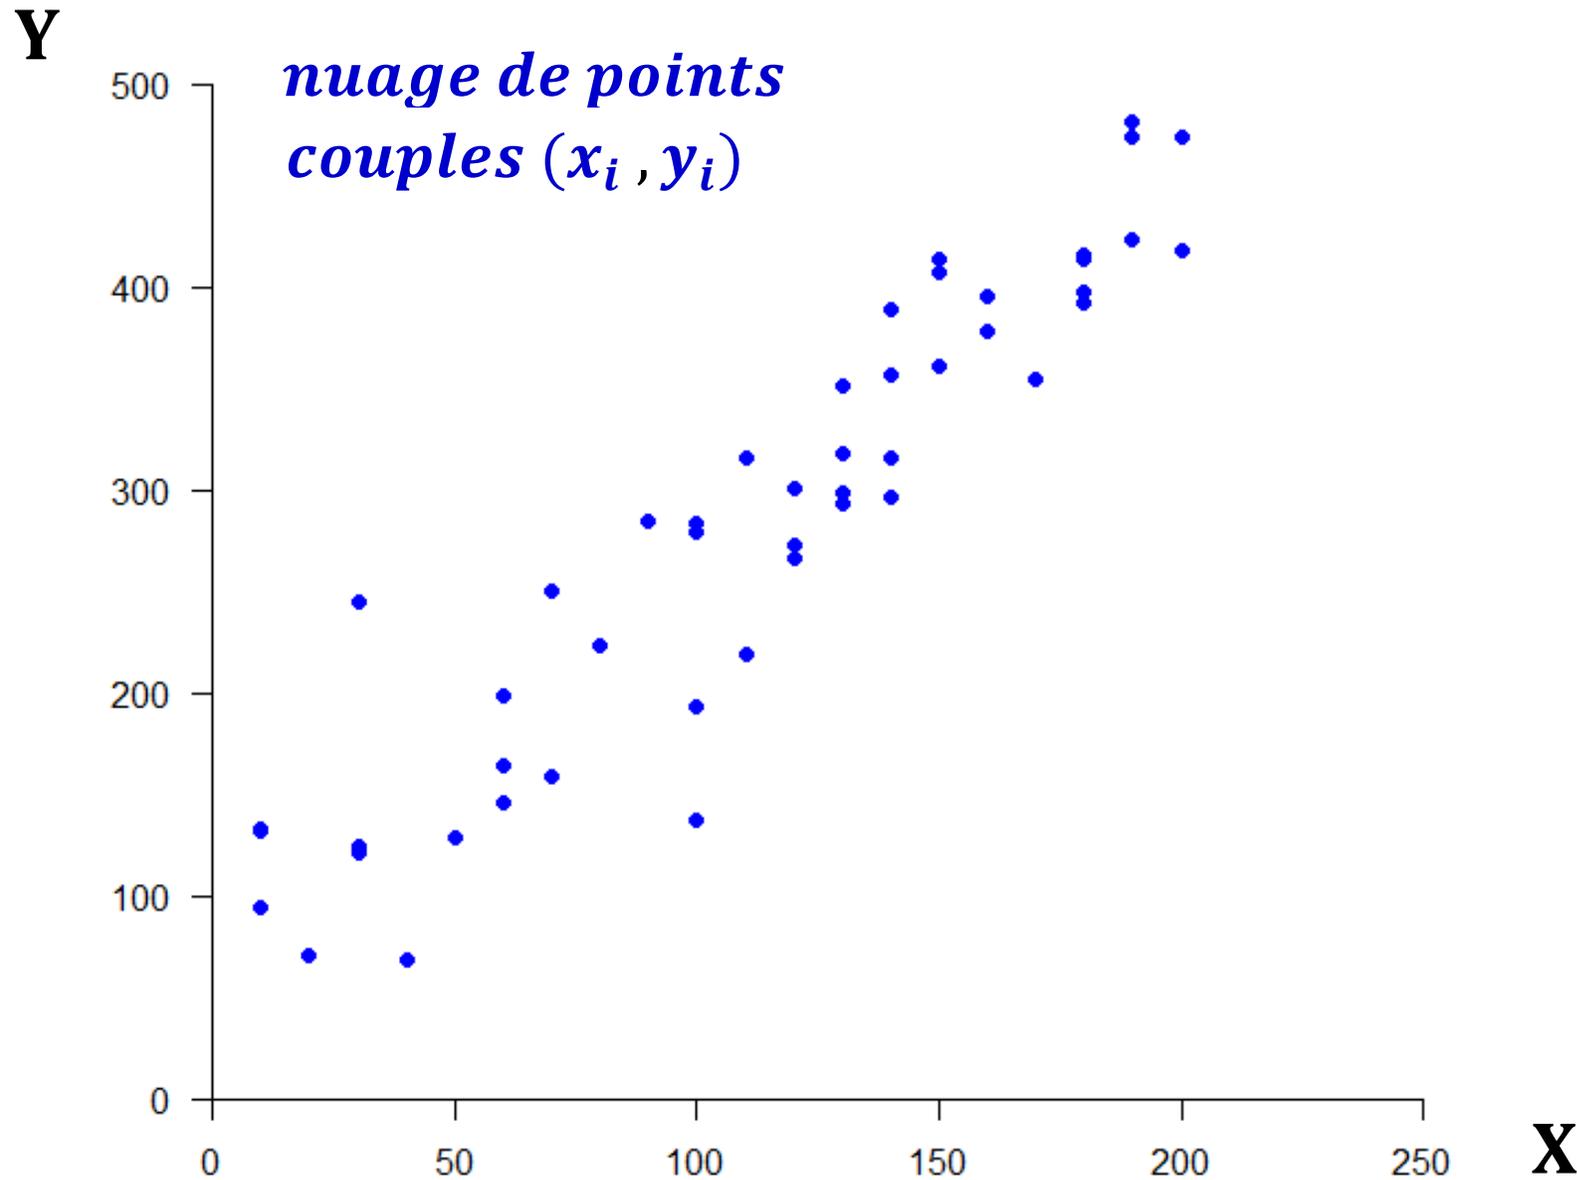
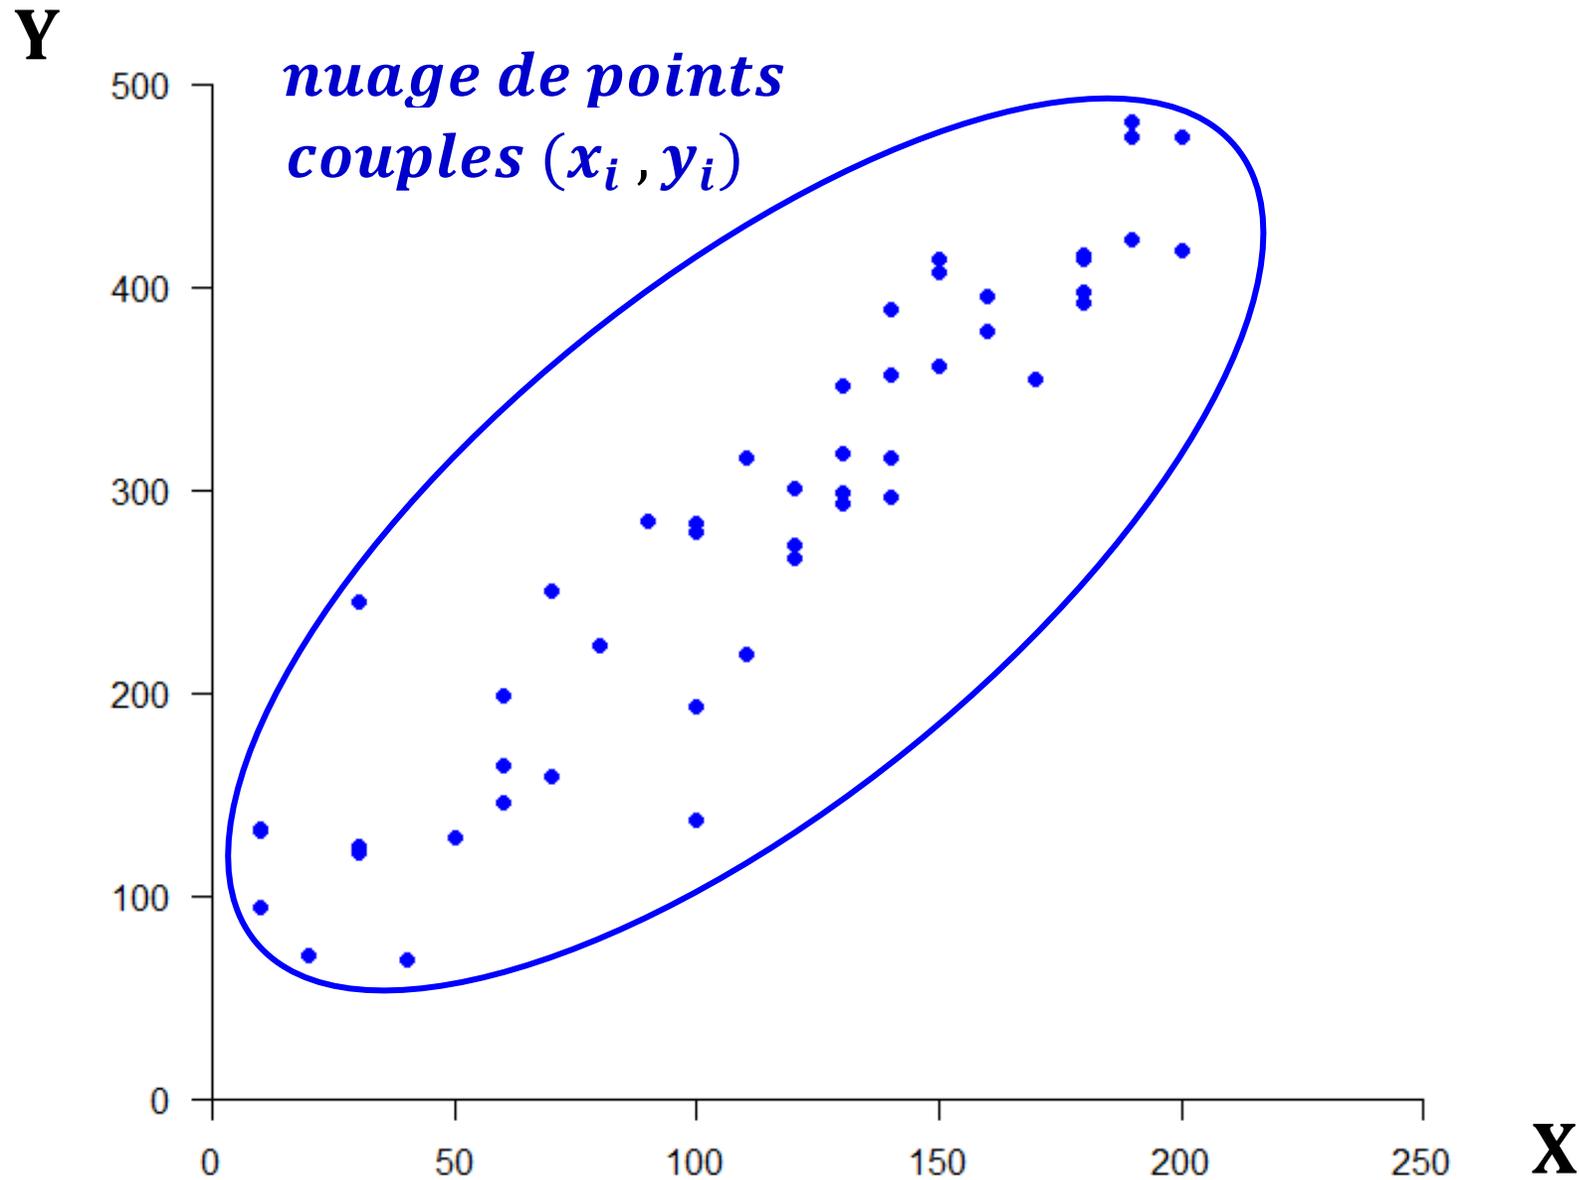


La Régression Linéaire : une brève présentation et pratique avec Rcmdr

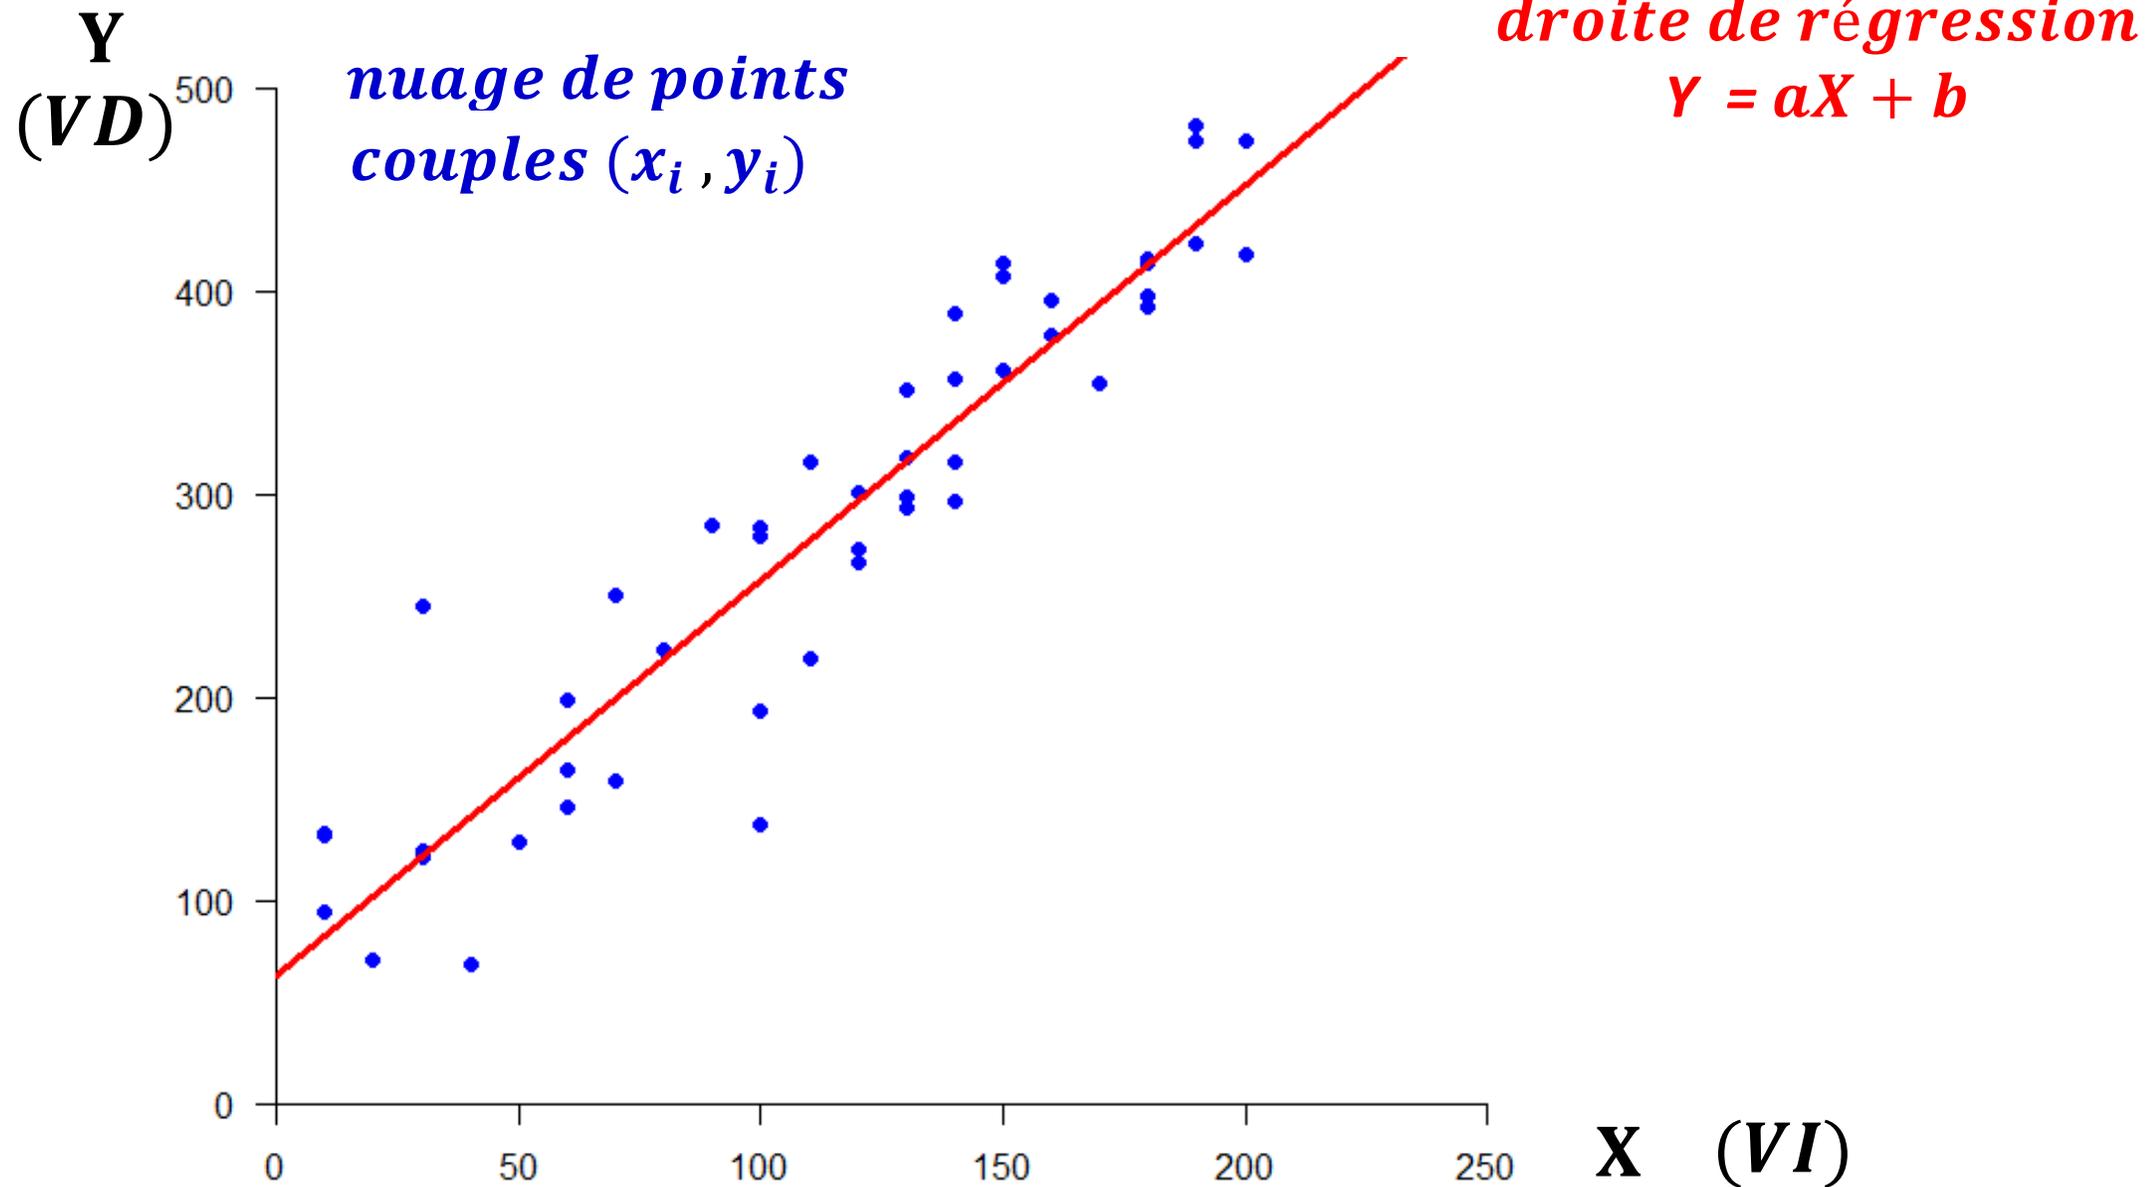
La Régression Linéaire : quelques repères



La Régression Linéaire : quelques repères

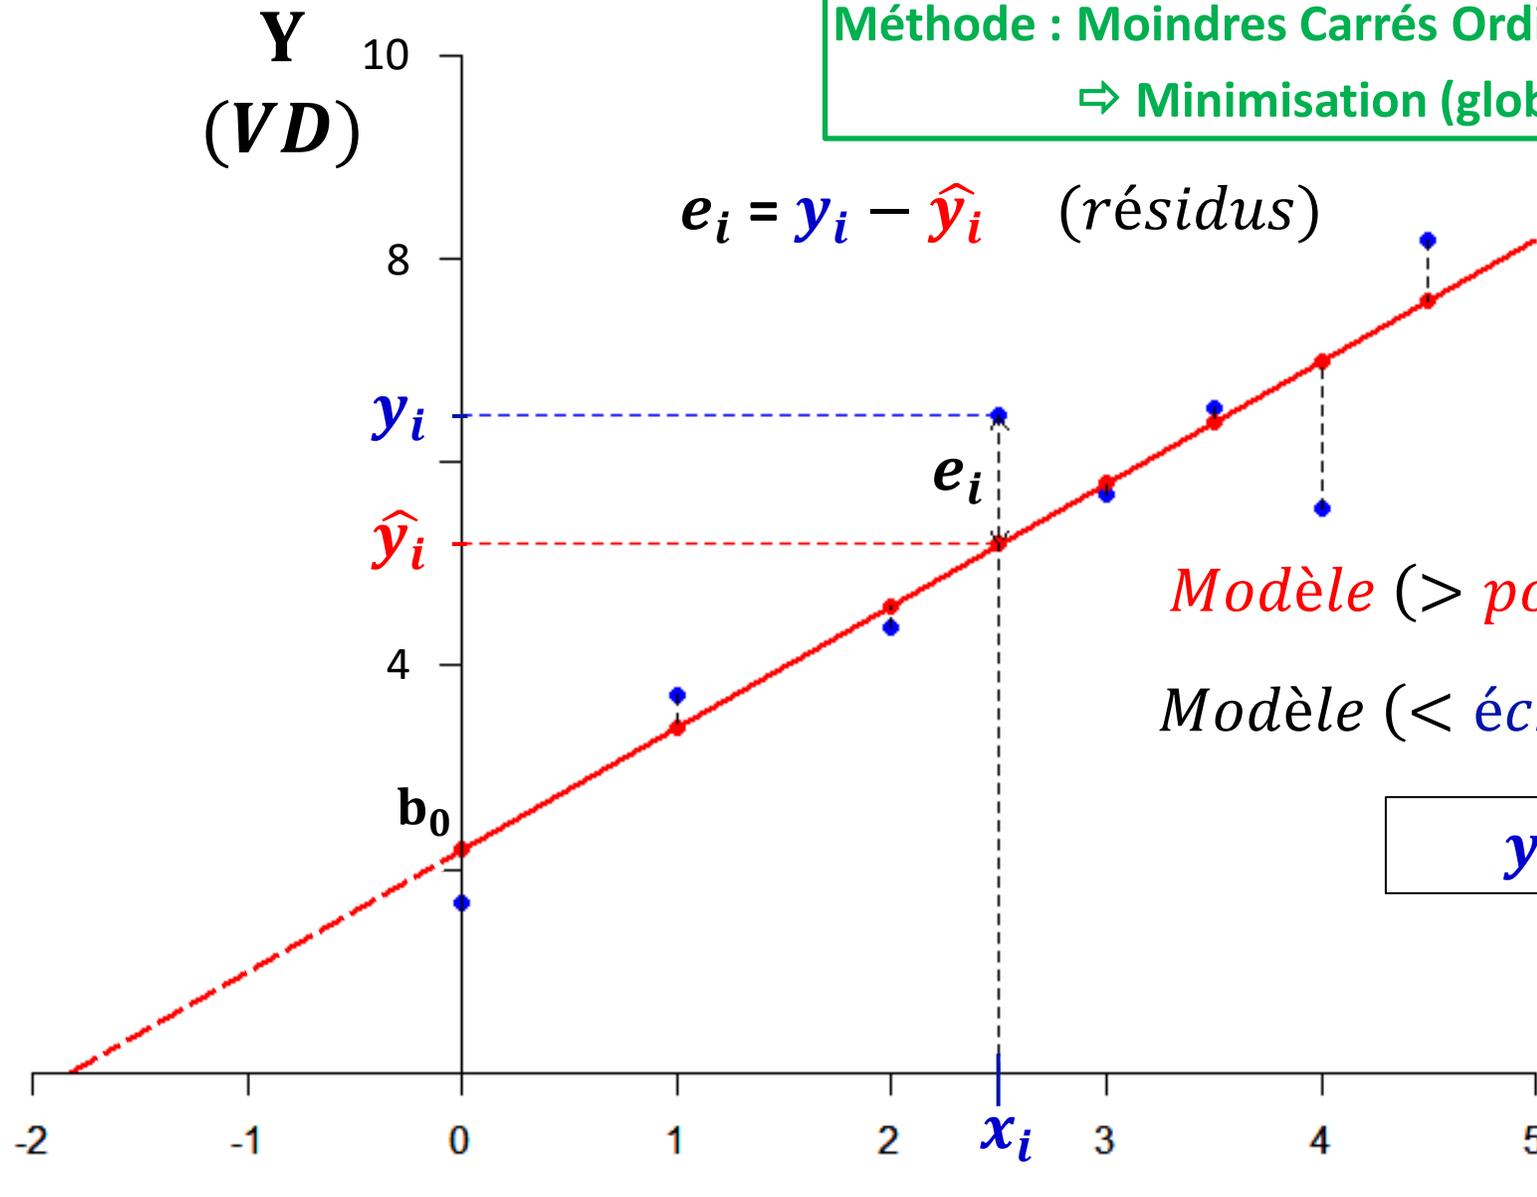


La Régression Linéaire : quelques repères



La Régression Linéaire : quelques repères

Méthode : Moindres Carrés Ordinaires MCO / OLS (> calcul matriciel)
⇒ Minimisation (globale) des erreurs/résidus



$$e_i = y_i - \hat{y}_i \quad (\text{résidus})$$

droite de régression

$$Y = b_0 + b_1 X$$

$$\hat{y}_i = b_0 + b_1 x_i$$

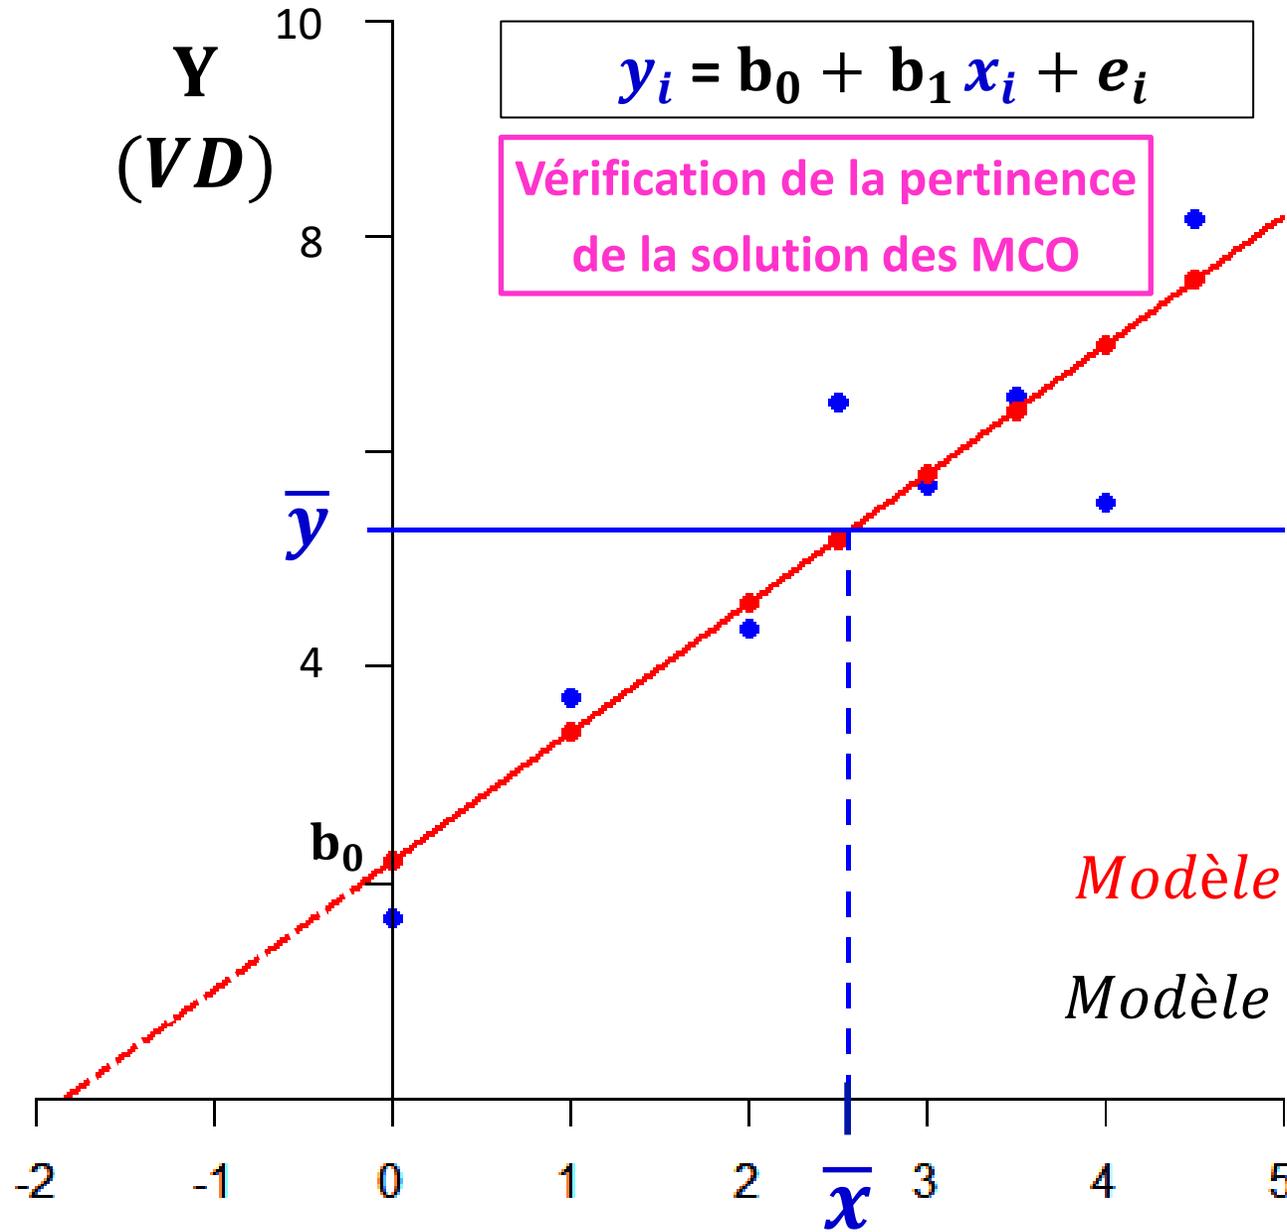
Modèle (> population) : $Y = \beta_0 + \beta_1 X + \varepsilon$

Modèle (< échantillon) : $Y = b_0 + b_1 X + E$

$$y_i = b_0 + b_1 x_i + e_i$$

$$b_0 = \widehat{\beta}_0 \quad ; \quad b_1 = \widehat{\beta}_1$$

La Régression Linéaire : quelques repères



$$y_i = b_0 + b_1 x_i + e_i$$

Vérification de la pertinence
de la solution des MCO

droite de régression

$$Y = b_0 + b_1 X$$

$$\hat{y}_i = b_0 + b_1 x_i$$

Tests sur les coefficients b :

(tests de Student)

$$H_0 : \beta_1 = 0 ; H_1 : \beta_1 \neq 0$$

$$H_0 : \beta_0 = 0 ; H_1 : \beta_0 \neq 0$$

Modèle ($>$ population) : $Y = \beta_0 + \beta_1 X + \varepsilon$

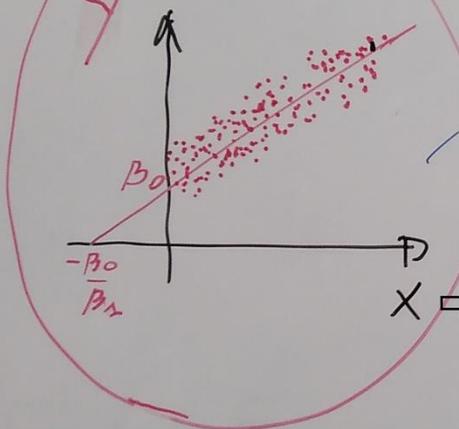
Modèle ($<$ échantillon) : $Y = b_0 + b_1 X + E$

$$b_0 = \hat{\beta}_0 ; b_1 = \hat{\beta}_1$$

Régression linéaire : quelques repères

Y : VA d'étude (normale)
 VRAI MODÈLE(??) ?

$Y \Rightarrow$ VD : mesures/observations
 (Variable Aléatoire)



population

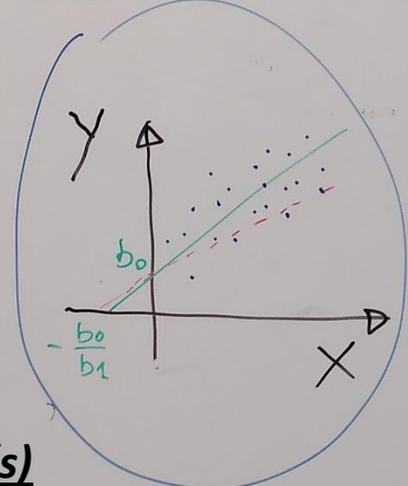
$$Y = \beta_0 + \beta_1 X$$

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

$(x_i, y_i, \varepsilon_i)$

Modèle (explicatif)
 régression population
 (ne sera jamais déterminable
 précisément)
 ← résidu population

Modèle obtenu (approche du modèle réel inconnu)
 Modèle déduit de nos observations (x_i, y_i)



échantillon
 (n)

$$Y = b_0 + b_1 \cdot X$$

$$y_i = b_0 + b_1 x_i + e_i$$

(x_i, y_i, e_i)

vrais coefficients
 (inconnus)

$$b_1 \pm t_{(n-2)} \cdot \frac{\hat{\sigma}_{\beta_1}}{\sqrt{n}}$$

$$\begin{cases} b_0 = \beta_0 \\ b_1 = \beta_1 \end{cases}$$

estimations
 ponctuelles de
 vrais coefficients
 (inconnus)

La Régression Linéaire : quelques repères

Introduction à l'analyse des erreurs

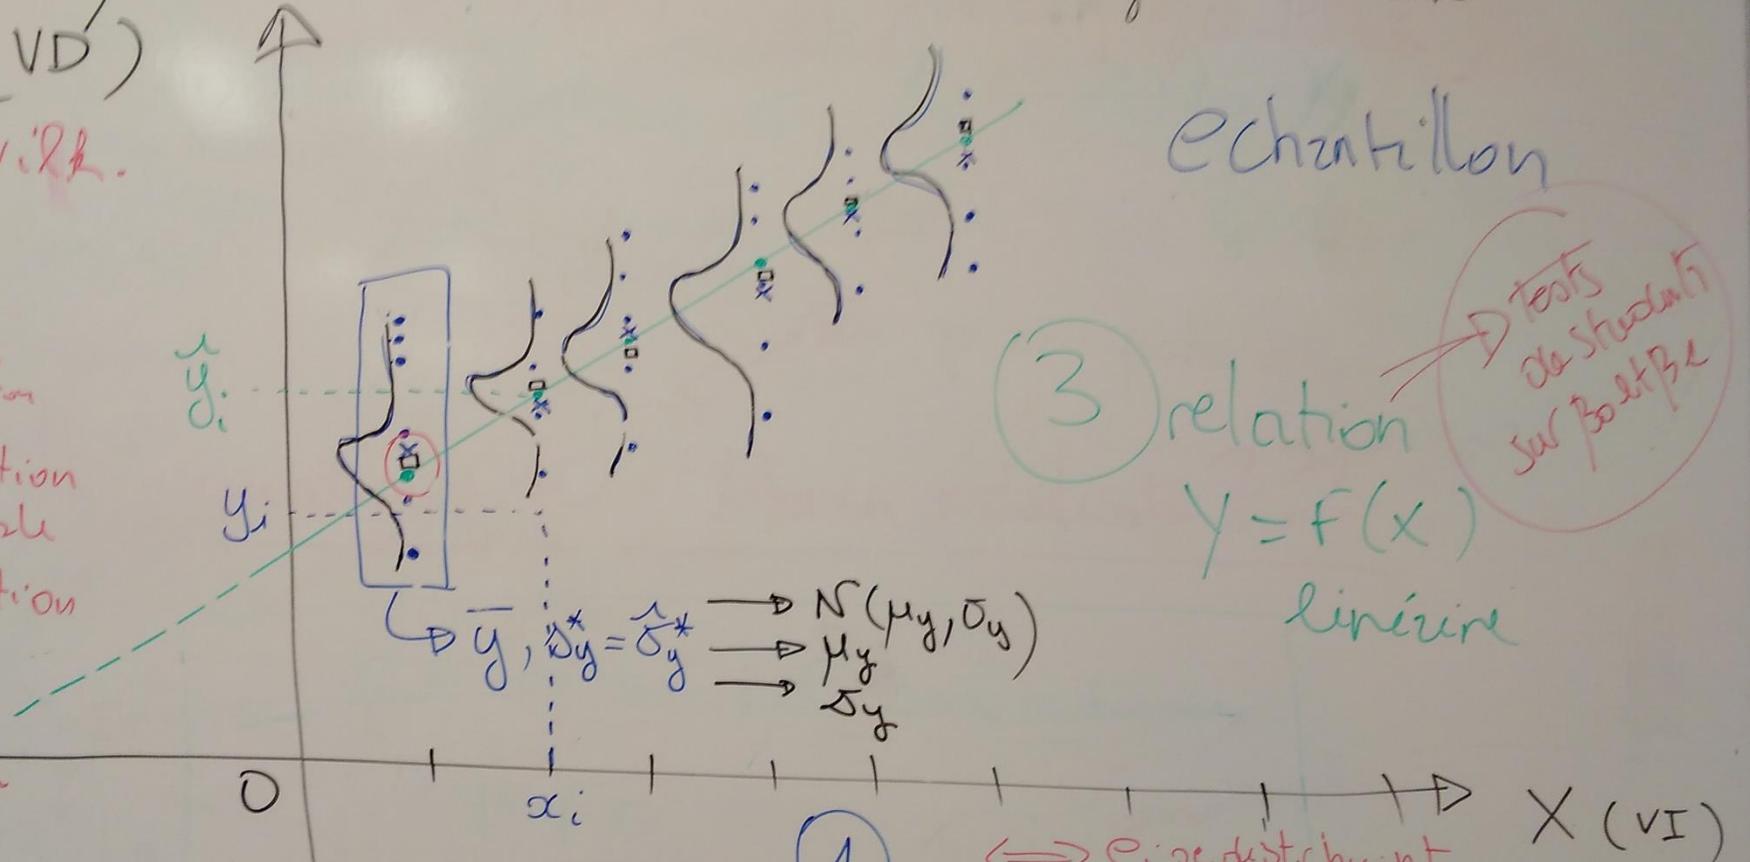
Shapiro (VD)
- Wilk.

H_0 : les données
sont issues
d'une population
pour laquelle
la distribution
est normale

H_1 : distribution
non
normale
de la
population.

• Kolmogorov-Smirnov
(KS)

• Lilliefors



3 relation
 $Y = F(x)$
linéaire

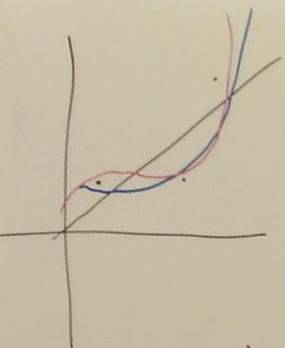
$N(\mu_y, \sigma_y)$
 μ_y
 σ_y

1 Contrainte

2 + homoscédasticité $\sigma_y^2 = c \cdot x^e$

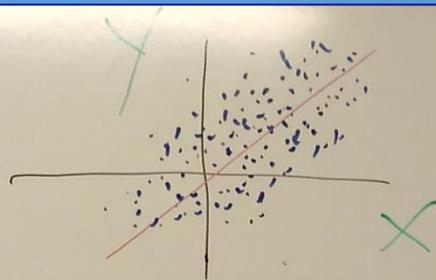
E_i se distribuent normalement (test + visuel)
VISUELLE

Régression linéaire : suite de l'analyse



?

nuage de point



$$\hat{\rho} = r \approx 0,3$$

pearson $R^2_{20,09}$

~~X explique-t-il Y~~

ou bien ~~Y explique-t-il X~~

MCO - méthode des Moindres Carrés Ordinaux (Maths)

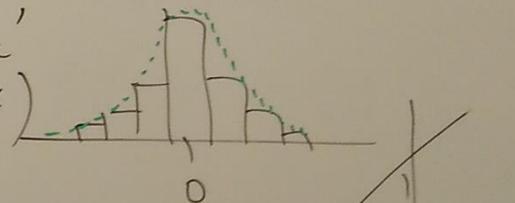
$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

droite réaliste??

(1) droite de régression $Y = b_0 + b_1 X$

(2) analyse de résidus e_i $y_i = b_0 + b_1 x_i + e_i$

+ test normalité (Shapiro-Wilk)



(3) β_1 significativement différent de 0?

$$t_0 = \frac{b_1 - 0}{\frac{\Delta_{b_1}^2}{n}}$$

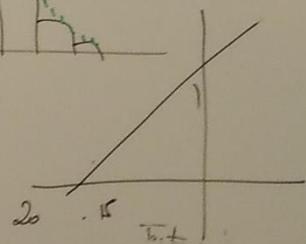
(4) R^2
part de la variance expliquée par le modèle

test de student sur le coefficient

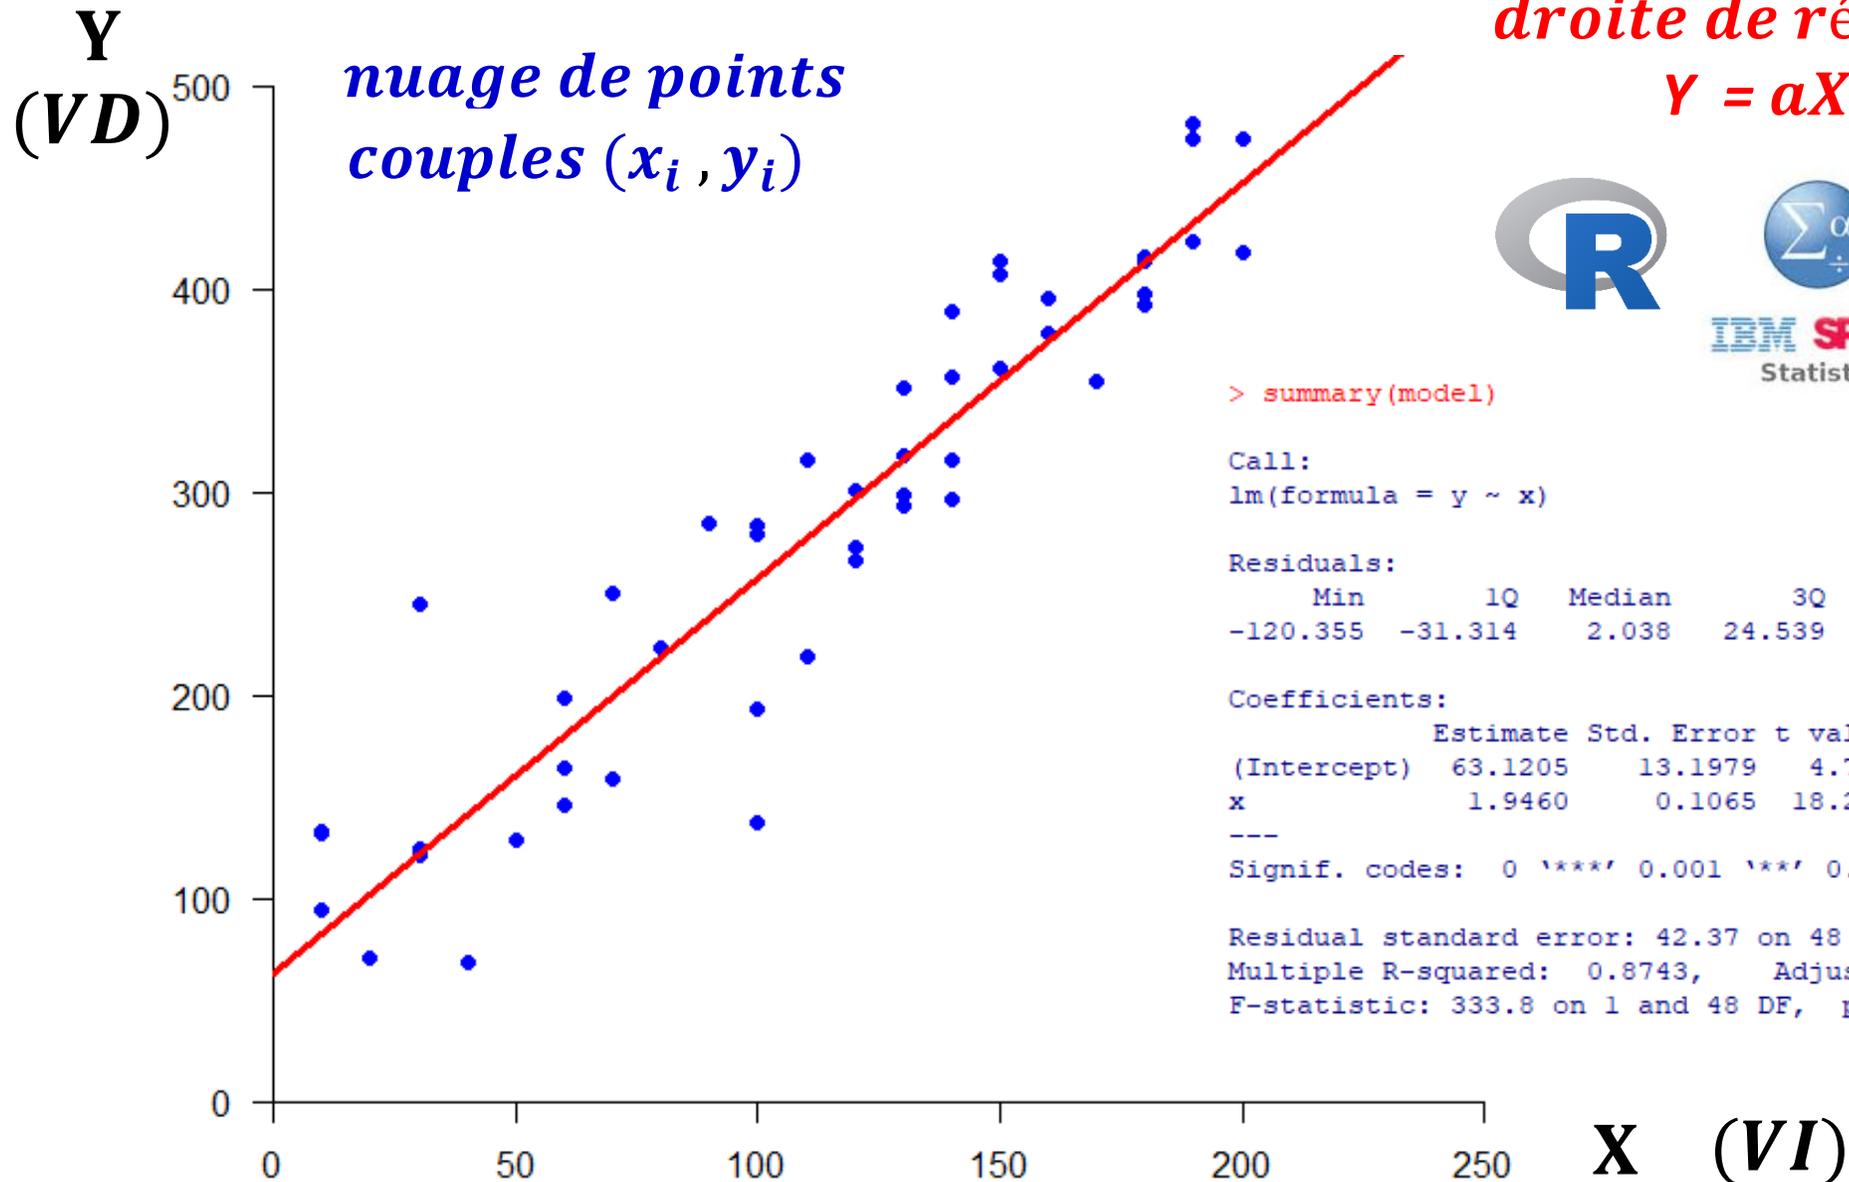
$$H_0 : \beta_1 = 0$$

$$H_1 : \beta_1 \neq 0$$

\iff test F sur la variance (Fisher)



La Régression Linéaire avec un logiciel



La Régression Linéaire : pratique avec Rcmdr

Données :

Éditer

Visualiser

Modèle : Script R

Empty script editor area.

Sortie

Soumettre

Empty output console area.

Messages

```
[2] AVIS: The Windows version of the R Commander works best under  
RGui with the single-document interface (SDI); see ?Commander.
```

R Commander

Fichier Édition **Données** Statistiques Graphes Modèles Distributions Outils Aide

Données Visualiser Modèle : Σ <Pas de modèle>

Script R R Markd

Nouveau jeu de données...
Charger un jeu de données...
Fusionner des jeux de données...
Importer des données
Données dans les paquets
Jeu de données actif
Gérer les variables du jeu de données actif

depuis un fichier texte, le presse-papier ou une URL...
depuis des données SPSS..
depuis un fichier SAS xport...
depuis un fichier SAS b7dat...
depuis des données Minitab...
depuis des données STATA...
depuis un fichier Excel...

R Lire des données depuis un fichier, le presse-papier ou une ...

Nom du tableau de données : biotope

Noms de variables dans le fichier :

Convertir les variables caractère en facteurs

Indicateur de données manquantes : NA

Emplacement du fichier de données

Système de fichiers local
 Presse-papier
 Lien internet (URL)

Séparateur de champs

Espaces Virgules [,]
 Semicolons [;] Tabulations
 Autre Spécifiez :

Séparateur décimal

Point [.]
 Virgule [,]

Aide OK Annuler

R Ouvrir

« Regression_Lineaire » regression_lineaire_avec_Rcmdr » Data_set

Rechercher dans : Data_set

Organiser Nouveau dossier

Nom	Modifié le	Type	Taille
mesures_biotope.csv	31/03/2022 11:14	Fichier CSV Micro...	6 Ko

Nom du fichier : mesures_biotope.csv

Tous les fichiers (*.*)

Ouvrir Annuler

Messages

```
[2] AVIS: The Windows version of the R  
RGui with the single-document interfac
```

	A	B	C	D	E	F
1	Y	X1	X2	X3	Equipe	
2	41,1	230,1	37,8	69,2	Equipe1	
3	29,4	44,5	39,3	45,1	Equipe3	
4	28,3	17,2	45,9	69,3	Equipe1	
5	37,5	151,5	41,3	58,5	Equipe3	
6	31,9	180,8	10,8	58,4	Equipe2	
7	26,2	8,7	48,9	75	Equipe2	
8	30,8	57,5	32,8	23,5	Equipe2	
9	32,2	120,2	19,6	11,6	Equipe1	
10	23,8	8,6	2,1	1	Equipe2	
11	29,6	199,8	2,6	21,2	Equipe3	
12	27,6	66,1	5,8	24,2	Equipe1	
13	36,4	214,7	24	4	Equipe3	
14	28,2	23,8	35,1	65,9	Equipe2	
15	28,7	97,5	7,6	7,2	Equipe1	
16	38	204,1	32,9	46	Equipe2	
17	41,4	195,4	47,7	52,9	Equipe2	
18	31,5	67,8	36,6	114	Equipe1	
19	43,4	281,4	39,6	55,8	Equipe3	
20	30,3	69,2	20,5	18,3	Equipe3	
21	33,6	147,3	23,9	19,1	Equipe3	
22	37	218,4	27,7	53,4	Equipe3	
23	31,5	237,4	5,1	23,5	Equipe3	
24	24,6	13,2	15,9	49,6	Equipe3	
25	34,5	228,3	16,9	26,2	Equipe2	
26	28,7	62,3	12,6	18,3	Equipe2	

```
Y;X1;X2;X3;Equipe
41,1;230,1;37,8;69,2;Equipe1
29,4;44,5;39,3;45,1;Equipe3
28,3;17,2;45,9;69,3;Equipe1
37,5;151,5;41,3;58,5;Equipe3
31,9;180,8;10,8;58,4;Equipe2
26,2;8,7;48,9;75;Equipe2
30,8;57,5;32,8;23,5;Equipe2
32,2;120,2;19,6;11,6;Equipe1
23,8;8,6;2,1;1;Equipe2
29,6;199,8;2,6;21,2;Equipe3
27,6;66,1;5,8;24,2;Equipe1
36,4;214,7;24;4;Equipe3
28,2;23,8;35,1;65,9;Equipe2
28,7;97,5;7,6;7,2;Equipe1
38;204,1;32,9;46;Equipe2
41,4;195,4;47,7;52,9;Equipe2
31,5;67,8;36,6;114;Equipe1
43,4;281,4;39,6;55,8;Equipe3
30,3;69,2;20,5;18,3;Equipe3
33,6;147,3;23,9;19,1;Equipe3
37;218,4;27,7;53,4;Equipe3
31,5;237,4;5,1;23,5;Equipe3
24,6;13,2;15,9;49,6;Equipe3
34,5;228,3;16,9;26,2;Equipe2
28,7;62,3;12,6;18,3;Equipe2
31;262,9;3,5;19,5;Equipe1
```

Données:

Éditer

Visualiser

Modèle: Script R

```
biotope <-  
  read.table("F:/UE-Bio-Data_sciences/Machine_learning/Regression_Lineaire/regression_lineaire_avec_Rcmdr/Data_set/mesures_biotope.csv",  
    header=TRUE, stringsAsFactors=TRUE, sep=";", na.strings="NA", dec=".",  
    strip.white=TRUE)
```

Sortie

Soumettre

```
> biotope <-  
+   read.table("F:/UE-Bio-Data_sciences/Machine_learning/Regression_Lineaire/regression_lineaire_avec_Rcmdr/Data_set/mesures_biotope.csv",  
+   header=TRUE, stringsAsFactors=TRUE, sep=";", na.strings="NA", dec=".",  
+   strip.white=TRUE)
```

Messages

```
RGui with the single-document interface (SDI); see ?Commander.  
[3] NOTE: Le jeu de données biotope a 200 lignes et 5 colonnes.
```

Données: **biotope**

Script R R Markdown

```
biotope <-  
  read.table("F:/UE-Bio  
  header=TRUE, strings  
  strip.white=TRUE)
```

Sortie

```
> biotope <-  
+ read.table("F:/UE-  
+ header=TRUE, stri  
+ strip.white=TRUE)
```

Messages

```
RGui with the single-document interface (SDI); see ?Commander.  
[3] NOTE: Le jeu de données biotope a 200 lignes et 5 colonnes.
```

Palette de couleurs...

Graphe indexé...

Graphe en points (dot plot)

Histogramme...

Graphe d'une variable numérique discrète...

Estimation de densité...

Graphe tiges et feuilles...

Boîte de dispersion...

Graphe quantile-quantile...

Boîte à moustaches pour symétrie...

Nuage de points...

Matrice de nuages de points...

Graphe en lignes...

Graphe XY conditionnel...

Graphe des moyennes...

Graphe en bande...

Graphe en barres...

Graphe en camembert...

Graphe 3D ▶

Enregistrer le graphe dans un fichier... ▶

Nuage de points

Données Options

variable x (une)

X1

X2

X3

Y

variable y (une)

X1

X2

X3

Y

Graphe par groupe...

Expression de sélection

<tous les cas valides>



Aide



Réinitialiser



OK



Annuler

R Commander

Fichier Édition Données Statis

Données : biotope

Script R R Markdown

```
biotope <-  
  read.table("F:/UB  
  header=TRUE, str  
  strip.white=TRUE)
```

Sortie

```
> biotope <-  
+ read.table("F:  
+ header=TRUE, s  
+ strip.white=TR
```

Messages

```
RGui with the sing  
[3] NOTE: Le jeu de
```

Nuage de points

Données Options

Options du graphe

- Décalages aléatoires x
- Décalages aléatoires y
- Axe X logarithmique
- Axe Y logarithmique
- Boîte à dispersion marginales
- Ligne des moindres carrés
- Courbe de lissage
- Afficher l'étendue

Fenêtre de lissage: 50

- Graphe d'ellipses de concentration

Niveaux de concentration: .5, .9

Identifier des points

- Automatiquement
- Avec la souris de manière interactive
- Ne pas identifier

Nombre de points à identifier: 2

Étiquettes et points du graphe

Libellé de l'axe X: <auto>

Libellé de l'axe Y: <auto>

Titre du graphe: <auto>

Caractères à utiliser: <auto>

Taille de point: 1.0

Taille du texte des axes: 1.0

Taille du texte des libellés d'axes: 1.0

Position de la légende

- Au dessus de graphe
- En haut à gauche
- En haut à droite
- En bas à gauche
- En bas à droite

Aide Réinitialiser OK Annuler Appliquer

Graphique

Appliquer

Nuage de points

Données Options

Options du graphe

- Décalages aléatoires x
- Décalages aléatoires y
- Axe X logarithmique
- Axe Y logarithmique
- Boite à dispersion marginales
- Ligne des moindres carrés
- Courbe de lissage
- Afficher l'étendue

Fenêtre de lissage

- Graphe d'ellipses de concentration

Niveaux de concentration :

Identifier des points

- Automatiser
- Avec la souris de manière interactive
- Ne pas identifier

Nombre de points à identifier :

Étiquettes et points du graphe

Libellé de l'axe X

Libellé de l'axe Y

Titre du graphe

Caractères à utiliser

Taille de point

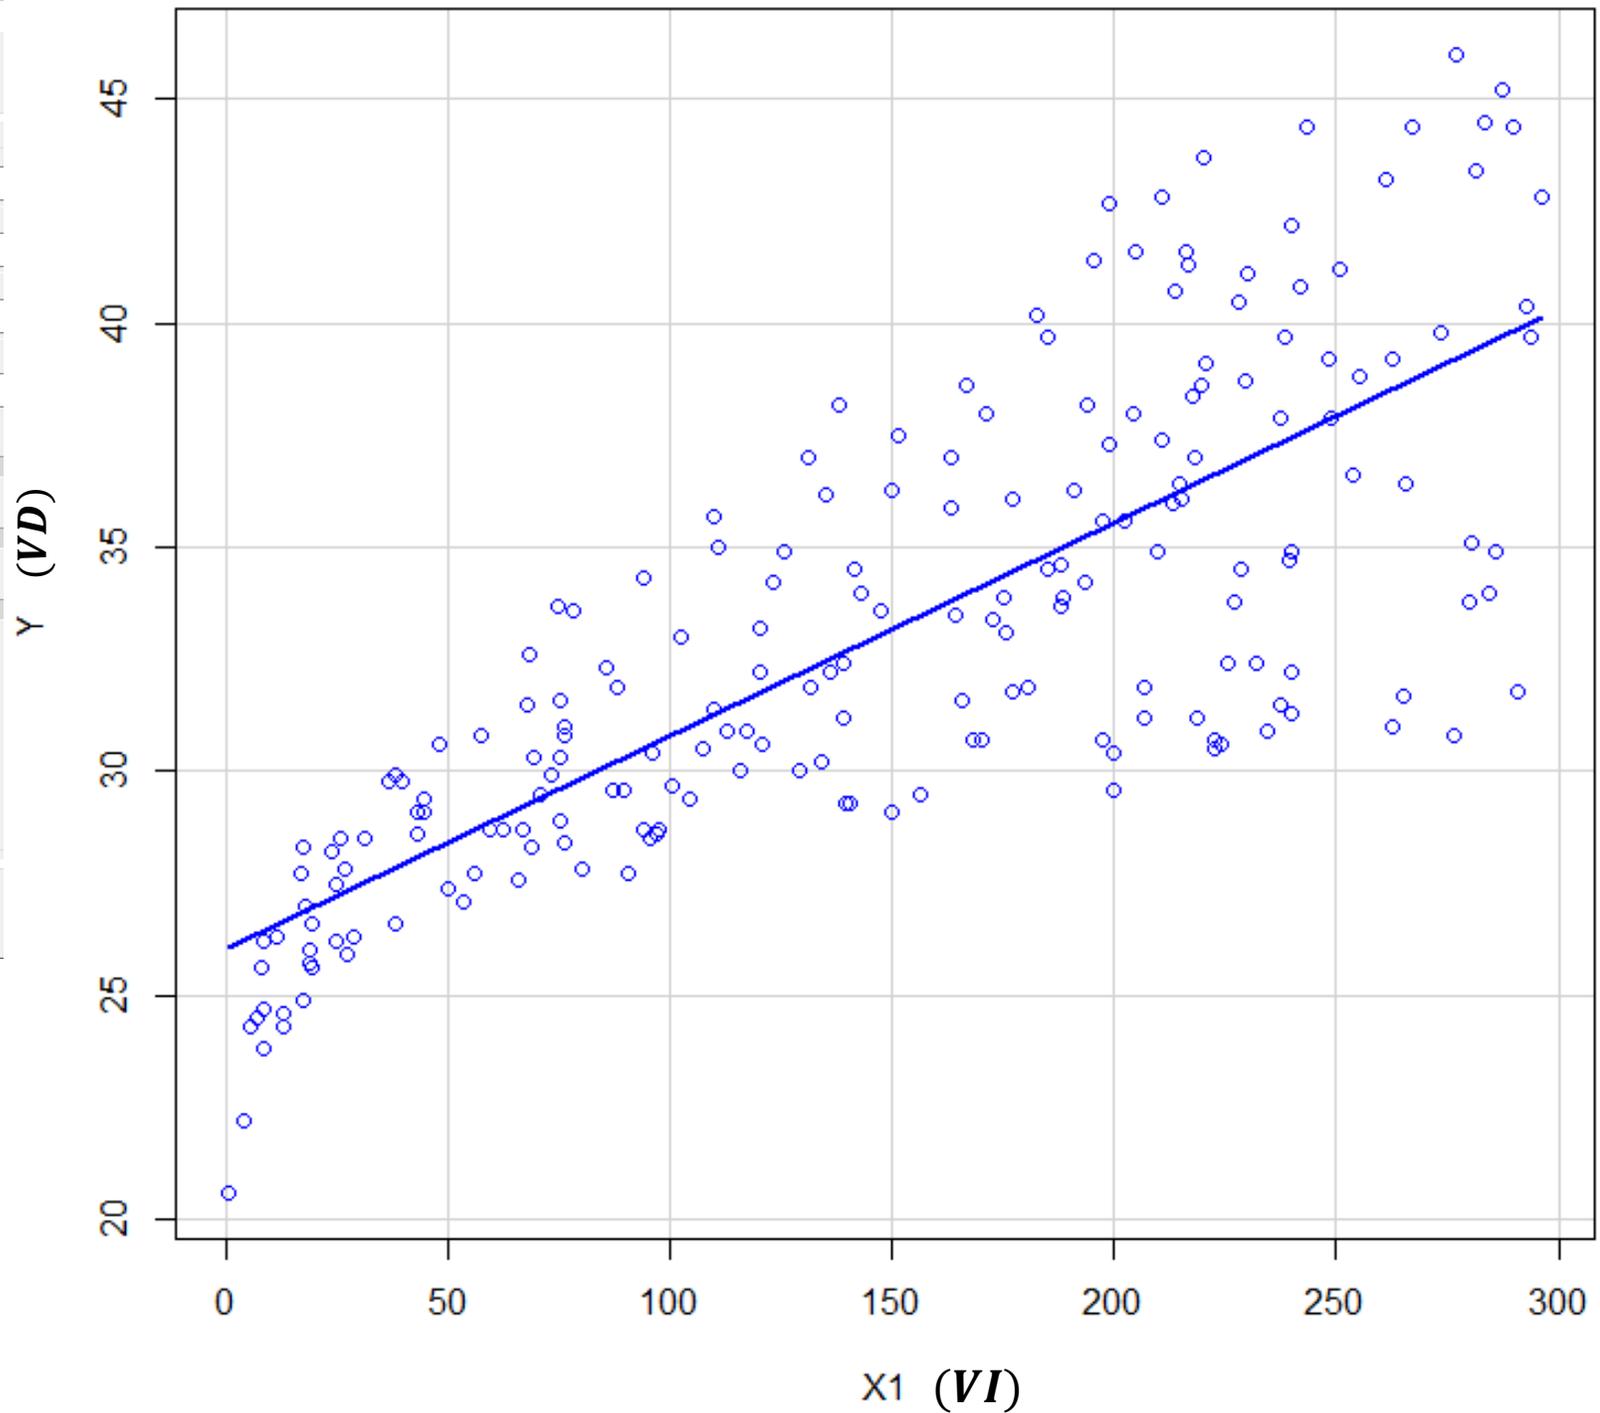
Taille du texte des axes

Taille du texte des libellés d'axes

Position de la légende

- Au dessus de graphe
- En haut à gauche
- En haut à droite
- En bas à gauche
- En bas à droite

Aide Réinitialiser OK Annuler



R Commander

Fichier Édition Données Statistiques Graphes Modèles Distributions Outils Aide

Données : [] Visualiser Modèle : Σ <Pas de modèle>

Script R R Markdown

- Résumés
- Tables de contingence
- Moyennes
- Proportions
- Variances
- Tests non paramétriques
- Analyse multivariée
- Ajustement de modèles
 - Régression linéaire...
 - Modèle linéaire...
 - Modèle linéaire généralisé...
 - Modèle Logit multinomial...
 - Modèle de régression ordinaire...
 - Modèle linéaire mixte...
 - Modèle linéaire généralisé mixte...

Sortie

Soumettre

Régression linéaire

Entrez un nom pour le modèle Reg_Y(X1)

Variable réponse (une)

- X1
- X2
- X3
- Y

Variables explicatives (une ou plus)

- X1
- X2
- X3
- Y

Expression de sélection

<tous les cas valides>

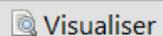

Aide Réinitialiser OK Annuler Appliquer

Messages

```
RGui with the single-document in  
[3] NOTE: Le jeu de données biot
```



Données : biotope

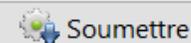


Modèle : RegModel.2

Script R R Markdown

```
RegModel.2 <- lm(Y~X1, data=biotope)
summary(RegModel.2)
```

Sortie



```
> summary(RegModel.2)

Call:
lm(formula = Y ~ X1, data = biotope)

Residuals:
    Min       1Q   Median       3Q      Max
-8.3860 -1.9545 -0.1913  2.0671  7.2124

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 26.032594   0.457843   56.86  <2e-16 ***
X1           0.047537   0.002691   17.67  <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 3.259 on 198 degrees of freedom
Multiple R-squared:  0.6119, Adjusted R-squared:  0.6099
F-statistic: 312.1 on 1 and 198 DF, p-value: < 2.2e-16
```

Messages

```
[3] NOTE: Le jeu de données biotope a 200 lignes et 5 colonnes.
[4] ERREUR: "Reg_Y(X1)" n'est pas un nom correct.
```

```
> summary(RegModel)
```

Call:

```
lm(formula = Y ~ X1, data = biotope)
```

Residuals:

Min	1Q	Median	3Q	Max
-8.3860	-1.9545	-0.1913	2.0671	7.2124

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	26.032594	0.457843	56.86	<2e-16 ***
X1	0.047537	0.002691	17.67	<2e-16 ***

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

Residual standard error: 3.259 on 198 degrees of freedom

Multiple R-squared: 0.6119, Adjusted R-squared: 0.6099

F-statistic: 312.1 on 1 and 198 DF, p-value: < 2.2e-16

Régression linéaire simple

Modèle (> population) : $Y = \beta_0 + \beta_1 X + \varepsilon$

$$Y = b_0 + b_1 X + E$$

Y : VD, VA quantitative continue (unités non précisées) > mesures biotope

X : Variable fixée quantitative continue (donc, à priori ce n'est pas une VA)

$$Y = 26,032594 + 0,0047537.X \quad \gggg \text{ Cette équation est-elle bien réaliste?}$$

$b_0 = 26,032594$ ordonnée à l'origine

$b_1 = 0,0047537$ pente de la droite de régression

Régression linéaire simple

$Y = 26,032594 + 0,0047537.X$ >>>> *Cette équation est-elle bien réaliste?*

Méthode des moindres carrés ordinaires (MCO, OLS in english)

*Les erreurs sont (globalement) minimisées :
méthode mathématique basée sur la dérivation (équation matricielle)
+ utilisation de la densité de probabilité de la Loi Normale*

*Permet d'obtenir (à la main, avec une machine à calculer, avec R, Python
ou tout autre logiciel) :*

$b_0 = 26,032594$ *ordonnée à l'origine*

$b_1 = 0,0047537$ *pente de la droite de régression*