

# Chapitre 4 Analyse statistique

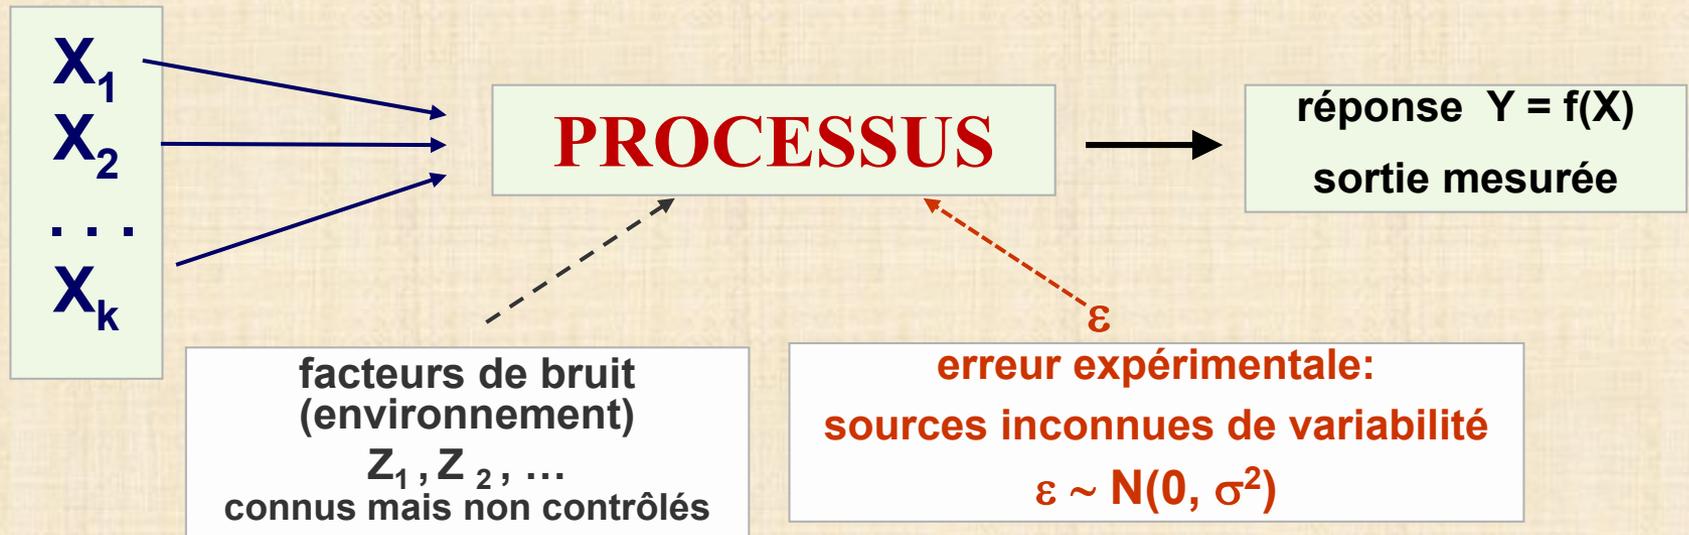
- **MODÈLES STATISTIQUES**
- **ANALYSE STATISTIQUE : étapes**
- **RÉGRESSION MULTIPLE**
  - ajustement du modèle
  - analyse de la variabilité - ANOVA
  - analyse des résidus
  - qualité d'un bon modèle
  - utilisation de *STATISTICA*
- **ANALYSE du PLAN 16 ESSAIS**
  - modèle avec 4 facteurs
  - modèle avec 5 facteurs
  - modèle avec 8 facteurs
  - étapes de l'analyse
  - calculs

# MODÉLISATION STATISTIQUE

Toute analyse statistique repose sur un **MODÈLE**

- fonction  $f$  pour représenter une relation entre input  $X$  et output  $Y$
- hypothèse distributionnelle pour le terme d'erreur  $\varepsilon$

$X_1, X_2, \dots, X_k$  : facteurs contrôlés (expérimentation)  
facteurs mesurés (mode passif)



$$Y = f(X_1, X_2, \dots, X_k; \beta_0, \beta_1, \beta_2, \dots) + \varepsilon$$

$f$  : fonction inconnue  $\rightarrow$  approximation polynôme  
 $\beta_0, \beta_1, \beta_2, \dots$  : paramètres statistiques inconnus

# MODÈLES : types

▪ **effets principaux ( ordre 1 ) :  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k$  (1)**

▪ **effets principaux et interaction :**

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \beta_{12} X_1 X_2 + \beta_{13} X_1 X_3 + \dots \quad (2)$$

▪ **quadratiques (facteurs quantitatifs) : ordre 2**

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \beta_{12} X_1 X_2 + \beta_{13} X_1 X_3 + \dots + \beta_{11} X_1^2 + \beta_{22} X_2^2 + \beta_{33} X_3^2 + \dots \quad (3)$$

▪ **d'analyse de la variance : variables catégoriques (4)**

**transformées en plusieurs variables indicatrices  $X = 0 / 1$**

**ou en plusieurs variables de type  $X = -1 / 0 / 1$  (codage à effet)**

▪ **mixtes : facteurs fixes + facteurs aléatoires (5)**

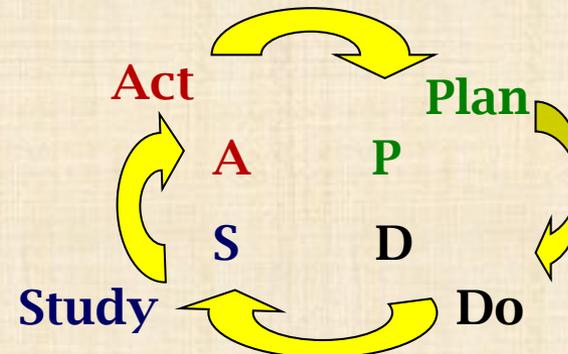
▪ **polynomial :  $Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \dots + \beta_k X^k$  peu utilisé**

# EXPÉRIMENTATION : étapes

PHASE	ÉTAPES
P: planifi - cation	1 Définir <b>PROCESSUS</b> / problématique / objectifs
	2 Choisir les variables de <b>RÉPONSE (S) Y</b> à mesurer
	3 Choisir les <b>VARIABLES</b> facteurs X et l'espace de variation
	4 Choisir et comparer des <b>PLANS EXPÉRIMENTAUX</b>
D: exécution	5 <b>PRÉPARER</b> pour l'expérience
	6 <b>CONDUIRE</b> l'expérience
S: analyse	7 <b>ANALYSE</b> statistique des résultats
A: transfert	8 <b>AGIR</b> avec les conclusions de l'analyse

analyse ? ch5

roue PDSA  
Shewhart - Deming



# **ANALYSE STATISTIQUE : processus (1/2)**

## **Étape 7**

**7.1 Spécification d'un modèle statistique**

**7.2 Estimation des paramètres du modèle**

**7.3 Décomposition de la variabilité : ANOVA**

**7.4 Tests d'hypothèses sur les paramètres**

**7.5 Analyse diagnostique des résidus**

- vérification des hypothèses de base
- identification d'observations influentes
- transformation Box-Cox de réponse Y

**7.6 Si nécessaire : itération des étapes 1 à 5**

**7.7 Optimisation de la réponse (s'il y a lieu)**

**7.8 Graphiques de la réponse**

# ANALYSE STATISTIQUE : processus (2/2)

1. Préparation de la matrice de tests pour la collecte des données

2. Spécification modèle pour l'analyse

**MATRICE MODÈLE = MATRICE DESIGN + COLONNES ADDITIONNELLES**  
**(augmentée) = (effets principaux) + (effets d'interaction)**

3. Optionnel : examen de la variable de réponse avec des cartes de Shewhart (si on a des répétitions)

4. Ajustement du modèle : estimation des paramètres statistiques  
 $\beta_0, \beta_1, \dots$

5. Calcul du tableau d'analyse de la variance : ANOVA

6. Tests d'hypothèses des paramètres (effets) :  $\beta_1, \beta_2, \dots$

7. Analyse diagnostique des résidus

8. Optionnel : Itération des étapes 4-5-6-7 - modèle avec effets importants seulement

9. Présentation graphiques des résultats

- diagramme Pareto

- diagrammes interactions

- diagrammes effets principaux

- courbes contour

# RÉGRESSION LINÉAIRE MULTIPLE (1 / 17)

**MODÈLE**  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_m X_m + \varepsilon$   $\varepsilon \sim N(0, \sigma^2)$

**DONNÉES**

	#	$X_0$	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	.....	X <sub>m</sub>	Y
$X_{i0} = 1$ effet général	1	1	x <sub>11</sub>	x <sub>12</sub>	x <sub>13</sub>	.....	x <sub>1m</sub>	y <sub>1</sub>
	2	1	x <sub>21</sub>	x <sub>22</sub>	x <sub>23</sub>	.....	x <sub>2m</sub>	y <sub>2</sub>
matrice des effets	.	.	.	.	.	.....	.	.
colonnes types	i	1	x <sub>i1</sub>	x <sub>i2</sub>	x <sub>i3</sub>	.....	x <sub>im</sub>	y <sub>i</sub>
$X_j, X_j X_k, X_j^2$	.	.	.	.	.	.....	.	.
	N	1	x <sub>N1</sub>	x <sub>N2</sub>	x <sub>N3</sub>	....	x <sub>Nm</sub>	y <sub>N</sub>

↑

écriture matricielle  $X_{N \times p} = [x_{ij}] \xrightarrow{p=1+m}$   $Y_{N \times 1}$  : vecteur N x 1  
 $\beta_{p \times 1} = (\beta_0, \beta_1, \beta_2, \beta_3, \dots, \beta_k)'$  : vecteur p x 1

remarque : l'opération de transposition de vecteurs / matrices est notée par le symbole ' '

**ESTIMATION** (principe de moindres carrés) :  $\text{Min}_{\beta} \sum_i (y_i - \sum_j \beta_j x_{ij})^2$

système d'équations linéaire à résoudre :  $(X' X) \beta = X' Y$

solution :  $\hat{\beta} = (X' X)^{-1} X' Y = C Y$

$C = (X' X)^{-1} X'$  est une matrice p x N de valeurs fixes connues

**ÉQUATION de PRÉDICTION**  $\hat{y} = X \hat{\beta}$

## PROPRIÉTÉS ESTIMATEURS $\hat{\beta}$

- combinaisons linéaires des  $y_i$
- sans biais :  $E(\hat{\beta}_j) = \beta_j$  pas d'erreur systématique
- $\text{var}(\hat{\beta}) = (X'X)^{-1} \sigma^2$  variance minimale (« meilleurs »)

## ESTIMATION de $\sigma^2$

résidu :  $e_i = \hat{y}_i - y_i$

somme de carrés résiduels :  $SSR = \sum e_i^2$

carré résiduel moyen :  $MSR = SSR / N - m - 1$

estimation :  $\hat{\sigma}^2 = MSR$   $\hat{\sigma} = (MSR)^{0.5}$

## DÉCOMPOSITION DE LA VARIABILITÉ : tableau d'analyse de la variance

$SSY = \sum (y_i - \bar{y})^2$  : somme **TOTALE** des carrés

$SSM = \sum (\hat{y}_i - \bar{y})^2$  : somme des carrés du **MODÈLE** (régression)

$SSR = \sum (\hat{y}_i - y_i)^2$  : somme des carrés **RÉSIDUELS**

## ÉQUATION FONDAMENTALE

somme de carrés (SS) :  $SSY = SSM + SSR$

variabilité : totale = modèle + résiduelle

degrés de liberté (df) :  $N - 1 = m + (N - m - 1)$

# RÉGRESSION LINÉAIRE MULTIPLE (3 / 17)

**TABLEAU D'ANALYSE VARIANCE : modèle de régression linéaire multiple**

SOURCE	df	SS	MS=SS / df	F-ratio	p-valeur
régression	m	SSM	MSM = SSM / m	$f = \text{MSM} / \text{MSR}$	$P(F \geq f)$
résiduelle	$N - m - 1$	SSR	$\text{MSR} = \text{SSR} / (N - m - 1) = \hat{\sigma}^2$	-----	-----
totale	$N - 1$	SSY	-----	-----	-----

$R^2 = \text{SSM} / \text{SSY}$  : **coefficient de détermination**

$0 \leq R^2 \leq 1$  : fraction de la **variabilité de Y** expliquée par les variables X

$R^2_{\text{adj}} = 1 - [(N - 1) / (N - m)](1 - R^2)$  : **coefficient de détermination ajusté**

**remarques**

- ajouter une variable explicative additionnelle dans un modèle augmente SSM et  $R^2$
- l'augmentation de  $R^2$  n'est pas toujours importante et significative
- $R^2_{\text{adj}}$  est préférable à  $R^2$  pour comparer deux modèles

**Test global**

$H_{0G} : \beta_1 = \beta_2 = \dots = \beta_m = 0$

vs  $H_{1G} : \text{non } H_{0G}$  (au moins un  $\beta \neq 0$ )

rejeter  $H_0$  au seuil  $\alpha$  si  $f > F_{m, N-m-1, 1-\alpha}$

Distribution d'échantillonnage de  $\hat{\beta}_j$   $j = 0, 1, 2, \dots, k$

$$[(\hat{\beta}_j - \beta_j) / \hat{\sigma} (c_{jj})^{0.5}] \sim t_{N-m-1} \quad c_{jj} : j\text{-ème élément diagonal de } (X'X)^{-1}$$

## Applications

(a) test  $H_{0j} : \beta_j = 0$  vs  $H_{1j} : \beta_j \neq 0$   $j = 1, 2, \dots, m$

rejeter  $H_{0j}$  au seuil  $\alpha$  si  $|\hat{\beta}_j| / \hat{\sigma} (c_{jj})^{0.5} > t_{N-m-1, 1-\alpha/2}$

(b) Intervalle de confiance  $\beta_j : \hat{\beta}_j \pm t_{N-m-1, 1-\alpha/2} \hat{\sigma} (c_{jj})^{0.5}$

(c) INTERVALLE de CONFIANCE MOYENNE de Y à  $X_1 = x_1^*, X_2 = x_2^*, \dots, X_k = x_k^*$

$$\hat{y}^* = \hat{\beta}_0 + \hat{\beta}_1 x_1^* + \dots + \hat{\beta}_k x_k^* \quad x^* = (x_1^*, x_2^*, \dots, x_k^*)$$

$$E(Y | X = x^*) : \hat{y}^* \pm t_{N-m-1, 1-\alpha/2} \hat{\sigma} [x^* (X'X)^{-1} x^{*'}]^{0.5}$$

(d) INTERVALLE de PRÉDICTION VALEUR de Y à  $X_1 = x_1^*, X_2 = x_2^*, \dots, X_k = x_k^*$

$$Y | X = x^* : \hat{y}^* \pm t_{N-m-1, 1-\alpha/2} \hat{\sigma} [1 + x^* (X'X)^{-1} x^{*'}]^{0.5}$$

# RÉGRESSION LINÉAIRE MULTIPLE (5 / 17)

**régression avec STATISTICA**

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
	Num	X1																
1	1	38.4																
2	2	40.3																
3	3	40.0																
4	4	31.8																
5	5	40.8																
6	6	41.3																
7	7	38.1																
8	8	50.8																
9	9	32.2																
10	10	38.4																
11	11	40.3																
12	12	32.2																
13	13	31.8																
14	14	41.3																
15	15	38.1																
16	16	50.8																
17	17	32.2	5.2	236	360	24.8												
18	18	38.4	6.1	220	365	26.0												
19	19	40.3	4.8	231	395	34.9												
20	20	40.0	6.1	217	272	18.2												
21	21	32.2	2.4	284	424	23.2												
22	22	31.4	0.2	316	428	18.0												
23	23	40.8	3.5	210	273	13.1												
24	24	41.3	1.8	267	358	16.1												
25	25	38.1	1.2	274	444	32.1												
26	26	50.8	8.6	190	345	34.7												
27	27	32.2	5.2	236	402	31.7												
28	28	38.4	6.1	220	410	33.6												
29	29	40.0	6.1	217	340	30.4												
30	30	40.8	3.5	210	347	26.6												

fenêtre de spécification

**autre module: GRM**  
**General Regression Models**  
**variables continues et**  
**variables catégoriques**

Type of analysis:

- Simple regression
- Multiple regression
- Factorial regression
- Polynomial regression
- Response surface regression
- Mixture surface regression
- One-way ANOVA
- Main effects ANOVA
- Factorial ANOVA
- Analysis of covariance
- Homogeneity-of-slopes model
- General linear models

Specification method:

- Quick specs dialog
- Analysis Wizard
- Analysis syntax editor

Use General linear models to analyze designs with any combination of categorical independent variables (factors), continuous predictor variables (covariates), or repeated measures.

Multiple dependent variables can be specified for any type of analysis.

## RÉGRESSION LINÉAIRE MULTIPLE (6 / 17)

**Exemple:** production de gazoline avec huiles brutes (données historiques)

N. H. Prater, *Petroleum Refiner - Experimental Designs in Industry* (ed. Chew) Wiley 1956 pp 109-137

**Y :** rendement production gazoline (% de l'huile brute)

**X1 :** gravité huile brute (deg. API)      **X2 :** pression vapeur (PSIA)

**X3 :** ASTM point 10% (deg. F)      **X4 :** point sortie gazoline (deg. F)

#	X1	X2	X3	X4	Y
1	38.4	6.1	220	235	6.9
2	40.3	4.8	231	307	14.4
3	40.0	6.1	217	212	7.4
4	31.8	0.2	316	365	8.5
5	40.8	3.5	210	218	8.0
6	41.3	1.8	267	235	2.8
7	38.1	1.2	274	285	5.0
8	50.8	8.6	190	205	12.2
9	32.2	5.2	236	267	10.0
10	38.4	6.1	220	300	15.2
11	40.3	4.8	231	367	26.8
12	32.2	2.4	284	351	14.0
13	31.8	0.2	316	379	14.7
14	41.3	1.8	267	275	6.4
15	38.1	1.2	274	365	17.6
16	50.8	8.6	190	275	22.3

17	32.2	5.2	236	360	24.8
18	38.4	6.1	220	365	26.0
19	40.3	4.8	231	395	34.9
20	40.0	6.1	217	272	18.2
21	32.2	2.4	284	424	23.2
22	31.4	0.2	316	428	18.0
23	40.8	3.5	210	273	13.1
24	41.3	1.8	267	358	16.1
25	38.1	1.2	274	444	32.1
26	50.8	8.6	190	345	34.7
27	32.2	5.2	236	402	31.7
28	38.4	6.1	220	410	33.6
29	40.0	6.1	217	340	30.4
30	40.8	3.5	210	347	26.6
31	41.3	1.8	267	416	27.8
32	50.8	8.6	190	407	45.7

**Y a t-il une  
structure  
dans ces  
données?**

**réponse:  
oui**

# RÉGRESSION LINÉAIRE MULTIPLE (7 / 17)

#	X1	X2	X3	groupe	X4	Y
8	50,8	8,6	190	1	205	12,2
16	50,8	8,6	190	1	275	22,3
26	50,8	8,6	190	1	345	34,7
32	50,8	8,6	190	1	407	45,7
6	41,3	1,8	267	2	235	2,8
14	41,3	1,8	267	2	275	6,4
24	41,3	1,8	267	2	358	16,1
31	41,3	1,8	267	2	416	27,8
5	40,8	3,5	210	3	218	8,0
23	40,8	3,5	210	3	273	13,1
30	40,8	3,5	210	3	347	26,6
2	40,3	4,8	231	4	307	14,4
11	40,3	4,8	231	4	367	26,8
19	40,3	4,8	231	4	395	34,9
3	40,0	6,1	217	5	212	7,4
20	40,0	6,1	217	5	272	18,2
29	40,0	6,1	217	5	340	30,4
1	38,4	6,1	220	6	235	6,9
10	38,4	6,1	220	6	300	15,2
18	38,4	6,1	220	6	365	26,0
28	38,4	6,1	220	6	410	33,6
7	38,1	1,2	274	7	285	5,0
15	38,1	1,2	274	7	365	17,6
25	38,1	1,2	274	7	444	32,1
9	32,2	5,2	236	8	267	10,0
17	32,2	5,2	236	8	360	24,8
27	32,2	5,2	236	8	402	31,7
12	32,2	2,4	284	9	351	14,0
21	32,2	2,4	284	9	424	23,2
4	31,8	0,2	316	10	365	8,5
13	31,8	0,2	316	10	379	14,7
22	31,4	0,2	316	10	428	18,0

données en structure emboîtée

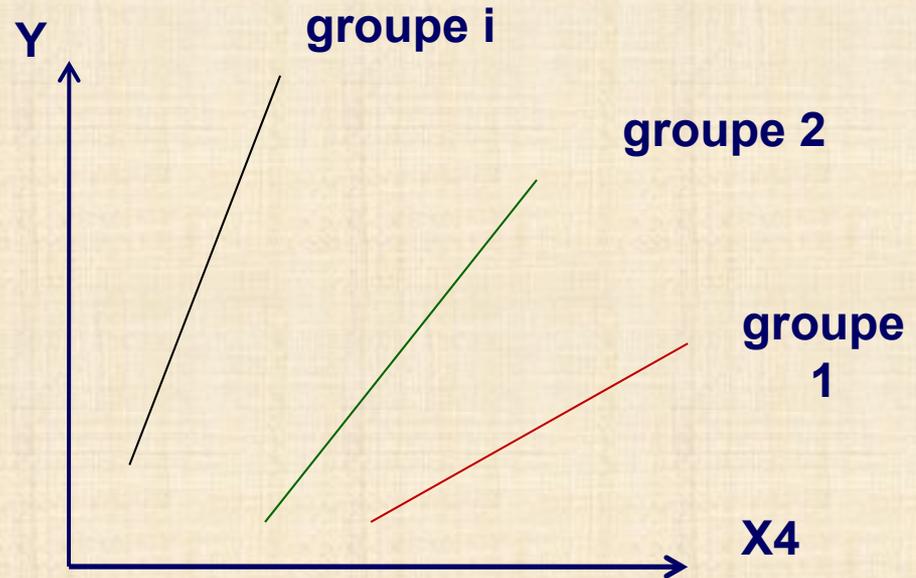
10 groupes d'huile brute définis par X1 X2 X3

régression de Y sur X4

1 modèle pour chaque groupe

analyse de covariance =

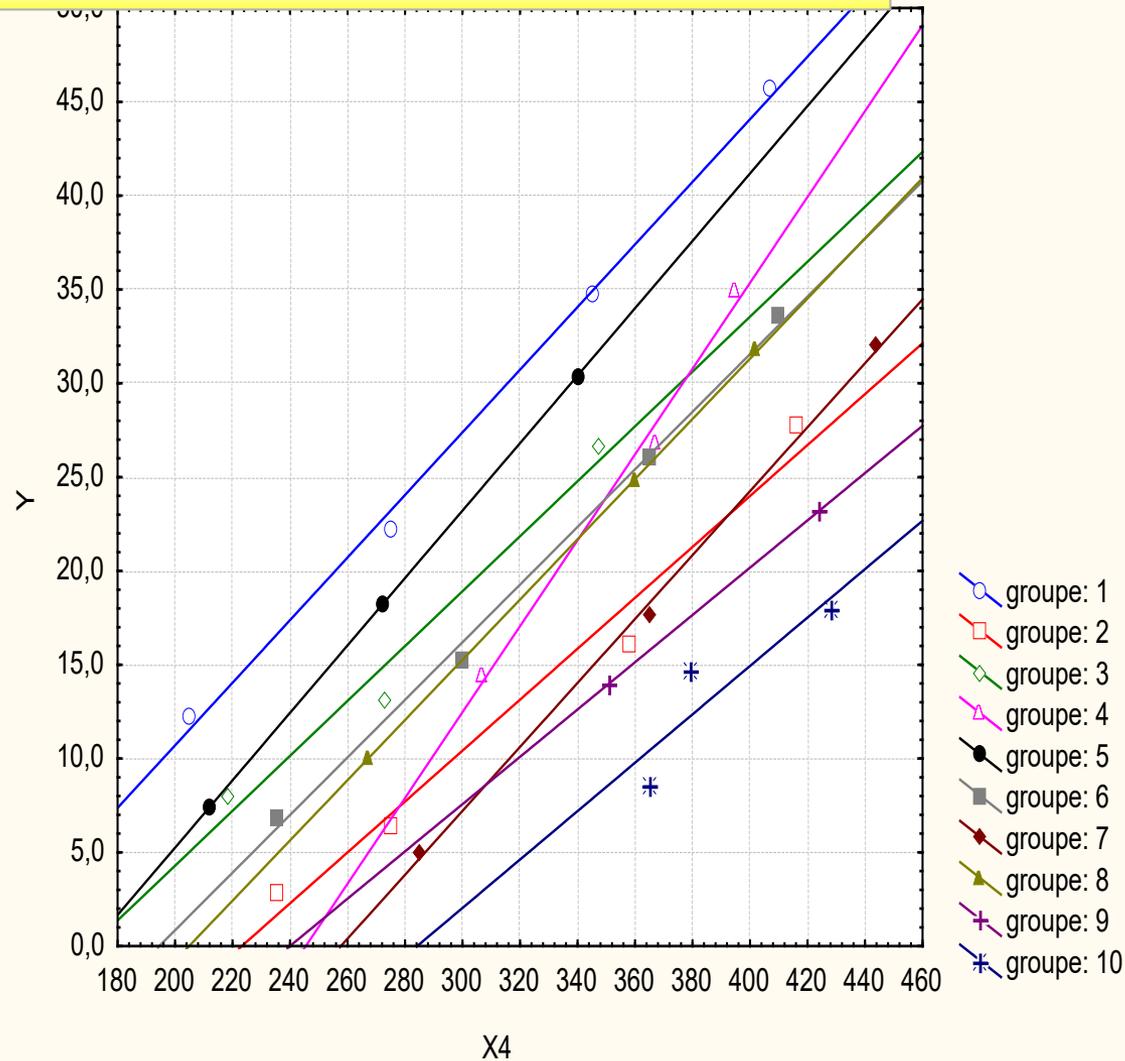
variables continues + variables catégoriques



modèle 1: pentes distinctes

modèle 2: pente égales – ANCOVA

## Modèle : pente égales - ANCOVA



**groupe: 1**  $Y = -22,67 + 0,167*x$

$r = 0,999$ ;  $p = 0,0012$ ;  $r^2 = 0,9976$

**groupe: 2**  $Y = -30,29 + 0,136*x$

$r = 0,9875$ ;  $p = 0,0125$ ;  $r^2 = 0,9752$

**groupe: 3**  $Y = -24,97 + 0,146*x$

$r = 0,9855$ ;  $p = 0,1084$ ;  $r^2 = 0,9713$

**groupe: 4**  $Y = -56,16 + 0,229*x$

$r = 0,9963$ ;  $p = 0,0550$ ;  $r^2 = 0,9925$

**groupe: 5**  $Y = -30,69 + 0,180*x$

$r = 1,0000$ ;  $p = 0,0006$ ;  $r^2 = 1,0000$

**groupe: 6**  $Y = -29,86 + 0,153*x$

$r = 0,9979$ ;  $p = 0,0021$ ;  $r^2 = 0,9958$

**groupe: 7**  $Y = -43,91 + 0,170*x$

$r = 0,9990$ ;  $p = 0,0281$ ;  $r^2 = 0,9981$

**groupe: 8**  $Y = -32,88 + 0,160*x$

$r = 1,0000$ ;  $p = 0,0048$ ;  $r^2 = 0,9999$

**groupe: 9**  $Y = -30,24 + 0,126*x$

$r = 1,0000$ ;  $p = ---$ ;  $r^2 = 1,0000$

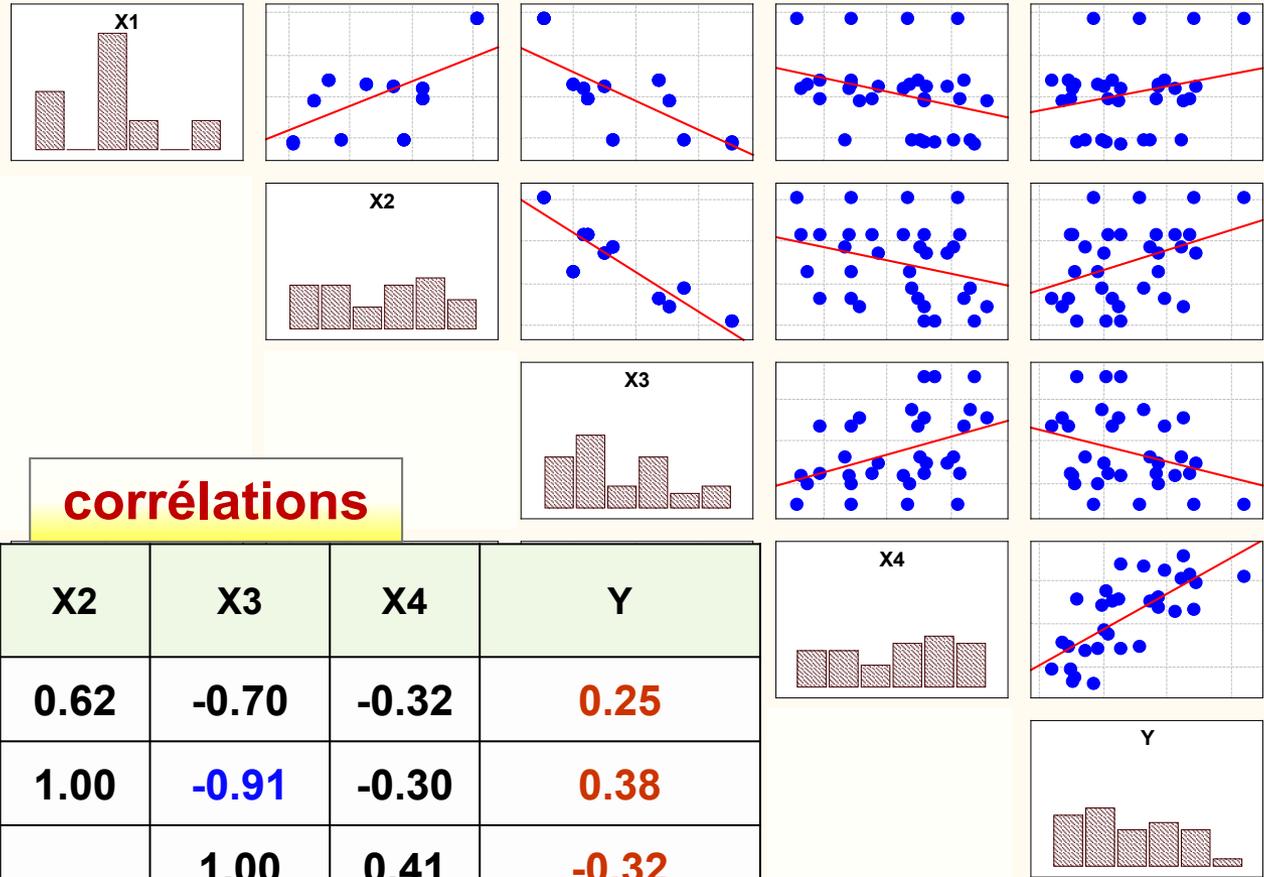
**groupe: 10**  $Y = -36,66 + 0,129*x$

$r = 0,8848$ ;  $p = 0,0387$ ;  $r^2 = 0,7828$

**RÉGRESSION  
LINÉAIRE  
MULTIPLE (9/ 17)**

**Analyse  
Régression  
Multiple**

Matrix Plot ( 22v\*48c)



**corrélations**

	X1	X2	X3	X4	Y
X1	1.00	0.62	-0.70	-0.32	0.25
X2		1.00	-0.91	-0.30	0.38
X3			1.00	0.41	-0.32
X4				1.00	0.71
Y					1.00

# RÉGRESSION LINÉAIRE MULTIPLE (10/17)

## Regression Summary for Dependent Variable: Y

R = 0.981    R<sup>2</sup> = 0.962    Adjusted R<sup>2</sup> = 0.957  
 F(4,27)=172.06    p < 0.00000    Std.Error of estimate: 2.23

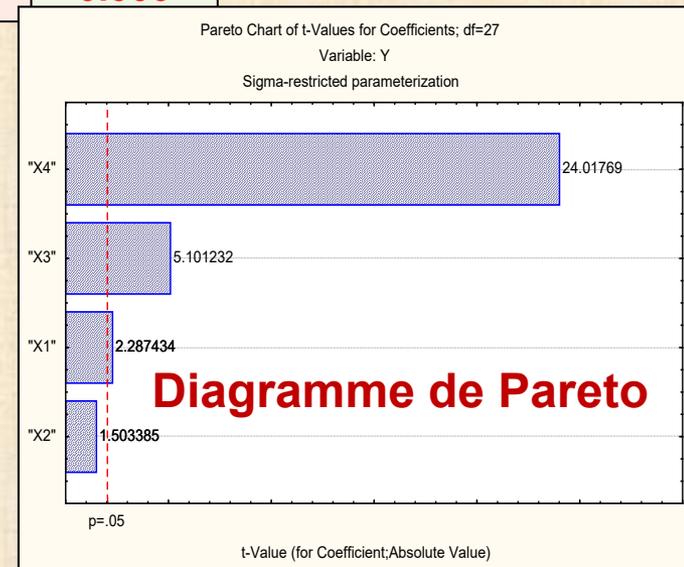
test de  
Student

variables  
significatives

	b*	Std.Err. b*	b	Std.Err. b	t(27)	p-level
Intercept			- 6.97	10.13	- 0.69	0.497
X1	0.120	0.053	0.23	0.10	2.29	0.030
X2	0.136	0.090	0.56	0.37	1.50	0.144
X3	- 0.522	0.102	- 0.15	0.03	- 5.10	0.000
X4	1.006	0.042	0.15	0.01	24.02	0.000

coefficients de l'équation de prédiction avec toutes les variables X et Y centrées réduites: permet de mieux comparer la contribution relative des X sur Y : corrélation partielle X<sub>i</sub> sur Y avec X<sub>j</sub> constants j ≠ i

coefficients bruts de l'équation de prédiction avec toutes les variables X et Y dans leurs unités d'origine



# RÉGRESSION LINÉAIRE MULTIPLE (11 / 17)

avec  
module  
GRM

**Regression Summary for Dependent Variable: Y**

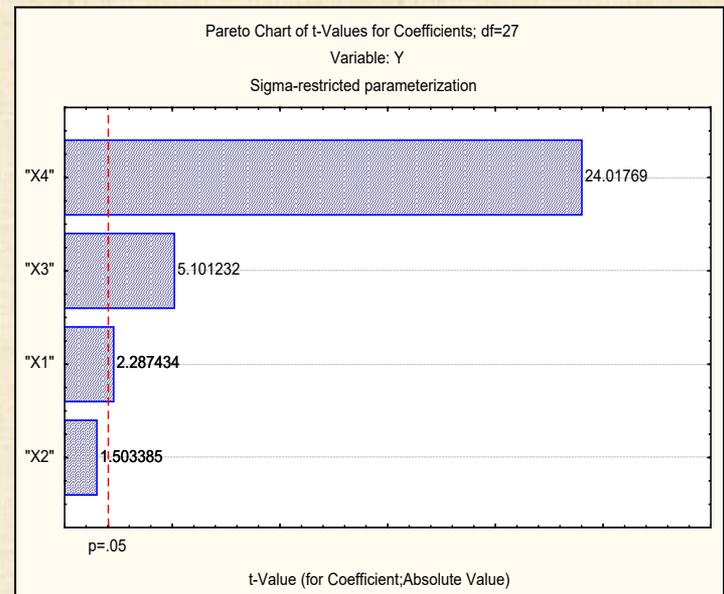
R = 0.981    R<sup>2</sup> = 0.962    Adjusted R<sup>2</sup> = 0.957

F(4,27)=172.06    p < 0.00000    Std. Error of estimate: 2.23 =  $\hat{\sigma}$

	Sums of Square SS	df	Mean Square MS	F	p-level
Regress.	3429.53	4	857.38	172.055	0.000000
Residual	134.55	27	4.98		
Total	3564.08				

	Degr. of freedom	Y SS	Y MS	Y F	Y p
Intercept	1	2.357	2.357	0.4730	0.497485
"X1"	1	26.074	26.074	5.2324	0.030230
"X2"	1	11.263	11.263	2.2602	0.144348
"X3"	1	129.675	129.675	26.0226	0.000023
"X4"	1	2874.54	2874.54	576.849	0.000000
Error	27	134.55	4.983		
Total	31	3564.08			

## Diagramme de Pareto



## RÉGRESSION LINÉAIRE MULTIPLE (12 / 17)

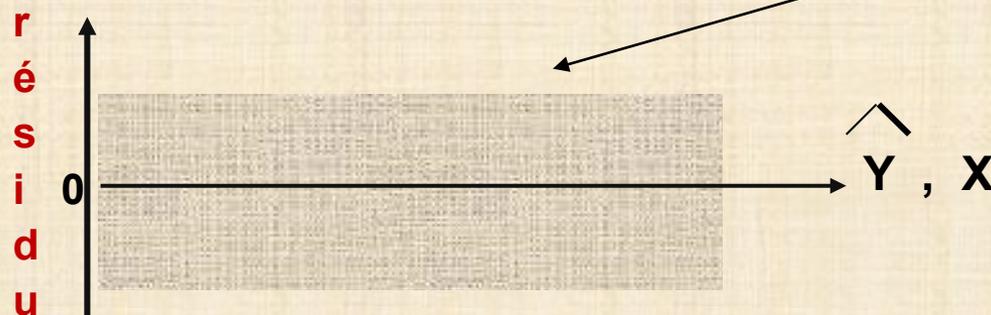
observations triées ordre résidu	Valeur Obs  Y	Valeur Préd $\hat{Y}$	Résidu r $\hat{Y} - Y$	Valeur prédite en centrée réduite	Résidu standard  r / sigma	Ecart type Préd $\hat{ET}(\hat{Y})$
29 . . . . . *	30.40	25.78	4.62	0.58	2.07	0.540
10 .* . . . . .	15.20	18.78	-3.58	-0.08	-1.60	0.603
2 .* . . . . .	14.40	17.93	-3.53	-0.16	-1.58	0.424
19 . . . . . * .	34.90	31.54	3.36	1.13	1.50	0.617
20 . . . . . * . .	18.20	15.26	2.94	-0.42	1.32	0.603
24 . * . . . . .	16.10	19.01	-2.91	-0.06	-1.30	0.731
...	...	...	...	...	...	...
12 . . . * . . . .	14.00	13.65	0.35	-0.57	0.16	0.744
26 . . . * . . . .	34.70	34.43	0.27	1.40	0.12	1.054
14 . . . * . . . .	6.40	6.17	0.23	-1.28	0.10	0.833
31 . . . * . . . .	27.80	27.98	-0.18	0.79	-0.08	0.872
30 . . . * . . . .	26.60	26.64	-0.04	0.66	-0.02	1.202
Minimum .* . . . ..	2.80	-0.01	-3.58	-1.87	-1.60	0.424
Maximum ... *	45.70	44.02	4.62	2.32	2.07	1.223
Moyenne .. *	19.66	19.66	0.00	0.00	0.00	0.857

## analyse des résidus ('model checking')

- important de faire une vérification a posteriori quand on ajuste tout modèle statistique
- hypothèses de base
  - variance constante?
  - distribution normale résidus?
  - « bon » modèle? (page suivante)
  - indépendance observations?
  - données aberrantes (ouliers)?
- Si hypothèses de base violées
  - quoi faire ?
  - solution : transformer Y
  - transformation de Box-Cox  $Y^\lambda$
  - $-2 < \lambda < 2$

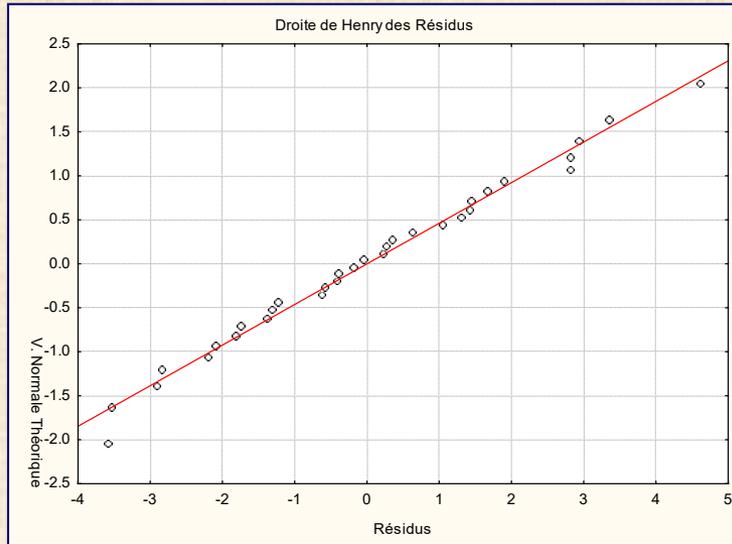
## critères «bon modèle» de régression multiple

- test global F significatif
- tests individuels significatifs pour chacun des coefficients du modèle ajusté
- $R^2$  élevé (au moins 0.70) et  $R^2_{adj}$  légèrement inférieur à  $R^2$
- analyse de sensibilité : pas d'observations avec une influence prépondérante
- absence de colinéarité forte entre les variables X
- analyse des résidus ne présente pas d'anomalies
  - indépendance des observations de Y (toujours vrai avec des données expér.)
  - distribution gaussienne : alignement sur un q-q plot (surtout données aberrantes)
  - variance de Y constante
  - graphiques des résidus avec ( y observés , chaque X ) : bande horizontale

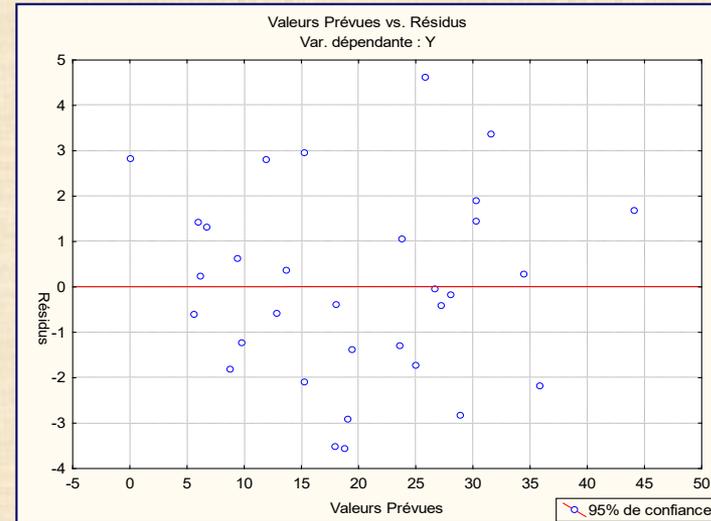


# RÉGRESSION LINÉAIRE MULTIPLE (15 / 17)

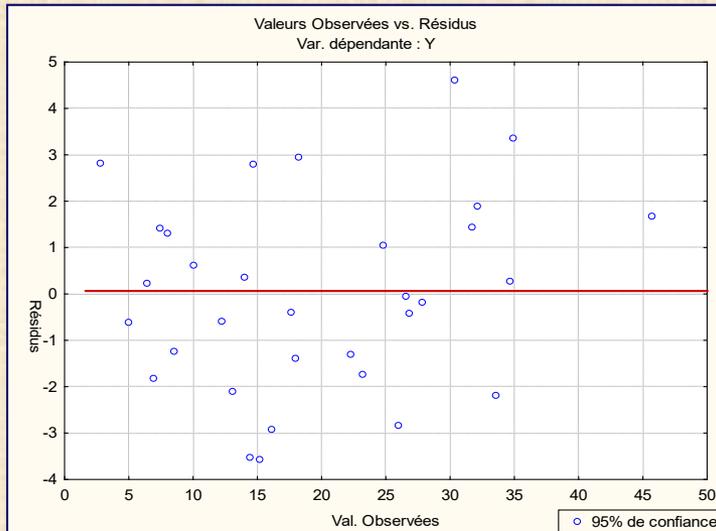
## résidus sur échelle gaussienne



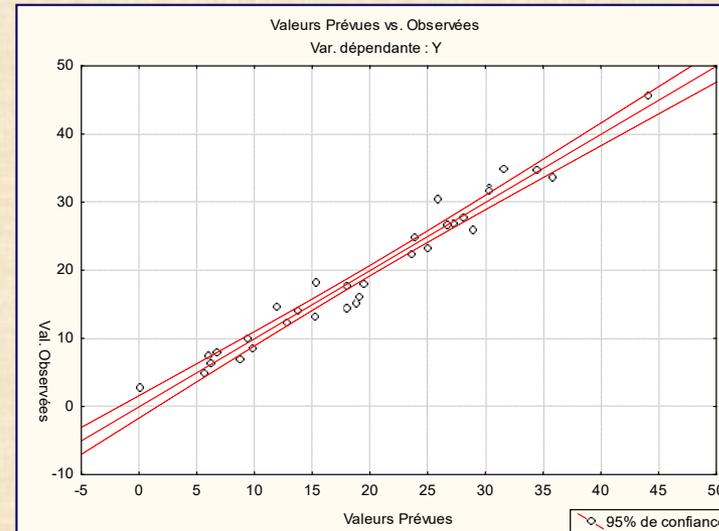
## résidus vs prédictions



## résidus vs observées

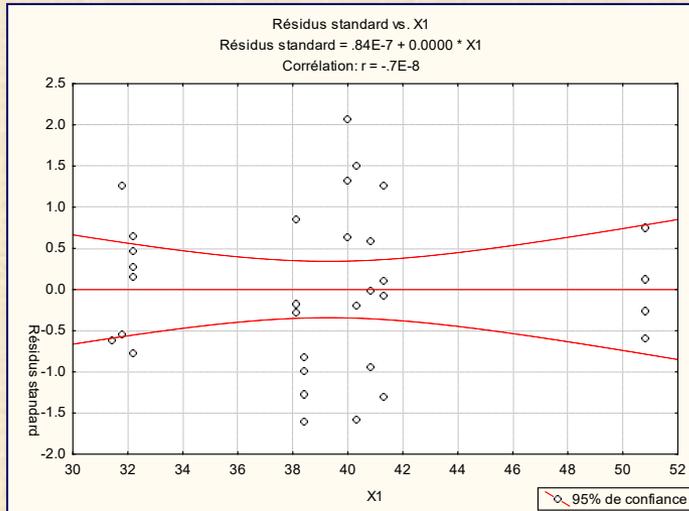


## prédictions vs observées

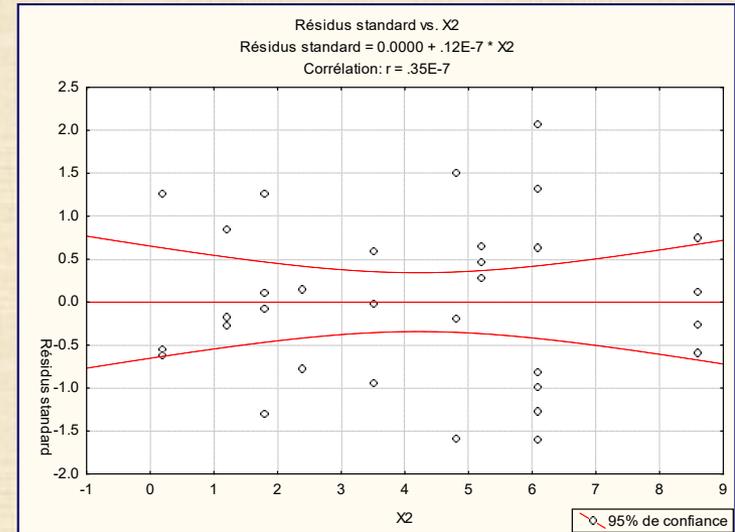


# RÉGRESSION LINÉAIRE MULTIPLE (16 / 17)

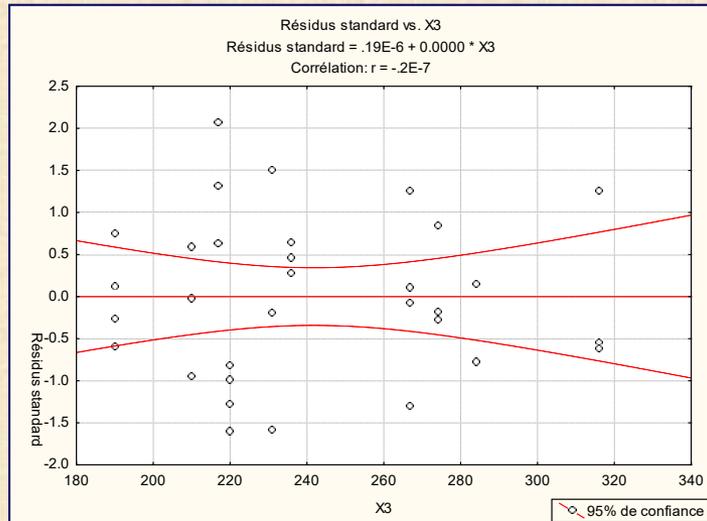
## résidu vs X1



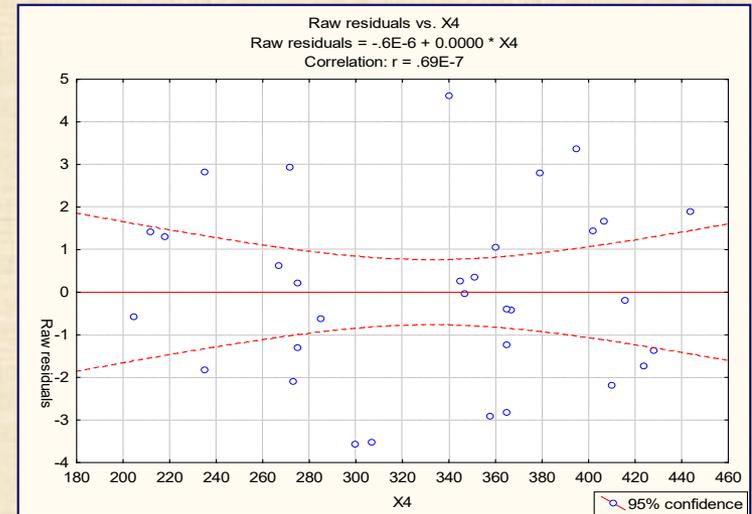
## résidu vs X2



## résidu vs X3



## résidu vs X4



## CORRECTIFS si les résidus présentent des anomalies

- **élimination** variables colinéaires redondantes :  
méthode de sélection de variables pas à pas ( stepwise)
- **ajout** termes additionnels dans modèle :  $X_i^2$  ,  $X_i X_{i'}$  (  $i \neq i'$  )
- **élimination** d'observations influentes
- **ajout** de nouvelles variables explicatives
- **recherche** de nouveaux modèles / formes fonctionnelles

## Transformation de Box-Cox de Y pour stabiliser la variance

nouvelle variable  $Y'$  transformation de puissance

$$Y' = Y^\lambda \quad -2 < \lambda < 2$$

**bonus fréquent** : corrige l'absence de normalité de la réponse Y

méthodes pour obtenir  $\lambda$  : **graphique** (page suivante) ou **analytique** (ch. 5)

## Forme équivalente de la transformation de Box-Cox

$$Y' = \begin{cases} (Y^\lambda - 1) / \lambda g^{\lambda-1} & \lambda \neq 0 \\ g \ln(Y) & \lambda = 0 \end{cases}$$

$$g = \exp [(1/n) \sum \ln(y)] = \Pi y^{1/n} \quad \text{moyenne géométrique}$$

# Transformation de Box-Cox

$$Y' = Y^\lambda$$

$$-2 < \lambda < 2$$

groupes de données  $(\bar{Y}_i, s_i)$   $i = 1, 2, 3, \dots, k$

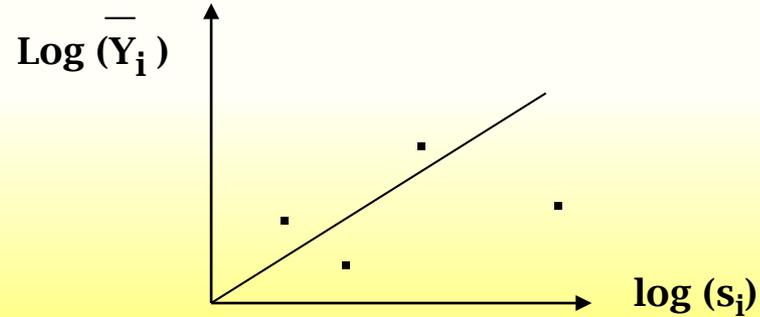
méthode graphique pour déterminer  $\lambda$

graphique de  $\log(\bar{Y}_i)$  vs  $\log(s_i)$

pente =  $\alpha$   $\lambda = 1 - \alpha$

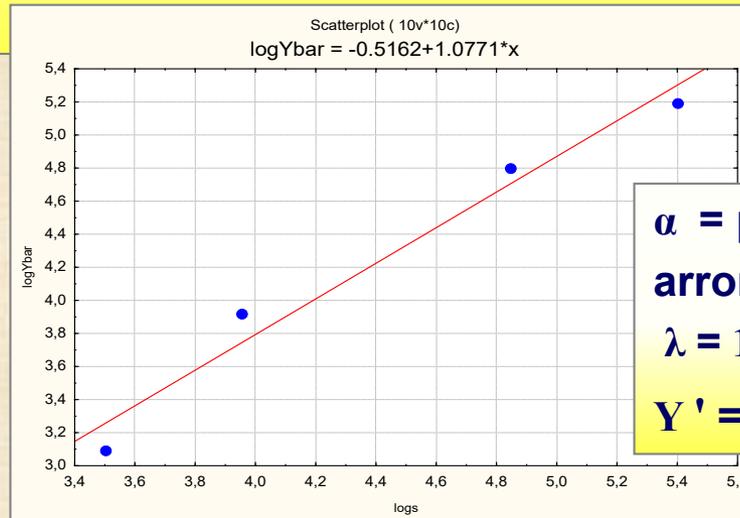
(arrondir)

$\alpha$	$\lambda$	$Y'$
3	-2	$1/Y^2$
2	-1	$1/Y$
1.5	-0.5	$Y^{-0.5}$
<b>1</b>	<b>0</b>	<b><math>\log(Y)</math></b>
0.5	0.5	$Y^{0.5}$
0	1	$Y$
-1	2	$Y^2$



## exemple

groupe	Ybar	s
A	22.13	33.22
B	50.37	52.29
C	121.21	127.15
D	180.41	222.14



$\alpha = \text{pente} = 1.07$   
 arrondi  $\alpha = 1$   
 $\lambda = 1 - \alpha = 0$   
 $Y' = \log(Y)$

# PLAN 2<sup>4</sup> : 16 ESSAIS

## 4 facteurs variant à 2 modalités

<u>matrice de design</u>					<u>iden.</u>	<u>Réponse</u>
colonne	1	2	3	4		
essai	A	B	C	D	id	Y
1	-	-	-	-	(1)	y1
2	+	-	-	-	a	y2
3	-	+	-	-	b	y3
4	+	+	-	-	ab	y4
5	-	-	+	-	c	y5
6	+	-	+	-	ac	y6
7	-	+	+	-	bc	y7
8	+	+	+	-	abc	y8
9	-	-	-	+	d	y9
10	+	-	-	+	ad	y10
11	-	+	-	+	bd	y11
12	+	+	-	+	abd	y12
13	-	-	+	+	cd	y13
14	+	-	+	+	acd	y14
15	-	+	+	+	bcd	y15
16	+	+	+	+	abcd	y16

- : modalité 1  
+ : modalité 2

chaque ligne  
représente un traitement

### identification

présence d'une  
lettre minuscule  
implique que le  
facteur prend la  
modalité +

### ordre standard Yates

colonne 1 (A)  
alternance des  
signes - et +

colonne 2 (B)  
alternance - - + +  
etc

## propriétés importantes du plan factoriel complet $2^4$

- **8 (+) et 8 (-) dans chaque colonne**  
**somme = 0**
- **ORTHOAGONALITÉ** → **permet de séparer les effets**  
**produit de 2 colonnes = 0**
- **ÉQUILIBRÉ** «balance»
  - **chaque modalité (niveau) de chaque facteur apparaît exactement 8 fois**
  - **toutes les combinaisons de 2 facteurs apparaissent exactement 4 fois**
  - **toutes les combinaisons de 3 facteurs apparaissent exactement 2 fois**

# PLAN DE 16 ESSAIS $2^4$ : matrice des effets – modèle pour l'analyse

plan

interactions doubles

interactions triples

inter.  
quadruple

#	gen	A	B	C	D	AB	AC	AD	BC	BD	CD	ABC	ABD	ACD	BCD	ABCD	Y
1	1	-1	-1	-1	-1	1	1	1	1	1	1	-1	-1	-1	-1	1	y1
2	1	1	-1	-1	-1	-1	-1	-1	1	1	1	1	1	1	-1	-1	y2
3	1	-1	1	-1	-1	-1	1	1	-1	-1	1	1	1	-1	1	-1	y3
4	1	1	1	-1	-1	1	-1	-1	-1	-1	1	-1	-1	1	1	1	y4
5	1	-1	-1	1	-1	1	-1	1	-1	1	-1	1	-1	1	1	-1	y5
6	1	1	-1	1	-1	-1	1	-1	-1	1	-1	-1	1	-1	1	1	y6
7	1	-1	1	1	-1	-1	-1	1	1	-1	-1	-1	1	1	-1	1	y7
8	1	1	1	1	-1	1	1	-1	1	-1	-1	1	-1	-1	-1	-1	y8
9	1	-1	-1	-1	1	1	1	-1	1	-1	-1	-1	1	1	1	-1	y9
10	1	1	-1	-1	1	-1	-1	1	1	-1	-1	1	-1	-1	1	1	y10
11	1	-1	1	-1	1	-1	1	-1	-1	1	-1	1	-1	1	-1	1	y11
12	1	1	1	-1	1	1	-1	1	-1	1	-1	-1	1	-1	-1	-1	y12
13	1	-1	-1	1	1	1	-1	-1	-1	-1	1	1	1	-1	-1	1	y13
14	1	1	-1	1	1	-1	1	1	-1	-1	1	-1	-1	1	-1	-1	y14
15	1	-1	1	1	1	-1	-1	-1	1	1	1	-1	-1	-1	1	-1	y15
16	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	y16

## PLAN DE 16 ESSAIS $2^4$ : matrice des effets – modèle pour l'analyse

- colonnes AB, AC, BC, ABC,... sont obtenues par multiplication –  $AB = A \times B$ , ...  $BCD = B \times C \times D$  ....

- engendre un maximum de 15 comparaisons appelés **CONTRASTES**

$$C = \sum c_i Y_i \quad \text{où} \quad \sum c_i = 0 \quad c_i = \pm 1$$

- les contrastes sont orthogonaux : produit de 2 colonnes = 0

**séparation complète des effets principaux et d'interaction**

- les contrastes transforment la réponse Y pour obtenir

- 4 effet principaux : A - B - C - D

- 6 effets d'interactions doubles : AB - AC - AD – BC – BD -CD

- 4 effets d'interaction triples : ABC – ABD – ACD - BCD

- l'interaction quadruple ABCD

- possibilité d'employer la matrice avec

5 – 6 – 7 – ... – 14 – 15 facteurs : plans fractionnaires  $2^{k-p}$

## Exploitation de la matrice augmentée 16 essais

### Application 1 : modèle avec 4 facteurs A, B, C, D

notation :  $X_{AB} = X_A X_B$  ,  $X_{ABC} = X_A X_B X_C$  etc.

**modèle**

$$\begin{aligned} Y = & \beta_0 + \beta_A X_A + \beta_B X_B + \beta_C X_C + \beta_D X_D \\ & + \beta_{AB} X_{AB} + \beta_{AC} X_{AC} + \beta_{AD} X_{AD} + \beta_{BC} X_{BC} + \beta_{BD} X_{BD} + \beta_{CD} X_{CD} + \\ & + \beta_{ABC} X_{ABC} + \beta_{ABD} X_{ABD} + \beta_{ACD} X_{ACD} + \beta_{BCD} X_{BCD} + \\ & + \beta_{ABCD} X_{ABCD} \end{aligned}$$

$$Y = \sum_{j=0}^{15} \beta_j X_j$$

où  $X_0 = 1$  ,  $X_1 = X_A$  ,  $X_2 = X_B$  , .... ,  $X_{15} = X_A X_B X_C X_D$

colonne identité  $X_0$  + les 15 colonnes de la matrice

## Exploitation de la matrice augmentée 16 essais

### Application 2 : modèle avec 5 facteurs A, B, C, D, E en 16 essais

5<sup>ème</sup> facteur E est défini (confondu) avec l'interaction , **E = ABCD**

$$Y = \sum_{j=0}^{15} \beta_j X_j$$

où  $X_j$  sont les 15 colonnes de la matrice  $j = 1, 2, \dots, 15$   
 et  $X_0 = 1$  la colonne identité

#### conséquences de **E = ABCD**

$X_1$	$X_2$	$X_3$	$X_4$	$X_5$	$X_6$	$X_7$	$X_8$	$X_9$	$X_{10}$	$X_{11}$	$X_{12}$	$X_{13}$	$X_{14}$	$X_{15}$
A	B	C	D	AB	AC	AD	BC	BD	CD	<del>ABC</del>	<del>ABD</del>	<del>ACD</del>	<del>BCD</del>	<del>ABCD</del>
				<del>CDE</del>	<del>BDE</del>	<del>BCE</del>	<del>ADE</del>	<del>ACE</del>	<del>ABE</del>	DE	CE	BE	AE	E

**modèle : effets principaux et les interactions doubles seulement  
toutes séparées -- plan de résolution V**

$$Y = \beta_0 + \beta_A X_A + \beta_B X_B + \beta_C X_C + \beta_D X_D + \beta_{AB} X_{AB} + \beta_{AC} X_{AC} + \beta_{AD} X_{AD} + \beta_{BC} X_{BC} \\ + \beta_{BD} X_{BD} + \beta_{CD} X_{CD} + \beta_{DE} X_{DE} + \beta_{CE} X_{CE} + \beta_{BE} X_{BE} + \beta_{AE} X_{AE} + \beta_E X_E$$

# Exploitation de la matrice augmentée 16 essais

## Application 3 : modèle 8 facteurs A, B, C, D, E, F, G, H en 16 essais

E, F, G, H définies (confondues) avec les 4 interactions triples :

**E = BCD      F = ACD      G = ABC      H = ABD**      (chapitre 3-27)

Modèle  $Y = \sum_{j=0}^{15} \beta_j X_j$        $X_j$  15 colonnes de la matrice  $j = 1, \dots, 15$   
 $X_0 = 1$  colonne identité

conséquences : définition de E, F, G, H avec des interactions triples

$X_1$	$X_2$	$X_3$	$X_4$	$X_5$	$X_6$	$X_7$	$X_8$	$X_9$	$X_{10}$	$X_{11}$	$X_{12}$	$X_{13}$	$X_{14}$	$X_{15}$
A	B	C	D	AB	AC	AD	BC	BD	CD	<del>ABC</del>	<del>ABD</del>	<del>ACD</del>	<del>BCD</del>	<del>ABCD</del>
				CG	BG	BH	AG	AH	AF	G	H	F	E	AE
				DH	DF	CF	DE	CE	BE					BF
				EF	EH	EG	FH	FG	GH					CH
														DG

colonnes 5 - 6 - 7 - 8 - 9 - 10 - 15 : interactions doubles confondues  
 complique l'interprétation si le coefficient  $\beta$  associé à la colonne est « grand »  
 aide : identifier effets principaux « importants » - colonnes 1-2-3-4-11-12-13-14

$$\begin{aligned}
 Y = & \beta_0 + \beta_A X_A + \beta_B X_B + \beta_C X_C + \beta_D X_D + \beta_5 (X_{AB} + X_{CG} + X_{DH} + X_{EF}) \\
 & + \beta_6 (X_{AC} + X_{BG} + X_{DF} + X_{EH}) + \dots + \beta_{10} (X_{CD} + X_{AF} + X_{BE} + X_{GH}) \\
 & + \beta_{11} X_G + \beta_{12} X_H + \beta_{13} X_F + \beta_{14} X_E + \beta_{15} (X_{AE} + X_{BF} + X_{CH} + X_{DG})
 \end{aligned}$$

## Analyse du plan de 16 essais

modèle et données 
$$y_i = \sum_{j=0}^{15} \beta_j x_{ij} + \varepsilon_i \quad i = 1, 2, \dots, 16$$

$y_i$  : réponse observée à l'essai (traitement  $i$ )

$\beta_j$  : coefficients du modèle (à estimer)  $j = 0, 1, \dots, 15$

$x_{ij}$  : constantes connues ( $\pm 1$ ) - colonnes de la matrice

$$x_{i0} = 1 \quad i = 1, 2, \dots, 16$$

**Propriétés matrice  $X \longrightarrow$  orthogonale**

$$\sum x_{ij} = 0 \quad \sum x_{ij}^2 = 16 \quad \sum x_{ij} x_{ij'} = 0 \quad j \neq j'$$

**conséquence : simplification des calculs de régression (ch. 4.6)**

$n$  données (répétitions) essai  $i$  :  $y_{i1}, y_{i2}, \dots, y_{in}$

$$\bar{y}_i = \sum_k^n y_{ik} / n : \text{moyenne de l'essai } i$$

$$s_i^2 = \sum_k (y_{ik} - \bar{y}_i)^2 / (n - 1) : \text{variance de l'essai}$$

$$\bar{y} = \sum_k \bar{y}_i / 16 : \text{grande moyenne}$$

## Analyse du plan de 16 essais

**Estimation  $\beta$**     moindres carrés    formules p.6

$$\hat{\beta}_0 = \bar{y} \qquad \hat{\beta}_j = \sum x_{ij} \bar{y}_i / 16$$

**Modèle ajusté**     $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_{15} x_{i15}$

Estimation de l'erreur expérimentale  $\sigma$

$$\hat{\sigma}^2 = \sum s_i^2 / 16 \quad \text{estimation directe (appelée erreur pure)}$$

**applicable seulement si  $n > 1$**

si  $n = 1$  plan sans répétition

l'estimation de  $\sigma$  est **indirecte** et basée sur la somme des carrés résiduels (s'il reste des degrés de liberté) après l'ajustement du modèle: **dépend du modèle employé**

méthode pour juger de l'importance des effets sans faire des tests de signification

**effets placés sur «half normal prob plot» : détails chapitre 5**

## Analyse du plan de 16 essais

### ANOVA

$$SS_{TOT} = \sum \sum (y_{ik} - \bar{y})^2 : \text{variabilité totale}$$

$$SS_{MOD} = n \sum (\hat{y}_i - \bar{y})^2 : \text{variabilité expliquée modèle (inter)}$$

$$SS_{INTRA} = \sum \sum (y_{ik} - \bar{y}_i)^2 : \text{intra variabilité} = 16 \hat{\sigma}^2$$

$$SS_{TOT} = SS_{MOD} + SS_{INTRA} : \text{décomposition de la variabilité}$$

$$SS_{MOD} = 16n \sum \hat{\beta}_j^2 : \text{décomposition orthogonale des effets}$$

### degrés de liberté

$$df_{TOT} = 16n - 1 : \text{degrés de liberté de } SS_{TOT}$$

$$df_{MOD} = 15 : \text{degrés de liberté de } SS_{MOD}$$

$$df_{INTRA} = 16(n - 1) : \text{degrés de liberté de } SS_{INTRA}$$

# Analyse du plan de 16 essais

## Tableau d'analyse de la variance

source	somme carrés (SS)	degrés liberté (df)	carrés moyens (MS)	F (ou t) (*)
<b>modèle</b>	$SS_{MOD}$	<b>15</b>	$MS_{MOD}$	$MS_{MOD} / \hat{\sigma}^2$
$\left\{ \begin{array}{l} x_1 \\ \cdot \\ x_{15} \end{array} \right.$	$\left\{ \begin{array}{l} 16n \hat{\beta}_1^2 \\ \cdot \\ 16n \hat{\beta}_{15}^2 \end{array} \right.$	$\left\{ \begin{array}{l} 1 \\ \cdot \\ 1 \end{array} \right.$	$\left\{ \begin{array}{l} 16n \hat{\beta}_1^2 \\ \cdot \\ 16n \hat{\beta}_{15}^2 \end{array} \right.$	$\left\{ \begin{array}{l} 16n \hat{\beta}_1^2 / \hat{\sigma}^2 \\ \cdot \\ 16n \hat{\beta}_{15}^2 / \hat{\sigma}^2 \end{array} \right.$
<b>intra</b>	$SS_{INTRA}$	<b>16 (n-1)</b>	$MS_{INTRA} = \hat{\sigma}^2$	-----
<b>totale</b>	$SS_{TOT}$	<b>16n - 1</b>	-----	

(\*) Les tests de signification F des coefficients  $\beta$  de chaque x sont équivalents aux tests t de Student

## Analyse du plan de 16 essais

### Test

global  $H_0 : \beta_1 = \beta_2 = \dots = \beta_{15} = 0$  aucun facteur est actif sur Y

rejet de  $H_0$  si  $MS_{MOD} / \hat{\sigma}^2 > F_{15, 16(n-1), 1-\alpha}$  Fisher

individuel  $H_{0j} : \beta_j = 0$  effet principal / interaction est zéro

rejet de  $H_{0j}$  si  $16 n \hat{\beta}_j^2 / \hat{\sigma}^2 > F_{1, 16(n-1), 1-\alpha} = t^2_{16(n-1), 1-\alpha}$

### Variation expliquée

$$R^2 = SS_{MOD} / SS_{TOT} \quad 0 \leq R^2 \leq 1$$

$$R_{adj}^2 = 1 - [(16n - 1) / (16n - 15)] (1 - R^2)$$

## Analyse du plan de 16 essais

### décomposition de la variabilité

$$SS_{TOT} = SS_{INTER} + SS_{INTRA} \quad \text{1 facteur (chapitre 2)}$$

$$SS_{TOT} = SS_{MOD} + SS_{RESID} \quad \text{régression (chapitre 4)}$$

$$SS_{TOT} = SS_{MOD} + SS_{INTRA} \quad \text{plan 16 essais / 15 effets / } n > 1$$

### Cas général (si $n > 1$ : répétitions)

$$\begin{aligned} SS_{TOT} &= SS_{MOD} + SS_{RESID} \\ &= SS_{MOD} + SS_{INTRA} + SS_{LOF} \end{aligned}$$


**LOF : « lack of fit »**

**exemples : chapitres 5/6**

# différence effet significatif VERSUS effet important

## RELATION entre F et R<sup>2</sup>

$$R^2 = df\_modèle * F\_modèle / (df\_modèle * F\_modèle + df\_erreur)$$

$$F = df\_erreur * R^2 / (df\_modèle * (1 - R^2))$$

Un ratio F\_modèle dépassant le F\_critique à 5% (F\_critique) permet de rejeter l'hypothèse nulle il n'implique pas nécessairement un R<sup>2</sup> élevé comme on peut le constater dans le tableau. Il faut distinguer entre un effet (test) **SIGNIFICATIF** et un effet qui est **IMPORTANT** disons un R<sup>2</sup> supérieur à 50%. Il faut que le ratio F soit au moins 4 fois plus grand (F\_gros = 4\*F\_critique (0,05) pour que le R<sup>2</sup> dépasse 50% .

df model	df erreur	F Critique (0,05)	R <sup>2</sup>	F_gros = 4 * F critique	R <sup>2</sup> F gros
1	5	6,61	0,57	26,43	0,84
1	10	4,96	0,33	19,86	0,67
1	15	4,54	0,23	18,17	0,55
1	20	4,35	0,18	17,40	0,47
1	30	4,17	0,12	16,68	0,36
1	50	4,03	0,07	16,14	0,24
3	5	5,41	0,76	21,64	0,93
3	10	3,71	0,53	14,83	0,82
3	15	3,29	0,40	13,15	0,72
3	20	3,10	0,32	12,39	0,65
3	30	2,92	0,23	11,69	0,54
3	50	2,79	0,14	11,16	0,40
5	5	5,05	0,83	20,20	0,95
5	10	3,33	0,62	13,30	0,87
5	15	2,90	0,49	11,61	0,79
5	20	2,71	0,40	10,84	0,73
5	30	2,53	0,30	10,13	0,63
5	50	2,40	0,19	9,60	0,49
10	5	4,74	0,90	18,94	0,97
10	10	2,98	0,75	11,91	0,92
10	15	2,54	0,63	10,17	0,87
10	20	2,35	0,54	9,39	0,82
10	30	2,16	0,42	8,66	0,74
10	50	2,03	0,29	8,10	0,62

