

Chapitre 2	Régression	linéaire simple
		<u>logistique</u>
▪ Modèles		2-5
▪ Modèle linéaire simple		6-26
▪ Modèles linéarisables		24-27
▪ Modèles non linéaires		28-32
▪ Modèle Logistique		33-43
▪ Critères comparaison modèles		44-47
▪ Exemples avec JMP		48-52

Objectif de ANALYSE STATISTIQUE : comprendre / prédire / optimiser SYSTÈME / PROCESSUS

TOUTE analyse statistique repose sur un **MODÈLE**


- relation entre input **X (fixe)** **Z (aléatoire)** et output **Y**
- connaissance de la structure des données:

plan de collecte des données / **nature** variables / **rôle** des variables

type d'influence des variables / **unités** statistiques (expérimentales)

$X_1, X_2, \dots, Z_1, Z_2, \dots$: facteurs, variables contrôlées en expérimentation
mode actif : données expérimentales

variables observées / mesurées en observation
mode passif – données observationnelles



Objectif de ANALYSE STATISTIQUE : comprendre / prédire / optimiser SYSTÈME / PROCESSUS

VARIABLES

RÔLE

Y : réponse , output

peut être: **binaire (0, 1), multinomiale (classification),
continue, multidimensionnelle**

X, Z : explicatives, régresseurs, input, **fixées, aléatoires**

NATURE

X (fixes) : continues, catégoriques

Z (aléatoires) : continues, catégoriques

INFLUENCE

X : affecte la **centralité (moyenne)** de Y : effets fixes

Z : affecte la **dispersion (variance)** de Y : effets aléatoires

MODÈLES à effets fixes seulement

$$Y = f(X_1, X_2, \dots, X_k; \beta_0, \beta_1, \beta_2, \dots) + \varepsilon \quad \varepsilon \sim N(0, \sigma^2)$$

MODÈLES à effets mixtes : effets fixes + effets aléatoires

$$Y = f(X_1, X_2, \dots, X_k; \beta_0, \beta_1, \beta_2, \dots) + g(Z_1, Z_2, \dots, Z_h; \sigma_1^2, \sigma_2^2, \dots) + \varepsilon$$

MODÈLES d'analyse de régression : X_1, X_2, \dots facteurs quantitatifs

- Linéaire simple : $Y = \beta_0 + \beta_1 X_1 + \varepsilon$
- Régression multiple : $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon$
- Effets principaux + effets d'interaction :
 $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \beta_{12} X_1 X_2 + \beta_{13} X_1 X_3 + \dots + \varepsilon$
- Quadratiques (response surface avec facteurs quantitatifs)
 $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \beta_{12} X_1 X_2 + \beta_{13} X_1 X_3 + \dots +$
 $+ \beta_{11} X_1^2 + \beta_{22} X_2^2 + \beta_{33} X_3^2 + \dots + \varepsilon$
- Régression logistique : Y à valeurs catégoriques (oui / non)
- Régression PLS: nombre variables $X >$ nombre d'observations ($k > n$)
- Modèle d'analyse de la variance: variables catégoriques A
codage à effets $X = 0 / 1 / -1$ selon les modalités de A
- Modèles avec 2 types de variables continues + catégoriques
- Mixtes: facteurs modalités fixes + facteurs modalités aléatoires
- Polynomial : $Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \dots + \beta_k X^k + \varepsilon$

observations : $Y_i = \varphi (X_{i1}, X_{i2}, \dots, X_{ik}; \beta_0, \beta_1, \beta_2, \dots) + \varepsilon_i \quad i = 1, 2, \dots, n$

implicitement : une observation par unité (individu, sujet) statistique
indépendance des Y_i ?

ANALYSE STATISTIQUE : étapes


1. Spécification d'un modèle statistique
2. Estimation des paramètres du modèle
3. Décomposition de la variabilité : ANOVA
4. Tests d'hypothèses sur les paramètres
5. Analyse diagnostique des résidus
 - vérification des hypothèses de base
 - identification d'observations influentes
 - transformation Y ? (si nécessaire)
6. Si nécessaire : itération des étapes 1 à 5
7. Optimisation de la réponse (s'il y a lieu)
8. Graphiques de la réponse

Exemple : relation entre

Y : épaisseur substrat

X : pression

X-pression	Y-epais	ordre
3	14	4
3	12	3
3	13	8
4	10	2
4	9	12
4	11	14
5	9	6
5	10	15
5	11	7
6	9	10
6	8	5
6	10	1
7	8	9
7	9	11
7	7	13



Regression Linéaire

Simple

$$Y = \beta_0 + \beta_1 X_1 + \varepsilon$$

Modèle $Y = \beta_0 + \beta_1 x + \varepsilon$ $\varepsilon \sim N(0, \sigma^2)$

Données (x_i, y_i) $i = 1, 2, \dots, n$

Étapes



- estimation des paramètres : β_0 β_1 σ^2
- décomposition de la variabilité :
= analyse de la variance
= **AN**alysis **Of** **VA**riance = **ANOVA**
- tests - intervalles de confiance
- prédiction de Y et graphiques
- validation du modèle: analyse résidus

Autre exemple : prix vs superficie



AREA m ²	PRICE kkr
134	5 495
115	4 700
167	7 500
185	7 775
84	3 500
98	4 000
115	4 850
185	7 500
164	6 900
145	5 950
123	5 010
128	5 600
167	6 750
115	5 000
178	7 200
97	4 290

AREA	PRICE
84	3500
97	4290
98	4000
115	4700
115	4850
115	5000
123	5010
128	5600
134	5495
145	5950
164	6900
167	7500
167	6750
178	7200
185	7775
185	7500



NOTATION

$\bar{x} = \sum x_i / n$: moyenne de X $\bar{y} = \sum y_i / n$: moyenne de Y

SPxy = $\sum (x_i - \bar{x})(y_i - \bar{y})$: somme des produits XY

SSxx = $\sum (x_i - \bar{x})^2$: somme des carrés de X

SSyy = $\sum (y_i - \bar{y})^2 = SStot$ = somme totale des carrés de Y

ESTIMATION principe des moindres carrés: minimiser $S(\beta_0, \beta_1)$

$S(\beta_0, \beta_1) = \sum (y_i - \beta_0 - \beta_1 x_i)^2$: écart par rapport à la droite

solution $b_1 = \hat{\beta}_1 = SPxy / SSxx = \sum c_i y_i$ où $c_i = (x_i - \bar{x}) / SSxx$

$b_0 = \hat{\beta}_0 = \bar{y} - b_1 \bar{x}$

$$\sum c_i = 0 \quad \sum c_i^2 = 1$$

prédiction $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x = \bar{y} + b_1 (x - \bar{x})$: droite de moindres carrés

résidu brut $e_i = \hat{y}_i - y_i$

somme des carrés résiduels $SS_{resid} = \sum e_i^2 = \sum (y_i - \hat{y}_i)^2$

carré résiduel moyen $MS_{resid} = SS_{resid} / (n - 2)$

estimation de σ^2 $\hat{\sigma}^2 = MS_{resid}$ $\hat{\sigma} = (MS_{resid})^{0.5}$

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

$$SS_{reg} = \sum (\hat{y}_i - \bar{y})^2 = (SP_{xy})^2 / SS_{xx} = \hat{\beta}_1^2 SS_{xx}$$

= somme des carrés de régression (modèle, expliquée par X)

ÉQUATION FONDAMENTALE DE DÉCOMPOSITION

somme de carrés (SS) : $SStot = SS_{reg} + SS_{resid}$

variabilité : totale = modèle + résiduelle

degrés de liberté (DDL) : $n - 1 = 1 + (n - 2)$

TABLEAU D'ANALYSE VARIANCE : modèle de régression linéaire simple

SOURCE	DDL	SS	MS = SS / DDL	F-ratio	p-valeur
régression	1	SS _{reg}	MS _{reg} = SS _{reg} / 1	$F_0 = MS_{reg} / MS_{resid}$	$P(F \geq F_0)$
résiduelle	n - 2	SS _{resid}	MS _{resid} = SS _{resid} / (n - 2) = $\hat{\sigma}^2$	-----	-----
totale	n - 1	SStot	-----		

$R^2 = SS_{reg} / SStot$: coefficient de détermination

$0 \leq R^2 \leq 1$: fraction variabilité Y expliquée par X

$r = \pm (R^2)^{0.5}$: coefficient de corrélation linéaire entre Y et X

remarque : le signe de r (+ ou -) sera celui de $\hat{\beta}_1$

TEST et INTERVALLE de CONFIANCE

résultat $(\hat{\beta}_1 - \beta_1) / (\hat{\sigma} / \text{SSxx}^{0.5}) \sim T_{n-2}$ (loi de Student)

applications

(a) test de β_1 $H_0 : \beta_1 = 0$ vs $H_1 : \beta_1 \neq 0$
 rejeter H_0 au seuil α si $|\hat{\beta}_1| (\text{SSxx})^{0.5} / \hat{\sigma} > t_{n-2, 1-\alpha/2}$

remarque : le test est équivalent au test F du tableau ANOVA

(b) intervalle de confiance de β_1 : $\hat{\beta}_1 \pm t_{n-2, 1-\alpha/2} \hat{\sigma} / (\text{SSxx})^{0.5}$

coefficient de confiance = $1 - \alpha$

(c) INTERVALLE de CONFIANCE : MOYENNE de Y à $X = x^*$

$$E(Y | X = x^*) : \hat{\beta}_0 + \hat{\beta}_1 x^* \pm t_{n-2, 1-\alpha/2} \hat{\sigma} \left[(1/n) + ((x^* - \bar{x})^2 / \text{SSxx}) \right]^{0.5}$$

remarque : un intervalle de confiance pour β_0 s'obtient avec $x^* = 0$

(d) INTERVALLE de PRÉDICTION : VALEUR de Y à $X = x^*$

$$Y | X = x^* : \hat{\beta}_0 + \hat{\beta}_1 x^* \pm t_{n-2, 1-\alpha/2} \hat{\sigma} \left[1 + (1/n) + ((x^* - \bar{x})^2 / \text{SSxx}) \right]^{0.5}$$


remarque : ne pas confondre (c) et (d)

Mise en œuvre avec STATISTICA


avec GRAPHICS
... 2D Scatterplots

avec STATISTICS...
... Multiple Linear Regression

variables continues seulement





pas d'analyse de la variance
pas d'analyse de résidus



Statistics ... Advanced Linear/Nonlinear Models

... General Linear Models et General Regression Models



module GRM **préférable** **module Multiple Regression**

Mise en œuvre avec STATISTICA

Multiple Linear Regression: Ch13-regression.sta in ch08a...

Quick | Advanced

Variables

Dependent: Y_EPAIS
Independent: X_PRESSI

Input file: Raw Data

Advanced options (stepwise or ridge regression)

Review descriptive statistics, correlation matrix

Extended precision computations

Batch processing/reporting

Print/report residual analysis

Specify all variables for the analysis; additional models (independent variables) can be specified later. For stepwise regression etc. check the advanced check box.

See also the General Regression Models (GRM) module.

OK
Cancel
Options

Multiple Regression Results: Ch13-regression.sta in ch08a14-MTH2302B-exemples.stw

Multiple Regression Results

Dependent: Y_EPAIS	Multiple R = ,83550998	F = 30,05733
	R ² = ,69807692	df = 1,13
No. of cases: 15	adjusted R ² = ,67485207	p = ,000105
	Standard error of estimate: 1,098950548	
Intercept: 15,500000000	Std. Error: 1,042556	t(13) = 14,867 p = ,0000

X_PRESSI b* = -.84

(significant b* are highlighted in red)

Alpha for highlighting effects: .05

Quick | Advanced | Residuals/assumptions/prediction


Summary: Regression results

OK
Cancel
Options
By Group

Regression Linéaire Simple : $Y = \beta_0 + \beta_1 X_1 + \varepsilon$

résultats

Exemple : épaisseur substrat
analyse avec le module
MULTIPLE REGRESSION
de **STATISTICA**



$r = -0.8355$ $R^2 = 0.698$
 $F(1,13)=30.057$ $p < 0.00011$

	b^*	Std. Err.	$b = \hat{\beta}$	Std. Err. b	t(13)	p-level
Intercept			15.500	1.0426	14.867	0.0000
X-pression	-0.8355	0.1524	-1.100	0.2006	-5.482	0.0001

$$b_0 = \hat{\beta}_0$$

test de
signification

$$b_1 = \hat{\beta}_1$$

coefficients
en variables
centrées - réduites

Regression Linéaire Simple : $Y = \beta_0 + \beta_1 X_1 + \varepsilon$


résultats

Exemple : épaisseur substrat

observés	prédits	résidus
14	12.2	1.8
12	12.2	-0.2
13	12.2	0.8
10	11.1	-1.1
9	11.1	-2.1
11	11.1	-0.1
9	10.0	-1.0
10	10.0	0.0
11	10.0	1.0
9	8.9	0.1
8	8.9	-0.9
10	8.9	1.1
8	7.8	0.2
9	7.8	1.2
7	7.8	-0.8

Tableau d'analyse de la variance

	SS	DDL	MS	F	p-valeur
Regress.	36.3	1	36.3	30.06	0.00011
Residuel	15.7	13	1.21		
Total	52	14			






Regression Linéaire Simple : $Y = \beta_0 + \beta_1 X_1 + \varepsilon$

VALIDATION du MODÈLE : ANALYSE des RÉSIDUS

- résidus VS valeurs prédites \hat{y} : variance constante ?
- résidus VS variable explicative X : variance constante ?
- résidus VS l'ordre des données : dépendance ?
- résidus sur échelle gaussienne : valeurs aberrantes ?

résultats



Résidus standardisés

$$z_i = e_i / \hat{\sigma} \quad \bar{z} = 0, \quad \text{écart type (z)} = 1$$

Résidus studentisés internes

$$t_i = e_i / \hat{\sigma} \left\{ \left[\frac{(n-1)}{n} + \frac{(x_i - \bar{x})^2}{SS_{xx}} \right]^2 \right\}$$

remarque : l'analyse des résidus peut se faire avec les


- résidus / résidus standardisés / résidus studentisés internes
- résidus studentisés externes ('deleted')
- **préférentiellement** : avec les résidus studentisés externes

Regression Linéaire Simple : $Y = \beta_0 + \beta_1 X_1 + \varepsilon$

résultats


	Y observé	Y prédit	résidu E	écart type Y prédit	Int. Prédiction à 95%		Int. confiance à 95%	
					lim inf Y	lim sup Y	lim inf Moy Y	lim sup Moy Y
1	14	12.2	1.8	0.49	9.60	14.8	11.1	13.3
2	12	12.2	-0.2	0.49	9.60	14.8	11.1	13.3
3	13	12.2	0.8	0.49	9.60	14.8	11.1	13.3
4	10	11.1	-1.1	0.35	8.61	13.6	10.3	11.9
5	9	11.1	-2.1	0.35	8.61	13.6	10.3	11.9
6	11	11.1	-0.1	0.35	8.61	13.6	10.3	11.9
7	9	10.0	-1.0	0.28	7.55	12.5	9.4	10.6
8	10	10.0	-0.0	0.28	7.55	12.5	9.4	10.6
9	11	10.0	1.0	0.28	7.55	12.5	9.4	10.6
10	9	8.9	0.1	0.35	6.41	11.4	8.1	9.7
11	8	8.9	-0.9	0.35	6.41	11.4	8.1	9.7
12	10	8.9	1.1	0.35	6.41	11.4	8.1	9.7
13	8	7.8	0.2	0.49	5.20	10.4	6.7	8.9
14	9	7.8	1.2	0.49	5.20	10.4	6.7	8.9
15	7	7.8	-0.8	0.49	5.20	10.4	6.7	8.9

Regression Linéaire Simple : $Y = \beta_0 + \beta_1 X_1 + \varepsilon$



intervalle de **confiance** :
moyenne de Y



intervalle de **prédiction** de Y



Autre exemple : prix maisons vs superficie







AREA m ²	PRICE K€
134	5 495
115	4 700
167	7 500
185	7 775
84	3 500
98	4 000
115	4 850
185	7 500
164	6 900
145	5 950
123	5 010
128	5 600
167	6 750
115	5 000
178	7 200
97	4 290



Regression Summary for Dependent Variable: PRICE (reg simple.sta in 2017-MTH8302-Exemples-REGRESSION.stw)						
R= ,9885756 R²= ,97728164 Adjusted R²= ,97565890 F(1,14)=602,24 p<,00000 Std.Error of estimate: 213,38						
	b*	Std.Err. of b*	b	Std.Err. of b	t(14)	p-value
Intercept			153,8133	234,2436	0,65664	0,522061
AREA	0,988576	0,040283	40,7086	1,6588	24,54061	0,000000

Analysis of Variance; DV: PRICE (reg simple.sta in 2017-MTH8302-Exemples-REGRESSION.stw)					
Effect	Sums of Squares	df	Mean Squares	F	p-value
Regress.	27419909	1	27419909	602,2418	0,000000
Residual	637416	14	45530		
Total	28057325				




JUSTESSE du MODÈLE: avec observations répétées de Y à des valeurs de X

Estimation de σ^2 : - calculée avec le modèle ajusté (Droite de Moindres Carrés)
- dépend du modèle postulé

question : peut-on estimer σ^2 indépendamment du modèle postulé ($y = \beta_0 + \beta_1 x + \varepsilon$) ?

réponse : **oui**, si on a au moins 2 observations de Y à au moins 3 valeurs distinctes de X

utilisation : tester le manque d'ajustement (maj) du modèle postulé



Données	somme carrés	ddl
$x_1 \rightarrow y_{11} \quad y_{12} \quad \dots \quad y_{1n_1}$	$(n_1 - 1) s_1^2$	$n_1 - 1$
$x_2 \rightarrow y_{21} \quad y_{22} \quad \dots \quad y_{2n_2}$	$(n_2 - 1) s_2^2$	$n_2 - 1$
.....
$x_k \rightarrow y_{k1} \quad y_{k2} \quad \dots \quad y_{kn_k}$	$(n_k - 1) s_k^2$	$n_k - 1$
SSE = $\sum (n_j - 1) s_j^2$		$n - k$

Nouvelle décomposition de la somme totale de carrés totale

avant : $SS_{tot} (totale) = SS_{reg} (modèle) + SS_{resid} (résiduelle)$

maintenant : $SS_{tot} = SS_{reg} + SS_{erpu} (erreur pure) + SS_{maj} (manque d'ajustement)$

deg. liberté : $n - 1 = 1 + (n - k) + (k - 2)$

remarque : SS_{maj} est calculée par différence $SS_{maj} = SS_{resid} - SS_{erpu}$

tableau d'analyse de la variance modifié

SOURCE	DDL	SS	MS = SS / DDL	F-ratio	p-valeur
modèle	1	SSreg	MSreg = SSreg/1	$F_1 = MSreg / MSresid$	$p_1 = P(F \geq F_1)$
résiduelle	n - 2	SSresid	MSresid = SSresid/(n-2)	-----	-----
{ LOF pure	k - 2	SSmaj	MSmaj = SSmaj/(k -2)	$F_2 = MSmaj / MSerpu$ -----	$p_2 = P(F \geq F_2)$ -----
	n - k	SSerpu	MSerpu = Sserpu / (n - k) = σ^2		
Totale	n - 1	SStot	-----		

test du manque d'ajustement du modèle linéaire

$$H_{0M} : E(Y | x) = \beta_0 + \beta_1 x \quad \text{versus} \quad H_1 : \text{non } H_{0M}$$

test : rejeter H_0 au seuil α si $F_2 > F_{n-k, k-2, 1-\alpha}$

remarques

- on rejette H_{0M} si $p_2 < \alpha$ (seuil)
- si on rejette H_{0M} , il faut postulé une autre équation (modèle) que la droite
- si on ne rejette pas H_{0M} , on conserve le tableau d'analyse de la variance (p 6)

RÉGRESSION LINÉAIRE SIMPLE : observations répétées

Exemple : expérience avec un facteur X contrôlé

X = température (degrés F)

Y = résistance matériau


données: X = 100 : Y = 20 – 25 – 23 – 27 – 19

X = 110 : Y = 25 – 29 – 31 – 30 – 27

X = 120 : Y = 36 – 37 – 29 – 40 – 33

X = 130 : Y = 35 – 39 – 31 – 42 – 44

X = 140 : Y = 43 – 40 – 36 – 48 – 47



R = 0,879 R² = 0,773 F(1,23)=78,323 p < 0,000

	b*	Std. Error	b	Std. Errorr	t(23)	p-level
Interct			-26.320	6.799	-3.87	0.0007
X_DEG	0.879	0.099	0.498	0.056	8.85	0.0000

ANOVA	SS	DF	MS	F	p-level
Regress.	1240.02	1	1240.02	78.323	0.0000
Residual	364.14	23	15.832		
Total	1604.16	24			

RÉGRESSION LINÉAIRE SIMPLE : observations répétées

Exemple : expérience avec un facteur X contrôlé (expérience)

X = température (degrés F) Y = résistance matériau

données: X = 100 : Y = 20 – 25 – 23 – 27 – 19 X = 110 : Y = 25 – 29 – 31 – 30 – 27

X = 120 : Y = 36 – 37 – 29 – 40 – 33 X = 130 : Y = 35 – 39 – 31 – 42 – 44

X = 140 : Y = 43 – 40 – 36 – 48 – 47

X_DEG	Y_STRENT Means	Y_STRENT Std.Dev.
100	22,8	3,35
110	28,4	2,41
120	35,0	4,18
130	38,2	5,26
140	42,8	4,97
All Grps	33,4	8,18

$$SS_{\text{Serpu}} = 4 (3,35^2 + 2,41^2 + \dots + 4,97^2)$$

$$= 347,6 \text{ avec } 4 \cdot 5 = 20 \text{ ddl}$$

$$SS_{\text{maj}} = SS_{\text{resid}} - SS_{\text{Serpu}} = 364,14 - 347,60$$

$$= 16,54 \text{ avec } 23 - 20 = 3 \text{ ddl}$$

$$MS_{\text{maj}} = 16,54 / 3 = 5,51$$

$$MS_{\text{Serpu}} = SS_{\text{Serpu}} / 20 = 17,38$$

$$F_2 = 5,51 / 17,38 = 0,32$$

modèle linéaire OK : pas rejeté

DÉFICIENCES DÉTECTÉES à l'analyse de résidus

correctifs et transformations

- rendre la **variance plus constante** (stabilisation de la variance)
- obtenir une **distribution gaussienne** pour le terme d'erreur
- **transformer** certains modèles non linéaires en modèles linéaires

TRANSFORMATIONS pour stabiliser la variance : $Y' = h(Y)$

<u>Cas</u>	<u>lien $\sigma^2 = \text{var}(Y)$ et $\mu = \text{moy}(Y)$</u>	<u>transformation Y'</u>
Y ~ Poisson	$\sigma^2 \propto \mu$	$Y' = Y^{0.5}$
Y ~ Binomiale	$\sigma^2 \propto \mu (1 - \mu)$	$Y' = \arcsin(Y^{0.5})$
plusieurs ordres de grandeurs pour Y	$\sigma^2 \propto \mu^2$	$Y' = \log(Y)$
autres cas: transformation Box-Cox		$Y' = Y^\lambda \quad -2 \leq \lambda \leq 2$ $\lambda = ?$

RÉGRESSION SIMPLE : transformations


TRANSFORMATIONS sur X ou Y pour rendre linéaire certains modèles

modèle originel	transformation	modèle linéaire	figure
$Y = \beta_0 X^{\beta_1}$	$X' = \ln(X)$ $Y' = \ln(Y)$	$\beta_0' = \ln(\beta_0)$ $Y' = \beta_0' + \beta_1 X'$	a
$Y = \beta_0 \exp(\beta_1 X)$	$X' = X$ $Y' = \ln(Y)$	$\beta_0' = \ln(\beta_0)$ $Y' = \beta_0' + \beta_1 X'$	b
$Y = 1 / (\beta_0 + \beta_1 X)$	$X' = X$ $Y' = 1 / Y$	$Y' = \beta_0 + \beta_1 X'$	c

Régression logistique : Y à 2 valeurs catégoriques (oui/non) (0, 1) d

$$Y = \frac{\exp(\beta_0 + \beta_1 x)}{1 + \exp(\beta_0 + \beta_1 X)}$$

linéarisation: $\log(Y/(1-Y)) = \beta_0 + \beta_1 x$






RÉGRESSION SIMPLE : transformations pour linéariser

Exemple: patients.sta
DAYS number of days that each patient was hospitalized
PROGNOSIS index of the prognosis for long-term recovery
 larger values reflect a better prognosis


Graphics ... 2D Scatterplots

Long term prognosis of severely injured patients

1 ID	2 Patient	3 DAYS	4 Y_PROGNOSIS
1	A	2	54
2	B	5	50
3	C	7	45
4	D	10	37
5	E	14	35
6	F	19	25
7	G	26	20
8	H	31	16
9	I	34	18
10	J	38	13
11	K	45	8
12	L	52	11
13	M	53	8
14	N	60	4
15	O	65	6




RÉGRESSION non linéaire avec Statistica




Nonlinear Estimation

**Fixed Nonlinear Regression:
transformations programmées**





Exemple: patients.sta ... Recherche une transformation des variables



identification de la transformation la plus utile avec la matrice de corrélation

Variable	Correlations (Patients.sta in Exemples REGRESSION-analyses.stw)							
	DAYS	PROGNOSIS	V1**2	V1**3	LN-V1	V2**2	V2**3	LN-V2
DAYS	1,000000	-0,941053	0,968107	0,914647	0,919686	-0,858993	-0,786973	-0,977280
PROGNOSIS	-0,941053	1,000000	-0,833385	-0,742322	-0,982535	0,976196	0,934715	0,949181
V1**2	0,968107	-0,833385	1,000000	0,985486	0,806789	-0,715873	-0,630328	-0,937609
V1**3	0,914647	-0,742322	0,985486	1,000000	0,718699	-0,613618	-0,528271	-0,880520
LN-V1	0,919686	-0,982535	0,806789	0,718699	1,000000	-0,980910	-0,958517	-0,910681
V2**2	-0,858993	0,976196	-0,715873	-0,613618	-0,980910	1,000000	0,988570	0,864646
V2**3	-0,786973	0,934715	-0,630328	-0,528271	-0,958517	0,988570	1,000000	0,793656
LN-V2	-0,977280	0,949181	-0,937609	-0,880520	-0,910681	0,864646	0,793656	1,000000

Nonlinear Estimation : specification du modèle par l'utilisateur



Exemple: patients.sta avec Fixed Nonlinear Regression

Long term prognosis of severely injured patients			
1 ID	2 Patient	3 DAYS	4 Y_PROGNOSIS
1	A	2	54
2	B	5	50
3	C	7	45
4	D	10	37
5	E	14	35
6	F	19	25
7	G	26	20
8	H	31	16
9	I	34	18
10	J	38	13
11	K	45	8
12	L	52	11
13	M	53	8
14	N	60	4
15	O	65	6

En Statistica, les variables, ont 2 noms
- celui qui est donné par l'utilisateur comme **ID, patient, DAYS, Y_PROGNOSIS**

- alias **v0, v1, v2, v3, v4** donné par Statistica

v0 = numéro de ligne


v1 = ID

v2 = patient

v3 = DAYS

v4 = Y_PROGNOSIS

**utilité : simplifie l'écriture des équations
comme dans l'exemple suivant**




Exemple: patients.sta avec Fixed Nonlinear Regression

Model is: $v4=a*\exp(b*v3)$ (Patients.sta in 2019-MTH8302-cours REGRESS)						
Dep. Var. : PROGNOSIS						
Level of confidence: 95.0% (alpha=0.050)						
	Estimate	Standard error	t-value df = 13	p-value	Lo. Conf Limit	Up. Conf Limit
a	58,60656	1,472155	39,8101	0,000000	55,42616	61,78696
b	-0,03959	0,001711	-23,1326	0,000000	-0,04328	-0,03589

Model is: $v4=a*\exp(b*v3)$ (Patients.sta in			
Dep. Var. : PROGNOSIS			
	Loss Function	a	b
1	128,6318	0,10000	0,100000
2	107,5159	0,48400	0,024948
3	106,0166	0,55084	0,041731
4	104,7397	0,80603	0,043587
5	103,0540	1,29923	0,032370
6	99,9276	2,29417	0,023877
7	94,5864	4,28583	0,013376
8	85,1784	8,27081	0,002636
9	69,0339	16,24156	-0,010138
10	41,8540	32,18361	-0,026108
11	10,6020	57,10354	-0,043433
12	7,0460	58,59191	-0,039305
13	7,0327	58,60049	-0,039576
14	7,0327	58,60635	-0,039586
15	7,0327	58,60656	-0,039586

Exemple: patients.sta avec Fixed Nonlinear Regression



Model is: $v4 = a \cdot \exp(b \cdot v3)$ (Patients.sta in 2019-MTH8302-cours REGRESS Dep. Var. : PROGNOSIS					
Effect	1 Sum of Squares	2 DF	3 Mean Squares	4 F-value	5 p-value
Regression	12060,54	2,00000	6030,270	1585,011	0,000000
Residual	49,46	13,00000	3,805		
Total	12110,00	15,00000			
Corrected Total	3943,33	14,00000			
Regression vs. Corrected Total	12060,54	2,00000	6030,270	21,409	0,000055

RÉGRESSION SIMPLE : modèle logistique

Si $Y = 0$ ou 1 peut-on faire de la régression?
Réponse: oui , régression logistique

Exemple : burns.sta
435 obs.
tableau 1 : données

patient	X_log(surf+1)	Y
1	1,35	0
...
34	1,75	1
...
434	2,35	0
435	2,35	1

tableau 2: résumé
(sans perte d'info)

id	X	Y	nombre
1	1,35	0	13
2	1,35	1	0
3	1,60	0	19
4	1,60	1	0
5	1,75	0	67
6	1,75	1	2
7	1,85	0	45
8	1,85	1	5
9	1,95	0	71
10	1,95	1	8
11	2,05	0	50
12	2,05	1	20
13	2,15	0	35
14	2,15	1	31
15	2,25	0	7
16	2,25	1	49
17	2,35	0	1
18	2,35	1	12

tableau 3 : réorganisation


	X	n_survit	n_décès	n_total	p_décès = n_décès / n_total
1	1,35	13	0	13	0,0000
2	1,60	19	0	19	0,0000
3	1,75	67	2	69	0,0290
4	1,85	45	5	50	0,1000
5	1,95	71	8	79	0,1013
6	2,05	50	20	70	0,2857
7	2,15	35	31	66	0,4697
8	2,25	7	49	56	0,8750
9	2,35	1	12	13	0,9231
	total	308	127	435	

$Y = 0$ si survit
 $= 1$ si décès

n = 435 adultes
traités pour des
brulures au 3ième
degré en fonction
de log(surface +1)
de brulure

3 méthodes d'ajustement

- Linéarisation
- Nonlinear estimation
- GLZ (linéaire généralisé)



fonction logistique

$$\pi(x) = \exp(\alpha + \beta x) / (1 + \exp(\alpha + \beta x))$$

- courbe en forme sigmoïdale
- $0 \leq \pi(x) \leq 1$ probabilités
- si x tends vers $-\infty$ $\pi(x)$ tend vers 0
- si x tends vers ∞ $\pi(x)$ tend vers 1
- si $x = -\alpha/\beta$ alors $\pi(x) = 0,5$
et la pente de $f(x)$ vaut $\beta/4$


$$\text{Prob}(Y = 1 \text{ si } X = x) = \pi(x) \\ = \exp(\alpha + \beta x) / (1 + \exp(\alpha + \beta x))$$

$$\text{Prob}(Y = 0 \text{ si } X = x) = 1 - \pi(x) \\ = 1 / (1 + \exp(\alpha + \beta x))$$

$$\log[\pi(x) / (1 - \pi(x))] = \alpha + \beta x$$

$$\log[\pi(x) / (1 - \pi(x))] = \text{logit}(\pi(x))$$

$\pi(x) / (1 - \pi(x))$: rapport des cotes
(odds ratio)



Interprétation du paramètre β

$$\text{logit}(\pi(x)) = \log[\pi(x) / (1 - \pi(x))] = \alpha + \beta x$$

$$\text{logit}(\pi(x+1)) = \log[\pi(x+1) / (1 - \pi(x+1))] = \alpha + \beta(x+1) = \alpha + \beta x + \beta$$

$$\beta = \text{logit}(\pi(x+1)) - \text{logit}(\pi(x))$$

$$= \log \left\{ \frac{[\pi(x+1) / (1 - \pi(x+1))] / \pi(x) / (1 - \pi(x))}{\pi(x) / (1 - \pi(x))} \right\}$$

$$= \log \{ \text{odds}(x+1) / \text{odds}(x) \}$$

$$e^\beta = \text{odds}(x+1) / \text{odds}(x) = \text{odds ratio} \quad (\text{ratio des cotes})$$

accroissement de la probabilité que $Y = 1$

si x augmente de 1

Tableau


i	X	p décès	logit(p) (obs)	logit(p) (pred)	p décès (pred)
1	1,35	0	indéfini	-7,816	0,0004
2	1,60	0	indéfini	-5,248	0,0053
3	1,75	0,0290	-3,540	-3,708	0,0235
4	1,85	0,1000	-2,197	-2,67	0,0621
5	1,95	0,1013	-2,183	-1,64	0,1538
6	2,05	0,2857	-0,916	-0,621	0,3329
7	2,15	0,4697	-0,092	0,406	0,5781
8	2,25	0,8750	2,10	1,434	0,7900
9	2,35	0,9231	2,485	2,461	0,9117

$$\text{logit}(p) = \ln[p/(1-p)]$$

logit(0) n'est pas défini

régression de logit(p)(obs) sur X
cas logit(p)(obs) défini i = 3, 4, ..., 7
 $u = \text{logit}(p)(\text{pred}) = -21,68 + 10,27 \cdot X$

utilisation de l'équation obtenue
pour tous les cas i = 1, 2, ..., 7
 $p_{\text{pred}} = \exp(u) / (1 + \exp(u))$



2 possibilités pour le calcul des prédictions

ajustement par linéarisation
équations linéaires – cas traité ici

ajustement par estimation **non linéaire**
équations **non linéaires** – page suivante

RÉGRESSION logistique : ajustement par estimation non linéaire

Exemple : burns.sta

tableau 1 : données

patient	X_log(surf+1)	Y	YC
1	1,35	0	1
.....			
34	1,75	1	0
.....			
434	2,35	0	1
435	2,35	1	0



Model: Logistic regression (logit)

nombre de 0 : 308 cas
nombre de 1 : 127 cas


Max likelihood

α β



Estimation - 23,73 11,15



RÉGRESSION logistique : ajustement par estimation non linéaire – module GLZ



Y - Parameter estimates (Burns all.sta) Modeled probability that Y = 0				
Effect	Level of Effect	Column	Estimate	Standard Error
Intercept		1	23,7271	2,357973
X		2	-11,1498	1,125685
Scale			1,0000	0,000000



remarque : codage employé par Statistica (page suivante)

RESPONSE CODES FOR 0 / 1 response variables

(source : Help de *Statistica*)

When selecting (or specifying via syntax) response codes for binomial response variables (e.g., for logit models), the two selected values (**numeric codes or text values**) are recoded for the analysis,

so that the **first code that is specified will be recoded to 1,**
and the **second value will be recoded to 0.**



For example, if you specified two text values *No* and *Yes*, then the first value (*No*) will be recoded for the analysis to 1, and the parameter estimates can be interpreted with respect to the probability of responding with *No*; so, if in such an analysis a positive parameter estimate is found for a particular predictor variable x_j , then it means that the more of x the greater is the likelihood of obtaining the response *No*.

Note that the default coding for binomial response variables in the ***Nonlinear Estimation module*** may not be the same as that performed in *GLZ*. One way to verify the particular coding that was performed is to review the spreadsheet of the predicted responses on the Resid 1 tab of the results dialog; that spreadsheet will report in the first column the recoded values (0 or 1) of the response variable.

Codes for dep. var. Logit and probit regression models, in a sense, predict probabilities underlying the dichotomous dependent variable, and these methods will produce predicted (expected) values in the range between 0 and 1 (for details, see **Common Nonlinear Regression Models**).

If the dependent variable is not coded in this way, that is, as 0 and 1, then you must specify the respective codes in the *Codes for dep. var.* boxes. To do this, double-click on this field (or press the F2 button on your keyboard) to display the variable dialog box or simply type in the two codes.

As the data are read, the dependent variable will then be transformed so that all values that match the first code become 0 (zero), and all values that match the second code become 1.

RÉGRESSION SIMPLE : estimation non linéaire

Pharmacologie.sta : estimation réponse à une dose de médicament

X DOSE	Y RESPONSE
1	0,5
2	2,3
3	3,4
4	24,0
5	54,7
6	82,1
7	94,8
8	96,2
9	96,4

Modèle

dose X - response Y (en %)



$$\text{response} = \beta_0 \left(1 - \frac{1}{1 + (\text{dose} / \beta_2)^{\beta_1}} \right)$$

non linéarisable

β_0 valeur à saturation


β_2 concentration quand Y = 50%

β_1 pente fonction



RÉGRESSION SIMPLE : estimation non linéaire

N=9	Response $= b_0 - b_0/(1+(Dose/b_2)**b_1)$ Loss: (OBS-PRED)**2 Final loss: 20,1880 R= 0,99932 Variance explained: 99,865%			
	b0	b2	b1	
	Estimate	99,54	4,80	6,76
	Std.Err.	1,57	0,05	0,43
	t(6)	63,33	95,13	15,80
	-95%CL	95,69	4,68	5,71
	+95%CL	103,39	4,92	7,81
	p-v alue	0,00	0,00	0,00



r	Model is: Response = $b_0 - b_0/(1+(Dose/b_2)**b_1)$		
	Observed	Predicted	Residuals
1	0,500	0,0025	0,4975
2	2,300	0,2669	2,0331
3	3,400	3,9845	-0,5845
4	24,000	22,4756	1,5244
5	54,700	56,6077	-1,9077
6	82,100	81,5184	0,5816
7	94,800	92,3411	2,4589
8	96,200	96,4906	-0,2906
9	96,400	98,1416	-1,7416

modélisation non linéaire

généralement avec des
études statistiques confirmatoires
 considération d'une ou plusieurs
 famille de modèles non linéaires

Modèles non linéaires

référence: Nonlinear Regression with Built-In Models p.101-122

JMP® 12 *Specialized Models*. Cary, NC: SAS Institute Inc., March 2015

Dans les sciences biologiques et les sciences de la vie, il existe des familles de fonctions de forme connue qui décrivent la relation entre 2 variables. Par exemple, les chercheurs en pharmacologie conduisent des expériences pour comprendre la force de la réponse en fonction de la concentration du médicament. La famille de fonctions logistiques est souvent employée pour l'étude de ce processus. Un autre exemple est l'utilisation des courbes de croissance exponentielle pour prédire le nombre de personnes d'une population en fonction du temps.

Description générale des fonctions

Courbes en forme de S croissantes ou décroissantes (sigmoïde)

- Fonctions logistiques, fonctions Gompertz ; ces fonctions ont une asymptote supérieure et une asymptote inférieure.
- Fonctions logistiques symétriques avec 2, 3 et 4 paramètres.
- Fonctions logistiques avec 5 paramètres, fonctions Gompertz : elles sont non symétriques.
- Fonctions logistiques avec 2 paramètres : la réponse doit être entre 0 et 1.

Courbes exponentielles de croissance et de décroissance

- Fonctions exponentielles, double exponentielle (bi-exponentielle), fonction mécanique de croissance.
- Fonctions exponentielles avec 2 et 3 paramètres ; la fonction avec 3 paramètres a une asymptote.
- Fonctions bi-exponentielle possède 2 procédés de croissance ou de décroissance.
- Fonctions mécaniques et fonctions exponentielle avec 3 paramètres : ces fonctions sont toujours croissantes mais le taux de croissance diminue et les fonctions ont une asymptote.

Courbes avec un pic

- Fonctions gaussiennes, fonctions de Lorentz ; ces fonctions sont croissantes jusqu'à un pic et ensuite elles sont décroissantes.
- La fonction gaussienne est la densité de Gauss (normale) à un facteur d'échelle près.
- La fonction de Lorentz est la densité de Cauchy à un facteur d'échelle près.

Courbes pharmacocinétique : étude de la concentration d'un médicament dans le corps

- Fonctions de dose orale avec 1 compartiment ou 2 compartiments (Bolus).
- Fonctions bi-exponentielle avec 4 paramètres.

Courbes Michaelis-Menten en cinétique biochimique.

Modèles non linéaires

Courbes sigmoïde : Logistic, Gompertz
Croissance / décroissance exponentielle:
 Exponentiel, Bi-exponentiel, mécanique
Modèles sommet : Gauss, Lorentz
Modèles pharmacocinétiques : 1-compartiment
 dose orale, dose Bolus 2-compartiment
 Bi-exponentielle 4P
Michaelis Menten: cinétique biochimique

Exponentielle 2P	$a\text{Exp}(bx)$	a échelle b taux croissance
Exponentielle 3P	$a + b\text{Exp}(cx)$	a asymptote b échelle c taux croissance
Bi Exponentielle 4P	$a\text{Exp}(-bx) + c\text{Exp}(-dx)$	a échelle 1 b taux décroissance 1 c échelle 2 d taux décroissance 2
Bi Exponentielle 5P	$a + b\text{Exp}(-cx) + d\text{Exp}(-fx)$	a asymptote b échelle 1 c taux décroissance 1 d échelle 2 f taux décroissance 2
Croissance mécanique	$a(1 - b\text{Exp}(-cx))$	a asymptote b échelle c taux croissance
Sommet Gauss	$a\text{Exp}\left(-\frac{1}{2}\left(\frac{x-b}{c}\right)^2\right)$	a sommet b point critique c taux croissance
Sommet Lorentz	$\frac{ab^2}{(x-c)^2 + b^2}$	a sommet b taux croissance c point critique

MODÈLE	FORMULE Y =	PARAMÈTRES
Polynômes	$\beta_0 + \sum_{i=1}^k \beta_i x^i$	
Logistique 2P	$\frac{1}{1 + \text{Exp}(-a(x-b))}$	a taux croissance b point d'inflexion
Logistique 3P	$\frac{c}{1 + \text{Exp}(-a(x-b))}$	a taux croissance b point inflexion c asymptote
Logistique 4P	$c + \frac{d-c}{1 + \text{Exp}(-a(x-b))}$	a taux croissance b point inflexion c asymptote inférieure d asymptote supérieure
Logistique 5P	$c + \frac{d-c}{(1 + \text{Exp}(-a(x-b)))^f}$	a taux croissance b point inflexion c asymptote inférieure d asymptote supérieure f puissance
Gompertz 3P	$a\text{Exp}(-\text{Exp}(-b(x-c)))$	a asymptote b taux croissance c point inflexion
Gompertz 4P	$a + (b-a)\text{Exp}(-\text{Exp}(-c(x-d)))$	a asymptote inférieure b asymptote supérieure c taux croissance d pont inflexion
dose orale 1 compartiment	$\frac{abc}{c-b}(\text{Exp}(-bx) - \text{Exp}(-cx))$	a aire courbe b taux élimination c taux absorption
dose Bolus 2 compartiments	$\frac{a}{\alpha-\beta}((\alpha-b)\text{Exp}(-\alpha x) - (\beta-b)\text{Exp}(-\beta x))$ $\alpha = \frac{1}{2}(b+c+d + \sqrt{(b+c+d)^2 - 4bd})$ $\beta = \frac{1}{2}(b+c+d - \sqrt{(b+c+d)^2 - 4bd})$	a concentration initiale b taux transfert In c taux transfert Out d taux élimination
Michaelis Menten	$\frac{ax}{b+x}$	a taux max réaction b infinité adverse

logiciel JMP

MODÈLE	FORMULE Y =	
Polynômes	$\beta_0 + \sum_{i=1}^k \beta_i x^i$	
Logistique 2P	$\frac{1}{1 + \text{Exp}(-a(x-b))}$	a taux croissance b point d'inflexion
Logistique 3P	$\frac{c}{1 + \text{Exp}(-a(x-b))}$	a taux croissance b point inflexion c asymptote
Logistique 4P	$c + \frac{d-c}{1 + \text{Exp}(-a(x-b))}$	a taux croissance b point inflexion c asymptote inférieure d asymptote supérieure
Logistique 5P	$c + \frac{d-c}{(1 + \text{Exp}(-a(x-b)))^f}$	a taux croissance b point inflexion c asymptote inférieure d asymptote supérieure f puissance
Gompertz 3P	$a \text{Exp}(-\text{Exp}(-b(x-c)))$	a asymptote b taux croissance c point inflexion
Gompertz 4P	$a + (b-a) \text{Exp}(-\text{Exp}(-c(x-d)))$	a asymptote inférieure b asymptote supérieure c taux croissance d point inflexion
Exponentielle 2P	$a \text{Exp}(bx)$	a échelle b taux croissance
Exponentielle 3P	$a + b \text{Exp}(cx)$	a asymptote b échelle c taux croissance
Bi-Exponentielle 4P	$a \text{Exp}(-bx) + c \text{Exp}(-dx)$	a échelle 1 b taux décroissance 1 c échelle 2 d taux décroissance 2
Bi-Exponentielle 5P	$a + b \text{Exp}(-cx) + d \text{Exp}(-fx)$	a asymptote b échelle 1 c taux décroissance 1 d échelle 2 f taux décroissance 2
Croissance mécanique	$a(1 - b \text{Exp}(-cx))$	a asymptote b échelle c taux croissance
Sommet Gauss	$a \text{Exp}\left(-\frac{1}{2} \left(\frac{x-b}{c}\right)^2\right)$	a sommet b point critique c taux croissance
Sommet Lorentz (Cauchy)	$\frac{ab^2}{(x-c)^2 + b^2}$	a sommet b taux croissance c point critique
dose orale 1 compartiment	$\frac{ab}{c-b} (\text{Exp}(-bx) - \text{Exp}(-cx))$	a aire courbe b taux élimination c taux absorption
dose Bolus 2 compartiments	$\frac{a}{\alpha - \beta} ((\alpha - b) \text{Exp}(-\alpha x) - (\beta - b) \text{Exp}(-\beta x))$ $\alpha = \frac{1}{2}(b + c + d + \sqrt{(b+c+d)^2 - 4bd})$ $\beta = \frac{1}{2}(b + c + d - \sqrt{(b+c+d)^2 - 4bd})$	a concentration initiale b taux transfert in c taux transfert out d taux élimination
Michaelis-Menten	$\frac{aX}{b + X}$	a taux max réaction b infinie adverse


Polynomial



$$\beta_0 + \sum_{i=1}^k \beta_i x^i$$

where k is the order of the p_i can also be fit using the Fit & platform.


Logistic 2P



$$\frac{1}{1 + \text{Exp}(-a(x-b))}$$

a = Growth Rate
b = Inflection Point


Logistic 3P



$$\frac{c}{1 + \text{Exp}(-a(x-b))}$$

a = Growth Rate
b = Inflection Point
c = Asymptote


Logistic 4P



$$c + \frac{d-c}{1 + \text{Exp}(-a(x-b))}$$

a = Growth Rate
b = Inflection Point
c = Lower Asymptote
d = Upper Asymptote


Logistic 5P



$$c + \frac{d-c}{(1 + \text{Exp}(-a(x-b)))^f}$$

a = Growth Rate
b = Inflection Point
c = Asymptote 1
d = Asymptote 2
f = Power


Gompertz 3P



$$a \text{Exp}(-\text{Exp}(-b(x-c)))$$

a = Asymptote
b = Growth Rate
c = Inflection Point


Gompertz 4P



$$a + (b-a) \text{Exp}(-\text{Exp}(-c(x-d)))$$

a = Lower Asymptote
b = Upper Asymptote
c = Growth Rate
d = Inflection Point


Exponential 2P



$$a \text{Exp}(bx)$$

a = Scale
b = Growth Rate

Exponential 3P



$$a + b \text{Exp}(cx)$$

a = Asymptote
b = Scale
c = Growth Rate


Biexponential 4P



$$a \text{Exp}(-bx) + c \text{Exp}(-dx)$$

a = Scale 1
b = Decay Rate 1
c = Scale 2
d = Decay Rate 2


Biexponential 5P



$$a + b \text{Exp}(-cx) + d \text{Exp}(-fx)$$

a = Asymptote
b = Scale 1
c = Decay Rate 1
d = Scale 2
f = Decay Rate 2


Mechanistic Growth



$$a(1 - b \text{Exp}(-cx))$$

a = Asymptote
b = Scale
c = Growth Rate

Two Compartment IV Bolus Dose




$$\frac{a}{\alpha - \beta} ((\alpha - b) \text{Exp}(-\alpha x) - (\beta - b) \text{Exp}(-\beta x))$$

$\alpha = \frac{1}{2}(b + c + d + \sqrt{(b+c+d)^2 - 4bd})$
 $\beta = \frac{1}{2}(b + c + d - \sqrt{(b+c+d)^2 - 4bd})$

a = Initial Concentration
b = Transfer Rate In
c = Transfer Rate Out
d = Elimination Rate


Michaelis-Menten



$$\frac{aX}{b + X}$$

a = Max Reaction Rate
b = Inverse Affinity


Gaussian Peak



$$a \text{Exp}\left(-\frac{1}{2} \left(\frac{x-b}{c}\right)^2\right)$$

a = Peak Value
b = Critical Point
c = Growth Rate


Lorentzian Peak



$$\frac{ab^2}{(x-c)^2 + b^2}$$

a = Peak Value
b = Growth Rate
c = Critical Point

One Compartment Oral Dose



$$\frac{abc}{c-b} (\text{Exp}(-bx) - \text{Exp}(-cx))$$

a = Area Under Curve
b = Elimination Rate
c = Absorption Rate

Critères pour la comparaison de modèles

AIC : Akaike Information Criterion

$$AIC = -2 \log(L) + 2k$$

L : vraisemblance maximisée k : nombre de paramètres du modèle

La déviance du modèle (- 2 log(L)) est pénalisée par 2 fois le nombre de paramètres k

L'AIC compromis entre le biais (qui diminue avec k) et la parcimonie

bon modèle : min (décrire les données avec le plus petit nombre de paramètres)

AICc : AIC corrigé

$$AICc = AIC + [2k(k - 1) / (n - k + 1)]$$

modification du critère Akaike pour des petits échantillons (n < 40k).

On doit avoir n ≥ k + 2. AICc est préférable à AIC pour de petits échantillons

AICc permet de comparer 2 modèles ou plus.

bon modèle : min

AICc Weight

Normalisation des valeurs **AICc** pour avoir une somme de 1

probabilité que le modèle est le meilleur parmi les modèles ajustés.

bon modèle : le plus près de 1

BIC : Bayesian Information Criterion

$$BIC = -2 * LL + k * \log(n)$$

mesure de comparaison entre modèles

bon modèle : min

SSE :

Sum of Square of Errors = somme différences entre Y observées et Y prédites

MSE :

Mean Square Error

valeur moyenne de SSE **bon modèle** : min

RMSE :

Root Mean Square Error

racine carrée de MSE **bon modèle** : min

R-Square : proportion de la variation de la variable de réponse expliquée par le modèle.

bon modèle : R-Square près de 1

Remarque



AIC ou AICc **préférable à R-square** car tient en compte le nombre de paramètres

Exemple : décroissance phosphates

1 ID	2 X7_CaOx10000	3 Y1_pHsat	4 Groupe	5 XA_col
1	0,018	11,16	20	1
2	1,209	10,51	20	1
3	2,678	9,84	20	1
4	4,145	9,58	20	1
5	5,611	9,25	20	1
6	0,008	11,23	20	2
7	0,748	10,59	20	2
8	1,482	9,88	20	2
9	2,216	9,85	20	2
10	2,949	9,38	20	2
11	0,016	11,22	35	1
12	1,495	9,68	35	1
13	2,962	9,20	35	1
14	4,429	9,30	35	1
15	5,895	9,00	35	1
16	0,006	11,07	35	2
17	0,745	10,11	35	2
18	1,479	9,64	35	2
19	2,213	9,33	35	2
20	2,946	8,99	35	2

71	0,014	11,07	110	1
72	0,515	10,33	125	1
73	1,404	9,74	125	1
74	2,872	9,68	125	1
75	4,343	9,05	125	1
76	0,005	10,80	125	2
77	0,453	10,59	125	2
78	0,770	10,17	125	2
79	1,359	9,33	125	2
80	2,095	9,20	125	2

groupe = 125




Exemple : décroissance phosphates

calculs avec JMP

groupe = 125

Modèle	AICc	Poids d'Akaike corrigé (AICc) 0...1	BIC	Somme des carrés des écarts (SSE)	Erreur quadratique moyenne (MSE)	RMSE	R carré
Exponentielle 2 paramètres	5,6468267	0,4565538	2,554582	0,3788521	0,0473565	0,2176155	0,9112445
Linéaire	6,3539489	0,3205843	3,2617042	0,4066115	0,0508264	0,2254472	0,9047411
Gompertz à 4 paramètres	9,1808096	0,0780005	-4,306265	0,1203669	0,0200611	0,1416374	0,9718011
Logistique à 4 paramètres	9,9208518	0,0538765	-3,566223	0,1296124	0,0216021	0,1469764	0,9696351
Exponentielle 3 paramètres	10,358711	0,0432832	3,5690516	0,3330639	0,0475806	0,2181297	0,9219715
Logistique à 3 paramètres	11,648305	0,0227137	4,8586452	0,3789081	0,0541297	0,232658	0,9112313
Gompertz à 3 paramètres	11,70708	0,0220559	4,9174208	0,3811417	0,0544488	0,2333427	0,9107081
Biexponentielle à 4 paramètres	15,771108	0,0028909	2,2840333	0,2326591	0,0387765	0,1969175	0,9454938
Logistique à 5 paramètres	24,26804	0,0000413	-1,91645	0,1214214	0,0242843	0,1558342	0,971554



Meilleur modèle :

Exponentiel à 2 paramètres

Coefficient	Estimation	Erreur standard
Échelle	10,88053	0,1125622
Taux de croissance	-0,000782	0,0000872

ANALYSE des EXEMPLES avec JMP

Exemple

Régression linéaire simple épaisseur

Régression logistique Burns

Non linéaire phosphates

data

reg simple - JMP Pro

	id	new2	AREA	PRICE	new5	X_PRESSI	Y_EPAIS	ORDRE	RESIDU
1	1	maison	134	5495	epaisseur	3	14	4	1.8
2	2		115	4700		3	12	3	-0.1999998
3	3		167	7500		3	13	8	0.8000002
4	4		185	7775		4	10	2	-1.1
5	5		84	3500		4	9	12	-2.1
6	6		98	4000		4	11	14	-0.1000004
7	7		115	4850		5	9	6	-1
8	8		185	7500		5	10	15	0
9	9		164	6900		5	11	7	1
10	10		145	5950		6	9	10	0.1000004
11	11		123	5010		6	8	5	-0.8999996
12	12		128	5600		6	10	1	1.1
13	13		167	6750		7	8	9	0.1999998
14	14		115	5000		7	9	11	1.2
15	15		178	7200		7	7	13	-0.8000002
16	16		97	4290					
17	17								
18	18								
19	19								

burns - JMP Pro

	id_patient	Surface	log(Surface+1)	X	10X	survit?	Y	Yc
1	1	4,1006532009691	1,6293686101503	1,6	160	oui	0	1
2	2	6,818745162709	2,0565240765546	2,05	205	oui	0	1
3	3	5,4860910214026	1,8696600413054	1,85	185	oui	0	1
4	4	4,0925310011067	1,627774956701	1,6	160	oui	0	1
5	5	6,8411251890701	2,0593823430785	2,05	205	oui	0	1
6	6	6,0806056563879	1,9573594487344	1,95	195	non	1	0
7	7	6,8408159450268	2,0593429035677	2,05	205	non	1	0
8	8	4,767476862857	1,7522346994161	1,75	175	oui	0	1
9	9	7,6260619485925	2,1547880798127	2,15	205	non	1	0
10	10	4,8685594426448	1,7696091936104	1,75	175	oui	0	1
11	11	3,9921514161059	1,6078669623591	1,6	160	oui	0	1
12	12	6,8012507254303	2,0542840702551	2,05	205	non	1	0
13	13	6,8984802474846	2,0666703672307	2,05	205	oui	0	1
14	14	5,4968440465237	1,8713165276891	1,85	185	oui	0	1
15	15	6,0834445538793	1,9577603083032	1,95	195	non	1	0
16	16	9,620563059878	2,3627920332292	2,35	235	non	1	0
17	17	5,4894791057518	1,8701822664397	1,85	185	oui	0	1
18	18	6,1675809577443	1,9695682138277	1,95	195	oui	0	1

	id_patient	Surface	log(Surface+1)	X	10X	survit?	Y	Yc
432	432	6,1358856048566	1,9651363644397	1,95	195	non	1	0
433	433	6,133507989848	1,9648031176181	1,95	195	oui	0	1
434	434	8,6294283451594	2,2648238621747	2,25	225	non	1	0
435	435	7,6371215838834	2,1560693772957	2,15	215	oui	0	1

phosphates - JMP Pro

	ID	X7_CaOx10000	Y1_pHSat	Groupe	XA_col
1	1	0,018	11,16	20	1
2	2	1,209	10,51	20	1
3	3	2,678	9,84	20	1
4	4	4,145	9,58	20	1
5	5	5,611	9,25	20	1
6	6	0,008	11,23	20	2
7	7	0,748	10,59	20	2
8	8	1,482	9,88	20	2
9	9	2,216	9,85	20	2
10	10	2,949	9,38	20	2
11	11	0,016	11,22	35	1
12	12	1,495	9,68	35	1
13	13	2,962	9,2	35	1
14	14	4,420	9,2	35	1

73	73	1,404	9,74	125	1
74	74	2,872	9,68	125	1
75	75	4,343	9,05	125	1
76	76	0,005	10,8	125	2
77	77	0,453	10,59	125	2
78	78	0,77	10,17	125	2
79	79	1,359	9,33	125	2
80	80	2,095	9,2	125	2

burns - JMP Pro

Fichier Édition Tables de données Lignes Colonnes Plan d'expérience Analyse Graphique Outils Afficher Fenêtre Aide

	id_patient	Surface	log(Surface+1)	X	10X	survit?	Y	Yc
1	1	4,1006532009691	1,6293686101503	1,6	160	oui	0	1
2	2	6,818745162709	2,0565240765546	2,05	205	oui	0	1
3	3	5,4860910214026	1,8696600413054	1,85	185	oui	0	1
4	4	4,0925310011067	1,627774956701	1,6	160	oui	0	1
5	5	6,8411251890701	2,0593823430785	2,05	205	oui	0	1
6	6	6,0806056563879	1,9573594487344	1,95	195	non	1	0
7	7	6,8408159450268	2,0593429035677	2,05	205	non	1	0
8	8	4,767476862857	1,7522346994161	1,75	175	oui	0	1
9	9	7,6260619485925	2,1547880798127	2,15	205	non	1	0
10	10	4,8685594426448	1,7696091936104	1,75	175	oui	0	1
11	11	3,9921514161059	1,6078669623591	1,6	160	oui	0	1
12	12	6,8012507254303	2,0542840702551	2,05	205	non	1	0
13	13	6,8984802474846	2,0666703672307	2,05	205	oui	0	1
14	14	5,4968440465237	1,8713165276891	1,85	185	oui	0	1
15	15	6,083444538793	1,9577603083032	1,95	195	non	1	0
16	16	9,620563059878	2,362792033292	2,35	235	non	1	0
17	17	5,4894791057518	1,8701822664397	1,85	185	oui	0	1
18	18	6,1675809577443	1,9695682138277	1,95	195	oui	0	1

Ajuster Y en fonction de Xx - Contextuel - JMP Pro

Modéliser la relation entre deux variables.

Sélectionner les colonnes

Définir les rôles des colonnes

Action

Y, Réponse: obligatoire facultatif

X, Facteur: obligatoire facultatif

Bloc: facultatif

Pondération: numérique facultatif

Fréquence: numérique facultatif

Par: facultatif

Logistique

logistique

Ajuster Y en fonction de Xx - Contextuel - JMP Pro

Modéliser la relation entre deux variables.

Sélectionner les colonnes

Définir les rôles des colonnes

Action

Y, Réponse: Yc facultatif


X, Facteur: X facultatif

Bloc: facultatif

Pondération: numérique facultatif

Fréquence: numérique facultatif

Par: facultatif



Itération(s)

Tester tout le modèle

Modèle	-Log- vraisemblance	Degrés de liberté	Khi deux	Prob. > khi deux
Différence	92,89696	1	185,7939	<,0001*
Complet	168,00193			
Réduit	260,89889			

R carré (U) 0,3561

AICc 340,032

BIC 348,155

Observations (ou sommes pondérées) 435

Détails de l'ajustement

Estimations des coefficients

Terme	Estimation	Erreur standard	Khi deux	Prob. > khi deux
Constante	-22,454537	2,2526374	99,36	<,0001*
X	10,5232724	1,0752925	95,77	<,0001*

Pour les logarithmes des odds de non/oui

Covariance des estimations

Exemple : décroissance phosphates



1 ID	2 X7_CaOx10000	3 Y1_pHsat	4 Groupe	5 XA_col
1	0,018	11,16	20	1
2	1,209	10,51	20	1
3	2,678	9,84	20	1
4	4,145	9,58	20	1
5	5,611	9,25	20	1
6	0,008	11,23	20	2
7	0,748	10,59	20	2
8	1,482	9,88	20	2
9	2,216	9,85	20	2
10	2,949	9,38	20	2
11	0,016	11,22	35	1
12	1,495	9,68	35	1
13	2,962	9,20	35	1
14	4,429	9,30	35	1
15	5,895	9,00	35	1
16	0,006	11,07	35	2
17	0,745	10,11	35	2
18	1,479	9,64	35	2
19	2,213	9,33	35	2
20	2,946	8,99	35	2

71	0,014	11,07	110	1
72	0,515	10,33	125	1
73	1,404	9,74	125	1
74	2,872	9,68	125	1
75	4,343	9,05	125	1
76	0,005	10,80	125	2
77	0,453	10,59	125	2
78	0,770	10,17	125	2
79	1,359	9,33	125	2
80	2,095	9,20	125	2

groupe = 125

ANALYSE des EXEMPLES avec JMP

st X7_CaOx10000; categorized by Groupe
18302-Exemples REGRESSION.stw 5v*80c




Exemple : décroissance phosphates

calculs avec JMP

groupe = 125

Modèle	AICc	Poids d'Akaike corrigé (AICc) 0...1	BIC	Somme des carrés des écarts (SSE)	Erreur quadratique moyenne (MSE)	RMSE	R carré
Exponentielle 2 paramètres	5,6468267	0,4565538	2,554582	0,3788521	0,0473565	0,2176155	0,9112445
Linéaire	6,3539489	0,3205843	3,2617042	0,4066115	0,0508264	0,2254472	0,9047411
Gompertz à 4 paramètres	9,1808096	0,0780005	-4,306265	0,1203669	0,0200611	0,1416374	0,9718011
Logistique à 4 paramètres	9,9208518	0,0538765	-3,566223	0,1296124	0,0216021	0,1469764	0,9696351
Exponentielle 3 paramètres	10,358711	0,0432832	3,5690516	0,3330639	0,0475806	0,2181297	0,9219715
Logistique à 3 paramètres	11,648305	0,0227137	4,8586452	0,3789081	0,0541297	0,232658	0,9112313
Gompertz à 3 paramètres	11,70708	0,0220559	4,9174208	0,3811417	0,0544488	0,2333427	0,9107081
Biexponentielle à 4 paramètres	15,771108	0,0028909	2,2840333	0,2326591	0,0387765	0,1969175	0,9454938
Logistique à 5 paramètres	24,26804	0,0000413	-1,91645	0,1214214	0,0242843	0,1558342	0,971554



Meilleur modèle :

Exponentiel à 2 paramètres

Coefficient	Estimation	Erreur standard
Échelle	10,88053	0,1125622
Taux de croissance	-0,000782	0,0000872