

# Master M2, SITN et Data Science, Université Claude Bernard, Lyon 1

Modèles de régression

année 2019-2020

Examen du 29 janvier 2020,  
Calculatrice autorisée  
Appareils connectables interdits.  
Durée 1h30.

*Note: Les trois exercices ont été traités avec le logiciel R. L'exercice 2 a été traité également avec le logiciel SAS. Vous trouvez les codes et les sorties associées sur les feuilles suivantes. Pour les tests d'hypothèse, il faut prendre le risque  $\alpha = 0.05$ .*

## Exercice 1.

Les données pour cet exercice proviennent du package MASS du logiciel R. Plus précisément, le tableau de données *coop* contient des expériences sur des essais en chimie analytique. Sept échantillons ont été envoyés à 6 laboratoires en 3 lots distincts. Chaque analyse a été dupliquée. Les variables mesurées sont:

*Conc:* la concentration du produit chimique étudié

*Lab:* le laboratoire, valeurs prises: L1, L2, L3, L4, L5, L6

*Spc:* l'échantillon, valeurs: S1, S2, S3, S4, S5, S6, S7

*Bat:* le lot, valeurs: B1, B2, B3.

- 1) En vous aidant du code R, donnez la forme statistique du modèle (M1). Il s'agit de quel type de modèle?
- 2) Testez si le modèle (M1) est significatif. (spécifiez: les hypothèses  $H_0$ ,  $H_1$ , les modèles correspondants, statistique de test et sa loi sous  $H_0$ , valeur de la statistique de test, conclusion)
- 3) Si le modèle (M1) est significatif, quelles sont les variables qui influent la concentration du produit chimique étudié? (il faut donner les détails seulement pour une seule variable. Ces détails sont: hypothèses  $H_0$ ,  $H_1$ , modèles correspondants, statistique de test et sa loi sous  $H_0$ , valeurs de la statistique, conclusion. Pour les autres variables explicatives, donnez seulement la conclusion)  
Donc, quelles sont les variables qu'il faut enlever du modèle?
- 4) Donnez les estimations des paramètres du modèle (M1). Interprétez ces estimations.
- 5) Donnez la qualité globale du modèle (M1). Interprétation.

## Exercice 2

Les données pour cet exercice proviennent du package MASS du logiciel R, le tableau *biopsy* contenant des données sur le cancer du sein suite à une biopsie pour 699 patientes.

Les variables mesurées sont:

*class:* prend deux valeurs: 1 pour cancer bénin et 2 pour cancer malin;

*V1:* épaisseur de la tumeur;

*V2:* uniformité de la taille des cellules;

*V3:* uniformité de la forme des cellules.

Pour cet exercice les logiciels R et SAS ont été utilisés. Pour répondre aux questions ils faudrait utiliser les sorties associées à ces deux logiciels.

- 1) Pour le modèle (M2), écrivez le modèle statistique correspondant. Il s'agit de quel type de modèle?
- 2) Testez si le modèle (M2) est significatif. (spécifiez: les hypothèses  $H_0$ ,  $H_1$ , les modèles correspondants, statistiques de test utilisées, conclusion).
- 3) Pour le modèle (M2), quelles variables ont une influence sur la probabilité que le cancer soit bénin? (donnez les détails suivants pour une seule variable explicative: les hypothèses  $H_0$ ,  $H_1$ , les modèles correspondants, statistique de test et sa loi sous  $H_0$ , conclusion. Pour les autres variables explicatives, donnez seulement la conclusion).
- 4) Donnez les estimations de tous paramètres du modèle (M2).
- 5) En considérant le modèle (M2), quelle est la probabilité que le cancer soit malin si on a mesuré les valeurs suivantes pour les variables explicatives:  $V1 = 3$ ,  $V2 = 1$ ,  $V3 = 1$ ? (vous donnez seulement l'expression de la probabilité, sans faire les calculs)
- 6) Considérons deux patientes qui ont les mêmes valeurs pour V1 et V2. En échange, la première patiente a  $V3 = 2$  et la deuxième patiente a  $V3 = 1$ . Pour laquelle des deux patientes, la probabilité d'avoir un cancer malin est plus grande? Justifiez votre réponse.
- 7) Réalisez une comparaison entre les vraies valeurs de la variable *class* et les valeurs prévues pour cette variable par le modèle (M2). Commentez la qualité du modèle (M2).

### Exercice 3

On utilise le même tableau de données de l'Exercice 2, complété avec plus les variables V4, ..., V9, qui sont toutes numériques. Par les modèles (M3) et (M4), la variable *V1* est modélisée fonction de V2, V3, ...V9.

- 1) Ecrivez la forme statistique du modèle (M3), qui est le même que le (M4). Il s'agit de quel type de modèle?
- 2) Quels sont les paramètres de ces modèles? Quelles sont les méthodes d'estimation des paramètres utilisées en (M3) et (M4)?
- 3) En se basant sur les sorties de la fonction "lm" et des deux graphiques obtenus pour les estimations des paramètres des deux modèles, comparez les estimations.

## LE CODE DU LOGICIEL R POUR LES EXERCICES 1, 2, 3

```
library(MASS)
library(car);
##### EXERCICE 1 #####
data(coop)
attach(coop)
Lab=factor(Lab); Spc=factor(Spc); Bat=factor(Bat);
m1=lm(Conc-Lab+Spc+Bat+Lab:Bat, contrasts = list(Bat=contr.sum, Spc=contr.sum,
Lab=contr.sum))
cat("\n SORTIES EXERCICE 1 \n")
print(Anova(m1,type="III"))
print(summary(m1))

##### EXERCICE 2 #####
data("biopsy")
attach(biopsy)
m2=glm(class ~ V1+V2+V3, family="binomial")
cat("\n SORTIES EXERCICE 2 \n")
summary(m2);

##### EXERCICE 3 #####
library(lqa)
pp=9/20; # c est la puissance de lambda
g=2/5;
n=nrow(biopsy)
la=n^{pp};
m3=lm(V1~V2+V3+V4+V5+V6+V7+V8+V9-1) # modele classique
cat("\n SORTIES EXERCICE 3 \n")
summary(m3)
c3=coef(m3) # estimations par moindres carrées
plot(c3)

wj=(1/abs(c3))^g; # les poids pour LASSO adaptatif
m4=lqa(V1~V2+V3+V4+V5+V6+V7+V8+V9-1,penalty=adaptive.lasso(lambda=la,
al.weights=wj),standardize=TRUE)
c4=m4$coef; # estimations par LASSO adaptatif
plot(c4)

par(mfrow=c(1,2))
plot(c3, xlab="numero Variable",main="Estimations par moindres carrées" );
plot(c4, xlab="numero Variable",main="Estimations par LASSO adaptatif")
```

## LE CODE SAS POUR L'EXERCICE 2

```
data exo2;
infile "exo2.txt" firstobs=2;;
input class V1 V2 V3; run;

proc logistic data=exo2 descending outest=tab1 covout;
model class=V1 V2 V3;
output out=outlog p=prev predprob=(individual crossvalidate); run;
run;
proc print data=outlog; run;
proc print data=tab1; run;
proc freq data=outlog;
table _FROM_*_INTO_; run;
```

# SORTIES SAS pour l'EXERCICE 2

## Le Système SAS

16:23 Monday, January 27, 2020

2

### La procédure LOGISTIC

Informations sur le modèle	
Table	WORK.EX02
Variable de réponse	class
Nombre de niveaux de réponse	2
Modèle	logit binaire
Technique d'optimisation	Score de Fisher

Profil de réponse	
Valeur ordonnée	Fréquence totale
1	241
2	458

La probabilité modélisée est class=2.

Etat de convergence du modèle	
Critère de convergence (GCONV=1E-8) respecté.	

Statistique d'ajustement du modèle		
Critère	Constante et Covariables uniquement	
AIC	902.527	197.997
SC	907.077	216.195
-2 Log L	900.527	189.997

Test de l'hypothèse nulle globale : BETAB=0				
Test	Khi2	Df	Pi > Khi2	
Rapport de vrais	710.5399	3	<.0001	
Score	522.6929	3	<.0001	
Wald	134.5168	3	<.0001	
Total	467	232	699	
	66.81	33.19	100.00	

## Le Système SAS

16:23 Monday, January 27, 2020

### La procédure LOGISTIC

Analyse des valeurs estimées du maximum de vraisemblance					
Paramètre	Df	Estimation	Erreur type	Khi2	Pi > Khi2
Intercept	1	-7.5916	0.6572	129.4460	<.0001
V1	1	0.5975	0.0988	36.5478	<.0001
V2	1	0.5535	0.1483	13.9320	0.0002
V3	1	0.7177	0.1542	21.6473	<.0001

Estimation du rapport de cotés		
Effet	Estimation du point	Intervalle de confiance de Wald à 95%
V1	1.817	1.497 - 2.206
V2	1.739	1.301 - 2.326
V3	2.050	1.515 - 2.773

Association des probabilités prédictes et des réponses observées			
Pourcentage concordant	98.8	D de Somers	0.977
Pourcentage discordant	1.1	Gamma	0.977
Pourcentage lié	0.1	Tau-a	0.442
Palès	110378	c	0.988

Fréquence Pourcentage Pct de ligne Pct de col.	Table de _FFROM_ par _INTO_				
	FFROM_Value (Valeur formatée de la réponse prédictée)	INTO_Value (Valeur formatée de la réponse observée)	1	2	Total
1	446	63.81	12	458	65.52
	97.38	95.50	5.17		
2	21	3.00	31.47	241	34.48
	8.71	91.29	4.50	94.83	
Total	467	232	699	100.00	
	66.81	33.19			

# SORTIES R : Pour les Exercices 1, 2, 3

## SORTIES EXERCICE 1 : Modèle (M1)

Anova Table (Type III tests)

```

Response: Conc
          Sum Sq Df F value Pr(>F)
(Intercept) 930.43 1 7685.0867 < 2.2e-16 ***
Lab        18.59  5 30.7140 < 2.2e-16 ***
Spc       1485.52 6 2044.9885 < 2.2e-16 ***
Bat        0.41  2 1.7114 0.182919
Lab:Bat    3.18 10 2.6226 0.004884 **
Residuals 27.60 228
...
Signif. codes: 0 0.001 0.01 0.05 0.1 1

```

Call:  
`lm(formula = Conc ~ Lab + Spc + Bat + Lab:Bat, contrasts = list(Bat = contr.sum, Spc = contr.sum, Lab = contr.sum))`

Residuals:

Min	1Q	Median	3Q	Max
-1.04631	-0.16175	0.00417	0.13053	1.85226

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	1.92151	0.02192	87.665	< 2e-16 ***
Lab1	-0.32794	0.04901	-6.691	1.70e-10 ***
Lab2	0.04564	0.04901	0.931	0.3528
Lab3	-0.32722	0.04901	-6.676	1.84e-10 ***
Lab4	0.45230	0.04901	9.228	< 2e-16 ***
Lab5	0.01135	0.04901	0.232	0.8171
Spc1	-1.41345	0.05369	-26.326	< 2e-16 ***
Spc2	-1.55567	0.05369	-28.975	< 2e-16 ***
Spc3	-0.84456	0.05369	-15.730	< 2e-16 ***
Spc4	-1.27956	0.05369	-23.832	< 2e-16 ***
Spc5	5.83988	0.05369	108.770	< 2e-16 ***
Spc6	-0.13567	0.05369	-2.527	0.0122 *
Bat1	-0.03068	0.03100	-0.990	0.3234
Bat2	0.05730	0.03100	1.849	0.0658 .
Lab1:Bat1	-0.02218	0.06931	-0.320	0.7492
Lab2:Bat1	0.122282	0.06931	1.772	0.0777 .
Lab3:Bat1	0.028533	0.06931	0.412	0.6810
Lab4:Bat1	0.12829	0.06931	1.851	0.0655 .

Call:  
`glm(formula = class ~ V1 + V2 + V3, family = "binomial")`

Residual standard error: 0.348 on 228 degrees of freedom  
Multiple R-squared: 0.982, Adjusted R-squared: 0.9802  
F-statistic: 541.4 on 23 and 228 DF, p-value: < 2.2e-16

SORTIES EXERCICE 2 : Modèle (M2)

Call:  
`glm(formula = class ~ V1 + V2 + V3, family = "binomial")`

Residuals:

Min	1Q	Median	3Q	Max
-3.5115	-0.1972	-0.0808	0.0257	2.8107

Coefficients:

	Estimate	Std. Error	t value	Pr(> z )
(Intercept)	-7.59180	0.66727	-11.377	< 2e-16 ***
V1	0.59749	0.09883	6.046	1.49e-09 ***
V2	0.55355	0.14830	3.733	0.00019 ***
V3	0.71769	0.15425	4.653	3.28e-06 ***
...				
Signif. codes:	0	0.001	0.01	0.05 0.1 1

Dispersion parameter for binomial family taken to be 1

Null deviance: 900.53 on 698 degrees of freedom  
AIC: 198

Residual deviance: 190.00 on 695 degrees of freedom  
AIC: 198

Number of Fisher Scoring iterations: 7

SORTIES EXERCICE 3

Call:  
 $\text{lm}(\text{formula} = \text{V1} - \text{v2} + \text{v3} + \text{v4} + \text{v5} + \text{v6} + \text{v7} + \text{v8} + \text{v9} - 1)$

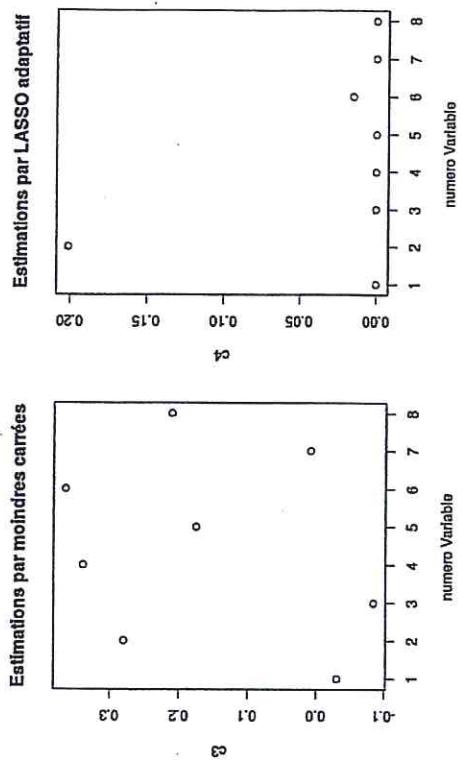
Residuals:

	Min	1Q	Median	3Q	Max
V2	-6.9551	-0.9673	0.6678	2.1140	7.0613

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
V2	-0.03019	0.07562	-0.399	0.689862
V3	0.28028	0.07534	3.720	0.000216 ***
V4	-0.08398	0.04862	-1.727	0.084614 *
V5	0.33877	0.05794	5.847	7.81e-09 ***
V6	0.17508	0.03845	4.554	6.26e-06 ***
V7	0.36486	0.05594	6.523	1.36e-10 ***
V8	0.00811	0.04517	0.180	0.857573
V9	0.21077	0.05970	3.530	0.000443 ***
---				
Signif. codes:	0	0.001	0.01	0.05 0.1 1

Residual standard error: 2.322 on 675 degrees of freedom  
 (16 observations deleted due to missingness)  
 Multiple R-squared: 0.8075, Adjusted R-squared: 0.8052  
 F-statistic: 353.9 on 8 and 675 DF, p-value: < 2.2e-16



$\uparrow$   
 CM3)

$\uparrow$   
 CM4)

Graphique coefficients estimés pour  
 CM3) et CM4)

## LE CODE DU LOGICIEL R POUR LES EXERCICES 1, 2, 3

```
library(MASS)
library(car);
#####
# EXERCICE 1 #####
data(coop)
attach(coop)
Lab=factor(Lab); Spc=factor(Spc); Bat=factor(Bat);
m1=lm(Conc~Lab+Spc+Bat+Lab:Bat, contrasts = list(Bat=contr.sum, Spc=contr.sum,
Lab=contr.sum))
cat("\n SORTIES EXERCICE 1 \n")
print(Anova(m1,type="III"))
print(summary(m1))

#####
# EXERCICE 2 #####
data("biopsy")
attach(biopsy)
m2=glm(class ~ V1+V2+V3, family="binomial")
cat("\n SORTIES EXERCICE 2 \n")
summary(m2);

#####
# EXERCICE 3 #####
library(lqa)
pp=9/20; # c est la puissance de lambda
g=2/5;
n=nrow(biopsy)
la=n^{pp};
m3=lm(V1~V2+V3+V4+V5+V6+V7+V8+V9-1) # modele classique
cat("\n SORTIES EXERCICE 3 \n")
summary(m3)
c3=coef(m3) # estimations par moindres carrées
plot(c3)

wj=(1/abs(c3))^{g}; # les poids pour LASSO adaptatif
m4=lqa(V1~V2+V3+V4+V5+V6+V7+V8+V9-1,penalty=adaptive.lasso(lambda=la,
al.weights=wj),standardize=TRUE)
c4=m4$coef; # estimations par LASSO adaptatif
plot(c4)

par(mfrow=c(1,2))
plot(c3, xlab="numero Variable",main="Estimations par moindres carrées" );
plot(c4, xlab="numero Variable",main="Estimations par LASSO adaptatif")
```

## LE CODE SAS POUR L'EXERCICE 2

```
data exo2;
infile "exo2.txt" firstobs=2;;
input class V1 V2 V3; run;

proc logistic data=exo2 descending outest=tab1 covout;
model class=V1 V2 V3;
output out=outlog p=prev predprob=(individual crossvalidate); run;
run;
proc print data=outlog; run;
proc print data=tab1; run;
proc freq data=outlog;
table _FROM_*_INTO_; run;
```

