

Quelques modèles linéaires généralisés

Cristian Preda

15/03/2021

Les modèles de régression

Soient

- ▶ Y la variable **réponse** et
- ▶ $X = (X_1, \dots, X_p)$ les variables **explicatives**

Un modèle de régression exprime le lien entre l'espérance conditionnelles de Y sachant $X = x$, $x = (x_1, \dots, x_p)$.

$$\mathbb{E}(Y|X = x) = f(x),$$

$f : \mathbb{R}^p \rightarrow \mathbb{R}$, fonction de régression

Quelques modèles classiques

- ▶ Le modèle logistique binaire

$$Y \in \{0, 1\}$$

$$\mathbb{E}(Y|X=x) = \mathbb{P}(Y=1|X=x)$$

$$\mathbb{P}(Y=1|X=x) = \frac{e^{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p}}{1 + e^{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p}},$$

ou

$$\log \left(\frac{\mathbb{P}(Y=1|X=x)}{\mathbb{P}(Y=0|X=x)} \right) = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p.$$

Quelques modèles classiques (cont.)

- Le modèle logistique binaire

Exemple:

```
d = read.table("http://math.univ-lille1.fr/~preda/GIS5/data_roc.txt", sep="\t", header=TRUE)
head(d,3)
```

	AGE	DIAB	PREMATURE
1	26	0	1
2	25	0	1
3	28	0	1

```
knitr::kable(table(d$PREMATURE), col.names = c("PREM", "proba"), align ="c")
```

PREM	proba
0	124
1	266

```
knitr::kable(prop.table(table(d$PREMATURE)), col.names = c("PREM", "proba"), align ="c")
```

PREM	proba
0	0.3179487
1	0.6820513

Quelques modèles classiques (cont.)

► Le modèle logistique binaire

Exemple (cont.)

```
m = glm(PREMATURE~AGE+as.factor(DIAB), family = "binomial", data = d)
summary(m)
```

```
Call:
glm(formula = PREMATURE ~ AGE + as.factor(DIAB), family = "binomial",
     data = d)
```

Deviance Residuals:

Min	1Q	Median	3Q	Max
-1.7916	-1.4227	0.8144	0.8883	1.0990

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	1.84558	0.57924	3.186	0.00144 **
AGE	-0.04146	0.02135	-1.942	0.05218 .
as.factor(DIAB)1	0.57163	0.67296	0.849	0.39565

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

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 487.74 on 389 degrees of freedom
Residual deviance: 483.45 on 387 degrees of freedom
AIC: 489.45

Number of Fisher Scoring iterations: 4

Quelques modèles classiques (cont.)

- Le modèle logistique binaire : qualité d'ajustement

Exemple (cont.)

McFadden's R^2 ou quantité de "deviance expliquée :

$$R^2 = 1 - \frac{LL(m)}{LL(m_{null})}$$

```
m_null = glm(PREMATURE~1, family = "binomial", data = d)
r2 = 1 - logLik(m)/logLik(m_null)
print(r2)
```

```
'log Lik.' 0.00881493 (df=3)
```

```
print((m>null.deviance - m$deviance)/m>null.deviance)
```

```
[1] 0.00881493
```

Le modèle semble assez mauvais! Un bon modèle à un $R^2 > 0.1$ (voir plus:
<http://eml.berkeley.edu/~mcfadden/travel.html>)

Quelques modèles classiques (cont.)

- ▶ Le modèle logistique binaire : qualité d'ajustement

Exemple (cont.)

Test de Hosmer-Lemeshow (goodness of fit):

```
library(ResourceSelection)
```

```
## ResourceSelection 0.3-5    2019-07-22
```

```
hoslem.test(m$y, fitted(m))
```

```
##  
##  Hosmer and Lemeshow goodness of fit (GOF) test  
##  
## data: m$y, fitted(m)  
## X-squared = 5.2652, df = 8, p-value = 0.7289
```

Quelques modèles classiques (cont.)

- ▶ Le modèle logistique binaire : qualité d'ajustement

La courbe ROC et AUC. (vu en cours de classification supervisée).

Voir aussi l'exemple dans :

http://math.univ-lille1.fr/~preda/GIS5/exemple_roc.R

Quelques modèles classiques (cont.)

► Le modèle logistique binaire

Un autre exemple :

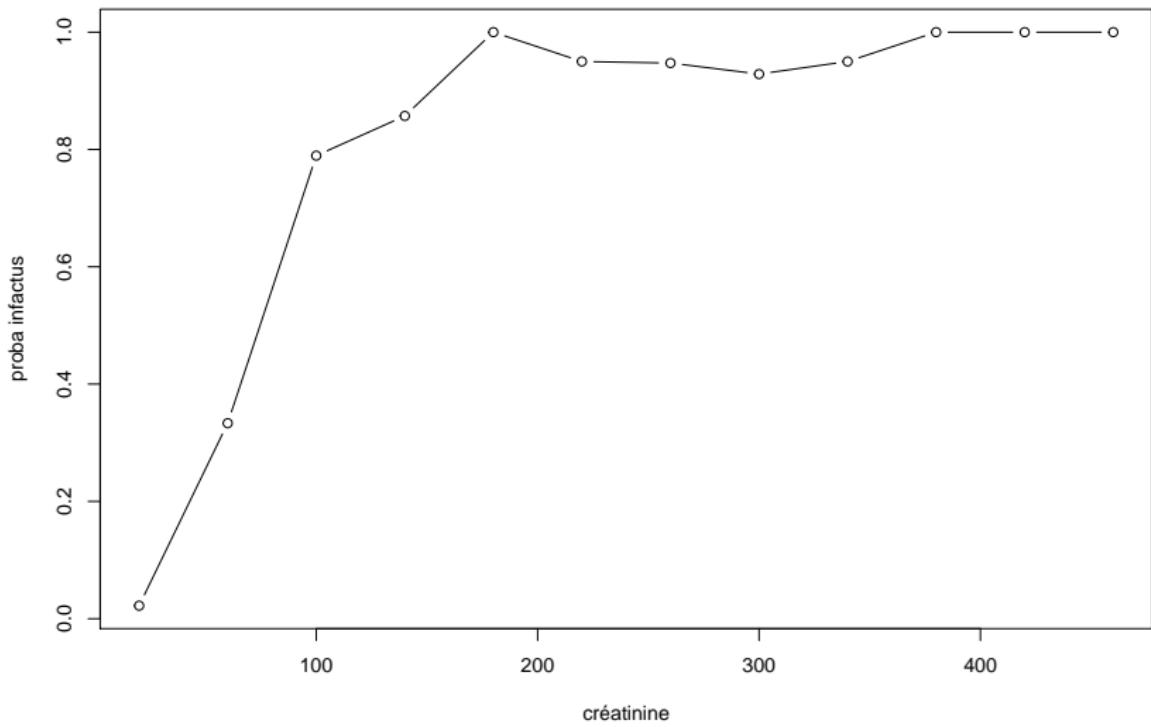
Les données (infarctus): un bon prédicteur pourrait être l'enzyme créatinine-Kinase (CK)

CK	nb_pat_infarctus	nb_pat_sans_infarctus
20	2	88
60	13	26
100	30	8
140	30	5
180	21	0
220	19	1
260	18	1
300	13	1
340	19	1
380	15	0
420	7	0
460	8	0

Quelques modèles classiques (cont.)

► Le modèle logistique binaire

```
p = d$nb_pat_infarctus/(d$nb_pat_infarctus+d$nb_pat_sans_infarctus)
plot(d$CK, p, xlab = "créatinine", ylab = "proba infarctus", type="b")
```



Quelques modèles classiques (cont.)

► Le modèle logistique binaire

```
m = glm(cbind(nb_pat_infarctus, nb_pat_sans_infarctus)~CK, family =binomial, data=d)
summary(m)
```

```
Call:
glm(formula = cbind(nb_pat_infarctus, nb_pat_sans_infarctus) ~
    CK, family = binomial, data = d)
```

```
Deviance Residuals:
```

Min	1Q	Median	3Q	Max
-3.08184	-1.93008	0.01652	0.41772	2.60362

```
Coefficients:
```

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-2.758358	0.336696	-8.192	2.56e-16 ***
CK	0.031244	0.003619	8.633	< 2e-16 ***

```
---
```

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

```
(Dispersion parameter for binomial family taken to be 1)
```

```
Null deviance: 271.712 on 11 degrees of freedom
Residual deviance: 36.929 on 10 degrees of freedom
AIC: 62.334
```

```
Number of Fisher Scoring iterations: 6
```

Quelques modèles classiques

- ▶ Régression logistique multinomiale

$$Y \in \{1, 2, \dots, K\}, \quad K \geq 2.$$

On choisit une modalité de référence : 1

$$\log \left(\frac{\mathbb{P}(Y = i|X = x)}{\mathbb{P}(Y = 1|X = x)} \right) = \beta_{i0} + \beta_{i1}x_1 + \dots + \beta_{ip}x_p, \quad i = 2, \dots, K$$

Quelques modèles classiques

- ▶ Régression logistique multinomiale

Exemple : évaluation des vins

```
library(ordinal)
library(nnet)
data("wine", package="ordinal")
head(wine)
```

	response	rating	temp	contact	bottle	judge
1	36	2	cold	no	1	1
2	48	3	cold	no	2	1
3	47	3	cold	yes	3	1
4	67	4	cold	yes	4	1
5	77	4	warm	no	5	1
6	60	4	warm	no	6	1

Quelques modèles classiques

► Régression logistique multinomiale

Exemple : évaluation des vins

```
m =multinom(rating~temp, data = wine)
```

```
# weights: 15 (8 variable)
initial value 115.879530
iter 10 value 90.682525
final value 90.134520
converged
```

```
summary(m)
```

```
Call:
multinom(formula = rating ~ temp, data = wine)
```

```
Coefficients:
(Intercept) tempwarm
2 1.1630698 7.147386
3 0.9552492 8.128180
4 -0.9165646 9.738184
5 -8.4736298 16.937776
```

```
Std. Errors:
(Intercept) tempwarm
2 0.5123225 26.04038
3 0.5262232 26.03893
4 0.8366930 26.04750
5 30.9428493 40.43853
```

```
Residual Deviance: 180.269
```

Quelques modèles classiques

- ▶ Régression logistique multinomiale **ordinale**

$$Y \in \{1, 2, \dots, K\}, \quad K \geq 2.$$

$$1 < 2 < \dots < K$$

$$\log \left(\frac{\mathbb{P}(Y \leq j | X = x)}{\mathbb{P}(Y > j | X = x)} \right) = \theta_j - \beta_1 x_1 - \dots - \beta_p x_p, \quad j = 1, \dots, K-1.$$

Interprétation de β_i :

$$\exp(-\beta_i) = \frac{\frac{\mathbb{P}(Y \leq j | X_i = x_i + 1)}{\mathbb{P}(Y > j | X_i = x_i + 1)}}{\frac{\mathbb{P}(Y \leq j | X_i = x_i)}{\mathbb{P}(Y > j | X_i = x_i)}}$$

}

https://cran.r-project.org/web/packages/ordinal/vignettes/clm_article.pdf

Quelques modèles classiques

► Régression de Poisson

Y = variable quantitative à valeurs dans $\{0, 1, \dots\}$

$$Y \sim \mathcal{P}(\lambda)$$

$$P(Y = k) = e^{-\lambda} \frac{\lambda^k}{k!}.$$

$$E(Y) = Var(Y) = \lambda.$$

Modèle de Poisson :

$$\log(\lambda|X = x) = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p.$$

Exemple :

<https://stats.idre.ucla.edu/r/dae/poisson-regression/>