

# TP d'Econométrie II avec le logiciel R

## Moindres carrés non-linéaires

L'objectif de ce TP est de se familiariser avec l'étude des modèles semi-paramétriques non-linéaires et qui ne peuvent pas se transformer en un modèle linéaire.

### Un exemple simulé

On commence par étudier un modèle souvent utilisé pour modéliser les croissances de populations. Ainsi, tape-t-on les commandes suivantes:

```
library(car)
n=100
x=1:n; eps=rnorm(n,0,1)
Y=4/(1+exp(-(-5+0.3*x)))+eps
ts.plot(Y)
dataY=data.frame(x,Y)
Y.nls=nls(Y ~ theta1/(1+exp(-(theta2+theta3*x))),
start=list(theta1 = 10, theta2 = 0, theta3 = 0.1),data=dataY,trace=TRUE)
summary(Y.nls); plot(Y.nls)
```

Quel est le modèle simulé? Comment sont calculées les p-values? Que concluez-vous? Changer l'initialisation de l'algorithme. Changez également le bruit du modèle. Que constatez-vous? Augmentez la taille de l'échantillon. Que constatez-vous? Faire une boucle de manière à tracer des histogrammes des estimateurs. Quel est le coefficient de détermination  $R^2$  pour une telle estimation?

### Un exemple sur données réelles

On travaille sur une base de données précisant l'évolution du poids de rats (l'étude statistique qui suit est due à Marc Lavielle, DR INRIA Polytechnique).

```
data.rat <- read.csv("ratWeight.csv")
data.select <- subset(data.rat, gender=="Female" & regime=="Control")
library(ggplot2); theme_set(theme_bw())
ggplot(data=data.select, aes(x=week, y=weight)) + geom_point() + geom_line() + facet_wrap(~id)
```

Qu'a-t-on fait? Que déduire?

On s'intéresse à un rat particulier:

```
di <- subset(data.select, id=="B38837")
pl <- ggplot(data=di) + geom_point(aes(week,weight), size=3, colour="#993399"); pl
poly2 <- lm(weight ~ poly(week,2,raw=T), data=di)
poly3 <- lm(weight ~ poly(week,3,raw=T), data=di)
poly4 <- lm(weight ~ poly(week,4,raw=T), data=di)
poly5 <- lm(weight ~ poly(week,5,raw=T), data=di)
poly.df <- data.frame(week=seq(0,18,by=0.5))
poly.df$p2 <- predict(poly2,poly.df)
poly.df$p3 <- predict(poly3,poly.df)
poly.df$p4 <- predict(poly4,poly.df)
poly.df$p5 <- predict(poly5,poly.df)
```

```

library(reshape2)
poly.df <- melt(poly.df, id="week", variable.name = "model", value.name = "prediction")
print(ggplot() +
  geom_line(data=poly.df, aes(x=week,y=prediction,colour=model), size=0.75) +
  geom_point(data=di, aes(x=week,y=weight), colour="black", size=3) +
  geom_point(data=di, aes(x=week,y=weight), colour="white", size=2) )
merge(AIC(poly2,poly3,poly4,poly5),BIC(poly2,poly3,poly4,poly5))

```

Qu'a-t-on fait? Que pensez vous de cette modélisation?

On utilise désormais un modèle non-linéaire:

```

nls1 <- nls(weight ~ A*exp(-b*exp(-k*week)), data=di, start=c(A=500, b=0.8, k=0.1))
summary(nls1)
nlreg.df <- data.frame(week=seq(0,25,by=0.5))
nlreg.df$f1 <- predict(nls1,nlreg.df)
pl + geom_line(data=nlreg.df, aes(x=week,y=f1), colour="#339900", size=1)

```

Quel est le modèle? Qu'en pensez-vous?

On propose deux autres modèles non linéaires:

```

nls2 <- nls(weight ~ A*(1-b*exp(-k*week)), data=di, start=c(A=500, b=0.8, k=0.1))
nls3 <- nls(weight ~ A/(1+ exp(-gamma*(week-tau))), data=di, start=c(A=500, gamma=0.8, tau=0))
nlreg.df$f2 <- predict(nls2,nlreg.df)
nlreg.df$f3 <- predict(nls3,nlreg.df)
nlreg.df <- melt(nlreg.df, id="week", variable.name = "model", value.name = "prediction")
pl + geom_line(data=nlreg.df, aes(x=week,y=prediction,colour=model), size=0.75)
cbind(AIC(nls1,nls2,nls3),BIC(nls1,nls2,nls3))
par(mfrow=c(1,2))
plot(predict(nls2), di$weight)
abline(a=0, b=1, lty=1, col="magenta")
residual.nls2 <- resid(nls2)/sd(resid(nls2))
plot(predict(nls2), residual.nls2)
abline(a=0, b=0, lty=2, col="magenta")

```

Quelle conclusion?

## Exercice

Recommencer avec une simulation du modèle  $Y_i = \theta_1 + \theta_2 * x_i^{\theta_3} + \varepsilon_i$ . On commencera par le cas  $\theta_1 = 2$ ,  $\theta_2 = 0.1$ ,  $\theta_3 = 0.2$  et  $\varepsilon_i \sim \mathcal{U}[-5,5]$ . Estimer les paramètres et interpréter les tests et graphique. Faire ensuite une transformation de Box-Cox pour retrouver  $\theta_3$  et ensuite effectuer une régression linéaire pour obtenir  $\theta_1$  et  $\theta_2$ . Conclusions? Recommencer plusieurs fois.