

DEA Analyse et Modélisation des Systèmes Biologiques

Introduction au logiciel S-PLUS©

D. Chessel

3 - Modèle linéaire

Résumé

La fiche contient le matériel nécessaire pour une séance de travaux dirigés sur S-PLUS consacrée au modèle linéaire. Elle illustre le cours de J.D. Lebreton, en particulier la régression simple, l'analyse de variance et de covariance et introduit au modèle linéaire multiplicatif.

Plan


1 - Régression simple	2
2 - Analyse de variance	7
3 - Densités de probabilité	11
3.1 - Loi de Gauss bivariée	11
3.2 - Types de lignes et de caractères :	11
3.3 - Loi de Student	12
4 - Analyse de covariance	13
4.1 - Une seule droite de régression	13
4.2 - L'effet du facteur	14
4.3 - Droites parallèles :	14
4.4 - Interaction	15
5 - Interaction sans répétition	16
5.1 - Modèle $y_{ij} = \mathbf{m} + a_i + b_j + \mathbf{e}_{ij}$	16
5.2 - Modèle $y_{ij} = \mathbf{m}a_i b_j + \mathbf{e}_{ij}$	17

1 - Régression simple

Lancer S-PLUS et s'assurer qu'on est bien dans le dossier de travail désiré :
Working data will be in D:\Data\DEA1_Data

Planter le premier exemple proposé par Tomassone R., Charles-Bajard S. & Bellanger L. (1998) Introduction à la planification expérimentale, DEA « Analyse et modélisation des systèmes biologiques »:

```
> Y  
[1] -0.6 7.9 10.5 15.4 20.3 23.8 28.8 34.7 39.1 45.4  
> x<-seq(from=0,to=45,by=5)  
> x  
[1] 0 5 10 15 20 25 30 35 40 45  
> plot(x,y)
```



lm

```
> ?lm
```

DESCRIPTION

Returns an object of class "lm" or "m1m" that represents a fit of a linear model.

USAGE

```
lm(formula, data=<<see below>>, weights=<<see below>>,  
subset=<<see below>>, na.action=na.fail, method="qr", model=F,  
x=F, y=F, contrasts=NULL, ...)
```

REQUIRED ARGUMENTS

formula a formula object, with the response on the left of a ~ operator, and the terms, separated by + operators, on the right.

```
> lm(y~x)  
Call:  
lm(formula = y ~ x)
```

Coefficients:
(Intercept) x
0.7909 0.9662

```
Degrees of freedom: 10 total; 8 residual
```

```
Residual standard error: 1.164
```

Un modèle linéaire est un objet

```
> lm1<-lm(y~x)
> lm1
Call:
lm(formula = y ~ x)

Coefficients:
(Intercept)      x
0.7909  0.9662

Degrees of freedom: 10 total; 8 residual
Residual standard error: 1.164
```

lm1 est de la classe lm

```
> class(lm1)
[1] "lm"
```

La classe lm est une sous-classe de la classe list

```
> is.list(lm1)
[1] T
```

lm1 est une collection de 11 composantes

```
> length(lm1)
[1] 11
> names(lm1)
[1] "coefficients"   "residuals"        "fitted.values"  "effects"
[5] "R"               "rank"            "assign"          "df.residual"
[9] "contrasts"       "terms"           "call"
```

Noms et numéros des composantes de lm1

```
> lm1[[1]]
(Intercept)      x
0.7909  0.9662
> lm1$coefficients
(Intercept)      x
0.7909  0.9662
> lm1[[2]]
     1     2     3     4     5     6     7     8     9
-1.391 2.278 0.04727 0.1164 0.1855 -1.145 -0.9764 0.09273 -0.3382
     10
1.131
> lm1$residuals
     1     2     3     4     5     6     7     8     9
-1.391 2.278 0.04727 0.1164 0.1855 -1.145 -0.9764 0.09273 -0.3382
     10
1.131
```

Le calcul est possible sur les composantes

```
> 2*lm1[[1]]
(Intercept)      x
1.582  1.932
```

Fonctions génériques : summary

```
> summary(y)
Min. 1st Qu. Median Mean 3rd Qu. Max.
-0.6    11.7    22 22.5    33.2 45.4

> summary(lm1)
```

```

Call: lm(formula = y ~ x)
Residuals:
    Min      1Q  Median      3Q     Max 
 -1.39 -0.817   0.07  0.168  2.28 

Coefficients:
            Value Std. Error t value Pr(>|t|)    
(Intercept) 0.791   0.684     1.156   0.281    
x            0.966   0.026     37.691  0.000 *** 
                                          
Residual standard error: 1.16 on 8 degrees of freedom
Multiple R-Squared:  0.994 
F-statistic: 1420 on 1 and 8 degrees of freedom, the p-value is 2.69 
e-010

Correlation of Coefficients:
(Intercept) 
x           -0.843

```

L'ordonnée à l'origine n'est pas significativement non nulle :

```

> lm2<-lm(y~1+x)
> lm2
Call:
lm(formula = y ~ -1 + x)

Coefficients:
x
0.9912

Degrees of freedom: 10 total; 9 residual
Residual standard error: 1.186
> summary(lm2)

Call: lm(formula = y ~ -1 + x)
Residuals:
    Min      1Q  Median      3Q     Max 
 -0.979 -0.587   0.243  0.574  2.94 

Coefficients:
            Value Std. Error t value Pr(>|t|)    
x  0.991   0.014     70.560   0.000 *** 
                                          
Residual standard error: 1.19 on 9 degrees of freedom
Multiple R-Squared:  0.998 
F-statistic: 4980 on 1 and 9 degrees of freedom, the p-value is 1.17 
e-013

```

Fonctions génériques : plot

> ?plot

DESCRIPTION

Creates a plot on the current graphics device.

This function is generic (see Methods); method functions can be written to handle specific classes of data. Classes which already have methods for this function include:
data.frame, design, factor, formula, gam, glm, lm, loess, preplot.gam, preplot.loess, profile, stl, surv.fit, times, tree, tree.sequence.

USAGE

plot(x, ...)

REQUIRED ARGUMENTS

x an S-PLUS object.

```
> ?plot.lm
```

DESCRIPTION

Creates a set of plots suitable for assessing a fitted linear model of class "lm".


USAGE

```
plot.lm(lm.obj, residuals = NULL, smooths = F, rugplot = F,
id.n = 3, ask = F, ...)
```

REQUIRED ARGUMENTS

lm.obj an lm object.

```
> plot(lm1) Que se passe t'il ?
> plot(lm1,ask=T)
> par(mfrow=c(3,2)) Pourquoi ?
> plot(lm1)
```



Graphique standard associé à un modèle linéaire

- 1) Résidus en fonction des valeurs prédictes
- 2) Racine des valeurs absolues des résidus en fonction des valeurs prédictes
- 3) Valeurs observées en fonction des valeurs prédictes
- 4) Graphique quantile-quantile normal des résidus (normalité des résidus). N.B. Chacun des graphiques proposés est issu d'une recherche approfondie. Le qq-plot est de Wilk M.B. & Gnanadesikan R. (1968). Probability plotting methods for the analysis of data. Biometrika, 55, 1-17 validé par Cleveland W.S. (1994) The elements of graphing data. Hobart Press, Summit, New Jersey, p. 143. Les modes de lecture sont décrits dans des ouvrages célèbres comme Tuckey J.W. (1977) Exploratory data analysis, Adisison-Wesley, Reading, Massachussets. Ici, les résidus sont sur-dispersés

par rapport à une loi normale (cf. du Toit S.H.C., Steyn A.G.W. & Stumpf R.H. (1986) Graphical Exploratory data analysis, Springer-Verlag, , New-York, p. 49). Ouvrages classiques : Chambers J.M., Cleveland W.S., Kleiner B. & Tukey P.A. (1983) Graphical methods for data analysis, Wadsworth, Belmont, California. Cleveland W.S. (1993) Visualizing data, Hobart Press, Summit, New Jersey.

5) graphique rf (r pour residuals, f pour fitted). A gauche, en abscisse le rang des valeurs prédictes sur $[0,1]$, en ordonnée les valeurs prédictes centrées (fonction de répartition inversée des prédictions). A droite à la même échelle en abscisse le rang des résidus sur $[0,1]$, en ordonnée les valeurs observées des résidus (fonction de répartition inversée des résidus). Le couple permet de comparer l'étendue de la distribution des observations qu'on espère beaucoup plus grande que celle des résidus. Ce graphe exprime le rapport variance expliquée - variance résiduelle.

6) Graphe des distances de Cook. Donne pour chacun des points de mesure la distance entre les paramètres estimés par la régression avec et sans ce point. Si l'importance du rôle de chaque point est concentré sur quelques valeurs, la régression n'est pas bonne (prise en compte de points aberrants). Voir Cook, R. D. and Weisberg, S. (1982). Residuals and Influence in Regression. Chapman and Hall, New York.

```
> cor(x,y)
[1] 0.997
> cor(x,y)*cor(x,y)
[1] 0.994
```

On peut refaire l'expérience :


```
> x
[1] 0 5 10 15 20 25 30 35 40 45
```

rnorm

```
> e<-rnorm(10)
> e
[1] 0.008629 -0.038239 -1.016802 -0.132446 -0.360349 -0.033747
[7] -1.883161 0.336839 -0.000354 1.206677
```

Calcul vectoriel

```
> y<-x+e
> y
[1] 0.008629 4.961761 8.983198 14.867554 19.639651 24.966253
[7] 28.116839 35.336839 39.999646 46.206677
> par(mfrow=c(1,1)) (Sinon que se passe t'il ?)
> plot(x,y)
> abline(0,1)
```



abline

```
> ?abline
> abline(lm(y~x)) est-ce possible ?
> abline(lm(y~-1+x)) est-ce possible ?
```

2 -Analyse de variance

Reprendre l'exemple introduit dans la fiche 1 (p. 3).

lm, anova

La richesse dépend de l'heure :

```
> lm1<-lm(ric~heu.fac)
> anova(lm1)
Analysis of Variance Table

Response: ric

Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value Pr(F)
heu.fac     1      3071    3071   208.7   0
Residuals 1313     19325       15
```

La richesse dépend de la semaine :

```
> lm2<-lm(ric~heu.fac+sem.fac)
> anova(lm2)
Analysis of Variance Table

Response: ric

Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value Pr(F)
heu.fac     1      3071    3071   293.8   0
sem.fac    51      6133     120    11.5   0
Residuals 1262     13192       10
```

La richesse dépend de la station :

```
> lm3<-lm(ric~heu.fac+sem.fac+sta.fac)
> anova(lm3)
Analysis of Variance Table

Response: ric

Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value Pr(F)
heu.fac     1      3071    3071   396.6   0
sem.fac    51      6133     120    15.5   0
sta.fac    13      3519     271    35.0   0
Residuals 1249     9673       8
```

Régression polynomiale :

```
> lm4<-lm(ric~heu.fac+poly(sem,2)+sta.fac)
> anova(lm4)
Analysis of Variance Table

Response: ric

Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value Pr(F)
heu.fac     1      3071    3071   338.5   0
poly(sem, 2) 2      4025    2012   221.8   0
sta.fac    13      3523     271    29.9   0
Residuals 1298     11777      9
> lm5<-lm(ric~heu.fac+poly(sem,3)+sta.fac)
```

```

> anova(lm5)
Analysis of Variance Table

Response: ric

Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value Pr(F)
heu.fac     1    3071   3071  356.6   0
poly(sem, 3) 3    4614   1538  178.6   0
sta.fac    13   3541    272   31.6   0
Residuals 1297   11170      9

```

```

> anova(lm4,lm5)
Analysis of Variance Table

```

```
Response: ric
```

	Terms	Resid.	Df	RSS	Test	Df
1	heu.fac + poly(sem, 2) + sta.fac		1298	11777		
2	heu.fac + poly(sem, 3) + sta.fac		1297	11170	1 vs. 2	1
	Sum of Sq	F Value	Pr(F)			
1						
2	607.2	70.5	1.11e-016			

Interactions :


```

> lm6<-lm(ric~heu.fac*poly(sem,3)*sta.fac)
> anova(lm6)
Analysis of Variance Table

```


```
Response: ric
```

	Terms	added sequentially (first to last)	Df	Sum of Sq	Mean Sq	F Value	Pr(F)
1	heu.fac	1	3071	3071	431.3	0.0000	
	poly(sem, 3)	3	4614	1538	216.0	0.0000	
	sta.fac	13	3541	272	38.2	0.0000	
	heu.fac:poly(sem, 3)	3	200	67	9.4	0.0000	
	heu.fac:sta.fac	13	509	39	5.5	0.0000	
	poly(sem, 3):sta.fac	39	1671	43	6.0	0.0000	
	heu.fac:poly(sem, 3):sta.fac	39	222	6	0.8	0.8047	
	Residuals	1203	8567	7			



On peut mettre la même courbe pour le matin et le soir (à une constante près).

```
> coplot(ric~sem|heu.fac,show.given = F)
```



Modèle additif sans intercation

Les modèles sont des objets

```

> lm5
Call:
lm(formula = ric ~ heu.fac + poly(sem, 3) + sta.fac)

Coefficients:
(Intercept) heu.fac poly(sem, 3)1 poly(sem, 3)2 poly(sem, 3)3
    7.407     -1.521      -29.19      -56.6       24.66
sta.fac1 sta.fac2 sta.fac3 sta.fac4 sta.fac5 sta.fac6 sta.fac7
   -1.572     0.3091     -0.2556     0.7351     -0.2176     0.2248     -0.327
sta.fac8 sta.fac9 sta.fac10 sta.fac11 sta.fac12 sta.fac13
   -0.1317    -0.01319     -0.1864     0.03339     0.1642      0.1017

Degrees of freedom: 1315 total; 1297 residual
Residual standard error: 2.935
> summary(lm5)

Call: lm(formula = ric ~ heu.fac + poly(sem, 3) + sta.fac)
Residuals:
    Min      1Q      Median      3Q      Max 
-10.1    -1.87   -0.0598    1.82    15.5 

Coefficients:
            Value Std. Error t value Pr(>|t|)    
(Intercept) 7.407    0.081    91.293  0.000    
heu.fac     -1.521   0.081   -18.775  0.000    
poly(sem, 3)1 -29.194  2.940   -9.930  0.000    
poly(sem, 3)2 -56.602  2.942   -19.238 0.000    

```

```

poly(sem, 3) 3 24.658 2.937 8.397 0.000
  sta.fac1 -1.572 0.209 -7.516 0.000
  sta.fac2 0.309 0.124 2.501 0.013
  sta.fac3 -0.256 0.088 -2.908 0.004
  sta.fac4 0.735 0.068 10.775 0.000
...

```


```
> plot(lm5, ask=T)
```

Make a plot selection (or 0 to exit):

```


1: plot: All
2: plot: Residuals vs Fitted Values
3: plot: Sqrt of abs(Residuals) vs Fitted Values
4: plot: Response vs Fitted Values
5: plot: Normal QQplot of Residuals
6: plot: r-f spread plot
7: plot: Cook's Distances
Selection: 5

```



Graphes quantiles-quantiles : Normalité des résidus


```
> qqnorm(rnorm(1500))
```



```

> ecrin[382,]
  STA SEM HEU RIC
382   5    1    1  24
> predict(lm5)[382]
  382
  8.522
> ecrin$RIC[382]-predict(lm5)[382]
  382
  15.48 un point aberrant ?
> hist(lm5$residuals, proba=T, nclass=30)
> lines(seq(-10,10,1),dnorm(seq(-10,10,1),mean=0,sd=2.935))

```




L'approche graphique des modèles statistiques : à consommer sans modération ...

3 - Densités de probabilité

3.1 - Loi de Gauss bivariée

Pour une corrélation de 0, 0.5, 0.8 et 0.9 :

```
x0<-seq(-2,2,le=20)
y0<-seq(-2,2,le=20)
xy0<-expand.grid(x=x0, y=y0)
z0<-dmvnorm(xy0,rho=0.50)
z0<-matrix(z0,nrow=20,ncol=20,byrow=T)
persp(x0,y0,z0,eye=c(-30,-20,2),box = F)
```




3.2 - Types de lignes et de caractères :

```
par(mai=c(0,0,0,0) ,cex=2)
```

```

plot(0,0,xlim=c(0,20),ylim=c(0,6),type="n",axes=F)
for (i in 1:5) {
  for(j in 1:4) {
    x0<-(j-1)*5+1
    y0<-6-i
    i0<-i+(j-1)*5-1
    text(x0,y0,paste(i0))
    points(x=x0+1,y=y0,pch=i0)
    par(lty=i0)
    segments(x0+2,y0,x0+4,y0)
  }
}

```




3.3 - Loi de Student

```

x0<-seq(-3,3,le=100)
y0<-dnorm(x0)
z0<-dt(x0,df=4)
plot(x0,y0,type="n")
lines(x0,y0,lty=1)
lines(x0,z0,lty=8)
legend(-3, 0.4, c("N(0,1)", "t(4)"), lty = c(1,8))

```



```

> qt(df = 4, c(0.025, 0.975))
[1] -2.776  2.776
> qnorm(c(0.025, 0.975))
[1] -1.96   1.96

```


4 - Analyse de covariance

```
> M<-rep(c("M1","M2","M3"),c(5,5,5))
> M
[1] "M1" "M1" "M1" "M1" "M1" "M2" "M2" "M2" "M2" "M2" "M3" "M3"
[13] "M3" "M3" "M3"
> X
[1] 2 4 5 8 6 14 16 15 19 11 20 18 23 25 24
> Y
[1] 5 8 7 9 11 7 8 10 13 12 20 22 26 28 24
```

X niveau de départ, Y niveau d'arrivée, M méthode d'enseignement.

```
> covjdl<-cbind.data.frame(X,Y,M)
> names(covjdl)<-c("X","Y","M")
> covjdl
   X   Y   M
1 2 5 M1
2 4 8 M1
3 5 7 M1
...
13 23 26 M3
14 25 28 M3
15 24 24 M3

> plot(X,Y,type="n")
> text(X,Y,M)
```




4.1 - Une seule droite de régression

```
> lm1<-lm(Y~X)
> anova(lm1)
Analysis of Variance Table

Response: Y

Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value    Pr(F)
X   1      599     599   31.53 0.00008407
Residuals 13      247      19
> abline(lm1)
```




4.2 - L'effet du facteur

```
> lm2<-lm(Y~M)
> anova(lm2)
Analysis of Variance Table
```

Response: Y

```
Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value    Pr(F)
M   2      760     380.0   53.02 1.103e-006
Residuals 12      86      7.2
> points(X,predict(lm2))
```



4.3 - Droites parallèles :

```
> lm3<-lm(Y~M+X)
> anova(lm3)
Analysis of Variance Table
```

Response: Y

```
Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value    Pr(F)
M   2      760.0     380.0   72.58 0.000000
X   1       28.4      28.4    5.43 0.03991
Residuals 11      57.6      5.2
```

```
> lm4<-lm(Y~X+M)
> anova(lm4)
Analysis of Variance Table
```

Response: Y

```
Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value    Pr(F)
X   1      599.0     599.0   114.4 0.0000004
M   2      189.4      94.7    18.1 0.0003329 Droites non égales
```


```

Residuals 11      57.6      5.2

> predict(lm3)
   1    2 3     4    5    6    7    8    9    10   11   12
6.295 7.432 8 9.705 8.568 9.432 10.57 10 12.27 7.727 22.86 21.73
   13   14 15
24.57 25.7 25.14
> predict(lm4)
   1    2 3     4    5    6    7    8    9    10   11   12
6.295 7.432 8 9.705 8.568 9.432 10.57 10 12.27 7.727 22.86 21.73
   13   14 15
24.57 25.7 25.14

> lines(X[M=="M1"],predict(lm3)[M=="M1"])
> lines(X[M=="M2"],predict(lm3)[M=="M2"])
> lines(X[M=="M3"],predict(lm3)[M=="M3"])

```



```

> coefficients(lm(Y[M=="M1"]~X[M=="M1"]))
(Intercept) X[M == "M1"]
4.25          0.75
> coefficients(lm(Y[M=="M2"]~X[M=="M2"]))
(Intercept) X[M == "M2"]
7.794         0.1471
> coefficients(lm(Y[M=="M3"]~X[M=="M3"]))
(Intercept) X[M == "M3"]
4.588         0.8824

```

4.4 - Interaction

```


> lm5<-lm(Y~M*X)
> anova(lm5)
Analysis of Variance Table

Response: Y

Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value Pr(F)
M   2    760.0   380.0   71.93 0.0000
X   1     28.4    28.4    5.38 0.0456
M:X  2     10.0     5.0    0.95 0.4220 NON SIGNIFICATIF
Residuals 9     47.5    5.3

> lines(X[M=="M1"],predict(lm5)[M=="M1"])
> lines(X[M=="M2"],predict(lm5)[M=="M2"])
> lines(X[M=="M3"],predict(lm5)[M=="M3"])

```



5 - Interaction sans répétition

16 stations météo dans les Rocheuses (4 altitudes x 4 expositions)

```
> roc
   Sud Sommet Nord Vallee
2460    88     83    74    39
2550    61     55    50    33
3000    22      9    17      0
3690   -39    -33   -39   -22

> roc.vec <- roc[, 1]
> for(i in 2:4) roc.vec <- append(roc.vec, roc[, i])
> roc.vec
[1]  88   61   22  -39   83   55    9  -33   74   50   17  -39   39   33    0  -22

> sta.vec <- names(roc)[rep(1:4, rep(4, le = 4))]
> sta.vec
[1] "Sud"      "Sud"      "Sud"      "Sud"      "Sommet"   "Sommet"   "Sommet"
[8] "Sommet"   "Nord"     "Nord"     "Nord"     "Nord"     "Nord"     "Vallee"
[15] "Vallee"   "Vallee"
> alt.vec <- row.names(roc)[rep(1:4, 4)]
> alt.vec
[1] "2460"    "2550"    "3000"    "3690"    "2460"    "2550"    "3000"    "3690"
[10] "2460"    "2550"    "3000"    "3690"    "2460"    "2550"    "3000"    "3690"
```

5.1 - Modèle $y_{ij} = \mathbf{m} + a_i + b_j + \mathbf{e}_{ij}$

```
> lm0<-lm(roc.vec~sta.vec+alt.vec)
```

Propriété des plans orthogonaux

```
> anova(lm0)
Analysis of Variance Table

Response: roc.vec

Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value Pr(F)
sta.vec  3      931     310     1.94 0.194
alt.vec  3     25162     8387    52.39 0.000
Residuals 9     1441      160

> lm1<-lm(roc.vec~alt.vec+sta.vec)
```

```

> anova(lm1)
Analysis of Variance Table

Response: roc.vec

Terms added sequentially (first to last)
  Df Sum of Sq Mean Sq F Value Pr(F)
alt.vec   3     25162    8387   52.39 0.000
sta.vec   3      931     310    1.94 0.194
Residuals 9     1441     160

> matrix(predict(lm0), 4, 4)
     [,1]   [,2]   [,3]   [,4]
[1,] 79.12  74.62  71.63  58.625
[2,] 57.87  53.38  50.38  37.375
[3,] 20.12  15.62  12.63 -0.375
[4,] -25.12 -29.62 -32.63 -45.625

> roc-matrix(predict(lm0), 4, 4)
      Sud Sommet Nord Vallee
2460  8.875  8.375  2.375 -19.625
2550  3.125  1.625 -0.375 -4.375
3000  1.875 -6.625  4.375  0.375
3690 -13.875 -3.375 -6.375  23.625

```

5.2 - Modèle $y_{ij} = \mathbf{m}_i b_j + \mathbf{e}_{ij}$ ¹

```

> svd(roc)
$d:
[1] 192.914  12.069    7.762    3.524

$v:
     [,1]   [,2]   [,3]   [,4]
[1,] -0.6008  0.4635  0.1312 -0.6380
[2,] -0.5444 -0.4482  0.6340  0.3174
[3,] -0.5119  0.3183 -0.5182  0.6067
[4,] -0.2841 -0.6949 -0.5588 -0.3523

$u:
     [,1]   [,2]   [,3]   [,4]
[1,] -0.7621  0.003526  0.51932  0.3867
[2,] -0.5264 -0.281129 -0.19003 -0.7796
[3,] -0.1390  0.959054 -0.02792 -0.2452
[4,]  0.3505 -0.034198  0.83271 -0.4273

> svd1<-svd(roc)
> svd1$u[,1]
[1] -0.7621 -0.5264 -0.1390  0.3505
> u1<-svd1$u[,1]

> t(svd1$v[,1])
     [,1]   [,2]   [,3]   [,4]
[1,] -0.6008 -0.5444 -0.5119 -0.2841
> v1<-t(svd1$v[,1])
> u1%*%v1
     [,1]   [,2]   [,3]   [,4]
[1,]  0.45783  0.41485  0.39006  0.21648
[2,]  0.31627  0.28659  0.26946  0.14955
[3,]  0.08352  0.07568  0.07116  0.03949
[4,] -0.21055 -0.19078 -0.17938 -0.09956
> svd1$d[1]*u1%*%v1
     [,1]   [,2]   [,3]   [,4]

```

¹ Mandel, J. (1961) Non additivity in two-way analysis of variance. *Journal of the American Statistical Association* : 65, 878-888.

```
[1,] 88.32 80.03 75.25 41.762
[2,] 61.01 55.29 51.98 28.850
[3,] 16.11 14.60 13.73 7.618
[4,] -40.62 -36.80 -34.61 -19.206
```

```
> roc-svd1$d[1]*u1%*%v1
      Sud Sommet Nord Vallee
2460 -0.3210 2.9693 -1.248 -2.762
2550 -0.0135 -0.2865 -1.983 4.150
3000 5.8880 -5.5996 3.273 -7.618
3690 1.6175 3.8049 -4.394 -2.794
```

RAPPEL

```
> roc-matrix(predict(lm0),4,4)
      Sud Sommet Nord Vallee
2460 8.875 8.375 2.375 -19.625
2550 3.125 1.625 -0.375 -4.375
3000 1.875 -6.625 4.375 0.375
3690 -13.875 -3.375 -6.375 23.625
```

Quel est le meilleur modèle ?

```
> sum((predict(lm0)-roc.vec)^2)/9
[1] 160.1
> sum((as.vector(svd1$d[1]*u1%*%v1)-roc.vec)^2)/9
[1] 24.26

> qqnorm(predict(lm0)-roc.vec)
> qqline(predict(lm0)-roc.vec)
> qqnorm(as.vector(svd1$d[1]*u1%*%v1)-roc.vec)
> qqline(as.vector(svd1$d[1]*u1%*%v1)-roc.vec)
```

