

Correction du TP2 : Estimation dans le modèle linéaire gaussien de grande dimension

M2 Statistique, 2019-2020

Statistique mathématique en grande dimension et applications, cours de M. Roquain

Exercice 1

1)

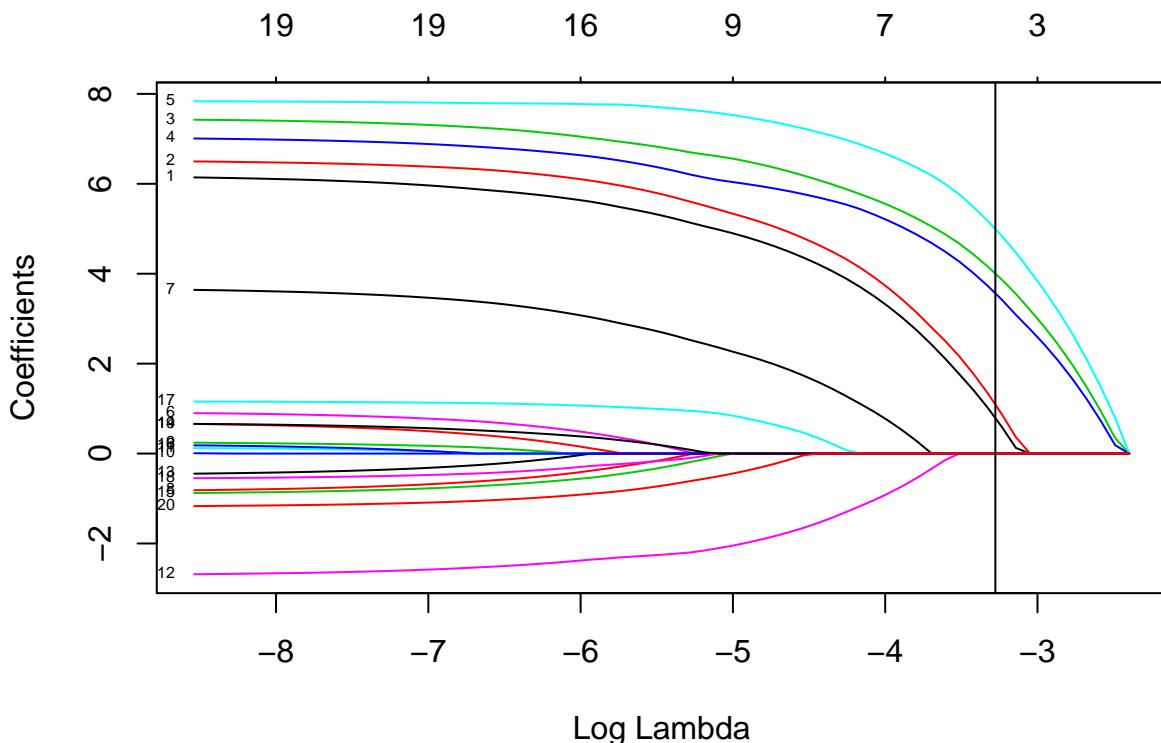
```
library(glmnet)
```

```
## Warning: package 'glmnet' was built under R version 3.3.2
## Loading required package: Matrix
## Warning: package 'Matrix' was built under R version 3.3.2
## Loading required package: foreach
## Loaded glmnet 2.0-10
n=102
p=20
X = matrix(rnorm(n*p),n,p)
normeX=apply(X,2,function(col) sum(col^2))
X = X%*%diag(1/sqrt(normeX))
apply(X,2,function(col) sum(col^2))[1:10]
```

```
## [1] 1 1 1 1 1 1 1 1 1 1
```

2)

```
s=5
delta=7
beta=c(rep(delta,s),rep(0,p-s))
Y=rnorm(n)+X%*%matrix(beta,p,1)
fit=glmnet(X,Y,standardize=FALSE,intercept=FALSE)
plot(fit,xvar="lambda",label=TRUE)
lambdath=3*sqrt(2*(1.1)*log(p))/(2*n)
abline(v=log(lambdath),lwd=1)
```



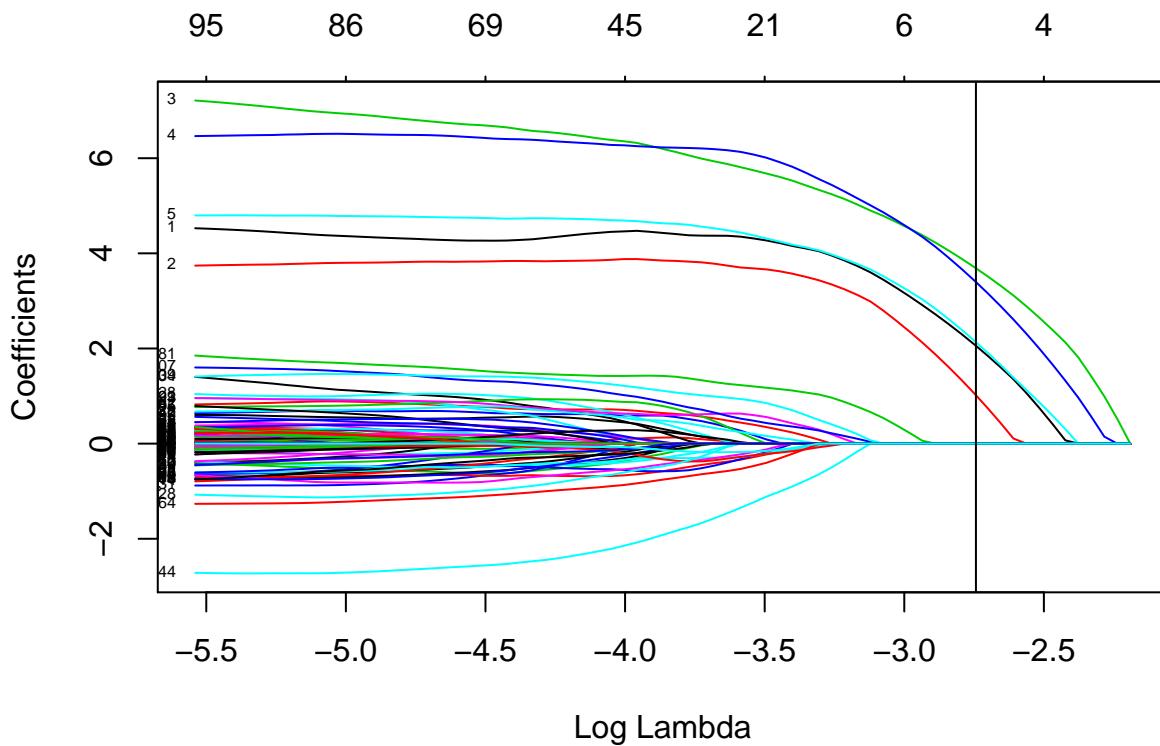
On voit qu'on sélectionne bien les 5 coordonnées de départ avec grande probabilité.

```

3)

n=102
p=6033
X = matrix(rnorm(n*p),n,p)
normeX=apply(X,2,function(col) sum(col^2))
X = X%*%diag(1/sqrt(normeX))
delta=7
beta=c(rep(delta,s),rep(0,p-s))
Y=rnorm(n)+X%*%matrix(beta,p,1)
fit=glmnet(X,Y,standardize=FALSE,intercept=FALSE)
plot(fit,xvar="lambda",label=TRUE)
lambdath=3*sqrt(2*(1.1)*log(p))/(2*n)
abline(v=log(lambdath),lwd=1)

```



```

betachap=as.vector(coef(fit,s=lambda)[-1])
which(beta!=0)

## [1] 1 2 3 4 5
which(beta!=0)

## [1] 1 2 3 4 5

```

On voit que le LASSO s'en sort encore bien alors que la dimension est très grande. Notons que tout de même la force du signal ($\delta = 7$) est très grande. Le λ théorique est cependant un peu grand.

4)

```

library(sda)

## Loading required package: entropy
## Loading required package: corpcor
## Loading required package: fdrtool
data(singh2002)
X=singh2002$x
n=dim(X)[1]
p=dim(X)[2]
normeX=apply(X,2,function(col) sum(col^2))
X = X%*%diag(1/sqrt(normeX))
delta=7
s=10
beta=c(rep(delta,s),rep(0,p-s))
Y=rnorm(n)+X%*%matrix(beta,p,1)
fit=glmnet(X,Y,standardize=FALSE,intercept=FALSE)

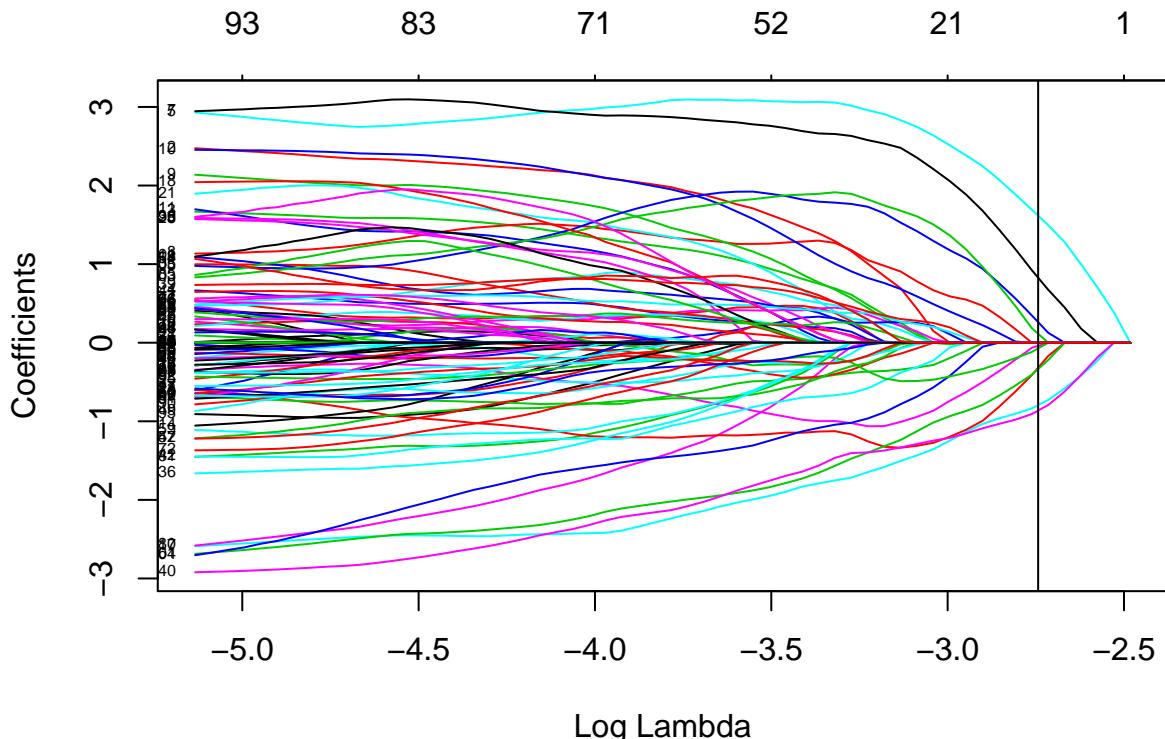
```

```

plot(fit,xvar="lambda",label=TRUE)

lambdath=3*sqrt(2*(1.1)*log(p))/(2*n)
abline(v=log(lambdath),lwd=1)

```



```

betachap=as.vector(coef(fit,s=lambdath)[-1])
which(betachap!=0)

```

```

## [1] 5 7 8 17 1232 1411 1905 2361 2440 2903 3752
which(beta!=0)

## [1] 1 2 3 4 5 6 7 8 9 10

```

On observe un comportement similaire à ce qui est au dessus. Notons que c'est assez fort car X n'est pas du tout orthogonale ici. Le λ théorique est cependant un peu grand.

Exercice 2

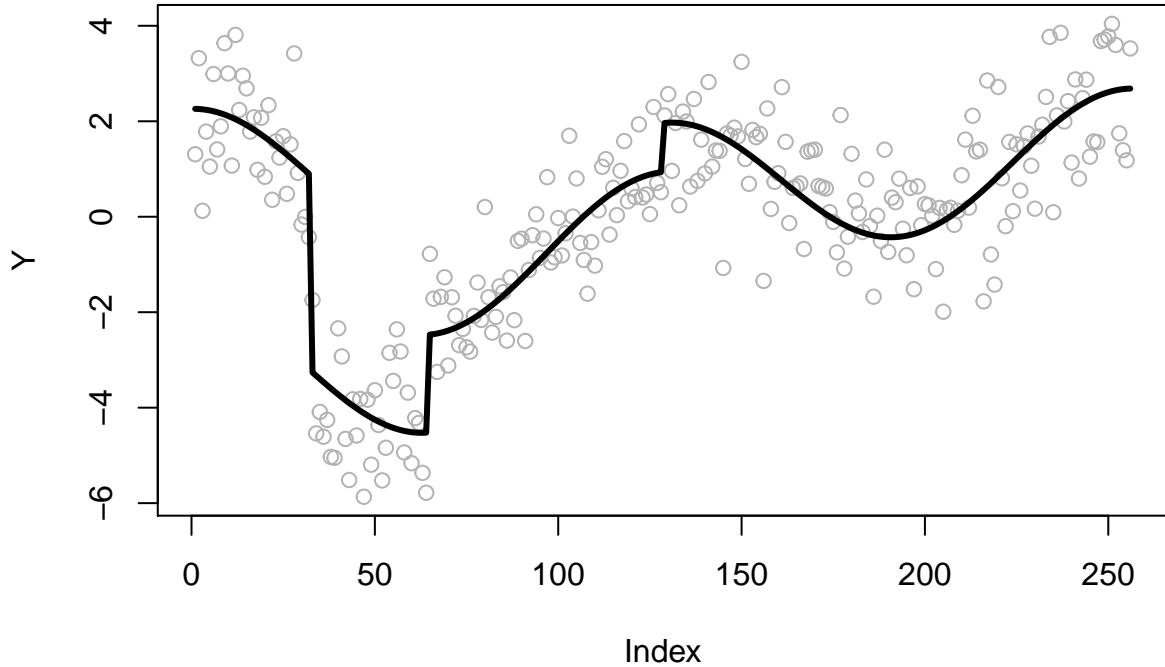
```

load("dataforTP2")
n=2^8
C=t(ComputeCosMat(n))
H=t(ComputeHaarMat(n))
X=cbind(H[,2:n],C[,2:n])
dim(X)

## [1] 256 510
f=2*fmixte
Y=f + rnorm(n)

```

```
plot(Y,col=gray(0.70))
lines(f,lwd=3)
```



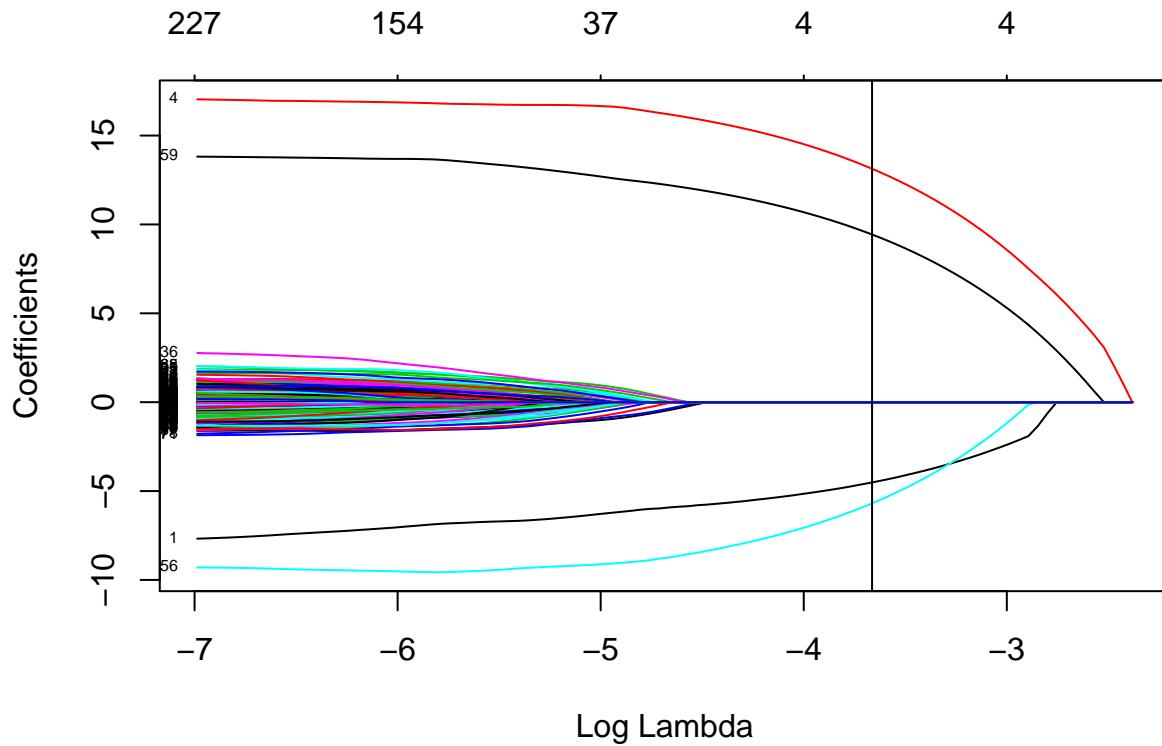
- 1) La matrice X n'a pas ses colonnes orthogonales puisque $p > n$. On peut s'en convaincre numériquement:

```
sum(C[,2]*H[,2])
```

```
## [1] 0.900322
```

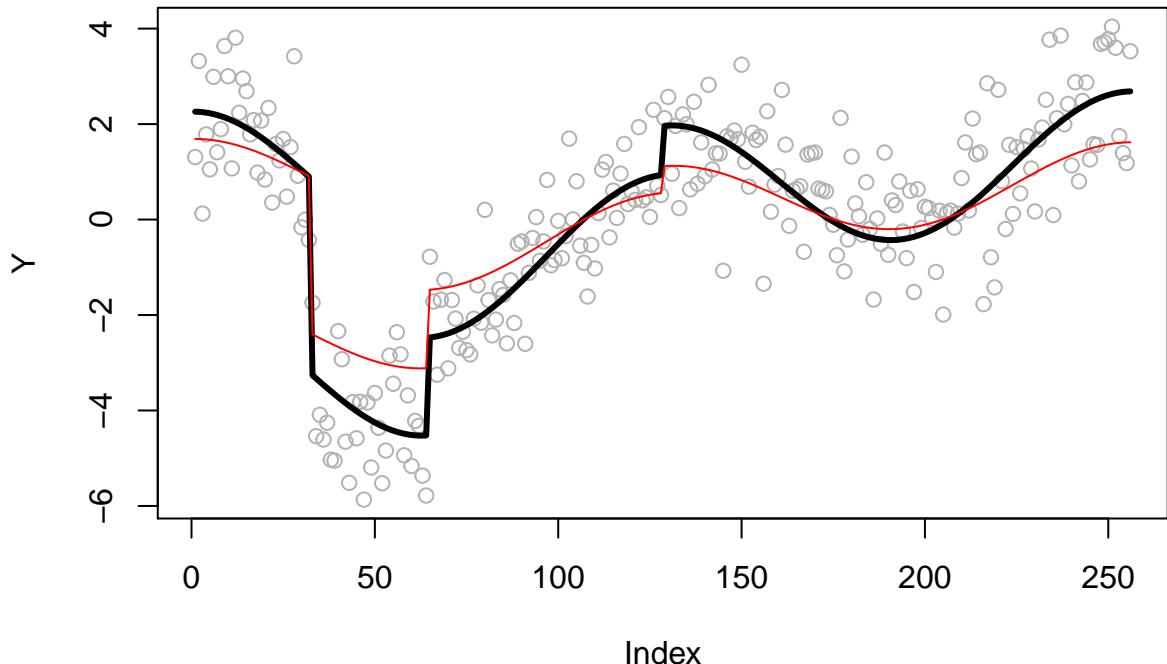
2)

```
fit=glmnet(X,Y,standardize=FALSE,intercept=FALSE)
plot(fit,xvar="lambda",label=TRUE)
lambdath=3*sqrt(2*1.1*log(p))/(2*n)
abline(v=log(lambdath),lwd=1)
```



```
betachap=as.vector(coef(fit,s=lambdath)[-1])
which(betachap!=0)
```

```
## [1] 1 4 256 259
3)
fchap=X%*%betachap
plot(Y,col=gray(0.70))
lines(f,lwd=3)
lines(fchap,lwd=1,col="red")
```

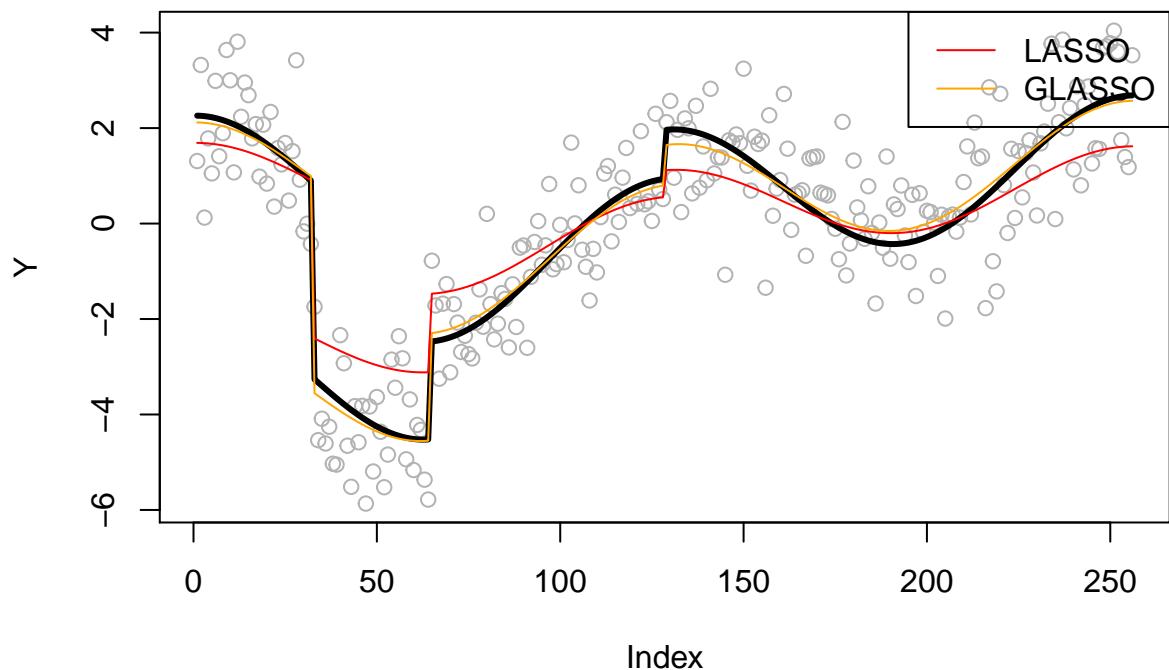


On voit que l'estimateur LASSO à l'air de sélectionner le bon support ici, mais il shrinke les coefficients. C'est la nature même de la norme ℓ^1 , qui a utilisé le shrinkage pour mettre à zero les coefficients pas loin de 0.

4)

```
mhat=which(betachap!=0)
betaOLSmhat=lm(Y~X[,mhat]-1)$coefficients
fchapGLASSO=X[,mhat] %*% as.matrix(betaOLSmhat,length(mhat),1)
plot(Y,col=gray(0.70))
lines(f,lwd=3)
lines(fchap,lwd=1,col="red")
lines(fchapGLASSO,col="orange")

legend("topright",c("LASSO","GLASSO"),col=c("red","orange"),lwd=c(1,1))
```



Ici
Gauss-LASSO marche très bien, car le support sélectionné par le LASSO est le bon, donc il s'agit de l'estimateur des moindres carrés sur le bon modèle, qui a des performances idéales.