

## Chapitre 3 : sélection de modèles et pénalisations

## Les données swiss du package faraway

Standardized fertility measure and socio-economic indicators for each of 47 French-speaking provinces of Switzerland at about 1888.

A data frame with 47 observations on 6 variables, each of which is in percent, i.e., in [0, 100].

- ▶ Fertility common standardized fertility measure
- ▶ Agriculture % of males involved in agriculture as occupation
- ▶ Examination % draftees receiving highest mark on army examination
- ▶ Education % education beyond primary school for draftees.
- ▶ Catholic % 'catholic' (as opposed to 'protestant').
- ▶ Infant.Mortality live births who live less than 1 year.

All variables but Fertility give proportions of the population.

Switzerland, in 1888, was entering a period known as the demographic transition ; i.e., its fertility was beginning to fall from the high level typical of underdeveloped countries.

The data collected are for 47 French-speaking "provinces" at about 1888.


Here, all variables are scaled to [0, 100], where in the original, all but "Catholic" were scaled to [0, 1].

```
summary(swiss)
```

```
##      Fertility      Agriculture      Examination      Education
##  Min.   :35.00   Min.   : 1.20   Min.   : 3.00   Min.   : 1.00
##  1st Qu.:64.70   1st Qu.:35.90   1st Qu.:12.00   1st Qu.: 6.00
##  Median :70.40   Median :54.10   Median :16.00   Median : 8.00
##  Mean   :70.14   Mean   :50.66   Mean   :16.49   Mean   :10.98
##  3rd Qu.:78.45   3rd Qu.:67.65   3rd Qu.:22.00   3rd Qu.:12.00
##  Max.   :92.50   Max.   :89.70   Max.   :37.00   Max.   :53.00
##      Catholic      Infant.Mortality
##  Min.   : 2.150   Min.   :10.80
##  1st Qu.: 5.195   1st Qu.:18.15
##  Median :15.140   Median :20.00
##  Mean   :41.144   Mean   :19.94
##  3rd Qu.:93.125   3rd Qu.:21.70
##  Max.   :100.000  Max.   :26.60
```

## Première vue des données

```
pairs(swiss, main="Simple Scatterplot Matrix")
```



## Sélection de variables $\ell_0$

## Tests de Fisher dans le modèle linéaire

## Test pour modèles emboîtés

Pour tester  $H_0 : \beta_{k_1} = \dots = \beta_{k_l} = 0$ , on utilise le test de Fisher.

- ▶ On note  $W = \text{vect}\{(1, X_1, \dots, X_p) / (X_{k_1}, \dots, X_{k_l})\}$  de dimension  $p + 1 - l$ .
- ▶ On note  $X\tilde{\beta} = \text{proj}_W^\top(Y)$  et on a toujours  $X\hat{\beta} = \text{proj}_V^\top(Y)$ .

### Statistique de Fisher

On a

$$\frac{(n-p-1)(\|Y - X\tilde{\beta}\|^2 - \|Y - X\hat{\beta}\|^2)}{I\|Y - X\hat{\beta}\|^2} \underset{H_0}{\sim} \mathcal{F}(l, n-p-1).$$

## Test du rapport de vraisemblance dans les glm

## Test du rapport de vraisemblance (LRT)

Pour tester  $H_0 : \beta_{k_1} = \dots = \beta_{k_l} = 0$ , dans un modèle linéaire généralisé, on utilise le test du rapport de vraisemblance (LRT).

- ▶ On note  $\hat{\beta}$  l'estimateur du maximum de vraisemblance dans le modèle complet
- ▶ et  $\tilde{\beta}$  l'estimateur du maximum de vraisemblance dans le modèle sans les variables  $X^{k_1}, \dots, X^{k_l}$

### Statistique du LRT

- ▶ On sait que

$$D^0(\hat{\beta}) - D^0(\tilde{\beta}) = -2 \log(\mathcal{L}(\tilde{\beta})) + 2 \log(\mathcal{L}(\hat{\beta}))$$

suit, sous  $\mathcal{H}_0$ , si  $n$  est grand, une loi du  $\chi^2(l)$

- ▶ On rejette  $\mathcal{H}_0$  au niveau  $\alpha$  si  $D^0(\hat{\beta}) - D^0(\tilde{\beta}) > z'$  où  $z'$  est un fractile de la loi du  $\chi^2(l)$ .

## Sélection pas à pas

Si le modèle de départ a  $p$  variables, on peut définir  $2^p$  sous-modèles, tous ceux de

$$\mathcal{M} = \mathcal{P}\{1, \dots, p\} = \{1, (1, X^1), (1, X^2), \dots, (1, X^1, X^2, \dots, X^p)\}$$

Dans l'exemple swiss, on peut former les modèles

- ▶ Fertility ~Agriculture+Examination+Education+ Catholic+Infant.Mortality (modèle complet)
- ▶ Fertility ~Examination+Education+ Catholic+Infant.Mortality
- ▶ Fertility ~Agriculture+Education+ Catholic+Infant.Mortality
- ▶ ...
- ▶ Fertility ~Agriculture
- ▶ Fertility ~Education
- ▶ ....
- ▶ Fertility ~1 (modèle null).

Il y a 32 modèles possibles.

## Algorithmes de recherche de sous-modèles

$2^P$  peut être très grand, il faut des algorithmes efficaces :

- ▶ **forward** : on part du modèle avec seulement l'intercept et on ajoute les variables une à une. A chaque pas, on ajoute celle qui a la plus grande statistique de Fisher. On s'arrête quand la p-value associée devient  $> 0.1$  (seuil arbitraire)
- ▶ **backward** : on part du modèle avec toutes les variables et on retire les variables une à une. A chaque pas, on retire celle qui a la plus petite statistique de Fisher. On s'arrête quand la p-value associée devient  $< 0.1$  (seuil arbitraire)
- ▶ **stepwise** mixte des deux premières (on ajoute, puis on permet une élimination, etc)

## Modèles complet et nul

- ▶ Modèle complet

```
fit_full = lm(Fertility~Agriculture+Examination+Education+
               Catholic+Infant.Mortality ,data = swiss)
```

```
summary(fit_full)$coefficients
```

	Estimate	Std. Error	t value	Pr(> t )
## (Intercept)	66.9151817	10.70603759	6.250229	1.906051e-07
## Agriculture	-0.1721140	0.07030392	-2.448142	1.872715e-02
## Examination	-0.2580082	0.25387820	-1.016268	3.154617e-01
## Education	-0.8709401	0.18302860	-4.758492	2.430605e-05
## Catholic	0.1041153	0.03525785	2.952969	5.190079e-03
## Infant.Mortality	1.0770481	0.38171965	2.821568	7.335715e-03

- ▶ Modèle nul

```
fit_null = lm(Fertility ~ 1, data = swiss)
summary(fit_null)$coefficients
```

	Estimate	Std. Error	t value	Pr(> t )
## (Intercept)	70.14255	1.822101	38.49542	1.212895e-36

## Première sélection de modèle “à la main” descendante (1)

```
drop1(fit_full, test = "F")
```

```
## Single term deletions
##
## Model:
## Fertility ~ Agriculture + Examination + Education + Catholic +
## Infant.Mortality
##          Df Sum of Sq    RSS      AIC F value    Pr(>F)
## <none>             2105.0 190.69
## Agriculture       1     307.72 2412.8 195.10  5.9934  0.018727 *
## Examination        1     53.03 2158.1 189.86  1.0328  0.315462
## Education          1   1162.56 3267.6 209.36 22.6432 2.431e-05 ***
## Catholic           1     447.71 2552.8 197.75  8.7200  0.005190 **
## Infant.Mortality   1     408.75 2513.8 197.03  7.9612  0.007336 **
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

## Première sélection de modèle “à la main” descendante (2)

```
drop1(update(fit_full, ~ . -Examination), test = "F")  
  
## Single term deletions  
##  
## Model:  
## Fertility ~ Agriculture + Education + Catholic + Infant.Mortality  
##           Df Sum of Sq    RSS      AIC F value    Pr(>F)  
## <none>            2158.1 189.86  
## Agriculture       1    264.18 2422.2 193.29  5.1413   0.02857 *  
## Education         1   2249.97 4408.0 221.43 43.7886 5.140e-08 ***  
## Catholic          1    956.57 3114.6 205.10 18.6165 9.503e-05 ***  
## Infant.Mortality  1    409.81 2567.9 196.03  7.9757   0.00722 **  
## ---  
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

## Première sélection de modèle “à la main” ascendante (1)

```
add1(fit_null, scope = ~ Agriculture+Examination+Education  
      +Catholic+Infant.Mortality,  
      test = "F")  
  
## Single term additions  
##  
## Model:  
## Fertility ~ 1  
##  
## Df Sum of Sq    RSS     AIC F value    Pr(>F)  
## <none>          7178.0 238.34  
## Agriculture     1     894.8 6283.1 234.09  6.4089  0.014917 *  
## Examination     1    2994.4 4183.6 214.97 32.2087 9.450e-07 ***  
## Education       1    3162.7 4015.2 213.04 35.4456 3.659e-07 ***  
## Catholic         1    1543.3 5634.7 228.97 12.3251  0.001029 **  
## Infant.Mortality 1    1245.5 5932.4 231.39  9.4477  0.003585 **  
## ---  
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

## Première sélection de modèle “à la main” ascendante (2)

```
add1(update(fit_null, ~. + Examination),
      scope = ~ Agriculture+Examination+Education
      +Catholic+Infant.Mortality,
      test = "F")

## Single term additions
##
## Model:
## Fertility ~ Examination
##           Df Sum of Sq    RSS     AIC F value    Pr(>F)
## <none>             4183.6 214.97
## Agriculture       1    110.83 4072.7 215.71  1.1973 0.279810
## Education         1    633.96 3549.6 209.25  7.8584 0.007497 **
## Catholic          1     93.91 4089.7 215.91  1.0103 0.320322
## Infant.Mortality  1    855.16 3328.4 206.22 11.3048 0.001608 **
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

## Première sélection de modèle “à la main” ascendante (3)

```
add1(update(fit_null, ~. + Examination + Infant.Mortality  
          +Catholic+Education),  
      scope = ~ Agriculture+Examination+Education  
      +Catholic+Infant.Mortality,  
      test = "F")  
  
## Single term additions  
##  
## Model:  
## Fertility ~ Examination + Infant.Mortality + Catholic + Education  
##           Df Sum of Sq    RSS    AIC F value  Pr(>F)  
## <none>            2412.8 195.10  
## Agriculture  1    307.72 2105.0 190.69  5.9934 0.01873 *  
## ---  
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

## Critères pénalisés

## Modèles, vrai modèle

On se donne une famille de modèles  $\mathcal{M}$ , par exemple

$$\mathcal{M} = \mathcal{P}\{1, \dots, p\} = 1, (1, X^1), (1, X^2), \dots, (1, X^1, X^2, \dots, X^p).$$

On suppose qu'il existe un vrai modèle  $m^* \in \mathcal{M}$  tel que :

$$\mathbb{E}(Y) = g^{-1}(X^{(m^*)}\beta^{(m^*)}).$$

On veut retrouver  $m^*$ .

- ▶ **Attention :** le  $R^2$  ou la log-vraisemblance ne sont pas des bons critères pour ce problème car ils choisiront toujours le modèle complet (avec toutes les covariables)
- ▶ On note  $m^{\text{full}} = (1, X^1, X^2, \dots, X^p)$  le modèle complet.

## Sélection via le R2 : pas une bonne idée

```
library(leaps)

choix <- regsubsets(Fertility~Agriculture+Examination+
                      Education+Catholic+Infant.Mortality,
                      data=swiss,
                      method = "exhaustive")
summary(choix)$rsq

## [1] 0.4406156 0.5745071 0.6625438 0.6993476 0.7067350
```

## Estimation dans le modèle $m$

Dans le modèle  $m$ , on note  $|m|$  le nombre de covariables qu'il contient

$$\hat{\beta}^{(m)}$$

l'estimateur au maximum de vraisemblance dans ce modèle.

## Pour le modèle linéaire

### AIC/BIC

On choisit  $\hat{m}_{AIC} \in \mathcal{M}$  et  $\hat{m}_{BIC} \in \mathcal{M}$  tel que :

$$\hat{m}_{AIC} = \underset{m \in \mathcal{M}}{\operatorname{argmin}} AIC(m),$$

$$\hat{m}_{BIC} = \underset{m \in \mathcal{M}}{\operatorname{argmin}} BIC(m),$$

avec

$$AIC(m) = \log \left( \|Y - X\hat{\beta}^{(m)}\|^2 \right) + 2\frac{|m|}{n} = \log \left( RSS^{(m)} \right) + 2\frac{|m|}{n}$$

$$BIC(m) = \log \left( \|Y - X\hat{\beta}^{(m)}\|^2 \right) + \frac{\log(n)|m|}{n} = \log \left( RSS^{(m)} \right) + \frac{\log(n)|m|}{n}.$$

## Pour les glm

### AIC/BIC

On choisit  $\hat{m}_{AIC} \in \mathcal{M}$  et  $\hat{m}_{BIC} \in \mathcal{M}$  tel que :

$$\hat{m}_{AIC} = \operatorname{argmin}_{m \in \mathcal{M}} AIC(m),$$

$$\hat{m}_{BIC} = \operatorname{argmin}_{m \in \mathcal{M}} BIC(m),$$

avec

$$AIC(m) = -2 \log \mathcal{L}(\hat{\beta}^{(m)}) + 2 \frac{|m|}{n}$$

$$BIC(m) = -2 \log \mathcal{L}(\hat{\beta}^{(m)}) + \frac{\log(n)|m|}{n}$$

où  $\log \mathcal{L}(\hat{\beta}^{(m)})$  est la log-vraisemblance dans le modèle  $m$ .

## Sélection automatique stepwise par AIC(1)

```
model.aic.both <- step(fit_null, direction = "both" ,
                        scope = ~ Agriculture+Examination+Education
                               +Catholic+Infant.Mortality, trace = TRUE)

## Start:  AIC=238.35
## Fertility ~ 1
##
##                                Df Sum of Sq    RSS     AIC
## + Education                 1   3162.7 4015.2 213.04
## + Examination               1   2994.4 4183.6 214.97
## + Catholic                  1   1543.3 5634.7 228.97
## + Infant.Mortality          1   1245.5 5932.4 231.39
## + Agriculture                1    894.8 6283.1 234.09
## <none>                      7178.0 238.34
##
## Step:  AIC=213.04
## Fertility ~ Education
##
##                                Df Sum of Sq    RSS     AIC
## + Catholic                   1    961.1 3054.2 202.18
## + Infant.Mortality           1    891.2 3124.0 203.25
## + Examination                1    465.6 3549.6 209.25
## <none>
```

## Sélection automatique stepwise par AIC (2)

```
summary(model.aic.both)

## 
## Call:
## lm(formula = Fertility ~ Education + Catholic + Infant.Mortality +
##     Agriculture, data = swiss)
## 
## Residuals:
##      Min       1Q   Median       3Q      Max 
## -14.6765  -6.0522   0.7514   3.1664  16.1422 
## 
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)    
## (Intercept) 62.10131  9.60489  6.466 8.49e-08 ***
## Education   -0.98026  0.14814 -6.617 5.14e-08 ***
## Catholic     0.12467  0.02889  4.315 9.50e-05 ***
## Infant.Mortality 1.07844  0.38187  2.824  0.00722 ** 
## Agriculture  -0.15462  0.06819 -2.267  0.02857 *  
## ---        
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
## 
## Residual standard error: 7.168 on 42 degrees of freedom
## Multiple R-squared:  0.6993  Adjusted R-squared:  0.6707  <img alt="progress bar" style="float: right; margin-right: 20px; height: 15px; width: 150px; background-color: #ccc; border: 1px solid #ccc; border-radius: 5px; position: relative;"/>
```

# Régressions pénalisées

# Introduction

On observe  $Y$  et  $X$  de dimension  $n \times p$ . On fait l'hypothèse qu'il existe un vrai modèle  $m^*$  tel que

$$Y = X^{m^*} \beta^{m^*} + \epsilon^{m^*} = X^* \beta^* + \epsilon^*,$$

et que  $|m^*|$  est petit devant  $p$  et  $n$ .

Quand  $p$  devient grand par rapport à  $n$ , il y a trois problèmes potentiels :

- ▶  $\hat{\beta} = (X^\top X)^{-1} X^\top Y$  peut ne pas être défini car  $X^\top X$  n'est alors plus inversible (c'est aussi le cas si des colonnes de  $X$  sont colinéaires)
- ▶ La variance d'estimation à partir de  $X$  devient trop grande.
- ▶ Les algorithmes de sélection de variables  $\ell_0$  ne peuvent plus être appliqués à cause des  $2^p$  modèles à comparer.

Ridge

## Régression Ridge

Hoerl et Kennard (1970) ont l'idée d'ajouter à  $X^\top X$  une matrice diagonale  $\lambda \text{Id}_n$  pour retrouver l'inversibilité pour

$$X^\top X + \lambda \text{Id}_p = PDP^{-1} + \lambda \text{Id}_p = P(D + \lambda \text{Id}_p)P^{-1}.$$


### Pénalité ridge

$$\hat{\beta}_\lambda^{\text{ridge}} = \underset{\beta \in \mathbb{R}^p}{\operatorname{argmin}} \|Y - X\beta\|^2 + \lambda \sum_{j=1}^p \beta_j^2$$

$$\hat{\beta}_\lambda^{\text{ridge}} = \underset{\beta \in \mathbb{R}^p}{\operatorname{argmin}} -\log \mathcal{L}(\beta) + \lambda \sum_{j=1}^p \beta_j^2$$

on forme les données pour les passer à glmnet

```
#?glmnet  
Y = Fertility  
X = as.matrix(swiss[,2:6],ncol = 4)  
fit_ridge = glmnet(X,Y, alpha = 0)  
autoplot(fit_ridge)
```



## Cross-validation pour $\lambda$

On sait qu'il existe une valeur  $\lambda^*$  du paramètre de régularisation qui minimise l'erreur de l'estimateur ridge. Cette valeur idéale dépend de quantités inconnues, il faut donc l'estimer.

Si on avait à disposition d'autres données, on aurait

- ▶ des données d'apprentissage (training, learning set)  
 $\mathcal{S}_L = \{(Y_1, X_i), \dots, (Y_n, X_n)\}$
- ▶ des données de validation, de test (testing, validation set)  
 $\mathcal{S}_T = \{(Y_{+,1}, X_{+,1}), \dots, (Y_{+,n'}, X_{+,n'})\}$  avec  $Y_+ = X_+ \beta^* + \epsilon_+$  ET  $\epsilon_+$  indépendants.

On pourrait calculer  $\hat{\beta}_\lambda^{\text{ridge}}$  pour chaque valeur de  $\lambda$  sur l'échantillon d'apprentissage, puis regarder pour quelle valeur de  $\lambda$  il y a le moins d'erreurs sur l'échantillon de test. Pour le modèle linéaire, on calcule

$$\frac{1}{n'} \sum_{i=1}^{n'} (Y_{+,i} - X_{+,i} \hat{\beta}^{(\lambda)})^2,$$

chaque valeur  $\lambda$  du paramètre de régularisation.

## création d'un jeu de données d'apprentissage et de test

```
shuffle = sample(1:nrow(swiss))
apprentissage = shuffle[1:33]
print(apprentissage)
```


```
## [1] 24 1 35 9 6 43 26 3 46 36 28 42 16 23 10 37 15 34 31 2 47
## [24] 29 18 25 4 22 41 30 8 19 45
```

```
test = shuffle[34:nrow(swiss)]
print(test)
```

```
## [1] 11 33 27 7 17 38 13 32 44 20 21 14 12 39
```

```
Y_apprentissage = Fertility$apprentissage
X_apprentissage = as.matrix(swiss$apprentissage, 2:6), ncol = 4)
Y_test = Fertility$test
X_test = as.matrix(swiss$test, 2:6), ncol = 4)
```

```
fit_ridge_apprentissage = glmnet(X_apprentissage,Y_apprentissage, alpha=1)
autoplot(fit_ridge_apprentissage)
```



```
predictions = predict(fit_ridge_apprentissage,newx=X_test)
erreurs_test = rep(0,100)
for (l in 1:100){
  erreurs_test[l] = mean((Y_test - predictions[,l])^2)
}

indice_ideal = which(erreurs_test == min(erreurs_test))
lambda_ideal = fit_ridge_apprentissage$lambda[indice_ideal]
lambda_ideal

## [1] 4.304976
```

## En pratique

Même en l'absence de données de validation (situation fréquente en pratique), on peut vouloir créer des données qui "ressemblent" à des données de test pour appliquer ce qui précède.

## Leave-one-out (jackknife)

Chaque observation joue à tour de rôle le rôle d'échantillon de validation.

### Estimation de l'erreur de généralisation par leave-one-out

$$\mathbb{E}(\|\widehat{Y}_+ - \widehat{\hat{Y}}_+^{(\lambda)}\|^2)_{loo} = \frac{1}{n} \sum_{i=1}^n (Y_i - X_i \hat{\beta}_{(-i)}^{(\lambda)})^2,$$

où  $\hat{\beta}_{(-i)}^{(\lambda)}$  a été calculé sur l'échantillon  $\mathcal{S}_L \setminus (Y_i, X_i)$  et pour la valeur  $\lambda$  du paramètre.

## K-fold cross-validation

On découpe l'échantillon initial en  $K$  sous-ensembles pour obtenir la partition  $\mathcal{S}_L = \mathcal{S}_{L,1} \cup \dots \cup \mathcal{S}_{L,K}$ . Dans le cas, où  $n = Kn_K$ , on tire aléatoirement et sans remise dans  $\mathcal{S}_L$  pour former les  $\mathcal{S}_{L,k}$ .

### Estimation de l'erreur de généralisation par K-fold cross-validation

$$\widehat{\text{eg}(\lambda)}_{K\text{fold}-cv} = \mathbb{E}(\|\mathbf{Y}_+ - \widehat{\mathbf{Y}}_+^{(\lambda)}\|^2)_{K\text{fold}-cv} = \frac{1}{n_K K} \sum_{k=1}^K \sum_{i=1}^{n_K} (\mathbf{Y}_{k,i} - \mathbf{X}_{k,i} \hat{\beta}_{(-k)}^{(\lambda)})^2,$$

où  $\hat{\beta}_{(-k)}^{(\lambda)}$  a été calculé sur l'échantillon  $\mathcal{S}_L \setminus \mathcal{S}_{L,k}$  et pour la valeur  $\lambda$  du paramètre.

On choisit alors

$$\hat{\lambda} = \arg \min_{\lambda \in \Lambda} \widehat{\text{eg}(\lambda)}_{K\text{fold}-cv}$$

## Cross-validation et comparaison avec l'AIC

```
fit_ridge_cv = cv.glmnet(X,Y, lambda = seq(0,3,0.01),alpha = 0)
coef(fit_ridge_cv)
```


```
## 6 x 1 sparse Matrix of class "dgCMatrix"
##                               1
## (Intercept)      61.46350702
## Agriculture     -0.06316741
## Examination     -0.34720834
## Education       -0.54782492
## Catholic         0.06627933
## Infant.Mortality 1.04759689
```

```
summary(model.aic.both)$coef[,1]
```

##	(Intercept)	Education	Catholic	Infant.Mortality
##	62.1013116	-0.9802638	0.1246664	1.0784422
##	Agriculture			
##	-0.1546175			

## Grille en lambda, learning curve

```
plot(fit_ridge_cv$lambda,fit_ridge_cv$cvm, type = 'l', xlab = "valeurs  
abline(v =fit_ridge_cv$lambda.min,col="red")
```



## Lasso et elastic-net

## Le lasso

Introduit en 1996 par Tibshirani, la lasso peut être vu comme un intermédiaire entre la régression ridge et la sélection  $\ell_0$ .

### Pénalité lasso

$$\begin{aligned}\hat{\beta}_\lambda^{\text{lasso}} &= \underset{\beta \in \mathbb{R}^p}{\operatorname{argmin}} \|Y - X\beta\|^2 + \lambda \sum_{j=1}^p |\beta_j| \\ &= \underset{\beta \in \mathbb{R}^p}{\operatorname{argmin}} \|Y - X\beta\|^2 + \lambda \|\beta\|_1.\end{aligned}$$


### Solution lasso sur design orthogonal

Quand  $X^\top X = Id_p$ , on sait que

$$\hat{\beta}_{\text{lasso}}^{(\lambda)} = \mathcal{S}_{\lambda/2}(Y^\top X),$$


avec  $\mathcal{S}_\tau(x) = sign(x)(|x| - \tau)_+$ .

```
fit_lasso = glmnet(X,Y, alpha = 1)
autoplot(fit_lasso)
```



## Cross-validation

```
fit_lasso_cv = cv.glmnet(X,Y,alpha = 1)
plot(coef(fit_full)[2:6],col = "red",ylab = "Coefficients", xaxt="n")
axis(1, 1:5, labels=names(coef(fit_full))[2:6])
points(coef(fit_lasso_cv)[2:6])
points(coef(fit_ridge_cv)[2:6],col = "blue")
```



## L'elastic net

### Elastic net

$$\hat{\beta}_\lambda^{\text{en}} = \underset{\beta \in \mathbb{R}^p}{\operatorname{argmin}} \|Y - X\beta\|^2 + \lambda_1 \|\beta\|_1 + \lambda_2 \|\beta\|_2^2$$

Attention dans `glmnet`, l'elastic-net est défini par

$$\hat{\beta}_\lambda^{\text{en}} = \underset{\beta \in \mathbb{R}^p}{\operatorname{argmin}} \|Y - X\beta\|^2 + \lambda \left( \alpha \|\beta\|_1 + \frac{1-\alpha}{2} \|\beta\|_2^2 \right)$$

## Cross validation en lambda et alpha

```
trControlCV <- trainControl(method = "CV", number = 5)
swissGlmnet <- train(Fertility ~ ., data = swiss, method = "glmnet",
                      trControl = trControlCV,
                      tuneGrid   = expand.grid(alpha = exp(seq(-8,0, length=10)),
                                                lambda = exp(seq(-8,0, length=10))
swissGlmnet

## glmnet
##
## 47 samples
## 5 predictor
##
## No pre-processing
## Resampling: Cross-Validated (5 fold)
## Summary of sample sizes: 38, 38, 38, 38, 36
## Resampling results across tuning parameters:
##
##     alpha      lambda      RMSE      Rsquared
## 0.0003354626 0.0003354626 7.434016 0.6474605
## 0.0003354626 0.0008159878 7.434016 0.6474605
## 0.0003354626 0.0019848296 7.434016 0.6474605
## 0.0003354626 0.0048279500 7.434016 0.6474605
## 0.0003354626 0.0117436285 7.434016 0.6474605
```