

Chapitre II : Régression linéaire multiple

M. Champion



2020-2021

I. Le modèle linéaire multiple

1.1 Objectifs

Un modèle linéaire **multiple** :

- permet de **décrire** et **modéliser** la relation entre une variable aléatoire quantitative continue Y (dite à expliquer) et p variables quantitatives contrôlées X^1, \dots, X^p (dites explicatives),
- utilise des observations $(x_i^1, \dots, x_i^p, y_i)_{i=1, \dots, n}$ d'un échantillon de taille n où :
 - ▶ x_1^j, \dots, x_n^j : valeurs connues et fixées (non aléatoires) de X^j ($1 \leq j \leq p$),
 - ▶ y_1, \dots, y_n : réponses obtenues considérées comme n réalisations de Y .

I. Le modèle linéaire multiple

1.2 Description du modèle

On appelle **modèle linéaire multiple gaussien** un modèle statistique qui peut s'écrire sous la forme :

$$\forall i \in \llbracket 1, n \rrbracket, \quad Y_i = \beta_0 + \beta_1 x_i^1 + \dots + \beta_p x_i^p + \varepsilon_i,$$

où les $(\varepsilon_i)_{1 \leq i \leq n}$ sont des termes d'erreur non observés, i.i.d :

$$\varepsilon_i \stackrel{i.i.d}{\sim} \mathcal{N}(0, \sigma^2).$$

- β_0, \dots, β_p (paramètres d'espérance) sont inconnus et à estimer pour comprendre l'effet des variables X^1, \dots, X^p sur la réponse Y .
- σ^2 (paramètre de variance) est également inconnu et à estimer.

→ La **dimension** du modèle est $p + 1$.

I. Le modèle linéaire multiple

1.2 Description du modèle

Le modèle

$$\forall i \in \llbracket 1, n \rrbracket, \quad Y_i = \beta_0 + \beta_1 x_i^1 + \dots + \beta_p x_i^p + \varepsilon_i,$$

avec

$$\forall i \in \llbracket 1, n \rrbracket, \quad \varepsilon_i \stackrel{i.i.d}{\sim} \mathcal{N}(0, \sigma^2),$$

est équivalent à

$$\forall i = 1, \dots, n, \quad \text{les } Y_i \text{ sont indépendants et } Y_i \sim \mathcal{N}\left(\beta_0 + \sum_{j=1}^p \beta_j x_i^j; \sigma^2\right).$$

I. Le modèle linéaire multiple

1.3 Ecriture matricielle du modèle linéaire multiple

Le modèle se réécrit matriciellement :

$$Y = X\beta + \varepsilon,$$

où X est une matrice de taille $n \times (p + 1)$ de terme général x_i^j , excepté la première colonne qui contient uniquement des 1, $Y = {}^t(Y_1, \dots, Y_n)$, $\varepsilon = {}^t(\varepsilon_1, \dots, \varepsilon_n)$ et $\beta = {}^t(\beta_0, \dots, \beta_p)$.

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & x_1^1 & \dots & x_1^p \\ \vdots & \vdots & & \vdots \\ 1 & x_n^1 & \dots & x_n^p \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix}.$$

I. Le modèle linéaire multiple

1.3 Ecriture matricielle du modèle linéaire multiple (R)

On utilisera le jeu de données `state.x77` tout au long de ce cours. Ce jeu de données contient des stats sur les 50 états des Etats-Unis dans les années 70.

```
data <- as.data.frame(state.x77)
str(data)
```

```
## 'data.frame':    50 obs. of  8 variables:
## $ Population: num  3615 365 2212 2110 21198 ...
## $ Income    : num  3624 6315 4530 3378 5114 ...
## $ Illiteracy: num  2.1 1.5 1.8 1.9 1.1 0.7 1.1 0.9 1.3 2 ...
## $ Life Exp  : num  69 69.3 70.5 70.7 71.7 ...
## $ Murder    : num  15.1 11.3 7.8 10.1 10.3 6.8 3.1 6.2 10.7 13.9
## $ HS Grad   : num  41.3 66.7 58.1 39.9 62.6 63.9 56 54.6 52.6 40
## $ Frost     : num  20 152 15 65 20 166 139 103 11 60 ...
## $ Area      : num  50708 566432 113417 51945 156361 ...
```

On souhaite expliquer l'espérance de vie `Life.Exp` en fonction des 7 autres variables `Population`, `Income`, `Illiteracy`, `Murder`, `HS.Grad`, `Frost`, `Area`.

II. Estimation des paramètres

2.1 Estimation de β par moindres carrés

La **méthode des moindres carrés** consiste à estimer $\beta \in \mathbb{R}^{p+1}$ en minimisant la somme des carrés des erreurs :

$$\min_{\beta \in \mathbb{R}^{p+1}} \frac{1}{n} \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i^1 - \dots - \beta_p x_i^p)^2,$$

qui se réécrit aussi :

$$\min_{\beta \in \mathbb{R}^{p+1}} \|Y - X\beta\|^2.$$

Théorème

Si tXX est inversible, l'estimateur des moindres carrés B de β est :

$$B = ({}^tXX)^{-1}{}^tXY.$$

II. Estimation des paramètres

2.2 Estimation de la variance σ^2

On note

- $SCT = \sum_{i=1}^n (Y_i - \bar{Y})^2$ (Somme des Carrés Totale),
- $SCM = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2$ (Somme des Carrés du Modèle),
- $SCR = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n e_i^2$ (Somme des Carrés Résiduelle),

de telle sorte que :

$$SCT = SCM + SCR.$$

Théorème

Un estimateur s^2 de σ^2 est donné par :

$$s^2 = \frac{SCR}{n - (p + 1)}.$$

II. Estimation des paramètres

2.3 Propriétés et lois des estimateurs

Théorème

Sous les hypothèses du modèle linéaire gaussien multiple, s^2 est un estimateur sans biais de σ^2 et on a :

$$\frac{(n - p - 1)s^2}{\sigma^2} = \frac{\text{SCR}}{\sigma^2} \sim \chi^2(n - p - 1).$$

De plus, s^2 est indépendant de B .

II. Estimation des paramètres

2.3 Propriétés et lois des estimateurs

Théorème

b_0, \dots, b_p sont des estimateurs sans biais de β_0, \dots, β_p . $B = {}^t(b_0, \dots, b_p)$ est un vecteur gaussien d'espérance β et de matrice de covariance $\sigma^2({}^tXX)^{-1}$:

$$B \sim \mathcal{N}(\beta, \sigma^2({}^tXX)^{-1}).$$

En particulier, si on note pour tout $j = 0, \dots, p$, c_j le $(j+1) \times (j+1)$ élément diagonal de la matrice $({}^tXX)^{-1}$:

$$\forall j \in \llbracket 0, p \rrbracket, \quad b_j \sim \mathcal{N}(\beta_j, \sigma^2 c_j).$$

On a aussi :

$$\forall j \in \llbracket 0, p \rrbracket, \quad \frac{b_j - \beta_j}{\sqrt{s^2 c_j}} \sim St(n - p - 1).$$

II. Estimation des paramètres

2.4 Qualité d'ajustement du modèle

La qualité d'ajustement du modèle est mesurée par le coefficient de détermination, défini par :

$$R^2 = \frac{SCM}{SCT} = 1 - \frac{SCR}{SCT} = 1 - \frac{\sum_i (Y_i - \hat{Y}_i)^2}{\sum_i (Y_i - \bar{Y}_i)^2}.$$

Il détermine à quel point l'équation de régression est adaptée pour décrire la distribution des points.

Remarque : En règle général, on utilise le R^2 ajusté :

$$R^2_{\text{ajusté}} = 1 - \frac{SCR / (n - p - 1)}{SCT / (n - 1)}.$$

II. Estimation des paramètres

2.5 Application sur R

```
modele <- lm(Life.Exp~.,data=data)
coefficients(modele)
```

```
##      (Intercept)      Population          Income      Illiteracy      Mu
## 7.094322e+01 5.180036e-05 -2.180424e-05 3.382032e-02 -3.011232
##           HS.Grad           Frost           Area
## 4.892948e-02 -5.735001e-03 -7.383166e-08
```

```
summary(modele)$sigma
```

```
## [1] 0.7447777
```

```
summary(modele)$r.squared
```

```
## [1] 0.7361563
```

III. Inférence sur les paramètres

3.1 Intervalle de confiance

Les **intervalles de confiance** de niveau de confiance $1 - \delta$ sont établis à partir des lois donnés dans le théorème précédent :

$$IC_{1-\delta}(\beta_j) = [b_j - t_{\delta/2} \sqrt{s^2 c_j}, b_j + t_{\delta/2} \sqrt{s^2 c_j}].$$

où $t_{\delta/2}$ est le $(1 - \delta/2)$ -quantile de la distribution de Student $St(n - p - 1)$:

$$\mathbb{P}(St(n - p - 1) \leq t_{\delta}) = 1 - \delta/2.$$

En pratique, t_{δ} est lu dans table de $St(n - p - 1)$.

III. Inférence sur les paramètres

3.2 Préviation

Etant donnée une nouvelle observation $(x_{n+1}^1, \dots, x_{n+1}^p)$ de $(X^j)_{1 \leq j \leq p}$, une prévision \hat{y}_{n+1} de y_{n+1} (non disponible!) est donnée par :

$$\begin{aligned}\hat{y}_{n+1} &= b_0 + b_1 x_{n+1}^1 + \dots + b_p x_{n+1}^p \\ &= X_{n+1} B,\end{aligned}$$

où $B = {}^t(b_0, \dots, b_p)$ est le vecteur de taille $p + 1$ contenant les estimations des paramètres $(\beta_0, \dots, \beta_p)$ du modèle et $X_{n+1} = (1, x_{n+1}^1, \dots, x_{n+1}^p)$ est le vecteur ligne de taille $p + 1$ contenant les nouvelles observations.

A t'on une idée de la précision de cette prévision?

- Construction d'un intervalle de prédiction de Y_{n+1}
- Construction d'un intervalle de confiance de $\mathbb{E}(Y_{n+1})$

III. Inférence sur les paramètres

3.2 Préviation

Théorème

Dans le cadre du MLGM, on a les deux résultats suivants :

$$\frac{\hat{Y}_{n+1} - \mathbb{E}(Y_{n+1})}{\sqrt{s^2 X_{n+1} ({}^t X X)^{-1} X_{n+1}}} \sim St(n - p - 1),$$

$$\frac{\hat{Y}_{n+1} - Y_{n+1}}{\sqrt{s^2 (1 + X_{n+1} ({}^t X X)^{-1} X_{n+1})}} \sim St(n - p - 1).$$

On en déduit les intervalles de prédiction et de confiance suivants :

$$IP_{1-\delta}(Y_{n+1}) = [\hat{y}_{n+1} \pm c_\delta s \sqrt{1 + X_{n+1} ({}^t X X)^{-1} X_{n+1}}].$$

$$IC_{1-\delta}(\mathbb{E}(Y_{n+1})) = [\hat{y}_{n+1} \pm c_\delta s \sqrt{X_{n+1} ({}^t X X)^{-1} X_{n+1}}].$$

III. Inférence sur les paramètres

3.3 Application sur R

```
confint(modele)
```

##		2.5 %	97.5 %
## (Intercept)	6.741567e+01	7.447078e+01	
## Population	-7.101457e-06	1.107022e-04	
## Income	-5.150751e-04	4.714666e-04	
## Illiteracy	-7.053624e-01	7.730031e-01	
## Murder	-3.952076e-01	-2.070387e-01	
## HS.Grad	1.861199e-03	9.599776e-02	
## Frost	-1.207830e-02	6.082932e-04	
## Area	-3.440321e-06	3.292657e-06	

III. Inférence sur les paramètres

3.3 Application sur R

```
newdata <- data.frame(Population=100000,Income=8000,  
                      Illiteracy = 0.5, Murder = 3,  
                      HS.Grad = 50,Frost=150,Area=1500)  
predict(modele, newdata,interval="prediction")
```

```
##           fit           lwr           upr  
## 1 76.64848 71.03262 82.26434
```

```
predict(modele, newdata,interval="confidence")
```

```
##           fit           lwr           upr  
## 1 76.64848 71.23749 82.05947
```

IV. Tests dans le modèle linéaire multiple

4.1 Test de la contribution globale

Il s'agit d'une généralisation du test de Fisher à p variables explicatives :

- compare les modèles M_1 (constant) et M_{p+1} (complet)

$$M_1 : \forall i \in \llbracket 1, n \rrbracket, Y_i = \beta_0 + \varepsilon_i, \quad \varepsilon_i \stackrel{i.i.d}{\sim} \mathcal{N}(0, \sigma^2)$$

$$M_{p+1} : \forall i \in \llbracket 1, n \rrbracket, Y_i = \beta_0 + \sum_{j=1}^p \beta_j x_i^j + \varepsilon_i, \quad \varepsilon_i \stackrel{i.i.d}{\sim} \mathcal{N}(0, \sigma^2).$$

- revient à tester, au risque δ fixé, l'hypothèse nulle

(H_0) : modèle M_1 (aucune variable n'a d'influence)

contre l'alternative

(H_1) : modèle M_{p+1} (au moins une des variables a de l'influence)

IV. Tests dans le modèle linéaire multiple

4.1 Test de la contribution globale

La **statistique de test** est

$$T_n = \frac{SCM/p}{SCR/(n-p-1)} \sim_{H_0} F(p, n-p-1),$$

ou encore :

$$T_n = \frac{(SCR_{M_1} - SCR)/p}{SCR/(n-p-1)} \sim_{H_0} F(p, n-p-1),$$

où SCR_{M_1} est la Somme des Carrés Résiduels pour le modèle M_1 .

IV. Tests dans le modèle linéaire multiple

4.1 Test de la contribution globale

Notons c_δ le quantile d'ordre δ de $F(p, n - p - 1)$ tel que :

$$\mathbb{P}(T_n \leq c_\delta) = 1 - \delta$$

La **règle de décision** est alors la suivante :

- si $T_n > c_\delta$, on rejette H_0 ,
- si $T_n \leq c_\delta$, on ne rejette pas H_0 .

En pratique, on prend un échantillon de taille n , on calcule la réalisation t_n de T_n sur cet échantillon et on compare sa valeur à c_δ , qui est lu sur la table de Fisher. On peut aussi calculer la p-valeur = $\mathbb{P}_{H_0}(T_n > t_n)$ que l'on compare au risque δ . Si la p-valeur est inférieure à δ , le test est significatif.

IV. Tests dans le modèle linéaire multiple

4.2 Test du modèle réduit

On teste si un ensemble de q variables explicatives ne suffit pas à expliquer Y :

- **Hypothèses :**

(H_0) : modèle réduit

$$\text{Modèle } M_{q+1} : \forall i \in \llbracket 1, n \rrbracket, Y_i = \beta_0 + \sum_{j=1}^q \beta_j x_i^j + \varepsilon_i, \quad \varepsilon_i \stackrel{i.i.d}{\sim} \mathcal{N}(0, \sigma^2),$$

contre

(H_1) : modèle complet

$$\text{Modèle } M_{p+1} : \forall i \in \llbracket 1, n \rrbracket, Y_i = \beta_0 + \sum_{j=1}^p \beta_j x_i^j + \varepsilon_i, \quad \varepsilon_i \stackrel{i.i.d}{\sim} \mathcal{N}(0, \sigma^2).$$

Ou encore :

$$(H_0) : \forall j = q + 1, \dots, p, \beta_j = 0 \text{ contre } (H_1) : \exists j \in \{q + 1, \dots, p\}, \beta_j \neq 0.$$

IV. Tests dans le modèle linéaire multiple

4.2 Test du modèle réduit

Théorème

On a le résultat suivant :

$$\frac{SCR}{\sigma^2} \sim \chi^2(n - p - 1).$$

On en déduit donc que sous H_0 :

$$\frac{SCR_{M_{q+1}}}{\sigma^2} \sim_{H_0} \chi^2(n - q - 1).$$

Si on note $SCE = SCR_{M_{q+1}} - SCR$, SCE et SCR sont indépendants et

$$\frac{SCE}{\sigma^2} \sim_{H_0} \chi^2(p - q).$$

La **statistique de test** est alors définie par

$$T_n = \frac{(SCR_{M_{q+1}} - SCR)/(p - q)}{SCR/(n - p - 1)} \sim_{H_0} F(p - q, n - p - 1).$$

IV. Tests dans le modèle linéaire multiple

4.2 Test du modèle réduit

Notons c_δ le quantile d'ordre δ de $F(p - q, n - p - 1)$ tel que :

$$\mathbb{P}(T_n \leq c_\delta) = 1 - \delta$$

• La **règle de décision** est alors la suivante :

- ▶ si $T_n > c_\delta$, on rejette H_0 ,
- ▶ si $T_n \leq c_\delta$, on ne rejette pas H_0 .

En pratique, on mesure T_n sur un échantillon de taille n . Si $c_n > t_\delta$, on conserve le modèle complet, on considère que le passage de M_{q+1} à M_{p+1} est significatif : au moins l'une des variables X^{q+1}, \dots, X^p a une influence significative sur Y (en plus de X^1, \dots, X^q). Si $t_n \leq c_\delta$, on ne rejette pas (H_0), on considère que le passage de M_{q+1} à M_{p+1} n'est pas significatif : l'influence des variables explicatives X^{q+1}, \dots, X^p n'est pas significative pour expliquer Y .

IV. Tests dans le modèle linéaire multiple

4.3 Table de l'analyse de la variance de la régression

IV. Tests dans le modèle linéaire multiple

4.4 Application sous R

```
modele1 <- lm(Life.Exp~1,data=data)
anova(modele,modele1)
```

```
## Analysis of Variance Table
```

```
##
```

```
## Model 1: Life.Exp ~ Population + Income + Illiteracy + Murder + Frost + Area
```

```
##
```

```
## Model 2: Life.Exp ~ 1
```

```
##   Res.Df    RSS Df Sum of Sq      F    Pr(>F)
```

```
## 1      42 23.297
```

```
## 2      49 88.299 -7   -65.002 16.741 2.534e-10 ***
```

```
## ---
```

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

IV. Tests dans le modèle linéaire multiple

4.4 Application sous R

```
modele4 <- lm(Life.Exp~Population+Frost+Area+Income,data=data)
anova(modele,modele4)
```

```
## Analysis of Variance Table
##
## Model 1: Life.Exp ~ Population + Income + Illiteracy + Murder + Frost + Area
## Model 2: Life.Exp ~ Population + Frost + Area + Income
##   Res.Df    RSS Df Sum of Sq    F    Pr(>F)
## 1      42 23.297
## 2      45 68.941 -3   -45.644 27.429 5.52e-10 ***
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

IV. Tests dans le modèle linéaire multiple

4.4 Application sous R

Quelques remarques :

- on peut toujours comparer des modèles emboîtés l'un dans l'autre,
- on peut toujours comparer tous les modèles au modèle complet (structure la plus riche),
- on peut toujours comparer tous les modèles au modèle constant (structure la moins riche),
- on ne peut jamais comparer les modèles non emboîtés à l'aide de ce test.

V. Sélection de modèles/variables

Si le test global (H_0) : M_1 contre (H_1) : M_{p+1} est significatif, au moins une des variables contribue à expliquer Y . Mais lesquelles?

- Première idée :

- ▶ tester la nullité des p coefficients de régression avec le test de Student $\forall j = 1, \dots, p, (H_0) : \beta_j = 0$ contre (H_1) : $\beta_j \neq 0$,
- ▶ éliminer toutes les variables X^j telles que le test de Student associé n'est pas significatif,

V. Sélection de modèles/variables

Si le test global (H_0) : M_1 contre (H_1) : M_{p+1} est significatif, au moins une des variables contribue à expliquer Y . Mais lesquelles?

- Première idée :

- ▶ tester la nullité des p coefficients de régression avec le test de Student $\forall j = 1, \dots, p, (H_0) : \beta_j = 0$ contre (H_1) : $\beta_j \neq 0$,
- ▶ éliminer toutes les variables X^j telles que le test de Student associé n'est pas significatif,
- ▶ **démarche fausse** car chaque test est effectué alors que les autres variables sont fixées, on ne prend pas en compte les possibles effets conjoints!

V. Sélection de modèles/variables

Si le test global (H_0) : M_1 contre (H_1) : M_{p+1} est significatif, au moins une des variables contribue à expliquer Y . Mais lesquelles?

- Première idée :
 - ▶ tester la nullité des p coefficients de régression avec le test de Student $\forall j = 1, \dots, p, (H_0) : \beta_j = 0$ contre (H_1) : $\beta_j \neq 0$,
 - ▶ éliminer toutes les variables X^j telles que le test de Student associé n'est pas significatif,
 - ▶ **démarche fautive** car chaque test est effectué alors que les autres variables sont fixées, on ne prend pas en compte les possibles effets conjoints!
- Deuxième idée : sélectionner les variables pertinentes par des méthodes de recherche exhaustive :
 - ▶ nécessite de comparer 2^p modèles,
 - ▶ si p pas trop élevé, on peut comparer tous les modèles possibles et choisir "le meilleur" modèle à partir d'un critère statistique de sélection de modèles.

V. Sélection de modèles/variables

5.1. Critères de sélection : critère du R^2

On peut se baser sur le coefficient de détermination R^2 , défini pour tout modèle M_{q+1} par :

$$R^2(q) = 1 - \frac{SCR_{M_{q+1}}}{SCT}.$$

- $0 \leq R^2 \leq 1$ donne la pourcentage de la variation totale de Y expliquée par le modèle de régression linéaire,
- R^2 augmente avec le nombre q de variables explicatives qui entrent dans le modèle,
- R^2 atteint son maximum si toutes les variables disponibles sont incluses, c'est-à-dire pour le modèle complet M_{p+1} ,
- Défaut : ne permet pas de comparer deux modèles ayant des nombres de variables explicatives différents.


V. Sélection de modèles/variables

5.1. Critères de sélection : critère du R^2 (R)

```
leaps <- regsubsets(Life.Exp~.,data=data,nbest=1,nvmax=10)
round(summary(leaps)$rsq,3)
```

```
## [1] 0.610 0.663 0.713 0.736 0.736 0.736 0.736
```

```
plot(leaps, scale="r2")
```



V. Sélection de modèles/variables

5.1. Critères de sélection : critère du R^2 ajusté

On choisit le modèle qui optimise le R^2 ajusté :

$$\max_{q \leq p} R^2_{\text{ajusté}}(q) = \max_{q \leq p} 1 - \frac{\text{SCR}_{M_{q+1}} / (n - q - 1)}{\text{SCT} / (n - 1)}.$$

- $R^2_{\text{ajusté}}$ n'augmente pas forcément lors de l'introduction de variables supplémentaires dans le modèle,
- comparaison possible de modèles n'ayant pas le même nombre de variables explicatives.

V. Sélection de modèles/variables

5.1. Critères de sélection : critère du R^2 ajusté (R)

```
summary(modele)$adj.r.squared
```

```
## [1] 0.6921823
```

```
summary(modele1)$adj.r.squared
```

```
## [1] 0
```


```
round(summary(leaps)$adjr2,3)
```

```
## [1] 0.602 0.648 0.694 0.713 0.706 0.699 0.692
```

V. Sélection de modèles/variables

5.1. Critères de sélection : critère du R^2 ajusté (R)

```
plot(leaps, scale="adjr2")
```



V. Sélection de modèles/variables

5.1. Critères de sélection : C_p de Mallows


On choisit le modèle qui minimise le coefficient C_p de Mallows :

$$\min_{q \leq p} C_p(q) = \min_{q \leq p} \frac{SCR_{M_{q+1}}}{s^2} - n + 2(q + 1).$$

```
round(summary(leaps)$cp,3)
```

```
## [1] 16.127  9.670  3.740  2.020  4.009  6.002  8.000
```

```
plot(leaps,scale="Cp")
```



V. Sélection de modèles/variables

5.1. Critères de sélection : PRESS

Si on note $\hat{y}_{(i)}$ la prédiction de y_i calculée sans tenir compte de la i -ème observation $(y_i, x_i^1, \dots, x_i^p)$, le PRESS est défini par :

$$\text{PRESS} = \sum_{i=1}^n (y_i - \hat{y}_{(i)})^2$$

et permet donc de comparer les capacités prédictives de deux modèles.

```
library(qpcR)
PRESS(modele4)$stat
```

```
## .....10.....20.....30.....40.....50
## [1] 125.0406
```

```
PRESS(modele1)$stat
```

```
## .....10.....20.....30.....40.....50
## [1] 91.93982
```

V. Sélection de modèles/variables

5.2. Critères de vraisemblance pénalisée

Certains critères se ramènent à l'utilisation d'une version pénalisée de la vraisemblance du modèle, afin de favoriser un modèle parcimonieux.

- Critère AIC :

$$\min_{q \leq p} \text{AIC}(q) = \min_{q \leq p} -2 \log(L(M_{q+1})) + 2(q + 1),$$

où $\log(L(M_{q+1}))$ est la log-vraisemblance du modèle M_{q+1} ($\sim \log \frac{\text{SCR}(M_{q+1})}{n}$).

- Critère BIC : on choisit le modèle qui minimise le critère BIC suivant :

$$\min_{q \leq p} \text{BIC}(q) = \min_{q \leq p} -2 \log(L(M_{q+1})) + (q + 1) \log n.$$

Le critère BIC, contrairement au critère AIC, fait intervenir la taille de l'échantillon n .

V. Sélection de modèles/variables

5.2. Critères de vraisemblance pénalisée (R)

```
AIC(modele)
```

```
## [1] 121.7092
```

```
AIC(modele1)
```

```
## [1] 174.3291
```

```
BIC(modele)
```

```
## [1] 138.9174
```

```
BIC(modele1)
```

```
## [1] 178.1532
```

V. Sélection de modèles/variables

5.3. Algorithmes de sélection

Lorsque p est grand, on préfère les méthodes de sélection pas à pas qui consiste à introduire ou à supprimer les variables les unes après les autres :

Sélection ascendante "forward"

On part du modèle $M_1 : \forall i \in \llbracket 1, n \rrbracket, y_i = \beta_0 + \varepsilon_i$

1. choisir la variable X^{j_1} qui contribue le plus à expliquer Y
 - ▶ celle qui garantit le coefficient de détermination R^2 le plus élevé,
 - ▶ celle pour laquelle le test de Fisher du modèle M_1 contre modèle $M_2 : \forall i \in \llbracket 1, n \rrbracket, y_i = \beta_0 + \beta_{j_1} x_i^{j_1} + \varepsilon_i$ est le plus significatif...
- 1'. tester la nullité du coefficient de régression β_{j_1} : retenir X^{j_1} si le test est significatif (p -valeur du test de student $\leq 5\%$)

V. Sélection de modèles/variables

5.3. Algorithmes de sélection

Lorsque p est grand, on préfère les méthodes de sélection pas à pas qui consiste à introduire ou à supprimer les variables les unes après les autres :

Sélection ascendante "forward"

2. choisir la variable X^{j_2} qui apporte le plus d'information en plus de X^{j_1}
 - ▶ celle pour laquelle le test de Fisher du modèle M_2 contre modèle M_3 :
 $\forall i \in \llbracket 1, n \rrbracket, y_i = \beta_0 + \beta_{j_1} x_i^{j_1} + \beta_{j_2} x_i^{j_2} + \varepsilon_i$ est le plus significatif possible,
 - ▶ celle qui fait progresser le plus le R^2 ...
- 2'. tester la nullité du coefficient de régression associé à X^{j_2} que l'on retient si le test de student est significatif.
- ...

V. Sélection de modèles/variables

5.3. Algorithmes de sélection

Lorsque p est grand, on préfère les méthodes de sélection pas à pas qui consiste à introduire ou à supprimer les variables les unes après les autres :

Sélection ascendante "forward"

Arrêt lorsque

- ▶ le nombre maximal de variables fixé à l'avance est atteint
- ▶ ou lorsque la valeur de R^2 fixée à l'avance est atteinte
- ▶ ou quand le test de nullité du coefficient de régression de la dernière variable introduite n'est pas significatif . . .

En pratique, cette méthode est mal fondée théoriquement et donc déconseillée.

V. Sélection de modèles/variables

5.3. Algorithmes de sélection

Lorsque p est grand, on préfère les méthodes de sélection pas à pas qui consiste à introduire ou à supprimer les variables les unes après les autres :

Sélection descendante "backward" Il s'agit de la version symétrique du "forward" :

- on part du modèle complet M_{p+1}
- à chaque étape k de l'algorithme, on enlève la variable j_k
 - ▶ qui donne le R^2 le plus faible
 - ▶ ou qui donne le test de Student $H_0 : \beta_{j_k} = 0$ contre $H_1 : \beta_{j_k} \neq 0$ le moins significatif (p -valeur la plus grande)
 - ▶ ou qui donne le test de Fisher du modèle sans X^{j_k} contre le modèle comprenant X^{j_k} le moins significative...
- arrêt : lorsque toutes les p -valeurs des tests de student/Fisher sont inférieures à 10% (ou 5% ...)

V. Sélection de modèles/variables

5.3. Algorithmes de sélection

Lorsque p est grand, on préfère les méthodes de sélection pas à pas qui consiste à introduire ou à supprimer les variables les unes après les autres :

Sélection mixte "stepwise" Ascendante avec remise en cause à chaque étape des variables déjà introduites, ce qui permet d'éliminer les variables qui ne sont plus informatives compte tenu de celle qui vient d'être ajoutée.

- étape 1 : identique à sélection ascendante
- étape 2 : choisir X^{j_2} qui apporte le plus d'information en plus de X^{j_1} .
 - ▶ tester le modèle M_1 contre le modèle $M_3 : Y_i = \beta + \beta_{j_1} x_i^{j_1} + \beta_{j_2} x_i^{j_2} + \varepsilon_i$
 - ▶ tester la nullité du coefficient de régression associé à X^{j_2} (dans le modèle M_3)
 - ▶ remettre alors en cause X^{j_1} en testant la nullité de β_{j_1} . Si le test est significatif on conserve M_3 , sinon on enlève X^{j_1} du modèle


VI. Problèmes de colinéarité

- Inverse de la matrice tXX non définie (problème de précision numérique),
- Estimateurs de variance très (trop) grande
- Difficulté de la sélection de variables : on ne peut enlever les variables X^j dont l'effet n'est pas significatif (test de Student non significatif) à cause des problèmes de colinéarité de variables explicatives
- Situation classique
 - ▶ $r(X^1, X^2)$ élevé : les 2 variables explicatives sont fortement corrélées
 - ▶ $r(X^1, Y)$ et $r(X^2, Y)$: les 2 variables explicatives sont corrélées avec la variable à expliquer
 - ▶ dans le modèle avec X^1 seul, X^1 est significatif
 - ▶ dans le modèle avec X^2 seul, X^2 est significatif
 - ▶ dans le modèle avec les deux variables, ni X^1 , ni X^2 ne sont significatifs
 - ▶ quel modèle choisir ? celui avec X^1 seul ou celui avec X^2 seul ? les 2 conviennent!

VI. Problèmes de colinéarité

Comment diagnostiquer une situation de colinéarité critique?

```
plot(data)
```



VI. Problèmes de colinéarité

Comment diagnostiquer une situation de colinéarité critique?

```
cor(data)
```

```
##          Population      Income  Illiteracy   Life.Exp      Murder
## Population  1.00000000  0.2082276  0.10762237 -0.06805195  0.3436
## Income      0.20822756  1.0000000  -0.43707519  0.34025534 -0.2300
## Illiteracy  0.10762237 -0.4370752  1.00000000 -0.58847793  0.7029
## Life.Exp   -0.06805195  0.3402553  -0.58847793  1.00000000 -0.7808
## Murder      0.34364275 -0.2300776  0.70297520 -0.78084575  1.0000
## HS.Grad    -0.09848975  0.6199323  -0.65718861  0.58221620 -0.4879
## Frost      -0.33215245  0.2262822  -0.67194697  0.26206801 -0.5388
## Area        0.02254384  0.3633154  0.07726113 -0.10733194  0.2283
##           HS.Grad      Frost      Area
## Population -0.09848975 -0.3321525  0.02254384
## Income      0.61993232  0.2262822  0.36331544
## Illiteracy -0.65718861 -0.6719470  0.07726113
## Life.Exp    0.58221620  0.2620680 -0.10733194
## Murder      -0.48797102 -0.5388834  0.22839021
## HS.Grad     1.00000000  0.3667797  0.33354187
```

VI. Problèmes de colinéarité

Comment diagnostiquer une situation de colinéarité critique?

On définit le **VIF** (Variance Inflation Factor) qui mesure qualitativement la dépendance linéaire d'une variable X^j par rapport aux autres variables :

$$\text{VIF}_j = \frac{1}{1 - R_j^2},$$

où R_j^2 est le coefficient de détermination de la régression de la variable X^j sur les autres variables.

VI. Problèmes de colinéarité

Pour le calculer :

- effectuer la régression de X^j sur les autres variables explicatives :

$$\forall i \in \llbracket 1, n \rrbracket, \quad x_i^j = \beta_0' + \sum_{k \neq j} \beta_k' x_i^k + \varepsilon_i'$$

- estimer les coefficients $(\beta_j')_{j \neq k}$,
- calculer le R_k^2 associé,
- en déduire le VIF_k .

Interprétation du VIF :

- si $R_j^2 \sim 0$, X^j n'est pas colinéaire aux autres variables et $VIF_j = 1$,
- si $R_j^2 \sim 1$, X^j est fortement liée aux autres variables et VIF_j est grand,
- on considère souvent que $VIF_j \geq 10$ est un signe de colinéarité importante.