

Régression Linéaire Multiple

N. Jégou

Université Rennes 2

M1 2SEP

Les données ozone

Individu	max03	T9	T12	T15	Ne9	Ne12	Ne15	Vx9	Vx12	Vx15	max03v
20010601	87	15.6	18.5	18.4	4	4	8	0.7	-1.7	-0.7	84
20010602	82	17.0	18.4	17.7	5	5	7	-4.3	-4.0	-3.0	87
20010603	92	15.3	17.6	19.5	2	5	4	3.0	1.9	0.5	82
20010604	114	16.2	19.7	22.5	1	1	0	1.0	0.3	-0.2	92
20010605	94	17.4	20.5	20.4	8	8	7	-0.5	-3.0	-4.3	114
20010606	80	17.7	19.8	18.3	6	6	7	-5.6	-5.0	-6.0	94
20010607	79	16.8	15.6	14.9	7	8	8	-4.3	-1.9	-3.88	80
20010610	79	14.9	17.5	18.9	5	5	4	0.0	-1.0	-1.4	99
20010611	101	16.1	19.6	21.4	2	4	4	-0.8	-1.0	-2.3	79
20010612	106	18.3	21.9	22.9	5	6	8	1.3	-2.3	-3.9	101

Au total $n = 112$ mesures.

Objectifs

- Des variables quantitatives :
 - Y : max03 variable à expliquer
 - $X_1 = T9, X_2 = T12, \dots, X_p = \text{max03v}$:
 $p = 10$ variables explicatives
- Expliquer le pic d'ozone Y par les variables X_1, \dots, X_p
- On dispose de données :

$$(Y_i, x_{i1}, \dots, x_{ip})_{i=1, \dots, n} \in \mathbb{R}^{p+1}$$


- → Prévoir pics de pollution
- → Déclencher des mesures de santé publique

Graphes

Les données $\in \mathbb{R}^{p+1}$: impossible à représenter (pour $p > 2$)


Graphes

Pour $p = 2$, représentation possible en 3 dimensions :



Graphes

Pour $p = 2$, représentation possible en 3 dimensions :



Le modèle linéaire

- On généralise les idées vues avec une variable
- On suppose l'existence d'une fonction $f : \mathbb{R}^p \rightarrow \mathbb{R}$ telle que

$$Y = f(X_1, X_2, \dots, X_p) + \varepsilon$$

- Modèle linéaire : f est supposée linéaire

$$\exists (\beta_0, \beta_1, \dots, \beta_p) \in \mathbb{R}^{p+1} : Y = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p + \varepsilon$$

- f est caractérisée par le paramètre $(\beta_0, \beta_1, \dots, \beta_p)$: modèle paramétrique

Le modèle linéaire

- On dispose de données dont on suppose qu'elles sont des réplifications de ce modèle
- Y et ε sont supposées aléatoires
- Les X_1, \dots, X_p sont non aléatoires

- D'où l'écriture (en ligne) du modèle

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \varepsilon_i, \quad i = 1, \dots, n$$

Le modèle linéaire

Ecriture matricielle :

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

avec

$$Y = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix}, \quad X = \begin{pmatrix} 1 & X_{11} & \dots & X_{1p} \\ 1 & X_{21} & \dots & X_{2p} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & X_{n1} & \dots & X_{np} \end{pmatrix}, \quad \beta = \begin{pmatrix} \beta_0 \\ \vdots \\ \beta_p \end{pmatrix} \quad \text{et} \quad \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

Hypothèses

- Hypothèses sur le design :
 - \mathcal{H}_1 : X de rang $p + 1$ (de plein rang)
i.e. Deux colonnes de X ne sont pas (parfaitement) corrélées

→ unicité de $\hat{\beta}$
- Hypothèses sur le résidu ε :
 - \mathcal{H}_2 : $\mathbb{E}(\varepsilon) = 0$ $\text{var}(\varepsilon) = \sigma^2 I_n$
centré / non corrélation des ε_i
 - \mathcal{H}_3 : $\varepsilon \sim \mathcal{N}(0, \sigma^2 I_n)$
→ IC, tests

Estimateur des Moindres Carrés Ordinaires

- Le principe généralise celui de la régression simple
- On minimise le coût quadratique

$$S(\beta_0, \beta_1, \dots, \beta_p) = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_{i1} - \dots - \beta_p x_{ip})^2$$

- On cherche $(\beta_0, \beta_1, \dots, \beta_p)$ tel que $S(\beta_0, \beta_1, \dots, \beta_p)$ minimum

Estimateur des Moindres Carrés Ordinaires

- L'estimateur des MCO (définition)

$$(\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p) = \operatorname{argmin}_{(\beta_0, \beta_1, \dots, \beta_p) \in \mathbb{R}^{p+1}} S(\beta_0, \beta_1, \dots, \beta_p)$$

- L'expression (matricielle) est :

$$\hat{\beta} = (X'X)^{-1}X'Y$$

Estimateur des Moindres Carrés Ordinaires

- Valeurs ajustées (prévues aux points du design) :

$$\hat{Y} = X\hat{\beta}$$

Soit, pour $i = 1, \dots, n$

$$\hat{Y}_i = \hat{\beta}_0 + \sum_{j=1}^p \hat{\beta}_j x_{ij}$$

- Estimation des résidus :

$$\hat{\varepsilon}_i = Y_i - \hat{Y}_i$$

- Estimateur de σ^2 : moyenne des résidus estimés

$$\hat{\sigma}^2 = \frac{1}{n - (p + 1)} \sum_{i=1}^n \hat{\varepsilon}_i^2$$

Propriétés de l'estimateur

- Estimateur $\hat{\beta}$ sans biais :

$$\forall j = 0, \dots, p \quad \mathbb{E}[\hat{\beta}_j] = \beta_j$$

- Estimateur de faible variance :

$$\text{var}(\hat{\beta}) = \sigma^2 (X'X)^{-1}$$

- Estimateur $\hat{\sigma}^2$ sans biais

$$\mathbb{E}[\hat{\sigma}^2] = \sigma^2$$

Intervalles de confiance

- Sous l'hypothèse \mathcal{H}_3 , on a la loi des $\hat{\beta}_j$:

$$\hat{\beta}_j \sim \mathcal{N}(\beta_j, \sigma^2(\mathbf{X}'\mathbf{X})_{jj}^{-1})$$

- On en déduit des IC sur les paramètres inconnus β_j :

$$\hat{\beta}_j - t_{1-\alpha/2}(n-p)\sqrt{\hat{\text{var}}(\hat{\beta}_j)} \leq \beta_j \leq \hat{\beta}_j + t_{1-\alpha/2}(n-p)\sqrt{\hat{\text{var}}(\hat{\beta}_j)}$$

avec la variance estimée

$$\hat{\text{var}}(\hat{\beta}_j) = \hat{\sigma}^2(\mathbf{X}'\mathbf{X})_{jj}^{-1}$$

Test de nullité d'un paramètre β_j

- On fixe l'erreur de première espèce
- Deux hypothèses pour formaliser l'influence (ou non) de X_j :

$$\mathcal{H}_0 : \beta_j = 0 \quad \text{vs} \quad \mathcal{H}_1 : \beta_j \neq 0$$

- La statistique de test :

$$T = \frac{\hat{\beta}_j}{\widehat{\text{var}}(\hat{\beta}_j)} \stackrel{\mathcal{H}_0}{\sim} \mathcal{T}(n-p)$$

- Observation de la stat. de test : T_{obs}
→ p-value
- Décision / Conclusion

Test de significativité globale

- C'est un test entre modèles emboîtés
- Les deux modèles envisagés sont
Modèle \mathbf{H}_1 (complet) : $Y = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p + \varepsilon$
Modèle \mathbf{H}_0 : $Y = \beta_0 + \varepsilon$
- La statistique de test est une statistique de Fisher :

$$F = \frac{\|\hat{Y}_{\mathbf{H}_1} - \hat{Y}_{\mathbf{H}_0}\|^2 / p}{\hat{\sigma}^2} \underset{\mathbf{H}_0}{\sim} \mathcal{F}(p, n - (p + 1))$$

- Décision entre :
 - Tous les $\beta_j, j \geq 1$ sont nuls : \mathbf{H}_0
 - Au moins un des $\beta_j, j \geq 1$ non nul : \mathbf{H}_1

Le coin de R

Estimation dans le modèle complet :

```
> reg.complet <- lm(max03 ~ ., data = don)
> summary(reg.complet)
```

Call:

```
lm(formula = max03 ~ ., data = don)
```

Residuals:

Min	1Q	Median	3Q	Max
-53.566	-8.727	-0.403	7.599	39.458

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	12.24442	13.47190	0.909	0.3656
T9	-0.01901	1.12515	-0.017	0.9866
T12	2.22115	1.43294	1.550	0.1243
T15	0.55853	1.14464	0.488	0.6266
Ne9	-2.18909	0.93824	-2.333	0.0216 *
Ne12	-0.42102	1.36766	-0.308	0.7588
Ne15	0.18373	1.00279	0.183	0.8550
Vx9	0.94791	0.91228	1.039	0.3013
Vx12	0.03120	1.05523	0.030	0.9765
Vx15	0.41859	0.91568	0.457	0.6486
max03v	0.35198	0.06289	5.597	1.88e-07 ***

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

Residual standard error: 14.36 on 101 degrees of freedom

Multiple R-squared: 0.7638, Adjusted R-squared: 0.7405

F-statistic: 32.67 on 10 and 101 DF, p-value: < 2.2e-16

Le coin de R

Intervalles de confiance sur les β_j :

```
> confint(reg.complet)
              2.5 %      97.5 %
(Intercept) -14.4802083 38.9690481
T9           -2.2510136  2.2129851
T12          -0.6214249  5.0637287
T15          -1.7121182  2.8291799
Ne9          -4.0502993 -0.3278850
Ne12         -3.1340934  2.2920630
Ne15         -1.8055357  2.1729977
Vx9          -0.8618028  2.7576211
Vx12         -2.0620871  2.1244836
Vx15         -1.3978619  2.2350470
max03v       0.2272237  0.4767292
```

Le coin de R

Prédictions

```
> new.x <- data.frame(max03=88, T9=15, T12=18, T15=20,  
+ Ne9=3, Ne12=4, Ne15=4, Vx9=0.7, Vx12=1.3, Vx15=1.4, max03v=85)  
  
> predict.lm(reg.complet, newdata = new.x)  
1  
86.80227
```

Le coin de R

Test global du modèle

```
> reg0 <- lm(max03 ~ 1, data = don)
```

```
> anova(reg0, reg.complet)
```

```
Analysis of Variance Table
```

```
Model 1: max03 ~ 1
```

```
Model 2: max03 ~ T9 + T12 + T15 + Ne9 + Ne12 + Ne15 + Vx9 + Vx12 + Vx15 +  
max03v
```

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	111	88192				
2	101	20827	10	67364	32.668	< 2.2e-16 ***

```
---
```

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


Intérêt d'un modèle parcimonieux

- Beaucoup de variables X dans le modèle :
 - Risque de surajustement : mauvais en prévision
 - Souvent des $\hat{\beta}_j$ non significativement $\neq 0$
 - Variables explicatives possiblement très corrélées
- Intérêt d'un modèle parcimonieux :
 - Retenir les variables significatives
 - Coût éventuellement moins élevé
 - Recherche de meilleurs prévisions

Le R^2 pour sélectionner un modèle ?

- Le R^2 mesure la qualité d'ajustement :

$$R^2 = \frac{\text{var}(\hat{Y})}{\text{var}(Y)}$$

- Problème : quand on ajoute une variable, le R^2 augmente
- Le critère du R^2 conduira à choisir le modèle complet
- \Rightarrow ce n'est pas un bon critère

Autres idées ?

- Enlever les variables non significatives du modèle complet ?
Problème : le fait d'enlever une seule variable modifie p-values et estimation des paramètres \Rightarrow sélection pas à pas ?
- Tests emboîtés sur tous les modèles possibles ?
Problème : beaucoup trop de modèles possibles

Sélection de modèle par critères pénalisés

- Dilemme :
 - Ajouter des variables : \uparrow la qualité d'ajustement
 - \Rightarrow risque de surajustement
- Les critères pénalisés résultent d'un compromis entre
 - Un terme favorisant la qualité d'ajustement
 - Un terme pénalisant le nombre de variables

Sélection de modèle par critères pénalisés

- Terme favorisant la qualité d'ajustement :

$$\phi_1\left(\sum (y_i - \hat{y}_i)^2\right) \quad \phi_1 \searrow$$

- Terme pénalisant le nombre de variables :

$$\phi_2 (\text{nb. de variables}) \quad \phi_2 \nearrow$$

- Compromis


$$\operatorname{argmin} \left\{ \phi_1\left(\sum (y_i - \hat{y}_i)^2\right) + \phi_2 (\text{nb. de variables}) \right\}$$

- Selon la fonction ϕ_2 , on a les critères : AIC, BIC, C_p, \dots

Mise en œuvre avec R

```
> library(leaps)
> critere.penalise <- regsubsets(max03~., int=T, nbest=1,
+   nvmax=10, method = "exhaustive",
+   really.big = T, data = don)
> plot(critere.penalise, scale = "bic")
```

Mise en œuvre avec R



Comparaison de modèles : Apprentissage - Validation

- Idée : se mettre en situation de prévision et comparer les performances des modèles
- Méthodologie
 - On sépare les données en deux échantillons : Apprentissage / Validation
 - On estime les $\hat{\beta}_j$ du modèle sur l'échantillon d'apprentissage
 - On déduit les prévisions \hat{Y}^* sur l'échantillon de validation
 - On calcule une erreur de prévision en comparant aux Y^* réellement observés sur l'échantillon de validation :

$$\|Y^* - \hat{Y}^*\|^2 = \frac{1}{n_{\text{validation}}} \sum_{i=1}^{n_{\text{validation}}} (Y_i^* - \hat{Y}_i^*)^2$$

- Nécessite suffisamment de données

Comparaison de modèles : Apprentissage - Validation

