

Introduction à la régression

cours n°4

*Interprétation géométrique
Précision et validation du modèle*

ENSM.SE – 1A

Olivier Roustant - Laurent Carraro

Objectifs du cours

- Connaître l'interprétation géométrique de la régression linéaire
- Savoir utiliser le coefficient de détermination R^2 pour apprécier la précision d'une régression
- Savoir valider ou invalider un modèle linéaire

Prévisions ponctuelles

- Considérons le modèle linéaire

$$y_i = \beta_0 + \beta_1 x_{1,i} + \dots + \beta_p x_{p,i} + e_i$$

avec e_1, \dots, e_n i.i.d $N(0, \sigma^2)$

- Prévision sans la régression :

$$\bar{y} := \sum_{i=1}^n y_i / n$$

- Prévision avec la régression :

$$\hat{y}_i := \hat{\beta}_0 + \hat{\beta}_1 x_{1,i} + \dots + \hat{\beta}_p x_{p,i}$$

Intérêt du modèle de régression

- Le modèle de régression a de l'intérêt si les erreurs $y_i - \hat{y}_i$ sont petites **relativement** aux erreurs $y_i - \bar{y}$ que l'on ferait sans avoir de prédicteurs
 - Donne envie de regarder $\frac{\|Y - \hat{Y}\|}{\|Y - \bar{Y}\|}$ avec $\|\cdot\|$ la norme usuelle de R^n et :

$$\hat{Y} = (\hat{y}_1, \dots, \hat{y}_n)' \quad \bar{Y} = (\bar{y}, \dots, \bar{y})' = \bar{y}(1, \dots, 1)' =: \bar{y}1$$

Des moindres carrés à la géométrie

- Estimation par moindres carrés

$$\hat{\beta} = \underset{\beta}{\operatorname{Argmin}} \|Y - X\beta\|^2$$


- Interprétation géométrique
 - $\hat{Y} = X\hat{\beta}$ est la **projection orthogonale** dans R^n de Y sur le plan engendré par les prédicteurs (1 inclus)

Des angles droits partout !

➤ Exercice

- Montrer que \bar{Y} est la projection orthogonale de Y sur la droite de R^n engendrée par $1 = (1, \dots, 1)$
- En déduire que \bar{Y} est aussi la projection orthogonale de \hat{Y} sur cette même droite

Interprétation géométrique




Coefficient de détermination R²


- Définition
 - $R^2 = 1 - \frac{\|\mathbf{Y} - \hat{\mathbf{Y}}\|^2}{\|\mathbf{Y} - \bar{\mathbf{Y}}\|^2} = \frac{\|\hat{\mathbf{Y}} - \bar{\mathbf{Y}}\|^2}{\|\mathbf{Y} - \bar{\mathbf{Y}}\|^2} \in [0,1]$
- Interprétation :
 - Pourcentage de variance expliquée par la régression
 - Numérateur et dénominateur s'interprètent effectivement comme la variance empirique des quantités considérées
 - La réponse est bien expliquée par la régression lorsque R² est proche de 1

Exemple

$$y_i = 1 - 0.2 i + e_i \text{ avec } e_1, \dots, e_{100} \text{ i.i.d } N(0, s^2)$$




$s=5, R^2 = 0.583$



$s=1, R^2 = 0.969$

Données de pollution (cf cours 1)



Call:

lm(formula = log(NO3) ~ log(SO4), data = pollution)

Residuals:

	Min	1Q	Median	3Q	Max
	-0.80424	-0.14485	-0.01087	0.16564	0.56666

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-0.43642	0.03679	-11.86	<2e-16 ***
log(SO4)	0.92168	0.03356	27.47	<2e-16 ***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’

R² de 82% : le prédicteur explique
plutôt bien la réponse

Residual standard error: 0.2417 on 165 degrees of freedom

Multiple R-Squared: 0.8205, Adjusted R-squared: 0.8195

F-statistic: 754.4 on 1 and 165 DF, p-value: < 2.2e-16

Quelques dangers du R²

- Le coefficient de détermination peut être égal à 1, et le modèle inexploitable
 - C'est ce qui arrive avec un modèle linéaire polynômial de degré n-1 avec n points...
- Attention : la précision du modèle n'est valable qu'aux points d'observation x_i
 - En dehors, on ne peut rien dire

Validation du modèle

- On cherche à savoir si l'hypothèse du modèle linéaire est validée :
 - Avait t-on le droit de supposer que e_1, \dots, e_n sont **indépendants** et de **même loi normale** ?

- On va étudier les « **résidus** » :

$$\hat{e}_i = y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_{1,i} + \dots + \hat{\beta}_p x_{p,i})$$

Que regarder sur les résidus ?



- Les résidus ne devraient pas montrer de régularité (indépendance + même loi), et être centrés sur 0
 - Tracé des résidus
 - Tracé des résidus contre chaque prédicteur
 - Tracé des résidus contre la réponse estimée

Que faut-il regarder sur les résidus (2)

- Les résidus devraient être normaux
 - Tracé de la droite de Henri
- Il conviendrait d'étudier les **résidus standardisés** et même **studentisés**
 - Pas au programme cette année !

Exemple de résidus corrects


- Simulations -



Exemple d'étude


- Réponse : pourcentage d'un rendement maximal de blé
- Prédicteur : quantité de pluies printanières (en m)
- 54 observations

Observation des données



```
donnees <- read.table("reg_pluie.txt", dec=",", sep="\t", header=TRUE)
plot(donnees)
```


Observation des données (suite)



`pairs(donnees)`

1er modèle

$$y_i = \beta_0 + \beta_1 x_i + e_i \text{ avec } e_1, \dots, e_{54} \text{ i.i.d } N(0, \sigma^2)$$



```
mod1 <- lm(rendement~pluie, data=donnees)
plot(rendement~pluie, data=donnees)
lines(donnees$pluie, mod1$fitted.values, col="red")
```

Table d'ANOVA

Call:

```
lm(formula = rendement ~ pluie, data = donnees)
```

Residuals:

Min	1Q	Median	3Q	Max
-0.119861	-0.034987	0.003603	0.040208	0.108037

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)		
(Intercept)	0.06620	0.02405	2.752	0.00813 **		
pluie	1.63673	0.07526	21.747	< 2e-16 ***		

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


Residual standard error: 0.05201 on 52 degrees of freedom

Multiple R-Squared: 0.9009, Adjusted R-squared: 0.899

F-statistic: 472.9 on 1 and 52 DF, p-value: < 2.2e-16


```
mod1 <- lm(rendement~pluie, data=donnees)
summary(mod1)
```

Examen des résidus



Examen des résidus (suite)


Courbure quadratique des résidus :
Suggère un polynôme de degré 2



```
plot(mod1$residuals~pluie, data=donnees)
plot(mod1$residuals~mod1$fitted.values, data=donnees)
```

2ème modèle

$$y_i = \beta_0 + \beta_1 x_i + \beta_{11} x_i^2 + e_i \text{ avec } e_1, \dots, e_{54} \text{ i.i.d } N(0, \sigma^2)$$



```
mod2 <- lm(rendement~pluie+I(pluie^2), data=donnees)
plot(rendement~pluie, data=donnees)
lines(donnees$pluie, mod2$fitted.values, col="red")
```

Table d'ANOVA

Call:

```
lm(formula = rendement ~ pluie + I(pluie^2), data = donnees)
```

Residuals:

Min	1Q	Median	3Q	Max
-0.125759	-0.031894	-0.000287	0.035384	0.093880

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-0.04246	0.04512	-0.941	0.35109
pluie	2.50171	0.31868	7.850	2.49e-10 ***
I(pluie^2)	-1.52278	0.54701	-2.784	0.00752 **

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


Residual standard error: 0.04893 on 51 degrees of freedom

Multiple R-Squared: 0.914, Adjusted R-squared: 0.9106



F-statistic: 271 on 2 and 51 DF, p-value: < 2.2e-16

```
mod2 <- lm(rendement~pluie+I(pluie^2), data=donnees)
summary(mod2)
```

Examen des résidus du 2nd modèle




Examen des résidus (suite)



```
plot(mod2$residuals~pluie,data=donnees)
plot(mod2$residuals~mod2$fitted.values, data=donnees)
```

Dernière étape : normalité des résidus



Conclusion

- Le modèle de régression linéaire polynomial de degré 2 est validé
- On pourra l'utiliser pour faire des prévisions