

TP R : Effets fixes et aléatoires

C. Preda

le 27 Mars 2018

Objectif du TP

L'objectif de ce TP est d'introduire les effets aléatoires dans un modèle d'analyse de la variance et plus généralement dans un modèle de régression. On fait appel à ce type d'effets (technique) dans le contexte des mesures répétées ou l'hypothèse d'indépendance des observations n'est plus valide. Nous allons illustrer cela de manière progressive à l'aide d'un exemple. Les packages qu'on va utiliser sont **nlme** et **lme4**.

Présentation du problème et des données.

Il s'agit de voir si le passage du sucre dans le sang (absorption) est différent chez les patients obèses et chez les patients contrôle (non-obèses). Pour cela, on réalise le plan d'expérience suivant : on forme un échantillon aléatoire de 13 patients obèses et un échantillon aléatoire de 20 patients contrôle. À chaque patient on administre une quantité fixe de sucre (10mg) et on regarde ensuite la glycémie (unité de mesure non-précisée) à 8 instants de temps différentes : à $t_0 = 0$ (avant la dose de sucre), à $t_1 = 0.5$ heures après la prise de sucre, et puis à $t_2 = 1h$, $t_3 = 1.5h$, $t_4 = 2h$, $t_5 = 3h$, $t_6 = 4h$ et $t_7 = 5h$.

La base de données est disponible en format *csv* (séparateur ";") à l'adresse :

<http://math.univ-lille1.fr/~preda/GIS5/glycemie.csv>

Remarquez la présence d'un en-tête pour les noms de variables dont un identificateur pour chaque patient (*id*). Pour des raisons qui seront évidentes plus tard, n'utilisez pas cette colonne comme *row.names* lors de la lecture des données.

Voici quelques tâches qui vous sont demandées:

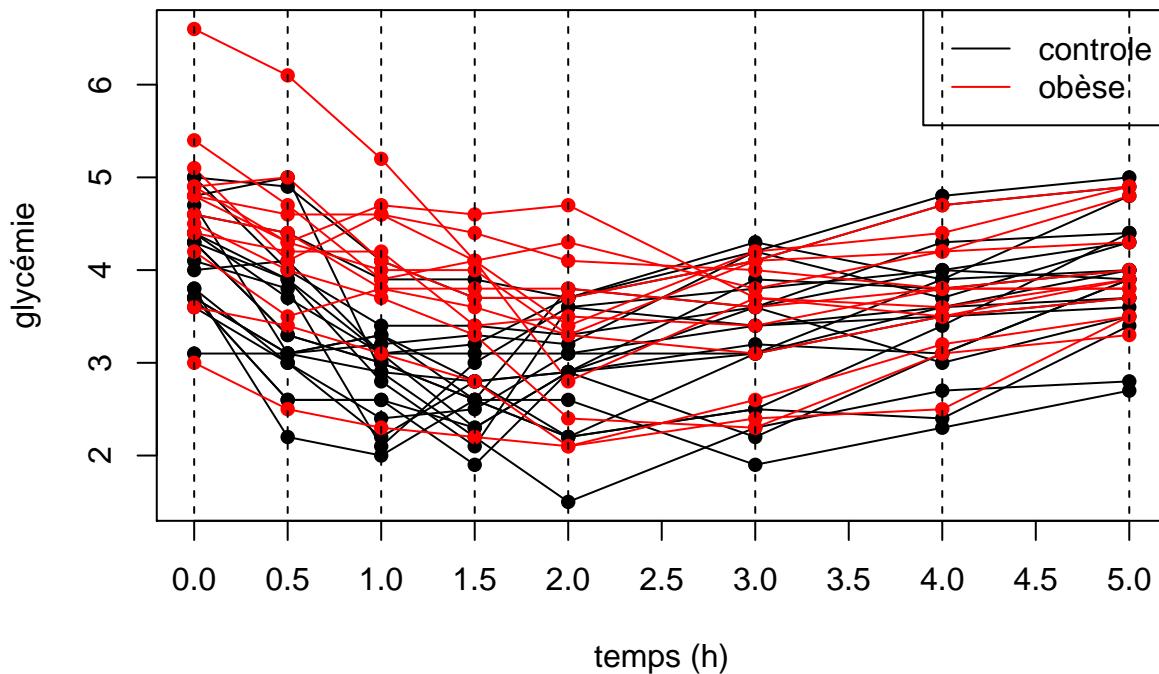
1. Statistiques descriptives pour chaque variable temps.

Preciser notamment la moyenne et l'écart-type.

2. Représentation graphique des données.

On attend quelques choses du genre :

Courbes de glycémie

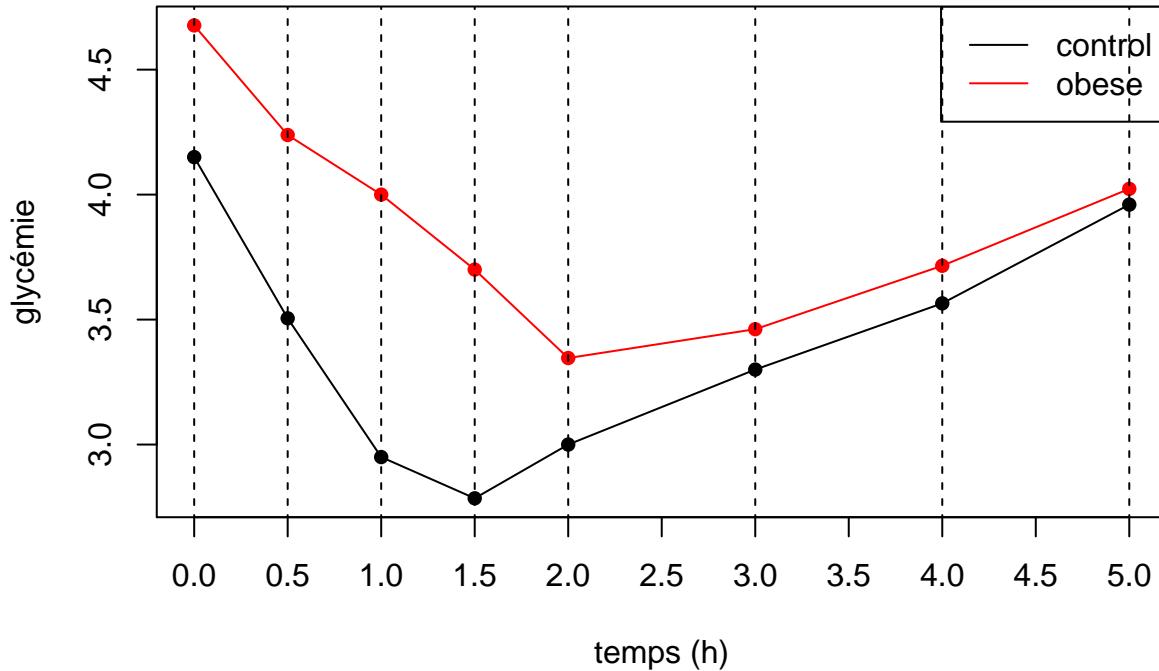


3. Comparaison des deux groupes par l'évolution moyenne de la glycémie

On s'intéresse à l'évolution moyenne de la glycémie par groupe.

Réaliser les graphiques suivants :

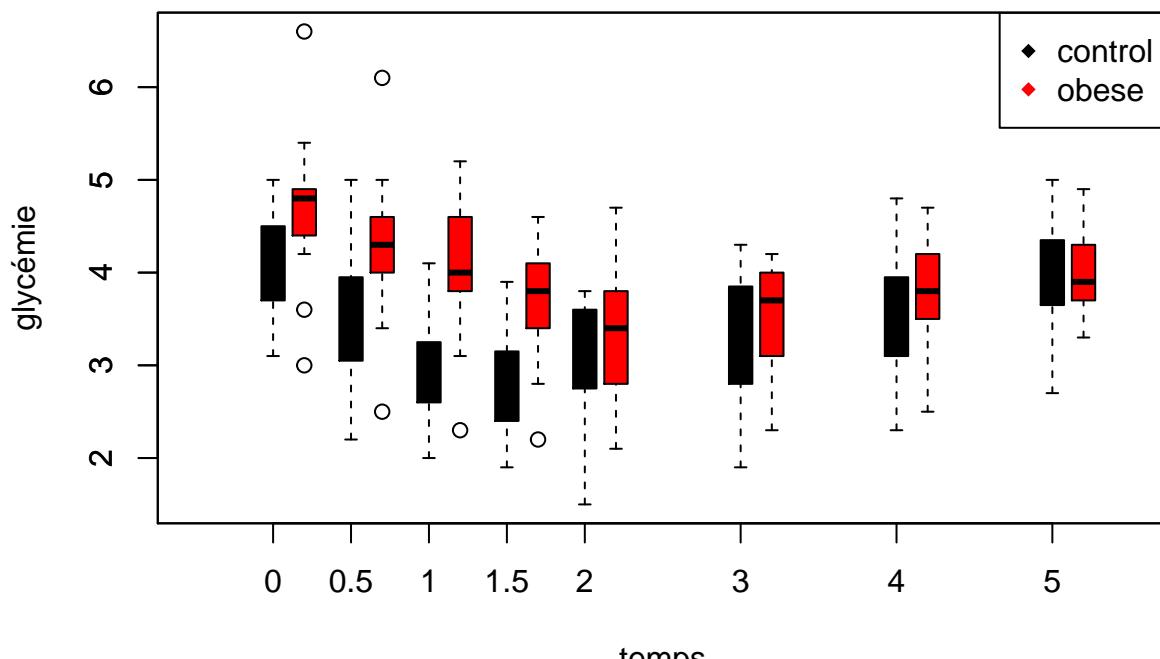
Evolution moyenne des deux groupes



ou en-

core :

Evolution moyenne des deux groupes



Pour ce dernier graphique, on utilisera surtout les paramètres *boxwex*, *at*, *boxfill* et *names* de la fonction *boxplot*.
Elevons le niveau de l'analyse statistiques (et de la discussion) maintenant.

4. Les premiers tests statistiques pour comparer les groupes.

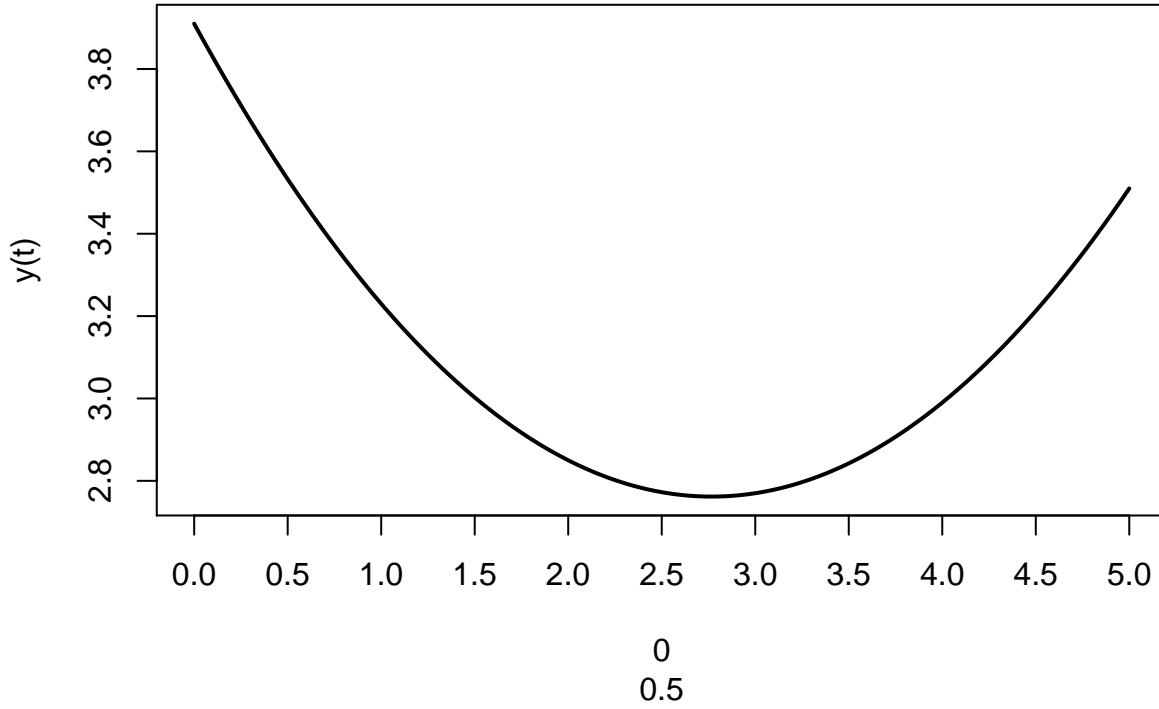
Pour chaque temps, comparer les deux groupes selon le niveaux moyen de la glycémie.

Note: Selon que l'hypothèse de normalité des données est vérifiée (à l'aide du test de Shapiro - fonction *shapiro.test*, on utilisera le test de Student (fonction *t.test*) ou, dans le cas contraire, le test de Wilcoxon (fonction *wilcox.test*). Pour rappel, les tests de Student et Wilcoxon permettent de vérifier l'hypothèse nulle selon laquelle les deux groupes ont la même esperance de la glycémie. Le test de Wilcoxon est un test non-paramétrique - c'est-à-dire que son utilisation n'est pas conditionnée par la loi des données.

Au vue des résultats numériques (et graphiques) il y a donc des differences significatives entre les deux groupes. Alons plus en détail.

Un modèle de régression quadratique

L'évolution de la glycémie en fonction du temps semble une fonction quadratique, c'est à dire une courbe (parabole) en "U" :



$$y(t) = a + bt + ct^2 + \varepsilon$$

avec a , b et c des coefficients et ε une erreur aléatoire.

Estimer un modèle de régression quadratique pour chaque groupe séparément. La variable explicative est donc le temps. Il faudrait donc construire cette variable. On transformera donc ces données initiales (dites en format *large*) en format *long* :

```
FALSE      groupe id temps    Y
FALSE 1    control 1   0.0 4.3
FALSE 2    control 1   0.5 3.3
FALSE 3    control 1   1.0 3.0
FALSE 4    control 1   1.5 2.6
FALSE 5    control 1   2.0 2.2
FALSE 6    control 1   3.0 2.5
FALSE 7    control 1   4.0 3.4
FALSE 8    control 1   5.0 4.4
FALSE 9    control 2   0.0 3.7
FALSE 10   control 2   0.5 2.6
```

Ceci se réalise facilement grâce à la fonction *reshape*. Voici le code R:

```
dlong <- reshape(data = d,
                  varying = list(names(d)[3:10]),
                  #idvar = c("id", "groupe"),
                  idvar = c("id"),
                  direction = "long", v.names = "Y"
                  )

head(dlong) # pour voir le résultat brut !
#Arrangeons un peu cela :

names(dlong)= c("groupe", "id", "temps", "Y")
```

```

dlong=dlong[order(dlong$id),]
row.names(dlong)=1:nrow(dlong)

# mettons les vrais temps
dlong[dlong$temp==1,c("temps")] = 0
dlong[dlong$temp==2,c("temps")] = 0.5
dlong[dlong$temp==3,c("temps")] = 1
dlong[dlong$temp==4,c("temps")] = 1.5
dlong[dlong$temp==5,c("temps")] = 2
dlong[dlong$temp==6,c("temps")] = 3
dlong[dlong$temp==7,c("temps")] = 4
dlong[dlong$temp==8,c("temps")] = 5

head(dlong, 10)

```

Maintenant on peut réaliser un modèle de régression quadratique pour les controles, par exemple.

```

mq_controle = lm(Y~temp+I(temp^2), data =dlong[dlong$groupe=="control", ])
summary(mq_controle)

```

Call:

```

lm(formula = Y ~ temp + I(temp^2), data = dlong[dlong$groupe ==
    "control", ])

```

Residuals:

Min	1Q	Median	3Q	Max
-1.45631	-0.44145	-0.05631	0.48336	1.47861

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)							
(Intercept)	3.88111	0.11377	34.114	< 2e-16 ***							
temp	-0.80512	0.11624	-6.926	1.05e-10 ***							
I(temp^2)	0.17136	0.02249	7.618	2.27e-12 ***							

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

Residual standard error: 0.6525 on 157 degrees of freedom

Multiple R-squared: 0.2774, Adjusted R-squared: 0.2682

F-statistic: 30.14 on 2 and 157 DF, p-value: 8.377e-12

```

print (shapiro.test(mq_controle$residuals)) #tester la normalité des residus

```

Shapiro-Wilk normality test

```

data: mq_controle$residuals
W = 0.99215, p-value = 0.5322
library(lmtest)
print(bptest(mq_controle)) # tester homoscedasticité des residus

```

studentized Breusch-Pagan test

```

data: mq_controle

```

```
BP = 0.50688, df = 2, p-value = 0.7761
print(dwtest(mq_controle)) # tester l'autocorrelation des residus
```

Durbin-Watson test

```
data: mq_controle
DW = 0.87339, p-value = 2.636e-13
alternative hypothesis: true autocorrelation is greater than 0
```

On a donc un problème d'autocorrelation des residus! Corrélationn due au temps!

Réaliser le même modèle pour le groupe des obeses et comparer les deux modèles à l'aide des coefficients et des leurs intervalles de confiance. Tracer les deux fonctions de régression sur le même graphique.

```
mq_obese = lm(Y~temp + I(temp^2), data = dlong[dlong$groupe == "obese", ])
summary(mq_obese)
```

```
Call:
lm(formula = Y ~ temp + I(temp^2), data = dlong[dlong$groupe ==
"obese", ])
```

Residuals:

Min	1Q	Median	3Q	Max
-1.75853	-0.29633	0.02538	0.41733	1.94380

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	4.65620	0.15373	30.288	< 2e-16 ***
temp	-0.87119	0.15706	-5.547	2.34e-07 ***
I(temp^2)	0.15169	0.03039	4.991	2.51e-06 ***

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

Residual standard error: 0.7108 on 101 degrees of freedom

Multiple R-squared: 0.2429, Adjusted R-squared: 0.2279

F-statistic: 16.2 on 2 and 101 DF, p-value: 7.893e-07

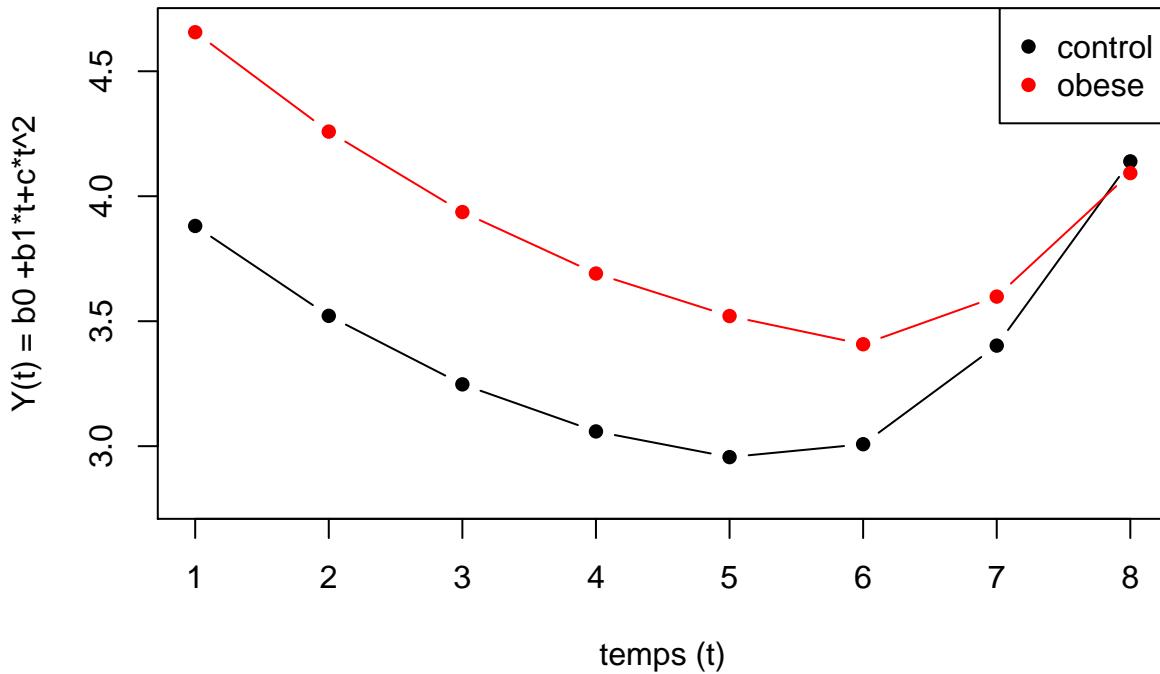
tracage des deux fonctions de regression:

```
plot(predict(mq_controle, newdata = data.frame(temp = t)), type = "b", col = "black", pch = 16, ylim =
main="Fonctions de régression pour les deux groupes",
ylab = "Y(t) = b0 +b1*t+c*t^2", xlab = "temp (t)")

lines(predict(mq_obese, newdata = data.frame(temp = t)), type = "b", col = "red", pch = 16)

legend("topright", c("control", "obese"), pch = c(16,16), col = c("black", "red"))
```

Fonctions de régression pour les deux groupes



Comparaison des fonctions de régression:

```
print(summary(mq_controle)$coefficients)
```

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	3.8811149	0.11377062	34.113508	1.677238e-74
temps	-0.8051201	0.11623791	-6.926485	1.045965e-10
I(temps^2)	0.1713587	0.02249273	7.618401	2.269600e-12

```
print(summary(mq_obese)$coefficients)
```

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	4.6561992	0.15372838	30.288481	1.73557e-52
temps	-0.8711851	0.15706222	-5.546751	2.34290e-07
I(temps^2)	0.1516886	0.03039248	4.990989	2.51214e-06

Interpréter le modèle :

```
mq = lm(Y~groupe*(temps+I(temps^2)), data = dlong)
summary(mq)
```

Call:
`lm(formula = Y ~ groupe * (temps + I(temps^2)), data = dlong)`

Residuals:

Min	1Q	Median	3Q	Max
-1.75853	-0.42139	-0.00511	0.44205	1.94380

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	3.88111	0.11786	32.931	< 2e-16 ***

```

groupeobese          0.77508   0.18777   4.128 4.95e-05 ***
temps                -0.80512   0.12041  -6.686 1.41e-10 ***
I(temp^2)            0.17136   0.02330   7.354 2.55e-12 ***
groupeobese:temps   -0.06606   0.19185  -0.344   0.731
groupeobese:I(temp^2) -0.01967   0.03712  -0.530   0.597
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 0.6759 on 258 degrees of freedom
Multiple R-squared: 0.3274, Adjusted R-squared: 0.3143
F-statistic: 25.11 on 5 and 258 DF, p-value: < 2.2e-16

Ecrire ce modèle et comparer avec les deux modèles précédentes. Que observez vous ?

Est-ce modèle valid ?

```
shapiro.test(mq$residuals) # p-value = 0.6341 ok - normalité
```

Shapiro-Wilk normality test

```

data: mq$residuals
W = 0.99546, p-value = 0.6341
btptest(mq) # p-value = 0.3461 ok - homoscédasticité
```

studentized Breusch-Pagan test

```

data: mq
BP = 5.6093, df = 5, p-value = 0.3461
dwtest(mq$residuals~dlong$temp) # p-value < 2.2e-16 NON ! residus autocorélés (y(t) est corrélé avec
```

Durbin-Watson test

```

data: mq$residuals ~ dlong$temp
DW = 0.72787, p-value < 2.2e-16
alternative hypothesis: true autocorrelation is greater than 0
```

Réalisons un modèle mixte basé sur mq. On commence avec la variante la plus simple : intercept aléatoire :

```
library(nlme)
```

```
mq_mixte1 = lme(Y~groupe*(temp+I(temp^2)), random = ~1|id, data =dlong, method = "ML")
summary(mq_mixte1)
```

Linear mixed-effects model fit by maximum likelihood

```
Data: dlong
      AIC      BIC      logLik
420.2566 448.8642 -202.1283
```

Random effects:

```
Formula: ~1 | id
        (Intercept) Residual
StdDev: 0.495311 0.4485368
```

```

Fixed effects: Y ~ groupe * (temps + I(temps^2))
              Value Std.Error DF  t-value p-value
(Intercept)      3.881115 0.13715062 227 28.298194 0.0000
groupeobese      0.775084 0.21851591  31  3.547038 0.0013
temps            -0.805120 0.08082548 227 -9.961216 0.0000
I(temps^2)        0.171359 0.01564022 227 10.956285 0.0000
groupeobese:temps -0.066065 0.12877561 227 -0.513024 0.6084
groupeobese:I(temps^2) -0.019670 0.02491885 227 -0.789366 0.4307

```

Correlation:

	(Intr)	gropbs	temps	I(t^2)	grpbs:
groupeobese	-0.628				
temps	-0.463	0.291			
I(temps^2)	0.386	-0.242	-0.962		
groupeobese:temps	0.291	-0.463	-0.628	0.604	
groupeobese:I(temps^2)	-0.242	0.386	0.604	-0.628	-0.962

Standardized Within-Group Residuals:

Min	Q1	Med	Q3	Max
-2.57947754	-0.61445174	-0.01557856	0.59624584	3.12335932

Number of Observations: 264

Number of Groups: 33

```

## visualiser les effets aléatoirs (alpha_i)
ranef(mq_mixte1)

```

```

(Intercept)
1 -0.171767742
2 -0.375848228
3  0.020974939
4 -0.115078718
5  0.009637134
6 -0.307821399
7 -0.205781156
8  0.145690791
9  0.429135910
10 -0.681968957
11 -0.443875057
12  0.440473715
13  0.281744448
14 -0.398523838
15  0.893985906
16  0.825959077
17  0.111677377
18 -0.636617738
19  0.077663963
20  0.100339572
21  0.072387523
22 -1.106744173
23  0.446535080
24  0.355832642
25 -0.029652720
26  0.219778985
27  0.412521666
28  0.333157032

```

```

29 -0.256408815
30  0.900047271
31 -0.879988078
32 -0.517178325
33  0.049711913

## validité du modèle
shapiro.test(mq_mixte1$residuals)

```

Shapiro-Wilk normality test

```

data: mq_mixte1$residuals
W = 0.99467, p-value = 0.06364
dwtest(residuals(mq_mixte1) ~ dlong$temp)

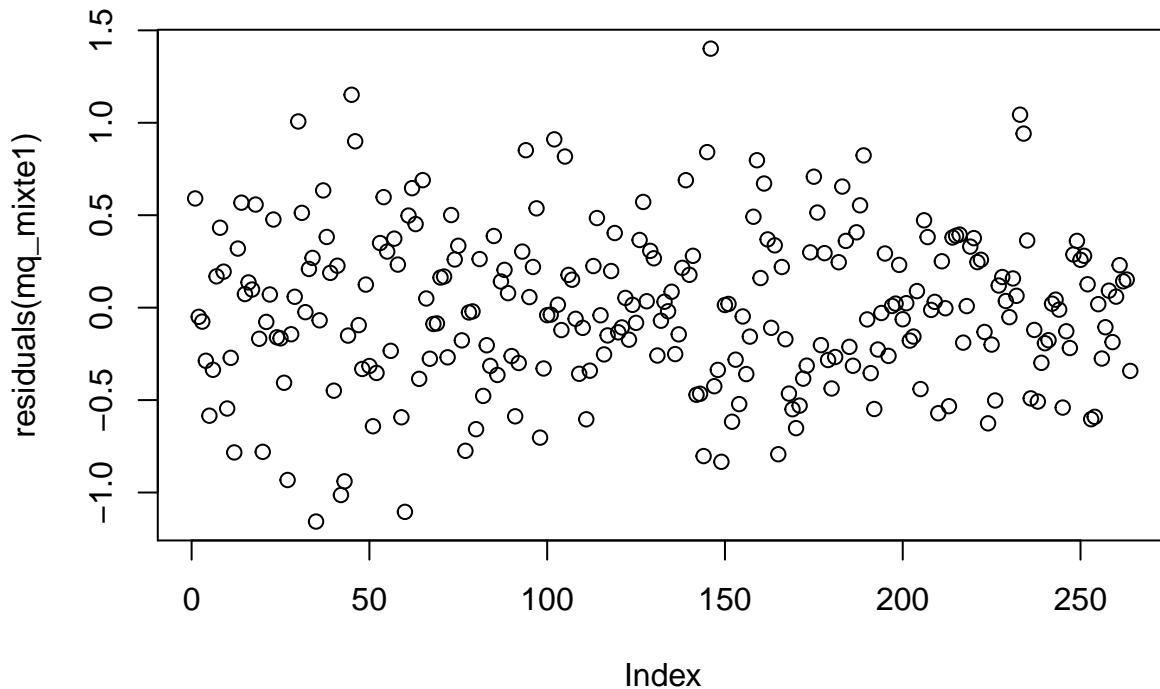
```

Durbin-Watson test

```

data: residuals(mq_mixte1) ~ dlong$temp
DW = 1.4638, p-value = 5.672e-06
alternative hypothesis: true autocorrelation is greater than 0
plot(residuals(mq_mixte1))

```



Réalisons un modèle mixte basé sur mq avec intercept et pente aléatoires.

```

mq_mixte2 = lme(Y ~ groupe * (temp + I(temp^2)), random = ~ temp | id, data = dlong)

summary(mq_mixte2)

```

```

Linear mixed-effects model fit by REML
Data: dlong
      AIC      BIC      logLik

```

442.1909 477.7205 -211.0955

Random effects:

Formula: ~temp | id
Structure: General positive-definite, Log-Cholesky parametrization
StdDev Corr
(Intercept) 0.58226295 (Intr)
temp 0.09931983 -0.479
Residual 0.41944687

Fixed effects: Y ~ groupe * (temp + I(temp^2))

	Value	Std.Error	DF	t-value	p-value
(Intercept)	3.881115	0.14933198	227	25.989843	0.0000
groupeobese	0.775084	0.23792393	31	3.257698	0.0027
temp	-0.805120	0.07795033	227	-10.328630	0.0000
I(temp^2)	0.171359	0.01445871	227	11.851588	0.0000
groupeobese:temp	-0.066065	0.12419476	227	-0.531947	0.5953
groupeobese:I(temp^2)	-0.019670	0.02303641	227	-0.853870	0.3941

Correlation:

	(Intr)	grpobs	temp	I(t^2)	grpbs:
groupeobese	-0.628				
temp	-0.496	0.311			
I(temp^2)	0.327	-0.205	-0.923		
groupeobese:temp	0.311	-0.496	-0.628	0.579	
groupeobese:I(temp^2)	-0.205	0.327	0.579	-0.628	-0.923

Standardized Within-Group Residuals:

Min	Q1	Med	Q3	Max
-2.7747658	-0.5953673	-0.0317570	0.5480193	2.8272453

Number of Observations: 264

Number of Groups: 33

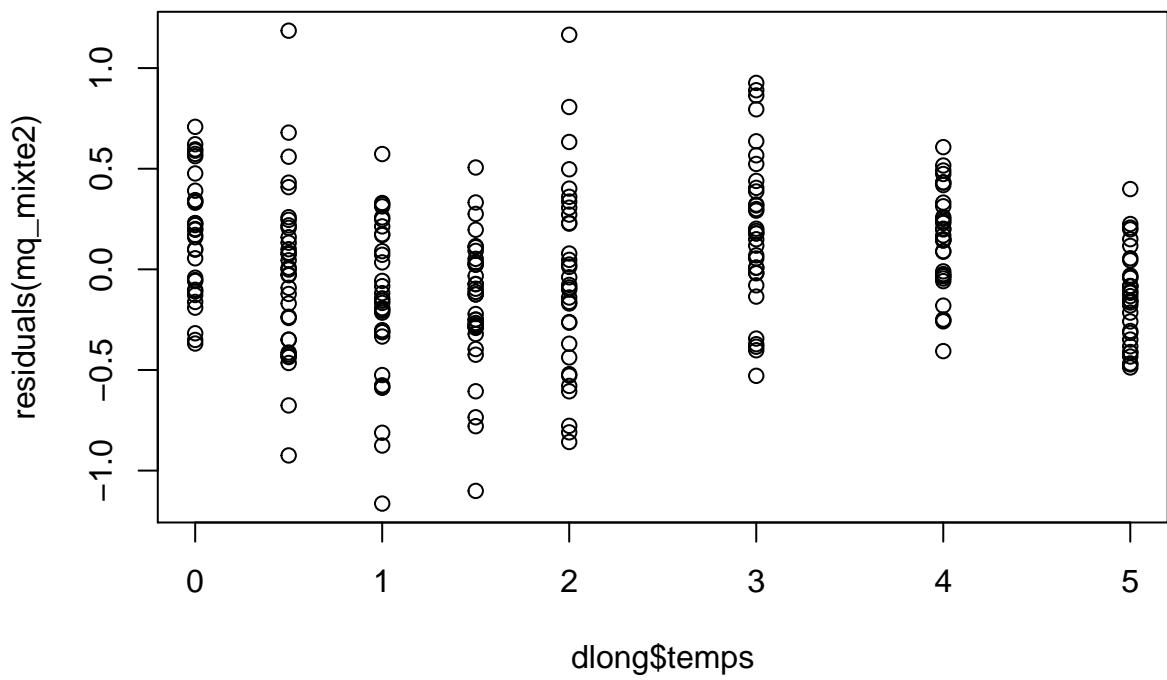
```
dwtest(residuals(mq_mixte2)~dlong$temp)
```

Durbin-Watson test

```
data: residuals(mq_mixte2) ~ dlong$temp
DW = 1.7414, p-value = 0.01668
alternative hypothesis: true autocorrelation is greater than 0
bptest(residuals(mq_mixte2)~dlong$temp)
```

studentized Breusch-Pagan test

```
data: residuals(mq_mixte2) ~ dlong$temp
BP = 2.8746, df = 1, p-value = 0.08999
plot(residuals(mq_mixte2)~dlong$temp)
```



```
plot(mq_mixte2)
```

