Taux de mortalité. Corrigé

On s'intéresse au taux de mortalité en fonction de facteurs économiques et environnementaux.

```
names(death_data)
```

```
##  [1] "Precipitation"            "January_temperature"
##  [3] "July_temperature"         "percent_65_or_older"
##  [5] "household_size"           "schooling_over_22"
##  [7] "full_kitchens"            "urban_population_density"
##  [9] "nonwhite_population"      "office_workers"
## [11] "poor_families"            "hydrocarbons"
## [13] "oxides_of_Nitrogen"       "Sulfur_Dioxide"
## [15] "humidity"                 "death_rate"
```

On cherche à comprendre l'influence des caractéristiques sociologiques et environnementales ci-dessous sur le taux de mortalité. Pour cela on utilise la commande ci-dessous.

```
death_lm = lm(death_rate ~ Precipitation + January_temperature + July_temperature +
    percent_65_or_older + household_size + schooling_over_22 + full_kitchens +
    urban_population_density + nonwhite_population + office_workers + poor_families +
    hydrocarbons + oxides_of_Nitrogen + Sulfur_Dioxide + humidity, data = death_data)
```

1. Ecrire le modèle correspondant aux instructions R données ci dessous. Rappelez ses hypothèses.

Evident

```
summary(death_lm)
```

```
##
## Call:
## lm(formula = death_rate ~ Precipitation + January_temperature +
##     July_temperature + percent_65_or_older + household_size +
##     schooling_over_22 + full_kitchens + urban_population_density +
##     nonwhite_population + office_workers + poor_families + hydrocarbons +
##     oxides_of_Nitrogen + Sulfur_Dioxide + humidity, data = death_data)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -75.285 -14.640   0.694  14.790  75.586
##
## Coefficients:
##                             Estimate Std. Error t value Pr(>|t|)
## (Intercept)                1.863e+03  4.108e+02   4.535  4.4e-05 ***
## Precipitation              2.072e+00  8.418e-01   2.462  0.01781 *
## January_temperature       -2.178e+00  6.752e-01  -3.225  0.00238 **
## July_temperature          -2.834e+00  1.771e+00  -1.600  0.11670
## percent_65_or_older       -1.404e+01  7.746e+00  -1.813  0.07670 .
## household_size            -1.154e+02  6.200e+01  -1.862  0.06933 .
## schooling_over_22         -2.425e+01  1.121e+01  -2.163  0.03605 *
## full_kitchens             -1.146e+00  1.467e+00  -0.781  0.43871
## urban_population_density   1.004e-02  4.123e-03   2.435  0.01899 *
## nonwhite_population        3.533e+00  1.282e+00   2.755  0.00850 **
## office_workers             5.229e-01  1.551e+00   0.337  0.73760
```

```
## poor_families             2.671e-01  2.565e+00   0.104  0.91755
## hydrocarbons             -8.890e-01  4.524e-01  -1.965  0.05574 .
## oxides_of_Nitrogen        1.866e+00  9.345e-01   1.997  0.05201 .
## Sulfur_Dioxide           -3.447e-02  1.423e-01  -0.242  0.80968
## humidity                  5.331e-01  1.052e+00   0.507  0.61474
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 32.33 on 44 degrees of freedom
## Multiple R-squared:  0.7985, Adjusted R-squared:  0.7298
## F-statistic: 11.63 on 15 and 44 DF,  p-value: 9.56e-11
```

2. On cherche à tester le modèle. Rappelez la définition de ce test. Rappelez l'expression de la statistique de test ainsi que sa loi. Retrouvez les degrés de libertés donnés dans les sorties R précédentes.

3. On fournit aussi les sorties suivantes:

```
death_lm_0 = lm(death_rate ~1,data=death_data)
anova(death_lm_0,death_lm)
```

```
## Analysis of Variance Table
##
## Model 1: death_rate ~ 1
## Model 2: death_rate ~ Precipitation + January_temperature + July_temperature +
##     percent_65_or_older + household_size + schooling_over_22 +
##     full_kitchens + urban_population_density + nonwhite_population +
##     office_workers + poor_families + hydrocarbons + oxides_of_Nitrogen +
##     Sulfur_Dioxide + humidity
##   Res.Df    RSS Df Sum of Sq      F   Pr(>F)
## 1     59 228308
## 2     44  46001 15    182307 11.625 9.56e-11 ***
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

A partir des sorties précédentes, donnez la valeur des sommes des carrées SCT, SCR et SCM, après avoir rappelé leurs définitions mathématiques.

4. Donnez l'estimation de σ^2 pour le modèle contenant toutes les covariables.

5. On ajoute une covariable au modèle appelée `add` et on ré-estime les paramètres du modèle.

Pour les question 1,2,3 4 et 5, même genre de réponses qu'aux exercices précédents.

```
summary(death_lm_add)
```

```
##
## Call:
## lm(formula = death_rate ~ add + Precipitation + January_temperature +
##     July_temperature + percent_65_or_older + household_size +
##     schooling_over_22 + full_kitchens + urban_population_density +
##     nonwhite_population + office_workers + poor_families + hydrocarbons +
##     oxides_of_Nitrogen + Sulfur_Dioxide + humidity, data = death_data)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -73.321 -15.734   1.795  15.682  68.796
##
## Coefficients:
```

```
##                              Estimate Std. Error t value Pr(>|t|)
## (Intercept)                 1.755e+03  4.162e+02   4.218 0.000125 ***
## add                         6.669e+00  5.159e+00   1.293 0.202991
## Precipitation               2.245e+00  8.460e-01   2.654 0.011112 *
## January_temperature        -2.299e+00  6.766e-01  -3.397 0.001476 **
## July_temperature           -2.565e+00  1.770e+00  -1.449 0.154568
## percent_65_or_older        -1.553e+01  7.774e+00  -1.998 0.052043 .
## household_size             -1.131e+02  6.156e+01  -1.837 0.073139 .
## schooling_over_22          -2.581e+01  1.119e+01  -2.306 0.025999 *
## full_kitchens              -8.305e-01  1.476e+00  -0.563 0.576531
## urban_population_density    1.137e-02  4.218e-03   2.694 0.010019 *
## nonwhite_population         3.128e+00  1.311e+00   2.387 0.021473 *
## office_workers              6.977e-01  1.545e+00   0.451 0.653900
## poor_families               6.688e-01  2.565e+00   0.261 0.795522
## hydrocarbons               -1.022e+00  4.606e-01  -2.219 0.031826 *
## oxides_of_Nitrogen          2.176e+00  9.578e-01   2.271 0.028181 *
## Sulfur_Dioxide             -8.819e-02  1.472e-01  -0.599 0.552231
## humidity                    6.052e-01  1.045e+00   0.579 0.565598
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 32.09 on 43 degrees of freedom
## Multiple R-squared:  0.8061, Adjusted R-squared:  0.7339
## F-statistic: 11.17 on 16 and 43 DF,  p-value: 1.574e-10
```

Comparez les sorties des deux modèles (estimation des paramètres, test de la nullité des paramètres...) Observez maintenant les R^2 du modèle $\mathcal{M}$ et de celui contenant la variable additionnelle. La variable ajoutée a en fait été simulée complètement au hasard. Commentez.

La variable ajoutée `add` n'apporte rien par rapport aux autres covariables (cf test de son paramètre). Par contre le R^2 a augmenté donc elle semble “améliorer” l'ajustment. C'est purement artificiel car la variable est random.... Juste du au fait que automatiquement, si j'aoute une covariable R^2 augmente. Rappeler la démo du cours ne fera pas de mal... (ou la faire si j'ai du retard en cours).

6. On revient aux tests de paramètres β_k. Quelles sont les variables qui vous semblent pertinentes pour expliquer le taux de mortalité? En particulier, les comparer aux corrélations représentées ci-desssous?

Bien rappeler le sens des tests des paramètres (on test bien $\beta_k = 0$ en présence des autres covariables. Donc si deux covariables sont très corrélées, au moment de faire les tests individuels sur chaque variable, les 2 paraîtront non-significatives. Mais en terme de sélection de modèle, il est important d”en garder l'une ou l'autre dans le modèle.

```
library(corrplot)
corrplot(cor(death_data),method = "ellipse")
```

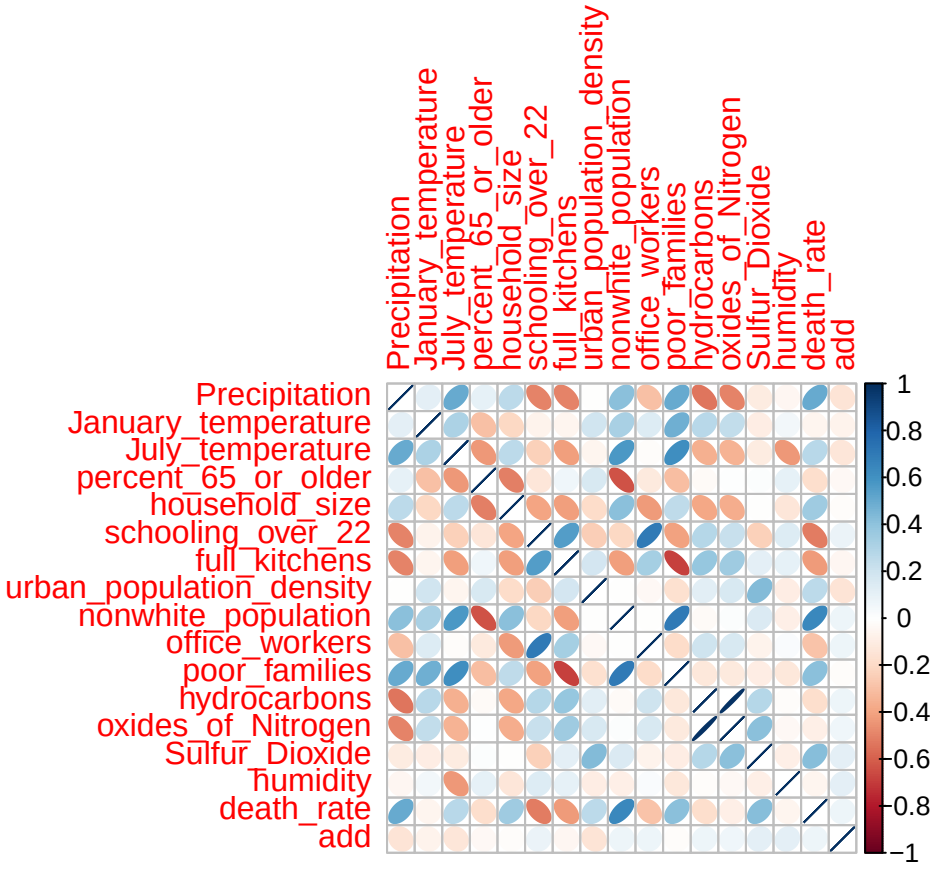
Precipitation
January_temperature
July_temperature
percent_65_or_older
household_size
schooling_over_22
full_kitchens
urban_population_density
nonwhite_population
office_workers
poor_families
hydrocarbons
oxides_of_Nitrogen
Sulfur_Dioxide
humidity
death_rate
add
1
0.8
0.6
0.4
0.2
0
-0.2
-0.4
-0.6
-0.8
-1