

Nous travaillons sous Python (SPYDER) durant cet exercice

Régression linéaire multiple

Inspirez-vous des tutoriels suivants :

- Manipulation des données : <http://tutoriels-data-mining.blogspot.fr/2017/02/python-manipulations-des-donnees-avec.html> [TUTO 1]
- Réalisation de la régression : <http://tutoriels-data-mining.blogspot.fr/2015/09/python-econometrie-avec-statsmodels.html> [TUTO 2]
- Quantiles et probabilités des lois d'usage courant : <http://tutoriels-data-mining.blogspot.fr/2017/04/probabilites-et-quantiles-sous-excel-r.html> [TUTO 3]
- ANACONDA est téléchargeable ici : <https://www.anaconda.com/distribution/> (nous utilisons la version Python 3.x).
- Installation et démarrage de l'EDI (éditeur de développement intégré) SPYDER de la distribution ANACONDA (<http://tutoriels-data-mining.blogspot.com/2015/08/python-la-distribution-anaconda.html> ; à partir de la page 9).

Objectif de l'étude : On souhaite expliquer la mortalité dans les métropoles américaines à partir des caractéristiques des villes (météo, pollution, etc.) et de la population (revenu, niveau d'éducation, etc.).

Voici la description de la base :

Description: Properties of some Standard Metropolitan Statistical Areas (a standard Census Bureau designation of the region around a city) in the United States, collected from a variety of sources. The data include information on the social and economic conditions in these areas, on their climate, and one indice of air pollution potentials.

city: City name

Mortality: Age adjusted mortality

JulyTemp: Mean July temperature (degrees Fahrenheit)

Rain: Annual rainfall (inches)

Education: Median education

PopDensity: Population density

Pop: Population

income: Median income


NOx: Nitrous Oxide

« City » correspond au label des observations ; « **Mortality** » est la variable endogène ; les autres variables sont les exogènes potentielles.

A faire :

Importation et vérification des données

1. Ouvrez le fichier « **mortality.xlsx** » dans Excel pour appréhender sa structure. Dans quelle feuille Excel sont situées les données ? (la seconde feuille nommée "data").
2. Lancer l'environnement de développement intégré SPYDER. Créez un nouveau projet FICHIER / NOUVEAU FICHIER, enregistrez le sous le nom « **exo_seance_5.py** ».
3. Modifiez le répertoire par défaut (**os.chdir**) [TUTO 2, page 3]
4. Importez la librairie **pandas** et affichez sa version [TUTO 1, page 2]. Notez la **version** de pandas que vous utilisez, cette information sera importante lors de l'importation des données.
5. En utilisant la librairie « pandas », importez le fichier « **mortality.xlsx** » dans un objet que vous nommerez « **df** » (on peut lire directement un fichier Excel avec **read_excel()** : https://pandas.pydata.org/pandas-docs/stable/generated/pandas.read_excel.html ; attention aux différentes options, notamment **header** et **index_col** ; pour indiquer le nom de la feuille à lire, vous utiliserez **sheetname** [version 0.20 et précédentes] ou **sheet_name** [version 0.21 et suivantes])
6. Pour vérifier l'importation, affichez :
 - a) Les premières lignes du DataFrame (**head**) [TUTO 1, page 2]
 - b) Le nombre d'observations et de variables (**shape**) (58, 7)
 - c) Le type des variables (**info**) (toutes doivent être numériques)
 - d) Les statistiques descriptives (**describe**)
 - e) La liste des labels (noms des villes) (**index**)
7. Réalisez le graphique croisant les variables prises deux à deux (**scatter_matrix**) [TUTO 1, page 19] [Remarque : à partir de Pandas 0.20, on peut faire directement **pandas.plotting.scattermatrix(...)**]. Quels commentaires ce graphique vous inspire-t-il ?



Régression et premières inspections des résultats

8. Lancez la régression avec l'ensemble des variables explicatives [TUTO 2, pages 4 et 5] (ols, fit).
Affichez le détail des résultats [TUTO 2, page 5] (summary).

```

=====
                        OLS Regression Results
=====
Dep. Variable:          mortality    R-squared:                0.371
Model:                  OLS         Adj. R-squared:           0.297
Method:                 Least Squares   F-statistic:              5.017
Date:                  Fri, 11 Mar 2016   Prob (F-statistic):       0.000416
Time:                  14:33:10         Log-Likelihood:           -308.57
No. Observations:      58             AIC:                      631.1
Df Residuals:          51             BIC:                      645.6
Df Model:               6
Covariance Type:       nonrobust
=====

```

	coef	std err	t	P> t	[95.0% Conf. Int.]	
Intercept	1115.5562	179.681	6.209	0.000	754.831	1476.282
julyTemp	1.4078	1.806	0.780	0.439	-2.218	5.033
rain	1.3946	0.791	1.763	0.084	-0.194	2.983
education	-30.3874	10.466	-2.903	0.005	-51.399	-9.376
pop	7.175e-06	5.74e-06	1.250	0.217	-4.34e-06	1.87e-05
income	-0.0004	0.002	-0.211	0.834	-0.004	0.003
nox	0.1081	0.203	0.534	0.596	-0.298	0.515


```

=====
Omnibus:                2.416    Durbin-Watson:           2.032
Prob(Omnibus):          0.299    Jarque-Bera (JB):        1.755
Skew:                   -0.415   Prob(JB):                 0.416
Kurtosis:                3.191    Cond. No.                 5.49e+07
=====

```

9. Quelles sont les valeurs du R^2 et R^2 ajusté ? Le modèle est-il globalement significatif à 10 % ?
Quelles sont les variables pertinentes à 10 % (c.-à-d. dont les coefficients sont significatifs à 10%) ?

10. À partir des résultats fournis par `summary()`, pouvez-vous dire que la distribution des erreurs est compatible avec la loi normale au risque 10 % ?
11. Pour confirmer cette analyse, tracez le graphique quantile-quantile plot pour évaluer la compatibilité des résidus avec une distribution gaussienne [TUTO 2, page 9].



12. Construisez le graphique des résidus avec l'endogène. Utilisez la librairie matplotlib (<http://www.python-simple.com/python-matplotlib/scatterplot.php>). Que constatez-vous ?
13. Refaites le même graphique pour chaque exogène (en abscisse). Remarque : pour accéder aux valeurs de la colonne j d'un DataFrame Pandas, il faudrait écrire `df.iloc[:, j]`
14. On souhaite tester la nullité simultanée des coefficients de `pop`, `income` et `nox` :
 - a) En utilisant la procédure des tests généralisés [TUTO 2, page 7] (F calculé = 1.195 ; p -value = 0.3208...)
 - b) En utilisant la procédure basée sur la comparaison des R^2 (https://eric.univ-lyon2.fr/~ricco/cours/cours/econometrie_regression.pdf ; section 10.4.3). Vous devriez obtenir une valeur identique de la statistique de test. Utilisez la librairie Scipy pour obtenir la p -value [TUTO 3, page 18] (même valeurs de stat de test et de p -value, sinon problème).

Détection des points atypiques

15. Nous souhaitons détecter les points atypiques et ou influents. Affichez le levier et le résidu studentisé des observations [TUTO 2, page 9].
16. Passez à la représentation graphique de ces informations. Quelle est l'observation qui semble la plus problématique dans les données ? [TUTO 2, pages 11 et 12]
17. Énumérez les villes à problèmes au sens du levier. [TUTO 2, page 12] (['Los Angeles, Long Beach, CA', 'San Francisco, CA', 'Bridgeport-Milford, CT', 'Worcester, MA', 'New York, NY']).

18. Énumérez les villes à problèmes au sens du résidu studentisé (au risque 10%) [TUTO 2, page 13] (['Los Angeles, Long Beach, CA', 'New Orleans, LA', 'Miami-Hialeah, FL', 'York, PA', 'Lancaster, PA', 'Chicago, IL']).
19. Quelles sont les villes problématiques au sens du levier **OU** du résidu studentisé ? (chacun fait comme il le souhaite, pour ma part j'ai réalisé un OU logique sur les deux vecteurs de booléens issus des tests sur le levier et le résidu studentisé -- https://docs.scipy.org/doc/numpy/reference/generated/numpy.logical_or.html) (10 observations).
20. Retirez ces villes de la base de données. Nommez **dfclean** le nouvel ensemble de données. De combien d'observations disposons-nous à présent ? (Il reste **48 observations** dans la base expurgée des observations à problèmes détectées précédemment) **Nous travaillons sur cette nouvelle base à partir de maintenant.**

Détection de la colinéarité

21. Relancez la régression et affichez les résultats détaillés.

```

OLS Regression Results
=====
Dep. Variable:          mortality    R-squared:                0.699
Model:                  OLS         Adj. R-squared:           0.655
Method:                 Least Squares  F-statistic:              15.85
Date:                   Wed, 21 Mar 2018  Prob (F-statistic):       2.56e-09
Time:                   10:26:26     Log-Likelihood:          -233.75
No. Observations:      48           AIC:                     481.5
Df Residuals:          41           BIC:                     494.6
Df Model:               6
Covariance Type:       nonrobust
=====
               coef    std err          t      P>|t|      [0.025    0.975]
-----
Intercept    1192.0128    134.301     8.876     0.000     920.786    1463.239
julyTemp     -0.3944         1.307    -0.302     0.764     -3.034     2.245
rain         3.1994         0.635     5.035     0.000     1.916     4.483
education   -27.2583         8.520    -3.199     0.003    -44.465    -10.052
pop         1.413e-05     7.1e-06     1.988     0.053    -2.21e-07  2.85e-05
income      -0.0021         0.002    -1.066     0.293     -0.006     0.002
nox         0.7001         0.436     1.607     0.116     -0.180     1.580
=====
Omnibus:                 3.741    Durbin-Watson:           2.064
Prob(Omnibus):           0.154    Jarque-Bera (JB):        3.533
Skew:                    0.611    Prob(JB):                 0.171
Kurtosis:                2.479    Cond. No.                 4.46e+07
=====

```

22. Quelles sont les variables associées à des coefficients significatifs à 10 % maintenant ? (rain, education, pop).
23. Détecter la colinéarité qui peut exister entre les variables explicatives du modèle en utilisant le critère VIF. Y a-t-il un problème de colinéarité dans cette régression ? [TUTO 2, pages 15 et 16] (non).
24. Testez à 10 % la nullité simultanée des coefficients associés aux variables « julyTemp » et « income ». Peut-on retirer ces variables du modèle ? ($F = 0.6278$, $p\text{-value} = 0.5388$).
25. **On décide de retirer ces variables. Réaliser la régression avec les exogènes : rain, education, pop, nox.** Interprétez les coefficients en analysant notamment leurs signes. Quelles sont les caractéristiques qui contribuent à la hausse (à la baisse) de la mortalité ?
26. Affichez le graphique qqplot pour les résidus de cette nouvelle régression. Que constate-t-on ?

Prédiction ponctuelle et par intervalle

27. Dans la feuille « prédiction » du fichier « mortality.xls » figurent les caractéristiques de la ville de Columbus. Calculer la prédiction ponctuelle du modèle pour cette observation ([TUTO 2, à partir de la page 16]) (prédiction ponctuelle : 895.5509...)
28. Calculez l'intervalle de prédiction au niveau de confiance 90 %. Est-ce qu'elle contient la vraie valeur de mortalité pour la ville de Colombus ? (835.8890 ; 955.2128).

Note finale : La lecture de ce support devrait vous être bénéfique :

<http://statsmodels.sourceforge.net/devel/examples/notebooks/generated/ols.html>