Econometrie

April 27, 2019

1 Projet SES722 2018-2019

BEC Alexandre, FABIEN Maël

2 Partie I - Regression

2.1 Question 1

- Lire le fichier **mroz.txt**.

https://www.rdocumentation.org/packages/car/versions/2.1-6/topics/Mroz

- Ne sélectionner que les observations pour lesquelles la variable **wage** est strictement positive.

```
In [129]: df_filt.head()
```

```
On dispose de  428  observations.
```

```
Out[129]:    inlf  hours  kidslt6  kidsgt6  age  educ    wage  repwage  hushrs  husage  \
          0     1   1610        1        0   32    12  3.3540     2.65    2708      34
          1     1   1656        0        2   30    12  1.3889     2.65    2310      30
          2     1   1980        1        3   35    12  4.5455     4.04    3072      40
          3     1    456        0        3   34    12  1.0965     3.25    1920      53
          4     1   1568        1        2   31    14  4.5918     3.60    2000      32

                ...    faminc     mtr  motheduc  fatheduc  unem  city  exper   nwifeinc  \
          0     ...     16310  0.7215        12         7   5.0     0     14  10.910060
          1     ...     21800  0.6615         7         7  11.0     1      5  19.499980
          2     ...     21040  0.6915        12         7   5.0     0     15  12.039910
          3     ...      7300  0.7815         7         7   5.0     0      6   6.799996
          4     ...     27300  0.6215        12        14   9.5     1      7  20.100060

                 lwage  expersq
          0   1.210154      196
          1   0.328512       25
          2   1.514138      225
```

```
3  0.092123        36
4  1.524272        49

[5 rows x 22 columns]
```

2.2 Question 2

- Faire les statistiques descriptives du salaire, de l'age et de l'éducation pour :

2.2.1 L'ensemble des femmes

In [130]:

Out[130]:

	wage	age	educ
count	428.000000	428.000000	428.000000
mean	4.177682	41.971963	12.658879
std	3.310282	7.721084	2.285376
min	0.128200	30.000000	5.000000
25%	2.262600	35.000000	12.000000
50%	3.481900	42.000000	12.000000
75%	4.970750	47.250000	14.000000
max	25.000000	60.000000	17.000000

Le salaire moyen des femmes dans la base de données est de 4.17. L'âge moyen est 42 ans. Le nombre d'années d'éducation moyen est de 12.7 années.

2.2.2 Pour les femmes dont le salaire du mari est supérieure à la médiane de l'échantillon.

In [132]:

Out[132]:

	wage	age	educ
count	214.000000	214.000000	214.000000
mean	4.896822	42.275701	13.242991
std	4.041606	7.388843	2.359045
min	0.161600	30.000000	5.000000
25%	2.513850	36.000000	12.000000
50%	3.846400	43.000000	12.000000
75%	5.854125	48.000000	16.000000
max	25.000000	59.000000	17.000000

Le salaire moyen des femmes dont mari gagne plus que la médiane est de 4.90. L'âge moyen est de 42.3 ans, et le nombre d'années d'éducation moyen est de 13.2 années.

2.2.3 Pour les femmes dont le salaire du mari est inférieur à la médiane de l'échantillon.

In [134]:

Out[134]:

	wage	age	educ
count	214.000000	214.000000	214.000000

```
mean      3.458541   41.668224   12.074766
std       2.143274    8.045482    2.054200
min       0.128200   30.000000    6.000000
25%       2.117275   35.000000   12.000000
50%       2.971800   41.000000   12.000000
75%       4.393800   47.000000   12.000000
max      18.267000   60.000000   17.000000
```

Le salaire moyen des femmes dont la mari gagne moins que la médiane est de 3.46. On voit que les femmes dont le mari gagne plus que la médiane gagnent en moyenne plus que les femmes dont le mari gagne moins que la médiane. Par ailleurs, l'écart-type est plus élevé pour les femmes dont le mari gagne plus que la médiane.

L'âge moyen pour le groupe des femmes dont le mari gagne moins que la médiane est de 41.7 ans, et le nombre d'années d'éducation moyen est 12.1 années.

On peut supposer l'existence de deux sous-groupes : - les femmes ayant bénéficié de moins d'éducation et disposant d'un salaire inférieur - les femmes plus jeunes, et dont le mari est probablement plus jeune, qui gagnent moins que la médiane.

2.2.4 Graphes de distribution

In [135]:

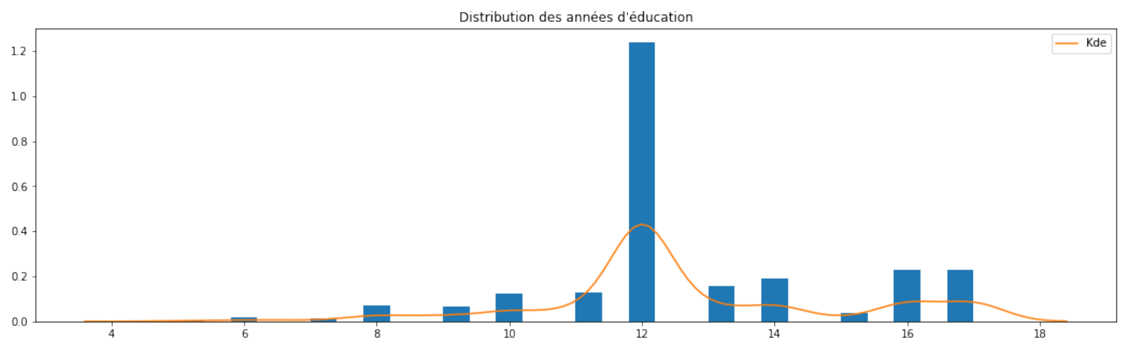

In [136]:

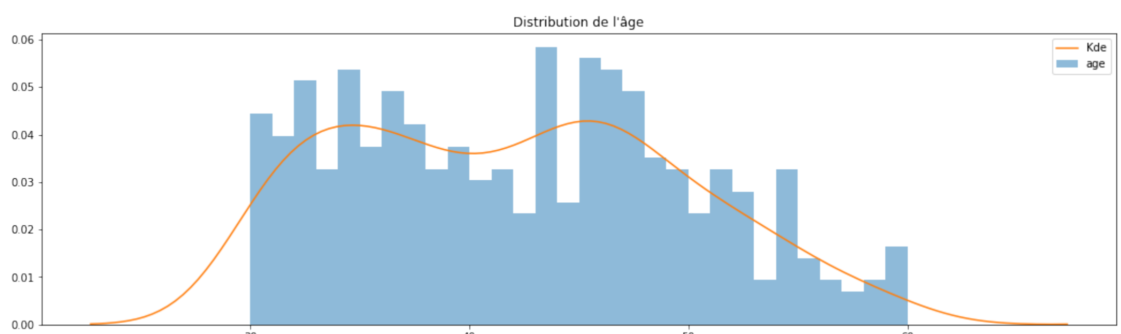

In [137]:

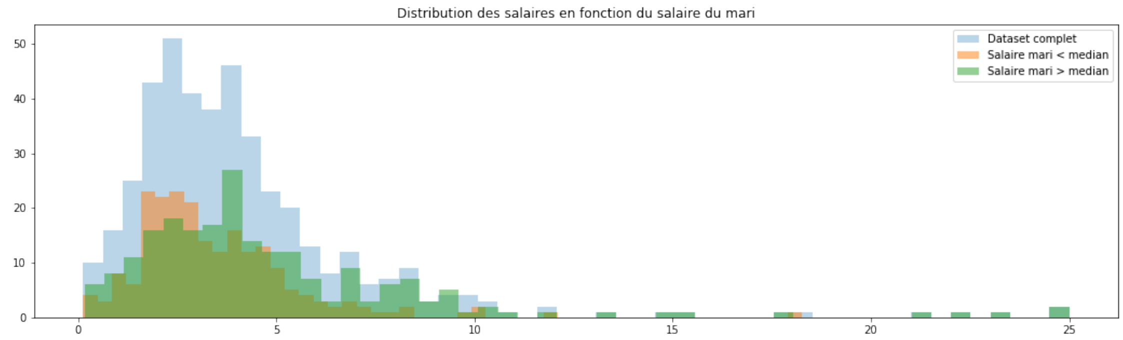

In [138]:

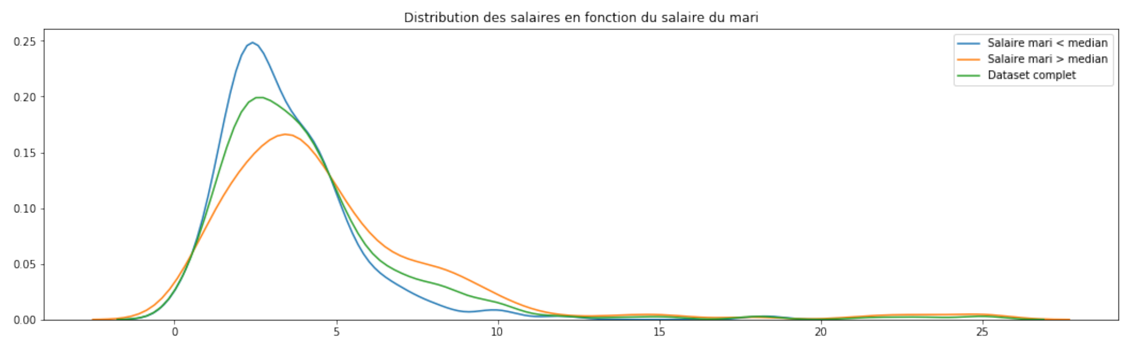

In [139]:

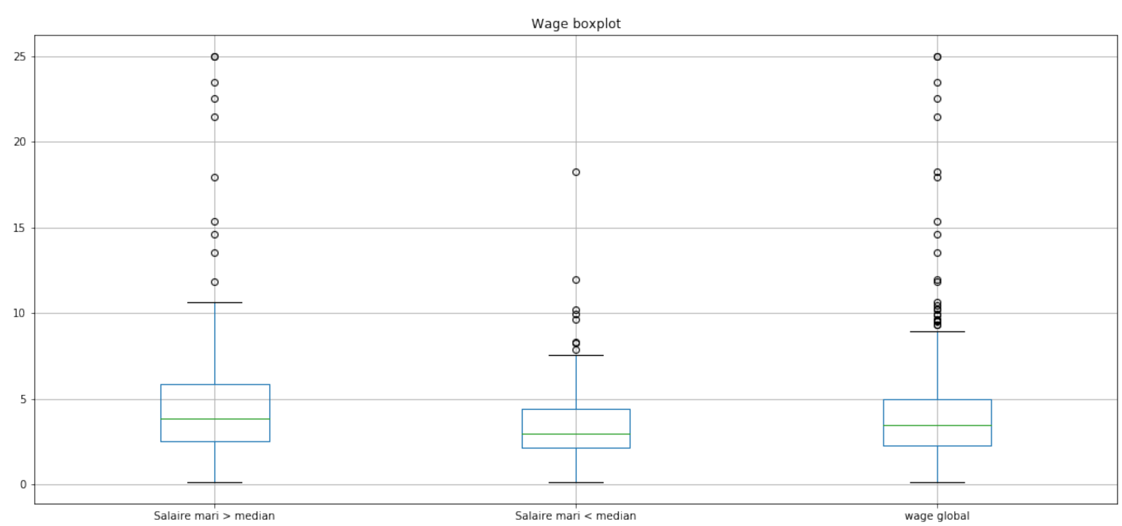

Par ces distributions, on illustre que lorsque le salaire du mari est supérieur à la médiane, le salaire de la femme semble être généralement plus élevé. Ceci devrait s'illustrer par une corrélation positive entre ces deux valeurs. La variance est également plus importante parmi les salaires des femmes dont le mari gagne plus que la médiane sur le box-plot.

2.3 Question 3

- Faire l'histogramme de la variable wage.

In [140]:

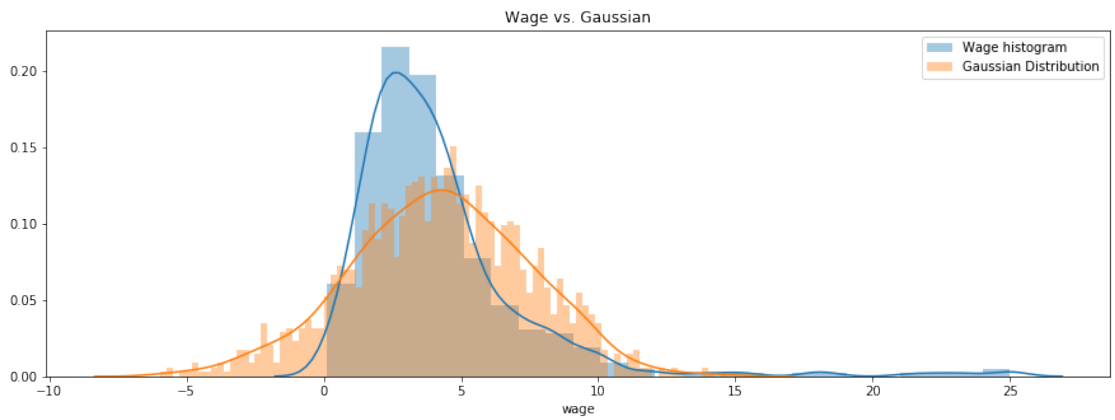

- Calculer le log de wage et faire l'histogramme.

In [141]:

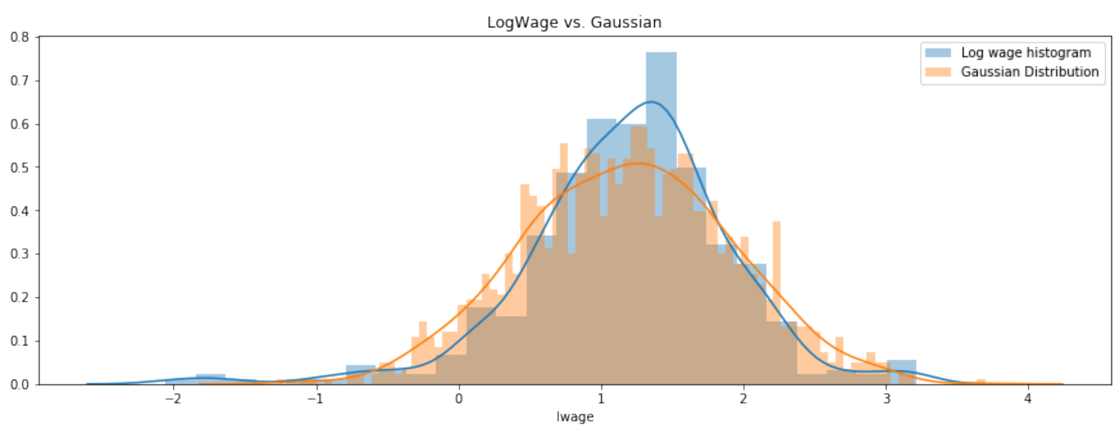

- Comparez les deux histogrammes et commentez

En prenant la variable **lwage**, la distribution semble plus proche d'un gaussienne. L'histogramme de **wage** est asymétrique car non négatif. C'est confirmé par le score de skewness avec **stats.skew**, qui est fortement positif pour la feature **wage**.

```
In [142]: print(stats.skew(df_filt.wage))
          print(stats.skew(df_filt.lwage))
```

```
3.0801391789818724
-0.6851599225277718
```

On peut supposer que travailler avec la variable lwage permettra de résoudre certains problèmes posés par wage.

2.4 Question 4

- Calculer les correlations motheduc et fatheduc.

```
In [143]:
```

```
Corrélation motheduc vs fatheduc:  0.554
p-value pour H0 pas de corrélation :  0.0
```

- Commentez.

La corrélation est de 55% entre l'éducation de la mère et celle du père. Cela s'explique probablement par le fait que les deux personnes au sein d'un couple appartiennent souvent à la même classe sociale et bénéficient des mêmes possibilités d'accès à l'éducation.

- Il y a-t-il un probleme de multicollinearite si l'on utilise ces variables comme variables explicatives ?

On rejette l'hypothèse nulle (pas de correlation) au seuil de 5%. La corrélaiton entre les deux variables peut introduire un biais de multicollinéarité.

Inclure ces deux variables peut surpondérer l'information sur l'éducation des parents. Cependant, une corrélation de 0.55 n'est pas une corrélation parfaite, et peut porter de l'information.

On peut d'ailleurs illustrer la corrélation entre les deux séries de cette manière. On remarque

```
In [144]:
```

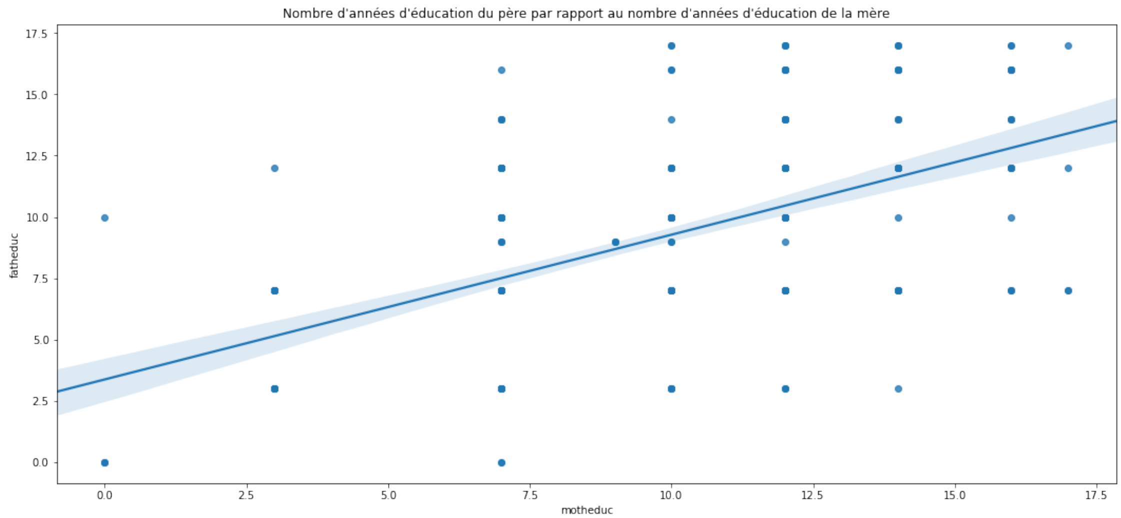

Il semble cependant y avoir un léger effet de compensation entre le nombre d'années d'éducation des parents. En effet, lorsque l'on affiche la différence entre le nombre d'années d'étude des deux parents, en fonction du nombre d'années d'étude de la mère, on se rend compte que : - lorsque la mère réalise très peu d'études, le père réalise généralement plus d'études - lorsque la mère réalise beaucoup d'études, le père réalise en moyenne légèrement moins d'études

In [145]:

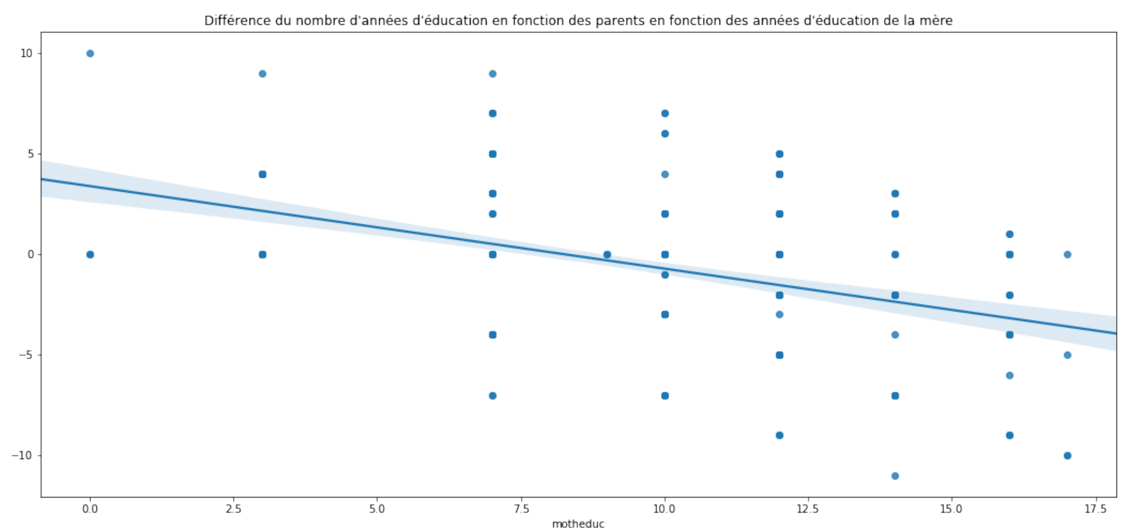

2.5 Question 5

- Faites un graphique en nuage de point entre wage et educ, wage et exper, wage et fatheduc. Commentez. S'agit-il d'un effet "toute chose étant égale par ailleurs ?"

In [146]:

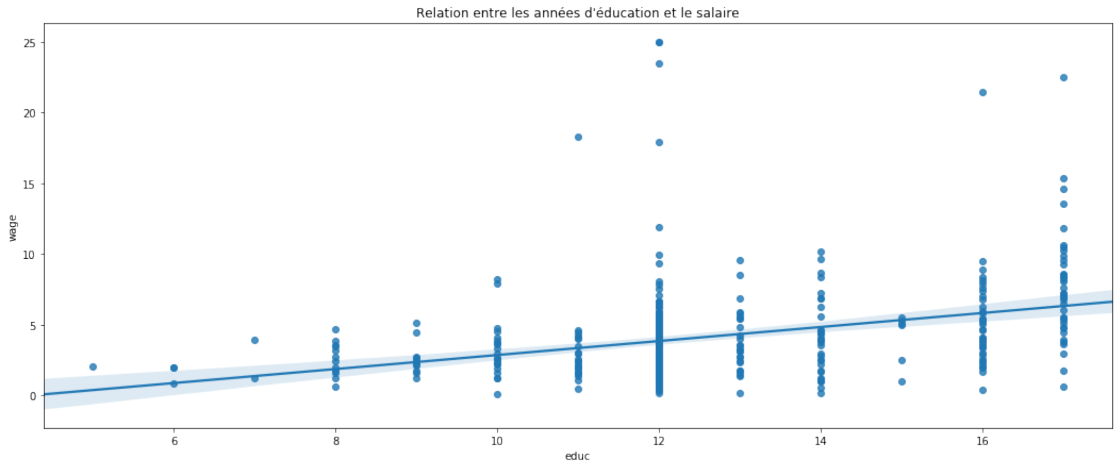

- Il ne s'agit pas d'un effet "toute chose étant égale par ailleurs", car pour chaque donnée, le reste des variables ne sont pas constantes.
- D'après la regression linéaire, les années d'éducation supplémentaires semblent augmenter significativement le salaire. Nous contrôlerons ceci juste après.
- Il semble que la variance ne soit pas la même pour chacune des années d'éducation (12 et 17 avec des pics de variance). Cela peut impliquer des problèmes d'héteroscedasticité.

In [147]:

- Certaines observations abérantes biaisent la pente.
- L'effet semble moins significatifs que l'éducation sur le salaire.
- Il existe un biais par rapport au nombre d'années d'éducation en amont. En effet, les jeunes diplomés avec peu d'expérience peuvent atteindre le même salaire d'entrée que des personnes travailllant depuis leur plus jeune âge.

On remarque que des années d'éducation supplémentaires ont tendance à faire augmenter le salaire. Cependant, l'expérience a un effet beaucoup moins prononcé. On remarque notamment quelques points pour lesquels les années d'étude sont relativement élevées et l'expérience très faible, mais pour autant le salaire est particulièrement élevé.

In [23]:

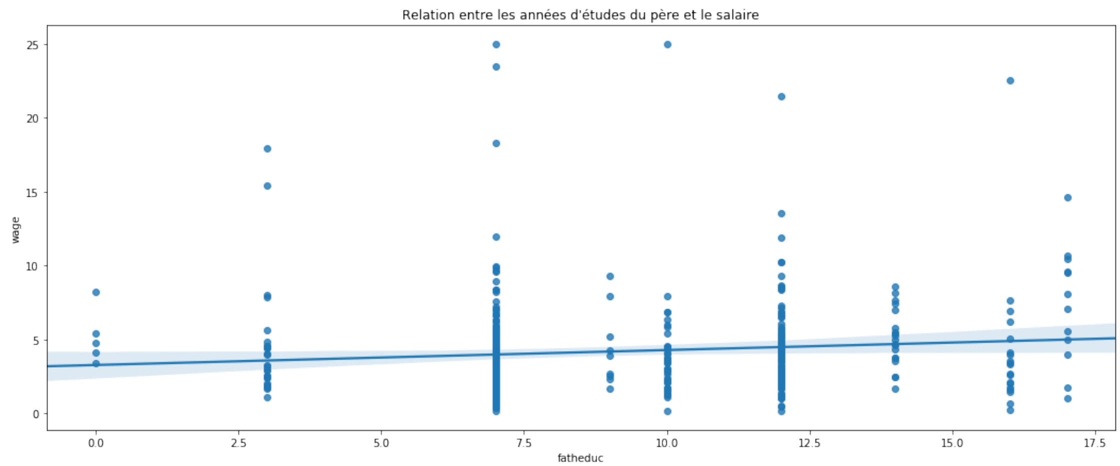

Des années d'éducation supplémentaires du père semblent apporter un meilleur salaire aux enfants. Cependant, la variance ne semble pas uniforme selon le nombre d'années d'études du père.

2.6 Question 6

- Quelle est l'hypothèse fondamentale qui garantie des estimateurs non biaisés ?

L'hypothèse de normalité des résidus garantit l'obtention du meilleur estimateur linéaire non-biaisé (BLUE). Ainsi, les résidus sont centrés en zéro, de variance constante à travers le temps (iid). On parle alors d'homoscedasticité.

- Expliquer le biais de variable omise.

On estime un modèle en prenant certaines variables, mais il en existent d'autres, que l'on ne peut pas contrôler par manque de données. Une variable omise viole l'hspothèse de normalité des résidus, car l'effet des variables omises se retrouve en partie dans les résidus.

2.7 Question 7

- Faire la régression de wage en utilisant les variables explicatives une constante, city, educ, exper, nwifeinc, kidslt6, kidsgt6.
- Commentez l'histogramme des résidus.

In [26]:

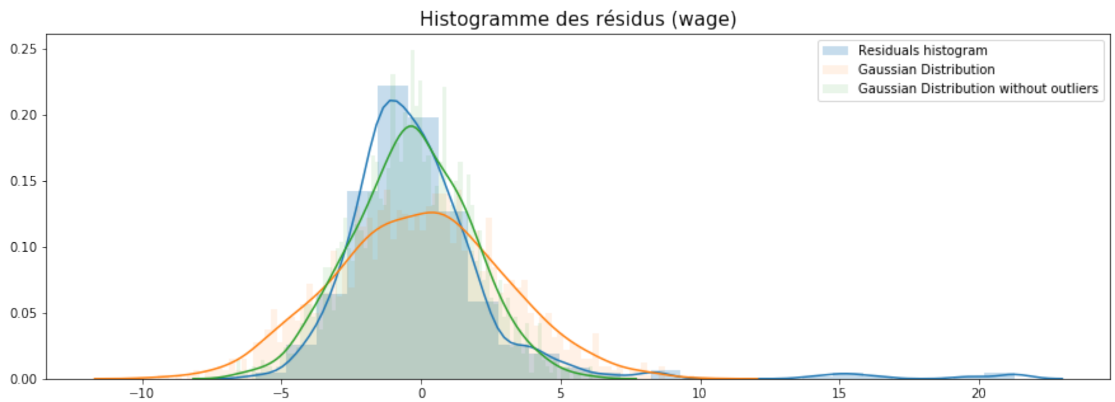

In [27]:

```
Score Skew & Kurtosis :  345.8247086376311
```

- Les résidus ne sont pas gaussiens mais centrés en zéro.
- La variance des résidus possède des valeurs extrêmes, qui entâchent l'hypothèse de normalité des résidus. Si on supprime ces valeurs extrêmes des résidus et que l'on trace l'historgramme d'une gaussienne de meme moyenne/variance, les deux courbes sont relativement proches, malgré une légère asymétrie des résidus.

In [28]:

```
                            OLS Regression Results
==============================================================================
Dep. Variable:                   wage   R-squared:                       0.127
Model:                            OLS   Adj. R-squared:                  0.115
Method:                 Least Squares   F-statistic:                     10.23
Date:                Fri, 26 Apr 2019   Prob (F-statistic):           1.41e-10
Time:                        17:40:10   Log-Likelihood:                -1090.0
No. Observations:                 428   AIC:                             2194.
Df Residuals:                     421   BIC:                             2222.
Df Model:                           6
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const         -2.4035      0.963     -2.495      0.013      -4.297      -0.510
city           0.3698      0.327      1.132      0.258      -0.272       1.012
educ           0.4600      0.070      6.546      0.000       0.322       0.598
exper          0.0238      0.021      1.141      0.255      -0.017       0.065
nwifeinc       0.0152      0.015      0.984      0.326      -0.015       0.046
kidslt6        0.0362      0.397      0.091      0.927      -0.744       0.816
```

```
kidsgt6       -0.0619      0.125     -0.494      0.622     -0.308      0.185
==============================================================================
Omnibus:                      345.825   Durbin-Watson:                   2.056
Prob(Omnibus):                  0.000   Jarque-Bera (JB):             6499.375
Skew:                           3.389   Prob(JB):                         0.00
Kurtosis:                      20.847   Cond. No.                         178.
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

- Seule l'éducaton apparait comme variable significative quand on utilise une constante.

2.8 Question 8

- Faire la régression de lwage sur une constante, city, educ, exper, nwifeinc, kidslt6, kidsgt6. Comparer l'histogramme obtenu à celui de la question 7.

In [30]:

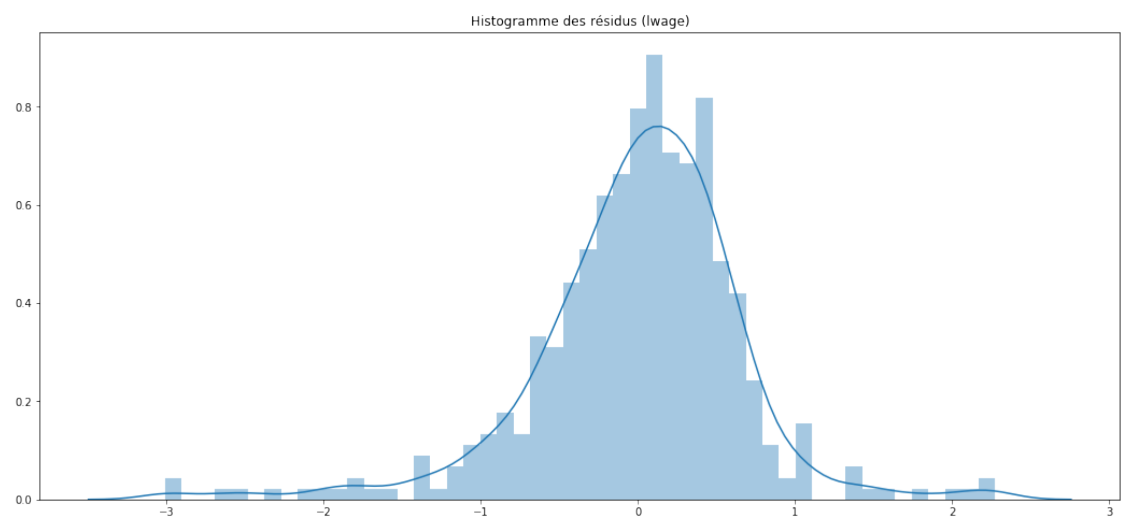


```
Score Skew & Kurtosis :  79.5424673464374
```

In [31]:

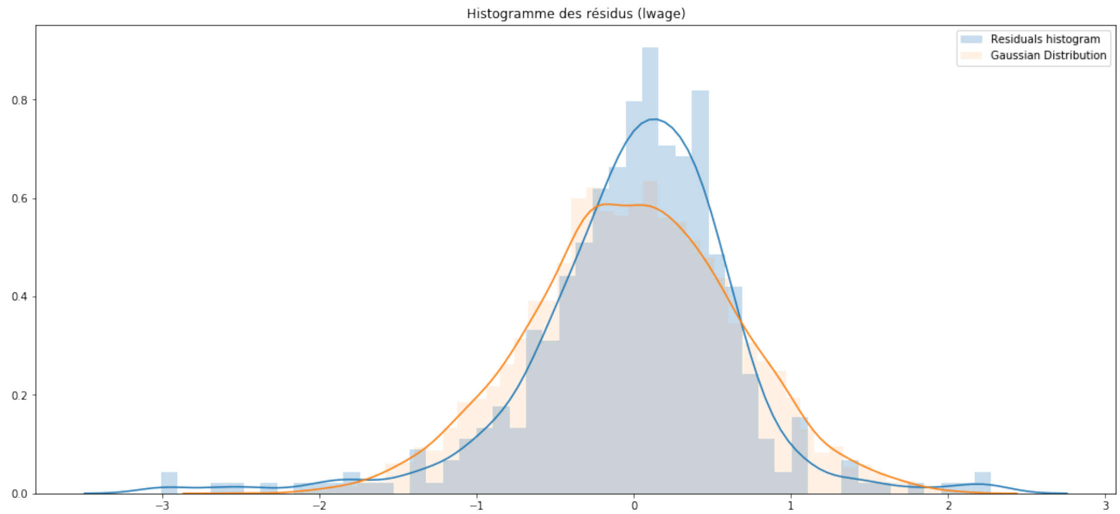

Le passage en log corrige l'heteroscedasticité remarquée à la question 7. La distribution des résidus est relativement proche de la Gaussienne, malgré une légère sur-concentration en zéro.

In [32]:

```
                            OLS Regression Results
==============================================================================
Dep. Variable:                  lwage   R-squared:                       0.156
Model:                            OLS   Adj. R-squared:                  0.144
Method:                 Least Squares   F-statistic:                     12.92
Date:                Fri, 26 Apr 2019   Prob (F-statistic):           2.00e-13
Time:                        17:40:11   Log-Likelihood:                -431.92
No. Observations:                 428   AIC:                             877.8
Df Residuals:                     421   BIC:                             906.3
Df Model:                           6
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const         -0.3990      0.207     -1.927      0.055      -0.806       0.008
city           0.0353      0.070      0.503      0.616      -0.103       0.173
educ           0.1022      0.015      6.771      0.000       0.073       0.132
exper          0.0155      0.004      3.452      0.001       0.007       0.024
nwifeinc       0.0049      0.003      1.466      0.143      -0.002       0.011
kidslt6       -0.0453      0.085     -0.531      0.596      -0.213       0.122
kidsgt6       -0.0117      0.027     -0.434      0.664      -0.065       0.041
==============================================================================
Omnibus:                       79.542   Durbin-Watson:                   1.979
Prob(Omnibus):                  0.000   Jarque-Bera (JB):              287.193
Skew:                          -0.795   Prob(JB):                     4.33e-63
Kurtosis:                       6.685   Cond. No.                         178.
```

```
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

Les variables éducation et expérience apparaissent alors comme significatives.

2.9 Question 9

- Tester l'hypothèse de non significativité de exper avec un seuil de significativité de 1%, 5% et 10% (test alternatif des deux côtés).

On continue de travailler avec logwage.
Les hypothèses de notre modèle peuvent s'exprimer comme suit :

$$H_0 : \beta_{exper} = 0$$

$$H_1 : \beta_{exper}! = 0$$

On calcule la stat de test suivante :

$$t_{exper} = \frac{}{\hat{\beta}_{exper}} \hat{\sigma}_{exper}$$

Puis l'on compare cette statistique de test à une valeur critique

$$t_{n-k}{}^{\alpha\%}$$

.

Si la stat de test est supérieure à la valeur critique, on rejette \$ H_0 \$. Autrement, on ne peut pas conclure au rejet de l'hypothèse nulle.

In [34]:

```
n, k :  428 7
sig2: 0.4479571976072196
t_exper :  3.4517182808127607
```

- Commentez les p-values.

In [35]:

```
Seuil: 10%
p_value de t_exper :  0.0006133650790143275
0.00 < 0.10: On rejette l'hypothèse de non-significativité

Seuil: 5%
p_value de t_exper :  0.0006133650790143275
0.00 < 0.05: On rejette l'hypothèse de non-significativité
```

```
Seuil: 1%
p_value de t_exper :  0.0006133650790143275
0.00 < 0.01: On rejette l'hypothèse de non-significativité
```

La p-value associée à la variable Experience étant particulièrement faible, on rejette l'hypothèse de non-significativité de la variable sur lwage.

2.10 Question 10

- Tester l'hypothèse que le coefficient associé à educ est égal à 10% avec un seuil de significativité de 5% (test à alternatif des deux côtés)

On teste désormais :

$$t_{educ} = (\hat{\beta}_{educ} - 0.1)/(\hat{\sigma}_{educ})$$

et l'on compare à nouveau cette statistique de test à la valeur critique.

In [36]:

```
T-stat :  0.14882666468792646
Seuil: 5%
p-value : 0.8817616705976787
0.88 > 0.05: On ne rejette pas l'hypothèse de non-significativité
```

La p-value vaut 0.88. On ne rejette donc pas l'hypothèse que le coefficient associé à l'éducation est de 10%.

2.11 Question 11

- Tester l'hypothèse jointe que le rendement de l'éducation est de 10% et que celui de l'expérience professionnelle est de 5%.

Pour réaliser un test d'hypothèses jointes, on estime une statistique de test de Fisher entre le modèle contraint et le modèle non-contrait selon les hypothèses :

$$H_0 : \beta_{educ} = 0.1, \beta_{exper} = 0.05$$

On définit SSR comme la Somme des résidus au carré. On estime donc deux modèles, un modèle non-contraint, et un modèle contraint.

$$F_{educ+exper} = (SSR_c - SSR_{nc})/(ddl_c - ddl_{nc}) \times (ddl_{nc})/(SSR_{nc})$$

On compare ensuite cette statistique de test à la valeur critique.

In [37]:

```
La p_value est de : 9.53570555850547e-11%
```

La p-value est inférieure au seuil alpha, on va donc rejeter H0.

2.12 Question 12

- De combien augmente le salaire en pourcentage avec 10 années d'expérience ?

In [38]:

```
                            OLS Regression Results
==============================================================================
Dep. Variable:                  lwage   R-squared:                       0.156
Model:                            OLS   Adj. R-squared:                  0.144
Method:                 Least Squares   F-statistic:                     12.92
Date:                Fri, 26 Apr 2019   Prob (F-statistic):           2.00e-13
Time:                        17:40:12   Log-Likelihood:                -431.92
No. Observations:                 428   AIC:                             877.8
Df Residuals:                     421   BIC:                             906.3
Df Model:                           6
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const         -0.3990      0.207     -1.927      0.055      -0.806       0.008
city           0.0353      0.070      0.503      0.616      -0.103       0.173
educ           0.1022      0.015      6.771      0.000       0.073       0.132
exper          0.0155      0.004      3.452      0.001       0.007       0.024
nwifeinc       0.0049      0.003      1.466      0.143      -0.002       0.011
kidslt6       -0.0453      0.085     -0.531      0.596      -0.213       0.122
kidsgt6       -0.0117      0.027     -0.434      0.664      -0.065       0.041
==============================================================================
Omnibus:                       79.542   Durbin-Watson:                   1.979
Prob(Omnibus):                  0.000   Jarque-Bera (JB):              287.193
Skew:                          -0.795   Prob(JB):                     4.33e-63
Kurtosis:                       6.685   Cond. No.                         178.
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

In [39]:

```
En 10 ans, le log du salaire augmente en moyenne de  15.49 %
```

On peut alors déterminer un intervalle de confiance autour de cette valeur :

```
In [40]:
```

```
L'intervalle de confiance est : [ 6.6682% ; 24.3076%]
```

2.13 Question 13

- Tester l'égalité des coefficients associés aux variables kidsgt6 et kidslt6. Interprétez.

Afin de contraindre le modèle, nous créeons une variable `kid = kidsgt6 + kidslt6`. On réécrit l'équation et on estime le coefficient associé à la variable 1 qui comprend l'effet de `kidsgt6 - kidslt6`. Si le coefficient n'est pas significativement différent de 0, on ne rejette pas l'hypothèse nulle d'égalité des deux coefficients.

```
In [41]: print(p_val)
```

```
0.7102679748432641
```

On ne rejette pas l'hypothèse d'égalité des coefficients car la p-value est de 0.71 et est supérieure à 5%.

2.14 Question 14

- En utilisant le modèle de la question 7, faire le test d'hétéroscédasticité de forme linéaire en donnant la p-valeur.

On réalise un F-test dans lequel on inclut uniquement la constante dans le modèle contraint. Ainsi, on teste le fait qu'il n'y ait pas de différence entre le modèle contraint et non-contraint. H0 corresond donc à une hypothèse d'homoscedasticité.

```
In [43]: print(p_val)
```

```
0.09130097553302419
```

On obtient une p-value de 9%, qui implique un rejet de l'hypothèse à 10% mais une non-rejet à 5%.

- Corriger le problème par rapport à la variable la plus importante en utilisant la méthode des MCG.

On applique la même méthode avec un estimateur des Moindres Carrés Généralisés cette fois-ci, en calculant le log des résidus, afin d'en déduire des poids pour le modèle Feasible Weighted Least Squares.

```
In [47]: print(p_val)
```

```
0.6271456383048878
```

La p-value est désormais de 63%, ce qui implique que l'on ne peut pas rejeter l'hypothèse d'homoscedasticité des résidus. On a bien corrigé le problème d'hétéroscedasticité.

- Comparer les écarts-types des coefficients estimés avec ceux obtenus à la question 7. Commenter.

In [48]:

```
                            OLS Regression Results
==============================================================================
Dep. Variable:                      y   R-squared:                       0.008
Model:                            OLS   Adj. R-squared:                 -0.006
Method:                 Least Squares   F-statistic:                    0.5795
Date:                Fri, 26 Apr 2019   Prob (F-statistic):              0.747
Time:                        17:40:12   Log-Likelihood:                -2120.8
No. Observations:                 428   AIC:                             4256.
Df Residuals:                     421   BIC:                             4284.
Df Model:                           6
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const         13.1731     16.795      0.784      0.433     -19.838      46.185
city          -3.5689      8.093     -0.441      0.659     -19.476      12.338
educ           0.0396      1.193      0.033      0.974      -2.305       2.384
exper         -0.2592      0.213     -1.216      0.225      -0.678       0.160
nwifeinc       0.0534      0.206      0.260      0.795      -0.351       0.457
kidslt6       -0.5866      6.666     -0.088      0.930     -13.689      12.515
kidsgt6       -1.2778      1.231     -1.038      0.300      -3.698       1.143
==============================================================================
Omnibus:                      642.845   Durbin-Watson:                   2.023
Prob(Omnibus):                  0.000   Jarque-Bera (JB):            94065.650
Skew:                           8.249   Prob(JB):                         0.00
Kurtosis:                      73.729   Cond. No.                         297.
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

Les écarts-types sont beaucoup plus élevés avec avec ce modèle.

2.15 Question 15

- Tester le changement de structure de la question 8 entre les femmes qui ont moins de 30 ans, entre 30 et 43 ans, plus de 43 ans (3 groupes mutuellement exclusifs). Donnez les p-valeurs.

Nous avons imaginé deux approches pour cette question : - Une analyse de variance (One-way ANOVA) - Un test de Chow entre les différents groupes

Commençons par l'ANOVA :

```
In [49]:
```

```
Out[49]: F_onewayResult(statistic=0.21829228903413253, pvalue=0.8039805155171003)
```

La p-value étant de 0.8039, on ne peut pas conclure à un effet significatif de l'âge.
On peut également tester nos conclusions à cette question en réalisant un test de Chow entre : - le groupe <30 et le reste - le groupe <43 et le reste - le groupe entre 30 et 43 et le reste
On construit la statistique de test sous le test de Chow de la manière suivante :

$$F_{chow} = (SSR - (SSR_{gr1} + SSR_{gr2}))/(ddl - (ddl_{gr1} + ddl_{gr2})) \times (ddl_{gr1} + ddl_{gr2})/((SSR_{gr1} + SSR_{gr2})$$

Groupe <30 vs. reste

```
In [50]: print(p_val)
```

```
0.7946563995696743
```

Groupe <43 vs. reste

```
In [51]: print(p_val)
```

```
0.30997341357260577
```

Groupe 30-43 vs. reste

```
In [52]: print(p_val)
```

```
0.6109025332616165
```

Toutes les p-values sont supérieures au seuil alpha de 5%. Ainsi, on ne peut pas rejeter l'hypothèse H0 qu'il n'y a aucun changement de régime. Cela conforte les résultats de notre ANOVA.

2.16 Question 16

- A partir de la variable kidslt6, créer un ensemble de variables binaires pour le nombre d'enfants de moins de 6 ans.

On crée les variables suivantes : - `kidslt6_1` pour les femmes ayant 1 enfant de moins de 6 ans - `kidslt6_2` pour les femmes ayant 2 enfants de moins de 6 ans
On supprime la variable `kidslt_6`.

- Refaire la question 8 avec ces variables et en utilisant comme référence les femmes qui ont des enfants de plus de 6 ans. (Faire la régression de lwage sur une constante, city, educ, exper, nwifeinc, kidslt6, kidsgt6.)

In [56]:

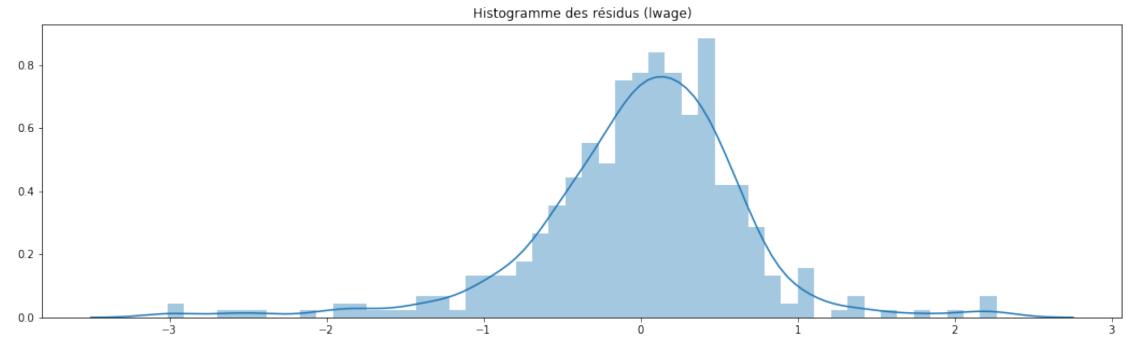

- Ces catégories sont-elles mutuellement exclusives ?

Telles que les variables sont construites, il n'est pas possible d'avoir 1 enfant de moins de 6 ans, et également 2 enfant de moins de 6 ans par exemple. Pour cette raison, les catégories sont mutuellement exclusives. On supprime par ailleurs la variable correspondant à 0 enfants, car si une femme n'a ni 1 enfant, ni 2 (dans ce set de données), alors elle n'a pas d'enfant de moins de 6 ans. Par ailleurs, on crée une variable gt6 qui vaut 1 lorsque la femme n'a pas d'enfant de plus de 6 ans, par rapport au cas de base où elle a un enfant de plus de 6 ans.

- Interprétez les paramètres associés aux variables binaires.

In [57]:

```
                            OLS Regression Results
==============================================================================
Dep. Variable:                  lwage   R-squared:                       0.155
Model:                            OLS   Adj. R-squared:                  0.141
Method:                 Least Squares   F-statistic:                     11.03
Date:                Fri, 26 Apr 2019   Prob (F-statistic):           8.15e-13
Time:                        17:40:13   Log-Likelihood:                -432.00
No. Observations:                 428   AIC:                             880.0
Df Residuals:                     420   BIC:                             912.5
Df Model:                           7
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const         -0.4314      0.192     -2.245      0.025      -0.809      -0.054
city           0.0366      0.070      0.520      0.603      -0.102       0.175
educ           0.1028      0.015      6.830      0.000       0.073       0.132
exper          0.0159      0.005      3.503      0.001       0.007       0.025
nwifeinc       0.0049      0.003      1.465      0.144      -0.002       0.011
kidslt6_1     -0.0560      0.108     -0.519      0.604      -0.268       0.156
```

```
kidslt6_2     -0.0662      0.259     -0.256      0.798     -0.575      0.442
gt6            0.0114      0.074      0.153      0.878     -0.134      0.157
==============================================================================
Omnibus:                       79.748   Durbin-Watson:                   1.978
Prob(Omnibus):                  0.000   Jarque-Bera (JB):              286.571
Skew:                          -0.798   Prob(JB):                     5.91e-63
Kurtosis:                       6.677   Cond. No.                         221.
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

Le coefficient associé à la variable binaire indique un que si la condition pour satisfaire la variable est respectée, on observe un changement de y égal au coefficient par rapport au cas par défaut pré-défini.

- Faire le test de non significativité de l'ensemble des variables binaires. Donnez les p-valeurs.

Aucune des variables ne semble être significative, car les p-valeurs sont toutes élevées, et on ne peut pas rejeter l'hypothèse nulle de non-significativité. Les coefficients, bien que non-significatifs, semblent indiquer que le fait de n'avoir aucun enfant est un plus pour le salaire.

```
In [58]: print(p_val)
```

```
0.14344360131309886
```

La p-value de 14.3 % indique que l'on ne peut pas rejeter l'hypothèse nulle de non-significativité de l'ensemble des variables binaires.

2.17 Question 17

A partir de l'échantillon global, faire une régression de inlf sur une constante, city, educ, age, kidslt6, kidsgt6.

```
In [59]:
```

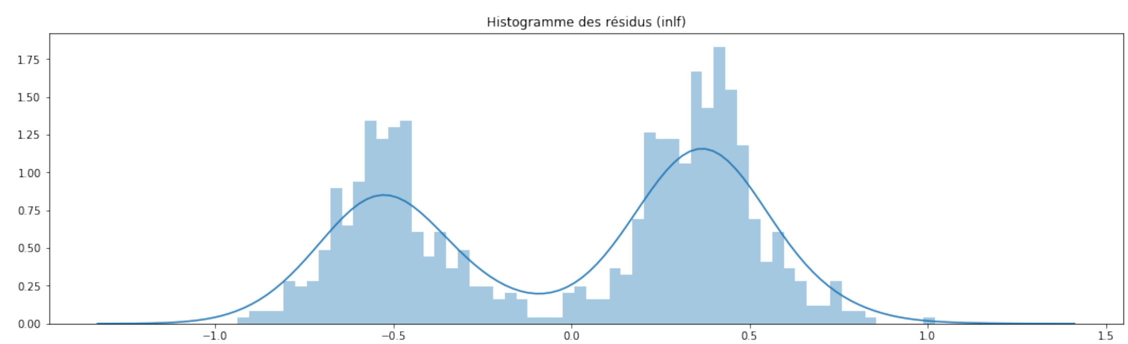

In [60]:

```
                            OLS Regression Results
==============================================================================
Dep. Variable:                   inlf   R-squared:                       0.124
Model:                            OLS   Adj. R-squared:                  0.118
Method:                 Least Squares   F-statistic:                     21.20
Date:                Fri, 26 Apr 2019   Prob (F-statistic):           7.29e-20
Time:                        17:40:13   Log-Likelihood:                -489.44
No. Observations:                 753   AIC:                             990.9
Df Residuals:                     747   BIC:                             1019.
Df Model:                           5
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const          0.7076      0.162      4.365      0.000       0.389       1.026
city          -0.0341      0.036     -0.944      0.346      -0.105       0.037
educ           0.0434      0.008      5.656      0.000       0.028       0.058
age           -0.0130      0.003     -5.081      0.000      -0.018      -0.008
kidslt6       -0.3075      0.036     -8.498      0.000      -0.378      -0.236
kidsgt6       -0.0173      0.014     -1.231      0.219      -0.045       0.010
==============================================================================
Omnibus:                        7.463   Durbin-Watson:                   0.246
Prob(Omnibus):                  0.024   Jarque-Bera (JB):               76.244
Skew:                          -0.245   Prob(JB):                     2.78e-17
Kurtosis:                       1.520   Cond. No.                         432.
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

- Interprétez les coefficients estimés.

Les coefficients estimés indiquent l'impact, estimé en pourcents, de l'augmentation d'une des variables explicatives sur la probabilité d'observation d'un 1 ou d'un 0 sur la variables `inlf`. Cette interprétation est statistiquement fausse, mais permet une bonne explicabilité du résultat dans les cadres de classification binaire.

D'après ce modèle, l'éducation, l'âge et le nombre d'enfants de moins de 6 ans sont des variables significatives.

2.18 Question 18

- Estimer le modèle probit de inlf sur une constante, city, educ, age, kidslt6, kidsgt6.

In [62]:

```
Optimization terminated successfully.
         Current function value: 0.617205
         Iterations 5
                          Probit Regression Results
==============================================================================
Dep. Variable:                      y   No. Observations:                  753
Model:                         Probit   Df Residuals:                      747
Method:                           MLE   Df Model:                            5
Date:                Fri, 26 Apr 2019   Pseudo R-squ.:                 0.09734
Time:                        17:40:13   Log-Likelihood:                -464.76
converged:                       True   LL-Null:                       -514.87
                                        LLR p-value:                 4.714e-20
==============================================================================
                 coef    std err          z      P>|z|      [0.025      0.975]
------------------------------------------------------------------------------
const          0.6050      0.467      1.297      0.195      -0.309       1.520
city          -0.0863      0.102     -0.842      0.400      -0.287       0.115
educ           0.1234      0.023      5.469      0.000       0.079       0.168
age           -0.0375      0.007     -5.008      0.000      -0.052      -0.023
kidslt6       -0.8846      0.112     -7.882      0.000      -1.105      -0.665
kidsgt6       -0.0542      0.040     -1.351      0.177      -0.133       0.024
==============================================================================
```

- Faire le test de non significativité jointes des coefficients associés à kidslt6 et à kidsgt6.

Etant donné qu'il est demandé de réaliser le test par approche de vraisemblance à la question 20, nous en concluons qu'il est demandé ici d'appliquer un F-Test, bien qu'il ne soit pas adapté au modèle probit.

```
In [63]: print(p_val)
```

```
Optimization terminated successfully.
         Current function value: 0.617205
         Iterations 5
Optimization terminated successfully.
         Current function value: 0.663577
         Iterations 4
3.3306690738754696e-16
```

La p-value est quasiment à 0, ce qui implique que l'on peut rejeter l'hypothèse de non-significativité jointe des coefficients associés à kidsle6 et kidsgt6 à 5%.

- Comparez le résultat du test à celui de la question 13

A la question 13, on ne rejettait pas l'hypothèse d'égalité des deux coefficients. Ici, on rejette l'hypothèse de non-significativité jointe des coefficients.

2.19 Question 19

- Calculer les effets partiels pour l'ensemble des variables explicatives : dp(y=1)/dxk (k = 1, ..., K), où K est le nombre de variables explicatives.

$$\delta p(x)/\delta x_j = g(\beta_0 + X\beta)\beta_j$$

$$g(z) = \delta G/\delta z(z)$$

In [64]:

```
Optimization terminated successfully.
         Current function value: 0.617205
         Iterations 5
       Probit Marginal Effects
=====================================
Dep. Variable:                   inlf
Method:                          dydx
At:                           overall
==============================================================================
                dy/dx    std err          z      P>|z|      [0.025      0.975]
------------------------------------------------------------------------------
x1            -0.0304      0.036     -0.843      0.399      -0.101       0.040
x2             0.0435      0.007      5.811      0.000       0.029       0.058
x3            -0.0132      0.003     -5.264      0.000      -0.018      -0.008
x4            -0.3116      0.035     -9.006      0.000      -0.379      -0.244
x5            -0.0191      0.014     -1.355      0.175      -0.047       0.009
==============================================================================
```

- Comparer vos résultats à ceux obtenus à la question 17. Commentez.

On remarque que globalement, les effets ont le même ordre de grandeur. Cela signifie notamment que l'absence de transformation ne pénalise pas trop la qualité du modèle. Cela conduit à la significativité des mêmes paramètres. Cependant, l'interprétation dans les modèles Probit ou Logit n'est plus aussi directe.

2.20 Question 20

- Faire le test de non significativité jointes des coefficients associés à kidslt6 et à kidsgt6 en utilisant la méthode du rapport de vraisemblance.

In [68]:
```
print(LR, p)
```

```
69.8366275999017 6.841778332359197e-16
```

Le rapport de vraisemblance vaut 69, et la p-value est très proche de 0.

- Comparez aux résultats de la question 18.

La p-value est inférieure à 5%, on peut donc rejeter l'hypothèse nulle de non-significativité jointe. On remarque que la conclusion est différente de la question 18, car les tests de Fisher ne sont notamment pas adaptés aux modèles probit ou logit.

3 Partie II - Séries Temporelles

3.1 Question 1

- Importer les données du fichier quarterly.xls

```
In [69]: df.head()

Out[69]:          DATE   FFR  Tbill  Tb1yr    r5   r10  PPINSA  Finished    CPI  \
         0 1960-01-01  3.93   3.87   4.57  4.64  4.49   31.67     33.20  29.40
         1 1960-04-01  3.70   2.99   3.87  4.30  4.26   31.73     33.40  29.57
         2 1960-07-01  2.94   2.36   3.07  3.67  3.83   31.63     33.43  29.59
         3 1960-10-01  2.30   2.31   2.99  3.75  3.89   31.70     33.67  29.78
         4 1961-01-01  2.00   2.35   2.87  3.64  3.79   31.80     33.63  29.84

            CPICORE   M1NSA   M2SA   M2NSA  Unemp  IndProd    RGDP  Potent  Deflator  \
         0    18.92  140.53  896.1  299.40   5.13    23.93  2845.3  2824.2    18.521
         1    19.00  138.40  903.3  300.03   5.23    23.41  2832.0  2851.2    18.579
         2    19.07  139.60  919.4  305.50   5.53    23.02  2836.6  2878.7    18.648
         3    19.14  142.67  932.8  312.30   6.27    22.47  2800.2  2906.7    18.700
         4    19.17  142.23  948.9  317.10   6.80    22.13  2816.9  2934.8    18.743

              Curr
         0  31.830
         1  31.862
         2  32.217
         3  32.624
         4  32.073
```

3.2 Question 2

- Calculer inf, le taux d'inflation à partir de la variable CPI.

Le taux d'inflation est donné par :
$ df_{inf} = (df_{CPI_t} - df_{CPI_{t-1}}) / (df_{CPI_t}) $

- Faire un graphique dans le temps de inf.

```
In [73]:
```

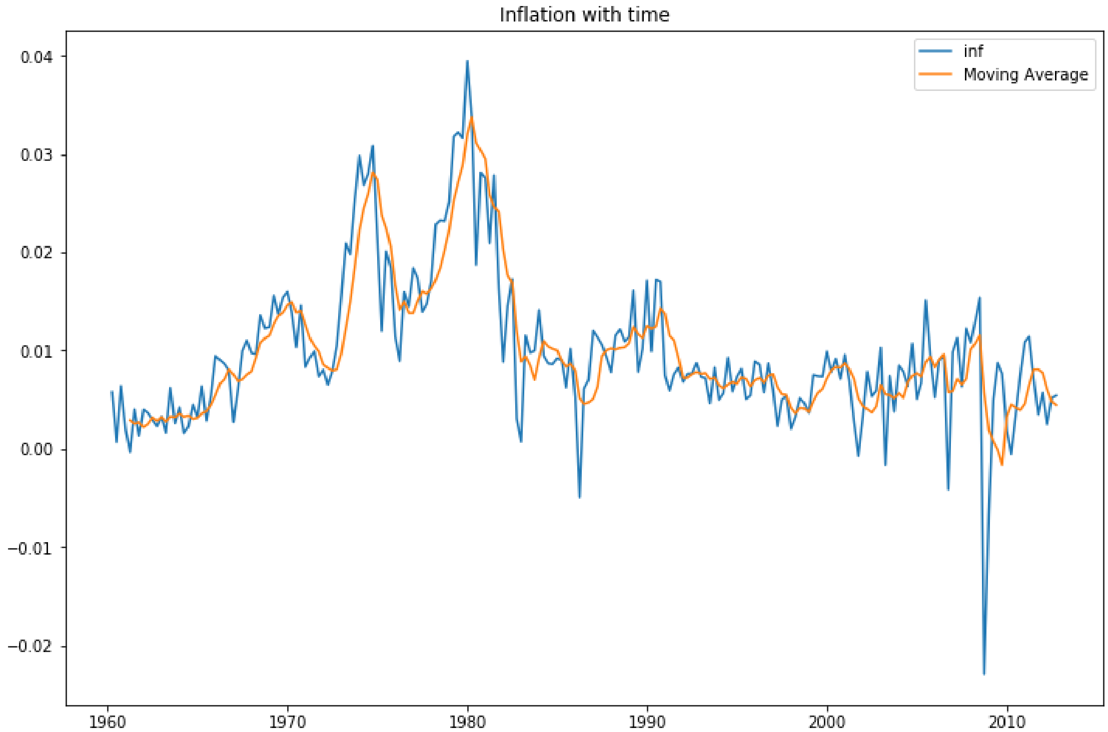

- Commentez.

L'inflation était élevée jusqu'en 1981, puis a chuté peu avant les années 1990. On remarque une déflation sur la période de crise financière de 2008. Le régime d'inflation semblait plus instable avant les années 90, puis contrôlé entre 1990 et 2008, avant la crise financière.

3.3 Question 3

- Interpréter l'autocorrélogramme et l'autocorrélogrammes partiels de inf.

In [74]:

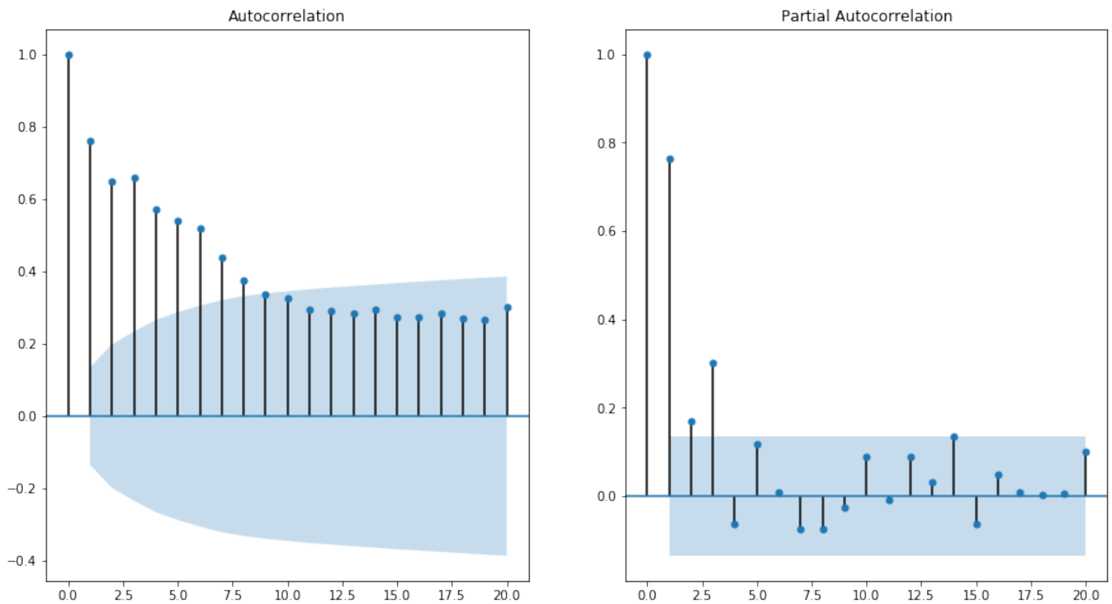

- L'autocorrélogramme indique que l'autocorrelation diminue avec le temps comme dans un processus ARMA(p,q)
- L'autocorrélogramme partiel oscille autour de 0 comme dans un processus de type Moving Average MA(1)

Cela signifie notamment qu'il existe une influence non-négligeable du passé pour la détermination des valeurs présentes. On peut supposer que la série n'est pas stationnaire.

- Quelle est la différence entre ces deux graphiques ?

L'autocorrélogramme donne l'influence d'une série à un temps t-k dans le passé sur la valeur de la série au temps t, indépendemment du reste des observations. L'autocorrélocgramme partiel réalise la régression de toutes du la valeur présente sur toutes les valeurs passées jusqu'au temps t-k. Ainsi, on identifie les effets joints des différents années.

3.4 Question 4

- Quelle est la différence entre la stationnarité et l'ergodicité ? Pourquoi a-t-on besoin de ces deux conditions?

- La stationarité est un état atteint lorsque ys, ys+1, ys+2 ... ne dépend pas de s. En d'autres termes, le futur et le présent sont relativement similaires.
- L'ergodicité est le processus par lequel l'on oublie les conditions initiales, et l'autocorrélation d''ordre k tend vers 0 quand k tend vers l'infini.
- Ces deux conditions sont nécessaires afin de pouvoir appliquer le théorème d'ergodicité qui garantit que la moyenne des valeurs des observations tend vers l'espérance de la série. Autrement dit, on s'assure que la série ne diverge pas de son espérance.

- Expliquez le terme "spurious regression".

- Le terme "spurious regression" se refère au fait que deux variables soient corrélées mais qu'aucun lien de causalité ne puis pour autant être établi entre les variables.

3.5 Question 5

- Proposer une modélisation AR(p) de inf, en utilisant tous les outils vus au cours.

In [75]:

```
                              ARMA Model Results
==============================================================================
Dep. Variable:                    inf   No. Observations:                  211
Model:                     ARMA(5, 0)   Log Likelihood                 832.908
Method:                       css-mle   S.D. of innovations              0.005
Date:                Fri, 26 Apr 2019   AIC                          -1651.816
Time:                        17:40:16   BIC                          -1628.353
Sample:                             0   HQIC                         -1642.331

==============================================================================
                 coef    std err          z      P>|z|      [0.025      0.975]
------------------------------------------------------------------------------
const          0.0093      0.002      4.018      0.000       0.005       0.014
ar.L1.inf      0.6044      0.068      8.857      0.000       0.471       0.738
ar.L2.inf     -0.0588      0.080     -0.737      0.462      -0.215       0.098
ar.L3.inf      0.3353      0.076      4.389      0.000       0.186       0.485
ar.L4.inf     -0.1316      0.080     -1.651      0.100      -0.288       0.025
ar.L5.inf      0.1190      0.068      1.742      0.083      -0.015       0.253
                                    Roots
=============================================================================
                  Real          Imaginary           Modulus         Frequency
-----------------------------------------------------------------------------
AR.1            1.0786           -0.0000j            1.0786           -0.0000
AR.2           -0.8581           -1.1850j            1.4631           -0.3497
AR.3           -0.8581           +1.1850j            1.4631            0.3497
AR.4            0.8714           -1.6967j            1.9074           -0.1745
AR.5            0.8714           +1.6967j            1.9074            0.1745
-----------------------------------------------------------------------------
```

Afin d'identifier le paramètre p optimal, on cherche à minimiser le critère Akaike Information Criterion (AIC).

In [77]:

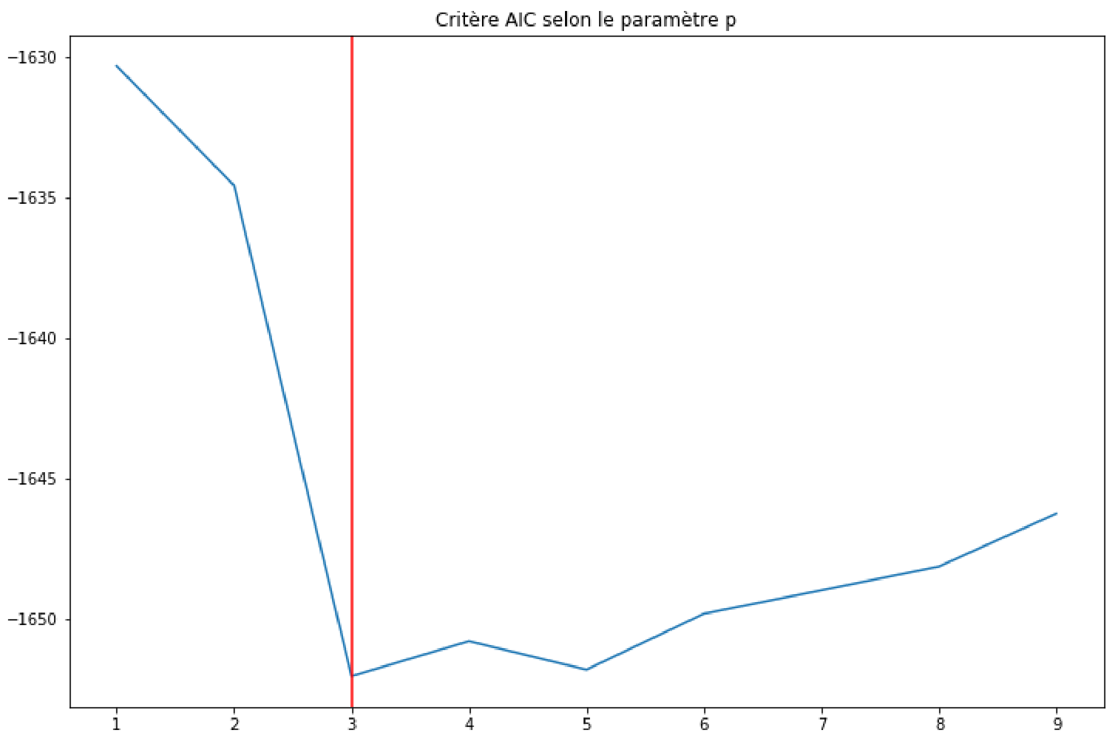

Le critère AIC est minimisé pour une valeur de p valant 3. On peut s'intéresser à la performance en prédiction d'un tel modèle.

In [79]:

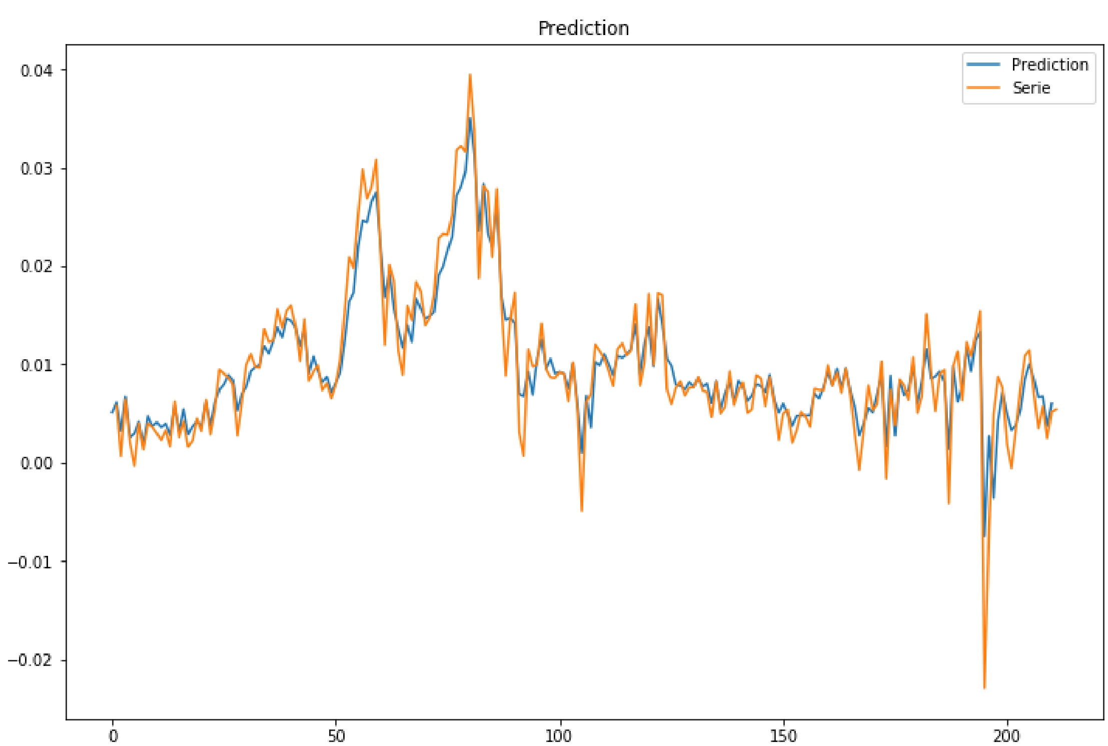

In [80]:

```
Lag: 3
Coefficients: [ 0.00962934  0.57949951 -0.01686016  0.29775042]
```

3.6 Question 6

- Estimer le modèle de la courbe de Philips qui explique le taux de chômage (Unemp) en fonction du taux d'inflation courant et une constante.

In [81]:

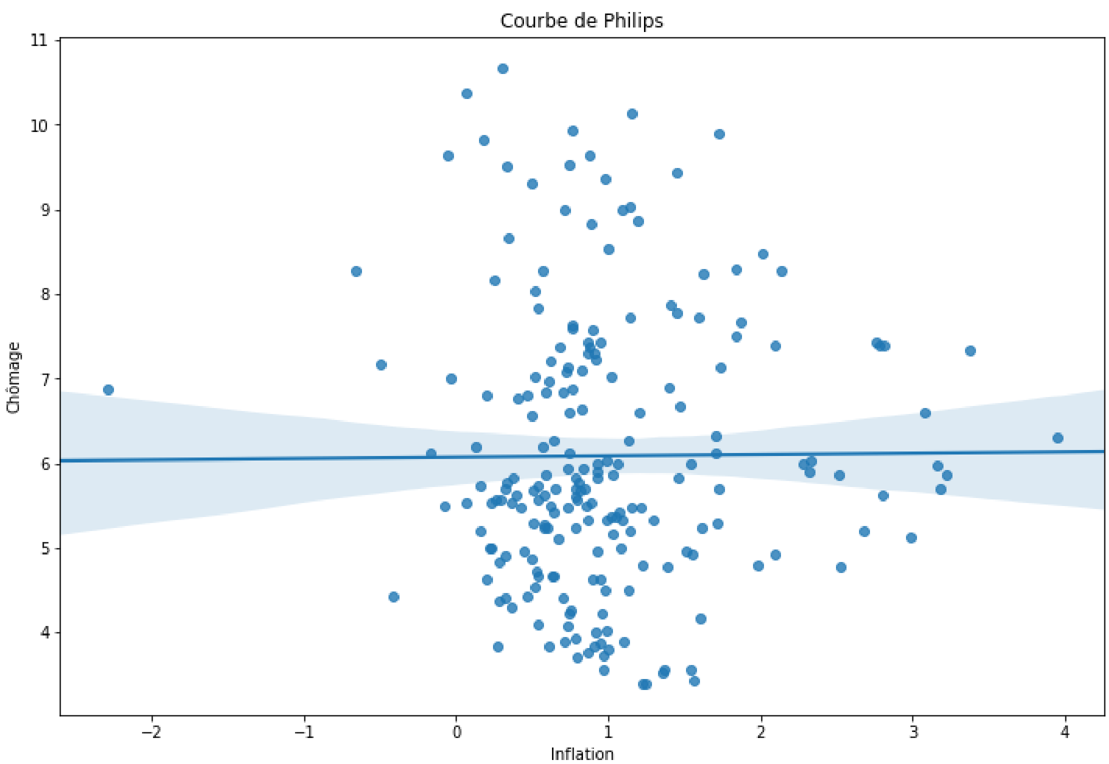

In [82]:

```
                            OLS Regression Results
==============================================================================
Dep. Variable:                  Unemp   R-squared:                       0.000
Model:                            OLS   Adj. R-squared:                 -0.005
Method:                 Least Squares   F-statistic:                   0.01214
Date:                Fri, 26 Apr 2019   Prob (F-statistic):              0.912
```

```
Time:                        17:41:07   Log-Likelihood:                -400.28
No. Observations:                 211   AIC:                             804.6
Df Residuals:                     209   BIC:                             811.3
Df Model:                           1
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const          6.0708      0.181     33.576      0.000       5.714       6.427
inf            0.0159      0.144      0.110      0.912      -0.269       0.301
==============================================================================
Omnibus:                       13.872   Durbin-Watson:                   0.044
Prob(Omnibus):                  0.001   Jarque-Bera (JB):               15.356
Skew:                           0.660   Prob(JB):                     0.000463
Kurtosis:                       2.937   Cond. No.                         2.99
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

Le coefficient semble indiquer qu'une augmentation de 1% de l'inflation augmente le chômage de 0.016%. Il ne semble pas que la variable CPI soit significative à 5% étant donné que la p-value est supérieure à ce seuil.

3.7 Question 7

- Tester l'autocorrélation des erreurs.

On peut commencer par représenter graphiquement la valeur des résidus :

In [84]:

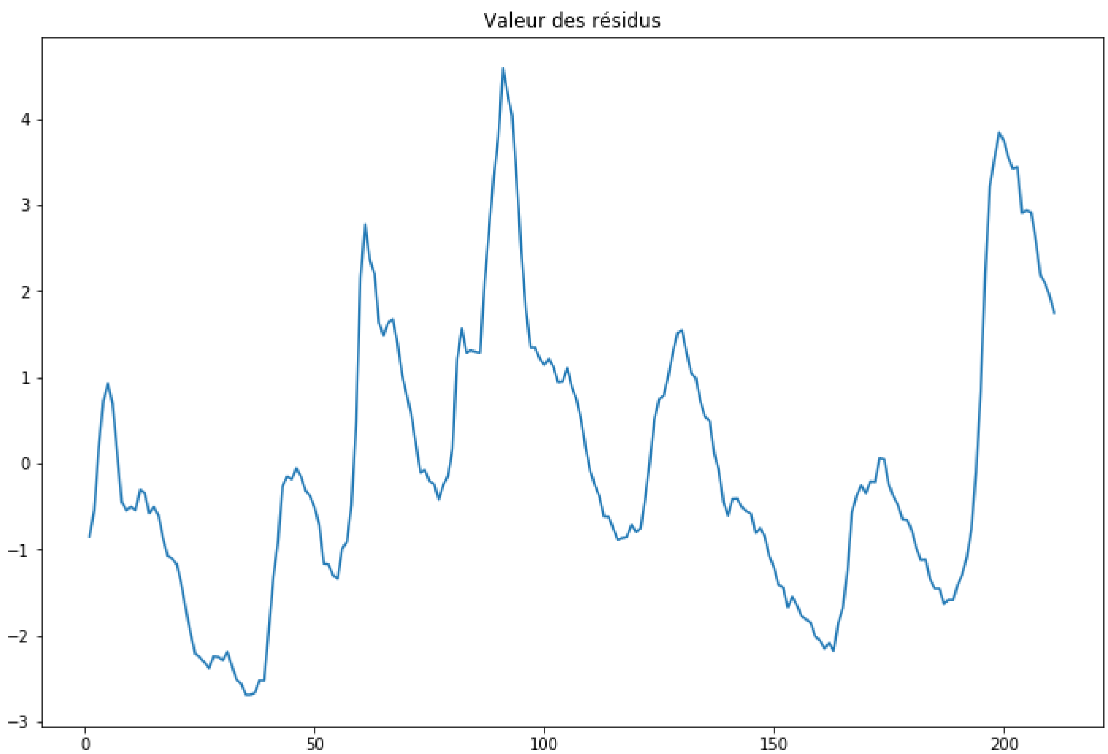
Valeur des résidus
4
3
2
1
0
−1
−2
−3
0
50
100
150
200

In [85]:

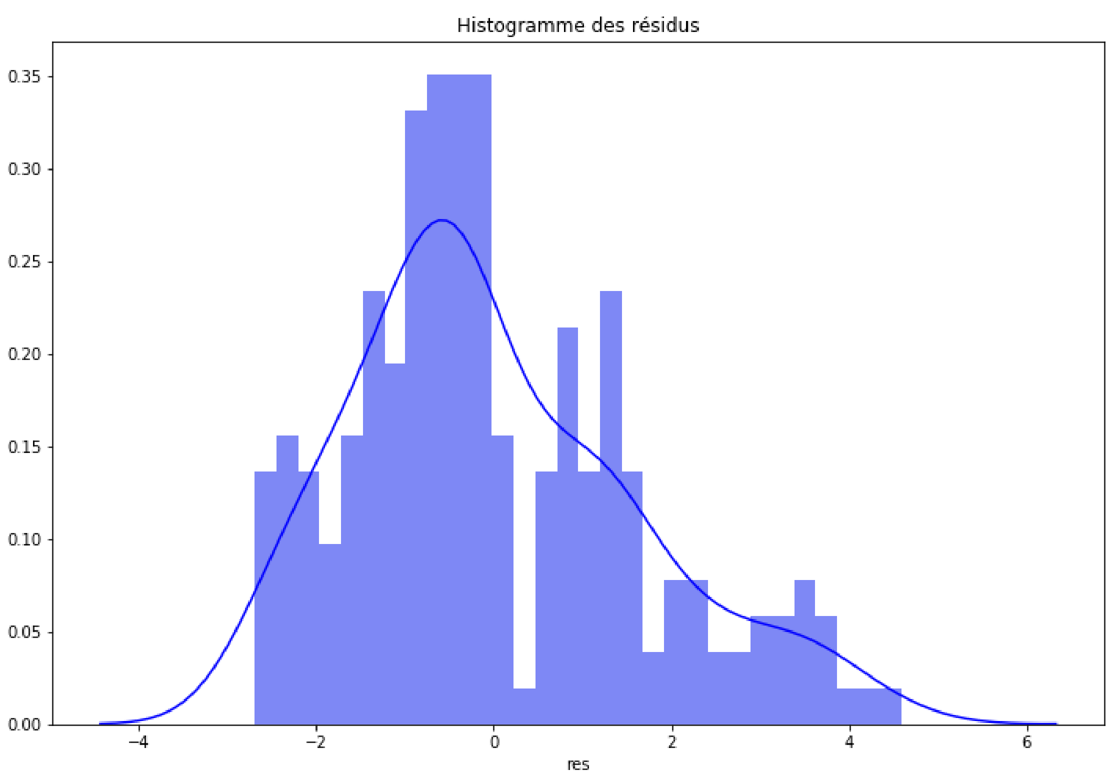
Histogramme des résidus
0.35
0.30
0.25
0.20
0.15
0.10
0.05
0.00
−4
−2
0
2
4
6
res

Pour tester l'autocorrélation des erreurs, on peut appliquer le test de Durbin Watson sur les résidus. Les résidus, après régression, devraient avoir une moyenne de 0 et pas de corrélation. Ainsi, si le test d'autocorrélation de Durbin Watson vaut environ 2, il n'y a pas d'autocorrélation, s'il vaut proche de 0, il y a une autocorrélation positive, et s'il vaut environ 4, l'autocorrélation est négative.

```
In [86]: # Durbin Watson test
         durbin_watson(df.res)
```

```
Out[86]: 0.044194128074712014
```

Ici, la valeur du test de DW est proche de 0. On en conclut que l'autocorrélation doit être positive. Si l'on regarde l'autocorrélogramme, on confirme ce constat.

```
In [87]:
```

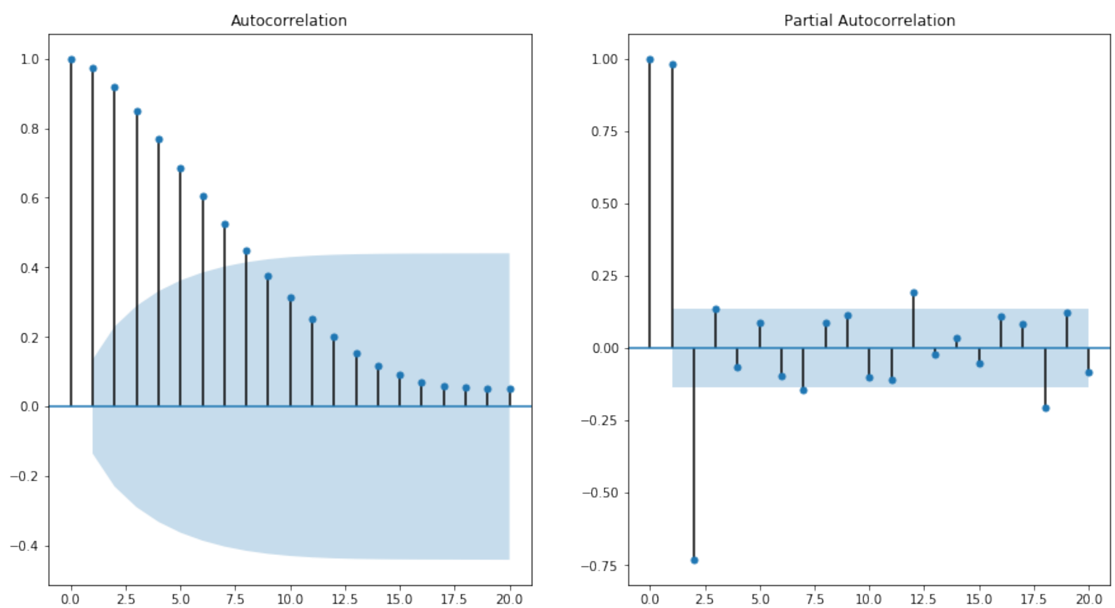

3.8 Question 8

- Corriger l'autocorrélation des erreurs par la méthode vue en cours.

Afin de corriger l'autocorrélation, on peut estimer un nouveau modèle égal à :

$$y_t - \rho y_{t-1} = \tilde{y}_t = (1-\rho)\beta_0 + \beta_1 \tilde{X}_t + \epsilon_t$$

```
In [88]: # Estimation de rho
         print(rho)
```

0.979923779970792

On estime maintenant avec le nouveau modèle laggé la statistique de Durbin Watson :

```
In [92]: durbin_watson(df['res_c'])
```

```
Out[92]: 0.718292189000225
```

Le test de Durbin Watson est plus proche de 2. On a donc corrigé une partie de l'autocorrélation.

```
In [93]:
```

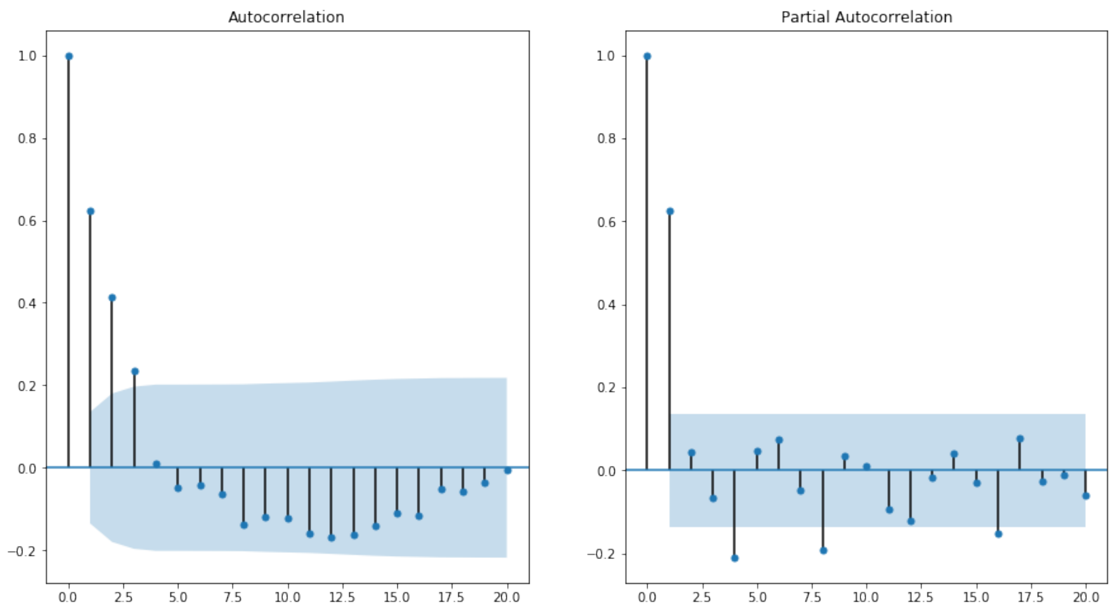

Nous pouvons donc utiliser ces valeurs corrigées pour la suite. (Nous ne savons pas si c'est ce qui était attendu, mais cela nous paraissait logique).

3.9 Question 9

- Tester la stabilité de la relation chômage-inflation sur deux sous-périodes de taille identique.

On peut commencer par regarder les paramètres lorsque l'on coupe notre période en 2 :

```
In [94]:
```

```
                            OLS Regression Results
==============================================================================
Dep. Variable:                      y   R-squared:                       0.007
Model:                            OLS   Adj. R-squared:                 -0.003
Method:                 Least Squares   F-statistic:                    0.7071
```

```
Date:                Fri, 26 Apr 2019   Prob (F-statistic):              0.402
Time:                        17:41:26   Log-Likelihood:                -204.20
No. Observations:                 105   AIC:                             412.4
Df Residuals:                     103   BIC:                             417.7
Df Model:                           1
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const          5.9377      0.287     20.662      0.000       5.368       6.508
x1            15.6225     18.579      0.841      0.402     -21.224      52.469
==============================================================================
Omnibus:                        3.884   Durbin-Watson:                   0.059
Prob(Omnibus):                  0.143   Jarque-Bera (JB):                3.782
Skew:                           0.462   Prob(JB):                        0.151
Kurtosis:                       2.889   Cond. No.                         111.
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

In [95]:

```
                            OLS Regression Results
==============================================================================
Dep. Variable:                      y   R-squared:                       0.031
Model:                            OLS   Adj. R-squared:                  0.022
Method:                 Least Squares   F-statistic:                     3.315
Date:                Fri, 26 Apr 2019   Prob (F-statistic):             0.0715
Time:                        17:41:26   Log-Likelihood:                -193.35
No. Observations:                 106   AIC:                             390.7
Df Residuals:                     104   BIC:                             396.0
Df Model:                           1
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const          6.4269      0.259     24.822      0.000       5.913       6.940
x1           -54.4051     29.882     -1.821      0.072    -113.663       4.853
==============================================================================
Omnibus:                       12.639   Durbin-Watson:                   0.082
Prob(Omnibus):                  0.002   Jarque-Bera (JB):               14.065
Skew:                           0.890   Prob(JB):                     0.000883
Kurtosis:                       3.121   Cond. No.                         203.
==============================================================================

Warnings:
```

```
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

On peut maintenant réaliser un test de changement de structure (test de Chow).

```
In [99]: print(F, p_val)
```

```
4.147753695614069 0.017132140479924507
```

La p-value est inférieure au seuil de 5%. On rejette donc l'hypothèse de stabilité entre les deux périodes pour la séparation que nous avons sélectionné.

3.10 Question 10

- Faites les tests changement de structure de Chow.

On commence par representer graphiquement les séries d'inflation et de chômage laggées.

```
In [100]:
```

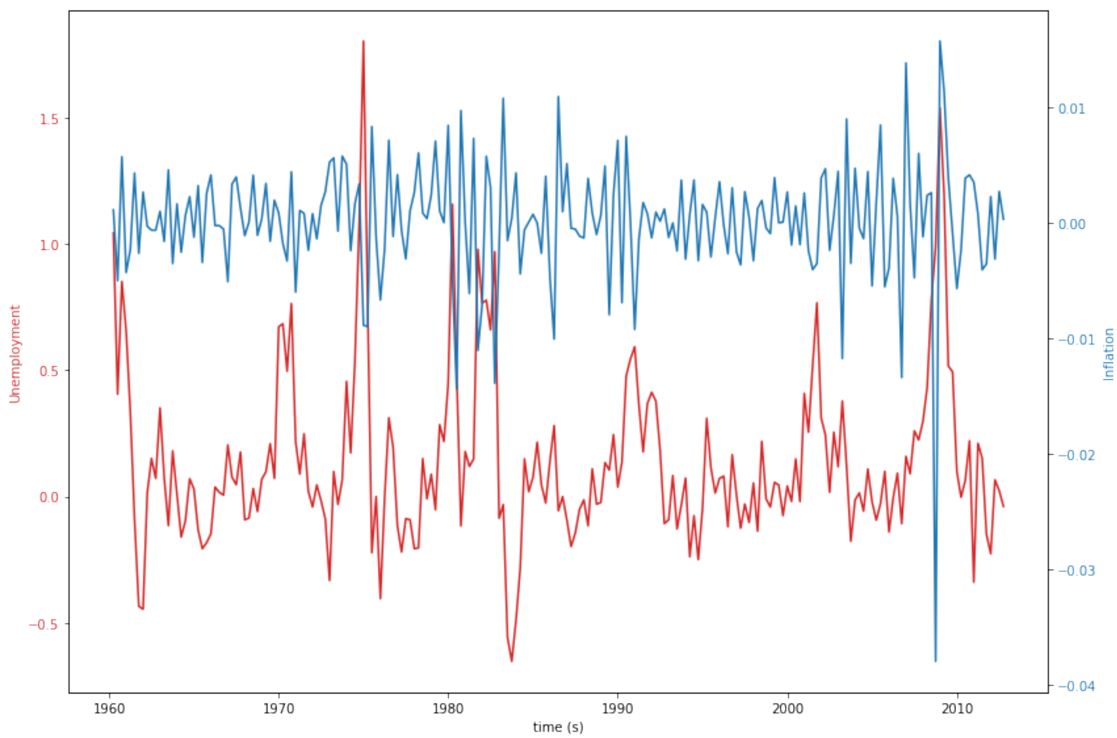

- Détecter le point de rupture.

```
In [103]:
```

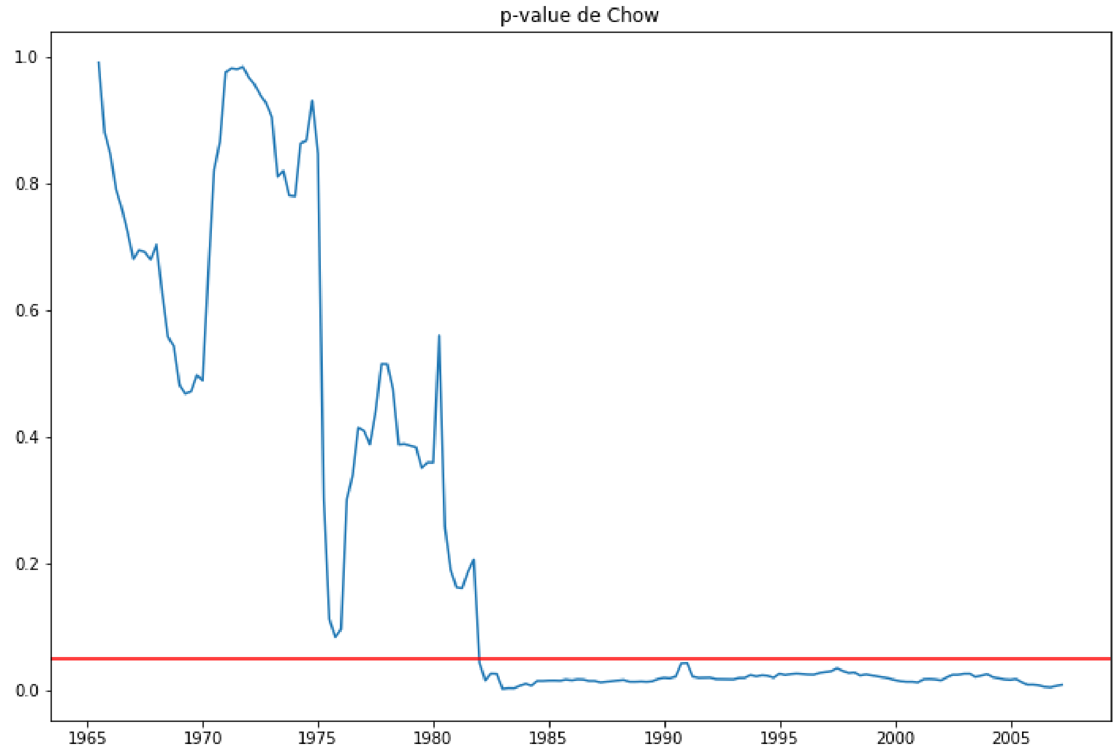


```
In [104]: # Période de rupture
          df.DATE[int(0.1*len(df)) + np.argmin(p_val)]

Out[104]: Timestamp('1982-10-01 00:00:00')
```

L'hypothèse nulle du test de Chow indique que l'on suppose qu'il n'y a pas de changement de structure. Ainsi, lorsque la p-value est inférieure à 5%, on doit faire l'hypothèse que la structure change dans le temps. Avant l'année 82, il n'y avait pas/peu de stabilité dans le régime d'inflation.

La crise pétrolière des années 70 a failli provoquer un changement de structure. En 1982, un point de rupture a été atteint.

3.11 Question 11

- Estimer la courbe de Philips en supprimant l'inflation courante des variables explicatives mais en ajoutant les délais d'ordre 1, 2, 3 et 4 de l'inflation et du chômage.

```
In [107]: # Variables 0-3 : Unemp.
          # Variables 4-7 : infl.

                            OLS Regression Results
==============================================================================
Dep. Variable:                      8   R-squared:                       0.463
Model:                            OLS   Adj. R-squared:                  0.441
Method:                 Least Squares   F-statistic:                     21.21
```

```
Date:                Fri, 26 Apr 2019   Prob (F-statistic):           4.55e-23
Time:                        17:41:32   Log-Likelihood:                -2.0160
No. Observations:                 206   AIC:                             22.03
Df Residuals:                     197   BIC:                             51.98
Df Model:                           8
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const          0.0469      0.020      2.308      0.022       0.007       0.087
0              0.6929      0.070      9.849      0.000       0.554       0.832
1             -0.0130      0.088     -0.148      0.882      -0.187       0.161
2              0.0601      0.088      0.685      0.494      -0.113       0.233
3             -0.1377      0.072     -1.925      0.056      -0.279       0.003
4              3.0798      3.853      0.799      0.425      -4.518      10.678
5              1.7130      4.141      0.414      0.680      -6.454       9.880
6              5.1964      4.058      1.281      0.202      -2.805      13.198
7              5.2705      3.758      1.402      0.162      -2.141      12.682
==============================================================================
Omnibus:                       34.516   Durbin-Watson:                   2.009
Prob(Omnibus):                  0.000   Jarque-Bera (JB):               78.607
Skew:                           0.763   Prob(JB):                     8.52e-18
Kurtosis:                       5.613   Cond. No.                         340.
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

Les variables significatives dans ce nouveau modèle sont : - le chômage au temps t-1 - le chômage au temps t-4

- Faire le test de Granger de non causalité de l'inflation sur le chômage. Donnez la p-valeur.

L'hypothèse nulle pour les tests de causalité de Granger est que la série temporelle dans la deuxième colonne, x2, ne cause PAS la série temporelle dans la première colonne, x1.

La causalité de Granger signifie que les valeurs passées de x2 ont un effet statistiquement significatif sur la valeur actuelle de x1, en tenant compte des valeurs passées de x1 comme variables explicatives.

Nous rejetons l'hypothèse nulle que x2 ne cause pas x1 au sens de Granger si les valeurs p sont inférieures au seuil désiré.

```
In [108]: granger(df[['Unemp_lag', 'inf_lag']], 5)
```

```
Granger Causality
number of lags (no zero) 1
ssr based F test:         F=0.3433  , p=0.5586  , df_denom=207, df_num=1
ssr based chi2 test:   chi2=0.3482  , p=0.5551  , df=1
```

```
likelihood ratio test: chi2=0.3480  , p=0.5553  , df=1
parameter F test:         F=0.3433  , p=0.5586  , df_denom=207, df_num=1

Granger Causality
number of lags (no zero) 2
ssr based F test:         F=0.5393  , p=0.5840  , df_denom=204, df_num=2
ssr based chi2 test:   chi2=1.1051  , p=0.5755  , df=2
likelihood ratio test: chi2=1.1022  , p=0.5763  , df=2
parameter F test:         F=0.5393  , p=0.5840  , df_denom=204, df_num=2

Granger Causality
number of lags (no zero) 3
ssr based F test:         F=0.8206  , p=0.4839  , df_denom=201, df_num=3
ssr based chi2 test:   chi2=2.5475  , p=0.4668  , df=3
likelihood ratio test: chi2=2.5320  , p=0.4695  , df=3
parameter F test:         F=0.8206  , p=0.4839  , df_denom=201, df_num=3

Granger Causality
number of lags (no zero) 4
ssr based F test:         F=0.8129  , p=0.5183  , df_denom=198, df_num=4
ssr based chi2 test:   chi2=3.3995  , p=0.4933  , df=4
likelihood ratio test: chi2=3.3719  , p=0.4976  , df=4
parameter F test:         F=0.8129  , p=0.5183  , df_denom=198, df_num=4

Granger Causality
number of lags (no zero) 5
ssr based F test:         F=1.1297  , p=0.3459  , df_denom=195, df_num=5
ssr based chi2 test:   chi2=5.9672  , p=0.3094  , df=5
likelihood ratio test: chi2=5.8824  , p=0.3178  , df=5
parameter F test:         F=1.1297  , p=0.3459  , df_denom=195, df_num=5
```

```
Out[108]: {1: ({'lrtest': (0.3479507614470094, 0.5552754528335102, 1),
              'params_ftest': (0.34326433653111804, 0.5585892708239268, 207.0, 1.0),
              'ssr_chi2test': (0.3482391819880981, 0.5551115828057411, 1),
              'ssr_ftest': (0.34326433653112526, 0.5585892708239268, 207.0, 1)},
             [<statsmodels.regression.linear_model.RegressionResultsWrapper at 0x1c27b57e10>,
              <statsmodels.regression.linear_model.RegressionResultsWrapper at 0x1c26bdac18>,
              array([[0., 1., 0.]])]),
           2: ({'lrtest': (1.1022042952622542, 0.576314276803943, 2),
              'params_ftest': (0.539338792500007, 0.5839628648705697, 204.0, 2.0),
              'ssr_chi2test': (1.1051157611029379, 0.5754759274931314, 2),
              'ssr_ftest': (0.5393387924999984, 0.5839628648705697, 204.0, 2)},
             [<statsmodels.regression.linear_model.RegressionResultsWrapper at 0x1c1e68c908>,
              <statsmodels.regression.linear_model.RegressionResultsWrapper at 0x10b3e9400>,
              array([[0., 0., 1., 0., 0.],
                     [0., 0., 0., 1., 0.]])]),
           3: ({'lrtest': (2.5320350129870803, 0.46952944812668085, 3),
```

```
    'params_ftest': (0.8205919320314315, 0.48386507661399847, 201.0, 3.0),
    'ssr_chi2test': (2.547509281530395, 0.46676624303068226, 3),
    'ssr_ftest': (0.8205919320314254, 0.48386507661399847, 201.0, 3)},
   [<statsmodels.regression.linear_model.RegressionResultsWrapper at 0x1c26e6e358>,
    <statsmodels.regression.linear_model.RegressionResultsWrapper at 0x1c26e6e320>,
    array([[0., 0., 0., 1., 0., 0., 0.],
           [0., 0., 0., 0., 1., 0., 0.],
           [0., 0., 0., 0., 0., 1., 0.]])]),
  4: ({'lrtest': (3.3718812726583565, 0.49762443173547544, 4),
    'params_ftest': (0.8129224208084789, 0.5182535412167016, 198.0, 4.0),
    'ssr_chi2test': (3.39949375974459, 0.4933241285296037, 4),
    'ssr_ftest': (0.8129224208084889, 0.518253541216691, 198.0, 4)},
   [<statsmodels.regression.linear_model.RegressionResultsWrapper at 0x1c26e6e438>,
    <statsmodels.regression.linear_model.RegressionResultsWrapper at 0x1c26e6e5c0>,
    array([[0., 0., 0., 0., 1., 0., 0., 0., 0.],
           [0., 0., 0., 0., 0., 1., 0., 0., 0.],
           [0., 0., 0., 0., 0., 0., 1., 0., 0.],
           [0., 0., 0., 0., 0., 0., 0., 1., 0.]])]),
  5: ({'lrtest': (5.882360219525708, 0.31783463281265495, 5),
    'params_ftest': (1.1297033821092815, 0.34594303534456483, 195.0, 5.0),
    'ssr_chi2test': (5.967151197807944, 0.3094283859411353, 5),
    'ssr_ftest': (1.129703382109271, 0.3459430353445758, 195.0, 5)},
   [<statsmodels.regression.linear_model.RegressionResultsWrapper at 0x1c26e6e978>,
    <statsmodels.regression.linear_model.RegressionResultsWrapper at 0x1c26e6ea58>,
    array([[0., 0., 0., 0., 0., 1., 0., 0., 0., 0., 0.],
           [0., 0., 0., 0., 0., 0., 1., 0., 0., 0., 0.],
           [0., 0., 0., 0., 0., 0., 0., 1., 0., 0., 0.],
           [0., 0., 0., 0., 0., 0., 0., 0., 1., 0., 0.],
           [0., 0., 0., 0., 0., 0., 0., 0., 0., 1., 0.]])])}
```

L'intégralité des p-values sont supérieures au seuil de 5%. Nous rejetons donc pas l'hypothèse nulle que l'inflation ne cause pas de chômage.

3.12 Question 12

- Représentez graphiquement les délais distribués et commentez.

Un délai distribué peut-être exprimé comme :

$$y_t = \alpha_0 + \delta_0 z_t + \delta_1 z_{t-1} + \delta_2 z_{t-2} + \delta_3 z_{t-3} + \delta_4 z_{t-4} + u_t$$

In [109]:

```
                            OLS Regression Results
==============================================================================
Dep. Variable:                      8   R-squared:                       0.455
Model:                            OLS   Adj. R-squared:                  0.442
Method:                 Least Squares   F-statistic:                     33.41
Date:                Fri, 26 Apr 2019   Prob (F-statistic):           1.02e-24
```

```
Time:                        17:41:32   Log-Likelihood:                -3.4753
No. Observations:                 206   AIC:                             18.95
Df Residuals:                     200   BIC:                             38.92
Df Model:                           5
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
const          0.0539      0.020      2.749      0.007       0.015       0.093
0              0.6924      0.070      9.917      0.000       0.555       0.830
1             -0.0230      0.087     -0.265      0.791      -0.194       0.148
2              0.0577      0.087      0.665      0.507      -0.113       0.229
3             -0.1571      0.069     -2.267      0.024      -0.294      -0.020
4              2.2438      3.435      0.653      0.514      -4.530       9.017
==============================================================================
Omnibus:                       37.726   Durbin-Watson:                   1.981
Prob(Omnibus):                  0.000   Jarque-Bera (JB):               88.869
Skew:                           0.821   Prob(JB):                     5.04e-20
Kurtosis:                       5.767   Cond. No.                         207.
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.
```

In [110]:

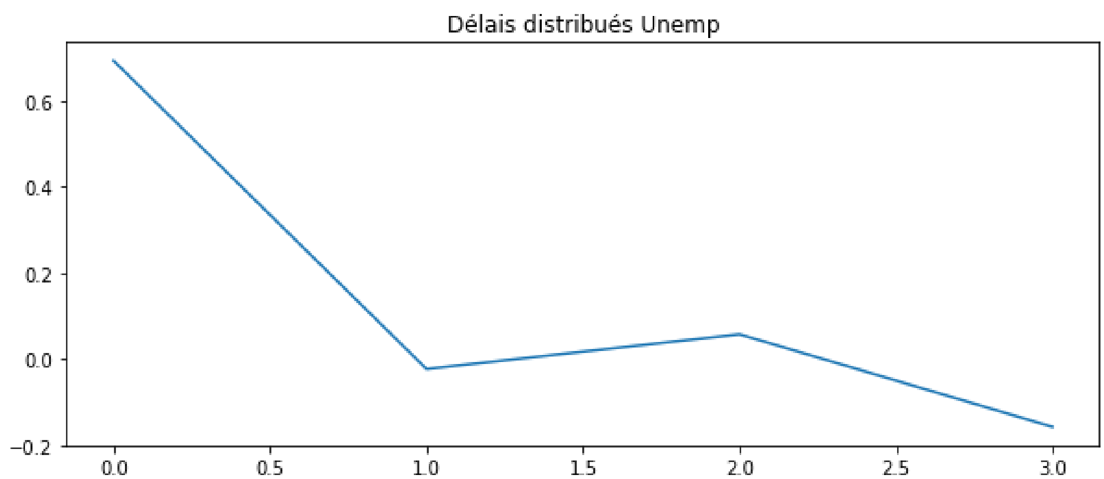

- Calculer l'impact à long de terme de l'inflation sur le chômage.

L'effet de long terme est donné par :

$$\delta_0 + \delta_1 + \delta_2 + \delta_3 + ...$$

In [111]: model.params[1:].sum()

Out[111]: 2.8137925103027586