solution_2017

December 25, 2020

1 Evaluation Python année 2016-2017 - solution

Le répertoire data contient deux fichiers csv simulés aléatoirement dont il faudra se servir pour répondre aux 10 questions qui suivent. Chaque question vaut deux points. Le travail est à rendre pour le lundi 20 février sous la forme d'un notebook envoyé en pièce jointe d'un mail.

[1]:
```
%matplotlib inline
```

[2]:
```
from jyquickhelper import add_notebook_menu
add_notebook_menu()
```

[2]:
```
<IPython.core.display.HTML object>
```

1.1 1

Deux fichiers sont extraits de la base de données d'un médecin. Un fichier contient des informations sur des personnes, un autre sur les rendez-vous pris par ces personnes. Quels sont-ils ?

[3]:
```
import pandas
persons = pandas.read_csv("https://raw.githubusercontent.com/sdpython/actuariat_python/
 ↪master/_doc/notebooks/examen/data/persons.txt",
                          sep="\t")
persons.head()
```

[3]:

	age	gender	idc	name
0	37	0	4ba0b473-f8ca-4466-a65b-40e9b8ba5029	Cendrillon
1	41	0	f44b004b-b01e-4835-b86d-1a42846c6d93	Cendrillon
2	46	1	304895f0-f686-4b0e-8854-a705bb5a6982	Balthazar
3	42	1	3f0d31d2-0ef4-4e7e-b876-07d10225cc8c	Balthazar
4	41	1	f29273f4-a76c-4158-b5f5-b3e5a080a0c7	Balthazar

[4]:
```
rend = pandas.read_csv("https://raw.githubusercontent.com/sdpython/actuariat_python/
 ↪master/_doc/notebooks/examen/data/rendezvous.txt",
                       sep="\t")
rend.head()
```

[4]:

	date	idc	\
0	2016-12-02 19:47:45.068274	4ba0b473-f8ca-4466-a65b-40e9b8ba5029	
1	2016-12-02 19:47:45.068274	4ba0b473-f8ca-4466-a65b-40e9b8ba5029	
2	2016-12-07 19:47:45.068274	f44b004b-b01e-4835-b86d-1a42846c6d93	
3	2016-12-17 19:47:45.068274	f44b004b-b01e-4835-b86d-1a42846c6d93	
4	2017-01-07 19:47:45.068274	f44b004b-b01e-4835-b86d-1a42846c6d93	

```
                                    idr  price
0  b7db0ac9-86a1-46f9-98ac-f1f8eb54072d   75.0
1  a65f721a-de11-4a01-be71-b26e2da3ac00   65.0
2  644b1236-b9ee-4ef5-8ca7-d1adadb547c8   75.0
3  aff6ac9e-5dd0-434e-9888-f724f6d40969   80.0
4  9ca87507-aa95-49a9-88b3-86ec9fbc44d6   80.0
```

[5]:
```
persons.shape, rend.shape
```

[5]:
```
((1000, 4), (2537, 4))
```

Le second fichier est plus volumineux et contient une variable *price* qui ne peut pas être reliée aux personnes. Le premier fichier est celui des personnes, le second celui des rendez-vous. La variable *idc* est présente dans les deux tables. C'est elle qui identifie les personnes dans les deux tables.

1.2 2

On souhaite étudier la relation entre le prix moyen payé par une personne, son âge et son genre. Calculer le prix moyen payé par une personne ?
La table des rendez-vous contient toutes l'information nécessaire. La question était un peu ambiguë. On peut déterminer le prix moyen payé par personne, ou le prix moyen des prix moyens… On va répondre à la première option car la seconde n'a pas beaucoup d'intérêt et c'est très proche du prix moyen par rendez-vous, ce que la question aurait sans doute formulé dans ce sens si telle avait été son intention. On groupe par *idc* et on fait la moyenne.

[6]:
```
gr = rend.groupby("idc").mean()
gr.head()
```

[6]:
```
                                     price
idc
003b0195-2acb-4f46-b7fa-28cf266a8f60   80.0
009e689c-51a1-4cef-99ca-a4ba364eba8d   80.0
00a213c2-1174-4359-8a67-fe710ec1b439   70.0
00e42818-aade-4758-a5f6-c78a6f235ea5   70.0
0153b785-9acd-4d28-aad1-62f8bf2faea3   75.0
```

1.3 3

Faire la jointure entre les deux tables.

[7]:
```
join = persons.merge(gr.reset_index(), on="idc")
join.head()
```

[7]:
```
   age  gender                                   idc        name      price
0   37       0  4ba0b473-f8ca-4466-a65b-40e9b8ba5029  Cendrillon  70.000000
1   41       0  f44b004b-b01e-4835-b86d-1a42846c6d93  Cendrillon  78.333333
2   46       1  304895f0-f686-4b0e-8854-a705bb5a6982   Balthazar  75.000000
3   42       1  3f0d31d2-0ef4-4e7e-b876-07d10225cc8c   Balthazar  95.000000
4   41       1  f29273f4-a76c-4158-b5f5-b3e5a080a0c7   Balthazar  90.000000
```

Cette jointure est assez simple puisque la colonne partagée porte le même nom dans les deux tables. On peut néanmoins se poser la question de savoir s'il y a des personnes qui n'ont pas de rendez-vous associé et réciproquement.

[8]:
```
join.shape
```

[8]:
```
(1000, 5)
```

[9]:
```
join = persons.merge(gr.reset_index(), on="idc", how="outer")
join.shape
```

[9]:
```
(1000, 5)
```

Visiblement, ce n'est pas le cas puisqu'une jointure incluant les éléments sans correspondances dans les deux tables n'ajoute pas plus d'éléments à la jointure.

1.4 4

Tracer deux nuages de points (age, prix moyen) et (genre, prix moyen) ?

[10]:
```
join.plot(x="age", y="price", kind="scatter")
```

[10]:
```
<matplotlib.axes._subplots.AxesSubplot at 0x1554008ecc0>
```

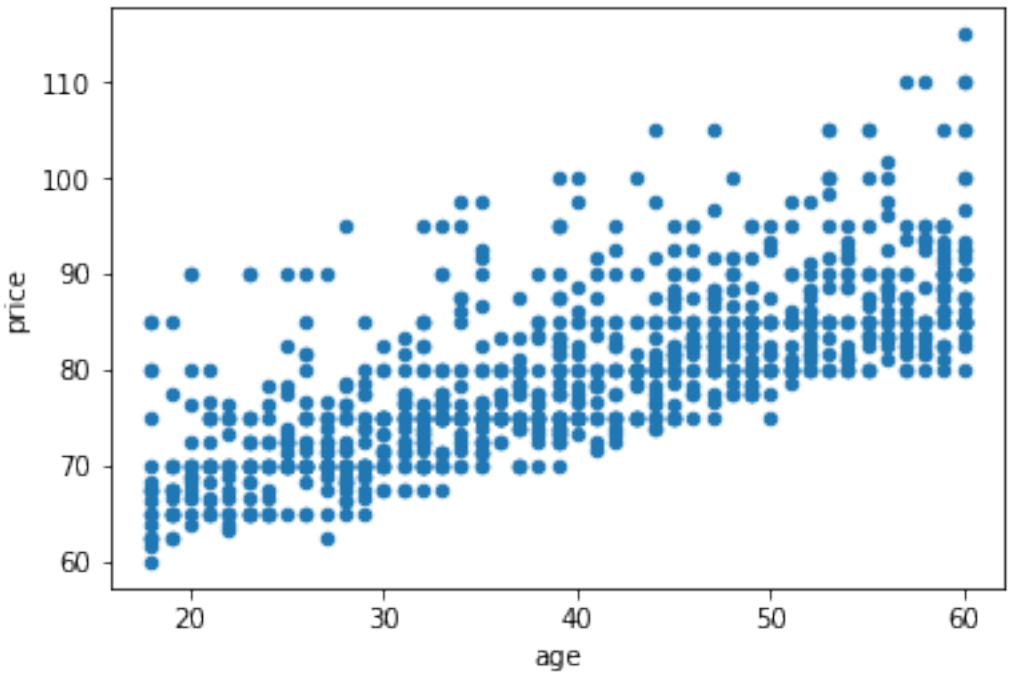

On peut aussi utiliser un module comme seaborn qui propose des dessins intéressants pour un statisticatien.

[11]:
```
import seaborn
g = seaborn.jointplot("age", "price", data=join, kind="reg", size=7, scatter_kws={"s":␣
↪10})
```

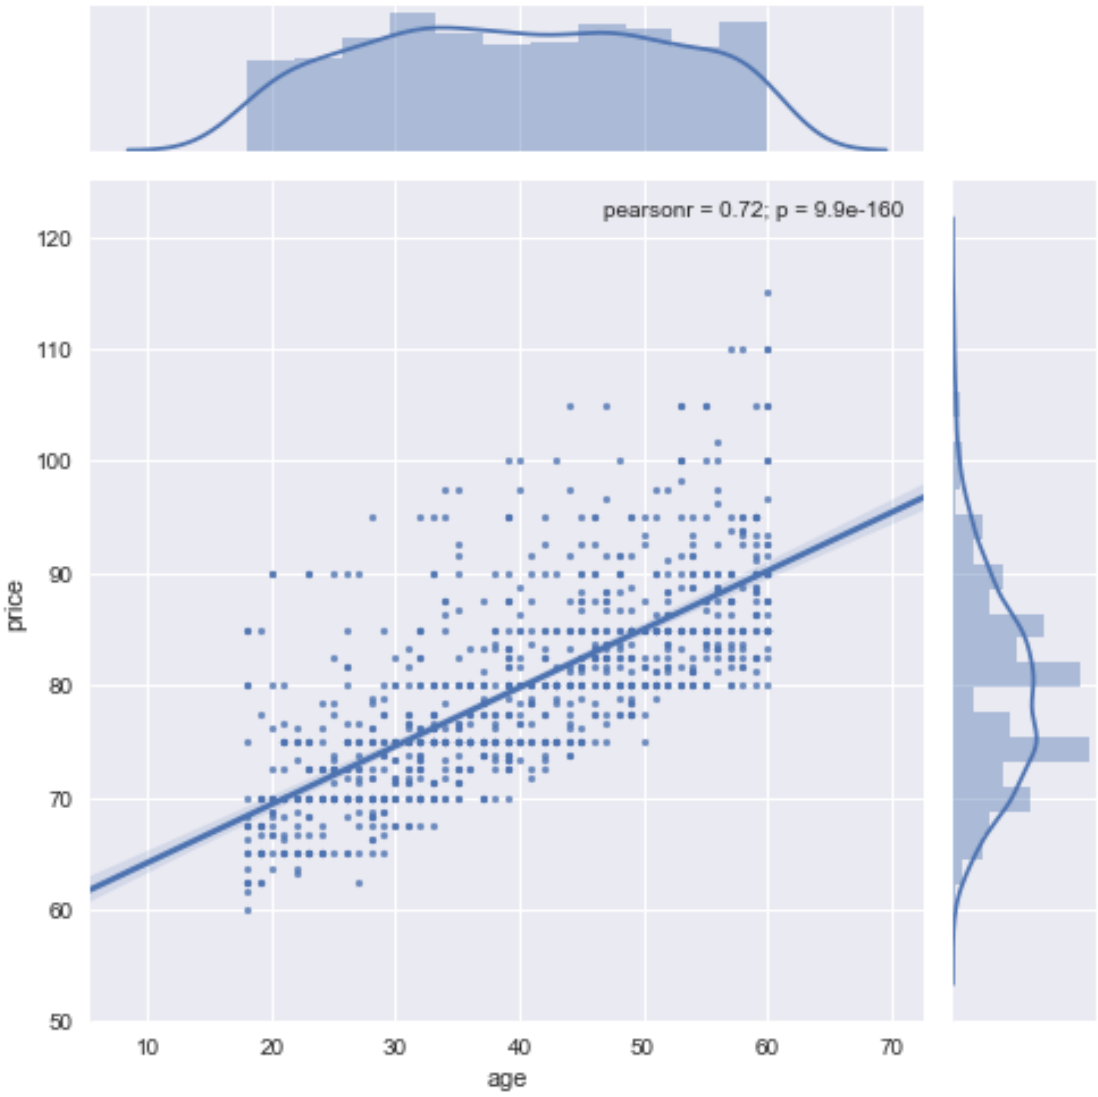

[12]:
```
join.plot(x="gender", y="price", kind="scatter")
```

[12]: <matplotlib.axes._subplots.AxesSubplot at 0x155422f6ef0>

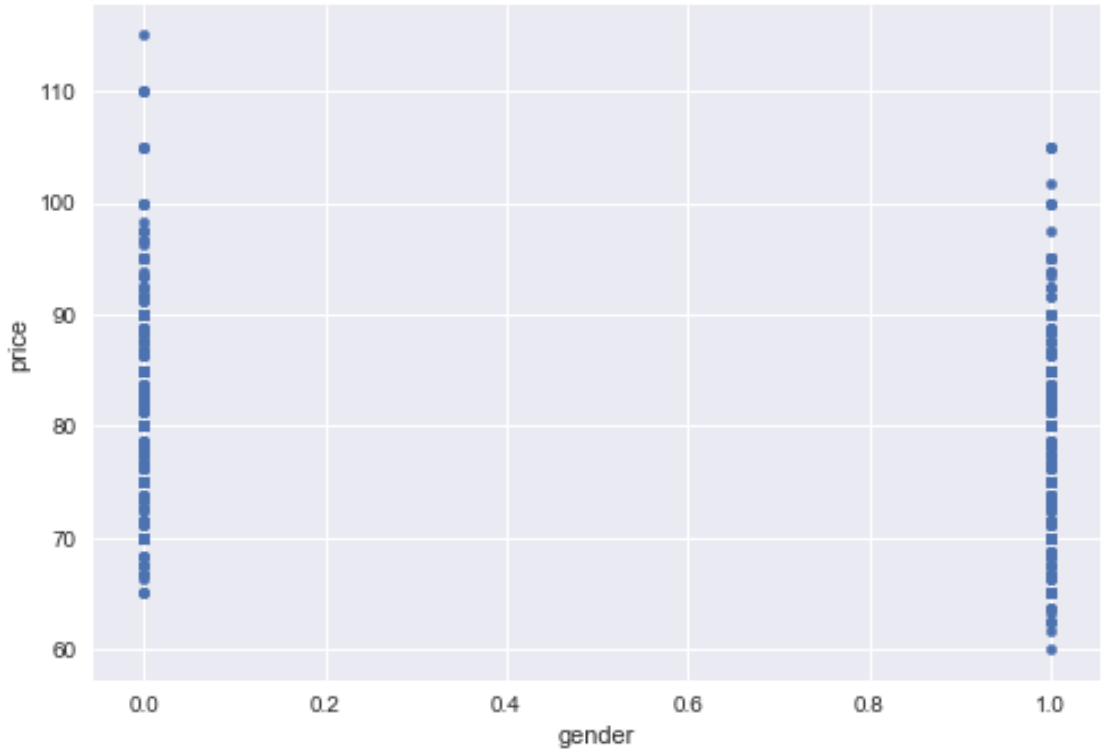

On ne voit pas grand chose sur ce second graphe. Une option est d'ajouter un bruit aléatoire sur le genre pour éclater le nuage.

[13]:
```
import numpy
bruit = join.copy()
bruit["gx"] = bruit.gender + numpy.random.random(bruit.shape[0])/3
bruit.plot(x="gx", y="price", kind="scatter")
```

[13]: <matplotlib.axes._subplots.AxesSubplot at 0x155423c30f0>

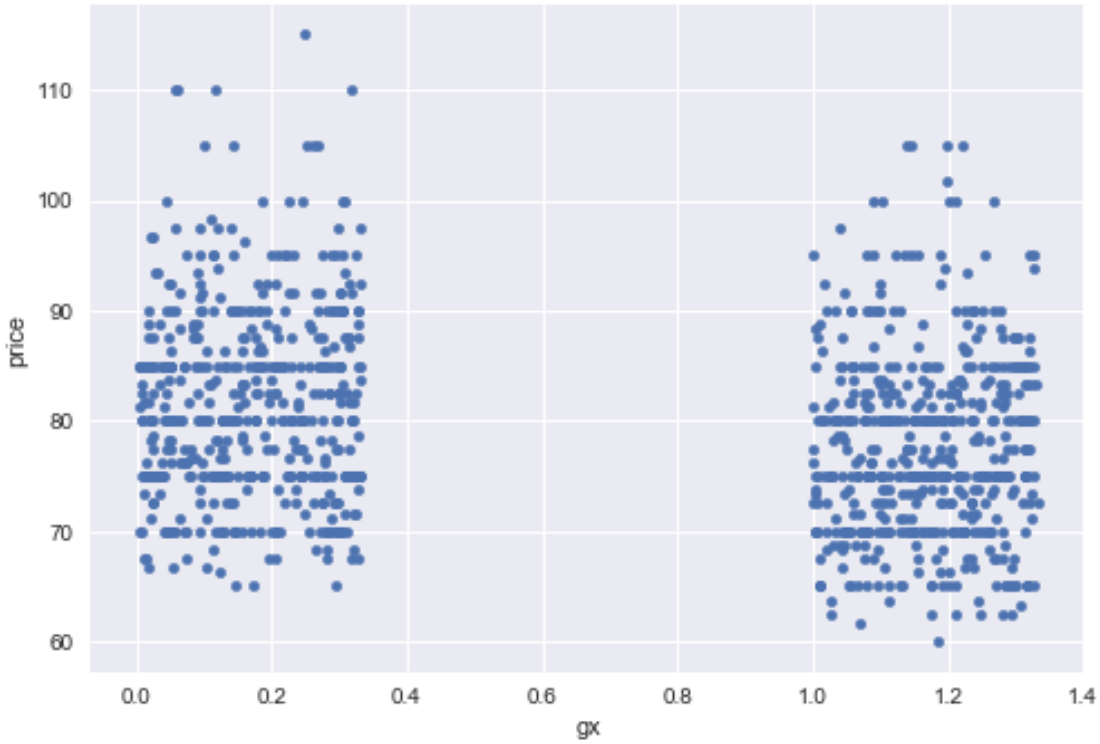

Il n'y a rien de flagrant. On peut faire un graphe moustache.

[14]:
```
join[["price", "gender"]].boxplot(by="gender")
```

[14]:
```
<matplotlib.axes._subplots.AxesSubplot at 0x1554245a278>
```

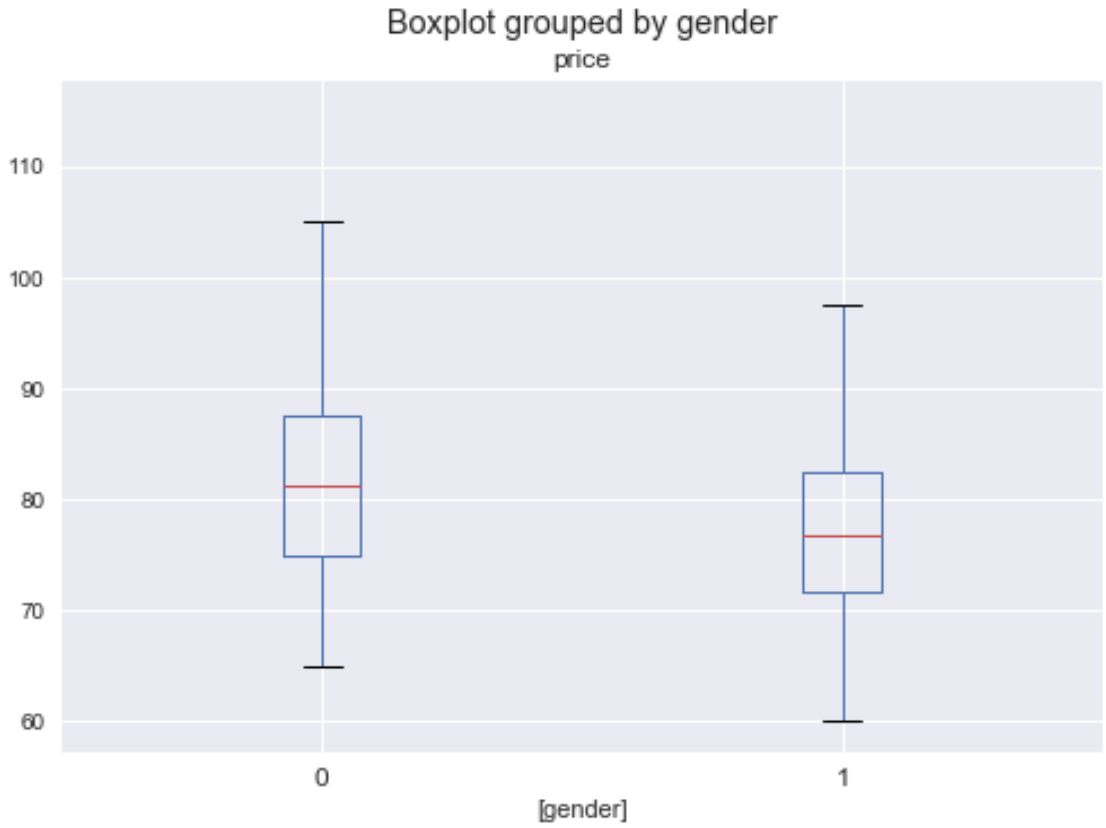

C'est mieux. Un dernier. Le diagramme violon, plus complet que le précédent.

[15]:
```
seaborn.violinplot(x="gender", y="price", data=join, inner="quart")
```

[15]:
```
<matplotlib.axes._subplots.AxesSubplot at 0x15542484d30>
```

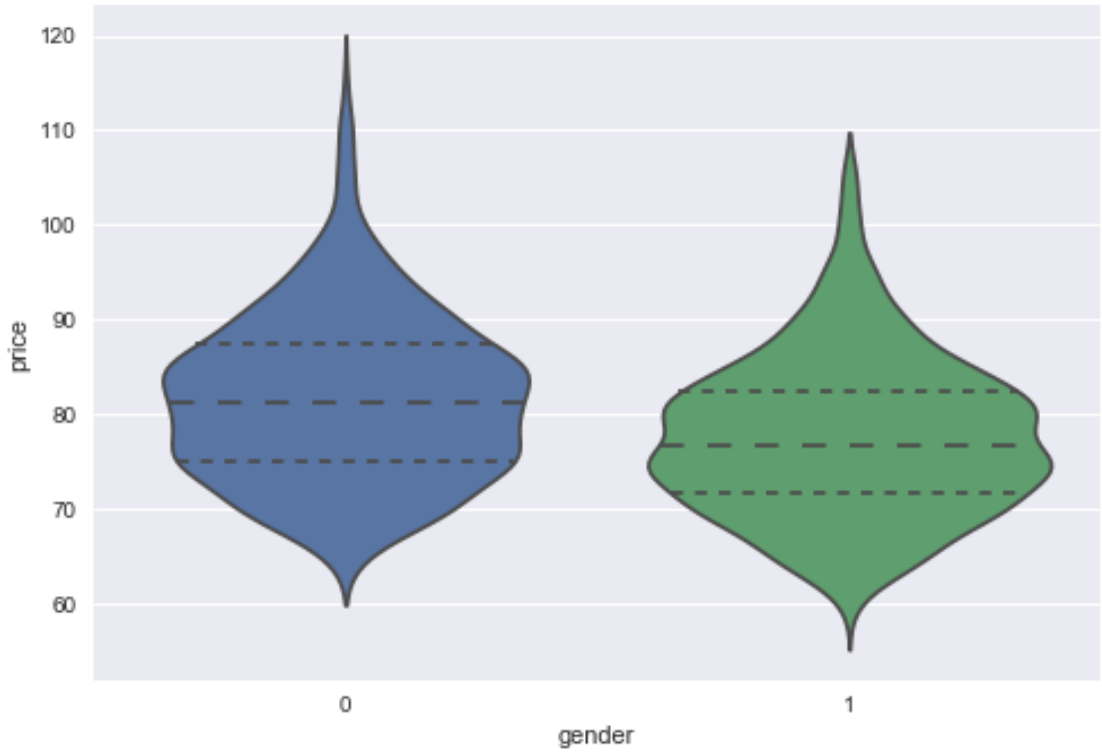

1.5 5

Calculer les coefficients de la régression prix_moyen ∼ age + genre.
Une régression. Le premier réflexe est scikit-learn.

[16]:
```
from sklearn.linear_model import LinearRegression
lr = LinearRegression()
lr.fit(join[["age", "gender"]], join["price"])
```

[16]:
```
LinearRegression(copy_X=True, fit_intercept=True, n_jobs=1, normalize=False)
```

[17]:
```
lr.coef_
```

[17]:
```
array([ 0.52440734, -4.36373925])
```

[18]:
```
lr.intercept_
```

[18]:
```
61.050576719028669
```

On utilise maintenant statsmodels qui est plus complet pour toute ce qui est un modèle linéaire.

[19]:
```
from statsmodels.formula.api import ols
lr = ols("price ~ age + gender", data=join)
res = lr.fit()
res.summary()
```

[19]:
```
<class 'statsmodels.iolib.summary.Summary'>
"""
                            OLS Regression Results
==============================================================================
Dep. Variable:                  price   R-squared:                       0.579
Model:                            OLS   Adj. R-squared:                  0.579
Method:                 Least Squares   F-statistic:                     686.6
Date:                Sun, 12 Mar 2017   Prob (F-statistic):          3.25e-188
Time:                        13:20:20   Log-Likelihood:                -3149.8
No. Observations:                1000   AIC:                             6306.
Df Residuals:                     997   BIC:                             6320.
Df Model:                           2
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
Intercept     61.0506      0.640     95.432      0.000      59.795      62.306
age            0.5244      0.015     35.302      0.000       0.495       0.554
gender        -4.3637      0.358    -12.194      0.000      -5.066      -3.662
==============================================================================
Omnibus:                      300.096   Durbin-Watson:                   1.999
Prob(Omnibus):                  0.000   Jarque-Bera (JB):              719.506
Skew:                           1.618   Prob(JB):                    5.77e-157
Kurtosis:                       5.608   Cond. No.                         151.
==============================================================================

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

Ou encore (après avoir ajouté une constante).

[20]:
```
from statsmodels.api import OLS
join2 = join.copy()
join2["cst"] = 1
lr = OLS(join2["price"], join2[["age", "gender", "cst"]])
res = lr.fit()
res.summary()
```

[20]:
```
<class 'statsmodels.iolib.summary.Summary'>
"""
                            OLS Regression Results
==============================================================================
Dep. Variable:                  price   R-squared:                       0.579
Model:                            OLS   Adj. R-squared:                  0.579
Method:                 Least Squares   F-statistic:                     686.6
Date:                Sun, 12 Mar 2017   Prob (F-statistic):          3.25e-188
Time:                        13:21:49   Log-Likelihood:                -3149.8
No. Observations:                1000   AIC:                             6306.
Df Residuals:                     997   BIC:                             6320.
Df Model:                           2
Covariance Type:            nonrobust
==============================================================================
```

```
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
age            0.5244      0.015     35.302      0.000       0.495       0.554
gender        -4.3637      0.358    -12.194      0.000      -5.066      -3.662
cst           61.0506      0.640     95.432      0.000      59.795      62.306
==============================================================================
Omnibus:                      300.096   Durbin-Watson:                   1.999
Prob(Omnibus):                  0.000   Jarque-Bera (JB):              719.506
Skew:                           1.618   Prob(JB):                    5.77e-157
Kurtosis:                       5.608   Cond. No.                        151.
==============================================================================

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

On peut aussi définir la régression sous la forme de formule avec le module patsy.

[21]:
```
from patsy import dmatrices
y, X = dmatrices("price ~ age + gender" , join, return_type="matrix")
y = numpy.ravel(y)
lr = LinearRegression(fit_intercept=False)
lr.fit(X, y)
```

[21]:
```
LinearRegression(copy_X=True, fit_intercept=False, n_jobs=1, normalize=False)
```

[22]:
```
lr.coef_, lr.intercept_
```

[22]:
```
(array([ 61.05057672,   0.52440734,  -4.36373925]), 0.0)
```

[23]:
```
X[:2]
```

[23]:
```
array([[  1.,  37.,   0.],
       [  1.,  41.,   0.]])
```

1.6 6

On souhaite étudier le prix d'une consultation en fonction du jour de la semaine. Ajouter une colonne dans la table de votre choix avec le jour de la semaine.
On convertit d'abord la colonne date (chaîne de caractères au format date) avec la fonction to_datetime.

[24]:
```
rend["date2"] = pandas.to_datetime(rend.date)
rend.dtypes
```

[24]:
```
date             object
idc              object
idr              object
price           float64
date2    datetime64[ns]
dtype: object
```

Et on récupère le jour de la semaine avec weekday.

[25]:
```
rend["weekday"] = rend.date2.dt.weekday
rend.head()
```

[25]:
```
                        date                                   idc  \
0  2016-12-02 19:47:45.068274  4ba0b473-f8ca-4466-a65b-40e9b8ba5029
1  2016-12-02 19:47:45.068274  4ba0b473-f8ca-4466-a65b-40e9b8ba5029
2  2016-12-07 19:47:45.068274  f44b004b-b01e-4835-b86d-1a42846c6d93
3  2016-12-17 19:47:45.068274  f44b004b-b01e-4835-b86d-1a42846c6d93
4  2017-01-07 19:47:45.068274  f44b004b-b01e-4835-b86d-1a42846c6d93

                                    idr  price                      date2  \
0  b7db0ac9-86a1-46f9-98ac-f1f8eb54072d   75.0 2016-12-02 19:47:45.068274
1  a65f721a-de11-4a01-be71-b26e2da3ac00   65.0 2016-12-02 19:47:45.068274
2  644b1236-b9ee-4ef5-8ca7-d1adadb547c8   75.0 2016-12-07 19:47:45.068274
3  aff6ac9e-5dd0-434e-9888-f724f6d40969   80.0 2016-12-17 19:47:45.068274
4  9ca87507-aa95-49a9-88b3-86ec9fbc44d6   80.0 2017-01-07 19:47:45.068274

   weekday
0        4
1        4
2        2
3        5
4        5
```

1.7 7

Créer un graphe moustache qui permet de vérifier cette hypothèse.
On réutilise le code d'une question précédente.

[26]:
```
rend[["price", "weekday"]].boxplot(by="weekday")
```

[26]:
```
<matplotlib.axes._subplots.AxesSubplot at 0x15543091668>
```

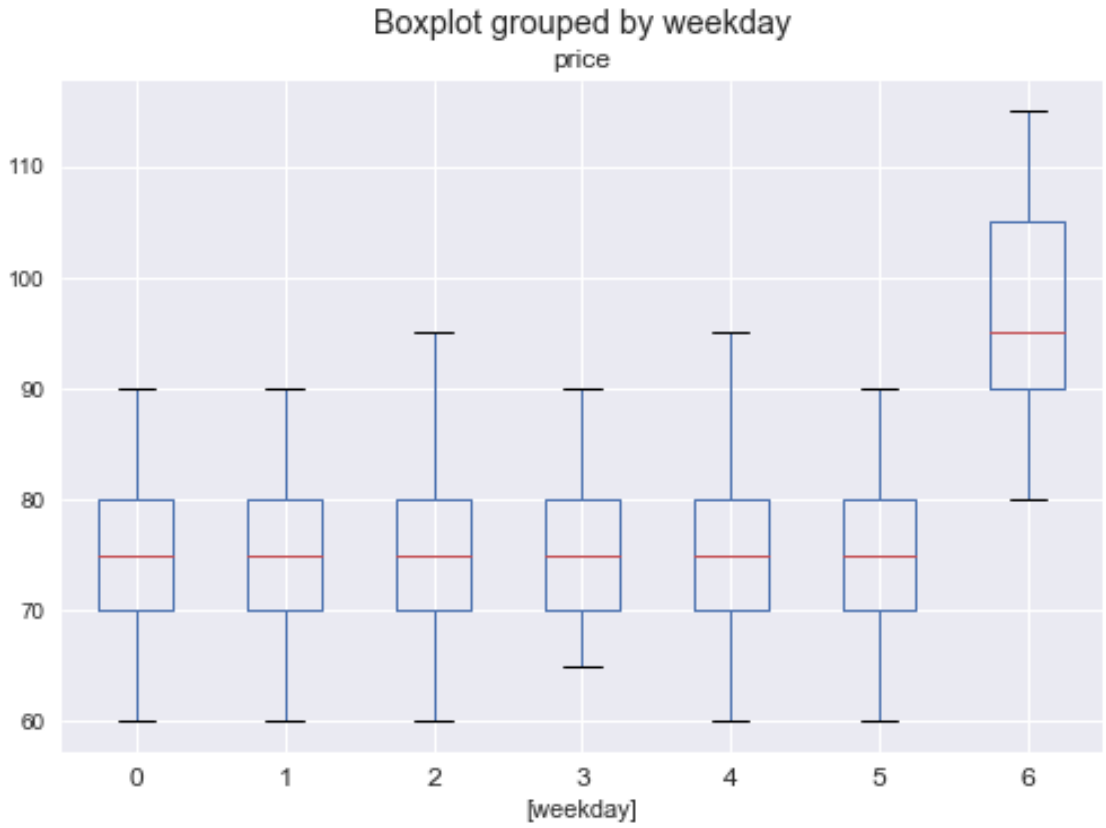

C'est clairement plus cher le dimanche.

1.8 8

Ajouter une colonne dans la table de votre choix qui contient 365 si c'est le premier rendez-vous, le nombre de jour écoulés depuis le précédent rendez-vous. On appelle cette colonne delay. On ajoute également la colonne $1/delay$.
Pour commencer, on convertit la date en nombre de jours depuis la première date.

[27]:
```
rend["constant"] = rend["date2"].min()
rend["jour"] = rend["date2"] - rend["constant"]
rend.head(n=2)
```

[27]:
```
                        date                                   idc  \
0  2016-12-02 19:47:45.068274  4ba0b473-f8ca-4466-a65b-40e9b8ba5029
1  2016-12-02 19:47:45.068274  4ba0b473-f8ca-4466-a65b-40e9b8ba5029

                                    idr  price                      date2  \
0  b7db0ac9-86a1-46f9-98ac-f1f8eb54072d   75.0 2016-12-02 19:47:45.068274
1  a65f721a-de11-4a01-be71-b26e2da3ac00   65.0 2016-12-02 19:47:45.068274

   weekday                   constant    jour
0        4 2016-11-18 19:47:45.068274 14 days
1        4 2016-11-18 19:47:45.068274 14 days
```

On convertit en entier.

[28]:
```
rend["jouri"] = rend.jour.apply(lambda d: d.days)
rend.head(n=2)
```

[28]:
```
                        date                                   idc  \
0  2016-12-02 19:47:45.068274  4ba0b473-f8ca-4466-a65b-40e9b8ba5029
1  2016-12-02 19:47:45.068274  4ba0b473-f8ca-4466-a65b-40e9b8ba5029

                                   idr  price                      date2  \
0  b7db0ac9-86a1-46f9-98ac-f1f8eb54072d   75.0 2016-12-02 19:47:45.068274
1  a65f721a-de11-4a01-be71-b26e2da3ac00   65.0 2016-12-02 19:47:45.068274

   weekday                   constant    jour  jouri
0        4 2016-11-18 19:47:45.068274 14 days     14
1        4 2016-11-18 19:47:45.068274 14 days     14
```

On trie par patient et jour puis on effectue la différence.

[29]:
```
diff = rend.sort_values(["idc", "jouri"])["jouri"].diff()
rend["diff"] = diff
rend.head(n=2)
```

[29]:
```
                        date                                   idc  \
0  2016-12-02 19:47:45.068274  4ba0b473-f8ca-4466-a65b-40e9b8ba5029
1  2016-12-02 19:47:45.068274  4ba0b473-f8ca-4466-a65b-40e9b8ba5029

                                   idr  price                      date2  \
0  b7db0ac9-86a1-46f9-98ac-f1f8eb54072d   75.0 2016-12-02 19:47:45.068274
1  a65f721a-de11-4a01-be71-b26e2da3ac00   65.0 2016-12-02 19:47:45.068274

   weekday                   constant    jour  jouri  diff
0        4 2016-11-18 19:47:45.068274 14 days     14 -26.0
1        4 2016-11-18 19:47:45.068274 14 days     14   0.0
```

Il reste à traiter le premier jour ou plutôt le premier rendez-vous. On le récupère pour chaque patient.

[30]:
```
first = rend[["idc", "date"]].groupby("idc", as_index=False).min()
first["j365"] = 365
first.head(n=2)
```

[30]:
```
                                   idc                      date  j365
0  003b0195-2acb-4f46-b7fa-28cf266a8f60 2016-12-02 19:47:45.068274   365
1  009e689c-51a1-4cef-99ca-a4ba364eba8d 2016-11-26 19:47:45.068274   365
```

Puis on fait une jointure.

[31]:
```
tout = rend.merge(first, on=["idc", "date"], how="outer")
tout[["idc", "jouri", "date", "j365"]].head(n=5)
```

[31]:
```
                                   idc  jouri                      date  \
0  4ba0b473-f8ca-4466-a65b-40e9b8ba5029     14 2016-12-02 19:47:45.068274
1  4ba0b473-f8ca-4466-a65b-40e9b8ba5029     14 2016-12-02 19:47:45.068274
2  f44b004b-b01e-4835-b86d-1a42846c6d93     19 2016-12-07 19:47:45.068274
3  f44b004b-b01e-4835-b86d-1a42846c6d93     29 2016-12-17 19:47:45.068274
4  f44b004b-b01e-4835-b86d-1a42846c6d93     50 2017-01-07 19:47:45.068274

    j365
```

```
0  365.0
1  365.0
2  365.0
3    NaN
4    NaN
```

Il ne reste plus qu'à remplacer les NaN par *jouri*.

[32]:
```
tout["delay"] = tout.j365.fillna(tout.jouri)
tout[["idc", "jouri", "date", "j365", "delay"]].head(n=8)
```

[32]:
```
                                  idc  jouri                        date  \
0  4ba0b473-f8ca-4466-a65b-40e9b8ba5029     14  2016-12-02 19:47:45.068274
1  4ba0b473-f8ca-4466-a65b-40e9b8ba5029     14  2016-12-02 19:47:45.068274
2  f44b004b-b01e-4835-b86d-1a42846c6d93     19  2016-12-07 19:47:45.068274
3  f44b004b-b01e-4835-b86d-1a42846c6d93     29  2016-12-17 19:47:45.068274
4  f44b004b-b01e-4835-b86d-1a42846c6d93     50  2017-01-07 19:47:45.068274
5  304895f0-f686-4b0e-8854-a705bb5a6982      1  2016-11-19 19:47:45.068274
6  3f0d31d2-0ef4-4e7e-b876-07d10225cc8c     30  2016-12-18 19:47:45.068274
7  f29273f4-a76c-4158-b5f5-b3e5a080a0c7      2  2016-11-20 19:47:45.068274

    j365  delay
0  365.0  365.0
1  365.0  365.0
2  365.0  365.0
3    NaN   29.0
4    NaN   50.0
5  365.0  365.0
6  365.0  365.0
7  365.0  365.0
```

Finalement, il faut ajouter une colonne $1/delay$. Comme des patients ont parfois deux rendez-vous le même jour, pour éviter les valeurs nulles, on ajoute la colonne $1/(1 + delay)$. On aurait pu également pour éviter les valeurs nulles considérer le temps en secondes et non en jour entre deux rendez-vous.

[33]:
```
tout["delay1"] = 1/ (tout["delay"] + 1)
tout[["delay", "delay1"]].head()
```

[33]:
```
   delay    delay1
0  365.0  0.002732
1  365.0  0.002732
2  365.0  0.002732
3   29.0  0.033333
4   50.0  0.019608
```

1.9 8 - réponse plus courte

On garde l'idée de la fonction diff et on ajoute la fonction shift.

[34]:
```
rend2 = rend.sort_values(["idc", "jouri"]).reset_index(drop=True).copy()
rend2["diff"] = rend2["jouri"].diff()
rend2.loc[rend2.idc != rend2.idc.shift(1), "diff"] = 365
rend2.head()
```

[34]:
```
                        date                                   idc  \
0  2016-12-02 19:47:45.068274  003b0195-2acb-4f46-b7fa-28cf266a8f60
1  2016-11-26 19:47:45.068274  009e689c-51a1-4cef-99ca-a4ba364eba8d
2  2016-12-20 19:47:45.068274  009e689c-51a1-4cef-99ca-a4ba364eba8d
3  2017-01-12 19:47:45.068274  009e689c-51a1-4cef-99ca-a4ba364eba8d
4  2016-12-02 19:47:45.068274  00a213c2-1174-4359-8a67-fe710ec1b439

                                    idr  price                      date2  \
0  6d65b2b5-f34d-4440-8442-679175554db4   80.0 2016-12-02 19:47:45.068274
1  065474ed-6ba3-4ee1-aa83-b89e97d5a2aa   80.0 2016-11-26 19:47:45.068274
2  38a02a6a-8c04-4630-aaa6-2077077a9f87   80.0 2016-12-20 19:47:45.068274
3  f4cf0df4-0b6a-4b0f-93c7-d12499026fab   80.0 2017-01-12 19:47:45.068274
4  c1b3381b-9663-429d-a8fb-3b24c20a125b   70.0 2016-12-02 19:47:45.068274

   weekday                   constant    jour  jouri   diff
0        4 2016-11-18 19:47:45.068274 14 days     14  365.0
1        5 2016-11-18 19:47:45.068274  8 days      8  365.0
2        1 2016-11-18 19:47:45.068274 32 days     32   24.0
3        3 2016-11-18 19:47:45.068274 55 days     55   23.0
4        4 2016-11-18 19:47:45.068274 14 days     14  365.0
```

1.10 9

Calculer les coefficients de la régression prix $\sim age + genre + delay + 1/delay + jour\_semaine$.
L'âge ne fait pas partie de la table *tout*. Il faut faire une jointure pour le récupérer.

[35]:
```
mat = tout.merge(persons, on="idc")
```

Ensuite retour à scikit-learn et plutôt le second statsmodels pour effectuer des tests sur les coefficients du modèle. On regarde d'abord les corrélations.

[36]:
```
mat[["age", "gender", "delay", "delay1", "weekday", "price"]].corr()
```

[36]:
```
              age    gender     delay    delay1   weekday     price
age      1.000000  0.030852 -0.010694 -0.023011  0.032413  0.614708
gender   0.030852  1.000000  0.008700 -0.026779 -0.000064 -0.198835
delay   -0.010694  0.008700  1.000000 -0.616038  0.039766  0.049796
delay1  -0.023011 -0.026779 -0.616038  1.000000  0.025400 -0.054954
weekday  0.032413 -0.000064  0.039766  0.025400  1.000000  0.448584
price    0.614708 -0.198835  0.049796 -0.054954  0.448584  1.000000
```

[37]:
```
seaborn.clustermap(mat[["age", "gender", "delay", "delay1", "weekday", "price"]].
↪corr(), figsize=(5,5))
```

```
c:\python36_x64\lib\site-packages\matplotlib\cbook.py:136:
MatplotlibDeprecationWarning: The axisbg attribute was deprecated in version
2.0. Use facecolor instead.
  warnings.warn(message, mplDeprecation, stacklevel=1)
```

[37]:
```
<seaborn.matrix.ClusterGrid at 0x155431c4550>
```

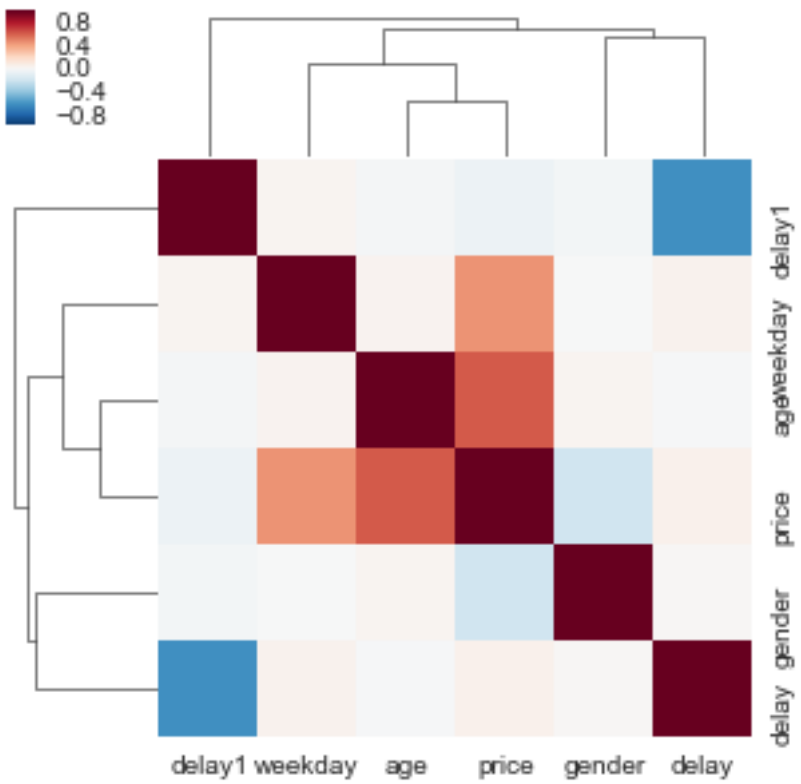

Si le jeu de données n'est pas trop volumineux.

[38]:
```
seaborn.pairplot(mat[["age", "gender", "delay", "delay1", "weekday", "price"]],
                 plot_kws={"s": 10}, size=1)
```

[38]: <seaborn.axisgrid.PairGrid at 0x155443f3b00>

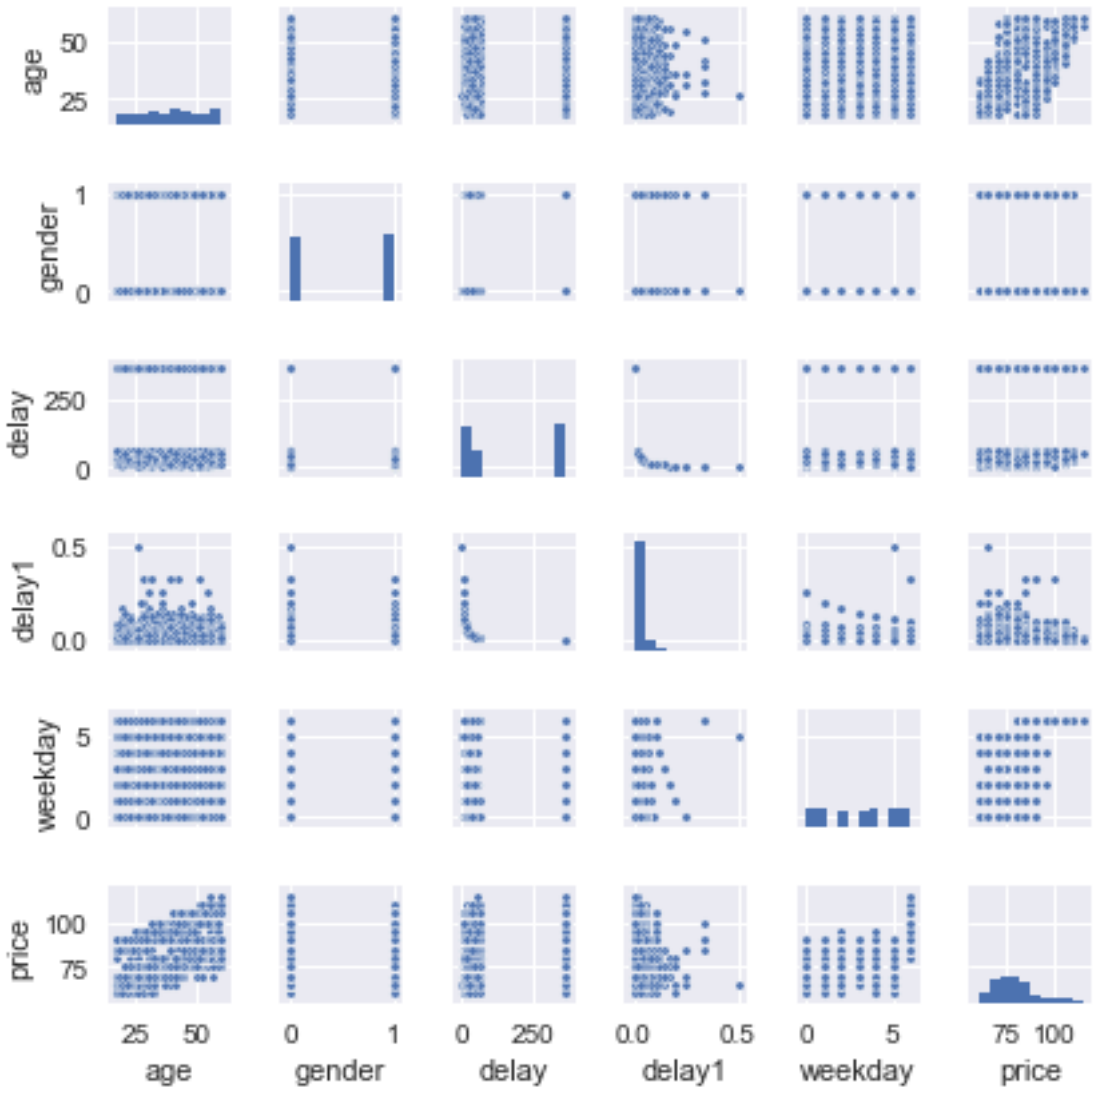

Un dernier pour la route.

[39]:
```
feat = mat[["age", "gender", "delay", "delay1", "weekday", "price"]]
g = seaborn.PairGrid(feat.sort_values("price", ascending=False), x_vars=feat.columns[:
 ↪-1],
                     y_vars=["price"], size=5, aspect=.25)
g.map(seaborn.stripplot, size=3, orient="h", palette="Reds_r", edgecolor="gray")
```

[39]:
```
<seaborn.axisgrid.PairGrid at 0x15545712f60>
```

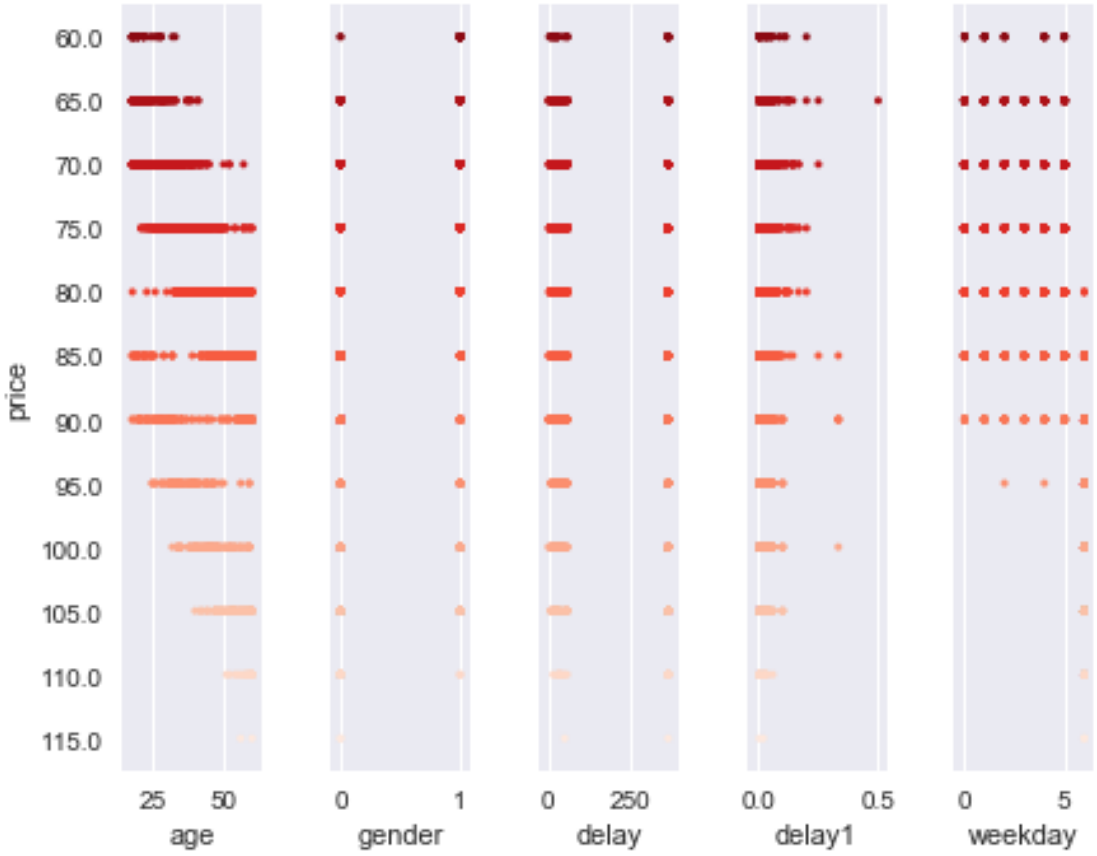

Régression

[40]:
```
lr = LinearRegression()
lr.fit(mat[["age", "gender", "delay", "delay1", "weekday"]], mat["price"])
lr.coef_
```

[40]:
```
array([  5.08109837e-01,  -4.41245429e+00,   5.42852787e-04,
        -1.60797483e+01,   2.12155016e+00])
```

[41]:
```
from statsmodels.formula.api import ols
lr = ols("price ~ age + gender + delay + delay1 + weekday", data=mat)
res = lr.fit()
res.summary()
```

[41]:
```
<class 'statsmodels.iolib.summary.Summary'>
"""
                            OLS Regression Results
==============================================================================
Dep. Variable:                  price   R-squared:                       0.612
Model:                            OLS   Adj. R-squared:                  0.612
Method:                 Least Squares   F-statistic:                     800.0
Date:                Sun, 12 Mar 2017   Prob (F-statistic):               0.00
Time:                        13:24:17   Log-Likelihood:                -8257.2
No. Observations:                2537   AIC:                         1.653e+04
```

```
Df Residuals:                     2531   BIC:                         1.656e+04
Df Model:                            5
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
Intercept     55.4146      0.545    101.618      0.000      54.345      56.484
age            0.5081      0.010     48.918      0.000       0.488       0.528
gender        -4.4125      0.250    -17.683      0.000      -4.902      -3.923
delay          0.0005      0.001      0.562      0.574      -0.001       0.002
delay1       -16.0797      4.842     -3.321      0.001     -25.575      -6.585
weekday        2.1216      0.061     34.623      0.000       2.001       2.242
==============================================================================
Omnibus:                       55.147   Durbin-Watson:                   1.969
Prob(Omnibus):                  0.000   Jarque-Bera (JB):               57.558
Skew:                           0.358   Prob(JB):                     3.17e-13
Kurtosis:                       2.823   Cond. No.                     9.20e+03
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly
specified.
[2] The condition number is large, 9.2e+03. This might indicate that there are
strong multicollinearity or other numerical problems.
"""
```

1.11 10

Comment comparer ce modèle avec le précédent ? Implémentez le calcul qui vous permet de répondre à cette question.

Nous pourrions comparer les coefficients R^2 (0.57, 0.61) des régressions pour savoir quelle est la meilleur excepté que celle-ci ne sont pas calculées sur les mêmes données. La comparaison n'a pas de sens et il serait dangeraux d'en tirer des conclusions. Les valeurs sont de plus très proches. Il faut comparer les prédictions. Dans le premier cas, on prédit le prix moyen. Dans le second, on prédit le prix d'une consultation. Il est alors possible de calculer une prédiction moyenne par patient et de comparer les erreurs de prédiction du prix moyen. D'un côté, la prédiction du prix moyen, de l'autre la prédiction du prix d'une consultation agrégé par patient.

[42]:
```
lr_moy = LinearRegression()
lr_moy.fit(join[["age", "gender"]], join["price"])
lr_moy.coef_, lr_moy.intercept_
```

[42]:
```
(array([ 0.52440734, -4.36373925]), 61.050576719028669)
```

[43]:
```
pred_moy = lr_moy.predict(join[["age", "gender"]])
join["pred_moy"] = pred_moy
join.head()
```

[43]:

	age	gender	idc	name	price	\
0	37	0	4ba0b473-f8ca-4466-a65b-40e9b8ba5029	Cendrillon	70.000000	
1	41	0	f44b004b-b01e-4835-b86d-1a42846c6d93	Cendrillon	78.333333	
2	46	1	304895f0-f686-4b0e-8854-a705bb5a6982	Balthazar	75.000000	
3	42	1	3f0d31d2-0ef4-4e7e-b876-07d10225cc8c	Balthazar	95.000000	
4	41	1	f29273f4-a76c-4158-b5f5-b3e5a080a0c7	Balthazar	90.000000	

```
   pred_moy
0  80.453648
1  82.551278
2  80.809575
3  78.711946
4  78.187538
```

On calcule l'erreur.

[44]:
```
err1 = ((join.pred_moy - join.price)**2).sum() / join.shape[0]
err1
```

[44]:
```
31.87444884457175
```

[45]:
```
join.plot(x="price", y="pred_moy", kind="scatter")
```

[45]:
```
<matplotlib.axes._subplots.AxesSubplot at 0x15546b180f0>
```

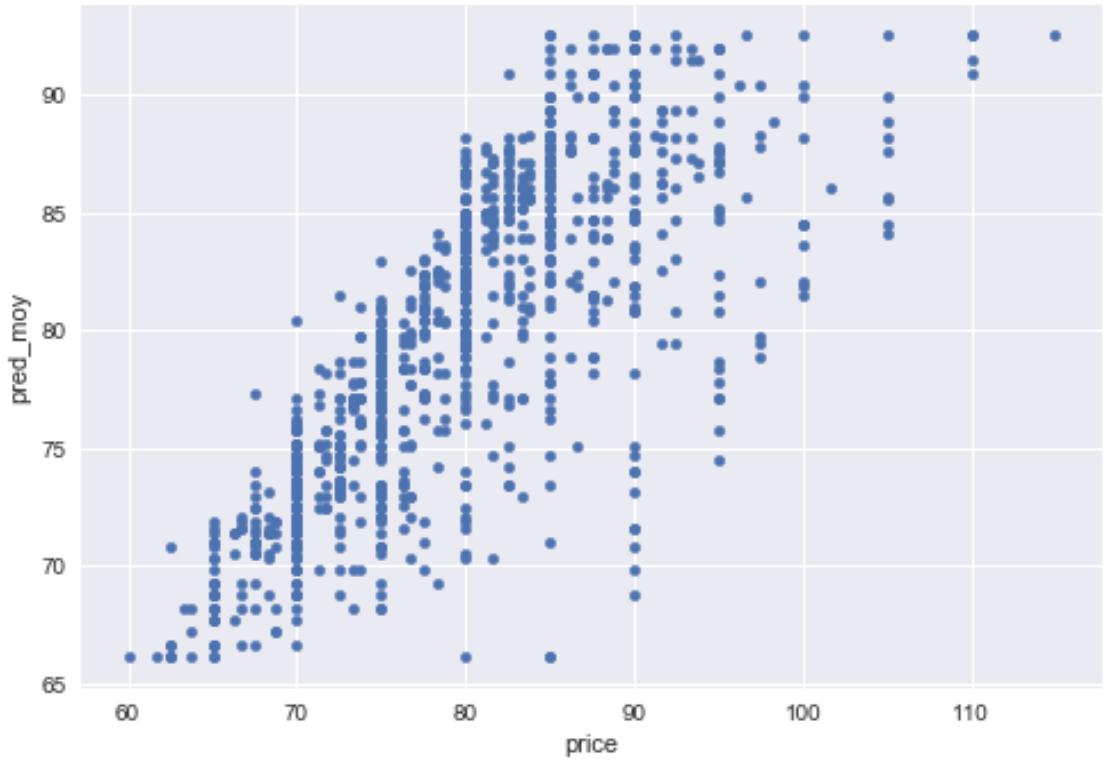

[46]:
```
lrc = LinearRegression()
feat = mat[["age", "gender", "delay", "delay1", "weekday", "price", "idc"]].copy()
lrc.fit(feat[["age", "gender", "delay", "delay1", "weekday"]], feat["price"])
lrc.coef_, lrc.intercept_
```

[46]:
```
(array([  5.08109837e-01,  -4.41245429e+00,   5.42852787e-04,
         -1.60797483e+01,   2.12155016e+00]), 55.414609503334248)
```

[47]:
```
predc = lrc.predict(feat[["age", "gender", "delay", "delay1", "weekday"]])
feat["predc"] = predc
feat.head()
```

[47]:

	age	gender	delay	delay1	weekday	price	\
0	37	0	365.0	0.002732	4	75.0	
1	37	0	365.0	0.002732	4	65.0	
2	41	0	365.0	0.002732	2	75.0	
3	41	0	29.0	0.033333	5	80.0	
4	41	0	50.0	0.019608	5	80.0	

	idc	predc
0	4ba0b473-f8ca-4466-a65b-40e9b8ba5029	82.855082
1	4ba0b473-f8ca-4466-a65b-40e9b8ba5029	82.855082
2	f44b004b-b01e-4835-b86d-1a42846c6d93	80.644421
3	f44b004b-b01e-4835-b86d-1a42846c6d93	86.334615
4	f44b004b-b01e-4835-b86d-1a42846c6d93	86.566717

On agrège les secondes prédictions.

[48]:
```
agg = feat[["idc","predc", "price"]].groupby("idc").mean()
agg.head()
```

[48]:

idc	predc	price
003b0195-2acb-4f46-b7fa-28cf266a8f60	85.048055	80.0
009e689c-51a1-4cef-99ca-a4ba364eba8d	83.945104	80.0
00a213c2-1174-4359-8a67-fe710ec1b439	72.345309	70.0
00e42818-aade-4758-a5f6-c78a6f235ea5	65.277461	70.0
0153b785-9acd-4d28-aad1-62f8bf2faea3	79.298313	75.0

[49]:
```
err2 = ((agg.predc - agg.price)**2).sum() / agg.shape[0]
err2
```

[49]:
```
20.6978360564799
```

Le second modèle est clairement meilleur.

[50]:
```
agg.plot(x="price", y="predc", kind="scatter")
```

[50]:
```
<matplotlib.axes._subplots.AxesSubplot at 0x15546b3a080>
```

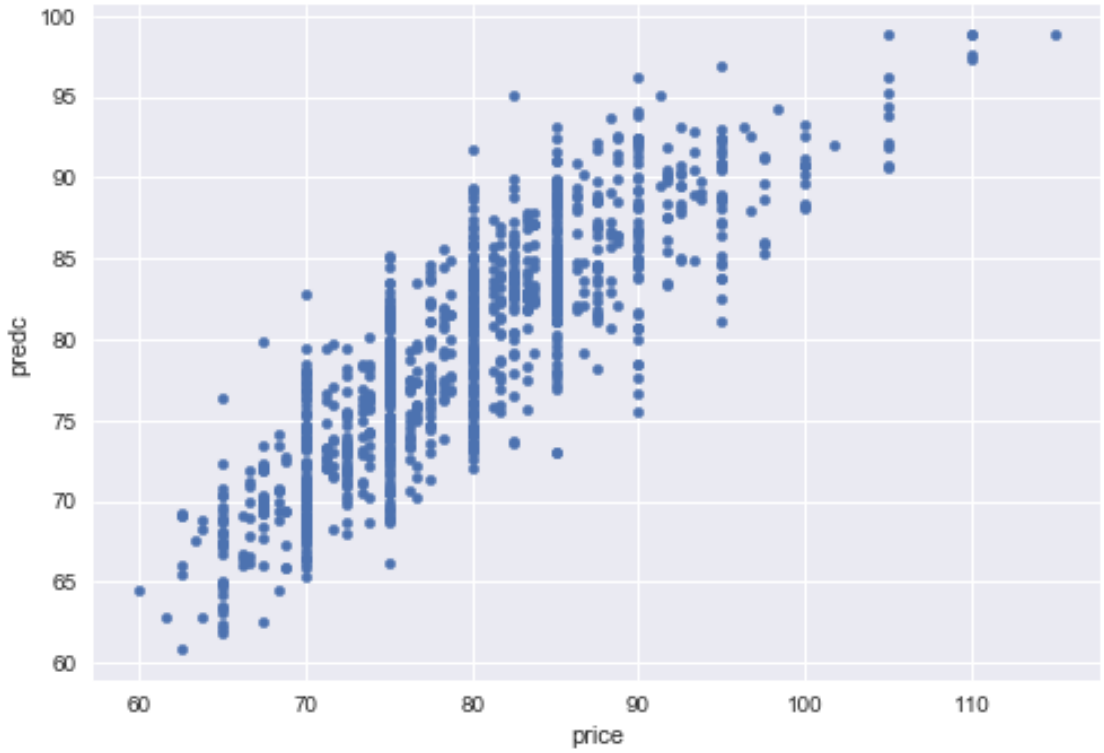

La seconde régression utilise une information dont on ne dispose pas au niveau agrégé : le jour de la semaine et un précédent graphe a clairement montré que c'était une variable importante. Un dernier graphe pour comparer les deux prédictions en montrant les prédictions triées par prix à prédire.

[51]:
```
temp = join.sort_values("price").reset_index(drop=True).reset_index(drop=False)
temp.head(n=1)
```

[51]:
```
   index  age  gender                                   idc       name  price  \
0      0   18       1  6423a722-4769-4a7c-8d1d-266538c2a07a  Balthazar   60.0

   pred_moy
0  66.12617
```

[52]:
```
temp.plot(x="index", y=["price", "pred_moy"])
```

[52]:
```
<matplotlib.axes._subplots.AxesSubplot at 0x15546be2080>
```

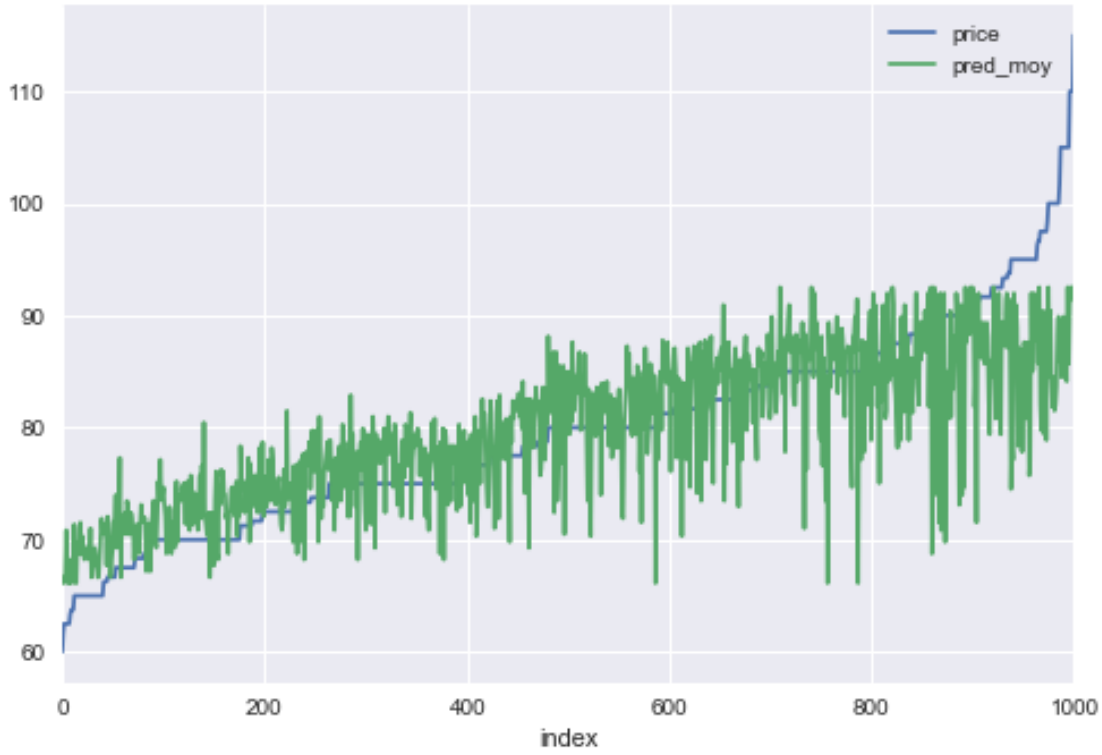

[53]:
```
temp2 = agg.sort_values("price").reset_index(drop=True).reset_index(drop=False)
temp2.head(n=1)
```

[53]:

	index	predc	price
0	0	64.54544	60.0

[54]:
```
ax = temp.plot(x="index", y="price", figsize=(14,4), ylim=[60,120])
temp.plot(x="index", y="pred_moy", linewidth=1, ax=ax, ylim=[60,120])
temp2.plot(x="index", y="predc", ax=ax, linewidth=0.6, ylim=[60,120])
```

[54]:
```
<matplotlib.axes._subplots.AxesSubplot at 0x15546c495c0>
```

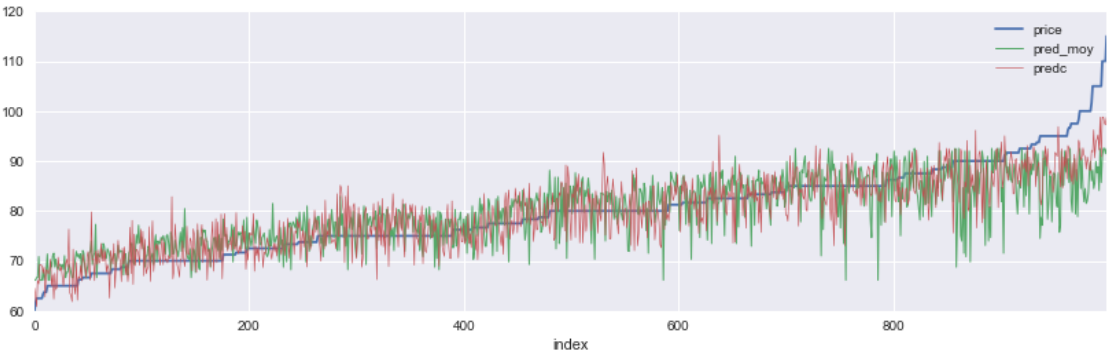

C'est finalement un peu plus visible sur le graphe précédent (nuage de points) mais aussi un peu trompeur du fait de la superposition des points. Une dernière remarque. En machine learning, nous avons l'habitude d'apprendre un modèle sur une base d'apprentissage et de tester les prédictions sur une autre. Dans notre cas, nous avons appris et prédit sur la même base. Ce type de tester est évidemment plus fiable. Mais nous avons comparé ici deux erreurs d'apprentissage moyennes et c'est exactement ce que l'on fait lorsqu'on compare deux coefficients R^2.
Un dernier graphe pour la route obtenu en triant les erreurs par ordre croissant.

[55]:
```
temp["erreur"] = temp.pred_moy - temp.price
temp2["erreur2"] = temp2.predc - temp2.price
ax = temp[["erreur"]].sort_values("erreur").reset_index(drop=True).plot()
temp2[["erreur2"]].sort_values("erreur2").reset_index(drop=True).plot(ax=ax)
ax.plot([0,1000], [0,0], "r--")
```

[55]:
```
[<matplotlib.lines.Line2D at 0x15546db5b38>]
```

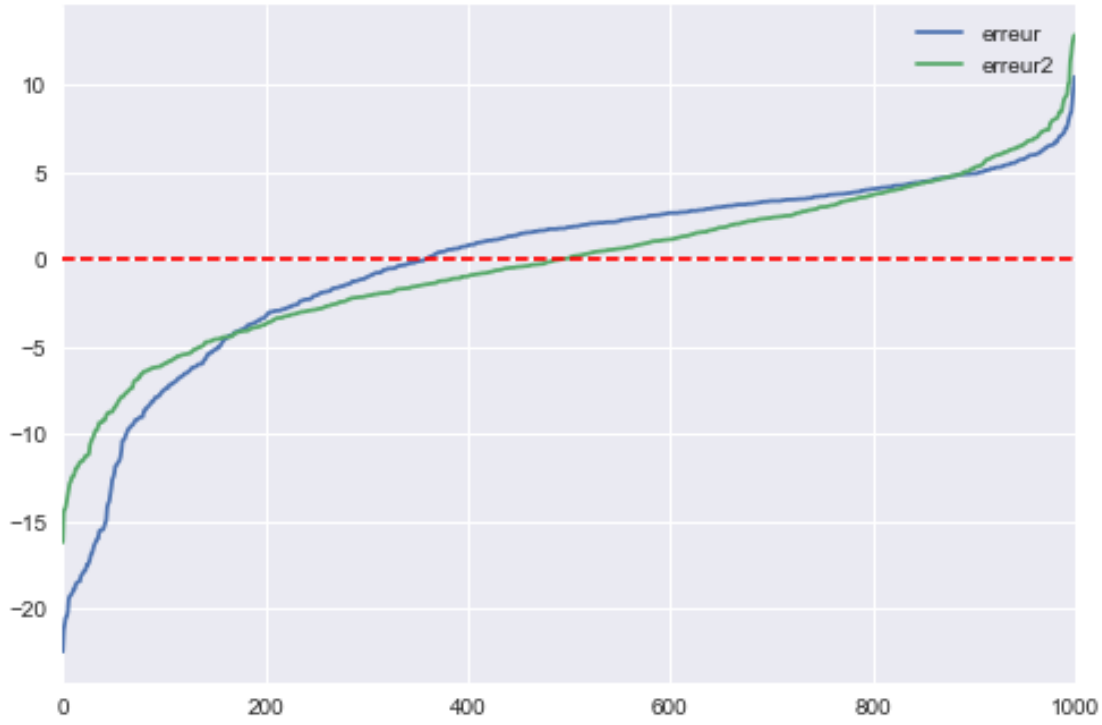

Le second modèle fait des erreurs moins importantes surtout côté négatif. Il sous-estime moins la bonne valeur.

1.12 Traitement spécifique de la variable catégorielle weekday

Le second modèle ne prend pas en compte le dimanche comme jour de la semaine. *weekday* est une variable catégorielle. Contrairment au genre, elle possède plus de deux modalités. Il serait intéressant de la traiter comme un ensemble de variable binaire et non une colonne de type entier.

[56]:
```
dummies = pandas.get_dummies(mat.weekday)
dummies.columns=["lu", "ma", "me", "je", "ve", "sa", "di"]
dummies.head()
```

[56]:
```
   lu  ma  me  je  ve  sa  di
0   0   0   0   0   1   0   0
1   0   0   0   0   1   0   0
2   0   0   1   0   0   0   0
3   0   0   0   0   0   1   0
4   0   0   0   0   0   1   0
```

On supprime une modalité pour éviter d'avoir une matrice corrélée avec la constante et on ajoute des variables au modèle de régression.

[57]:
```
mat2 = pandas.concat([mat, dummies.drop("lu", axis=1)], axis=1)
mat2.head(n=1)
```

[57]:
```
                        date                                   idc  \
0  2016-12-02 19:47:45.068274  4ba0b473-f8ca-4466-a65b-40e9b8ba5029

                                    idr  price                      date2  \
0  b7db0ac9-86a1-46f9-98ac-f1f8eb54072d   75.0 2016-12-02 19:47:45.068274

   weekday                   constant    jour  jouri  diff …    delay1  age  \
0        4 2016-11-18 19:47:45.068274 14 days     14 -26.0 …  0.002732   37

   gender        name  ma me  je  ve  sa  di
0       0  Cendrillon   0  0   0   1   0   0

[1 rows x 22 columns]
```

[58]:
```
lr = ols("price ~ age + gender + delay + delay1 + ma + me + je + ve + sa + di",␣
 ↪data=mat2)
res = lr.fit()
res.summary()
```

[58]:
```
<class 'statsmodels.iolib.summary.Summary'>
"""
                            OLS Regression Results
==============================================================================
Dep. Variable:                  price   R-squared:                       0.918
Model:                            OLS   Adj. R-squared:                  0.917
Method:                 Least Squares   F-statistic:                     2812.
Date:                Sun, 12 Mar 2017   Prob (F-statistic):               0.00
Time:                        13:50:22   Log-Likelihood:                -6293.7
No. Observations:                2537   AIC:                         1.261e+04
Df Residuals:                    2526   BIC:                         1.267e+04
Df Model:                          10
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
Intercept     59.0371      0.272    217.342      0.000      58.504      59.570
age            0.5005      0.005    104.318      0.000       0.491       0.510
gender        -4.0722      0.115    -35.321      0.000      -4.298      -3.846
delay          0.0003      0.000      0.661      0.509      -0.001       0.001
delay1       -20.7385      2.236     -9.275      0.000     -25.123     -16.354
ma            -0.0840      0.208     -0.405      0.686      -0.491       0.323
```

```
me              0.3003      0.216      1.392      0.164      -0.123       0.723
je              0.1607      0.219      0.735      0.463      -0.268       0.590
ve             -0.1748      0.212     -0.825      0.409      -0.590       0.240
sa              0.1849      0.210      0.879      0.379      -0.227       0.597
di             20.0978      0.211     95.203      0.000      19.684      20.512
==============================================================================
Omnibus:                      257.849   Durbin-Watson:                   2.034
Prob(Omnibus):                  0.000   Jarque-Bera (JB):              484.437
Skew:                          -0.672   Prob(JB):                    6.40e-106
Kurtosis:                       4.666   Cond. No.                     9.20e+03
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly
specified.
[2] The condition number is large, 9.2e+03. This might indicate that there are
strong multicollinearity or other numerical problems.
"""
```

On vérifie que le coefficient pour dimanche n'est clairement significatif contrairement aux autres dont la probabilité d'être nul est élevée. Le médecin appliquerait une majoration de 20 euros le dimanche. Le coefficient R^2 est aussi nettement plus élevé. On construit les prédictions d'un second modèle en ne tenant compte que de la variable dimanche.

[59]:
```
lrc = LinearRegression()
feat2 = mat2[["age", "gender", "delay", "delay1", "price", "idc", "di"]].copy()
lrc.fit(feat2[["age", "gender", "delay", "delay1", "di"]], feat2["price"])
lrc.coef_, lrc.intercept_
```

[59]:
```
(array([  5.00892234e-01,  -4.07229120e+00,   2.97614199e-04,
         -2.07004497e+01,   2.00395644e+01]), 59.079512942729707)
```

[60]:
```
predc = lrc.predict(feat2[["age", "gender", "delay", "delay1", "di"]])
feat2["predc"] = predc
feat2.head()
```

[60]:
```
   age  gender  delay    delay1  price                                  idc  \
0   37       0  365.0  0.002732   75.0  4ba0b473-f8ca-4466-a65b-40e9b8ba5029
1   37       0  365.0  0.002732   65.0  4ba0b473-f8ca-4466-a65b-40e9b8ba5029
2   41       0  365.0  0.002732   75.0  f44b004b-b01e-4835-b86d-1a42846c6d93
3   41       0   29.0  0.033333   80.0  f44b004b-b01e-4835-b86d-1a42846c6d93
4   41       0   50.0  0.019608   80.0  f44b004b-b01e-4835-b86d-1a42846c6d93

   di      predc
0   0  77.664596
1   0  77.664596
2   0  79.668165
3   0  78.934710
4   0  79.225084
```

[61]:
```
agg2 = feat2[["idc","predc", "price"]].groupby("idc").mean()
agg2.head()
```

[61]:

idc	predc	price
003b0195-2acb-4f46-b7fa-28cf266a8f60	80.103904	80.0
009e689c-51a1-4cef-99ca-a4ba364eba8d	80.812446	80.0
00a213c2-1174-4359-8a67-fe710ec1b439	67.581598	70.0
00e42818-aade-4758-a5f6-c78a6f235ea5	66.890947	70.0
0153b785-9acd-4d28-aad1-62f8bf2faea3	74.158351	75.0

[62]:
```
err2d = ((agg2.predc - agg2.price)**2).sum() / agg2.shape[0]
err2d
```

[62]: 3.626505427547844

Nettement, nettement mieux.

[63]:
```
agg2.plot(x="price", y="predc", kind="scatter")
```

[63]: <matplotlib.axes._subplots.AxesSubplot at 0x155472d6438>

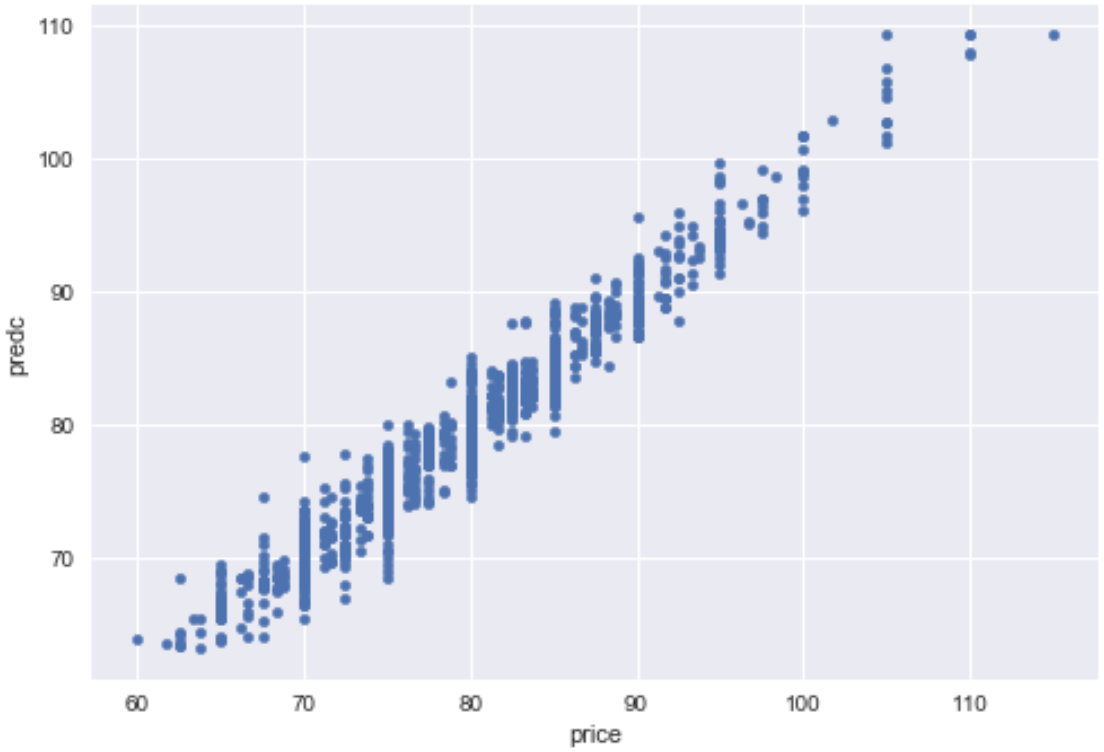

[64]:
```
temp2 = agg2.sort_values("price").reset_index(drop=True).reset_index(drop=False)
ax = temp2.plot(x="index", y="price", figsize=(14,4), ylim=[60,120])
temp2.plot(x="index", y="predc", linewidth=1, ax=ax, ylim=[60,120])
```

[64]: <matplotlib.axes._subplots.AxesSubplot at 0x15547424c18>

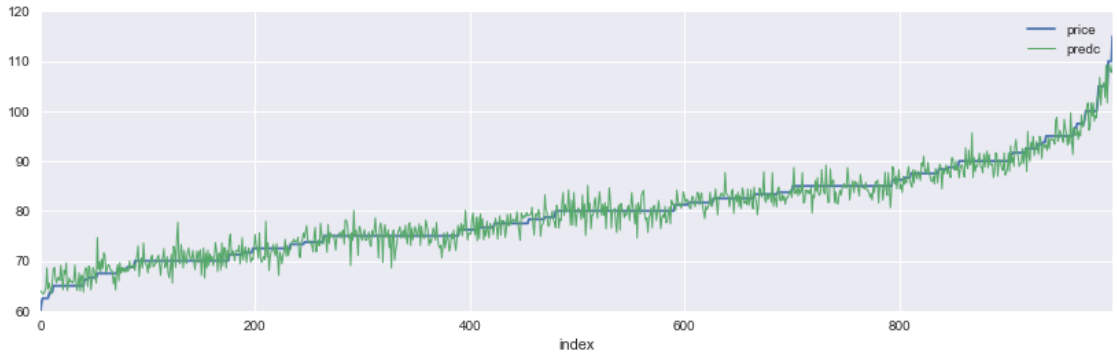

1.13 Une variable catégorielle en une seule colonne ?

Un jeu de données peut rapidement croître s'il est étendu pour chaque variable catégorielle. On peut utiliser le module category_encoders ou statsmodels.

[65]:
```
from category_encoders import PolynomialEncoder
encoder = PolynomialEncoder(cols=["weekday"])
encoder.fit(rend[["weekday"]], rend["price"])
pred = encoder.transform(rend[["weekday"]])
conc = pandas.concat([rend[["weekday"]], pred], axis=1)
conc.head()
```

[65]:

	weekday	col_weekday_0	col_weekday_1	col_weekday_2	col_weekday_3	\
0	4	1.0	0.188982	-3.273268e-01	-0.408248	
1	4	1.0	0.188982	-3.273268e-01	-0.408248	
2	2	1.0	-0.188982	-3.273268e-01	0.408248	
3	5	1.0	0.377964	5.551115e-17	-0.408248	
4	5	1.0	0.377964	5.551115e-17	-0.408248	

	col_weekday_4	col_weekday_5	col_weekday_6
0	0.080582	0.545545	0.493464
1	0.080582	0.545545	0.493464
2	0.080582	-0.545545	0.493464
3	-0.564076	-0.436436	-0.197386
4	-0.564076	-0.436436	-0.197386

Ou associer la valeur de la cible à prédire pour chaque jour de la semaine.

[66]:
```
copy = rend[["weekday", "price"]].copy()
gr = copy.groupby("weekday", as_index=False).mean()
gr
```

[66]:

	weekday	price
0	0	76.112532
1	1	76.195373
2	2	77.047478
3	3	76.677116
4	4	76.049724
5	5	76.630728
6	6	97.078804

[67]:
```
feat3 = mat[["age", "gender", "delay", "delay1", "price", "idc", "weekday"]]
feat3 = feat3.merge(gr, on="weekday", suffixes=("", "_label"))
feat3.head()
```

[67]:

	age	gender	delay	delay1	price	idc	weekday	price_label
0	37	0	365.0	0.002732	75.0	4ba0b473-f8ca-4466-a65b-40e9b8ba5029	4	76.049724
1	37	0	365.0	0.002732	65.0	4ba0b473-f8ca-4466-a65b-40e9b8ba5029	4	76.049724
2	57	1	365.0	0.002732	85.0	7ffb8a8b-a829-41f1-9572-2985ee9ba05e	4	76.049724
3	30	0	365.0	0.002732	75.0	0153b785-9acd-4d28-aad1-62f8bf2faea3	4	76.049724
4	28	1	28.0	0.034483	70.0	47e415f0-f4e9-40c5-a59d-adc4c0621c8a	4	76.049724

On apprend avec la variable *weekday* :

[68]:
```
lr = ols("price ~ age + gender + delay + delay1 + weekday", data=feat3)
res = lr.fit()
res.summary()
```

[68]:
```
<class 'statsmodels.iolib.summary.Summary'>
"""
                            OLS Regression Results
==============================================================================
Dep. Variable:                  price   R-squared:                       0.612
Model:                            OLS   Adj. R-squared:                  0.612
Method:                 Least Squares   F-statistic:                     800.0
Date:                Sun, 12 Mar 2017   Prob (F-statistic):               0.00
Time:                        18:57:20   Log-Likelihood:                -8257.2
No. Observations:                2537   AIC:                         1.653e+04
Df Residuals:                    2531   BIC:                         1.656e+04
Df Model:                           5
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
Intercept     55.4146      0.545    101.618      0.000      54.345      56.484
age            0.5081      0.010     48.918      0.000       0.488       0.528
gender        -4.4125      0.250    -17.683      0.000      -4.902      -3.923
delay          0.0005      0.001      0.562      0.574      -0.001       0.002
delay1       -16.0797      4.842     -3.321      0.001     -25.575      -6.585
weekday        2.1216      0.061     34.623      0.000       2.001       2.242
==============================================================================
Omnibus:                       55.147   Durbin-Watson:                   0.442
Prob(Omnibus):                  0.000   Jarque-Bera (JB):               57.558
Skew:                           0.358   Prob(JB):                     3.17e-13
Kurtosis:                       2.823   Cond. No.                     9.20e+03
==============================================================================

Warnings:
```

```
[1] Standard Errors assume that the covariance matrix of the errors is correctly
specified.
[2] The condition number is large, 9.2e+03. This might indicate that there are
strong multicollinearity or other numerical problems.
"""
```

Et on compare avec la variable *price_label* :

[69]:
```
lr = ols("price ~ age + gender + delay + delay1 + price_label", data=feat3)
res = lr.fit()
res.summary()
```

[69]:
```
<class 'statsmodels.iolib.summary.Summary'>
"""
                            OLS Regression Results
==============================================================================
Dep. Variable:                  price   R-squared:                       0.917
Model:                            OLS   Adj. R-squared:                  0.917
Method:                 Least Squares   F-statistic:                     5611.
Date:                Sun, 12 Mar 2017   Prob (F-statistic):               0.00
Time:                        18:58:01   Log-Likelihood:                -6298.8
No. Observations:                2537   AIC:                         1.261e+04
Df Residuals:                    2531   BIC:                         1.264e+04
Df Model:                           5
Covariance Type:            nonrobust
==============================================================================
                 coef    std err          t      P>|t|      [0.025      0.975]
------------------------------------------------------------------------------
Intercept    -14.9859      0.664    -22.576      0.000     -16.288     -13.684
age            0.5000      0.005    104.173      0.000       0.491       0.509
gender        -4.0767      0.115    -35.344      0.000      -4.303      -3.851
delay          0.0003      0.000      0.601      0.548      -0.001       0.001
delay1       -20.8060      2.237     -9.303      0.000     -25.192     -16.420
price_label    0.9696      0.008    122.209      0.000       0.954       0.985
==============================================================================
Omnibus:                      249.245   Durbin-Watson:                   2.035
Prob(Omnibus):                  0.000   Jarque-Bera (JB):              459.156
Skew:                          -0.660   Prob(JB):                    1.98e-100
Kurtosis:                       4.613   Cond. No.                     9.47e+03
==============================================================================

Warnings:
[1] Standard Errors assume that the covariance matrix of the errors is correctly
specified.
[2] The condition number is large, 9.47e+03. This might indicate that there are
strong multicollinearity or other numerical problems.
"""
```

Aussi bien qu'avec la variable *dimanche*.

[70]:
```
```