25 gennaio 2017

Esercizio 0

0.1

- a => Funz cum emp: h, Istogramma: f
- b => Funz cum emp: g, Isogramma: d
- c => Funz cum emp: i, Istogramma e

0.2

$$P(B|A) = \frac{P(A,B)}{P(A)}$$

la probabilità condizionata di un evento A rispetto a un evento B è la probabilità che si verifichi A, sapendo che B è verificato.

0.3

$$T_n = \frac{\sum_{i=1}^{n} X_i}{n}$$

0.4

$$P(|T_n - \mu| < 0.5)$$

$$P(-0.5 < T_n - \mu < 0.5)$$

$$P(-\frac{0.5}{\frac{\sigma}{\sqrt{n}}} < \frac{T_n - \mu}{\frac{\sigma}{\sqrt{n}}} < \frac{0.5}{\frac{\sigma}{\sqrt{n}}})$$

$$P(-\frac{0.5}{\frac{\sigma}{\sqrt{n}}} < Z < \frac{0.5}{\frac{\sigma}{\sqrt{n}}})$$

$$\phi(\frac{0.5}{\frac{\sigma}{\sqrt{n}}}) - \phi(-\frac{0.5}{\frac{\sigma}{\sqrt{n}}})$$

In [1]:

```
import pandas as pd
import matplotlib.pyplot as plt
import scipy.stats as st
import math
```

In [2]:

```
Z = st.norm()
n = 47
sigma = 2.5
z1 = 0.5 * math.sqrt(n)/ sigma
z2 = - (0.5 * math.sqrt(n)/ sigma)
Z.cdf(z1) -Z.cdf(z2)
```

Out[2]:

```
0.8296658522624347
```

Esercizio 1

In [15]:

```
df = pd.read_csv('dati-ospedali_new.csv', sep=';')
df[:10]
```

Out[15]:

	Odontoiatri_Universitari	Geologi_SSN	Collaboratori_tecnico-profes_Univ	Tecnico-sanitario_Univ	Inge
0	NaN	NaN	0.0	0.0	0.0
1	0.0	NaN	0.0	0.0	0.0
2	NaN	NaN	0.0	0.0	0.0
3	NaN	NaN	0.0	0.0	0.0
4	NaN	NaN	0.0	0.0	0.0
5	NaN	NaN	0.0	0.0	0.0
6	NaN	NaN	0.0	0.0	0.0
7	NaN	NaN	0.0	0.0	0.0
8	NaN	NaN	0.0	0.0	0.0
9	NaN	NaN	0.0	0.0	0.0

10 rows × 83 columns

In [4]:

```
# 1.1
len(df)
```

Out[4]:

```
146
```

In [5]:

```
# 1.2
len(df.columns)
```

Out[5]:

83

In [6]:

```
# 1.3
medici = df['MediciSSN'].dropna()
# 1.3.1
medici.hist(bins=20)
plt.show()

# medici.plot.box(vert=False)
# plt.show()

from statsmodels.distributions.empirical_distribution import ECDF
dist = ECDF(medici)
plt.plot(dist.x, dist.y)
plt.show()
```

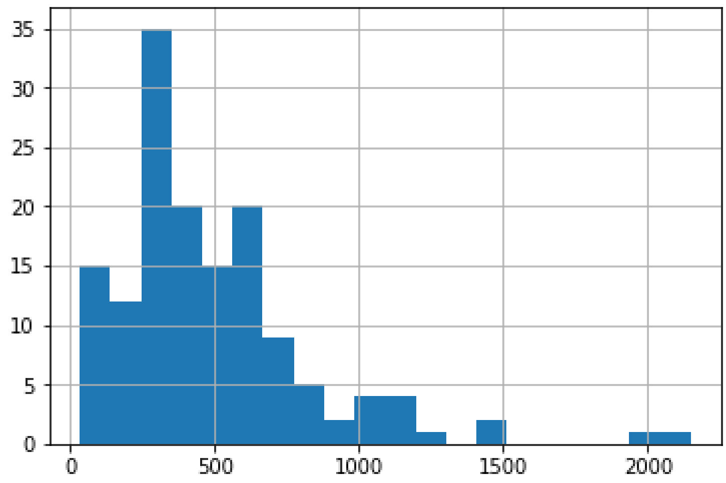

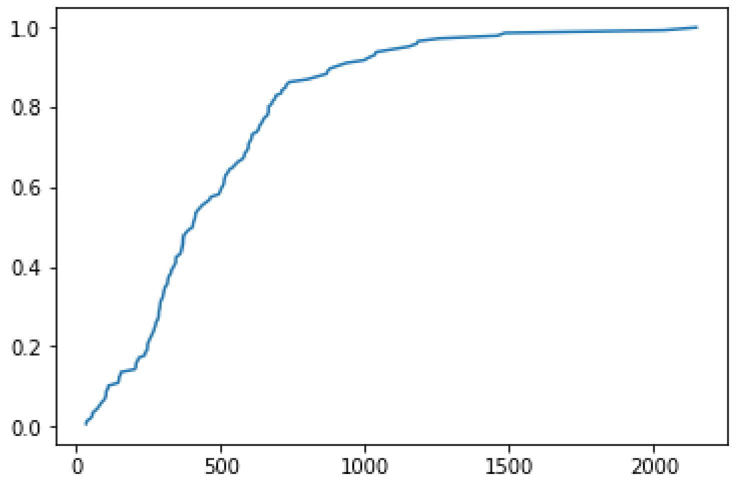

In [7]:

```
# 1.3.2
import statsmodels.api as sm
medici_no_outliers = df.loc[df['MediciSSN'] < 1300,'MediciSSN'].dropna()
sm.qqplot(medici_no_outliers,fit=True, line='45')
(medici_no_outliers.mean(), medici_no_outliers.median())

# dal grafico si può vedere come il parametro segua una legge normale essendo quasi sov
rapposto alla bisettrice del quadrante
# (media e mediana non mi convincono troppo, ma vabbé)
```

Out[7]:

(451.40140845070425, 383.5)

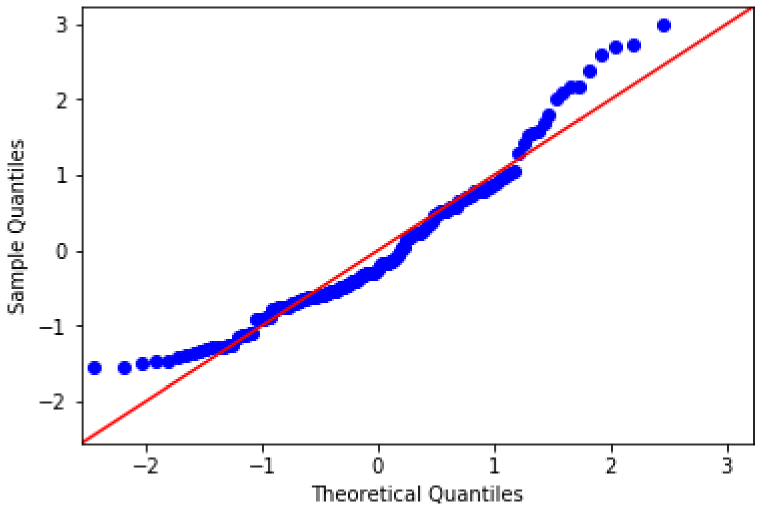

In [8]:

```
# 1.3.3
(medici.median(), medici.quantile(0.75) - medici.quantile(0.25))

# utilizzo la mediana come indice di centralità perché più robusto rispetto agli outlie
rs presenti nel carattere.
# di conseguenza utilizzo il range interquartile per lo stesso motivo e ben si sposa co
n la mediana

# (non uso la varianza perché deriva dalla media che soffre gli outliers)
```

Out[8]:

(402.5, 357.25)

In [9]:

```
# 1.4
farmacisti = df['Farmacisti_SSN']
```

In [10]:

```
# 1.4.1
farmacisti.plot.box()
plt.show()
```

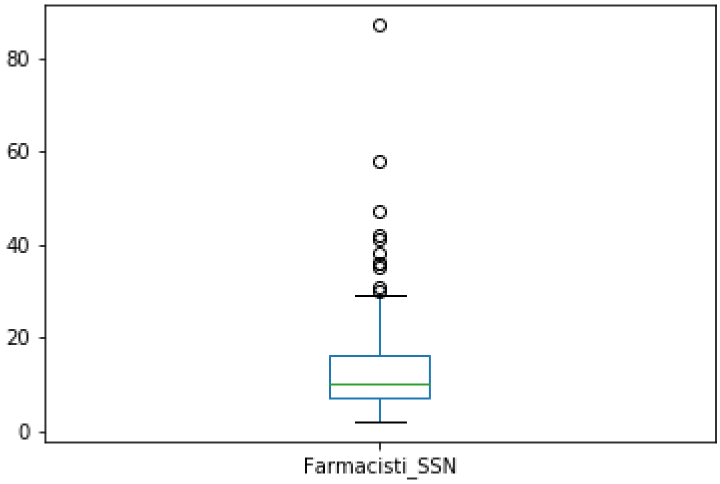

In [11]:

```
# 1.4.2 / 1.4.3
# Coefficiente di variazione (o deviazione standard relativa)
medici_mean = 406.6
medici_dev = 160.7
medici_coeff_var = medici_dev / medici_mean

farmacisti_mean = 6.4
farmacisti_dev = 2.9
farmacisti_coeff_var = farmacisti_dev / farmacisti_mean

(medici_coeff_var, farmacisti_coeff_var)
```

Out[11]:

```
(0.39522872602065906, 0.45312499999999994)
```

In [12]:

```
# 1.4.4
plt.scatter(medici, farmacisti)
plt.show()

medici.corr(farmacisti)
# il grafico mostra una dipendenza lineare tra i due caratteri
# il valore di correlazione molto vicino a 1 conferma la relazione
```

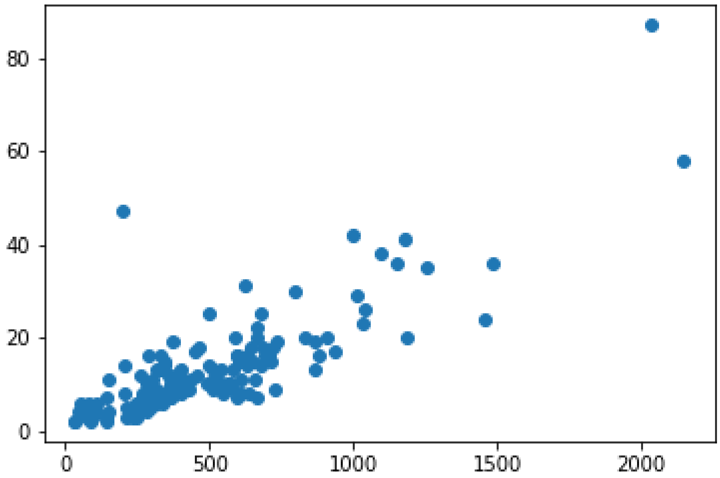

Out[12]:

```
0.8191729725239217
```

1.5

0 farmacisti => 2 \ 1 farmacisti => 22 \ 2 farmacisti => 4 \ 3 farmacisti => 1

0 grande struttura => 24 \ 1 grande struttra => 5

(L'esercizio richiedeva di basarsi sulla tabella sulla fotocopia. Nel caso richiedesse di farlo tramite codice bisogna fare così) pd.crosstab(index=df.Avvocati_SSN, columns= df.grandestruttura, margins=True)

Esercizio 2

veri positivi : 15 \ veri negativi : 12 \ falsi positivi : 35 \ falsi negativi : 2

Esercizio 3

In [13]:

```
# 3.1
ingegneri = df['Ingegneri_SSN']
(ingegneri.mean(), ingegneri.std())
```

Out[13]:

```
(4.708333333333333, 4.306240389679412)
```

3.2

$$P(|\bar{X}_n - u| < 0.5) >= 0.85$$

$$P(-0.5 < \bar{X}_n - u < 0.5) >= 0.85$$

$$P(-\frac{0.5}{\frac{\sigma}{\sqrt{n}}} < \frac{\bar{X}_n - u}{\frac{\sigma}{\sqrt{n}}} < \frac{0.5}{\frac{\sigma}{\sqrt{n}}}) >= 0.85$$

$$P(-\frac{0.5}{\frac{\sigma}{\sqrt{n}}} < Z < \frac{0.5}{\frac{\sigma}{\sqrt{n}}}) >= 0.85$$

$$P(Z < \frac{0.5}{\frac{\sigma}{\sqrt{n}}}) - P(Z < -\frac{0.5}{\frac{\sigma}{\sqrt{n}}}) >= 0.85$$

$$\phi(\frac{0.5}{\frac{\sigma}{\sqrt{n}}}) - \phi(-\frac{0.5}{\frac{\sigma}{\sqrt{n}}}) >= 0.85$$

$$\phi(\frac{0.5}{\frac{\sigma}{\sqrt{n}}}) - (1 - \phi(\frac{0.5}{\frac{\sigma}{\sqrt{n}}})) >= 0.85$$

$$2\phi(\frac{0.5}{\frac{\sigma}{\sqrt{n}}}) >= 1.85$$

$$\phi(\frac{0.5}{\frac{\sigma}{\sqrt{n}}}) >= 0.925$$

$$\frac{0.5}{\frac{\sigma}{\sqrt{n}}} >= \phi^{-1}(0.925)$$

$$n >= (\frac{\sigma}{0.5}\phi^{-1}(0.925))^2$$

In [14]:

```
sigma = ingegneri.std()
X = st.norm()
((sigma/0.5)*X.ppf(0.925))**2
```

Out[14]:

```
153.70884494899622
```

Per avere una stima del valore atteso con un errore inferiore a 1 è necessario un campione di almeno 154 elementi. Il nostro dataset ne contiene solo 146