Gennaio 2018

Esercizio 0

0.1

La media campionaria è uno stimatore non distorto per μ? $E(X) = \mu$

$$E(\overline{X}) = \frac{1}{n}\sum_{i=1}^{n} E(X_i) = \frac{n}{n}E(X) = E(X)$$

0.2

Grafico delle funzioni di ripartizione?

0.3

$X \sim Expon(\lambda)$

$E(X) = \frac{1}{\lambda}$ quindi

$$\lambda = \frac{1}{E(X)}$$

0.4

$Var(X) = \frac{1}{\lambda^2} = E(X)^2$

Deviazione standard = $\sqrt{Var(X)} = E(X)$

0.5

L'esponenziale B ha il parametro con valore più alto perchè per p più alto F_X è maggiore (vedi punto 2)

In [1]:

```
import pandas as pd
import matplotlib.pyplot as plt
import scipy.stats as st
import numpy as np
import statsmodels.api as sm
from scipy.stats import expon
from scipy.stats import geom
```

Esercizio 1

In [2]:

```
dati = pd.read_csv("astici.csv",delimiter=",",decimal=".")
dati.columns
```

Out[2]:

```
Index(['kg.di.pesce', 'settore.di.pesca', 'forza.del.mare', 'peso.astic
e'], dtype='object')
```

1.1

In [3]:

```
len(dati)
```

Out[3]:

```
281
```

1.2

In [4]:

```
len(dati['settore.di.pesca'].unique())
```

Out[4]:

```
9
```

1.3

In [5]:

```
len(dati[dati['settore.di.pesca'] == 'A'])
```

Out[5]:

```
37
```

1.4

In [6]:

```
dati['settore.di.pesca'].value_counts().plot.bar()
plt.show()
```

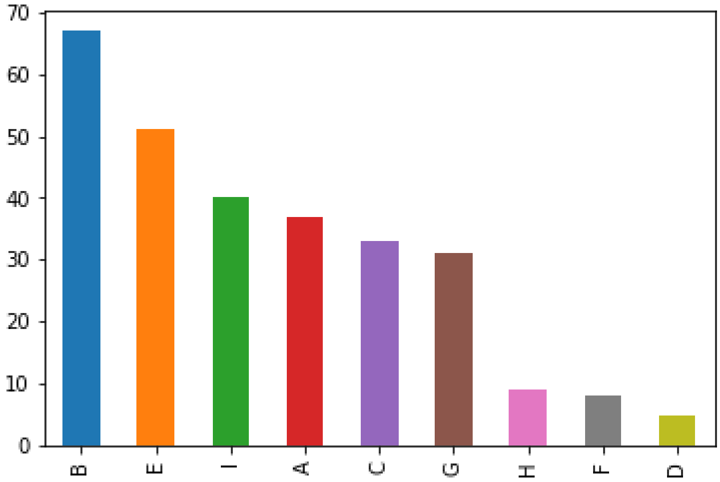

1.5

Settore B

1.6

In [7]:

```
p = len(dati[dati['settore.di.pesca'] == "B"])/len(dati)
p * 100
```

Out[7]:

```
23.843416370106763
```

1.7

In [8]:

```
dati['forza.del.mare'].head()
#CATEGORICO
```

Out[8]:

```
0    9
1    9
2    9
3    7
4    8
Name: forza.del.mare, dtype: int64
```

1.8

In [9]:

```
dati['forza.del.mare'].value_counts().sort_index().plot.bar()
plt.show()
```

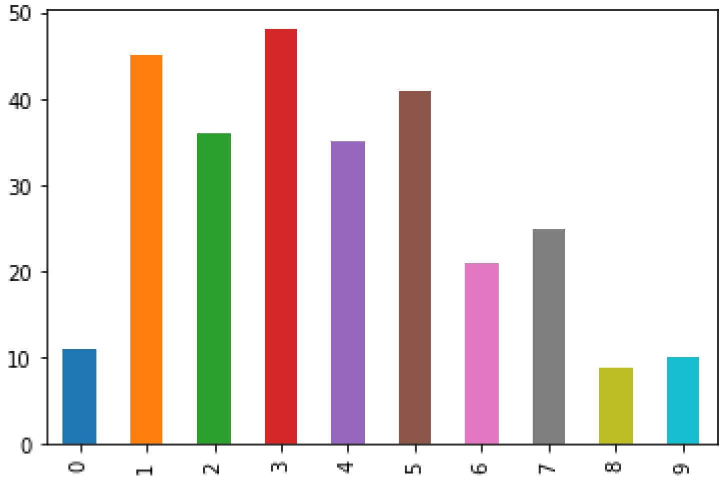

1.9

In [10]:

```
#1.9
ecdf = sm.distributions.ECDF(dati['forza.del.mare'])
x = np.arange(dati['forza.del.mare'].min(), dati['forza.del.mare'].max()+1)
y = ecdf(x)
plt.step(x,y)
plt.show()
```

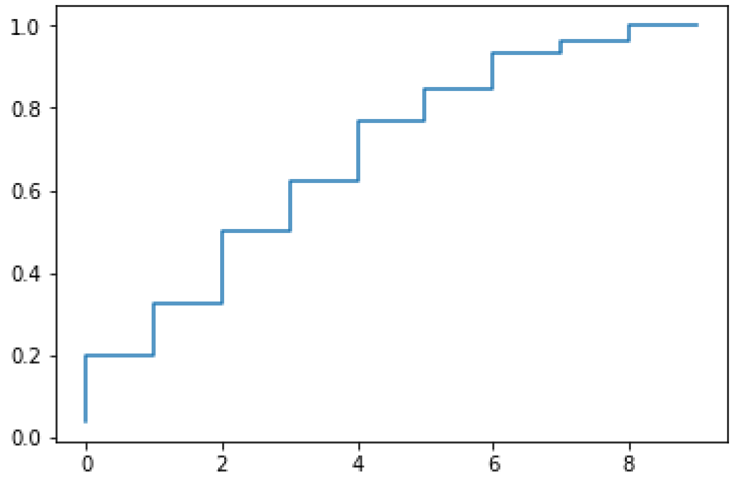

1.10

In [11]:

```
sm.qqplot(dati['forza.del.mare'],line="45")
plt.show()
```

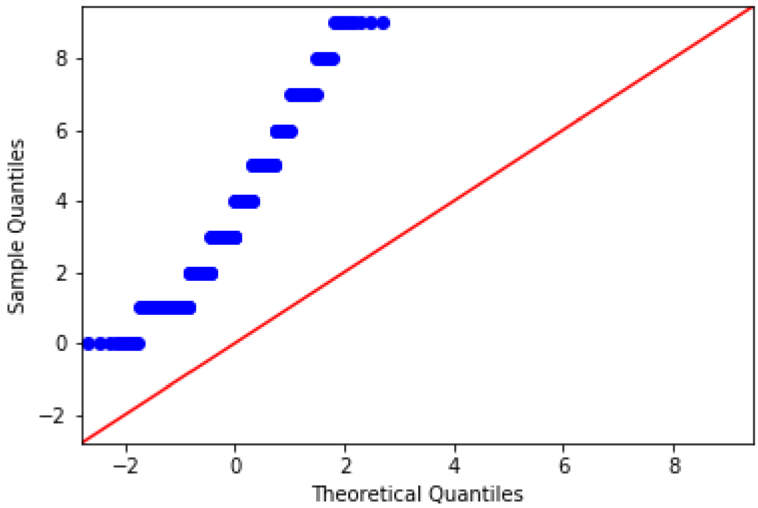

Il Q-Q Plot è la rappresentazione grafica dei quantili di una distribuzione. Confronta la distribuzione cumulata della variabile osservata con la distribuzione cumulata della normale. Se la variabile osservata presenta una distribuzione normale, i punti di questa distribuzione congiunta si addensano sulla diagonale che va dal basso verso l'alto e da sinistra verso destra. In questo caso i punti non si distribuiscono su questa diagonale e quindi possiamo affermare che non è approssimativamente normale.

1.11

In [12]:

```
dati['forza.del.mare'].mean()
```

Out[12]:

```
3.804270462633452
```

1.12

In [13]:

```
dati['forza.del.mare'].mode()
```

Out[13]:

```
0    3
dtype: int64
```

Il valore della forza del mare riscontrato più spesso è stato il 3.

1.13

In [14]:

```
dati['peso.astice'].head()
#QUANTITATIVO CONTINUO
```

Out[14]:

```
0    29.9
1    29.3
2    29.9
3    29.9
4    28.4
Name: peso.astice, dtype: float64
```

1.14

In [15]:

```
#1.14 QUANTITATIVO CONTINUO -> HIST?
dati['peso.astice'].plot.hist()
plt.show()
```

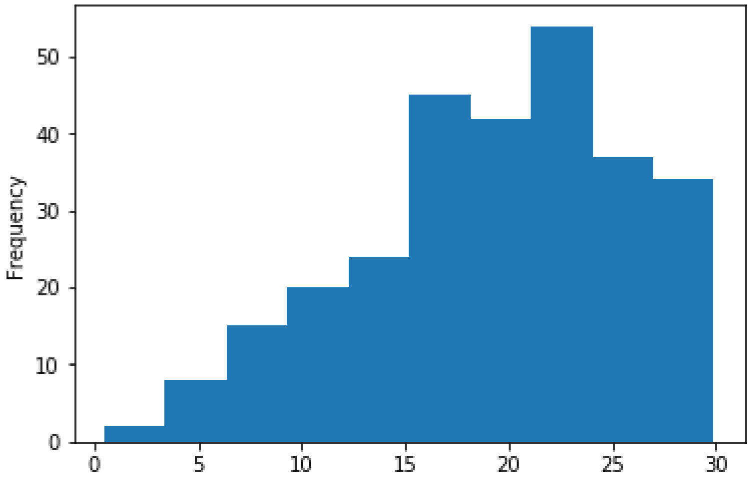

1.15

In [16]:

```
#EVIDENZIARE GLI OUTLIER
dati['peso.astice'].plot.box()
plt.show()
```

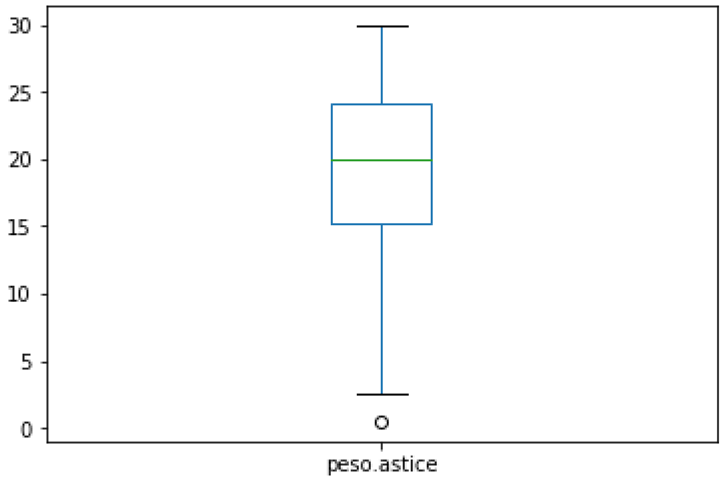

1.16

In [17]:

```
astici_filtrato = dati[dati['peso.astice'] != dati['peso.astice'].min()]
```

1.17

In [18]:

```
print(astici_filtrato['peso.astice'].var(),astici_filtrato['peso.astice'].mean())
```

```
40.49094930875574 19.354285714285737
```

1.18

$$P(|X - E(X)| < 10)$$
$$2\Phi(\frac{10\sqrt{n}}{\sigma}) - 1$$

In [19]:

```
import math
n = len(astici_filtrato['peso.astice'])
X = st.norm()
sigma = astici_filtrato['peso.astice'].std()
pi = (10*math.sqrt(n))/sigma
2*X.cdf(pi)-1
```

Out[19]:

```
1.0
```

1.19

In [20]:

```
#RELAZIONE TRA peso.astice e forza.del.mare
plt.scatter(dati['peso.astice'],dati['forza.del.mare'])
plt.show()
```

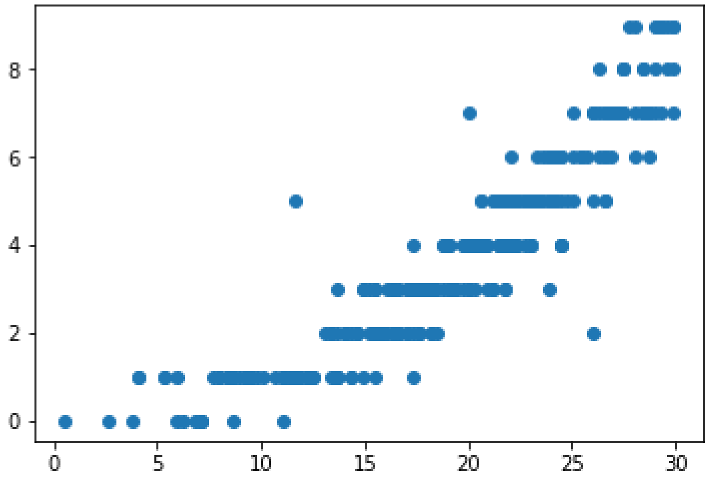

In questo grafico è evidente una relazione tra i due caratteri. La relazione evidenziata è lineare positiva.

In [21]:

```
#RELAZIONE TRA peso.astice e kg.di.pesce.
plt.scatter(dati['peso.astice'],dati['kg.di.pesce'])
plt.show()
```

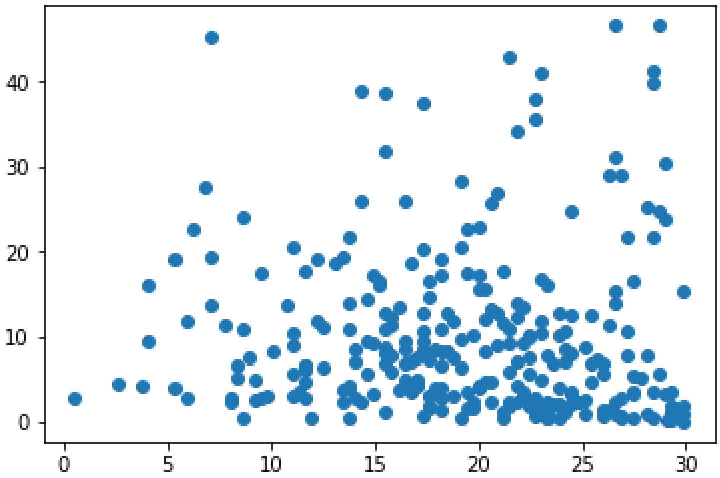

In questo grafico invece non si evidenzia nessun tipo di relazione tra i duie caratteri in quanto i puntini sono tutti sparsi.

1.20

In [22]:

```
#INDICE CHE INDICA LA RELAZIONE: INDICE DI CORRELAZIONE
dati["peso.astice"].corr(dati["forza.del.mare"])
```

Out[22]:

```
0.9156381240896676
```

Esercizio 2

2.1

In [23]:

```
#FUNZIONE CUMULATIVA EMPIRICA
ecdf = sm.distributions.ECDF(dati['kg.di.pesce'])
x = np.arange(dati['kg.di.pesce'].min(), dati['kg.di.pesce'].max()+1)
y = ecdf(x)
plt.step(x,y)
plt.show()
```

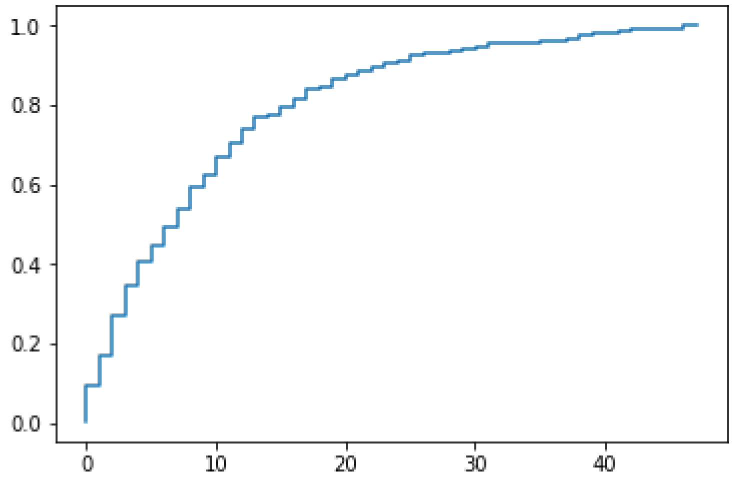

2.2

In [24]:

```
dati['kg.di.pesce'].var()/len(dati)
```

Out[24]:

0.346324073964187

In [25]:

```
dati['kg.di.pesce'].mean()
```

Out[25]:

10.078838086708181

2.3

La media campionaria è sempre uno stimatore non deviato, mentre la varianza bisogna verificare

2.4

In [26]:

```
dati['kg.di.pesce'].hist()
plt.show()
```

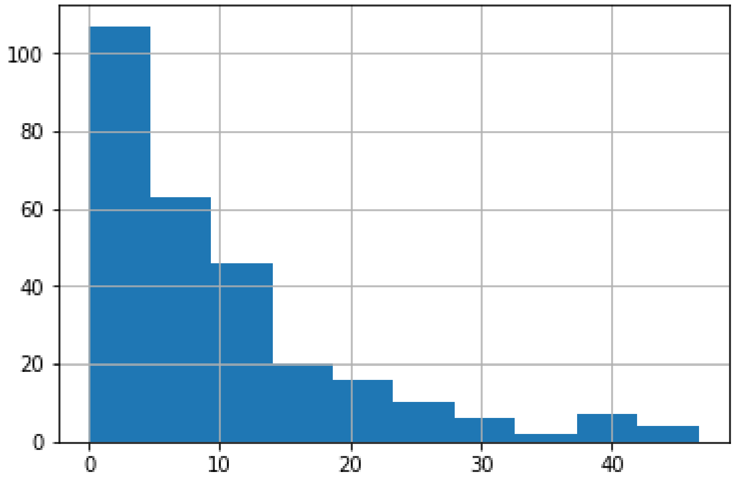

Il grafico appena proposto suggerisce che kg.di.pesce potrebbe distribuirsi come un esponenziale in quanto il grafico approssima molto bene quello della distribuzione esponenziale. Poi sappiamo che nell'aponenziale il valore atteso a le deviazione standard si equivalgono e anche in questo caso se stimo i due valori sono molto vicini tra di loro.

In [27]:

```
dati["kg.di.pesce"].describe()
```

Out[27]:

```
count    281.000000
mean      10.078838
std        9.864941
min        0.020205
25%        2.886564
50%        7.182464
75%       13.533704
max       46.633104
Name: kg.di.pesce, dtype: float64
```

2.5

$\lambda = \frac{1}{E(X)}$

In [28]:

```
1/(dati["kg.di.pesce"].mean())
```

Out[28]:

```
0.09921778595875896
```