Gennaio 2016

In [14]:

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

Esercizio 0 ¶

0.1,0.2 Grafici

$D_X = 2, \dots, 14, X \sim Unif(D_X)$

$X \sim Geom(p), n \in \{0, 1, 2, \dots\}$

0.3

$$E(X) = \frac{1-p}{p}$$

0.4

$$p = \frac{1}{E(X)+1}$$

0.5

$$Var(X) = \frac{1-p}{p^2} = E(X)(E(X)+1)$$

Esercizio 1

In [10]:

```
df = pd.read_csv('Comune_Bergamo_-_Incidenti_stradali.csv')
df.columns
```

Out[10]:

```
Index(['Protocollo', 'Anno', 'Data', 'Ora', 'Localita', 'NaturaIncidente',
       'N_Illesi', 'N_Feriti', 'N_Riservata', 'N_Morti', 'Pedoni',
       'Velocipedi', 'Ciclomotori_Motocicli', 'Mezzi_Pesanti',
       'Localizzazione'],
      dtype='object')
```

1.1

In [11]:

```
len(df)
```

Out[11]:

```
28040
```

1.2

- Protocollo categorici
- Anno ordinali
- Data ordinali
- Ora ordinali
- Localita categorici
- NaturaIncidente categorici
- N_Illesi scalari
- N_Feriti scalari
- N_Riservata 28040 non-null int64
- N_Morti scalari
- Pedoni categorici
- Velocipedi categorici
- Ciclomotori_Motocicli categorici
- Mezzi_Pesanti categorici
- Localizzazione categorici

In [12]:

```
df.info()
```

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 28040 entries, 0 to 28039
Data columns (total 15 columns):
Protocollo               28040 non-null object
Anno                     28040 non-null int64
Data                     28040 non-null object
Ora                      28040 non-null object
Localita                 28040 non-null object
NaturaIncidente          28040 non-null object
N_Illesi                 28040 non-null int64
N_Feriti                 28040 non-null int64
N_Riservata              28040 non-null int64
N_Morti                  28040 non-null int64
Pedoni                   28040 non-null bool
Velocipedi               28040 non-null bool
Ciclomotori_Motocicli    28040 non-null bool
Mezzi_Pesanti            28040 non-null bool
Localizzazione           27954 non-null object
dtypes: bool(4), int64(5), object(6)
memory usage: 2.5+ MB
```

1.3

Modello Uniforme Anno intorno ai 2000

In [21]:

```
df['Anno'].value_counts(sort=False).plot.bar()
plt.show()
```

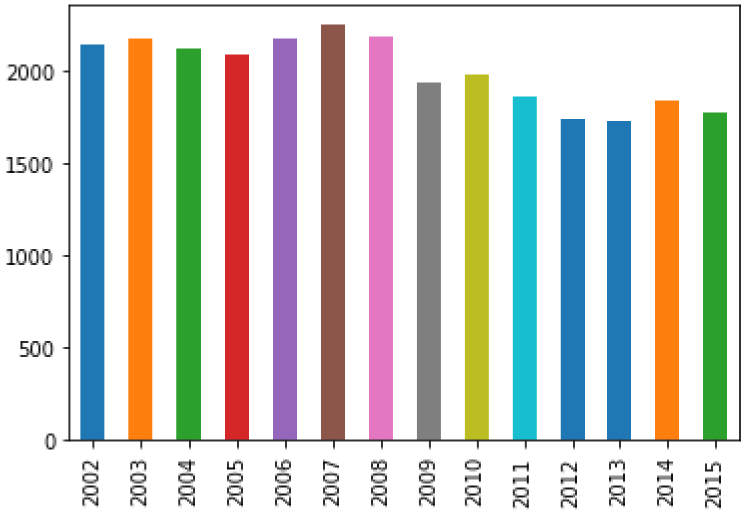

1.4

In [33]:

```
n_feriti = pd.crosstab(index=df['N_Feriti'],columns="Frequenza Relativa",colnames=[''],
normalize=True)
n_feriti
```

Out[33]:

	Frequenza Relativa
N_Feriti	
0	0.501676
1	0.398930
2	0.074750
3	0.016084
4	0.005528
5	0.001961
6	0.000571
7	0.000357
8	0.000071
9	0.000036
10	0.000036

1.5

In [31]:

```
### incidenti, feriti ???
n_feriti.cumsum().plot()
plt.show()
```

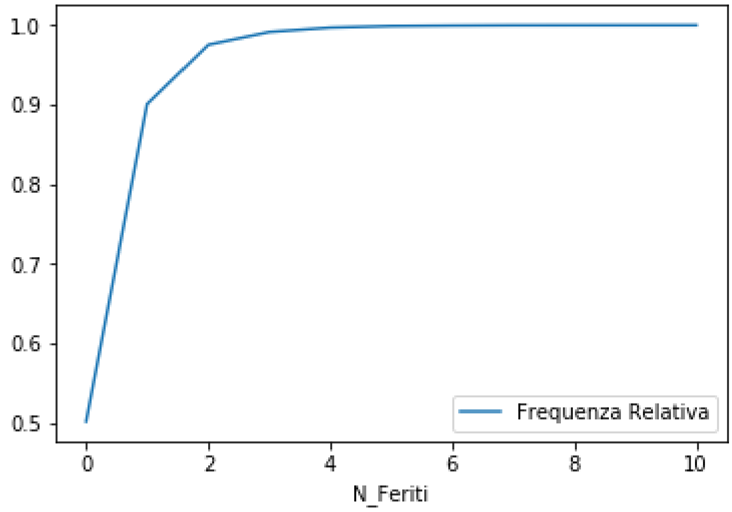

1.6

!A = "nessuno ferito"

A = "almeno un ferito" = 1-P(!A)

In [43]:

```
1-df['N_Feriti'].value_counts(normalize=True).sort_index()[0]
#1-n_feriti[:1]
```

Out[43]:

```
0.49832382310984313
```

1.7

valore atteso -> stimo con media campionaria

In [44]:

```
df['N_Feriti'].mean()
```

Out[44]:

```
0.6357703281027104
```

1.8

Osservando il grafico e notando dai dati quì sotto che media e deviazione standard sono vicini possiamo assumere che il modello probabilistico è geometrico

In [45]:

```
df['N_Feriti'].describe()
```

Out[45]:

```
count    28040.000000
mean         0.635770
std          0.790586
min          0.000000
25%          0.000000
50%          0.000000
75%          1.000000
max         10.000000
Name: N_Feriti, dtype: float64
```

In [48]:

```
from statsmodels.distributions.empirical_distribution import ECDF
dist = ECDF(df['N_Feriti'].dropna())
plt.plot(dist.x, dist.y)
plt.show()
```

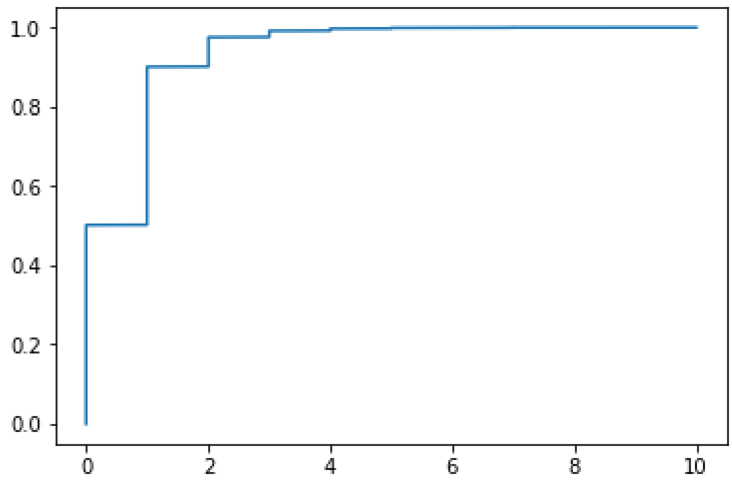

1.9

stima parametro della distribuzione

In [53]:

```
p = (1/(1+df['N_Feriti'].mean()))#vedi esercizio 0
p
```

Out[53]:

```
0.6113327664769879
```

1.10

In [56]:

```
X = st.geom(p,loc=-1)
x = np.arange(11) #numero max di incidenti
plt.plot(x,X.pmf(x),'o')
plt.show()
```

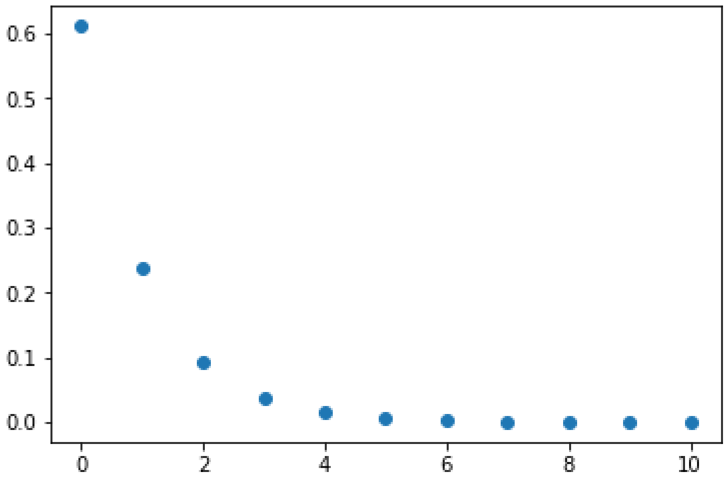

1.11

diagramma dispesione N_Feriti e N_Illesi

In [64]:

```
plt.scatter(df['N_Feriti'],df['N_Illesi'],color="brown")
plt.xlabel('Feriti')
plt.ylabel('Illesi')
plt.show()
```

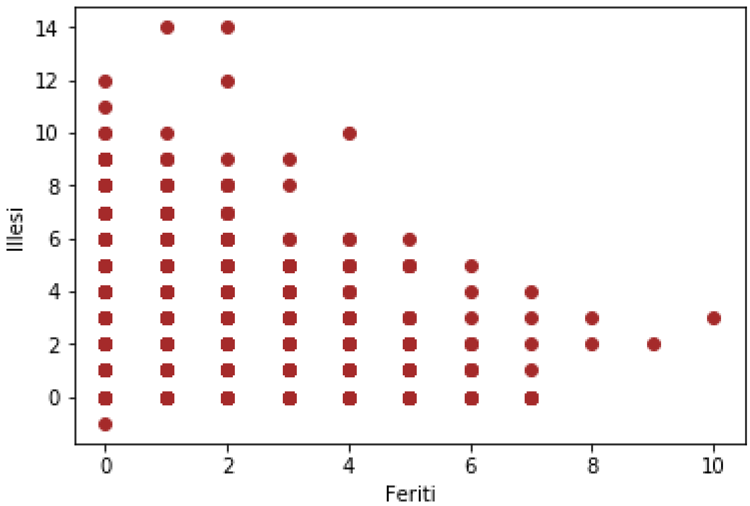

1.12

Correlazione tra feriti e illesi

In [65]:

```
df['N_Feriti'].corr(df['N_Illesi'])
```

Out[65]:

```
-0.3070519976103214
```

Esercizio 2

Dati $X_1, \dots, X_n$ campione casuale, con X= numero illesi incidente

2.1

Stimatore del valore atteso

$$T_n = \overline{X}$$

In [58]:

```
df['N_Illesi'].mean()
```

Out[58]:

```
1.7973965763195434
```

2.2

$Var(\overline{X}) = \frac{1}{n} Var(X)$

$$\sigma(\overline{X}) = \sqrt{\frac{1}{n} Var(X)}$$

In [59]:

```
std = (df['N_Illesi'].var()/df['N_Illesi'].dropna().count())**0.5
std
```

Out[59]:

```
0.007751809852772057
```

2.3

Dimostrare che $P(|Z| < k) = 2\Phi(k) - 1$

$$P(|Z| < k) = P(-k < Z < k) = \Phi(k) - \Phi(-k) = \Phi(k) - (1 - \Phi(k)) = 2\Phi(k) - 1$$

2.4

Determinare k tale che $P(|Z| < k) = 0.99$. Riprendo l'esercizio precedente

$$2\Phi(k) - 1 = 0.99$$

$$\Phi(k) = \frac{1.99}{2} = 0.995$$

$$k = \Phi^{-1}(0,955)$$

In [6]:

```
Z = st.norm()
Z.ppf(0.995)
```

Out[6]:

```
2.5758293035489004
```

2.5

$$P(|T_n - \mu| < \epsilon) = 0.99$$

$$2\Phi(\frac{\epsilon\sqrt{n}}{\sigma}) - 1 = 0.99$$

$$P(|\overline{X} - E(\bar{(}X))| \leq 0.99) > \frac{Var(X)}{n * 0.99}$$

$$\epsilon = \frac{\phi^{-1}(0.995)\sigma}{\sqrt{n}}$$

In [60]:

```
(Z.ppf(0.995) * df['N_Illesi'].std())/df['N_Illesi'].dropna().count()**0.5
```

Out[60]:

```
0.019967338974309353
```