

TP 1

Exercice 1

1.

On commence par importer les packages, et simuler un échantillon

```
In [41]: #imports
import numpy as np
import matplotlib.pyplot as plt
from scipy import stats
```

```
n = 100
lam = 10
```

```
x = np.random.poisson(lam,n)
print(x)
```

```
[13  6  9  7 12 10 14  6  6  8 11  7 12  7 10  7  7 11  9  7 16  9  1
 1  6
 12  9  7  3  8  6 15 17  7 11 17  7  9  9  7  9  4 14  7  8  8  8
 8  5
  6  7  4  9  9  7 13  5  9 10  9 13  5  8 11 10  6 12  6 10  8  5
 9 12
 11 11 12  5  9  7 10 14  5  9 12 12  6  9  4  9 12 14  5 13 13 11  1
 0 11
 13 11 12  7]
```


2.

D'après le cours, on a

$$\mathbb{P}(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}.$$

```
In [42]: from math import factorial
kvec = range(21)
pk = [lam**k/factorial(k)*np.exp(-lam) for k in kvec]
print(pk[:2])
print(stats.poisson.pmf(kvec, lam)[:2])#pour comparaison
%matplotlib inline
plt.figure()
plt.plot(kvec,pk,color = 'blue',linestyle = "-.")
plt.plot(kvec,stats.poisson.pmf(kvec, lam),color = "red",linestyle =
":.")
print(pk)
```

```
[4.5399929762484854e-05, 0.00045399929762484856]
[4.53999298e-05 4.53999298e-04]
[4.5399929762484854e-05, 0.00045399929762484856, 0.00226999648812424
27, 0.007566654960414142, 0.018916637401035358, 0.03783327480207071
5, 0.06305545800345119, 0.09007922571921598, 0.11259903214901998, 0.
1251100357211333, 0.1251100357211333, 0.1137363961101212, 0.09478033
009176765, 0.07290794622443666, 0.05207710444602618, 0.0347180696306
8413, 0.021698793519177577, 0.012763996187751515, 0.0070911089931952
87, 0.0037321626279975197, 0.0018660813139987598]
```




3.

D'après le cours, on a, par la loi forte des grands nombres

$$\hat{p}_k \xrightarrow{p.s.} \mathbb{E} \left[\mathbb{1}_{X_i=k} \right] = p_k.$$


```
In [43]: n = 100
lam = 10
x = np.random.poisson(lam,n)
counts = np.bincount(x)
freq = counts/n
plt.figure()
plt.bar(range(21),stats.poisson.pmf(range(21),lam))
plt.plot(freq,color = "red",linewidth = 2)
plt.show()
```



```
In [44]: def compare_theo_and_empirical(n,ax, lam = 10):
x = np.random.poisson(lam,n)
counts = np.bincount(x,minlength = 21)
freq = counts/n
ax.bar(range(20),stats.poisson.pmf(range(20), lam))
ax.plot(freq,color = "red",linewidth = 2)

fig,axes = plt.subplots(4)
for i,n in enumerate([10,100,1000,10000]):
    compare_theo_and_empirical(n,axes[i],lam = 10)

plt.show()
```



On observe effectivement la convergence.

4.


```
In [45]: lam = 1.4
mu = 1.6
n = 10000

x= np.random.poisson(lam,n)
y= np.random.poisson(mu,n)
z = x+y

print(np.mean(z==4),stats.poisson.pmf(4,lam+mu),sep = " vs ")

0.1628 vs 0.16803135574154085
```

```
In [46]: freq = np.bincount(z)/n
plt.figure()
plt.bar(range(20),stats.poisson.pmf(range(20),lam+mu))
plt.plot(freq,color = "red",linewidth = 2)
plt.show()
```



Exercice 2

1.

(a)

```
In [47]: #pour les plots interactif dans notebook


N = 10**3
x = np.random.uniform(0,2,N)
```

(b)

```
In [48]: y = np.cumsum(x)/range(1,N+1)
```

(c)

```
In [49]: %matplotlib inline
plt.plot(y)
plt.show()
```



Il semble y avoir convergence (p.s.)

2.

(a)

On peut reconnaître la densité de la loi exponentielle, d'où

$$I = \mathbb{E}[X^5],$$

où $X \sim \mathcal{E}(1)$.

(b)

```
In [50]: n = 10000000
x= np.random.exponential(scale = 1,size = n)
print(np.mean(x**5))
from math import gamma
gamma(6)
```

120.15422976222577

Out[50]: 120.0

On remarque que l'on fait une erreur sur l'évaluation de cette quantité, mais cela peut-être utile pour calculer des intégrales pour lesquelles on n'a pas de valeur explicite.

3.

On reconnaît de nouveau des lois, et on identifie

$$I_2 = \mathbb{E} \left[\cos \left(Z(X^2 + Y) \right) \right],$$

avec $X \sim \mathcal{E}(1)$, $Y \sim \mathcal{N}(0, 1)$, $Z \sim \mathcal{U}([0, 1])$, indépendantes.

La technique précédente donne :

```
In [51]: n = 100000
x = np.random.exponential(size = n)
y = np.random.normal(size =n)
z = np.random.uniform(size = n)

print(np.mean( np.cos( z*(x**2+y) )))
```

0.6217801107020385

Exercice 3

1.

On simule l'échantillon. On fera bien attention à la paramétrisation des fonctions, par le "scale", i.e. $s = \frac{1}{\lambda}$ selon comment a été définie la loi exponentielle. La densité considérée ici est donc

$$f_s(x) = \frac{1}{s} e^{-\frac{x}{s}}$$

```
In [52]: lam = 2
scale = 1/lam
n = 100
x = np.random.exponential(scale = scale,size = n)
print(x[:4])
print(np.mean(x))
```


```
[0.05086701 0.34368684 0.19570821 0.26910347]
0.5013063897815807
```

2.

On peut représenter la densité théorique de la loi, ainsi qu'un histogramme

```
In [53]: n = 10000
x = np.random.exponential(scale,n)
plt.figure()
plt.hist(x,bins = 50,density = True)
xseq = np.linspace(0,10,1000)
plt.plot(xseq,stats.expon.pdf(xseq,scale = scale),color = "red",lin
estyle = "--")
plt.xlim(0,4)
```


Out [53]: (0, 4)



3.

On peut comparer (au choix) la densité ou la fonction de répartition.


```
In [54]: n = 10000## assez pour pouvoir illustrer les propriétés
x = np.random.normal(size= n)
y = np.random.normal(size = n)
z = x/y
xseq= np.linspace(-20,20,100)
xseq[0] = -10000
xseq[99] = 10000##juste pour avoir la bonne normalisation de l'histogramme, on m'avait fait la remarque
plt.figure()
plt.plot(xseq,stats.cauchy.pdf(xseq),color = "red",linestyle = "--")
plt.xlim(-10,10)
plt.hist(z, bins = xseq,density = True)
plt.show()
```



4.

On peut faire de même pour cette propriété.


```
In [55]: n = 10000## assez pour pouvoir illustrer les propriétés
x = np.random.normal(size= n)
y = np.random.normal(size = n)
z = x**2+y**2
plt.figure()
xseq= np.linspace(0,15,100)
plt.hist(z, bins = xseq,density = True)
plt.plot(xseq,stats.expon.pdf(xseq,scale = 2),color = "red",linesty
le = "--")
plt.show()
```




Exercice 4

1.

```
In [56]: %matplotlib notebook
N = 10**7
x = np.random.uniform(-1,1,N)
y = np.cumsum(1/np.abs(x))/range(1,N+1)
%matplotlib inline
plt.plot(y)
```

Out[56]: [<matplotlib.lines.Line2D at 0x7f3bc7c052d0>]




On n'observe pas de convergence. Cela signifie a priori que l'on a pas $\mathbb{E}\left[\frac{1}{|U|}\right] < +\infty$. On peut le démontrer aisément, puisque

$$\mathbb{E}\left[\frac{1}{|U|}\right] = \int_{-1}^1 \frac{du}{2u} = +\infty$$

2.

On peut simuler plusieurs réalisations de la moyenne de 100 réalisations i.i.d. de loi exponentielles de paramètre 1.


```
In [57]: x = [ np.mean( np.random.exponential(size = 100) )   for i in rang
e(1000)]
plt.figure()
plt.hist(x,bins = 80,density = True);
```



Cela ressemble à une loi normale, ce que l'on peut illustrer

```
In [58]: m = np.mean(x)
v = np.var(x)
plt.figure()
plt.hist(x,bins = 50,density = True)
xseq = np.linspace(0.7,1.3,100)
plt.plot(xseq,stats.norm.pdf(xseq,loc = m,scale = np.sqrt(v)),color
= "red",linestyle = "--")
```

Out [58]: [matplotlib.lines.Line2D at 0x7f3bc7259f50]



In []:

In []: