



DEVOIR MAISON V

ECG2 MATHS APPLIQUÉES

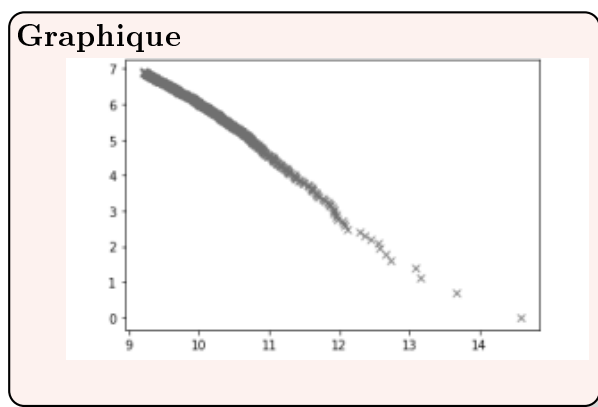
HEC/ESSEC 2023 SUJET 0 ÉNONCÉ 2

Loi de Pareto-Zipf. On souhaite modéliser la loi de probabilité de la variable aléatoire T qui, à une ville, choisie au hasard parmi les villes françaises, associe l'effectif de sa population. On note n le nombre de villes.

- Pour 2018, on dispose d'un fichier `Data1.csv` de données provenant de l'INSEE et on utilise la bibliothèque `pandas`. On exécute les instructions suivantes :

```
1 import pandas as pd
2 import numpy.random as rd
3 import numpy as np
4 import matplotlib.pyplot as plt
5
6 dataset = pd.read_csv('Data1.csv', sep = ";")
7 donnees = dataset[["Libelle", "Population"]]
8 donnees = donnees.sort_values(by = ["Population", "Libelle"], ascending =
9     False, ignore_index = True)
10
11 logPopu = [np.log(t) for t in donnees["Population"]]
12 logRang = [np.log(k) for k in range(1, lenPopu)+1)]
13 plt.plot(logPopu, logRang, '*')
```

ce qui produit le graphique suivant :



Expliquer pourquoi le programme et le graphique précédent justifient qu'il existe deux réels a et b tels que, pour toute ville, le réel $\frac{a}{t^b}$ où t est l'effectif de celle-ci, est une approximation raisonnable du rang de celle-ci dans la liste des villes classées par ordre décroissant de population ?

Quelle grandeur peut-on calculer pour confirmer ce que l'on constate graphiquement? Quelle méthode peut-on utiliser pour obtenir le meilleur couple (a, b) en un certain sens?

- b. On suppose que l'on a pour toutes les villes $r = \frac{a}{t^b}$, r étant le rang de cette ville, t son effectif, a et b deux réels identiques pour toutes les villes. Si x est l'effectif d'une des villes françaises, quelle est, en fonction de a , b , x et n , la proportion de villes dont la population urbaine est supérieure ou égale à x ?

• On suppose désormais que T suit la loi de Pareto de paramètre $\theta > 1$ et $x_0 > 0$, c'est-à-dire qu'elle admet pour densité la fonction f définie par

$$f(x) = \begin{cases} \theta \frac{x_0^\theta}{x^{\theta+1}} & \text{si } x \geq x_0 \\ 0 & \text{sinon} \end{cases} .$$

On note $\text{Par}(\theta, x_0)$ cette loi.

2. a. Déterminer la fonction de répartition F de T .
- b. En calculant $\mathbb{P}([T > x])$, montrer que ce résultat est cohérent avec le résultat de la question 1 et exprimer x_0 et θ en fonction de a , b et n .
- c. Montrer que $\mathbb{E}(T)$ existe et vaut $\frac{\theta}{\theta-1}x_0$.
3. Soit $x \geq x_0$, on note \mathbb{P}_x la probabilité conditionnelle sachant $[T > x]$.
- a. Montrer que pour tout $t \geq x \geq x_0$, $\mathbb{P}_x(T > t) = \left(\frac{x}{t}\right)^\theta$.
- b. On pose pour tout $t \in \mathbb{R}$, $F_x(t) = \mathbb{P}_x([T \leq t])$. De quelle loi F_x est-elle la fonction de répartition? Quelle est alors l'espérance de cette loi?
4. Soit $\delta \in]1, +\infty[$
- On suppose que Y est une variable aléatoire à valeurs dans $[x_0, +\infty[$ dont f_Y est une densité, continue sur $[x_0, +\infty[$, F_Y la fonction de répartition. On suppose que pour tout $x \geq x_0$, $\mathbb{P}([Y \geq x]) > 0$.
- a. Soit $x \geq x_0$. Montrer que la fonction G_x définie sur \mathbb{R} par $G_x : t \mapsto \mathbb{P}_{[Y \geq x]}(Y \leq t)$ est une fonction de répartition d'une variable aléatoire à densité dont on déterminera une densité.
- On suppose que pour tout $x \geq x_0$, l'espérance d'une variable aléatoire de fonction de répartition G_x existe et vaut δx .
- b. En déduire que pour tout $x \geq x_0$, $(\delta - 1)xf_Y(x) = \delta(1 - F_Y(x))$.
- c. Résoudre l'équation différentielle $(1 - \delta)xy' - \delta y = 0$ sur $[x_0, +\infty[$.
- d. En déduire que Y suit une loi de Pareto dont on précisera les paramètres.