



T.P. n°3

*Simulations de variables aléatoires (finies et) discrètes
Statistiques descriptives univariées*

1 Simulation de v.a.r suivant une loi discrète à l'aide de la fonction `rand()`

1.1 Simulation d'une v.a.r suivant une loi de Bernoulli

☞ Rappeler la définition, la loi et les résultats concernant la loi de Bernoulli.

$X \hookrightarrow \mathcal{B}(p)$ signifie que $P(X = 0) = 1 - p$, $P(X = 1) = p$, $E(X) = p$, et $V(X) = p(1-p)$.

☞ On considère la fonction ci-dessous, que l'on recopiera et enregistrera sous le nom `bernouilli.sci`. Que fait-elle ?

```
function y = bernouilli (p)
    r=rand();
    if r < p then
        y = 1;
    else
        y = 0;
    end
endfunction
```

☞ Écrire une fonction `v=SampleBernoulli(N,p)` qui prend en paramètre un entier N non nul, un réel p de $]0;1[$ et renvoie un vecteur ligne v contenant le résultat de la simulation de N v.a.r indépendantes de loi $\mathcal{B}(p)$.

- (1) Évaluer la commande `U=SampleBernoulli(1000, 0.3); Y=tabul(U, "i")`. On rappellera notamment ce que fait la commande `tabul()`.
- (2) Que font les instructions suivantes? Interpréter.

```
m=mean(U);
v=mean(U-m).^2;
```

- (3) Taper ensuite `clf(); bar(Y(:, 1), Y(:, 2))`. Expliquer le fonctionnement de `bar` en détaillant le contenu de `Y(:, 1)` et `Y(:, 2)`.
- (4) Le résultat obtenu est-il cohérent?
- (5) Le diagramme obtenu représente l'effectif de chaque classe. Comment modifier l'appel pour obtenir un diagramme des fréquences?

1.2 Simulation d'une v.a.r suivant une loi binomiale

☞ Rappeler la définition, la loi et les résultats concernant la loi binomiale

$$X \hookrightarrow \mathcal{B}(n, p) \iff X(\Omega) = \quad , \quad P(X = \quad) = \quad , \quad E(X) = \quad \text{et} \quad V(X) =$$

- (1) Écrire une fonction `y=binomiale(n,p)` qui prend en argument un entier non nul `n`, un réel `p` de $]0; 1[$ et renvoie une variable `y` résultat de la simulation d'une v.a.r de loi binomiale $\mathcal{B}(n, p)$.
- (2) Écrire une fonction `v=SampleBinomiale(N,n,p)` qui prend en argument deux entiers non nuls `N` et `n`, un réel `p` entre 0 et 1 et renvoie un vecteur ligne `v` contenant le résultat de la simulation de `N` v.a.r indépendantes de loi $\mathcal{B}(n, p)$.
- (3) Évaluer `U=SampleBionmiale(1000, 10, 0.3)`. Comparer la moyenne et la variance empiriques aux valeurs théoriques. Calculer de deux façons l'écart-type. Détailler les commandes permettant d'obtenir le tracé d'un diagramme des effectifs à l'aide de la fonction `bar`.
- (4) Comment peut-on obtenir le même résultat en faisant appel à la fonction `histplot`?
- (5) Que font les commandes suivantes?

```
m=tabul(U, "i");
effc=cumsum(m(:,2) );
frec=effc/sum(m(:, 2));
```

Remarque 1. La fonction `histplot` convient davantage à des v.a.r à densité. Par exemple, l'appel `histplot(0:n, sampleBinomiale(N, n, p))` ne convient pas : Scilab considère alors que la première classe est $[0; 1]$ (et non pas $[0; 1[$!).

1.3 Simulation d'une v.a.r suivant une loi géométrique

☞ Rappeler la définition, la loi et les résultats concernant la loi binomiale

$$X \hookrightarrow \mathcal{G}(p) \iff X(\Omega) = \quad , \quad P(X = \quad) = \quad , \quad E(X) = \quad \text{et} \quad V(X) =$$

☞ On considère la fonction ci-dessous, que l'on recopiera et enregistrera sous le nom `geometrique.sci`. Que fait-elle ? Est-on sûr que cette fonction s'arrête toujours?

```
function y = geometrique (p)
    r=bernoulli(p);
    y = 1;
    while r >= p
        y = y+1;
        r=bernoulli(p);
    end
endfunction
```

- (1) Écrire une fonction `v=SampleGeometrique(N,p)` qui prend en paramètre un entier `N` non nul, un réel `p` de $]0; 1[$ et renvoie un vecteur ligne `v` contenant le résultat de la simulation de `N` v.A.R indépendantes de loi $\mathcal{G}(p)$.
- (2) Évaluer `U=SampleGeometrique(1000, 0.4)`. Comparer les moyenne et variance empiriques aux valeurs théoriques.
- (3) Détailler les commandes permettant d'obtenir le tracé d'un diagramme des effectifs à l'aide de la fonction `bar`.

(4) Peut-on obtenir le même résultat en utilisant la fonction `histplot`?

2 Simulation de v.a.r suivant une loi discrète à laide de la fonction `grand()`

☞ Compléter le texte ci-dessous

- `grand(1,N, ,a,b)` génère 1 échantillon de N nombres aléatoires suivant la loi $\mathcal{U}([a; b])$.
- `grand(,)` génère m échantillons de N nombres aléatoires suivant la loi $\mathcal{U}([a; b])$.

- `grand(1,N,"bin",n,p)` génère 1 échantillon de N nombres aléatoires suivant la loi .
- `grand(,)` génère m échantillon de N nombres aléatoires suivant la loi .

- `grand(1,N,"geom",n,p)` génère 1 échantillon de N nombres aléatoires suivant la loi .
- `grand(,)` génère m échantillon de N nombres aléatoires suivant la loi .

- `grand(1,N, ,lam)` génère 1 échantillon de N nombres aléatoires suivant la loi $\mathcal{P}(lam)$.
- `grand(,)` génère m échantillons de N nombres aléatoires suivant la loi $\mathcal{P}(lam)$.

2.1 Comparaisons de distributions

- (1) Écrire un programme (et l'enregistrer sous le nom `distrib_geom.sce`) qui
 - demande à l'utilisateur d'entrer la valeur d'un paramètre p ;
 - demande à l'utilisateur d'entrer la valeur d'un paramètre N ;
 - réalise la simulation d'un échantillon de N v.a.r. indépendantes de loi géométrique $\mathcal{G}(p)$ (on stocke le résultat obtenu dans une variable `obs`);
 - trace le diagramme des effectifs de cette simulation.

- (2) Ajouter `width=0.4, 'red'` dans l'appel à la fonction `bar`. À quoi servent ces arguments optionnels?

- (3) Comment modifier le programme précédent afin d'obtenir le diagramme des fréquences ? Le faire.

- (4) On ajoute les lignes suivantes

```
x = 1:10
y = (1-p) ^ (x-1) * p
bar(x, y, width=0.4)
```

- (a) Que contient la variable `y`? Que cela représente-t-il pour une v.a.r X telle que $X \hookrightarrow \mathcal{G}(p)$?
 - (b) Représenter simultanément les diagrammes à bâtons des valeurs théoriques et empiriques. On ajustera le programme afin d'éviter toute superposition des bâtons.
- (5) Écrire un programme `distrib_poisson.sce` analogue au précédent pour la loi de Poisson et comparer une fois encore les diagrammes des valeurs théoriques et empiriques.
 - ☞ Afin de calculer les valeurs théoriques de la loi de Poisson, on pourra écrire sa propre fonction `facto()` pour calculer $k!$.

3 Autres exercices

Exercice 1. (Diagramme circulaire) On considère les commandes suivantes (que l'on recopiera et exécutera) permettant de générer une série statistique

```
n=input("n=?");
X=grand(1,n,"bin",10,0.5)
```

Écrire des commandes permettant de tracer le *diagramme circulaire* associé à cette série à l'aide de la commande `pie`.

☞ On précisera comment fonctionne l'instruction `pie`.

Exercice 2. (Simulation d'une loi usuelle, regroupement par classes) On lance 6 pièces équilibrées et on note X le nombre de *pile* obtenus.

- (1) Écrire une séquence SciLab qui crée une liste x de 40 simulations de la variable aléatoire X .
- (2) Taper l'instruction ci dessous et expliquer ce qu'elle fait.

```
[I, 0, N] = dsearch(x, [-.5:1:6.5])
```

☞ On précisera comment fonctionne l'instruction `dsearch`.

Exercice 3. (Poolage sanguin, d'après **CCIP 1994**) On étudie une méthode de détection des porteurs d'un parasite au sein d'un ensemble donné de N individus tirés au sort. La probabilité d'être porteur du parasite dans la population est $p \in]0; 1[$. Les personnes sont atteintes indépendamment les unes des autres.

On dispose d'un test permettant d'établir de façon certaine qu'un échantillon de sang contient ou non le parasite, le résultat de ce test étant dit positif dans le premier cas et négatif dans le second.

Pour chacun des N individus, on possède un prélèvement sanguin. On envisage alors deux méthodes de détection:

- Première méthode: on teste un à un les N prélèvements, effectuant ainsi N tests.
- Seconde méthode (*poolage*):
 - On fixe un entier naturel non nul ℓ . On suppose que N est un multiple de ℓ et on pose $N = n \times \ell$. On répartit alors les N prélèvements en n groupes G_1, G_2, \dots, G_n , chaque groupe G_i contenant le même nombre ℓ de prélèvements. Pour chacun des groupes G_i , on extrait une quantité de sang de chacun des ℓ prélèvements qu'il contient, puis on mélange ces extraits, obtenant ainsi un échantillon de sang H_i , caractéristique du groupe G_i .
 - On teste alors H_i :
 - si le test de H_i est négatif, aucun des individus au sein du groupe G_i n'est porteur du parasite. Le travail sur le groupe G_i est alors terminé;
 - si le test de H_i est positif, on teste un à un les prélèvements de G_i pour détecter les porteurs du parasite au sein du groupe G_i .

Soient X la variable aléatoire égale au nombre de groupes G_i pour lesquels le test de H_i a été positif et T la variable aléatoire égale au nombre total de tests effectués dans la réalisation de la méthode du poolage.

- (1) Écrire une fonction `y=pool(1,p)` simulant le test sur un groupe de taille ℓ (avec probabilité p de contamination de chaque individu). (La fonction renverra 0 ou 1 selon que le test est négatif ou non).
- (2) Écrire alors une fonction `y=poolage_sanguin(N,p)` renvoyant le résultat de la simulation de X et N .
- (3) Quelle est, en moyenne, la méthode la plus avantageuse?

Exercice 4. (D'après **ECRICOME 2017**) Soit n un entier naturel non nul.

On effectue une série illimitée de tirages d'une boule avec remise dans une urne contenant n boules numérotées de 1 à n . On considère la variable aléatoire T_n égale au nombre de tirages nécessaires pour que, pour la première fois, la somme des numéros des boules obtenues soit supérieure ou égale à n . Soit également Y une variable aléatoire à valeurs dans \mathbb{N}^* telle que:

$$\forall k \in \mathbb{N}^*, P(Y = k) = \frac{k-1}{k!}.$$

(1) Écrire une fonction `y=T(n)` permettant de simuler la variable T_n .

On peut montrer (et en fait le sujet le demandait) que (T_n) converge en loi vers T , c'est à dire que, tout entier naturel k non nul,

$$\lim_{n \rightarrow +\infty} P(T_n = k) = P(Y = k).$$

(2) Recopier et exécuter le script suivant pour les valeurs de n suivantes:

$$n = 5, \quad n = 10, \quad n = 50, \quad n = 100, \quad n = 1000.$$

```
function y=freqT(n)
    y=zeros(1,n);
    for i=1:100000
        k=T(n);
        y(k)=y(k)+1;
    end
    y=y/100000;
endfunction

function y=loitheoY(n)
    y=zeros(1,n);
    for i=1:n
        y(i)=(i-1)/prod(1:i);
    end
endfunction

n=input('n=?');
plot2d(loitheoY(6), -2)
x=freqT(n)
bar(x(1:5), .05)
```

(3) Expliquer ce que représentent les vecteurs renvoyés par les fonctions `freqT` et `loitheoY`. Comment ces vecteurs sont-ils représentés graphiquement dans chaque graphique obtenu ?

(4) Expliquer en quoi cette succession de graphiques permet d'illustrer le résultat susnommé?

Exercice 5. (D'après **ECRICOME 2015**)

On effectue des tirages **sans remise** une urne U contenant $(N - 1)$ boules blanches ($N \geq 3$) et une boule noire, jusqu'à l'obtention de la boule noire.

On note X la variable aléatoire qui prend pour valeur le nombre de tirages nécessaires pour l'obtention de la boule noire.

On notera pour tout entier naturel i non nul:

- N_i l'événement "on tire une boule noire lors du i -ième tirage" .
- B_i l'événement "on tire une boule blanche lors du i -ième tirage".

(1) On simule 10000 fois cette expérience aléatoire.

Recopier et compléter le programme SciLab suivant pour qu'il affiche l'histogramme donnant la fréquence d'apparition du rang d'obtention de la boule noire:

```
N=input('N=?');
S=zeros(1, N);
for k= 1 : 10000
    i=1;
    M=N;
    while .....
        i=i+1;
        M=.....
    end
    S(i)=S(i)+1;
end
disp(S / 10000)
bar(S / 10000)
```

(2) Exécuter le programme complété ci-dessus en entrant 5 au clavier. Quelle conjecture pouvez-vous émettre sur la loi de la variable aléatoire X à partir de l'histogramme obtenu?

Exercice 6. (D'après EDHEC 2004)

On désigne par n un entier naturel supérieur ou égal à 2. On lance n fois une pièce équilibrée (c'est-à-dire donnant *pile* avec la probabilité $1/2$ et *face* également avec la probabilité $1/2$), les lancers étant supposés indépendants.

On note Z la variable aléatoire qui vaut 0 si l'on n'obtient aucun pile pendant ces n lancers et qui, dans le cas contraire, prend pour valeur le rang du premier pile.

Recopier et compléter le programme suivant pour qu'il renvoie une simulation de la variable aléatoire Z .

```
function y=EDHEC2004(n)
    y=0;
    i=1;
    while y==0 & i<n
        r=.....
        if ..... then
            y=.....
        end
        i=i+1;
    end
endfunction
```

Exercice 7. (D'après HEC 2014) Si X est une v.a.r, on appelle *médiane* de X , tout réel m vérifiant les deux conditions:

$$P(X \leq m) \geq \frac{1}{2} \quad \text{et} \quad P(X \geq m) \geq \frac{1}{2}.$$

On admet qu'un tel réel m existe toujours. Soit N un entier supérieur ou égal à 1. Soit X une variable aléatoire discrète à valeurs dans $\llbracket 1; \rrbracket$.

La loi d'une telle variable X est stockée dans un vecteur ligne X de longueur N . Écrire une fonction `y=mediane(X)` prenant en argument un vecteur ligne X et renvoyant la médiane de X . (**Naturellement**, sans utiliser la commande `median()`.)