

## Initiation au calcul numérique – TP Proba. 2

### Simulation de variables aléatoires discrètes

Les exercices marqués d'un astérisque sont à réaliser en **priorité**.

Avant de commencer ce TP, créer un sous-répertoire `TP_Proba_2`, et créer un script (vide) `TP.m` dans ce sous-répertoire.

Dans ce TP, on va s'intéresser à la façon de **simuler des lois discrètes**. Rappelons que la fonction `rand` d'Octave fournit des réalisations de variables aléatoires de loi uniforme sur  $[0, 1]$ . C'est à partir de cette fonction que l'on va chercher à obtenir des variables suivant n'importe quelle loi prescrite.

On verra ensuite comment valider les tirages obtenus en estimant leur loi par méthode de Monte-Carlo sous forme d'histogramme.

Enfin, on appliquera tout cela pour étudier numériquement le modèle d'**urne d'Ehrenfest**, qui a joué un rôle important dans l'histoire de la thermodynamique (et qui sera étudié mathématiquement en MACS 2).

## 1 Lois discrètes quelconques, lois classiques

On rappelle que définir une probabilité sur un ensemble dénombrable  $D$  (c'est-à-dire une loi discrète) revient à se donner une famille  $(p_i)_{i \in D}$  de réels positifs tels que

$$\sum_{i \in D} p_i = 1.$$

On dit alors que  $X$  a pour loi  $(p_i)_{i \in D}$  si  $X$  est une v.a. à valeurs dans  $D$  et  $P(X = i) = p_i$  pour tout  $i \in D$ .

*N.B. Rigoureusement, la loi est  $\mu = \sum_{i \in D} p_i \delta_i$ , mais on l'assimile souvent, pour simplifier, à la famille  $(p_i)_{i \in D}$ .*

### Exercice 1\* : Simulation d'une loi quelconque sur $\mathbb{N}$

Soit  $(p_n)_{n \in \mathbb{N}}$  une probabilité sur  $\mathbb{N}$ . Le cas d'une probabilité sur  $\{0, 1, \dots, N\}$  correspond au cas où  $p_n = 0$  pour tout  $n > N$ . On va utiliser la propriété suivante pour simuler une variable aléatoire de loi  $(p_n)_{n \in \mathbb{N}}$  :

**Proposition 1.1.** Soit  $U$  une variable aléatoire de loi uniforme sur  $[0, 1]$ . On définit

$$X = \min\{k \geq 0 \mid U < p_0 + p_1 + \dots + p_k\}$$

Alors  $X$  a pour loi  $(p_n)_{n \in \mathbb{N}}$ .

On commence par démontrer cette propriété.

- À quelle condition sur  $U$  a-t-on  $X = 0$ ? En déduire  $P(X = 0)$ .
- Plus généralement, pour  $k \geq 1$ , à quelle condition sur  $U$  a-t-on  $X = k$ ? En déduire  $P(X = k)$ . Conclure.
- Écrire une fonction `x=simul_discrete(vp)` qui, étant donné un vecteur `vp=[p0 p1 ... pn]` dont la somme vaut 1, renvoie une valeur aléatoire (à valeurs dans  $\{0, 1, \dots, n\}$ ) qui suit la loi donnée par `vp`.
- (Écrire dans `TP.m`) Utiliser la fonction précédente pour remplir un vecteur `tirage1` avec 10000 valeurs aléatoires indépendantes, de loi donnée par le vecteur  $p = (0.1, 0.5, 0.25, 0.15)$ .
- On calcule un vecteur qui servira ensuite. Définir une fonction `vp=binomiale(n,p)` qui, étant donné  $n$  entier et  $p \in [0, 1]$ , renvoie le vecteur

$$[p_0 \ p_1 \ \dots \ p_n] = \left[ \binom{n}{0} p^0 (1-p)^n, \binom{n}{1} p^1 (1-p)^{n-1}, \dots, \binom{n}{n} p^n (1-p)^0 \right]$$

On pourra utiliser la fonction Octave `nchoosek(n,k)` qui renvoie  $\binom{n}{k}$ .

En déduire une fonction `vx=simul_binomiale(n,p,nb)` qui renvoie un vecteur de `nb` tirages indépendants de loi  $\mathcal{B}(n, p)$ .

- (Écrire dans `TP.m`) La loi binomiale  $\mathcal{B}(n, p)$  est la loi  $(p_k)_{0 \leq k \leq n}$  donnée par  $p_k = \binom{n}{k} p^k (1-p)^{n-k}$  pour  $k = 0, \dots, n$ . Remplir un tableau `tirage2` avec 10000 valeurs aléatoires indépendantes, de loi binomiale  $\mathcal{B}(10, 0.4)$ .

- La loi géométrique  $\mathcal{G}(p)$  est la loi  $(p_k)_{k \geq 1}$  donnée par  $p_k = (1-p)^{k-1} p$  pour  $k = 1, 2, \dots$  (et donc  $p_0 = 0$ ). Vérifier qu'on a  $p_0 + \dots + p_k = 1 - (1-p)^k$  et en déduire que  $X = \lfloor \frac{\ln(1-U)}{\ln(1-p)} \rfloor + 1$  dans la Proposition 1.1. En déduire une fonction `x=simul_geometrique(p)` qui, étant donné  $p \in (0, 1]$ , renvoie une réalisation d'une variable de loi géométrique  $\mathcal{G}(p)$ .

- (Écrire dans `TP.m`) Remplir un tableau `tirage3` avec 10000 valeurs aléatoires indépendantes, de loi géométrique  $\mathcal{G}(0.4)$ .

## Exercice 2\* : Estimer des probabilités

Répondre aux questions suivantes dans un script `estim_proba.m`, qui fera afficher les résultats.

1. À l'aide de la méthode de Monte-Carlo, estimer la probabilité  $P(X > 7)$ , où  $X$  suit la loi  $\mathcal{B}(20, 0.4)$ .
2. À l'aide de la méthode de Monte-Carlo, estimer la probabilité  $P(X > Y^2)$ , où  $X$  suit la loi  $\mathcal{B}(20, 0.4)$ ,  $Y$  suit la loi uniforme sur  $\{1, 2, 3, 4, 5\}$ , et  $X$  et  $Y$  sont indépendantes.

## Exercice 3\* : Estimer des espérances

Répondre aux questions suivantes dans un script `estim_espe.m`, qui fera afficher les résultats.

1. À l'aide de la méthode de Monte-Carlo, estimer l'espérance  $E[\sqrt{X}]$ , où  $X$  suit la loi  $\mathcal{G}(0.3)$ .
2. À l'aide de la méthode de Monte-Carlo, estimer l'espérance  $E\left[\frac{X}{X+Y}\right]$  où  $X$  et  $Y$  suivent la loi  $\mathcal{G}(0.5)$  et sont indépendantes.
3. À l'aide de la méthode de Monte-Carlo, estimer l'espérance  $E\left[\min\{k \geq 1 \mid X_1 + \dots + X_k > 20\}\right]$  où  $X_1, X_2, \dots$  suivent la loi uniforme sur  $\{1, 2, 3, 4, 5, 6\}$  et sont indépendantes.
4. À l'aide de la méthode de Monte-Carlo, estimer l'espérance de la plus grande valeur propre de la matrice  $AA^T$  où  $A$  est une matrice aléatoire  $5 \times 5$  symétrique dont les coefficients sont indépendants et de loi uniforme sur  $[-1, 1]$ . (Avec `eig`)

## Exercice 4 : Simulation de la loi binomiale (2<sup>e</sup> méthode)

On propose de simuler (à nouveau) la loi binomiale de paramètres  $n$  et  $p$  à l'aide de sa propriété principale :

**Proposition 1.2.** Soit  $n \in \mathbb{N}$ ,  $p \in [0, 1]$ . Si  $X_1, \dots, X_n$  sont des variables aléatoires indépendantes, qui suivent toutes la loi de Bernoulli de paramètre  $p$ , alors  $S = X_1 + \dots + X_n$  suit la loi binomiale de paramètres  $n$  et  $p$ .

On rappelle que la loi de Bernoulli de paramètre  $p$  est la loi d'une v.a.  $X$  telle que  $P(X = 1) = p$  et  $P(X = 0) = 1 - p$ . On rappelle aussi que, si  $U$  suit la loi uniforme sur  $[0, 1]$ , alors la v.a.  $\mathbf{1}_{\{U \leq p\}}$  suit la loi de Bernoulli de paramètre  $p$ .

1. Grâce à cette proposition, définir une fonction `x=simul_binomiale2(n,p)` qui renvoie une réalisation d'une variable de loi  $\mathcal{B}(n, p)$ .
2. (Écrire dans `TP.m`) Remplir un tableau `tirage4` avec 10000 valeurs aléatoires indépendantes, de loi binomiale  $\mathcal{B}(10, 0.4)$ .

## Exercice 5 : Simulation de la loi géométrique (2<sup>e</sup> méthode)

On propose de simuler (à nouveau) la loi géométrique de paramètre  $p$  à l'aide de sa propriété principale :

**Proposition 1.3.** Soit  $n \in \mathbb{N}$ ,  $p \in ]0, 1]$ . Si  $X_1, X_2, \dots$  sont des variables aléatoires indépendantes, qui suivent toutes la loi de Bernoulli de paramètre  $p$ , alors  $N = \min\{n \geq 1 \mid X_n = 1\}$  suit la loi géométrique de paramètre  $p$ .

1. Grâce à cette proposition, définir une fonction `x=simul_geometrique2(p)` qui renvoie une réalisation d'une variable de loi  $\mathcal{G}(p)$ .
2. (Écrire dans `TP.m`) Remplir un tableau `tirage5` avec 10000 valeurs aléatoires indépendantes, de loi géométrique  $\mathcal{G}(0.4)$ .

## 2 Estimation de loi discrète par histogramme

On souhaite utiliser la méthode de Monte-Carlo pour s'assurer que les programmes écrits dans la première partie renvoient des résultats compatibles avec les lois de probabilités simulées.

On utilise d'abord une validation "graphique", à l'aide d'histogrammes, pour représenter la proportion de tirages égaux à chacune des valeurs possibles.

Par la loi des grands nombres, si  $X_1, X_2, \dots$  sont indépendantes et suivent la même loi  $p = (p_n)_{n \in \mathbb{N}}$  sur  $\mathbb{N}$ , alors pour tout  $k \in \mathbb{N}$ ,

$$\frac{\text{nombre de variables égales à } k \text{ parmi } X_1, \dots, X_N}{N} \xrightarrow[N \rightarrow \infty]{} p_k \quad \text{presque sûrement.}$$

Autrement dit, l'histogramme converge, si on représente un **histogramme normalisé** : la hauteur de la barre centrée en  $k$  doit être égale à la *proportion* des données égales à  $k$  (par défaut, l'histogramme donne le *nombre* de telles données).

Pour obtenir un histogramme normalisé des données contenues dans un vecteur `v`, où les barres sont centrées au vecteur `centres` (par exemple, `centres=0:10`), on pourra utiliser :

```
nelem=hist(v,centres); % nelem contient le nombre d'éléments dans chaque classe
N=length(v); % N est le nombre total d'éléments
bar(centres,nelem/N,1);
```

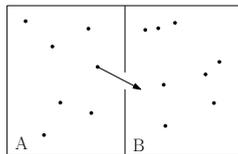
NB. Dans Octave, on peut aussi utiliser `hist(v,centres,1)` pour normaliser un histogramme de façon à sommer à 1.

## Exercice 6\* : Validation des tirages précédents

- (Écrire dans TP.m) Représenter dans une même fenêtre graphique, mais sur différents axes (avec subplot), des histogrammes des vecteurs `tirage*` obtenus précédemment. On les représentera de façon à ce que, en ordonnée, apparaisse la **proportion** de tirages égaux à chaque valeur (et non le nombre de tirages). Pour `tirage3` et `tirage4`, on représentera en abscisses les valeurs de 1 à 10.
- (Écrire dans TP.m) Modifier le script pour superposer aux graphes précédents les histogrammes des valeurs théoriques (on pourra utiliser `bar(centres, vp, 0.5, 'r')` : 0.5 représente la largeur relative la barre). Au besoin, corriger les programmes de la partie 1 qui semblent faux !
- (Écrire dans TP.m) Pour chaque jeu de tirages, calculer et faire afficher dans la fenêtre de commande la somme des différences entre les  $p_k$  et les proportions de tirages égaux à  $k$  (données par  $n\text{elem}(k)/N$ ), pour avoir une vision plus quantitative des erreurs.

## 3 Étude numérique de l'urne d'Ehrenfest

On s'intéresse à un modèle introduit par le couple de physiciens Ehrenfest au tout début du XX<sup>e</sup> siècle pour l'expérience suivante :  $M$  molécules de gaz (en pratique,  $M \simeq 10^{23}$ ...) sont réparties dans deux récipients  $A$  et  $B$  séparés par une cloison percée, et on observe l'évolution de la quantité de gaz dans le récipient  $A$ . Dans ce modèle, on représente les déplacements de molécules entre récipients de la façon suivante : après un temps fixé, une molécule choisie au hasard, uniformément parmi l'**ensemble** des molécules, et indépendamment de tout ce qui s'est déjà passé, change de récipient ; et ceci se répète indéfiniment.



Notons  $X_n$  le nombre de molécules dans  $A$  après  $n$  échanges. Alors  $(X_n)_{n \geq 0}$  se définit par récurrence :  $X_0$  est fixé (par exemple on peut choisir  $X_0 = M$ , c'est-à-dire que le récipient  $B$  est vide) et, pour tout  $n \in \mathbb{N}$ ,

$$X_{n+1} = \begin{cases} X_n - 1 & \text{avec probabilité } \frac{X_n}{M} \\ X_n + 1 & \text{avec probabilité } 1 - \frac{X_n}{M}. \end{cases}$$

En effet, la molécule qui change de récipient se trouve d'abord dans  $A$  avec probabilité  $\frac{X_n}{M}$  (il y a  $X_n$  molécules dans  $A$ , parmi les  $M$  molécules).

On souhaite étudier la composition de chaque récipient, au fil du temps : on peut s'attendre à un "équilibre", mais au bout de combien de temps, et vers quel "équilibre" ? Comme l'expérience dépend de  $M$  et  $X_0$ , on notera  $P_{M, X_0}(\cdot)$  et  $E_{M, X_0}[\cdot]$  pour la probabilité et l'espérance relatives à cette expérience.

## Exercice 7 : Convergence vers l'« équilibre »

Écrire les réponses (autres que les fonctions) dans un script `ex7.m`

- Écrire une fonction `vx=trajectoire(x0, M, n)` qui simule une réalisation de la suite des positions (ou "trajectoire")  $[X_1, \dots, X_n]$  partant de  $X_0 = x_0$  et pour  $M$  molécules.
- Représenter graphiquement le résultat pour  $X_0 = M = 100$ . Qu'observe-t-on ? (faire varier  $n$ ). Superposer sur le même graphe 5 réalisations de trajectoires. Imposer `ylim([0 M])` pour voir les valeurs de 0 à  $M$  en ordonnée.
- Écrire une fonction `t=temps_atteinte(x0, M, y)` qui simule  $X_0, X_1, \dots$ , partant de  $X_0 = x_0$ , pour  $M$  molécules, jusqu'au temps d'atteinte de  $y$  :

$$T_y = \min\{n > 0 \mid X_n = y\},$$

et renvoie la valeur de  $T_y$ .

- Par la méthode de Monte-Carlo (on prendra  $N = 1000$  seulement), estimer  $E_{M, M}[T_{M/2}]$  lorsque  $M = 100$ .

## Exercice 8 : Distribution à l'« équilibre »

Écrire les réponses (autres que les fonctions) dans un script `ex8.m`

- Dans un script séparé, `ex8A.m`, produire un vecteur `vx` contenant  $N = 1000$  réalisations de  $X_{500}$  pour  $X_0 = M = 100$ . NB. On utilise ici un script séparé pour éviter de recalculer `vx` à chaque question suivante.

2. Dans `ex8.m`, faire représenter un histogramme normalisé des valeurs obtenues. A priori, on prendra `centres=0:M`, mais on pourra adapter la plage aux valeurs significatives. Comment expliquer qu'une classe sur deux soit vide?
3. Pour faire disparaître le phénomène observé, modifier `ex8A.m` pour que  $X_0$  vale  $M$  avec probabilité  $1/2$  et  $M - 1$  avec probabilité  $1/2$  à chaque tirage, et refaire la question précédente.

### Exercice 9 : Retour au point de départ

A priori, ce modèle est **réversible**, il est en particulier possible d'avoir  $X_n = M$  (récipient  $B$  vide) pour  $n > 0$ , et on peut en fait facilement démontrer que  $X_n = M$  pour une **infinité** de valeurs de  $n$  (cf. cours de MACS 2), ce qui pourtant n'est (heureusement) jamais observé en pratique : on n'observe **jamais** de "trou d'air" spontané dans une pièce! Autrement dit, l'évolution observée est **irréversible**. Comment expliquer cette apparente contradiction (en supposant le modèle réaliste)?

1. Par la méthode de Monte-Carlo, estimer la valeur de  $E_{M,M}[T_M]$  lorsque  $M = 10$  (NB.  $T_M$  est le temps de **retour** en  $M$ ).
2. Plus généralement, représenter graphiquement les estimations (avec  $N = 100$  seulement) de  $E_{M,M}[T_M]$  lorsque  $M = 2, \dots, 10$ . Quelle est votre conclusion?