

Corrigé

1. On commence par écrire un programme Python qui donne les N premiers pas d'une marche aléatoire sur \mathbb{Z}^d , avec $d \in \{1, 2, 3, 4\}$.

```
1 from random import random
2 from copy import copy
3
4 def random_walk(n, d):
5     if d==1:
6         step = [(1, ), (-1, )]
7         pos = [0]
8     elif d==2:
9         step = [(1, 0), (-1, 0), (0, 1), (0, -1)]
10        pos = [0, 0]
11    elif d==3:
12        step = [(1, 0, 0), (-1, 0, 0), (0, 1, 0), (0, -1, 0), (0, 0, 1), (0, 0, -1)]
13        pos = [0, 0, 0]
14    elif d==4:
15        step = [(1, 0, 0, 0), (-1, 0, 0, 0), (0, 1, 0, 0), (0, -1, 0, 0),
16                (0, 0, 1, 0), (0, 0, -1, 0), (0, 0, 0, 1), (0, 0, 0, -1)]
17        pos = [0, 0, 0, 0]
18    else:
19        raise (NotImplementedError)
20    res = []
21    for k in range(n):
22        st = step[int(2*d*random())]
23        for i in range(d):
24            pos[i] += st[i]
25        res.append(copy(pos))
26    return res
```

Le programme suivant calcule alors la suite $(C_n)_{1 \leq n \leq N}$:

```
1 def Csequence(L):
2     res = []
3     visited = []
4     count = 0
5     for x in L:
6         if not (x in visited):
7             count += 1
8             visited.append(x)
9         res.append(count)
10    return res
```

Par exemple, `Csequence(random_walk(30,2))` renvoie

```
1 [1, 2, 3, 3, 4, 5, 5, 6, 6, 6, 6, 6, 7, 8, 9, 10, 11, 11, 12, 13, 13, 14,
2 15, 15, 15, 16, 17, 18, 19, 20]
```

2. D'après le Théorème 1 du texte, la suite $\frac{C_n}{n}$ converge en probabilité vers α , c'est donc un estimateur consistant de ce paramètre. Les commandes `Csequence(random_walk(10000,3))[-1]/10000` et `Csequence(random_walk(10000,4))[-1]/10000` renvoient respectivement

$$\alpha(d = 3) \simeq 0.6731;$$

$$\alpha(d = 4) \simeq 0.8172.$$


Pour $d = 3$, on est proche à 2% près du résultat théorique. Pour illustrer la convergence en probabilité de $\frac{C_n \log n}{n}$ lorsque $d = 2$, on peut dresser un histogramme de simulations des valeurs

de cette variable aléatoire avec $n = 10000$. Le petit programme suivant prend quelques minutes pour dessiner un histogramme sur 1000 essais.

```

1 import numpy, math
2 import matplotlib.pyplot as plt
3
4 plt.hist(numpy.array([ Csequence(random_walk(10000,2))[-1]
5 * math.log(10000)/10000 for i in range(1000) ]), bins="auto")
6
7 plt.show()

```



L'histogramme montre bien une concentration autour d'une valeur qui semble un peu inférieure à π ; mais ceci est dû au fait qu'on a seulement une convergence vers cette valeur, et qu'une suite convergente avec des logarithmes (ici, $\frac{C_n \log n}{n}$) a souvent une vitesse de convergence très faible (c'est typiquement ce qui se produit en théorie asymptotique des nombres).

3. Si $0 \in \{X_1, \dots, X_n\}$, alors au temps n , la marche aléatoire a visité tous les entiers compris entre m_n (négatif) et M_n (positif), donc

$$C_n = M_n - m_n + 1.$$

En fait, la relation est encore vraie si $0 \notin \{X_1, \dots, X_n\}$: dans ce cas, la marche reste tout le temps strictement positive ou strictement négative, et si l'on regarde par exemple le cas où elle reste positive, alors $m_n = 1$, et $C_n = M_n = M_n - m_n + 1$.


La formule ci-dessus implique que si $C_n \geq 2b + 1$, alors soit $M_n \geq b$, soit $-m_n \geq b$. Par symétrie, M_n et $-m_n$ ont même loi, donc

$$\mathbb{P}[C_n \geq 2b + 1] \leq \mathbb{P}[M_n \geq b] + \mathbb{P}[-m_n \geq b] = 2\mathbb{P}[M_n \geq b].$$

4. La première identité repose sur le principe de réflexion. Si $a \geq b$, alors il est clair que l'événement $\{M_n \geq b\}$ est inclus dans l'événement $\{X_n = a\}$, donc $\{M_n \geq b \text{ et } X_n = a\} = \{X_n = a\}$ et l'égalité des probabilités est claire. Si $a < b$, remarquons que

$$\begin{aligned} & \mathbb{P}[M_n \geq b \text{ et } X_n = a] \\ &= \frac{1}{2^n} \text{card} \{C \text{ chemin de longueur } n \text{ partant de } 0, \text{ finissant en } a \text{ et dépassant le niveau } b\}, \end{aligned}$$

où par chemin on entend une suite $(0 = x_0, x_1, x_2, \dots, x_n)$ d'entiers telle que $|x_i - x_{i-1}| = 1$ pour tout $i \in [1, n]$. En effet, tous les chemins de longueur n ont la même probabilité pour la distribution de pas $\mu = \frac{1}{2} \delta_1 + \frac{1}{2} \delta_{-1}$, à savoir $\frac{1}{2^n}$. Associons à un chemin C compté ci-dessus le chemin C' obtenu en réfléchissant la partie du chemin de C après le premier temps m tel que C passe par b (voir le dessin ci-dessous).



Le chemin C' ainsi obtenu est encore de longueur n , et sa position finale est $b - (a - b) = 2b - a$. Réciproquement, tout tel chemin de longueur n s'arrêtant en $2b - a$ atteint à un temps $m \leq n$ le niveau b (car $2b - a > b$), donc est obtenu par réflexion d'un chemin C finissant en a et dépassant le niveau b . On a donc :

$$\begin{aligned} & \mathbb{P}[M_n \geq b \text{ et } X_n = a] \\ &= \frac{1}{2^n} \text{card} \{C' \text{ chemin de longueur } n \text{ partant de } 0 \text{ et finissant en } 2b - a\} \\ &= \mathbb{P}[X_n = 2b - a]. \end{aligned}$$

Alors, en faisant la somme sur tous les entiers a possibles, on obtient :

$$\mathbb{P}[M_n \geq b] = \sum_{a \geq b} \mathbb{P}[X_n = a] + \sum_{a < b} \mathbb{P}[X_n = 2b - a] = \mathbb{P}[X_n \geq b] + \mathbb{P}[X_n \geq b + 1].$$

En particulier, pour tout $b \geq 1$,

$$\mathbb{P}[C_n \geq 2b + 1] \leq 2 \mathbb{P}[M_n \geq b] \leq 4 \mathbb{P}[X_n \geq b] = 2 \mathbb{P}[|X_n| \geq b].$$

Or, la variable X_n a moyenne 0 et variance n , donc par l'inégalité de Bienaymé-Chebyshev, $\mathbb{P}[|X_n| \geq b] \leq \frac{n}{b^2}$. Ainsi,

$$\mathbb{P} \left[\frac{C_n}{\sqrt{n}} \geq L \right] = O \left(\frac{1}{L^2} \right)$$


uniformément en n , et la suite de variables aléatoires $(\frac{C_n}{\sqrt{n}})_{n \geq 1}$ est tendue.

5. On dresse un histogramme de $\frac{C_n}{\sqrt{n}}$ pour $d = 1$, $n = 10000$ et $N = 10000$ essais :

```

1 def C1d(n):
2     res = list(map(lambda x : x[0], random_walk(n,1)))
3     M = max(res)
4     m = min(res)
5     return M-m+1
6
7 plt.hist(numpy.array([C1d(10000)/100 for i in range(10000)]), bins="auto")
8 plt.plot()

```



L'histogramme reste bien concentré autour de valeurs quasiment toutes plus petites que 4, et est proche d'une loi à densité sur \mathbb{R}_+ .

6. Le texte montre que

$$\mathbb{E}[(C_n)^2] \leq \sum_{1 \leq i \leq n} \alpha_i + 2 \sum_{1 \leq i < j \leq n} \alpha_i \alpha_{j-i},$$

avec $\alpha_i = \mathbb{P}[R_0^+ \geq i]$. La suite $(\alpha_i)_{i \geq 1}$ est décroissante et tend vers α . Fixons $\varepsilon > 0$, et N tel que $\alpha \leq \alpha_i \leq \alpha + \varepsilon$ si $i \geq N$. La première somme $\sum_{1 \leq i \leq n} \alpha_i$ peut simplement être majorée par n , et dans la seconde somme, les termes tels que $i \geq N$ et $j \geq i + N$ donnent une contribution plus petite que $n(n-1)(\alpha + \varepsilon)^2$. Or, le nombre de couples (i, j) tels que $i < N$ ou $j < i + N$ est plus petit que $2nN$, donc

$$\mathbb{E}[(C_n)^2] \leq n(2N + 1) + n(n-1)(\alpha + \varepsilon)^2.$$

En divisant par n , on voit donc que $\mathbb{E}[(\frac{C_n}{n})^2] \leq (\alpha + \varepsilon)^2 + O(\frac{1}{n})$ pour tout $\varepsilon > 0$, puisque N est fixé (dépendant de ε). Ceci implique bien l'estimée $\alpha^2 + o(1)$.

7. Le coefficient binomial $\binom{n+m}{l}$ compte le nombre de parties A de $[1, n+m]$ de taille l . Or, une telle partie s'écrit de manière unique sous la forme $A = A_1 \sqcup A_2$ avec $A_1 \subset [1, n]$, $A_2 \subset [n+1, n+m]$, $\text{card}(A_1) = k$, $\text{card}(A_2) = l - k$ et $0 \leq k \leq l$. Si k est fixé, alors il y a $\binom{n}{k}$ possibilités pour A_1 et $\binom{m}{l-k}$ possibilités pour A_2 . Donc,

$$\binom{n+m}{l} = \sum_{k=0}^l \text{card} \{(A_1, A_2) \mid \text{card}(A_1) = k \text{ et } \text{card}(A_2) = l - k\} = \sum_{k=0}^l \binom{n}{k} \binom{m}{l-k}.$$

8. Considérons deux marches aléatoires standards unidimensionnelles et indépendantes $(X_n)_{n \in \mathbb{N}}$ et $(X'_n)_{n \in \mathbb{N}}$. La suite $Y_n = \frac{X_n}{2}(1, 1) + \frac{X'_n}{2}(1, -1)$ est une marche aléatoire standard bidimensionnelle : en effet, chacune des 4 sommes suivantes a probabilité $\frac{1}{4}$ pour un pas $Y_{n+1} - Y_n$.

$$\begin{aligned} \frac{1}{2}(1, 1) + \frac{1}{2}(1, -1) &= (1, 0); \\ \frac{1}{2}(1, 1) - \frac{1}{2}(1, -1) &= (0, 1); \\ -\frac{1}{2}(1, 1) + \frac{1}{2}(1, -1) &= (0, -1); \\ -\frac{1}{2}(1, 1) - \frac{1}{2}(1, -1) &= (-1, 0). \end{aligned}$$

Comme $((1, 1), (1, -1))$ est une base de \mathbb{R}^2 , $Y_n = (0, 0)$ si et seulement si $X_n = 0$ et $X'_n = 0$. Ainsi,

$$\mathbb{P}[Y_n = (0, 0)] = \mathbb{P}[X_n = 0] \mathbb{P}[X'_n = 0] = (\mathbb{P}[X_n = 0])^2.$$

9. Pour l'identité reliant $G_{2,k}(z)$ à $G_2(z)$, notons $R_0^{(k)} = R_0^{(k)}((X_m)_{m \in \mathbb{N}})$ le temps de k -ième retour en 0 de la marche aléatoire $(X_m)_{m \in \mathbb{N}}$; comme la marche aléatoire standard bidimensionnelle est récurrente, $R_0^{(k)} < +\infty$ presque sûrement pour toute valeur de k . La variable aléatoire $R_0^{(k)}$ est un temps d'arrêt, et on notera $\mathcal{F}_{R_0^{(k)}}$ la sous-tribu de \mathcal{F} qui lui est associée. Pour $k \geq 2$, remarquons que

$$R_0^{(k)}((X_m)_{m \in \mathbb{N}}) = R_0^{(k-1)}((X_m)_{m \in \mathbb{N}}) + R_0^{(1)}((X_{m+R_0^{(k-1)}})_{m \in \mathbb{N}}).$$

La propriété de Markov forte assure que la chaîne décalée en temps $(X_{m+R_0^{(k-1)}})_{m \in \mathbb{N}}$ est indépendante de $\mathcal{F}_{R_0^{(k-1)}}$ et de même loi que la chaîne de départ $(X_m)_{m \in \mathbb{N}}$ (l'indépendance vient du fait que $X_{R_0^{(k-1)}} = 0$ presque sûrement, donc la loi de la chaîne décalée conditionnellement à $\mathcal{F}_{R_0^{(k-1)}}$ est constante). Alors,

$$\begin{aligned} \mathbb{P}[R_0^{(k)}((X_m)_{m \in \mathbb{N}}) = 2n] &= \sum_{n_1+n_2=n} \mathbb{P}[R_0^{(k-1)}((X_m)_{m \in \mathbb{N}}) = 2n_1 \text{ et } R_0^{(1)}((X_{m+R_0^{(k-1)}})_{m \in \mathbb{N}}) = 2n_2] \\ &= \sum_{n_1+n_2=n} \mathbb{P}[R_0^{(k-1)}((X_m)_{m \in \mathbb{N}}) = 2n_1] \mathbb{P}[R_0^{(1)}((X_m)_{m \in \mathbb{N}}) = 2n_2] \end{aligned}$$

donc les coefficients de la série génératrice $G_{2,k}$ vérifient la relation de produit de Cauchy par rapport à ceux de $G_{2,k-1}$ et G_2 . Par conséquent, par une récurrence immédiate, on a bien $G_{2,k}(z) = (G_2(z))^k$.

Pour la seconde identité, fixons z de module strictement plus petit que 1. On a

$$G_3(z) = \sum_{n=0}^{\infty} \mathbb{P}[R_0^+ > 2n] z^n,$$

la série étant absolument convergente puisque $\mathbb{P}[R_0^+ > 2n] \leq 1$. Pour tout n , $\mathbb{P}[R_0^+ > 2n] = \sum_{k>n} \mathbb{P}[R_0^+ = 2k]$, donc la famille $(\mathbb{P}[R_0^+ = 2k] z^n)_{(k,n) | k>n}$ est sommable. On peut donc la resommer par blocs :

$$\begin{aligned} G_3(z) &= \sum_{(k,n) | k>n} \mathbb{P}[R_0^+ = 2k] z^n = \sum_{k=1}^{\infty} \mathbb{P}[R_0^+ = 2k] \left(\sum_{n=0}^{k-1} z^n \right) \\ &= \frac{1}{z-1} \left(\sum_{k=1}^{\infty} \mathbb{P}[R_0^+ = 2k] (z^k - 1) \right) = \frac{G_2(z) - 1}{z-1}. \end{aligned}$$

La seconde partie de l'identité vient finalement de la Proposition 3 : $G_2(z) - 1 = -\frac{1}{G_1(z)}$.