

Feuille d'exercices 3

1 Correction de l'exercice sur la loi hypergéométrique

On interroge au hasard n individus différents dans une population de N individus dont N_1 fument et $N_2 = N - N_1$ ne fument pas. Soit X le nombre de fumeurs parmi les n interrogés.

a) Déterminer $P(X = k)$ ($0 \leq k \leq n$); calculer l'espérance et la variance de X .

b) Que se passe-t-il à la limite lorsque

i) n est fixe, $N \rightarrow \infty$ et $\frac{N_1}{N} \rightarrow p$ ($0 < p < 1$).

ii) $n, N, N_1 \rightarrow \infty$ et $\frac{nN_1}{N} \rightarrow \lambda$ ($\lambda > 0$).

Pour simplifier on suppose que $n \leq \min(N_1, N_2)$. Il s'agit d'un sondage sans remise. Commençons par dénombrer le nombre d'échantillons possibles. Il s'agit de compter le nombre de sous-ensembles à n éléments à choisir parmi $N = N_1 + N_2$. Il y a donc C_N^n possibilités. Soit k un entier naturel inférieur à n . Le nombre d'échantillons qui contiennent exactement k fumeurs est $C_{N_1}^k C_{N_2}^{n-k}$. En effet, il faut choisir k fumeurs parmi N_1 puis $n - k$ non fumeurs parmi N_2 . La loi de X est donc donnée par

$$P(X = k) = \frac{C_{N_1}^k C_{N_2}^{n-k}}{C_N^n}. \quad (1)$$

Calculons maintenant les deux premiers moments de X .

• Première méthode

Pour un ordre donné de $\{1, 2, \dots, n\}$, on utilise la décomposition de X

$$X = \sum_{i=1}^n Y_i \quad \text{où } Y_i = 1 \text{ si le } i\text{-ème individu fume} \quad Y_i = 0 \text{ sinon} \quad (i = 1, 2, \dots, n).$$

Les variables aléatoires $(Y_i)_{i=1, \dots, n}$ ont toutes la même loi mais ne sont pas indépendantes. Par les mêmes arguments que ceux utilisés pour établir (1), on montre que pour $i, j \in \{1, \dots, n\}$ avec $i \neq j$ on a

$$\begin{aligned} E(Y_i^2) &= E(Y_i) = P(Y_i = 1) = \frac{N_1}{N}, \\ E(Y_i Y_j) &= P(Y_i = 1, Y_j = 1) = \frac{C_{N_1}^2 C_{N_2}^0}{C_N^2} = \frac{N_1(N_1 - 1)}{N(N - 1)}. \end{aligned}$$

Donc

$$E(X) = E\left(\sum_{i=1}^n Y_i\right) = \sum_{i=1}^n E(Y_i) = \frac{nN_1}{N}, \quad (2)$$

et

$$E(X^2) = E \left[\left(\sum_{i=1}^n Y_i \right)^2 \right] = \sum_{i=1}^n E(Y_i) + 2 \sum_{1 \leq i < j \leq n} E(Y_i Y_j) = \frac{nN_1}{N} + \frac{n(n-1)N_1(N_1-1)}{N(N-1)}.$$

Après factorisation, on en déduit

$$\begin{aligned} \text{Var } X = E(X^2) - (E(X))^2 &= \frac{nN_1}{N} + \frac{n(n-1)N_1(N_1-1)}{N(N-1)} - \left(\frac{nN_1}{N} \right)^2 \\ &= \frac{nN_1N_2(N-n)}{N^2(N-1)}. \end{aligned} \quad (3)$$

• Deuxième méthode

On a pour $n, N_1 \geq 1$,

$$E(X) = \sum_{k=0}^n k P(X = k) = \sum_{k=0}^n k \frac{C_{N_1}^k C_{N_2}^{n-k}}{C_N^n} = \frac{nN_1}{N} \sum_{j=0}^{n-1} \frac{C_{N_1-1}^j C_{N_2}^{n-1-j}}{C_{N-1}^{n-1}} = \frac{nN_1}{N}.$$

En effet, l'égalité $\sum_{j=0}^{n-1} \frac{C_{N_1-1}^j C_{N_2}^{n-1-j}}{C_{N-1}^{n-1}} = 1$ s'obtient en considérant l'équation de normalisation pour la loi hypergéométrique de paramètres $N_1 - 1, N_2, n - 1$. Par le même raisonnement on obtient d'autre part pour $n, N_1 \geq 2$

$$\begin{aligned} E[X(X-1)] &= \sum_{k=0}^n k(k-1) P(X = k) = \sum_{k=0}^n k(k-1) \frac{C_{N_1}^k C_{N_2}^{n-k}}{C_N^n} \\ &= \frac{nN_1(n-1)(N_1-1)}{N(N-1)} \sum_{j=0}^{n-2} \frac{C_{N_1-2}^j C_{N_2}^{n-2-j}}{C_{N-2}^{n-2}} = \frac{nN_1(n-1)(N_1-1)}{N(N-1)}. \end{aligned}$$

D'où

$$\begin{aligned} \text{Var } X = E[X(X-1)] + E(X)[1 - E(X)] &= \frac{nN_1(n-1)(N_1-1)}{N(N-1)} + \frac{nN_1}{N} \left(1 - \frac{nN_1}{N} \right) \\ &= \frac{nN_1N_2(N-n)}{N^2(N-1)}. \end{aligned}$$

On retrouve donc bien, en utilisant cette méthode, les résultats (2) et (3).

Etudions maintenant les propriétés asymptotiques de la loi hypergéométrique.

- i) n est fixe, $N \rightarrow \infty$ et $\frac{N_1}{N} \rightarrow p$ ($0 < p < 1$). On s'attend intuitivement à trouver la loi d'échantillonnage pour un tirage avec remise. C'est-à-dire la loi binomiale. On a pour $k \in \{0, \dots, n\}$

$$\begin{aligned} P(X = k) &= \frac{C_{N_1}^k C_{N_2}^{n-k}}{C_N^n} \\ &= C_n^k \frac{N_1(N_1-1)\cdots(N_1-k+1)N_2(N_2-1)\cdots(N_2-n+k+1)}{N(N-1)\cdots(N-n+1)} \\ &= C_n^k \left(\frac{N_1}{N} \right)^k \left(\frac{N_2}{N} \right)^{n-k} \frac{\left(1 - \frac{1}{N_1} \right) \cdots \left(1 - \frac{k-1}{N_1} \right) \left(1 - \frac{1}{N_2} \right) \cdots \left(1 - \frac{n-k-1}{N_2} \right)}{\left(1 - \frac{1}{N} \right) \cdots \left(1 - \frac{n-1}{N} \right)}. \end{aligned}$$

On trouve finalement

$$\lim_{N \rightarrow \infty} P(X = k) = C_n^k p^k (1-p)^{n-k}.$$

C'est la loi binomiale de paramètres n, p .

ii) $n, N, N_1 \rightarrow \infty$ et $\frac{nN_1}{N} \rightarrow \lambda$ ($\lambda > 0$). On écrit ici

$$\begin{aligned} P(X = 0) &= \frac{C_{N_1}^0 C_{N_2}^n}{C_N^n} = \frac{(N - N_1)(N - 1 - N_1) \cdots (N - n + 1 - N_1)}{N(N - 1) \cdots (N - n + 1)} \\ &= \left(1 - \frac{N_1}{N}\right) \left(1 - \frac{N_1}{N - 1}\right) \cdots \left(1 - \frac{N_1}{N - n + 1}\right). \end{aligned}$$

D'où

$$\left(1 - \frac{N_1}{N}\right)^n \geq P(X = 0) \geq \left(1 - \frac{N_1}{N - n + 1}\right)^n.$$

En passant à la limite dans ces inégalités on obtient $\lim_{N \rightarrow \infty} P(X = 0) = \exp(-\lambda)$.
D'autre part pour $k \in \mathbb{N}$

$$\frac{P(X = k + 1)}{P(X = k)} = \frac{(n - k)(N_1 - k)}{(k + 1)(N_2 - n + k + 1)} = \left(\frac{nN_1}{N}\right) \left(\frac{1}{k + 1}\right) \frac{\left(1 - \frac{k}{N_1}\right) \left(1 - \frac{k}{n}\right)}{1 - \frac{N_1 + n - k - 1}{N}}.$$

On en déduit que

$$\lim_{N \rightarrow \infty} \frac{P(X = k + 1)}{P(X = k)} = \frac{\lambda}{k + 1}.$$

Par suite

$$\lim_{N \rightarrow \infty} P(X = k) = \exp(-\lambda) \frac{\lambda^k}{k!},$$

il s'agit de la loi de Poisson de paramètre λ .

2 Modèles binomiaux et de Poisson

- 1) Pour estimer la taille d'une population animale, on installe successivement r trappes. Soit q la probabilité qu'un animal soit capturé par une trappe et N la taille de la population avant l'expérience.
 - a) Supposant que les animaux capturés ne sont pas relâchés, donner la probabilité que les effectifs de capture soient n_1, \dots, n_r .
 - b) Une méthode alternative consiste à relâcher les animaux après *marquage*. Donner la probabilité que les effectifs des captures soient n_1, \dots, n_r et que les effectifs d'animaux recapturés soient m_1, \dots, m_{r-1} .
- 2) Soit une population à k modalités en proportions p_1, \dots, p_k . On en tire n individus (avec remise). Déterminer la loi de (n_1, \dots, n_k) , nombres d'individus prenant les modalités $1, \dots, k$. En déduire la loi marginale de n_1 .

- 3) La ville de Londres étant divisée en 576 districts, on a relevé le nombre d'impacts de bombes subi par chaque district pendant la seconde guerre mondiale. Les résultats sont donnés dans le tableau suivant :

k	0	1	2	3	4	5 et plus
N_k	229	211	93	35	7	1

- a) Comment tester l'adéquation de ces observations à une loi de Poisson? (On rappelle que, si $Z \sim \chi^2(4)$ alors $P(Z \leq 7.8) = 0.9$ et $P(Z \leq 9.5) = 0.95$)
- b) Si l'adéquation à une loi de Poisson est acceptable, donner la probabilité que la dernière observation vaille 6.

3 Approximation de Poisson de De Moivre

- 1) Trouver la probabilité (approximative) que, sur 500 personnes, $k = 0, 1, 2, 3$ aient leur anniversaire le 20 janvier.
- 2) Une compagnie de téléphone déservant 2000 abonnés cherche à déterminer le nombre N de lignes nécessaires pour que le réseaux ne soit saturé qu'avec une probabilité inférieure à 1%. En moyenne, chaque utilisateur donne un appel de deux minutes toutes les heures. Déterminer N_{\min} en utilisant l'approximation de De Moivre.
- 3) On effectue une enquête, durant une épidémie de grippe, dans le but de connaître la proportion p de personnes présentant ensuite des complications graves. On observe un échantillon représentatif de 400 personnes et pour un tel échantillon 40 personnes ont présenté des complications.
- a) Donner un intervalle de confiance pour p au risque 5%.
- b) On désire que la valeur estimée \hat{p} diffère de la proportion inconnue exacte p de moins de 0,005 avec une probabilité égale à 95%. Quel sera l'effectif d'un tel échantillon?
- c) Quel devrait être le risque pour obtenir le même intervalle qu'à la question précédente en conservant l'effectif $n = 400$. Quelles conclusions peut-on en tirer?
- 4) Soit $N_n \sim \mathcal{B}(n, p)$. On note

$$N_n^* = \frac{N_n - np}{\sqrt{np(1-p)}}.$$

Construire la transformée de Laplace de N_n^* , $M_n(t) = \mathbb{E}[\exp(tN_n^*)]$ et déduire de l'inégalité de Markov,

$$P(N_n^* \geq s) \leq M_n(t)e^{-ts} \quad (s, t > 0),$$

une majoration de $P(N_n^* \geq s)$.

4 Introduction à l'estimation

On considère X_1, X_2, \dots, X_n des variables aléatoires i.i.d. de loi de Poisson de paramètre θ inconnu, $\theta \in [0, \infty[$.

- 1) On cherche à estimer θ .
 - a) L'estimateur $\bar{X} = \frac{X_1 + \dots + X_n}{n}$ est-il d'espérance θ (sans biais)? Que vaut $E(\bar{X} - \theta)^2$ (risque quadratique)?
 - b) Montrer que, pour tout estimateur sans biais $h(X_1, \dots, X_n)$, il existe un estimateur $\hat{h}(X_1 + \dots + X_n)$ de θ de risque quadratique inférieur : \bar{X} est une statistique exhaustive.
 - c) Quel est l'estimateur qui maximise la probabilité de la réalisation observée (maximum de vraisemblance)?
- 2) On cherche maintenant à estimer $e^{-l\theta}$, probabilité pour que sur l expériences futures, on observe toujours 0.
 - a) On propose l'estimateur, $e^{-l\bar{X}}$? Est-il sans biais? Quel est son risque quadratique?
 - b) Déterminer une fonction g de N dans R telle que $g(n\bar{X})$ soit un estimateur sans biais. Que se passe-t-il si on prend $n = 1$, $l = 2$?

5 Écart d'une loi de Poisson à sa moyenne

Soit N une variable aléatoire de loi de Poisson de paramètre $\lambda > 0$. Prouver que, pour tout u réel, $\exp(uN)$ a une moyenne que l'on calculera. Soit h la fonction $x \rightarrow (1+x)\log(1+x) - x$; montrer que h est positive, strictement pour $x \neq 0$. Montrer que, pour $\xi > 0$:

$$\inf_{u>0} E \left[e^{u(N-(1+\xi)\lambda)} \right] = e^{-\lambda h(\xi)} \quad \text{et} \quad P(N \geq (1+\xi)\lambda) \leq e^{-\lambda h(\xi)}.$$

Prouver de même : $P(N \leq (1-\xi)\lambda) \leq e^{-\lambda h(-\xi)}$.

6 Extinction d'une population

Soient X_1, \dots, X_n des variables entières indépendantes de même fonction génératrice $f(s) = E(s^{X_1})$. Dans ce qui suit, on convient qu'une somme comprenant 0 terme est nulle.

- 1) Soit N une variable aléatoire de loi $\mathcal{P}(\lambda)$ indépendante de X_1, \dots, X_n . On définit $S = X_1 + \dots + X_N$. Montrer que S est *infinitement divisible*, c'est-à-dire que, pour tout $m \in \mathbb{N}$, elle peut se représenter comme la somme de m variables Y_i^m i.i.d.
- 2) On suppose que les X_i sont des variables aléatoires décrivant le nombre de descendants d'une paramécie. Les descendants directs des paramécies de la génération t forment la génération $t+1$ et on note Z^t la taille de la génération t . Écrire Z^{t+1} en fonction des descendants de chaque paramécie de la génération t , $X_1^t, \dots, X_{Z^t}^t$.

- 3) Partant d'une paramécie à l'instant 0, $Z^0 = 1$, montrer que la fonction génératrice de Z^t est $f^t(s) = f(f^{t-1}(s))$ ($t > 1$). Quelle est cette fonction si X_1 suit une loi de Bernoulli?
- 4) Une caractéristique importante concerne les chances de survie de la population. Soit ρ la probabilité que la population s'éteigne et ρ_t celle qu'elle ait disparu à la génération t . Exprimer ρ_t en fonction de f et déduire de la relation de récurrence entre ρ_t et ρ_{t-1} une équation définissant ρ .
- 5) Déduire de la convexité de f que le fait que ρ soit égale à 1 dépend de $f'(1)$. Interpréter en terme de $\mathbb{E}(X_1)$.
- 6) Montrer que, si $\rho < 1$, $f^t(s)$ tend vers ρ pour tout $0 < s < 1$ et interpréter.
- 7) Considérant Y^t , nombre de descendants de la paramécie jusqu'à la génération t , déduire de

$$Y^t = 1 + Z^1 + \dots + Z^t$$

que la fonction génératrice g_t de Y^t est telle que $g_t(s) = sf(g_{t-1}(s))$.

7 La ruine du joueur

Les fluctuations d'un jeu sont souvent décrites par une suite (Y_n) de variables indépendantes égales à $+1$ ou à -1 ($+1$ pour un succès, -1 pour un échec). Le nombre de points gagnés après n jeux est donc $S_n = Y_1 + \dots + Y_n$.

On suppose $P(Y_n = +1) = p$, $P(Y_n = -1) = q$, ($p + q = 1$).

- 1) Montrer que $\frac{S_n}{n}$ converge presque sûrement vers $2p - 1$.
- 2) Calculer pour $n \geq 1$, $E \left[\left(\frac{q}{p} \right)^{S_n} \right]$ et $E(S_n)$.
- 3) Soit Γ un événement qui ne dépend que de S_1, \dots, S_k avec $1 \leq k < n$. Montrer que $E \left[\left(\frac{q}{p} \right)^{S_n} \mathbb{1}_\Gamma \right] = E \left[\left(\frac{q}{p} \right)^{S_k} \mathbb{1}_\Gamma \right]$ et $E[(S_n - n(2p - 1))\mathbb{1}_\Gamma] = E[(S_k - k(2p - 1))\mathbb{1}_\Gamma]$.
- 4) Soit ν une variable aléatoire, à valeurs dans \mathbb{N} , telle que, pour $n \geq 1$, l'événement $\{\nu = n\}$ ne dépend que de S_1, \dots, S_n . Une telle variable aléatoire s'appelle un temps d'arrêt. On suppose de plus qu'il existe un entier M strictement positif tel que $P(\nu \leq M) = 1$. Prouver

$$E \left[\left(\frac{q}{p} \right)^{S_\nu} \right] = 1, \quad E[S_\nu] = (2p - 1)E(\nu). \quad (4)$$

- 5) On considère, pour $a, b \in \mathbb{N}$, la variable aléatoire $\nu_{a,b} = \inf\{n : S_n = -a \text{ ou } S_n = b\}$. On pose ensuite, pour $M \geq 1$, $\nu_{a,b}^M = \min(M, \nu_{a,b})$. Vérifier que $\nu_{a,b}^M$ est un temps

d'arrêt et en déduire que (4) vaut pour $\nu_{a,b}$. Supposons que le joueur possède une fortune initiale égale à a . Calculer la probabilité pour que le joueur s'arrête ruiné, $P(S_{\nu_{a,b}} = -a)$, et, pour $p \neq \frac{1}{2}$, la valeur moyenne de la durée du jeu $E(\nu_{a,b})$.

6) On suppose $p = \frac{1}{2}$, prouver : $E(S_{\nu_{a,b}}^2) = E(\nu_{a,b})E(Y_1^2)$. En déduire $E(\nu_{a,b})$.