

CORRIGÉ 9

Exercice 1. (i).

$$\begin{aligned}\mathbb{E}[S_n] &= \mathbb{E}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \mathbb{E}[X_i] = n\mu, \\ \text{Var}(S_n) &= \text{Var}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \text{Var}(X_i) = n\sigma^2.\end{aligned}$$

(ii). Avec $b_n = n\mu$ et $a_n = 1/(\sqrt{n}\sigma)$ on a

$$\begin{aligned}\mathbb{E}[Z_n] &= \mathbb{E}\left[\frac{\sum_{i=1}^n X_i - n\mu}{\sqrt{n}\sigma}\right] = \frac{1}{\sqrt{n}\sigma} \left(\sum_{i=1}^n \mathbb{E}[X_i] - n\mu\right) = 0, \\ \text{Var}(Z_n) &= \text{Var}\left(\frac{\sum_{i=1}^n X_i - n\mu}{\sqrt{n}\sigma}\right) = \frac{1}{n\sigma^2} \sum_{i=1}^n \text{Var}(X_i) = 1.\end{aligned}$$

(iii).

$$\begin{aligned}\mathbb{E}[\bar{X}_n] &= \mathbb{E}\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n} \sum_{i=1}^n \mathbb{E}[X_i] = \mu, \\ \text{Var}(\bar{X}_n) &= \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \frac{\sigma^2}{n}.\end{aligned}$$

(iv). Avec $d_n = \mu$ et $c_n = \sqrt{n}/\sigma$ on a

$$\begin{aligned}\mathbb{E}[Z_n] &= \mathbb{E}\left[\sqrt{n} \frac{\bar{X}_n - \mu}{\sigma}\right] = \frac{\sqrt{n}}{\sigma} (\mathbb{E}[\bar{X}_n] - \mu) = 0, \\ \text{Var}(Z_n) &= \text{Var}\left(\sqrt{n} \frac{\bar{X}_n - \mu}{\sigma}\right) = \frac{n}{\sigma^2} \text{Var}(\bar{X}_n) = 1.\end{aligned}$$

- (v). On ne connaît pas la loi des X_i . Bien que l'on connaisse $\mathbb{E}[X_i]$ et $\text{Var}(X_i)$, ce n'est pas assez pour déterminer la loi de X_i .
- (vi). Puisqu'on ne connaît pas la loi de X_i , on ne sait pas quelle est la probabilité $\Pr(X_i \leq x)$, pour $x \in \mathbb{R}$. On peut seulement la borner en appliquer les inégalités de concentration comme l'inégalité de Markov ou de Chebyshev.
- (vii). Par le théorème central limite, la limite de la distribution de Z_n si $n \rightarrow \infty$ est $\mathcal{N}(0, 1)$. Donc pour n grand, la distribution de Z_n est approximativement $\mathcal{N}(0, 1)$.
- (viii). D'après la partie (vii), on a $\Pr(Z_n \leq x) \approx \Phi(x)$, où $\Phi(x)$ est la fonction de répartition de la loi $\mathcal{N}(0, 1)$. Cela montre la grande puissance du théorème central limite et le rôle central de la loi $\mathcal{N}(0, 1)$.

Exercice 2. La variable aléatoire X représente le résultat du jet d'un dé équilibré. Elle peut donc prendre comme valeur $\{1, 2, 3, 4, 5, 6\}$. La fonction de masse de X est

$$f_X(x) = 1/6,$$

pour tout x dans $\{1, 2, 3, 4, 5, 6\}$ et 0 sinon. Par définition,

$$\mathbb{E}(X) = \sum_{x=1}^6 x f_X(x) = (1 + 2 + \dots + 6)/6 = 7/2.$$

Par ailleurs, on trouve $E(X^2) = \sum_{x=1}^6 x^2 f_X(x) = 91/6$ et donc $\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2 = 91/6 - 49/4 = 35/12$. Soit X_i le résultat du i -ème dé. On cherche

$$\Pr\left(30 \leq \sum_{i=1}^{10} X_i \leq 40\right) = \Pr\left(30/10 \leq \sum_{i=1}^{10} X_i/10 \leq 40/10\right) = \Pr(3 \leq \bar{X}_n \leq 4).$$

Par le théorème centrale limite, on sait que $\bar{X}_n (= \sum_{i=1}^{10} X_i/10)$ suit approximativement une loi normale $\mathcal{N}(\mu, \sigma^2/10)$, avec $\mu = \mathbb{E}(X_i) = 7/2$ et $\sigma^2 = \text{Var}(X_i) = 35/12$. En centrant et en réduisant :

$$\begin{aligned} \Pr\left(30 \leq \sum_{i=1}^{10} X_i \leq 40\right) &= \Pr(3 \leq \bar{X}_n \leq 4) \\ &= \Pr\left(\frac{3 - \mu}{\sqrt{\sigma^2/10}} \leq \frac{\bar{X}_n - \mu}{\sqrt{\sigma^2/10}} \leq \frac{4 - \mu}{\sqrt{\sigma^2/10}}\right) \\ &\approx \Phi(\sqrt{6/7}) - \Phi(-\sqrt{6/7}) \\ &\approx 0.65. \end{aligned}$$

Exercice 3. (i). Notons p le pourcentage recherché, et considérons $p \in (0, 1)$. Si on choisit par hasard une personne parmi les étudiant-e-s de l'EPFL/UNIL, celle-ci sera une femme avec la probabilité p et un homme avec la probabilité $1 - p$. On peut définir une variable aléatoire

$$X = \begin{cases} 1 & \text{si la personne choisie est une femme,} \\ 0 & \text{si la personne choisie est un homme.} \end{cases}$$

La loi de cette variable est $\mathcal{B}(p)$.

- (ii). Le paramètre d'intérêt est p .
- (iii). Puisqu'il serait difficile d'observer toutes les personnes qui étudient à l'EPFL/UNIL, on va observer un sous-ensemble. Ce sous-ensemble doit être représentatif, par exemple on peut observer un certain nombre d'étudiant-e-s qui mangent dans une grande cafétéria pendant la pause de midi.
- (iv). Un choix intuitif est le pourcentage de femmes dans le sous-ensemble observé.
- (v). Même si on connaissait la valeur de p , on ne connaîtrait pas en avance la valeur de l'estimateur. Si l'on va dans la même cafétéria deux jours différents et l'on observe le même nombre d'étudiant-e-s, ce ne seront pas exactement les mêmes étudiant-e-s, donc on n'obtiendra pas le même résultat.

- (vi). On suppose que $p = 0.4$ et $n = 100$. D'après la partie ((i)), on peut supposer que les observations $x_1, \dots, x_{100}$ constituent une réalisation de $X_1, \dots, X_{100} \stackrel{iid}{\sim} \mathcal{B}(p)$. L'estimateur proposé dans la partie ((iv)) s'écrit $\hat{p}_{100} = \bar{X}_{100} = (\sum_{i=1}^{100} X_i)/100$.

$$\begin{aligned}\mathbb{E}[\hat{p}_{100}] &= \mathbb{E}\left(\frac{1}{100} \sum_{i=1}^{100} X_i\right) = \mathbb{E}[X_1] = p, \\ \text{Var}[\hat{p}_{100}] &= \text{Var}\left(\frac{1}{100} \sum_{i=1}^{100} X_i\right) = \frac{1}{100} \text{Var}[X_1] = \frac{p(1-p)}{100}, \\ \text{b}(\hat{p}_{100}) &= \mathbb{E}[\hat{p}_{100}] - p = 0.\end{aligned}$$

L'estimateur $\hat{p}_n$ est non-biaisé. Si la taille de l'échantillon augmente, la variance diminue alors que l'espérance ne change pas. Donc, avec un plus grand échantillon, on estime le pourcentage avec une plus grande précision (on s'attend à être plus proche de la vraie valeur).

- (vii). Remarquons tout d'abord que nous sommes ici dans la même situation que dans l'exercice 1. Les variables $X_1, \dots, X_n$ sont indépendantes et identiquement distribuées, d'espérance $\mu = p$ et de variance $\sigma^2 = p(1-p)$. Nous pouvons donc utiliser le théorème central limite pour approximer la loi de

$$Z_n = \sqrt{n} \frac{\bar{X}_n - \mu}{\sigma} = \sqrt{n} \frac{\hat{p}_n - p}{\sqrt{p(1-p)}}.$$

Pour trouver n tel que $\Pr(\hat{p}_n < 0.5) \geq 0.95$ on calcule (avec $p = 0.4$)

$$\begin{aligned}\Pr(\hat{p}_n < 0.5) &\geq 0.95 \\ \Rightarrow \Pr\left(\sqrt{n} \frac{\hat{p}_n - 0.4}{\sqrt{0.4 \times 0.6}} < \sqrt{n} \frac{0.5 - 0.4}{\sqrt{0.4 \times 0.6}}\right) &\geq 0.95 \\ \Rightarrow \Phi(0.204 \sqrt{n}) &\geq 0.95 \\ \Rightarrow \sqrt{n} &\geq \frac{\Phi^{-1}(0.95)}{0.204} \\ \Rightarrow n &\geq 65.42.\end{aligned}$$

Donc on a besoin d'observer au moins 66 personnes.

Exercice 4. Soit X_i le nombre de clients qui entrent le i ème jour. Comme X_i est une variable aléatoire suivant la loi de Poisson avec paramètre $\lambda = 12$, on a $\mathbb{E}[X_i] = 12$ et $\text{Var}(X_i) = 12$. Le nombre total de clients entrants n jours est $S_n = \sum_{i=1}^n X_i$.

Par le théorème central limite, on sait que la variable standardisée

$$Z_n = \frac{S_n - n \times 12}{\sqrt{n \times 12}}$$

suit approximativement la loi $\mathcal{N}(0, 1)$ pour n grand.

- (i). Avec $n = 22$ nous pouvons calculer

$$\begin{aligned}\Pr(S_{22} \geq 250) &= \Pr\left(\frac{S_{22} - 22 \times 12}{\sqrt{22 \times 12}} \geq \frac{250 - 22 \times 12}{\sqrt{22 \times 12}}\right) \\ &\approx 1 - \Phi\left(\frac{250 - 22 \times 12}{\sqrt{22 \times 12}}\right) = 1 - \Phi\left(-\frac{14}{\sqrt{264}}\right) = \Phi(0.862) = 0.805.\end{aligned}$$

(ii). Maintenant on cherche n tel que $\Pr(S_n \geq 250) = 0.975$. On veut donc que

$$\begin{aligned} \Pr(S_n \geq 250) &= 0.975 \\ \Leftrightarrow \Pr\left(\frac{S_n - n \times 12}{\sqrt{n \times 12}} \geq \frac{250 - n \times 12}{\sqrt{n \times 12}}\right) &= 0.975 \\ \Leftrightarrow 1 - \Phi\left(\frac{250 - n \times 12}{\sqrt{n \times 12}}\right) &= 0.975 \\ \Leftrightarrow \Phi\left(\frac{250 - n \times 12}{\sqrt{n \times 12}}\right) &= 0.025 \\ \Leftrightarrow \frac{250 - n \times 12}{\sqrt{n \times 12}} &= \Phi^{-1}(0.025) \\ \Leftrightarrow \frac{250 - n \times 12}{\sqrt{n \times 12}} &= -\Phi^{-1}(0.975) \\ \Leftrightarrow \frac{250 - n \times 12}{\sqrt{n \times 12}} &= -1.96 \\ \Leftrightarrow -n \times 12 + 1.96\sqrt{12}\sqrt{n} + 250 &= 0. \end{aligned}$$

Cela donne lieu à une équation du second degré en termes de $\sqrt{n}$, dont les solutions sont

$$\frac{-1.96\sqrt{12} \pm \sqrt{1.96^2 \times 12 + 4 \times 12 \times 250}}{-2 \times 12} = \begin{cases} 4.86 \\ -4.29 \end{cases}.$$

Puisque $\sqrt{n} \geq 0$, on obtient que $\sqrt{n} = 4.86$ et $n = 23.6$. Si le magasin ouvre ses portes pendant au moins 24 jours, il reçoit au moins 250 clients avec une probabilité plus grande que 0.975.

Exercice 5. (i). On sait que $\int_{-\infty}^{\infty} f(x) dx = 1$. Donc

$$1 = \int_0^1 c x^{\theta-1} dx = c \left[\frac{x^\theta}{\theta} \right]_0^1 = \frac{c}{\theta},$$

et on voit bien que $c = \theta$. On a donc la densité

$$f(x) = \begin{cases} \theta x^{\theta-1} & \text{si } x \in (0, 1) \\ 0 & \text{sinon.} \end{cases}$$

(ii). On a

$$\mathbb{E}[X_1] = \int_{-\infty}^{\infty} x f(x) dx = \int_0^1 x \theta x^{\theta-1} dx = \theta \int_0^1 x^\theta dx = \theta \left[\frac{x^{\theta+1}}{\theta+1} \right]_0^1 = \frac{\theta}{\theta+1}.$$

(iii). Les variables X_i sont continues, donc la fonction de vraisemblance est

$$L(\theta) = f_1(x_1; \theta) \times f_2(x_2; \theta) \times \dots \times f_n(x_n; \theta),$$

où $f_i(x_i; \theta) = f(x_i; \theta)$ est la densité pour chaque X_i . On trouve

$$L(\theta) = \theta x_1^{\theta-1} \theta x_2^{\theta-1} \dots \theta x_n^{\theta-1} = \theta^n \left(\prod_{i=1}^n x_i \right)^{\theta-1}.$$

Donc

$$\ell(\theta) = \log(L(\theta)) = n \log(\theta) + (\theta - 1) \sum_{i=1}^n \log(x_i).$$

Pour trouver la valeur de θ qui maximise $\ell(\theta)$ on résout

$$\begin{aligned} \ell'(\theta) &= 0 \\ \Leftrightarrow \frac{n}{\theta} + \sum_{i=1}^n \log(x_i) &= 0 \\ \Leftrightarrow \frac{1}{\theta} &= -\frac{1}{n} \sum_{i=1}^n \log(x_i) \\ \Leftrightarrow \theta &= -\frac{n}{\sum_{i=1}^n \log(x_i)}. \end{aligned}$$

Il s'agit bien d'un maximum puisque

$$\ell''(\theta) = -\frac{n}{\theta^2} < 0,$$

pour tout $\theta > 0$. Donc la valeur $\theta = -\frac{n}{\sum_{i=1}^n \log(x_i)}$ maximise la fonction $L(\theta)$ et $-\frac{n}{\sum_{i=1}^n \log(x_i)}$ est l'estimateur du maximum de vraisemblance, $\hat{\theta}_{ML} = -\frac{n}{\sum_{i=1}^n \log(x_i)}$. Remarquons que puisque $x_i \in (0, 1)$, on a $\log(x_i) < 0$ et par conséquent $-\frac{n}{\sum_{i=1}^n \log(x_i)} > 0$.

(iv). Pour la méthode des moments on doit résoudre l'équation

$$\bar{X}_n = \frac{\hat{\theta}}{\hat{\theta} + 1}.$$

Ceci donne $\hat{\theta}_{MOM} = \bar{X}_n / (1 - \bar{X}_n)$.

Exercice 6. (i). Les variables X_i sont discrètes, donc la fonction de vraisemblance est

$$L(p) = f_1(x_1; p) \times f_2(x_2; p) \times \dots \times f_n(x_n; p),$$

où $f_i(x_i; p) = P(X_i = x_i) = p^{x_i} (1 - p)^{1-x_i}$ est la fonction de fréquences pour chaque X_i . On trouve

$$L(p) = p^{x_1} (1 - p)^{1-x_1} p^{x_2} (1 - p)^{1-x_2} \dots p^{x_n} (1 - p)^{1-x_n} = p^{\sum_{i=1}^n x_i} (1 - p)^{n - \sum_{i=1}^n x_i}.$$

- (ii). Comme $\mathbb{E}[X_i] = p$, l'estimateur des moments se trouve en résolvant l'équation $\hat{p}_{MOM} = \bar{X}_n$. Cette équation est déjà résolue, donc $\hat{p}_{MOM} = \bar{X}_n$.
- (iii). L'estimateur du maximum de vraisemblance est la valeur de p qui maximise $L(p)$, ou, de manière équivalente, la valeur qui maximise la fonction $\ell(p) = \log(L(p))$.

On a

$$\ell(p) = \sum_{i=1}^n x_i \log(p) + \left(n - \sum_{i=1}^n x_i \right) \log(1 - p).$$

Pour trouver le maximum on résout

$$\begin{aligned}
 \ell'(p) &= 0 \\
 \Leftrightarrow \frac{\sum_{i=1}^n x_i}{p} - \frac{n - \sum_{i=1}^n x_i}{1-p} &= 0 \\
 \Leftrightarrow (1-p) \sum_{i=1}^n x_i - p \left(n - \sum_{i=1}^n x_i \right) &= 0 \\
 \Leftrightarrow \sum_{i=1}^n x_i &= pn \\
 \Leftrightarrow p &= \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}_n.
 \end{aligned}$$

Il s'agit bien d'un maximum, étant donné que

$$\ell''(p) = -\frac{\sum_{i=1}^n x_i}{p^2} - \frac{n - \sum_{i=1}^n x_i}{(1-p)^2} < 0,$$

quel que soit $p \in (0, 1)$. Donc la valeur $p = \bar{x}_n$ maximise la fonction $L(p)$ et $\bar{X}_n$ est l'estimateur du maximum de vraisemblance, $\hat{p}_{ML} = \bar{X}_n$.

(iv). On a $\hat{p}_{MOM} = \hat{p}_{ML} = \bar{X}_n$. Donc

$$\mathbb{E}[\hat{p}_{MOM}] = \mathbb{E}[\hat{p}_{ML}] = \mathbb{E}[\bar{X}_n] = \mathbb{E}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \mathbb{E}\left(\sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}[X_i] = p,$$

parce que les variables X_i sont toutes $\mathcal{B}(p)$. Donc les estimateurs sont non-biaisés. Pour la variance on a

$$\begin{aligned}
 \text{Var}[\hat{p}_{MOM}] &= \text{Var}[\hat{p}_{ML}] = \text{Var}[\bar{X}_n] = \\
 &= \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \text{Var}\left(\sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}[X_i] = \frac{p(1-p)}{n},
 \end{aligned}$$

parce que les variables X_i sont indépendantes et toutes $\mathcal{B}(p)$.

Exercice 7. (i). $\mathbb{E}(Y) = \int_{-\infty}^{\infty} y f_Y(y) dy = 1/\lambda$, et $\text{Var}(Y) = \int_{-\infty}^{\infty} y^2 f_Y(y) dy - (\mathbb{E}(Y))^2 = 1/\lambda^2$.

(ii). On sait que $\mathbb{E}(\bar{Y}_n) = \mathbb{E}(Y) = 1/\lambda$ et $\text{Var}(\bar{Y}_n) = \text{Var}(Y)/n$. Par le théorème central limite,

$$\Pr\left(\frac{\bar{Y}_n - \mathbb{E}(\bar{Y}_n)}{\sqrt{\text{Var}(\bar{Y}_n)}} \leq z\right) = \Pr\left(\sqrt{n} \frac{\bar{Y}_n - \mathbb{E}(Y)}{\sqrt{\text{Var}(Y)}} \leq z\right) = \Pr\left(\sqrt{n} \frac{\bar{Y}_n - 1/\lambda}{1/\lambda} \leq z\right) \rightarrow \Pr(Z \leq z),$$

où $Z \sim \mathcal{N}(0, 1)$.

(iii). La vraisemblance

$$L(\lambda) = \prod_{i=1}^n f_Y(y_i; \lambda) = \prod_{i=1}^n \lambda \exp(-\lambda y_i) = \lambda^n \exp\left(-\sum_{i=1}^n \lambda y_i\right).$$

La log-vraisemblance est

$$l(\lambda) = n \log(\lambda) - \sum_{i=1}^n y_i \lambda$$

On a

$$\frac{dl}{d\lambda}(\lambda) = \frac{n}{\lambda} - \sum_{i=1}^n y_i$$

et

$$\frac{d^2l}{d\lambda^2}(\lambda) = -\frac{n}{\lambda^2} < 0$$

pour tout $\lambda > 0$. L'estimateur du maximum de vraisemblance satisfait donc

$$\frac{dl}{d\lambda}(\hat{\lambda}) = 0 \Leftrightarrow \hat{\lambda} = 1/\bar{Y}_n.$$

C'est bien un maximum car la deuxième dérivée est négative.

(iv). On applique la méthode delta avec $g(x) = 1/x$. On a

$$\bar{Y}_n \stackrel{\text{approx.}}{\sim} \mathcal{N}\left(\frac{1}{\lambda}, \frac{1}{\lambda^2} \frac{1}{n}\right) = \mathcal{N}(\mu, \sigma^2/n),$$

avec $\mu = 1/\lambda$ et $\sigma^2 = 1/\lambda^2$. Ainsi $g(\mu) = 1/\mu = \lambda$ et $g'(\mu) = -1/\mu^2 = -\lambda^2$ de sorte que

$$\hat{\lambda}_{ML} = g(\bar{Y}_n) \stackrel{\text{approx.}}{\sim} \mathcal{N}(g(\mu), g'(\mu)^2 \sigma^2/n) = \mathcal{N}(\lambda, \lambda^2/n).$$