



Fiche n° 5

Ex 1. Test sur les intentions de vote

1) Soit S_n une variable aléatoire sur $(\Omega, \mathcal{F}, (\mathbf{P}_\theta)_{\theta \in [0,1]})$ de loi binomiale $\text{Bin}(n, \theta)$ sous \mathbf{P}_θ .

a) Montrer pour toute constante a , que l'application

$$\theta \mapsto \mathbf{P}_\theta(S_n \geq a)$$

est croissante sur $[0, 1]$ (en θ). *Indication* : on utilisera une méthode de simulation de la loi binomiale.

b) Soit $\theta_0 \in [0, 1]$. En déduire la construction d'un événement de la forme

$$R = \{S_n \geq a\}$$

de telle sorte que $\sup_{\theta \leq \theta_0} \mathbf{P}_\theta(R) \leq 0,05$.

2) Application à la construction d'un test : Avant une élection, un candidat A affirme qu'il est sûr de dépasser le score des 30%. Pour savoir s'il a raison, on interroge un nombre n suffisant de personnes et on note S_n le nombre de personnes parmi les n interrogées qui ont l'intention de voter pour le candidat A. Si le nombre S_n dépasse un certain seuil (à déterminer), le candidat A affirmera que son score dépasse 30% en souhaitant que le risque de se tromper n'excède pas 5%.

On introduit alors le paramètre θ représentant la probabilité (inconnue) de voter pour A sur l'ensemble des électeurs et un modèle statistique $(\Omega, \mathcal{F}, (\mathbf{P}_\theta)_{\theta \in]0,1[})$ dans lequel S_n suit une loi binomiale $\text{Bin}(n, \theta)$ sous \mathbf{P}_θ .

On observe une réalisation de S_n et à l'aide de cette observation, on veut décider l'une des deux hypothèses suivantes :

$$H_0 : \theta \leq 0,3 \quad \text{ou bien si} \quad H_1 : \theta > 0,3.$$

La règle de décision sera donc du type

– si on observe $S_n(\omega) \geq a$, alors on rejette H_0 (et on accepte H_1)

– sinon, on accepte l'hypothèse H_0 ,

a étant un seuil à déterminer. Il est déterminé de telle sorte que la probabilité de rejeter H_0 à tort soit contrôlée par un niveau donné (ici 5%). Par exemple, c'est la probabilité pour le candidat A de conclure que $\theta > 0,3$ alors qu'en réalité $\theta \leq 0,3$.

a) Déterminer le seuil a (en fonction de n).

b) On recueille 32% d'intentions de votes auprès de 500 personnes, que pouvez-vous en conclure ?

Ex 2. Les ex-aequo d'un échantillon

1) On se propose de montrer que si X et Y sont deux variables aléatoires réelles *indépendantes* de fonctions de répartition respectives F et G et si F est *continue*, alors $P(X = Y) = 0$. Voici quelques indications. On note pour $M \in \mathbb{N}^*$,

$$\Delta_M := \{(x, y) \in [-M, M]^2; x = y\} \quad \text{et} \quad \Delta := \{(x, y) \in \mathbb{R}^2; x = y\}.$$

Il s'agit de prouver que $P_{(X,Y)}(\Delta) = 0$ (pourquoi?). En remarquant¹ que pour tout $k \in \mathbb{N}^*$,

$$\Delta_M \subset \bigcup_{-Mk \leq j < Mk} \left[\frac{j}{k}, \frac{j+1}{k} \right]^2,$$

utiliser la continuité *uniforme* de F sur le *compact* $[-M, M]$ pour montrer que

$$\forall \varepsilon > 0, \quad P_{(X,Y)}(\Delta_M) \leq \varepsilon(G(M) - G(-M)).$$

En déduire que $P_{(X,Y)}(\Delta_M) = 0$, puis que $P_{(X,Y)}(\Delta) = 0$.

2) Montrer que si X_1, \dots, X_n est un échantillon de la loi de f.d.r. F continue, presque sûrement il n'y a pas d'*ex-aequo* dans l'échantillon.

3) On suppose que la f.d.r. F est discontinue au point x_0 et on note

$$N_n(x_0) := \text{card}\{i = 1, \dots, n; X_i = x_0\}.$$

Montrer que $N_n(x_0) \xrightarrow[n \rightarrow +\infty]{\text{p.s.}} +\infty$. On donnera un résultat plus précis que cette affirmation.

Ex 3. Calculs sur la f.d.r. empirique

On note X_1, \dots, X_n un échantillon de la loi de f.d.r. F , *i.e.* les X_i sont indépendantes et de même loi de f.d.r. F . On note F_n la fonction de répartition empirique associée à l'échantillon :

$$\forall x \in \mathbb{R}, \quad F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\{X_i \leq x\}}.$$

1) Tracer le graphe de F_n pour une réalisation de l'échantillon X_1, \dots, X_n de votre choix (en prenant $n = 5$ par exemple).

2) On suppose dans cette question que les X_i sont des v.a. positives (ou plus généralement que $P(X_1 < 0) = 0$). Calculez $\int_0^{+\infty} (1 - F_n(t)) dt$ et interprétez le résultat.

Ex 4. Polygone de fréquences cumulées croissantes

Soit X_1, \dots, X_n un échantillon, F la f.d.r. de chaque X_i et F_n la fonction de répartition empirique associée à cet échantillon. On note $X_{n:1}, \dots, X_{n:n}$ les statistiques d'ordre de l'échantillon, obtenues par le réordonnement croissant de l'échantillon, *i.e.* pour tout $\omega \in \Omega$, $\{X_1(\omega), \dots, X_n(\omega)\} = \{X_{n:1}(\omega), \dots, X_{n:n}(\omega)\}$ et $X_{n:i}(\omega) \leq X_{n:i+1}(\omega)$ pour $i = 1, \dots, n-1$. En particulier $X_{n:1} = \min_{1 \leq i \leq n} X_i$ et $X_{n:n} = \max_{1 \leq i \leq n} X_i$. On posera par commodité $X_{n:0} := X_{n:1} - 1$ (convention non standard). On définit le lissage polygonal G_n de F_n , comme la fonction continue affine par morceaux valant 1 à droite de $X_{n:n}$, valant 0 à gauche de $X_{n:1} - 1$, coïncidant avec F_n en chaque $X_{n:i}$ (donc en chaque point de saut de F_n) et interpolant linéairement entre deux sauts consécutifs de F_n .

1. Dessin impératif!

- 1) Représentez F_n et G_n pour les deux échantillons observés suivants

$$X_1(\omega) = 2; X_2(\omega) = 1,5; X_3(\omega) = 4; X_4(\omega) = 0,5.$$

$$X_1(\omega') = 3; X_2(\omega') = 2; X_3(\omega') = 2; X_4(\omega') = 1,5; X_5(\omega') = 4.$$

2) On suppose dans cette question F continue sur \mathbb{R} . En utilisant le théorème de Glivenko-Cantelli, montrez que presque-sûrement G_n converge vers F uniformément sur \mathbb{R} quand n tend vers $+\infty$.

3) Donnez un argument général montrant que cette convergence uniforme presque sûre ne peut avoir lieu lorsque F n'est pas continue sur \mathbb{R} . Proposez une autre explication de ce résultat négatif en vous basant sur l'exercice 2.

Entraînement supplémentaire facultatif :

Ex 5. Simulation de lois gaussiennes

Soit $M_i = (U_i, V_i)_{i \in \mathbb{N}^*}$ une suite de vecteurs i.i.d de loi uniforme sur $[-1, 1]^2$. On définit la variable aléatoire

$$T := \inf \{ n \in \mathbb{N}^* : U_n^2 + V_n^2 < 1 \},$$

avec la convention $\inf \emptyset = +\infty$.

- 1) Quelle est la loi de T et celle de M_T ?
- 2) On pose $R^2 = U_T^2 + V_T^2$ et

$$X = U_T \sqrt{\frac{-2 \log(R^2)}{R^2}} \quad \text{et} \quad Y = V_T \sqrt{\frac{-2 \log(R^2)}{R^2}}.$$

Quelle est la loi du vecteur (X, Y) ? (On pourra utiliser un changement de variable en coordonnées polaires dans le calcul de $E(f(X, Y))$).

Ex 6. Estimation du paramètre de position de la loi log-normale

Extrait de l'examen d'IS (mai 2005) On rappelle qu'une variable aléatoire Y suit la loi gaussienne $\mathfrak{N}(m, \sigma)$, de paramètres $m \in \mathbb{R}$ et $\sigma \in \mathbb{R}_+$, si elle admet pour densité la fonction

$$g : \mathbb{R} \rightarrow \mathbb{R}, \quad y \mapsto \frac{1}{\sigma \sqrt{2\pi}} \exp\left(-\frac{(y-m)^2}{2\sigma^2}\right).$$

On sait qu'alors Y admet des moments de tout ordre et que

$$\mathbf{E}Y = m, \quad \text{Var } Y = \sigma^2.$$

- 1) Exprimez $\mathbf{E}(Y^2)$ en fonction des paramètres m et σ .
- 2) On dit qu'une variable aléatoire X suit la loi log-normale de paramètres m et σ , avec $m \in \mathbb{R}$ et $\sigma \in \mathbb{R}_+$, si elle admet pour densité la fonction

$$f : \mathbb{R} \rightarrow \mathbb{R}, \quad x \mapsto \frac{1}{x\sigma\sqrt{2\pi}} \exp\left(-\frac{(\ln x - m)^2}{2\sigma^2}\right) \mathbf{1}_{]0, +\infty[}(x).$$

La fonction f est donc nulle sur \mathbb{R}_- et strictement positive sur \mathbb{R}_+ . Vérifiez à l'aide d'un changement de variable que f est bien une densité de probabilité sur \mathbb{R} .

3) Vérifiez de même que la variable aléatoire $\ln X$ a des moments de tout ordre et que

$$\mathbf{E}(\ln X) = m, \quad \text{Var}(\ln X) = \sigma^2.$$

4) On se propose dans la suite de l'exercice d'étudier l'estimation du paramètre m . Pour cela on dispose d'un échantillon *observé* $X_1(\omega), \dots, X_n(\omega)$ avec n grand. On considère donc que les variables aléatoires X_i utilisées ici sont indépendantes et de même loi que X et ceci, quelles que soient les valeurs prises par les paramètres m et σ . En utilisant la question précédente, proposez en justifiant votre réponse, un estimateur T_n de m qui soit *fortement consistant*, *i.e.* presque-sûrement convergent vers m lorsque n tend vers $+\infty$.

5) Expliquez brièvement comment construire à partir de la valeur observée $T_n(\omega)$ un intervalle de confiance au niveau $1 - \varepsilon$ pour m , en distinguant les deux cas σ connu, puis σ inconnu. Indiquez quels sont les théorèmes limites utilisés pour cela.

6) (*A traiter quand le cours aura avancé*) On suppose que σ est connu et m inconnu. Déterminez l'estimateur de m par la méthode du maximum de vraisemblance.