


Exercice 1

1) $F_X: x \in \mathbb{R} \mapsto \mathbb{P}(X \leq x) \in [0, 1]$. Croissante, $\lim_{x \rightarrow -\infty} F_X = 0$, $\lim_{x \rightarrow +\infty} F_X = 1$.

Si X est une variable aléatoire qui vaut 0 p.s., alors $F_X(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$
ce qui n'est ni bijectif, ni injectif, ni surjectif.

2) Pour tout $q \in [0, 1]$, $F_X^{-1}(q) = \inf \{x \in \mathbb{R} : F_X(x) \geq q\}$.

Propriété utile: pour tout $x \in \mathbb{R}$ et $q \in [0, 1]$, $q \leq F_X(x) \Leftrightarrow F_X^{-1}(q) \leq x$



3) NON, aucune des deux égalités n'est vraie en général car cela voudrait dire que F_X est toujours bijective, et on a donné un contre-exemple.

a) D'après la propriété, $\forall x \in \mathbb{R}$, $F_X^{-1}(F_X(x)) \leq x$ donc $F_X^{-1}(F_X(x)) \leq x$.

b) De même, $\forall q \in [0, 1]$, $F_X^{-1}(q) \leq F_X^{-1}(q)$ donc $q \leq F_X(F_X^{-1}(q))$.

4) On utilise $F_X^{-1}(U) \leq x \Leftrightarrow U \leq F_X(x)$, donc

$$\mathbb{P}(F_X^{-1}(U) \leq x) = \mathbb{P}(U \leq F_X(x)) = F_X(x) = \mathbb{P}(X \leq x)$$

$\mathbb{P}(U \in [0, F_X(x)])$ $\leftarrow$ def. de F_X

(Si $U \sim \mathcal{U}([0, 1])$ et $[0, F_X(x)] \subset [0, 1]$, alors $\mathbb{P}(U \in [0, F_X(x)]) = \frac{F_X(x) - 0}{1 - 0} = F_X(x)$)

Les fonctions de répartition de $F_X^{-1}(U)$ et de X sont les mêmes, donc ces variables ont la même loi.

5) «La loi de X n'a pas d'atome» : on a donc F_X continue, F_X est surjective $\mathbb{R} \rightarrow \text{Im}(F_X)$
(0,1), [0,1], (0,1], [0,1]
donc pour tout $q \in (0, 1)$, il existe $y \in \mathbb{R}$ tel que $F_X(y) = q$.

Soit $q \in (0, 1)$, soit $z \in \mathbb{R}$ le plus grand réel tel que $F_X(z) = q$.
 $\mathbb{P}(F_X(X) \leq q) = (?)$ $F_X(z) \leq q$

(But: $= q$)
(car alors $= \mathbb{P}(U \leq q)$ où $U \sim \mathcal{U}([0, 1])$)

$F_X(X) = \mathbb{P}(X' \leq X | X)$ où X' et X ont la même loi.
X est une v.a. à valeurs dans $\mathbb{R}$.
Si $f: \mathbb{R} \rightarrow [0, 1]$, on peut définir $f(X)$ une v.a. à valeurs dans $[0, 1]$

0 1

quelle est
donc on considère la
fonction de répartition


Si $f: \mathbb{R} \rightarrow [0,1]$ on peut définir $f(x)$ une v.a. à valeurs dans $[0,1]$

Prenez $f = F_X: t \mapsto P(X \leq t)$

Soit X' de même loi que X

$F_X(X)$, $F_X(X')$, $F_X(X)$, $F_{X'}(X')$ ont la même loi.

$P(X \leq X) = 1$, alors que



$P(F_X(X) \leq q) = P(F_X(X) \leq F_X(z)) = P(X \leq z) = F_X(z) = q$.

(car $F_X(y) \leq F_X(z) \Leftrightarrow y \leq z$ par définition de z)

Exercice 2

On note $X_1, \dots, X_n$ les observations (avec ici $n=20$).

On suppose les X_i iid de loi P .

1) $H_0: P = U([0,1])$


$H_1: P \neq U([0,1])$

Si F est la fonction de répartition de X_1 et F_U la fonction de répartition de la loi $U([0,1])$,

$H_0: F = F_U$

$H_1: F \neq F_U$

2) $F_U: t \in \mathbb{R} \mapsto \begin{cases} 0 & \text{si } t \leq 0 \\ t & \text{si } t \in (0,1) \\ 1 & \text{si } t \geq 1 \end{cases}$




3)  Ne pas confondre $X_1, \dots, X_n$ et $X_{(1)}, \dots, X_{(n)}$

Statistiques d'ordre: c'est l'échantillon $X_1, \dots, X_n$ trié par ordre croissant, $X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$

Pour tout $x \in \mathbb{R}$,

$$\begin{aligned} F_n(x) &= \frac{1}{n} \sum_{i=1}^n 1_{X_i \leq x} = \frac{1}{n} \sum_{i=1}^n 1_{X_{(i)} \leq x} \\ &= \begin{cases} 0 & \text{si } x < X_{(1)} \\ \frac{1}{n} \max \{ i \in \{1, \dots, n\} : X_{(i)} \leq x \} & \text{si } x \in [X_{(i)}, X_{(i+1)}) \\ 1 & \text{si } x \geq X_{(n)} \end{cases} \\ &= \begin{cases} 0 & \text{si } x < X_{(1)} \\ \frac{i}{n} & \text{si } x \in [X_{(i)}, X_{(i+1)}) \\ 1 & \text{si } x \geq X_{(n)} \end{cases} \end{aligned}$$



4)


Lorsque les X_i ont pour fonction de répartition F ,


$\|F_n - F\|_\infty \xrightarrow{n \rightarrow +\infty} 0$. (Sous H_0 , $\|F_n - F_U\|_\infty \xrightarrow{n \rightarrow +\infty} 0$)

5)

Sous H_0 ,

$\sqrt{n} \|F_n - F_U\|_\infty \xrightarrow{n \rightarrow +\infty} \sup_{t \in [0,1]} |B(t)|$ où B est le pont brownien sur $[0,1]$.
sont la loi de Kolmogorov.





- 6) D'après le Théorème de Glivenko-Cantelli, $\|F_n - F^*\|_{\infty} \xrightarrow{n \rightarrow +\infty} 0$ Si $X_1, \dots, X_n$ sont iid de fonction de répartition F^* et F_n est la fn de répartition empirique alors
- $\|F_n - F_0\|_{\infty} - \|F^* - F_0\|_{\infty} \leq \|F_n - F^*\|_{\infty}$ par l'inégalité triangulaire « $F_n \rightarrow F^*$ en norme infinie »
- Donc $\|F_n - F_0\|_{\infty} \xrightarrow{n \rightarrow +\infty} \|F^* - F_0\|_{\infty}$ [a-b] - [a-c] ≤ [b-c]
a = F_0(t), b = F_n(t), c = F^*(t)
puis sup t ∈ [0, 1]
- Enfin, $\sqrt{n} \|F_n - F_0\|_{\infty} \xrightarrow{n \rightarrow +\infty} +\infty$ lorsque $F^* \neq F_0$
- $\|F_n - F_0\|_{\infty} \xrightarrow{n \rightarrow +\infty} \|F^* - F_0\|_{\infty}$?

$$\|F_n - F_0\|_{\infty} - \|F^* - F_0\|_{\infty} \xrightarrow{n \rightarrow +\infty} 0$$

Puis $\sqrt{n} \|F_n - F_0\|_{\infty} \sim \sqrt{n} \|F^* - F_0\|_{\infty} \xrightarrow{n \rightarrow +\infty} +\infty$ constante > 0

- 7) On prend comme statistique de test $\sqrt{n} \|F_n - F_0\|_{\infty}$.

Cette quantité tend vers $+\infty$ sous H_1 , d'où une région de rejet de la forme $R = [t, +\infty[$.

On prend t la quantile d'ordre 95% de la loi de Kolmogorov.

- 8) Le tableau A.14, version « Two-Sided », contient les quantiles de $\|F_n - F_0\|_{\infty}$ pour différentes valeurs de n .

Two-Sided: on prend comme statistique $\sup_{t \in [0, 1]} |F_n(t) - F_0(t)| = \max \left(\sup_{t \in [0, 1]} (F_n(t) - F_0(t)), \sup_{t \in [0, 1]} (F_0(t) - F_n(t)) \right)$

One-Sided:
↳ pour tester $F > F_0$ $\sup_{t \in [0, 1]} (F_n(t) - F_0(t))$
↳ pour tester $F < F_0$ $\sup_{t \in [0, 1]} (F_0(t) - F_n(t))$

On prend donc $t = \sqrt{n} \times 0,294$.

(Exercice 3: tableau A.16)

- 9) Le maximum est atteint en $X_{(2)}$.

$$\|F_n - F_0\|_{\infty} = \max_{1 \leq i \leq n} \left(\max \left(F_0(X_{(i)}) - \frac{i-1}{n}, \frac{i}{n} - F_0(X_{(i)}) \right) \right)$$

→ Prenez $i=2$.

$$\|F_n - F_0\| = 0,402. \quad \stackrel{(i=2)}{=} \max \left(\underbrace{0,402}_{F_0(X_{(2)})}, \underbrace{-0,352}_{\frac{2}{20} - 0,452} \right)$$

10) $T = \sqrt{n} \|F_n - F_0\|_{\infty}$, $T^{obs} = \sqrt{n} \times 0,402$.

$\sqrt{n} \times 0,402 \in [\sqrt{n} \times 0,294; +\infty[$ donc on rejette H_0 : les X_i ne suivent pas la loi $\mathcal{U}([0, 1])$.

11)

$[0, \frac{1}{3}[$	$[\frac{1}{3}, \frac{2}{3}[$	$[\frac{2}{3}, 1]$
1 = N_1	10 = N_2	9 = N_3

$(N_1, N_2, N_3) \sim \text{Mult}(20, p)$ avec p inconnue.

Test de $H_0: p = (\frac{1}{3}, \frac{1}{3}, \frac{1}{3})$ vs $H_1: p \neq (\frac{1}{3}, \frac{1}{3}, \frac{1}{3})$

Suite du test : voir TD 8.

Exercice 3 Reprenez la démarche du cours !

Notons $X_1, \dots, X_m$ le premier échantillon et $Y_1, \dots, Y_m$ le second ($n=5$ et $m=10$).

Notons $h(X, Y) = \|F_n - G_m\|_\infty$
fonction de répartition empirique de $(Y_1, \dots, Y_m)$
fonction de répartition empirique de $(X_1, \dots, X_n)$

$$h(X, Y) = \sup_{x \in \mathbb{R}} \left| \frac{1}{n} \sum_{i=1}^n \overset{F_n(x)}{\mathbb{1}_{X_i \leq x}} - \frac{1}{m} \sum_{j=1}^m \overset{G_m(x)}{\mathbb{1}_{Y_j \leq x}} \right|$$

Notons F_X la fonction de répartition (inconnue!) de X et F_Y celle de Y .

$$H_0: F_X = F_Y$$

$$H_1: F_X \neq F_Y$$

$$U_i, V_j \text{ des v.a. i.i.d de loi } \mathcal{U}([0,1]) \sim \sup_{x \in \mathbb{R}} \left| \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{F_X^{-1}(U_i) \leq x} - \frac{1}{m} \sum_{j=1}^m \mathbb{1}_{F_Y^{-1}(V_j) \leq x} \right|$$

$$\text{soit } H_0 \sim \sup_{x \in \mathbb{R}} \left| \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{F_X^{-1}(U_i) \leq x} - \frac{1}{m} \sum_{j=1}^m \mathbb{1}_{F_X^{-1}(V_j) \leq x} \right|$$

$$h(X, Y) \sim \sup_{q \in \text{Im}(F_X)} \left| \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{U_i \leq q} - \frac{1}{m} \sum_{j=1}^m \mathbb{1}_{V_j \leq q} \right|$$

et la loi du terme de droite ne dépend ni de F_X ni de F_Y , seulement de n et m !

en fait si via la $\ll q \in \text{Im}(F_X) \gg$
mais en tout cas

$$h(X, Y) \leq \sup_{q \in (0,1)} \left| \dots \right|$$

Notons $d_{n,m,\alpha}$ le quantile de niveau α de la v.a. $\sup_{q \in (0,1)} \left| \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{U_i \leq q} - \frac{1}{m} \sum_{j=1}^m \mathbb{1}_{V_j \leq q} \right|$.

Alors $P(h(X, Y) \leq d_{n,m,\alpha}) \geq \alpha$

Sous H_1 , $h(X, Y) \xrightarrow[n \rightarrow +\infty]{m \rightarrow +\infty} \|F_X - F_Y\|_\infty$ alors que sous H_0 , $h(X, Y) \xrightarrow[n \rightarrow +\infty]{m \rightarrow +\infty} 0$

donc on prend une région de rejet de la forme $R = [t, +\infty[$.

Un choix naturel est $t = d_{n,m,1-\alpha}$ si on veut que le test soit de niveau α .


$n=5, m=10, \alpha=5\%$: d'après la table A.16, $d_{5,10,0.95} = 0.7$.


Calcul: $h(X, Y)^{\text{obs}} = \underline{\hspace{2cm}}$

(car $h(X, Y) = \|F_n - G_m\|_\infty \leq \|F_n - F_X\|_\infty + \|F_X - F_Y\|_\infty + \|F_Y - G_m\|_\infty$
 $\xrightarrow{\text{Glivenko-Cantelli}} 0 + \|F_X - F_Y\|_\infty + 0$
 $\xrightarrow{\text{Glivenko-Cantelli}} 0$)

Sous H_1 par l'inégalité triangulaire,

$$\left| \|F_n - G_m\|_\infty - \|F_X - F_Y\|_\infty \right| \leq \|F_n - F_X\|_\infty + \|G_m - F_Y\|_\infty \xrightarrow{\text{Glivenko-Cantelli}} 0$$





donc $h(x, y)^{obs} = 0,7$.

$h(x, y)^{obs} \in [0,7; +\infty[$ donc on rejette H_0 : les échantillons suivent des lois différentes.

$h(x, y) \in \{0, \frac{1}{10}, \frac{2}{10}, \dots, \frac{9}{10}, 1\}$.

donc $d_{n,m,\alpha} = \frac{1}{10} \inf \{i \in \{0, \dots, 10\} : \overbrace{P(h(x, y) \geq \frac{i}{10})}^{11 \text{ valeurs à calculer}} \geq \alpha \}$