

# Simulations stochastiques - TD 7

## Derniers exercices sur les tests et Révisions

**Exercice 1** (Test d'adéquation de Kolmogorov). Soit  $(X_1, \dots, X_n)$  un  $n$ -échantillon de fonction de répartition  $F$ . On note  $\mathbb{F}_n$  la fonction de répartition empirique associée :

$$\forall t \in \mathbb{R}, \mathbb{F}_n(t) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{X_i \leq t}.$$

Soit  $F_{\text{réf}}$  une fonction de répartition continue. On souhaite tester  $H_0 : F = F_{\text{réf}}$  contre  $H_1 : F \neq F_{\text{réf}}$  sur la base de l'observation de  $(X_1, \dots, X_n)$ . On rappelle que le test d'adéquation de Kolmogorov est donné par  $\mathbb{1}_{D_n > d_{n,1-\alpha}}$ , où  $d_{n,1-\alpha}$  est le quantile d'ordre  $1 - \alpha$  de la loi de  $D_n$  sous  $H_0$ , et où

$$D_n = \sup_{t \in \mathbb{R}} |\mathbb{F}_n(t) - F_{\text{réf}}(t)|.$$

1. Rappeler pourquoi, sous  $H_0$ , la loi de  $D_n$  ne dépend en fait pas de la fonction de répartition  $F_{\text{réf}}$ . Quelle conséquence intéressante cela a-t-il sur le quantile  $d_{n,1-\alpha}$  ?
2. Nous allons montrer que le test est consistant, i.e., si  $H_1$  est vraie, alors  $\mathbb{P}(D_n > d_{n,1-\alpha}) \rightarrow 1$  quand  $n \rightarrow +\infty$ .
  - (a) En utilisant le théorème de Glivenko-Cantelli, montrer que  $\lim_{n \rightarrow +\infty} d_{n,1-\alpha} = 0$ .
  - (b) On suppose maintenant que  $H_1$  est vraie, et on fixe  $t \in \mathbb{R}$  tel que  $F(t) \neq F_{\text{réf}}(t)$ . Montrer que, presque sûrement,  $\liminf_{n \rightarrow +\infty} D_n \geq |F(t) - F_{\text{réf}}(t)|$ .
  - (c) En déduire que le test est consistant. Qu'est-ce que cela signifie en pratique ?
3. On souhaite tester si une variable aléatoire  $X$  suit une loi normale  $\mathcal{N}(2, 1)$ . On observe échantillon de taille 21 :

0.3 0.7 0.9 1.2 1.4 1.4 1.5 1.5 1.6 1.9 2.0 2.1 2.1 2.3 2.5 2.6 2.7 3.0 3.8 3.9 4.0

Que vaut  $D_n(\omega)$  sur cet exemple ? Donner une expression simple à calculer sur un ordinateur.

**Exercice 2** (Test de Kolmogorov-Smirnov pour deux échantillons indépendants). Soit  $(X_1, \dots, X_n)$  un  $n$ -échantillon de fonction de répartition  $F$ , et  $(Y_1, \dots, Y_m)$  un  $m$ -échantillon de fonction de répartition  $G$  et indépendant de  $(X_1, \dots, X_n)$ . On suppose que  $F$  et  $G$  sont continues sur  $\mathbb{R}$ . On note  $\mathbb{F}_n$  la fonction de répartition empirique de  $(X_1, \dots, X_n)$ ,  $\mathbb{G}_m$  la fonction de répartition empirique de  $(Y_1, \dots, Y_m)$  et on définit

$$D_{n,m} = \sup_{t \in \mathbb{R}} |\mathbb{F}_n(t) - \mathbb{G}_m(t)|.$$

On s'intéresse aux hypothèses  $H_0 : "F = G"$  et  $H_1 : "F \neq G"$ .

1. Que traduit l'égalité  $F = G$  sur les lois des  $X_i$  et des  $Y_j$  ?
2. Soit  $U_1, \dots, U_n, V_1, \dots, V_m$  des variables aléatoires i.i.d. uniformes sur  $[0, 1]$ . On notera  $F^{-1}$  et  $G^{-1}$  les inverses généralisées des fonctions  $F$  et  $G$ . Montrer que  $(F^{-1}(U_1), \dots, F^{-1}(U_n))$  est un  $n$ -échantillon de fonction de répartition  $F$ , que  $(G^{-1}(V_1), \dots, G^{-1}(V_m))$  est un  $m$ -échantillon de fonction de répartition  $G$ , et que ces deux échantillons sont indépendants.
3. En déduire que, si  $F = G$ , alors la loi de  $D_{n,m}$  ne dépend pas de  $F$ .
4. En utilisant le fait que la loi de  $D_{n,m}$  est connue sous  $H_0$  (cette loi est tabulée), construire un test de  $H_0$  contre  $H_1$ .
5. On souhaite comparer deux médicaments censés soulager la douleur post-opératoire. Sur 16 patients dont 8 ont pris un médicament A habituel et les 8 autres un médicament B expérimental, on a observé les temps de soulagement suivants (en heures). Y a-t-il une différence significative au niveau 5% entre A et B ?

A	6.8	3.1	5.8	4.5	3.3	4.7	4.2	4.9
B	4.4	2.5	2.8	2.1	6.6	0.0	4.8	2.3

**Exercice 3.** On notera  $\Phi$  la fonction de répartition d'une loi gaussienne centré réduite. Dans la suite, on considère une famille de lois de probabilités  $(\mathbb{P}_\theta, \theta \in ]0, 1[)$  ayant pour fonction de répartition

$$F_\theta(x) = (1 - \theta)\Phi\left(\frac{x - m}{\sigma}\right) + \theta\Phi\left(\frac{x - m}{5\sigma}\right), \quad x \in \mathbb{R}$$

Dans la suite, on suppose que l'on dispose d'un échantillon  $X_1, \dots, X_n$  de variables aléatoires i.i.d. distribuées selon  $\mathbb{P}_\theta$  pour un  $\theta$  que l'on cherche à estimer. On supposera les paramètres  $m$  et  $\sigma > 0$  connus.

1. Quelle est la loi d'une variable aléatoire  $X$  distribuée selon  $\mathbb{P}_0$  ? selon  $\mathbb{P}_1$  ?
2. Expliquer pourquoi la loi de  $X$  distribuée selon  $\mathbb{P}_\theta$  admet une densité et la calculer.
3. Calculer  $\mathbb{E}_\theta(X_1)$ .
4. Calculer  $\text{Var}_\theta(X_1)$ .
5. Au vu des questions précédentes, proposer un estimateur fortement consistant de  $\theta$  à partir de l'échantillon  $X_1, \dots, X_n$ .
6. Proposer une méthode de simulation de l'échantillon  $X_1, \dots, X_n$ .

### Les exercices suivants correspondent à l'examen de l'année 2016

**Exercice 4.** Soit  $U$  une variable aléatoire uniforme sur  $[0, 1]$ . La variable  $2U - 1$  est alors uniforme sur  $[-1, 1]$ . De la même manière, pour chacune des lois de probabilités suivantes, déterminer une variable aléatoire uniquement fonction de  $U$  et ayant cette loi. Justifier les réponses.

1. La loi uniforme sur  $[-3, 12]$ .
2. La loi d'une variable égale à 0 avec probabilité  $1/2$ , 1 avec probabilité  $1/3$ ,  $-1$  avec probabilité  $1/6$ .

3. La loi d'une variable aléatoire réelle dont la fonction de répartition en  $x$  vaut  $1/2 + (\arctan(x)/\pi)$  (on admettra que cette fonction est une bijection de  $\mathbb{R}$  vers  $(0, 1)$ ), par ailleurs la loi de probabilité définie ici s'appelle *loi de Cauchy*.

**Exercice 5.** Soit  $(X_k)_{k \geq 1}$  une suite de variables aléatoires i.i.d. uniformes sur  $[-1, 1]^2$ . On note  $K$  le plus petit indice  $k$  tel que  $X_k \in [0, 1]^2$ .

1. Déterminer la probabilité que  $K = k$  pour tout  $k \geq 1$  : comment appelle-t-on la loi de  $K$  ?
2. Quelle est la loi de  $X_K$  ? (pas de démonstration demandée)

**Exercice 6.** On considère l'intégrale suivante :

$$I = \int_0^1 \int_0^1 \int_0^1 f(x, y, z) dx dy dz$$

avec

$$f(x, y, z) = \sin(e^{3x-4y+5z} + e^{x-3y+7z} - 4xy).$$

1. Comment voir, sans calcul, que  $f$  est bien intégrable sur  $[0, 1] \times [0, 1] \times [0, 1]$  ?
2. On se donne des variables aléatoires i.i.d. uniformes sur  $[0, 1]$ , notées  $(X_k)_{k \geq 1}$ ,  $(Y_k)_{k \geq 1}$ ,  $(Z_k)_{k \geq 1}$ . On pose

$$T_k := f(X_k, Y_k, Z_k).$$

Déterminer une suite de variables aléatoires ne dépendant que de  $(T_k)_{k \geq 1}$  et convergeant presque sûrement vers  $I$ .

3. Comment voir, à nouveau sans calcul, que la variance de  $T_k$  est inférieure ou égale à 1 ?
4. Déterminer une suite  $(I_n)_{n \geq 1}$  de variables aléatoires, ne dépendant que de  $(T_k)_{k \geq 1}$ , telle que pour  $n \geq 1$ ,

$$\mathbb{P}[|I - I_n| \leq 5/\sqrt{n}] > 0.95$$

et pour tout  $n$  suffisamment grand,

$$\mathbb{P}[|I - I_n| \leq 2/\sqrt{n}] > 0.95.$$

On justifiera bien sûr ces deux inégalités.

**Exercice 7.** Soit  $(X_n)_{n \geq 1}$  une suite de variables aléatoires i.i.d., de loi exponentielle de paramètre  $\lambda$  (avec  $\lambda > 0$ ). On notera  $\mathbb{E}_\lambda$ ,  $\text{Var}_\lambda$  et  $\mathbb{P}_\lambda$  les espérances, variances et probabilités calculées avec le paramètre  $\lambda$ .

### Partie 1

1. Montrer que  $\mathbb{E}_\lambda[X_1] = 1/\lambda$  et  $\text{Var}_\lambda[X_1] = 1/\lambda^2$ .
2. On considère  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ . Montrer que, pour tout  $n \geq 1$ ,  $\mathbb{P}(\bar{X}_n > 0) = 1$ .
3. Soit  $\alpha \in ]0, 1[$ . Montrer que, pour tout  $n \geq 1$ ,

$$\mathbb{P}_\lambda \left( \left| \bar{X}_n - \frac{1}{\lambda} \right| > \frac{1}{\lambda \sqrt{n\alpha}} \right) \leq \alpha.$$

4. En déduire un intervalle de confiance de niveau  $\alpha$  pour  $\lambda$  (valable pour tout  $n \geq 1$ ).

## Partie 2

On s'intéresse maintenant au test d'hypothèses suivant :

$$H_0 : \lambda \leq \lambda_0$$

$$H_1 : \lambda > \lambda_0$$

5. Soit  $\varphi_n$  un test de l'hypothèse  $H_0$  contre l'hypothèse  $H_1$ . Comment est défini le risque de première espèce de  $\varphi_n$  ?
6. Soit  $t \in \mathbb{R}$  un réel quelconque.
- (a) Rappeler comment on peut simuler une v.a. de loi exponentielle de paramètre  $\lambda$  à partir d'un v.a. de loi  $\mathcal{U}([0, 1])$ .
- (b) Montrer par couplage que la fonction  $\lambda \mapsto \mathbb{P}_\lambda(\bar{X}_n < t)$  est une fonction croissante sur  $\mathbb{R}_+^*$ . On admettra qu'elle est aussi continue.
7. Soit  $\alpha \in ]0, 1[$ . Montrer que le test  $\varphi_n$  défini par

$$\varphi_n(X_1, \dots, X_n) = \mathbb{1} \left\{ \bar{X}_n < \frac{1}{\lambda_0} - \frac{1}{\lambda_0 \sqrt{n\alpha}} \right\}$$

est de niveau  $\alpha$ .

8. Application numérique : on souhaite tester si  $\lambda \leq 1$  ou  $\lambda > 1$ . On observe un échantillon de taille  $n = 10000$ , de moyenne empirique égale à 0,6. Que peut-on en déduire au niveau  $\alpha = 1\%$  ? Par ailleurs, que signifie ce 1% concrètement ?