

TD 9 : tests de Kolmogorov-Smirnov

Les questions marquées d'un astérisque (*) sont facultatives.

Pour les exercices faisant intervenir un test de Kolmogorov-Smirnov, on se réfèrera aux tables de quantiles à la fin de la feuille, tirées de "Advanced Statistics from an Elementary Point of View", par Michael J. Panik. Attention à bien utiliser le α correspondant au Two-Sided Test!

Pour information, il est possible de réaliser des tests de Kolmogorov-Smirnov dans R grâce à la fonction `ks.test`. Les tests du χ^2 se réalisent avec `chisq.test`, de Student avec `t.test`.

Exercice 1. (Fonction de répartition) Soit X une variable aléatoire à valeurs dans \mathbb{R} .

- Rappeler la définition de la fonction de répartition F_X de X . La fonction F_X est-elle injective? Surjective? Bijective?
- Rappeler la définition de l'inverse généralisée F_X^{-1} de F_X .
- A-t-on (si oui, le montrer, si non, donner un contre-exemple et (*) corriger l'énoncé) :
 - Pour tout $x \in \mathbb{R}$, $(F_X^{-1} \circ F_X)(x) = x$?
 - Pour tout $q \in [0, 1]$, $(F_X \circ F_X^{-1})(q) = q$?
- Soit $U \sim \mathcal{U}([0, 1])$. Montrer que $F_X^{-1}(U)$ a la même loi que X .
On utilisera que si deux variables X et Y vérifient : pour tout $t \in \mathbb{R}$, $\mathbb{P}(X \leq t) = \mathbb{P}(Y \leq t)$, alors elles ont la même loi.
- Supposons que la loi de X n'a pas d'atomes. Montrer que $F_X(X) \sim \mathcal{U}([0, 1])$. (*) Et si la loi de X a un atome?

Exercice 2. On observe l'échantillon de 20 observations (supposées indépendantes), trié par ordre croissant par souci de lisibilité, suivant :

0.278	0.452	0.464	0.494	0.496	0.505	0.576	0.592	0.602	0.608
0.661	0.683	0.690	0.696	0.704	0.728	0.754	0.850	0.902	0.949

On souhaite savoir s'il a été généré suivant la loi uniforme sur $[0, 1]$.

- Formuler les hypothèses H_0 et H_1 .
- Quelle est la fonction de répartition F_U de la loi uniforme?
- Rappeler la définition de la fonction de répartition empirique F_n fondée sur un n -échantillon (X_1, \dots, X_n) . On note $X_{(1)} \leq \dots \leq X_{(n)}$ les statistiques d'ordre de l'échantillon, c'est-à-dire l'échantillon trié par ordre croissant.
- Énoncer le théorème de Glivenko-Cantelli.
- Vers quelle loi convergerait $\sqrt{n}\|F_n - F_U\|_\infty$ si les observations suivaient la loi uniforme?
- Si les observations suivaient une loi de fonction de répartition $F^* \neq F_U$, vers quoi convergerait $\|F_n - F_U\|_\infty$? Et $\sqrt{n}\|F_n - F_U\|_\infty$?
- En déduire une région de rejet du test ayant pour statistique de test $\|F_n - F_U\|_\infty$.
- Fournir les bornes de cette région de rejet en se fondant sur les tables de quantiles à la fin de l'énoncé.

Attention, deux points peuvent vous induire en erreur :

- Référez-vous à la ligne « Two-Sided Test » pour le niveau des quantiles;
- La table est construite pour la statistique $\|F_n - F_U\|_\infty$, pas $\sqrt{n}\|F_n - F_U\|_\infty$.

9. Calculer $\|F_n - F_U\|_\infty$.
10. Conclure.
11. Il est également possible de faire un test du chi-deux d'adéquation. Pour cela, on compte le nombre d'observations tombant dans des intervalles de poids similaire. Ici, on choisit $[0, \frac{1}{3}]$, $[\frac{1}{3}, \frac{2}{3}]$ et $[\frac{2}{3}, 1]$. Effectuer ce test et comparer les conclusions.

Exercice 3. (Test à deux échantillons) On observe deux échantillons, triés par ordre croissant :

-0.367 0.109 0.424 0.517 3.405

et

0.396 0.783 0.810 1.290 1.604 1.640 1.799 1.857 2.579 2.787

Testez s'ils ont la même loi.

La table est construite pour la statistique $\|F_n - G_m\|_\infty$ lorsque F_n et G_m sont des fonctions des répartition empiriques de deux échantillons indépendants, le premier composé de n variables i.i.d. uniformes sur $[0, 1]$ et le second composé de m variables i.i.d. uniformes sur $[0, 1]$. On justifiera soigneusement pourquoi il est possible d'utiliser cette table de quantiles dans cet exercice.

Exercice 4. (*) (Correction de Lilliefors) Soit (X_1, \dots, X_n) un échantillon de variables aléatoires i.i.d. On souhaite tester si elles suivent une loi normale, mais sans connaître leur moyenne ni leur variance : il n'est donc pas possible d'utiliser le test de Kolmogorov-Smirnov.

Soit \bar{X}_n la moyenne empirique de l'échantillon et $\hat{\sigma}_n$ son écart-type empirique. Pour tout $i \in \{1, \dots, n\}$, on note $Z_i = (X_i - \bar{X}_n)/\hat{\sigma}_n$ l'observation X_i recentrée et renormalisée. Soit F la fonction de répartition de la loi normale centrée réduite et F_n^Z la fonction de répartition empirique de l'échantillon $(Z_i)_{1 \leq i \leq n}$. La statistique du test de Lilliefors est

$$D = \|F_n^Z - F\|_\infty.$$

1. En notant $Z_{(1)} \leq \dots \leq Z_{(n)}$ les statistiques d'ordre de l'échantillon $(Z_i)_{1 \leq i \leq n}$, montrer que

$$D = \max_{1 \leq i \leq n} \left(F(Z_{(i)}) - \frac{i-1}{n}, \frac{i}{n} - F(Z_{(i)}) \right).$$

2. Montrer que la loi de D ne dépend que de la taille de l'échantillon et non de sa moyenne ou de sa variance.
3. En déduire un test de normalité de l'échantillon (X_1, \dots, X_n) .
4. (*) La loi des Z_i ne dépend ni de la moyenne, ni de la variance des X_i . Pourquoi ne peut-on pas leur appliquer le test de Kolmogorov-Smirnov ? (Cela consisterait à remplacer F , fonction de répartition de la loi normale centrée réduite, par la fonction de répartition de Z dans la définition de D .)

Pour en savoir plus sur les tests de normalité, vous pouvez vous référer au cours http://eric.univ-lyon2.fr/~ricco/cours/cours/Test_Normalite.pdf

Table A.14 Quantiles of the Kolmogorov-Smirnov Test Statistics D_n

The table gives the upper $100(1 - \alpha)\%$ quantile $\hat{d}_{n,1-\alpha}$ of the sampling distribution of \hat{D}_n such that $P(\hat{D}_n \leq \hat{d}_{n,1-\alpha}) = 1 - \alpha$ or $P(\hat{D}_n \geq \hat{d}_{n,1-\alpha}) = \alpha$ (e.g., for $n = 20$ and $\alpha = 0.05$, the one-tail critical region is $\mathcal{R} = \{\hat{d}_{20} | \hat{d}_{20} \geq \hat{d}_{20,0.95} = 0.265\}$; the two-tail critical region is $\mathcal{R} = \{\hat{d}_{20} | \hat{d}_{20} \geq \hat{d}_{20,0.95} = 0.294\}$).

One-Sided Test 1 - α =	0.90	0.95	0.975	0.99	0.995	1 - α =	0.90	0.95	0.975	0.99	0.995
Two-Sided Test 1 - α =	0.80	0.90	0.95	0.98	0.99	1 - α =	0.80	0.90	0.95	0.98	0.99
$n = 1$	0.900	0.950	0.975	0.990	0.995	$n = 21$	0.226	0.259	0.287	0.321	0.344
2	0.684	0.776	0.842	0.900	0.929	22	0.221	0.253	0.281	0.314	0.337
3	0.565	0.636	0.708	0.785	0.829	23	0.216	0.247	0.275	0.307	0.330
4	0.493	0.565	0.624	0.689	0.734	24	0.212	0.242	0.269	0.301	0.323
5	0.447	0.509	0.563	0.627	0.669	25	0.208	0.238	0.264	0.295	0.317
6	0.410	0.468	0.519	0.577	0.617	26	0.204	0.233	0.259	0.290	0.311
7	0.381	0.436	0.483	0.538	0.576	27	0.200	0.229	0.254	0.284	0.305
8	0.358	0.410	0.454	0.507	0.542	28	0.197	0.225	0.250	0.279	0.300
9	0.339	0.387	0.430	0.480	0.513	29	0.193	0.221	0.246	0.275	0.295
10	0.323	0.369	0.409	0.457	0.489	30	0.190	0.218	0.242	0.270	0.290
11	0.308	0.352	0.391	0.437	0.468	31	0.187	0.214	0.238	0.266	0.285
12	0.296	0.338	0.375	0.419	0.449	32	0.184	0.211	0.234	0.262	0.281
13	0.285	0.325	0.361	0.404	0.432	33	0.182	0.208	0.231	0.258	0.277
14	0.275	0.314	0.349	0.390	0.418	34	0.179	0.205	0.227	0.254	0.273
15	0.266	0.304	0.338	0.377	0.404	35	0.177	0.202	0.224	0.251	0.269
16	0.258	0.295	0.327	0.366	0.392	36	0.174	0.199	0.221	0.247	0.265
17	0.250	0.286	0.318	0.355	0.381	37	0.172	0.196	0.218	0.244	0.262
18	0.244	0.279	0.309	0.346	0.371	38	0.170	0.194	0.215	0.241	0.258
19	0.237	0.271	0.301	0.337	0.361	39	0.168	0.191	0.213	0.238	0.255
20	0.232	0.265	0.294	0.329	0.352	40	0.165	0.189	0.210	0.235	0.252

Adapted from L.H. Miller, "Tables of Percentage Points of Kolmogorov Statistics," *JASA*, 51, 1956, 111-121. Reprinted with permission from *The Journal of the American Statistical Association*. Copyright [1956] by the American Statistical Association. All rights reserved.

Table A.15 Quantiles of the Kolmogorov-Smirnov Test Statistic $D_{n,m}$ When $n = m$

The table gives the upper $100(1 - \alpha) \%$ quantile $\hat{d}_{n,m}$ of the sampling distribution of $\hat{D}_{n,m}$ such that $P(\hat{D}_{n,m} \leq \hat{d}_{n,m,1-\alpha}) = 1 - \alpha$ or $P(\hat{D}_{n,m} \geq \hat{d}_{n,m,1-\alpha}) = \alpha$ (e.g., for $n = m = 15$ and $\alpha = 0.05$, the one-tail critical region is $\mathcal{R} = \{\hat{d}_{15,15} | \hat{d}_{15,15} \geq \hat{d}_{15,15,0.95} = 0.40\}$; the two-tail critical region is $\mathcal{R} = \{\hat{d}_{15,15} | \hat{d}_{15,15} \geq \hat{d}_{15,15,0.95} = 0.467\}$).

One-Sided Test 1 - α =	0.90	0.95	0.975	0.99	0.995	1 - α =	0.90	0.95	0.975	0.99	0.995
Two-Sided Test 1 - α =	0.80	0.90	0.95	0.98	0.99	1 - α =	0.80	0.90	0.95	0.98	0.99
$n = 3$	2/3	2/3				$n = 20$	6/20	7/20	8/20	9/20	10/20
4	3/4	3/4	3/4			21	6/21	7/21	8/21	9/21	10/21
5	3/5	3/5	4/5	4/5	4/5	22	7/22	8/22	8/22	10/22	10/22
6	3/6	4/6	4/6	5/6	5/6	23	7/23	8/23	9/23	10/23	10/23
7	4/7	4/7	5/7	5/7	5/7	24	7/24	8/24	9/24	10/24	11/24
8	4/8	4/8	5/8	5/8	6/8	25	7/25	8/25	9/25	10/25	11/25
9	4/9	5/9	5/9	6/9	6/9	26	7/26	8/26	9/26	10/26	11/26
10	4/10	5/10	6/10	6/10	7/10	27	7/27	8/27	9/27	11/27	11/27
11	5/11	5/11	6/11	7/11	7/11	28	8/28	9/28	10/28	11/28	12/28
12	5/12	5/12	6/12	7/12	7/12	29	8/29	9/29	10/29	11/29	12/29
13	5/13	6/13	6/13	7/13	8/13	30	8/30	9/30	10/30	11/30	12/30
14	5/14	6/14	7/14	7/14	8/14	31	8/31	9/31	10/31	11/31	12/31
15	5/15	6/15	7/15	8/15	8/15	32	8/32	9/32	10/32	12/32	12/32
16	6/16	6/16	6/25	8/16	12/15	34	8/34	10/34	11/34	12/34	13/34
17	9/29	7/17	7/17	8/22	9/17	36	9/36	10/36	11/36	12/36	13/36
18	6/18	7/18	8/18	9/18	9/19	38	9/38	10/38	11/38	13/38	14/38
19	6/19	7/19	8/19	9/19	9/19	40	9/40	10/40	12/40	13/40	14/40
						Approximation	1.52	1.73	1.92	2.15	2.30
						for $n > 40$:	$\frac{1.52}{\sqrt{n}}$	$\frac{1.73}{\sqrt{n}}$	$\frac{1.92}{\sqrt{n}}$	$\frac{2.15}{\sqrt{n}}$	$\frac{2.30}{\sqrt{n}}$

Adapted from Z.W. Birnbaum and R.A. Hall, "Small Sample Distribution for Multisample Statistics of the Smirnov Type," *The Annals of Mathematical Statistics*, 31, 1960, 710-720, with kind permission from the Institute of Mathematical Statistics.

Table A.16 Quantiles of the Kolmogorov-Smirnov Test Statistic $D_{n,m}$ When $n \neq m^*$

The table gives the upper $100(1-\alpha)\%$ quantile $\hat{d}_{n,m}$ of the sampling distribution of $\hat{D}_{n,m}$ such that $P(\hat{D}_{n,m} \leq \hat{d}_{n,m,1-\alpha}) = 1 - \alpha$ or $P(\hat{D}_{n,m} \geq \hat{d}_{n,m,1-\alpha}) = \alpha$ (e.g., for $n = 6, m = 10$, and $\alpha = 0.05$, the one-tail critical region is $\mathcal{R} = \{\hat{d}_{6,10} | \hat{d}_{6,10} \geq \hat{d}_{6,10,0.95} = 0.567\}$; the two-tail critical region is $\mathcal{R} = \{\hat{d}_{6,10} | \hat{d}_{6,10} \geq \hat{d}_{6,10,0.95} = 0.633\}$).

One-Sided Test	$1 - \alpha =$	0.90	0.95	0.975	0.99	0.995
Two-Sided Test	$1 - \alpha =$	0.80	0.90	0.950	0.98	0.990
$n = 1$	$m = 9$	17/18				
	10	9/10				
$n = 2$	3	5/6				
	4	3/4				
	5	4/5	4/5			
	6	5/6	5/6			
	7	5/7	6/7			
	8	3/4	7/8	7/8		
	9	7/9	8/9	8/9		
$n = 3$	10	7/10	4/5	9/10		
	$m = 4$	3/4	3/4			
	5	2/3	4/5	4/5		
	6	2/3	2/3	5/6		
	7	2/3	5/7	6/7	6/7	
	8	5/8	3/4	3/4	7/8	
	9	2/3	2/3	7/9	8/9	8/9
	10	3/5	7/10	4/5	9/10	9/10
	12	7/12	2/3	3/4	5/6	11/12
	$m = 5$	3/5	3/4	4/5	4/5	
$n = 4$	6	7/12	2/3	3/4	5/6	5/6
	7	17/28	5/7	3/4	6/7	6/7
	8	5/8	5/8	3/4	7/8	7/8
	9	5/9	2/3	3/4	7/9	8/9
	10	11/20	13/20	7/10	4/5	4/5
	12	7/12	2/3	2/3	3/4	5/6
	16	9/16	5/8	11/16	3/4	13/16
	$m = 6$	3/5	2/3	2/3	5/6	5/6
$n = 5$	7	4/7	23/35	5/7	29/35	6/7
	8	11/20	5/8	27/40	4/5	4/5
	9	5/9	3/5	31/45	7/9	4/5
	10	1/2	3/5	7/10	7/10	4/5
	15	8/15	3/5	2/3	11/15	11/15
	20	1/2	11/20	3/5	7/10	3/4

Table A.16 (Contd.)

One-Sided Test	$1 - \alpha =$	0.90	0.95	0.975	0.99	0.995
Two-Sided Test	$1 - \alpha =$	0.80	0.90	0.950	0.98	0.990
$n = 6$	$m = 7$	23/42	4/7	29/42	5/7	5/6
	8	1/2	7/12	2/3	3/4	3/4
	9	1/2	5/9	2/3	13/18	7/9
	10	1/2	17/30	19/30	7/10	11/15
	12	1/2	7/12	7/12	2/3	3/4
	18	4/9	5/9	11/18	2/3	13/18
	24	11/24	1/2	7/12	5/8	2/3
$n = 7$	$m = 8$	27/56	33/56	5/8	41/56	3/4
	9	31/63	5/9	40/63	5/7	47/63
	10	33/70	39/70	43/70	7/10	5/7
	14	3/7	1/2	4/7	9/14	5/7
	28	3/7	13/28	15/28	17/28	9/14
$n = 8$	$m = 9$	4/9	13/24	5/8	2/3	3/4
	10	19/40	21/40	23/40	27/40	7/10
	12	11/24	1/2	7/12	5/8	2/3
	16	7/16	1/2	9/16	5/8	5/8
	32	13/32	7/16	1/2	9/16	19/32
$n = 9$	$m = 10$	7/15	1/2	26/45	2/3	31/45
	12	4/9	1/2	5/9	11/18	2/3
	15	19/45	22/45	8/15	3/5	29/45
	18	7/18	4/9	1/2	5/9	11/18
	36	13/36	5/12	17/36	19/36	5/9
$n = 10$	$m = 15$	2/5	7/15	1/2	17/30	19/30
	20	2/5	9/20	1/2	11/20	3/5
	40	7/20	2/5	9/20	1/2	
$n = 12$	$m = 15$	23/60	9/20	1/2	11/20	7/12
	16	3/8	7/16	23/48	13/24	7/12
	18	13/36	5/12	17/36	19/36	5/9
	20	11/30	5/12	7/15	31/60	17/30
	$m = 20$	7/20	2/5	13/30	29/60	31/60
$n = 15$	$m = 20$	7/20	2/5	13/30	29/60	31/60
$n = 16$	$m = 20$	27/80	31/80	17/40	19/40	41/80
Large-sample approximation		$1.07\sqrt{\frac{m+n}{mn}}$	$1.22\sqrt{\frac{m+n}{mn}}$	$1.36\sqrt{\frac{m+n}{mn}}$	$1.52\sqrt{\frac{m+n}{mn}}$	$1.63\sqrt{\frac{m+n}{mn}}$

*Let n be the smaller sample size and let m be the larger sample size. If this table does not cover n and m , use the large sample approximation.

Adapted from F.J. Massey, "Distribution Table for the Deviation Between Two Sample Cumulatives," *The Annals of Mathematical Statistics*, 23, 1952, 435–441. Corrections appear in Davis, L.S. (1958), *Mathematical Tables and other Aids to Computation*, 12, 1952, 262–263, with kind permission from the Institute of Mathematical Statistics.