
CORRECTIONS TDS TESTS NON PARAMÉTRIQUES

Décembre 2022

Exercice 1

- **Énoncé** : On observe les 10 valeurs suivantes pour X_1, \dots, X_{10}

0.39	0.22	0.99	0.62	0.18	0.53	0.15	0.96	0.7	0.26
------	------	------	------	------	------	------	------	-----	------

Proposez un test au niveau 5% pour tester l'adéquation à la loi uniforme $\mathcal{U}([0, 1])$.

- **Correction** : le test de Kolmogorov est bien adapté à ce problème d'adéquation. La fonction de répartition de la loi uniforme $\mathcal{U}([0, 1])$ est $F(x) = x\mathbb{1}_{[0,1]}(x) + \mathbb{1}_{]1,+\infty[}(x)$. Donc la statistique du test s'écrit

x_i	0.15	0.18	0.22	0.26	0.39	0.53	0.62	0.7	0.96	0.99
E_i^-	0.15	0.08	0.02	0.04	0.01	0.03	0.02	0	0.16	0.09
E_i^+	0.05	0.02	0.08	0.14	0.11	0.07	0.08	0.10	0.06	0.01
$\text{Max}(E_i^+, E_i^-)$	0.15	0.08	0.08	0.14	0.11	0.07	0.08	0.10	0.16	0.09

Donc $D_n = 0.16$. Les tables donnent un seuil $S_{10,0.05} = 0.4093$, ce qui signifie qu'on accepte l'hypothèse H_0 avec un risque $\alpha = 0.05$.

La syntaxe Matlab est pour une loi normale $[H,P,KSSTAT,CV] = kstest(x,'Alpha',0.05)$, et pour une loi uniforme $[H,P,KSSTAT,CV] = kstest(x,'cdf',[x',unicdf(x,0,1)]', 'Alpha',0.05)$ où x est une ligne contenant toutes les données.

$n \backslash \alpha$	0.001	0.01	0.02	0.05	0.1	0.15	0.2
1		0.99500	0.99000	0.97500	0.95000	0.92500	0.90000
2	0.97764	0.92930	0.90000	0.84189	0.77639	0.72614	0.68377
3	0.92063	0.82900	0.78456	0.70760	0.63604	0.59582	0.56481
4	0.85046	0.73421	0.68887	0.62394	0.56522	0.52476	0.49265
5	0.78137	0.66855	0.62718	0.56327	0.50945	0.47439	0.44697
6	0.72479	0.61660	0.57741	0.51926	0.46799	0.43526	0.41035
7	0.67930	0.57580	0.53844	0.48343	0.43607	0.40497	0.38145
8	0.64098	0.54180	0.50654	0.45427	0.40962	0.38062	0.35828
9	0.60846	0.51330	0.47960	0.43001	0.38746	0.36006	0.33907
10	0.58042	0.48895	0.45662	0.40925	0.36866	0.34250	0.32257
11	0.55588	0.46770	0.43670	0.39122	0.35242	0.32734	0.30826
12	0.53422	0.44905	0.41918	0.37543	0.33815	0.31408	0.29573
13	0.51490	0.43246	0.40362	0.36143	0.32548	0.30233	0.28466
14	0.49753	0.41760	0.38970	0.34890	0.31417	0.29181	0.27477
15	0.48182	0.40420	0.37713	0.33760	0.30397	0.28233	0.26585
16	0.46750	0.39200	0.36571	0.32733	0.29471	0.27372	0.25774
17	0.45440	0.38085	0.35528	0.31796	0.28627	0.26587	0.25035
18	0.44234	0.37063	0.34569	0.30936	0.27851	0.25867	0.24356
19	0.43119	0.36116	0.33685	0.30142	0.27135	0.25202	0.23731
20	0.42085	0.35240	0.32866	0.29407	0.26473	0.24587	0.23152
25	0.37843	0.31656	0.30349	0.26404	0.23767	0.22074	0.20786
30	0.34672	0.28988	0.27704	0.24170	0.21756	0.20207	0.19029
35	0.32187	0.26898	0.25649	0.22424	0.20184	0.18748	0.17655
40	0.30169	0.25188	0.23993	0.21017	0.18939	0.17610	0.16601
45	0.28482	0.23780	0.22621	0.19842	0.17881	0.16626	0.15673
50	0.27051	0.22585	0.21460	0.18845	0.16982	0.15790	0.14886
OVER 50	1.94947	1.62762	1.51743	1.35810	1.22385	1.13795	1.07275
	\sqrt{n}	\sqrt{n}	\sqrt{n}	\sqrt{n}	\sqrt{n}	\sqrt{n}	\sqrt{n}

Valeurs du seuil pour le test de Kolmogorov (un échantillon).

Exercice 2

- **Énoncé** : Huit individus sont traités avec le soporifique S et huit autres individus avec un produit inactif I. Pour chacun des 16 sujets, le temps de sommeil moyen après traitement a été enregistré : X_i représente le temps de sommeil moyen pour l'individu i traité avec le soporifique (S) et Y_j représente le temps de sommeil moyen pour l'individu j traité avec le produit (I). On a observé (en minutes)

individus	1	2	3	4	5	6	7	8
$x_i(S)$	578	568	548	478	458	538	618	548
$y_j(I)$	430	360	430	570	490	480	380	400

1. Peut-on considérer que les deux échantillons sont indépendants ?
2. Peut-on conclure à l'efficacité du soporifique ? Proposez deux tests pour répondre à cette question. Vous préciserez bien le modèle utilisé, les hypothèses testées, les statistiques de test utilisées, la zone de rejet ainsi que les conclusions des deux tests proposés pour un niveau $\alpha = 5\%$.

- **Correction**

1. Les deux échantillons concernent des individus différents donc on peut supposer qu'ils sont indépendants.
2. Une première approche pour tester l'efficacité du soporifique est de tester si les lois de $x_i(S)$ et de $y_j(I)$ sont différentes ou pas. On peut alors utiliser le test de Kolmogorov-Smirnov qui rejette H_0 si

$$D_{n,n} = \frac{1}{n} \max_{j \in \{1, \dots, 2n\}} \left| 2 \sum_{k=1}^j \alpha_k - j \right| > S_{n,\alpha}$$

avec $\alpha_k = 1$ si la k ème plus petite observation appartient à la suite y et $\alpha_k = 0$ dans le cas contraire. Les deux échantillons ordonnés sont

$$y_2 = 360 < y_7 = 380 < y_8 = 400 < y_1 = 430 = y_3 < x_5 = 458 < x_4 = 478 < y_6 = 480 \\ < y_5 = 490 < x_6 = 538 < x_3 = x_8 = 548 < x_2 = 568 < y_4 = 570 < x_1 = 578 < x_7 = 618$$

donc

– Variables α_k

$$\alpha_1 = 1, \alpha_2 = 1, \alpha_3 = 1, \alpha_4 = 1, \alpha_5 = 1, \alpha_6 = 0, \alpha_7 = 0, \alpha_8 = 1$$

$$\alpha_9 = 1, \alpha_{10} = 0, \alpha_{11} = 0, \alpha_{12} = 0, \alpha_{13} = 0, \alpha_{14} = 1, \alpha_{15} = 0, \alpha_{16} = 0$$

– Valeurs de $\sum_{k=1}^j \alpha_k$: 1, 2, 3, 4, 5, 5, 5, 6, 7, 7, 7, 7, 8, 8, 8

– Valeurs de $\left| 2 \sum_{k=1}^j \alpha_k - j \right|$: 1, 2, 3, 4, 5, 4, 3, 4, 5, 4, 3, 2, 1, 2, 1, 0

– Statistique de test : $D_{n,n} = 5/8 = 0.625$

– p-value : $p = 0.0248$

Donc on rejette H_0 avec $\alpha = 0.05$, ce qui signifie que le soporifique semble efficace.

– Si on se fixe un risque de première espèce $\alpha = 0.05$, on trouve un seuil $S_{0.05} = \frac{4}{8} < D_{n,n} = 5/8$ donc on rejette l'hypothèse H_0 avec un risque $\alpha = 0.05$.

Remarques

- La commande Matlab est $[h,p,ks2stat] = kstest2(y,x,'tail','larger')$ (fonction de répartition de l'échantillon y supérieure à celle de l'échantillon x) avec $x = [578, 568, 548, 478, 458, 538, 618, 548]$ et $y = [430, 360, 430, 570, 490, 480, 380, 400]$ car le test est unilatéral. Pour un test bilatéral, on utiliserait $[h,p,ks2stat] = kstest2(x,y)$.

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 $1 - \alpha =$	0.90	0.95	0.975	0.99	0.995	$1 - \alpha =$	0.90	0.95	0.975	0.99	0.995
Two-Sided Test $1 - \alpha =$	0.80	0.90	0.95	0.98	0.99	$1 - \alpha =$	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 $n > 40$:	$\frac{1.52}{\sqrt{n}}$	$\frac{1.73}{\sqrt{n}}$	$\frac{1.92}{\sqrt{n}}$	$\frac{2.15}{\sqrt{n}}$	$\frac{2.30}{\sqrt{n}}$

Valeurs du seuil pour le test de Kolmogorov-Smirnov (deux échantillons de mêmes tailles $n = m$).

3. Une deuxième approche consiste à effectuer un test de Mann-Whitney qui permet de tester si la loi des x_i de fonction de répartition G vérifie $G > F$, où F est la fonction de répartition des y_j (ce qui correspond à tester si les valeurs de x_i sont supérieures aux valeurs de y_j).
- **Suite ordonnée** $z(\cdot) = (360, 380, 400, 430, 430, 458, 478, 480, 490, 538, 548, 548, 568, 570, 578, 618)$
 - **Médicaments associés**
($y_2, y_7, y_8, y_1 = y_3, x_5, x_4, y_6, y_5, x_6, x_3 = x_8, x_2, y_4, x_1, x_7$)
 - **rangs des y_j**
 $r_1 = 4.5, r_2 = 1, r_3 = 4.5, r_4 = 14, r_5 = 9, r_6 = 8, r_7 = 2, r_8 = 3$ et $W = \sum_{i=1}^8 r_i = 46$
 - **Statistique de Mann-Whitney** : $U_{\text{obs}} = W - \frac{8 \times 9}{2} = 10$
 - **p-value** : en utilisant l'approximation normale de la loi de Mann-Whitney avec correction de continuité, on obtient

$$p\text{-value} = F\left(\frac{U_{\text{obs}} - E[U]}{\sigma}\right)$$

avec $E[U] = \frac{nm}{2} - 0.5$ et $\sigma^2 = \frac{nm(n+m+1)}{12}$ et F est la fonction de répartition de la loi normale $\mathcal{N}(0, 1)$. Après application numérique, on obtient $p\text{-value} \approx 0.012$. **Donc on rejette H_0 (définie par $F = G$) avec $\alpha = 0.05$, i.e., on décide que le soporifique S a plus d'effet sur le sommeil que le produit I, avec ce risque $\alpha = 0.05$.**

- Pour $\alpha = 0.05$, les tables du test unilatéral de Mann-Whitney donnent un seuil $S_{0.05} = 15 > U = 10$, donc on rejette H_0 avec ce risque α .
- Pour $\alpha = 0.05$, les tables du test unilatéral de Wilcoxon (test unilatéral à gauche WS) donnent un seuil $S_{0.05} = 51 > W = 46$, ce qui confirme le rejet de H_0 avec ce risque α .

Remarques :

- Sous Matlab, la commande est $[p, h, stats] = \text{ranksum}(y, x, 'tail', 'left')$ (car on calcule les rangs du premier échantillon, ici y , et "left" indique qu'on cherche si les valeurs de y_i sont inférieures aux valeurs de x_i).
- sous R, la somme des rangs est la statistique de Mann-Whitney, donc il faut retrancher $m(m+1)/2$ pour avoir U .

n ₂	α	n ₁																	
		3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
3	.05	0	0	1	2	2	3	4	4	5	5	6	7	7	8	9	9	10	11
	.01	--	0	0	0	0	0	1	1	1	2	2	3	3	4	4	4	5	
4	.05	0	1	2	3	4	5	6	7	8	9	10	11	12	14	15	16	17	18
	.01	--	--	0	1	1	2	3	3	4	5	5	6	7	7	8	9	9	10
5	.05	1	2	4	5	6	8	9	11	12	13	15	16	18	19	20	22	23	25
	.01	--	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
6	.05	2	3	5	7	8	10	12	14	16	17	19	21	23	25	26	28	30	32
	.01	--	1	2	3	4	6	7	8	9	11	12	13	15	16	18	19	20	22
7	.05	2	4	6	8	11	13	15	17	19	21	24	26	28	30	33	35	37	39
	.01	0	1	3	4	6	7	9	11	12	14	16	17	19	21	23	24	26	28
8	.05	3	5	8	10	13	15	18	20	23	26	28	31	33	36	39	41	44	47
	.01	0	2	4	6	7	9	11	13	15	17	20	22	24	26	28	30	32	34
9	.05	4	6	9	12	15	18	21	24	27	30	33	36	39	42	45	48	51	54
	.01	1	3	5	7	9	11	14	16	18	21	23	26	28	31	33	36	38	40
10	.05	4	7	11	14	17	20	24	27	31	34	37	41	44	48	51	55	58	62
	.01	1	3	6	8	11	13	16	19	22	24	27	30	33	36	38	41	44	47
11	.05	5	8	12	16	19	23	27	31	34	38	42	46	50	54	57	61	65	69
	.01	1	4	7	9	12	15	18	22	25	28	31	34	37	41	44	47	50	53
12	.05	5	9	13	17	21	26	30	34	38	42	47	51	55	60	64	68	72	77
	.01	2	5	8	11	14	17	21	24	28	31	35	38	42	46	49	53	56	60
13	.05	6	10	15	19	24	28	33	37	42	47	51	56	61	65	70	75	80	84
	.01	2	5	9	12	16	20	23	27	31	35	39	43	47	51	55	59	63	67
14	.05	7	11	16	21	26	31	36	41	46	51	56	61	66	71	77	82	87	92
	.01	2	6	10	13	17	22	26	30	34	38	43	47	51	56	60	65	69	73
15	.05	7	12	18	23	28	33	39	44	50	55	61	66	72	77	83	88	94	100
	.01	3	7	11	15	19	24	28	33	37	42	47	51	56	61	66	70	75	80
16	.05	8	14	19	25	30	36	42	48	54	60	65	71	77	83	89	95	101	107
	.01	3	7	12	16	21	26	31	36	41	46	51	56	61	66	71	76	82	87
17	.05	9	15	20	26	33	39	45	51	57	64	70	77	83	89	96	102	109	115
	.01	4	8	13	18	23	28	33	38	44	49	55	60	66	71	77	82	88	93
18	.05	9	16	22	28	35	41	48	55	61	68	75	82	88	95	102	109	116	123
	.01	4	9	14	19	24	30	36	41	47	53	59	65	70	76	82	88	94	100
19	.05	10	17	23	30	37	44	51	58	65	72	80	87	94	101	109	116	123	130
	.01	4	9	15	20	26	32	38	44	50	56	63	69	75	82	88	94	101	107
20	.05	11	18	25	32	39	47	54	62	69	77	84	92	100	107	115	123	130	138
	.01	5	10	16	22	28	34	40	47	53	60	67	73	80	87	93	100	107	114

Tables pour le test unilatéral à gauche de Mann-Whitney (Rejet de H_0 si $U < S_\alpha$). Pour un test bilatéral, les valeurs correspondent à deux fois le risque. Par exemple, pour $n = m = 7$, le seuil $S_\alpha = 6$ correspond à un risque $\alpha = 0.01$ pour un test unilatéral et à un risque 0.02 pour un test bilatéral.

Appendix : Wilcoxon Rank-Sum Table

Probabilities relate to the distribution of W_A , the rank sum for group A when $H_0 : A = B$ is true. The tabulated value for the **lower tail** is the largest value of w_A for which $\text{pr}(W_A \leq w_A) \leq \text{prob}$. The tabulated value for the **upper tail** is the smallest value of w_A for which $\text{pr}(W_A \geq w_A) \leq \text{prob}$.

		Lower Tail					Upper Tail						
n_A	n_B	<i>prob</i>					<i>prob</i>						
		.005	.01	.025	.05	.10	.20	.20	.10	.05	.025	.01	.005
4	4			10	11	13	14	22	23	25	26		
	5		10	11	12	14	15	25	26	28	29	30	
	6	10	11	12	13	15	17	27	29	31	32	33	34
	7	10	11	13	14	16	18	30	32	34	35	37	38
	8	11	12	14	15	17	20	32	35	37	38	40	41
	9	11	13	14	16	19	21	35	37	40	42	43	45
	10	12	13	15	17	20	23	37	40	43	45	47	48
	11	12	14	16	18	21	24	40	43	46	48	50	52
	12	13	15	17	19	22	26	42	46	49	51	53	55
5	5	15	16	17	19	20	22	33	35	36	38	39	40
	6	16	17	18	20	22	24	36	38	40	42	43	44
	7	16	18	20	21	23	26	39	42	44	45	47	49
	8	17	19	21	23	25	28	42	45	47	49	51	53
	9	18	20	22	24	27	30	45	48	51	53	55	57
	10	19	21	23	26	28	32	48	52	54	57	59	61
	11	20	22	24	27	30	34	51	55	58	61	63	65
	12	21	23	26	28	32	36	54	58	62	64	67	69
6	6	23	24	26	28	30	33	45	48	50	52	54	55
	7	24	25	27	29	32	35	49	52	55	57	59	60
	8	25	27	29	31	34	37	53	56	59	61	63	65
	9	26	28	31	33	36	40	56	60	63	65	68	70
	10	27	29	32	35	38	42	60	64	67	70	73	75
	11	28	30	34	37	40	44	64	68	71	74	78	80
	12	30	32	35	38	42	47	67	72	76	79	82	84
7	7	32	34	36	39	41	45	60	64	66	69	71	73
	8	34	35	38	41	44	48	64	68	71	74	77	78
	9	35	37	40	43	46	50	69	73	76	79	82	84
	10	37	39	42	45	49	53	73	77	81	84	87	89
	11	38	40	44	47	51	56	77	82	86	89	93	95
	12	40	42	46	49	54	59	81	86	91	94	98	100
8	8	43	45	49	51	55	59	77	81	85	87	91	93
	9	45	47	51	54	58	62	82	86	90	93	97	99
	10	47	49	53	56	60	65	87	92	96	99	103	105
	11	49	51	55	59	63	69	91	97	101	105	109	111
	12	51	53	58	62	66	72	96	102	106	110	115	117
9	9	56	59	62	66	70	75	96	101	105	109	112	115
	10	58	61	65	69	73	78	102	107	111	115	119	122
	11	61	63	68	72	76	82	107	113	117	121	126	128
	12	63	66	71	75	80	86	112	118	123	127	132	135
10	10	71	74	78	82	87	93	117	123	128	132	136	139
	11	73	77	81	86	91	97	123	129	134	139	143	147
	12	76	79	84	89	94	101	129	136	141	146	151	154
11	11	87	91	96	100	106	112	141	147	153	157	162	166
	12	90	94	99	104	110	117	147	154	160	165	170	174
12	12	105	109	115	120	127	134	166	173	180	185	191	195

Tables pour les tests unilatéraux à gauche et à droite de Wilcoxon (Rejet de H_0 si $W < S_\alpha$ ou si $W > S_\alpha$).

Exercice 3

- **Énoncé** : Dans une usine, on a du mal à fixer le taux d'acidité des yaourts. En comparant ce taux pour 10 pots après 5 heures de fabrication au taux pour ces mêmes 10 pots juste au moment de la fabrication, on obtient :

0h : x_i	12.51	12.48	12.91	12.56	12.58	12.82	12.53	12.50	12.51	12.42
5h : y_i	12.82	12.79	12.74	12.88	12.82	12.40	12.84	12.81	12.91	12.39

1. Peut-on considérer que les échantillons (X_1, \dots, X_n) et (Y_1, \dots, Y_n) sont indépendants ?
2. On considère les variables $Z_i = Y_i - X_i$ pour $i = 1, \dots, n$. On supposera dans un premier temps que les variables Z_i sont i.i.d. de loi normale. Proposez un test, basé sur (Z_1, \dots, Z_n) pour tester s'il y a eu une variation significative du taux d'acidité.
3. On ne suppose plus que les Z_i sont de loi normale et on introduit la variable

$$N = \sum_{i=1}^n \mathbb{1}_{Z_i \geq 0}$$

Quelle est la loi de N sous l'hypothèse que la médiane des variables Z_i est nulle ?

4. En utilisant la variable N , testez s'il y a eu une variation significative du taux d'acidité.

- **Correction**

1. Comme les deux échantillons correspondent aux mêmes pots à différents instants, on ne peut pas supposer qu'ils sont indépendants. On parle d'échantillons appariés.
2. Si on peut supposer que les variables $Z_i = Y_i - X_i$ sont i.i.d. normales, on peut faire un test de Student avec les hypothèses $H_0 : m = 0$ et $H_1 : m \neq 0$, où m est la moyenne de Z_i . Ce test est défini par


$$\text{Rejet de } H_0 \text{ si } T_n = \left| \sqrt{n} \frac{\bar{Z}}{S_n} \right| > S_{n,\alpha}$$

avec $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (Z_i - \bar{Z})^2$ et $\bar{Z} = \frac{1}{n} \sum_{i=1}^n Z_i$, avec un seuil $S_{n,\alpha} = F_{n-1}^{-1}(1 - \alpha)$, F_{n-1} étant la fonction de répartition d'une loi de Student à $n - 1$ degrés de liberté. Quelques calculs numériques permettent d'obtenir $T_n \approx 1.84$ et $S_{10,0.05} \approx 2.228$. On accepte donc l'hypothèse H_0 avec $\alpha = 0.05$, ce qui signifie qu'il n'y a pas de variation significative du taux d'acidité après 5 heures.

3. Comme la médiane des Z_i est nulle, on a $P[Z_i \geq 0] = 1/2$ et comme les variables Z_i sont indépendantes, N suit une loi binomiale $\mathcal{B}(n, 1/2)$.
4. On peut rejeter H_0 si $N > S_{n,\alpha}$. La table de la loi binomiale donne $S_{10,0.05} \in]7, 8[$. Comme $N = 7 < S_{10,0.05}$, on accepte l'hypothèse H_0 avec le risque $\alpha = 0.05$ et donc on en conclut que qu'il n'y a pas de variation significative du taux d'acidité après 5 heures.

Table de la loi de Student

Valeurs de T ayant la probabilité P d'être dépassées en valeur absolue




ν	$P = 0,90$	0,80	0,70	0,60	0,50	0,40	0,30	0,20	0,10	0,05	0,02	0,01
1	0,158	0,325	0,510	0,727	1,000	1,376	1,963	3,078	6,314	12,706	31,821	63,657
2	0,142	0,289	0,445	0,617	0,816	1,061	1,386	1,886	2,920	4,303	6,965	9,925
3	0,137	0,277	0,424	0,584	0,765	0,978	1,250	1,638	2,353	3,182	4,541	5,841
4	0,134	0,271	0,414	0,569	0,741	0,941	1,190	1,533	2,132	2,776	3,747	4,604
5	0,132	0,267	0,408	0,559	0,727	0,920	1,156	1,476	2,015	2,571	3,365	4,032
6	0,131	0,265	0,404	0,553	0,718	0,906	1,134	1,440	1,943	2,447	3,143	3,707
7	0,130	0,263	0,402	0,549	0,711	0,896	1,119	1,415	1,895	2,365	2,998	3,499
8	0,130	0,262	0,399	0,546	0,706	0,889	1,108	1,397	1,860	2,306	2,896	3,355
9	0,129	0,261	0,398	0,543	0,703	0,883	1,100	1,383	1,833	2,262	2,821	3,250
10	0,129	0,260	0,397	0,542	0,700	0,879	1,093	1,372	1,812	2,228	2,764	3,169
11	0,129	0,260	0,396	0,540	0,697	0,876	1,088	1,363	1,796	2,201	2,718	3,106
12	0,128	0,260	0,395	0,539	0,695	0,873	1,083	1,356	1,782	2,179	2,681	3,055
13	0,128	0,259	0,394	0,538	0,694	0,870	1,079	1,350	1,771	2,160	2,650	3,012
14	0,128	0,258	0,393	0,537	0,692	0,868	1,076	1,345	1,761	2,145	2,624	2,977
15	0,128	0,258	0,393	0,536	0,691	0,866	1,074	1,341	1,753	2,131	2,602	2,947
16	0,128	0,258	0,392	0,535	0,690	0,865	1,071	1,337	1,746	2,120	2,583	2,921
17	0,128	0,257	0,392	0,534	0,689	0,863	1,069	1,333	1,740	2,110	2,567	2,898
18	0,127	0,257	0,392	0,534	0,688	0,862	1,067	1,330	1,734	2,101	2,552	2,878
19	0,127	0,257	0,391	0,533	0,688	0,861	1,066	1,328	1,729	2,093	2,539	2,861
20	0,127	0,257	0,391	0,533	0,687	0,860	1,064	1,325	1,725	2,086	2,528	2,845
21	0,127	0,257	0,391	0,532	0,686	0,859	1,063	1,323	1,721	2,080	2,518	2,831
22	0,127	0,256	0,390	0,532	0,686	0,858	1,061	1,321	1,717	2,074	2,508	2,819
23	0,127	0,256	0,390	0,532	0,685	0,858	1,060	1,319	1,714	2,069	2,500	2,807
24	0,127	0,256	0,390	0,531	0,685	0,857	1,059	1,318	1,711	2,064	2,492	2,797
25	0,127	0,256	0,390	0,531	0,684	0,856	1,058	1,316	1,708	2,060	2,485	2,787
26	0,127	0,256	0,390	0,531	0,684	0,856	1,058	1,315	1,706	2,056	2,479	2,779
27	0,127	0,256	0,389	0,531	0,684	0,855	1,057	1,314	1,703	2,052	2,473	2,771
28	0,127	0,256	0,389	0,530	0,683	0,855	1,056	1,313	1,701	2,048	2,467	2,763
29	0,127	0,256	0,389	0,530	0,683	0,854	1,055	1,311	1,699	2,045	2,462	2,756
30	0,127	0,256	0,389	0,530	0,683	0,854	1,055	1,310	1,697	2,042	2,457	2,750
∞	0,126	0,253	0,385	0,524	0,674	0,842	1,036	1,282	1,645	1,96	2,326	2,576

Nota. ν est le nombre de degrés de liberté.
 Le quantile d'ordre $1 - \frac{\alpha}{2}$ se lit dans la colonne $P = \alpha$.
 Le quantile d'ordre $1 - \alpha$ se lit dans la colonne $P = 2\alpha$.

Table de la variable aléatoire Binomiale

Fournit la probabilité $P(X \leq x)$
pour $X \sim \text{Bi}(n, p)$



p		0,1	0,2	0,25	0,3	0,4	0,5	0,6	0,7	0,75	0,8	0,9
n=5	x											
	0	0,5905	0,3277	0,2373	0,1681	0,0778	0,0312	0,0102	0,0024	0,0010	0,0003	0,0000
	1	0,9185	0,7373	0,6328	0,5282	0,3370	0,1875	0,0870	0,0308	0,0156	0,0067	0,0005
	2	0,9914	0,9421	0,8965	0,8369	0,6826	0,5000	0,3174	0,1631	0,1035	0,0579	0,0086
	3	0,9995	0,9933	0,9844	0,9692	0,9130	0,8125	0,6630	0,4718	0,3672	0,2627	0,0815
	4	1,0000	0,9997	0,9990	0,9976	0,9898	0,9688	0,9222	0,8319	0,7627	0,6723	0,4095
5	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
n=10	x											
	0	0,3487	0,1074	0,0563	0,0282	0,0060	0,0010	0,0001	0,0000	0,0000	0,0000	0,0000
	1	0,7361	0,3758	0,2440	0,1493	0,0464	0,0107	0,0017	0,0001	0,0000	0,0000	0,0000
	2	0,9298	0,6778	0,5256	0,3828	0,1673	0,0547	0,0123	0,0016	0,0004	0,0001	0,0000
	3	0,9872	0,8791	0,7759	0,6496	0,3823	0,1719	0,0548	0,0106	0,0035	0,0009	0,0000
	4	0,9984	0,9672	0,9219	0,8497	0,6331	0,3770	0,1662	0,0473	0,0197	0,0064	0,0001
	5	0,9999	0,9936	0,9803	0,9527	0,8338	0,6230	0,3669	0,1503	0,0781	0,0328	0,0016
	6	1,0000	0,9991	0,9965	0,9894	0,9452	0,8281	0,6177	0,3504	0,2241	0,1209	0,0128
	7	1,0000	0,9999	0,9996	0,9984	0,9877	0,9453	0,8327	0,6172	0,4744	0,3222	0,0702
	8		1,0000	1,0000	0,9999	0,9983	0,9893	0,9536	0,8507	0,7560	0,6242	0,2639
	9		1,0000	1,0000	1,0000	0,9999	0,9990	0,9940	0,9718	0,9437	0,8926	0,6513
10				1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
n=15	x											
	0	0,2059	0,0352	0,0134	0,0047	0,0005	0,0000	0,0000				
	1	0,5490	0,1671	0,0802	0,0353	0,0052	0,0005	0,0000	0,0000			
	2	0,8159	0,3980	0,2361	0,1268	0,0271	0,0037	0,0003	0,0000	0,0000		
	3	0,9444	0,6482	0,4613	0,2969	0,0905	0,0176	0,0019	0,0001	0,0000	0,0000	
	4	0,9873	0,8358	0,6865	0,5155	0,2173	0,0592	0,0093	0,0007	0,0001	0,0000	
	5	0,9978	0,9389	0,8516	0,7216	0,4032	0,1509	0,0338	0,0037	0,0008	0,0001	
	6	0,9997	0,9819	0,9434	0,8689	0,6098	0,3036	0,0950	0,0152	0,0042	0,0008	0,0000
	7	1,0000	0,9958	0,9827	0,9500	0,7869	0,5000	0,2131	0,0500	0,0173	0,0042	0,0000
	8	1,0000	0,9992	0,9958	0,9848	0,9050	0,6964	0,3902	0,1311	0,0566	0,0181	0,0003
	9		0,9999	0,9992	0,9963	0,9662	0,8491	0,5968	0,2784	0,1484	0,0611	0,0022
	10		1,0000	0,9999	0,9993	0,9907	0,9408	0,7827	0,4845	0,3135	0,1642	0,0127
	11		1,0000	1,0000	0,9999	0,9981	0,9824	0,9095	0,7031	0,5387	0,3518	0,0556
	12			1,0000	1,0000	0,9997	0,9963	0,9729	0,8732	0,7639	0,6020	0,1841
	13				1,0000	0,9995	0,9948	0,9647	0,9198	0,8329	0,4510	
	14					1,0000	1,0000	0,9995	0,9953	0,9866	0,9648	0,7941
15						1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000

Tables loi binomiale.

p		0,1	0,2	0,25	0,3	0,4	0,5	0,6	0,7	0,75	0,8	0,9
n=20	x											
	0	0,1216	0,0115	0,0032	0,0008	0,0000	0,0000					
	1	0,3917	0,0692	0,0243	0,0076	0,0005	0,0000					
	2	0,6769	0,2061	0,0913	0,0355	0,0036	0,0002	0,0000				
	3	0,8670	0,4114	0,2252	0,1071	0,0160	0,0013	0,0000				
	4	0,9568	0,6296	0,4148	0,2375	0,0510	0,0059	0,0003	0,0000			
	5	0,9887	0,8042	0,6172	0,4164	0,1256	0,0207	0,0016	0,0000	0,0000		
	6	0,9976	0,9133	0,7858	0,6080	0,2500	0,0577	0,0065	0,0003	0,0000	0,0000	
	7	0,9996	0,9679	0,8982	0,7723	0,4159	0,1316	0,0210	0,0013	0,0002	0,0000	
	8	0,9999	0,9900	0,9591	0,8867	0,5956	0,2517	0,0565	0,0051	0,0009	0,0001	
	9	1,0000	0,9974	0,9861	0,9520	0,7553	0,4119	0,1275	0,0171	0,0039	0,0006	0,0000
	10	1,0000	0,9994	0,9961	0,9829	0,8725	0,5881	0,2447	0,0480	0,0139	0,0026	0,0000
	11		0,9999	0,9991	0,9949	0,9435	0,7483	0,4044	0,1133	0,0409	0,0100	0,0001
	12		1,0000	0,9998	0,9987	0,9790	0,8684	0,5841	0,2277	0,1018	0,0321	0,0004
	13		1,0000	1,0000	0,9997	0,9935	0,9423	0,7500	0,3920	0,2142	0,0867	0,0024
	14			1,0000	1,0000	0,9984	0,9793	0,8744	0,5836	0,3828	0,1958	0,0113
	15				1,0000	0,9997	0,9941	0,9490	0,7625	0,5852	0,3704	0,0432
	16					1,0000	0,9987	0,9840	0,8929	0,7748	0,5886	0,1330
	17					1,0000	0,9998	0,9964	0,9645	0,9087	0,7939	0,3231
	18						1,0000	0,9995	0,9924	0,9757	0,9308	0,6083
	19							1,0000	0,9992	0,9968	0,9885	0,8784
20								1,0000	1,0000	1,0000	1,0000	
n=25	x											
	0	0,0718	0,0038	0,0008	0,0001	0,0000						
	1	0,2712	0,0274	0,0070	0,0016	0,0001	0,0000					
	2	0,5371	0,0982	0,0321	0,0090	0,0004	0,0000					
	3	0,7636	0,2340	0,0962	0,0332	0,0024	0,0001	0,0000				
	4	0,9020	0,4207	0,2137	0,0905	0,0095	0,0005	0,0000				
	5	0,9666	0,6167	0,3783	0,1935	0,0294	0,0020	0,0001				
	6	0,9905	0,7800	0,5611	0,3407	0,0736	0,0073	0,0003	0,0000			
	7	0,9977	0,8909	0,7265	0,5118	0,1536	0,0216	0,0012	0,0000			
	8	0,9995	0,9532	0,8506	0,6769	0,2735	0,0539	0,0043	0,0001	0,0000		
	9	0,9999	0,9827	0,9287	0,8106	0,4246	0,1148	0,0132	0,0005	0,0000	0,0000	
	10	1,0000	0,9944	0,9703	0,9022	0,5858	0,2122	0,0344	0,0018	0,0002	0,0000	
	11	1,0000	0,9985	0,9893	0,9558	0,7323	0,3450	0,0778	0,0060	0,0009	0,0001	
	12		0,9996	0,9966	0,9825	0,8462	0,5000	0,1538	0,0175	0,0034	0,0004	
	13		0,9999	0,9991	0,9940	0,9222	0,6550	0,2677	0,0442	0,0107	0,0015	0,0000
	14		1,0000	0,9998	0,9982	0,9656	0,7878	0,4142	0,0978	0,0297	0,0056	0,0000
	15		1,0000	1,0000	0,9995	0,9868	0,8852	0,5754	0,1894	0,0713	0,0173	0,0001
	16			1,0000	0,9999	0,9957	0,9461	0,7265	0,3231	0,1494	0,0468	0,0005
	17				1,0000	0,9988	0,9784	0,8464	0,4882	0,2735	0,1091	0,0023
	18					1,0000	0,9997	0,9927	0,9264	0,6593	0,4389	0,2200
	19						0,9999	0,9980	0,9706	0,8065	0,6217	0,3833
	20						1,0000	0,9995	0,9905	0,9095	0,7863	0,5793
	21							1,0000	0,9999	0,9976	0,9668	0,9038
	22								1,0000	0,9996	0,9910	0,9679
	23									1,0000	0,9999	0,9930
	24										1,0000	0,9962
25											1,0000	

Tables loi binomiale.


Exercice 4

- **Énoncé** : On pèse 20 plaquettes de beurre pris au hasard dans une production normande. Les résultats, en grammes, sont :

247.0	247.8	250.2	251.3	251.9	249.4	248.8	247.1	255.0	247.0
254.8	244.8	250.7	250.7	252.6	251.1	254.1	249.2	252.0	254.0

On suppose que le poids en grammes d'une plaquette de beurre de cette production peut être modélisé par une v.a.r X . Peut-on affirmer que X suit une loi normale ?

- **Correction** : avec un nombre de données aussi faible, la superposition de l'histogramme et de la densité de probabilité de la loi normale de moyenne $\hat{m} = \bar{x}$ et de variance $\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ est peu informative, comme le montre la figure ci-dessous



Il est donc plus judicieux d'appliquer un des tests de normalité du cours.

- **Test de Lilliefors** : la valeur de la statistique de test est $D_n = 0.0912$ et le seuil associé est $S_{20,0.05} = 0.1920$ donc on accepte l'hypothèse de normalité avec le risque $\alpha = 0.05$ (la p -valeur vérifie $p > 0.50$).

La commande Matlab est $x = [247.0, 247.8, 250.2, 251.3, 251.9, 249.4, 248.8, 247.1, 255.0, 247.0, 254.8, \dots]$ et $[H, P, KSTAT, critval] = lillietest(x)$.

- **Test de Shapiro-Wilk** : la statistique du test de Shapiro-Wilk est $SW_n = 0.9698$ tandis que le seuil associé est $S_{20,0.05} = 0.905$ donc on accepte également l'hypothèse de normalité avec le risque $\alpha = 0.05$ (la p -valeur est $p = 0.7516$).

La commande Matlab est $[H, pValue, SWstatistic] = swtest(x, 0.05)$.

$n \setminus \alpha$	0.01	0.05	0.10	0.15	0.20
16	0.2477	0.2128	0.1956	0.1843	0.1758
17	0.2408	0.2071	0.1902	0.1794	0.1711
18	0.2345	0.2018	0.1852	0.1747	0.1666
19	0.2285	0.1965	0.1803	0.1700	0.1624
20	0.2226	0.1920	0.1764	0.1666	0.1589
21	0.2190	0.1881	0.1726	0.1629	0.1553
22	0.2141	0.1840	0.1690	0.1592	0.1517
23	0.2090	0.1798	0.1650	0.1555	0.1484
24	0.2053	0.1766	0.1619	0.1527	0.1458
25	0.2010	0.1726	0.1589	0.1498	0.1429
26	0.1985	0.1699	0.1562	0.1472	0.1406
27	0.1941	0.1665	0.1533	0.1448	0.1381
28	0.1911	0.1641	0.1509	0.1423	0.1358
29	0.1886	0.1614	0.1483	0.1398	0.1334
30	0.1848	0.1590	0.1460	0.1378	0.1315
31	0.1820	0.1559	0.1432	0.1353	0.1291
32	0.1798	0.1542	0.1415	0.1336	0.1274
33	0.1770	0.1518	0.1392	0.1314	0.1254
34	0.1747	0.1497	0.1373	0.1295	0.1236
35	0.1720	0.1478	0.1356	0.1278	0.1220
36	0.1695	0.1454	0.1336	0.1260	0.1203
37	0.1677	0.1436	0.1320	0.1245	0.1188
38	0.1653	0.1421	0.1303	0.1230	0.1174
39	0.1634	0.1402	0.1288	0.1214	0.1159
40	0.1616	0.1386	0.1275	0.1204	0.1147
41	0.1599	0.1373	0.1258	0.1186	0.1131
42	0.1573	0.1353	0.1244	0.1172	0.1119
43	0.1556	0.1339	0.1228	0.1159	0.1106
44	0.1542	0.1322	0.1216	0.1148	0.1095
45	0.1525	0.1309	0.1204	0.1134	0.1083
46	0.1512	0.1293	0.1189	0.1123	0.1071
47	0.1499	0.1282	0.1180	0.1113	0.1062
48	0.1476	0.1269	0.1165	0.1098	0.1047
49	0.1463	0.1256	0.1153	0.1089	0.1040
50	0.1457	0.1246	0.1142	0.1079	0.1030
OVER 50	1.035	0.895	0.819	0.775	0.741
	$\overline{f(n)}$	$\overline{f(n)}$	$\overline{f(n)}$	$\overline{f(n)}$	$\overline{f(n)}$

where

$$f(n) = \frac{.83 + n}{\sqrt{n}} - .01$$

Valeurs du seuil pour le test de Lilliefors.

Table 4b : table des valeurs limites W_α de $W = \frac{b^2}{Z^2}$
 pour les risques $\alpha = 5\%$ et 1%
 (Biometrika 1965)

n	Risque 5 %	Risque 1 %
	$W_{0,05}$	$W_{0,01}$
5	0,762	0,686
6	0,788	0,713
7	0,803	0,730
8	0,818	0,749
9	0,829	0,764
10	0,842	0,781
11	0,850	0,792
12	0,859	0,805
13	0,866	0,814
14	0,874	0,825
15	0,881	0,835
16	0,887	0,844
17	0,892	0,851
18	0,897	0,858
19	0,901	0,863
20	0,905	0,868
21	0,908	0,873
22	0,911	0,878
23	0,914	0,881
24	0,916	0,884
25	0,918	0,888
26	0,920	0,891
27	0,923	0,894
28	0,924	0,896
29	0,926	0,898
30	0,927	0,900
31	0,929	0,902
32	0,930	0,904
33	0,931	0,906
34	0,933	0,908
35	0,934	0,910
36	0,935	0,912
37	0,936	0,914
38	0,938	0,916
39	0,939	0,917
40	0,940	0,919
41	0,941	0,920
42	0,942	0,922
43	0,943	0,923
44	0,944	0,924
45	0,945	0,926
46	0,945	0,927
47	0,946	0,928
48	0,947	0,929
49	0,947	0,929
50	0,947	0,930

Valeurs du seuil pour le test de Shapiro-Wilk.

Exercice 5

- **Énoncé** : Pour comparer la proportion de personnes atteintes par la grippe en ville et à la campagne, deux échantillons ont été étudiés :
 - sur 100 personnes habitant une grande agglomération, on a observé une proportion $p_0 = 0.24$ de sujets ayant eu la grippe.
 - sur 100 personnes habitant à la campagne, on a observé une proportion $p_1 = 0.20$ de sujets ayant eu la grippe.

Selon vous, la proportion de sujets atteints par la grippe est-elle différente en ville et à la campagne ?

- **Correction** : il suffit d'effectuer un test du χ^2 d'homogénéité pour déterminer si les deux lois définies sur l'ensemble {Grippe, Non-grippe} sont identiques ou pas.

	Ville	Campagne	$N_{k.}$
Grippe	24	20	44
Non-Grippe	76	80	156
$N_{.l}$	100	100	$n = 200$

Les **effectifs théoriques** sous l'hypothèse H_0 sont

	Ville	Campagne
Grippe	$\frac{44 \times 100}{200} = 22$	$\frac{44 \times 100}{200} = 22$
Non-Grippe	$\frac{156 \times 100}{200} = 78$	$\frac{156 \times 100}{200} = 78$

La statistique du test du χ^2 d'homogénéité est donc

$$\phi = \frac{(24 - 22)^2}{22} + \frac{(76 - 78)^2}{78} + \frac{(20 - 22)^2}{22} + \frac{(80 - 78)^2}{78} = \frac{4}{11} + \frac{4}{39} \approx 0.47.$$

Puisque $(K - 1) \times (L - 1) = 1$, le seuil du test s'écrit $S_\alpha = F_1^{-1}(0.95) = 3.84$ (où F_1 est la fonction de répartition d'une loi du χ_1^2). Donc on accepte l'hypothèse H_0 avec le risque $\alpha = 0.05$ (la p -valeur est $p = 1 - F_1(0.47) = 0.4947$), i.e., on peut accepter que les proportions de sujets atteints par la grippe en ville et à la campagne sont similaires. *Remarque* : la table indique que la p -valeur est dans l'intervalle $]0.2, 0.8[$, ce qui est suffisant pour prendre une décision avec les risques habituels $\alpha = 0.01$ et $\alpha = 0.05$.

• **Correction**

1. On peut effectuer un test du χ^2 défini par

$$\text{Rejet de } H_0 \text{ si } \phi_n = \sum_{k=1}^K \frac{(Z_k - np_k)^2}{np_k} > S_{K,\alpha}$$

La statistique de test est donc

$$\phi_n = \frac{(100 - 160 \times \frac{9}{16})^2}{90} + \frac{(18 - 160 \times \frac{3}{16})^2}{30} + \frac{(24 - 160 \times \frac{3}{16})^2}{30} + \frac{(18 - 160 \times \frac{1}{16})^2}{10} = \frac{608}{45} \approx 13.51.$$

Sous l'hypothèse H_0 , ϕ_n suit asymptotiquement une loi du χ_3^2 , donc

$$S_{K,\alpha} = F_3^{-1}(1 - \alpha)$$

où F_3^{-1} est l'inverse de la fonction de répartition d'une loi du χ_3^2 . Pour $\alpha = 0.05$, on obtient

$$S_{K,\alpha} = F_3^{-1}(0.95) \approx 7.81.$$

On rejette donc l'hypothèse que les proportions de boules noires, rouges, jaunes et vertes sont respectivement 9/16, 3/16, 3/16 et 1/16. La p -valeur du test est la valeur de α telle que $\phi_n = 13.81 = S_{K,\alpha} = F_3^{-1}(1 - \alpha)$ donc cette p -valeur est égale à $1 - F_3(\phi_n) = 1 - F_3(13.51)$. En utilisant les tables, on en déduit

$$p\text{-valeur} \in]10^{-3}, 5.10^{-3}[.$$

2. La loi multinomiale de paramètres $(n, (p_1, p_2, p_3, p_4))$ est définie par

$$P[N_1 = n_1, \dots, N_K = n_k] = \frac{n!}{n_1! \dots n_k!} p_1^{n_1} \dots p_K^{n_K} \propto p_1^{n_1} \dots p_K^{n_K}$$

avec $n = \sum_{k=1}^K n_i$. Avec $(p_1, p_2, p_3, p_4) = (1 - 3\theta, \theta, \theta, \theta)$, on a

$$P[N_1 = n_1, \dots, N_K = n_k] \propto (1 - 3\theta)^{n_1} \theta^{n_2 + n_3 + n_4} = (1 - 3\theta)^{n_1} \theta^{n - n_1}$$

qui est maximum pour θ solution de

$$\frac{-3n_1}{1 - 3\theta} + \frac{n - n_1}{\theta} = 0 \Leftrightarrow \theta = \frac{1}{3} \left(1 - \frac{n_1}{n} \right).$$

L'estimateur du maximum de vraisemblance de θ est donc

$$\hat{\theta} = \frac{1}{3} \left(1 - \frac{N_1}{n} \right)$$

où N_1 est le nombre de boules noires. L'application numérique donne

$$\hat{\theta} = \frac{1}{8}.$$

3. Dans le cas où on estime un paramètre, la loi asymptotique de ϕ_n sous H_0 est une loi du χ_{K-2}^2 . Pour $\alpha = 0.05$, le seuil est donc

$$S_{K,0.05} = F_2^{-1}(0.95) \approx 5.99.$$

La statistique de test est donc

$$\phi_n = \frac{(100 - 160 \times \frac{5}{8})^2}{100} + \frac{(18 - 160 \times \frac{1}{8})^2}{20} + \frac{(24 - 160 \times \frac{1}{8})^2}{20} + \frac{(18 - 160 \times \frac{1}{8})^2}{20} = \frac{6}{5} = 1.2.$$

Donc on accepte l'hypothèse que le taux de boules de chaque couleur est de la forme $(p_1, p_2, p_3, p_4) = (1 - 3\theta, \theta, \theta, \theta)$ avec $\theta = \frac{1}{8}$.

Exercice 7

- **Énoncé** : À une élection, deux candidats se présentent : N. S. et S. R. On demande aux 500 électeurs sondés leur opinion politique (i.e., leur choix à la future élection) mais aussi leur appartenance sociale (Rentiers/Actifs/Retraités). On obtient les résultats suivants :

	N. S.	S. R.	Somme
Rentiers	40	100	140
Actifs	140	210	350
Retraités	77	23	100
Somme	257	333	590

L'opinion politique dépend-elle de l'appartenance sociale ?

- **Correction** : on demande de tester l'indépendance entre l'opinion politique et l'appartenance sociale des votants. On peut faire ce test à l'aide d'un test du χ^2 d'indépendance. Le test du χ^2 d'indépendance rejette H_0 si

$$I_n = \sum_{k=1}^K \sum_{l=1}^L \frac{\left(N_{k,l} - \frac{N_{k,\cdot} N_{\cdot,l}}{n}\right)^2}{\frac{N_{k,\cdot} N_{\cdot,l}}{n}} > S_{K,L,\alpha}$$

Pour cet exemple, la statistique de test vaut

$$I_n = \frac{\left(40 - \frac{140 \times 257}{590}\right)^2}{\frac{140 \times 257}{590}} + \dots + \frac{\left(23 - \frac{100 \times 333}{590}\right)^2}{\frac{100 \times 333}{590}} \approx 60.82.$$

Le seuil de décision vaut $S_\alpha = F_2^{-1}(0.95) = 5.99$ où F_2 est la fonction de répartition d'une loi du χ_2^2 car $(K-1) \times (L-1) = 2$. On rejette donc H_0 avec le risque $\alpha = 0.05$ et donc on décide que l'opinion politique dépend de l'appartenance sociale avec un risque $\alpha = 0.05$ (la p -valeur vaut $p = 6.22 \times 10^{-14}$).

Exercice 8

- **Énoncé** : Dans une université, les élèves sont répartis en deux groupes de cours appelés CM1 et CM2. Tous les élèves sont invités à se prononcer pour ou contre la suppression des cours en amphi. Les résultats sont les suivants

	Pour	Contre
CM1	20	80
CM2	40	60

On note $X_i \in \{0, 1\}$ l'avis du i ème élève (avec $X_i = 1$ si le i ème élève est pour et $X_i = 0$ s'il est contre). De même, on note $Y_j \in \{0, 1\}$ le cours du j ème élève avec $Y_j = 1$ si le i ème élève est dans le CM1 et $Y_j = 0$ s'il est dans le CM2.

1. Existe-t-il un lien entre l'appartenance d'un élève à l'un des deux groupes de cours et sa décision concernant la suppression des cours en amphi ?
 2. Les variables (X_1, \dots, X_n) et (Y_1, \dots, Y_n) ont-elle la même loi ?
- **Correction** : Pour déterminer le lien entre les variables X_i et Y_j , on peut faire un test du χ^2 d'indépendance. Le tableau de contingences pour ce problème est

	Pour	Contre	$N_{k,\cdot}$
CM1	20	80	100
CM2	40	60	100
$N_{\cdot,l}$	60	140	200

Le test du χ^2 d'indépendance rejette H_0 si

$$I_n = \sum_{k=1}^K \sum_{l=1}^L \frac{\left(N_{k,l} - \frac{N_{k,\cdot} N_{\cdot,l}}{n}\right)^2}{\frac{N_{k,\cdot} N_{\cdot,l}}{n}} > S_{K,L,\alpha}$$

Pour cet exemple, la statistique de test vaut

$$I_n = \frac{\left(20 - \frac{100 \times 60}{200}\right)^2}{\frac{100 \times 60}{200}} + \frac{\left(80 - \frac{100 \times 140}{200}\right)^2}{\frac{100 \times 140}{200}} + \frac{\left(40 - \frac{100 \times 60}{200}\right)^2}{\frac{100 \times 60}{200}} + \frac{\left(60 - \frac{100 \times 140}{200}\right)^2}{\frac{100 \times 140}{200}}$$

soit

$$I_n = \frac{100}{30} + \frac{100}{70} + \frac{100}{30} + \frac{100}{70} \approx 9.52.$$

Le seuil de décision vaut $S_\alpha = F_1^{-1}(0.95) \approx 3.84$ où F_1 est la fonction de répartition d'une loi du χ_1^2 car $(K - 1) \times (L - 1) = 2$. On rejette donc H_0 avec le risque $\alpha = 0.05$ ce qui signifie qu'il y a un lien entre l'appartenance d'un élève à l'un des deux cours CM1 et CM2 et sa décision.

- Pour répondre à cette question, on peut utiliser un test du χ^2 d'homogénéité. Le tableau de contingences pour ce problème est

	X_i	Y_j	$N_{k.}$
0	60	100	160
1	140	100	240
$N_{.l}$	200	200	400

La statistique du test d'homogénéité associé est

$$I_n = \frac{\left(60 - \frac{160 \times 200}{400}\right)^2}{\frac{160 \times 200}{400}} + \frac{\left(100 - \frac{160 \times 200}{400}\right)^2}{\frac{160 \times 200}{400}} + \frac{\left(140 - \frac{240 \times 200}{400}\right)^2}{\frac{240 \times 200}{400}} + \frac{\left(100 - \frac{240 \times 200}{400}\right)^2}{\frac{240 \times 200}{400}},$$

soit

$$I_n = \frac{400}{80} + \frac{400}{80} + \frac{400}{120} + \frac{400}{120} \approx 12.67.$$


Le seuil de décision vaut $S_\alpha = F_1^{-1}(0.95) \approx 3.84$ où F_1 est la fonction de répartition d'une loi du χ_1^2 car $(K - 1) \times (L - 1) = 2$. On rejette donc H_0 avec le risque $\alpha = 0.05$ ce qui signifie que les variables (X_1, \dots, X_n) et (Y_1, \dots, Y_n) n'ont pas la même loi.

ANNEXE 4 : Tables de la loi normale

Loi Normale $\mathcal{N}(0, 1)$

$$\Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}} du$$

$$\Phi(-x) = 1 - \Phi(x)$$



x	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0.0	.5000	.5040	.5080	.5120	.5160	.5199	.5239	0.5279	.5319	.5359
0.1	.5398	.5438	.5478	.5517	.5557	.5596	.5636	0.5675	.5714	.5753
0.2	.5793	.5832	.5871	.5910	.5948	.5987	.6026	0.6064	.6103	.6141
0.3	.6179	.6217	.6255	.6293	.6331	.6368	.6406	0.6443	.6480	.6517
0.4	.6554	.6591	.6628	.6664	.6700	.6736	.6772	0.6808	.6844	.6879
0.5	.6915	.6950	.6985	.7019	.7054	.7088	.7123	0.7157	.7190	.7224
0.6	.7257	.7291	.7324	.7357	.7389	.7422	.7454	0.7486	.7517	.7549
0.7	.7580	.7611	.7642	.7673	.7703	.7734	.7764	0.7794	.7823	.7852
0.8	.7881	.7910	.7939	.7967	.7995	.8023	.8051	0.8078	.8106	.8133
0.9	.8159	.8186	.8212	.8238	.8264	.8289	.8315	0.8340	.8365	.8389
1.0	.8413	.8438	.8461	.8485	.8508	.8531	.8554	0.8577	.8599	.8621
1.1	.8643	.8665	.8686	.8708	.8729	.8749	.8770	0.8790	.8810	.8830
1.2	.8849	.8869	.8888	.8907	.8925	.8944	.8962	0.8980	.8997	.9015
1.3	.9032	.9049	.9066	.9082	.9099	.9115	.9131	0.9147	.9162	.9177
1.4	.9192	.9207	.9222	.9236	.9251	.9265	.9279	0.9292	.9306	.9319
1.5	.9332	.9345	.9357	.9370	.9382	.9394	.9406	0.9418	.9429	.9441
1.6	.9452	.9463	.9474	.9484	.9495	.9505	.9515	0.9525	.9535	.9545
1.7	.9554	.9564	.9573	.9582	.9591	.9599	.9608	0.9616	.9625	.9633
1.8	.9641	.9649	.9656	.9664	.9671	.9678	.9686	0.9693	.9699	.9706
1.9	.9713	.9719	.9726	.9732	.9738	.9744	.9750	0.9756	.9761	.9767
2.0	.9772	.9778	.9783	.9788	.9793	.9798	.9803	0.9808	.9812	.9817
2.1	.9821	.9826	.9830	.9834	.9838	.9842	.9846	0.9850	.9854	.9857
2.2	.9861	.9864	.9868	.9871	.9875	.9878	.9881	0.9884	.9887	.9890
2.3	.9893	.9896	.9898	.9901	.9904	.9906	.9909	0.9911	.9913	.9916
2.4	.9918	.9920	.9922	.9925	.9927	.9929	.9931	0.9932	.9934	.9936
2.5	.9938	.9940	.9941	.9943	.9945	.9946	.9948	0.9949	.9951	.9952
2.6	.9953	.9955	.9956	.9957	.9959	.9960	.9961	0.9962	.9963	.9964
2.7	.9965	.9966	.9967	.9968	.9969	.9970	.9971	0.9972	.9973	.9974
2.8	.9974	.9975	.9976	.9977	.9977	.9978	.9979	0.9979	.9980	.9981
2.9	.9981	.9982	.9982	.9983	.9984	.9984	.9985	0.9985	.9986	.9986

Fonction de répartition de la loi normale $\mathcal{N}(0, 1)$.

$n \setminus \alpha$	0.01	0.05	0.10	0.15	0.20
16	0.2477	0.2128	0.1956	0.1843	0.1758
17	0.2408	0.2071	0.1902	0.1794	0.1711
18	0.2345	0.2018	0.1852	0.1747	0.1666
19	0.2285	0.1965	0.1803	0.1700	0.1624
20	0.2226	0.1920	0.1764	0.1666	0.1589
21	0.2190	0.1881	0.1726	0.1629	0.1553
22	0.2141	0.1840	0.1690	0.1592	0.1517
23	0.2090	0.1798	0.1650	0.1555	0.1484
24	0.2053	0.1766	0.1619	0.1527	0.1458
25	0.2010	0.1726	0.1589	0.1498	0.1429
26	0.1985	0.1699	0.1562	0.1472	0.1406
27	0.1941	0.1665	0.1533	0.1448	0.1381
28	0.1911	0.1641	0.1509	0.1423	0.1358
29	0.1886	0.1614	0.1483	0.1398	0.1334
30	0.1848	0.1590	0.1460	0.1378	0.1315
31	0.1820	0.1559	0.1432	0.1353	0.1291
32	0.1798	0.1542	0.1415	0.1336	0.1274
33	0.1770	0.1518	0.1392	0.1314	0.1254
34	0.1747	0.1497	0.1373	0.1295	0.1236
35	0.1720	0.1478	0.1356	0.1278	0.1220
36	0.1695	0.1454	0.1336	0.1260	0.1203
37	0.1677	0.1436	0.1320	0.1245	0.1188
38	0.1653	0.1421	0.1303	0.1230	0.1174
39	0.1634	0.1402	0.1288	0.1214	0.1159
40	0.1616	0.1386	0.1275	0.1204	0.1147
41	0.1599	0.1373	0.1258	0.1186	0.1131
42	0.1573	0.1353	0.1244	0.1172	0.1119
43	0.1556	0.1339	0.1228	0.1159	0.1106
44	0.1542	0.1322	0.1216	0.1148	0.1095
45	0.1525	0.1309	0.1204	0.1134	0.1083
46	0.1512	0.1293	0.1189	0.1123	0.1071
47	0.1499	0.1282	0.1180	0.1113	0.1062
48	0.1476	0.1269	0.1165	0.1098	0.1047
49	0.1463	0.1256	0.1153	0.1089	0.1040
50	0.1457	0.1246	0.1142	0.1079	0.1030
OVER 50	1.035	0.895	0.819	0.775	0.741
	f(n)	f(n)	f(n)	f(n)	f(n)

where

$$f(n) = \frac{.83 + n}{\sqrt{n}} - .01$$

Valeurs du seuil pour le test de Lilliefors.

Table 7 : Coefficients de Shapiro-Wilk :

n = taille de l'échantillon, i = numéro de la différence d_i

n	i	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
2		0,7071														
3		0,7071	0													
4		0,6872	0,1677													
5		0,6646	0,2413	0												
6		0,6431	0,2806	0,0875												
7		0,6233	0,3031	0,1401	0											
8		0,6052	0,3164	0,1743	0,0561											
9		0,5888	0,3244	0,1976	0,0947	0										
10		0,5739	0,3291	0,2141	0,1224	0,0399										
11		0,5601	0,3315	0,226	0,1429	0,0695	0									
12		0,5475	0,3325	0,2347	0,1586	0,0922	0,0303									
13		0,5359	0,3325	0,2412	0,1707	0,1099	0,0539	0								
14		0,5251	0,3318	0,246	0,1802	0,124	0,0727	0,024								
15		0,515	0,3306	0,2495	0,1878	0,1353	0,088	0,0433	0							
16		0,5056	0,329	0,2521	0,1939	0,1447	0,1005	0,0593	0,0196							
17		0,4963	0,3273	0,254	0,1988	0,1524	0,1109	0,0725	0,0359	0						
18		0,4886	0,3253	0,2553	0,2027	0,1587	0,1197	0,0837	0,0496	0,0163						
19		0,4808	0,3232	0,2561	0,2059	0,1641	0,1271	0,0932	0,0612	0,0303	0					
20		0,4734	0,3211	0,2565	0,2085	0,1686	0,1334	0,1013	0,0711	0,0422	0,014					
21		0,4643	0,3185	0,2578	0,2119	0,1736	0,1399	0,1092	0,0804	0,053	0,0263	0				
22		0,459	0,3156	0,2571	0,2131	0,1764	0,1443	0,115	0,0878	0,0618	0,0368	0,0122				
23		0,4542	0,3126	0,2563	0,2139	0,1787	0,148	0,1201	0,0941	0,0696	0,0459	0,0228	0			
24		0,4493	0,3098	0,2554	0,2145	0,1807	0,1512	0,1245	0,0997	0,0764	0,0539	0,0321	0,0107			
25		0,445	0,3069	0,2543	0,2148	0,1822	0,1539	0,1283	0,1046	0,0823	0,061	0,0403	0,02	0		
26		0,4407	0,3043	0,2533	0,2151	0,1836	0,1563	0,1316	0,1089	0,0876	0,0672	0,0476	0,0284	0,0094		
27		0,4366	0,3018	0,2522	0,2152	0,1848	0,1584	0,1346	0,1128	0,0923	0,0728	0,054	0,0358	0,0178	0	
28		0,4328	0,2992	0,251	0,2151	0,1857	0,1601	0,1372	0,1162	0,0965	0,0778	0,0598	0,0424	0,0253	0,0084	
29		0,4291	0,2968	0,2499	0,215	0,1064	0,1616	0,1395	0,1192	0,1002	0,0822	0,065	0,0483	0,032	0,0159	0
30		0,4254	0,2944	0,2487	0,2148	0,187	0,163	0,1415	0,1219	0,1036	0,0862	0,0697	0,0537	0,0381	0,0227	0,0076

Table des valeurs limites de W

n	5%	1%
3	0.767	0.753
4	0.748	0.687
5	0.762	0.686
6	0.788	0.713
7	0.803	0.730
8	0.818	0.749
9	0.829	0.764
10	0.842	0.781
11	0.850	0.792
12	0.859	0.805
13	0.856	0.814
14	0.874	0.825
15	0.881	0.835
16	0.837	0.844
17	0.892	0.851
18	0.897	0.858
19	0.901	0.863
20	0.905	0.868
21	0.908	0.873
22	0.911	0.878
23	0.914	0.881
24	0.916	0.884
25	0.918	0.888
26	0.920	0.891
27	0.923	0.894
28	0.924	0.896
29	0.926	0.898
30	0.927	0.900

Coefficients et seuil du test de Shapiro-Wilk.

Loi de Khi-deux

Le tableau donne x tel que P(K > x) = p

Table with columns labeled 'p' and 'ddl' (degrees of freedom) and rows representing probability values from 0.999 down to 0.001 for each degree of freedom from 1 to 900.

Table du chi2.

n ₂	α	n ₁																	
		3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
3	.05	--	0	0	1	1	2	2	3	3	4	4	5	5	6	6	7	7	8
	.01	--	0	0	0	0	0	0	0	0	1	1	1	2	2	2	2	3	3
4	.05	--	0	1	2	3	4	4	5	6	7	8	9	10	11	11	12	13	14
	.01	--	--	0	0	0	1	1	2	2	3	3	4	5	5	6	6	7	8
5	.05	0	1	2	3	5	6	7	8	9	11	12	13	14	15	17	18	19	20
	.01	--	--	0	1	1	2	3	4	5	6	7	7	8	9	10	11	12	13
6	.05	1	2	3	5	6	8	10	11	13	14	16	17	19	21	22	24	25	27
	.01	--	0	1	2	3	4	5	6	7	9	10	11	12	13	15	16	17	18
7	.05	1	3	5	6	8	10	12	14	16	18	20	22	24	26	28	30	32	34
	.01	--	0	1	3	4	6	7	9	10	12	13	15	16	18	19	21	22	24
8	.05	2	4	6	8	10	13	15	17	19	22	24	26	29	31	34	36	38	41
	.01	--	1	2	4	6	7	9	11	13	15	17	18	20	22	24	26	28	30
9	.05	2	4	7	10	12	15	17	20	23	26	28	31	34	37	39	42	45	48
	.01	0	1	3	5	7	9	11	13	16	18	20	22	24	27	29	31	33	36
10	.05	3	5	8	11	14	17	20	23	26	29	33	36	39	42	45	48	52	55
	.01	0	2	4	6	9	11	13	16	18	21	24	26	29	31	34	37	39	42
11	.05	3	6	9	13	16	19	23	26	30	33	37	40	44	47	51	55	58	62
	.01	0	2	5	7	10	13	16	18	21	24	27	30	33	36	39	42	45	48
12	.05	4	7	11	14	18	22	26	29	33	37	41	45	49	53	57	61	65	69
	.01	1	3	6	9	12	15	18	21	24	27	31	34	37	41	44	47	51	54
13	.05	4	8	12	16	20	24	28	33	37	41	45	50	54	59	63	67	72	76
	.01	1	3	7	10	13	17	20	24	27	31	34	38	42	45	49	53	56	60
14	.05	5	9	13	17	22	26	31	36	40	45	50	55	59	64	67	74	78	83
	.01	1	4	7	11	15	18	22	26	30	34	38	42	46	50	54	58	63	67
15	.05	5	10	14	19	24	29	34	39	44	49	54	59	64	70	75	80	85	90
	.01	2	5	8	12	16	20	24	29	33	37	42	46	51	55	60	64	69	73
16	.05	6	11	15	21	26	31	37	42	47	53	59	64	70	75	81	86	92	98
	.01	2	5	9	13	18	22	27	31	36	41	45	50	55	60	65	70	74	79
17	.05	6	11	17	22	28	34	39	45	51	57	63	67	75	81	87	93	99	105
	.01	2	6	10	15	19	24	29	34	39	44	49	54	60	65	70	75	81	86
18	.05	7	12	18	24	30	36	42	48	55	61	67	74	80	86	93	99	106	112
	.01	2	6	11	16	21	26	31	37	42	47	53	58	64	70	75	81	87	92
19	.05	7	13	19	25	32	38	45	52	58	65	72	78	85	92	99	106	113	119
	.01	3	7	12	17	22	28	33	39	45	51	56	63	69	74	81	87	93	99
20	.05	8	14	20	27	34	41	48	55	62	69	76	83	90	98	105	112	119	127
	.01	3	8	13	18	24	30	36	42	48	54	60	67	73	79	86	92	99	105

Tables pour le test bilatéral de Mann-Whitney.