

**Exercice 1****Nettoie, c'est donc ton frère****7 points**

i	x	z
1	0.00	2.29
2	0.39	2.26
3	0.78	2.11
4	1.17	1.86
5	1.57	1.50
6	1.96	1.07
7	2.35	0.69
8	2.81	0.40
9	3.14	0.29

On considère les  $n = 9$  observations suivantes :

les observations  $z$  sont liées aux  $x$  à travers le modèle suivant :

$$z_i - c = r \cos(x_i) + \varepsilon_i \quad i = 1, n$$

où les  $\varepsilon_i$  sont des variables aléatoires i.i.d. distribuées selon une loi normale centrée de variance  $\sigma^2$  inconnue et  $(c, r)$  sont deux paramètres inconnus.

1. construire l'estimateur des paramètres  $c$  et  $r$  au sens des moindres carrés et calculez l'estimation à partir des données fournies,
2. donnez un estimateur de  $\sigma^2$  la variance des  $\varepsilon_i$ ,
3. calculez le coefficient de détermination de cette régression,
4. calculez l'influence (l'effet levier) de la première et de la dernière observation (remarque : on pourra estimer que toute valeur inférieure à  $10^{-3}$  en valeur absolue est égale à 0).
5. le modèle est-il bien spécifié ? Sinon quel autre modèle vous semble mieux adapté aux observations ?
6. donnez un intervalle de la meilleure prédiction de  $z$  pour  $x = 2, 5$  ?
7. le coach avec lequel vous avez effectué vos révisions vous a assuré que dans l'exercice *Nettoie, c'est donc ton frère* le coefficient directeur de la droite  $a$  serait inférieur à 1. Peut-on lui donner raison statistiquement ? (détaillez bien les différentes étapes de votre raisonnement).

**Exercice 2****Régime crétois (tous des menteurs)****4 points**

Chez un individu adulte, le logarithme du dosage en d-dimères, variable que nous noterons  $X$ , est modélisé par une loi normale d'espérance  $\mu$  et de variance  $\sigma^2$ . La variable  $X$  est un indicateur de risque cardio-vasculaire : on considère que chez les individus sains,  $\mu$  vaut -1, alors que chez les individus à risque,  $\mu$  vaut 0. Dans les deux cas, la valeur de la variance  $\sigma^2$  est la même : 0,09.

1. Un patient présente une valeur de  $X$  égale à -0.46. Calculer la p-valeur du test que vous construirez dans le cas où l'on ne souhaite pas alarmer inutilement plus de 1 % des patients.
2. On suppose maintenant que l'on a mesuré  $X$  sur 9 individus consommant de l'huile d'olive et sur 13 individus n'en consommant pas. Sur ces échantillons, les résultats suivants ont été mesurés :

effectifs	moyenne	variance
9	-0,78	0,0729
13	-0,98	0,1024

on considère un risque de première espèce de 5%.

- a) construire un test statistique permettant de décider si l'huile d'olive réduit significativement le risque cardio vasculaire en supposant que la variance est connue et égale à 0.09,
- b) même question si l'on suppose maintenant que la variance est inconnue, calculez la p valeur et donnez vos conclusions,
- c) en supposant la variance connue et les effectifs des deux groupes égaux, quelle devrait être la taille de l'échantillon pour que la p valeur soit de l'ordre de 1 %.

---

**Exercice 3****C(ad)ucé aime****6 points**

Pour chaque question donnez la(es) affirmation(s) exacte(s) en justifiant votre choix.

1. La distribution de la taille des étudiants en médecine a une espérance de 170 cm avec un écart type de la population de 10 cm. On réalise un échantillon par tirage au sort de 100 étudiants en médecine.

1. La probabilité que la moyenne de l'échantillon soit au dessus de 171,96 cm est de 5%
2. La probabilité que la moyenne de l'échantillon soit au dessus de 171,96 cm est de 10%
3. La probabilité que la moyenne de l'échantillon soit au dessus de 171,96 cm est de 2,5%
4. La probabilité que la moyenne de l'échantillon soit au dessus de 189,6 cm est de 2,5%
5. Il n'est pas possible de répondre avec les éléments disponibles

2. Dans un test statistique, Le risque de première espèce (risque alpha) :

1. Est le risque de rejeter l'hypothèse nulle alors qu'elle est vraie
2. Correspond, lors d'un essai thérapeutique, dans un test sur le critère d'efficacité d'un médicament, au risque de conclure que le médicament est efficace alors qu'il ne l'est pas
3. Correspond, lors d'un essai thérapeutique, dans un test sur le critère de tolérance clinique ou biologique d'un médicament, au risque de conclure que le médicament a une bonne tolérance alors que celle-ci est mauvaise
4. Permet de définir la puissance d'un test : puissance = 1 - alpha
5. Est toujours connu

3. Une étude de la pratique du sport avant et après l'accouchement a pour résultats :
  - Nombre de femmes faisant du sport avant et faisant du sport après : 25
  - Nombre de femmes ne faisant pas de sport avant et ne faisant pas de sport après : 35
  - Nombre de femmes faisant du sport avant ne faisant pas de sport après : 25
  - Nombre de femmes ne faisant pas de sport avant et faisant du sport après : 15On désire savoir si l'accouchement modifie la pratique du sport.

1. Il s'agit ici de comparer le pourcentage de femmes qui pratiquent du sport avant l'accouchement : 50/100 au pourcentage de femmes qui pratiquent du sport après 40/100 par la technique de comparaison de 2 pourcentages pour séries indépendantes
2. Il s'agit ici de comparer le pourcentage de femmes qui pratiquent du sport avant l'accouchement : 50/100 au pourcentage de femmes qui pratiquent du sport après 40/100 par un  $\chi^2$  d'indépendance
3. On a examiné au total 50 femmes
4. Il s'agit de série appariée. On s'intéresse aux femmes qui changent de statut. Si l'accouchement n'a pas d'effets sur la pratique du sport, on doit s'attendre aux fluctuations du hasard prêt à avoir autant de femmes qui arrêtent le sport que de femmes qui se mettent à faire du sport
5. On utilise la comparaison de pourcentage pour séries appariées :  $\chi^2 = \frac{(25-15) * (25-15)}{(25+15)} = \frac{100}{40} = 2,5$  DDL 1 différence non significative au seuil de risque 5%. Il n'est pas possible de mettre en évidence une influence de l'accouchement sur la pratique du sport au seuil de risque 5%

4. On se demande si un traitement T modifie la glycémie des malades qui le reçoivent. On mesure la glycémie des sujets de deux groupes de 49 patients : les patients du premier groupe (groupe T) sont traités par T ; ceux de l'autre groupe ne sont pas traités (groupe NT). Les groupes sont constitués par tirage au sort, et on compare leur moyenne. Les moyennes et

variances observées dans les deux groupes sont :  $mT = 5,9$  mmol/ml,  $mNT = 5,5$  mmol/ml,  $s2T = 0,4$ ,  $s2NT = 0,6$ .

1. L'hypothèse nulle testée est que les moyennes observées  $mT$  et  $mNT$  sont identiques
2. Au risque 5 %, les moyennes observées  $mT$  et  $mNT$  diffèrent significativement
3. Le degré de signification est compris entre 1 % et 1 ‰
4. Le degré de signification est compris entre 5 % et 1 ‰
5. Le test est valide car les tailles des groupes sont suffisantes

---

**Exercice 4** **Il en connaît un rayon sur le centre** **3 points**

Supposons que l'on dispose d'un ensemble d'observations  $(x_i, y_i), i = 1, n$  liées par le modèle suivant :

$$(x_i - a)^2 + (y_i - b)^2 = r^2 + \varepsilon_i \quad i = 1, n$$

où les  $\varepsilon_i$  sont des variables aléatoires i.i.d. distribués selon une loi normale centrée de variance  $\sigma^2$  inconnue,  $(a, b)$  un centre inconnu et  $r$  un rayon.

1. ce modèle est-il linéaire ?
2. donnez le système de trois équations à trois inconnues vérifié par les estimateurs au sens des moindres carrés du centre  $(a, b)$  et du carré de rayon  $r^2$ ,
3. connaissant  $(a, b)$  quelle est la valeur de l'estimateur du carré de rayon  $r^2$  au sens des moindres carrés ? En déduire les deux équations vérifiées par les estimateurs du centre  $(a, b)$ .

---

**Formulaire :**

– régression simple :

$$\min_{a,b} \sum_{i=1}^n (ax_i + b - y_i)^2$$

– solution  $\hat{a}$  et  $\hat{b}$  définis par :

$$\hat{a} = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\text{cov}(\mathbf{x}, \mathbf{y})}{V_x} \quad \text{et} \quad \hat{b} = \bar{y} - \hat{a} \bar{x}$$

– estimateur de la variance :  $\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n (\hat{a}x_i + \hat{b} - y_i)^2$

– prédiction avec une probabilité  $\alpha$  :

$$y_x \in \left\{ \bar{y} + \hat{a}(\mathbf{x} - \bar{x}) \pm t_{\frac{\alpha}{2}} \hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(\mathbf{x} - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \right\}$$

– modèle linéaire multiple :  $y = \sum_{j=1}^p x_j \alpha_j + \alpha_0 + \varepsilon$

– estimateur des moindres carrés :  $\hat{\alpha} = (X^\top X)^{-1} X^\top y$

– le coefficient de détermination  $R^2 = \frac{\text{SC Expliqué}}{\text{SC Total}} = \frac{\sum_{i=1}^n (z_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$

– projecteur :  $H = X(X^\top X)^{-1} X^\top$

– influence des observations (effet levier) :  $H_{ii}$

– contributions (distance de Cook) :  $c_i = \frac{H_{ii}}{p(1-H_{ii})^2} \frac{\hat{\varepsilon}_i^2}{\hat{\sigma}^2}$

**Tables de la loi normale :** Cette table nous donne les valeurs de  $t$  telle que  $P(X \leq t)$  lorsque  $X$  suit une loi normale centrée réduite

$$\Pi(t) = P(X \leq t) = \int_{-\infty}^t \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx \quad \text{et} \quad \Pi(-t) = 1 - \Pi(t).$$

t	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0.0	0.5000	0.5040	0.5080	0.5120	0.5160	0.5199	0.5239	0.5279	0.5319	0.5359
0.1	0.5398	0.5438	0.5478	0.5517	0.5557	0.5596	0.5636	0.5675	0.5714	0.5753
0.2	0.5793	0.5832	0.5871	0.5910	0.5948	0.5987	0.6026	0.6064	0.6103	0.6141
0.3	0.6179	0.6217	0.6255	0.6293	0.6331	0.6368	0.6406	0.6443	0.6480	0.6517
0.4	0.6554	0.6591	0.6628	0.6664	0.6700	0.6736	0.6772	0.6808	0.6844	0.6879
0.5	0.6915	0.6950	0.6985	0.7019	0.7054	0.7088	0.7123	0.7157	0.7190	0.7224
0.6	0.7257	0.7291	0.7324	0.7357	0.7389	0.7422	0.7454	0.7486	0.7517	0.7549
0.7	0.7580	0.7611	0.7642	0.7673	0.7704	0.7734	0.7764	0.7794	0.7823	0.7852
0.8	0.7881	0.7910	0.7939	0.7967	0.7995	0.8023	0.8051	0.8078	0.8106	0.8133
0.9	0.8159	0.8186	0.8212	0.8238	0.8264	0.8289	0.8315	0.8340	0.8365	0.8389
1.0	0.8413	0.8438	0.8461	0.8485	0.8508	0.8531	0.8554	0.8577	0.8599	0.8621
1.1	0.8643	0.8665	0.8686	0.8708	0.8729	0.8749	0.8770	0.8790	0.8810	0.8830
1.2	0.8849	0.8869	0.8888	0.8907	0.8925	0.8944	0.8962	0.8980	0.8997	0.9015
1.3	0.9032	0.9049	0.9066	0.9082	0.9099	0.9115	0.9131	0.9147	0.9162	0.9177
1.4	0.9192	0.9207	0.9222	0.9236	0.9251	0.9265	0.9279	0.9292	0.9306	0.9319
1.5	0.9332	0.9345	0.9357	0.9370	0.9382	0.9394	0.9406	0.9418	0.9429	0.9441
1.6	0.9452	0.9463	0.9474	0.9484	0.9495	0.9505	0.9515	0.9525	0.9535	0.9545
1.7	0.9554	0.9564	0.9573	0.9582	0.9591	0.9599	0.9608	0.9616	0.9625	0.9633
1.8	0.9641	0.9649	0.9656	0.9664	0.9671	0.9678	0.9686	0.9693	0.9699	0.9706
1.9	0.9713	0.9719	0.9726	0.9732	0.9738	0.9744	0.9750	0.9756	0.9761	0.9767
2.0	0.9772	0.9778	0.9783	0.9788	0.9793	0.9798	0.9803	0.9808	0.9812	0.9817
2.1	0.9821	0.9826	0.9830	0.9834	0.9838	0.9842	0.9846	0.9850	0.9854	0.9857
2.2	0.9861	0.9864	0.9868	0.9871	0.9875	0.9878	0.9881	0.9884	0.9887	0.9890
2.3	0.9893	0.9896	0.9898	0.9901	0.9904	0.9906	0.9909	0.9911	0.9913	0.9916
2.4	0.9918	0.9920	0.9922	0.9925	0.9927	0.9929	0.9931	0.9932	0.9934	0.9936
2.5	0.9938	0.9940	0.9941	0.9943	0.9945	0.9946	0.9948	0.9949	0.9951	0.9952
2.6	0.9953	0.9955	0.9956	0.9957	0.9959	0.9960	0.9961	0.9962	0.9963	0.9964
2.7	0.9965	0.9966	0.9967	0.9968	0.9969	0.9970	0.9971	0.9972	0.9973	0.9974
2.8	0.9974	0.9975	0.9976	0.9977	0.9977	0.9978	0.9979	0.9979	0.9980	0.9981
2.9	0.9981	0.9982	0.9982	0.9983	0.9984	0.9984	0.9985	0.9985	0.9986	0.9986
3.0	0.9987	0.9987	0.9987	0.9988	0.9988	0.9989	0.9989	0.9989	0.9990	0.9990
3.1	0.9990	0.9991	0.9991	0.9991	0.9992	0.9992	0.9992	0.9992	0.9993	0.9993
3.2	0.9993	0.9993	0.9994	0.9994	0.9994	0.9994	0.9994	0.9995	0.9995	0.9995
3.3	0.9995	0.9995	0.9995	0.9996	0.9996	0.9996	0.9996	0.9996	0.9996	0.9997
3.4	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9998
3.5	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998
3.6	0.9998	0.9998	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.7	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.8	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000

**Tables de la loi de Student :** Cette table nous donne les valeurs de  $t$  telle que  $\mathbb{P}(T > t)$  lorsque  $T$  suit une loi de student à  $\nu$  degrés de liberté

$\nu$	0,10	0,05	0,025	0,01	0,005	0,001
1	3,078	6,314	12,706	31,821	63,657	318,313
2	1,886	2,920	4,303	6,965	9,925	22,327
3	1,638	2,353	3,182	4,541	5,841	10,215
4	1,533	2,132	2,776	3,747	4,604	7,173
5	1,476	2,015	2,571	3,365	4,032	5,893
6	1,440	1,943	2,447	3,143	3,707	5,208
7	1,415	1,895	2,365	2,998	3,499	4,782
8	1,397	1,860	2,306	2,896	3,355	4,499
9	1,383	1,833	2,262	2,821	3,250	4,296
10	1,372	1,812	2,228	2,764	3,169	4,143
11	1,363	1,796	2,201	2,718	3,106	4,024
12	1,356	1,782	2,179	2,681	3,055	3,929
13	1,350	1,771	2,160	2,650	3,012	3,852
14	1,345	1,761	2,145	2,624	2,977	3,787
15	1,341	1,753	2,131	2,602	2,947	3,733
16	1,337	1,746	2,120	2,583	2,921	3,686
17	1,333	1,740	2,110	2,567	2,898	3,646
18	1,330	1,734	2,101	2,552	2,878	3,610
19	1,328	1,729	2,093	2,539	2,861	3,579
20	1,325	1,725	2,086	2,528	2,845	3,552
21	1,323	1,721	2,080	2,518	2,831	3,527
22	1,321	1,717	2,074	2,508	2,819	3,505
23	1,319	1,714	2,069	2,500	2,807	3,485
24	1,318	1,711	2,064	2,492	2,797	3,467
25	1,316	1,708	2,060	2,485	2,787	3,450
26	1,315	1,706	2,056	2,479	2,779	3,435
27	1,314	1,703	2,052	2,473	2,771	3,421
28	1,313	1,701	2,048	2,467	2,763	3,408
29	1,311	1,699	2,045	2,462	2,756	3,396
30	1,310	1,697	2,042	2,457	2,750	3,385
31	1,309	1,696	2,040	2,453	2,744	3,375
32	1,309	1,694	2,037	2,449	2,738	3,365
33	1,308	1,692	2,035	2,445	2,733	3,356
34	1,307	1,691	2,032	2,441	2,728	3,348
35	1,306	1,690	2,030	2,438	2,724	3,340
36	1,306	1,688	2,028	2,434	2,719	3,333
37	1,305	1,687	2,026	2,431	2,715	3,326
38	1,304	1,686	2,024	2,429	2,712	3,319
39	1,304	1,685	2,023	2,426	2,708	3,313
40	1,303	1,684	2,021	2,423	2,704	3,307
50	1,299	1,676	2,009	2,403	2,678	3,261
100	1,290	1,660	1,984	2,364	2,626	3,174
$\infty$	1,282	1,645	1,960	2,326	2,576	3,090

**Tables de la loi du  $\chi^2$  :** Cette table nous donne les valeurs de  $t$  telle que  $\mathbb{P}(X > t)$  lorsque  $X$  suit une loi du chi 2 à  $\nu$  degrés de liberté

$\nu$	0.3	0.2	0.1	0.05	0.025	0.01	0.005	0.001
1	1.0742	1.6424	2.7055	3.8415	5.0239	6.6349	7.8794	10.8276
2	2.4079	3.2189	4.6052	5.9915	7.3778	9.2103	10.5966	13.8155
3	3.6649	4.6416	6.2514	7.8147	9.3484	11.3449	12.8382	16.2662
4	4.8784	5.9886	7.7794	9.4877	11.1433	13.2767	14.8603	18.4668
5	6.0644	7.2893	9.2364	11.0705	12.8325	15.0863	16.7496	20.5150
6	7.2311	8.5581	10.6446	12.5916	14.4494	16.8119	18.5476	22.4577
7	8.3834	9.8032	12.0170	14.0671	16.0128	18.4753	20.2777	24.3219
8	9.5245	11.0301	13.3616	15.5073	17.5345	20.0902	21.9550	26.1245
9	10.6564	12.2421	14.6837	16.9190	19.0228	21.6660	23.5894	27.8772
10	11.7807	13.4420	15.9872	18.3070	20.4832	23.2093	25.1882	29.5883
11	12.8987	14.6314	17.2750	19.6751	21.9200	24.7250	26.7568	31.2641
12	14.0111	15.8120	18.5493	21.0261	23.3367	26.2170	28.2995	32.9095
13	15.1187	16.9848	19.8119	22.3620	24.7356	27.6882	29.8195	34.5282
14	16.2221	18.1508	21.0641	23.6848	26.1189	29.1412	31.3193	36.1233
15	17.3217	19.3107	22.3071	24.9958	27.4884	30.5779	32.8013	37.6973
16	18.4179	20.4651	23.5418	26.2962	28.8454	31.9999	34.2672	39.2524
17	19.5110	21.6146	24.7690	27.5871	30.1910	33.4087	35.7185	40.7902
18	20.6014	22.7595	25.9894	28.8693	31.5264	34.8053	37.1565	42.3124
19	21.6891	23.9004	27.2036	30.1435	32.8523	36.1909	38.5823	43.8202
20	22.7745	25.0375	28.4120	31.4104	34.1696	37.5662	39.9968	45.3147
21	23.8578	26.1711	29.6151	32.6706	35.4789	38.9322	41.4011	46.7970
22	24.9390	27.3015	30.8133	33.9244	36.7807	40.2894	42.7957	48.2679
23	26.0184	28.4288	32.0069	35.1725	38.0756	41.6384	44.1813	49.7282
24	27.0960	29.5533	33.1962	36.4150	39.3641	42.9798	45.5585	51.1786
25	28.1719	30.6752	34.3816	37.6525	40.6465	44.3141	46.9279	52.6197
26	29.2463	31.7946	35.5632	38.8851	41.9232	45.6417	48.2899	54.0520
27	30.3193	32.9117	36.7412	40.1133	43.1945	46.9629	49.6449	55.4760
28	31.3909	34.0266	37.9159	41.3371	44.4608	48.2782	50.9934	56.8923
29	32.4612	35.1394	39.0875	42.5570	45.7223	49.5879	52.3356	58.3012
30	33.5302	36.2502	40.2560	43.7730	46.9792	50.8922	53.6720	59.7031
31	34.5981	37.3591	41.4217	44.9853	48.2319	52.1914	55.0027	61.0983
32	35.6649	38.4663	42.5847	46.1943	49.4804	53.4858	56.3281	62.4872
33	36.7307	39.5718	43.7452	47.3999	50.7251	54.7755	57.6484	63.8701
34	37.7954	40.6756	44.9032	48.6024	51.9660	56.0609	58.9639	65.2472
35	38.8591	41.7780	46.0588	49.8018	53.2033	57.3421	60.2748	66.6188
36	39.9220	42.8788	47.2122	50.9985	54.4373	58.6192	61.5812	67.9852
37	40.9839	43.9782	48.3634	52.1923	55.6680	59.8925	62.8833	69.3465
38	42.0451	45.0763	49.5126	53.3835	56.8955	61.1621	64.1814	70.7029
39	43.1053	46.1730	50.6598	54.5722	58.1201	62.4281	65.4756	72.0547
40	44.1649	47.2685	51.8051	55.7585	59.3417	63.6907	66.7660	73.4020

Soit  $Y \sim \mathcal{N}(0, 1)$  une variable aléatoire normale centrée réduite. Soit  $Y_1, Y_2, \dots, Y_n$  un échantillon de  $n$  réalisations i.i.d. de cette variable aléatoire.

**La loi du  $\chi^2$**  On appelle loi du  $\chi^2$  à  $n$  degrés de libertés la loi de la variable aléatoire  $Z_n = \sum_{i=1}^n Y_i^2$

**La loi de student** On appelle loi de student à  $n$  degrés de libertés la loi de la variable aléatoire  $T_n$

$$T_n = \frac{N}{\sqrt{\frac{X_n}{n}}} \quad \begin{array}{l} N \sim \mathcal{N}(0, 1) \\ X_n \sim \chi_n^2 \end{array}$$

**Theorem 0.1 (Théorème du  $\chi^2$  (Pearson))** pour  $N_{ij}$  effectif observés et pour  $n_{ij}$  effectif théorique

$$X_{ij} = \frac{N_{ij} - n \hat{p}_{ij}}{\sqrt{n \hat{p}_{ij}}} \quad \sum_{i=1}^I \sum_{j=1}^J X_{ij}^2 \longrightarrow \chi_{(I-1)(J-1)}^2$$

la variable  $T_{n_x+n_y-2}$  suit une loi de student à  $n_x + n_y - 2$  degrés de liberté :

$$T_{n_x+n_y-2} = \frac{\sqrt{n_x+n_y-2} (\bar{X} - \bar{Y} - (\mu_x - \mu_y))}{\sqrt{\left(\frac{1}{n_x} + \frac{1}{n_y}\right) S_{xy}^2}}$$

avec  $S_{xy}^2 = S_x^2 + S_y^2 = \sum_{i=1}^{n_x} (X_i - \bar{X})^2 + \sum_{i=1}^{n_y} (Y_i - \bar{Y})^2$

Mise en œuvre du test du  $\chi^2$

1. on construit un tableau de contingence  $O$  des observations (2 variables qualitatives de respectivement  $I$  et  $J$  modalités)
2. on calcule les marginales  $p_i = \frac{1}{n} \sum_{j=1}^J O_{ij}$
3. on calcule pour chaque case du tableau des effectifs théoriques  $T_{ij} = np_i p_j$  (en supposant l'indépendance)
4. on calcule la distance du  $\chi^2$   $D(O, T) = \sum_{i=1}^I \sum_{j=1}^J \frac{(O_{ij} - T_{ij})^2}{T_{ij}}$
5. on calcule le nombre de degrés de liberté du  $\chi^2$  :  $d = (I - 1)(J - 1)$
6. on regarde dans les tables d'une variable aléatoire  $Z$  distribué suivant une loi  $\chi^2$  à  $d$  degrés de liberté la p-valeur de  $D(O, T)$  :  $pval = \mathbb{P}(Z \geq D(O, T))$
7. on décide qu'on ne peut pas conclure à la dépendance si la p-valeur est supérieure à 0,05, si  $pval \geq 0,05$

Mise en œuvre du test de comparaison des moyennes (T test ou test de student)

1. la question : les deux groupes sont ils des réalisations de la même loi
2. le modèle : gaussien
3. les hypothèses : même variance  $\sigma^2$  inconnue

4. calcul de

$$t = \frac{\bar{x}_t - \bar{x}_p}{\sqrt{\hat{\sigma}^2 \left(\frac{1}{n_t} + \frac{1}{n_p}\right)}} \quad \hat{\sigma}^2 = \frac{1}{n_t+n_p-2} \left( \sum_{i=1}^{n_t} (x_{ti} - \bar{x}_t)^2 + \sum_{i=1}^{n_p} (x_{pi} - \bar{x}_p)^2 \right)$$

$n_t$  nombre de cas avec traitement  
 $n_p$  nombre de cas sans traitement

5. calcul de la p-valeur  $T \sim \mathcal{T}_{n_t+n_p-2}$  (ou lecture sur les tables)  $pval = \mathbb{P}(T \leq t)$  ou  $pval = \mathbb{P}(T \geq t)$  ou  $pval = \mathbb{P}(-|t| \leq T \leq |t|)$
6. on décide que les deux groupes sont ils des réalisation de la même loi si la p-valeur est supérieure à 0,05, si  $pval \geq 0,05$

Mise en œuvre du test sur la pente de la régression

1. les hypothèses : 
$$\begin{cases} \mathcal{H}_0 : \text{indépendance} & a = 0 \\ \mathcal{H}_1 : \text{dépendance} & a \neq 0 \end{cases}$$

2. calcul de 
$$\hat{a} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

3. calcul de 
$$\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n (y_i - (\hat{a}x_i + \hat{b}))^2$$
 et de 
$$S_x^2 = \sum_{i=1}^n (x_i - \bar{x})^2$$

4. calcul de 
$$t = \frac{\hat{a}}{\sqrt{\frac{\hat{\sigma}^2}{S_x^2}}}$$

5. calcul du nombre de degrés de liberté  $d = n - 2$

6. calcul de la p-valeur  $T \sim \mathcal{T}_d$  (ou lecture sur les tables)

$$pval = \mathbb{P}(|T| \geq t)$$

7. on décide de garder  $\mathcal{H}_0$  ( $a = 0$ ) si la p-valeur est supérieure à 0,05, si  $pval \geq 0,05$