

Statistiques inférentielle 2

Table des matières

Chapitre 1. Les tests non paramétriques	1
1. Test d'ajustement de deux distributions : "test du khi-deux"	1
2. Test de normalité	9
3. Test de Khi-deux d'indépendance	12
4. Test de Kolmogorov-Smirnov	14

CHAPITRE 1

Les tests non paramétriques

Ce cours a pour objectif la présentation des tests non paramétriques les plus couramment utilisés. Il se situe dans le cadre de l'inférence statistique et des tests d'hypothèse usuels : on cherche à apprécier des caractéristiques d'une population à partir d'un échantillon issu de cette population.

Un test non-paramétrique présente quelques avantages :

1. Son application est relativement facile et rapide,
2. S'applique à des échantillons de petites tailles,
3. S'applique à des caractères qualitatifs, à des grandeurs de mesure, à des rangs de classement, etc.

On distinguera principalement les deux familles suivantes :

a). Test du Khi-deux de Pearson :

- (1) Test d'ajustement ou d'adéquation entre deux distributions.
- (2) Test d'indépendance dans un tableau de contingence.
- (3) Test d'homogénéité de plusieurs populations.

b) Tests appliqués aux rangs et aux signes

- (1) Test de la somme des rangs (Wilcoxon et Mann-Withney)
- (2) Test de signes
- (3) Test de la somme des rangs des différences positives (Wilcoxon)
- (4) Test d'indépendance de rangs de Spearman

1. Test d'ajustement de deux distributions : "test du khi-deux"

Introduction

Le test de Pearson, appelé aussi le test du khi-deux est un outil statistique qui permet de vérifier la concordance entre une distribution expérimentale et une distribution théorique.

On cherche donc à déterminer si un modèle théorique est susceptible de représenter adéquatement le comportement probabiliste de la variable observée, comportement fondé sur les fréquences des résultats obtenus sur l'échantillon.

Comment procéder ?

Répartitions expérimentales

On répartit les observations suivant k classes (si le caractère est continu) ou k valeurs (si le caractère est discret). On dispose alors des effectifs des k classes : O_1, O_2, \dots, O_k . On a bien sûr la relation

$$\sum_{i=1}^k O_i = N$$

où N est le nombre total d'observations effectuées.

Répartitions théoriques

En admettant comme plausible une distribution théorique particulière, on peut construire une répartition idéale des observations de l'échantillon de taille N en ayant recours aux probabilités tablées (ou calculées) du modèle théorique : p_1, p_2, \dots, p_k . On obtient alors les effectifs théoriques T_i en écrivants $T_i = Np_i$. On dispose automatiquement de la relation

$$\sum_{i=1}^k T_i = N$$

Définition de l'écart entre les deux distributions

Pour évaluer l'écart entre les effectifs observés n_i et les effectifs théoriques T_i , on utilise la somme des écarts normalisés entre les deux distributions, à savoir

$$\chi^2 = \frac{(O_1 - T_1)^2}{T_1} + \frac{(O_2 - T_2)^2}{T_2} + \dots + \frac{(O_k - T_k)^2}{T_k}$$

La statistique χ^2 représente une sorte de "distance" globale entre les effectifs observés et les effectifs attendus. Plus la distribution étudiée diffère de la distribution théorique.

Mais quel est le nombre de degrés de liberté de cette variable du khi-deux ?

1. Si la distribution théorique est entièrement spécifiée, c'est-à-dire si on cherche à déterminer si la distribution observée suit une loi dont les paramètres sont connus avant même de choisir l'échantillon, on a $k - 1$ degrés de liberté (k carrés indépendants moins une relation entre les variables).

2. S'il faut d'abord estimer r paramètres de la loi à partir des observations de l'échantillon (par exemple on cherche si la distribution est normale mais on ne connaît d'avance ni sa moyenne ni son écart-type), il n'y a plus que $k - 1 - r$ degrés de liberté.

Dans le cas général, on dira que la loi du khi-deux suivie par l'écart entre les deux distributions a $k - 1 - r$ degrés de liberté lorsqu'on a estimé r paramètres de la loi théorique à partir des observations de l'échantillon (avec la possibilité pour r de valoir 0).

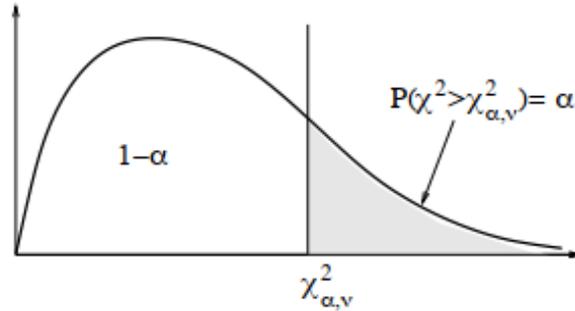
REMARQUE 1. *Le nombre d'observations par classes ne doit pas être faible, Np_i doit être supérieur à 5, $\forall i = 1, 2, \dots, k$. Dans le cas contraire, on regroupe deux ou plusieurs classes adjacentes de façon à réaliser cette condition. On tient compte de ce regroupement pour le nombre de degrés de liberté.*

Le test d'ajustement de χ^2

Il nous faut maintenant décider, à l'aide de cet indicateur qu'est le χ^2 , si les écarts entre les effectifs théoriques et ceux qui résultent des observations sont significatifs d'une différence de distribution ou si ils sont dus aux fluctuations d'échantillonnage. Nous procéderons comme d'habitude en quatre étapes.

1ère étape : Formulation des hypothèses.

On va donc tester l'hypothèse \mathbf{H}_0 contre l'hypothèse \mathbf{H}_1 :



- $\left\{ \begin{array}{l} \mathbf{H}_0 \text{ Les observations suivent la distribution théorique spécifiée} \\ \mathbf{H}_1 \text{ Les observations ne suivent la distribution théorique spécifiée} \end{array} \right.$

2^{ème} étape : Détermination de la fonction χ^2

On utilise la variable aléatoire

$$\chi^2 = \frac{(O_1 - T_1)^2}{T_1} + \frac{(O_2 - T_2)^2}{T_2} + \dots, \frac{(O_k - T_k)^2}{T_k}$$

3^{ème} étape : Détermination des valeurs critiques de χ^2 délimitant les zones d'acceptation et de rejet.

On impose à la zone d'acceptation de \mathbf{H}_0 concernant la valeur du χ^2 d'être un intervalle dont 0 est la borne inférieure (car un χ^2 est toujours positif).

Il nous faut donc déterminer dans la table la valeur maximale $\chi^2_{\alpha, \nu}$ de l'écart entre les deux distributions imputable aux variations d'échantillonnage au seuil de signification α , c'est-à-dire vérifiant $P(\chi^2 > \chi^2_{\alpha, \nu}) = \alpha$. $\chi^2_{\alpha, \nu}$ représente donc la valeur critique pour un test sur la concordance entre deux distributions et le test sera toujours unilatéral à droite.

4^{ème} étape : Calcul de la valeur de χ^2 prise dans l'échantillon et conclusion du test.

On calcule la valeur χ_0^2 prise par χ^2 dans l'échantillon.

- Si la valeur χ_0^2 se trouve dans la zone de rejet, on dira que l'écart observé entre les deux distributions est **statistiquement significatif** au seuil α . Cet écart est anormalement élevé et ne permet pas d'accepter \mathbf{H}_0 . On rejette \mathbf{H}_0 .
- Si la valeur χ_0^2 se trouve dans la zone d'acceptation, on dira que l'écart-réduit observé n'est pas significatif au seuil α . Cet écart est imputable aux fluctuations d'échantillonnage. On accepte \mathbf{H}_0

EXEMPLE 1. *Un pisciculteur possède un bassin qui contient trois variétés de truites : communes, saumonées et arc-en-ciel. Il voudrait savoir s'il peut considérer que son bassin contient autant de truites de chaque variété. Pour cela, il effectue, au hasard 399 prélèvements avec remise et obtient les résultats suivants :*

Variétés	saumonée	commune	arc-en-ciel
Effectifs	145	118	136

SOLUTION 1. On cherche à savoir s'il y a équirépartition des truites entre chaque espèce c'est-à-dire on suppose de \mathcal{L}_0 est la loi uniforme, une probabilité de $1/3$ pour chaque classe (soit $C_i = \frac{399}{13} = 133$)

C'est-à dire on souhaite tester l'ajustement de cette loi à une loi connue uniforme

Variétés	commune	saumonée	arc-en-ciel
Effectifs O_i	145	118	136
Effectifs T_i	133	133	133

On obtient

$$\begin{aligned}\chi_{calculée}^2 &= \frac{(O_1 - T_1)^2}{T_1} + \frac{(O_2 - T_2)^2}{T_2} + \frac{(O_3 - T_3)^2}{T_3} \\ &= \frac{(145 - 133)^2}{133} + \frac{(118 - 133)^2}{133} + \frac{(136 - 133)^2}{133} \approx 2.84\end{aligned}$$

La valeur théorique lue dans la table du $\chi_{\alpha, \nu}^2$ au risque de 5% avec $\nu = 3 - 1 - 0 = 2$ degrés de liberté vaut 5.99.

On ne peut rejeter l'hypothèse que son bassin contient autant de truites de chaque variété car $\chi_{calculée}^2 < \chi_{\alpha, \nu}^2$

EXEMPLE 2. On veut tester si un dé n'est pas truqué au risque $\alpha = 0,05$. Pour cela on lance le dé 60 fois et on obtient les résultats suivants

face	1	2	3	4	5	6
O_i	15	7	4	11	6	17
T_i	10	10	10	10	10	10

On a fait figurer dans le tableau la valeur espérée T_i du nombre d'apparitions de i dans l'hypothèse où le dé n'est pas truqué, ceci afin de faciliter le calcul de la χ_{cal}^2 qui est donc ici égale à

$$\begin{aligned}\chi_{cal}^2 &= \sum_{i=1}^6 \frac{(O_i - T_i)^2}{T_i} = \frac{(15 - 10)^2}{10} + \frac{(7 - 10)^2}{10} + \frac{(4 - 10)^2}{10} \\ &\quad + \frac{(11 - 10)^2}{10} + \frac{(6 - 10)^2}{10} + \frac{(17 - 10)^2}{10} \\ &= 13.6\end{aligned}$$

Sous l'hypothèse $\mathbf{H}_0 : "p_1 = \dots = p_6 = \frac{1}{6}"$, la variable aléatoire χ_{cal}^2 a donc pris la valeur 13,6. Or le seuil de rejet lu dans la table de la loi du $\chi_{\alpha, \nu}^2$ est $\chi_{0,05,5}^2 = 11,07$. La valeur observée dépassant cette valeur, on est amené à rejeter l'hypothèse H_0 au risque $\alpha = 0,05$. On notera qu'au risque $\alpha = 0,025$, on rejette aussi H_0 . Mais au risque $\alpha = 0,01$, on ne peut plus rejeter l'hypothèse H_0 malgré la mauvaise impression donnée par les résultats. Si on persiste à vouloir le risque 0,01, il est plus raisonnable de recommencer l'expérience avec un échantillon de taille beaucoup plus grande.

EXEMPLE 3 (loi uniforme). Une statistique relative aux résultats du concours d'entrée à une grande école fait ressortir les répartitions des candidats et des admis

selon la profession des parents.

Profession des candidats	Nombre de candidats	Nombre d'admis
Fonctionnaires et assimilés	2244	180
Commerce, industrie	988	89
Professions libérales	575	48
Propriétaires rentiers	423	37
Propriétaires agricoles	287	13
Artisans, petits commerçants	210	18
Banque, assurance	209	17
Total	4936	402

Tester l'hypothèse (risque $\alpha = 0,05$) selon laquelle la profession des parents n'a pas d'influence sur l'accès à cette grande école.

Il s'agit du test d'ajustement d'une distribution théorique, on pose les hypothèses

H_0 : "la profession des parents n'a pas d'influence sur l'accès à cette grande école", la proportion des admis est constante pour toutes les professions soit $p = \frac{402}{4936} \simeq 0,0814$

H_1 : "la profession des parents influe sur l'accès à cette grande école"

Sous H_0 , le nombre d'admis pour la i -ième profession est $N_i p$.

i	N_i	n_i effectif observé	$N_i p$ effectif théorique	$\left(\frac{n_i - N_i p}{N_i p}\right)^2$
1	2244	180	$\frac{2244 \times 402}{4936} \simeq 182,76$	0,0416
2	988	89	$\frac{988 \times 402}{4936} \simeq 80,47$	0,9042
3	575	48	$\frac{575 \times 402}{4936} \simeq 46,830$	0,0293
4	423	37	$\frac{423 \times 402}{4936} \simeq 34,450$	0,1887
5	287	13	$\frac{287 \times 402}{4936} \simeq 23,374$	4,6050
6	210	18	$\frac{210 \times 402}{4936} \simeq 17,10$	0,0471
7	209	17	$\frac{209 \times 402}{4936} \simeq 17,02$	$\simeq 0$
Total	4936	402	402	5,8181

Le χ^2 calculé vaut 5,8181. Le nombre de degrés de liberté est $7 - 1 = 6$. La table fournit $\chi_{6;0,95}^2 = 12,59$ donc χ^2 calculé $< \chi_{6;0,95}^2$.

On ne rejette pas H_0 , ce qui signifie que la profession des parents n'a pas d'influence sur l'accès à cette grande école.

EXEMPLE 4 (loi normale). On suppose que le rendement X (quintaux par hectares d'une parcelle de blé) suit une loi normale $\mathcal{N}(m, \sigma)$. L'observation du rendement de 1000 parcelles a donné les résultats suivants :

Rendement	Nombre de parcelles
$[0, 10[$	5
$[10, 20[$	6
$[20, 30[$	40
$[30, 40[$	168
$[40, 50[$	288
$[50, 60[$	277
$[60, 70[$	165
$[70, 80[$	49
$[80, 90[$	2
Total	1000

Afin de mettre en place un test d'ajustement, d'éterminons dans un premier temps la moyenne arithmétique et l'écarttype de la distribution observée :

$$E(X) = \mu = \frac{1}{N} \sum_i n_i x_i = 49.76$$

$$V(X) = \sigma^2 = \frac{1}{N} \sum_i n_i x_i^2 - [E(X)]^2 = 164.5424 \text{ donc } \sigma \simeq 12,827$$

Problème : Tester l'hypothèse (risque $\alpha = 0,05$) selon laquelle l'ajustement de la distribution observée à une loi normale $\mathcal{N}(50, 13)$ est acceptable.

Les hypothèses du test du χ^2 sont les suivantes :

• H_0 : “ $X \rightsquigarrow \mathcal{N}(50, 13)$ ”

• H_1 : “ X ne suit pas $\mathcal{N}(50, 13)$ ” On désigne par $[a_0, a_1[$, $[a_1, a_2[$, ..., $[a_8, a_9[$ les classes et par x_1, x_2, \dots, x_9 les centres de ces classes. Sous H_0 , $X \rightsquigarrow \mathcal{N}(50, 13)$

et $Z = \frac{X - 50}{13} \rightsquigarrow \mathcal{N}(0, 1)$, donc $p_i = p(X \in [a_{i-1}, a_i]) = \Phi(z_i) - \Phi(z_{i-1})$

avec $z_i = \frac{a_i - 50}{13}$ et $z_{i-1} = \frac{a_{i-1} - 50}{13}$. L'effectif théorique de la i ème classe

est $1000p_i$ et $\sum_i \frac{(n_i - Np_i)^2}{Np_i} \rightsquigarrow \chi_{\alpha, \nu}^2$. On a le tableau suivant

Classe	n_i	z_i	$\Phi(z_i)$	p_i	Np_i	Np_i corrigée	n_i corrigée	$\sum_i \frac{(n_i - Np_i)^2}{Np_i}$
$[0, 10[$	5	-3.0769	0.0010	0.0009	0.9	10.4	11	0.0346
$[10, 20[$	6	-2.3077	0.0105	0.0095	9.5			
$[20, 30[$	40	-1.5385	0.0620	0.0515	51.5	51.5	40	2.568
$[30, 40[$	168	-0.7692	0.2209	0.1589	158.9	158.9	168	0.5211
$[40, 50[$	288	0	0.5	0.2791	279.1	279.1	288	0.283
$[50, 60[$	277	0.7692	0.7791	0.2791	279.1	279.1	277	0.0158
$[60, 70[$	165	1.5385	0.9380	0.1589	158.9	158.9	165	0.234
$[70, 80[$	49	2.3077	0.9895	0.0515	51.5	51.5	49	0.1214
$[80, 90[$	2	3.0769	0.9990	0.0095	9.5	9.5	2	5.9211
Total	1000			1	1000	1000	1000	9.7

On effectue le regroupement des deux premières classes car $Np_i < 5$. Le χ^2 calculé vaut 9.7. Après le regroupement, il reste 8 classes, les deux paramètres de la loi normale sont donnés, le nombre de degrés de liberté est $\nu = 8 - 1 = 7$. A l'aide de la table, on obtient $\chi_{7,0,95}^2 = 14.07$. Ainsi, $\chi_{cal}^2 < \chi_{7,0,95}^2$.

On ne rejette pas H_0 , l'ajustement de la distribution observée à une loi normale $\mathcal{N}(50, 13)$ est acceptable ne spécifie pas complètement la loi qu'on considère.

EXEMPLE 5 (loi de Poisson). Supposons qu'on s'intéresse au nombre de voitures se présentant par minute à un poste de péage sur une autoroute. On peut se demander si cette variable aléatoire peut être modélisée par une **loi de Poisson** ($\mathcal{P}(\lambda)$). On souhaite donc tester l'hypothèse fondamentale H_0 : " $X \rightsquigarrow \mathcal{P}(\lambda)$ " contre l'hypothèse alternative H_1 : " X ne suit pas $\mathcal{P}(\lambda)$ ". On ne précise pas la valeur du paramètre λ . On peut toutefois l'estimer à partir des données disponibles mais dans ce cas, $r = 1$. Le nombre de degrés sera alors $\nu = k - r - 1 = k - 2$.

On effectue 200 comptages au péage

x_i	0	1	2	3	4	5	6	7	8	≥ 9	Total
n_i	6	15	40	42	37	30	10	12	8	0	200
$n_i x_i$	0	15	80	126	148	150	60	84	64	0	727

où x_i et n_i désignent respectivement le nombre de voitures par minute et l'effectif correspondant lors de l'observation $n^o i$ (par exemple, $x_1 = 0$ et $n_1 = 6$) c'est-à-dire que lors de 6 observations, il y a 0 voiture). La moyenne arithmétique de cette distribution observée est

$$\frac{\sum n_i x_i}{\sum n_i} = \frac{727}{200} = 3.635 \simeq 3.5$$

Problème : Tester l'hypothèse (au risque $\alpha = 0,01$) selon laquelle X suit une loi de Poisson de paramètre 3,5.

On pose

- H_0 : " $X \rightsquigarrow \mathcal{P}(3,5)$ "
- H_1 : " X ne suit pas $\mathcal{P}(3,5)$ "

Sous H_0 , $p_i = p(X = i) = e^{-3,5} \frac{(3,5)^i}{i!}$, on a donc le tableau de valeurs suivant

x_i	n_i	p_i	Np_i	Np_i corrigée	n_i corrigée	$\sum_i \frac{(n_i - Np_i)^2}{Np_i}$
0	6	0,0302	6,04	6,04	6	0,00026
1	15	0,1057	21,14	21,14	15	1,78333
2	40	0,1850	37	37	40	0,24324
3	42	0,2158	43,16	43,16	42	0,03118
4	37	0,1888	37,76	37,76	37	0,01530
5	30	0,1322	26,44	26,44	30	0,47933
6	10	0,0771	15,42	15,42	10	1,90508
7	12	0,0385	7,7	7,7	12	2,40130
8	8	0,0169	3,38	5,34	8	1,32502
≥ 9	0	0,0098	1,96			
Total	200	1	200	200	200	8,18404

On a effectué le regroupement des deux dernières classes car l'effectif théorique y est inférieur à 5. Après ce regroupement, le nombre de classes est de 9. Le nombre de degrés de liberté est $9 - 1 - 1 = 7$. Au risque $\alpha = 0,01$, $\chi_{7,0.99}^2 = 18,48$ donc $\chi_{cal}^2 = 8,18404 < \chi_{7,0.99}^2$. On ne rejette pas l'hypothèse \mathbf{H}_0 et $X \rightsquigarrow \mathcal{P}(\lambda = 3,5)$ au risque $\alpha = 0,01$.

EXEMPLE 6 (loi binomiale). Supposons qu'on ait recueilli 300 bêtes contenant chacune trois ampoules. Dans chaque bête, on compte le nombre d'ampoules défectueuses. On obtient les résultats suivants

Nombred'ampoules défectueuses x_i	Nombre de bêtes observées n_i
0	190
1	95
2	10
3	5
Total	300

Pour chaque ampoule testée, on peut observer deux états différents : l'ampoule est défectueuse ou non. Le nombre X d'ampoules défectueuses par bête suit une loi binomiale de paramètres $n = 3$ et p . Déterminons p . Dans la distribution observée, le nombre d'ampoules défectueuses est de $0 \times 190 + 1 \times 95 + 2 \times 10 + 3 \times 5 = 130$ soit 130 ampoules défectueuses sur un total de 900 ampoules. La proportion d'ampoules défectueuses est alors de $\frac{130}{900} \simeq 0,144$

Prenons $p = 0,15$

Problème : Tester l'hypothèse (au risque $\alpha = 0,01$) selon laquelle le nombre d'ampoules défectueuses par bête suit une loi binomiale de paramètres $n = 3$ et $p = 0,15$.

On considère donc les hypothèses suivantes :

- \mathbf{H}_0 : $X \rightsquigarrow \mathcal{B}(3, 0,15)$
- \mathbf{H}_1 : X ne suit pas cette loi binomiale

et on détermine ensuite les probabilités théoriques ($X \rightsquigarrow \mathcal{B}$) :

$$p_0 = P\{X = 0\} = (0,85)^3 \simeq 0,6141$$

$$p_1 = P\{X = 1\} = C_3^1 (0,15)(0,85)^2 \simeq 0,3251$$

$$p_2 = P\{X = 2\} = C_3^2 (0,15)^2(0,85) \simeq 0,0574$$

$$p_3 = P\{X = 3\} = C_3^3 (0,15)^3 \simeq 0,0034$$

On a le tableau (provisoire) suivant :

x	effectif observé n_i	p_i	effectif théorique
0	190	0,6141	184,23
1	95	0,3251	97,53
2	10	0,0574	17,22
3	5	0,0034	1,02
T	300	1	300

L'effectif théorique de la quatrième classe est faible, en effet $1,02 < 5$. On effectue un regroupement de classes, les classes 2 et 3.

x_i	n_i	Np_i	$\sum_i \frac{(n_i - Np_i)^2}{Np_i}$
0	190	184,23	0,18071
1	95	97,53	0,06563
2 ou 3	15	18,24	0,57553
Total	300	300	0,82187

Après le regroupement, le nombre de classes est 3, le nombre de degrés de liberté est $3 - 1 = 2$. Au risque $\alpha = 0,01$, $\chi_{2,0.99}^2 = 9,21$. Donc $\chi_{calc}^2 = 0,82187 < \chi_{2,0.99}^2$. On ne rejette pas \mathbf{H}_0 au profit de \mathbf{H}_1 . On considère que le nombre d'ampoules défectueuses par boîte suit une loi binomiale de paramètre $n = 3$, $p = 0,15$ au risque $\alpha = 0,01$

2. Test de normalité

Les tests précédents sont des tests généraux s'appliquant sur n'importe quelle loi. Lorsque la loi à tester est la loi normale, on parle de test de normalité.

On cherche à se déterminer entre :

\mathbf{H}_0 : les données suivent une loi normale.

\mathbf{H}_1 : les données ne suivent pas une loi normale

2.1. Méthodes graphiques : Droite de Henry. La droite de Henry est une méthode pour visualiser les chances qu'a une distribution d'être gaussienne. Elle permet de lire rapidement la moyenne et l'écart type d'une telle distribution.

Principe : On représente les quantiles théoriques en fonction des quantiles observés (Diagramme Q-Q).

Si X est une variable gaussienne de moyenne \bar{x} et de variance σ^2 et si Z est une variable de loi normale centrée réduite, on a les égalités suivantes :

$$P(X < x_i) = P\left(\frac{X - \bar{x}}{\sigma} < \frac{x_i - \bar{x}}{\sigma}\right) = P(Z < y_i) = \Phi(y_i)$$

$y = \frac{x - \bar{x}}{\sigma}$. (on note Φ la fonction de répartition de la loi normale centrée réduite)

Pour chaque valeur x_i de la variable X , on peut calculer $P(X < x_i)$ puis en déduire, à l'aide d'une table de la fonction Φ , y_i tel que $\Phi(y_i) = P(X < x_i)$.

Si la variable est gaussienne, les points de coordonnées (x_i, y_i) sont alignés sur la droite d'équation $y = \frac{x - \bar{x}}{\sigma}$

EXEMPLE 7. Lors d'un examen noté sur 20, on obtient les résultats suivants :

- 10% des candidats ont obtenu moins de 4
- 30% des candidats ont obtenu moins de 8
- 60% des candidats ont obtenu moins de 12
- 80% des candidats ont obtenu moins de 16

On cherche à déterminer si la distribution des notes est gaussienne, et, si oui, ce que valent son espérance et son écart type.

On connaît donc 4 valeurs x_i , et, pour ces 4 valeurs, on connaît $P(X < x_i)$.

En utilisant la table “Table de la fonction de répartition de la loi normale centrée réduite”, on détermine les y_i correspondants :

x_i	$P(X < x_i) = \Phi(y_i)$	y_i
4	0,10	-1,282
8	0,30	-0,524
12	0,60	0,253
16	0,80	0,842

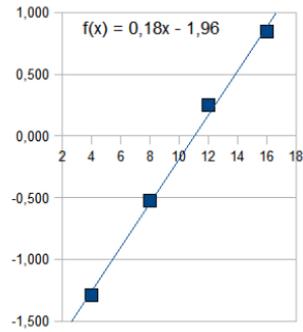


FIG. 1. Droite de Henry

Les points paraissent alignés. La droite coupe l'axe des abscisses au point d'abscisse 11 et le coefficient directeur est 0,18 environ, ce qui donnerait un écart type de $\frac{1}{0,18} = 5,6$. Cela laisse penser que la distribution est gaussienne de paramètres $\mu = 11$ et $\sigma = 5,6$.

3. Test de Khi-deux d'indépendance

Le test de khi-deux est fréquemment utilisé pour tester si deux caractères, qualitatifs ou quantitatifs (répartis en classes), observés dans une population sont indépendants ou si, au contraire, ils sont dépendants : présentent un certain degré d'association (liaison).

DÉFINITION 1 (Définition du test d'indépendance). *Le test d'indépendance est utilisé pour tester l'hypothèse nulle d'absence de relation entre deux variables qualitatives. On peut également dire que ce test vérifie l'hypothèse d'indépendance de ces variables. Si deux variables dépendent l'une de l'autre, la variation de l'une influence la variation de l'autre.*

3.1. Principe général du test :

- (1) Un échantillon aléatoire de taille n est prélevé d'une population et est observé selon deux caractères X à p modalités et Y à q modalités.
- (2) La répartition des n observations suivant les modalités croisées des deux caractères se présente sous la forme d'un tableau à double entrée appelé tableau de contingence.
- (3) Il s'agit par la suite de tester, à l'aide du khi-deux de Pearson, si les deux caractères sont indépendants ou non.

Tableau de contingence. Tableau des effectifs observés :

	y_1	y_j	...	y_l	Total ligne
x_1	n_{11}		n_{1j}	n_{1l}	$n_{1.} = \sum_j n_{1j}$
.
.
.
x_i	n_{i1}	n_{ij}	n_{il}	.
.
.
.
x_k	n_{k1}		n_{kj}	n_{kl}	.
Total colonne	$n_{.1} = \sum_i n_{i1}$	$n_{.j}$	$n_{.l}$	$n = n_{..} = \sum_i \sum_j n_{ij}$

– **Les hypothèses statistiques** peuvent s'énoncer ainsi :

$$\begin{cases} \mathbf{H}_0 & \text{les caractères : } X \text{ et } Y \text{ sont indépendants} \\ \mathbf{H}_1 & \text{les caractères : } X \text{ et } Y \text{ sont dépendants} \end{cases}$$

– **Sous l'hypothèse nulle \mathbf{H}_0** : indépendance des deux caractères, on a,

$$p_{ij} = p_i \cdot p_j : \forall (i = 1, \dots, k \text{ et } j = 1, \dots, l) \text{ (probabilités conjointes } p_{ij} = \frac{n_{ij}}{n}$$

– l'estimation des effectifs théoriques s'obtient en répartissant la taille de l'échantillon n dans les proportions obtenues selon les estimations des probabilités conjointes (indépendance en probabilité)

$$\text{(indépendance en probabilité) : } f_{ij} = \frac{n_{i.}}{n} \cdot \frac{n_{.j}}{n} = \frac{\hat{n}_{ij}}{n} : \text{d'où } \hat{n}_{ij} = \frac{n_{i.} \cdot n_{.j}}{n}$$

– Pour comparer les répartitions théorique et observée, on calcule, sous l'hypothèse nulle \mathbf{H}_0 la quantité :

$$\chi^2_{\text{calculé}} = \sum_i^k \sum_j^l \frac{(n_{ij} - \hat{n}_{ij})^2}{\hat{n}_{ij}},$$

laquelle sous \mathbf{H}_0 est distribuée selon la loi du khi-deux $\chi^2_{(k-1)(l-1)d.d.l}$: noté χ^2 table pour le risque d'erreur α choisi.

– **Décision et conclusion du test statistique :**

L'hypothèse nulle \mathbf{H}_0 d'indépendance est rejetée, au niveau α , si $\chi^2_{calculé} \geq \chi^2_{table}$ (le test statistique est toujours unilatéral).

EXEMPLE 8. *Test d'indépendance : taux de guérison et coût du médicament.*

Pour comparer l'efficacité de 2 médicaments comparables, mais de prix très différents, la Sécurité sociale a effectué une enquête sur les guérisons obtenues avec ces deux traitements. Les résultats sont présentés dans le tableau suivant :

	Original	Générique	Total
Guérisons	156	44	200
Non-guérisons	44	6	50
Total	200	50	250

Au seuil de signification $\alpha = 5\%$, peut-on conclure que ces deux médicaments ont la même efficacité ?

- (1) Hypothèses statistiques :
- (2) Seuil de signification :
- (3) Conditions d'application du test :
- (4) Degré de liberté :
- (5) Statistique de test :
- (6) Calcul de la statistique du χ^2 calculé sous l'hypothèse nulle \mathbf{H}_0 :
- (7) Règle de décision et conclusion

1. Hypothèses statistiques $\left\{ \begin{array}{l} \mathbf{H}_0 \text{ indépendance} \\ \mathbf{H}_1 \text{ dépendance} \end{array} \right.$

2. Seuil de signification : $\alpha = 5\%$

3. Conditions d'application du test : Un échantillon aléatoire de taille $n = 250$ observé selon deux caractères qualitatifs à $k = 2$ et $l = 2$ modalités.

4. Degré de liberté : $(k - 1)(l - 1) = 1d.d.l.$

5. Statistique de test : $\chi^2_{calculé} = \sum_i^k \sum_j^l \frac{(n_{ij} - \hat{n}_{ij})^2}{\hat{n}_{ij}} \sim \chi^2_{1d.d.l}$:

6. Calcul de la statistique du $\chi^2_{calculé}$ sous l'hypothèse nulle \mathbf{H}_0 Indépendance

	Original	Générique	Total
Guérisons	$\frac{200 \times 200}{250} = 160$	$\frac{200 \times 50}{250} = 40$	200
Non-guérisons	$\frac{50 \times 200}{250} = 40$	$\frac{50 \times 50}{250} = 10$	50
Total	200	50	250

Tableau aux effectifs théoriques $\hat{n}_{ij} = \frac{n_i \cdot n_{.i}}{n}$

$$\chi^2_{calculé} = \sum_i^k \sum_j^l \frac{(n_{ij} - \hat{n}_{ij})^2}{\hat{n}_{ij}} = 2.5$$

7. **Décision et conclusion** : fractile de la loi du χ^2_1 (cf. table) : $\chi^2_{1, \alpha=5\%} = 3,84$. La valeur du χ^2 calculé appartient à la zone de non-rejet de \mathbf{H}_0 . En effet, $\chi^2_{calculé} = 2,5 < \chi^2_{1, \alpha=5\%}$

Il n'y a pas de dépendance significative entre les deux caractères : le taux de guérison et le coût du médicament sont indépendants. Au seuil de signification $\alpha = 5\%$, on peut conclure que ces deux médicaments ont la même efficacité

4. Test de Kolmogorov-Smirnov

Le principe est simple. On mesure l'écart maximum qui existe soit entre une fonction de répartition empirique (donc des fréquences cumulées) et une fonction de répartition théorique, soit entre deux fonctions de répartition empiriques.

Dans le premier cas, soit une fonction de répartition empirique F_n et la fonction de répartition d'une loi de probabilité théorique F .

$$D_n = \sup_{x \in \mathbb{R}} |F_n(x) - F(x)|$$

Précisons que le test de K-S est indépendant de cette loi théorique : on peut comparer la répartition empirique aussi bien à une loi normale qu'à une loi de Poisson ou autre.

Etant donnés :

- (1) Un échantillon de taille n d'observations d'une variable,
- (2) Et une fonction de répartition de référence $F(x)$, le test de Kolmogorov teste l'hypothèse \mathbf{H}_0 selon laquelle l'échantillon a été prélevé dans une population de fonction de répartition $F(x)$.

Pour cela, il calcule sur l'échantillon une quantité D , appelée "statistique de Kolmogorov", dont la distribution est connue lorsque \mathbf{H}_0 est vraie. La statistique de Kolmogorov-Smirnov D_n est définie par

$$D_n = \sup_{x \in \mathbb{R}} |F_n(x) - F(x)|$$

où $F_n(x)$ est la proportion des observations dont la valeur est inférieure ou égale à x (fonction de répartition empirique).

Une valeur élevée de D ($D = |F_n(x) - F(x)|$) est une indication que la distribution de l'échantillon s'éloigne sensiblement de la distribution de référence $F(x)$, et qu'il est donc peu probable que \mathbf{H}_0 soit correcte. Plus précisément,

$$P\left(\sup_{x \in \mathbb{R}} |F_n(x) - F(x)| > \frac{c}{n}\right) \xrightarrow{\infty} \alpha(c) = 2 \sum (-1)^{r-1} \exp(-2r^2 c^2)$$

pour toute constante $c > 0$. Le terme $\alpha(c)$ vaut 0,05 pour $c = 1,36$. Pour $n > 100$, la valeur critique du test est approximativement de la forme $\frac{c}{\sqrt{n}}$. Les valeurs usuelles de c en fonction de α sont :

α	0,200	0,10	0,05	0,02	0,01
c	1,073	1,224	1,358	1,517	1,628

Si $D_n > \frac{c}{\sqrt{n}}$, on rejette H_0 .

EXEMPLE 9. *Une nouvelle clientèle étrangère est attendue dans une station balnéaire. Afin de mieux connaître leurs goûts, des brasseurs ont commandé une étude de marché. En début de saison, on demande à vingt de ces nouveaux touristes de donner leur préférence parmi cinq types de bières, de la moins amère (bière 1) à la plus amère (bière 5). A l'aide d'un test de K-S, le chargé d'études décide de*

comparer les résultats avec une loi uniforme, c'est-à-dire une situation où chaque bière aurait eu la préférence de quatre répondants.

Les résultats de l'enquête sont les suivants :

1 3 2 5 1 2 2 4 1 2 2 1 3 3 2 4 5 1 1 2

On se fixe un risque d'erreur de 5%. L'hypothèse \mathbf{H}_0 à tester est celle de l'égalité avec une loi uniforme.

Résumons les écarts entre observations et répartition uniforme :

Classe	Effectifs	Uniforme	Cumul réel	Cumul théorique	D
1	6	4	0,30	0,20	0,10
2	7	4	0,65	0,40	0,25
3	3	4	0,80	0,60	0,20
4	2	4	0,90	0,80	0,10
5	2	4	1,00	1,00	0,00

La distance la plus élevée s'établit à $D = 0,25$.

On calcule pour $n = 20$ et $\alpha = 5\%$ la valeur de $\frac{c}{\sqrt{20}} = 0,303$. Bien que ces touristes semblent préférer les bières les moins amères, on ne peut pas rejeter l'hypothèse selon laquelle ils n'ont pas de préférence particulière.