

chp3 Test non paramétrique

III Comparaisons de proportions

1) Comparaison d'une proportion à une valeur donnée

soit un n-éch d'une population présentant un caractère A.

On note par X le nombre d'individus ayant le caractère A.

$$X = \sum_{i=1}^n I_A(x_i)$$

si x_i présente A $I_A(x_i) = 1$ sinon $I_A(x_i) = 0$.

On note par p la proportion d'individus présentant le caractère A.

$\hat{p} = \frac{1}{n} X$ un estimateur sans biais de p .

La question qui on se pose : La proportion est elle égale à une pr po

. Test bilatéral : $H_0 : p = p_0$ vs $H_1 : p \neq p_0$

On rejette H_0 si $U_{\text{obs}} = \frac{|X - np_0|}{\sqrt{np_0(1-p_0)}} > U_{1-\alpha/2}$.

on $X \sim B(n, p)$ (somme de bernoulli ind)

$E(X) = np$ et $\text{var}(X) = np(1-p)$

pour n assez grand $X \sim N(np, \sqrt{np(1-p)})$ (En général, n et n)

Donc sous H_0 : $U_{\text{obs}} \sim N(0,1)$

$$U_{1-\alpha/2} = F^{-1}_{N(0,1)}(1-\alpha/2)$$

[Rq: Dans certains cas, on utilise la règle de décision suivante

$$U_{\text{obs}} = 2\sqrt{n} \left| \arcsin \sqrt{\frac{x}{n}} - \arcsin \sqrt{p_0} \right| > U_{1-\alpha/2} \quad U_{\text{obs}} \sim N(0,1)$$

arc sin est calculé pour les angles exprimés en radians (pas en degrés)

. Test unilatérale $H_0 : p = p_0$ vs $H_1 : p > p_0$

$$\text{La règle de décision } U_{\text{obs}} = \frac{|X - np_0|}{\sqrt{np_0(1-p_0)}} > U_{1-\alpha}$$

[Pour le second test]

$$U_{\text{obs}} = 2\sqrt{n} \left| \arcsin \sqrt{\frac{x}{n}} - \arcsin \sqrt{p_0} \right| > U_{1-\alpha}$$

II) Comparaison de deux proportions:

Deux échantillons de tailles n_1 et n_2 respect

p_1 La proportion d'inds de l'ech 1 ayant le caract \acute{e} re A
 p_2 —————— 2 —————— A

On compare les deux proportions p_1 et p_2 .

On peut présenter les résultats du tableau de contingence suivant

| | Ech 1 | Ech 2 | Totaux |
|-----------|-----------|-----------|---------------------|
| A | a | b | a+b |
| \bar{A} | $n_1 - a$ | $n_2 - b$ | $n_1 + n_2 - a - b$ |
| Totaux | n_1 | n_2 | $(n_1 + n_2)$ |

$$H_0: p_1 = p_2$$

Méthode de asymptotique: les tailles d'échantillon suffisamment grandes.

$H_0: p_1 = p_2 = p_0$ contre $H_1: p_1 \neq p_2$

La statistique de décision : $U = \frac{1}{n_1} \sum_{i=1}^{n_1} I_A(x_i) + \frac{1}{n_2} \sum_{i=1}^{n_2} I_A(y_i)$

$RC = [|U| > k_\alpha]$.

On rejette le fait que $p_1 = p_2$ au risque d'au moins k_α donnée t.p $P(RC) = \alpha$

$$U \sim N\left(0, \sqrt{p_0(1-p_0)\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}\right) \quad P\left(|U| > \sqrt{\frac{p_0(1-p_0)(\frac{1}{n_1} + \frac{1}{n_2})}{p_0(1-p_0)(\frac{1}{n_1} + \frac{1}{n_2})}}\right) = \alpha/2$$

Pour un test un latéral $H_0: p_1 = p_2 = p_0$ contre $H_1: p_1 > p_2$ (ou $p_1 < p_2$)

au seuil α , on rejette H_0 si $P(U > k_\alpha) = \alpha$.

$$P\left(\frac{U}{\sqrt{\frac{p_0(1-p_0)}{\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}}} > k_\alpha\right) = \alpha.$$

Exemple
Sur 96 pièces provenant d'un fournisseur A, il y a 12 qui sont défectueuses et sur 55 pièces provenant d'un autre fournisseur B, il y a 15 défectueuses. Peut-on dire, que la proportion des pièces défectueuses de A est la même que celle de B, au seuil $\alpha = 5\%$.

$H_0: p_1 = p_2 = p$ contre $H_1: p_1 \neq p_2$.

$$\hat{p}_1 = \frac{1}{n_1} \sum_{i=1}^{n_1} I_A(x_i) = \frac{12}{96} = \frac{1}{8} \quad \hat{p}_2 = \frac{15}{55} = \frac{3}{11}$$

$$U = \hat{p}_1 - \hat{p}_2 \sim N\left(0, \sqrt{p(1-p)\left(\frac{1}{96} + \frac{1}{55}\right)}\right)$$

$$U = \hat{p}_1 - \hat{p}_2 \sim N\left(0, \sqrt{p(1-p)\left(\frac{1}{96} + \frac{1}{55}\right)}\right) \quad \text{on l'estime par } \hat{p} = \frac{12+15}{96+55} = \frac{27}{151} = 0,18$$

$$P\left(|U| > k_\alpha\right) = 0,05$$

$$k_\alpha = F_{N(0,1)}^{-1}(1 - 0,025) = 1,96$$

$$\frac{U}{\sqrt{0,18(1-0,18)\left(\frac{1}{96} + \frac{1}{55}\right)}} = \frac{0,18 - 0,136}{\sqrt{0,18(1-0,18)\left(\frac{1}{96} + \frac{1}{55}\right)}} = 2,28$$

on rejette H_0 .

Test de Cramer Von Mises

Sont x_1, \dots, x_n n'éch de X de f.r F

$F^*(x)$ f.r. connue.

$$H_0: F(x) = F^*(x) \quad \forall x \text{ conti } H_1: F(x) \neq F^*(x)$$

On suppose que tout les paramètres de F^* sont connus.

Indicateur d'écart du test est

$$I = \int_{-\infty}^{+\infty} |F^*(x) - F(x)|^2 dF(x)$$

La distribution de cet indicateur a été tabulée. On démontre que

$$I = \frac{1}{2n} + \sum_{i=1}^n \left[\frac{d_i - 1}{2n} - F^*(x_i) \right]^2$$

où d_i valeurs de l'éch ordonnées π_i .

Au seuil α , on rejette H_0 si la valeur de I dépasse k_α .

Rq: Le test de Cramer Von Mises a les mêmes applications que le test de Kolmogorov. La différence entre ces deux tests réside dans le fait que pour le test de K.V.M. Kolmogorov seul l'écart max entre la distribution empirique et la distribution d'ajustement entre en considération alors que le test de Cramer V.N., l'indicateur d'écart prend mieux en compte l'ensemble des données en ce sens que la somme des écarts intervient. Le test de Kolmogorov est donc beaucoup plus sensible à l'existence des points aberrants ds un échantillon que le test de Cramer V.N. On pense généralement que ce dernier est plus puissant, mais cela n'a pas été démontré théoriquement.

2) Test de χ^2

Il permet de comparer la densité de la loi à l'histogramme construit à partir des obs.

Le pb avec l'histogramme est le choix très arbitraire des classes. On suppose néanmoins que k classes sont choisies.

Le principe du test de χ^2 est de comparer le pourcentage d'obs observé dans la classe numéro i , que nous noterons par \hat{p}_i au pourcentage d'obs contenues dans cette classe que nous noterons par p_i .

Sont les k classes $C_i = [a_i, a_{i+1}[$; $i = \overline{1, k}$

$$p_1 = P(C_1) = F(a_2) - F(a_1); \dots; p_k = P(C_k) = F(a_{k+1}) - F(a_k)$$

Test : $H_0: F(x) = F_0(x)$ vs $H_1: \exists x: F_0(x) \neq F(x)$

$$\text{Lstat de décision } \chi^2_{\text{obs}} = \sum_{i=1}^k \left(\frac{N_i - n p_i}{\sqrt{n p_i}} \right)^2$$

La distribution de χ^2_{obs} est χ^2_{k-1} ($\sum N_i = n$)

N_i = effectif de la classe C_i

$$N_i \sim N(n p_i; n p_i (1-p_i)) \quad \left(\frac{N_i - n p_i}{\sqrt{n p_i (1-p_i)}} \right) \sim N(0, 1)$$

On admet aussi que si p_i est petit $n p_i (1-p_i) \approx n p_i$ par suite

$$\sum_{i=1}^n \left(\frac{N_i - n p_i}{\sqrt{n p_i}} \right)^2 \sim \chi^2_{k-1} \quad (\text{n assez grand})$$

Le test de χ^2 est applicable pour $n p_i > 10$ généralement sinon on regroupe les classes.

Ex Soit un dé à 6 faces dont on veut vérifier la régularité.

X le nbre apparu après lancement.

Tester $X \sim U_{[1, \dots, 6]}$ contre $F_X(x) \neq F_U(x)$ pour x

C'est $H_0: p_i = 1/6$ vs $H_1: \exists i: p_i \neq 1/6$.

Pour cela on lance le dé 100 fois on obtient

| i | 1 | 2 | 3 | 4 | 5 | 6 |
|-----|----|---|----|----|----|---|
| n | 11 | 9 | 11 | 11 | 31 | |

Ces données sont-elles compatibles avec la distri sous H₀ ?

$$C_i = \text{Fac } i^*$$

$$P(Z) = \sum_{i=1}^6 \frac{(n_i - np_i)^2}{np_i} = 24,56$$

Au seuil $\alpha = 0,05$, on trouve X_5^2 pour $k = 11,1$

$x_{ob}^2 > x_5^2$ on rejette H_0

H₀: si sous H₀ la forme de la distribution est connue à r paramètres inconnus. On estime les paramètres. χ^2_{k-r} la statistique de décision suit dans ce cas χ^2_{k-r} .

III / Tests d'indépendance de deux caractères.

1) Test de χ^2 eff (test de Flamm).

1) Test de X et de Y.
 Soit une population sur laquelle on observe de caractères X et Y.
 On s'intéresse à proposer de tester l'indépendance des deux caractères.
 On suppose que les individus de la population peuvent être regroupés
 en k classes selon X et l classes selon Y.

en k classes selon X et s classes selon Y .
 Hyp : si X ou Y sont qualitatifs, les classes sont les modalités

sous H_0 : $X \perp Y \Leftrightarrow f_{ij} = f_i \times f_j$ - La statistique de décision $d^2 = \sum_{i,j} \frac{(f_{ij} - f_i \times f_j')^2}{n \times f_i \times f_j'} \sim \chi^2_{(k-1)(s-1)}$

On rejette H_0 au seuil α , si $d > k_\alpha$.

Exp: On interroge 100 personnes de catégories professionnelles X_1 et X_2 , et lisant le journal Y_1 ou Y_2 . On obtient l'ancé entre X et Y au seuil 5%.

| $\frac{4}{3}x$ | x_1 | x_2 | $\frac{7}{3}x$ |
|----------------|-------|-------|----------------|
| y_1 | 27 | 9 | 36 |
| y_2 | 12 | 52 | 64 |
| y_3 | 39 | 61 | 100 |

Si X et Y sont gaussiennes.

Indép de X et Y (\Leftrightarrow) $S = 0$

$$r = \frac{\text{cov}(X, Y)}{\sqrt{S_X} \sqrt{S_Y}}$$

comparer r à 0

Proposition

Si X et Y sont indép^{te} et si R est le coefficient de corrélation empirique on a

$$\frac{R}{\sqrt{1-R^2}} \sqrt{n-2} \sim T_{n-2}$$

Test $X \perp Y$ $RC = [|R| > k]$.

Rq: On donne:

$$z = \frac{1}{2} \log \left(\frac{1+r}{1-r} \right) \sim N \left(\frac{1}{2} \log \frac{1+S}{1-S} ; \frac{1}{n-3} \right)$$

Rq
si X et Y ne sont pas gaussiennes, ce test précédent reste valable mais il test la corrélation linéaire non pas l'indépendance.

$$\frac{N_{ij}}{n} \sim N(p_{ij}, \sqrt{\frac{p_{ij}}{n^2}}) = N(p_{ij}, \sqrt{\frac{p_{ij}}{n}})$$

$$\left(\frac{\frac{N_{ij}}{n} - p_{ij}}{\sqrt{\frac{p_{ij}}{n}}} \right)^2 \sim \chi_1^2$$