

Rappel: test d'adéquation du χ^2 :

But: tester H_0 "la loi \mathbb{P} de l'échantillon X_1, \dots, X_n est \mathcal{Q} ".

Teste basé sur une statistique et une décomposition des réalisations (discrétisation).

$\mathbb{R} = \Omega_1 \cup \dots \cup \Omega_q$ pour $q \geq 1$, $\Omega_i \cap \Omega_j = \emptyset$ si $i \neq j$.

On teste H_0 : " $\mathbb{P}(\Omega_i) = \mathcal{Q}(\Omega_i) \forall i=1, \dots, q$ ".

$$\hookrightarrow Z_n(X_1, \dots, X_n) = n \sum_{i=1}^q \frac{\left(\frac{\sum_{j=1}^n \mathbb{1}_{\Omega_i}(X_j)}{n} - \mathcal{Q}(\Omega_i) \right)^2}{\mathcal{Q}(\Omega_i)}$$

• $Z_n \xrightarrow{\text{loi}} \chi_{q-1}^2$ si $\mathbb{P}(\Omega_i) = \mathcal{Q}(\Omega_i) \forall i$.

• $Z_n \rightarrow +\infty$ si $\exists i \in \{1, \dots, q\}, \mathbb{P}(\Omega_i) \neq \mathcal{Q}(\Omega_i)$.

Exemple d'application: Expérience de Mendel sur la transmission des traits génétiques.

Teste la transmission des charac. de petits pois

Teste la transmission des charac. de petits pois après hybridation.

Théorie: on a un génome constitué de paires de gènes, et on transmet un gène de chaque paire à nos descendants.

Sur les pois:
Gène couleur: "c" pour couleur verte, récessif.
"C" pour couleur jaune, dominant.
Gène forme: "f" pour "ridé", récessif
"F" pour "ronde/lisse", dominant.

Procédure de teste: on hybride deux plants CcFf et on regarde le génome des "enfants".

↳ on répète ce processus plein de fois et on regarde la fréquence des différentes expressions de gènes

Si Mendel a juste, on doit avoir que tous les 16 génotypes possibles sont équiprobables

↳ on prédit

| Vert | | Jaune |

	Vert	Jaune
ridé	$\frac{1}{16}$	$\frac{3}{16}$
lisse	$\frac{3}{16}$	$\frac{9}{16}$

Test du χ^2 pour vérifier si l'échantillon de Mendel respecte ces prédictions.

	J + lisse	J. + ridé	V. + lisse	V + ridé	556
Nb. de pois	315	101	108	32	
Fréq. exp.	$\frac{315}{556}$	$\frac{101}{556}$	--	--	
Fréq. théo.	$\frac{9}{16}$	$\frac{3}{16}$	$\frac{3}{16}$	$\frac{1}{16}$	

Notre stat. de test : $n = 556$, $h = 4$

$$Z_{556} = n \sum_{i=1}^h \left(\frac{\sum_{j=1}^n \mathbb{1}_{\Delta \nu_i}(X_j)}{n} - Q(\Delta \nu_i) \right)^2$$

$Q(\Delta \nu_i)$

$$= 556 \left(\frac{\left(\frac{315}{556} - \frac{9}{16} \right)^2}{\frac{9}{16}} + \frac{\left(\frac{101}{556} - \frac{3}{16} \right)^2}{\frac{3}{16}} + \frac{\left(\frac{108}{556} - \frac{3}{16} \right)^2}{\frac{3}{16}} + \frac{\left(\frac{32}{556} - \frac{1}{16} \right)^2}{\frac{1}{16}} \right)$$

$$\approx 0.47$$

Région de rejet pour un test à niveau de confiance 95%
 $\{Z_{556} \geq c\}$ avec c tq. $P(\chi_3^2 > c) = 0.05$

$$\hookrightarrow c = 7.82.$$

$0.47 \ll 7.82$, on ne rejette pas H_0 .

Principe d'appli: on souhaite que $\forall i, i'$

$$\frac{\left(\frac{\sum_{j=1}^n \mathbb{1}_{\Omega_i}(X_j)}{n} - Q(\Omega_i) \right)^2}{Q(\Omega_i)}$$

et l'équivalent pour i' ait un ratio au plus ...

\Leftrightarrow on veut que les $Q(\Omega_i)$ soient toutes de même ordre de grandeur.

Exemple de test d'indépendance du χ^2 :

Yeux \ chev.	Blond	Brun	Noir	Roux	Tot.	Freq.
Bleu	25	9	3	7	44	44/124
Gris	13	17	20	7	47	:
Brun	7	13	8	5	33	:

Brun	7	13	6	5	33	:
tot.	45	39	21	19	124	
freq.	45/124	--	--	--	--	

But: tester si "couleur de cheveux" est indép. de "couleur d'yeux".

On introduit les quantités:

$$P_{ij} = \mathbb{P}(\text{un individu ait les yeux de couleur } i \text{ et les cheveux de couleur } j)$$

Yeux: 1 \equiv bleu, 2 \equiv gris, 3 \equiv brun

Cheveux: 1 \equiv blond, 2 \equiv brun, 3 \equiv noir, 4 \equiv roux.

$$P_{i*} = \sum_{j=1}^4 P_{ij} = \mathbb{P}(\text{un individu ait les yeux } i)$$

$$P_{*j} = \sum_{i=1}^3 P_{ij} = \mathbb{P}(\text{un individu ait les cheveux } j)$$

Si cheveux et yeux indép. on doit avoir

$$P_{ij} = P_{i*} \cdot P_{*j} \quad \forall i, j.$$

On introduit l'hypothèse nulle paramétrique

$$H_0: "P_{ij} = P_{i*} \cdot P_{*j} \quad \forall i=1, \dots, 3, \text{ et } j=1, \dots, 4"$$

On construit une statistique de test:

On construit une statistique de test:

N_{ij} = nombre d'individus dans l'échantillon avec yeux i et cheveux j .

$N_{i\cdot}$ = nombre _____ avec les yeux i

$N_{\cdot j}$ = nombre _____ avec les cheveux j .

$$Z_n = n \sum_{i=1}^3 \sum_{j=1}^4 \frac{\left(\frac{N_{ij}}{n} - q_{ij} \right)^2}{q_{ij}}$$

→ Sous H_0 , on a $q_{ij} = p_{ij} = p_{i\cdot} \cdot p_{\cdot j}$

$$\leadsto Z_n = n \sum_{i=1}^3 \sum_{j=1}^4 \frac{\left(\frac{N_{ij}}{n} - p_{i\cdot} \cdot p_{\cdot j} \right)^2}{p_{i\cdot} \cdot p_{\cdot j}}$$

⚠ on ne connaît pas $p_{i\cdot}$ et $p_{\cdot j}$.

Solution: on les approxime

$$\leadsto Z_n = n \sum_{i=1}^3 \sum_{j=1}^4 \frac{\left(\frac{N_{ij}}{n} - \frac{N_{i\cdot}}{n} \cdot \frac{N_{\cdot j}}{n} \right)^2}{\frac{N_{i\cdot}}{n} \cdot \frac{N_{\cdot j}}{n}}$$

$\frac{N_{i\cdot}}{n}$ est l'estimateur "moyenne empirique" de $p_{i\cdot}$.

Z_n sera notre statistique de test. Il

se trouve que Z_n converge vers une loi
du χ^2 : degrés de liberté ?

12 paramètres - 1 relation entre eux

- nombre de relations induites par les
estimations empiriques de p_{i*} , p_{*j} .

$$\begin{aligned} 3 + 4 - 1 - 1 & \text{ car } p_{1*} + p_{2*} + p_{3*} = 1 \\ & = 5 \quad p_{*1} + p_{*2} + \dots + p_{*4} = 1 \end{aligned}$$

$12 - 1 - 5 = 6$ degrés de liberté.

t-tests: De la même façon que les tests
du χ^2 sont basés sur trouver une statistique
de test qui suit une loi du χ^2 , les t-tests
sont basés sur trouver une statistique de
test qui suit une loi de Student.

Déf: (loi de Student). Soit $\nu > 0$. On dit qu'une
variable aléatoire X suit une loi de Student
avec paramètre ν si c'est une v.a. continue
avec densité
$$f_X(x) = \frac{\Gamma(\frac{\nu+1}{2})}{\sqrt{\nu\pi} \Gamma(\frac{\nu}{2})} \left(1 + \frac{x^2}{\nu}\right)^{-\frac{\nu+1}{2}}$$

Si $\nu \in \mathbb{N}^*$, on parlera de loi de Student à

Si $\nu \in \mathbb{N}^*$, on parlera de loi de Student à ν degrés de liberté.

Cette loi apparait en stat à travers le resultat suivant:

Lemme (4.5.1) Soit Z, V deux v.a. indépendantes avec $Z \sim \mathcal{N}(0,1)$, $V \sim \chi_{\nu}^2$ pour $\nu \in \{2, 3, \dots\}$.
Alors, $Z \sqrt{\frac{\nu}{V}} \sim \text{Student}(\nu)$.

Cette structure va apparaitre sous la forme

$$\frac{(\bar{X}_n - E[X_i])}{\sqrt{\hat{\sigma}_n^2}} = \frac{\sqrt{n} (\bar{X}_n - E[X_i])}{\underbrace{\sqrt{\text{Var}(X_i)}}_{\sim \mathcal{N}(0,1)}} \cdot \frac{1}{\underbrace{\sqrt{\sum_{i=1}^n (X_i - \bar{X}_n)^2}}_{\sim \frac{1}{\sqrt{\chi_{n-1}^2}}}}$$