

# Chi-deux

## I Présentation

**Définition 1** Soit  $X_1, X_2, \dots, X_n$ ,  $n$  variables indépendantes suivant la même loi normale  $N(m; \sigma)$ . Alors la variable aléatoire  $Z = \frac{1}{\sigma^2} [(X_1 - m)^2 + (X_2 - m)^2 + \dots + (X_n - m)^2]$  suit la loi du chi\_deux à  $n$  degrés de liberté.


**Remarque 1** On sait que si  $X_i$  suit la loi normale  $N(m; \sigma)$ , alors  $\frac{X_i - m}{\sigma}$  suit la loi normale centrée réduite  $N(0; 1)$ . D'où une définition équivalente :

**Définition 2** Soit  $X_1, X_2, \dots, X_n$ ,  $n$  variables indépendantes suivant la loi normale centrée réduite  $N(0; 1)$ . Alors la variable aléatoire  $Z = X_1^2 + X_2^2 + \dots + X_n^2$  suit la loi du chi\_deux à  $n$  degrés de liberté. On la note  $\chi^2_{(n)}$ .

**Remarque 2**  $\chi^2_{(1)}$  a une espérance égale à 1 et une variance égale à 2. Donc  $\chi^2_{(n)}$  a une espérance égale à  $n$  et une variance égale à  $2n$ .

D'après le théorème central limite, pour  $n$  suffisamment grand,  $Z$ , qui est une somme de variables aléatoires indépendantes et de même loi, est approximativement distribuée selon une loi normale d'espérance  $n$  et de variance  $2n$ , donc suit approximativement la loi  $N(n; \sqrt{2n})$ . L'approximation est excellente à partir de  $n=30$ .

**Allure des densités de probabilité** La courbe de densité de  $\chi^2_{(n)}$  a pour équation  $y = ke^{-x/2} x^{n/2-1}$  où  $k$  est tel que l'aire sous la courbe vaut 1. On observe que lorsque  $n$  augmente, la courbe de densité de  $\chi^2_{(n)}$  se rapproche d'une courbe de Gauss. Le maximum s'obtient pour  $x = n - 2$



## II Test d'ajustement à une loi.

**Position du problème.** On extrait d'une population ( $\Pi$ ) un échantillon ( $E_n$ ) de taille  $n$ . Les résultats  $(x_j)_{1 \leq j \leq n}$  du caractère étudié sont regroupés en  $k$  classes, et on note  $(o_i)_{1 \leq i \leq k}$  l'effectif observé dans chaque classe.

De même, soit  $(t_i)_{1 \leq i \leq k}$  l'effectif théorique résultant de la loi du modèle théorique. Pour mesurer l'adéquation de l'échantillon au modèle théorique, on calcule la somme des écarts quadratiques réduits

$$d^2 = \sum_{i=1}^k \frac{(o_i - t_i)^2}{t_i}$$

Dans chaque classe, l'effectif observé  $o_i$  varie quand on passe d'un échantillon ( $E_n$ ) à un autre.  $o_i$  est la réalisation d'une variable aléatoire  $O_i$ .

**Théorème.** On détermine les classes pour que dans chacune d'elles  $t_i \geq 5$ . Dans ces conditions, pour  $n$  assez grand, la variable aléatoire  $D^2 = \sum_{i=1}^k \frac{(O_i - t_i)^2}{t_i}$  suit une loi du  $\chi^2_{(k-1)}$ .

### Mise en place du test.

Hypothèse  $H_0$  : la distribution observée n'est pas significativement différente de la distribution théorique.

Seuil critique : on choisit  $\alpha = P(\text{rejeter à tort } H_0)$   
comme  $D^2$  suit une loi du  $\chi^2_{(k-1)}$ , on en déduit le nombre  $h$  tel que  
 $\alpha = P(\chi^2_{(k-1)} > h)$

Règle de décision : si  $d^2 > h$  on rejette  $H_0$  au risque  $\alpha$   
sinon, on ne rejette pas  $H_0$ , c'est-à-dire qu'on considère que la différence entre la distribution observée et la distribution théorique est due aux fluctuations d'échantillonnage.

## III Test d'homogénéité.

**Position du problème.** Les observations d'une variable qualitative sur  $p$  échantillons permettent-elles de conclure que les échantillons proviennent de la même population?

**Résolution** La méthode consiste à comparer les effectifs observés de chacune des  $k$  modalités sur les  $p$  échantillons, avec les effectifs théoriques qu'on devrait obtenir dans le cas où ils seraient issus d'une même population.

Pour cela, on fabrique deux tableaux de contingence de taille  $p \times k$ , l'un contenant les effectifs  $o_{ij}$  observés et l'autre les effectifs théoriques  $t_{ij}$ .

La variable aléatoire  $D^2 = \sum_{i=1}^p \sum_{j=1}^k \frac{(O_{ij} - t_{ij})^2}{t_{ij}}$  suit approximativement la loi du  $\chi^2_{(p-1)(k-1)}$

### Mise en place du test.

Hypothèse  $H_0$  : les  $p$  échantillons proviennent de la même population.

Seuil critique : on calcule  $h$  par  $\alpha = P(\chi^2_{(p-1)(k-1)} > h)$

Règle de décision : si  $d^2 > h$  on rejette  $H_0$  au risque  $\alpha$   
sinon, on ne rejette pas  $H_0$ , c'est-à-dire qu'on considère que les différences entre les distributions observées et les distributions théoriques sont dues aux fluctuations d'échantillonnage.