

# INTRODUCTION AUX TESTS STATISTIQUES

MATTHIEU KOWALSKI

## 1. INTRODUCTION À LA THÉORIE DES TESTS

La théorie des tests consiste à tester si une hypothèse est vraie. On dit qu'on teste  $H_0$  (l'hypothèse nulle) contre  $H_1$  (hypothèse alternative). Dans cette situation, il est possible de commettre deux erreurs : conclure que  $H_0$  est vraie alors qu'en réalité c'est  $H_1$  qui est vérifiée, et vice versa. On définit ces deux erreurs :

**Définition 1** (Erreur de première et seconde espèce). *On appelle erreur de première espèce ou erreur de type I la quantité*

$$\alpha = \mathbb{P}\{\text{accepter } H_0 | H_1 \text{ est vraie}\}.$$

*On appelle erreur de seconde espèce ou erreur de type II la quantité*

$$\beta = \mathbb{P}\{\text{accepter } H_1 | H_0 \text{ est vraie}\}.$$

Pour construire un test statistique au risque  $\alpha$ , on fixe l'erreur de première espèce à  $\alpha$ , avec  $\alpha$  «petit» (de l'ordre de 5%, 1% voire moins). Une fois cette erreur fixée, on n'a plus aucun contrôle sur l'erreur de seconde espèce  $\beta$  !

On réalise un test selon les étapes suivantes :

- (1) Définition des hypothèses  $H_0$  et  $H_1$ . Cela implique de faire un choix : quelle est l'hypothèse privilégiée, suivant l'erreur qu'on veut contrôler.
- (2) Choix du niveau  $\alpha$  (petit).
- (3) Calculer la statistique du test. Ce calcul se fait à l'aide des observations statistiques à notre disposition, et du test choisies.
- (4) Conclusion au vu de l'échantillon selon la règle de décision associée au test. La conclusion étant le rejet ou l'acceptation de  $H_0$ .

**Remarque 1.** *Si, à l'issue du test, on accepte  $H_1$ , alors l'erreur commise est  $\alpha$  (par définition !). Puisque  $\alpha$  est fixé «petit», l'erreur commise est «petite».*

*Si on rejette  $H_0$ , l'erreur commise est  $\beta$  (toujours par définition !). Cette erreur n'est pas contrôlée et peut être très grande : l'acceptation de  $H_0$  ne permet donc pas, a priori, de conclure que  $H_0$  est effectivement vraie.*

## 2. UN TEST PARAMÉTRIQUE : LE TEST DE FISHER-STUDENT

On dispose de deux échantillons  $(X_1, \dots, X_{n_X})$  et  $(Y_1, \dots, Y_{n_Y})$  (de tailles éventuellement différentes) de loi  $P_1$  et  $P_2$  indépendantes de moyenne  $\mu_X$  et  $\mu_Y$  et de variance  $\sigma_X^2$  et  $\sigma_Y^2$  finies. Autrement dit

$$\forall i \quad \mathbb{E}\{X_i\} = \mu_1 \quad \text{Var}\{X_i\} = \sigma_1^2,$$

---

CES NOTES SONT TRÈS LARGEMENT INSPIRÉES DES NOTES MANUSCRITES DE SÉBASTIEN LOUSTAU, MERCI À LUI !

et

$$\forall i \quad \mathbb{E}\{Y_i\} = \mu_2 \quad \text{Var}\{Y_i\} = \sigma_2^2.$$

On note

$$\bar{X} = \frac{1}{n} \sum_{i=1}^{n_X} X_i \quad \text{et} \quad \bar{Y} = \frac{1}{n} \sum_{i=1}^{n_Y} Y_i$$

les moyennes empiriques et

$$S_X^2 = \frac{1}{n} \sum_{i=1}^{n_X} (X_i - \bar{X})^2 \quad \text{et} \quad S_Y^2 = \frac{1}{n} \sum_{i=1}^{n_Y} (Y_i - \bar{Y})^2$$

les variances empiriques.

On veut tester

$H_0$  : les moyennes sont égales, ie  $\mu_X = \mu_Y$

$H_1$  : les moyennes sont différentes, ie  $\mu_X \neq \mu_Y$ .

Pour cela, on suppose que  $X_i$  et  $Y_i$  suivent des lois normales. Le test s'effectue en deux étapes : on teste d'abord l'égalité des variances, et si ce test est accepté, alors on teste l'égalité des moyennes.

### 2.1. 1ère étape : test de Fisher d'égalité des variances.

2.1.1. *Hypothèses.* Pour comparer les moyennes, il faut pouvoir supposer que les variances sont égales. On va donc tester

$$H_0 : \sigma_X^2 = \sigma_Y^2 \quad \text{contre} \quad H_1 : \sigma_X^2 \neq \sigma_Y^2.$$

2.1.2. *Statistique de test.* Pour cela, on va calculer la statistique de test

$$F = \frac{n_X(n_Y - 1) S_X^2}{n_Y(n_X - 1) S_Y^2}.$$

On s'arrangera en pratique pour avoir  $F \geq 1$ , i.e.  $S_X^2 \geq S_Y^2$ .

Pour  $\alpha$  fixé, on définit la quantité  $\mathcal{F}_{n_X-1, n_Y-1; 1-\alpha/2}$ , qui est le fractile d'ordre  $1 - \alpha/2$  d'une loi de Fisher, telle que

$$\mathbb{P}\{Z > \mathcal{F}_{n_X-1, n_Y-1; 1-\alpha/2}\} = \frac{\alpha}{2}.$$

où  $Z \sim \mathcal{F}(n_X - 1, n_Y - 1)$ , i.e.  $Z$  suit une loi de Fisher de paramètres  $(n_X - 1)$ ,  $(n_Y - 1)$ .

La quantité  $\mathcal{F}_{n_X-1, n_Y-1; 1-\alpha/2}$  est donnée par les tables statistiques de la loi de Fisher.

2.1.3. *Règle de décision.* Ainsi, la règle de décision du test de Fisher est :

- Si  $F < \mathcal{F}_{n_X-1, n_Y-1; 1-\alpha/2}$ , alors on **accepte**  $H_0$ . On peut donc supposer que les variances sont égales. On passe alors à l'étape 2 : le test de Student d'égalité des moyennes.
- Si  $F > \mathcal{F}_{n_X-1, n_Y-1; 1-\alpha/2}$ , alors on **rejette**  $H_0$ . On peut conclure (avec un risque  $\alpha$  petit de se tromper) que les variances ne sont pas égales, et on ne peut pas poursuivre.

**Remarque 2.** Si les deux échantillons sont de même taille  $n_X = n_Y = n$ , la statistique de test devient

$$F = \frac{S_X^2}{S_Y^2}.$$

et suit une loi de Fisher de paramètres  $(n-1), (n-1)$

## 2.2. 2ème étape : test de Student d'égalité des moyennes.

2.2.1. *Hypothèses.* On va tester

$$H_0 : \mu_X^2 = \mu_Y^2 \quad \text{contre} \quad H_1 : \mu_X^2 \neq \mu_Y^2.$$

2.2.2. *Statistique de test.* Pour cela, on va calculer la statistique de test

$$T = \frac{\sqrt{n_X + n_Y - 2}}{\sqrt{\frac{1}{n_X} + \frac{1}{n_Y}}} \frac{|\bar{X} - \bar{Y}|}{\sqrt{n_X S_X^2 + n_Y S_Y^2}}.$$

Pour  $\alpha$  fixé, on définit la quantité  $t_{(n_X+n_Y-2); 1-\alpha/2}$ , qui est le fractile d'ordre  $1 - \alpha/2$  d'une loi de Student-t, telle que

$$\mathbb{P}\{Z > t_{(n_X+n_Y-2); 1-\alpha/2}\} = \frac{\alpha}{2},$$

où  $Z \sim t((n_X + n_Y - 2))$ , i.e.  $Z$  suit une loi de Student-t à  $(n_X + n_Y - 2)$  degrés de liberté.

La quantité  $t_{(n_X+n_Y-2); 1-\alpha/2}$  est donnée par les tables statistiques de la loi de Student-t.

2.2.3. *Règle de décision.* Ainsi, la règle de décision du test de Student est :

- Si  $T < t_{(n_X+n_Y-2); 1-\alpha/2}$ , alors on **accepte**  $H_0$ . On peut donc supposer que les moyennes sont égales. Le risque de se tromper  $\beta$  est inconnu et peut être élevé.
- Si  $T > t_{(n_X+n_Y-2); 1-\alpha/2}$ , alors on **rejette**  $H_0$ . On peut conclure (avec un risque  $\alpha$  petit de se tromper) que les moyennes ne sont pas égales.

**Remarque 3.** Si les deux échantillons sont de même taille  $n_X = n_Y = n$ , la statistique de test devient

$$T = \frac{\sqrt{n-1} |\bar{X} - \bar{Y}|}{\sqrt{S_X^2 + S_Y^2}}.$$

et suit une loi de Student-t à  $2(n-1)$  degrés de liberté.

## 3. TESTS DU $\chi^2$

Le test du  $\chi^2$  est *non paramétrique* : contrairement au test de Fisher-Student, on ne va pas tester des paramètres (comme la moyenne ou la variance), mais des distributions. Le test du  $\chi^2$  va permettre de répondre aux questions :

- (1) Est-ce que la population que j'observe suit une loi *donnée* à l'avance ?
- (2) Si j'observe deux variables statistiques  $(X_1, \dots, X_n)$  et  $(Y_1, \dots, Y_n)$  (observées sur le même ensemble d'individus), sont-elles indépendantes ?

### 3.1. Test du $\chi^2$ d'adéquation.

3.1.1. *Hypothèses.* On dispose d'un  $n$ -échantillon  $(X_1, \dots, X_n)$  réparti en  $K$  classes  $(\mathcal{C}_1, \dots, \mathcal{C}_K)$ . On se donne une loi théorique  $P$  dont les paramètres sont connus ou estimés. On note  $r$  le nombre de paramètres que l'on aura estimé (éventuellement  $r = 0$  si la loi est parfaitement connue). On va tester

$H_0$  : la population est distribuée selon  $P$

contre

$H_1$  : la population n'est pas distribuée selon  $P$ .

3.1.2. *Statistique de test.* Connaissant la loi  $P$  (par hypothèse), on connaît les *effectifs théoriques* pour chacune des classes  $\mathcal{C}_k$ ,  $k \in \{1, \dots, K\}$ . On note

$$p_k = \mathbb{P}\{X \in \mathcal{C}_k\}$$

la probabilité théorique qu'une réalisation de la v.a.  $X$  appartienne à  $\mathcal{C}_k$ . Ainsi, l'effectif théorique  $n_k$  de la classe  $\mathcal{C}_k$  est donné par

$$n_k = np_k.$$

On note  $N_k$  les *effectifs observés* sur notre échantillon  $(X_1, \dots, X_n)$  dans chacune des classes  $\mathcal{C}_k$ .

La statistique de test que l'on va calculer est :

$$D^2 = \sum_{k=1}^K \frac{(N_k - np_k)^2}{np_k}.$$

Pour  $\alpha$  fixé, on définit la quantité  $\chi_{K-1-r;1-\alpha}$ , qui est le fractile d'ordre  $1 - \alpha$  d'une loi de  $\chi^2$ , telle que

$$\mathbb{P}\{Z > \chi_{K-1-r;1-\alpha}\} = 1 - \alpha.$$

où  $Z \sim \chi^2(K - 1 - r)$ , i.e.  $Z$  suit une loi du  $\chi^2$  à  $K - 1 - r$  degrés de liberté. On rappelle que  $K$  est le nombre de classe et  $r$  le nombre de paramètres estimés.

La quantité  $\chi_{K-1-r;1-\alpha}$  est donnée par les tables statistiques de la loi du  $\chi^2$ .

3.1.3. *Règle de décision.* Ainsi, la règle de décision du test du  $\chi^2$  d'adéquation est :

- Si  $D^2 < \chi_{K-1-r;1-\alpha}$ , alors on **accepte**  $H_0$ . On peut donc supposer que la population est issue de la loi  $P$ . Le risque de se tromper  $\beta$  est inconnu et peut être élevé.
- Si  $D^2 > \chi_{K-1-r;1-\alpha}$ , alors on **rejette**  $H_0$ . On peut conclure (avec un risque  $\alpha$  petit de se tromper) que la population ne suit pas la loi  $P$ .

3.1.4. *Présentation pratique des calculs.* On résume toutes les informations précédente dans un tableau :

Classes	effectifs observés	effectifs théoriques	résidus
$\mathcal{C}_1$	$N_1$	$np_1$	$\frac{(N_1 - np_1)^2}{np_1}$
$\mathcal{C}_2$	$N_2$	$np_2$	$\frac{(N_2 - np_2)^2}{np_2}$
$\vdots$			
$\mathcal{C}_k$	$N_k$	$np_k$	$\frac{(N_k - np_k)^2}{np_k}$
$\vdots$			
$\mathcal{C}_K$	$N_K$	$np_K$	$\frac{(N_K - np_K)^2}{np_K}$
Total	$N$	$N$	$D^2$

### 3.2. Test du $\chi^2$ d'indépendance.

3.2.1. *Hypothèses.* Soit  $(X_1, \dots, X_n)$  et  $(Y_1, \dots, Y_n)$  deux variables statistiques *qualitatives* observés sur un échantillon de  $n$  individus. On suppose que les facteurs  $X$  et  $Y$  prennent respectivement les modalités  $c_1, \dots, c_r$  et  $d_1, \dots, d_s$ . Le but est d'étudier l'interaction entre les deux facteurs  $X$  et  $Y$ . On va tester

$H_0$  : les facteurs  $X$  et  $Y$  sont indépendants

contre

$H_1$  : les facteurs  $X$  et  $Y$  interagissent .

3.2.2. *Statistique de test.* Pour cela, on va utiliser le *tableau de contingence*. Ce tableau résume comment une caractéristique dépend d'une autre et donne le nombre d'individus possédant simultanément la modalité  $c_i$  de la variable  $X$  et la modalité  $d_j$  de la variable  $Y$ . Un tel tableau se présente sous la forme suivante, pour un échantillon de taille  $n$  :

X \ Y	Y					
	$d_1$	$\dots$	$d_j$	$\dots$	$d_s$	
$c_1$	$N_{11}$		$N_{1j}$		$N_{1J}$	$N_{1\bullet}$
$\vdots$			$\vdots$			
$c_i$	$N_{i1}$	$\dots$	$N_{ij}$	$\dots$	$N_{iJ}$	$N_{i\bullet}$
$\vdots$			$\vdots$			
$c_r$	$N_{r1}$		$N_{rj}$		$N_{rJ}$	$N_{r\bullet}$
	$N_{\bullet 1}$		$N_{\bullet j}$		$N_{\bullet J}$	$N$

où  $N_{ij}$  désigne le nombre de fois où  $X$  a pris la modalité  $c_i$  et  $Y$  la modalité  $d_j$ . Autrement dit,  $N_{ij}$  représente le nombre d'individus qui possède à la fois la caractéristique  $c_i$  et la caractéristique  $d_j$ . On définit les quantités

$$N_{i\bullet} = \sum_{j=1}^s N_{ij} \quad N_{\bullet j} = \sum_{i=1}^r N_{ij}$$

qui représentent respectivement le nombre d'individus qui possèdent la modalité  $c_i$  et le nombre d'individus avec la modalité  $d_j$ .

Comme pour les test du  $\chi^2$  d'adéquation, on connaît les *effectifs observés*  $N_{ij}$ , qu'on va comparer aux *effectifs théoriques*. On note

$$p_{ij} = \mathbb{P}\{X = c_i, Y = d_j\}, \quad p_{i\bullet} = \mathbb{P}\{X = c_i\}, \quad p_{\bullet j} = \mathbb{P}\{Y = d_j\}.$$

Si les variables  $X$  et  $Y$  sont indépendantes, alors on a  $p_{ij} = p_{i\bullet}p_{\bullet j}$ , et l'effectif théorique de chaque cas est donné par  $np_{i\bullet}p_{\bullet j}$ . Cependant, les  $p_{i\bullet}$  et  $p_{\bullet j}$  ne sont pas connus. On les estime alors par

$$\hat{p}_{i\bullet} = \frac{N_{i\bullet}}{N} \quad \text{et} \quad \hat{p}_{\bullet j} = \frac{N_{\bullet j}}{N}.$$

La statistique de test que l'on va calculer est :

$$D^2 = \sum_{i=1}^r \sum_{j=1}^s \frac{(N_{ij} - \frac{N_{i\bullet}N_{\bullet j}}{n})^2}{\frac{N_{i\bullet}N_{\bullet j}}{n}}.$$

Pour  $\alpha$  fixé, on définit la quantité  $\chi_{(r-1)(s-1);1-\alpha}$ , qui est le fractile d'ordre  $1 - \alpha$  d'une loi de  $\chi^2$ , telle que

$$\mathbb{P}\{Z > \chi_{(r-1)(s-1);1-\alpha}\} = 1 - \alpha.$$

où  $Z \sim \chi^2((r-1)(s-1))$ , i.e.  $Z$  suit une loi du  $\chi^2$  à  $(r-1)(s-1)$  degrés de liberté.

La quantité  $\chi_{(r-1)(s-1);1-\alpha}$  est donnée par les tables statistiques de la loi du  $\chi^2$ .

3.2.3. *Règle de décision.* Ainsi, la règle de décision du test du  $\chi^2$  d'indépendance est :

- Si  $D^2 < \chi_{K-1-r;1-\alpha}$ , alors on **accepte**  $H_0$ . On peut donc supposer que la population est issue de la loi  $P$ . Le risque de se tromper  $\beta$  est inconnu et peut être élevé.
- Si  $D^2 > \chi_{(r-1)(s-1);1-\alpha}$ , alors on **rejette**  $H_0$ . On peut conclure (avec un risque  $\alpha$  petit de se tromper) que les deux facteurs  $X$  et  $Y$  sont indépendant.

3.2.4. *présentation pratique des calculs.* On construit d'abord le tableau des effectifs observés

$\begin{array}{c} Y \\ \backslash \\ X \end{array}$	$d_1$	$\dots$	$d_j$	$\dots$	$d_s$	
$c_1$	$N_{11}$		$N_{1j}$		$N_{1J}$	$N_{1\bullet}$
$\vdots$			$\vdots$			
$c_i$	$N_{i1}$	$\dots$	$N_{ij}$	$\dots$	$N_{iJ}$	$N_{i\bullet}$
$\vdots$			$\vdots$			
$c_r$	$N_{r1}$		$N_{rj}$		$N_{rJ}$	$N_{r\bullet}$
	$N_{\bullet 1}$		$N_{\bullet j}$		$N_{\bullet J}$	$N$

On calcul ensuite le tableau des effectifs théoriques

$X \backslash Y$	$d_1$	$\dots$	$d_j$	$\dots$	$d_s$
$c_1$	$\frac{N_{1\bullet}N_{\bullet 1}}{N}$		$\frac{N_{1\bullet}N_{\bullet j}}{N}$		$\frac{N_{1\bullet}N_{\bullet s}}{N}$
$\vdots$			$\vdots$		
$c_i$	$\frac{N_{i\bullet}N_{\bullet 1}}{N}$	$\dots$	$\frac{N_{i\bullet}N_{\bullet j}}{N}$	$\dots$	$\frac{N_{i\bullet}N_{\bullet s}}{N}$
$\vdots$			$\vdots$		
$c_r$	$\frac{N_{r\bullet}N_{\bullet 1}}{N}$		$\frac{N_{r\bullet}N_{\bullet j}}{N}$		$\frac{N_{r\bullet}N_{\bullet s}}{N}$

Et enfin le tableau des résidus

$X \backslash Y$	$d_1$	$\dots$	$d_j$	$\dots$	$d_s$
$c_1$	$\frac{\left(N_{11} - \frac{N_{1\bullet}N_{\bullet 1}}{N}\right)^2}{\frac{N_{1\bullet}N_{\bullet 1}}{N}}$		$\frac{\left(N_{1j} - \frac{N_{1\bullet}N_{\bullet j}}{N}\right)^2}{\frac{N_{1\bullet}N_{\bullet j}}{N}}$		$\frac{\left(N_{1s} - \frac{N_{1\bullet}N_{\bullet s}}{N}\right)^2}{\frac{N_{1\bullet}N_{\bullet s}}{N}}$
$\vdots$			$\vdots$		
$c_i$	$\frac{\left(N_{i1} - \frac{N_{i\bullet}N_{\bullet 1}}{N}\right)^2}{\frac{N_{i\bullet}N_{\bullet 1}}{N}}$	$\dots$	$\frac{\left(N_{ij} - \frac{N_{i\bullet}N_{\bullet j}}{N}\right)^2}{\frac{N_{i\bullet}N_{\bullet j}}{N}}$	$\dots$	$\frac{\left(N_{is} - \frac{N_{i\bullet}N_{\bullet s}}{N}\right)^2}{\frac{N_{i\bullet}N_{\bullet s}}{N}}$
$\vdots$			$\vdots$		
$c_r$	$\frac{\left(N_{r1} - \frac{N_{r\bullet}N_{\bullet 1}}{N}\right)^2}{\frac{N_{r\bullet}N_{\bullet 1}}{N}}$		$\frac{\left(N_{rj} - \frac{N_{r\bullet}N_{\bullet j}}{N}\right)^2}{\frac{N_{r\bullet}N_{\bullet j}}{N}}$		$\frac{\left(N_{rs} - \frac{N_{r\bullet}N_{\bullet s}}{N}\right)^2}{\frac{N_{r\bullet}N_{\bullet s}}{N}}$