

# Statistique inférentielle

## Tests

A. Godichon-Baggioni



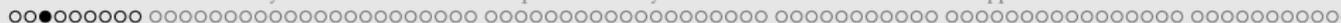
# I. Généralités

## PRINCIPE D'UN TEST

Le principe d'un test consiste à

1. Poser une hypothèse nulle  $H_0$  contre une hypothèse alternative  $H_1$
2. A l'aide d'un modèle probabiliste, définir une zone de rejet de l'hypothèse nulle  $H_0$
3. Regarder si le résultat expérimental est dans cette zone de rejet
4. Si le résultat est dans la zone de rejet, on rejette l'hypothèse  $H_0$ .
5. Si le résultat n'est pas dans la zone de rejet, on ne rejette pas l'hypothèse  $H_0$ .

**Attention!** La sémantique est importante.



## EXEMPLE

**Le lancer de pièce :** On souhaite savoir si la pièce est équilibrée. On jette 10 fois une pièce et on obtient 9 "Face". Un test permet de dire avec un certain risque si cette proportion de "Face" est seulement due à la fluctuation d'échantillonnage ou bien si la pièce est truquée.

## ETAPES D'UN TEST STATISTIQUE

On dispose de  $n$  données  $x_1, \dots, x_n$  qui sont des réalisations de variables qualitatives ou quantitatives et on fixe un risque  $\alpha \in (0, 1)$ .

► Introduire un modèle probabiliste

On peut supposer que les  $x_i$  sont des réalisations de variables aléatoires indépendantes  $X_1, \dots, X_n$  (ce qui est le cas pour le lancer de pièce)

► Les hypothèses nulles et alternatives : disposant d'un modèle probabiliste, on souhaite vérifier une hypothèse sur ce modèle, appelée hypothèse nulle  $H_0$  et on introduit sa négation  $H_1$ .

Dans le cas du lancer de pièce, on pose les hypothèses

$$H_0 : \theta = 0.5 \quad \text{contre} \quad H_1 : \theta \neq 0.5$$

# ETAPES D'UN TEST STATISTIQUE

► La statistique de test et sa loi sous  $H_0$  :

Une fois le modèle probabiliste introduit, il faut disposer d'une variable aléatoire appelée statistique de test, notée  $Z$

On connaît sa loi sous  $H_0$

Sa loi n'est pas la même sous  $H_1$

$Z$  est définie en fonction des variables aléatoires

$X_1, \dots, X_n$ , i.e  $Z = T(X_1, \dots, X_n)$  et on note sa réalisation

$z_{obs} = T(x_1, \dots, x_n)$  qui doit être calculable.

# ETAPES D'UN TEST STATISTIQUE

► Zone de rejet :

Connaissant la loi de  $Z$  sous  $H_0$ , on peut déterminer ses valeurs les plus extrêmes, i.e déterminer une zone  $ZR$  telle que  $\mathbb{P}[Z \in ZR] \leq \alpha$  si  $H_0$  est vraie.

► On conclut le test à partir de la valeurs observée  $z_{obs}$

Si  $z_{obs}$  appartient à la zone de rejet, on rejette  $H_0$  au risque  $\alpha$ .

Si  $z_{obs}$  n'appartient pas à la zone de rejet, on ne rejette pas  $H_0$  au risque  $\alpha$ .

## EXEMPLE

**Le lancer de pièce :** On teste au risque de 5%

$$H_0 : \theta = 0.5 \quad \text{contre} \quad H_1 : \theta \neq 0.5$$

On a la statistique de test

$$Z = \sum_{i=1}^{10} X_i \sim \mathcal{B}(10, 0.5) \quad \text{sous } H_0$$

On a la zone de rejet

$$Z_{R_{H_0}} = \{0, 1\} \cup \{9, 10\}.$$

Ici,  $z_{obs} = 9$  et on rejette donc  $H_0$ .

## P-VALUE

Plus le seuil  $\alpha$  est petit plus le test est fiable.

$$p - \text{value} = \inf \{ \alpha \in (0, 1), \text{"On rejette } H_0 \text{"} \}$$

La  $p$ -value est la probabilité d'avoir eu un aussi mauvais résultat que  $z_{obs}$  sous  $H_0$ .

- ▶ Si  $p - \text{value} \geq \alpha$ , on ne rejette pas  $H_0$ .
- ▶ Si  $p - \text{value} < \alpha$ , on rejette  $H_0$ .

## II. Tests sur la moyenne et la variance

# TESTS SUR LA MOYENNE ET LA VARIANCE

**Contexte :** On considère  $x_1, \dots, x_n$  des réalisations de variables aléatoires indépendantes et identiquement distribuées  $X_1, \dots, X_n$  avec  $X_1 \sim \mathcal{N}(\mu, \sigma^2)$  avec  $\mu$  et  $\sigma^2$  inconnus.

**Test de conformité de la moyenne :** Soit  $\mu_0$  une valeurs donnée, on souhaite tester

$$H_0 : \text{''}\mu = \mu_0\text{''} \quad \text{contre} \quad H_1 : \text{''}\mu \neq \mu_0\text{''}.$$

**Test de conformité de la variance :** Soit  $\sigma_0^2$  une valeurs donnée, on souhaite tester

$$H_0 : \text{''}\sigma^2 = \sigma_0^2\text{''} \quad \text{contre} \quad H_1 : \text{''}\sigma^2 \neq \sigma_0^2\text{''}.$$

# TEST DE CONFORMITÉ D'UNE MOYENNE

**Construction de la statistique de test :** On a la statistique de test :

$$Z = \sqrt{n} \frac{\bar{X}_n - \mu_0}{S_n}$$

Sous  $H_0$ ,

$$\sqrt{n} \frac{\bar{X}_n - \mu_0}{S_n} \sim T_{n-1}$$

où  $T_{n-1}$  suit une loi de Student à  $n - 1$  degrés de liberté, ce qui est faux sous  $H_1$ .

# TEST DE CONFORMITÉ D'UNE MOYENNE

**Le test :** On teste au risque  $\alpha \in (0, 1)$

$$H_0 : \text{''}\mu = \mu_0\text{''} \quad \text{contre} \quad H_1 : \text{''}\mu \neq \mu_0\text{''}.$$

On a la statistique de test

$$Z = \sqrt{n} \frac{\bar{X}_n - \mu_0}{S_n} \sim T_{n-1} \quad \text{sous } H_0$$

On définit la zone de rejet par

$$ZR = \{|Z| > t_{n-1, 1-\alpha/2}\}$$

où  $t_{n-1, 1-\alpha/2}$  est le quantile d'ordre  $1 - \alpha/2$  de la loi de Student à  $n - 1$  degrés de liberté.

On calcule  $z_{obs}$ , si  $|z_{obs}| > t_{n-1, 1-\alpha/2}$ , on rejette  $H_0$ , et on ne rejette pas  $H_0$  sinon.

## REMARQUE

**Remarque 1 :** Faire ce test revient à vérifier que  $\mu_0$  est dans l'intervalle de confiance de niveau  $1 - \alpha$

$$IC_{1-\alpha}(\mu) = \left[ \bar{x}_n - t_{n-1, 1-\alpha/2} \frac{S_n}{\sqrt{n}}; \bar{x}_n + t_{n-1, 1-\alpha/2} \frac{S_n}{\sqrt{n}} \right].$$

Si  $\mu_0 \in IC_{1-\alpha}(\mu)$ , on ne rejette pas  $H_0$  et inversement.

## REMARQUE

**Remarque 2 :** Pour trouver la zone de rejet, cela revient à chercher  $c_\alpha$  tel

$$\mathbb{P}_{\mu=\mu_0} [\text{''On rejette } H_0\text{''}] = \mathbb{P}_{\mu=\mu_0} [|\bar{X}_n - \mu_0| \geq c_\alpha] = \alpha.$$

## REMARQUE

**Remarque 3 :** Soit  $T$  une variable aléatoire suivant une loi de Student à  $n - 1$  degrés de liberté. On a alors

$$p - \text{value} = \mathbb{P} [|T| \geq |z_{obs}|] .$$

## TEST D'INÉGALITÉ $\mu \leq \mu_0$

On teste au risque  $\alpha \in (0, 1)$

$$H_0 : \mu \leq \mu_0 \quad \text{contre} \quad H_1 : \mu > \mu_0$$

Sous  $H_0$ , il existe  $\mu' \leq \mu_0$  tel que

$$Z(\mu') = \sqrt{n} \frac{\bar{X}_n - \mu'}{S_n} \sim T_{n-1}.$$

On définit la zone de rejet par

$$ZR = \{Z(\mu_0) > t_{n-1, 1-\alpha}\}.$$

On calcule  $z_{obs}$ , si  $z_{obs} > t_{n-1, 1-\alpha}$ , on rejette  $H_0$  et inversement.

## REMARQUE

**Remarque 1 :** Pour trouver la zone de rejet, cela revient à chercher  $c_\alpha$  tel que

$$\sup_{\mu \leq \mu_0} \mathbb{P}_\mu [\text{"On rejette } H_0\text{"}] = \sup_{\mu \leq \mu_0} \mathbb{P}_\mu [\bar{X}_n \geq c_\alpha] = \alpha.$$

## REMARQUE

**Remarque 2 :** Soit  $T$  une variable aléatoire suivant une loi de Student à  $n - 1$  degrés de liberté. On a alors

$$p - \text{value} = \mathbb{P} [T \geq z_{obs}] .$$

## TEST D'INÉGALITÉ $\mu \geq \mu_0$

**Le test :** On teste au risque  $\alpha \in (0, 1)$

$$H_0 : \text{''}\mu \geq \mu_0\text{''} \quad \text{contre} \quad H_1 : \text{''}\mu < \mu_0\text{''}$$

Sous  $H_0$ , il existe  $\mu' \geq \mu_0$  tel que

$$Z(\mu') = \sqrt{n} \frac{\bar{X}_n - \mu'}{S_n} \sim T_{n-1}.$$

On définit la zone de rejet par

$$ZR = \{Z(\mu_0) < -t_{n-1, 1-\alpha}\}.$$

On calcule  $z_{obs}$ , si  $z_{obs} < -t_{n-1, 1-\alpha}$ , on rejette  $H_0$  et inversement.

## REMARQUE

**Remarque 1 :** Pour trouver la zone de rejet, cela revient à chercher  $c_\alpha$  tel que

$$\sup_{\mu \geq \mu_0} \mathbb{P}_\mu [\text{''On rejette } H_0\text{''}] = \sup_{\mu \geq \mu_0} \mathbb{P}_\mu [\bar{X}_n \leq c_\alpha] = \alpha.$$

## REMARQUE

**Remarque 2 :** Soit  $T$  une variable aléatoire suivant une loi de Student à  $n - 1$  degrés de liberté. On a alors

$$p - \text{value} = \mathbb{P} [T \leq z_{obs}] .$$

## APPLICATION

A la suite d'un traitement (régime alimentaire) sur une variété de porcs, on prélève un échantillon de 5 individus et on les pèse. On obtient les poids suivants (en kg) :

83 81 84 80 85

On suppose que les  $x_i$  sont des réalisations de variables aléatoires i.i.d suivant une loi normale. On sait que le poids moyen de cette variété de porcs est de 87.6 kg. Le régime alimentaire a-t-il eu un impact sur le poids moyen ?

## APPLICATION

On teste au risque de 5%

$$H_0 : \mu = 87.6 \quad \text{contre} \quad H_1 : \mu \neq 87.6.$$

On a la statistique de test

$$Z = \sqrt{5} \frac{\bar{X}_5 - 87.6}{S_n} \sim T_4 \quad \text{sous } H_0.$$

On a donc la zone de rejet

$$ZR = \{|Z| \geq t_{4,0.975}\}.$$

Ici,  $t_{4,0.975} = 2.78$ . De plus,

$$z_{obs} = \sqrt{5} \frac{\bar{x}_5 - 87.6}{s_5} = \sqrt{5} \frac{82.6 - 87.6}{s_5} = -5.28.$$

On a  $|z_{obs}| > 2.78$ , et on rejette donc  $H_0$ .

## APPLICATION

Un biologiste affirme que le régime augmente le poids des porcs! On teste au risque de 5%

$$H_0 : \mu \geq 87.6 \quad \text{contre} \quad H_1 : \mu < 87.6.$$

On a la zone de rejet

$$ZR = \left\{ \sqrt{5} \frac{\bar{X}_5 - 87.6}{S_5} < -t_{4,0.95} \right\}$$

Ici,  $t_{4,0.95} = 2.13$  et  $z_{obs} = -5.28$ . On rejette donc  $H_0$ .

## TEST DE CONFORMITÉ D'UNE VARIANCE

Soit  $\sigma_0^2$  connue, on souhaite tester au risque  $\alpha \in (0, 1)$

$$H_0 : \sigma^2 = \sigma_0^2 \quad \text{contre} \quad H_1 : \sigma^2 \neq \sigma_0^2.$$

**Construction de la statistique de test :** Comme

$$\frac{(n-1)S_n^2}{\sigma^2} \sim \chi_{n-1}^2,$$

on a la statistique de test

$$\frac{(n-1)S_n^2}{\sigma_0^2} \sim \chi_{n-1}^2 \quad \text{sous } H_0,$$

ce qui est faux sous  $H_1$ .

## TEST DE CONFORMITÉ D'UNE VARIANCE

**Le test :** On teste au risque  $\alpha \in (0, 1)$

$$H_0 : \sigma^2 = \sigma_0^2 \quad \text{contre} \quad H_1 : \sigma^2 \neq \sigma_0^2.$$

On a la statistique de test

$$Z = \frac{(n-1)S_n^2}{\sigma_0^2} \sim \chi_{n-1}^2 \quad \text{sous } H_0,$$

On définit la zone de rejet comme

$$ZR = \{Z < k_{\alpha/2}\} \cup \{Z > k_{1-\alpha/2}\},$$

où  $k_{\alpha/2}$  et  $k_{1-\alpha/2}$  sont les quantiles de la loi du Khi-deux à  $n-1$  degrés de liberté.

On calcule  $z_{obs}$ . Si  $z_{obs} < k_{\alpha/2}$  ou  $z_{obs} > k_{1-\alpha/2}$ , on rejette  $H_0$  et inversement.

## REMARQUES

**Remarque 1 :** Notons que faire ce test revient à vérifier que  $\sigma_0^2$  appartient à l'intervalle de confiance obtenu à partir des données observées.

Si  $\sigma_0^2$  appartient à l'intervalle de confiance, on ne rejette pas  $H_0$  et inversement.

## REMARQUES

**Remarque 2 :** Soit  $Z$  une variable aléatoire suivant une loi du Khi-deux à  $n - 1$  degrés de liberté. On a alors

$$p - \text{value} = \min \{2\mathbb{P} [Z \leq z_{obs}], 2\mathbb{P} [Z \geq z_{obs}]\} .$$

## APPLICATION

On reprend l'exemple des porcs. Le même biologiste pense que si les résultats ne sont pas concluants, c'est dû à une variance qui serait égale à 25.

On va donc "vérifier" si cela est vrai.

## APPLICATION

On teste au risque de 5%

$$H_0 : \sigma^2 = 25 \quad \text{contre} \quad H_1 : \sigma^2 \neq 25.$$

On a la statistique de test

$$Z = \frac{4}{25} S_n^2 \sim \chi_4^2 \quad \text{sous } H_0.$$

On a la zone de rejet

$$ZR = \{Z < k_{0.025}\} \cup \{Z > k_{0.975}\}.$$

Ici,  $k_{0.025} = 0.48$  et  $k_{0.975} = 11.14$ . De plus

$$z_{obs} = \frac{4}{25} s_n^2 = 0.29$$

Comme  $z_{obs} < 0.48$ , on rejette  $H_0$ .

## III. Comparaison de moyennes

## TESTS DE COMPARAISON DE DEUX MOYENNES

**Présentation du problème** On considère deux jeux de données

- ▶  $x_1, \dots, x_p$  qui sont  $p$  réalisations d'une variable aléatoire  $X$ .
- ▶  $y_1, \dots, y_q$  qui sont  $q$  réalisations d'une variable aléatoire  $Y$ .

On souhaite comparer les moyennes théoriques des variables  $X$  et  $Y$ .

- ▶ On dispose des estimations  $\bar{x}_p$  et  $\bar{y}_q$ .
- ▶ Les différences entre ces estimations ne sont-elles dues qu'à la fluctuation d'échantillonnage ?

## TESTS DE COMPARAISON DE DEUX MOYENNES

**Le modèle probabiliste :** On fait les hypothèses suivantes :

- ▶ Les données  $x_1, \dots, x_p$  sont les réalisations de variables aléatoires  $X_1, \dots, X_p$  indépendantes et de même loi  $\mathcal{N}(\mu_1, \sigma_1^2)$ .
- ▶ Les données  $y_1, \dots, y_q$  sont les réalisations de variables aléatoires  $Y_1, \dots, Y_q$  indépendantes et de même loi  $\mathcal{N}(\mu_2, \sigma_2^2)$ .
- ▶ Les deux échantillons sont indépendants et de même variance, i.e  $\sigma_1^2 = \sigma_2^2 = \sigma^2$ .

## APPLICATION

On souhaite comparer les productions laitières de deux races bovines. On choisit 50 bêtes de chaque race ( $p = q = 50$ ) et on mesure pour chaque bête la production annuelle totale de lait (en tonnes). On obtient les productions moyennes

$$\bar{x}_{50} = 4.680 \quad \text{et} \quad \bar{y}_{50} = 4.690$$

On souhaite donc savoir si cette différence est seulement due à la fluctuation d'échantillonnage.

# TEST BILATÉRAL

On veut tester au risque  $\alpha$

$$H_0 : " \mu_1 = \mu_2 " \quad \text{contre} \quad H_1 : " \mu_1 \neq \mu_2 " .$$

**Construction de la statistique de test :**

Proposition

On a

$$\bar{X}_p - \bar{Y}_q \sim \mathcal{N} \left( \mu_1 - \mu_2, \frac{\sigma^2}{p} + \frac{\sigma^2}{q} \right) .$$

Cependant, on ne connaît pas  $\sigma^2$  et on ne peut donc pas construire de statistique de test à partir de cette proposition.

## TEST D'ÉGALITÉ

On considère  $S^2$  l'estimateur de  $\sigma^2$  défini par

$$\begin{aligned} S^2 &= \frac{1}{p+q-2} \left( \sum_{i=1}^p (X_i - \bar{X}_p)^2 + \sum_{i=1}^q (Y_i - \bar{Y}_q)^2 \right) \\ &= \frac{1}{p+q-2} ((p-1)S_X^2 + (q-1)S_Y^2), \end{aligned}$$

avec  $S_X^2 = \frac{1}{p-1} \sum_{i=1}^p (X_i - \bar{X}_p)^2$  et  $S_Y^2 = \frac{1}{q-1} \sum_{i=1}^q (Y_i - \bar{Y}_q)^2$ .

### Proposition

1. On a

$$\frac{p+q-2}{\sigma^2} S^2 \sim \chi_{p+q-2}^2.$$

2. Les variables  $\bar{X}_p - \bar{Y}_q$  et  $S^2$  sont indépendantes.

# CONSTRUCTION DE LA STATISTIQUE DE TEST

## Corollaire

On a

$$\frac{\sqrt{pq}}{\sqrt{p+q}} \frac{(\bar{X}_p - \bar{Y}_q) - (\mu_1 - \mu_2)}{S} \sim T_{p+q-2},$$

où  $T_{p+q-2}$  suit une loi de Student à  $p + q - 2$  degrés de liberté.

On obtient donc la statistique de test

$$\frac{\sqrt{pq}}{\sqrt{p+q}} \frac{\bar{X}_p - \bar{Y}_q}{S} \sim T_{p+q-2} \quad \text{sous } H_0,$$

ce qui est faux sous  $H_1$ .

## TEST D'ÉGALITÉ DE DEUX MOYENNES

**Le test :** On teste au risque  $\alpha \in (0, 1)$

$$H_0 : \mu_1 = \mu_2 \quad \text{contre} \quad H_1 : \mu_1 \neq \mu_2.$$

On a la statistique de test

$$Z = \frac{\sqrt{pq}}{\sqrt{p+q}} \frac{\bar{X}_p - \bar{Y}_q}{S} \sim T_{p+q-2} \quad \text{sous } H_0.$$

On définit la zone de rejet

$$ZR = \{Z, |Z| > t_{p+q-2, 1-\alpha/2}\},$$

où  $t_{p+q-2, 1-\alpha/2}$  est le quantile d'ordre  $1 - \alpha/2$  de la loi de Student à  $p + q - 2$  degrés de liberté. On calcule  $z_{obs}$ . Si

$|z_{obs}| > t_{p+q-2, 1-\alpha/2}$  on rejette  $H_0$  et inversement.

## REMARQUES

**Remarque 1 :** Cela revient à vérifier que 0 appartient à l'intervalle de confiance de  $\mu = \mu_1 - \mu_2$ .  
Si 0 appartient à cet intervalle de confiance, on ne rejette pas  $H_0$  et inversement.

## REMARQUES

**Remarque 2 :** Pour trouver la zone de rejet, comme sous  $H_0$   $\bar{X}_q - \bar{Y}_q$  doit être proche de 0, cela revient à chercher  $c_\alpha$  tel que

$$\mathbb{P}_{\mu=0} [\text{"On rejette } H_0\text{"}] = \mathbb{P}_{\mu=0} (|\bar{X}_p - \bar{Y}_q| \geq c_\alpha) = \alpha.$$

**Remarque 3 :** Soit  $T$  une variable aléatoire suivant une loi de Student à  $p + q - 2$  degrés de liberté, on a alors

$$p - \text{value} = \mathbb{P} [|T| > |z_{obs}|] .$$

## APPLICATION : LES IRIS DE FISHER

On considère un jeu de données classique : les Iris de Fisher, où on souhaite reconnaître le type d'Iris à partir de la longueur des sépales.

On note  $x_1, \dots, x_{50}$  les longueurs des Iris de la variété Virginica et  $y_1, \dots, y_{50}$  celle de la variété Versicolor et on obtient les résultats

$$\begin{aligned}\bar{x}_{50} &= 5.94 & s_X &= 0.52 \\ \bar{y}_{50} &= 6.59 & s_Y &= 0.64.\end{aligned}$$

## APPLICATION : LES IRIS DE FISHER

On test au risque de 5%

$$H_0 : " \mu_1 = \mu_2 " \quad \text{contre} \quad H_1 : " \mu_1 \neq \mu_2 " .$$

On a la statistique de test

$$Z = \frac{\sqrt{50 \times 50} \bar{X}_{50} - \bar{Y}_{50}}{\sqrt{50 + 50} S} \sim T_{98} \quad \text{sous } H_0 .$$

On a la zone de rejet

$$ZR = \{ |Z| > t_{98,0.975} \} .$$

Ici  $t_{98,0.975} = 1.98$  et  $z_{obs} = -5.63$ . On rejette donc  $H_0$ .

## TEST D'INÉGALITÉ $\mu_1 \leq \mu_2$

**Le test :** On veut tester au risque  $\alpha \in (0, 1)$

$$H_0 : \text{''}\mu_1 \leq \mu_2\text{''} \quad \text{contre} \quad H_1 : \text{''}\mu_1 > \mu_2\text{''}.$$

Sous  $H_0$ , il existe  $\mu' \leq 0$  tel que

$$Z(\mu') = \frac{\sqrt{pq}}{\sqrt{p+q}} \frac{\bar{X}_p - \bar{Y}_q - \mu'}{S} \sim T_{p+q-2}.$$

On définit la zone de rejet par

$$ZR = \{Z(0) > t_{p+q-2, 1-\alpha}\}$$

où  $t_{p+q-2, 1-\alpha}$  est le quantile d'ordre  $1 - \alpha$  de la loi de Student à  $p + q - 2$  degrés de liberté.

On calcule  $Z_{obs}$ . Si  $Z_{obs} > t_{p+q-2, 1-\alpha}$ , on rejette  $H_0$  et inversement.

## REMARQUES

**Remarque 1 :** Pour trouver la zone de rejet, comme  $\mu = \mu_1 - \mu_2$  peut être aussi petit que l'on veut sous  $H_0$ , trouver la zone de rejet revient donc à chercher  $c_\alpha$  tel que sous  $H_0$ ,

$$\sup_{\mu \leq 0} \mathbb{P}_\mu [\text{"On rejette } H_0\text{"}] = \sup_{\mu \leq 0} \mathbb{P}_\mu [\bar{X}_q - \bar{Y}_q \geq c_\alpha] = \alpha.$$

## REMARQUES

**Remarque 2 :** Soit  $T$  une variable aléatoire suivant une loi de Student à  $p + q - 2$  degrés de liberté, on a alors

$$p - \text{value} = \mathbb{P}[T > z_{obs}].$$

## TEST D'INÉGALITÉ $\mu_1 \geq \mu_2$

**Le test :** On veut tester au risque  $\alpha \in (0, 1)$

$$H_0 : \text{''}\mu_1 \geq \mu_2\text{''} \quad \text{contre} \quad H_1 : \text{''}\mu_1 < \mu_2\text{''}.$$

Sous  $H_0$ , il existe  $\mu' \geq 0$  tel que

$$Z(\mu') = \frac{\sqrt{pq}}{\sqrt{p+q}} \frac{\bar{X}_p - \bar{Y}_q - \mu'}{S} \sim T_{p+q-2}.$$

On définit la zone de rejet par

$$ZR = \{Z(0) < -t_{p+q-2, 1-\alpha}\}$$

où  $t_{p+q-2, 1-\alpha}$  est le quantile d'ordre  $1 - \alpha$  de la loi de Student à  $p + q - 2$  degrés de liberté.

On calcule  $Z_{obs}$ . Si  $Z_{obs} < -t_{p+q-2, 1-\alpha}$ , on rejette  $H_0$  et inversement.

## REMARQUES

**Remarque 1 :** Pour trouver la zone de rejet, comme  $\mu = \mu_1 - \mu_2$  peut être aussi grand que l'on veut sous  $H_0$ , trouver la zone de rejet revient donc à chercher  $c_\alpha$  tel que sous  $H_0$ ,

$$\sup_{\mu \geq 0} \mathbb{P}_\mu [\text{"On rejette } H_0\text{"}] = \sup_{\mu \geq 0} \mathbb{P}_\mu [\bar{X}_q - \bar{Y}_q \leq c_\alpha] = \alpha.$$

## REMARQUES

**Remarque 2 :** Soit  $T$  une variable aléatoire suivant une loi de Student à  $p + q - 2$  degrés de liberté, on a alors

$$p - \text{value} = \mathbb{P}[T < z_{obs}].$$

## IV. Tests de Fisher

## TEST DE FISHER

On rappelle que pour les tests de comparaison de moyennes, on a du faire les hypothèses suivantes :

- ▶ Les données  $x_1, \dots, x_p$  sont les réalisations de variables aléatoires  $X_1, \dots, X_p$  indépendantes et de même loi  $\mathcal{N}(\mu_1, \sigma_1^2)$ .
- ▶ Les données  $y_1, \dots, y_q$  sont les réalisations de variables aléatoires  $Y_1, \dots, Y_q$  indépendantes et de même loi  $\mathcal{N}(\mu_2, \sigma_2^2)$ .
- ▶ Les deux échantillons sont indépendants et de même variance, i.e  $\sigma_1^2 = \sigma_2^2 = \sigma^2$ .

L'indépendance est souvent donnée par le protocole expérimentale. On veut donc

- ▶ Tester si les variables  $X, Y$  suivent des loi normales.
- ▶ Tester si elles ont la même variance.

# TEST DE FISHER

On veut tester au risque  $\alpha \in (0, 1)$

$$H_0 : \text{''}\sigma_1^2 = \sigma_2^2\text{''} \quad \text{contre} \quad H_1 : \text{''}\sigma_1^2 \neq \sigma_2^2\text{''}.$$

## Le cadre probabiliste :

- ▶ Les données  $x_1, \dots, x_p$  sont les réalisations de variables aléatoires  $X_1, \dots, X_p$  indépendantes et de même loi  $\mathcal{N}(\mu_1, \sigma_1^2)$ .
- ▶ Les données  $y_1, \dots, y_q$  sont les réalisations de variables aléatoires  $Y_1, \dots, Y_q$  indépendantes et de même loi  $\mathcal{N}(\mu_2, \sigma_2^2)$ .
- ▶ Les deux échantillons sont indépendants.

# CONSTRUCTION DE LA STATISTIQUE DE TEST

On dispose des estimateurs  $S_X^2, S_Y^2$  de  $\sigma_1^2, \sigma_2^2$  définis par

$$S_X^2 = \frac{1}{p-1} \sum_{i=1}^p (X_i - \bar{X}_p)^2 \quad S_Y^2 = \frac{1}{q-1} \sum_{i=1}^q (Y_i - \bar{Y}_q)^2.$$

La construction du test de Fisher repose sur la définition suivante :

## Définition

Soient  $p, q$  deux entiers positifs et soient  $Z_p \sim \chi_p^2$  et  $Z_q \sim \chi_q^2$  deux variables aléatoires indépendantes. Alors

$$\frac{Z_p/p}{Z_q/q} \sim F(p, q)$$

où  $F(p, q)$  suit une loi de Fisher à  $p, q$  degrés de liberté.

# CONSTRUCTION DE LA STATISTIQUE DE TEST

## Corollaire

On a

$$\frac{\sigma_2^2 S_X^2}{\sigma_1^2 S_Y^2} \sim F(p-1, q-1).$$

On obtient donc la statistique de test

$$\frac{S_X^2}{S_Y^2} \sim F(p-1, q-1) \quad \text{sous } H_0,$$

ce qui est faux sous  $H_1$ .

## TEST DE FISHER

**Le test :** On teste au risque  $\alpha$

$$H_0 : \sigma_1^2 = \sigma_2^2 \quad \text{contre} \quad H_1 : \sigma_1^2 \neq \sigma_2^2.$$

On a la statistique de test

$$Z = \frac{S_X^2}{S_Y^2} \sim F(p-1, q-1) \quad \text{sous } H_0$$

On a la zone de rejet

$$ZR = \{Z < f_{p-1, q-1, \alpha/2}\} \cup \{Z > f_{p-1, q-1, 1-\alpha/2}\},$$

où  $f_{p-1, q-1, \alpha/2}$  et  $f_{p-1, q-1, 1-\alpha/2}$  sont les quantiles d'ordre  $\alpha/2$  et  $1 - \alpha/2$  de la loi de Fisher à  $p - 1, q - 1$  degrés de liberté.

On calcule  $z_{obs}$ . Si  $z_{obs}$  appartient à la zone de rejet, on rejette  $H_0$  et inversement.

## REMARQUES

**Remarque 1 :** Soit  $f_{p,q,\alpha}$  le quantile d'ordre  $\alpha$  de la loi de Fisher de paramètres  $p, q$ . Alors

$$f_{p,q,1-\alpha} = \frac{1}{f_{p,q,\alpha}},$$

où  $f_{p,q,1-\alpha}$  est le quantile d'ordre  $1 - \alpha$  de la loi de Fisher de paramètres  $p, q$ .

**Remarque 2 :** Soit  $F$  une variable aléatoire suivant une loi de Fisher de paramètres  $p, q$ ,

$$p - \text{value} = \min \{ \mathbb{P} [F \leq z_{obs}], \mathbb{P} [F \geq z_{obs}] \}.$$

## REMARQUES

**Remarque 3 :** On peut intervertir  $S_X^2$  et  $S_Y^2$ , et on obtient alors la statistique de test

$$Z = \frac{S_Y^2}{S_X^2} \sim F(q-1, p-1) \quad \text{sous } H_0.$$

**Remarque 4 :** On voit souvent la statistique de test

$$Z = \frac{\max(S_X^2, S_Y^2)}{\min(S_X^2, S_Y^2)}$$

## APPLICATION

On reprend l'exemple des Iris de Fisher. On a  $s_X^2 = 0.52^2$  et  $s_Y^2 = 0.64^2$ . On teste au risque de 5%

$$H_0 : \sigma_1^2 = \sigma_2^2 \quad \text{contre} \quad H_1 : \sigma_1^2 \neq \sigma_2^2.$$

On a la statistique de test

$$Z = \frac{S_X^2}{S_Y^2} \sim F(49, 49) \quad \text{sous } H_0$$

et la zone de rejet

$$Z_R = \{Z < 0.57\} \cup \{Z > 1.76\}$$

et  $z_{obs} = 0.66$  et on ne rejette donc pas  $H_0$ .

# TEST DE SHAPIRO-WILK

Soient  $x_1, \dots, x_n$  des réalisations de variables aléatoires indépendantes et de même loi  $X_1, \dots, X_n$ . Le test de Shapiro-Wilk permet de tester :

$H_0$  : "la variable  $X$  est Gaussienne"

contre

$H_1$  : "la variable  $X$  n'est pas Gaussienne"

- ▶ si la  $p$ -value est supérieure au risque  $\alpha$ , alors on ne rejette pas  $H_0$
- ▶ sinon, on rejette  $H_0$ .

## APPLICATION : LES IRIS DE FISHER

On reprend l'exemple des Iris, on obtient pour le test de Shapiro-Wilk :

- ▶  $p$  – value = 0.46 pour les Virginica
- ▶  $p$  – value = 0.26 pour les Versicolor

Dans les deux cas, on ne peut pas rejeter le caractère gaussien des données observées.

## V. Cas apparié

# TEST DE STUDENT DANS LE CAS APPARIÉ

On considère ici des réalisations  $((x_1, y_1), \dots, (x_n, y_n))$  d'un couple de variable aléatoire  $(X, Y)$  et on souhaite comparer les moyennes des variables aléatoires  $X, Y$ .

## Le carde probabiliste :

- ▶ Les données  $(x_1, y_1), \dots, (x_n, y_n)$  sont les réalisations de couples variables aléatoires  $(X_1, Y_1), \dots, (X_n, Y_n)$  indépendantes et de même loi que  $(X, Y)$ .
- ▶ Les variables  $X$  et  $Y$  ne sont pas indépendantes.
- ▶ La variable aléatoire  $X - Y$  suit une loi normale d'espérance  $\mu = \mu_1 - \mu_2$  et de variance  $\sigma^2$ .

# CONSTRUCTION DE LA STATISTIQUE DE TEST

On dispose des estimateurs  $\bar{X}_n$  et  $\bar{Y}_n$ .

## Proposition

On a

$$\bar{X}_n - \bar{Y}_n \sim \mathcal{N}\left(\mu_1 - \mu_2, \frac{\sigma^2}{n}\right).$$

En particulier, on a

$$\sqrt{n} \frac{\bar{X}_n - \bar{Y}_n - (\mu_1 - \mu_2)}{\sigma} \sim \mathcal{N}(0, 1).$$

Comme  $\sigma$  est inconnu, ce résultat est inexploitable.

# CONSTRUCTION DE LA STATISTIQUE DE TEST

On considère l'estimateur  $S^2$  de  $\sigma^2$  défini par

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - Y_i - (\bar{X}_n - \bar{Z}_n))^2$$

## Proposition

1. On a

$$\frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$$

2. Les variables  $\bar{X}_n - \bar{Y}_n$  et  $S^2$  sont indépendantes.

# CONSTRUCTION DE LA STATISTIQUE DE TEST

## Corollaire

On a

$$\sqrt{n} \frac{\bar{X}_n - \bar{Y}_n - (\mu_1 - \mu_2)}{S} \sim T_{n-1},$$

où  $T_{n-1}$  suit une loi de Student à  $n - 1$  degrés de liberté.

On obtient donc, pour le test d'égalité, la statistique de test

$$\sqrt{n} \frac{\bar{X}_n - \bar{Y}_n}{S} \sim T_{n-1} \quad \text{sous } H_0$$

ce qui est faux sous  $H_1$ .

## TEST D'ÉGALITÉ $\mu_1 = \mu_2$

**Le test :** On teste au risque  $\alpha \in (0, 1)$

$$H_0 : " \mu_1 = \mu_2 " \quad \text{contre} \quad H_1 : " \mu_1 \neq \mu_2 " .$$

On a la statistique de test

$$\sqrt{n} \frac{\bar{X}_n - \bar{Y}_n}{S} \sim T_{n-1} \quad \text{sous } H_0 .$$

On a la zone de rejet

$$ZR = \{ Z, |Z| > t_{n-1, 1-\alpha/2} \}$$

où  $t_{n-1, 1-\alpha/2}$  est le quantile d'ordre  $1 - \alpha/2$  de la loi de Student à  $n - 1$  degrés de liberté.

Si  $|z_{obs}| > t_{n-1, 1-\alpha/2}$ , on rejette  $H_0$  et inversement.

## REMARQUES

**Remarque 1 :** Faire ce test revient à vérifier que 0 appartient à l'intervalle de confiance de niveau  $1 - \alpha$  de  $\mu = \mu_1 - \mu_2$ .  
Si 0 appartient à cet intervalle, on ne rejette pas  $H_0$  et inversement.

## REMARQUES

**Remarque 2 :** Pour trouver la zone de rejet, comme  $\bar{X}_n - \bar{Y}_n$  doit être proche de 0, on cherche  $c_\alpha$  tel que sous  $H_0$ ,

$$\mathbb{P}_{\mu=0} [\text{"On rejette } H_0\text{"}] = \mathbb{P}_{\mu=0} [|\bar{X}_n - \bar{Y}_n| \geq c_\alpha] = \alpha.$$

## REMARQUES

**Remarque 3 :** Soit  $T$  une variable aléatoire suivant une loi de Student à  $n - 1$  degrés de liberté, on a alors

$$p\text{-value} = \mathbb{P} [|T| > |z_{obs}|] .$$

## APPLICATION

On s'intéresse à un échantillon de 30 matières fécales, que l'on soumet à deux méthodes de spectrométrie pour étudier leur teneur en lutécium radioactif. On obtient

$$\bar{x}_{30} = 120.83 \quad \text{et} \quad \bar{y}_{30} = 119.33$$

- ▶ En faisant le test pour les données appariées, on obtient une  $p$ -value égale à 0.66, et au risque de 5%, on ne rejette pas  $H_0$ .
- ▶ En faisant le test de Student vu précédemment, on obtient une  $p$ -value égale à 0.0031 et on aurait alors rejeté  $H_0$ .

## TEST D'INÉGALITÉ $\mu_1 \leq \mu_2$

**Le test :** On teste au risque  $\alpha \in (0, 1)$

$$H_0 : \text{''}\mu_1 \leq \mu_2\text{''} \quad \text{contre} \quad H_1 : \mu_1 > \mu_2\text{''}.$$

Sous  $H_0$ , il existe  $\mu' \leq 0$  tel que

$$Z(\mu') = \sqrt{n} \frac{\bar{X}_n - \bar{Y}_n - \mu'}{S} \sim T_{n-1}.$$

On définit la zone de rejet par

$$ZR = \{Z(0) > t_{n-1, 1-\alpha}\},$$

où  $t_{n-1, 1-\alpha}$  est le quantile d'ordre  $1 - \alpha$  de la loi de Student à  $n - 1$  degrés de liberté.

On calcule  $z_{obs}$ . Si  $z_{obs} > t_{n-1, 1-\alpha}$  on rejette  $H_0$  et inversement.

## REMARQUES

**Remarque 1 :** Pour trouver la zone de rejet, comme  $\mu = \mu_1 - \mu_2$  peut être aussi petit que l'on veut sous  $H_0$ , on cherche  $c_\alpha$  tel que

$$\sup_{\mu \leq 0} \mathbb{P}_\mu [\text{"On rejette } H_0\text{"}] = \sup_{\mu \leq 0} \mathbb{P}_\mu [\bar{X}_n - \bar{Y}_n \geq c_\alpha] = \alpha.$$

## REMARQUES

**Remarque 2 :** Soit  $T$  une variable aléatoire suivant une loi de Student à  $n - 1$  degrés de liberté, on a

$$p - \text{value} = \mathbb{P}[T \geq z_{obs}] .$$

## TEST D'INÉGALITÉ $\mu_1 \geq \mu_2$

**Le test :** On teste au risque  $\alpha \in (0, 1)$

$$H_0 : \text{''}\mu_1 \geq \mu_2\text{''} \quad \text{contre} \quad H_1 : \mu_1 < \mu_2\text{''}.$$

Sous  $H_0$ , il existe  $\mu' \geq 0$  tel que

$$Z(\mu') = \sqrt{n} \frac{\bar{X}_n - \bar{Y}_n - \mu'}{S} \sim T_{n-1}.$$

On définit la zone de rejet par

$$ZR = \{Z(0) < -t_{n-1, 1-\alpha}\},$$

où  $t_{n-1, 1-\alpha}$  est le quantile d'ordre  $\alpha$  de la loi de Student à  $n - 1$  degrés de liberté.

On calcule  $z_{obs}$ . Si  $z_{obs} < -t_{n-1, 1-\alpha}$  on rejette  $H_0$  et inversement.

## REMARQUES

**Remarque 1 :** Pour trouver la zone de rejet, comme  $\mu = \mu_1 - \mu_2$  peut être aussi grand que l'on veut sous  $H_0$ , on cherche  $c_\alpha$  tel que

$$\sup_{\mu \geq 0} \mathbb{P}_\mu [\text{"On rejette } H_0\text{"}] = \sup_{\mu \geq 0} \mathbb{P}_\mu [\bar{X}_n - \bar{Y}_n \leq c_\alpha] = \alpha.$$

## REMARQUES

**Remarque 2 :** Soit  $T$  une variable aléatoire suivant une loi de Student à  $n - 1$  degrés de liberté, on a

$$p - \text{value} = \mathbb{P}[T \leq z_{obs}].$$

## VI. Tests du Khi-deux

# TEST D'INDÉPENDANCE DU KHI-DEUX

Le test d'indépendance du Khi-deux permet de vérifier l'indépendance entre deux variables aléatoires  $X$  et  $Y$ , i.e on veut tester au risque  $\alpha$

$H_0$  : "  $X, Y$  indépendantes" contre  $H_1$  :  $X, Y$  pas indépendantes".

**Le cadre :** On dispose de  $n$  données  $(x_1, y_1), \dots, (x_n, y_n)$  qui sont des réalisations de couples de variables aléatoires i.i.d  $(X_k, Y_k)$  de même loi que  $(X, Y)$  à valeurs dans  $\{a_1, \dots, a_p\} \times \{b_1, \dots, b_q\}$ .



# NOTATIONS

On note :

- ▶  $O_{i,j} = \sum_{k=1}^n \mathbf{1}_{\{X_k=a_i, Y_k=b_j\}}$ , qui désigne le nombre de données pour lesquelles  $(X, Y) = (a_i, b_j)$ .
- ▶  $O_{i,\cdot} = \sum_{j=1}^q O_{i,j}$  qui désigne le nombre de données pour lesquelles  $X = a_i$ .
- ▶  $O_{\cdot,j} = \sum_{i=1}^p O_{i,j}$  qui désigne le nombre de données pour lesquelles  $Y = b_j$ .
- ▶  $E_{i,j} = \frac{O_{i,\cdot} \times O_{\cdot,j}}{n}$ .

Notons que :

- ▶  $O_{i,j}/n$  est un estimateur de  $\mathbb{P}[X = a_i, Y = b_j]$ .
- ▶  $E_{i,j}/n$  est un estimateur de  $\mathbb{P}[X = a_i] \mathbb{P}[Y = b_j]$ .

# CONSTRUCTION DE LA STATISTIQUE DE TEST

Sous l'hypothèse  $H_0$ , les estimations  $o_{i,j}/n$  et  $e_{i,j}/n$  sont censées être proches. On introduit donc la statistique de test :

$$Z = \sum_{i=1}^p \sum_{j=1}^q \frac{(O_{i,j} - E_{i,j})^2}{E_{i,j}}.$$

## Proposition

*Si  $X$  et  $Y$  sont indépendantes,*

$$Z \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \chi_{(p-1)(q-1)}^2.$$

La proposition précédente est fausse sous  $H_1$ .

## TEST D'INDÉPENDANCE DU KHI-DEUX

**Le test :** On teste au risque  $\alpha \in (0, 1)$ ,

$H_0$  : "X, Y indépendantes" contre  $H_1$  : X, Y pas indépendantes".

On a la statistique de test

$$Z = \sum_{i=1}^p \sum_{j=1}^q \frac{(O_{i,j} - E_{i,j})^2}{E_{i,j}} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \chi_{(p-1)(q-1)}^2.$$

On a la zone de rejet

$$ZR = \{Z > k_{(p-1)(q-1), 1-\alpha}\}$$

où  $k_{(p-1)(q-1), 1-\alpha}$  est le quantile d'ordre  $1 - \alpha$  de la loi du Khi-deux à  $(p - 1)(q - 1)$  degrés de liberté.

On calcule  $z_{obs}$ . Si  $z_{obs} > k_{(p-1)(q-1)}$ , on rejette  $H_0$  et inversement.

## APPLICATION :

On étudie l'influence du sexe sur la couleur des cheveux d'un groupe d'élèves. On veut savoir si la couleur des cheveux est indépendante du sexe. Pour cela, on dispose des données suivantes :

| Sexe   | Blond | Roux | Châtain | Brun | Noir de Jais | Total |
|--------|-------|------|---------|------|--------------|-------|
| Garçon | 592   | 119  | 849     | 504  | 36           | 2100  |
| Fille  | 544   | 97   | 677     | 451  | 14           | 1783  |
| Total  | 1136  | 2126 | 1526    | 955  | 50           | 3883  |

On désigne par  $X$  la variable couleur des cheveux et par  $Y$  la variable sexe.

## APPLICATION

On teste au risque de 5%

$H_0$  : "X, Y indépendantes" contre  $H_1$  : X, Y pas indépendantes".

On a la statistique de test

$$Z = \sum_{i=1}^5 \sum_{j=1}^2 \frac{(O_{i,j} - E_{i,j})^2}{E_{i,j}} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \chi_4^2 \quad \text{sous } H_0.$$

On a la zone de rejet

$$ZR = \{Z > 9.50\}.$$

On a  $z_{obs} = 10.47$  et on rejette donc l'hypothèse  $H_0$ . A noter que l'on a une  $p$ -value égale à 0.033 et on n'aurait donc pas rejeté  $H_0$  au risque de 1%.

# TEST D'ADÉQUATION DU KHI-DEUX

**Le cadre :** On dispose de  $n$  données  $x_1, \dots, x_n$  qui sont des réalisations de variables aléatoires indépendantes  $X_1, \dots, X_n$  et de même loi, à valeurs dans  $\{a_1, \dots, a_K\}$ . On note  $P$  la loi inconnue de la variable aléatoire discrète  $X$  et on souhaite savoir si  $P = P_0$ , où  $P_0$  est une loi connue.

On veut donc tester au risque  $\alpha \in (0, 1)$

$H_0$  : "La loi de  $X$  est  $P_0$ "    contre     $H_1$  : "La loi de  $X$  n'est pas  $P_0$ "

# NOTATIONS

On note  $p_{0,1}, \dots, p_{0,K}$  les probabilités définissant la loi  $P_0$ . On note pour tout  $k = 1, \dots, K$  :

- ▶  $E_k$  l'effectif "observé" pour la modalité  $a_k$

$$E_k = \sum_{i=1}^n \mathbf{1}_{\{X_i = a_k\}}$$

- ▶  $N_k$  l'effectif théorique pour la modalité  $a_k$  sous la loi  $P_0$

$$N_k = np_{0,k}.$$

## CONSTRUCTION DE LA STATISTIQUE DE TEST

La variable  $E_k/n$  est un estimateur naturel de  $p_k = \mathbb{P}[X = a_k]$ .  
Sous  $H_0$ , cet estimateur doit donc converger vers  $N_k/n = p_{0,k}$ .  
On s'intéresse donc à la statistique de test :

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

### Proposition

*Si la loi de  $X$  est  $P_0$ ,*

$$Q^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \chi_{K-1}^2.$$

La proposition précédente est fausse sous  $H_1$ .

## TEST D'ADÉQUATION DU KHI-DEUX

**Le test :** On teste au risque  $\alpha \in (0, 1)$

$H_0$  : "La loi de  $X$  est  $P_0$ " contre  $H_1$  : "La loi de  $X$  n'est pas  $P_0$ "

On a la statistique de test

$$Q^2 = \sum_{k=1}^K \frac{(E_k - N_k)^2}{N_k} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \chi_{K-1}^2 \quad \text{sous } H_0$$

On définit la zone de rejet

$$ZR = \{Q^2 > k_{K-1, 1-\alpha}\},$$

où  $k_{K-1, 1-\alpha}$  est le quantile d'ordre  $1 - \alpha$  de la loi du Khi-deux à  $K - 1$  degrés de liberté.

On calcule  $q_{obs}^2$ . Si  $q_{obs}^2 > k_{K-1, 1-\alpha}$ , on rejette  $H_0$  et inversement.

## APPLICATION

Un biologiste pense qu'à un âge donné :

- ▶ 50% des bébés marchent
- ▶ 12% ont une ébauche de marche
- ▶ 38% ne marchent pas

On fait une étude sur 80 bébés et on obtient :

- ▶ 35 de ces bébés ne marchent pas
- ▶ 4 ont une ébauche de marche
- ▶ 41 ne marchent pas

## APPLICATION

On souhaite donc vérifier que le biologiste à tort. On résume les données dans le tableau suivant :

|                    | Marche          | Ebauche          | Ne marche pas    | Total |
|--------------------|-----------------|------------------|------------------|-------|
| Effectif observé   | 35              | 4                | 41               | 80    |
| Effectif Théorique | $80 \times 0.5$ | $80 \times 0.12$ | $80 \times 0.38$ | 80    |
| "Distance"         | 0.625           | 3.267            | 3.696            | 7.588 |

## APPLICATION

On teste donc au risque 5% l'hypothèse nulle  $H_0$  : "X suit la loi  $P_0$ " contre  $H_1$  : "X ne suit pas la loi  $P_0$ ". On a la statistique de test

$$Q^2 = \sum_{k=1}^3 \frac{(E_k - N_k)^2}{N_k} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \chi^2_2 \quad \text{sous } H_0$$

On a la zone de rejet

$$ZR = \{Q^2 > 5.99\}.$$

Ici,  $q_{obs}^2 = 7.5878$  et on rejette donc  $H_0$ .

## VII. Tests asymptotiques

## TESTS ASYMPTOTIQUES

On considère ici des données  $x_1, \dots, x_n$  qui sont des réalisations de variables aléatoires  $X_1, \dots, X_n$  qui sont indépendantes et de même loi que  $X$ . On s'intéresse à l'estimation d'un paramètre  $\theta$  de la loi de  $X$ , et on suppose que l'on a un estimateur  $\hat{\theta}_n$  asymptotiquement normal, i.e qu'il existe  $\sigma^2 > 0$  tel que

$$\sqrt{n} (\hat{\theta}_n - \theta) \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, \sigma^2).$$

On suppose également que l'on dispose d'un estimateur consistant  $\hat{\sigma}_n^2$  de la variance asymptotique  $\sigma^2$ . A l'aide du théorème de Slutsky, on a alors

$$\sqrt{n} \frac{\hat{\theta}_n - \theta}{\hat{\sigma}_n} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

## TEST D'ÉGALITÉ

**Le test :** On teste au risque  $\alpha \in (0, 1)$

$$H_0 : " \theta = \theta_0 " \quad \text{contre} \quad H_1 : " \theta \neq \theta_0 " .$$

On a la statistique de test

$$Z = \sqrt{n} \frac{\hat{\theta}_n - \theta_0}{\hat{\sigma}_n} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, 1) \quad \text{sous } H_0 .$$

On a la zone de rejet

$$ZR = \{ |z_{obs}| > q_{1-\alpha/2} \}$$

où  $q_{1-\alpha/2}$  est le quantile d'ordre  $1 - \alpha/2$  de la loi normale centrée réduite.

On calcule  $z_{obs}$ . Si  $|z_{obs}| > q_{1-\alpha/2}$ , on rejette  $H_0$  et inversement.

## REMARQUES

**Remarque 1 :** Faire ce test revient à vérifier que  $\theta_0$  est dans l'intervalle de confiance asymptotique de niveau  $1 - \alpha$  de  $\theta$ .

## REMARQUES

**Remarque 2 :** Pour trouver la zone de rejet, on cherche  $c_\alpha$  tel que sous  $H_0$

$$\lim_{n \rightarrow +\infty} \mathbb{P}_{\theta=\theta_0} [\text{"On rejette } H_0\text{"}] = \lim_{n \rightarrow +\infty} \mathbb{P}_{\theta=\theta_0} \left[ \left| \hat{\theta}_n - \theta \right| > c_\alpha \right] = \alpha.$$

## REMARQUES

**Remarque 3 :** Soit  $Z$  une variable aléatoire suivant une loi normale centrée réduite, alors

$$p\text{-value} = \mathbb{P} [|Z| > |z_{obs}|] .$$

## TEST D'INÉGALITÉ $\theta_0 \geq \theta$

**Le test :** On teste au risque  $\alpha \in (0, 1)$

$$H_0 : " \theta_0 \geq \theta " \quad \text{contre} \quad H_1 : " \theta_0 < \theta " .$$

Sous  $H_0$ , il existe  $\theta' \leq \theta_0$  tel que

$$Z(\theta') = \sqrt{n} \frac{\hat{\theta}_n - \theta'}{\hat{\sigma}_n} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

On définit la zone de rejet par

$$ZR = \{ Z(\theta_0) > q_{1-\alpha} \},$$

où  $q_{1-\alpha}$  est le quantile d'ordre  $1 - \alpha$  de la loi normale centrée réduite.

On calcule  $z_{obs}$ . Si  $z_{obs} > q_{1-\alpha}$ , on rejette  $H_0$  et inversement.

## REMARQUES

**Remarque :** Soit  $Z$  une variable aléatoire suivant une loi normale centrée réduite, on a

$$p - \text{value} = \mathbb{P}[Z \geq z_{obs}].$$

## TEST D'INÉGALITÉ $\theta_0 \leq \theta$

**Le test :** On teste au risque  $\alpha \in (0, 1)$

$$H_0 : " \theta_0 \leq \theta " \quad \text{contre} \quad H_1 : " \theta_0 > \theta " .$$

Sous  $H_0$ , il existe  $\theta' \geq \theta_0$  tel que

$$Z(\theta') = \sqrt{n} \frac{\hat{\theta}_n - \theta'}{\hat{\sigma}_n} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

On définit la zone de rejet par

$$ZR = \{ Z(\theta_0) < -q_{1-\alpha} \},$$

où  $q_{1-\alpha}$  est le quantile d'ordre  $1 - \alpha$  de la loi normale centrée réduite.

On calcule  $z_{obs}$ . Si  $z_{obs} < -q_{1-\alpha}$ , on rejette  $H_0$  et inversement.

## REMARQUES

**Remarque :** Soit  $Z$  une variable aléatoire suivant une loi normale centrée réduite, on a

$$p - \text{value} = \mathbb{P}[Z \leq z_{obs}].$$