

Démarche statistique

Premiers pas avec

David Causeur

L'Institut Agro

IRMAR CNRS UMR 6625

<https://dcauseur.netlify.app>



Plan

- 1 Effet à l'échelle d'une population
- 2 Décider à partir de données
- 3 Effet 'groupe'
 - Comparaison de groupes
 - Analyse de variance à un facteur
 - Estimation des paramètres d'effet
 - Test de Fisher
 - Le cas particulier de la comparaison de 2 groupes
 - Décrire un effet groupe
 - Test avec des données appariées
- 4 Effet linéaire

Plan

- 1 Effet à l'échelle d'une population
- 2 Décider à partir de données
- 3 Effet 'groupe'
 - Comparaison de groupes
 - Analyse de variance à un facteur
 - Estimation des paramètres d'effet
 - Test de Fisher
 - Le cas particulier de la comparaison de 2 groupes
 - Décrire un effet groupe
 - Test avec des données appariées
- 4 Effet linéaire

Plan

- 1 Effet à l'échelle d'une population
- 2 Décider à partir de données
- 3 Effet 'groupe'**
 - Comparaison de groupes
 - Analyse de variance à un facteur
 - Estimation des paramètres d'effet
 - Test de Fisher
 - Le cas particulier de la comparaison de 2 groupes
 - Décrire un effet groupe
 - Test avec des données appariées
- 4 Effet linéaire

Comparaison de deux groupes

Test de l'effet d'un facteur à deux modalités :

$$\begin{cases} H_0 : \delta = \mu_1 - \mu_2 = 0 \\ H_1 : \delta = \mu_1 - \mu_2 \neq 0 \end{cases}$$

► Test de comparaison entre sexes dans \mathbb{R}



Test de Student

Reprenons la statistique de Fisher :

$$F = \frac{n_1(\bar{Y}_{1\bullet} - \bar{Y}_{\bullet\bullet})^2 + n_2(\bar{Y}_{2\bullet} - \bar{Y}_{\bullet\bullet})^2}{\hat{\sigma}^2},$$

avec

$$\begin{aligned} n_1(\bar{Y}_{1\bullet} - \bar{Y}_{\bullet\bullet})^2 &= n_1 \left(\bar{Y}_{1\bullet} - \frac{n_1 \bar{Y}_{1\bullet} + n_2 \bar{Y}_{2\bullet}}{n_1 + n_2} \right)^2, \\ &= n_1 n_2^2 \left(\frac{\bar{Y}_{2\bullet} - \bar{Y}_{1\bullet}}{n_1 + n_2} \right)^2, \\ n_2(\bar{Y}_{2\bullet} - \bar{Y}_{\bullet\bullet})^2 &= n_2 n_1^2 \left(\frac{\bar{Y}_{2\bullet} - \bar{Y}_{1\bullet}}{n_1 + n_2} \right)^2. \end{aligned}$$

Test de Student

Reprenons la statistique de Fisher :

$$\begin{aligned}
 F &= \frac{n_1(\bar{Y}_{1\bullet} - \bar{Y}_{\bullet\bullet})^2 + n_2(\bar{Y}_{2\bullet} - \bar{Y}_{\bullet\bullet})^2}{\hat{\sigma}^2}, \\
 &= \left(\frac{\bar{Y}_{2\bullet} - \bar{Y}_{1\bullet}}{\hat{\sigma}}\right)^2 \frac{n_1 n_2 (n_1 + n_2)}{(n_1 + n_2)^2}, \\
 &= \underbrace{\left(\frac{\bar{Y}_{2\bullet} - \bar{Y}_{1\bullet}}{\hat{\sigma} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}\right)^2}_T.
 \end{aligned}$$

Test de Student

Reprenons la statistique de Fisher :

$$F = T^2, \text{ où } T = \frac{\bar{Y}_{2\bullet} - \bar{Y}_{1\bullet}}{\hat{\sigma}_{\hat{\delta}} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} = \frac{\hat{\delta}}{\hat{\sigma}_{\hat{\delta}}}.$$

En effet,

$$\begin{aligned}\sigma_{\hat{\delta}}^2 &= \text{Var}(\bar{Y}_{1\bullet} - \bar{Y}_{2\bullet}), \\ &= \text{Var}(\bar{Y}_{1\bullet}) + \text{Var}(\bar{Y}_{2\bullet}), \\ &= \sigma^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right).\end{aligned}$$

Test de Student

Reprenons la statistique de Fisher :

$$F = T^2, \text{ où } T = \frac{\bar{Y}_{2\bullet} - \bar{Y}_{1\bullet}}{\hat{\sigma} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} = \frac{\hat{\delta}}{\hat{\sigma}_{\hat{\delta}}}.$$

Soit $\hat{\theta}$ un estimateur de θ et $\hat{\sigma}_{\hat{\theta}}$ un estimateur de l'écart-type de $\hat{\theta}$.

Pour le test de $H_0 : \theta = \theta_0$, $T_{\theta_0} = (\hat{\theta} - \theta_0) / \hat{\sigma}_{\hat{\theta}}$ est appelée **statistique de Student**.

Test de Student

► Statistique du test de Student dans \mathbb{R}

La distribution de T sous l'hypothèse nulle est la **loi de Student** à $n - 2$ degrés de liberté, notée \mathcal{T}_{n-2} .

► p-value du test de Student dans \mathbb{R}

Test unilatéral

Test de $H_0 : \delta = 0$ contre $H_1 : \delta < 0$.

Règle **unilatérale** de décision : H_0 est rejetée si T prend une valeur jugée anormalement faible sous H_0 .

Ici, la p-value est la probabilité pour qu'une variable aléatoire de loi \mathcal{T}_{n-2} soit plus petite que la valeur observée de T :

▶ Test de Student unilatéral dans \mathbb{R}

Intervalle de confiance d'un paramètre

L'ensemble des valeurs θ_0 telles que $H_0 : \theta = \theta_0$ n'est pas rejetée au seuil α est un intervalle de confiance de θ , de niveau de confiance $1 - \alpha$.

On en déduit l'intervalle de confiance $CI_{1-\alpha}(\delta)$:

$$\begin{aligned} CI_{1-\alpha}(\delta) &= \left\{ \delta_0, -t_{1-\alpha/2}^{(n-2)} \leq \frac{\hat{\delta} - \delta_0}{\hat{\sigma}_{\delta}} \leq t_{1-\alpha/2}^{(n-2)} \right\}, \\ &= \left[\hat{\delta} - t_{1-\alpha/2}^{(n-2)} \hat{\sigma}_{\delta}; \hat{\delta} + t_{1-\alpha/2}^{(n-2)} \hat{\sigma}_{\delta} \right]. \end{aligned}$$

► Intervalle de confiance par `t.test` dans R

Intervalle de confiance d'un paramètre

Pour les paramètres μ_1 et μ_2 :

$$CI_{1-\alpha}(\mu_j) = \left[\hat{\mu}_j - t_{1-\alpha/2}^{(n-2)} \frac{\hat{\sigma}}{\sqrt{n_j}} ; \hat{\mu}_j + t_{1-\alpha/2}^{(n-2)} \frac{\hat{\sigma}}{\sqrt{n_j}} \right].$$

► Intervalle de confiance par `t.test` dans R



Puissance du test de Student

Dans quelle mesure le test de Student peut-il détecter une différence de moyennes à l'échelle de la population ?

Cas des données `porcs` : si la différence de moyenne entre mâles et femelles à l'échelle de la population vaut 1, le test de Student conclura-t'il que l'effet sexe est significatif ?

Puissance du test de Student

Soit le test de $H_0 : \mu_1 - \mu_2 = 0$ contre $H_1 : \mu_1 - \mu_2 = \delta \neq 0$.
Au seuil α , la **puissance** du test est la probabilité sous H_1
que le test rejette H_0 :


$$\text{Puissance}(\delta) = \mathbb{P}_{\mu_1 - \mu_2 = \delta}(|T| \geq t_{1-\alpha/2}^{(n-2)}).$$

Sous H_1 , $T \sim \mathcal{T}_{n-2}(\lambda)$ avec :

$$\lambda = \frac{\delta}{\sigma \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}. \quad \text{[paramètre de non-centralité]}$$

Puissance du test de Student

Density function of Student distribution (58 d.f.)



Puissance du test de Student

Plus λ est grand, plus le test de Student est puissant :

- Plus $|\delta|/\sigma$ est grand, plus le test est puissant.
- Plus n_1 et n_2 sont grands, plus le test est puissant.

▶ Puissance du test de Student dans \mathbb{R}

Tests Post-hoc

L'effet d'un facteur est significatif = les moyennes de la variable réponse dans *certain*s groupes sont différentes.

Quels groupes ?

$P_0 \neq P_{25} \neq P_{50}$ ou $P_0 \neq \{P_{25} = P_{50}\}$ ou ...

Tests post-hoc pour 3 groupes : 3 tests simultanés

- $H_0^{(12)} : \mu_1 = \mu_2,$
- $H_0^{(13)} : \mu_1 = \mu_3,$
- $H_0^{(23)} : \mu_2 = \mu_3.$

► Comparaisons deux à deux dans \mathbb{R}

Tests Post-hoc

Quel risque d'erreur pour plusieurs tests simultanés ?

Probabilité d'au moins un rejet à tort (faux positif) :

$$\begin{aligned}
 & \mathbb{P}_{H_0^{(ii')}, i \neq i'} (\text{au moins une hypothèse } H_0^{(ii')} \text{ rejetée}) \\
 & \leq \sum_{i \neq i'} \mathbb{P}_{H_0^{(ii')}} (H_0^{(ii')} \text{ rejetée}), \\
 & \leq 3\alpha
 \end{aligned}$$

Correction de Bonferroni : $\alpha^* = \alpha/3$:

► Correction de Bonferroni dans \mathbb{R}

Tests sur un paramètre - Résumé

- 1 Test de $H_0 : \theta = \theta_0$ contre $H_1 : \theta \neq \theta_0$ ou $\theta > \theta_0$
 - Statistique du test de Student : $T = (\hat{\theta} - \theta_0) / \hat{\sigma}_{\hat{\theta}}$
 - Loi sous $H_0 : T \sim \mathcal{T}_k$, où k est le nombre de degrés de liberté pour l'estimation de $\hat{\sigma}_{\hat{\theta}}^2$
- 2 Intervalle de confiance de niveau $1 - \alpha$: ensemble des θ_0 tels que H_0 n'est pas rejetée au seuil α
- 3 Comparaison de moyennes : $H_0 : \mu_1 = \mu_2$
- 4 Evaluation d'un dispositif expérimental :
 - Puissance du test (à objectif de précision fixé)
 - Taille d'échantillon nécessaire (à objectifs de précision et de puissance fixés)
- 5 Tests post-hoc : correction du seuil (Bonferroni) pour un contrôle global du risque d'un faux positif.

Plan

- 1 Effet à l'échelle d'une population
- 2 Décider à partir de données
- 3 Effet 'groupe'
 - Comparaison de groupes
 - Analyse de variance à un facteur
 - Estimation des paramètres d'effet
 - Test de Fisher
 - Le cas particulier de la comparaison de 2 groupes
 - Décrire un effet groupe
 - Test avec des données appariées
- 4 Effet linéaire