

Test de Student et Comparaison de Moyenne

①.

①. Contexte Général :

- On s'intéresse à un phénomène que l'on étudie à l'aide de mesures. Ex: effet d'un médicament sur une charge virale.
- En général on étudie l'effet de facteurs sur une variable : Fact: Médicament, Var: Charge.
- On voudrait avoir une réponse qui soit généralisable à la pop. alors que les mesures sont faites uniquement sur un ensemble restreint d'individus.
- Pex le Pb: - choix des individus: échantillonnage .
- erreur comme lors de la généralisat°

| échantillon | Effect | populat° | | Pas d'effet |
|-------------|--------|----------|----|-------------|
| | | Effet | TP | |
| | | | | FP |
| | | | FN | TN |

- la stratégie des tests = tjs partir de l'hyp. "pas d'effet" - hypothèse nulle (raisonnée par l'abordage).

→ on préfère dire qu'il n'y a pas d'effet plutôt que de se tromper. → Faut donc plutôt H_0 .

- Demarche de base: test d'hypothèse de comparaison de moyennes.
 - Comp. de populations dans un cadre limité.
 - ex: dose du médicament ?
 - . facteurs Qualit. quantit.

↳ Dans un 2^e tps, le modèle linéaire permettre de prendre en compte + options du cadre empirique.

②. Construction de la Stat. de Student.

- 2 pop A, B, y^A , y^B , \bar{y}^A , \bar{y}^B
- 3 nips: effectifs, moy, variance
- la variance peut être connue ou non.

$$T = \frac{\bar{y}_A - \bar{y}_B}{\sqrt{\frac{s_A^2}{n_A} + \frac{s_B^2}{n_B}}} = \text{quantité qui résume l'info et qui dépend des données.}$$

↳ elle va servir à définir une règle de décision quant au rejet de H₀.

= pour répondre à la question "y-a-t-il un effet?"

↳ C'est un score.

- plus le score est élevé, plus on dit que la différence est significative \Rightarrow il faut un seuil
- Or on voit bien que l'erreur va dépendre du seuil : plus le seuil est petit, plus on aura FP.

\hookrightarrow Comment choisir le seuil ?

③. L'utilité du modèle : les Distributions à Variances Connues.

- le score de Student peut être utilisé malgré d'un traité statistique. La construction est naturelle et son interprétation intuitive.
- si on modélise les données avec un modèle F_0 , alors on aura une règle pour le choix du seuil.

Modèle Gaussien : avec la bhyp.

• loi des estimateurs

sous H_0 : $\{ p_A = p_B \} =$ l'hyp. concernant les paramètres du modèle.

$$T \sim N(0,1).$$

f_{θ_0}

- on doit faire les calculs sous f_{θ_0} .
- on ne doit pas ce qu'il se passe sous f_{θ_1} .

- Règle de décision : On observe une valeur du t_{obs.} = une réalisation, et on le compare au Quantile de la loi normale.

Si $|t_{obs}| > u_{1-\alpha/2}$ alors on rejette H_0 .

↳ définit la région de rejet : R_α - ensemble des valeurs de t irréalistes pour H_0 .

α = risque de 1^{re} espèce = 5%.

↳ nécessite la valeur du quantile.

$$\begin{aligned} \text{- Notion de } P_v: & P(|t_{obs}| > u_{1-\alpha/2}) \\ &= P(|T| > t_{obs}). \end{aligned}$$

$$(P_v(t_{obs}) < \alpha) \Leftrightarrow (t_{obs} \in R_\alpha)$$

↓
réfère le t^r d'enem = niveau du test pour que l'on est prêt à accepter.

lequel H_0 sera rejetté.

→ (α, β) liés : on fixe α et on max. β selon \bar{n} .

↳ une manière facile de composer des tests
↳ selon leur \bar{n} .

→ Comment max \bar{n} ?

→ Dans les $E(T) = 0$, $V(T) = \frac{m}{m-2}$

↳ si $m \rightarrow$ On pourra mieux rejeter

→ Etape d'après = Calculer n pour \bar{n} .

↳ Supposons qu'on connaît θ_0 .

$$\text{Ex. } \frac{\theta_0 - \theta_1}{\sigma} \sqrt{R(R+1)} = \text{diff. normalisée}$$

↳ Réformuler la question :

- quelle \bar{n} pour un n donné ?
- si on veut \bar{n} , combien de n doivent être donné $\frac{\theta_0 - \theta_1}{\sigma}$.

dans R: $\begin{cases} \text{uver-test} \\ t.\text{test} \end{cases}$

Résumé sur la méthodologie.

(3)

- 4 étapes :
 - données $y_1 \dots y_n$
 - modèle définit la loi des Y_i , il dépend d'un paramètre θ .
 - hyp. à tester : hypothèse nulle qui porte sur les paramètres.
 - règle de décision : une stat $T = f(Y_i)$
 - région de rejet.

(4) . Test du Student: Modèle Gaussien à N variables indon.
↳ test sur les paramètres (construire le test).

(5) . La prob. des données app.

Hyp: les prop. A et B sont \perp .
si non vérifiée?

→ on travaille sur la f .

(6) . Notion de puissance d'un test.

= $\pi =$ proba que la procédure rejette H_0
quand elle est fausse.

Comparaison de populations (Stat descriptives)

①

Modèle:

- $x_{1A} \dots x_{n_A}, x_{2A} \dots x_{m_A}$, iid $N(\mu_A, \sigma^2)$
- $x_{1B} \dots x_{n_B}, \dots \dots \dots (f_B, \sigma^2)$
- les 2 populations sont indépendantes (pas d'expériences).

Hypothèse: $H_0 = \{\mu_A = \mu_B\}$.

→ Variance homogène : $S^2 = \frac{1}{n_A + n_B - 2} \left((n_A - 1) s_A^2 + (n_B - 1) s_B^2 \right)$

$$T = \frac{|\bar{X}_A - \bar{X}_B|}{S \sqrt{\frac{1}{n_A} + \frac{1}{n_B}}} \sim \mathcal{C}(n_A + n_B - 2)$$

→ Variance hétérogène : $s_H^2 = \frac{1}{n_A - 1} \sum (x_{iA} - \bar{x}_A)^2$

$$T = \frac{|\bar{X}_A - \bar{X}_B|}{\sqrt{\frac{s_A^2}{n_A} + \frac{s_B^2}{n_B}}} \sim \mathcal{C}(df)$$

$$df = \frac{(w_A + w_B)^2}{\frac{w_A^2}{n_A-1} + \frac{w_B^2}{n_B-1}}, \quad w_A = \frac{s_H^2}{n_A}$$

avec df approché par Satterwaite

Hypothèse préalable: $H_0 = \{\sigma_A^2 = \sigma_B^2\}$.

$$F = \frac{s_A^2 / (n_A - 1)}{s_B^2 / (n_B - 1)} \sim \mathcal{F}(n_A - 1, n_B - 1).$$

$$F' = \text{folded } F = \frac{\max(s_A^2, s_B^2)}{\min(s_A^2, s_B^2)}.$$

$$\text{Rq: IC}(6) = \left\{ \chi_{\alpha/2, n-1}^2 \leq \frac{(n-1) s^2}{\sigma_0^2} \leq \chi_{1-\alpha/2, n-1}^2 \right\}.$$

Règle de décision :

(1). Si $\{ |t_{\text{obs}}| > |t_{1-\alpha/2, n-1}|\} \Rightarrow$ Rejet avec risque α
 $= R_\alpha$ (région de rejet).

(2). Si $P_0 = P(|T| > |t_{\text{obs}}|) < \alpha$.

- proba d'obtenir les données si H_0
étant vraie.

(1) \Leftrightarrow (2)