

### Leçon 3

## Comparaison de deux moyennes: test $t$

14:57

1

1

---

---

---

---

---

---

---

---

### Au programme

- Comment comparer deux moyennes en termes de différence à l'aide principalement du test  $t$  de Student?
  - Justifier, définir le test  $t$  et reconnaître les situations de recherche où son utilisation est appropriée
  - Analyser un tableau, un diagramme et une courbe des moyennes pour une variable dichotomique
  - Effectuer un test  $t$  et interpréter les résultats en termes de signification statistique
  - Différencier un test bilatéral d'un test unilatéral
  - Calculer et interpréter la mesure d'association éta-carré en termes de signification réelle

14:51

2

2

---

---

---

---

---

---

---

---

### Différence entre deux moyennes

#### Exemples de questions de recherche

1. Y a-t-il une différence entre pays sous-développés et développés quant à l'importance de l'espérance de vie?
2. Les garçons sont-ils meilleurs que les filles en statistiques sociales (notes)?
3. Les citadins et les ruraux sont-ils confrontés avec la même ampleur au chômage?
4. Y a-t-il une différence entre hommes et femmes quant à la préférence concernant la taille de la famille?
5. Y a-t-il une différence entre les étudiants absentéistes et non absentéistes quant à la performance à l'examen?

14:51

3

3

---

---

---

---

---

---

---

---

### Différence entre deux moyennes

Exemple illustratif & justification

- Y a-t-il une différence entre hommes et femmes quant au nombre d'heures passées devant la TV/jour (Fox, 1999)?

X

Sexe  
(Homme / Femme)

→

Temps d'écoute TV/j  
(0, 1, 2,....heures)

Y

- Or, les tableaux bivariés, et le  $\chi^2$ , sont limités (Fox, 1999)
  - Diversité des valeurs d'une variable quantitative
  - La catégorisation implique une perte :
    - ✦ d'information, qui risque de changer la structure de la relation
    - ✦ des propriétés mathématiques, et donc de la puissance statistique
  - Nécessité d'un grand nombre de  $n$  pour des % stables
- Le test  $t$  de Student est approprié pour analyser une relation entre une VI dichotomique et une VD quantitative

14:51 4

---

---

---

---

---

---

---

---

---

---

4

### Différence entre deux moyennes

Définition & logique

- Le test  $t$  de Student est un test d'hypothèse: on cherche à valider un paramètre supposé à l'aide d'une statistique
- Cette statistique compare deux moyennes d'échantillon
  - Calcul de la moyenne du groupe 1 (temps moyen des hommes)
  - Calcul de la moyenne du groupe 2 (temps moyen des femmes)
  - Calcul de la différence observée entre les deux moyennes
- La différence observée dans  $n$  est-elle suffisamment importante pour être généralisée avec confiance à  $N$ ?
- À l'instar du test du chi-carré  $\chi^2$ , on compare le  $t_{calculé}$  (statistique) au  $t_{critique}$  (table distribution d'échantillonnage)

14:51 5

---

---

---

---

---

---

---

---

---

---

5

### Différence entre deux moyennes

Illustration: tableau, diagramme & courbe des moyennes  
 → Temps passé devant la TV selon le sexe (Fox, p.206)

Temps passé devant la télévision	Sexe	
	Hommes	Femmes
Moyenne (heures)	2,75	3,01
Écart-type	2,03	2,22
Nombre de cas (n)	855	1085

14:51 6

---

---

---

---

---

---

---

---

---

---

6

## Différence entre deux moyennes

Au-delà de l'observation: la signification statistique

- Il faut s'assurer que la différence observée dans  $n$  est statistiquement significative en utilisant le test  $t$
- Le test  $t$  consiste à comparer cette différence observée et la différence attendue s'il n'y avait pas de relation dans  $N$ 
  - Si la différence observée est similaire à la différence attendue, alors on peut croire qu'il n'y a vraiment pas de relation ( $H_0$ )
  - En revanche, si la différence observée s'écarte vraiment de la différence attendue, alors on peut croire qu'il y a une relation ( $H_1$ )

14:51

7

7

---

---

---

---

---

---

---

---

---

---

## Différence entre deux moyennes

Hypothèses statistiques

- Hypothèse nulle (à tester!)
  - Il n'y a pas de différence dans le temps moyen passé devant la TV entre les hommes et les femmes dans  $N$
$$H_0: \mu_h = \mu_f \text{ ou de façon équivalente } H_0: \mu_h - \mu_f = 0$$
- Hypothèse alternative (recherche): de trois choses, l'une!
  - bidirectionnelle : Il y a une différence dans le temps moyen passé devant la TV entre hommes et femmes dans  $N$   $H_1: \mu_h \neq \mu_f$
  - unidirectionnelle : Le temps moyen passé devant la TV chez les hommes est inférieur à celui des femmes dans  $N$   $H_1: \mu_h < \mu_f$
  - unidirectionnelle : Le temps moyen passé devant la TV chez les femmes est supérieur à celui des hommes dans  $N$   $H_1: \mu_f > \mu_h$

14:51

8

8

---

---

---

---

---

---

---

---

---

---

## Test $t$ de Student

Formule complète

$$t = \frac{\overline{X_1 - X_2} - (\mu_1 - \mu_2)}{S_{\overline{X_1 - X_2}}}$$

↑ Différence observée  
 ↓ Différence attendue  
 ← Erreur-type

$\overline{X_1}$  = moyenne de la VD pour la catégorie 1 de la VI dans l'échantillon  
 $\overline{X_2}$  = moyenne de la VD pour la catégorie 2 de la VI dans l'échantillon  
 $\mu_1$  = moyenne de la VD pour la catégorie 1 de la VI dans la population  
 $\mu_2$  = moyenne de la VD pour la catégorie 2 de la VI dans la population  
 $S_{\overline{X_1 - X_2}}$  = erreur-type de la différence entre les moyennes dans  $n$

14:51

9

9

---

---

---

---

---

---

---

---

---

---

### Test $t$ de Student

#### Formule simplifiée

- Puisque la différence attendue s'il n'y avait pas de relation dans  $N$  donne  $\mu_1 - \mu_2 = 0$ , sous l'hypothèse nulle, on peut simplifier la formule en enlevant  $\mu_1 - \mu_2$  :

$$t = \frac{(\bar{X}_1 - \bar{X}_2) - (0)}{S_{\bar{X}_1 - \bar{X}_2}}$$

- Le numérateur est la différence entre les moyennes de la variable dépendante pour les deux catégories dans l'échantillon  $n$
- Le dénominateur est l'erreur-type (ou écart-type) de la différence entre deux  $\bar{X}$  pour tous les échantillons possibles dans  $N$

- La valeur du  $t$  indique à combien d'écart-types la différence entre deux moyennes se situe par rapport à 0

14:51 10

10

---

---

---

---

---

---

---

---

---

---

### Test $t$ de Student

#### Des erreurs-types

- Erreur-type d'une moyenne  $S_{\bar{X}}$ 
  - Supposons qu'un sondage donne une moyenne observée, et que l'on répète l'expérience de sondage 100 fois. Que serait l'écart-type des moyennes de tous les échantillons possibles (68%)?

$$S_{\bar{X}} = \frac{s}{\sqrt{n}} = \sqrt{\frac{s^2}{n}} = \sqrt{s^2 \frac{1}{n}}$$

- Erreur-type d'une différence entre deux moyennes  $S_{\bar{X}_1 - \bar{X}_2}$ 
  - Si un sondage donne une différence observée entre 2 moyennes, et que l'on répète l'expérience 100 fois, que serait l'écart-type des différences de moyennes de tous les échantillons possibles (68%)?

$$S_{\bar{X}_1 - \bar{X}_2} = \sqrt{s^2 \text{ combinée} \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}$$

14:51 11

11

---

---

---

---

---

---

---

---

---

---

### Test $t$ de Student

#### Erreur-type de la différence entre deux $\bar{X}$ : visualisation

$D_{\bar{X}} = \bar{X}_1 - \bar{X}_2 = -0,26$

-1s<sub>D $\bar{X}$</sub>     -0,26    +1s<sub>D $\bar{X}$</sub>

68% des échant.

14 12

12

---

---

---

---

---

---

---

---

---

---

### Test $t$ de Student

Erreur-type de la différence entre deux  $\bar{X}$  : formule complète

$$s_{\bar{X}_1 - \bar{X}_2} = \sqrt{\left( \frac{n_1 s_1^2 + n_2 s_2^2}{n_1 + n_2 - 2} \right) \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}$$

Variance combinée
Correction du biais

$s_1^2$  = variance de la variable dépendante pour la catégorie 1  
 $s_2^2$  = variance de la variable dépendante pour la catégorie 2  
 $n_1$  = le nombre de cas dans la catégorie 1 de la var. indépendante  
 $n_2$  = le nombre de cas dans la catégorie 2 de la var. indépendante  
 $n_1 s_1^2 + n_2 s_2^2$  = somme des variances pondérées  
 $n_1 + n_2 - 2$  = degrés de liberté correspondant à  $(n_1 - 1) + (n_2 - 1)$

14:51 13

13

---

---

---

---

---

---

---

---

---

---

### Test $t$ de Student

Calcul: exemple de Fox (p.214)

→ Pour l'exemple sur le nombre d'heures passées devant la TV selon le sexe, effectuons les calculs conduisant à  $t = -2,653$

Sexe		$t = \frac{\bar{X}_1 - \bar{X}_2}{S_{\bar{X}_1 - \bar{X}_2}} = \frac{D_{\bar{X}}}{S_{D_{\bar{X}}}}$
Hommes (Catégorie 1)	Femmes (Catégorie 2)	
$\bar{X}_1 = 2,75$	$\bar{X}_2 = 3,01$	$= \frac{-0,26}{0,098}$
$s_1^2 = 2,030^2$ $N_1 = 855$	$s_2^2 = 2,225^2$ $N_2 = 1085$	
$\sqrt{\left( \frac{2,030^2 + 2,225^2}{(855-1)+(1085-1)} \right) \left( \frac{1}{855} + \frac{1}{1085} \right)}$		

14:51 14

14

---

---

---

---

---

---

---

---

---

---

### Test $t$ de Student

Erreur-type de la différence: interprétation

$D_{\bar{X}} \pm S_{D_{\bar{X}}} = -0,26 \pm 0,098 = -0,36 \text{ et } -0,16$

Différences de moyennes de tous les échantillons possibles

68% de chance

14 15

15

---

---

---

---

---

---

---

---

---

---

## Test $t$ de Student

### Étapes préalables à la prise de décision

- Formulons les hypothèses statistiques
  - Hypothèse nulle: il n'y a pas de différence dans le nombre d'heures passées devant la TV chez les hommes et les femmes  
 $H_0: \mu_1 = \mu_2$  ou de façon équivalente  $H_0: \mu_1 - \mu_2 = 0$
  - Hypothèse alternative bilatérale | bidirectionnelle: il y a une diff. dans le nombre d'heures passées devant la TV chez les H et les F  
 $H_1: \mu_1 \neq \mu_2$
- Après le calcul du  $|t|$ , calculons les degrés de liberté
  - $dl = (855-1)+(1085-1) = 1938$
- Fixons le seuil de signification à 0,05 (risque d'erreur 5%)

14:51 16

16

---

---

---

---

---

---

---

---

---

---

## Test $t$ de Student

### Table statistique (Fox, p.344)

TABLEAU 2 : LA DISTRIBUTION DU  $t$

		Seuil de signification pour un test unilatéral					
		0,10	0,05	0,025	0,01	0,005	0,0005
		Seuil de signification pour un test bilatéral					
		0,20	0,10	$\alpha$ 0,05	0,02	0,01	0,001
Degrés de liberté	1	3,078	6,314	12,706	31,821	63,657	636,619
	2	1,886	2,920	4,303	6,965	9,925	31,598
	3	1,638	2,353	3,182	4,451	5,841	12,941
	4	1,533	2,132	2,776	3,747	4,604	8,610
	5	1,476	2,015	2,571	3,365	4,032	6,859
	40	1,303	1,684	2,021	2,423	2,704	3,551
	60	1,296	1,671	2,000	2,390	2,660	3,460
	120	1,289	1,658	1,980	2,358	2,617	3,373
	$\infty$	1,282	1,645	1,960	2,326	2,576	3,291

14:51 17

17

---

---

---

---

---

---

---

---

---

---

## Test $t$ de Student

### Table statistique: lire et prendre une décision

- Elle présente la valeur critique (minimale) du  $t$  nécessaire au rejet de l'hypothèse nulle pour un degré de liberté  $dl$  et un seuil de signification  $\alpha$  donnés
- Comment déterminer la sig. statistique d'une relation?
  - Retrouver les  $dl$  dans la colonne de gauche
  - En allant vers la droite, déterminer la valeur critique qui correspond au niveau de signification considéré pour un test donné
  - Si le  $t$  calculé est  $\leq$  à la valeur critique du  $t$ , il faudra accepter l'hypothèse nulle et conclure à une absence de différence sig.
  - Si le  $t$  calculé est  $>$  à la valeur critique du  $t$ , il faudra rejeter l'hypothèse nulle et conclure à l'existence d'une différence sig.

14:51 18

18

---

---

---

---

---


---

---

---

---

---



19

---

---

---

---

---

---

---

---

---

---

### Test $t$ de Student

Décision & conclusion

→ Règle de décision: rejet de  $H_0$  si

- $t_{\text{calculé}} > t_{\text{critique}}$

■ **Décision:** la valeur calculée absolue du  $t$  (2,65) excède la valeur critique du  $t$  (1,96), avec 1938 **dl** et un seuil 0,05 pour un test bilatéral. On rejette donc l'hypothèse nulle

- [Autrement dit, l'écart symbolisé par la valeur 2,65 est différent de 0 et ne serait pas dû au hasard de l'échantillonnage

■ **Conclusion:** il existe une relation statistique significative entre le sexe et le temps d'écoute de la TV. Il y a au moins 95% de chance que la différence H/F existe dans **N**...

14:51 20

20

---

---

---

---

---

---

---

---

---

---

### Test $t$ de Student

Test bilatéral vs. test unilatéral

■ Un test bilatéral est utilisé lorsque qu'on s'intéresse seulement à la différence entre les deux moyennes

- Il considère les deux côtés de la distribution d'échantillonnage
- Peu importe que  $t$  soit + ou - :  $H_1: \mu_1 \neq \mu_2$
- Il est plus exigeant et donc demeure plus souvent utilisé

■ Un test unilatéral est utilisé lorsque la direction de la différence entre les deux moyennes est prédite

- Il ne considère qu'un côté de la distribution d'échantillonnage
- Que  $t$  soit + ou - importe:  $H_1: \mu_1 < \mu_2$  ou  $H_1: \mu_1 > \mu_2$
- $t$  est associé à un  $\alpha$  2 fois plus petit (ex: 0,025 contre 0,05)

14:51 21

21

---

---

---

---

---

---

---

---

---

---





**Test t de Student**

**Conditions d'application**

- Caractère probabiliste de l'échantillonnage
  - Les échantillons des 2 groupes d'observations sont aléatoires
- Normalité de la distribution de la VD quantitative
  - Si  $n \geq 15$  par groupe, le test t est robuste (Green & Salkind, 2011)
- Égalité des variances des groupes ou homoscédasticité
  - Si  $\sigma_1^2 \neq \sigma_2^2$  et que l'hétéroscédasticité est forte, deux possibilités:
    - ❖  $n_1 = n_2$ , le test t de Student est robuste
    - ❖  $n_1 \neq n_2$ , le test t n'est pas robuste, utiliser le test t' de Welch
- Indépendance des échantillons ou groupes
  - S'ils sont associés ou pairés, utiliser le test t pairé

14:51 25

25

---

---

---

---

---

---

---

---

**Tout prochainement**

- Prochaine leçon
  - Synthèse & Révision
- Au labo d'Excel d'aujourd'hui
  - Construire et interpréter des tableaux et diagrammes de moyennes illustrant la différence entre deux moyennes
  - Tester la signification statistique de cette différence au moyen du test t de Student, tout en construisant une table statistique du t
  - Mesurer l'intensité ou la signification réelle d'une différence de moyennes au moyen de l'éta-carré

14:51 26

26

---

---

---

---

---

---

---

---