

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Principaux tests statistiques pour échantillons de petites tailles

Etienne Dantan

(Etienne.Dantan@univ-nantes.fr)

Master 2 BBRT, DCPS et SANH

18 Octobre 2013

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- On considère deux populations \mathcal{P}_A et \mathcal{P}_B (ou plus) desquelles sont extraits deux échantillons de tailles n_A et n_B .
- A partir de ces observations, on cherche à savoir si les **caractéristiques** des deux populations peuvent être considérées comme égales, ou bien si elles semblent être différentes.

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- 2 types de variables aléatoires

1- v.a. quantitatives :

→ **v.a. discontinues ou discrètes**

x_i : *nombre fini* (ex. : lancé de dé) ou *nombre infini dénombrable* (ex. : nombre de petits par portée pour une espèce animale donnée, nombre de mutations dans une séquence ADN, etc.)

→ **v.a. continues**

x_i : *nombre infini non dénombrable* (ex. : taille ou âge d'un individu tiré au hasard)

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

2- v.a. qualitatives :

→ v.a. ordinales

x_i : valeurs non numériques pouvant être ordonnées
(ex. : intensité d'une douleur (faible=1, moyenne=2 ou forte=3))

→ v.a. catégorielles ou nominales

x_i : valeurs non numériques ne pouvant pas être ordonnées (ex. : malade=1 ou non malade=0, fumeurs=1 ou non fumeurs=0)

⇒ en fonction de la question d'intérêt : **étude quantitative**
ou **fréquentielle**

Exemple - Comparaison de 2 fréquences

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

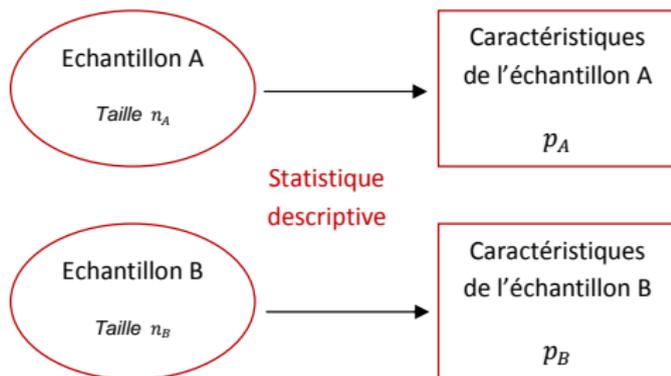
Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

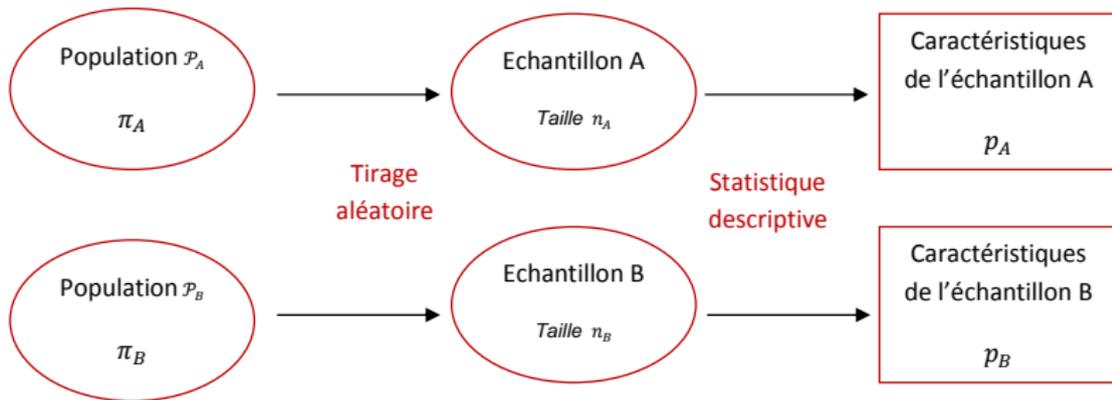
Corrélation linéaire

χ^2 d'indépendance

Conclusion



Exemple - Comparaison de 2 fréquences



$$H_0: \pi_A = \pi_B = \pi$$

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Conclusion

- rejet de H_0 : la différence entre π_A et π_B n'est pas due au hasard,
i.e. échantillons A et B semblent représentatifs de 2 populations distinctes
- non rejet de H_0 : la différence entre π_A et π_B semble due aux fluctuations d'échantillonnage,
i.e. nous n'avons pas pu mettre en évidence de différence significative

⇒ **attention** : il existe **toujours** une probabilité de se tromper

α : probabilité de se tromper en rejetant H_0

β : probabilité de se tromper en ne rejetant pas H_0 , i.e. en rejetant H_1

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

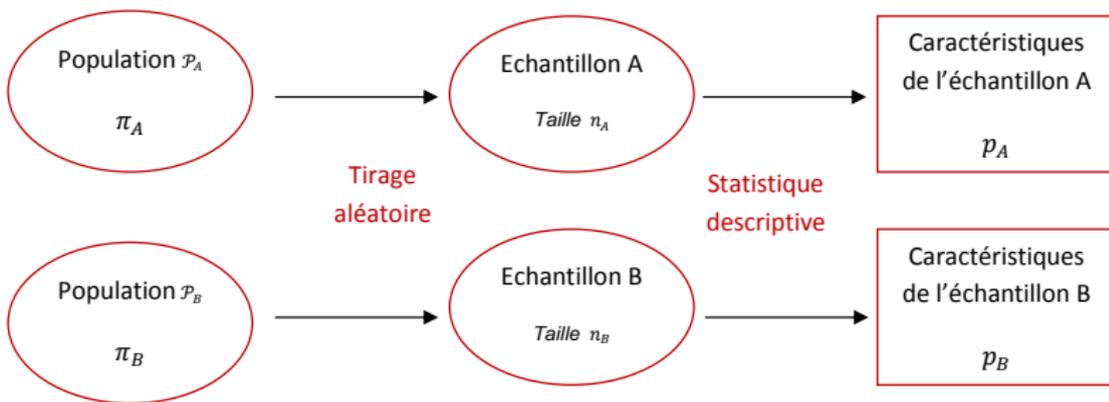
- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Rejet de H_0 au risque de 1^{ère} espèce α



Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

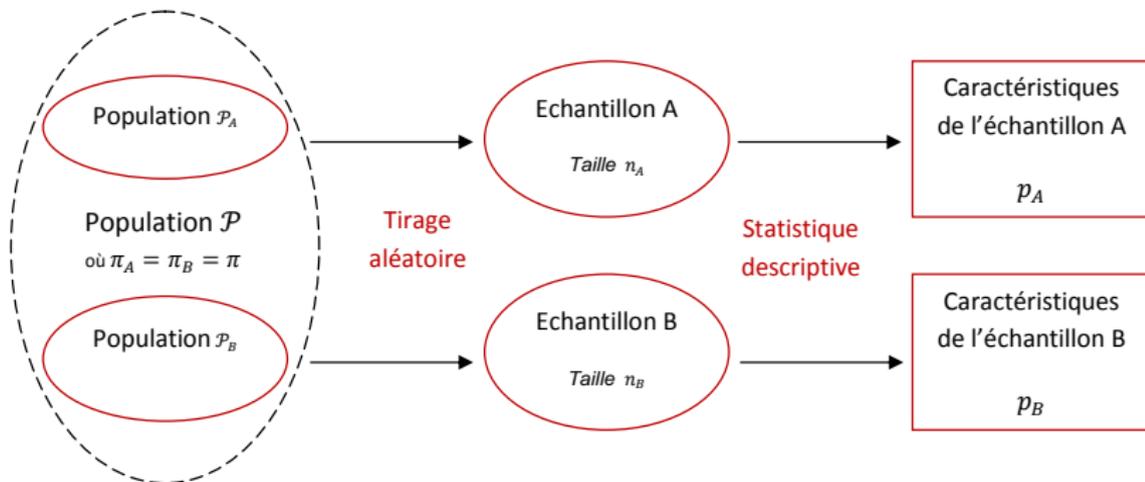
- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Non rejet de H_0 au risque de 1^{ère} espèce α



Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- 1 Variable quantitative continue à expliquer

en fonction d'une autre variable qualitative explicative à deux modalités

⇒ comparaison de deux moyennes

- Test de Student de comparaison de deux moyennes issues de 2 populations **indépendantes** représentées par 2 **grands** échantillons (test paramétrique : approximation normale)
- Test de Mann-Whitney de comparaison de 2 distributions de 2 v.a. issues de 2 populations **indépendantes** représentées par 2 **petits** échantillons (test non-paramétrique)

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- 1 Variable quantitative continue à expliquer

en fonction d'une autre variable qualitative explicative à + de 2 modalités

⇒ comparaison de + de 2 moyennes

→ ANOVA

à partir de + de 2 populations **indépendantes** représentées par des **grands** échantillons

→ Test de Kruskal-Wallis de comparaison de + de 2 distributions de v.a.

issues de + de 2 populations **indépendantes** représentées par des **petits** échantillons (test non-paramétrique)

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- 1 Variable quantitative continue à expliquer

en fonction d'une autre variable qualitative explicative à deux modalités

⇒ comparaison de deux moyennes

- Test de Student de comparaison d'une différence à 0 pour 2 populations **appariées** représentées par 2 **grands** échantillons (test paramétrique)
- Test de Wilcoxon de comparaison de 2 distributions de 2 v.a. issues de 2 populations **appariées** représentées par 2 **petits** échantillons (test non-paramétrique)

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- 1 Variable qualitative à expliquer

en fonction d'une autre variable qualitative explicative à deux modalités

⇒ comparaison de deux pourcentages

- Test de comparaison de deux fréquences issues de 2 populations **indépendantes** représentées par 2 **grands** échantillons (test paramétrique : approximation normale)
- Test exact de Fisher de comparaison de deux fréquences issues de 2 populations **indépendantes** représentées par 2 **petits** échantillons (test non-paramétrique)

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- 1 Variable qualitative à expliquer

en fonction d'une autre variable qualitative explicative à deux modalités

⇒ comparaison de deux pourcentages

- Test de Mc Nemar de comparaison de deux fréquences issues de 2 populations **appariées** représentées par 2 **grands** échantillons (test paramétrique)
- Test de Mc Nemar de comparaison de deux fréquences issues de 2 populations **appariées** représentées par 2 **petits** échantillons (calcul exact proba critique basé sur la loi binomiale)

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- 1 Variable quantitative à expliquer
en fonction d'une autre variable quantitative explicative
- Coefficient de corrélation

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

⇒ 6 étapes

- 1 Définition des hypothèses nulle H_0 et alternative H_1
- 2 Choix du test, écriture de la statistique de test et de sa loi sous H_0
- 3 Choix du niveau de signification α , Définition de la région critique (RC)
- 4 Calcul de la statistique de test
- 5 Conclusion statistique : rejet ou non de H_0
- 6 Conclusion épidémiologique

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

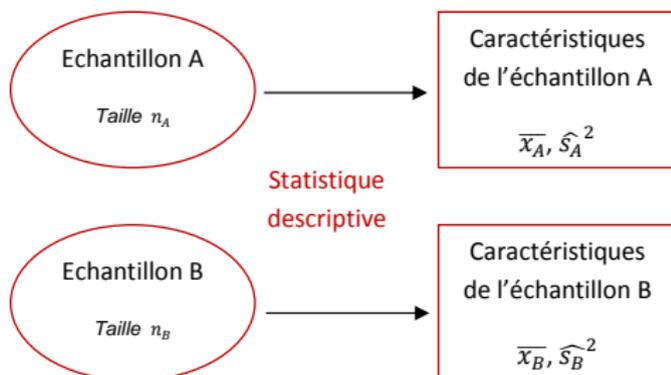
4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

Principe

On observe 2 échantillons A et B **indépendants**
(i.e. individus \neq dans les 2 groupes)



Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

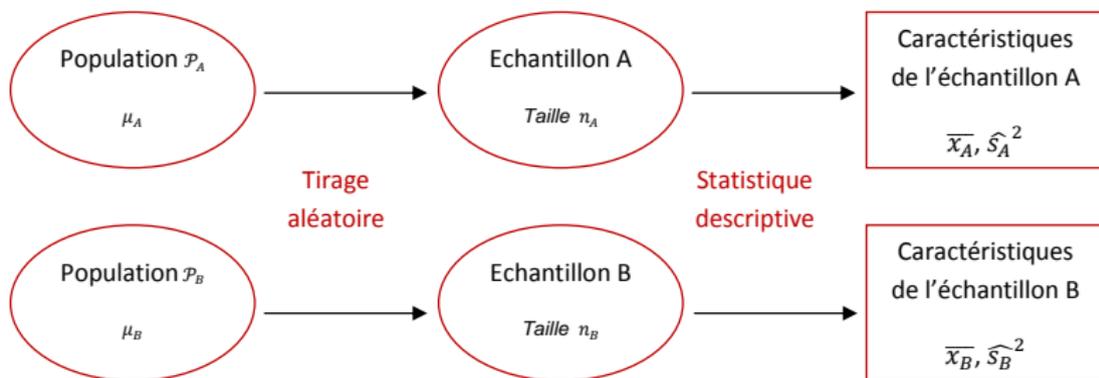
2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Raisonnement par l'absurde :

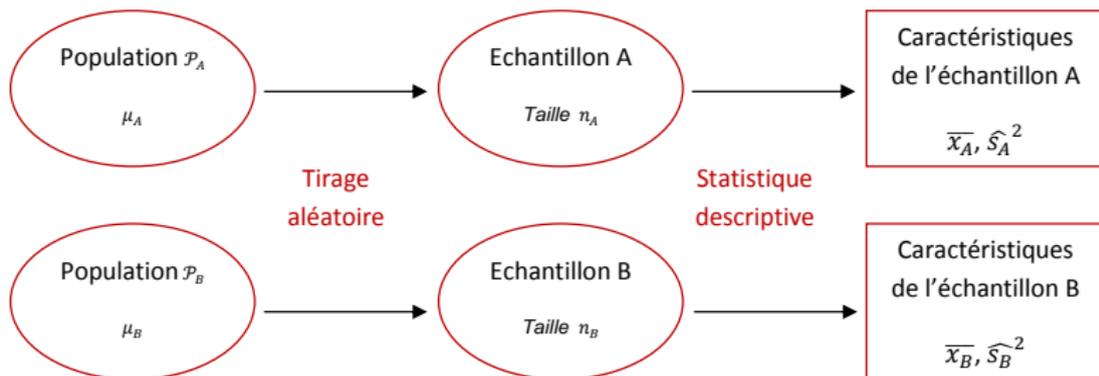


$$H_0: \mu_A = \mu_B \quad ?$$

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Comparaison de 2 moyennes

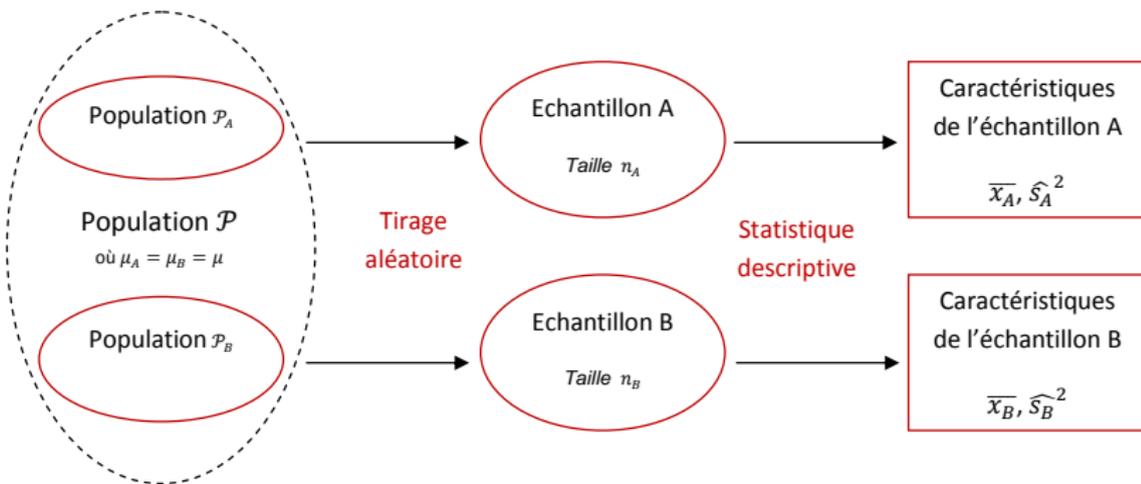
Si **rejet** de H_0 , alors les 2 échantillons semblent issus de 2 populations distinctes :



- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Comparaison de 2 moyennes

Si **non rejet** de H_0 , alors les 2 échantillons semblent issus d'une seule et même population :



- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Contexte

• Définition des variables aléatoires :

- X_A : v.a. continue dans la population \mathcal{P}_A de moyenne μ_A .

On observe un échantillon de taille n_A

$\{X_{A,1}, X_{A,2}, \dots, X_{A,n_A}\}$.

- X_B : v.a. continue dans la population \mathcal{P}_B de moyenne μ_B .

On observe un échantillon de taille n_B

$\{X_{B,1}, X_{B,2}, \dots, X_{B,n_B}\}$.

⇒ Test usuel :

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Contexte

- Définition des variables aléatoires :
 - X_A : v.a. continue dans la population \mathcal{P}_A de moyenne μ_A .

On observe un échantillon de taille n_A
 $\{X_{A,1}, X_{A,2}, \dots, X_{A,n_A}\}$.
 - X_B : v.a. continue dans la population \mathcal{P}_B de moyenne μ_B .

On observe un échantillon de taille n_B
 $\{X_{B,1}, X_{B,2}, \dots, X_{B,n_B}\}$.

⇒ Test usuel : **Test paramétrique de STUDENT**

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Test nécessitant des **effectifs de grandes tailles ($n \geq 30$)**
→ car théorème central limite valide
 - Test de Student avec des petits échantillons existe,
MAIS hypothèses à vérifier :
 - les 2 variables **distribuées selon une loi normale**
 - les variances des 2 variables **égales**
- ⇒ en générale **Manque de puissance** pour montrer les 2 propositions précédentes

⇒ **Solution :**

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Test nécessitant des **effectifs de grandes tailles ($n \geq 30$)**
→ car théorème central limite valide
 - Test de Student avec des petits échantillons existe,
MAIS hypothèses à vérifier :
 - les 2 variables **distribuées selon une loi normale**
 - les variances des 2 variables **égales**
- ⇒ en générale **Manque de puissance** pour montrer les 2 propositions précédentes
- ⇒ **Solution : TEST NON PARAMETRIQUE**

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

- Aucune hypothèse sur la distribution des v.a.
- Tests souvent basés sur la notion de rangs
→ si les distributions entre groupes sont \neq , les rangs sont \neq
- Exemple :
 - Groupe A (n=3) : 1, 5, 3
 - Groupe B (n=3) : 7, 6, 10
- Rangs :
 - Groupe A (n=3) : 1, 3, 2
 - Groupe B (n=3) : 5, 4, 6
- Sommes des rangs :
 - Groupe A (n=3) : 6
 - Groupe B (n=3) : 15

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

- **Tests paramétriques :**
 - exigent une spécification de la forme de la distribution
- **Tests non paramétriques :**
 - pas de référence à une répartition particulière
 - peuvent s'appliquer à des petits échantillons
- **Avantages/Inconvénients :**
 - tests non paramétriques théoriquement moins puissants que tests paramétriques
 - études ont montré : exactitude des tests non paramétriques sur des grands échantillons n'est que légèrement inférieure à celle des tests paramétriques
 - tests non paramétriques sont bcp plus exacts sur des petits échantillons

Comparaison de 2 moyennes :

Test non paramétrique de Mann-Whitney

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- permet de comparer la distribution de 2 v.a. observées à partir de 2 échantillons **indépendants** (A et B)
- Définition des v.a. :
 - X_A : v.a. continue dans le groupe A de taille n_A
 - X_B : v.a. continue dans le groupe B de taille n_B
- Par convention, on définit le groupe comme le plus petit échantillon ($n_A \leq n_B$)

- Choix des hypothèses
 - H_0 : X_A et X_B ont la même distribution
 - H_1 : X_A et X_B n'ont pas la même distribution
- Somme des rangs
 - R_A : somme des rangs occupés par les valeurs observées de X_A
 - R_B : somme des rangs occupés par les valeurs observées de X_B
- Si des ex-aequos entre des valeurs, on affecte la moyenne des rangs (si les ex-aequos sont du même groupe, rien ne change)

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- Statistique de test :

$$M = \min(M_A, M_B)$$

avec

$$M_A = n_A n_B + n_A(n_A + 1)/2 - R_A$$

et

$$M_B = n_A n_B - U_A = n_A n_B + n_B(n_B + 1)/2 - R_B$$

- Choix du seuil α (5%) et définition de la région critique :
2 cas de figure
 - $n_A \leq 10$
 - $n_A > 10$

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

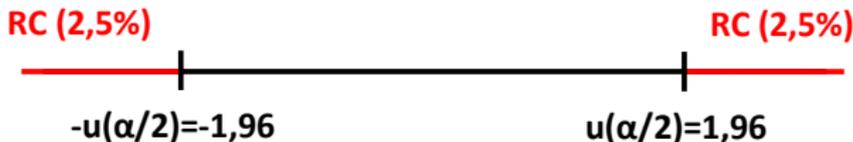
Comparaison de 2 moyennes : Test non paramétrique de Mann-Whitney

- Si $n > 10$, alors sous H_0 :

$$M \sim \mathcal{N}(n_A n_B / 2, \sqrt{n_A n_B (n_A + n_B + 1) / 12})$$

$$U = \frac{M - n_A n_B / 2}{\sqrt{n_A n_B (n_A + n_B + 1) / 12}} \sim \mathcal{N}(0, 1)$$

→ test bilatéral, loi normale



Introduction

Comparaison
 de moyennes

2 échantillons
 indépendants

+ de 2 échantillons
 indépendants

2 échantillons
 appariés

Comparaison
 de fréquences

2 échantillons
 indépendants

2 échantillons
 appariés

Corrélation
 linéaire

χ^2 d'indépen-
 dance

Conclusion

Comparaison de 2 moyennes :

Test non paramétrique de Mann-Whitney

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

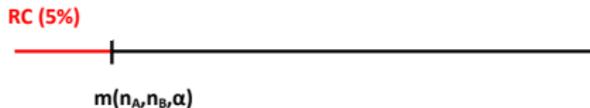
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Si $n \leq 10$, alors :



- Lecture dans la table de la valeur critique $m(n_A; n_B, \alpha)$

Comparaison de 2 moyennes : Test non paramétrique de Mann-Whitney

Critical Values of the Mann-Whitney U
 (Two-Tailed Testing)

n ₂	α	n ₁																			
		3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20		
3	.05	--	0	0	1	1	2	2	3	3	4	4	5	5	6	6	7	7	8		
	.01	--	0	0	0	0	0	0	0	0	1	1	1	2	2	2	3	3			
4	.05	--	0	1	2	3	4	4	5	6	7	8	9	10	11	11	12	13	14		
	.01	--	--	0	0	0	1	1	2	2	3	3	4	5	5	6	6	7	8		
5	.05	0	1	2	3	5	6	7	8	9	11	12	13	14	15	17	18	19	20		
	.01	--	--	0	1	1	2	3	4	5	6	7	7	8	9	10	11	12	13		
6	.05	1	2	3	5	6	8	10	11	13	14	16	17	19	21	22	24	25	27		
	.01	--	0	1	2	3	4	5	6	7	9	10	11	12	13	15	16	17	18		
7	.05	1	3	5	6	8	10	12	14	16	18	20	22	24	26	28	30	32	34		
	.01	--	0	1	3	4	6	7	9	10	12	13	15	16	18	19	21	22	24		
8	.05	2	4	6	8	10	13	15	17	19	22	24	26	29	31	34	36	38	41		
	.01	--	1	2	4	6	7	9	11	13	15	17	18	20	22	24	26	28	30		
9	.05	2	4	7	10	12	15	17	20	23	26	28	31	34	37	39	42	45	48		
	.01	0	1	3	5	7	9	11	13	16	18	20	22	24	27	29	31	33	36		
10	.05	3	5	8	11	14	17	20	23	26	29	33	36	39	42	45	48	52	55		
	.01	0	2	4	6	9	11	13	16	18	21	24	26	29	31	34	37	39	42		
11	.05	3	6	9	13	16	19	23	26	30	33	37	40	44	47	51	55	58	62		
	.01	0	2	5	7	10	13	16	18	21	24	27	30	33	36	39	42	45	48		
12	.05	4	7	11	14	18	22	26	29	33	37	41	45	49	53	57	61	65	69		
	.01	1	3	6	9	12	15	18	21	24	27	31	34	37	41	44	47	51	54		
13	.05	4	8	12	16	20	24	28	33	37	41	45	50	54	59	63	67	72	76		
	.01	1	3	7	10	13	17	20	24	27	31	34	38	42	45	49	53	56	60		
14	.05	5	9	13	17	22	26	31	36	40	45	50	55	59	64	67	74	78	83		
	.01	1	4	7	11	15	18	22	26	30	34	38	42	46	50	54	58	63	67		
15	.05	5	10	14	19	24	29	34	39	44	49	54	59	64	70	75	80	85	90		
	.01	2	5	8	12	16	20	24	29	33	37	42	46	51	55	60	64	69	73		
16	.05	6	11	15	21	26	31	37	42	47	53	59	64	70	75	81	86	92	98		
	.01	2	5	9	13	18	22	27	31	36	41	45	50	55	60	65	70	74	79		
17	.05	6	11	17	22	28	34	39	45	51	57	63	67	75	81	87	93	99	105		
	.01	2	6	10	15	19	24	29	34	39	44	49	54	60	65	70	75	81	86		
18	.05	7	12	18	24	30	36	42	48	55	61	67	74	80	86	93	99	106	112		
	.01	2	6	11	16	21	26	31	37	42	47	53	58	64	70	75	81	87	92		
19	.05	7	13	19	25	32	38	45	52	58	65	72	78	85	92	99	106	113	119		
	.01	3	7	12	17	22	28	33	39	45	51	56	63	69	74	81	87	93	99		
20	.05	8	14	20	27	34	41	48	55	62	69	76	83	90	98	105	112	119	127		
	.01	3	8	13	18	24	30	36	42	48	54	60	67	73	79	86	92	99	105		

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Si $u \in RC \rightarrow p < \alpha$:
 - Rejet de H_0 car moins de 5% de chances qu'elle soit vraie
 - Il semble que les 2 distributions soient différentes
- Si $u \notin RC \rightarrow p > \alpha$:
 - Non rejet de H_0 car plus de 5% de chances qu'elle soit vraie
 - On ne peut pas montrer que les 2 distributions soient différentes

- Remarques de vocabulaire :
 - Ce test est aussi appelé Mann-Withney/Wilcoxon
 - On peut aussi voir “test de Wilcoxon pour échantillons indépendants”
 - A éviter mais rencontré dans la littérature : “non-parametric t-test”
- Problèmes des faibles effectifs :
 - Du point de vue statistique :
 - Test possible à partir de 3 sujets par groupe
 - Du point de vue méthodologique :
 - Résultats très peu robustes : un sujet supplémentaire peut tout changer
 - Résultats très peu puissants : attention à l'interprétation du non-rejet de H_0

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- Des biologistes s'intéressent à l'effet d'un nouveau médicament en phase pré-clinique. Ils testent sur 5 souris le médicament de référence (médicament A) et sur 8 autres souris la nouvelle molécule (médicament B).
- 13 prélèvements sanguins sont réalisés. Les concentrations (en micro/L) obtenues sont présentées dans le tableau suivant :

Concentration								
Médicament A	25	12	7	9	18			
Médicament B	17	19	14	6	16	20	22	13

X_A : concentration du médicament A dans le sang
 X_B : concentration du médicament B dans le sang

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

On cherche à répondre à la question suivante :
“Les concentrations de médicament B dans le sang
sont-elles significativement différentes de celles du
médicament A ?” (risque d'erreur de 1^{ère} espèce fixé à
5%) ?

- Quel test statistique doit-on réaliser ?

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

On cherche à répondre à la question suivante :
“Les concentrations de médicament B dans le sang
sont-elles significativement différentes de celles du
médicament A ?” (risque d’erreur de 1ère espèce fixé à
5%) ?

- Quel test statistique doit-on réaliser ?

Test de Mann-Whitney pour **échantillons indépendants**

Conditions \Rightarrow échantillons de petites tailles ($n < 30$)

Test d’une $\neq \Rightarrow$ **test bilatéral**

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Quelle est l'hypothèse nulle H_0 de ce test ?
- Quelle est l'hypothèse alternative H_1 de ce test ?

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Quelle est l'hypothèse nulle H_0 de ce test ?
- Quelle est l'hypothèse alternative H_1 de ce test ?

H_0 : les distributions des concentrations dans le sang des médicaments A et B sont identiques, autrement dit X_A et X_B ont la même distribution

H_1 : les distributions issues des 2 concentrations des 2 médicaments ne sont pas identiques, c'est-à-dire que X_A et X_B n'ont pas la même distribution

Introduction

Comparaison de moyennes

2 échantillons indépendants
 + de 2 échantillons indépendants
 2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants
 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Remarque : on exclue les valeurs nulles

Rang								
Médicament A	13	4	2	3	9			
Médicament B	8	10	6	1	7	11	12	5

- Somme des rangs $R_A = 31$
 - Somme des rangs $R_B = 60$
- ⇒ Statistique de test

$$M = \min(5 * 8 + 5 * 6/2 - 31, 3 * 3 + 3 * 4/2 - 12)$$

$$= \min(24, 16) = 16$$

$n_A = 5 < 10 \Rightarrow$ on lit dans la table la valeur critique définissant la région critique.

Au seuil $\alpha = 0.05$, pour $n_A = 5$ et $n_B = 8$, on a pour valeur critique la valeur 6

$M \notin$ à la région critique

\Rightarrow Non Rejet H_0 au risque 5% de se tromper

Nous n'avons pas pu mettre en évidence une différence significative entre les distributions des concentrations de médicaments A et B.

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

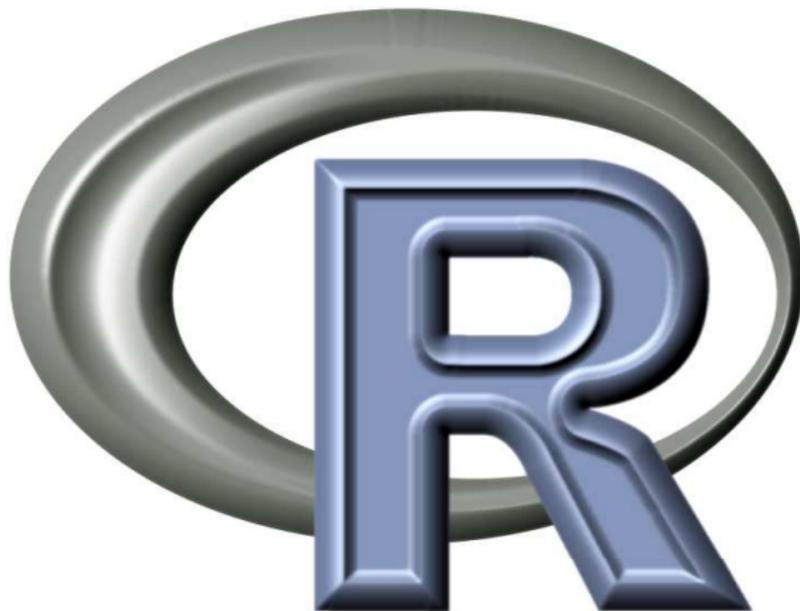
Corrélation linéaire

χ^2 d'indépendance

Conclusion



<http://www.r-project.org/>



- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Comparaison de 2 moyennes :

Exemple sous Rcmdr

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

The screenshot shows the R Commander application window. The menu bar includes 'Fichier', 'Edition', 'Données', 'Statistiques', 'Graphes', 'Modèles', 'Distributions', 'Outils', and 'Aide'. The 'Données' menu is open, showing options: 'Nouveau jeu de données...', 'Charger un jeu de données...', 'Fusionner des jeux de données...', 'Importer des données', 'Données dans les paquets', 'Jeu de données actif', and 'Gérer les variables du jeu de données actif'. The 'Importer des données' option is selected, opening a sub-menu with the following options: 'depuis un fichier texte, le presse-papier ou une URL...', 'depuis des données SPSS.', 'depuis un fichier SAS xport...', 'depuis des données Minitab...', 'depuis des données STATA...', and 'depuis un fichier Excel, Access ou dBase...'. The main workspace is empty, and the 'Sortie' window is visible at the bottom.

Comparaison de 2 moyennes :

Exemple sous Rcmdr

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

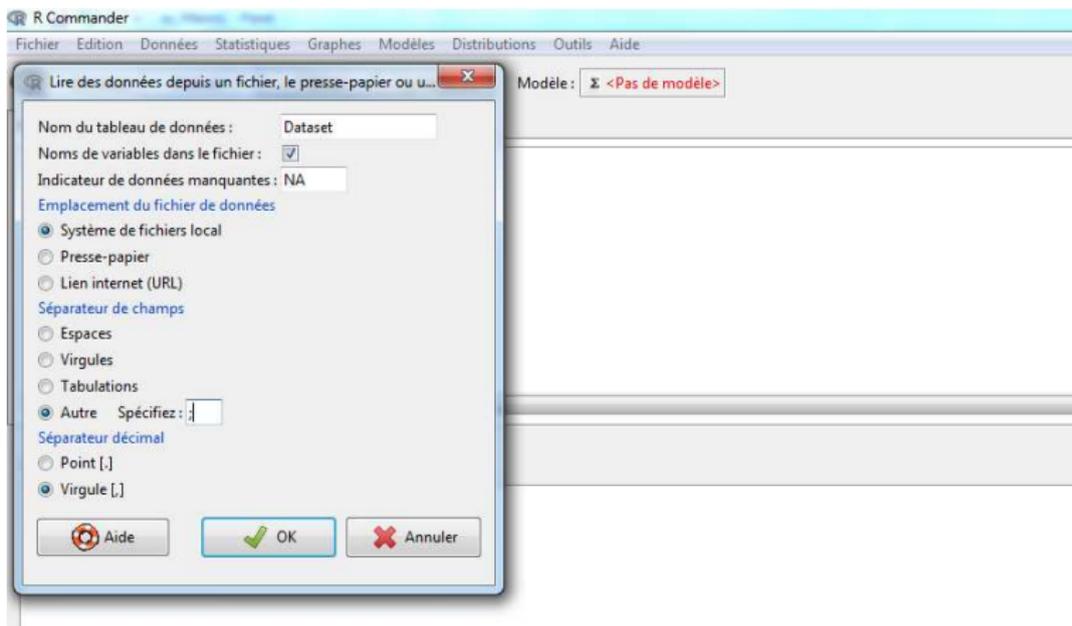
2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion



Comparaison de 2 moyennes :

Exemple sous Rcmdr

Introduction

Comparaison
de moyennes2 échantillons
indépendants+ de 2 échantillons
indépendants2 échantillons
appariésComparaison
de fréquences2 échantillons
indépendants2 échantillons
appariésCorrélation
linéaire χ^2 d'indépen-
dence

Conclusion

The screenshot shows the R Commander interface. The script editor contains the following R code:

```
showData(Dataset, placement='-20+200', font=getRcmdr('logFont'), maxwidth=80, maxheight=30)
```

The output window shows the result of the command:

```
> showData(Dataset, placement='-20+200', font=getRcmdr('logFont'), maxwidth=80, maxheight=30)
```

	Concentration	Groupe
1	25	A
2	12	A
3	7	A
4	9	A
5	18	A
6	17	B
7	19	B
8	14	B
9	6	B
10	16	B
11	20	B
12	22	B
13	13	B

Comparaison de 2 moyennes :

Exemple sous Rcmdr

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

The screenshot shows the R Commander interface. The 'Statistiques' menu is open, and 'Tests non paramétriques' is selected. A submenu is displayed with the following options:

- Test Wilcoxon bivarié...
- Test Wilcoxon apparié...
- Test Kruskal-Wallis...
- Test de somme des rangs de Friedman

The main window shows the following code in the script editor:

```
showData(Dataset, placement='-20+200', font=getRcmdr('logFont'), maxwidth=80, maxheight=30)
```

The 'Sortie' window shows the output of the command:

```
> showData(Dataset, placement='-20+200', font=getRcmdr('logFont'), maxwidth=80, maxheight=30)
```

Comparaison de 2 moyennes :

Exemple sous Rcmdr

Introduction

Comparaison
de moyennes2 échantillons
indépendants+ de 2 échantillons
indépendants2 échantillons
appariésComparaison
de fréquences2 échantillons
indépendants2 échantillons
appariésCorrélation
linéaire χ^2 d'indépen-
dance

Conclusion

R Commander

Fichier Édition Données Statistiques Graphes Modèles Distributions Outils Aide

Test de Wilcoxon bivarié

Données Options

Groupes (un) Variable réponse (une)

Groupe Concentration

Aide Réinitialiser OK Annuler Appliquer

maxheight=30)

Sortie

```
> showData(Dataset, placement='-20+200', font=getRcmdr('logFont'), maxwidth=80, maxheight=30)
> tapply(Dataset$Concentration, Dataset$Groupe, median, na.rm=TRUE)
  A  B
12.0 16.5
> wilcox.test(Concentration ~ Groupe, alternative="two.sided", data=Dataset)

      Wilcoxon rank sum test

data: Concentration by Groupe
W = 16, p-value = 0.6216
alternative hypothesis: true location shift is not equal to 0
```

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- Comparaison de 2 moyennes pour échantillons indépendants
⇒ Test de Student, tests non paramétrique
- Comparaison de k moyennes (2 ou plus) simultanément pour échantillons indépendants
⇒ Analyse de la Variance (ANOVA)

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Généralisation du test de Student
- Tester avec un seul test paramétrique si toutes les moyennes sont issues de la même population
- H_0 : les échantillons (groupes) proviennent de la même population
 - \Leftrightarrow Variabilité de l'ensemble uniquement conditionnée par les fluctuations d'échantillonnage
 - $\Leftrightarrow H_0 : \mu_1 = \mu_2 = \dots = \mu_k$
- H_1 : au moins 2 moyennes diffèrent entre elles

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

- Objectif de l'ANOVA

- Décomposer la variabilité totale des données quantitatives (disposée en k groupes)

⇒ Différentes sources de variabilité :

- fluctuations individuelles (variabilité intra-groupe)
- fluctuations entre les groupes (variabilité inter-groupe)

- Idée générale

Si **variabilité inter-groupe** > **variabilité intra-groupe**

⇒ 2 moyennes au moins \neq

⇒ Comparaison de variances

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Données observées :

Facteur	Groupe 1	Groupe 2	...	Groupe k
Effectif	n_1	n_2	...	n_k
Mesure	X_{11}	X_{12}	...	X_{1k}
Mesure	X_{21}	X_{22}	...	X_{2k}
Mesure
Mesure	$X_{n_1 1}$	$X_{n_2 2}$...	$X_{n_k k}$
Moyennes	\bar{X}_1	\bar{X}_2	...	\bar{X}_k

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Limites

- Conditions de validité de l'ANOVA

- critère d'intérêt (variable dépendante) quantitative
- indépendance des observations
- normalité du critère dans chaque groupe
- homoscédasticité : homogénéité des variances

- Si conditions non vérifiées

- ANOVA robuste à une certaine **hétéroscédasticité** (variance homogène)
- ANOVA robuste face à une certaine **asymétrie** ou **applatissage** des distributions

- Mais en cas de non respect majeur de la normalité
- ⇒ Transformation des données : $\log(x_{ij}), \sqrt{x_{ij}}, \frac{1}{x_{ij}}, \dots$
- ⇒ ANOVA non paramétrique : test de Kruskal-Wallis
- Mais en cas de non indépendance des résidus
- ⇒ changer de modèle

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Comparaison de K populations (**2 ou plus**)
simultanément pour échantillons indépendants
- Les fonctions de répartition $F_k(X)$ sont-elles toutes
identiques ?
 - $H_0 : F_1(X) = \dots = F_k(X) = \dots = F_K(X)$
 - $H_1 : \text{au moins 1 distribution est différente des autres}$

- Généralisation à K populations du test de la somme des rangs de Wilcoxon-Mann-Withney bilatéral
- Alternative non paramétrique à l'ANOVA quand v.a. **non gaussienne**

⇒ Statistique de test de Kruskal-Wallis :

$$H = \frac{12}{n(n+1)} \sum_{k=1}^K n_k (\bar{r}_k - \bar{r})^2$$

\bar{r} : moyenne globale des rangs

\bar{r}_k : moyenne des rangs pour le groupe k

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- ⇒ Expression d'une variabilité inter-classe
⇔ dispersion des moyennes conditionnelles autour de la moyenne globale
- $H \geq 0$
 - si H_0 vérifiée, moyennes conditionnelles des rangs proches de la moyenne globale
↔ H proche de 0
 - si H_1 vérifiée, H s'écarte de 0

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

- si effectifs élevés ($n_k \geq 5, \forall k$), alors sous $H_0, H \sim \chi_{K-1}^2$
- Région critique : $H \geq \chi_{K-1}^2$
- Traitement des ex-aequo

$$\tilde{H} = \frac{H}{1 - \frac{\sum_{g=1}^G (t_g^3 - t_g)}{n^3 - n}}$$

G : nombre de valeurs distinctes ($G \leq n$)
 t_g : nombre de valeurs pour la valeur n^o

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- On souhaite comparer trois médicaments (A, B et C) contre les maux de têtes. La molécule C est aujourd'hui la référence sur le marché.
- 15 patients venants aux urgences pour des migraines sont traités par une des 3 molécules. Sur une échelle de 0 à 20, on demande aux patients d'évaluer leur douleur après que le médicament soit administré.

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Les résultats ont été rassemblés dans le tableau ci-dessous.

Molécule A	3	5	6	3	4
Molécule B	10	8	5	7	5
Molécule C	13	11	7	11	8

⇒ **Existe-t-il une différence d'efficacité entre les 3 molécules ?**

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

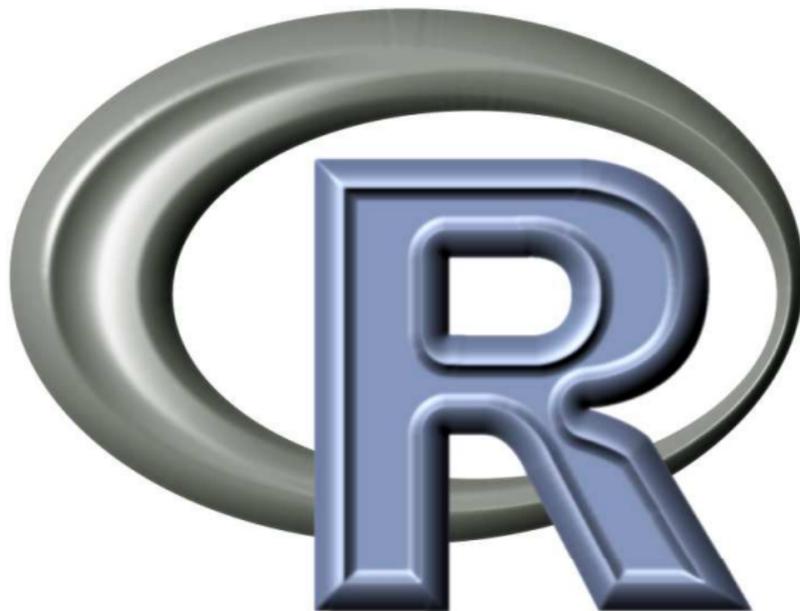
H_0 : “Il n’y a pas de différence entre les distributions de scores de douleur des 3 groupes.”

$$\Leftrightarrow H_0 : F_A = F_B = F_C$$

H_1 : “Il y a au moins un score dans l’un des groupes dont la distribution diffère de celle des 2 autres.”



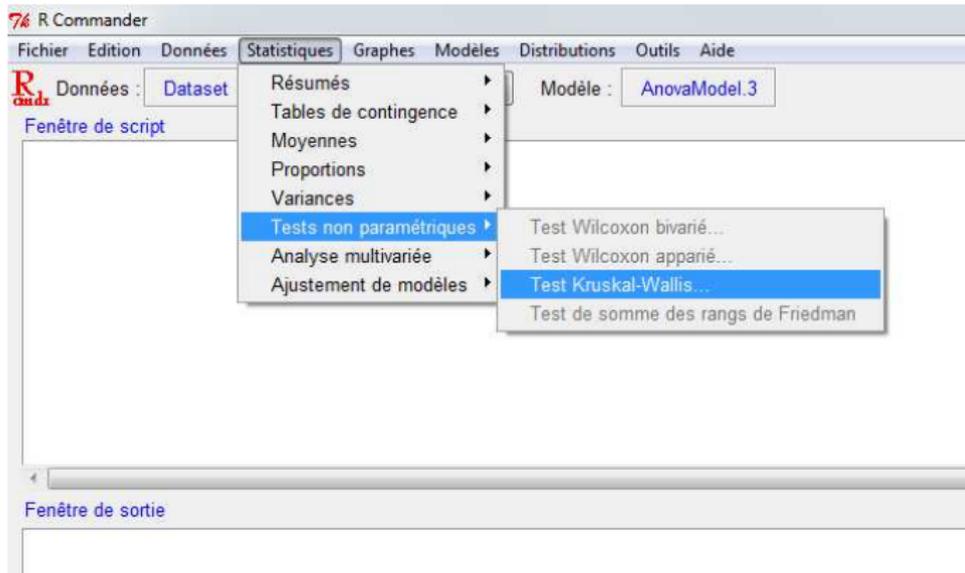
<http://www.r-project.org/>



- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Exemple (1) sous Rcmdr

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion



Exemple (2) sous Rcmdr

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

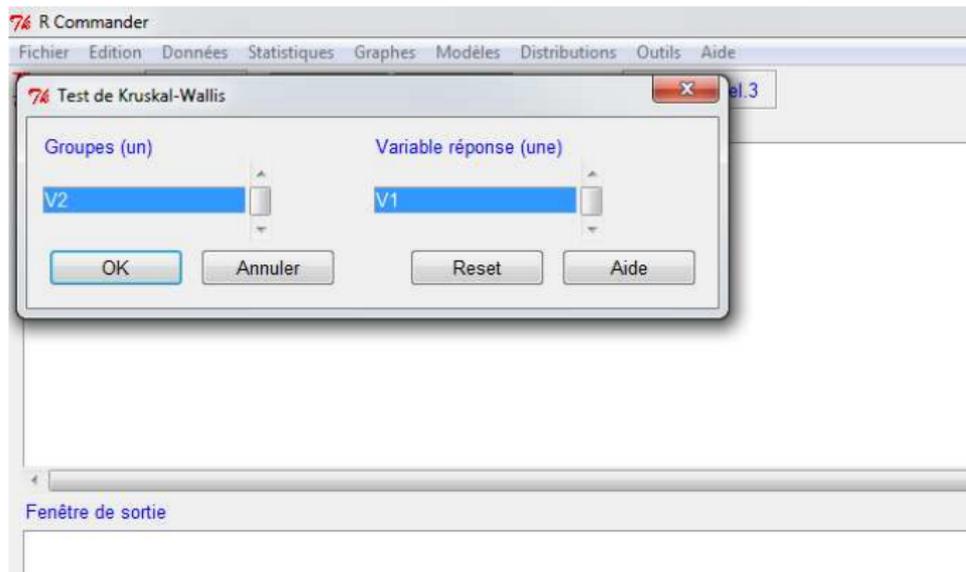
2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion



```

Fenêtre de sortie

> tapply(Dataset$V1, Dataset$V2, median, na.rm=TRUE)
 1  2  3
 4  7 11

> kruskal.test(V1 ~ V2, data=Dataset)

      Kruskal-Wallis rank sum test

data:  V1 by V2
Kruskal-Wallis chi-squared = 9.3942, df = 2, p-value = 0.009122
    
```

$$H = 9.39 > 5.99 = \chi_{2,ddl}^2 (p_c < 0.05) \Rightarrow \text{Rejet de } H_0$$

Au seuil $\alpha = 0.05$, il semble qu'il y ait au moins deux molécules entraînant un score moyen de douleur qui soit différent.

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

L'échantillon A n'est pas indépendant de l'échantillon B

Echantillons dépendants (ou appariés, ou liés)

- observations obtenues chez les mêmes individus
patient est son propre "témoin"
ex : Etude avant/après (douleur avant et après la prise d'un antalgique)
ex : Etude Cas/Témoin (deux pommades sur une même peau)
- observations obtenues chez des individus \neq présentant des caractéristiques similaires
ex : Etude Cas/Témoin (appariement sur les facteurs de risque)
ex : Etude en cluster (deux souris d'une même litière, deux jumeaux, etc.)

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Intérêt de l'appariement

- contrôler la variabilité inter-individuelle

↘ variabilité inter-individuelle

⇒ ↘ variabilité totale (σ ↘)

⇒ augmenter la puissance statistique dans la
comparaison

⇒ **Test statistique approprié** qui tient compte de
l'appariement des observations

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Contexte

- On observe 2 échantillons dépendants A et B de même taille $n = n_A = n_B$
- On définit le couple (X_A, X_B) pour chaque sujet/paire
- Définition de la variable aléatoire $D = X_A - X_B$: v.a. continue de moyenne μ_D .
- On observe un échantillon de taille $n \{d_1, d_2, \dots, d_n\}$.

Remarque : cf. les tests de comparaison d'une moyenne observée à une valeur de référence.

⇒ Test usuel :

Contexte

- On observe 2 échantillons dépendants A et B de même taille $n = n_A = n_B$
- On définit le couple (X_A, X_B) pour chaque sujet/paire
- Définition de la variable aléatoire $D = X_A - X_B$: v.a. continue de moyenne μ_D .
- On observe un échantillon de taille $n \{d_1, d_2, \dots, d_n\}$.

Remarque : cf. les tests de comparaison d'une moyenne observée à une valeur de référence.

⇒ Test usuel : Test paramétrique de STUDENT

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Test nécessitant des **effectifs de grandes tailles ($n \geq 30$)**
→ car théorème central limite valide

⇒ **Solution :**

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Test nécessitant des **effectifs de grandes tailles ($n \geq 30$)**
→ car théorème central limite valide

⇒ **Solution : TEST NON PARAMETRIQUE**

Comparaison de 2 moyennes

Test de Wilcoxon pour données appariées

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Permet de comparer la distribution de 2 v.a. observées à partir de 2 échantillons **appariés** (A et B)
- Définition des v.a. (n sujets par groupe)
 - (X_A, X_B) : v.a. observées pour chaque paire
 - $X = X_A - X_B$: différence pour chaque paire
- Choix des hypothèses
 - H_0 : X_A et X_B ont la même distribution
 - H_1 : X_A et X_B n'ont pas la même distribution

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Principe des rangs : classement des valeurs absolues $|X|$ en excluant les valeurs nulles et en notant le signe de la différence
- Soit k le nombre de différence non nulles
- Somme des rangs
 - $R(-)$: somme des rangs occupés par les différences négatives
 - $R(+)$: somme des rangs occupés par les différences positives
- si des ex-aequo entre des valeurs, on affecte la moyenne des rangs

Comparaison de 2 moyennes

Test de Wilcoxon pour données appariées

- Statistique de test :

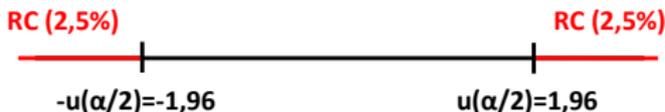
$$W = \min(R(+), R(-))$$

- Choix du seuil α (5%) et définition de la région critique
- Si $n > 20$, alors sous H_0 :

$$W \sim \mathcal{N}(n(n+1)/4, \sqrt{n(n+1)(2n+1)/24})$$

$$U = \frac{W - n(n+1)/4}{\sqrt{n(n+1)(2n+1)/24}} \sim \mathcal{N}(0, 1)$$

- test bilatéral, loi normale



Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

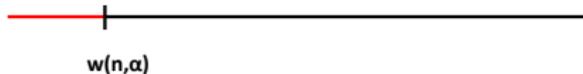
Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Si $n \leq 20$, lecture dans la table :

RC (5%)



Comparaison de 2 moyennes

Test de Wilcoxon pour données appariées

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Critical Values of the Wilcoxon Signed Ranks Test

n	Two-Tailed Test		One-Tailed Test	
	$\alpha = .05$	$\alpha = .01$	$\alpha = .05$	$\alpha = .01$
5	--	--	0	--
6	0	--	2	--
7	2	--	3	0
8	3	0	5	1
9	5	1	8	3
10	8	3	10	5
11	10	5	13	7
12	13	7	17	9
13	17	9	21	12
14	21	12	25	15
15	25	15	30	19
16	29	19	35	23
17	34	23	41	27
18	40	27	47	32
19	46	32	53	37
20	52	37	60	43
21	58	42	67	49
22	65	48	75	55
23	73	54	83	62
24	81	61	91	69
25	89	68	100	76
26	98	75	110	84
27	107	83	119	92
28	116	91	130	101
29	126	100	140	110
30	137	109	151	120

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Si $u \in RC \rightarrow p < \alpha$:
 - Rejet de H_0 car moins de 5% de chances qu'elle soit vraie
 - Il semble que les 2 distributions soient différentes
- Si $u \notin RC \rightarrow p > \alpha$:
 - Non rejet de H_0 car plus de 5% de chances qu'elle soit vraie
 - On ne peut pas montrer que les 2 distributions soient différentes

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Des chimistes ont mis au point une nouvelle méthode de mesure de concentration d'un toxique dans le sang. A partir de 12 prélèvements sanguins divisés en deux tubes, la nouvelle méthode (A) est comparée avec la méthode existante (B).
- Les concentrations obtenues sont présentées dans le tableau suivant :

Numéro tube	1	2	3	4	5	6	7	8	9	10	11	12
Méthode A	55	25	21	7	16	14	7	9	5	4	4	1
Méthode B	17	17	14	11	10	9	8	5	3	2	1	0

X_A et X_B : concentrations de toxiques sur les 12 prélèvements obtenus respectivement à l'aide des méthodes A et B

$X = X_A - X_B$: différence de chacune des paires.

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

On cherche à répondre à la question suivante :

“Les concentrations de toxique obtenues avec la nouvelle méthode sont telles significativement différente de celles obtenues avec la méthode de référence ?” (risque d’erreur de 1^{ère} espèce fixé à 5%) ?

- Quel test statistique doit-on réaliser ?

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

On cherche à répondre à la question suivante :
“Les concentrations de toxique obtenues avec la nouvelle méthode sont telles significativement différente de celles obtenues avec la méthode de référence ?” (risque d’erreur de 1ère espèce fixé à 5%) ?

- Quel test statistique doit-on réaliser ?

Test de Wilcoxon pour **données appariées**

Conditions \Rightarrow échantillons de petites tailles ($n < 30$)

Test d’une $\neq \Rightarrow$ **test bilatéral**

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Quelle est l'hypothèse nulle H_0 de ce test ?
- Quelle est l'hypothèse alternative H_1 de ce test ?

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Quelle est l'hypothèse nulle H_0 de ce test ?
- Quelle est l'hypothèse alternative H_1 de ce test ?

H_0 : les distributions issues des 2 méthodes de prélèvements sont identiques, autrement dit X_A et X_B ont la même distribution

H_1 : les distributions issues des 2 méthodes de prélèvements ne sont pas identiques, c'est-à-dire que X_A et X_B n'ont pas la même distribution

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

On travaille sur les valeurs absolues des rangs
 Remarque : on exclue les valeurs nulles

Numéro tube	1	2	3	4	5	6	7	8	9	10	11	12
δ Méthode A - Méthode B	38	8	7	-4	6	5	-1	4	2	2	3	1
Rang	12	11	10	6.5	9	8	1.5	6.5	3	4	5	1.5

Rang négatif	1.5	6.5										
Rang positif	12	11	10	9	8	6.5	3	4	5	1.5		

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

La statistique de test est définie de la manière suivante :

$$W = \min(R(-), R(+))$$

$R(-)$: \sum des rangs occupées par les différences négatives

$R(+)$: \sum des rangs occupées par les différences positives

En pratique, on a donc :

$$R_- = 1.5 + 6.5 = 8$$

$$R_+ = 12 + 11 + 10 + 9 + 8 + 6.5 + 3 + 4 + 5 + 1.5 = 70$$

$$\Rightarrow W = 8$$

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

$n = 12 < 20 \Rightarrow$ on lit dans la table la valeur critique définissant la région critique.

Au seuil $\alpha = 0.05$, pour $n = 12$, on a pour valeur critique la valeur 13 (pour un test bilatéral)

$W \in$ à la région critique

\Rightarrow Rejet H_0 au risque 5% de se tromper

Il semble donc y avoir une différence significative entre les distributions des concentrations de toxiques issues de la méthode A et de la méthode B.



<http://www.r-project.org/>



- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Comparaison de 2 moyennes

Exemple pour données appariées sous Rcmdr

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

The screenshot shows the R Commander interface. The 'Statistiques' menu is open, and the 'Tests non paramétriques' option is selected. A sub-menu is displayed, showing the following options: 'Test Wilcoxon bivarié...', 'Test Wilcoxon apparié...' (highlighted), 'Test Kruskal-Wallis...', and 'Test de somme des rangs de Friedman'. The 'Données' field shows 'TT Data' and the 'Modèle' field shows '<Pas de modèle>'. The 'Script R' field shows 'R.Markdown'.

Comparaison de 2 moyennes

Exemple pour données appariées sous Rcmdr

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

R Commander

Fichier Edition Données Statistiques Graphes Modèles Distributions Outils Aide

Test Wilcoxon apparié

Données Options

Première variable (une)	Seconde variable (une)
MethodeA	MethodeA
MethodeB	MethodeB

Aide Réinitialiser OK Annuler Appliquer

Sortie

Comparaison de 2 moyennes

Exemple pour données appariées sous Rcmdr

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

R Commander

Fichier Edition Données Statistiques Graphes Modèles Distributions Outils Aide

Données: Dataset Éditer Visualiser Modèle: <Pas de modèle>

Script R R Markdown

```
median(Dataset$MethodeB - Dataset$MethodeA, na.rm=TRUE) # median difference
wilcox.test(Dataset$MethodeB, Dataset$MethodeA, alternative='two.sided', paired=TRUE)
```

Sortie

```
> median(Dataset$MethodeB - Dataset$MethodeA, na.rm=TRUE) # median difference
[1] -3.5

> wilcox.test(Dataset$MethodeB, Dataset$MethodeA, alternative='two.sided', paired=TRUE)

      Wilcoxon signed rank test with continuity correction

data: Dataset$MethodeB and Dataset$MethodeA
V = 8, p-value = 0.0166
alternative hypothesis: true location shift is not equal to 0
```

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Test paramétrique de Student

pour la comparaison de 2 fréquences observées
(expression incorrecte !!)

\iff pour la comparaison d'une fréquence théorique issue d'une population représentée par un échantillon observé à une fréquence théorique issue d'une autre population représentée par un autre échantillon

Comparaison de 2 fréquences :

Test paramétrique de Student

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

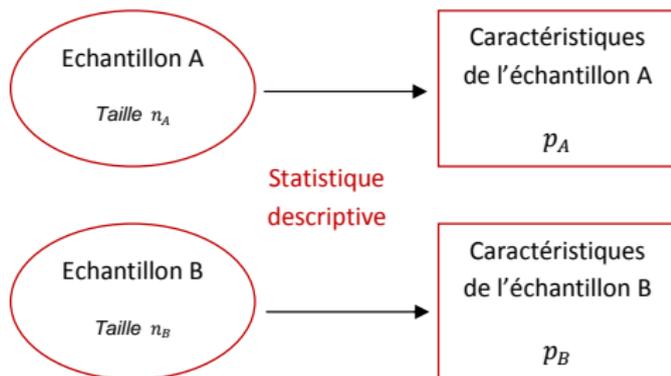
2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

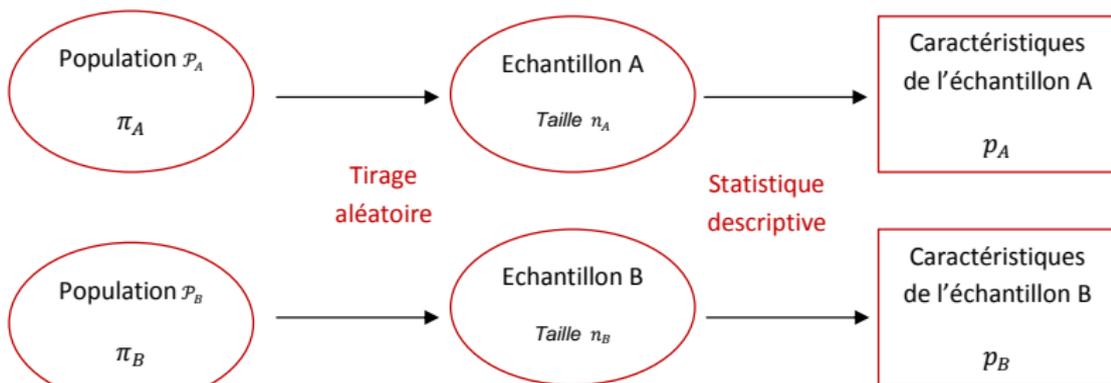
Conclusion



Comparaison de 2 fréquences :

Test paramétrique de Student

avec $n_A > 30$ et $n_B > 30$
 et $n_A p_A > 5$, $n_A(1 - p_A) > 5$, $n_B p_B > 5$, $n_B(1 - p_B) > 5$



$$H_0: \pi_A = \pi_B = \pi$$

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

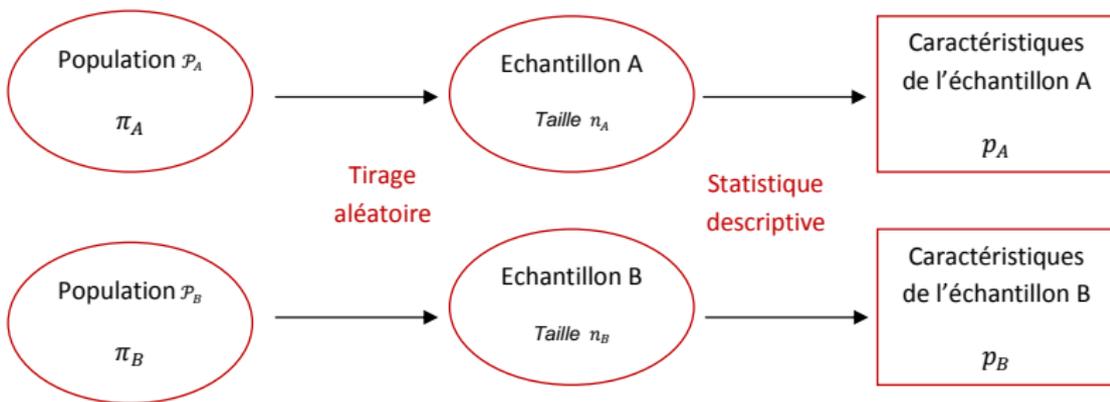
- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Conclusion

- non rejet de H_0 : la différence entre π_A et π_B semble due aux fluctuations d'échantillonnage, i.e. échantillons A et B semblent représentatifs de la population P
 - rejet de H_0 : la différence entre π_A et π_B n'est pas due au hasard, i.e. échantillons A et B semblent représentatifs de 2 populations distinctes
- ⇒ **attention** : il existe **toujours** une probabilité de se tromper
- α : probabilité de se tromper en rejetant H_0
 - β : probabilité de se tromper en ne rejetant pas H_0 , i.e. en rejetant H_1

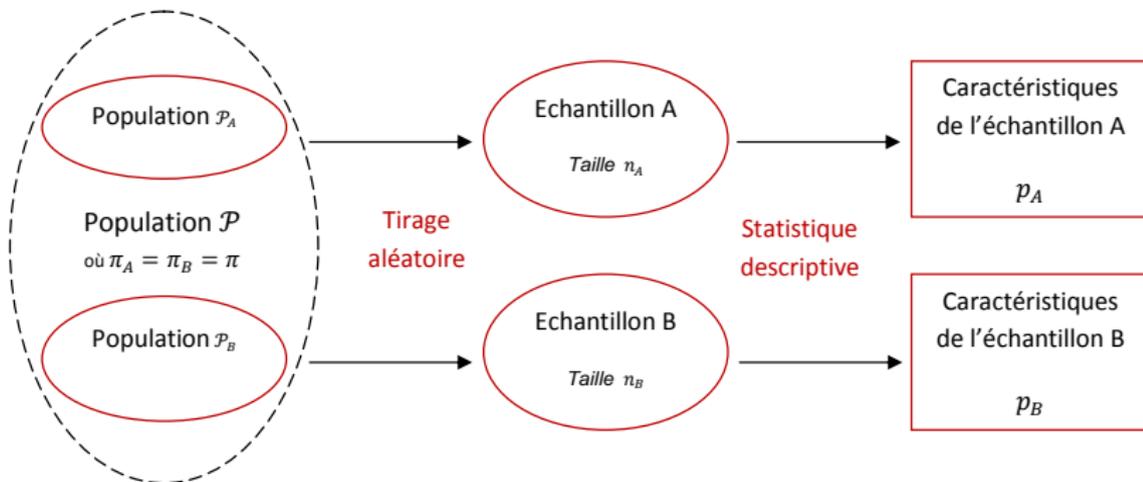
- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Non rejet de H_0 au risque de 1^{ère} espèce α



- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Rejet de H_0 au risque de 1^{ère} espèce α



Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Philosophie similaire à celle d'un test paramétrique de Student pour comparaison de 2 moyennes
- Non présenté car Test du χ^2 plus intéressant !
- Problème quand les effectifs sont petits
 - Aucune hypothèse possible
 - Solution : calcul exact de la probabilité critique

- Adapté aux petits échantillons
- Principe : calculer exactement la probabilité critique p (probabilité d'obtenir des échantillons au moins aussi éloignés de H_0 que celui qui est observé)
- Mise en oeuvre et raisonnement repose sur la **loi hypergéométrique**
- Peut nécessiter des combinaisons de calculs très nombreuses en fonction du nombre de modalités comparées
⇒ **2 modalités (succès/échec)**

Loi hypergéométrique

Epreuve aléatoire
de Bernouilli

S (succès) : $\Pr(S) = p, 0 \leq p \leq 1$

E (échec) : $\Pr(E) = 1 - p = q, 0 \leq q \leq 1$

Si n répétitions **non indépendantes** de l'épreuve,

et R : v.a. caractérisant le nombre de succès,

$$R \sim H(N, n, p)$$

Taille de la
population

Nb de
répétitions

Probabilité
de succès

Exemple :

-tirage **sans remise** dans un lot de **taille finie N**

→ Contenu de la population est **modifié à chaque tirage** → il n'y a plus indépendance

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

On observe :

	Modalité 1	Modalité 2	Total
Groupe 1	a	b	a+b
Groupe 2	c	d	c+d
Total	a+c	b+d	N

Probabilité d'obtenir cette configuration : p

$$p(obs) = \frac{C_{a+c}^a C_{b+d}^b}{C_N^{a+b}} = \frac{(a+b)!(c+d)!(a+c)!(b+d)!}{a!b!c!d!N!}$$

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- De la même manière, on calcule toutes les probabilités p_i pour tous les échantillons i encore plus éloignés de H_0 que l'échantillon observé,
- c'est-à-dire les tableaux composés des effectifs a', b', c', d' tels que

$$\left| \frac{a'}{a' + c'} - \frac{b'}{b' + d'} \right| \geq \left| \frac{a}{a + c} - \frac{b}{b + d} \right|$$

- Calcul de la probabilité critique :

$$p = p(\text{obs}) + \sum_i p_i$$

Un peu de discussion...

Attention à la **surinterprétation** des résultats...
surtout dans le cas de **petits échantillons**

⇒ le risque α existe et $\alpha \neq 0$

Conclusion statistique

- Si $p_c < \alpha$.
 - Rejet de H_0 car moins de α % de chance qu'elle soit vraie.
- Si $p_c > \alpha$.
 - Non rejet de H_0 car plus de α % de chance qu'elle soit vraie.

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Conclusion épidémiologique

- Si Rejet de H_0 ,
 - cas bilatéral : Il semble que les 2 proportions théoriques π_A et π_B soient significativement différente.
 - cas unilatéral : Il semble que la proportion théorique π_A soit significativement inférieure (supérieure) à la proportion théorique π_B
- Si Non rejet de H_0
 - cas bilatéral et unilatéral : On ne peut pas exclure le fait que les 2 échantillons soient issus de la même population.

Cas unilatéral

- stratégie identique mais on ne compte que les échantillons i encore plus éloignés de H_0 mais que d'un seul côté

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Comparaison de 2 traitements A et B contre infection nosocomiale
⇒ proportions de patients infectés
- Hypothèses :
 $H_0 : \pi_A = \pi_B = \pi$
 $H_1 : \pi_A \neq \pi_B$
- Etude pilote : N=16 patients
 - 7 patients dans le groupe A
 - 9 patients dans le groupe B

On observe :

	Infectés	Non infectés	Total
Groupe A	6	1	7
Groupe B	2	7	9
Total	8	8	16

Idée

Calculer sous H_0 la probabilité (exacte) d'obtenir un écart entre les groupes \geq à celui observé en conservant les mêmes totaux (lignes et colonnes)

\Rightarrow **Probabilité critique de Fisher** : somme de ces probabilités

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

On observe :

	Infectés	Non infectés	Total
Groupe A	6	1	7
Groupe B	2	7	9
Total	8	8	16

1 seule autre possibilité avec les mêmes totaux

	Infectés	Non infectés	Total
Groupe A	7	0	7
Groupe B	1	8	9
Total	8	8	16

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

On observe :

	Infectés	Non infectés	Total
Groupe A	6	1	7
Groupe B	2	7	9
Total	8	8	16

Probabilité d'obtenir cette configuration : p_1

$$p_1 = \frac{7!9!8!8!}{6!1!2!7!16!}$$

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Seconde configuration avec même totaux mais des écarts entre les groupes supérieurs à ce qu'on observe

	Infectés	Non infectés	Total
Groupe A	7	0	7
Groupe B	1	8	9
Total	8	8	16

Probabilité d'obtenir cette configuration : p_2

$$p_2 = \frac{7!9!8!8!}{7!0!1!8!16!}$$

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

⇒ Probabilité d'avoir l'une ou l'autre des configurations possibles :

$$p = p_1 + p_2 = \frac{7!9!8!8!}{6!1!2!7!16!} + \frac{7!9!8!8!}{7!0!1!8!16!} \approx 0.0203$$

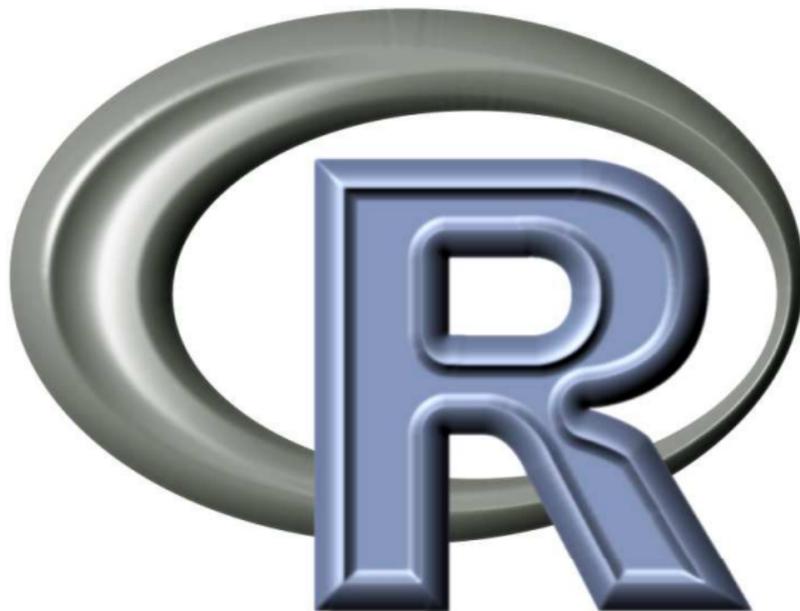
- ici, hypothèse **bilatérale** ⇒ écart doit être envisagé dans les 2 sens ⇒ probabilité critique de Fisher

$$p_c = 2 * p = 0.0406 < 0.05$$

⇒ Rejet de H_0 au seuil $\alpha = 5\%$



<http://www.r-project.org/>



Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

Comparaison de 2 fréquences

Exemple sous Rcmdr

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

The screenshot shows the R Commander interface. The 'Statistiques' menu is open, and the option 'Remplir et analyser un tri croisé...' is highlighted. The menu items are: Résumés, Tables de contingence, Moyennes, Proportions, Variances, Tests non paramétriques, Analyse multivariée, and Ajustement de modèles. The 'Tables de contingence' sub-menu is also open, showing 'Tri croisé...', 'Tri croisé de plusieurs variables...', and 'Remplir et analyser un tri croisé...'. The 'Données' menu shows 'TT Data' and 'R Markdown'. The 'Sortie' window is empty.

Comparaison de 2 fréquences

Exemple sous Rcmdr

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

R Commander

Fichier Edition Données Statistiques Graphes Modèles Distributions Outils Aide

Remplissez la table à double entrées

Table Statistiques

Nombre de lignes : 2

Nombre de colonnes : 2

Entrez les dénombrements :

	1	2
1	6	1
2	2	7

Aide Réinitialiser OK Annuler Appliquer

Comparaison de 2 fréquences

Exemple sous Rcmdr

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

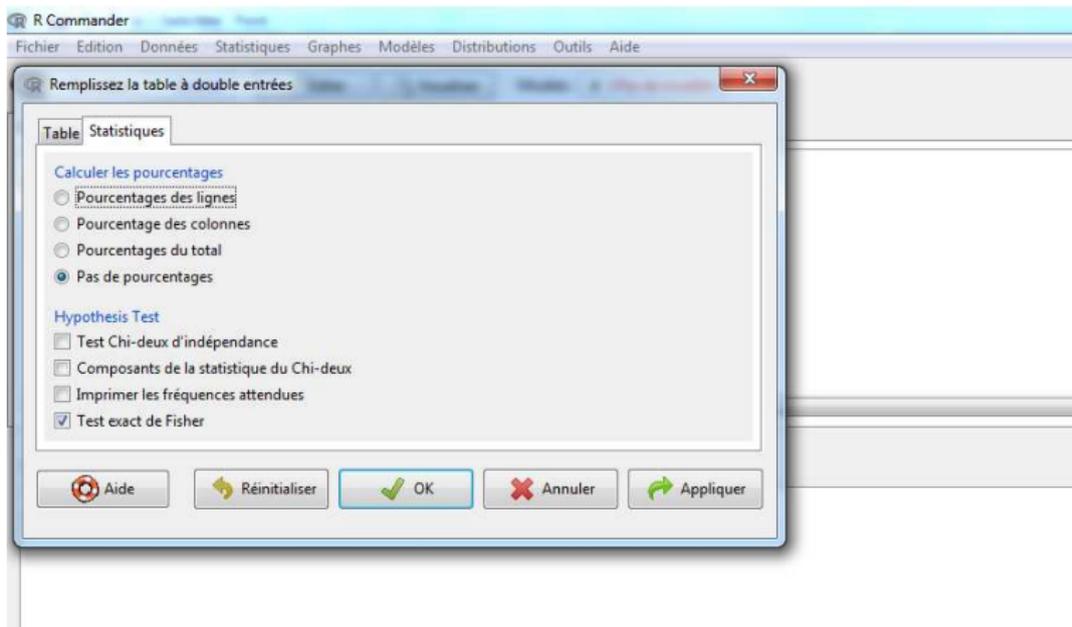
Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion



Comparaison de 2 fréquences

Exemple sous Rcmdr

R Commander

Fichier Edition Données Statistiques Graphes Modèles Distributions Outils Aide

Données: Éditer Visualiser Modèle:

Script R **R Markdown**

```
.Table <- matrix(c(6,1,2,7), 2, 2, byrow=TRUE)
rownames(.Table) <- c('1', '2')
colnames(.Table) <- c('1', '2')
.Table # Counts
.Test <- chisq.test(.Table, correct=FALSE)
.Test
remove(.Test)
remove(.Table)
```

Sortie

```
> .Table <- matrix(c(6,1,2,7), 2, 2, byrow=TRUE)
> rownames(.Table) <- c('1', '2')
> colnames(.Table) <- c('1', '2')

> .Table # Counts
  1 2
1 6 1
2 2 7

> .Test <- chisq.test(.Table, correct=FALSE)
> .Test

      Pearson's Chi-squared test

data:  .Table
X-squared = 6.3492, df = 1, p-value = 0.01174
```

Introduction

Comparaison
de moyennes2 échantillons
indépendants+ de 2 échantillons
indépendants2 échantillons
appariésComparaison
de fréquences2 échantillons
indépendants2 échantillons
appariésCorrélation
linéaire χ^2 d'indépen-
dence

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

L'échantillon A n'est pas indépendant de l'échantillon B

Echantillons dépendants (ou appariés, ou liés)

- observations obtenues chez les mêmes individus
patient est son propre "témoin"
ex : Etude avant/après (douleur avant et après la prise d'un antalgique)
ex : Etude Cas/Témoin (deux pommades sur une même peau)
- observations obtenues chez des individus \neq présentant des caractéristiques similaires
ex : Etude Cas/Témoin (appariement sur les facteurs de risque)
ex : Etude en cluster (deux souris d'une même litière, deux jumeaux, etc.)

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- Exemple classique : **essai thérapeutique en “cross-over”**
 ⇒ patient est son propre “témoin”
 traitements comparés administrés successivement
 (*ordre d’administration tiré au sort*)
- Critères d’intérêt : Succès(+) vs. Echec (-)**

		Avant traitement	Après traitement
Sujets	1	+	-
	2	-	+
	3	+	+
	4	-	-

	N	+	+

On réalise un **test de Mc Nemar** pour comparer 2 proportions théoriques issues de 2 populations représentées par 2 échantillons

⇒ 4 configurations possibles :

+ + q sujets

+ - r sujets

- + s sujets

- - t sujets

		Après		
		+	-	
Avant	+	q	r	q+r
	-	s	t	s+t
		q+s	r+t	N=q+r+s+t

Introduction

Comparaison de moyennes

2 échantillons indépendants
 + de 2 échantillons indépendants
 2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants
 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- **Problème posé** : Comparer proportions

$$p_1(+)\text{ avant} : \frac{q+r}{N} = p_1$$

et

$$p_2(+)\text{ après} : \frac{q+s}{N} = p_2$$

$$\Delta = p_1 - p_2 = \frac{q+r}{N} - \frac{q+s}{N} = \frac{r}{N} - \frac{s}{N}$$

⇒ Seuls interviennent les effectifs r et s relatifs à un changement

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Remarques

⇒ La différence entre les proportions observées de succès dépend

- Effectifs de paires discordantes
- Effectif total

- Sous H_0 , on s'attend à avoir la même proportion de paires discordantes ($p_{(+ -)}$ et $p_{(- +)}$)

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Soit $\pi_{(+ -)}$ et $\pi_{(- +)}$: proportions théoriques de paires discordantes

$$H_0 : \pi_{(+ -)} = \pi_{(- +)} = 0.5$$

$$H_1 : \pi_{(+ -)} \neq \pi_{(- +)} \quad (\text{en bilatéral})$$

⇒ Comparaison d'une proportion observée ("+-" ou "-+") parmi total de paires discordantes) à une proportion théorique (=0.5)

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

$$H_0 : \pi_{(+)} = \pi_{(-)} = 0.5$$

$$H_1 : \pi_{(+)} \neq \pi_{(-)} \quad (\text{en bilatéral})$$

- Statistique

⇒ R=nombre de sujets (+) parmi les $n = r + s$ ayant expérimenté un changement

⇒ Si H_0 est vraie : $R \sim B(n, \pi_{(+)} = 0.5)$

$$E(R) = n\pi_{(+)} = n/2$$

$$\text{Var}(R) = n\pi_{(+)}(1 - \pi_{(+)}) = n/4$$

- si $n > 30$, approximation de la loi binomiale par une **loi normale**

Sous H_0 ,

$$R \sim N\left(\mu = \frac{n}{2}, \sigma = \frac{\sqrt{n}}{2}\right)$$

$$\Rightarrow T = \frac{R - \frac{n}{2}}{\frac{\sqrt{n}}{2}} \sim N(0, 1)$$

- Réalisation pratique

$$|t_{exp}| = \left| \frac{r - \frac{n}{2}}{\frac{\sqrt{n}}{2}} \right| = \left| \frac{r - s}{\sqrt{r + s}} \right|$$

$\Rightarrow |t_{exp}| < t_{table, \alpha} \Rightarrow$ non Rejet de H_0 au seuil α

$\Rightarrow |t_{exp}| \geq t_{table, \alpha} \Rightarrow$ Rejet de H_0 au seuil α

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Remarque :

Si $T = \frac{R - \frac{n}{2}}{\frac{\sqrt{n}}{2}} \sim N(0, 1)$, alors

$$T^2 = \frac{(R - S)^2}{R + S} \sim \chi_{1ddl}^2$$

Contexte

Dans un service de neurologie, une étude est mise en place dans le cadre de douleurs polyneuropathiques : elle vise à comparer le traitement de référence par tramadol à un traitement nouvellement mis sur le marché. On s'intéresse à l'amélioration de la satisfaction des patients vis à vis de la douleur ressentie.

On interroge 60 patients pris en charge pour une polyneuropathie avant la prise du nouveau médicament lorsqu'il sont traités par tramadol et après l'introduction du nouveau médicament (+ : douleur ; - : pas de douleur).

On observe :

		Après	
		+	-
Avant	+	18	26
	-	11	5

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Etape 1 : Choix des hypothèses

question d'intérêt :
le choix de la nouvelle thérapeutique semble-t-il pertinent ?

⇔ la proportion de patients ayant des douleurs polyneuropathiques après la prise du nouveau médicament est-elle moindre que celle avant ?

⇒ **test unilatéral**

$$H_0 : \pi_{(+ -)} = \pi_{(- +)} = 0.5$$

$$H_1 : \pi_{(+ -)} > \pi_{(- +)}$$

Etape 2 : Choix du test, statistique de test et loi sous H_0

Sous H_0 , comme $n = 26 + 11 = 37 > 30$, on a :

$$T = \frac{R - \frac{n}{2}}{\frac{\sqrt{n}}{2}} \sim N(0, 1)$$

R : v.a. représentant le nombre de gens qui ont changé d'avis dans un sens bien précis (par ex., de + vers -)

S : v.a. telle que $S = n - R$ (nombre de gens qui ont changé d'avis dans l'autre sens).

On montre que

$$T = \frac{R - (R + S)/2}{\sqrt{R + S}/2} = \frac{\frac{2R - R - S}{2}}{\sqrt{R + S}/2} = \frac{R - S}{\sqrt{R + S}}$$

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

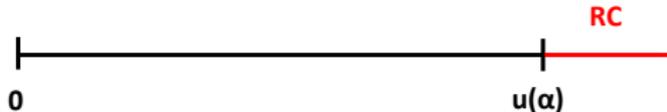
Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Etape 3 : Choix du niveau de signification α , Définition de la région critique (RC)

ICI : test unilatéral



en pratique, $\alpha = 0.05$

\Rightarrow RC : $[1.64; +\infty[$

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Etape 4 : Calcul de statistique de test

Analyse numérique réalisée à l'aide des observations

Il y a deux manières de calculer t_{exp}

$$t_{exp} = \frac{r - n/2}{\sqrt{n}/2} = \frac{r - s}{\sqrt{r + s}} = \frac{26 - 37/2}{\sqrt{37}/2} = \frac{26 - 11}{\sqrt{26 + 11}} \approx 2.47$$

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Etape 5 : Conclusion statistique

- $t_{exp} \approx 2.47 \in [1.64; +\infty[$
- $\Rightarrow t_{exp} \in RC \rightarrow p_c < \alpha$
 - \rightarrow Rejet de H_0 au seuil $\alpha = 5\%$

Etape 6 : Conclusion épidémiologique

- \Rightarrow Il semble que la proportion de patients sans douleur après la prise du nouveau traitement soit moindre que celle des patients avec des douleurs neuropathiques. Je peux affirmer cela avec moins de 5% de chances de me tromper
- \Rightarrow La nouvelle thérapeutique semble être intéressante dans l'amélioration de la satisfaction des patients vis à vis de leur prise en charge.

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- si $n < 30$, test binomial basé sur le calcul de la probabilité (p_c) sous H_0

Exemple (petits échantillons)

On étudie un échantillon de **30 patients**

On observe

		Après a-Tab	
		+	-
Avant a-Tab	+	10	12
	-	5	3

Etape 1 : Choix des hypothèses

question d'intérêt :

le choix de la nouvelle thérapeutique semble-t-il pertinent ?

⇔ la proportion de patients ayant des douleurs
polyneuropathiques après la prise du nouveau médicament
est-elle moindre que celle avant ?

⇒ **test unilatéral**

$$H_0 : \pi_{(+ -)} = \pi_{(- +)} = 0.5$$

$$H_1 : \pi_{(- +)} > \pi_{(+ -)}$$

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

Etape 2 : Choix du test, statistique de test et loi sous H_0

Sous H_0 , comme $n = 12 + 5 = 17 < 30$, on a :

$$S \sim B(n = 17, \pi_{(+)} = 0.5)$$

où S = nombre de sujets (-) parmi les $n = r + s$ ayant expérimenté un changement

Etape 3 : Choix du niveau de signification α

en pratique, $\alpha = 0.05$

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Etape 4 : Calcul de la probabilité critique

$$\begin{aligned} p_c &= Pr(S \geq 12) = 1 - Pr(S < 12) \\ &= 1 - Pr(S = 0) - Pr(S = 1) - \dots - Pr(S = 11) \\ &= 1 - C_{17}^0 0.5^0 (1 - 0.5)^{17} - C_{17}^1 0.5^1 (1 - 0.5)^{16} \\ &\quad - \dots - C_{17}^{11} 0.5^{11} (1 - 0.5)^6 \\ &\approx 0.071 \end{aligned}$$

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Etape 5 : Conclusion statistique

- $p_c \approx 0.071 > \alpha = 0.05$
→ Non Rejet de H_0 au seuil $\alpha = 5\%$

Etape 6 : Conclusion épidémiologique

- ⇒ Il semble que la proportion de patients sans douleur après la prise du nouveau traitement ne soit pas significativement différente de celle des patients avec des douleurs neuropathiques. Je peux affirmer cela avec moins de 5% de chances de me tromper
- ⇒ notre étude ne nous a pas permis de mettre en évidence une efficacité du nouveau traitement

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- 2 v.a. quantitatives X et Y sont mesurées sur les mêmes sujets et sont supposées liées

⇒ **quel est l'intensité de ce lien ?**

⇒ **existe-t-il un lien (une association) entre ces 2 v.a. ?**

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- 2 v.a. quantitatives X et Y sont mesurées sur les mêmes sujets et sont supposées liées

⇒ **quel est l'intensité de ce lien ?**

⇔ quelle est la valeur du coefficient de corrélation ?

⇒ **existe-t-il un lien (une association) entre ces 2 v.a. ?**

Introduction

Comparaison de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- 2 v.a. quantitatives X et Y sont mesurées sur les mêmes sujets et sont supposées liées
- ⇒ **quel est l'intensité de ce lien ?**
 - ⇔ quelle est la valeur du coefficient de corrélation ?
- ⇒ **existe-t-il un lien (une association) entre ces 2 v.a. ?**
 - ⇔ le coefficient de corrélation des 2 v.a. est-il significativement \neq de 0 ?

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

- lien entre "Poids" et "Taille"
- lien entre "Alimentation" et "Prise de poids"
- lien entre "Âge" et "Déclin cognitif"
- lien entre "Âge" et "Taux de cholestérol"
- lien entre "Âge" et "Décès"

Remarque :

pour l'étude d'un lien entre le statut tabagique et la survenue d'un cancer du poumon, **que faire ?**

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- lien entre “Poids” et “Taille”
- lien entre ”Alimentation” et “Prise de poids”
- lien entre ”Âge” et “Déclin cognitif”
- lien entre ”Âge” et “Taux de cholestérol”
- lien entre ”Âge” et “Décès”

Remarque :

pour l'étude d'un lien entre le statut tabagique et la survenue d'un cancer du poumon, **que faire ?**

→ analyse de la relation entre 2 variables qualitatives

- lien entre “Poids” et “Taille”
- lien entre ”Alimentation” et “Prise de poids”
- lien entre ”Âge” et “Déclin cognitif”
- lien entre ”Âge” et “Taux de cholestérol”
- lien entre ”Âge” et “Décès”

Remarque :

pour l'étude d'un lien entre le statut tabagique et la survenue d'un cancer du poumon, **que faire ?**

→ analyse de la relation entre 2 variables qualitatives

⇒ Test de chi-deux, Test de comparaison de deux fréquences
+ calcul OR

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- Soient 2 v.a. quantitatives continues X et Y (avec une distribution jointe supposée bi-normale), de moyennes μ_X et μ_Y et de variances σ_X^2 et σ_Y^2

→ En pratique, bi-normalité pas évidente, déjà bien si X et Y sont considérées normales

- Echantillon composé de n individus ($i = 1, \dots, n$)

⇒ On observe n couples (y_i, x_i)

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Coefficient de corrélation entre X et Y :

$$\rho = \frac{\text{Cov}(X, Y)}{\sqrt{\sigma_X^2 \sigma_Y^2}}$$

⇒ ρ mesure l'intensité de la relation entre deux variables quantitatives X et Y **si cette relation est linéaire**

Introduction

Comparaison
de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

Comparaison
de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation
linéaire

χ^2 d'indépendance

Conclusion

- Limites du coefficient de corrélation de Pearson

⇒ Bi-normalité des 2 v.a. X et Y pas vérifiée

→ Solutions :

- Limites du coefficient de corrélation de Pearson

⇒ Bi-normalité des 2 v.a. X et Y pas vérifiée

→ Solutions :

- utilisation de transformée de X et Y pour se rapprocher de la bi-normalité (ou tout du moins de la normalité de chacune des v.a.)
- utiliser un coefficient basé sur les rangs et un test non-paramétrique

⇒ corrélation de Spearman

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Soient 2 v.a. quantitatives continues X et Y , de moyennes μ_X et μ_Y et de variances σ_X^2 et σ_Y^2
 - Echantillon composé de n individus ($i = 1, \dots, n$)
- ⇒ On observe n couples (y_i, x_i)
- pour X et Y , on affecte le rang correspondant à chacune des valeurs
- ⇒ On observe n couples de rang (R_{Y_i}, R_{X_i})

- Soient 2 v.a. quantitatives continues X et Y , de moyennes μ_X et μ_Y et de variances σ_X^2 et σ_Y^2
 - Echantillon composé de n individus ($i = 1, \dots, n$)
- ⇒ On observe n couples (y_i, x_i)
- pour X et Y , on affecte le rang correspondant à chacune des valeurs
- ⇒ On observe n couples de rang (R_{Yi}, R_{Xi})
- ⇒ Coefficient de corrélation entre X et Y :

$$\rho = \frac{\text{Cov}(R_Y, R_X)}{\sqrt{\sigma_{R_X}^2 \sigma_{R_Y}^2}}$$

Introduction

Comparaison de moyennes

2 échantillons indépendants
+ de 2 échantillons indépendants
2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants
2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Coefficient de corrélation entre X et Y :

→ + simple de s'intéresser à $D = R_{X_i} - R_{Y_i}$, on alors :

$$\rho = 1 - \frac{6 \sum_{i=1}^n D_i^2}{n * (n^2 - 1)}$$

- Interprétation du coefficient de corrélation de Spearman :

- ⇒ on montre facilement que $\rho \in [-1; +1]$
- $r = 1$: lien linéaire parfait dans le même sens
- $r = -1$: lien linéaire parfait dans le sens inverse
- $|r| > 0.5$: lien linéaire fort
- $0.3 < |r| < 0.5$: lien linéaire moyen
- $0.1 < |r| < 0.3$: lien linéaire faible
- $r = 0$: pas de liaison linéaire
- ⇒ identique à celle du coefficient de corrélation de Pearson

Introduction

Comparaison de moyennes

2 échantillons indépendants
+ de 2 échantillons indépendants
2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants
2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Interprétation du coefficient de corrélation linéaire :

→ si X et Y sont 2 v.a. indépendantes alors

$$\rho = 0$$

En effet, si X et Y sont 2 v.a. indépendantes, alors

$$E(X.Y) = E(X).E(Y)$$

$$\rightarrow \text{Cov}(X, Y) = E(X.Y) - E(X).E(Y) = 0$$

$$\Rightarrow \rho = 0$$

→ si $\rho = 0$ et X et Y normalement distribuées $\Rightarrow X$ et Y sont 2 v.a. indépendantes

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Soient Y et X v.a. représentant respectivement la **tension artérielle systolique** et l'**âge de femmes** incluses dans un échantillon
- On réalise un échantillon de 10 femmes, les résultats sont présentés dans le tableau suivant :

Sujet	1	2	3	4	5	6	7	8	9	10
x (ans)	56	42	72	36	63	47	55	49	38	42
y (mmHg)	14.7	12.5	16.0	11.8	14.9	12.8	15.0	14.5	11.5	14.0

⇒ On souhaite tester si la tension artérielle systolique diffère avec l'âge chez les femmes

Exemple (suite)

Introduction

Comparaison
de moyennes

- 2 échantillons indépendants
- + de 2 échantillons indépendants
- 2 échantillons appariés

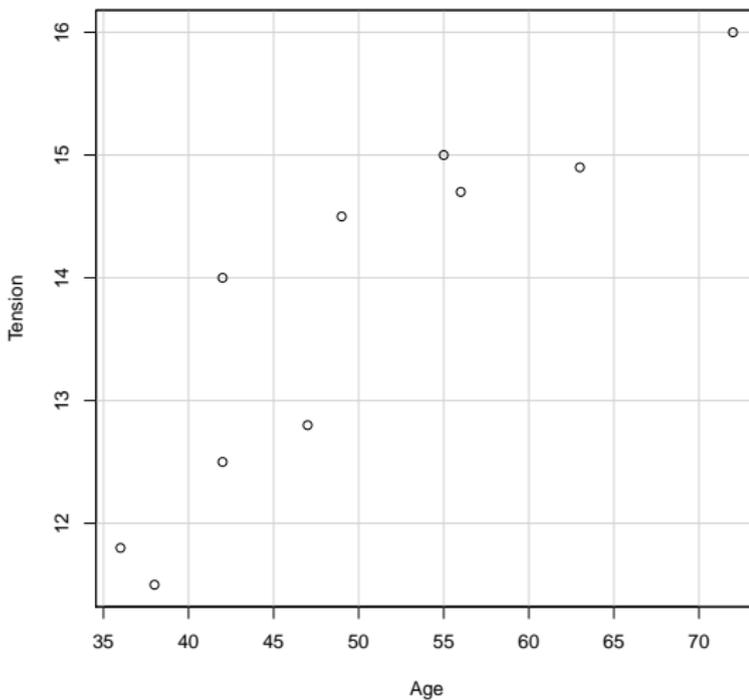
Comparaison
de fréquences

- 2 échantillons indépendants
- 2 échantillons appariés

Corrélation
linéaire

χ^2 d'indépendance

Conclusion



Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

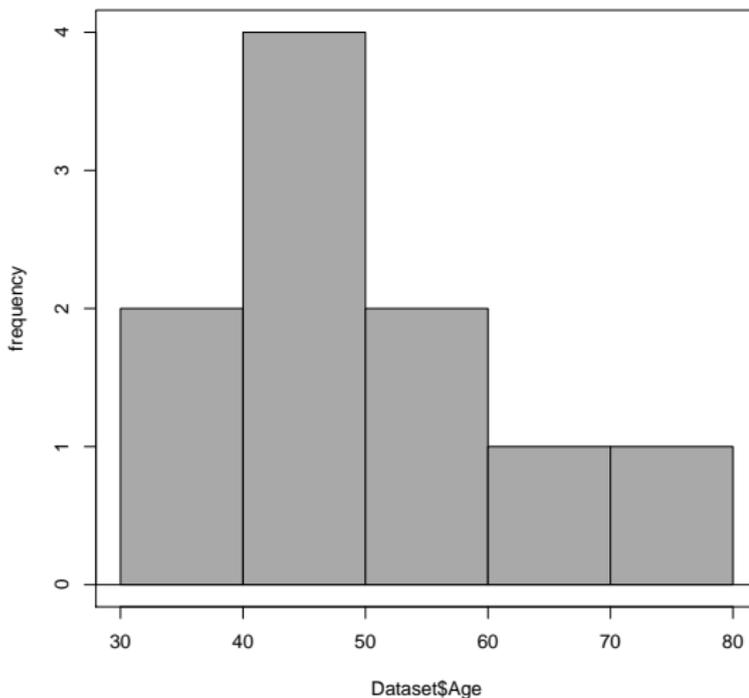
Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

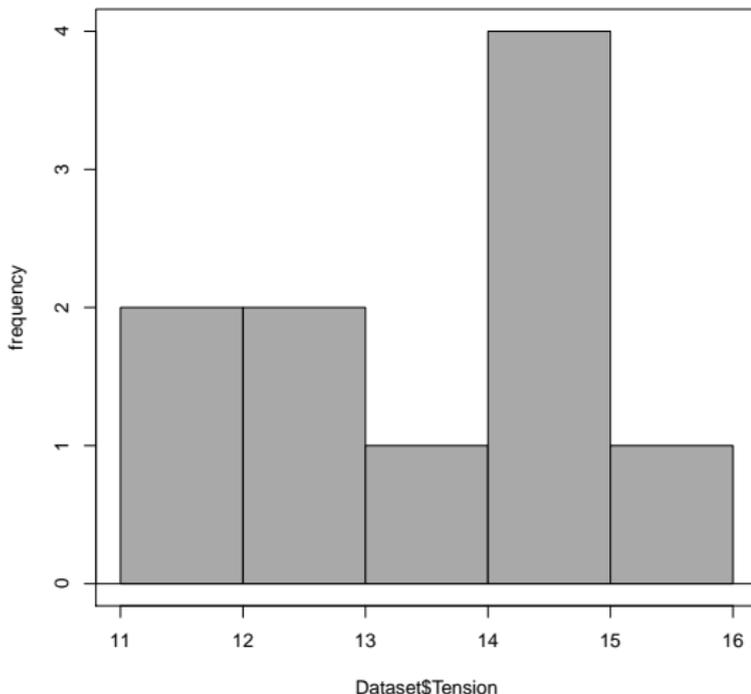
χ^2 d'indépendance

Conclusion



Exemple (suite)

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion



Exemple (suite)

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

- On observe :

Sujet	1	2	3	4	5	6	7	8	9	10
x (ans)	56	42	72	36	63	47	55	49	38	42
y (mmHg)	14.7	12.5	16.0	11.8	14.9	12.8	15.0	14.5	11.5	14.0

- affectation des rangs
- calcul des différences de rangs

Sujet	1	2	3	4	5	6	7	8	9	10
r_X	8	3.5	10	1	9	5	7	6	2	3.5
r_Y	7	3	10	2	8	4	9	6	1	5
d	1	0.5	0	-1	1	1	-2	0	1	-1.5
d^2	1	0.25	0	1	1	1	4	0	1	2.25

- Coefficient de corrélation estimé entre X et Y :

$$r = 1 - \frac{6 * 11.5}{10 * (10^2 - 1)} \approx 0.93$$

→ $|r| > 0.5 \Rightarrow$ Forte corrélation : Il semble que la tension artérielle systolique augmente avec l'âge chez les femmes

Peut-on conclure que le coefficient de corrélation linéaire ρ de la population est significativement différent de 0 ?

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- Coefficient de corrélation estimé entre X et Y :

$$r = 1 - \frac{6 * 11.5}{10 * (10^2 - 1)} \approx 0.93$$

→ $|r| > 0.5 \Rightarrow$ Forte corrélation : Il semble que la tension artérielle systolique augmente avec l'âge chez les femmes

Peut-on conclure que le coefficient de corrélation linéaire ρ de la population est significativement différent de 0 ?

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

étape 1 : Choix des hypothèses

question d'intérêt \Rightarrow test bilatéral

$$H_0 : \rho = 0 \quad \Leftrightarrow \text{on suppose l'indépendance entre X et Y}$$

$$H_1 : \rho \neq 0$$

question d'intérêt \Rightarrow test unilatéral

$$H_0 : \rho = 0 \quad \Leftrightarrow \text{on suppose l'indépendance entre X et Y}$$

$$H_1 : \rho > 0 \text{ (ou bien } < \text{)}$$

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

étape 2 : Choix du test, statistique de test et loi sous H_0

2 cas de figure :

- $n > 10$
- $n \leq 10$

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

étape 2 : Choix du test, statistique de test et loi sous H_0

Sous H_0 , avec hypothèse de **normalité** des 2 v.a., la statistique de test :

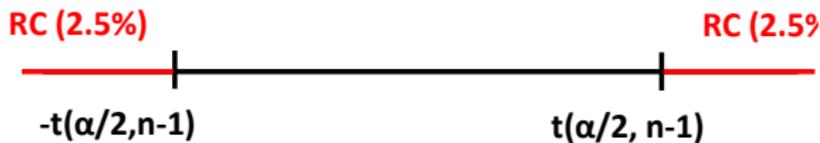
$$T = \frac{R - \rho}{\sqrt{\text{Var}(R)}} \sim \text{Student}_{(n-2)ddl}$$

où $\sqrt{\text{Var}(R)} = \frac{1-R^2}{n-2}$

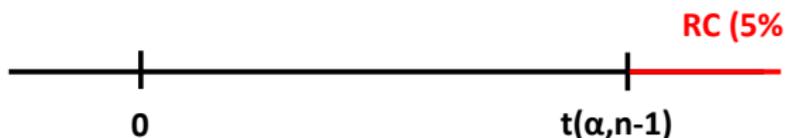
$$\Rightarrow T = \frac{R\sqrt{n-2}}{\sqrt{1-R^2}} \sim \text{Student}_{(n-2)ddl}$$

étape 3 : Choix du niveau de signification α , Définition de la région critique (RC)

α , test bilatéral, loi de Student



α , test unilatéral, loi de Student



Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

étape 4 : Calcul de la statistique de test

Analyse numérique réalisée à l'aide des estimations issues
des échantillons A et B

$$t_{exp} = \frac{r\sqrt{n-2}}{\sqrt{1-r^2}}$$

étape 5 & 6 : Conclusion statistique et épidémiologique

- Si $t_{exp} \in RC \rightarrow p_c < \alpha$.
 - Rejet de H_0 car moins de α % de chance qu'elle soit vraie.
 - Il semble que ρ soit \neq de 0.
 - Les v.a. X et Y semblent **linéairement** corrélées.
- Si $t_{exp} \notin RC \rightarrow p_c > \alpha$.
 - Non rejet de H_0 car plus de α % de chance qu'elle soit vraie.
 - On ne peut pas montrer que ρ soit \neq de 0.
 - On ne peut pas montrer que les v.a. X et Y semblent **linéairement** corrélées.

Remarque : p_c =probabilité de se tromper en rejetant H_0

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

- On range la v.a. $X : (R_{Xi})$
- Sous H_0 (hypothèse d'aucune corrélation),
→ le rang de la variable Y est supposé distribué aléatoire selon les $n!$ arrangements possibles
- Comparaison immédiate du coefficient de corrélation estimé r avec ceux théoriques calculés sous H_0 (fournies dans la table) à un certain seuil α

Attention au nb de ddl= n-2 !!

Table

α	0.50	0.20	0.10	0.05	0.02	0.01	0.005	0.002	0.001
n									
4	0.600	1.000	1.000						
5	0.500	0.800	0.900	1.000	1.000				
6	0.371	0.657	0.829	0.886	0.943	1.000	1.000		
7	0.321	0.571	0.714	0.786	0.893	0.929	0.964	1.000	1.000
8	0.310	0.524	0.643	0.738	0.833	0.881	0.905	0.952	0.976
9	0.267	0.483	0.600	0.700	0.783	0.833	0.867	0.917	0.933
10	0.248	0.455	0.564	0.648	0.745	0.794	0.830	0.879	0.903
11	0.236	0.427	0.536	0.618	0.709	0.755	0.800	0.845	0.873
12	0.224	0.406	0.503	0.587	0.671	0.727	0.776	0.825	0.860
13	0.209	0.385	0.484	0.560	0.648	0.703	0.747	0.802	0.835
14	0.200	0.367	0.464	0.538	0.622	0.675	0.723	0.776	0.811
15	0.189	0.354	0.443	0.521	0.604	0.654	0.700	0.754	0.786
16	0.182	0.341	0.429	0.503	0.582	0.635	0.679	0.732	0.765
17	0.176	0.328	0.414	0.485	0.566	0.615	0.662	0.713	0.748
18	0.170	0.317	0.401	0.472	0.550	0.600	0.643	0.695	0.728
19	0.165	0.309	0.391	0.460	0.535	0.584	0.628	0.677	0.712
20	0.161	0.299	0.380	0.447	0.520	0.570	0.612	0.662	0.696
21	0.156	0.292	0.370	0.435	0.508	0.556	0.599	0.648	0.681
22	0.152	0.284	0.361	0.425	0.496	0.544	0.586	0.634	0.667
23	0.148	0.278	0.353	0.415	0.486	0.532	0.573	0.622	0.654
24	0.144	0.271	0.344	0.406	0.476	0.521	0.562	0.610	0.642
25	0.142	0.265	0.337	0.398	0.466	0.511	0.551	0.598	0.630
26	0.138	0.259	0.331	0.390	0.457	0.501	0.541	0.587	0.619
27	0.136	0.255	0.324	0.382	0.448	0.491	0.531	0.577	0.608
28	0.133	0.250	0.317	0.375	0.440	0.483	0.522	0.567	0.598
29	0.130	0.245	0.312	0.368	0.433	0.475	0.513	0.558	0.589
30	0.128	0.240	0.306	0.362	0.425	0.467	0.504	0.549	0.580
31	0.126	0.236	0.301	0.356	0.418	0.459	0.496	0.541	0.571
32	0.124	0.232	0.296	0.350	0.412	0.452	0.489	0.533	0.563
33	0.121	0.229	0.291	0.345	0.405	0.446	0.482	0.525	0.554
34	0.120	0.225	0.287	0.340	0.399	0.439	0.475	0.517	0.547
35	0.118	0.222	0.283	0.335	0.394	0.433	0.468	0.510	0.539
36	0.116	0.219	0.279	0.330	0.388	0.427	0.462	0.504	0.533
37	0.114	0.216	0.275	0.325	0.383	0.421	0.456	0.497	0.526
38	0.113	0.212	0.271	0.321	0.378	0.415	0.450	0.491	0.519
39	0.111	0.210	0.267	0.317	0.373	0.410	0.444	0.485	0.513
40	0.110	0.207	0.264	0.313	0.368	0.405	0.439	0.479	0.507

Introduction

Comparaison
de moyennes2 échantillons
indépendants+ de 2 échantillons
indépendants2 échantillons
appariésComparaison
de fréquences2 échantillons
indépendants2 échantillons
appariésCorrélation
linéaire χ^2 d'indépen-
dence

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Conclusion statistique et épidémiologique

- Si $r > r_{theo} \rightarrow p_c < \alpha$.
 - Rejet de H_0 car moins de α % de chance qu'elle soit vraie.
 - Il semble que ρ soit \neq de 0.
 - Les v.a. X et Y semblent **linéairement** corrélées.
- Si $r \leq r_{theo} \rightarrow p_c > \alpha$.
 - Non rejet de H_0 car plus de α % de chance qu'elle soit vraie.
 - On ne peut pas montrer que ρ soit \neq de 0.
 - On ne peut pas montrer que les v.a. X et Y semblent **linéairement** corrélées.

Remarque : p_c =probabilité de se tromper en rejetant H_0

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

étape 1 : Choix des hypothèses

question d'intérêt :

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

étape 1 : Choix des hypothèses

question d'intérêt :

On souhaite tester si la tension artérielle systolique diffère avec l'âge chez les femmes

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

étape 1 : Choix des hypothèses

question d'intérêt :

On souhaite tester si la tension artérielle systolique diffère avec l'âge chez les femmes

⇒ test bilatéral

$H_0 : \rho = 0$ ⇔ on suppose l'**indépendance** entre X et Y

$H_1 : \rho \neq 0$

On a dans notre exemple : $n = 10$

$$r \approx 0.933$$

et pour 10 – 2 ddl, avec $\alpha = 5\%$, on a :

$$r_{theo} = 0.738$$

- $r > r_{theo} \rightarrow p_c < \alpha$
 - Rejet de H_0 car moins de α % de chance qu'elle soit vraie.
 - Il semble que ρ soit \neq de 0.
 - Les v.a. X et Y semblent **linéairement** corrélées

⇒ la tension artérielle systolique semble liée à l'âge chez les femmes

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

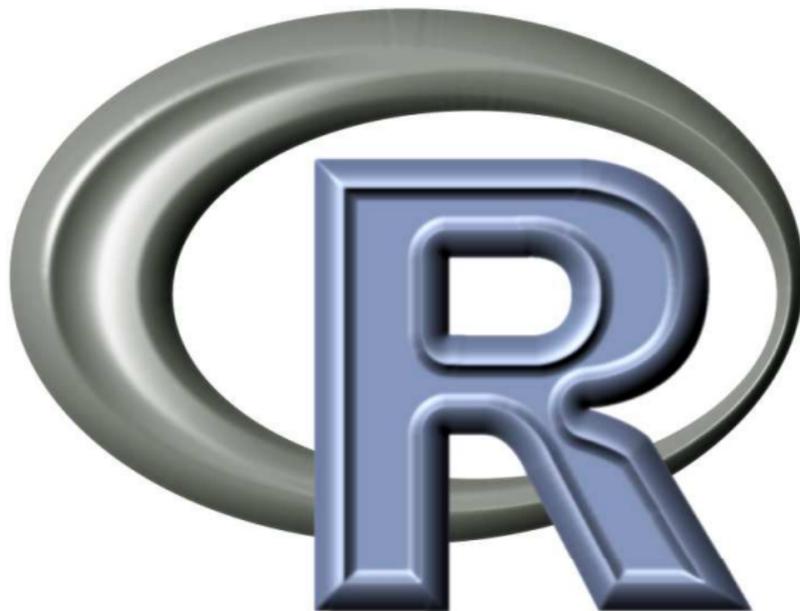
Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion



<http://www.r-project.org/>



Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

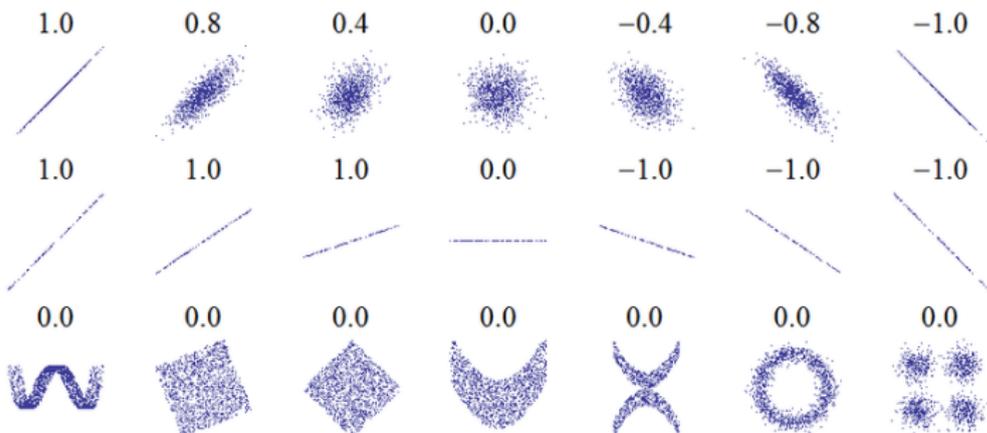
2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion



- Attention aux conclusions non-valides pour une relation non-linéaire.
- Plusieurs relations possibles pour un même coefficient de corrélation → quantification de la relation souvent nécessaire.

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Coefficient de corrélation linéaire mesure la liaison entre 2 v.a. quantitatives

⇒ **Attention** dans l'interprétation de la corrélation

- 1 corrélation entre 2 v.a. n'entraîne pas obligatoirement une relation de causalité

→ 1 corrélation **forte** et **significative** peut signifier

- un lien fortuit
- un lien commun
- un lien de causalité

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

Comparaison de 2 fréquences ou + :

Test du χ^2 d'indépendance

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

- On observe un échantillon de N sujets avec pour chaque sujet 2 critères de qualification :
 - 1 variable catégorielle A à k modalités
 - 1 variable catégorielle B à l modalités

⇒ Classification sous forme de **tableau de contingence** :

	B_1	...	B_j	...	B_l	Totaux lignes T_i
A_1	O_{11}	...	O_{1j}	...	O_{1l}	$O_{1.} = T_1$
...
A_i	O_{i1}	...	O_{ij}	...	O_{il}	$O_{i.} = T_i$
...
A_k	O_{k1}	...	O_{kj}	...	O_{kl}	$O_{k.} = T_k$
Totaux colonnes S_j	$O_{.1} = S_1$...	$O_{.j} = S_j$...	$O_{.l} = S_l$	$O_{..} = N = \text{Effectif total}$

- Hypothèses :

- H_0 : indépendance entre A et B
- H_1 : dépendance entre A et B

- On peut montrer que la statistique de test suivante :

$$\chi_{exp}^2 = \sum_i \sum_j \frac{(O_{ij} - C_{ij})^2}{C_{ij}} \sim \chi_{(k-1)(l-1)}^2 \text{ ddl}$$

où C_{ij} : effectif théorique sous H_0

- **Conditions de validité :**

$C_{ij} \geq 5$ sinon regrouper (*éventuellement*) des classes adjacentes

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Comparaison de 2 fréquences ou + :

Test du χ^2 d'indépendance

Région critique :

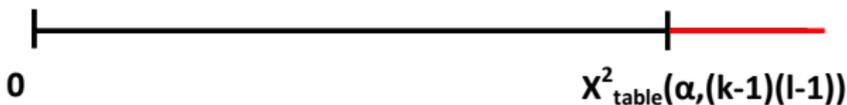


TABLE DE LA FONCTION DE REPARTITION DU χ^2

Degré liberté	Probabilité α									
	0,995	0,990	0,975	0,950	0,900	0,100	0,050	0,025	0,010	0,005
1	0,00	0,00	0,00	0,00	0,02	2,71	3,84	5,02	6,63	7,88
2	0,01	0,02	0,05	0,10	0,21	4,61	5,99	7,38	9,21	10,60
3	0,07	0,11	0,22	0,35	0,58	6,25	7,81	9,35	11,34	12,84
4	0,21	0,30	0,48	0,71	1,06	7,78	9,49	11,14	13,28	14,86
5	0,41	0,55	0,83	1,15	1,61	9,24	11,07	12,83	15,09	16,75
6	0,68	0,87	1,24	1,64	2,20	10,64	12,59	14,45	16,81	18,55
7	0,99	1,24	1,69	2,17	2,83	12,02	14,07	16,01	18,48	20,28
8	1,34	1,65	2,18	2,73	3,49	13,36	15,51	17,53	20,09	21,95
9	1,73	2,09	2,70	3,33	4,17	14,68	16,92	19,02	21,67	23,59
10	2,16	2,56	3,25	3,94	4,87	15,99	18,31	20,48	23,21	25,19
11	2,60	3,05	3,82	4,57	5,58	17,28	19,68	21,92	24,73	26,76
12	3,07	3,57	4,40	5,23	6,30	18,55	21,03	23,34	26,22	28,30
13	3,57	4,11	5,01	5,89	7,04	19,81	22,36	24,74	27,69	29,82
14	4,07	4,66	5,63	6,57	7,79	21,06	23,68	26,12	29,14	31,32
15	4,60	5,23	6,26	7,26	8,55	22,31	25,00	27,49	30,58	32,80
16	5,14	5,81	6,91	7,96	9,31	23,54	26,30	28,85	32,00	34,27
17	5,70	6,41	7,56	8,67	10,09	24,77	27,59	30,19	33,41	35,72
18	6,26	7,01	8,23	9,39	10,86	25,99	28,87	31,53	34,81	37,16
19	6,84	7,63	8,91	10,12	11,65	27,20	30,14	32,85	36,19	38,58

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

Conclusion :

- $\chi_{exp}^2 \geq \chi_{table(\alpha, (k-1)l-1)}^2 \text{ ddl} \rightarrow p < \alpha$

⇒ Rejet de H_0 : Dépendance entre les variables A et B

- $\chi_{exp}^2 < \chi_{table(\alpha, (k-1)l-1)}^2 \text{ ddl} \rightarrow p > \alpha$

⇒ Non rejet de H_0 : Nous n'avons pas pu mettre en évidence une dépendance entre les variables A et B

Comparaison de 2 fréquences ou + :

Exemple

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

- Lors d'un essai clinique comparant 2 traitements A et B (150 patients randomisés dans chaque bras), l'ensemble des effets indésirables sont collectés
- Les patients sont classés en 3 groupes : pas d'effet indésirable (PEI), au moins un effet indésirable (et aucun grave) (EI), au moins un effet indésirable grave (EIG)
- Voici la répartition des sujets en fonction de leur traitement et de la survenue d'effets indésirables :

	PEI	EI	EIG
traitement A	71	50	29
traitement B	98	32	20

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

On cherche à répondre à la question suivante :
“Existe-t-il un lien significatif entre le traitement et les effets secondaires ?” (risque d’erreur de 1ère espèce fixé à 5%) ?

- Quelle est l’hypothèse nulle H_0 de ce test ?
- Quelle est l’hypothèse alternative H_1 de ce test ?

On cherche à répondre à la question suivante :
“Existe-t-il un lien significatif entre le traitement et les effets secondaires ?” (risque d’erreur de 1ère espèce fixé à 5%) ?

- Quelle est l’hypothèse nulle H_0 de ce test ?
- Quelle est l’hypothèse alternative H_1 de ce test ?

H_0 : les proportions d’effets secondaires sont égales dans les 2 groupes de traitement

H_1 : Il y a au moins 2 proportions qui sont différentes

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d’indépendance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- Quel type de test permet de répondre à cette question ?

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Quel type de test permet de répondre à cette question ?

Test de χ^2 d'indépendance

→ Test de l'existence d'un lien entre le traitement et la survenue d'effets secondaires

→ c'est-à-dire l'indépendance entre la survenue d'effets secondaires et la prise du traitement A ou B

- Calcul de la statistique de test

Tableau de contingence des effectifs théoriques :

	PEI	EI	EIG	
traitement A	$\frac{150 \cdot 169}{300} = 84.5$	41	24.5	150
traitement B	84.5	41	24.5	150
Total	169	82	49	300

Sous H_0 ,

- la proportion d'effets indésirables graves(...) devrait être la même quelque soit le traitement :

$$49/300 \approx 0.1633$$

- rapportée aux patients traités par le médicament A :

$$150 * 49/300 = 24.5$$

Conditions d'application :

$$\frac{49 * 150}{300} = 24.5 > 5$$

La statistique de test est égale à

$$\chi^2_{calc} = \sum_{i,j} \frac{(O_{ij} - C_{ij})^2}{C_{ij}} \sim \chi^2_{theo}(2ddl)$$

Tableau des écarts au carré $\frac{(O_{ij}-C_{ij})^2}{C_{ij}}$:

	PEI	EI	EIG
traitement A	2.16	1.98	0.83
traitement B	2.16	1.98	0.83

La statistique de test calculée est :

$$\chi^2_{calc} = 2.16 + 2.16 + 1.98 + 1.98 + 0.83 + 0.83 = 9.94$$

- Conclusion

La région critique au seuil $\alpha = 0.05$ est défini en fonction du nombre de degré de liberté

$$RC = [5.99; +\infty[$$

$$\chi_{calc}^2 = 9.94 \in RC$$

\Rightarrow Rejet de H_0 au seuil $\alpha = 0.05$

Il semble donc que les proportions des différents types d'effets indésirables ne soient pas indépendantes de la prescription médicale ($p_c < 0.05$).

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Comparaison de 2 fréquences ou + :

Exemple sous R

<http://www.r-project.org/>



Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Comparaison de 2 fréquences ou + :

Exemple sous R

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

```
> t<-table(baseChisq$Traitement,baseChisq$EffInd)
> t
```

```
      EI  EIG  PEI
A  50   29   71
B  32   20   98
```

```
>
> test<-chisq.test(t)
> test
```

Pearson's Chi-squared test

```
data:  t
X-squared = 9.9179, df = 2, p-value = 0.00702
```

```
>
> test$expected
```

```
      EI  EIG  PEI
A  41  24.5  84.5
B  41  24.5  84.5
```

- Cas particulier d'un tableau 2*2 :

	Malades	Non Malade	Total
Exposés	a	b	a+b
Non exposés	c	d	c+d
Total	a+c	b+d	N

⇒ Comparaison de 2 % sur 2 grands échantillons indépendants

- H_0 : le % de bronchite est le même quelle que soit l'exposition

$$H_0 : \pi_e = \pi_{\bar{e}} \quad \text{et} \quad H_1 : \pi_e \neq \pi_{\bar{e}}$$

où π_e : % de bronchite chez les exposés

où $\pi_{\bar{e}}$: % de bronchite chez les non exposés

- Introduction
- Comparaison de moyennes
 - 2 échantillons indépendants
 - + de 2 échantillons indépendants
 - 2 échantillons appariés
- Comparaison de fréquences
 - 2 échantillons indépendants
 - 2 échantillons appariés
- Corrélation linéaire
- χ^2 d'indépendance
- Conclusion

- **Mesure d'association** entre un facteur d'exposition (facteur de risque) et la présence de la maladie

	Malades (M)	Non Malade (\bar{M})	Total
Exposés (E)	a	b	a+b
Non exposés (\bar{E})	c	d	c+d
Total	a+c	b+d	N

- Odds (côte) :

$$\frac{\text{Prob}(M)}{\text{Prob}(\bar{M})} = \frac{p}{1-p}$$

- Odds chez les exposés :

$$\frac{a/(a+b)}{b/(a+b)} = \frac{a}{b}$$

- Odds chez les non exposés :

$$\frac{c/(c+d)}{d/(c+d)} = \frac{c}{d}$$

⇒ Odds ratio :

$$\frac{\text{Odds chez les exposés}}{\text{Odds chez les non exposés}} = \frac{a/b}{c/d} = \frac{ad}{bc}$$

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Remarques :

- Si Odds Ratio=OR>1 \Rightarrow facteur de risque
- Si Odds Ratio=OR<1 \Rightarrow facteur protecteur

\Rightarrow OR est-il significativement \neq de 1 ?
Intervalle de confiance, test

- On observe le tableau de contingence suivant chez 460 patients chez lesquels on s'intéresse à l'efficacité d'un vaccin contre la grippe

	Grippe	Pas de grippe	Total
Vaccin	20	220	240
Placebo	80	140	220
Total	100	360	460

⇒ Existe-t-il un lien entre la grippe et la vaccination ? (au risque de 1ère espèce $\alpha = 5\%$?

⇒ Test du χ^2

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

- Calcul de la statistique de test

Tableau de contingence des effectifs théoriques :

	Grippe	Pas de grippe	Total
Vaccin	$\frac{240 * 100}{460} = 52.17$	187.83	240
Placebo	47.83	172.17	220
Total	100	360	460

Sous H_0 ,

- la proportion de grippe devrait être la même quelque soit le genre :

$$100/460 \approx 0.22$$

- rapportée au nombre de personnes vaccinées :

$$240 * 100/460 = 52.17$$

Conditions d'application :

$$\frac{220 * 100}{460} = 47.83 > 5$$

La statistique de test est égale à

$$\chi^2_{calc} = \sum_{i,j} \frac{(O_{ij} - C_{ij})^2}{C_{ij}} \sim \chi^2_{theo}(2ddl)$$

Tableau des écarts au carré $\frac{(O_{ij}-C_{ij})^2}{C_{ij}}$:

	Grippe	Pas de grippe
Vaccin	19.84	5.51
Placebo	21.64	6.01

La statistique de test calculée est :

$$\chi^2_{calc} = 19.84 + 5.51 + 21.64 + 6.01 \approx 53$$

Conclusion

La région critique au seuil $\alpha = 0.05$ est défini en fonction du nombre de degré de liberté

$$RC = [3.84; +\infty[$$

$$\chi^2_{calc} = 53 \in RC$$

\Rightarrow Rejet de H_0 car moins de α % de chance qu'elle soit vraie.

Il semble que la proportion de grippe soit différente selon que l'on soit vacciné ou non ($p_c < 0.05$).

\Rightarrow Existence d'un lien entre grippe et vaccination

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Conclusion

La région critique au seuil $\alpha = 0.05$ est défini en fonction du nombre de degré de liberté

$$RC = [3.84; +\infty[$$

$$\chi^2_{calc} = 53 \in RC$$

\Rightarrow Rejet de H_0 car moins de α % de chance qu'elle soit vraie.

Il semble que la proportion de grippe soit différente selon que l'on soit vacciné ou non ($p_c < 0.05$).

\Rightarrow Existence d'un lien entre grippe et vaccination

\Rightarrow Intensité de ce lien ?

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Odds Ratio

$$OR = \frac{20 * 140}{220 * 80} = 0.159 < 1$$

⇒ La vaccination apparaît comme un facteur protecteur de la grippe

- La distribution de l'OR n'est pas symétrique ($OR > 0$)
 → Distribution non normale

⇒ $\ln(OR) \sim$ distribution normale (approximativement)
 - Calcul de l'IC de $\ln(OR)$, puis on en déduit celui de OR

- Variance de $\ln(OR)$:

$$s^2(\ln(OR)) = \frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d}$$

⇒ Intervalle de confiance à 95% de $\ln(OR)$:

$$IC_{95\%}(\ln(OR)) = \ln(OR) \pm 1.96 * s(\ln(OR))$$

⇒ Intervalle de confiance à 95% de OR :

$$IC_{95\%}(OR) = e^{\ln(OR) \pm 1.96 * s(\ln(OR))}$$

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dence

Conclusion

- $OR = 0.159 \rightarrow \ln(OR) = \ln(0.159) \approx -1.839$
- $s^2(\ln(OR)) = \frac{1}{20} + \frac{1}{220} + \frac{1}{80} + \frac{1}{140} \approx 0.0742$
- dans l'exemple :

$$IC_{95\%}(OR) = e^{-1.839 \pm 1.96 * 0.0742} = [0.093; 0.272]$$

- Existe-il un lien entre grippe et vaccination ?

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- $OR = 0.159 \rightarrow \ln(OR) = \ln(0.159) \approx -1.839$
- $s^2(\ln(OR)) = \frac{1}{20} + \frac{1}{220} + \frac{1}{80} + \frac{1}{140} \approx 0.0742$
- dans l'exemple :

$$IC_{95\%}(OR) = e^{-1.839 \pm 1.96 * 0.0742} = [0.093; 0.272]$$

- Existe-il un lien entre grippe et vaccination ?

$$1 \notin IC_{95\%}(OR)$$

\Rightarrow Rejet de H_0 au seuil 5% (supposant $OR = 1$)

- Risque Relatif=RR : Rapport des risques

	Malades (M)	Non Malade (\bar{M})	Total
Exposés (E)	a	b	a+b
Non exposés (\bar{E})	c	d	c+d
Total	a+c	b+d	N

$$RR = \frac{Prob(M|E)}{Prob(M|\bar{E})} = \frac{a/(a+b)}{c/(c+d)}$$

- ⇒ RR s'interprète comme un coefficient de proportionnalité
 par ex., $RR = 2 \Rightarrow$ les sujets exposés ont 2 fois plus de risque d'être malade que les non exposés

- ⇒ **Interprétation extrêmement intéressante et pertinente**

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- Problème :

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

- **Problème :**

- Nécessité d'avoir un échantillon représentatif

→ Prévalence de la maladie doit être celle de la population

$$p = \frac{a + c}{N}$$

→ pas systématique

par ex. : étude cas-témoin où on a souvent

$$p = \frac{a + c}{N} = \frac{1}{2} \text{ car } (a + c) = (b + d)$$

⇒ Odds Ratio calculable !!

- **Problème :**

- Nécessité d'avoir un échantillon représentatif

→ Prévalence de la maladie doit être celle de la population

$$p = \frac{a + c}{N}$$

→ pas systématique

par ex. : étude cas-témoin où on a souvent

$$p = \frac{a + c}{N} = \frac{1}{2} \text{ car } (a + c) = (b + d)$$

⇒ Odds Ratio calculable !!

- Si maladie rare, alors $OR \approx RR$

$$a \ll b \text{ et } c \ll d \Rightarrow RR \approx \frac{a/b}{c/d} = \frac{ad}{bc}$$

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

1. Introduction

2. Comparaison de moyennes

Comparaison de 2 échantillons indépendants

Comparaison de + de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

3. Comparaison de fréquences

Comparaison de 2 échantillons indépendants

Comparaison de 2 échantillons appariés

4. Coefficient de corrélation linéaire

5. χ^2 d'indépendance

6. Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants
+ de 2 échantillons
indépendants
2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants
2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

Un peu de discussion...

- p_c : probabilité critique ou degré de signification
- ⇒ probabilité de rejeter H_0 à tort
- ⇒ mesure la crédibilité de H_0 , quantifie le “désaccord” entre ce qu’on observe et l’hypothèse nulle H_0

Mais p_c ne quantifie pas l’importance de la différence

Un peu de discussion...

Ne pas mettre en évidence de différence statistiquement significative entre 2 groupes

ne signifie pas

qu'il y ait **équivalence** entre les 2 groupes (H_0 vraie)
(Altman, 2005)

- ⇒ Un résultat non statistiquement significatif peut avoir 2 causes :
- l'hypothèse **H_0 est vraie** (i.e. les 2 groupes proviennent de la même population)
 - la puissance statistique n'est pas suffisante (i.e. nombre de sujets insuffisant, β existe et $\neq 0$)

Introduction

Comparaison de moyennes

2 échantillons indépendants

+ de 2 échantillons indépendants

2 échantillons appariés

Comparaison de fréquences

2 échantillons indépendants

2 échantillons appariés

Corrélation linéaire

χ^2 d'indépendance

Conclusion

Introduction

Comparaison
de moyennes

2 échantillons
indépendants

+ de 2 échantillons
indépendants

2 échantillons
appariés

Comparaison
de fréquences

2 échantillons
indépendants

2 échantillons
appariés

Corrélation
linéaire

χ^2 d'indépen-
dance

Conclusion

MERCI DE VOTRE ATTENTION