

Statistiques Déductives

Bon pas de panique, il y a pas mal de calculs mais rien de bien compliqué. On apprend bien les calculs et après on s'entraîne avec des exos et ça ira tout seul ! Et bon courage pour cette année !

I. Les tests d'hypothèses

a. Tout d'abord qu'est-ce que c'est ?

Ce sont des tests statistiques grâce auxquels on tente de tirer des conclusions à partir d'observations. On cherche donc à comparer deux populations.

b. Comment définir les hypothèses ?

- H_0 : Hypothèse nulle = aucune différence
- H_1 : Hypothèse alternative = différence


Deux situations possibles :

- Situation Unilatérale : On peut seulement dire si oui ou non il y a une différence
- Situation Alternative : On peut dire qu'une des deux conditions est meilleure si différence

Le test permet par la suite de confirmer ou d'infirmer les hypothèses formulées. En cherchant à savoir si on accepte ou rejette H_0 avec un risque α .

c. Étapes de mise en œuvre d'un test d'hypothèse

- 1- Définir H_0 et H_1 (rôles symétriques)
- 2- Définir le test en fonction des données (quantitatif ou qualitatif / grand ou petit échantillon)
- 3- Choisir le risque α (fixé à priori et le plus souvent 5%)
- 4- Recueillir les données
- 5- Calculer Z_c (paramètre que l'on cherche)
- 6- Utilisation de la règle de décision (basé sur H_0 et α et on examine Z_c sur le modèle théorique = courbe de Gauss et la compare à Z_t = valeur théorique lue sur la table statistique de l'écart-réduit




Acceptation de H_0	Rejet de H_0
$Z_c < Z_t$	$Z_c > Z_t$
$p = 1 - \alpha$	$p \leq \alpha$

- 7- Fixer le degré de signification de p (= *risque d'erreur réel qui se rattache à la conclusion donc à postériori = conviction avec laquelle on rejette α*)
- 8- Interpréter les résultats : au niveau de l'échantillon (est-ce qu'on accepte H_0) et au niveau de la population (est-ce qu'on peut extrapoler)

Ces étapes sont valables pour tous les tests qui vont suivre

A savoir :

- Si $\alpha = 5\%$ alors $Z_t = 1,96$
- Si $Z_c < Z_t$: on accepte H_0 et rejette H_1
- Si $Z_c > Z_t$: on rejette H_0 et accepte H_1
- Si $p \leq \alpha$: on rejette H_0 et accepte H_1
- Si H_0 est accepté $p = 1 - \alpha$



d. Risque et puissance d'un test

α = **Risque de première espèce** : Probabilité de rejeter H_0 alors que H_0 est vraie (*rejet à tort de l'hypothèse nulle souvent fixé à 5%*)

β = **Risque de deuxième espèce** : Probabilité d'accepter H_0 alors que H_0 est fautive (*rejet à tort de l'hypothèse alternative jamais définie mais en général égale à 20%*)

$1 - \beta$ = **Puissance du test** : Probabilité de rejeter H_0 alors que H_0 est fautive (*probabilité de bien détecter la différence*)

On choisit toujours de maîtriser α plutôt que β qui peut être pourtant important également. Rejeter H_0 à tort est le plus grave.

		Décision du statisticien	
		Rejet H_0	Non rejet H_0
Réalité	H_0 vraie	α	$1 - \alpha$
	H_1 vraie	$1 - \beta$	β

2. Liaison entre deux variables qualitatives

a. Comparaison de pourcentages

- 1- H_0 : Pas de différence significative entre les populations pour le caractère étudié
 H_1 : Différence significative du caractère étudié
- 2- **Qualitative Binaire** (Variable 1 : échantillon A/B - Variable 2 : Présence ou non du caractère)

- 3- Souvent $\alpha = 5\%$
- 4- Pourcentages p_A et p_B de la présence du caractère dans les échantillons A et B
- 5- Calcul : avec $q = 1 - p$

$$\varepsilon_c = \frac{pA - pB}{\sqrt{\frac{pA \cdot qA}{nA} + \frac{pB \cdot qB}{nB}}}$$

- 6- Comparer ε_c et ε_t lu dans la table de l'écart-réduit

Table de l'écart réduit

		α								
		0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09
0	∞	2,576	2,326	2,17	2,054	1,96	1,881	1,812	1,751	1,695
0,1	1,645	1,598	1,555	1,514	1,476	1,44	1,405	1,372	1,341	1,311
0,2	1,282	1,254	1,227	1,2	1,175	1,15	1,126	1,103	1,08	1,058
0,3	1,036	1,015	0,994	0,974	0,954	0,935	0,915	0,896	0,878	0,86
0,4	0,842	0,824	0,806	0,789	0,772	0,755	0,739	0,722	0,706	0,69
0,5	0,674	0,659	0,643	0,628	0,613	0,598	0,583	0,568	0,553	0,539
0,6	0,524	0,51	0,496	0,482	0,468	0,454	0,44	0,426	0,412	0,399
0,7	0,385	0,372	0,358	0,345	0,332	0,319	0,305	0,292	0,279	0,266
0,8	0,253	0,24	0,228	0,215	0,202	0,189	0,176	0,164	0,151	0,138
0,9	0,126	0,113	0,1	0,088	0,075	0,063	0,05	0,038	0,025	0,013

Pour $\alpha = 5\%$ on a $\varepsilon_t = 1,96$

- 7- Pour $\alpha = 5\%$
 - Si $\varepsilon_c < \varepsilon_t$: on accepte H_0 et rejette H_1 alors $p = 1 - \alpha$
 - Si $\varepsilon_c > \varepsilon_t$: on rejette H_0 et accepte H_1 alors $p = \alpha/2$
- 8- Interpréter les résultats

b. Test du χ^2 (CHI)

- 1- H_0 : Pas de différence dans la répartition du caractère étudié entre les populations (*pas de lien entre les deux variables étudiées*)
 H_1 : Différence dans la répartition du caractère étudié entre les populations (*lien entre les deux variables étudiées*)
- 2- Lien entre deux variables qualitatives avec $n \geq 2$ ($V1$: n échantillons / $V2$: n caractères étudiés)
- 3- Souvent $\alpha = 5\%$

- 4- Effectifs Observés

$V2 \setminus V1$	Modalité A	Modalité B	Totaux
Modalité 1	O_1	O_2	$O_1 + O_2$
Modalité 2	O_3	O_4	$O_3 + O_4$
Totaux	$O_1 + O_3$	$O_2 + O_4$	$O_1 + O_2 + O_3 + O_4$

- 5- Calculer χ^2

o_i = données observées

c_i : données calculées = $\frac{(\text{ligne } i) \times (\text{colonne } i)}{\text{Effectif total}}$

$$X_c^2 = \frac{\sum(o_i - c_i)}{c_i}$$

- 6- Comparaison de X_c^2 à X_t^2 lue dans la table du X^2 fonction du risque et du degré de liberté (ddl) = nombre minimal de valeur dans une série qui permet de calculer les valeurs manquantes lorsqu'on dispose des totaux

$$\text{DDL} = (\text{nombre de lignes} - 1) \times (\text{nombre de colonnes} - 1)$$

- 7- Comparer X_c^2 et X_t^2

ddl	α								
	0,9	0,5	0,3	0,2	0,1	0,05	0,02	0,01	0,001
1	0,016	0,455	1,074	1,642	2,706	3,841	5,412	6,635	10,827
2	0,211	1,386	2,408	3,219	4,605	5,991	7,824	9,21	13,815
3	0,584	2,366	3,665	4,642	6,251	7,815	9,837	11,345	16,266
4	1,064	3,357	4,878	5,989	7,779	9,488	11,668	13,277	18,467
5	1,61	4,351	6,064	7,289	9,236	11,07	13,388	15,086	20,515
6	2,204	5,348	7,231	8,558	10,645	12,592	15,033	16,812	22,457
7	2,833	6,346	8,383	9,803	12,017	14,067	16,622	18,475	24,322

Pour $\alpha = 5\%$ et $ddl = 1$ on a $X_t^2 = 3,841$

- 8- Interpréter les résultats

3. Liaison entre deux variables : qualitative et quantitative

a. Comparaison de moyennes pour séries indépendantes

- 1- H_0 : Les moyennes ne sont pas différentes
 H_1 : Les moyennes sont différentes
- 2- Lien d'une variable qualitative avec une variable quantitative indépendante avec n_A et $n_B \geq 30$ = grands échantillons
- 3- Souvent 5%
- 4- Calcul des moyennes m_A et m_B et des écarts-types s_A et s_B
- 5- Calcul de ϵ

$$\epsilon = \frac{m_1 - m_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

- 6- Voir Table de l'écart réduit
- 7- Comparer ε_α et ε
- 8- Interpréter les résultats

b. Test t de Student pour séries indépendantes

- 1- H0 : Les moyennes ne sont pas différentes
H1 : Les moyennes sont différentes
- 2- Lien d'une variable qualitative avec une variable quantitative indépendante
avec n_A et $n_B < 30 =$ petits échantillons
- 3- Souvent 5%
- 4- Calcul des moyennes m_A et m_B et des écart-types s_A et s_B
- 5- Calcul de t

$$t = \frac{m_1 - m_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

- 6- Lecture dans la table t de Student
Avec **DDL = (n1-1) + (n2-1)**

α d.d.l.	0,90	0,50	0,30	0,20	0,10	0,05	0,02	0,01	0,001
1	0,158	1,000	1,963	3,078	6,314	12,706	31,821	63,657	636,619
2	0,142	0,816	1,386	1,886	2,920	4,303	6,965	9,925	31,598
3	0,137	0,765	1,250	1,638	2,353	3,182	4,541	5,841	12,924
4	0,134	0,741	1,190	1,533	2,132	2,776	3,747	4,604	8,610
5	0,132	0,727	1,156	1,476	2,015	2,571	3,365	4,032	6,869
6	0,131	0,718	1,134	1,440	1,943	2,447	3,143	3,707	5,959
7	0,130	0,711	1,119	1,415	1,895	2,365	2,998	3,499	5,408
8	0,130	0,706	1,108	1,397	1,860	2,306	2,896	3,355	5,041
9	0,129	0,703	1,100	1,383	1,833	2,262	2,821	3,250	4,781
10	0,129	0,700	1,093	1,372	1,812	2,228	2,764	3,169	4,587
11	0,129	0,697	1,088	1,363	1,796	2,201	2,718	3,106	4,437

- 7- Comparer t et t_α
- 8- Interpréter les résultats

c. Comparaison de moyennes pour séries appariées = méthode des couples

- 1- H0 : Les moyennes ne sont pas différentes
H1 : Les moyennes sont différentes

- 2- Lien d'une variable qualitative avec une variable quantitative (1 échantillon mais 2 valeurs par personne) avec n_A et $n_B \geq 30$ = grands échantillons
- 3- Souvent 5%
- 4- Calcul de la moyenne m_d et de l'écart-type s_d avec d la différence de résultat pour un même sujet
- 5- Calcul de ε

$$\varepsilon = \frac{m_d}{\sqrt{\frac{s^2}{n}}}$$

- 6- Voir Table de l'écart réduit
- 7- Comparer ε_α et ε
- 8- Interpréter les résultats

d. Test t de Student pour séries appariées = méthode des couples

- 1- H_0 : Les moyennes ne sont pas différentes
 H_1 : Les moyennes sont différentes
- 2- Lien d'une variable qualitative avec une variable quantitative (1 échantillon mais 2 valeurs par personne) avec n_A et $n_B < 30$ = petits échantillons
- 3- Souvent 5%
- 4- Calcul de la moyenne m_d avec d la différence de résultat pour un même sujet et la variance de la différence s^2
- 5- Calcul de t

$$t = \frac{m_d}{\sqrt{\frac{s^2}{n}}}$$

- 6- Voir table t de Student avec $ddl = n - 1$
- 7- Comparer t et t_α
- 8- Interpréter les résultats


4. Liaison entre deux variables quantitatives

a. Corrélation et régression


Corrélation : évaluation de la liaison entre deux variables quantitatives

Régression : méthode qui permet l'explication mathématique des relations entre variables observées

Nuage de points :



Droite de régression : permet de visualiser si une des 2 variables est **dépendante** de l'autre



V1 en x
V2 en y
Soit la droite $y=f(x)$

Droite de régression = Droite des moindres carrées : passe au plus près de chaque point du nuage -> elle permet de prédire la valeur d'une variable en connaissant l'autre.

b. Test du coefficient de corrélation

- 1- H0 : Les variables sont indépendantes entre elles (Pas de lien)
HI : Les variables sont dépendantes = corrélées (lien entre les deux variables étudiées)
- 2- Variables quantitatives avec $n \geq 10$ par échantillon
- 3- Souvent $\alpha = 5\%$
- 4- Recueil de x_i et y_i pour chaque valeur pour chaque échantillon et de leur moyenne m_x et m_y
- 5- Calcul de $r =$ Coefficient de corrélation = pente de la droite ($TJS < 1$)
Si $r = 0$ alors pas calculable (non lié)
Si $r > 0$: Les variables varient dans le même sens (liaison positive)
Si $r < 0$: Les variables varient en sens opposé (liaison négative)

$$r = \frac{\sum(x_i - m_x)(y_i - m_y)}{\sqrt{\sum(x_i - m_x)^2 \sum(y_i - m_y)^2}} = \frac{\sum xy - \frac{\sum x \sum y}{n}}{\sqrt{(\sum x^2 - \frac{(\sum x)^2}{n})(\sum y^2 - \frac{(\sum y)^2}{n})}}$$

6- Lecture de la table du coefficient de corrélation avec **DDL = n - 2**

d.d.l. \ α	0,10	0,05	0,02	0,01
1	0,9877	0,9969	0,9995	0,9999
2	0,9000	0,9500	0,9800	0,9900
3	0,8054	0,8783	0,9343	0,9587
4	0,7293	0,8114	0,8822	0,9172
5	0,6694	0,7545	0,8329	0,8745
6	0,6215	0,7067	0,7887	0,8343
7	0,5822	0,6664	0,7498	0,7977
8	0,5494	0,6319	0,7155	0,7646
9	0,5214	0,6021	0,6851	0,7348
10	0,4973	0,5760	0,6581	0,7079
11	0,4762	0,5529	0,6339	0,6835
12	0,4575	0,5324	0,6120	0,6614
13	0,4409	0,5139	0,5923	0,6411
14	0,4259	0,4973	0,5742	0,6226
15	0,4124	0,4821	0,5577	0,6055

- 7- Comparer $|r|$ et r_α
- 8- Extrapolation possible uniquement si tirage au sort !
Corrélation \neq Causalité

5. Tests non paramétriques

a. Définition

Utilisé en cas d'effectif très faible soit $4 < n < 12$ avec un caractère quantitatif c'est le seul test possible. Test avec forte robustesse (= utile alors que la population ne se distribue pas normalement) car transforme les données quantitatives en mesures ordinaires (=rangs)

b. Test U de Mann et Whitney

- 1- H_0 : Les moyennes sont proches (Pas de différence)
 H_1 : Les moyennes ne sont pas proches (différence)
- 2- **Une variable quantitative et une variable qualitative** avec n_A et ou $n_B < 12$
- 3- Souvent $\alpha = 5\%$
- 4- Recueil des valeurs de A et B puis rangement croissant
Attention les valeurs égales comptent 1/2

Nbr	1	5	7	10	13	23	34	56	67	134	235
Grp	A	A	B	A	B	A	A	B	A	B	B
U	0	0	2	1	3	2	2	5	3	6	6

- 5- Calcul de U_{AB} et U_{BA}
 $U_{AB} = 2+3+5+6+6 = 22$
 $U_{BA} = 0+0+1+2+2+3 = 8$
RQ: $U_{AB} + U_{BA} = n_A + n_B = 22+8 = 6 \times 5 = 30$
 U_c est la plus petite somme entre U_{AB} et U_{BA} de même pour n_i

6- Avec $n_1 = 5$ et $n_2 - n_1 = 1$ alors $U_t = 3$

$n_2 - n_1$	1	2	3	4	5	6	7	8	9	10
0	-	-	-	0	2	5	8	13	17	23
1	-	-	-	1	3	6	10	15	20	26

→ La valeur U théorique = 3

7- Comparer U et $U_{\text{théo}}$

8- Interpréter les résultats

c. Test du coefficient r' de Spearman

1- H_0 : Pas de lien entre les variables

H_1 : Lien entre les variables

2- Deux **variables quantitatives** avec $n < 12$

3- Généralement 5%

4- Recueil des valeurs, classement par ordre croissant, Calcul de la différence de rang attribué

5- Calcul de r' ($tjs < 1$)

d_i = différence de rang entre x et y pour un couple i

Si $r > 0$: Les variables varient dans le même sens (*liaison positive*)

Si $r < 0$: Les variables varient en sens opposé (*liaison négative*)

$$r' = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)}$$

6- On cherche r' fonction de α et n

$n \backslash \alpha$	0.2	0.1	0.05	0.02	0.01	0.002
4	1.000	1.000	-	-	-	-
5	0.800	0.900	1.000	1.000	-	-
6	0.657	0.829	0.886	0.943	1.000	-
7	0.571	0.714	0.786	0.893	0.929	1.000
8	0.524	0.643	0.738	0.833	0.881	0.952
9	0.483	0.600	0.700	0.783	0.833	0.917
10	0.455	0.564	0.648	0.745	0.794	0.879
11	0.427	0.536	0.618	0.709	0.755	0.845
12	0.406	0.503	0.587	0.678	0.727	0.818

7- Comparer $|r'|$ et r'_α

8- Si H_1 vrai alors les deux séries sont corrélées

6. Synthèse

	Test	
	Paramétriques	Non paramétrique
Comparaison de 2 échantillons indépendants	<ul style="list-style-type: none"> ▲ Test t de Student ▲ Test de comparaison de moyennes 	<ul style="list-style-type: none"> ▲ Test de Mann-Whitney
Comparaison de 2 échantillons appariés	<ul style="list-style-type: none"> ▲ Test t de Student pour séries appariées ▲ Test de comparaison de moyennes pour séries appariées 	<ul style="list-style-type: none"> ▲ Test de Wilcoxon
Test de corrélation	<ul style="list-style-type: none"> ▲ Test du coefficient r 	<ul style="list-style-type: none"> ▲ Test du coefficient r' de Spearman

Effectif	Données quantitatives	Données qualitatives	Données qualitatives et quantitatives
$n \geq 30$	<ul style="list-style-type: none"> • Coefficient de corrélation r • r' de Spearman 	<ul style="list-style-type: none"> • Comparaison de pourcentages • Chi-2 	<ul style="list-style-type: none"> • Comparaison de moyennes • T de Student • U Mann et Whitney
$30 > n \geq 12$	<ul style="list-style-type: none"> • Coefficient de corrélation r • r' de Spearman 	<ul style="list-style-type: none"> • Comparaison de pourcentages • Chi-2 	<ul style="list-style-type: none"> • T de Student • U Mann et Whitney
$12 > n > 4$	<ul style="list-style-type: none"> • r' de Spearman 	<ul style="list-style-type: none"> • Comparaison de pourcentages • Chi-2 	<ul style="list-style-type: none"> • U Mann et Whitney

Petite dédicace rapide car il est 1h du matin, que j'ai sommeil et que j'ai déjà dépassé la dead line mais bon je voulais vous faire un joli cours.

Dédicace au tuteur de l'an dernier sur qui j'ai pris exemple et à qui j'ai piqué quelques phrases

Dédicace à ma maman parce que bon je serais pas là sans elle quand même

Dédicace à nos chef Tut

Dédicace à toute la famille Biostat

Dédicace à vous les PI à qui je souhaite beaucoup de courage et en qui je crois pour cette année