

Objectifs du cours

Etre capable de comparer


- deux pourcentages de 2 séries indépendantes

Tous les tests statistiques, quels qu'il soient,

calculent

la probabilité de se tromper en rejetant H_0

↓
le petit p



**Comment comparer
deux pourcentages de deux
séries indépendantes?**

- Test exact de Fisher
- Test du χ^2 (χ^2) de Pearson

Exemple 1

Epidémie de gastro-entérite

	Malades	Sains	Taux d'attaque
Huitres +	41	68	37,6 %
Huitres -	13	48	21,3%

Problème ?

Avait-t-on vraiment plus de risques de contracter une gastro-entérite après avoir mangé des huitres?

Y-a-t-il vraiment un taux d'attaque plus élevé chez les mangeurs d'huitres que chez les non-mangeurs ?

Exemple 1

La fréquence de gastro-entérite est-elle plus élevée chez les mangeurs d'huitres ?


Mangeurs d'huitres : taux d'attaque = 37,6 %
Non-mangeurs : taux d'attaque = 21,3 %

H_0 : taux d'attaque_{mangeurs} = taux d'attaque_{non-mangeurs}

H_1 : taux d'attaque_{mangeurs} \neq taux d'attaque_{non-mangeurs}


Comparaison de 2 pourcentages

échantillons



Comparaison de 2 pourcentages

échantillons



Si H_0 est vraie $P_1 = P_2 = P$

Exemple 1 Epidémie de gastro-entérite

	Malades	Sains	Taux d'attaque
Huitres +	41	68	37,6 %
Huitres -	13	48	21,3%

Si H_0 est vrai,
la différence Δ entre les 2 pourcentages
devrait être proche de zéro

$$\text{Or } \Delta = 37,6 \% - 21,3 \% = 16,3 \%$$

Est-ce que 16,3 est suffisamment éloigné de zéro
pour qu'on rejette H_0 ?

**Principe des tests
de comparaison de pourcentages**

Calculer la probabilité, si H_0 est vrai,
d'obtenir une configuration montrant
une différence au moins aussi grande
que celle qui a été observée

- 1) Si cette probabilité est faible ($< 5\%$), alors on considère
 - que la configuration observée n'est pas due au hasard
 - on rejette H_0
 - on accepte H_1
- 2) Si cette probabilité est élevée, alors
 - on ne rejette pas H_0
 - on considère que la différence est due à une simple fluctuation d'échantillonnage

Test exact de Fisher
pour comparer deux pourcentages

Principe du test exact de Fisher (1)

- 1) Calculer la probabilité, si H_0 est vrai,
d'obtenir la configuration observée

a	b	t_1
c	d	t_2
n_1	n_2	N

$$p = \frac{n_1! n_2! t_1! t_2!}{a! b! c! d! N!}$$

Principe du test exact de Fisher (1)

1) Calculer la probabilité, si H_0 est vrai, d'obtenir la configuration observée

	Malades	Sains	Total
Huitres +	41	68	109
Huitres -	13	48	61
Total	54	116	170

$$\Delta = 37,6 \% - 21,3 \% = 16,3 \%$$

$$p = \frac{54! 116! 109! 61!}{41! 68! 13! 48! 170!} = 0,012$$

Principe du test exact de Fisher (2)

2) Calculer toutes les probabilités d'obtenir, si H_0 est vrai, des configurations aboutissant à une différence encore plus grande

	M	S	T.A	$ \Delta $	p		M	S	T.A	$ \Delta $	p
+	41	68	37,6	16,3	0,012	+	28	81	25,7	16,9	0,01
-	13	48	21,3			-	26	35	42,6		
+	42	67	38,5	18,8	0,0052	+	27	82	24,8	19,5	0,005
-	12	49	19,7			-	27	34	44,3		
+	43	66	39,4	21,4	0,0020	Hypothèse alternative bilatérale					
-	11	50	18,0			Lorsque le taux d'attaque est plus élevé chez les non mangeurs					
+	44	65	40,4	24,0	0,0006	Lorsque le taux d'attaque est plus élevé chez les mangeurs					
-	10	51	16,4								

Principe du test exact de Fisher (3)

3) Additionner toutes les p d'obtenir, des configurations aboutissant à une différence encore plus grande

	M	S	T.A	Δ	p		M	S	T.A	Δ	p
+	41	68	37,6	16,3	0,012	+	28	81	25,7	16,9	0,01
-	13	48	21,3			-	26	35	42,6		
+	42	67	38,5	18,8	0,0052	+	27	82	24,8	19,5	0,005
-	12	49	19,7			-	27	34	44,3		
+	43	66	39,4	21,4	0,0020	+					
-	11	50	18,0			-					

$$p = 0,12 + 0,0052 + 0,002 + \dots + 0,01 + 0,005 + \dots$$

$$p = 0,039$$

Principe du test exact de Fisher (3)

3) Additionner toutes les probabilités d'obtenir, si H_0 est vrai, des configurations aboutissant à une différence encore plus grande que celle qui est observée

$$p = \sum \frac{n_1! n_2! t_1! t_2!}{a! b! c! d! N!}$$

Exemple 1 Test de Fisher exact avec Stata

	Malades	Sains	Taux d'attaque
Huitres +	41	68	37,6 %
Huitres -	13	48	21,3%

Conclusion :
la différence entre les T.A. chez consommateurs
et non-consommateurs d'huitres est significative.

$$p < 0,04$$

Test exact de Fisher
Conditions d'application

Aucune !

si ce n'est un ordinateur
et un logiciel

Test de χ^2

(test de chi2 de Pearson)

Exemple 1

Epidémie de gastro-entérite

	Malades	Sains	Total	Taux d'attaque
Huitres +	41	68	109	37,6 %
Huitres -	13	48	61	21,3%
Total	54	116	170	31,8%

Si H_0 est vraie, il devrait y avoir, la même proportion de malades chez consommateurs d'huitres et les non-consommateurs

Si H_0 est vraie, il devrait y avoir

31,8 % de malades chez les 109 consommateurs d'huitres

31,8 % de malades chez les 61 non-consommateurs

TESTS STATISTIQUES

COMPARAISON DE POURCENTAGES

PR BOUZBID

Faculté de Médecine d'Annaba
Biomathématiques Statistiques
1 ère année Médecine Dentaire

EX 2

Epidémie de gastro-entérite

Comparaison de la fréquence de la maladie
selon la consommation de tomates

Effectifs observés :

	Malades	Sains	Total	Taux d'attaque
Huitres +	41	68	109	37,6 %
Huitres -	13	48	61	21,3 %
Total	54	116	170	31,8 %

Si H_0 est vrai, on devrait avoir un tableau proche du tableau suivant:

	Malades	Sains	Total	Taux d'attaque
Huitres +			109	31,8 %
Huitres -			61	31,8 %
Total	54	116	170	31,8 %

exemple 1

Test de chi2

Tableau de valeurs attendues (théoriques)

	Malades	Sains	Total	Taux d'attaque
Huitres +	34,6	74,4	109	31,8 %
Huitres -	$= 54/170 \times 61$	$= 116/170 \times 61$	61	31,8 %
Total	54	116	170	31,8 %

Exemple 1 Epidémie de gastro-entérite
 Comparaison des effectifs observés et attendus

Effectifs observés :

	Malades	Sains	Total	Taux d'attaque
Huitres +	41	68	109	37,6 %
Huitres -	13	48	61	21,3%
Total	54	116	170	31,8%

Si H_0 est vrai, on devrait avoir le tableau d'effectifs attendus :

	Malades	Sains	Total	Taux d'attaque
Huitres +	34,6	74,4	109	31,8%
Huitres -	19,4	41,6	61	31,8%
Total	54	116	170	31,8%

Exemple 1 Epidémie de gastro-entérite
 Comparaison des effectifs observés et attendus

41	68
13	48

Effectifs observés : o_i

34,6	74,4
19,4	41,6

Effectifs attendus, théoriques ou calculés : c_i

Si H_0 est vraie, la somme des différences entre les o_i et les c_i est proche de zéro

≈ 0	≈ 0
≈ 0	≈ 0

**Test de χ^2
Principe**

On calcule une expression

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

L'expression ci-dessus suit un loi dite du χ^2 .

Si H_0 est vrai, la valeur χ^2 doit être proche de zéro.

Notion de degré de liberté : ddl


32		109
		61
54	116	170

Notion de degré de liberté : ddl

32	77	109
22	39	61
54	116	170

$$\text{ddl} = (C-1) \times (L-1)$$

$$\text{ddl} = (2-1) \times (2-1) = 1$$



Test de χ^2 à 1ddl Principe

- Si la valeur observée χ^2_0 est inférieure à 3,84 , on ne rejette pas H₀
- Si la valeur observée χ^2_0 est supérieure à 3,84, on rejette H₀
- On regarde dans la table de χ^2 , la valeur de p correspondant à la valeur observée χ^2_0 .

Exemple 1 Epidémie de gastro-entérite
Calcul du χ^2

o_i	41	68
	13	48

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

c_i	34,6	74,4
	19,4	41,6

$$\chi^2 = \frac{(41 - 34,6)^2}{34,6} + \frac{(68 - 74,4)^2}{74,4} + \frac{(13 - 19,4)^2}{19,4} + \frac{(48 - 41,6)^2}{41,6}$$

$\chi^2 = 4,8 \quad > 3,84$

**Table de χ^2 , ddl = 1
(alpha bilatéral)**

$\chi^2 = 4,8$

$\chi^2 >$	1,64	2,71	3,84	4,22	4,71	5,41	6,63
alpha	20%	10%	5%	4%	3%	2%	1%

$p < 3 \%$

Exemple 1

Epidémie de gastro-entérite

	Malades	Sains	Total	Taux d'attaque
Huitres +	41	68	109	37,6 %
Huitres -	13	48	61	21,3%

Conclusion :
la différence entre les taux d'attaque
chez consommateurs et non-consommateurs d'huitres
est significative.

$$p < 3\%$$

Tests de χ^2 : condition d'application

les effectifs « théoriques » de chaque case

doivent être ≥ 5