

GC – Probabilités et Statistique

<http://moodle.epfl.ch/course/view.php?id=14271>

Cours 12

■ CETTE MATIÈRE NE SERA PAS EXAMINÉE!!

■ Tests χ^2 :

■ CETTE MATIÈRE NE SERA PAS EXAMINÉE!!

- **Adéquation** : tester la conformité ('goodness-of-fit' / 'adéquation') des données à une distribution théorique
- **Indépendance** : étude de la distribution conjointe de deux variables qualitatives
- **Homogénéité** : comparaison de la distribution d'une variable qualitative dans plusieurs échantillons

■ Paradoxe de Simpson

Révision : Variables (I)

- En statistique, les caractéristiques qui varient pour les individus de la populations sont appelées **variables**
- Différentes sortes de variables :
 - **Variables qualitatives** : les modalités sont des mots ou 'etiquettes' que l'on appelle des *catégories*
Exemples : couleur des yeux ('bleu', 'brun', 'vert') ;
votre programme de télé préféré
 - **Variables quantitatives** : les modalités sont des valeurs numériques
Exemples : âge, nombre de membres d'une famille, le poids

Révision : Variables (II)

- **Variables qualitatives** peuvent être classées comme :
 - Échelle *nominale* – les catégories ne sont pas naturellement ordonnées (e.g. couleur des yeux, sexe)
 - *Même si* les modalités ont des codes numériques (e.g. sexe = '0' pour 'mâle', = '1' pour 'femelle')
 - Échelle *ordinale* – les catégories peuvent être ordonnées (e.g. 'toujours', 'quelquefois', 'jamais')
- **Variables quantitatives** sont distinguées comme :
 - Variables *discrètes* – les valeurs possibles peuvent être énumérées sous la forme d'une list de chiffres (le plus souvent : les entiers naturels 0, 1, 2, ...)
 - Variables *continues* – l'ensemble des valeurs possibles est constitué par une intervalle

Analyse des données catégorielles

- Jusqu'à présent, on a examiné des variables continues (en régression) et variables factorielles (catégorielles) dans le contexte de l'ANOVA
- Une variable catégorielle pourrait être considérée comme un *classement* des observations
- Classement : une variable
 - test d'adéquation
- Classements : plusieurs variables (au moins 2)
 - représentation par tableau de contingence
 - test d'indépendance
 - test de l'homogénéité des distributions
 - p. ex. test d'égalité des deux proportions

Test d'adéquation

- Comment pouvons-nous mesurer l'adéquation des données à une théorie ?
- Situation : on observe la répartition de n objets dans k classes
- On veut tester l'*adéquation des données à une distribution théorique*

Example 12.1

Soixante lancers d'un dé ont donné les résultats :

huit fois '1'

dix fois '2'

neuf fois '3'

seize fois '4'

treize fois '5'

quatre fois '6'

On veut tester l'hypothèse selon laquelle le dé est équilibré – comment peut-on faire cela ??

Révision : Multinomial distribution

- L'une des distributions conjointes les plus importantes (VAs discrètes) est la **distribution multinomiale**
- Il s'agit d'un analogue à plusieurs variables de la *distribution binomiale* :
 - Pour la distribution *binomiale*, il y a 2 résultats possibles pour chacun des n épreuves indépendantes
 - Pour la distribution *multinomiale*, chaque épreuve peut entraîner l'un des r résultats possibles, de probabilités respectives $p_1, p_2, \dots, p_r$, telles que $\sum_{i=1}^r p_i = 1$
- La loi conjointe de la distribution multinomiale est :

$$P(X_1 = n_1, X_2 = n_2, \dots, X_r = n_r) = \frac{n!}{n_1! n_2! \dots n_r!} p_1^{n_1} p_2^{n_2} \dots p_r^{n_r}$$

- Si $r = 2$, c'est quelle distribution ??

Test d'adéquation, cont.

- Pour tester l'adéquation des données à une répartition théorique, on dispose de deux éléments :

- n *observations réparties* dans k 'cellules' :

n_1	n_2	$\cdots$	n_k
-------	-------	----------	-------

- une fonction de *fréquence théorique* :

p_1	p_2	$\cdots$	p_k
-------	-------	----------	-------

- *Une mesure de distance* entre la répartition empirique (observée) et la loi théorique se base sur la répartition des n observations selon la loi théorique (les *nombres espérés* dans les cellules) :

$n \times p_1$	$n \times p_2$	$\cdots$	$n \times p_k$
----------------	----------------	----------	----------------

Statistique de test

- La statistique de test :

$$\begin{aligned} \chi_{obs}^2 &= \sum_{i=1}^k \frac{(\text{observé} - \text{espéré})^2}{\text{espéré}} \\ &= \sum_{i=1}^k \frac{(n_i - np_i)^2}{np_i} \end{aligned}$$

- Pour n 'suffisamment grand' ($\forall i, = \boxed{np_i \geq 5}$), sous H

$$\chi_{obs}^2 \sim \chi_{k-p-1}^2,$$

où p = nombre de paramètres estimés à partir des données

- $\Rightarrow$ Règle générale : il faut un nombre espéré de **5** dans chaque cellule

Table de χ^2

TABLE C: Chi-Square distributions

cum probability		0.025	0.80	0.90	0.95	0.975	0.99	0.995	0.999	0.9995
right tail		0.975	0.2	0.1	0.05	0.025	0.01	0.005	0.001	0.0005
	df									
	1	0.00098	1.64	2.71	3.84	5.02	6.63	7.88	10.83	12.12
	2	0.051	3.22	4.61	5.99	7.38	9.21	10.60	13.82	15.20
	3	0.216	4.64	6.25	7.81	9.35	11.34	12.84	16.27	17.73
	4	0.48	5.99	7.78	9.49	11.14	13.28	14.86	18.47	20.00
	5	0.83	7.29	9.24	11.07	12.83	15.09	16.75	20.51	22.11
	6	1.24	8.56	10.64	12.59	14.45	16.81	18.55	22.46	24.10
	7	1.69	9.80	12.02	14.07	16.01	18.48	20.28	24.32	26.02
	8	2.18	11.03	13.36	15.51	17.53	20.09	21.95	26.12	27.87
	9	2.70	12.24	14.68	16.92	19.02	21.67	23.59	27.88	29.67
	10	3.25	13.44	15.99	18.31	20.48	23.21	25.19	29.59	31.42
	11	3.82	14.63	17.28	19.68	21.92	24.73	26.76	31.26	33.14
	12	4.40	15.81	18.55	21.03	23.34	26.22	28.30	32.91	34.82
	13	5.01	16.98	19.81	22.36	24.74	27.69	29.82	34.53	36.48
	14	5.63	18.15	21.06	23.68	26.12	29.14	31.32	36.12	38.11
	15	6.26	19.31	22.31	25.00	27.49	30.58	32.80	37.70	39.72
	16	6.91	20.47	23.54	26.30	28.85	32.00	34.27	39.25	41.31
	17	7.56	21.61	24.77	27.59	30.19	33.41	35.72	40.79	42.88
	18	8.23	22.76	25.99	28.87	31.53	34.81	37.16	42.31	44.43
	19	8.91	23.90	27.20	30.14	32.85	36.19	38.58	43.82	45.97
	20	9.59	25.04	28.41	31.41	34.17	37.57	40.00	45.31	47.50
	21	10.28	26.17	29.62	32.67	35.48	38.93	41.40	46.80	49.01
	22	10.98	27.30	30.81	33.92	36.78	40.29	42.80	48.27	50.51
	23	11.69	28.43	32.01	35.17	38.08	41.64	44.18	49.73	52.00
	24	12.40	29.55	33.20	36.42	39.36	42.98	45.56	51.18	53.48
	25	13.12	30.68	34.38	37.65	40.65	44.31	46.93	52.62	54.95
	30	16.79	36.25	40.26	43.77	46.98	50.89	53.67	59.70	62.16
	40	24.43	47.27	51.81	55.76	59.34	63.69	66.77	73.40	76.10
	50	32.36	58.16	63.17	67.50	71.42	76.15	79.49	86.66	89.56
	60	40.48	68.97	74.40	79.08	83.30	88.38	91.95	99.61	102.7
	80	57.15	90.41	96.58	101.9	106.6	112.3	116.3	124.8	128.3
	100	74.22	111.7	118.5	124.3	129.6	135.8	140.2	149.4	153.2

Exemple, cont.

Exemple 12.1, cont.

Faisons le test ($\alpha = 0,05$) ...

1

2

3

4

5

Autre exemple

Exemple 12.2 Supposons que la proportion des éléments 'défectueux' dans une grande population est inconnue, et que l'on veut tester les hypothèses : $H : p = 0.1$ vs. $A : p \neq 0.1$

Activité Faire un test d'adéquation en supposant un échantillon aléatoire de 100 éléments dont 16 défectueux...

1

2

3

4

5

Pouvez-vous penser à un autre test pour résoudre ce problème ??

Distributions continues

- Pour une loi *discrète*, il est facile de faire la répartition nécessaire pour le test...
- ... ce qui *ne marche plus* pour les distributions *continues* :
 - plusieurs répartitions possibles
 - comment choisir ??

Exemple spécifique : loi uniforme

- Considérons une VA X qui prend les valeurs entre 0 et 1, mais la densité n'est pas connue
- Supposons en plus qu'on a un échantillon de 100 valeurs tirées aléatoirement de cette distribution, et qu'on veut tester si les observations suivent la loi uniforme
- Alors, on peut diviser l'intervalle $(0, 1)$ en 20 sous-intervalles $(0, 0.05)$, $(0.05, 0.10)$, *etc.*
- Si la distribution est uniforme, alors la probabilité qu'une observation particulière est dans le sous-intervalle i est $p_i = 1/20$, $i = 1, \dots, 20$
- On a donc que le nombre espéré dans chaque sous-intervalle est $np_i = 100/20 = 5$
- Ensuite, on peut faire le calcul de la statistique X^2 comme avant

Distributions continues, cont.

- Cette méthode pourrait être utilisée pour *toute distribution continue* (elle ne dépende pas de la distribution uniforme)
- Le choix de k et un peu arbitraire : en général, choisissez un nombre k et les sous-intervalles tel que les nombres espérés sont **à peu près égaux et pas trop petits**
- 1 Faire une partition de l'intervalle (qui pourrait être toutes les réelles) en k sous-intervalles disjoints
- 2 Déterminer la probabilités $p_i^0, i = 1, \dots, k$, en supposant une distribution particulière (H), et donc les *nombres espérés* (np_i^0)
- 3 $\forall i$, trouver N_i , le nombre *d'observations* dans le sous-intervalle i
- 4 Calculer X_{obs}^2
- 5 Sous H , $X_{obs}^2 \sim \chi_{k-1}^2$

Test des hypothèses composées

- On a considéré les hypothèses (nulles) **simples** : la loi est *complètement spécifiée* par l'hypothèse
- P. ex. $H : p = 0.1$ est une hypothèse *simple*
- Dans ce cas, il n'est pas nécessaire de faire l'estimation des paramètres, et la statistique $X_{obs}^2 \sim \chi_{k-1}^2$ sous H
- Par contre, il se peut que l'hypothèse nulle comprend *plusieurs valeurs* pour le(s) paramètre(s)
- Une telle hypothèse est dite **composée**

Statistique de test pour les hypothèses composées

- Pour une hypothèse nulle composée, il faut *modifier* la statistique de test X_{obs}^2 , car le nombre espéré d'observations de classe i n'est plus complètement spécifié par l'hypothèse nulle H
- **Modification :** remplacer np_i *par son EMV* $n\hat{p}_i$ dans le calcul de X_{obs}^2
- Sous H , cette $X_{obs}^2 \sim \chi_{k-p-1}^2$, où p est le *nombre de paramètres estimés* pour le calcul des $\hat{p}_i$

Example

Example 12.3

Dans une population d'une plante diploïde annuelle, on a observé la composition génotypique d'un échantillon de 146 individus pour un locus autosomal. Trois allèles codominants F , S et C ont été mis en évidence. On a obtenu les résultats suivants (les parents sont inconnus, alors l'ordre des allèles n'est pas important ; donc p. ex. ' FS ' se réfère à FS ou SF) :

FF	FS	FC	SS	SC	CC
18	76	24	13	10	5

La population présente-t-elle des proportions conformes à celles de Hardy-Weinberg ?

[Indication : HWE proportions pour 3 allèles sont $(p + q + r)^2$]

Test

1

2

3

4

5

PAUSE

Tableau de contingence

- Le *tableau de contingence* est un moyen particulier de représenter *simultanément* deux caractères observés sur une même population (ou échantillon)
- On représente les *fréquences* des valeurs d'un couple de variables (X, Y) de modalités $x_i = 1, \dots, r$, $y_j = 1, \dots, c$, dans un tableau à double entrée, le *tableau de contingence*
- r = nombre de lignes, c = nombre de colonnes
- Exemple :
 - Couleur des cheveux = blonds, roux, bruns, noirs
 - Couleur des yeux = bruns, verts, bleus
- Les valeurs dans le tableau représente *le nombre d'observations de chaque combinaison* des valeurs possibles pour le couple ('cellule')
- Les *sommes* des valeurs d'une ligne ou d'une colonne sont les *effectifs marginaux*

Tableau cheveux/yeux

The table shows the relationship between eye color (yeux) and hair color (chev.). The rows represent hair colors (blonds, roux, bruns, noirs) and the columns represent eye colors (bleus, verts, bruns). The cells are labeled n_{ij} . The marginal totals are labeled $n_{i.}$ for rows and $n_{.j}$ for columns. The Grand Total is labeled $n_{..}$.

Annotations:

- cellules* (red arrows pointing to the cells n_{11}, n_{12}, n_{13})
- effectifs marginaux (lignes)* (blue arrows pointing to the row marginal totals $n_{1.}, n_{2.}, n_{3.}, n_{4.}$)
- effectifs marginaux (colonnes)* (green arrows pointing to the column marginal totals $n_{.1}, n_{.2}, n_{.3}$)

yeux chev.	bleus	verts	bruns	
blonds	n_{11}	n_{12}	n_{13}	$n_{1.}$
roux	n_{21}	n_{22}	n_{23}	$n_{2.}$
bruns	n_{31}	n_{32}	n_{33}	$n_{3.}$
noirs	n_{41}	n_{42}	n_{43}	$n_{4.}$
	$n_{.1}$	$n_{.2}$	$n_{.3}$	Grand Total $n_{..}$

Test d'indépendance : intuition

- Construire le tableau bivarié théorique sous la NULLE *i.e.* s'il n'y a *pas d'association*
- Comparer le tableau *réel, observé* au tableau théorique
- Mesurer *la différence* entre ces deux tableaux
- S'il existe *une différence suffisamment grande*, on conclure qu'il y a une *relation significative* (*i.e.* déviation significative de l'indépendance)
- Autrement, on conclure que nos observations varions *seulement en raison de la variabilité aléatoire*

Test d'indépendance

- Deux caractères sont *indépendants* si la valeur de l'un *n'influe pas sur les distributions des valeurs de l'autre*
- $\implies$ les fréquences conjointes doivent être proches des *produits de fréquences marginales*
- Sous l'hypothèse que X et Y sont *indépendantes*, les probabilités conjointes sont :

$$p_{ij} = P(X = x_i \text{ et } Y = y_j) = P(X = x_i) \times P(Y = y_j)$$

- Sur la base du tableau de contingence, on estime les deux *probabilités marginales* par :

$$P(X = x_i) = \frac{\sum_{j=1}^c n_{ij}}{\sum_{i=1}^r \sum_{j=1}^c n_{ij}} = \frac{n_{i.}}{n_{..}} = \frac{n_{i.}}{n}$$

$$P(Y = y_j) = \frac{\sum_{i=1}^r n_{ij}}{\sum_{i=1}^r \sum_{j=1}^c n_{ij}} = \frac{n_{.j}}{n_{..}} = \frac{n_{.j}}{n}$$

Test d'indépendance, cont.

- Donc, on obtient $\hat{p}_{ij} = n_{i.} n_{.j} / n^2$
($n = n_{..} = \sum_{i=1}^r \sum_{j=1}^c n_{ij}$, la taille de l'échantillon)
- $\implies$ Sous l'hypothèse (nulle) d'indépendance, les nombres espérés de la cellule (i, j) sont :

$$n \times P(X = x_i) \times P(Y = y_j) = \frac{\sum_{j=1}^c n_{ij} \times \sum_{i=1}^r n_{ij}}{n} = \frac{n_{i.} n_{.j}}{n}$$

Statistique de test

- La statistique de test est toujours de la forme

$$\begin{aligned} \chi_{obs}^2 &= \sum_{i=1}^r \sum_{j=1}^c \frac{(\text{observé} - \text{espéré})^2}{\text{espéré}} \\ &= \frac{(n_{11} - n_{1.}n_{.1}/n)^2}{n_{1.}n_{.1}/n} + \frac{(n_{12} - n_{1.}n_{.2}/n)^2}{n_{1.}n_{.2}/n} + \dots + \frac{(n_{rc} - n_{r.}n_{.c}/n)^2}{n_{r.}n_{.c}/n} \end{aligned}$$

- Pour n 'suffisamment grand' ($\forall i, j, \quad np_{ij} \geq 5$), sous H

$$\chi_{obs}^2 \sim \chi_{(r-1) \times (c-1)}^2$$

Exemple

Le tableau suivant montre les résultats d'une enquête auprès de 6672 personnes concernant le lien entre le *sexe* et le fait que la personne est *droitière ou gauchère* :

	hommes	femmes	
droitiers	2780	3281	6061
gauchers	311	300	611
	3091	3581	6672

Tester au niveau $\alpha = 0,05$ l'hypothèse que les caractères 'sexe' et 'main dominante' sont indépendants ...

Solution

Le tableau théorique :

	hommes	femmes	
droitiers	2808	3253	6061
gauchers	283	328	611
	3091	3581	6672

$2808 = 6061 \times 3091/6672$, etc.

$$\chi^2 = \frac{(2780 - 2808)^2}{2808} + \frac{(3281 - 3253)^2}{3253} + \frac{(311 - 283)^2}{283} + \frac{(300 - 328)^2}{328}$$

$$= 5.68$$

Sous H , $\chi^2 \sim \chi^2_1$; $\chi^2_{1,0.95} = 3.84 < 5.68$.

Donc, on **REJETTE** l'hypothèse nulle : les données indiquent *une déviation significative* de l'hypothèse d'indépendance.

Test d'indépendance : autre exemple

Exemple 12.4 Est-ce que la participation à classe influent sur la réussite à l'examen ? Tester au niveau $\alpha = 0,01$...

	réussite échec		
présent	25	6	31
absent	8	15	23
	33	21	54

Nombres espérés :

PS :

PF :

AS :

AF :

Test

1

2

3

4

5

Test d'homogénéité

- Le **test d'homogénéité** (ou de comparaison) consiste à vérifier que J échantillons (groupes) *proviennent de la même population*
- C.-à-d., la distribution de la variable d'intérêt est *la même* dans toutes les populations
- Il s'agit d'une *comparaison de la distribution* d'une variable qualitative dans plusieurs échantillons
- Considérons un facteur A qui peut prendre I valeurs différentes sur une population
- La probabilité d'apparition des différentes valeurs de A est p_i , $i = 1, \dots, I$
- Soit J échantillons C_j de tailles n_j respectives issu de la population

Test d'homogénéité, cont.

- Les fréquences d'apparition des valeurs A_i du facteur A dans l'échantillon C_j sont notées n_{ij}
- L'hypothèse nulle H pose que les distributions sont *les mêmes*
- $\implies$ les différences observées entre tous les échantillons sont dûes à la *variabilité d'échantillonnage* (variation aléatoire)

Modalité du facteur	C_1	C_2	$\cdots$	C_J	Total
A_1	n_{11}	n_{12}	$\cdots$	n_{1J}	$n_{1.}$
A_2	n_{21}	n_{22}	$\cdots$	n_{2J}	$n_{2.}$
$\vdots$					
A_I	n_{I1}	n_{I2}	$\cdots$	n_{IJ}	$n_{I.}$
	$n_{.1}$	$n_{.2}$		$n_{.J}$	$n_{..} = n$

Statistique de test

- Sous H , *les probabilités* d'apparition des différentes modalités du facteur *sont toutes égales dans les distributions marginales*
- Probabilité d'apparition de la modalité j du facteur A :

$$p_{i.} = n_{i.}/n$$

- Nombre espéré de modalité i dans l'échantillon j :

$$E_{ij} = n_{.j} p_{i.} = \frac{n_{i.} n_{.j}}{n}$$

- La statistique de test (homogénéité) est toujours de forme :

$$\chi_{obs}^2 = \sum \frac{(\text{observé} - \text{espéré})^2}{\text{espéré}} = \sum_{i=1}^I \sum_{j=1}^J \frac{(n_{ij} - n_{i.} n_{.j}/n)^2}{n_{i.} n_{.j}/n}$$

- À noter : c'est *la même formule* que celle du test d'indépendance
- Sous H , $\chi^2 \sim \chi_{(I-1)(J-1)}^2$

Exemple

Exemple 12.3, cont.

La même population a été analysée l'année suivante (échantillon de 119 individus) ; la structure génotypique est telle que :

<i>FF</i>	<i>FS</i>	<i>FC</i>	<i>SS</i>	<i>SC</i>	<i>CC</i>
12	60	22	11	8	6

La distribution génotypique de la population a-t-elle changé depuis l'année précédente ?

Test

1

2

3

4

5

Le paradoxe de Simpson

- Également connu sous le nom de *effet Yule-Simpson*
- Un effet qui se produit lorsque le *association marginale* entre deux variables catégorielles est *qualitativement différent* de la *association partielle* entre les deux mêmes variables **après avoir contrôlé une (ou plusieurs) autres variables**
- Pour l'historique, voir <https://www.britannica.com/topic/Simpsons-paradox>

Le paradoxe de Simpson - exemple concret (I)

- Considérons deux hôpitaux : A et B
- L'année dernière, l'hôpital A a réalisé 2100 interventions chirurgicales, dont 63 patients sont décédés
- L'hôpital B a effectué 800 interventions chirurgicales, dont 16 patients sont décédés
- Activité : Calculer la proportion de décès dans chaque hôpital et décider lequel vous choisiriez si vous auriez besoin d'une intervention chirurgicale.

Choix : _____

Le paradoxe de Simpson - exemple concret (II)

- Considérons maintenant une *variable cachée* : quel était l'état des patients lorsqu'ils sont arrivés à l'hôpital ?
- Pour ceux en *bon état* :
 - 600 est allé à A et 6 sont morts
 - 600 est allé à B et 8 sont morts
- Pour ceux en *mauvais état* :
 - 1500 est allé à A et 57 sont morts
 - 200 est allé à B et 8 sont morts
- Activité, suite : Encore une fois, calculer la proportion de décès dans chaque hôpital et décider lequel vous choisiriez si vous auriez besoin d'une intervention chirurgicale

Choix : _____

Le paradoxe de Simpson - exemple concret (III)

- Donc – vous n'avez pas fait le même choix, non ??
- Ce que nous venons de voir est un exemple de *Le paradoxe de Simpson*
- Les données d'un groupe global donnent des proportions qui semblent favoriser un choix plutôt qu'un autre
- MAIS : lorsque les groupes sont **répartis en sous-groupes**, chaque groupe plus petit peut avoir des proportions qui produire le *résultat opposé*