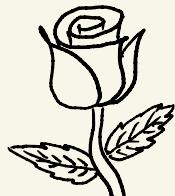


Chap 7 Tests du χ^2

I. Introduction

1) Motivation



RR

RB

BB



L'hypothèse : Dans un croisement,



$$\downarrow + = \text{H}$$

I avec $P \frac{1}{2}$ I : $\frac{1}{2}$

II avec $P \frac{1}{2}$ II : $\frac{1}{2}$

On veut tester cette hypothèse à partir de notre observation :

Génération 1 : RR BB

Génération 2 : RB

Génération 3 : RR RB BB
141 315 144 Total : 600

2) La loi multinomiale

Def 1: $n \geq 2$, $2 \leq k \leq n$, $p_1 + \dots + p_k = 1$. Un vecteur aléatoire (N_1, \dots, N_k) suit la loi multinomiale de paramètres n et (p_1, \dots, p_k) si :

$$\forall (n_1, \dots, n_k) \in \mathbb{N}^k,$$

$$P(N_1 = n_1, \dots, N_k = n_k) = \begin{cases} \frac{n!}{n_1! \dots n_k!} p_1^{n_1} \dots p_k^{n_k} & n_1 + \dots + n_k = n \\ 0 & \text{sinon} \end{cases}$$

Rq : Si $k=2$, $P(N_1 = n_1, N_2 = n - n_1)$

$$= \frac{n!}{n_1!(n-n_1)!} p_1^{n_1} (1-p_1)^{n-n_1}$$

$$N_1 \sim B(n, p_1)$$

$$N_2 = n - N_1 \sim B(n, 1-p_1)$$

Rq : Si $n_1 + \dots + n_k = n$, alors

$$\frac{n!}{n_1! \dots n_k!} = \frac{n!}{n_1!(n-n_1)!} \times \frac{(n-n_1)!}{n_2!(n-n_1-n_2)!} \times \dots \times \frac{(n-\sum_{j=1}^{k-1} n_j)!}{n_k!(n-\sum_{j=1}^k n_j)!}$$

$$= \binom{n}{n_1} \times \binom{n-n_1}{n_2} \times \dots \times \binom{n-\sum_{j=1}^{k-1} n_j}{n_k}$$

~~0! = 1~~

Rq : $(p_1 + \dots + p_k)^n = \sum_{\substack{n_1, \dots, n_k \in \mathbb{N} \\ n_1 + \dots + n_k = n}} \frac{n!}{n_1! \dots n_k!} p_1^{n_1} \dots p_k^{n_k}$

Ré: Soit (X_1, \dots, X_n) un n -échantillon à valeurs dans $\{1, \dots, k\}$ de loi $\mathbb{P}(X_i=j) = p_j$, $1 \leq j \leq k$.

$X_i \rightarrow$

$\begin{array}{ c c c c } \hline 0 & 0 & \dots & 0 \\ \hline 0 & 0 & \dots & 0 \\ \hline \end{array}$	$\begin{array}{ c c c c } \hline 1 & 0 & \dots & 0 \\ \hline 0 & 0 & \dots & 0 \\ \hline \end{array}$	\dots	$\begin{array}{ c c c c } \hline 0 & 0 & \dots & 1 \\ \hline 0 & 0 & \dots & 0 \\ \hline \end{array}$
---	---	---------	---

$$\underbrace{\begin{matrix} 1 \\ N_1^n \\ \downarrow \\ N_1^n \end{matrix}}_{\sim} \quad \underbrace{\begin{matrix} 2 \\ N_2^n \\ \downarrow \\ N_2^n \end{matrix}}_{\sim} \quad \dots \quad \underbrace{\begin{matrix} k \\ N_k^n \\ \downarrow \\ N_k^n \end{matrix}}_{\sim}$$

Bernoulli(p_j)
 $N_j^n \sim \sum_{i=1}^n \mathbb{1}_{X_i=j}$, alors $N_j^n \sim B(n, p_j)$

On pose $N_j^n = \sum_{i=1}^n \mathbb{1}_{X_i=j}$, alors

(N_1^n, \dots, N_k^n) suit la loi multinomiale de paramètres n et (p_1, \dots, p_k) . En effet:

- * $N_1^n + \dots + N_k^n = n$
- * A une valeur (n_1, \dots, n_k) du k -uplet (N_1^n, \dots, N_k^n) , il y a $\frac{n!}{n_1! \dots n_k!}$ valeurs de (x_1, \dots, x_n) correspondantes pour le n -uplet (X_1, \dots, X_n) . Chaque cas a une probabilité $p_1^{n_1} \dots p_k^{n_k}$.

Prop 2: Si (N_1, \dots, N_k) suit la loi multinomiale de paramètres n et (p_1, \dots, p_k) , alors

$$\mathbb{E}[N_i] = n p_i \quad \text{Var}(N_i) = n p_i (1-p_i) \quad N_i \sim B(n, p_i)$$

pour $i \neq j$, $\text{Cov}(N_i, N_j) = -n p_i p_j$

Dém: On pourra calculer ces quantités avec les N_j^i définies ci-dessus.

$$N_j^i \sim B(n, p_j),$$

donc $\mathbb{E}[N_j^i] = n p_j, \text{Var}(N_j^i) = n p_j (1-p_j)$

$$i \neq j: \text{Cov}(N_i^i, N_j^i) = \mathbb{E}[N_i^i N_j^i] - \underbrace{\mathbb{E}[N_i^i] \mathbb{E}[N_j^i]}_{n p_i \quad n p_j}$$

$$\mathbb{E}[N_i^i N_j^i] = \sum_{l=1}^n \sum_{l'=1}^n \underbrace{\mathbb{E}[\mathbb{1}_{X_l=i} \mathbb{1}_{X_{l'}=j}]}_{\begin{cases} 0 \\ p_i p_j \end{cases}}$$

$$\begin{aligned} &= \begin{cases} 0 \\ p_i p_j \end{cases} & l = l' \\ && l \neq l' \end{aligned}$$

$$= (n^2 - n) p_i p_j$$

$$\text{D'où } \text{Cov}(N_i^i, N_j^i) = -n p_i p_j$$

3) Un résultat de convergence

(X_1, \dots, X_n) n-échantillon à ratess dans $\{x_1, \dots, x_k\}$. $p_j = \mathbb{P}(X_i=j)$

$$N_j^i = \sum_{l=1}^n \mathbb{1}_{X_l=j}.$$

Prop 3

$$Z_n = \begin{pmatrix} \frac{N_1 - np_1}{\sqrt{np_1}}, & \dots & \frac{N_k - np_k}{\sqrt{np_k}} \end{pmatrix}$$

espece
observé

$$Z_n \xrightarrow[n \rightarrow \infty]{d} N_K(0, \Sigma_p)$$

où $\Sigma_p = (\sqrt{p_i p_j})_{1 \leq i, j \leq k}$

Dém: On pose $Y_i = \begin{pmatrix} \mathbb{1}_{X_1=i} - p_1 \\ \vdots \\ \mathbb{1}_{X_k=i} - p_k \end{pmatrix}$

Ce sont des vecteurs aléatoires i.i.d et centrés.

Le TCL vectoriel entraîne que

$$Z_n = \frac{1}{\sqrt{n}} \left(\underbrace{\frac{Y_1 + \dots + Y_n}{n} - \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix}}_{\frac{Y_1 + \dots + Y_n}{\sqrt{n}}} \right)$$

$$\xrightarrow[n \rightarrow \infty]{d} N_K(0, \Sigma_p)$$

avec $(\Sigma_p)_{i,j} = \text{Cov}(Y_{i,(i)}, Y_{j,(j)})$

$$= E[Y_{i,(i)} Y_{j,(j)}]$$

$$= \frac{1}{\sqrt{p_i p_j}} E[(\mathbb{1}_{X_1=i} - p_i)(\mathbb{1}_{X_1=j} - p_j)]$$

$$\begin{aligned}
 (\Sigma_p)_{i,j} &= \frac{1}{\sqrt{p_i p_j}} \left(\underbrace{\mathbb{E}(\mathbb{1}_{X_1=i, X_2=j})}_{p_i \mathbb{1}_{i=j} - p_i \mathbb{E}[\mathbb{1}_{X_2=j}]} + p_i p_j \right. \\
 &\quad \left. - \underbrace{p_i \mathbb{E}[\mathbb{1}_{X_2=j}]}_{p_j} - \underbrace{p_j \mathbb{E}[\mathbb{1}_{X_1=i}]}_{p_i} \right) \\
 &= \frac{1}{\sqrt{p_i p_j}} (p_i \mathbb{1}_{i=j} - p_i p_j) \\
 &= \begin{cases} -\sqrt{p_i p_j} & i \neq j \\ 1 - p_i & i = j \end{cases}
 \end{aligned}$$

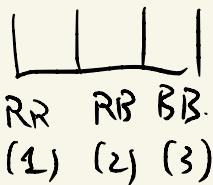
II. Test du χ^2 d'ajustement

On a un vecteur aléatoire de loi multinomiale de paramètres n et $\underline{p} = (p_1, \dots, p_k)$. On veut tester
 inconnu

$H_0: "p = p^{\circ}"$ contre $H_1: "p \neq p^{\circ}"$.

ex: Fleurs $p^{\circ} = (\frac{1}{4}, \frac{1}{2}, \frac{1}{4})$

$$\text{Et } \frac{1}{4} \frac{1}{2} \frac{1}{4} \quad \hat{p}_1 = \frac{141}{600}, \quad \hat{p}_2 = \frac{315}{600}, \quad \hat{p}_3 = \frac{144}{600}$$



$$n = 600$$

Th4 (X_1, \dots, X_n) un n-échantillon à valeurs dans $\{1, \dots, k\}$, $p_j = \mathbb{P}(X_i=j)$. $N_j^{\hat{}} = \sum_{i=1}^n \mathbf{1}_{X_i=j}$.

On introduit

$$D_n^2 = \sum_{j=1}^k \frac{(N_j^{\hat{}} - np_j^{\circ})^2}{np_j^{\circ}}$$

Alors \star si $p=p^{\circ}$, $D_n^2 \xrightarrow[n \rightarrow \infty]{\text{L}} \chi^2(k-1)$

\star si $p \neq p^{\circ}$, $D_n^2 \xrightarrow[n \rightarrow \infty]{\text{P.S.}} +\infty$

Dém: \star $p=p^{\circ}$. $D_n^2 = \|Z_n\|^2$

$$\text{avec } Z_n = \begin{pmatrix} \frac{N_1^{\hat{}} - np_1^{\circ}}{\sqrt{np_1^{\circ}}} \\ \vdots \\ \frac{N_k^{\hat{}} - np_k^{\circ}}{\sqrt{np_k^{\circ}}} \end{pmatrix}$$

$$Z_n \xrightarrow[n \rightarrow \infty]{\text{L}} Y \sim N_k(0, I_n - E_{p^{\circ}})$$

$$(E_{p^{\circ}})_{ij} = \sqrt{p_i^{\circ} p_j^{\circ}}$$

$\|\cdot\|^2$ est une fonction ℓ^2 ,

$$\text{donc } \|Z_n\|^2 \xrightarrow[n \rightarrow \infty]{\text{L}} \|Y\|^2$$

$$D_n^2 =$$

$$E_{p^{\circ}} = \begin{pmatrix} \sqrt{p_1^{\circ}} \\ \vdots \\ \sqrt{p_k^{\circ}} \end{pmatrix} (\sqrt{p_1^{\circ}}, \dots, \sqrt{p_k^{\circ}})$$

$$V = \text{vect}(v_1, \dots, v_p)$$

$$X = \text{matcan}(v_1, \dots, v_p)$$

$$\Pi_V = X(X^T X)^{-1} X^T$$

$$\sqrt{p^{\circ}}$$

Pourquoi $\Pi_{\text{Vect}(\bar{\mathbb{P}}^{\circ})} = \bar{\mathbb{P}}^{\circ}$? $\Pi_{\text{Vect}(\bar{\mathbb{P}}^{\circ})} = \bar{\mathbb{P}}^{\circ} (\underbrace{t \bar{\mathbb{P}}^{\circ} \bar{\mathbb{P}}^{\circ}}_{t \bar{\mathbb{P}}^{\circ}})^{-1} t \bar{\mathbb{P}}^{\circ}$

Soit $v \in \mathbb{R}^k$,

$$\begin{aligned}\Pi_{\text{Vect}(\bar{\mathbb{P}}^{\circ})} v &= \bar{\mathbb{P}}^{\circ} \langle \bar{\mathbb{P}}^{\circ}, v \rangle \\ &= \bar{\mathbb{P}}^{\circ} t \bar{\mathbb{P}}^{\circ} v\end{aligned}$$

matrice de projection
orthogonale.

$$I_k - \bar{\mathbb{P}}^{\circ} = \Pi_{\text{Vect}(\bar{\mathbb{P}}^{\circ})}^{\perp}$$

Par le théorème de Cochran, si $w \sim N_k(0, I_k)$,

alors $\Pi_{\text{Vect}(\bar{\mathbb{P}}^{\circ})}^{\perp} w \sim N_k(0, I_k - \bar{\mathbb{P}}^{\circ})$

et de plus $\|\Pi_{\text{Vect}(\bar{\mathbb{P}}^{\circ})}^{\perp} w\|^2 \sim \chi^2(k-1)$
dim(Vect(\bar{\mathbb{P}}^{\circ})^{\perp})

Par conséquent, $\|y\|^2 \sim \chi^2(k-1)$ et on a monté

$$D_n^2 \xrightarrow{n \rightarrow \infty} \chi^2(k-1)$$

* Si $p \neq p^{\circ}$, alors il existe j tel que $p_j \neq p_j^{\circ}$.

$$D_n^2 \geq \frac{(N_j - n p_j^{\circ})^2}{n p_j^{\circ}} = n \frac{(N_j/n - p_j^{\circ})^2}{p_j^{\circ}}$$

Par la loi des grands nombres,

$$\frac{N_j^n}{n} = \frac{\sum_{i=1}^n \mathbb{1}_{X_i=j}}{n} \xrightarrow[n \rightarrow \infty]{\text{P.S.}} \mathbb{E}[\mathbb{1}_{X_1=j}] = p_j \neq p_j^*$$

Donc $\frac{(N_j^n/n - p_j^*)^2}{p_j^*} \xrightarrow[n \rightarrow \infty]{\text{P.S.}} \frac{(p_j - p_j^*)^2}{p_j^*} > 0$

Donc $D_n^2 \xrightarrow[n \rightarrow \infty]{\text{P.S.}} +\infty$.

Ques 5: Soit $\alpha \in]0, 1[$. Le test du χ^2 de H_0 : " $p = p^*$ "

contre H_1 : " $p \neq p^*$ " de niveau α est donné par

$$\text{si } D_n^2 > C_{1-\alpha}^{(K-1)}$$

quantile d'ordre $1-\alpha$ de $\chi^2(K-1)$

ex: Fleurs

$$D_n^2 = \frac{(141 - 600 \times \frac{1}{4})^2}{600 \times \frac{1}{4}} + \frac{(315 - 600 \times \frac{1}{2})^2}{600 \times \frac{1}{2}} + \frac{(KFF - 600 \times \frac{1}{4})^2}{600 \times \frac{1}{4}}$$

$$\approx 1,53$$

$$\alpha = 5\%, \quad C_{1-\alpha}^{(2)} \approx 5,99, \quad \text{si } D_n^2 > C_{1-\alpha}^{(2)} = 0,$$

donc on accepte H_0 : " $p = (\frac{1}{4}, \frac{1}{2}, \frac{1}{4})$ ".

Rq: Puissance asymptotique (puissance
 Pour $p \neq p^*$, on a vu que

$$\pi_1: \begin{cases} \mathbb{H}_1 \rightarrow [0, 1] \\ \theta \mapsto \mathbb{P}_{\theta}(\phi(X)=1) \end{cases}$$

$$\liminf_{n \rightarrow \infty} \frac{D_n^2}{n} \geq c > 0$$

Donc pour tout $t > 0$, $\underline{\mathbb{P}}_p(D_n^2 > t) \xrightarrow{n \rightarrow \infty} 1$

$$\pi_1(p)$$

III. Variantes

1) Test du χ^2 d'ajustement à une famille paramétrisée de loi

Dans certains cas pratiques, il se peut que on soit obligé d'estimer certains paramètres avant d'appliquer le test du χ^2 . Dans ce cas on utilise le théorème suivant:

Th b). $\Theta \subseteq \mathbb{R}^d$, $k > d+1$ et

$$p: \theta \in \Theta \rightarrow (p_1(\theta), \dots, p_k(\theta)) \in \mathbb{R}^k.$$

On suppose que p est injective et de classe C^2 ,

et les $\beta_j(\theta)$ ne s'annulent jamais sur Θ .

On suppose de plus que pour tout $\theta \in \Theta$,

les vecteurs

$$\begin{pmatrix} \frac{\partial}{\partial \theta_1} \beta_1(\theta) \\ \vdots \\ \frac{\partial}{\partial \theta_k} \beta_k(\theta) \end{pmatrix} \dots \begin{pmatrix} \frac{\partial}{\partial \theta_1} \beta_1(\theta) \\ \vdots \\ \frac{\partial}{\partial \theta_k} \beta_k(\theta) \end{pmatrix}$$

sont libres.

Soit (x_1, \dots, x_n) un n -échantillon de loi $p(\theta)$

avec $\theta \in \Theta$. On note $\hat{\theta}_n$ l'EMV de θ et

$$N_j = \sum_{i=1}^n \mathbb{1}_{x_i=j} \text{ pour } j \in \{1, \dots, k\}. \text{ Alors}$$

$$D_n^2(\hat{\theta}_n) = \sum_{j=1}^k \frac{(N_j - n p_j(\hat{\theta}_n))^2}{n p_j(\hat{\theta}_n)} \xrightarrow{n \rightarrow \infty} \chi^2(k-1-d).$$

dans le Th4

Ex: On a une VA y à valeurs dans \mathbb{N} . $d=0$

On veut savoir si y suit une loi de Poisson.

H_0 : " $y \sim p(\theta)$ pour un certain $\theta > 0$ " $\neq (\theta = \theta_0 \text{ etc.})$

H_1 : " $y \not\sim p(\theta)$ pour tout $\theta > 0$ "

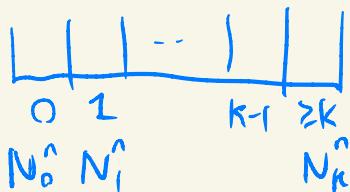
Comment passer à une loi multinomiale?

On construit $X_i = \begin{cases} Y_i & \text{si } 0 \leq Y_i \leq k-1 \\ k & \text{si } Y_i \geq k \end{cases}$.

On a des observations X_1, \dots, X_n à valeurs dans $\{0, 1, \dots, k\}$, avec $P_j = \mathbb{P}(X_i = j)$, $0 \leq j \leq k$.

$N_j^n = \sum_{i=1}^n \mathbb{1}_{X_i=j}$. Alors

(N_0^n, \dots, N_k^n) suit une loi multinomiale de paramètres n et (P_0, \dots, P_k) .



On considère $p(\theta) = (P_0(\theta), \dots, P_k(\theta))$

$$P_j(\theta) = \begin{cases} \mathbb{P}(Y_i = j) & 0 \leq j \leq k-1 \\ \mathbb{P}(Y_i \geq k) & j = k \end{cases}$$

Par le théorème 6, on sait que $Y_i \sim p(\theta)$

$$\mathbb{P}_{H_0}(\mathbb{1}_{D_n^2(\hat{\theta}_n) > C_{1-\alpha}^{(k-1)}} = 1) \lesssim \alpha$$

$\downarrow k+1 - \frac{\alpha}{1}$

Donc $\mathbb{1}_{D_n^2(\hat{\theta}_n) > C_{1-\alpha}^{(k-1)}}$ est

un test de H_0 contre H_1 de niveau α .

Idee: On compte le nombre de contraintes indépendantes.

Si a_1, \dots, a_r sont des vecteurs de \mathbb{R}^k

linéairement indépendants et $Z \sim N_k(0, I_k)$

$$(*) \quad \forall 1 \leq i \leq r, \langle a_i, Z \rangle = 0$$

Conditionné à (*), $\|Z\|^2 \sim \chi^2(k-r)$

(conditionné à (*), $Z \stackrel{d}{=} V \sqrt{\lambda} Z$)

avec $V = \text{vect}(a_1, \dots, a_r)$

on applique le th de Cochran

$$\text{ex: } D_n^2 = \sum_{j=1}^n \frac{(N_j - np_j^0)^2}{np_j^0} = \|Z_n\|^2 \sim \chi^2(d-1)$$

$\swarrow Z_n(j)^2$

Contrainte: $\sum_{j=1}^n \underbrace{J_n p_j^0}_{N_j - np_j^0} Z_n(j) = 0$

$\swarrow N_j - np_j^0$

Dans notre cas:

$$D_n^2(\hat{\theta}_n) = \|Z_n\|^2$$

$$\text{avec } Z_n(j) = \frac{N_j - n \hat{p}_j(\hat{\theta}_n)}{\sqrt{n \hat{p}_j(\hat{\theta}_n)}}$$

Quelles sont les contraintes ?

$$\# 1 \rightarrow \sum_{j=1}^n \sqrt{n \hat{p}_j(\hat{\theta}_n)} Z_n(j) = 0$$

$$\# d \rightarrow \text{EMV : vraisemblance } V_X(\theta) = \prod_{j=1}^k \hat{p}_j(\theta)^{N_j}$$

$$l_X(\theta) = \sum_{j=1}^n N_j \ln \hat{p}_j(\theta)$$

$$\left\{ \begin{array}{l} \partial_{\theta_i} l_X(\hat{\theta}_n) = 0 \rightarrow \sum_{j=1}^n N_j \frac{\partial_{\theta_i} \hat{p}_j(\hat{\theta}_n)}{\hat{p}_j(\hat{\theta}_n)} = 0 \\ \partial_{\theta_d} l_X(\hat{\theta}_n) = 0 \end{array} \right.$$

(lien à $Z_n(j)$)

Nb de contraintes = d+1,

$$\|Z_n\|^2 \underset{n \rightarrow \infty}{\sim} \chi^2(k-1-d)$$

2) Test du χ^2 d'indépendance

Th 7 On observe un n-échantillon $((X_1, Y_1), \dots, (X_n, Y_n))$

T avec X_i à valeurs dans $\{1, \dots, k\}$ et Y_i à valeurs dans $\{1, \dots, l\}$. Pour tout $i \in \{1, \dots, k\}$ et $j \in \{1, \dots, l\}$,

On pose

$$N_{i,j} = \sum_{r=1}^n \mathbb{1}_{(X_r, Y_r) = (i, j)}$$

$$N_{i,\cdot} = \sum_{r=1}^n \mathbb{1}_{X_r = i}$$

$$N_{\cdot,j} = \sum_{r=1}^n \mathbb{1}_{Y_r = j}.$$

i, j	1	...	ℓ	
1				
:				
$N_{i,j}$				$N_{i,\cdot}$
k				

Si les $(X_i)_{1 \leq i \leq n}$ sont indépendantes des $(Y_j)_{1 \leq j \leq \ell}$,

alors

$$D_n^2 = \sum_{i=1}^k \sum_{j=1}^{\ell} \frac{(N_{i,j} - N_{i,\cdot} N_{\cdot,j}/n)^2}{N_{i,\cdot} N_{\cdot,j} / n}$$
$$\xrightarrow[n \rightarrow \infty]{} \chi^2((k-1)(\ell-1))$$

Csg : H_0 : "Les X_i sont indépendantes des Y_j "

Contre H_1 : "les X_i ne sont pas indépendantes des Y_j "

$\Downarrow D_n^2 > c_{1-\alpha}^{(k+l-1)(l-1)}$ est un test de H_0 contre H_1 de niveau α .

Dém: $p_i = \mathbb{P}(X_i=i)$, $q_j = \mathbb{P}(Y_i=j)$

$$\Theta = (\underbrace{p_1, \dots, p_k, q_1, \dots, q_{l-1}}_{\dim = k+l-2}) \quad \begin{aligned} p_k &= 1 - p_1 - \dots - p_{k-1} \\ q_l &= 1 - q_1 - \dots - q_{l-1} \end{aligned}$$

on veut tester

$$H_0: " \forall i, j, \mathbb{P}(X_i=i, Y_i=j) = \overbrace{p_i q_j}^{\text{---}} "$$

contre $H_1: " \text{---} "$

Il suffit d'appliquer le Th 6 :

$$\hat{\theta}_n = \left(\frac{N_{1,1}}{n}, \dots, \frac{N_{k,l-1}}{n}, \frac{N_{\cdot,1}}{n}, \dots, \frac{N_{\cdot,l-1}}{n} \right)$$

$$\hat{p}_{i,j}(\hat{\theta}_n) = \frac{N_{i,\cdot}}{n} \times \frac{N_{\cdot,j}}{n} \quad \frac{N_{i,\cdot} \times N_{\cdot,j}}{n}$$

$$D_n^2(\hat{\theta}_n) = \sum_{i=1}^k \sum_{j=1}^l \frac{(N_{i,j} - n \hat{p}_{i,j}(\hat{\theta}_n))^2}{n \hat{p}_{i,j}(\hat{\theta}_n)}$$

$$\begin{aligned} & \xrightarrow[n \rightarrow \infty]{\text{--}} \chi^2(kl - 1 - (k+l-2)) \\ &= \chi^2((k-1)(l-1)) \end{aligned}$$

3) Test du χ^2 d'homogénéité.

Cas particulier du χ^2 indépendance.

On observe un n -échantillon (X_1, \dots, X_n) et un m -échantillon (Y_1, \dots, Y_m) . On suppose que les deux échantillons sont indépendants et à valeurs dans $\{1, \dots, k\}$. On pose

$$N_i = \sum_{r=1}^n \mathbb{1}_{X_r=i}, \quad M_i = \sum_{r=1}^m \mathbb{1}_{Y_r=i}$$

$$\hat{p}_i = \frac{N_i + M_i}{n + m}.$$

Si les deux échantillons ont la même loi, alors

$$D_{n,m}^2 = \sum_{i=1}^k \left(\frac{(N_i - n\hat{p}_i)^2}{n\hat{p}_i} + \frac{(M_i - m\hat{p}_i)^2}{m\hat{p}_i} \right)$$

$$\underset{n, m \rightarrow \infty}{\approx} \chi^2(k-1)$$

Csg: $H_0: "P_{X_i} = P_{Y_i}"$ contre $H_1: "P_{X_i} \neq P_{Y_i}"$.

Il $D_{n,m}^2 > C \frac{(k-1)}{2-\alpha}$ est un test de H_0 contre H_1 , de niveau α .

Idee: On considere le vecteur alatoire (U, V) avec V à valeurs dans $[0, 1]$.

Conditionné à $V=0$, $U \sim X$; conditionné à $V=1$, $U \sim Y$.

On prend un n -échantillon $((U_1, V_1), \dots, (U_n, V_n))$

Supposons que $P_{X_i} = P_{Y_i}$, alors les U_i sont indépendantes des V_i .

→ Test d'indépendance.

$U \backslash V$	0	1	
0	N_0	M_0	$N_0 + M_0$
1	N_1	M_1	\vdots
\vdots	\vdots	\vdots	
k	N_k	M_k	$N_k + M_k$
	n	m	

D_{n+m}^2 (independance)

$$= \sum_{i=1}^k \frac{(N_i - \frac{n(N_i + M_i)}{n+m})^2}{\frac{n(N_i + M_i)}{n+m}} + \frac{(M_i - \frac{m(N_i + M_i)}{n+m})^2}{\frac{m(N_i + M_i)}{n+m}}$$

$D_{n,m}^2$

$$\simeq \chi^2((k-1)(2-1)) = \chi^2(k-1)$$