

(2) การคำนวณหาค่าความเสี่ยงประเภทที่ 2

$$\beta(p_1) \approx \Pr \left\{ Z > \frac{(n/p_0 - n/p_1)}{\sqrt{nq_1/p_1^2}} + Z_\alpha \sqrt{\frac{p_1^2 q_1}{p_0^2 q_0}} \right\}$$

$$\begin{aligned} \text{หรือ } \beta(p_1) &= \sum_{k=k^*+1}^{\infty} \binom{y-1}{n-1} p_1^k q_1^{n-k} \\ &= 1 - \sum_{y=n}^{k^*} \binom{y-1}{n-1} p_1^k q_1^{n-k} \end{aligned}$$

โดยที่  $k^*$  คือค่าของ  $k'$  ที่คำนวณได้จากสมการ  $\alpha = \sum_{y=n}^{k'} \binom{y-1}{n-1} p_0^k q_0^{n-k}$

ก. การคำนวณหาขนาดตัวอย่างอุดมคติ

$$n \approx \frac{(Z_{1-\beta} - Z_\alpha \sqrt{p_1^2 q_1 / p_0^2 q_0})^2 (q_1 / p_1^2)}{(1/p_0 - 1/p_1)^2}$$

สำหรับการทดสอบสมมุติฐาน  $H_0: p_0$  vs  $H_1: p \neq p_0$  จะขอเว้นไว้เป็นแบบฝึกหัด

#### 6.2.4 การทดสอบสมมุติฐานเกี่ยวกับพารามิเตอร์ $p$ ของกลุ่มประชากรทวินาม

ก.  $H_0: p = p_0$  vs  $H_1: p = p_1 < p_0$

(1) การพัฒนาตัวทดสอบ

การทดสอบสมมุติฐานเกี่ยวกับพารามิเตอร์  $p$  ของกลุ่มประชากรทวินามมีผลเช่นเดียวกับการทดสอบเกี่ยวกับพารามิเตอร์  $p$  ในกรณีของเบอร์นูลลี ทั้งนี้เพราะตัวแปรสุ่มทวินามเกิดจากการทดลองเบอร์นูลลีอิสระ<sup>1</sup> ที่กระทำต่อเนื่องกัน  $n$  ครั้ง

ดังนั้น เมื่อทำการทดลองเบอร์นูลลีอิสระ  $n$  ครั้ง ภายใต้สมมุติฐานหลัก  $H_0: p = p_0$  และทำการทดลองเบอร์นูลลีอิสระ  $n$  ครั้ง ภายใต้สมมุติฐานรอง  $H_1: p = p_1 < p_0$ .

จะปรากฏ  $L_0$  และ  $L_1$  ดังนี้

$$L_0 = \prod_{i=1}^n p_0^{x_i} q_0^{n-x_i} = p_0^{\sum x_i} q_0^{n-\sum x_i}$$

และ 
$$L_1 = \prod_{i=1}^n p_1^{x_i} q_1^{n-x_i} = p_1^{\sum x_i} q_1^{n-\sum x_i}$$

<sup>1</sup> อ่านตอน 4.2.2

ดังนั้น โดยอาศัย NPL เราจะปฏิเสธสมมติฐานหลักเมื่อ

$$\frac{L_0}{L_1} = \left(\frac{p_0}{p_1}\right)^{\sum x_i} \left(\frac{q_0}{q_1}\right)^{n - \sum x_i} \leq k$$

$$\Rightarrow (\ln p_0 - \ln p_1) \sum_i^n x_i - (\ln q_0 - \ln q_1) \sum_i^n x_i + n \ln q_0 - n \ln q_1 \leq \ln k$$

$$\{(\ln p_0 - \ln p_1) - (\ln q_0 - \ln q_1)\} \sum_i^n x_i \leq \ln k - n \ln q_0 + n \ln q_1$$

เนื่องจาก  $p_1 < p_0$  ดังนั้น  $q_1 > q_0$  ซึ่งมีผลให้  $\{(\ln p_0 - \ln p_1) - (\ln q_0 - \ln q_1)\}$  มีค่าเป็น ปริมาณบวก

ดังนั้นจึงปฏิเสธสมมติฐานหลักเมื่อ

$$\begin{aligned} \sum_i^n x_i &\leq \frac{\ln k - n \ln q_0 + n \ln q_1}{(\ln p_0 - \ln p_1) - (\ln q_0 - \ln q_1)} \\ &= k' \end{aligned}$$

จากสมการ  $\alpha = \Pr \{\text{Reject } H_0\}$

$$\Rightarrow \alpha = \Pr \left\{ \sum_i^n X_i \leq k' \mid p = p_0 \right\}$$

เนื่องจาก  $X \sim \text{Bernoulli}(p)$  ดังนั้น ตัวแปรสุ่ม  $y = \sum_i^n X_i \sim \text{Binomial}(n, p)$  และเมื่อ  $H_0$  เป็นจริงหรือ  $p = p_0$  ตัวแปรสุ่ม  $Y$  จึงมีการแจกแจงแบบ Binomial  $(n, p_0)$

$$\Rightarrow \Pr \left\{ \sum_i^n X_i \leq k' \right\} = \alpha = \sum_{y=0}^{k'} \binom{n}{y} p_0^y q_0^{n-y}$$

หรือปฏิเสธสมมติฐานหลักเมื่อ  $y = \sum_i^n x_i \leq k'$  เมื่อ  $k'$  สามารถคำนวณหาได้จากสมการ

$$\alpha = \sum_{y=0}^{k'} \binom{n}{y} p_0^y q_0^{n-y}$$

อย่างไรก็ตาม เราสามารถประมาณค่าของ  $k'$  โดยอาศัย CLT ได้ดังนี้

$$\text{จาก} \quad \alpha = \Pr \left\{ \sum_i^n X_i \leq k' \mid p = p_0 \right\}$$

$$\Rightarrow \alpha \approx \Pr \left\{ \frac{Y - E(Y)}{\sqrt{V(Y)}} \leq \frac{k' - np_0}{\sqrt{np_0 q_0}} \right\} = \Pr \left\{ Z \leq \frac{k' - np_0}{\sqrt{np_0 q_0}} \right\}$$

$$\text{ดังนั้น } \Pr \left\{ Z \leq \frac{k' - np_0}{\sqrt{np_0 q_0}} \right\} \approx \alpha = \Pr \{ Z \leq Z_\alpha \}$$

$$\Rightarrow k' \approx np_0 + Z_\alpha \sqrt{np_0 q_0}$$

นั่นคือ ปฏิเสธสมมติฐานหลัก ณ ระดับนัยสำคัญ  $\alpha$  เมื่อ

$$y = \sum_1^n x_i \leq np_0 + Z_\alpha \sqrt{np_0 q_0}$$

หรือปฏิเสธสมมติฐานหลัก ณ ระดับนัยสำคัญ  $\alpha$  เมื่อ  $Z_c = \frac{y - np_0}{\sqrt{np_0 q_0}} \leq Z_\alpha$

(2) การคำนวณหาค่าความเสี่ยงประเภทที่ 2

$$\beta(p_1) = \Pr \left\{ \sum_1^n X_i > k^* \mid p = p_1 < p_0 \right\}$$

ทั้งนี้  $k^*$  คือค่าของ  $k'$  ที่คำนวณได้จากสมการ  $\alpha = \sum_{y=0}^{k'} \binom{n}{y} p_0^y q_0^{n-y}$

$$\text{ดังนั้น } \beta(p_1) = \sum_{y=k^*+1}^n \binom{n}{y} p_1^y q_1^{n-y} = 1 - \sum_{y=0}^{k^*} \binom{n}{y} p_1^y q_1^{n-y}$$

หรือประมาณค่าได้โดยอาศัย CLT ดังนี้

$$\begin{aligned} \beta(p_1) &\approx \Pr \left\{ \sum_1^n X_i > np_0 + z_\alpha \sqrt{np_0 q_0} \mid p = p_1 \right\} \\ &\approx \Pr \left\{ Z > \frac{np_0 - np_1}{\sqrt{np_1 q_1}} + Z_\alpha \sqrt{\frac{p_0 q_0}{p_1 q_1}} \right\} \end{aligned}$$

(3) การคำนวณหาขนาดตัวอย่างที่เหมาะสม

จาก

$$\begin{aligned} \beta(p_1) &\approx \Pr \left\{ Z > \frac{\sqrt{n} (p_0 - p_1)}{\sqrt{p_1 q_1}} + Z_\alpha \sqrt{\frac{p_0 q_0}{p_1 q_1}} \right\} \\ \Rightarrow \sqrt{n} &\approx \frac{(Z_{1-\beta} - Z_\alpha \sqrt{p_0 q_0 / p_1 q_1}) \sqrt{p_1 q_1}}{(p_0 - p_1)} \end{aligned}$$

$$\text{ดังนั้น } n \approx \frac{(Z_{1-\beta} - Z_\alpha \sqrt{p_0 q_0 / p_1 q_1})^2 (p_1 q_1)}{(p_0 - p_1)^2}$$

ข.  $H_0 : p = p_0$  vs  $H_1 : p = p_1 > p_0$

โดยอาศัยเทคนิคและวิธีการทำนองเดียวกับ ข้อ ก. เราสามารถพิสูจน์ได้ว่า

(1) ปฏิเสธสมมุติฐานหลัก ณ ระดับนัยสำคัญ  $\alpha$  เมื่อ

$$y = \sum_{i=1}^n x_i > k'$$

โดยที่  $k'$  สามารถคำนวณค่าได้จากสมการ

$$\begin{aligned} \alpha &= \sum_{y=k'+1}^n \binom{n}{y} p_0^y q_0^{n-y} \\ &= 1 - \sum_{y=0}^{k'} \binom{n}{y} p_0^y q_0^{n-y} \end{aligned}$$

หรือปฏิเสธสมมุติฐานหลัก ณ ระดับนัยสำคัญ  $\alpha$  เมื่อ

$$y = \sum_{i=1}^n x_i > np_0 + Z_{1-\alpha} \sqrt{np_0 q_0}$$

หรือ

$$z_c = \frac{y - np_0}{\sqrt{np_0 q_0}} > Z_\alpha$$

$$(2) \beta(p_1) = \sum_{y=0}^{k'} \binom{n}{y} p_1^y q_1^{n-y}$$

โดยที่  $k^*$  คือค่าของ  $k'$  ที่คำนวณได้จากสมการ

$$\alpha = 1 - \sum_{y=0}^{k'} \binom{n}{y} p_0^y q_0^{n-y}$$

$$\text{หรือ } \beta(p_1) \approx \Pr \left\{ Z \leq \frac{np_0 - np_1}{\sqrt{np_1 q_1}} + Z_{1-\alpha} \sqrt{\frac{p_0 q_0}{p_1 q_1}} \right\}$$

(3) การคำนวณหาขนาดตัวอย่างที่เหมาะสม

$$n \approx \frac{(Z_\beta - Z_{1-\alpha} \sqrt{p_0 q_0 / p_1 q_1})^2 (p_1 q_1)}{(p_0 - p_1)^2}$$

สำหรับการทดสอบ  $H_0 : p = p_0$  vs  $H_1 : p \neq p_0$  ขอเว้นไว้เป็นแบบฝึกหัด

ตัวอย่าง 6.15 ทอดเหรียญ 100 ครั้ง ปรากฏว่าเหรียญหงายก้อย 58 ครั้ง ท่านจะสรุปได้หรือไม่  
ว่าเหรียญนี้เป็นเหรียญต่างหรือไม่ต่าง

วิธีทำ ให้  $p$  = ความน่าจะเป็นที่เหรียญจะหงายก้อย

$$H_0 : p = .5 \text{ vs } H_1 : p > .5$$

ปฏิเสธสมมุติฐานหลักเมื่อ  $y > k$  โดยที่  $k$  เป็นค่าคงที่ที่คำนวณได้จากสมการ

$$\alpha = 1 - \sum_{y=0}^k \binom{n}{y} p_0^y q_0^{n-y}$$

$$\Rightarrow \sum_{y=0}^k \binom{n}{y} p_0^y q_0^{n-y} = 1 - \alpha$$

กำหนดให้  $\alpha = 0.05$ ,  $n = 100$  ดังนั้น โดยอาศัยตารางทวินาม เราย่อมหาค่า  $k$  ได้ แต่  
เนื่องจากตารางทวินามเสนอดตารางไว้สำหรับค่า  $n$  เพียง 30 (สำหรับตารางที่มีอยู่บางตาราง  
อาจเสนอ  $n$  ถึง 50 หรือ 100) ดังนั้นเพื่อความสะดวกจึงใช้ CLT เข้าช่วย กล่าวคือ

ปฏิเสธสมมุติฐานเมื่อ

$$y = \sum_{i=1}^n x_i > np_0 + Z_{1-\alpha} \sqrt{np_0 q_0}$$

ให้  $\alpha = 0.05$ ,  $n = 100$ ,  $p_0 = .5$ ,  $Z_{.95} = 1.64$

$$y = \sum_{i=1}^{100} x_i = 58$$

$$np_0 + Z_{1-\alpha} \sqrt{np_0 q_0} = 50 + (1.64) \sqrt{25} = 58.2$$

จะเห็นว่า  $y = 58$  มีได้มากกว่า  $np_0 + Z_{1-\alpha} \sqrt{np_0 q_0} = 58.2$  ดังนั้นจึงไม่อาจปฏิเสธ  
สมมุติฐานหลัก และเชื่อว่าเหรียญไม่ต่าง

หมายเหตุ เพื่อประโยชน์ในการเปรียบเทียบจะขอทดสอบสมมุติฐานนี้โดยนัยของ Goodness  
of fit test ดังนี้ (ดูรายละเอียดในตอนต่อไป)

$$H_0 : p_1 = p_2 = \frac{1}{2} \text{ vs } H_1 : p_1 \neq \frac{1}{2}, p_2 \neq \frac{1}{2}$$

เมื่อ  $p_1$  = ความน่าจะเป็นที่เหรียญจะหงายหัว

$p_2$  = ความน่าจะเป็นที่เหรียญจะหงายก้อย

ในที่นี้  $f_x(x) = \frac{1}{2}, x = 0, 1$  (Discrete Uniform Distribution)

$X_1 =$  จำนวนครั้งที่เหรียญหงายหัว = 42

$X_2 =$  จำนวนครั้งที่เหรียญหงายก้อย = 58

$E_1 =$  ค่าคาดหวังว่าเหรียญจะหงายหัว =  $100 p_1 = 100 \left(\frac{1}{2}\right) = 50$

$E_2 =$  ค่าคาดหวังว่าเหรียญจะหงายก้อย =  $100 p_2 = 100 \left(\frac{1}{2}\right) = 50$

ปฏิเสธสมมติฐานหลักเมื่อ  $\chi_c^2 > \chi_{k-1, 1-\alpha}^2 = \chi_{1, .95}^2 = 3.841$

$$\chi_c^2 = \sum_{i=1}^2 \frac{(X_i - E_i)^2}{E_i} = \frac{(42 - 50)^2}{50} + \frac{(58 - 50)^2}{50} = 2.56$$

จะเห็นว่า  $\chi_c^2$  ไม่ได้มากกว่า  $\chi_{1, .95}^2 = 3.841$  ดังนั้นจึงไม่อาจปฏิเสธสมมติฐานหลักและเชื่อว่าเหรียญไม่ถ่วง

**ตัวอย่าง 6.18** บริษัท ก. ดำริที่จะสั่งเครื่องจักรชนิดใหม่เข้ามาใช้แทนเครื่องจักรรุ่นเก่า เพราะรู้สึกว่าเครื่องรุ่นเก่าผลิตสินค้าที่ผิดมาตรฐานปะปนออกมาถึง 10% เครื่องรุ่นใหม่ที่จะสั่งซื้อนี้จะต้องมีประสิทธิภาพสูง กล่าวคือ สามารถผลิตสินค้าได้ตรงตามมาตรฐานได้มากกว่า 90%

ก. จากการทดลองนำเครื่องรุ่นใหม่มาผลิตสินค้า พบว่าเมื่อสุ่มตัวอย่างผลิตภัณฑ์ที่ผลิตโดยเครื่องจักรรุ่นใหม่มา 100 ชิ้น พบผลิตภัณฑ์ที่ผิดมาตรฐานปะปนอยู่ 12 ชิ้น ดังนี้ ถ้าท่านเป็นเจ้าของที่ฝ่ายควบคุมคุณภาพ ท่านจะแนะนำบริษัทอย่างไร

ข. ถ้าจะให้การตัดสินใจของท่านผิดพลาดเพียง 1% ( $\alpha = \beta = .01$ ) ท่านควรสุ่มตัวอย่างผลิตภัณฑ์มาตรวจสอบกี่ชิ้น ถ้า  $p = .08$

**วิธีทำ**  $H_0 : p = .10$  vs  $H_1 : p < .10$

ปฏิเสธสมมติฐานหลักเมื่อ  $y \leq np_0 + Z_\alpha \sqrt{np_0 q_0}$

$n = 100, p_0 = .10$  ให้  $\alpha = .01$

$$\text{ดังนั้น } np_0 + Z_\alpha \sqrt{np_0 q_0} = 10 + (2.33) \sqrt{100 (.10) (.9)} = 3.01$$

แต่  $y = \sum_i^{100} x_i = 12$  ซึ่งมีได้น้อยกว่า  $np_0 + Z_\alpha \sqrt{np_0 q_0} = 3.01$

ดังนั้น จึงไม่อาจปฏิเสธสมมุติฐานหลัก และเชื่อว่าเครื่องรุ่นใหม่มีได้มีคุณภาพสูงกว่ารุ่นที่กำลังใช้อยู่

ข. ขนาดตัวอย่างที่เหมาะสม คือ

$$n \approx \frac{(Z_{1-\beta} - Z_\alpha \sqrt{p_0 q_0 / p_1 q_1})^2 (p_1 q_1)}{(p_0 - p_1)^2}$$

$$\alpha = \beta = .01, p_0 = .10, q_0 = .90, p_1 = .08, q_1 = .92$$

$$\Rightarrow n \approx \frac{(2.33 + 2.33 \sqrt{(.10)(.90) / (.08)(.92)})^2 (.08)(.92)}{(.10 - .08)^2}$$

$$n \approx 4936$$

นั่นคือ ถ้าตามความเป็นจริงแล้วเครื่องรุ่นใหม่ผลิตสินค้าผิดมาตรฐานเพียง 8% และต้องการให้การตัดสินใจครั้งนี้ผิดพลาดเพียง 1% ฝ่ายควบคุมคุณภาพ ควรสุ่มตัวอย่าง ผลิตภัณฑ์ที่ทดลองผลิตโดยเครื่องรุ่นใหม่มาตรวจสอบคุณภาพประมาณ 4,936 ชิ้น

### 6.3 การทดสอบไคกำลังสอง ( $\chi^2$ - test)

#### 6.3.1 บทนำ

การทดสอบไคกำลังสองโดยทั่วไปที่เราคุ้นเคยอยู่ก็คือ  $\chi^2_{k-1} = \sum_i \frac{(O_i - E_i)^2}{E_i}$  ซึ่งนิยม

ใช้ทดสอบสมมุติฐานเกี่ยวกับความเป็นอิสระระหว่างคุณลักษณะทางประชากร 2 ลักษณะ หรือเกินกว่า 2 ลักษณะ (Contingency Table-Test of Independence) และทดสอบความสงสัยเกี่ยวกับการแจกแจงของกลุ่มประชากรอันเป็นการตรวจสอบเพื่อหา pdf. ที่เหมาะสมของกลุ่มประชากร<sup>1</sup> ที่ไปเก็บตัวอย่างมา (Goodness of Fit Test) โดยปกติเป็นการนำความถี่มาใช้ แต่ธรรมชาติของความถี่จะเป็นลักษณะของการกระจายแบบตัดตอน ขณะที่การกระจายแบบ  $\chi^2$  เป็นการแจกแจงแบบต่อเนื่อง ปัญหาในขั้นต้นก็คือ  $\chi^2$ -Test พัฒนามาจากแนวคิดใดและตัวทดสอบสำหรับสมมุติฐานข้างต้นพัฒนาอย่างไร? การนำการกระจาย  $\chi^2$  มาใช้กับความถี่เหมาะสมเพียงใด? ในปัญหาที่เกี่ยวกับพัฒนาตัวทดสอบสำหรับสมมุติฐานต่าง ๆ จะได้กล่าวถึงในตอนต่อไป ในที่นี้จะได้กล่าวถึงแนวคิดเบื้องต้นอันเป็นที่มาของ  $\chi^2$ -test ดังนี้

<sup>1</sup> วิธีตรวจสอบเพื่อหา pdf. ที่เหมาะสมของกลุ่มประชากรมีหลายวิธี เช่น การใช้ Probability Paper การวิเคราะห์ฮิสโตแกรม การใช้วิธี Simulation การใช้ Monte Carlo Technique การใช้ Goodness of Fit Test ฯลฯ

ถ้าตัวแปรสุ่ม  $X_i \sim N(\mu_i, \sigma_i^2); i = 1, 2, \dots, n$

$$\Rightarrow L = \prod_i f_x(x_i; \mu_i, \sigma_i^2)$$

$$= \frac{1}{\sigma_1 \sigma_2 \dots \sigma_n (2\pi)^{n/2}} \exp \left\{ -\frac{1}{2} \sum_i \left( \frac{x_i - \mu_i}{\sigma_i} \right)^2 \right\}$$

$$= \frac{1}{\prod_i \sigma_i (2\pi)^{n/2}} e^{-\frac{1}{2} \sum_i Z_i^2}$$

ซึ่งในกรณีนี้เราได้พิสูจน์มาแล้วในทฤษฎี 3.6 ว่า  $Z_i^2 \sim \chi_{(1)}^2$  และ  $\sum_i \left( \frac{x_i - \mu_i}{\sigma_i} \right)^2 = \sum_i Z_i^2 \sim \chi_{(n)}^2$

ลองพิจารณากรณีของตัวแปรสุ่มทวินามซึ่งเป็นตัวแปรสุ่มแบบตัดตอน คือ

$$f_{X_i}(x_i; n, p_i) = \binom{n}{x_i} p_i^{x_i} q_i^{n-x_i}; x_i = 1, 2, \dots, n$$

โดยที่  $p$  = Probability of Success และ  $X_1$  คือ จำนวน Success จากผลการทดลองเบอร์นูลลีอิสระ  $n$  ครั้ง หรือนัยหนึ่ง  $X_1$  คือจำนวนความถี่ (frequency) ของ  $p_1$

ปัญหาที่พบก็คือ เราสามารถอาศัย CLT ประมาณได้ว่าตัวแปรสุ่ม  $Y = \frac{X_1 - np_1}{\sqrt{np_1 q_1}}$

มีการแจกแจงแบบ  $N(0, 1)$  ได้ถ้า  $n \rightarrow \infty$  และ  $p \rightarrow .5$  แต่ตัวแปรสุ่ม  $y^2 = \left( \frac{X_1 - np_1}{\sqrt{np_1 q_1}} \right)^2$  จะมีการ

กระจายแบบใด? สามารถอนุมานให้มีการแจกแจงแบบ  $\chi_{(1)}^2$  ได้หรือไม่?

ปัญหานี้นับเป็นประเด็นเบื้องต้นในการพัฒนา  $\chi^2$ -test ซึ่งเราสามารถอาศัยความรู้เรื่อง Limiting Distribution พิสูจน์หา pdf ของ  $Y^2$  ได้ดังนี้

$$\text{ให้ } W = Y^2$$

$$\begin{aligned} \Rightarrow F_w(w) &= \Pr \{W \leq w\} \\ &= \Pr \{Y^2 \leq w\} \\ &= \Pr \{-\sqrt{w} \leq Y \leq \sqrt{w}\} \end{aligned}$$



ให้  $G_n(y)$  คือ pdf ของตัวแปรสุ่ม  $Y$

$$\Rightarrow F_w(w) = \Pr\{Y \leq \sqrt{w}\} - \Pr\{Y \leq -\sqrt{w}\}$$

โดยอาศัย Limiting distribution  $\lim_{n \rightarrow \infty} G_n(y) \rightarrow N(0, 1)$

$$\begin{aligned} \text{ดังนั้น } \lim_{n \rightarrow \infty} F_w(w) &= \lim_{n \rightarrow \infty} \{\Pr\{Y \leq \sqrt{w}\} - \Pr\{Y \leq -\sqrt{w}\}\} \\ &\approx \Pr\{Z \leq \sqrt{w}\} - \Pr\{Z \leq -\sqrt{w}\}; \text{ เมื่อ } z \sim N(0, 1) \\ &\approx \int_{-\infty}^{\sqrt{w}} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2} dz - \int_{-\infty}^{-\sqrt{w}} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2} dz \\ &\approx 2 \int_0^{\sqrt{w}} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2} dz \end{aligned}$$

$$\text{ดังนั้น } f_w(w) = F_w'(w)$$

$$\begin{aligned} &\approx 2 \left\{ \int_0^{\sqrt{w}} \frac{\partial}{\partial w} \left( \frac{1}{\sqrt{w\pi}} e^{-\frac{1}{2}z^2} \right) dz + \frac{d\sqrt{w}}{dw} \left( \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(\sqrt{w})^2} \right) \right. \\ &\quad \left. - \frac{d}{dw} (0) \left( \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(0)^2} \right) \right\} \\ &\approx 2 \left\{ 0 + \frac{1}{2\sqrt{w}} \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}w} \right\} \\ &\approx \frac{1}{\sqrt{w}} \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}w} \end{aligned}$$

$$\Rightarrow f_w(w) \approx \frac{\left(\frac{1}{2}\right)^2}{\Gamma\left(\frac{1}{2}\right)} \cdot w^{-\frac{1}{2}} \cdot e^{-\frac{1}{2}w}, 0 < w < \infty^2$$

1 ดูเชิงอรรถที่ 2 หน้า 66 ในหนังสือ "ทฤษฎีสถิติ 2 เล่ม 1" โดยผู้เขียนคนเดียวกัน

2  $\because W = Y^2$  และ  $Y \sim N(0, 1)$  ซึ่ง  $-\infty < Y < \infty$  ดังนั้น  $0 < W < \infty$

นั่นคือตัวแปรสุ่ม

$$W = Y^2 \sim \chi_{(1)}^2$$

$$\Rightarrow Y^2 \left( \frac{X_1 - np_1}{np_1 q_1} \right)^2 = \frac{(X_1 - np_1)^2}{np_1 q_1} \sim \chi_{(1)}^2$$

ถ้าให้  $n$  (total frequency) =  $X_1 + X_2$  โดยกำหนดให้  $p_1 p_2 = 1$  หรือ  $p_2 = 1 - p_1 = q_1$ <sup>1</sup>

$$\text{ดังนั้น } Y^2 = \frac{(X_1 - np_1)^2}{np_1 q_1} = \frac{(X_1 - np_1)^2}{np_1 (1 - p_1)} = \frac{(X_1 - np_1)^2}{np_1} + \frac{(X_1 - np_1)^2}{n(1 - p_1)}$$

เนื่องจาก  $n = X_1 + X_2 \Rightarrow X_2 = n - X_1$  และ  $X_1 = n - X_2$

และ  $p_1 + p_2 = 1 \Rightarrow p_1 = 1 - p_2$  ดังนั้น  $np_1 = n(1 - p_2) = n - np_2$

$$\begin{aligned} \text{ดังนั้น } Y^2 &= \frac{(X_1 - np_1)^2}{np_1} + \frac{(n - X_2 - n(1 - p_2))^2}{np_2} \\ &= \frac{(X_1 - np_1)^2}{np_1} + \frac{(-X_2 + np_2)^2}{np_2} \\ &= \frac{(X_1 - np_1)^2}{np_1} + \frac{(X_2 - np_2)^2}{np_2} \end{aligned}$$

นั่นคือ ถ้า  $X_1 \sim b(n, p_1)$  โดยที่  $X_1 + X_2 = n$  และ  $p_1 + p_2 = 1$  แล้วตัวแปรสุ่ม

$$Y^2 = \frac{(X_1 - np_1)^2}{np_1} + \frac{(X_2 - np_2)^2}{np_2} \sim \chi_{(1)}^2$$

ทั้งนี้ เมื่อพิจารณา  $f_{X_1}(x, n, p_1)$  จะพบว่า

$$\begin{aligned} f_{X_1}(x, n, p_1) &= \binom{n}{x_1} p_1^{x_1} q_1^{n-x_1} \\ &= \binom{n}{x_1} p_1^{x_1} (1 - p_1)^{n-x_1} \end{aligned}$$

---

<sup>1</sup>  $X_1$  = ความถี่ของ  $p_1$ ,  $X_2$  = ความถี่ของ  $p_2$  (หรือ  $q_1$ )

$$= \frac{n!}{x_1! (n - x_1)!} p_1^{x_1} p_2^{n-x_1}$$

$$\therefore x_1 + x_2 = n \quad \text{ดังนั้น} \quad x_2 = n - x_1$$

$$\text{ดังนั้น} \quad f_{x_1}(x_1; n, p_1) \approx \frac{n!}{x_1! x_2!} p_1^{x_1} p_2^{x_2-1}$$

ดังนั้น เราจึงสรุปผลได้ว่า  $X_1 \sim b(n, p_1)$  และกำหนดให้  $X_1 =$  ความถี่ของ  $p_1$  และ  $X_2 =$  ความถี่ของ  $p_2$  ( $p_2 = 1 - p_1 = q_1$ ) ซึ่ง  $X_1$  มี pdf ดังนี้คือ

$$f_{x_1}(x_1; n, p_1) = \frac{n!}{x_1! x_2!} p_1^{x_1} p_2^{x_2-1}$$

$$\text{แล้วเราสามารถพิสูจน์ได้ว่าตัวแปรสุ่ม } Y^2 \text{ เมื่อ } Y = \frac{X_1 - E(X_1)}{\sqrt{V(X_1)}} = \frac{X_1 - np_1}{\sqrt{np_1 q_1}}$$

จะมีการกระจายแบบ  $\chi_{(1)}^2$  โดยประมาณเมื่อ  $n \rightarrow \infty$

$$\text{ดังนั้น} \quad Y^2 = \frac{(X_1 - np_1)^2}{np_1} + \left( \frac{X_2 - np_2}{np_2} \right)^2$$

$$\text{และถ้าให้ } E_1 = np_1 \text{ และ } E_2 = np_2$$

$$\Rightarrow Y^2 = \frac{(X_1 - E_1)^2}{E_1} + \frac{(X_2 - E_2)^2}{E_2} = \sum_i \frac{(X_i - E_i)^2}{E_i} \sim \chi_{(1)}^2$$

และจากความเป็นจริงเหล่านี้ ถ้าเราขยายความถี่ทั่วไปของการแจกแจงแบบพหุนาม คือเมื่อ  $X_1, X_2, \dots, X_{k-1}$  มีการแจกแจงแบบพหุนามที่มีพารามิเตอร์  $n, p_1, p_2, \dots, p_{k-1}$  และ  $X_1 + X_2 + \dots + X_k = n$  หรือ  $X_k = n - (X_1 + X_2 + \dots + X_{k-1})$  และ  $p_1 + p_2 + \dots + p_k = 1$  หรือ  $p_k = 1 - (p_1 + p_2 + \dots + p_{k-1})$  ถ้า  $n \rightarrow \infty$  เราสามารถพิสูจน์ได้ว่า

$$\sum_i \frac{(X_i - np_i)^2}{np_i} \sim \chi_{(k-1)}^2$$

<sup>1</sup> อ่านตอน 4.2.7

<sup>2</sup> ขอให้สังเกตว่า  $f_{x_1}(x_1; n, p_1) = \frac{n!}{x_1! x_2!} p_1^{x_1} p_2^{x_2-1}$  เป็นกรณีเฉพาะของการแจกแจงแบบพหุนาม เมื่อ  $k = 2$  โดยที่  $k =$  จำนวน พารามิเตอร์  $p$  หรือจำนวนความถี่  $X$  ของพารามิเตอร์  $p$

### 6.3.2 การทดสอบภาวะสารรูปสมิทที (Goodness of Fit Test)

การทดสอบภาวะสารรูปสมิทที คือการทดสอบดูว่า กลุ่มตัวอย่างหรือข้อมูลที่ได้รับมานั้น มีภาวะสอดคล้องกับการแจกแจงของประชากรกลุ่มที่น่าสงสัย (สารรูป) ได้ดีเพียงใด (สมิทที) หรือนัยหนึ่งเป็นการทดสอบเพื่อเสาะหาการแจกแจงของกลุ่มประชากรอันเป็นแหล่งที่มาของกลุ่มข้อมูลนั่นเอง

ด้วยเหตุที่เราจะทราบว่าประชากรกลุ่มใดพึงมีการแจกแจงในรูปใดนั้น ดัชนีที่ใช้วัดคือ ความน่าจะเป็นที่ได้รับจากการกำหนดค่าหรือเซตของ Domain แล้วนำมาแจกแจงเรียกว่า Probability Distribution เช่น การแจกแจงความน่าจะเป็นที่จะมีผู้โดยสารมาลงสถานี ก. ดังนี้

| <u>จำนวนผู้โดยสารมาถึง<br/>สถานีต่อ 1 ชั่วโมง</u> | <u>ความน่าจะเป็น</u> |
|---|----------------------|
| 6   | .004096              |
| 7   | .030720              |
| 8   | .102144              |
| 9   | .198400              |
| 10  | .249840              |
| 11  | .214200              |
| 12  | .127905              |
| 13  | .053550              |
| 14  | .015615              |
| 15  | .003100              |
| 16  | .000399              |
| 17  | .000030              |
| 18  | .000001              |
|   | <u>1.000000</u>      |

ด้วยเหตุนี้ การทดสอบภาวะสารรูปสัณหิตี จึงเป็นการทดสอบที่มุ่งเปรียบเทียบความน่าจะเป็น โดยเปรียบเทียบความน่าจะเป็นว่ามีค่าเท่ากับความน่าจะเป็นที่ได้รับจากกลุ่มประชากรที่สงสัยหรือไม่

นั่นคือ  $H_0: p_i = p_{i0}; i = 1, 2, \dots, k$

$p_{i0}$  = ค่าความน่าจะเป็น ณ domain ที่  $i; i = 1, 2, \dots, k$  ที่คำนวณได้จากกลุ่มประชากรที่น่าสงสัย

อย่างไรก็ตาม ในการพัฒนาทางทฤษฎีนั้น เราอาจตีความหมายของสมมุติฐานได้ว่าการทดสอบที่ต้องการคือการเปรียบเทียบ Observed Frequency กับ Expected Frequency ที่พึงได้รับจากกลุ่มประชากรที่สงสัย เมื่อ  $\text{Expected Frequency} = np_i$ ,  $p_i$  = ค่าความน่าจะเป็นที่ได้รับจากกลุ่มประชากรที่สงสัย ณ domain ที่  $i; i = 1, 2, \dots, k$  และ  $X_i$  = Observed Frequency ณ domain ที่  $i; i = 1, 2, \dots, k$

และขอให้สังเกตว่า  $X_1, X_2, \dots, X_k$  มีการแจกแจงแบบพหุนาม

การพัฒนาตัวทดสอบสามารถดำเนินการได้ดังนี้

$H_0: p_i = p_{i0}, i = 1, 2, \dots, k$  vs  $H_1: p_i \neq p_{i0}; i = 1, 2, \dots, k$

(ก) การพัฒนาตัวทดสอบ

จากการทดลองหนึ่งที่ให้ผลลัพธ์ออกมาเป็น  $k$  อย่าง (Categories) คือ  $A_1, A_2, \dots, A_k$ <sup>2</sup> ให้  $p_i$  คือความน่าจะเป็นที่การทดลองจะปรากฏผลลัพธ์เป็น  $A_i$  และให้  $X_i$  คือจำนวนครั้ง (ความถี่) ของการปรากฏผลการทดลองเป็น  $A_i$  จากการทดลองอิสระ  $n$  ครั้ง ทั้งนี้  $X_1 + X_2 + \dots + X_k = n$  และ  $p_1 + p_2 + \dots + p_k = 1$

ดังนั้นตัวแปรสุ่ม  $X_i$  ซึ่งมีการกระจายแบบทวินาม<sup>3</sup> หรือ  $b(n, p_i)$  และ  $X_1, X_2, \dots, X_k$  มีการกระจายแบบพหุนาม

1. อ่าน Monte Carlo Technique-Isaac N. Gibra "Probability and Statistical Inference for Scientists and Engineers" p. 43.

2 เช่น ผลการทดลองทอดลูกเต๋ามี 6 อย่าง คือ หงายหน้าเอียง หงายหน้า 2, ..., หงายหน้า 6 กฎของเมนเดลเสนอว่า การผสมพันธุ์พืชจะปรากฏลักษณะพืชเป็น 4 ลักษณะ ในอัตราส่วน 9 : 3 : 3 : 1

3 อาจถือว่า  $X_i$  เกิดขึ้นจากการทดลองเบอร์นูลลีที่ผลการทดลองเป็น 1 ถ้าปรากฏ  $A_i$  และมีค่าเป็น 0 ถ้าไม่ปรากฏ  $A_i$  ซึ่งในที่นี้เราจะมีตัวแปรสุ่มเป็น  $X_{ij}; i = 1, 2, \dots, n; j = 1, 2, \dots, k$  แต่จะไม่กล่าวถึงและขอใช้วิธีพิจารณาเฉพาะตัวแปร  $X_i$  เท่านั้น จะไม่มองลึกไปถึงรากเหง้าของ  $X_i$  เพราะสลับซับซ้อนกว่าแต่ให้ผลลัพธ์ตรงกัน

พิจารณา Parameter Space จะพบว่า

$$\omega = \{p_{10}, p_{20}, \dots, p_{k_0}\} \text{ และ } \Omega = \{p_1, p_2, \dots, p_k; p_i \geq 0; i = 1, 2, \dots, k\}$$

ดังนั้น

$$L_\omega = L_\omega^\wedge = \prod_{i_0}^k p_{i_0}^{x_{i_0}} = p_{10}^{x_{10}} p_{20}^{x_{20}} \dots p_{k_0}^{x_{k_0}}$$

และ

$$L_\Omega = \prod_i^k p_i^{x_i} = p_1^{x_1} p_2^{x_2} \dots p_k^{x_k}$$

จะเห็นว่าเราไม่จำเป็นต้องประมาณค่าพารามิเตอร์ใดใน  $L_\omega$  แต่ใน  $L_\Omega$  จะต้องประมาณค่าพารามิเตอร์ถึง  $k$  ตัว คือ  $p_1, p_2, \dots, p_k$

แต่เมื่อพิจารณาพารามิเตอร์  $p_1, p_2, \dots, p_k$  จะพบว่า  $p_1 + p_2 + \dots + p_k = 1$  แสดงว่าเรามีความจำเป็นต้องประมาณค่าพารามิเตอร์เพียง  $k - 1$  ตัว เท่านั้น ตัวสุดท้ายที่เหลือประมาณได้จากผลต่างที่เกิดจากการนำค่าพารามิเตอร์  $k - 1$  ที่ประมาณได้ไปหักลบออกจาก 1 และเพื่อความสะดวกจะใช้ตัวที่  $k$  คือ ถือว่า  $p_k = 1 - (p_1 + p_2 + \dots + p_{k-1}) = 1 - \sum_i^{k-1} p_i$

ดังนั้น เมื่อแทนที่  $p_k$  ใน  $L_\Omega$  ด้วย  $1 - \sum_i^{k-1} p_i$  ย่อมมีผลให้มีความจำเป็นต้องประมาณค่าเฉพาะ  $p_1, p_2, \dots, p_{k-1}$  เท่านั้น

$$\Rightarrow L_\Omega = p_1^{x_1} p_2^{x_2} p_{k-1}^{x_{k-1}} \dots p_k^{x_k} (1 - \sum_i^{k-1} p_i)^{x_k}$$

$$\frac{\partial \ln l}{\partial p_i} = 0; i = 1, 2, \dots, k - 1$$

$$\Rightarrow 0 + 0 + \dots + \frac{X_i}{p_i} + 0 + \dots + \frac{X_k}{1 - \sum_i^{k-1} p_i} (-1) = 0; i = 1, 2, \dots, k - 1$$

$$\Rightarrow \frac{X_i}{p_i} - \frac{X_k}{p_k} = 0$$

$$\text{ดังนั้น } p_i = X_i \cdot \frac{p_k}{X_k}; i = 1, 2, \dots, k - 1 \quad \dots\dots\dots(1)$$

<sup>1</sup> ในที่นี้ไม่จำเป็นต้องสนใจ  $\binom{n}{x_1, x_2, \dots, x_k}$  เพราะมิได้สนใจการสลับเทอม แต่จะให้ปรากฏเทอม  $\binom{n}{x_1, x_2, \dots, x_k}$  ไว้ด้วย

ก็ไม่ผิด ดู Isaac N. Gibra, Op cit, p. 450

$\therefore \sum_{i=1}^k p_i = 1$  ดังนั้น เมื่อรวมตลอดทุกค่าของ  $i$  ตั้งแต่ 1 ถึง  $k$  ใน

สมการที่ (1)

$$\Rightarrow \sum_{i=1}^k \hat{p}_i = \frac{p_k}{X_k} \sum_{i=1}^k X_i$$

$$\Rightarrow 1 = \frac{p_k}{X_k} \cdot n \quad \because \sum_{i=1}^k X_i = n \cdot \sum_{i=1}^k \hat{p}_i = 1 = \sum_{i=1}^k p_i$$

$$\text{ดังนั้น} \quad \frac{p_k}{X_k} = \frac{1}{n} \quad \dots\dots\dots(2)$$

แทนค่า  $\frac{p_k}{X_k}$  จากสมการ (2) ลงในสมการที่ (1)

$$\Rightarrow \hat{p}_i = \frac{X_i}{n}; i = 1, 2, \dots, k - 1$$

ขณะเดียวกัน  $\hat{p}_k = 1 - (\hat{p}_1 + \hat{p}_2 + \dots + \hat{p}_{k-1})$

$$= 1 - \left( \frac{X_1}{n} + \frac{X_2}{n} + \dots + \frac{X_{k-1}}{n} \right)$$

$$= \frac{n - (X_1 + X_2 + \dots + X_{k-1})}{n}$$

$$= X_k/n$$

$$\text{ดังนั้น} \quad L_{\hat{Q}} = \prod_{i=1}^k \hat{p}_i^{X_i} = \left(\frac{X_1}{n}\right)^{X_1} \cdot \left(\frac{X_2}{n}\right)^{X_2} \dots \left(\frac{X_k}{n}\right)^{X_k}$$

โดยอาศัย MLRT เราจะปฏิเสธสมมุติฐานหลักเมื่อ  $\lambda = L_{\hat{Q}}/L_{\hat{Q}_0} \leq k$   
 นั่นคือ ปฏิเสธสมมุติฐานหลักเมื่อ

$$\lambda = \frac{p_{10}^{X_1} p_{20}^{X_2} \dots p_{k0}^{X_k}}{\left(\frac{X_1}{n}\right)^{X_1} \left(\frac{X_2}{n}\right)^{X_2} \dots \left(\frac{X_k}{n}\right)^{X_k}} \leq k$$

$$= \left(\frac{np_{10}}{X_1}\right)^{X_1} \left(\frac{np_{20}}{X_2}\right)^{X_2} \dots \left(\frac{np_{k0}}{X_k}\right)^{X_k}$$

จาก ทฤษฎี 7.1 เมื่อ  $n \rightarrow \infty$  แล้วตัวแปรสุ่ม  $-2 \ln \lambda \sim \chi^2$  มี  $df =$  จำนวนพารามิเตอร์ที่กำหนดไว้ตามสมมติฐานหลัก เมื่อ  $\lambda = L_{\omega}/L_{\omega_0}$

$$\begin{aligned} \text{ดังนั้น } -2 \ln \lambda &= -2 \ln \left\{ \left( \frac{np_{10}}{X_1} \right)^{X_1} \left( \frac{np_{20}}{X_2} \right)^{X_2} \dots \left( \frac{np_{k0}}{X_k} \right)^{X_k} \right\} \\ &= -2 \sum_{i=1}^k X_i \ln \left( \frac{np_{i0}}{X_i} \right) \end{aligned}$$

ในที่นี้  $-2 \ln \lambda$  จะมีการแจกแจงโดยประมาณแบบ  $\chi^2$  มี  $df = k - 1$  เหตุที่  $df = k - 1$  เพราะการแจกแจงแบบพหุนามนั้นมีข้อจำกัดว่า  $\sum_{i=1}^k p_i = 1$  การกำหนดค่า  $p_i$  ในสมมติฐานหลักจึงกำหนดเพียง  $k - 1$  ค่าเท่านั้น ค่าที่เหลือไม่จำเป็นต้องกำหนดเพราะสามารถหาค่าได้หรือทราบค่าได้โดยอัตโนมัติ

โดยอาศัยทฤษฎี 7.1 และ MLRT เราจึงปฏิเสธสมมติฐานหลักเมื่อ

$$-2 \sum_{i=1}^k X_i \ln \left( \frac{np_{i0}}{X_i} \right) > -2 \ln k$$

กำหนดให้  $Y_i = X_i - np_{i0}$

และเพื่อให้ง่ายขึ้นเราจะกำหนดให้  $np_{i0} = E_i$  นั่นคือ  $Y_i = X_i - E_i$  หรือ  $X_i = Y_i + E_i$ <sup>1</sup>

$$-2 \ln \lambda = -2 \sum_{i=1}^k (Y_i + E_i) \ln \left( \frac{E_i}{Y_i + E_i} \right) > -2 \ln k$$

$$\Rightarrow -2 \ln \lambda = +2 \sum_{i=1}^k (Y_i + E_i) \ln \left( \frac{Y_i + E_i}{E_i} \right)$$

$$= 2 \sum_{i=1}^k (Y_i + E_i) \ln \left( 1 + \frac{Y_i}{E_i} \right)$$

<sup>1</sup> ขอให้สังเกตว่า  $X_i =$  Observed Frequency,  $E_i =$  Expected Frequency  $= np_{i0}$



$$= 2 \sum_i^k (Y_i + E_i) \left\{ \frac{Y_i}{E_i} - \frac{1}{2} \left( \frac{Y_i}{E_i} \right)^2 + \frac{1}{3} \left( \frac{Y_i}{E_i} \right)^3 - \dots \right\}^1$$

$$- 2 \ln \lambda = 2 \left\{ \left( \sum_i^k \frac{Y_i^2}{E_i} - \frac{1}{2} \sum_i^k \frac{Y_i^3}{E_i^2} + \frac{1}{3} \sum_i^k \frac{Y_i^4}{E_i^3} - \dots \right) + \right.$$

$$\left. \left( \sum_i^k Y_i - \frac{1}{2} \sum_i^k \frac{Y_i^2}{E_i} + \frac{1}{3} \sum_i^k \frac{Y_i^3}{E_i^2} - \frac{1}{4} \sum_i^k \frac{Y_i^4}{E_i^3} + \dots \right) \right\}$$

แต่  $\sum_i^k Y_i = \sum_i^k (X_i - E_i) = \sum_i^k X_i - \sum_i^k E_i = n - \sum_i^k np_i$

$$= n - n \sum_i^k p_i = n - n(1) = 0$$

ดังนั้น  $-2 \ln \lambda = \sum_i^k \frac{Y_i^2}{E_i} - \frac{1}{3} \sum_i^k \frac{Y_i^3}{E_i^2} + \frac{1}{6} \sum_i^k \frac{Y_i^4}{E_i^3} - \dots$

แต่เนื่องจากตัวแปรสุ่ม  $X_i \sim b(n, p_i)$  และเมื่อ  $H_0$  เป็นจริง คือ  $p_i = p_{i_0}$

ดังนั้น  $X_i \sim b(n, p_{i_0})$  ซึ่งจะพบว่า  $\mu_i = E(X_i) = np_{i_0} = E_i$

และ  $\sigma_i^2 = V(X_i) = np_{i_0}(1 - p_{i_0}) = np_{i_0}(1 - p_{i_0}) = E_i(1 - p_{i_0})$

$$\Rightarrow E_i = \sigma_i^2 / (1 - p_{i_0})$$

$$\begin{aligned} \text{ดังนั้น } \frac{Y_i}{E_i} &= \frac{X_i - E_i}{E_i} = \frac{X_i - \mu_i}{\sigma_i^2 / (1 - p_{i_0})} \\ &= \frac{X_i - \mu_i}{\sigma_i^2} \cdot (1 - p_{i_0}) \\ &= \frac{X_i - \mu_i}{\sigma_i} \cdot \frac{1 - p_{i_0}}{\sigma_i} \end{aligned}$$

<sup>1</sup> จากอนุกรมเทย์เลอร์ของ  $f(u)$  ณ จุด  $a$  คือ

$$f(u) = f(a) + f'(a)(u - a) + f''(a)(u - a)^2 \frac{1}{2!} + \dots + f^{(n)}(a)(u - a)^n \frac{1}{n!} + R_n$$

ดังนั้น ถ้า  $f(u) = \ln(1 + u)$  เมื่อ  $a = 0$  จะพบว่า

$$f(u) = \ln(1 + u) = u - \frac{u^2}{2} + \frac{u^3}{3} - \frac{u^4}{4} + \dots \text{ เมื่อ } |u| < 1 \text{ หรือ } -1 < u < 1$$

$$= \frac{X_i - \mu_i}{\sigma_i} \cdot \frac{1 - p_{i_0}}{\sqrt{np_{i_0}(1 - p_{i_0})}}$$

$$= \frac{X_i - \mu_i}{\sigma_i} \sqrt{\frac{1 - p_{i_0}}{np_{i_0}}}$$

เมื่อ  $n \rightarrow \infty$  จะพบว่า  $\frac{X_i - \mu_i}{\sigma_i} \rightarrow N(0, 1)$  และ  $\frac{1 - p_{i_0}}{np_{i_0}} \rightarrow 0$  นั่นคือ  $n \rightarrow \infty$  แล้ว

$$\frac{Y_i}{E_i} \rightarrow N(0, 1) \text{ ที่มีค่าน้อยมาก}$$

เหตุที่  $\frac{Y_i}{E_i} \sim N(0, 1)$  ที่มีค่าน้อยมาก ดังนั้น  $\frac{Y_1^2}{E_1}, \frac{Y_2^2}{E_2}, \frac{Y_3^2}{E_3}, \dots$  ย่อมมีค่าน้อยลงตามลำดับ จนสามารถ

ตัดทิ้งไปได้โดยมิได้มีผลกระทบกระเทือนแต่ประการใด

$$\text{พิจารณา } -2 \ln \lambda = \sum_i^k \frac{Y_i^2}{E_i} - \frac{1}{3} \sum_i^k \frac{Y_i^3}{E_i} + \frac{1}{6} \sum_i^k \frac{Y_i^4}{E_i} + \dots$$

$$\Rightarrow -2 \ln \lambda \approx \sum_i^k \frac{Y_i^2}{E_i}$$

นั่นคือ ปฏิเสธสมมติฐานหลักเมื่อ  $-2 \ln \lambda > -2 \ln k$  หรือปฏิเสธสมมติฐานหลัก เมื่อ

$$\sum_i^k \frac{Y_i^2}{E_i} > -2 \ln k = k'$$

จากสมการ  $\alpha = \Pr \{\text{Reject } H_0 \mid H_0\}$

$$\Rightarrow \alpha = \Pr \left\{ \sum_i^k \frac{Y_i^2}{E_i} > k' \mid p_i = p_{i_0}; i = 1, 2, \dots, k \right\}$$

$$\text{แต่ } -2 \ln \lambda \approx \sum_i^k \frac{Y_i^2}{E_i} \sim \chi_{(k-1)}^2$$

<sup>1</sup> ตัด  $\sum_i^k \frac{Y_i^3}{E_i}, \sum_i^k \frac{Y_i^4}{E_i}$  และเทอมกำลังสูงอื่น ๆ ทิ้งเพราะมีค่าน้อยมาก

$$\Rightarrow \Pr \left\{ \sum_i^k \frac{Y_i^2}{E_i} > k' \right\} = \alpha = \Pr \{ \chi_{(k-1)}^2 > \chi_{(k-1), 1-\alpha}^2 \}$$

$$\Rightarrow k' = \chi_{(k-1), 1-\alpha}^2$$

$$\text{นั่นคือ ปฏิเสธสมมติฐานหลักเมื่อ } \sum_i^k \frac{Y_i^2}{E_i} = \sum_i^k \frac{(X_i - E_i)^2}{E_i} > \chi_{(k-1), 1-\alpha}^2$$

โดย  $X_i$  = Observed Frequency และ  $E_i = np_{i_0}$  = Expected Frequency

สำหรับการคำนวณหาความเสี่ยงประเภทที่ 2 และ Power of Test จะไม่ขอกล่าวถึง เพราะเกี่ยวข้องกับ Noncentral  $\chi^2$  Distribution นักศึกษาที่สนใจขอให้ย้อนไปดูวิธีหา  $\beta$  และ  $\pi$  ในเรื่องการทดสอบเกี่ยวกับค่าเฉลี่ยของกลุ่มประชากรปกติเมื่อไม่ทราบค่าของ  $\sigma^2$

**ตัวอย่าง 6.17** การบันทึกข้อมูลจากแหล่งข้อมูลซึ่งมีค่าอยู่ระหว่าง 0 - 1 โดยแบ่ง Domain ออกเป็น 4 ช่วง คือ  $A_1 = \{x; 0 < x < \frac{1}{4}\}$ ,  $A_2 = \{x; \frac{1}{4} \leq x < \frac{1}{2}\}$ ,  $A_3 = \{x; \frac{1}{2} < x \leq \frac{3}{4}\}$ ,

$$A_4 = \{x; \frac{3}{4} < x \leq 1\}$$

จากการบันทึกข้อมูล 80 ชุด ปรากฏค่าความถี่ของข้อมูลที่ตกอยู่ในช่วง  $A_1, A_2, A_3$  และ  $A_4$  เท่ากับ 6, 18, 20 และ 36 ชุดตามลำดับ

จงตรวจสอบดูว่าข้อมูลทั้ง 80 ชุด น่าจะเป็นข้อมูลจากกลุ่มประชากร (parent population) ไດ ให้ใช้ระดับนัยสำคัญ 5%

**วิธีทำ** เนื่องจาก domain ของตัวแปรสุ่ม  $X$  คือ (0, 1) ดังนั้น กลุ่มประชากรที่น่าสงสัยว่าจะเป็นไปได้คือ Beta Family<sup>1</sup> ในที่นี้ขอตั้งข้อสงสัยเป็น 2 ประการ เพราะความถี่ค่อย ๆ ทวีขึ้น คือ

1. Triangular Distribution  $f_x(x) = 2x; 0 \leq x \leq 1$ <sup>2</sup>
2. J-Distribution  $f_x(x) = 7x^6; 0 \leq x \leq 1$

ค่าความน่าจะเป็น  $p_i; i = 1, 2, 3, 4$  สำหรับ pdf. ทั้งสองพร้อมทั้งค่าความถี่คาดหวังปรากฏดังนี้

<sup>1</sup> อ่านตอน 4.2.3 โดยเฉพาะอย่างยิ่งคือ ตอน 4.2.3.1 หน้า 188

<sup>2</sup> ดูรูปหน้า 192

$$P_{i_0} = \int_{A_i} f_x(x) dx; i = 1, 2, 3, 4$$

$$\text{และ } E_i = np_{i_0} = 80 p_{i_0}; i = 1, 2, 3, 4$$

|                                |                          |                          |              |             |
|--------------------------------|--------------------------|--------------------------|--------------|-------------|
| $P_{i_0} = \int_{A_i} 2x dx$   | 1/16                     | 3/16                     | 5/16         | 7/16        |
| $E_i$                          | 5                        | 15                       | 25           | 35          |
| $P_{i_0} = \int_{A_i} 7x^6 dx$ | $6.10351 \times 10^{-5}$ | $7.75146 \times 10^{-3}$ | .12567138672 | .8655161133 |
| $E_i$                          | .00488                   | .62012                   | 10.05371     | 69.32129    |

ก. กรณีที่สงสัยว่ากลุ่มประชากรมีการแจกแจงแบบ Triangular

$$H_0 : p_1 = 1/16, p_2 = 3/16, p_3 = 5/16, p_4 = 7/16$$

$$H_1 : p_1 \neq 1/16, p_2 \neq 3/16, p_3 \neq 5/16, p_4 \neq 7/16$$

ความถี่ที่เป็นค่าสังเกตและความถี่ที่คาดหวังว่าจะปรากฏจาก Triangular Dist<sup>n</sup> ณ

Domain  $A_i; i = 1, 2, 3, 4$  ปรากฏดังตาราง

|       |   |    |    |    |
|-------|---|----|----|----|
| $X_i$ | 6 | 18 | 20 | 36 |
| $E_i$ | 5 | 15 | 25 | 35 |

$$\begin{aligned} \text{ดังนั้น } \chi_c^2 &= \sum_i \frac{(X_i - E_i)^2}{E_i} \\ &= \frac{(6 - 5)^2}{5} + \frac{(18 - 15)^2}{15} + \frac{(20 - 25)^2}{25} + \frac{(36 - 35)^2}{35} \\ &= 1.828 \end{aligned}$$

จากตาราง  $\chi_{3,.95}^2 = 7.815$

จะเห็นว่า  $\chi_c^2 < \chi_{3,.95}^2 = 7.815$

ดังนั้น จึงไม่อาจปฏิเสธสมมติฐานหลักหรือเชื่อว่ากลุ่มประชากรที่สงสัยว่าเป็น Parent Population คือ Triangular Dist<sup>n</sup> หรือเชื่อว่าค่าความน่าจะเป็น  $p_i$  สอดคล้องกับค่า  $p_i$  ที่ได้รับจาก Triangular Distribution

หนึ่ง ขอให้เป็นที่สังเกตว่า ตามตัวอย่างนี้  $X_i$  และ  $E_i$  มีค่าใกล้เคียงกันมาก ณ จุดนี้เราจึงพอจะเดาคำตอบได้จากการเปรียบเทียบระหว่างค่าสังเกตกับค่าคาดหวังที่ละคู่ ถ้าหากมีค่าใกล้เคียงกันก็พอจะเชื่อได้ว่าสมมติฐานหลักถูกต้อง ถ้าหากมีค่าแตกต่างกันมากเราเชื่อว่าสมมติฐานรองน่าจะถูกต้อง

ข. กรณีที่น่าสงสัยว่ากลุ่มประชากรมีการแจกแจงแบบ  $j$

$$H_0: p_1 = 6.10351 \times 10^{-5}, p_2 = 7.75146 \times 10^{-3}, p_3 = .12567, p_4 = .86551$$

$$H_1: p_1 \neq .10351 \times 10^{-5}, p_2 \neq 7.75146 \times 10^{-3}, p_3 \neq .12567, p_4 \neq .86551$$

เปรียบเทียบความถี่ได้ดังตาราง

|       |        |        |          |          |
|-------|--------|--------|----------|----------|
| $X_i$ | 6      | 18     | 20       | 36       |
| $E_i$ | .00488 | .62012 | 10.05371 | 69.32129 |

ก่อนที่จะวิเคราะห์ตัวอย่างนี้ขอให้นักศึกษาพึงทราบข้อจำกัดของ  $\chi^2$ -test ดังนี้<sup>1</sup>

เนื่องจาก  $\sum_i \frac{(X_i - E_i)^2}{E_i}$  มิใช่มีการแจกแจงแบบ  $\chi^2$  โดยตรง แต่เป็นเพียงมีการแจกแจงแบบ  $\chi^2$  โดยประมาณ ดังนั้น เพื่อให้  $\sum_i \frac{(X_i - E_i)^2}{E_i}$  มีการแจกแจงใกล้เคียงกับ  $\chi^2$  - Dist- ขนาดตัวอย่าง  $n$  ควรมีขนาดใหญ่มาก ๆ เพื่อให้  $E_i \geq 5$  ในขณะเดียวกันจำนวน  $k^2$  จะต้องไม่น้อยกว่า 5 คือ  $k \geq 5$  หรือถ้า  $k < 5$  ค่าของ  $E$  ก็จะต้องสูงกว่า 5 มิฉะนั้น การประมาณค่าด้วย  $\chi^2$  - dist<sup>n</sup> จะไม่สัมฤทธิ์ผล

<sup>1</sup> Hoel, Opcit., p. 247 Isaac N. Gibra, Opcit., p. 453, Hogg and Craig, Opcit, p. 309.

<sup>2</sup>  $k$  = จำนวนตัวแปรสุ่ม  $\times$  ในฟังก์ชันการแจกแจงพหุนาม หรือในทางปฏิบัติ  $k$  = จำนวนกลุ่มย่อยของ domain หรือจำนวน category

หนทางสำหรับแก้ปัญหา เมื่อ  $E_i < 5$  ให้ปฏิบัติดังนี้

- 1) รวมค่าความถี่คาดหวังในกลุ่มที่อยู่ใกล้เคียงกันเข้าด้วยกันจนกระทั่งทำให้  $E_i \geq 5$
- 2) รวมค่าความถี่สังเกตที่สอดคล้องกับความถี่ใน ข้อ 1) เข้าด้วยกัน

3) df ของ  $\sum \frac{(X_i - E_i)^2}{E_i}$  มีค่าเท่ากับ  $r - 1$  เมื่อ  $r$  คือจำนวน category ที่เหลืออยู่หลัง

จากการดำเนินการใน ข้อ 1) และ 2)

อนึ่ง ค่า  $E_i$  ควรเป็นเลขจำนวนเต็มเพราะเป็นค่าความถี่ แต่ในหลายกรณีค่า  $E_i$  มักมิได้เป็นเลขจำนวนเต็ม ซึ่งในกรณีเช่นนี้ยังคงให้ใช้ค่านั้นได้ต่อไป เพราะการปรับค่าให้กลับเป็นเลขจำนวนเต็มอาจมีผลเสียต่อค่าของ  $\chi^2$  และโครงสร้างเดิมอันเป็นผลลัพธ์ของการพัฒนาตัวทดสอบ

ตามตัวอย่างใน ข้อ ข. เราสามารถปรับตารางเสียใหม่โดยนำความถี่  $X_1$  และ  $X_2$  รวมกับ  $X_3$  และนำ  $E_1$  และ  $E_2$  รวมกับ  $E_3$  ซึ่งปรากฏผลดังตารางต่อไปนี้

|       |          |          |
|-------|----------|----------|
| $X_i$ | 44       | 36       |
| $E_i$ | 10.67871 | 69.32129 |

$$\chi^2 = \frac{(44 - 10.67871)^2}{10.67871} + \frac{(36 - 69.32129)^2}{69.32129} \sim \chi_{(1)}^2$$

$$= 119.99086$$

ขณะที่  $\chi_{1, .95}^2 = 3.841$

เราจึงสรุปได้ว่าค่า  $p_i$  มิได้สอดคล้องกับค่า  $p_{ij}$  ที่ได้รับมาจาก J-Distribution หรือนัยหนึ่งเชื่อว่ากลุ่มตัวอย่างนี้มิได้เป็นกลุ่มตัวอย่างของประชากร J-Distribution

ตัวอย่าง 6.18 ในการบันทึกข้อมูลจากแหล่งข้อมูลที่ให้ค่าอยู่ในช่วง  $(-\infty, \infty)$  โดยแบ่ง domain ออกเป็น 8 ช่วง คือ  $A_1 = \{x; -\infty < x < 0\}$ ,  $A_i = \{x; i - 2 < x \leq i - 1\}; i = 1, 2, \dots, 7$  และ  $A_8 = \{x; 6 < x < \infty\}$  ปรากฏความถี่ของข้อมูลที่ปรากฏในช่วง  $A_1, A_2, \dots, A_8$  เท่ากับ 60, 96, 140, 210, 172, 160, 88 และ 74 ชุด ตามลำดับ

อยากทราบว่าข้อมูลทั้ง 1,000 ชุด นี้ น่าจะสุ่มมาจากกลุ่มประชากรใดหรือ Parent Population น่าจะมีการแจกแจงแบบใด ให้ใช้ระดับนัยสำคัญ 5%

วิธีทำ จากการพิจารณา domain จะพบว่าค่าของตัวแปรสุ่มปรากฏในช่วง  $(-\infty, \infty)$  หนึ่ง เมื่อพิจารณาความถี่ในช่วงต่าง ๆ พบว่ามีความถี่เท่ากับ 60, 96, 140, 210, 172, 160, 88, 74 โดยลักษณะของฮิสโตแกรมแล้วเข้าข่ายโค้งปกติ ด้วยเหตุนี้เราจึงเดาได้ว่า Parent Population น่าจะมีการแจกแจงแบบปกติ

$$f_x(x; \mu, \sigma^2) = \frac{1}{\sigma \sqrt{2\pi}} \exp \left\{ -\frac{1}{2\sigma^2} (x - \mu)^2 \right\}; -\infty < x < \infty$$

และเพื่อความสะดวกขอถือว่า  $\mu = 3, \sigma^2 = 4$ <sup>1</sup>

ดังนั้น

$$p_{i_0} = \int_{A_i} \frac{1}{\sigma \sqrt{2\pi}} \exp \left\{ -\frac{1}{2\sigma^2} (x - \mu)^2 \right\} dx; i = 1, 2, \dots, 8$$

และความถี่คาดหวัง  $E_i = np_{i_0} = 1000 p_{i_0}; i = 1, 2, \dots, 8$

สำหรับการคำนวณหาค่า  $p_{i_0}$  ให้ปฏิบัติดังนี้

$$\begin{aligned} p_{1_0} &= \int_{-\infty}^0 \frac{1}{\sigma \sqrt{2\pi}} e^{1/2(x-\mu)^2/\sigma^2} dx \\ &= \int_{-\infty}^0 \frac{1}{2\sqrt{2\pi}} e^{-\frac{1}{2(4)}(x-3)^2} dx \end{aligned}$$

<sup>1</sup> ในทางปฏิบัติเราอาจประมาณค่า  $\mu$  และ  $\sigma^2$  จากกลุ่มตัวอย่างหรืออาศัยข้อสนเทศในอดีต

$$\text{ให้ } \frac{x-3}{2} = z \text{ ดังนั้น } dx = 2 dz \text{ และ } -\infty \leq z \leq -1.5$$

$$\Rightarrow p_{10} = \int_{-\infty}^{-1.5} \frac{1}{\sqrt{2\pi}} e^{-z^2/2} dz = \int_{-\infty}^{-1.5} f_z(x) dz$$

$$= \Pr \{Z \leq -1.5\} = .06681$$

ในทำนองเดียวกัน

$$p_{20} = \int_{-1.5}^{-1} f_z(z) dz = \Pr \{Z \leq -1\} - \Pr \{Z \leq -1.5\}$$

$$= .1587 - .06681 = .09189$$

$$p_{30} = \int_{-1}^{-.5} f_z(z) dz = \Pr \{Z \leq -.5\} - \Pr \{Z \leq -1\} = .3085 - .1587$$

$$p_{40} = \int_{-.5}^0 f_z(z) dz = \Pr \{Z \leq 0\} - \Pr \{Z \leq -.5\} = .5000 - .3085$$

$$p_{50} = \int_0^{.5} f_z(z) dz = \Pr \{Z \leq .5\} - \Pr \{Z \leq 0\} = .6915 - .5000$$

$$p_{60} = \int_{.5}^1 f_z(z) dz = \Pr \{Z \leq 1\} - \Pr \{Z \leq .5\} = .8413 - .6915$$

$$p_{70} = \int_1^{1.5} f_z(z) dz = \Pr \{Z \leq 1.5\} - \Pr \{Z \leq 1\} = .93319 - .8413$$

$$p_{80} = \int_{1.5}^{\infty} f_z(z) dz = \Pr \{Z < \infty\} - \Pr \{Z \leq 1.5\} = 1 - .93319$$

ดังนั้น ค่า  $p_{i0}$  และ  $E_i$ ;  $i = 1, 2, \dots, 8$  ปรากฏดังตารางต่อไปนี้

|       |        |        |       |       |       |       |        |        |
|-------|--------|--------|-------|-------|-------|-------|--------|--------|
| $p_i$ | .06681 | .09189 | .1498 | .1915 | .1915 | .1498 | .09189 | .06681 |
| $E_i$ | 66.81  | 91.89  | 149.8 | 191.5 | 191.5 | 149.8 | 91.89  | 66.81  |



ดังนั้น  $H_0 : p_1 = .06681, p_2 = .09189, p_3 = .1498, p_4 = .1915, p_5 = .1915$   
 $p_6 = .1498, p_7 = .09189, p_8 = .06681$

$H_1 : p_1 \neq .06681, \dots, p_7 \neq .09189, p_8 \neq .06681$

ตารางเปรียบเทียบระหว่างความถี่สังเกตกับความถี่คาดหวัง ปรากฏดังนี้

|       |       |       |       |       |       |       |       |       |
|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| $X_i$ | 60    | 96    | 140   | 210   | 172   | 160   | 88    | 74    |
| $E_i$ | 66.81 | 91.89 | 149.8 | 191.5 | 191.5 | 149.8 | 91.89 | 66.81 |

$$\chi_c^2 = \frac{(60 - 66.81)^2}{66.81} + \frac{(96 - 91.89)^2}{91.89} + \dots + \frac{(74 - 66.81)^2}{66.81}$$

$$= 6.92492626262264$$

$$\chi_{7,.95}^2 = 14.07$$

จะเห็นได้ว่า  $\chi_c^2 < 14.07$

นั่นคือ เราไม่อาจปฏิเสธสมมติฐานหลักและเชื่อว่ากลุ่มประชากรมีการแจกแจงแบบปกติ  $N(3, 4)$

**ตัวอย่าง 8.19** ในการศึกษากลุ่มเลือดพบว่ามนุษย์จะมีอัตราของเลือดทั้ง 4 กลุ่ม คือ A, B, AB และ O ในอัตราส่วน  $q^2 : p^2 + 2pq : r^2 + 2qr : 2pr$

จากการเจาะเลือดของคนทั่วไปโดยสุ่ม 770 คน พบว่าเป็นผู้มีกลุ่มเลือด A รวม 180 คน กลุ่มเลือด B รวม 360 คน กลุ่มเลือด AB รวม 132 คน กลุ่มเลือด O รวม 98 คน

อยากทราบค่าของความถี่ข้างต้นนี้สนับสนุนอัตราส่วน  $p = .4, q = .4, r = .2$  หรือไม่?

**วิธีทำ** ถ้า  $p = .4, q = .4, r = .2$  ดังนั้น

$$q^2 : p^2 + 2pq : r^2 + 2qr : 2pr = 0.16 : 0.48 : 0.20 : 0.16$$

นั่นคือ  $H_0 : p_1 = 16/100, p_2 = 48/100, p_3 = 20/100, p_4 = 16/100$

$H_1 : p_1 \neq 16/100, p_2 \neq 48/100, p_3 \neq 20/100, p_4 \neq 16/100$

ตารางเปรียบเทียบระหว่างความถี่สังเกตและความถี่คาดหวังปรากฏดังนี้

|                        |       |       |     |       |
|------------------------|-------|-------|-----|-------|
| $X_i$                  | 180   | 360   | 132 | 98    |
| $E_i = np_i = 770 p_i$ | 123.2 | 369.6 | 154 | 123.2 |

$$\chi^2 = \frac{(180 - 123.2)^2}{123.2} + \frac{(360 - 369.6)^2}{369.6} + \frac{(132 - 154)^2}{154} + \frac{(98 - 123.2)^2}{123.2}$$

$$= 34.73376623371$$

แต่  $\chi_{3, .95}^2 = 7.815$  ซึ่งจะพบว่า  $\chi^2 > 7.815$

นั่นคือ เราปฏิเสธสมมติฐานหลัก ณ ระดับนัยสำคัญ 5% และเชื่อว่าทฤษฎีเกี่ยวกับกลุ่มเลือดที่ว่าอัตราส่วนระหว่างคนที่มีกลุ่มเลือด A, B, AB และ O ที่เท่ากับ  $q^2:p^2 + 2pq:r^2 + 2qr:2pr$  นั้น ค่า p, q, r ไม่ควรมีค่าเป็น .4, .4 และ .2

ตัวอย่าง 8.20 จากการบันทึกจำนวนเรือบรรทุกน้ำมันที่เข้าโรงกลั่นรวมทั้งสิ้น 1,000 วัน ปรากฏข้อมูลดังนี้

| จำนวนเรือที่เข้า<br>โรงกลั่นต่อวัน | ความถี่ |
|------------------------------------|---------|
| 0                                  | 376     |
| 1                                  | 356     |
| 2                                  | 191     |
| 3                                  | 57      |
| 4                                  | 16      |
| 5                                  | 2       |
| 6                                  | 1       |
| 7                                  | 1       |
|                                    | 1,000   |

อยากทราบว่าจำนวนเรือที่เข้าโรงกลั่นในแต่ละวันเป็นตัวแปรสุ่มพัวซองหรือไม่ ทั้งนี้ให้ใช้ระดับนัยสำคัญ 5%

วิธีทำ  $H_0: p_i = p_i; i = 0, 1, 2, \dots, 7$

เหตุที่  $\lambda =$  อัตราถั่วเฉลี่ยจำนวนเรือที่เข้าโรงกลั่นต่อวัน

$$\begin{aligned} \text{ดังนั้น } \lambda &= \frac{1}{1,000} (0 \times 376 + 1 \times 356 + 2 \times 191 + \dots + 7 \times 1) \\ &= 1 \text{ ลำ/วัน} \end{aligned}$$

$$\text{ดังนั้น } p_{i_0} = \frac{e^{-1} 1^y}{y!} = \frac{1}{ey!}; y = 0, 1, 2, \dots, 7$$

จากตารางพัวของพบว่า

$$p_{00} = .368, p_{10} = .368, p_{20} = .184, p_{30} = .061$$

$$p_{40} = .015, p_{50} = .003, p_{60} = .001, p_{70} = 0$$

$$E_i = np_{i_0} = 1,000 p_{i_0}; i = 0, 1, 2, \dots, 7$$

ดังนั้น จึงปรากฏข้อมูลเปรียบเทียบระหว่างค่าสังเกตและค่าคาดหวังดังนี้

| จำนวนเรือ | 0   | 1   | 2   | 3  | 4  | 5 | 6 | 7 |
|-----------|-----|-----|-----|----|----|---|---|---|
| $X_i$     | 376 | 256 | 191 | 57 | 16 | 2 | 1 | 1 |
| $E_i$     | 368 | 368 | 184 | 61 | 15 | 3 | 1 | 0 |

จัดกลุ่มข้อมูลค่าคาดหวัง  $E_i$  ที่มีค่าต่ำกว่า 5 เข้าเป็นกลุ่มที่มีค่าน้อยเท่ากับ 5 ในที่นี้กระทำโดยนำ 3 และ 1 ไปรวมกับ 15 ข้อมูลที่ต้องการจึงปรากฏดังตาราง

| จำนวนเรือ | 0   | 1   | 2   | 3  | 4 - 7 |
|-----------|-----|-----|-----|----|-------|
| $X_i$     | 376 | 356 | 191 | 57 | 20    |
| $E_i$     | 368 | 368 | 184 | 61 | 19    |

$$\chi_c^2 = \frac{(376 - 368)^2}{368} + \frac{(356 - 368)^2}{368} + \frac{(191 - 184)^2}{184} + \frac{(57 - 61)^2}{61} + \frac{(20 - 19)^2}{19} = 1.146$$

$$\text{แต่ } \because \chi_{4, .95}^2 = 9.48$$

จะเห็นว่า  $\chi^2 = 1.146$  มีได้มากกว่า  $\chi^2_{.95}$  ดังนั้น จึงไม่อาจปฏิเสธสมมุติฐานหลัก และเราเชื่อว่าจำนวนเรือที่เข้าโรงกลั่นเป็นตัวแปรสุ่มพัวของ

### 6.3.3 ตารางจำแนก (Contingency Table : CT)

CT คือ ตารางจำแนกหลายทาง (Multiple Classification) หมายความว่า จำแนกกลุ่มตัวอย่างออกเป็น 2 ทาง 3 ทาง 4 ทาง หรือมากกว่านั้นตามคุณลักษณะทางประชากรที่สนใจ โดยมีเจตนาเพื่อศึกษาความเกี่ยวข้องสัมพันธ์กันในระหว่างตัวแปรที่แสดงคุณลักษณะทางประชากร และโดยปกติเราจะจำแนกคุณลักษณะทางประชากรหนึ่ง ๆ ออกเป็นหลายระดับ ดังนั้น เราจึงอาจกล่าวได้ว่า CT คือ ตารางจำแนกที่มุ่งตรวจสอบดูว่าระดับต่าง ๆ ของคุณลักษณะหนึ่งของกลุ่มประชากรจะผันผวนไปตามระดับต่าง ๆ ของอีกคุณลักษณะหนึ่งของประชากรหรือไม่ ตัวอย่างเช่น ผู้วิจัยอยากทราบว่าความพึงพอใจในการเลือกคู่อรงผันผวนไปตามระดับการศึกษาของผู้เลือกคู่อรงหรือไม่ ในกรณีเช่นนี้เราอาจจำแนกความพึงพอใจออกเป็น 4 ระดับ คือ ไม่พึงพอใจเลย พึงพอใจน้อย พึงพอใจมาก และพึงพอใจที่สุด ขณะที่จำแนกระดับการศึกษาของบุคคลออกเป็น 4 ระดับ คือ ไม่มีการศึกษา มีการศึกษา ระดับประถมศึกษา มีการศึกษาระดับมัธยมศึกษา และมีการศึกษาระดับอุดมศึกษา การจำแนกคุณลักษณะนี้เรียกว่า  $4 \times 4$  CT หรือผู้วิจัยต้องการทราบว่า ความพึงพอใจในกฎหมายรัฐธรรมนูญของประชาชนผันแปรไปตามเพศและระดับรายได้ของประชากรหรือไม่ ในกรณีเช่นนี้อาจจำแนกความพึงพอใจในกฎหมายรัฐธรรมนูญออกเป็น 3 ระดับ คือ พอใจ ไม่พอใจ และเฉย ๆ ขณะที่จำแนกเพศออกเป็นเพศชายและเพศหญิง และจำแนกระดับรายได้ต่อเดือนเป็น 4 ระดับ คือ ไม่เกิน 5,000 บาท 5,000 - 10,000 บาท 10,000 - 15,000 บาท และ 15,000 บาท ขึ้นไป ลักษณะนี้เรียกว่า  $3 \times 2 \times 4$  CT ดังนั้น เป็นต้น จะเห็นได้ว่า CT จะเป็นตารางที่แสดงหรือแจกจำแนกกลุ่มตัวอย่างออกเป็นกลุ่มย่อย ๆ  $r \times c$  กลุ่ม หรือ  $r \times c \times k$  กลุ่ม เช่น ตามตัวอย่างข้างต้น ตาราง CT จำแนกกลุ่มตัวอย่างเป็น  $4 \times 4 = 16$  กลุ่มย่อย หรือ  $3 \times 2 \times 4 = 24$  กลุ่มย่อย เรียกกลุ่มย่อย ๆ เหล่านี้ว่า ห้อง (cell) ดังนั้น แต่ละ cell จึงแสดงความถี่หรือจำนวนหน่วยตัวอย่างที่มีคุณสมบัติสอดคล้องกับระดับย่อยที่สอดคล้องกัน ดังตัวอย่างเรื่องการศึกษาความสัมพันธ์ระหว่างทัศนคติต่อกฎหมายรัฐธรรมนูญกับเพศของประชาชน สมมุติว่าทำการสำรวจกับประชาชน 3,750 คน ปรากฏข้อมูลดังตาราง

| เพศ  | ทัศนคติที่มีต่อกฎหมายรัฐธรรมนูญ |         |       |
|------|---------------------------------|---------|-------|
|      | พอใจ                            | ไม่พอใจ | เฉย ๆ |
| ชาย  | 1155                            | 475     | 243   |
| หญิง | 1083                            | 442     | 362   |

ข้อมูลใน cell ที่ (1, 1) คือ 1,155 แสดงจำนวนกลุ่มตัวอย่างย่อย (ความถี่) ที่เป็นเพศชาย และพึงพอใจในกฎหมายรัฐธรรมนูญ หรือใน cell ที่ (2, 3) ข้อมูลคือ 362 แสดงจำนวนกลุ่มตัวอย่างย่อย (ความถี่) ที่เป็นเพศหญิง และไม่มีความรู้สึกใด ๆ ต่อกฎหมายรัฐธรรมนูญ เป็นต้น

ดังนั้น สิ่งที่น่าสนใจศึกษาจึงมุ่งไปที่การศึกษาว่าคุณลักษณะทางประชากรมีความเกี่ยวเนื่องกันหรือไม่ สมมุติฐานหลักที่ใช้จึงเสนอไว้ในลักษณะเป็นกลาง คือคุณลักษณะทางประชากรที่สนใจนั้นไม่เกี่ยวข้องกันหรือเป็นอิสระต่อกัน ขณะที่สมมุติฐานรองหรือสมมุติฐานเพื่อการวิจัยจะชี้ทิศทางไว้โดยกำหนดว่าคุณลักษณะทางประชากรที่สนใจมีความเกี่ยวเนื่องถึงกัน อนึ่งเมื่อเราจำแนกกลุ่มตัวอย่างออกเป็นกลุ่มย่อย ๆ หลายกลุ่ม (cell หรือ Category) โดยทั่วไปคือ  $r \times c$  หรือ  $r \times c \times k$  หรือ  $r \times c \times k \times l$  กลุ่ม ดังนั้น ลักษณะการแจกแจงของความถี่เหล่านี้จึงเป็นการแจกแจงแบบพหุนาม โดยกำหนดว่า  $p_{ij}$  หรือ  $p_{ijk}$  หรือ  $p_{ijkl}$  คือค่าความน่าจะเป็นที่หน่วยตัวอย่างใด ๆ จากตัวอย่าง  $n$  ชุด จะตกอยู่ใน cell ที่  $(i, j)$  หรือ  $(i, j, k)$  หรือ  $(i, j, k, l)$  ตามลำดับ

#### ตารางจำแนก 2 ทาง (Two-way contingency Table : 2 CT)

2 CT คือตารางจำแนกที่จำแนกกลุ่มตัวอย่างออกเป็น 2 ทาง ตามคุณลักษณะทางประชากรที่สนใจ 2 ลักษณะ

สมมุติคุณลักษณะทางประชากร 2 ลักษณะที่สนใจ คือ A และ B และเราสามารถแบ่งคุณลักษณะ A ออกเป็น  $r$  ระดับ คือ  $A_1, A_2, \dots, A_r$  แบ่งคุณลักษณะ B ออกเป็น  $c$  ระดับ คือ  $B_1, B_2, \dots, B_c$  ให้  $X_{ij}$  แสดงจำนวนหน่วยตัวอย่าง (ความถี่) ที่สอดคล้องกับระดับที่  $i$  ของคุณลักษณะ A และสอดคล้องกับระดับที่  $j$  ของคุณลักษณะ B เมื่อ  $i = 1, 2, \dots, r$  และ  $j = 1, 2, \dots, c$ <sup>1</sup> และความถี่ในทุก cell รวมกันจะต้องเท่ากับขนาดตัวอย่าง  $n$  หรือนัยหนึ่ง  $\sum_i \sum_j X_{ij} = n$  ดังตาราง<sup>2</sup>

<sup>1</sup> หรือ  $X_{ij}$  = จำนวนความถี่ที่ตกอยู่ใน cell ที่  $(i, j)$

<sup>2</sup>  $p_{ij}$  = Probability of inclusion

| คุณลักษณะ<br>A | คุณลักษณะ B                       |                                   |                                   |                                   |     |                                   | รวม  |
|----------------|-----------------------------------|-----------------------------------|-----------------------------------|-----------------------------------|-----|-----------------------------------|--|
|                | B <sub>1</sub>                    | B <sub>2</sub>                    | B <sub>3</sub>                    | B <sub>4</sub>                    | ... | B <sub>c</sub>                    |  |
| A <sub>1</sub> | X <sub>11</sub> , p <sub>11</sub> | X <sub>12</sub> , p <sub>12</sub> | X <sub>13</sub> , p <sub>13</sub> | X <sub>14</sub> , p <sub>14</sub> | ... | X <sub>1c</sub> , p <sub>1c</sub> | X <sub>1..</sub> , p <sub>1.</sub>         |
| A <sub>2</sub> | X <sub>21</sub> , p <sub>21</sub> | X <sub>22</sub> , p <sub>22</sub> | X <sub>23</sub> , p <sub>23</sub> | X <sub>24</sub> , p <sub>24</sub> | ... | X <sub>2c</sub> , p <sub>2c</sub> | X <sub>2..</sub> , p <sub>2.</sub>         |
| A <sub>3</sub> | X <sub>31</sub> , p <sub>31</sub> | X <sub>32</sub> , p <sub>32</sub> | X <sub>33</sub> , p <sub>33</sub> | X <sub>34</sub> , p <sub>34</sub> | ... | X <sub>3c</sub> , p <sub>3c</sub> | X <sub>3..</sub> , p <sub>3.</sub>         |
| ⋮              |                                   |                                   |                                   |                                   |     |                                   |  |
| A <sub>r</sub> | X <sub>r1</sub> , p <sub>r1</sub> | X <sub>r2</sub> , p <sub>r2</sub> | X <sub>r3</sub> , p <sub>r3</sub> | X <sub>r4</sub> , p <sub>r4</sub> | ... | X <sub>rc</sub> , p <sub>rc</sub> | X <sub>r..</sub> , p <sub>r.</sub>         |
| รวม            | X <sub>.1</sub> , p <sub>.1</sub> | X <sub>.2</sub> , p <sub>.2</sub> | X <sub>.3</sub> , p <sub>.3</sub> | X <sub>.4</sub> , p <sub>.4</sub> | ... | X <sub>.c</sub> , p <sub>.c</sub> | X <sub>..</sub> = n<br>p <sub>..</sub> = 1 |

เมื่อ  $X_{ij}$  = จำนวนความถี่ที่ตกอยู่ในห้อง (cell) ที่ (i, j)

$p_{ij}$  = Probability of Inclusion

$$X_{i.} = X_{i1} + X_{i2} + \dots + X_{ic} = \sum_j X_{ij} \text{ สำหรับทุกค่าของ } i; i = 1, 2, \dots, r$$

$$X_{.j} = X_{1j} + X_{2j} + \dots + X_{rj} = \sum_i X_{ij} \text{ สำหรับทุกค่าของ } j; j = 1, 2, \dots, c$$

$$X_{..} = \sum_i \sum_j X_{ij} = \sum_i X_{i.} = \sum_j X_{.j} = n$$

ให้  $p_{ij}$  = ความน่าจะเป็นที่หน่วยตัวอย่างใด ๆ จะตกอยู่ใน cell ที่ (i, j) หรือนัยหนึ่งคือ ความน่าจะเป็นที่หน่วยตัวอย่างใด ๆ จะมีคุณสมบัติหรือลักษณะสอดคล้องกับ ระดับที่ i ของคุณลักษณะ A และระดับที่ j ของคุณลักษณะ B;  $i = 1, 2, \dots, r$ ;  $j = 1, 2, \dots, c$

$$p_{i.} = \sum_j p_{ij} = \text{ความน่าจะเป็นที่หน่วยตัวอย่างใด ๆ จะมีคุณสมบัติหรือลักษณะสอดคล้องกับระดับที่ } i \text{ ของคุณลักษณะ A; } i = 1, 2, \dots, r$$

$$p_{.j} = \sum_i p_{ij} = \text{ความน่าจะเป็นที่หน่วยตัวอย่างใด ๆ จะมีคุณสมบัติหรือลักษณะสอดคล้องกับระดับที่ } j \text{ ของคุณลักษณะ B; } j = 1, 2, \dots, c$$

$$p_{..} = \sum_i \sum_j p_{ij} = \sum_i p_{i.} = \sum_j p_{.j} = 1$$

ดังนั้น  $f(x_{11}, x_{12}, \dots, x_{rc}; p_{11}, p_{12}, \dots, p_{rc}) = p_{11}^{x_{11}} p_{12}^{x_{12}} \dots p_{1c}^{x_{1c}} \dots p_{r1}^{x_{r1}} p_{r2}^{x_{r2}} \dots p_{rc}^{x_{rc}}$

$$= \prod_i \prod_j p_{ij}^{x_{ij}}$$

หรือจะใช้  $f(x_{11}, x_{12}, \dots, x_{rc}; p_{11}, p_{12}, \dots, p_{rc}) = \binom{n}{x_{11} \ x_{12} \ \dots \ x_{rc}} \prod_i \prod_j p_{ij}^{x_{ij}}$  ก็ได้

สมมุติฐานที่ต้องการทดสอบคือ คุณสมบัติ A และ B เป็นอิสระต่อกัน หรือนัยหนึ่ง เมื่อมองในรูปของความน่าจะเป็นก็คือ ความน่าจะเป็นที่หน่วยตัวอย่างใด ๆ จะมีคุณสมบัติสอดคล้องกับระดับที่ i ใด ๆ ของ A ได้นั้น มีจำเป็นต้องมีสาเหตุสืบเนื่องมาจากคุณสมบัติที่สอดคล้องกับระดับที่ j หนึ่งใดของ B หรือกลับกัน

นั่นคือ  $\Pr(A_i | B_j) = \Pr(A_i); i = 1, 2, \dots, r; j = 1, 2, \dots, c$

หรือ  $\Pr(B_j | A_i) = \Pr(B_j); i = 1, 2, \dots, r; j = 1, 2, \dots, c$

หรือ  $\Pr(A_i \cap B_j) = \Pr(A_i) \Pr(B_j); i = 1, 2, \dots, r; j = 1, 2, \dots, c$

หรือ  $p_{ij} = p_{i.} p_{.j}; i = 1, 2, \dots, r; j = 1, 2, \dots, c$

ดังนั้น สมมุติฐานทางสถิติที่จะทดสอบ คือ

$$H_0: p_{ij} = p_{i.} p_{.j} \text{ vs } H_1: p_{ij} = p_{ij} \neq p_{i.} p_{.j}^1$$

(1) การพัฒนาตัวทดสอบ

จาก  $H_0$  และ  $H_1$  เราสามารถแจก parameter space ออกมาได้ดังนี้

$$\omega = \{p_{i.}, p_{.j}; 0 \leq p_{i.} \leq 1, 0 \leq p_{.j} \leq 1; i = 1, 2, \dots, r; j = 1, 2, \dots, c\}$$

และ

$$\Omega = \{p_{ij}; 0 \leq p_{ij} \leq 1; i = 1, 2, \dots, r; j = 1, 2, \dots, c\}$$

<sup>1</sup>  $H_0$ : ความน่าจะเป็นที่หน่วยตัวอย่างใด ๆ จะตกอยู่ใน cell ที่ (i, j) มีค่าเท่ากับความน่าจะเป็นที่หน่วยตัวอย่างจะตกอยู่ในระดับที่ i ของ A และ ระดับที่ j ของ B หรือ  $\Pr(A_i \cap B_j) = \Pr(A_i) \Pr(B_j)$  หรือความน่าจะเป็นที่หน่วยตัวอย่างใด ๆ จะมีคุณสมบัติสอดคล้องกับระดับที่ i ของคุณลักษณะ A ได้นั้น มีจำเป็นต้องมีสาเหตุมาจากการมีคุณสมบัติที่สอดคล้องกับระดับที่ j หนึ่งใดของ B

$H_1$ : ความน่าจะเป็นที่หน่วยตัวอย่างใด ๆ ที่จะมีคุณสมบัติสอดคล้องกับระดับที่ i ของ A ได้นั้น จำเป็นต้องมีสาเหตุพัวพัน (Interaction) มาจากระดับที่ j ของคุณลักษณะ B

ดังนั้น  $L_\omega = \prod_i^r \prod_j^c (p_i p_j)^{x_{ij}}$  และ  $L_\alpha = \prod_i^r \prod_j^c (p_{ij})^{x_{ij}}$

พิจารณา  $L_\omega$  จะพบว่า

$$\begin{aligned} L_\omega &= \prod_i^r \prod_j^c (p_i p_j)^{x_{ij}} = \prod_i^r (p_i)^{x_{i1} + x_{i2} + \dots + x_{i,c}} \prod_j^c (p_j)^{x_{1j} + x_{2j} + \dots + x_{rj}} \\ &= \prod_i^r \{(p_i)^{x_{i1}} (p_i)^{x_{i2}} \dots (p_i)^{x_{i,c}}\} \cdot \prod_j^c \{(p_j)^{x_{1j}} (p_j)^{x_{2j}} \dots (p_j)^{x_{rj}}\} \\ &= \prod_i^r (p_i)^{\sum_j^c x_{ij}} \prod_j^c (p_j)^{\sum_i^r x_{ij}} \\ \Rightarrow L_\omega &= \prod_i^r (p_i)^{x_{i.}} \prod_j^c (p_j)^{x_{.j}} \end{aligned}$$

เนื่องจากเซต  $\omega$  ประกอบด้วยพารามิเตอร์ที่ไม่ทราบค่า  $(r-1) + (c-1)$  ตัวคือ  $p_1, p_2, \dots, p_{(r-1)}$  และ  $p_{.1}, p_{.2}, \dots, p_{.(c-1)}$  ทั้งนี้ เพราะ

$$\begin{aligned} p_r &= 1 - \sum_i^{r-1} p_i = 1 - (p_1 + p_2 + \dots + p_{(r-1)}) \text{ และ } p_c = 1 - \sum_j^{c-1} p_j \\ &= 1 - (p_{.1} + p_{.2} + \dots + p_{.(c-1)}) \end{aligned}$$

ดังนั้น เราจึงประมาณค่าพารามิเตอร์เพียง  $r+c-2$  ตัว ในที่นี้จะเริ่มด้วยการประมาณค่า  $p_i; i=1, 2, \dots, r-1$  ก่อน แล้วจึงค่อยประมาณค่า  $p_j; j=1, 2, \dots, c-1$

จาก  $L_\omega = \prod_i^r (p_i)^{x_{i.}} \prod_j^c (p_j)^{x_{.j}}$

แทนที่  $p_r$  ด้วย  $1 - \sum_i^{r-1} p_i$  และแทนที่  $p_c$  ด้วย  $1 - \sum_j^{c-1} p_j$

$$\Rightarrow L_\omega = (p_1)^{x_{1.}} (p_2)^{x_{2.}} \dots (p_{(r-1)})^{x_{(r-1).}} (1 - \sum_i^{r-1} p_i)^{x_{r.}} (p_{.1})^{x_{.1}} (p_{.2})^{x_{.2}} \dots p_{.(c-1)}^{x_{.(c-1)}} (1 - \sum_j^{c-1} p_j)^{x_{.c}}$$

---

<sup>1</sup> เพื่อแสดงให้เห็นความจริงของ identity นี้ ขอให้ให้นักศึกษาทดลองกระจายกับตัวอย่างขนาดเล็ก เช่น  $\prod_i^2 \prod_j^2 (p_i p_j)^{x_{ij}}$  โดยไล่เรียง subscript ทีละตัว อาจเริ่มจาก  $j$  ก่อน แล้วเริ่ม  $i$  ภายหลังก็ได้



$$\frac{\partial}{\partial p_i} \ln L_\omega = 0; i = 1, 2, \dots, r - 1$$

$$\text{ดังนั้น } 0 + 0 + \dots + 0 + \frac{X_i}{p_i} + 0 + \dots + \frac{X_r(-1)}{(1 - \sum_i^{r-1} p_i)} = 0$$

$$; i = 1, 2, \dots, r - c$$

$$\Rightarrow \frac{X_i}{p_i} = \frac{X_r}{p_r}; i = 1, 2, \dots, r - 1$$

$$p_i = (p_r/X_r) X_i; i = 1, 2, \dots, r - 1 \quad \dots\dots\dots(1)$$

รวมตลอดในทุกค่าของ  $i$  ตั้งแต่ 1 ถึง  $r$

$$\sum_i^r p_i = (p_r/X_r) \sum_i^r X_i$$

$$1 = (p_r/X_r)n$$

$$\text{ดังนั้น } p_r/X_r = 1/n \quad \dots\dots\dots(2)$$

แทนค่า (2) ใน (1)  $\Rightarrow \hat{p}_i = X_i/n; i = 1, 2, \dots, r - 1$

$$\begin{aligned} \text{และ } \hat{p}_r &= 1 - (\hat{p}_1 + \hat{p}_2 + \dots + \hat{p}_{(r-1)}) \\ &= 1 - \left( \frac{X_1}{n} + \frac{X_2}{n} + \dots + \frac{X_{(r-1)}}{n} \right) \\ &= \frac{X_r}{n} \end{aligned}$$

ในการทำงานเดียวกัน เมื่อดิฟเฟอเรนเชียล  $\ln L_\omega$  เทียบต่อ  $p_j$  เราสามารถพิสูจน์ได้ว่า

$$p_j = \frac{X_j}{n}; j = 1, 2, \dots, c - 1 \text{ และ } \hat{p}_c = \frac{X_c}{n}$$

แทนค่า  $\hat{p}_i, \hat{p}_j$  ใน  $L_\omega$  จะได้  $L_\Delta$  ดังนี้

$$\begin{aligned} L_\Delta &= \prod_i^r \left(\frac{X_i}{n}\right)^{x_i} \prod_j^c \left(\frac{X_j}{n}\right)^{x_j} \\ &= \frac{\prod_i^r (X_i)^{x_i}}{n^{x_1} n^{x_2} \dots n^{x_r}} \frac{\prod_j^c (X_j)^{x_j}}{n^{x_1} n^{x_2} \dots n^{x_c}} \\ &= \frac{1}{n^n} \prod_i^r (X_i)^{x_i} \frac{1}{n^n} \prod_j^c (X_j)^{x_j} \end{aligned}$$

พิจารณา  $L_\Omega = \prod_i^r \prod_j^c (p_{ij})^{x_{ij}}$

$$= \prod_i^{r-1} \prod_j^{c-1} (p_{ij})^{x_{ij}} \prod_i^{r-1} (p_{ic})^{x_{ic}} \prod_j^{c-1} (p_{rj})^{x_{rj}}$$


$$\{1 - \sum_i^{r-1} \sum_j^{c-1} p_{ij} - \sum_i^{r-1} p_{ic} - \sum_j^{c-1} p_{rj}\}^{x_{rc} - 1}$$

$$\frac{\partial}{\partial p_{ij}} \ln L_\Omega = 0; i = 1, 2, \dots, r; j = 1, 2, \dots, c \text{ ยกเว้น } p_{rc}$$

$$\Rightarrow 0 + 0 + \dots + 0 + \frac{X_{ij}}{p_{ij}} + 0 + \dots + 0 + \frac{(-1) X_{rc}}{1 - \sum_i^{r-1} \sum_j^{c-1} p_{ij} - \sum_i^{r-1} p_{ic} - \sum_j^{c-1} p_{rj}}$$

$$i = 1, 2, \dots, r; j = 1, 2, \dots, c \text{ ยกเว้น } p_{rc}$$

<sup>1</sup> ดูไดอะแกรม



$$\Rightarrow \frac{X_{ij}}{p_{ij}} = \frac{X_{rc}}{p_{rc}}; i = 1, 2, \dots, r; j = 1, 2, \dots, c$$

$$p_{ij} = \frac{p_{rc}}{X_{rc}} \cdot X_{ij}; i = 1, 2, \dots, r; j = 1, 2, \dots, c \quad \dots\dots\dots(1)$$

$$\sum_i^r \sum_j^c p_{ij} = \frac{p_{rc}}{X_{rc}} \sum_i^r \sum_j^c X_{ij}$$

$$1 = \frac{p_{rc}}{X_{rc}} \cdot n$$

$$\frac{p_{rc}}{X_{rc}} = \frac{1}{n} \quad \dots\dots\dots(2)$$

แทน (2) ใน (1)

$$\Rightarrow \hat{p}_{ij} = \frac{X_{ij}}{n}; i = 1, 2, \dots, r; j = 1, 2, \dots, c \text{ ยกเว้น } p_{rc}$$

และเราสามารถพิสูจน์ได้ว่า  $\hat{p}_{rc} = \frac{X_{rc}}{n}$

ดังนั้น  $L_{\hat{\alpha}} = \prod_i^r \prod_j^c \left(\frac{X_{ij}}{n}\right)^{X_{ij}} = \frac{1}{n^{(\sum X_{ij})}} \prod_i^r \prod_j^c X_{ij}^{X_{ij}}$

$$\Rightarrow L_{\hat{\alpha}} = \frac{1}{n^n} \prod_i^r \prod_j^c (X_{ij})^{X_{ij}}$$

โดยอาศัย MLR เราจะปฏิเสธสมมุติฐานหลักเมื่อ  $\lambda = \frac{L_{\hat{\alpha}}}{L_{\alpha}} \leq k$

$$\lambda = \left\{ \frac{1}{n^n} \cdot \frac{1}{n^n} \prod_i^r (X_i)^{X_i} \prod_j^c (X_j)^{X_j} \right\} / \left\{ \frac{1}{n^n} \prod_i^r \prod_j^c (X_{ij})^{X_{ij}} \right\} \leq k$$

$$\Rightarrow \lambda = \frac{\prod_i^r (X_i)^{X_i} \prod_j^c (X_j)^{X_j}}{n^n \prod_i^r \prod_j^c (X_{ij})^{X_{ij}}} \leq k$$

นั่นคือ ปฏิเสธสมมุติฐานหลัก ณ ระดับนัยสำคัญ  $\alpha$  เมื่อ  $\lambda \leq k$  โดยที่ค่าของ  $k$  สามารถคำนวณได้จากสมการต่อไปนี้คือ

$$\int_{-\infty}^k f_{\lambda}(x) dx = \alpha^{-1}$$

อย่างไรก็ตาม pdf ของ  $\lambda$  หาได้ค่อนข้างยากและซับซ้อนมาก<sup>2</sup> ดังนั้นในทางปฏิบัติจึงจำเป็นต้องประมาณ pdf ของ  $\lambda$  โดยอาศัยทฤษฎี 7.1 ทั้งนี้มีข้อจำกัดว่าขนาดตัวอย่าง  $n$  ต้องใหญ่มากพอ ( $n \rightarrow \infty$ )

$$\Rightarrow -2 \ln \lambda \sim \chi^2$$

สำหรับ df ของ  $\chi^2$  ให้พิจารณา Reparameterized Space “กล่าวคือจาก  $\omega$  จะพบว่าเสนอพารามิเตอร์ไว้เพียง  $rc - 1$  ค่า ค่าสุดท้ายคือ  $p_r$  ไม่จำเป็นต้องกำหนดเพราะ  $\sum_i \sum_j p_{ij} = 1$  สำหรับใน  $\omega$  จะพบว่าเสนอพารามิเตอร์ไว้เพียง  $(r - 1) + (c - 1)$  ค่าคือ  $p_i; i = 1, 2, \dots, r - 1$  และ  $p_j; j = 1, 2, \dots, c - 1$  ค่าสุดท้ายคือ  $p_r$  และ  $p_c$  ไม่จำเป็นต้องกำหนดเพราะ  $\sum_i p_i = 1$  และ  $\sum_j p_j = 1$

ดังนั้น Reparameterized Space จึงประกอบด้วยพารามิเตอร์เพียง  $(rc-1) - (r+c-2) = rc - r - c + 1 = (r-1)(c-1)$  ค่า

ดังนั้น โดยอาศัยทฤษฎี 7.1  $-2 \ln \lambda \sim \chi^2_{(r-1)(c-1)}$  เมื่อ

$$\lambda = \left\{ \prod_i (X_i)^{x_i} \prod_j (X_j)^{x_j} \right\} / \left\{ n^n \prod_i \prod_j (X_{ij})^{x_{ij}} \right\}$$

$$\text{นั่นคือ ปฏิเสธสมมติฐานหลักเมื่อ } -2 \ln \lambda = 2 \ln \left\{ \frac{\prod_i (X_i)^{x_i} \cdot \prod_j (X_j)^{x_j}}{n^n \prod_i \prod_j (X_{ij})^{x_{ij}}} \right\} > -2 \ln k = k'$$

และโดยอาศัยเทคนิคทำนองเดียวกับตอน 6.3.2 เราสามารถพิสูจน์ได้ว่า เมื่อ  $n \rightarrow \infty$  แล้ว เราจะปฏิเสธสมมติฐานหลักเมื่อ

<sup>1</sup> ในภาษากรีก  $\lambda$  คืออักษรตัวพิมพ์ขณะที่  $\lambda$  คืออักษรตัวเขียน อ่านว่าแลมด้า

<sup>2</sup> อ่านเพิ่มเติมจาก Mood, Graybill and Boe, Introduction to the Theory of Statistics, 3<sup>rd</sup> ed., p.455-9

<sup>3</sup> ทฤษฎี 7.1