

วิธีดำเนินการวิจัย

ในการวิจัยครั้งนี้ต้องการศึกษาความสัมพันธ์ระหว่างสัมประสิทธิ์สหสัมพันธ์กับค่าทดสอบไคสแควร์ ในกรณีที่ประชากรมีการแจกแจงแบบปกติสองตัวแปร โดยจะประมาณช่วงความเชื่อมั่น (Confidence interval) พร้อมทั้งค่าคาดหวัง (Expected value) ของค่าสัมประสิทธิ์สหสัมพันธ์ ณ ค่าไคสแควร์ในแต่ละช่วง และศึกษาอิทธิพลของขนาดตัวอย่าง ขนาดตาราง และการสุ่มกลุ่มข้อมูล ที่มีต่อค่าไคสแควร์ ในกรณีที่ประชากรมีการแจกแจงแบบพหุนามสองตัวแปร จะศึกษาเฉพาะอิทธิพลของขนาดตัวอย่าง ขนาดตาราง ที่มีต่อค่าไคสแควร์ แต่จะไม่ประมาณช่วงความเชื่อมั่นพร้อมทั้งค่าคาดหวังของสัมประสิทธิ์สหสัมพันธ์ ทั้งนี้เพราะในการวิจัยครั้งนี้จะศึกษาเฉพาะสัมประสิทธิ์สหสัมพันธ์เชิงเส้นแบบเพียร์สัน (Pearson Product-Moment Correlation Coefficient) ซึ่งมีข้อตกลงเบื้องต้นว่าตัวแปรจะต้องมีการแจกแจงแบบต่อเนื่อง สำหรับข้อมูลที่ใช้ในการวิจัยว่าเป็นที่จะต้องเตรียมข้อมูลประชากร (Population data) ที่มีสภาพการแจกแจงตามที่กำหนดเสียก่อน เพื่อให้ผลสรุปถูกต้องและมีความมั่นใจได้ว่าประชากรมีคุณสมบัติตามที่ต้องการศึกษา โดยจะใช้วิธีการที่เรียกว่าเทคนิคการจำลองแบบ (Simulation technique) มาผลิต (generate) ข้อมูลประชากร ซึ่งตัวแปรที่สร้างขึ้นคือค่า (X,Y) จากนั้นจะดำเนินการสุ่มตัวอย่างขนาดต่าง ๆ เพื่อคำนวณค่าไคสแควร์ในรูปแบบของขนาดตารางการถ่วงที่แตกต่างกัน และจะดำเนินการศึกษาในขั้นตอนต่อไปในแต่ละกรณีดังนี้

3.1 กรณีตัวแปรมีการแจกแจงแบบพหุนามสองตัวแปร (Bivariate multinomial)

การสร้างข้อมูลประชากรที่มีการแจกแจงแบบพหุนามสองตัวแปร จะใช้ซับรูทีนแรนดู (Subroutine Randu) ผลิตตัวเลขสุ่มที่มีการแจกแจงแบบสม่ำเสมอในช่วง (0, 1) เลขสุ่มที่ได้จะถูกสร้างให้มีลักษณะสุ่ม (random) และเป็นอิสระต่อกัน โดยตัวเลขสุ่มแต่ละหมายเลขมีโอกาสดังขึ้นเท่าเทียมกันการใช้โปรแกรมย่อยจะใช้คำสั่ง CALL RANDU (IX, IY, YFL) พารามิเตอร์ในวงเล็บมีความหมายดังนี้

IX คือตัวเลขลุ่มตัวแรก จะต้องเป็นจำนวนเต็มบวกที่เป็นเลขคู่ และน้อยกว่า 2147483648 ซึ่ง IX นี้จะเป็นค่าเริ่มต้นที่จะให้สับรูทีนตัวจำนวน IY ออกมาให้ โดย IX จะเป็นค่าที่ส่งมาจากโปรแกรมหลัก (Main Program) IY คือตัวเลขลุ่มจำนวนเต็มบวกของสับรูทีนนี้ และจะใช้เป็นตัวจำนวน IY ตัวต่อ ๆ ไป พิสัยของตัวเลขลุ่มจะอยู่ระหว่าง 0 กับ 2^{32} YFL คือเลขลุ่มที่คำนวณได้ และมีการแจกแจงแบบลุ่ม่าเลมอในช่วง (0,1)

ในกรณีที่ประเภทการแจกแจงแบบพหุนามสองตัวแปร (bivariate multinomial) จะแบ่งการศึกษาออกเป็นสองกรณีคือ กรณีที่ตัวแปรทั้งสองเป็นอิสระต่อกัน และกรณีที่ตัวแปรทั้งสองไม่เป็นอิสระต่อกัน ดังนี้

3.1.1 กรณีที่ตัวแปรทั้งสองเป็นอิสระต่อกัน

ในกรณีที่ตัวแปรทั้งสองเป็นอิสระต่อกัน จะศึกษาขนาดตาราง 4×5 4×3 4×2 2×3 และ 2×2 ขนาดตัวอย่างเท่ากับ 50 100 และ 150 เพื่อศึกษาอิทธิพลของขนาดตัวอย่างและขนาดตารางที่ต่อค่าไคล์แควร์ ในแต่ละกรณีจะกระทำซ้ำเป็นจำนวน 300 รอบ โดยดำเนินการตามขั้นตอนต่อไปนี้

1. ผลิตตัวเลขลุ่มที่มีการแจกแจงแบบลุ่ม่าเลมอในช่วง (0,1) โดยใช้สับรูทีนแรนดู (Subroutine Randu) เรียกข้อมูลเลขลุ่มที่ได้ครั้งแรกว่า X_k ($k = 1, 2, \dots, n$) โดยที่ n คือขนาดตัวอย่าง จากนั้นจะผลิตตัวเลขลุ่มที่มีการแจกแจงแบบลุ่ม่าเลมอขึ้นมาอีกชุดหนึ่ง โดยใช้สับรูทีน แรนดู และเรียกข้อมูลเลขลุ่มที่ได้ว่า Y_k ($k = 1, 2, \dots, n$) ดังนั้นข้อมูลเลขลุ่มที่ผลิตขึ้นมาคือ (X_k, Y_k)

2. ถ้ากำหนดการแจกแจงโดยตารางแจกแจงความน่าจะเป็นร่วมดังนี้

ตารางที่ 3.1 แสดงตารางแจกแจงความน่าจะเป็นร่วมขนาดตาราง rxc

| | | Y | | | | |
|---|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| | | Y ₁ | Y ₂ | | Y _c | |
| X | X ₁ | f ₁₁ | f ₁₂ | | f _{1c} | f _{1.} |
| | X ₂ | f ₂₁ | f ₂₂ | | f _{2c} | f _{2.} |
| | . | | | | | |
| | . | | | | | |
| | . | | | | | |
| | . | | | | | |
| | X _r | f _{r1} | f _{r2} | | f _{rc} | f _{r.} |
| | f _{.1} | f _{.2} | | f _{.c} | 1.00 | f _{..} |

$$f_{i.} = \sum_{j=1}^c f_{ij}$$

$$f_{.j} = \sum_{i=1}^r f_{ij}$$

และ $f_{i.} \times f_{.j} = f_{ij}$

จากตารางแจกแจงความน่าจะเป็นร่วม

f_{ij} หมายถึงความน่าจะเป็นร่วมที่ตัวแปรพหุนามล่องตัวแปร (X_k, Y_k) จะตกอยู่ในช่อง (i, j)

$f_{i.}$ หมายถึงความน่าจะเป็นที่ตัวแปรพหุนามล่องตัวแปร (X_k, Y_k) จะมีค่า X_k ตกในแถวตอนที่ i Y_k ตกอยู่ในแถวตั้งที่ j ใด ๆ

$f_{.j}$ หมายถึงความน่าจะเป็นที่ตัวแปรพหุนามล่องตัวแปร (X_k, Y_k) จะมีค่า Y_k ตกในแถวตั้งที่ j X_k ตกอยู่ในแถวตอนที่ i ใด ๆ

$$f_{..} = \sum_{i=1}^r f_{i.} = \sum_{j=1}^c f_{.j} = n$$

จากนั้น จะพิจารณาค่าของตัวแปร (X_k, Y_k) โดยจะพิจารณาตัวแปร

X_k ดังนี้

ถ้า $0 \leq X_k < f_{1.}$ จะนับเป็นความถี่ในแถวตอนที่หนึ่ง

ถ้า $f_{1.} \leq X_k < f_{1.} + f_{2.}$ จะนับเป็นความถี่ในแถวตอนที่สอง

⋮

ถ้า $f_{1.} + \dots + f_{(r-1).} \leq X_k < 1.00$ จะนับเป็นความถี่ในแถวตอนที่ r

จะพิจารณาตัวแปร Y_k ในทำนองเดียวกันดังนี้

ถ้า $0 \leq Y_k < f_{.1}$ จะนับเป็นความถี่ในแถวตั้งที่หนึ่ง

ถ้า $f_{.1} \leq Y_k < f_{.1} + f_{.2}$ จะนับเป็นความถี่ในแถวตั้งที่สอง

⋮

ถ้า $f_{.1} + f_{.2} + \dots + f_{.(c-1).} \leq Y_k < 1.00$ จะนับเป็นความถี่ในแถวตั้งที่ c

ดังนั้น เมื่อพิจารณาข้อมูลพหุนามล่องตัวแปร (X_k, Y_k) ถ้า X_k อยู่ในช่องตามแถวตอนที่ i และ Y_k อยู่ในแถวตั้งที่ j จะนับเป็นความถี่ในช่อง (i, j) นั้น และจะกระทำซ้ำตั้งแต่ $k = 1$ ถึง n ซึ่งจะได้ความถี่สะสมคือ O_{ij}

O_{ij} หมายถึง จำนวนความถี่ของข้อมูลพหุนามสองตัวแปรที่ผลิตขึ้นและตกในช่อง (i, j) ที่ได้จากการจำลองแบบ

3. เมื่อนับจำนวนความถี่บรรจุในตารางการถักรวนครบตามขนาดตัวอย่างที่กำหนด จากนั้นจะคำนวณจำนวนความถี่คาดหวัง (Expected frequency) ภายใต้สมมติฐานว่าง ดังนี้

$$E_{ij} = \frac{O_{i.} \times O_{.j}}{n}$$

E_{ij} หมายถึง ความถี่คาดหวังในช่อง (i, j)

เมื่อ $O_{i.}$ หมายถึง จำนวนความถี่รวมของทุกแถวตั้ง ในแถวอน i

$O_{.j}$ หมายถึง จำนวนความถี่รวมของทุกแถวอน ในแถวตั้ง j

n หมายถึง ขนาดตัวอย่าง

เมื่อหาจำนวนความถี่ที่คาดหวังจนครบทุกช่องในตารางการถักรวนแล้ว จะคำนวณหาค่าไคส์แควร์ได้ดังนี้

$$W = \sum_{i=1}^r \sum_{j=1}^c \frac{(O_{ij} - E_{ij})^2}{E_{ij}}$$

จากสมมติฐานว่าง W จะมีการแจกแจงแบบไคส์แควร์ มี d.f. = $(r-1)(c-1)$ เช่น จะศึกษาขนาดตาราง 4×5 โดยมีตารางแจกแจงความน่าจะเป็นร่วมดังนี้

ตารางที่ 3.2 แสดงตารางแจกแจงความน่าจะเป็นร่วม ขนาดตาราง 4×5

| | | Y | | | | | |
|---|----------|-------|-------|-------|-------|-------|----------|
| | | Y_1 | Y_2 | Y_3 | Y_4 | Y_5 | $f_{i.}$ |
| X | X_1 | .02 | .04 | .08 | .04 | .02 | .20 |
| | X_2 | .03 | .06 | .12 | .06 | .03 | .30 |
| | X_3 | .03 | .06 | .12 | .06 | .03 | .30 |
| | X_4 | .02 | .04 | .08 | .04 | .02 | .20 |
| | $f_{.j}$ | .10 | .20 | .40 | .20 | .10 | 1.00 |

ถ้าลุ่มข้อมูลเลขลุ่ม (X,Y) ขึ้นมา จะพิจารณาตัวแปร X ก่อน ดังนี้

| | | |
|-----|-----------------------|---------------------------------|
| ถ้า | $0 \leq x < .2$ | จะนับเป็นความถี่ในแถวบนที่หนึ่ง |
| ถ้า | $.2 \leq x < .5$ | จะนับเป็นความถี่ในแถวบนที่สอง |
| ถ้า | $.5 \leq x < .8$ | จะนับเป็นความถี่ในแถวบนที่สาม |
| ถ้า | $.8 \leq x \leq 1.00$ | จะนับเป็นความถี่ในแถวบนที่สี่ |

จากนั้นจะพิจารณาตัวแปร Y ดังนี้

| | | |
|-----|-----------------------|-----------------------------------|
| ถ้า | $0 \leq y < .1$ | จะนับเป็นความถี่ในแถวตั้งที่หนึ่ง |
| ถ้า | $.1 \leq y < .3$ | จะนับเป็นความถี่ในแถวตั้งที่สอง |
| ถ้า | $.3 \leq y < .7$ | จะนับเป็นความถี่ในแถวตั้งที่สาม |
| ถ้า | $.7 \leq y < .9$ | จะนับเป็นความถี่ในแถวตั้งที่สี่ |
| ถ้า | $.9 \leq y \leq 1.00$ | จะนับเป็นความถี่ในแถวตั้งที่ห้า |

เมื่อบันทึกความถี่ลงในตารางการแจกแจงตามขนาดตัวอย่างที่กำหนดแล้วจะคำนวณความถี่คาดหวังภายใต้สมมติฐานว่าง ขึ้นสุดท้ายจะคำนวณค่าไคล้แควร์ จากนั้นจะลุ่มตัวอย่างชุดใหม่จนกระทั่งครบ 300 ครั้ง แล้วคำนวณหาค่าเฉลี่ย (mean) และส่วนเบี่ยงเบนมาตรฐาน (standard deviation) ของค่าไคล้แควร์ พร้อมทั้งหาค่าสูงสุดและค่าต่ำสุดของค่าไคล้แควร์ เพื่อนำไปคำนวณหาอันตรภาคชั้น สำหรับสร้างกราฟรูบฮิสโตแกรมแสดงการแจกแจงแบบไคล้แควร์ โดยประมาณ

ในแต่ละขนาดตัวอย่าง เมื่อลุ่มข้อมูลขึ้นมาชุดหนึ่ง จะคำนวณค่าไคล้แควร์จนครบในทุกขนาดตารางที่ศึกษา จากนั้นจะกลับไปลุ่มข้อมูลชุดใหม่จนครบ 300 รอบ

3.1.2 กรณีตัวแปรทั้งสองไม่เป็นอิสระต่อกัน

ตัวแปรพหุนามสองตัวแปรจะไม่เป็นอิสระต่อกันถ้า $f_{ij} \neq f_{i.} \times f_{.j}$
 สำหรับค่าของ i, j ดังนั้น การผลิตข้อมูลพหุนามสองตัวแปร โดยทั่วไปการแจกแจงจะกำหนด
 โดยตารางแจกแจงความน่าจะเป็นร่วมดังนี้

ตารางที่ 3.3 แสดงตารางแจกแจงความน่าจะเป็นร่วม กรณีตัวแปรทั้งสองไม่เป็นอิสระต่อกัน
 ขนาดตาราง $r \times c$

| | | | | | | |
|-------|----------|----------|-------|-------|----------|-----------------|
| | | Y_1 | Y_2 | | Y_c | |
| X_1 | f_{11} | f_{12} | | | f_{1c} | $f_{1.}$ |
| X_2 | f_{21} | f_{22} | | | f_{2c} | $f_{2.}$ |
| ⋮ | | | | | | |
| ⋮ | | | | | | |
| ⋮ | | | | | | |
| ⋮ | | | | | | |
| ⋮ | | | | | | |
| X_r | f_{r1} | f_{r2} | | | f_{rc} | $f_{r.}$ |
| | $f_{.1}$ | $f_{.2}$ | | | $f_{.c}$ | 1.00 $f_{..}$ |

$$f_{i.} = \sum_{j=1}^c f_{ij}$$

$$f_{.j} = \sum_{i=1}^r f_{ij}$$

การ ผลิตข้อมูลพหุนามสองตัวแปรตามลักษณะตารางแจกแจงความน่าจะเป็นร่วม จะ ดำเนินการดังนี้

1. ผลิตข้อมูลเลขสุ่มที่มีการแจกแจงสม่ำเสมอในช่วง (0,1) โดยใช้สับรูกิน RANDU เรียกข้อมูลเลขสุ่มที่ได้ว่า RN_1, RN_2, \dots, RN_n โดยที่ n คือขนาดตัวอย่าง
2. จากตารางที่ 3.3 f_{ij} หมายถึงความน่าจะเป็นร่วมที่ตัวแปรพหุนามสองตัวแปร (X_k, Y_k) จะตกอยู่ในช่อง (i, j) เราจะพิจารณาค่าของ RN_k ($k = 1, 2, \dots, n$) ดังนี้

ถ้า $0 \leq RN_k < f_{11}$ จะนับความถี่ลงในช่อง (1,1)

ถ้า $f_{11} \leq RN_k < f_{11} + f_{12}$ จะนับความถี่ลงในช่อง (1,2)

ถ้า $f_{11} + f_{12} \leq RN_k < f_{11} + f_{12} + f_{13}$ จะนับความถี่ลงในช่อง (1,3)

ดังนั้นถ้าให้

$$I_{ij} = \text{ช่วงที่ปิดที่เปิด } [a_{i,j-1}, a_{i,j})$$

โดยที่


$$a_{1,0} = 0$$

$$a_{1,j} = \sum_{k=1}^j f_{1k} \quad (1 \leq j \leq c)$$

$$a_{i,0} = \sum_{r=1}^i f_{r.} \quad (2 \leq i \leq r)$$

$$a_{i,j} = \sum_{r=1}^i f_{r.} + \sum_{k=1}^j f_{ik} \quad (2 \leq i \leq r, 1 \leq j \leq c)$$

$$a_{r,c} = 1$$



และให้ O_{ij} หมายถึง จำนวนความถี่ของข้อมูลพหุนามสองตัวแปรที่ผลิตขึ้นและตกในช่อง (i, j) ที่ได้จากการจำลองแบบ

เราจะพิจารณาค่าของ RN_1, RN_2, \dots, RN_n ถ้า $RN_k \in I_{ij}$

เราจะนับความถี่แต่ละสัมนในช่อง (i, j) และจะกระทำซ้ำตั้งแต่ค่า $k = 1$ ถึง n ผลสุดท้ายจะได้ความถี่แต่ละสัมนคือ O_{ij}

เมื่อนับจำนวนความถี่บรรจุในตารางการแจกแจงครบตามขนาดตัวอย่างแล้ว จะหาความถี่ที่คาดหวัง (Expected frequency) ภายใต้อัลมิตฐานว่างดังนี้

$$E_{ij} = \frac{O_{i.} \times O_{.j}}{n}$$

จะคำนวณหาค่าไคส์แควร์ จาก

$$W = \sum_{i=1}^r \sum_{j=1}^c \frac{(O_{ij} - E_{ij})^2}{E_{ij}}$$

W จะมีการแจกแจงแบบไคส์แควร์ ที่มี $d.f. = (r-1)(c-1)$ เช่น จะศึกษาตารางขนาด 2×2 ซึ่งมีตารางแจกแจงความน่าจะเป็นร่วม ดังนี้

| | | | | |
|---|----------|-------|-------|----------|
| | | Y | | |
| | | Y_1 | Y_2 | $f_{i.}$ |
| X | X_1 | .1 | .4 | .5 |
| | X_2 | .4 | .1 | .5 |
| | $f_{.j}$ | .5 | .5 | 1.00 |
| | | | | $f_{..}$ |

จะพิจารณาค่าของ RN_1, \dots, RN_n ถ้า $RN_k \in I_{ij}$ จะนับความถี่แต่ละสัมนในช่อง (i, j) ดังนี้

$0 \leq RN_k < .1$ จะนับเป็นความถี่ในช่อง (1,1)

$.1 \leq RN_k < .5$ จะนับเป็นความถี่ในช่อง (1,2)

$.5 \leq RN_k < .9$ จะนับเป็นความถี่ในช่อง (2,1)

$.9 \leq RN_k \leq 1.00$ จะนับเป็นความถี่ในช่อง (2,2)

เมื่อบันทึกความถี่ลงในตารางการกระจายจนครบตามขนาดตัวอย่างที่กำหนดแล้วจะคำนวณค่าไคลแคร์ จากนั้นจะสุ่มข้อมูลชุดใหม่จนครบ 300 รอบ และคำนวณค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานพร้อมทั้งสร้างกราฟรูปฮิสโตแกรมแสดงการแจกแจงแบบไคลแคร์โดยประมาณ เช่นเดียวกับกรณีตัวแปรทั้งสองเป็นอิสระต่อกัน โดยศึกษาขนาดตาราง 2×2 และขนาดตัวอย่างเท่ากับ 50 100 และ 150

3.2 กรณีตัวแปรมีการแจกแจงแบบปกติสองตัวแปร

ในกรณีตัวแปรมีการแจกแจงแบบปกติสองตัวแปร จะศึกษาอิทธิพลของขนาดตัวอย่างขนาดตารางและการแบ่งกลุ่มข้อมูลที่มีต่อค่าทดสอบไคลแคร์และประมาณช่วงความเชื่อมั่นพร้อมทั้งค่าคาดหวังของสัมประสิทธิ์สหสัมพันธ์ ณ ค่าไคลแคร์แต่ละช่วง โดยศึกษาขนาดตัวอย่างเท่ากับ 20 30 40 50 75 และ 100 ขนาดตาราง 2×2 2×3 2×4 2×5 3×3 3×4 3×5 4×4 4×5 และ 5×5 กำหนดค่าสัมประสิทธิ์สหสัมพันธ์ตั้งแต่ 0.00 (0.02) 0.40 (0.01) 0.60 (0.02) 0.98 (หมายความว่าตั้งแต่ 0.00 ถึง 0.40 มีความกว้างของช่วงเท่ากับ 0.02 จาก 0.40 ถึง 0.60 มีความกว้างของช่วงเท่ากับ 0.01 และจาก 0.60 ถึง 0.98 มีความกว้างของช่วงเท่ากับ 0.02) รวม 60 ระดับจะดำเนินการศึกษาตามขั้นตอนดังนี้

3.2.1 การสร้างข้อมูลประชากรที่มีการแจกแจงแบบปกติสองตัวแปร จะใช้สับรูทีนแรนดอมผลิตตัวเลขสุ่มที่มีการแจกแจงแบบสม่ำเสมอในช่วง (0, 1) ก่อน โดยใช้คำสั่ง CALL RANDU (IX, IY, YFL) เช่นเดียวกับกรณีประชากรมีการแจกแจงแบบพหุนามสองตัวแปร จากนั้นจึงใช้สับรูทีนเกาส์ (Subroutine Gauss) ในการคำนวณหาตัวเลขสุ่มที่มีการแจกแจงแบบปกติ โดยใช้คำสั่ง CALL GAUSS (IX, S, AM, V) พารามิเตอร์ในวงเล็บมีความหมายดังนี้

IX คือตัวเลขลุ่มตัวแรก ซึ่งเป็นจำนวนเต็มบวกที่เป็นเลขคี่ที่น้อยกว่า 2147483648

S คือส่วนเบี่ยงเบนมาตรฐานของการแจกแจงแบบปกติ

AM คือค่าเฉลี่ยเลขคณิตของการแจกแจงแบบปกติ

V คือตัวเลขลุ่มที่มีการแจกแจงแบบปกติที่คำนวณได้

สำหรับ IX, S และ AM เป็นค่าที่ส่งมาจากโปรแกรมหลัก ส่วนผลลัพธ์คือ V จะเป็นตัวแปรลุ่มที่มีการแจกแจงแบบปกติ ที่มีค่าเฉลี่ย AM และส่วนเบี่ยงเบนมาตรฐานเท่ากับ S

ในการคำนวณหาเลขลุ่มที่มีการแจกแจงแบบปกติที่มีค่าเฉลี่ย และส่วนเบี่ยงเบนมาตรฐานตามที่กำหนด จะใช้ค่า X_i ที่ผลิตได้จากสับรูทินแรนดอม ซึ่งมีการแจกแจงแบบสม่ำเสมอ การประมาณจะใช้สูตร

$$Y = \frac{\sum_{i=1}^k X_i - \frac{K}{2}}{\frac{K}{12}}$$

เมื่อ X_i คือเลขลุ่มที่มีการแจกแจงแบบสม่ำเสมอ และ $0 < X_i < 1$

K คือจำนวนค่า X_i ที่ใช้ในการประมาณค่า Y

Y คือเลขลุ่มที่มีการแจกแจงแบบปกติ

โดยปกติแล้ว ตัวเลขลุ่ม Y จะมีค่าเข้าใกล้เลขลุ่มที่มีการแจกแจงแบบปกติ เมื่อค่าของ K ใหญ่มากคือเข้าใกล้ค่าอนันต์ (infinity) สำหรับสับรูทินเกาส์จะใช้ $K = 12$ เพื่อให้เครื่องลดเวลาในการคำนวณ (Excution) ดังนั้นจากสูตรในการคำนวณข้างต้นจะได้สูตรใหม่เป็น

$$Y = \frac{12}{\sum_{i=1}^{12} X_i} - 6.0$$

เพื่อให้เลขลุ่มที่สร้างขึ้นมาคือค่า Y มีค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานตามที่ต้องการนั้น จะใช้สูตร

$$Y' = Y * S + AM$$

โดยที่ Y' คือตัวเลขลุ่มที่มีการแจกแจงแบบปกติที่มีค่าเฉลี่ยและส่วนเบี่ยงเบน
มาตรฐานตามที่กำหนด

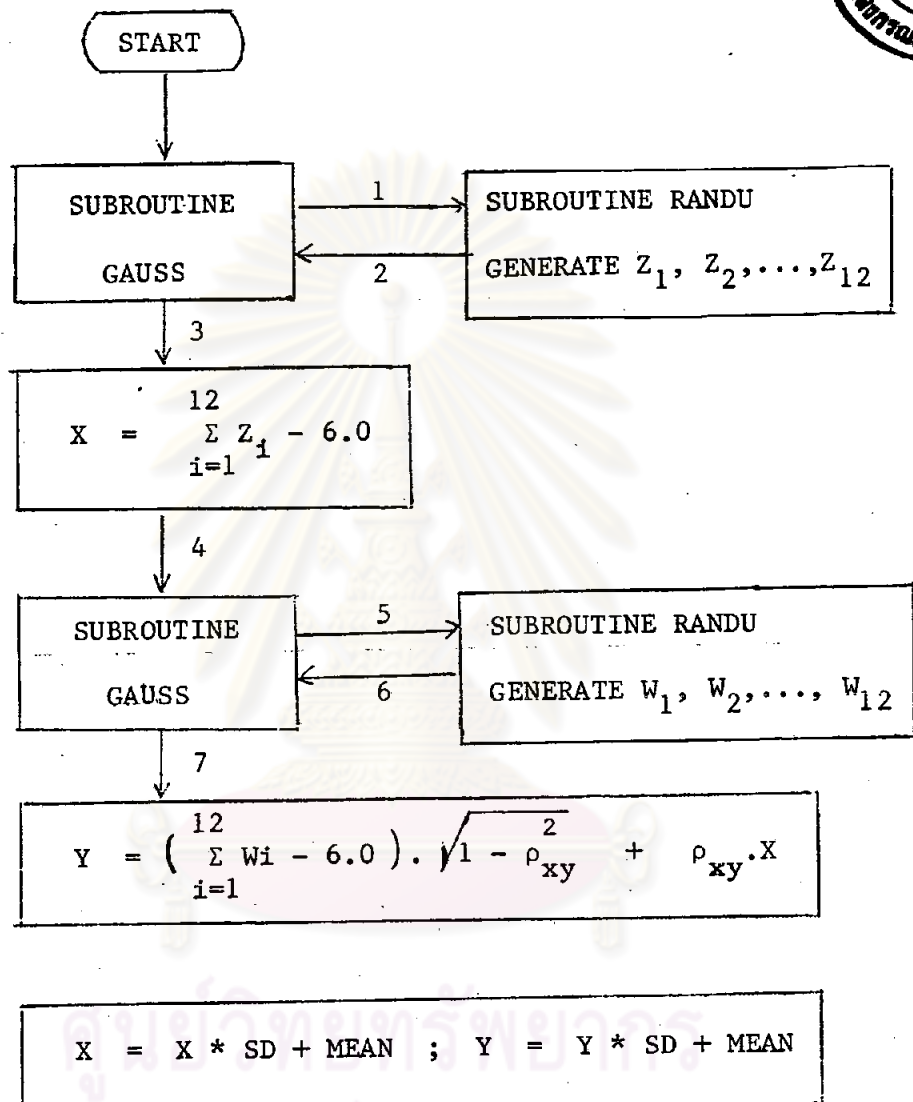
S คือส่วนเบี่ยงเบนมาตรฐานตามที่ต้องการ

AM คือค่าเฉลี่ยเลขคณิตที่กำหนด

สำหรับในการศึกษาครั้งนี้ จะต้องใช้ข้อมูลประชากรที่มีการแจกแจงแบบปกติสอง
ตัวแปร ดังนั้นต้องสร้างตัวเลขลุ่มขึ้นมาก่อนโดยอาศัยสุ่มทวินแรนดู จากนั้นจะนำมาสร้างตัวแปร
ปกติมาตรฐานโดยใช้สุ่มทวินแกวลส์ดังกล่าวมาแล้วข้างต้น และเรียกค่าที่ได้ครั้งแรกว่า X
ต่อไปจะสร้างตัวเลขลุ่มที่มีการแจกแจงแบบลุ่ม่า ล่ม่อขึ้นมาอีกชุดหนึ่งโดยใช้สุ่มทวินแรนดู แล้วจึง
นำตัวเลขลุ่มนี้มาสร้างตัวแปรปกติมาตรฐาน เรียกค่าที่ได้ชื่อว่า Y โดยค่า Y นี้ จะมีลักษณะการ
แจกแจงขึ้นอยู่กับค่า X ที่ได้จากครั้งแรก ซึ่งสรุปเป็นผังงาน (Flowchart) ได้ดังรูปที่ 3.1

ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย

รูปที่ 3.1 แสดงผังงานการสร้างข้อมูลที่มีการแจกแจงแบบปกติสองตัวแปร



3.2.2. การคำนวณค่าไคสแควร์

เมื่อสร้างข้อมูลประชากรที่มีการแจกแจงแบบปกติสองตัวแปร โดยกำหนดค่าพารามิเตอร์ คือ $\underline{\mu} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$, $\underline{\Sigma} = \begin{bmatrix} 1 & \rho \\ \rho & 1 \end{bmatrix}$; $\rho = 0.1, \dots, 0.9$ โดยวิธีการจำลองแบบด้วยโปรแกรมคอมพิวเตอร์ ซึ่งตัวแปรที่สร้างขึ้นคือค่า (X, Y) แล้ว จะดำเนินการสุ่มตัวอย่างตามขนาดตัวอย่างที่กำหนดแล้วปรับให้เป็นตัวแปรที่ไม่ต่อเนื่องเสียก่อน โดยการสุ่มข้อมูลให้สอดคล้องกับขนาดของตารางการแจกแจง ซึ่งจะต้องกำหนดจุดแบ่งเพื่อเป็นเกณฑ์ในการจำแนกตัวแปร X และตัวแปร Y ที่สุ่มขึ้นมาจะตกอยู่ในแถวอนันต์ (row) แถวใดแถวหนึ่ง และแถวตั้ง (column) แถวใดแถวหนึ่ง ก็จะนับเป็นจำนวนความถี่ที่สังเกตได้ (Observed frequency) ในแถวอนันต์และแถวตั้งนั้น สำหรับการหาจุดแบ่งจะอาศัยพื้นที่ใต้โค้งปกติตามสัดส่วนในการจำแนกกลุ่มดังตารางที่ 3.1

ตารางที่ 3.4 แสดงค่าสัดส่วนพร้อมทั้งจุดแบ่งในแต่ละระดับ

| จำนวนระดับ | สัดส่วนแต่ละระดับ | จุดแบ่ง (z) |
|------------|--------------------------|------------------------------|
| 2 | .50, .50 | 0.000 |
| 3 | .33, .33, .33 | -0.430, 0.430 |
| 4 | .25, .25, .25, .25 | -0.675, 0.000, 0.675 |
| 5 | .20, .20, .20, .20, .20, | -0.845, -0.225, 0.225, 0.845 |

สมมติว่ากำหนดขนาดตารางการแจกแจงชนิด 2×3 นั่นคือมีแถวอนันต์ 2 แถว และแถวตั้ง 3 แถว ถ้ากำหนดให้ตัวแปร X เป็นตัวแปรด้านแถวอนันต์ และตัวแปร Y เป็นตัวแปรด้านแถวตั้ง ดังนั้น สัดส่วนที่ความถี่ควรจะตกในแต่ละช่องของแถวอนันต์ประมาณ 50% และมีจุดแบ่งที่ 0.000 และสัดส่วนที่ความถี่ควรจะตกในแต่ละช่องของแถวตั้งประมาณ 33% มีจุดแบ่งที่ -0.430 และ 0.430 ถ้าสุ่มข้อมูล (X, Y) ขึ้นมา จะพิจารณาตัวแปร X ถ้าน้อยกว่าหรือเท่ากับ 0.000 จะตกในแถวอนันต์ที่หนึ่ง ถ้ามากกว่า 0.000 จะตกในแถวอนันต์ที่สอง ในทำนองเดียวกัน พิจารณาตัวแปร Y ถ้าน้อยกว่าหรือเท่ากับ -0.430 จะตกในแถวตั้งที่หนึ่ง ถ้าอยู่ระหว่าง -0.430 และ 0.430 จะตกในแถวตั้งที่สอง แต่ถ้ามากกว่าหรือเท่ากับ 0.430 จะตกในแถวตั้งที่สาม ดังนั้นข้อมูล (X, Y) คู่ใดจะตกในช่อง (Cell) ใด จะนับเป็นจำนวนความถี่เท่ากับหนึ่ง เมื่อจำแนกข้อมูลจนครบแล้ว จะคำนวณค่าความถี่ที่คาดหวัง (Expected frequency)

ภายใต้สมมติฐานว่าง (H_0) ถ้าความถี่ที่คาดหวังของช่วงใดช่วงหนึ่งเป็นศูนย์ จะไม่ใช่ข้อมูลชุดนี้ แต่จะกลับไปสู่ข้อมูลชุดใหม่ขึ้นมา ขั้นสุดท้ายจะคำนวณค่าไคล้แควร์ จากนั้นก็ย้อนกลับไปสู่ตัวอย่างชุดใหม่ จนกระทั่งครบ 300 ครั้ง แล้วคำนวณหาค่าเฉลี่ยเลขคณิต (mean) และส่วนเบี่ยงเบนมาตรฐาน (standard deviation) ของค่าไคล้แควร์ พร้อมทั้งหาค่าสูงสุดและค่าต่ำสุดของค่าไคล้แควร์ เพื่อนำไปหาอันตรภาคชั้น (class interval) สำหรับสร้างกราฟระหว่างความถี่กับค่าไคล้แควร์ รายละเอียดของโปรแกรมสร้างกราฟนี้อยู่ในภาคผนวก ค.

ในแต่ละขนาดตัวอย่าง จะคำนวณค่าไคล้แควร์จนครบทุก ๆ ขนาดตาราง และครบทุกระดับสัมประสิทธิ์สหสัมพันธ์ และจะเปลี่ยนขนาดตัวอย่างไปจนครบทุกรูปแบบของการศึกษา

3.2.3 การประมาณช่วงแห่งความเชื่อมั่นและค่าคาดหวังของสัมประสิทธิ์สหสัมพันธ์

เมื่อสร้างลักษณะการแจกแจงของประชากรและคำนวณค่าไคล้แควร์ได้แล้ว ขั้นต่อไปจะคำนวณหาช่วงแห่งความเชื่อมั่น (confidence interval) พร้อมทั้งค่าคาดหวัง (expected value) ของค่าสัมประสิทธิ์สหสัมพันธ์ ณ ค่าไคล้แควร์แต่ละช่วง เริ่มจากการสร้างตารางแจกแจงความถี่ (frequency distribution) ระหว่างค่าไคล้แควร์กับค่าสัมประสิทธิ์สหสัมพันธ์ โดยแบ่งค่าไคล้แควร์จากค่าต่ำสุดถึงค่าสูงสุดออกเป็นช่วง ๆ กำหนดความกว้างของช่วงในแต่ละระดับดังตารางที่ 3.5

ตารางที่ 3.5 แสดงความกว้างของช่วงในแต่ละระดับของค่าไคล้แควร์

| ค่าไคล้แควร์ | ความกว้างของช่วง |
|-----------------|------------------|
| 0.00 - 0.99 | 0.1 |
| 1.00 - 2.99 | 0.2 |
| 3.00 - 9.99 | 0.5 |
| 10.00 - 19.99 | 1.00 |
| 20.00 - 49.99 | 2.00 |
| 50.00 - 99.99 | 5.00 |
| 100.00 - 199.99 | 10.00 |

ดังนั้น จะมีจำนวนขึ้นรวมทั้งหมด 79 ขึ้น ซึ่งจะครอบคลุมค่าไคส์แควร์ทุกค่าในทุกกรณี ซึ่งจะตัดไว้ในแถวนอนของตาราง สำหรับแถวตั้งจะเป็นค่าสัมประสิทธิ์สหสัมพันธ์ จะศึกษาตั้งแต่ระดับ 0.00 (0.02) 0.40 (0.01) 0.60 (0.02) 0.98 จะมีจำนวนทั้งหมด 60 ระดับ จะใช้สัญลักษณ์แทนว่า ρ_i จากนั้นจะพิจารณาว่าค่าไคส์แควร์ที่คำนวณได้ในแต่ละระดับของสัมประสิทธิ์สหสัมพันธ์จะตกอยู่ในช่วงใดของค่าไคส์แควร์ จะนับเป็นความถี่ (frequency ใช้สัญลักษณ์ f_i) ในช่วงนั้น เมื่อได้จำนวนความถี่ลงในตารางจนครบแล้ว จากนั้นจะคำนวณหาค่าคาดหวังของค่าสัมประสิทธิ์สหสัมพันธ์ โดยคำนวณได้จากสูตร

$$E(\rho|W) = \frac{\sum f_i \rho_i}{\sum f_i}$$

ในที่นี้ ρ_i คือค่าสัมประสิทธิ์สหสัมพันธ์

$$W = \frac{1}{\sum_{l=1}^j} \frac{\sum_{k=1}^j (O_{lk} - E_{lk})^2}{E_{lk}}, \quad W \sim \chi^2$$

$E(\rho|W)$ คือค่าคาดหวังของค่าสัมประสิทธิ์สหสัมพันธ์ เมื่อกำหนดค่าไคส์แควร์ในแต่ละชั้น

$\sum f_i \rho_i$ คือผลรวมของผลคูณระหว่างความถี่กับค่าสัมประสิทธิ์สหสัมพันธ์ในแต่ละชั้นของค่าไคส์แควร์

$\sum f_i$ คือผลรวมของความถี่ทั้งหมดในแต่ละชั้นของค่าไคส์แควร์

และคำนวณส่วนเบี่ยงเบนมาตรฐานได้จากสูตรดังนี้

$$\begin{aligned} \text{Var}(\rho|W) &= E(\rho^2|W) - (E(\rho|W))^2 \\ &= \frac{\sum f_i \rho_i^2}{\sum f_i} - \left(\frac{\sum f_i \rho_i}{\sum f_i} \right)^2 \end{aligned}$$

$$\text{SD}(\rho|W) = \sqrt{\text{Var}(\rho|W)}$$

$\text{Var}(\rho|W)$ คือความแปรปรวนของค่าสัมประสิทธิ์สหสัมพันธ์ เมื่อกำหนดค่าไคส์แควร์ในแต่ละชั้น

$\text{SD}(\rho|W)$ คือส่วนเบี่ยงเบนมาตรฐานของค่าสัมประสิทธิ์สหสัมพันธ์ เมื่อกำหนดค่าไคส์แควร์ในแต่ละชั้น

$\sum_{i=1}^2 p_i^2$ คือผลรวมของผลคูณระหว่างความถี่กับค่าสัมประสิทธิ์สหสัมพันธ์
ยกกำลังสอง

เพราะฉะนั้นจะประมาณช่วงแห่งความเชื่อมั่น $(1-\alpha)$ 100 % ได้จากสูตร

$$E(\rho|w) \pm Z_{\frac{\alpha}{2}} \cdot SD(\rho|w)$$

โดย $Z_{\frac{\alpha}{2}}$ คือค่าที่ได้จากตารางพื้นที่ใต้โค้งปกติ เมื่อกำหนดระดับนัยสำคัญชนิด

2 ทางเท่ากับ α สำหรับในการวิจัยครั้งนี้จะใช้ระดับนัยสำคัญ 2 ระดับ คือ $\alpha = 0.05$

จะได้ $Z_{\frac{\alpha}{2}} = 1.96$ และ $\alpha = 0.10$ จะได้ $Z_{\frac{\alpha}{2}} = 1.645$

ดังนั้น ขีดจำกัดความเชื่อมั่น (Confidence limit) คือ

$$E(\rho|w) - Z_{\frac{\alpha}{2}} \cdot SD(\rho|w) \quad \text{เป็นขีดจำกัดล่าง (lower limit)}$$

$$E(\rho|w) + Z_{\frac{\alpha}{2}} \cdot SD(\rho|w) \quad \text{เป็นขีดจำกัดบน (upper limit)}$$

จากนั้น จะคำนวณหาความน่าจะเป็นที่ค่าสัมประสิทธิ์สหสัมพันธ์จะอยู่ระหว่างขีด
จำกัดล่าง และขีดจำกัดบนของช่วงแห่งความเชื่อมั่นจากการประมาณค่า ดังนี้

$$P(\rho_1 \leq \rho \leq \rho_2 | w) = \frac{m}{n}$$

เมื่อ ρ_1 คือขีดจำกัดล่างของช่วงแห่งความเชื่อมั่นจากการคำนวณ

ρ_2 คือขีดจำกัดบนของช่วงแห่งความเชื่อมั่นจากการคำนวณ

m คือผลรวมของความถี่ที่อยู่ระหว่าง ρ_1 และ ρ_2

n คือความถี่รวมทั้งหมดในแต่ละช่วงของค่าโคสโคแวร์

3.2.4 การวิเคราะห์ความถดถอยอย่างง่ายแบบเชิงเส้น (Simple linear regression analysis)

หลังจากประมาณช่วงแห่งความเชื่อมั่นพร้อมทั้งค่าคาดหวังของค่าสัมประสิทธิ์ในแต่ละช่วงของค่าไคล์แควร์แล้ว ขึ้นต่อไปจะพยากรณ์ค่าคาดหวังของสัมประสิทธิ์สหสัมพันธ์ ซึ่งกำหนดให้เป็นตัวแปรไม่อิสระ (dependent variable) โดยอาศัยค่าของตัวแปรอิสระ (independent variable) คือ ค่าจุดกลาง (mid point) ของค่าไคล์แควร์ในแต่ละช่วง ซึ่งสมการที่จะใช้พยากรณ์หรือประมาณค่าคาดหวังของสัมประสิทธิ์สหสัมพันธ์ เป็นดังนี้

$$E(\rho|W = w_{ij}) = a + b \cdot w_{ij}$$

โดย $E(\rho|W = w_{ij})$ คือค่าคาดหวังของสัมประสิทธิ์สหสัมพันธ์

ณ จุดกลางของค่าไคล์แควร์ (w_{ij})

a คือค่าคงที่ (constant) หรือค่าของ $E(\rho|W)$

เมื่อ $w_{ij} = 0$

b คือสัมประสิทธิ์ความถดถอย (regression coefficient) หรือค่าความชัน (slope)

การหาค่าประมาณ a, b สามารถทำได้หลายวิธี แต่ในภครศึกษาครั้งนี้ จะใช้วิธีกำลังสองน้อยที่สุด (Method of least square) โดยในแต่ละขนาดตัวอย่างและแต่ละขนาดตารางจะได้สมการความถดถอยหนึ่งสมการ จากนั้นจะหาค่าประมาณค่าคาดหวังของสัมประสิทธิ์สหสัมพันธ์ โดยแทนค่าจุดกลางในแต่ละสมการ แล้วจะนำค่าประมาณที่ได้นี้ของทุกขนาดตัวอย่าง ในแต่ละขนาดตารางมาสร้างสมการความถดถอยอีกครั้งหนึ่ง กำหนดให้ค่าประมาณค่าคาดหวังเป็นตัวแปรไม่อิสระ และขนาดตัวอย่างเป็นตัวแปรอิสระ เพื่อสามารถพยากรณ์ค่าคาดหวังของสัมประสิทธิ์สหสัมพันธ์ เมื่อกำหนดขนาดตัวอย่าง ดังสมการ

$$E(\hat{\rho}|W = w_{ij}) = a + b \cdot n.$$

$E(\hat{\rho}|W = w_{ij})$ คือ ค่าประมาณค่าคาดหวังของสัมประสิทธิ์สหสัมพันธ์

ในแต่ละค่าจุดกลางของค่าไคล์แควร์

a คือค่าของ $E(\hat{\rho}|W)$ เมื่อกำหนด $n = 0$

b คือสัมประสิทธิ์ความถดถอย หรือค่าความชัน (slope)

n คือขนาดตัวอย่าง

การหาค่าประมาณ a , b จะใช้วิธีกำลังสองน้อยที่สุดเช่นเดียวกัน ซึ่งในแต่
ละขนาดตารางจะได้สมการความถดถอย \hat{y} ค่าจุดกลางของค่าโกล์แควรีในแต่ละช่วง



ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย