



### 1.1 ความเป็นมาของปัญหา

การวิเคราะห์ความสัมพันธ์ (Correlation Analysis) เป็นการศึกษาเกี่ยวกับความสัมพันธ์ระหว่างตัวแปรว่ามีความสัมพันธ์กันขนาดไหน หรือเป็นการศึกษาถึงระดับของความสัมพันธ์ของตัวแปรนั่นเอง ซึ่งมาตรวัดความสัมพันธ์ระหว่างตัวแปรซึ่งเรียกว่า สัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) มีอยู่หลายแบบ ซึ่งขึ้นอยู่กับลักษณะของตัวแปรว่าจะเป็นแบบใด โดยทั่วไปแบ่งประเภทของตัวแปรเป็น 4 แบบคือ แบบอัตราส่วน (ratio scale) แบบช่วง (interval scale) แบบลำดับ (ordinal scale) และแบบแบ่งกลุ่ม (nominal scale) ในกรณีที่ตัวแปรเป็นแบบอัตราส่วน หรือแบบช่วง สัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปรสองตัวที่รู้จักกันดีที่สุดคือ สัมประสิทธิ์สหสัมพันธ์เชิงเส้นแบบ Pearson (Pearson Product Moment Correlation Coefficient) ที่ใช้สัญลักษณ์  $\rho$  ซึ่งสามารถคำนวณหาได้โดย

$$\rho = E\left[\frac{(X-\mu_X)}{\sigma_X} \frac{(Y-\mu_Y)}{\sigma_Y}\right]$$

$$= \frac{N\sum XY - (\sum X)(\sum Y)}{\sqrt{\{N\sum X^2 - (\sum X)^2\}\{N\sum Y^2 - (\sum Y)^2\}}}$$

โดยมีตัวประมาณค่าของ  $\rho$  คือ  $r$  ซึ่งคำนวณหาได้จาก

$$r = \frac{1}{n-1} E\left[\frac{(X-\bar{X})}{S_X} \frac{(Y-\bar{Y})}{S_Y}\right]$$

$$= \frac{n\sum XY - (\sum X)(\sum Y)}{\sqrt{\{n\sum X^2 - (\sum X)^2\}\{n\sum Y^2 - (\sum Y)^2\}}}$$

เมื่อ $\rho$	คือสัมประสิทธิ์สหสัมพันธ์ของประชากรระหว่างตัวแปร X และ Y
$r$	คือสัมประสิทธิ์สหสัมพันธ์ของตัวอย่างระหว่างตัวแปร X และ Y
$\Sigma X$	คือผลรวมของค่าตัวแปร X
$\Sigma Y$	คือผลรวมของค่าตัวแปร Y
$\Sigma XY$	คือผลรวมของผลคูณระหว่างค่าตัวแปร X และตัวแปร Y
$\Sigma X^2$	คือผลรวมของกำลังสองของค่าตัวแปร X
$\Sigma Y^2$	คือผลรวมของกำลังสองของค่าตัวแปร Y
N	คือจำนวนคู่ของค่าตัวแปร X และ Y
n	คือจำนวนคู่ของค่าตัวแปร X และ Y จากตัวอย่าง
$\sigma_X$	คือส่วนเบี่ยงเบนมาตรฐานของประชากรของตัวแปร X
$\sigma_Y$	คือส่วนเบี่ยงเบนมาตรฐานของประชากรของตัวแปร Y
$S_X$	คือส่วนเบี่ยงเบนมาตรฐานจากตัวอย่างของตัวแปร X
$S_Y$	คือส่วนเบี่ยงเบนมาตรฐานจากตัวอย่างของตัวแปร Y

โดยค่าของ  $\rho$  และ  $r$  เป็นไปได้ตั้งแต่ -1 ถึง 1 ซึ่งถ้าค่าคำนวณเป็นลบ แสดงว่าตัวแปรทั้งสองมีความสัมพันธ์กันในทิศทางตรงกันข้าม นั่นคือถ้าตัวแปรหนึ่งมีค่ามาก อีกตัวหนึ่งจะมีค่าน้อย แต่ถ้าค่าคำนวณเป็นบวก แสดงว่าตัวแปรทั้งสองมีความสัมพันธ์เชิงเส้นในทิศทางเดียวกัน นั่นคือถ้าตัวแปรตัวหนึ่งมีค่ามาก (หรือน้อย) อีกตัวหนึ่งจะมีค่ามาก (หรือน้อย) เช่นเดียวกัน ในกรณีที่ค่าคำนวณเท่ากับ  $\pm 1$  แสดงว่าตัวแปรทั้งสองมีความสัมพันธ์เชิงเส้นกันมาก หรือมีความสัมพันธ์กันอย่างสมบูรณ์ (Perfect Correlation) แต่ถ้าค่าคำนวณเท่ากับศูนย์ แสดงว่าตัวแปรทั้งสองไม่มีความสัมพันธ์ (Uncorrelation) เชิงเส้น

ส่วนในการวิจัยทางสังคมศาสตร์ส่วนมากแล้ว ข้อมูลที่เก็บรวบรวมมาวิเคราะห์มักจะอยู่ในรูปของข้อมูลแบบแบ่งกลุ่ม หรือข้อมูลเชิงคุณภาพ (Qualitative data) ซึ่งสามารถนำมาจำแนกให้อยู่ในรูปตารางการถ้อย (Contingency table) ได้ ค่าที่ปรากฏในตารางการถ้อยจะเป็นความถี่ของค่าสังเกตที่เก็บรวบรวมมาได้ ซึ่งเรียกว่าข้อมูลจำนวนนับ (Counted data) หรือข้อมูลจำแนกประเภท (Categorical data) ข้อมูลประเภทนี้ส่วนมากการวิเคราะห์จะใช้การทดสอบแบบไคสแควร์ (Chi-square test) โดยมีตัวสถิติทดสอบไคสแควร์ ( $\chi^2$ ) ซึ่งมีสูตรคำนวณดังนี้

$$\chi^2 = \sum_i \sum_j \frac{(O_{ij} - E_{ij})^2}{E_{ij}}$$

เมื่อ  $O_{ij}$  คือความถี่ของค่าสังเกตในแถวที่  $i$  และสัตมภ์ที่  $j$

$E_{ij}$  คือความถี่คาดหวังของค่าสังเกตในแถวที่  $i$  และสัตมภ์ที่  $j$  โดย

$$E_{ij} = \frac{R \cdot C}{T}$$

$R$  คือผลรวมของความถี่ของตัวแปรในแถวที่  $i$

$C$  คือผลรวมของความถี่ของตัวแปรในสัตมภ์ที่  $j$

$T$  คือผลรวมของความถี่ทั้งหมด

$r$  คือจำนวนแถวของตารางแจกแจง

$c$  คือจำนวนสัตมภ์ของตารางแจกแจง

ตัวสถิติไคสแควร์นี้ จะใช้สำหรับทดสอบว่าตัวแปรทางด้านแถวและตัวแปรทางด้านสัตมภ์ เป็นอิสระต่อกันหรือไม่ ถ้าผลการทดสอบปรากฏว่าตัวแปรทางด้านแถว และตัวแปรทางด้านสัตมภ์ เป็นอิสระต่อกัน แสดงว่าตัวแปรทั้งสองไม่มีความสัมพันธ์กัน แต่ถ้าผลการทดสอบปรากฏว่าตัวแปรทางด้านแถว และตัวแปรทางด้านสัตมภ์ไม่เป็นอิสระต่อกัน แสดงว่าตัวแปรทั้งสองมีความสัมพันธ์กัน หรือตัวแปรด้านหนึ่งสามารถอธิบายตัวแปรอีกด้านหนึ่งได้ แต่ในการทดสอบความเป็นอิสระกันของ ข้อมูลนั้น ค่าไคสแควร์ที่คำนวณได้เพียงแต่เป็นตัวทดสอบว่าตัวแปรด้านแถวและด้านสัตมภ์ มีความสัมพันธ์กันหรือไม่เท่านั้น เพราะค่าของไคสแควร์ที่ใช้ในการทดสอบนั้นไม่ได้เป็นตัวชี้ว่า ถ้าค่าไคสแควร์มากตัวแปรทั้งสองจะต้องมีความสัมพันธ์กันมาก หรือถ้าค่าไคสแควร์น้อย ก็สรุปไม่ได้เช่นเดียวกันว่าตัวแปรทั้งสองจะต้องมีความสัมพันธ์กันน้อยตามไปด้วย เพราะได้มีการพิสูจน์แล้วว่าถ้าความถี่ของข้อมูลเพิ่มขึ้นเป็นสัดส่วนเท่า ๆ กันแล้ว ค่าของไคสแควร์ที่คำนวณได้ก็จะเพิ่มขึ้นเท่ากับจำนวนเท่าของสัดส่วนที่เพิ่มขึ้นนั้น<sup>1</sup> ดังนั้นการที่จะนำค่าไคสแควร์มาเป็นตัวบอกความสัมพันธ์ของตัวแปรทั้งสองจึงยังไม่ถูกต้องนัก จึงได้มีนักสถิติหลายท่านได้คิดค้นตัวสถิติที่จะใช้วัดความสัมพันธ์ของข้อมูลที่อยู่ในรูปแบบแบ่งกลุ่ม ดังนี้

<sup>1</sup>Hubert M. Blalock, JR "Social Statistics" p. 300-301.

1.1.1 สัมประสิทธิ์ฟาย (Phi-coefficient) เขียนแทนด้วยสัญลักษณ์  $\phi$  เมื่อ

$$\phi = \sqrt{\chi^2/n}$$

โดย  $\phi$  คือสัมประสิทธิ์ที่ใช้วัดความสัมพันธ์ระหว่างตัวแปรทั้งสอง

$\chi^2$  คือค่าสถิติทดสอบไคสแควร์ที่ใช้ทดสอบความเป็นอิสระระหว่างตัวแปร  
ตัวแปร 2 ตัว

$n$  คือจำนวนข้อมูลทั้งหมด

1.1.2 สัมประสิทธิ์เจอนโซของเพียร์สัน (Pearson's Contingency Coefficient)

เขียนแทนด้วยสัญลักษณ์ C เมื่อ

$$C = \sqrt{\frac{\chi^2}{\chi^2+n}}$$

โดย C คือสัมประสิทธิ์ที่ใช้วัดความสัมพันธ์ระหว่างตัวแปร

1.1.3 สัมประสิทธิ์เจอนโซของชูโพร (Tschuprow's Contingency Coefficient)

เขียนแทนด้วยสัญลักษณ์ T เมื่อ

$$T = \sqrt{\frac{\chi^2/n}{(r-1)(c-1)}}$$

โดย T คือสัมประสิทธิ์ที่ใช้วัดความสัมพันธ์ระหว่างตัวแปรทั้งสอง

$r$  คือจำนวนแถวของตารางการแจกแจง

$c$  คือจำนวนลําดับของตารางการแจกแจง

1.1.4 สัมประสิทธิ์เจอนโซของคราเมอร์ (Cramer's Contingency Coefficient)

เขียนแทนด้วยสัญลักษณ์ V เมื่อ

$$V = \sqrt{\frac{\chi^2}{n \min\{r-1, c-1\}}}$$

โดย V คือสัมประสิทธิ์ที่ใช้วัดความสัมพันธ์ระหว่างตัวแปรทั้งสอง

1.1.5 สัมประสิทธิ์การทํานายของกัทแมน (Guttman's coefficient of Optimal

Predictability) เขียนแทนด้วยสัญลักษณ์  $\lambda$  เมื่อ

$$\lambda = \frac{(\sum f_r + \sum f_c) - (F_r + F_c)}{2n - (F_r + F_c)}$$

โดย  $\lambda$  คือสัมประสิทธิ์ที่ใช้วัดความสัมพันธ์ระหว่างตัวแปรทั้งสอง

$f_r$  คือความถี่สูงสุดที่พบในแต่ละแถวของตารางการแจกแจง

$f_c$  คือความถี่สูงสุดที่พบในแต่ละสัตมภ์ของตารางการแจกแจง

$F_r$  คือความถี่สูงสุดที่พบในยอดรวมของแต่ละแถวในตารางการแจกแจง

$F_c$  คือความถี่สูงสุดที่พบในยอดรวมของแต่ละสัตมภ์ในตารางการแจกแจง

#### 1.1.6 สัมประสิทธิ์แบบกูดแมนและครัสคัล (Goodman and Kruskal's Tau)

เขียนแทนด้วยสัญลักษณ์  $\tau$  เมื่อ

$$\tau = \frac{\{\sum_{ij} f_{ij}^2 / f_{.j} - \sum f_{i.}^2 / n\} + \{\sum_{ij} f_{ij}^2 / f_{i.} - \sum f_{.j}^2 / n\}}{2n - \{\sum f_{i.}^2 / n + \sum f_{.j}^2 / n\}}$$

โดย  $\tau$  คือสัมประสิทธิ์ที่ใช้วัดความสัมพันธ์ระหว่างตัวแปรทั้งสอง

$f_{ij}$  คือความถี่ของข้อมูลในแถวที่  $i$  และสัตมภ์ที่  $j$

$f_{.j}$  คือผลรวมของความถี่ของข้อมูลในสัตมภ์ที่  $j$

$f_{i.}$  คือผลรวมของความถี่ของข้อมูลในแถวที่  $i$

$n$  คือจำนวนข้อมูลทั้งหมด

ดังนั้นเมื่อมีตัวสถิติที่จะใช้วัดความสัมพันธ์ของข้อมูลในตารางการแจกแจงหลายตัว จึงเป็นที่น่าสนใจว่า ตัวสถิติที่ใช้วัดความสัมพันธ์ดังกล่าวข้างต้น ตัวใดจะให้ผลการทดสอบที่มีความถูกต้องเชื่อถือได้มากกว่าตัวสถิติใดบ้าง และตัวสถิติแต่ละตัวนั้น เหมาะสมที่จะนำไปหาความสัมพันธ์เมื่อข้อมูลมีลักษณะใด

## 1.2 วัตถุประสงค์ของการวิจัย

เพื่อเปรียบเทียบความถูกต้อง เชื่อมต่อได้ของตัวสถิติที่ใช้วัดความสัมพันธ์ระหว่างตัวแปรแบบกลุ่ม 2 ตัว 6 ชนิด คือ สัมประสิทธิ์ห่าย สัมประสิทธิ์เงื่อนไขของเพียร์สัน สัมประสิทธิ์เงื่อนไขของยูโพร สัมประสิทธิ์เงื่อนไขของคราเมอร์ สัมประสิทธิ์การทํานายของกัทแมน และสัมประสิทธิ์แบบกุดแมนและครัลส์ล

## 1.3 สมมติฐานของการวิจัย

ตัวสถิติที่ใช้วัดความสัมพันธ์ระหว่างตัวแปรแบบแบ่งกลุ่ม 2 ตัวทั้ง 6 ชนิด ให้ผลแตกต่างกัน โดยคาดว่าตัวสถิติคราเมอร์น่าจะใช้วัดได้ดีที่สุด

## 1.4 ขอบเขตของการวิจัย

1.4.1 ศึกษาเฉพาะกรณีข้อมูลมีการแจกแจงแบบปกติสองตัวแปร (Bivariate normal distribution)

1.4.2 ขนาดตัวอย่างที่ใช้ในการวิเคราะห์เท่ากับ 20 30 50 100 200 และ 500 และตารางการณั้จที่ใช้ในการวิเคราะห์มีขนาด 2x2 2x3 2x4 3x3 3x4 3x5 4x4 4x5 และ 5x5

1.4.3 จำลองข้อมูลในแต่ละลักษณะจำนวน 500 ครั้ง

## 1.5 ประโยชน์ที่คาดว่าจะได้รับ

เพื่อช่วยให้นักวิจัยโดยเฉพาะทางด้านสังคมศาสตร์สามารถเลือกใช้ตัวสถิติที่ใช้วัดความสัมพันธ์ระหว่างตัวแปรแบบแบ่งกลุ่ม 2 ตัว ได้อย่างเหมาะสม