

เอกสารและผลงานวิจัยที่เกี่ยวข้อง

ในบทนี้ ผู้วิจัยได้กำหนดเนื้อหาออกเป็น 6 ตอน ซึ่งในแต่ละตอนประกอบด้วยหัวข้อต่าง ๆ ดังนี้

ตอนที่ 1 สหสัมพันธ์และความถดถอย สหสัมพันธ์อย่างง่าย การวิเคราะห์การถดถอยอย่างง่าย และค่าประมาณของพารามิเตอร์ β_0 และ β

ตอนที่ 2 การวิเคราะห์สหสัมพันธ์และการถดถอยพหุคูณ และการประมาณค่าพารามิเตอร์ในการวิเคราะห์การถดถอย

ตอนที่ 3 การเลือกสมการถดถอยที่ดีที่สุด และวิธีคัดเลือกตัวแปรเพื่อการพยากรณ์

ตอนที่ 4 การซิมูเลชัน (Simulation) และการสร้างเลขสุ่ม (Random Number)

ตอนที่ 5 การแจกแจงแบบปกติหลายตัวแปร และ การแจกแจงค่าสหสัมพันธ์พหุคูณกำลังสอง

ตอนที่ 6 งานวิจัยที่เกี่ยวข้อง

ซึ่งแต่ละหัวข้อมียุทธศาสตร์ เอียดต่างๆ ดังนี้

ตอนที่ 1

สหสัมพันธ์และความถดถอย (Correlation and Regression)

การวิเคราะห์สหสัมพันธ์ (Correlation Analysis) เป็นระเบียบวิธีที่ใช้วัดความสัมพันธ์ระหว่างตัวแปรว่ามีความสัมพันธ์กันมากน้อยเพียงใดโดยไม่คำนึงถึงว่าตัวแปรใดจะเป็นตัวแปรอิสระ และตัวแปรใดจะเป็นตัวแปรตาม

ส่วนการวิเคราะห์ความถดถอย (Regression Analysis) เป็นวิธีการที่ได้ชื่อมาจาก Sir Francis Galton เมื่อปี ค.ศ.1899 ซึ่งเป็นการศึกษานเชิงเปรียบเทียบเกี่ยวกับแนวโน้มของลักษณะความสูงของบุตรหลานที่มีบิดามารดาสูงและเตี้ย ปรากฏว่าความสูงของบุตรหลานจะถดถอยเข้าหาส่วนสูงเฉลี่ยของประชากร ดังนั้นการวิเคราะห์ถดถอยจึงเป็นวิธีการที่ใช้ในการพิจารณาถึงรูปแบบที่เป็นไปได้ของความสัมพันธ์ระหว่างตัวแปร มีวัตถุประสงค์เพื่อใช้เป็นประโยชน์ในการพยากรณ์ (Predict) หรือการประมาณ (Estimate) ค่าของตัวแปรตัวหนึ่งซึ่งเรียกว่าตัวแปรตามหรือตัวแปรเกณฑ์ (Dependent Variable) โดยใช้ค่าของตัวแปร

อีกตัวหนึ่งหรืออีกชุดหนึ่งที่กำหนดค่าให้ ซึ่งเรียกว่า ตัวแปรอิสระหรือตัวแปรทำนาย (Independent Variable) เป็นตัวประมาณ

การวิเคราะห์สหสัมพันธ์และการถดถอยนี้ ถ้าเป็นการวิเคราะห์เกี่ยวกับตัวแปรเพียงสองตัว (Bivariate) เรียกว่า สหสัมพันธ์อย่างง่าย (Simple Correlation) ถ้าประกอบด้วยตัวแปรเกณฑ์ 1 ตัว และตัวแปรทำนายอีก 1 ตัว เรียกว่า การถดถอยอย่างง่าย (Simple Regression) ส่วนสหสัมพันธ์พหุคูณ (Multiple Correlation) หมายถึง การวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรมากกว่า 2 ตัวขึ้นไป แต่ถ้าในการวิเคราะห์นั้นเป็นการพยากรณ์ตัวแปรเกณฑ์ตัวหนึ่งด้วยตัวแปรทำนายมากกว่า 1 ตัวขึ้นไป เราเรียกว่า การถดถอยพหุคูณ (Multiple Regression)

สหสัมพันธ์อย่างง่าย (Simple Correlation)

สหสัมพันธ์อย่างง่าย หมายถึง ความสัมพันธ์ระหว่างตัวแปรใด ๆ 2 ตัว โดยไม่คำนึงถึงว่าตัวแปรใดเป็นตัวแปรอิสระหรือตัวแปรตาม เพราะตัวแปรทั้งสองนี้เป็นตัวแปรสุ่ม ซึ่งได้มาจากการสุ่มกลุ่มตัวอย่าง และวัดค่าของตัวแปรทั้งสองพร้อม ๆ กัน และนำค่าที่ได้มาหาความสัมพันธ์ ค่าที่ใช้วัดความสัมพันธ์นี้เรียกว่า สัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) ใช้สัญลักษณ์เป็นตัวอักษรกรีก คือ ρ (อ่านว่า โร) ถ้ามีตัวแปรเพียง 2 ตัว เรียกว่า สัมประสิทธิ์สหสัมพันธ์อย่างง่าย (Simple Correlation Coefficient) ซึ่งค่าดังกล่าวเป็นค่าที่ได้จากการเปรียบเทียบความแปรปรวนร่วม (Covariance) ระหว่างตัวแปร 2 ตัว (x, y) กับผลคูณของความเบี่ยงเบนมาตรฐาน (Standard Deviation) ของ x และ y ดังนี้

$$\rho = \rho_{xy} = \rho_{yx} = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \quad (2.1)$$

$$\rho_{xy} = \frac{\sum_{i=1}^n (X_i - \mu_x) (Y_i - \mu_y)}{\sqrt{\sum_{i=1}^n (X_i - \mu_x)^2 \sum_{i=1}^n (Y_i - \mu_y)^2}} \quad (2.2)$$

เมื่อ n คือจำนวนข้อมูลทั้งหมด และสัมประสิทธิ์สหสัมพันธ์อย่างง่าย (ρ) มีค่าอยู่ระหว่าง -1 หรือ $+1$ เป็นค่าที่ไม่มีหน่วย แต่จะบอกถึงระดับความสัมพันธ์ระหว่างตัวแปรว่ามีมากน้อยเพียงใด ในการคำนวณค่า ρ นี้จะต้องทราบข้อมูลทั้งหมดในประชากร ซึ่งในทางปฏิบัติแล้ว เราไม่อาจทราบค่าเหล่านี้ได้ จึงประมาณค่า ρ ด้วยค่าสหสัมพันธ์ (r) จากข้อมูลกลุ่มตัวอย่างดังนี้

$$\rho = \rho_{xy} = r = r_{xy} = r_{yx} \quad (2.3)$$


$$r_{xy} = \frac{\sum_{i=1}^n (X_i - \bar{X}) (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

$$r_{xy} = \frac{n \sum xy - \sum x \sum y}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}} \quad (2.4)$$


ซึ่งค่าสหสัมพันธ์ (r) นี้ อาจจะมีความสัมพันธ์ไปทางเดียวกัน หรือตรงกันข้ามก็ได้ ถ้า x และ y มีความสัมพันธ์ไปทางเดียวกันอย่างสมบูรณ์ จะให้ค่า $r = +1$ ถ้า x และ y มีความสัมพันธ์กันอย่างสมบูรณ์ แต่เป็นไปทางตรงกันข้าม จะให้ค่า $r = -1$ และถ้า x, y มีการกระจายมาก จะให้ค่า $r = 0$ ตามแผนภาพ ดังนี้




$$r = +1$$



$$r = -1$$



$$r = 0$$




$$r = 0$$

แผนภาพที่ 2 แสดงการกระจายสหสัมพันธ์ระหว่าง x และ y


การวิเคราะห์การถดถอยอย่างง่าย (Simple Regression Analysis)

ในกรณีที่มีตัวแปรเพียง 2 ตัว คือ ตัวแปรเกณฑ์ (y) และตัวแปรทำนาย (x) นั้น สามารถดูลักษณะการถดถอยของ y ที่มีต่อ x ได้จากแผนภาพการกระจาย (Scatter Diagram) ซึ่งมีลักษณะดังนี้

แผนภาพที่ 3 แสดงการถดถอยเชิงเส้นตรงของตัวแปร x และ y



ความสัมพันธ์ระหว่าง x กับ y
เป็นเส้นตรง และไปทางเดียวกัน
 x เพิ่ม y เพิ่ม
 x ลด y ลด



ความสัมพันธ์ระหว่าง x กับ y
เป็นเส้นตรง แต่เป็นไปทางตรง
กันข้าม
 x เพิ่ม y ลด
 x ลด y เพิ่ม

จากแผนภาพที่ 3 แสดงให้เห็นการถดถอยเชิงเส้นตรงอย่างง่ายของตัวแปรเกณฑ์ y ที่มีตัวแปรทำนาย x เพียงตัวเดียว ซึ่งสามารถแสดงความสัมพันธ์ในรูปของตัวแบบสมการทางคณิตศาสตร์ ดังนี้

$$Y_i = \beta_0 + \beta X_i + \epsilon_i \quad (2.5)$$

เมื่อ β_0 คือ ค่า Y-intercept คือค่าที่เส้นตรงตัดแกน Y หรือค่า y เมื่อ $x = 0$
 β ค่าความชัน (Slope) ของเส้นตรง คือค่าที่แสดงให้เห็นว่า เมื่อ x มีค่าเปลี่ยนไป 1 หน่วย y จะเปลี่ยนไปโดยเฉลี่ยเท่าไร เรียกค่านี้ว่า สัมประสิทธิ์ความถดถอย (Regression Coefficient) ซึ่งจะมีค่าเป็นบวก เมื่อ x และ y มีความสัมพันธ์ไปทางเดียวกัน

และมีค่าเป็นลบ เมื่อ x และ y มีความสัมพันธ์ไปในทางตรงกันข้าม และมีค่าเป็น 0 เมื่อการเปลี่ยนแปลงของ y ไม่ขึ้นกับการเปลี่ยนแปลงของ x

ϵ_i คือ ค่าความคลาดเคลื่อนที่มีลักษณะเป็นตัวแปรสุ่ม ซึ่งเป็นอิสระจาก x และ y ภายใต้อัตนสมมติดังนี้

1. ค่า x_i ต้องเป็นค่าที่วัดได้โดยไม่มีผลผิดพลาด และเป็นค่าที่กำหนดค่าให้คงที่
2. ϵ_i มีค่าเฉลี่ยเท่ากับ 0 หรือ $E(\epsilon_i) = 0$
3. ค่าความแปรปรวนของ ϵ_i มีค่าคงที่และเท่ากับค่าความแปรปรวนของ Y นั่นคือ $V(\epsilon_i) = V(Y_i) = \sigma^2$ และค่า σ^2 นี้จะเท่ากับ $\sigma^2_{y \cdot x}$ ซึ่งเป็นค่าความแปรปรวนของ Y เมื่อกำหนดค่าให้ X คงที่ด้วย
4. ϵ_i และ ϵ_j เป็นอิสระต่อกัน นั่นคือ $Cov(\epsilon_i, \epsilon_j) = 0$ เมื่อ $i \neq j$

Y_i หมายถึง Y ที่ได้จากหน่วยตัวอย่างซึ่งมีค่า $X = x_i$ จึงอาจเขียนค่า Y_i ในรูปของ Y/x_i ได้จากข้อสมมติข้างต้นดังนี้ Y_i จะมีค่าเฉลี่ยดังนี้

$$E(Y_i) = E(Y/x_i) = \mu_{y \cdot x_i} = \beta_0 + \beta x_i \quad (2.6)$$

$$\text{นั่นคือ } Y_i = \mu_{y \cdot x_i} + \epsilon_i$$

$$\text{ฉะนั้นค่าประมาณของ } Y_i \text{ จึงหมายถึง } \hat{Y}_i = \hat{\beta}_0 + \hat{\beta}x_i = \hat{\mu}_{y_i \cdot x_i}$$

นั่นเอง

ค่าประมาณของพารามิเตอร์ β_0 และ β

ในทางปฏิบัติผู้วิจัยจะไม่สามารถทราบค่าพารามิเตอร์ (β_0, β, σ^2) ที่แท้จริงของประชากรได้ แต่จะประมาณได้จากข้อมูลกลุ่มตัวอย่างที่ศึกษา (Y_i, x_i) จำนวน n คู่ ซึ่งจะได้อัตนสมมติของ Y_i ดังนี้

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}x_i = b_0 + bx_i = \hat{\mu}_{y_i \cdot x_i} \quad (2.7)$$

ค่า b_0 และ b นี้จะหาได้โดยวิธีกำลังสองน้อยที่สุด (Least Squares Method) ซึ่งจะกำหนดโดยการหาค่าต่ำสุดของผลรวมของความคลาดเคลื่อน (ϵ_i) ยกกำลังสอง ($\sum_{i=1}^n \epsilon_i^2$) โดยใช้อนุพันธ์เชิงส่วน (Partial Derivative) ดังนี้

$$\sum_{i=1}^n \hat{\epsilon}_i^2 = \sum_{i=1}^n (Y_i - \hat{Y})^2 = \sum_{i=1}^n (Y_i - b_0 - bX_i)^2 \quad (2.8)$$

$$\begin{aligned} \frac{\partial}{\partial b_0} \left(\sum_{i=1}^n \epsilon_i^2 \right) &= -2 \sum_{i=1}^n (Y_i - b_0 - bX_i) = 0 \\ &= -2 \sum_{i=1}^n (Y_i - b_0 - bX_i) (X_i) = 0 \end{aligned} \quad (2.9)$$

จากผลข้างต้นนี้ จะทำให้ได้ชุดสมการปกติ (Normal equations) ดังนี้

$$nb_0 + b \sum_{i=1}^n X_i = \sum_{i=1}^n Y_i \quad (2.10)$$

$$b_0 \sum_{i=1}^n X_i + b \sum_{i=1}^n X_i^2 = \sum_{i=1}^n X_i Y_i \quad (2.11)$$

ซึ่งให้ค่าประมาณของ b_0 และ b ดังนี้

$$\hat{b}_0 = b_0 = \bar{y} - b\bar{x} \quad (2.12)$$

$$\hat{b} = b = \frac{\sum_{i=1}^n (X_i - \bar{x})(Y_i - \bar{y})}{\sum_{i=1}^n (X_i - \bar{x})^2} = \frac{\sum_{i=1}^n (X_i - \bar{x}) Y_i}{\sum_{i=1}^n (X_i - \bar{x})^2} \quad (2.13)$$

ตอนที่ 2

การวิเคราะห์สหสัมพันธ์และการถดถอยพหุคูณ

(Multiple correlation and Regression analysis)

การวิเคราะห์สหสัมพันธ์และการถดถอยพหุคูณ เป็นแนวคิดและเทคนิคที่ขยายมาจาก การวิเคราะห์สหสัมพันธ์และการถดถอยอย่างง่าย (Simple Correlation and Regression) เป็นการศึกษาความสัมพันธ์ระหว่างตัวแปรตาม (Dependent Variable) และกลุ่มของตัวแปร อิสระ (Set of Independent Variables) ภายใต้รูปแบบที่กำหนด ซึ่งอาจเป็นเส้นตรง หรือเส้นโค้ง จากการวิเคราะห์การถดถอยจะได้สมการถดถอยพหุคูณ ซึ่งโดยปกติแล้วจะร่วมกันอธิบายตัวแปรเกณฑ์ได้มากกว่า เพราะในการวิเคราะห์ปัญหาบางอย่างที่จำเป็นต้องใช้การ ถดถอยนั้น บางครั้งการศึกษการถดถอยอย่างง่ายอาจจะไม่เพียงพอ ทั้งนี้เพราะการประมาณ ค่าของตัวแปรเกณฑ์เพื่อให้อก้เคียงที่สุดนั้น เรามักจะต้องพิจารณาตัวแปรพยากรณ์ที่มีอิทธิพล หรือมีความสัมพันธ์ต่อตัวแปรเกณฑ์มากกว่า 1 ตัวขึ้นไป โดยมีสมการถดถอยเป็นตัวชี้ให้เห็นถึง ความสัมพันธ์เฉลี่ยของตัวแปรเหล่านั้นดังนี้ (Lindeman 1980: 94)

$$Y_i = b_0 + b_1X_1 + b_2X_2 + \dots + b_pX_p + e_i \quad (2.14)$$

- โดยที่
- Y_i คือ ตัวแปรเกณฑ์ (Criterion variables or Dependent variable)
 - X_i คือ ตัวแปรพยากรณ์ (Predictor variable or Independent variable); $i = 1, 2, \dots, p$
 - b_0 คือ ค่าคงที่ ซึ่งจะมีค่าเท่ากับ Y เมื่อ X_i ทั้งหมดมีค่าเท่ากับศูนย์
ค่า b_0 เป็นค่าประมาณของ β_0
 - b_i คือ สัมประสิทธิ์การถดถอยของประชากรบางส่วน (Population Partial Regression Coefficient) ของ X_i เมื่อให้ $X_i = X_1 \dots X_p$ เป็นค่าคงที่ นั่นคือ เมื่อ X_i มีค่าเปลี่ยนแปลงไป 1 หน่วย จะมีผลทำให้ Y เปลี่ยนแปลงไป b_i หน่วย เมื่อ ตัวแปรพยากรณ์อื่น ๆ คงที่ และเป็นค่าประมาณของ β_i

e_i คือ ความคลาดเคลื่อนที่แสดงถึงความแตกต่างระหว่างสมการถดถอย
 กับค่าจริง มีลักษณะ เป็นตัวแปรสุ่มที่ไม่ทราบค่า และเป็นค่า
 ปรมาณของ $\epsilon_i \quad \epsilon \sim N(0, \sigma^2)$

$$E(\epsilon_i) = 0 \quad ; \quad i = 1, 2, \dots, n$$

$$E(\epsilon_i \epsilon_j) = \sigma^2 \quad ; \quad i = j$$

$$= 0 \quad ; \quad i \neq j$$

จากสมการ (2.14) สามารถแสดงในรูปของเมตริกซ์ได้ดังนี้

$$Y = X\beta + \epsilon$$

เมื่อ

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \cdot \\ \cdot \\ Y_n \end{bmatrix}_{n \times 1} \quad X = \begin{bmatrix} 1 & X_{11} & X_{12} & \dots & X_{1p} \\ 1 & X_{21} & X_{22} & \dots & X_{2p} \\ \cdot & \cdot & \cdot & & \cdot \\ \cdot & \cdot & \cdot & & \cdot \\ 1 & X_{n1} & X_{n2} & \dots & X_{np} \end{bmatrix}_{n \times (k+1)}$$

$$\beta = \begin{bmatrix} b_0 \\ b_1 \\ \cdot \\ \cdot \\ b_p \end{bmatrix}_{(k+1) \times 1} \quad \epsilon = \begin{bmatrix} e_1 \\ e_2 \\ \cdot \\ \cdot \\ e_n \end{bmatrix}_{n \times 1}$$

จากตัวแบบ (2.14) ผลรวมของความคลาดเคลื่อนกำลังสองจะมีค่าเป็น (วิธีคิด
หล่อธีระ ชุณสกกุล 2524: 124)

$$\begin{aligned} \sum_{i=1}^n e_i^2 &= \underline{\underline{E}}' \underline{\underline{E}} = (\underline{\underline{Y}} - \underline{\underline{X}}\underline{\underline{\beta}})' (\underline{\underline{Y}} - \underline{\underline{X}}\underline{\underline{\beta}}) \\ &= \underline{\underline{Y}}' \underline{\underline{Y}} - \underline{\underline{\beta}}' \underline{\underline{X}}' \underline{\underline{Y}} - \underline{\underline{Y}}' \underline{\underline{X}} \underline{\underline{\beta}} + \underline{\underline{\beta}}' \underline{\underline{X}}' \underline{\underline{X}} \underline{\underline{\beta}} \\ &= \underline{\underline{Y}}' \underline{\underline{Y}} - 2 \underline{\underline{\beta}}' \underline{\underline{X}}' \underline{\underline{Y}} + \underline{\underline{\beta}}' \underline{\underline{X}}' \underline{\underline{X}} \underline{\underline{\beta}} \end{aligned} \quad (2.15)$$

การประมาณค่าพารามิเตอร์ในการวิเคราะห์การถดถอย

(Estimation of Parameters in Multiple Regression)

เนื่องจากการวิจัยในทางปฏิบัตินั้น ผู้วิจัยจะไม่สามารถศึกษาจากกลุ่มประชากรทั้งหมดได้ จึงไม่ทราบค่าพารามิเตอร์ β ที่แท้จริง โดยทั่วไปจะประมาณค่าพารามิเตอร์ (Parameter) จากข้อมูลกลุ่มตัวอย่างที่นำมาศึกษา วิธีการประมาณตัวประมาณค่าที่นิยมใช้กันมากคือ วิธีกำลังสองน้อยที่สุด (Least Square Estimation Method) ซึ่งจะได้ค่าประมาณสัมประสิทธิ์การถดถอย พหุคูณจากการอนุพันธ์ (differentiate) สมการ (2.15) เทียบกับ β แล้วได้ค่าเท่ากับศูนย์

$$\begin{aligned} \frac{\partial(\underline{\underline{E}}'\underline{\underline{E}})}{\partial \underline{\underline{\beta}}} &= -2 \underline{\underline{X}}' \underline{\underline{Y}} + 2 \underline{\underline{X}}' \underline{\underline{X}} \underline{\underline{\beta}} = 0 \\ &\underline{\underline{X}}' \underline{\underline{X}} \underline{\underline{\beta}} = \underline{\underline{X}}' \underline{\underline{Y}} \\ \underline{\underline{\beta}} &= (\underline{\underline{X}}' \underline{\underline{X}})^{-1} \underline{\underline{X}}' \underline{\underline{Y}} \end{aligned} \quad (2.16)$$

ซึ่งจะได้ตัวประมาณค่าที่ไม่เอนเอียงของ (β) ซึ่งมีค่าเฉลี่ยความคลาดเคลื่อนกำลังสองน้อยที่สุด ในบรรดาตัวประมาณค่าที่ไม่เอนเอียงทั้งหลาย



ตอนที่ 3

การเลือกสมการถดถอยที่ดีที่สุด

การวิจัยที่ใช้วิธีการพยากรณ์ โดยพื้นฐานแล้ว นักวิจัยไม่มีจุดมุ่งหมายในการทดสอบสมมติฐานในการเปรียบเทียบว่า ตัวแปรพยากรณ์ตัวใดมีความสำคัญต่อการเปลี่ยนแปลงของตัวแปรเกณฑ์มากกว่ากัน ความสำคัญของการวิจัยประเภทนี้มักจะอยู่ที่การค้นหาตัวแปรพยากรณ์ที่สามารถพยากรณ์ตัวแปรที่สนใจได้ถูกต้องแม่นยำที่สุดเท่าที่ความรู้เกี่ยวกับตัวพยากรณ์จะมีอยู่ ดังนั้นหน้าที่สำคัญของนักวิจัยก็คือ การค้นหาสมการหรือการประมาณค่าสัมประสิทธิ์การถดถอยของตัวแปรในสมการพยากรณ์ เพื่อให้มีความคลาดเคลื่อนในการพยากรณ์ต่ำสุด

จากสมการ (2.16) ค่าสัมประสิทธิ์การถดถอยที่ได้เป็นค่าการแสดงการเปลี่ยนแปลงค่าเฉลี่ยของ Y เมื่อ X_i เปลี่ยนไป 1 หน่วย ขณะที่ตัวแปรพยากรณ์อื่น ๆ คงที่ และค่าสัมประสิทธิ์การถดถอยของคะแนนดิบ (Unstandardized Coefficient) นี้ เป็นค่าซึ่งใช้ในการประมาณค่า Y เท่านั้น ถ้าต้องการเปรียบเทียบความสำคัญของตัวแปรพยากรณ์ที่มีต่อตัวแปรเกณฑ์จะทำได้โดยการแปลงค่าสัมประสิทธิ์การถดถอยคะแนนดิบ (b_i) ให้เป็นสัมประสิทธิ์คะแนนมาตรฐาน (Standardized Coefficient)

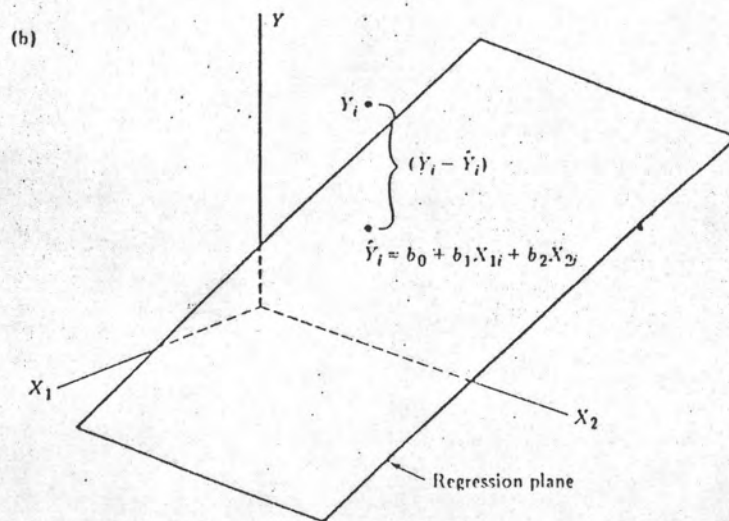

$$\text{โดย } \beta_i = b_i \frac{S_{x_i}}{S_y} \quad (2.17)$$

เมื่อ β_i = ค่าสัมประสิทธิ์คะแนนมาตรฐาน (Standardized Beta Weight)

S_{x_i} = ส่วนเบี่ยงเบนมาตรฐานของ X_i

S_y = ส่วนเบี่ยงเบนมาตรฐานของ Y

จากข้อมูลกลุ่มตัวอย่าง สามารถพิจารณาลักษณะความแปรปรวนของตัวแปรเกณฑ์ (y) จากค่าเฉลี่ย Y ได้ดังรูป (Lindeman 1980: 100)



ซึ่งแสดงกราฟและระนาบของการถดถอย จะเห็นว่าความแปรปรวนทั้งหมดประกอบด้วยความแปรปรวน 2 ส่วน ส่วนแรกคือส่วนที่ตัวแปรเกณฑ์ (Y_i) แตกต่างจากค่าประมาณที่ได้จากเส้นถดถอยหรือระนาบการถดถอย (\hat{Y}_i) เรียกว่า ความแปรปรวนที่ไม่สามารถอธิบายได้ (Unexplained variation) ส่วนที่สอง คือ ส่วนที่ตัวแปรเกณฑ์ที่ประมาณค่าได้จากการประมาณค่าจากเส้นถดถอยหรือระนาบการถดถอย (\hat{Y}_i) แตกต่างจากค่าเฉลี่ยของตัวแปรเกณฑ์ ซึ่งเรียกว่าความแปรปรวนที่สามารถอธิบายได้ (Explained variation) นั่นคือ

$$Y_i - \bar{Y} = (Y_i - \hat{Y}_i) + (\hat{Y}_i - \bar{Y}) \quad (2.18)$$

เมื่อนำ (2.18) มายกกำลังสองจะได้

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 + \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + 2 \sum_{i=1}^n (Y_i - \hat{Y}_i)(\hat{Y}_i - \bar{Y}) \quad (2.19)$$

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 + \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 \quad (2.20)$$

$$\text{ที่ SST} = \sum_{i=1}^n (Y_i - \bar{Y})^2 \quad (2.21)$$

$$\text{SSE} = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2.22)$$

$$\text{และ SSR} = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 \quad (2.23)$$

ซึ่งสามารถสรุปเป็นตารางวิเคราะห์ความแปรปรวน (Analysis of Variance) ดังตารางที่ 1

ตารางที่ 1 แสดงแหล่งความแปรปรวนในการวิเคราะห์การถดถอยพหุคูณ

แหล่งความแปรปรวน	ระดับความเป็นอิสระ	ผลบวกกำลังสอง	ผลบวกกำลังสองเฉลี่ย	F'
การถดถอย	k	$\sum B' X' Y - n\bar{Y}^2 = SSR$	$\frac{SSR}{K} = MSR$	---
ความคลาดเคลื่อน	n-k-1	$\sum Y' Y - \sum B' X' Y = SSE$	$\frac{SSE}{n-k-1} = MSE$	
ยอดรวม	n-1	$\sum Y' Y - n\bar{Y}^2 = SST$		

เราจึงสร้างสมการพยากรณ์ได้ดังนี้

$$\hat{Y} = a + b_1X_1 + b_2X_2 + \dots + b_pX_p \quad (2.24)$$

นำสัมประสิทธิ์การถดถอย b_1, b_2, \dots, b_p มาทดสอบความมีนัยสำคัญ โดยทดสอบสมมติฐาน

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0 \quad (2.25)$$

ค่าสถิติที่ใช้ในการทดสอบคือ

$$F = \frac{MSR}{MSE} \quad (2.26)$$

ดังนั้นเมื่อสร้างสมการพยากรณ์ได้แล้ว ก่อนที่จะมีการนำเอาสมการไปใช้ ต้องคำนึงถึงว่าสมการนั้นน่าเชื่อถือหรือไม่ เกณฑ์อันหนึ่งที่นิยมใช้กันมากในการตัดสินใจเกี่ยวกับการศึกษาเรื่องการถดถอยเชิงเส้นคือ สัมประสิทธิ์การทำนาย (Coefficient of Determination)

$$R^2 = \frac{SSR}{SST} \quad (2.27)$$

R^2 นี้ เรียกว่า สัมประสิทธิ์การทำนาย (Coefficient of Determination) ซึ่งจะมีค่าอยู่ระหว่าง 0 กับ 1

$R^2 \times 100$ หมายถึง ร้อยละของความแปรปรวนทั้งหมดของค่าที่สังเกตได้ (Y_i) ที่ถูกอธิบายได้โดยสมการพยากรณ์ หรืออาจกล่าวได้อีกว่า R^2 ก็คือ Goodness of Fit ของพื้นที่ผิวของระนาบการถดถอยนั่นเอง

ในการวิเคราะห์การถดถอยพหุคูณ ค่า R^2 ที่สูงขึ้นย่อมเป็นสิ่งที่ต้องการ เพราะนั่นหมายความว่า ตัวแปรพยากรณ์ (X_s) สามารถใช้พยากรณ์ตัวแปรเกณฑ์ได้ดี

วิธีคัดเลือกตัวแปรเพื่อการพยากรณ์

ในการวิเคราะห์การถดถอยพหุคูณนั้น มักจะมีตัวแปรทำนายหลายตัวที่ใช้ในการพยากรณ์ตัวแปรเกณฑ์ ปัญหาที่ผู้วิจัยต้องการคือจะ เลือกตัวแปรทำนายเพียงจำนวนหนึ่งทีน้อยที่สุดและมีประสิทธิภาพมากที่สุด เพื่อให้ตัวแบบถดถอยเชิงเส้นที่ตีหรือเหมาะสมที่สุดที่ใช้ในการพยากรณ์ วิธีคัดเลือกตัวแปรทำนายเข้าสู่สมการถดถอยมีอยู่หลายวิธีด้วยกัน แต่วิธีที่ผู้วิจัยเสนอมีอยู่ 3 วิธีคือ

1. การคัดเลือกตัวแปรแบบไปข้างหน้า (forward Selection)
2. การกำจัดตัวแปรแบบถดถอยหลัง (Backward Elimination)
(Draper and Smith 1966)
3. การถดถอยแบบขั้นบันได (Stepwise Regression)
(Efroymsen 1960)

ซึ่งทั้ง 3 วิธีนี้เป็นวิธีที่ใช้กันแพร่หลายมากในการคัดเลือกเอาตัวแปรทำนายเข้าสู่ตัวแบบถดถอยเชิงเส้น ซึ่งในแต่ละวิธีจะมีวิธีการคัดเลือกตัวแปรทำนายเป็นขั้นและมีข้อดีข้อเสียดังนี้

1. การเลือกตัวแปรแบบไปข้างหน้า (Forward Selection)
 - 1.1 พิจารณาสัมประสิทธิ์สหสัมพันธ์บางส่วนระหว่างตัวแปรเกณฑ์กับตัวแปรทำนาย แต่ละตัว (r_{xy}) เลือกตัวแปรทำนายที่ให้ค่าสัมประสิทธิ์สหสัมพันธ์บางส่วนสูงที่สุดสมมติได้ X_j สมการจะเป็น $\hat{Y} = a + b_j X_j$
 - 1.2 หาค่าสัมประสิทธิ์สหสัมพันธ์บางส่วนระหว่างตัวแปรเกณฑ์กับตัวแปรทำนายแต่ละตัวที่ยังไม่อยู่ในสมการ โดยถือว่าได้รวมตัวแปรทำนาย X_j ไว้ในสมการแล้ว นั่นคือหาค่า

$$r_{y(lj)} = \frac{r_{y1} - r_{yj} r_{1j}}{\sqrt{(1 - r_{1j}^2)}}$$

เมื่อ $l = 1, 2, \dots, j - 1, j + 1, \dots, k$

$k =$ จำนวนตัวแปรทำนายทั้งหมดที่จะพิจารณา

- 1.3 เลือกค่าสัมประสิทธิ์สหสัมพันธ์บางส่วนที่สูงที่สุด สมมติให้ $r_{y(1j)}$

จึงรวบรวม X_1 ไว้ในสมการเป็นตัวแปรใหม่

1.4 พิจารณา partial F ของตัวแปรทำนายใหม่ X_1 ในข้อ 1.3 ถ้ามีค่าสูงกว่า $F_{\alpha}(1, n-m-1)$ แสดงว่าเป็นการสมควรที่จะรวม X_1 ไว้ในสมการ ในที่นี้ m คือจำนวนตัวแปรทำนายในสมการใหม่ และ n คือจำนวนค่าสังเกต (observation)

1.5 ทำตามข้อ 1.2, 1.3 และ 1.4 อีก โดยถือว่าสมการได้รวมตัวแปรทำนายไว้แล้ว 2 ตัว 3 ตัว ฯลฯ ตามลำดับ จน partial F ที่ได้จากตัวแปรทำนายมีค่าน้อยกว่า $F_{\alpha}(1, n-m-1)$ ตัวแปรทำนายใหม่จึงไม่ควรรวมอยู่ในสมการ ซึ่งแสดงว่าได้สมการที่เหมาะสมที่สุดแล้ว

ในกรณีที่รวมตัวแปรทำนายไว้แล้ว 2 ตัว สมมติเป็นตัวที่ 1 และ 2 จะหาสัมประสิทธิ์สหสัมพันธ์บางส่วนของ Y และตัวแปรทำนายตัวที่ 3 ได้ดังนี้

$$r_{y(3.12)} = \frac{r_{y(3.1)} - r_{y(2.1)} r_{3(2.1)}}{\sqrt{(1-r_{3(2.1)}^2)}} \quad (2.29)$$

และในกรณีที่รวมตัวแปรทำนายไว้แล้ว 3 ตัว สัมประสิทธิ์สหสัมพันธ์บางส่วนของ Y และตัวแปรทำนายตัวที่ 4 คือ

$$r_{y(4.123)} = \frac{r_{y(4.12)} - r_{y(3.12)} r_{4(3.12)}}{\sqrt{(1-r_{4(3.12)}^2)}} \quad (2.30)$$

วิธีนี้ดีกว่าวิธีการกำจัดตัวแปรแบบถอยหลังในแง่ของการประหยัดเวลาในการคำนวณ โดยที่ไม่ต้องพิจารณาตัวแปรทำนายทั้งหมดโดยไม่จำเป็น แต่มีข้อเสียตรงที่ไม่ได้มีการพิจารณาบทบาทของตัวแปรทำนายที่รวมอยู่ในสมการในขั้นก่อน เมื่อมีตัวแปรทำนายตัวใหม่เข้าไปอยู่ในสมการ บทบาทในที่นี้หมายถึง ความสามารถในการพยากรณ์ตัวแปรเกณฑ์ ซึ่งอาจจะเปลี่ยนแปลงได้ในแต่ละขั้น เนื่องจากความสัมพันธ์ระหว่างตัวแปรทำนายที่เข้าไปใหม่กับตัวแปรทำนายที่มีอยู่เดิมในสมการ ซึ่งอาจทำให้ไม่ได้สมการที่เหมาะสมที่สุด

2. การกำจัดตัวแปรแบบถอยหลัง (Backward Elimination)

2.1 ตั้งสมการที่รวมตัวแปรทำนายที่ควรพิจารณาทั้งหมด สมมติมี K ตัวสมการจะเป็นดังนี้

$$\hat{Y} = a + b_1 X_1 + b_2 X_2 + \dots + b_k X_k$$

2.2 คำนวน partial F ของตัวแปรทำนายแต่ละตัว ในจำนวน partial F นี้ ตัวเลือกที่น้อยที่สุด สมมติได้ F_j แล้วนำ F_j เปรียบเทียบกับค่า F จากตารางคือ $F_{\alpha}(1, n-k-1)$ ถ้า F_j น้อยกว่า F จากตารางให้กำจัดตัวแปรทำนาย X_j ออกจากสมการ

2.3 ตั้งสมการใหม่โดยไม่รวม X_j ในสมการ แล้วทำตามข้อ 2.2 อีก โดยที่ค่า K จะเปลี่ยนเป็น $K-1$ ทำเช่นนี้จนจนที่ partial F ทุก ๆ ตัว มีค่ามากกว่า F ที่กำหนดจากตาราง

วิธีนี้ดีในแง่ที่ได้พิจารณาตัวแปรทำนายทุกตัวในตอนเริ่มแรก อย่างไรก็ตามยังเสียเวลาในการคำนวณมาก และสำคัญคือไม่ได้นำตัวแปรทำนายเดิมที่ออกจากสมการแล้วกลับมาพิจารณาอีก เมื่อตัดตัวแปรทำนายใหม่ออกจากสมการ

3. การถดถอยแบบขั้นบันได (Stepwise Regression)

วิธีนี้คล้ายกับวิธีการเลือกตัวแปรแบบไปข้างหน้า แตกต่างกันตรงที่ในแต่ละขั้นที่มีการเพิ่มตัวแปรเข้าไปในสมการทีละตัวจะมีการคำนวณ partial F ของตัวแปรทำนายอื่น ๆ ที่มีอยู่ในสมการเดิม โดยที่ถือว่าตัวแปรทำนายนั้น ๆ เข้าไปอยู่ในสมการที่รวมตัวแปรใหม่ด้วยเป็นตัวสุดท้าย การที่ต้องตรวจสอบค่า partial F ของตัวแปรทำนายที่มีอยู่เดิม นั้น เนื่องจากความจริงที่ว่าตัวแปรทำนายเดิมนั้นอาจจะไม่เหมาะสมที่จะอยู่ในสมการใหม่ เพราะตัวแปรเดิมอาจมีความสัมพันธ์กับตัวแปรใหม่ ซึ่งการเลือกตัวแปรแบบไปข้างหน้าไม่ได้ตรวจสอบในเรื่องนี้นั้นคือ เมื่อรวมตัวแปรทำนายใดไว้ในสมการแล้วจะไม่กำจัดออกในขั้นต่อไป และการกำจัดตัวแปรแบบถดถอยหลังก็เช่นเดียวกัน คือจะไม่นำตัวแปรทำนายที่เอาออกไปแล้วกลับเข้ามาพิจารณาอีก

การถดถอยแบบขั้นบันไดทำได้ดังนี้

3.1 พิจารณาสัมประสิทธิ์สหสัมพันธ์บางส่วนระหว่างตัวแปรเกณฑ์กับตัวแปรทำนายแต่ละตัว (r_{xy}) เลือกตัวแปรทำนายที่ให้ค่าสัมประสิทธิ์สหสัมพันธ์บางส่วนสูงสุด สมมติให้ X_j สมการจะเป็น $\hat{Y} = a + b_j X_j$

3.2 หาค่าสัมประสิทธิ์สหสัมพันธ์บางส่วนระหว่างตัวแปรเกณฑ์กับตัวแปรทำนายแต่ละตัวที่ยังไม่อยู่ในสมการ โดยถือว่าได้รวมตัวแปรทำนาย X_j ไว้ในสมการแล้ว และเลือกตัวแปรทำนายที่ให้ค่าสัมประสิทธิ์สหสัมพันธ์บางส่วนสูงสุด สมมติให้ X_1 สมการจะเป็น

$$\hat{Y} = a + b_j X_j + b_1 X_1$$

3.3 พิจารณา partial F ของทั้ง X_1 และ X_j ถ้ามีค่ามากกว่า $F_{\infty}(1, n-3)$ ทั้ง 2 ตัวก็รวม X_1 และ X_j ไว้ในสมการ

3.4 ทำตามข้อ 3.2 และ 3.3 โดยที่จะมีตัวแปรทำนายรวมอยู่ในสมการแล้ว 2 ตัว 3 ตัว ฯลฯ ตามลำดับ ในแต่ละขั้นต้องพิจารณาค่า partial F ของตัวแปรทำนายทุกตัว ถ้าตัวใดมีค่าน้อยกว่า $F_{\infty}(1, n-m-1)$ ก็จะตัดตัวแปรทำนายนั้นออกจากสมการ ทำเช่นนี้จนไม่มีตัวแปรต้นตัวใดที่จะรวมในสมการจะไม่มีตัวใดที่จะถูกตัดออกจากสมการ (วิชิต หล่อจิระสุนท์กุล 2524)

ตอนที่ 4

ซิมูเลชัน (Simulation)

ซิมูเลชัน (Simulation) คือ ขบวนการที่จัดสร้างระบบจำลองขึ้นมาแทนระบบจริง แล้วนำเอาระบบจำลองที่สร้างขึ้นมานี้ไปทำการทดลอง ซึ่งจุดมุ่งหมายของการทำซิมูเลชัน ก็คือ

1. เพื่อศึกษาพฤติกรรมของระบบจริง เพื่อจะได้นำมาใช้ในการพยากรณ์พฤติกรรมของระบบจริงว่าในอนาคตจะเป็นอย่างไร
2. เพื่อประเมินผลหรือเพื่อควบคุมระบบจริง

รูปแบบของระบบจำลองมีอยู่ 2 ชนิด คือ

1. Continuous Model คือ รูปแบบจำลองที่มีการเปลี่ยนไปตามเงื่อนไขของเวลา
2. Discrete models คือ รูปแบบจำลองที่ให้กฎเกณฑ์เกี่ยวกับการเปลี่ยนแปลงของสถานภาพของรูปแบบในช่วงเวลาที่กำหนด ซึ่งการเปลี่ยนแปลงสถานภาพของรูปแบบนี้เป็นไปได้ 2 ลักษณะ คือ Deterministic และ Probabilistic การเปลี่ยนแปลงในลักษณะ Deterministic เป็นการเปลี่ยนแปลงตามกฎเกณฑ์ที่กำหนดขึ้นมา แต่การเปลี่ยนแปลงในลักษณะ Probabilistic เป็นการเปลี่ยนแปลงที่เกิดขึ้นตามโอกาส (chance)

การสร้างตัวเลขสุ่ม (Random Number)

จากการซิมูเลชัน (Simulation) ในรูปแบบจำลองที่เรียกว่า probabilistic หรือ Stochastic ซึ่งเป็นการจำลองที่มีการเปลี่ยนแปลงตามโอกาส (chance) คือ มีโอกาสที่จะเปลี่ยนแปลงไปในรูปแบบต่าง ๆ ได้หลายอย่าง ทำให้พยากรณ์ล่วงหน้าได้ยาก มีลักษณะเหมือนการเล่นเกมส์หรือการพนัน การจำลองข้อมูลที่มีลักษณะ ไม่นั่นอนเช่นนี้ ทำได้โดยการสร้างตัวเลขขึ้นมา ซึ่งเรียกวิธีการเช่นนี้ว่า การสร้างเลขสุ่ม (Random Number)

การสร้างเลขสุ่ม (Random Number) นี้แจกแจงได้หลายลักษณะ แต่ละลักษณะทำได้หลายวิธี ซึ่งผู้วิจัยเสนอเฉพาะวิธีที่ใช้ในการทำวิจัยครั้งนี้เท่านั้น ดังนี้

1. การสร้างเลขสุ่มให้มีการแจกแจงอย่างสม่ำเสมอ (Uniformly Distributed Random Numbers) ซึ่งมีค่าเฉลี่ยเท่ากับ 0 ความแปรปรวนเท่ากับ 1 ซึ่งมีสูตรดังนี้

$$n_{i+1} = (an+c) \pmod{M}$$

$$r = n/m$$

r คือ เลขสุ่ม (Random Number) ที่ต้องการ

n คือ เลขจำนวนเต็ม ที่ใช้เป็นค่าเริ่มต้น (หรือเรียกว่า Seed)

m คือ เลขจำนวนเต็ม มีค่า 2^{31} หรือ 2^{33}

a คือ เลขจำนวนเต็ม ที่มีค่าไม่แน่นอน แต่ละสูตรมีค่าไม่เท่ากัน

c คือ เลขจำนวนเต็ม แต่ละสูตรมีค่าไม่เท่ากัน

วิธีที่ใช้ในการวิจัยครั้งนี้คือวิธี Prime Modulus Multiplicative ซึ่งมีสูตรดังนี้

$$R_{i+1} = (aR_i + c) \pmod{M}$$

$$M = 2147483647 \text{ หรือ } 2^{31}-1$$

$$a = 16807 \text{ หรือ } 7^5$$

$$R_i = 973253 \text{ หรือ เป็นเลขใหม่ที่มีค่าอยู่ระหว่าง } (\pm 2^{31} - 1)$$

$$R_{i+1} = \text{เลขสุ่มที่ต้องการ}$$

2. การสร้างเลขสุ่มที่มีการแจกแจงแบบปกติ (Normal Random Number Distribution) ที่มีค่าเฉลี่ยเท่ากับ 0 ความแปรปรวนเท่ากับ 1 ซึ่งมีอยู่ด้วยกันหลายวิธี วิธีที่ใช้ในการวิจัยครั้งนี้คือวิธีของ Box และ Muller (1975: 550-556) มีดังนี้

$$X_n = (-2 \ln R_n)^{1/2} \cos 2\pi R_{n+1}$$

$$X_{n+1} = (-2 \ln R_n)^{1/2} \sin 2\pi R_{n+1}$$

เมื่อ X_n, X_{n+1} คือ เลขสุ่มที่มีการแจกแจงแบบปกติ ตามที่ต้องการ
 R_n, R_{n+1} คือ ค่าที่เรียงลำดับคู่ของ เลขสุ่มที่มีการแจกแจงแบบสม่ำเสมอ

3. การสร้างเลขสุ่มที่มีการแจกแจงแบบปกติหลายตัวแปร (Multivariate Normal Random Distribution) ที่มีค่าเฉลี่ย เท่ากับ 0 ความแปรปรวนเท่ากับ 1 เราสามารถสร้างตัวแปรสุ่ม $X_i = (X_1, X_2, \dots, X_n)$ ได้ตั้งวิธีของ Scheuer ซึ่งผู้วิจัยใช้ในการทำวิจัยครั้งนี้ และได้เสนอไว้อย่างละเอียดในบทที่ 3

ตอนที่ 5

การแจกแจงแบบปกติหลายตัวแปร

(Multivariate Normal Distribution)

เมื่อ X_{ij} เป็นตัวแปรสุ่ม (random variable)

$$X = \begin{bmatrix} X_{11} & \dots & X_{1p} \\ \cdot & & \cdot \\ \cdot & & \cdot \\ X_{n1} & \dots & X_{np} \end{bmatrix}$$

X_{ij} จะมีการแจกแจงแบบปกติหลายตัวแปร (Multivariate Normal Distribution) เมื่อมี p.d.f. (Probability Density Function) ดังนี้ (Morrison 1967 : 98-99)

$$f_X(X) = \frac{1}{(2\pi)^{p/2} |\Sigma|^{1/2}} \exp - 1/2 (X - \mu) \Sigma^{-1} (X - \mu) \quad (2.31)$$

โดยที่ $-\infty < X_i < \infty ; i = 1, 2, \dots, p$

เขียนได้เป็น $X \sim N(\underline{\mu}, \Sigma)$

เมื่อ $\underline{\mu} = (\mu_1, \mu_2, \dots, \mu_p)$

$$\Sigma = \begin{bmatrix} \sigma_{11} & \dots & \sigma_{1p} \\ \cdot & & \cdot \\ \cdot & & \cdot \\ \sigma_{ni} & \dots & \sigma_{np} \end{bmatrix}$$

Σ เป็น $p \times p$ positive definite และสมมาตร (Symmetric) ซึ่งคือเมตริกซ์ ความแปรปรวนและความแปรปรวนร่วม (Variance - Covariance Matrix)

การแจกแจงของค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณกำลังสอง

(Distribution of the Multiple Correlation Coefficient Square)

ค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณ ($\rho_{y.12..p}$) หมายถึงความสัมพันธ์เชิงเส้นระหว่างตัวแปรเกณฑ์ (Y) กับผลรวมเชิงเส้นของตัวแปรทำนาย (X_s) (Lindeman 1982 : 108) หรือกล่าวได้ว่าเป็นสัมประสิทธิ์สหสัมพันธ์โปรดักโมเมนต์ (Product moment) ของตัวแปรเกณฑ์ที่สังเกตได้กับตัวแปรเกณฑ์ที่พยากรณ์ได้จากสมการถดถอย (Y)

$$R_{y.12\dots p} = r_{yy} = \sqrt{1 - \frac{\sigma^2 (Y-\hat{Y})}{\sigma_y^2}} \quad (2.32)$$

เมื่อศึกษากับกลุ่มตัวอย่างสามารถประมาณค่าโดย

$$R_{y.12\dots p} = \sqrt{1 - \frac{MSE}{S^2_y}} = \sqrt{\beta_1 r_{y1} + \beta_2 r_{y2} + \dots + \beta_p r_{yp}} \quad (2.33)$$

เมื่อ r_{yi} คือ สัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปรเกณฑ์กับตัวแปรทำนาย (X_i) แต่ละตัว และ β คือ สัมประสิทธิ์การถดถอยมาตรฐานที่จะทำให้ค่าสหสัมพันธ์พหุคูณมีค่าสูงสุดซึ่งมีค่าอยู่ระหว่าง 0 ถึง 1 และจะมีค่าเพิ่มขึ้นเมื่อจำนวนตัวแปรทำนายเพิ่มขึ้น

การประมาณค่าสหสัมพันธ์พหุคูณกำลังสองของประชากรจะมีลักษณะ เช่นเดียวกับ การศึกษาสหสัมพันธ์อย่างง่าย โดยคาดว่าค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณกำลังสองที่คำนวณได้จากกลุ่มตัวอย่าง ($R^2_{y.12\dots p}$) จะกระจายอยู่รอบ ๆ ค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณกำลังสองของประชากร แต่เนื่องจากค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณกำลังสองนี้มีค่าอยู่ระหว่าง 0 ถึง 1 และจัดเป็นตัวประมาณค่าที่เอนเอียง จึงทำให้การแจกแจงมีความเอนเอียงไปทางบวกเสมอ ซึ่งไม่สามารถคาดคะเนลักษณะการแจกแจงที่แน่นอนได้ จากการศึกษาพบว่า ลักษณะการแจกแจงของค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณกำลังสองนี้ จะขึ้นอยู่กับอิทธิพลของขนาดของกลุ่มตัวอย่าง จำนวน ตัวแปรทำนายและระดับความสัมพันธ์ในประชากร (ρ) (Muirhead 1982 : 171) ดังนี้

$$\begin{aligned} \text{เมื่อ } \rho &= 0 \\ E(R^2) &= \frac{p-1}{n-1} \end{aligned} \quad (2.34)$$

$$\text{และ } \text{Var}(R^2) = \frac{2(n-p)(p-1)}{(n^2-1)(n-1)} \quad (2.35)$$

จาก (2.34) และ (2.35) เมื่อระดับความสัมพันธ์ของประชากรมีค่าเป็นศูนย์ หรือไม่มีความสัมพันธ์กันเลย ลักษณะการแจกแจงของค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณกำลังสองจะขึ้นอยู่กับขนาดของกลุ่มตัวอย่างและจำนวนตัวแปรทำนายเท่านั้น เมื่อจำนวนตัวแปรทำนายเพิ่มขึ้นจะทำให้ค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณกำลังสองสูงขึ้นด้วย ($p \rightarrow n : R \rightarrow 1$) แต่ถ้าระดับความสัมพันธ์ในประชากรไม่เท่ากับศูนย์ ($\rho \neq 0$) แล้ว การคาดคะเนลักษณะการแจกแจงของค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณกำลังสองจะทำได้ยากมากดังนี้

เมื่อ $\rho \neq 0$

$$E(R^2) = 1 - \frac{n-p-1}{n-1} (1-\rho^2) F(1, 1, (n+1)/2, \rho^2) \quad (2.36)$$

เมื่อ $F(a, b, c, x)$ เป็นฟังก์ชันไฮเปอร์จีออเมตริกซ์ (Hypergeometrix) ซึ่งถ้าใช้เพียงสองเทอมแรกของสมการจะได้

$$E(R^2) = 1 - \frac{n-p-1}{n-1} (1-\rho^2) - \frac{n-p-1}{n-1} \frac{2}{n+1} \rho^2 (1-\rho^2) \quad (2.37)$$

และ

$$\text{Var}(R^2) = \frac{n-p+1}{n^2(n+2)} (1-\rho^2)^2 \left\{ 2(p-1)+4p^2 \left[\frac{4(p-1) + n(n+p+1)}{n+4} \right] + 0(n^{-2}) \right\} \quad (2.38)$$

ซึ่ง วิชาร์ต (Wishart 1931: 353-367) ได้ทำการศึกษาและได้เสนอสูตรการ
คำนวณค่าที่คาดหวัง (Expected) ของค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณกำลังสองไว้ดังนี้

$$E(R^2) = \frac{(1 - \rho^2)(a - \rho^2)}{a + b + 1/2}$$

$$= \frac{a + (b - 1/2) \rho^2 + \rho^4}{a + b + 1/2} \quad (2.39)$$

และ

$$\text{Var}(R^2) = \frac{4 \rho^2 (1 - \rho^2)}{n}$$

$$= \frac{2 \rho^2 (1 - \rho^2)^2}{(a + b + 1/2)} \quad (2.40)$$

เมื่อ a คือ 1/2 ของขั้นแห่งความเป็นอิสระ (Degree of Freedom) อัน
เนื่องมาจากฟังก์ชันการถดถอย (SSR)

b คือ 1/2 ของขั้นแห่งความเป็นอิสระ (Degree of Freedom) อัน
เนื่องมาจากความคลาดเคลื่อน (SSE)

จะเห็นว่าลักษณะการแจกแจงของค่าสัมประสิทธิ์สหสัมพันธ์พหุคูณกำลังสอง นอกจาก
จะขึ้นอยู่กับขนาดของกลุ่มตัวอย่าง และจำนวนตัวแปรทำนายแล้ว ยังขึ้นอยู่กับระดับของความ
สัมพันธ์ในประชากรซึ่งไม่ทราบค่าอีกด้วย

ตอนที่ 6

งานวิจัยที่เกี่ยวข้อง

กรณีการ เฝ้าระวังเสียงเจริญสิทธิ์ (2527: 48-49) ได้ใช้เทคนิคมอนติคาร์โลซิมูเลชัน ทำการศึกษาการแจกแจงของค่าสหสัมพันธ์แบบปกติสองตัวแปร ณ ระดับความสัมพันธ์ในประชากร (0) ต่าง ๆ ตั้งแต่ $0 = 0.1, 0.2, \dots, 0.9$ เพื่อนำไปใช้ประโยชน์กรณีที่ต้องการสุ่มตัวอย่างที่มีคุณสมบัติตามต้องการ ผลการศึกษาพบว่า ยืนยันลักษณะการแจกแจงของข้อมูลว่ามีความแปรปรวนในกรณีที่ $0 = 0$ แล้วขนาดของกลุ่มตัวอย่างมีน้อยกว่า 25 แต่เมื่อขนาดของกลุ่มตัวอย่างมีค่าเท่ากับหรือมากกว่า 25 การแจกแจงของค่าสหสัมพันธ์จะมีลักษณะ เป็นปกติโดยประมาณ และยืนยันว่า เมื่อแปลงค่าสหสัมพันธ์โดยวิธี Fisher's transformation แล้ว Z_F จะมีลักษณะการแจกแจง เป็นปกติโดยประมาณ ข้อสรุปที่สำคัญที่ได้จากการศึกษา คือ ในการทดสอบสมมติฐานกรณีที่ 0 มีค่าอื่น ๆ ที่ไม่เท่ากับ 0 ณ ระดับ $\alpha = 0.01$ ขนาดของกลุ่มตัวอย่างที่เหมาะสมควรถูกใช้ตั้งแต่ 9 ขึ้นไปที่ระดับ $\alpha = 0.05$ และที่ระดับ $\alpha = 0.10$ ควรถูกใช้ตั้งแต่ 5 ขึ้นไป

จะเด็จ สวรรค์ตรานนท์ (2530) ได้เปรียบเทียบวิธีการคัดเลือกตัวแปรอิสระเข้าสู่สมการถดถอย 5 วิธีด้วยกัน คือ วิธีการกำจัดตัวแปรพรวนแบบถอยหลัง วิธีการเลือกตัวแปรแบบไปข้างหน้า วิธีการถดถอยแบบขั้นบันได วิธีการถดถอยแบบขั้นตอน และวิธีการกำจัดตัวแปรโดยใช้สัมประสิทธิ์สหสัมพันธ์ เมื่อความคลาดเคลื่อนมีการแจกแจงแบบปกติ โลกจิตติ ดับเบิล เอ็กซ์โพเนนเชียล และแบบปกติปโลมปน สำหรับรูปแบบของการแจกแจงแบบปกติปโลมปนนั้น ได้ทำการศึกษาเมื่อสเกลแพคเตอร์มีค่าเท่ากับ 3 และ 10 การปโลมปนเท่ากับ 5%, 10% และ 25% ขนาดตัวอย่างเท่ากับ 15, 30, 50 และ 100 จำนวนตัวแปรอิสระเท่ากับ 3, 5, 7, และ 9 ใน ระดับนัยสำคัญ .01 และ .05 ตามลำดับ โดยการเปรียบเทียบวิธีการเลือกสมการถดถอยนั้น ได้พิจารณาค่าผลรวมของความคลาดเคลื่อนกำลังสอง ค่าเฉลี่ยของความคลาดเคลื่อนกำลังสอง และค่าของตัวสถิติที ซึ่งสรุปผลได้ดังนี้

1) เมื่อความคลาดเคลื่อนมีการแจกแจง เป็นไปตามข้อตกลงเบื้องต้น นั้นวิธีของการถดถอยแบบขั้นบันไดให้ผลดีที่สุด ส่วนวิธีที่ให้ผลรองลงไปคือ วิธีการเลือกตัวแปรแบบไปข้างหน้า วิธีการถดถอยแบบขั้นตอน วิธีการกำจัดตัวแปรโดยใช้สัมประสิทธิ์สหสัมพันธ์และวิธีที่ให้ผลเป็นอันดับสุดท้าย คือวิธีการกำจัดตัวแปรแบบถอยหลัง

2) เมื่อความคลาดเคลื่อนมีการแจกแจงไม่เป็นไปตามข้อตกลงเบื้องต้นนั้น ในกรณีที่มีความคลาดเคลื่อนมีการแจกแจงแบบโลจิสติก วิธีการถดถอยแบบขั้นบันไดให้ผลดีที่สุด ส่วนวิธีที่ให้ผลรองลงไปคือ วิธีการเลือกตัวแปรไปข้างหน้า วิธีการถดถอยแบบขั้นตอน และวิธีที่ให้ผลเป็นอันดับสุดท้ายคือ วิธีการกำจัดตัวแปรแบบถอยหลังและการกำจัดตัวแปรโดยวิธีสัมประสิทธิ์สหสัมพันธ์ ในกรณีที่ความคลาดเคลื่อนมีการแจกแจงแบบดับเบิลเอ็กซ์โปเนเนเชียลและแบบปกติปลอมปนนั้น จะให้ผลเหมือนกันคือ วิธีการถดถอยแบบขั้นบันไดให้ผลดีที่สุด ส่วนวิธีที่ให้ผลรองลงไปตามลำดับคือ วิธีการเลือกตัวแปรแบบไปข้างหน้า วิธีการกำจัดตัวแปรโดยวิธีสัมประสิทธิ์สหสัมพันธ์การถดถอยแบบขั้นตอน และวิธีที่ให้ผลเป็นอันดับสุดท้าย คือ วิธีการกำจัดตัวแปรแบบถอยหลัง

ฮาลินสกีและเฟลด์ (Halinske and feldt 1970:151-158) ได้ทำการศึกษาโดยใช้เทคนิคมอนติคาร์โลซิมูเลชัน เกี่ยวกับขนาดของกลุ่มตัวอย่างที่เหมาะสมในการวิเคราะห์การถดถอยพหุคูณ พบว่า ควรใช้อัตราส่วนระหว่างขนาดของกลุ่มตัวอย่างกับจำนวนตัวแปรอย่างน้อยที่สุดเท่ากับ 10 : 1

มิลเลอร์และคันซ์ (Miller and Kuncce 1978: 157-163) ได้ทำการศึกษาแบบครอสแวลิเดชัน (Cross-Validation) เกี่ยวกับขนาดของกลุ่มตัวอย่างที่เหมาะสมในการวิเคราะห์การถดถอยพหุคูณ พบว่าควรใช้อัตราส่วนระหว่างขนาดของกลุ่มตัวอย่างกับจำนวนตัวแปรอย่างน้อยที่สุดเท่ากับ 10 : 1