

วิธีการวิจัย

เทคนิคหรือวิธีการทางสถิติที่ใช้ในการวิเคราะห์ตัวแปรหลายตัวนั้น มีอยู่ด้วยกันหลายวิธี ในแต่ละวิธีต่างก็มีข้อจำกัด ความเหมาะสมและวัตถุประสงค์แตกต่างกันออก การเลือกใช้เทคนิคหรือวิธีการวิเคราะห์ปัญหาที่เหมาะสมจึงเป็นสิ่งจำเป็น อย่างไรก็ตาม บ่อยครั้งที่เราพบว่าในปัญหาเรื่องเดียวกัน มีเทคนิคหรือวิธีการทางสถิติที่ใช้ได้หลายวิธี ผู้ใช้จึงต้องตัดสินใจว่าจะเลือกใช้วิธีใด ซึ่งเหมาะสมที่สุด ประหยัดค่าใช้จ่ายหรือใช้ทรัพยากรน้อยที่สุด แต่ในขณะเดียวกันก็ให้ผลชัดเจนและตรงตามวัตถุประสงค์ที่ได้กำหนดไว้

สำหรับในการศึกษาเพื่อหาตัวแปรที่เหมาะสมในการจัดลำดับความสำคัญของพื้นที่ที่มีปัญหาแล่งพืดครั้งนี้ ผู้ศึกษาจะทำการเปรียบเทียบวิธีการทางสถิติ 4 วิธีด้วยกันคือ วิธีการวิเคราะห์องค์ประกอบหลัก วิธีการวิเคราะห์ค่าโคโมดอล วิธีการวิเคราะห์ถดถอยพหุ และวิธีการวิเคราะห์ค่าแยกประเภท ขั้นตอนของการวิเคราะห์ในแต่ละวิธีจะปรากฏรายละเอียดในส่วนแรกของบทนี้ สำหรับส่วนที่ล่องจะกล่าวถึงวิธีการคัดเลือกตัวแปรที่เหมาะสมในการจัดลำดับความสำคัญของพื้นที่ที่มีปัญหาแล่งพืดและสถิติที่ใช้ในการคัดเลือก และในส่วนสุดท้ายของบทนี้จะเป็นวิธีการเปรียบเทียบผลการวิเคราะห์ประกอบหลักในกรณีที่ไม่ได้มีการตัดตัวแปรหรือกรณีที่มีการตัดตัวแปรก่อนทำการวิเคราะห์ตลอดจนวิธีการตัดตัวแปรก่อนที่จะทำการวิเคราะห์องค์ประกอบหลักด้วยวิธีมัลติเพิลคอรีเลชัน รายละเอียดและขั้นตอนของการวิเคราะห์ของวิธีการต่าง ๆ มีดังต่อไปนี้

3.1 วิธีการวิเคราะห์ของแต่ละวิธี

3.1.1 วิธีวิเคราะห์องค์ประกอบหลัก (Principal Component Method)

เป็นวิธีหนึ่งในการแสวงหาปัจจัยแรก ซึ่งเป็นองค์ประกอบหลักหรือเป็นตัวแปรตัวใหม่ que แสดงความสัมพันธ์เชิงเส้นตรงกับตัวแปรต่าง ๆ ที่นำมาศึกษา การวิเคราะห์โดยเทคนิคนี้ เราต้องรู้ว่ามปัจจัยใดที่ส่งผลต่อลักษณะที่เราจะศึกษา ผลจากการวิเคราะห์เราจะได้ตัวแปรประกอบใหม่ที่อยู่ในรูปค่าถ่วงน้ำหนัก ที่สามารถนใช้จัดลำดับความมากน้อยหรือความสำคัญ

ที่สามารถใช้เปรียบเทียบกันได้ ตัวแบบหรือรูปแบบสมการเป็นดังนี้คือ

$$Y_i = \sum_{j=1}^k a_{ij} x_j \quad \begin{matrix} i = 1, 2 \dots k \\ j = 1, 2 \dots k \end{matrix}$$

โดยที่ Y_i = ค่าตัวแปรประกอบขององค์ประกอบ (Component) ที่ i

a_{ij} = ค่าน้ำหนัก (Loading) บนองค์ประกอบที่ i ของตัวแปรที่ j

x_j = ตัวแปรตัวที่ j

ขั้นตอนในการคำนวณเพื่อหาตัวแปรใหม่ซึ่งเป็นตัวแปรประกอบ มีดังนี้

1) จาก $X = [x_1 \dots x_k]$ ซึ่งเป็นตัวแปร k ตัวที่นำมาศึกษา

2) หาเมตริกซ์ความแปรปรวนร่วม (Covariance Matrix; S_x)

$$S_x = E[(X - E(X))(X - E(X))']$$

3) หา Characteristic Roots (λ) จากสมการ $[S - \lambda I] = 0$

โดยที่ $\lambda = \lambda_1, \lambda_2 \dots \lambda_k$

λ_i = Characteristic root ที่ i ของ S_x

และ $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k$

I = Identity matrix

4) หา Characteristic Vectors (a) จากสมการ

$$(S - \lambda I) a = 0$$

a_i = Characteristic vector ที่ i ที่สอดคล้อง
กับ Characteristic root ที่ i (λ_i)

$$a'_i = [a_{i1}, a_{i2}, \dots, a_{ik}]$$

5) หาค่า Characteristic vector ที่ normalized แล้ว
โดยการหาร Characteristic vectors ด้วยความยาว (length) ของ
Characteristic vectors จะได้ Principal factor.

6) หมุนแกนองค์ประกอบให้แกนตั้งฉากซึ่งกันและกัน (Orthogonal)
จะได้องค์ประกอบที่เป็นอิสระต่อกัน ค่าที่ได้จากการหมุนแกนคือค่าตัวประกอบที่จะนำไปใช้วิเคราะห์
เพื่อหาตัวแปรที่สำคัญ โดยเราจะพิจารณาจากตัวประกอบที่ 1 ซึ่งเป็นตัวประกอบที่มีค่าความ
แปรปรวน (Variance) สูงสุด และจากองค์ประกอบที่ 1 นี้ตัวแปรที่มีความสำคัญสูงสุดคือ
ตัวแปรที่มีค่าน้ำหนักสูงสุดในองค์ประกอบที่ 1

ดังนั้น เราจะใช้องค์ประกอบที่ 1 หรือองค์ประกอบที่มีความแปรปรวน
สูงสุด เพื่อหาตัวแปรใหม่ ซึ่งก็คือ

$$Y_1 = a_{11}x_1 + a_{12}x_2 + \dots + a_{1k}x_k$$

อย่างไรก็ตาม เราจะเห็นได้ว่าตัวประกอบที่ได้จะแสดงความสัมพันธ์
เชิงเส้นกับตัวแปรเดิมที่นำมาศึกษาทั้งหมด ดังนั้น ในกรณีที่มีตัวแปรจำนวนมาก ย่อมจะทำให้
เสียเวลาและค่าใช้จ่ายทั้งในการเก็บรวบรวมข้อมูลและการประมวลผล โดยเฉพาะในกรณีที่
ตัวแปรบางตัวยากแก่การเก็บรวบรวมและไม่ช่วยให้ผลการวิเคราะห์มีความหมายมากขึ้นแต่อย่าง
ใด ดังนั้น บ่อยครั้งที่เราพบว่า การตัดตัวแปรบางตัวออกก่อนที่จะทำการวิเคราะห์องค์ประกอบ
หลัก ไม่ทำให้ผลที่ได้รับเปลี่ยนแปลงไปแต่อย่างใด หรือถ้าจะเปลี่ยนแปลงก็เพียงเล็กน้อยเท่า
นั้น¹ จากแนวความคิดดังกล่าวในปี 1982 โจนลลิเฟ้ (Jolliffe) ได้เสนอวิธีการตัดตัวแปร

¹JOLLIFFE, I.T., "Discarding Variables in a Principal
Component Analysis I : Artificial Data", Applied Statistics, 21 1972,
pp 160-173.

ที่ซับซ้อน (Rejection Method) หลายวิธีด้วยกัน และผลจากการทดสอบทั้งกับข้อมูลที่สร้างขึ้น (Artificial Data) ตลอดจนข้อมูลจริง (Real Data) พบว่า วิธีการตัดตัวแปรที่เรียกว่าวิธี มัลติเพิลคอร์เรลชัน (Multiple Correlation Method) เป็นวิธีที่ง่ายและให้ผลดีหรือให้ผลใกล้เคียงกับผลที่ได้จากการวิเคราะห์ในกรณีที่ไม่ได้มีการตัดตัวแปร ในการศึกษาครั้งนี้จึงได้นำหลักการของวิธีการดังกล่าวมาทำการศึกษาเปรียบเทียบด้วย

สำหรับในการศึกษาครั้งนี้ ตัวแปรที่ใช้ในการวิเคราะห์องค์ประกอบหลักมี

11 ตัวดังต่อไปนี้

CASE	=	จำนวนคดียาเสพติด
ADDICT	=	จำนวนผู้ติดยาเสพติดที่สมัครใจเข้ารับการรักษา
WEIGHT	=	น้ำหนักของกลาง
FACTORY	=	จำนวนโรงงาน
DENSITY	=	ความหนาแน่นของประชากร
RATING	=	อัตราการเพิ่มของประชากร
TEMPLE	=	จำนวนวัด
STU-TEA	=	จำนวนนักเรียนต่อครูหนึ่งคน
BAR	=	จำนวนสถานเริงรมย์
BANK	=	จำนวนธนาคาร
TRUCK	=	จำนวนรถบรรทุก

3.1.2 วิธีวิเคราะห์คาโนนิคอล (Canonical Analysis)

เป็นเทคนิคการวิเคราะห์ตัวแปรหลายตัวอีกวิธีหนึ่ง มีจุดมุ่งหมายที่สำคัญคือหาแบบแผนความสัมพันธ์ระหว่างตัวแปร 2 ชุด และพิจารณาจากชุดที่มีความสัมพันธ์กันมากที่สุด หลักการของวิธีวิเคราะห์คาโนนิคอลก็คือเราจะแบ่งตัวแปรที่มีอยู่ออกเป็น 2 กลุ่มแล้วหาความสัมพันธ์ระหว่างตัวแปรทั้ง 2 กลุ่มนี้ ซึ่งถ้าตัวแปรทั้ง 2 กลุ่มนี้มีความสัมพันธ์กันแล้ว เราก็จะใช้ตัวแปรในกลุ่มที่วัดได้ง่ายหรือเก็บรวบรวมได้ง่ายกว่าไปใช้ ผลจากการวิเคราะห์เราจะ

ได้ตัวแปรตัวใหม่ ซึ่งเป็นตัวแปรประกอบที่สร้างขึ้นมาจากตัวแปรเดิมทั้ง 2 กลุ่ม ตัวแปรใหม่นี้ เรียกว่า ตัวแปรคาโนนิกอล (Canonical Variate) มีขั้นตอนในการคำนวณดังนี้

ถ้าให้ x_1, x_2, \dots, x_p เป็นตัวแปรในกลุ่มที่ 1

และ y_1, y_2, \dots, y_q เป็นตัวแปรในกลุ่มที่ 2

กำหนดให้ $q \leq p$

ให้ U และ V เป็นตัวแปรใหม่ ซึ่งเป็นผลรวมเชิงเส้นของตัวแปรกลุ่มที่ 1

และ 2

$$\text{เราจะได้ว่า } U_1 = \alpha_{11}x_1 + \alpha_{12}x_2 + \dots + \alpha_{1p}x_p$$

$$U_2 = \alpha_{21}x_1 + \alpha_{22}x_2 + \dots + \alpha_{2p}x_p$$

⋮

$$U_q = \alpha_{q1}x_1 + \alpha_{q2}x_2 + \dots + \alpha_{qp}x_p$$

$$V_1 = \beta_{11}y_1 + \beta_{12}y_2 + \dots + \beta_{1q}y_q$$

⋮

$$V_q = \beta_{q1}y_1 + \beta_{q2}y_2 + \dots + \beta_{qq}y_q$$

ถ้าให้ ρ_c เป็นค่าความสัมพันธ์ระหว่าง U และ V ค่า ρ_c นี้จะเรียกว่าค่าสัมประสิทธิ์สหสัมพันธ์คาโนนิกอล (Canonical Correlation Coefficient)

$$\text{ซึ่ง } \rho_c = \frac{\text{Cov}(U, V)}{\sqrt{\text{Var}(U) \text{Var}(V)}}$$

วิธีวิเคราะห์ค่าโคโมคอลลนี้เราต้องการหาแบบแผนความสัมพันธ์ที่ทำให้ความสัมพันธ์ระหว่าง U และ V ลู่สุด ดังนั้นถ้าให้

$\rho_c^{(1)}$ เป็นลหสัมพันธ์ค่าโคโมคอลลที่มีค่าลู่สุด ซึ่งจะเรียกว่าค่าสัมประสิทธิ์ลหสัมพันธ์ค่าโคโมคอลลอันดับที่หนึ่ง ที่เกิดจาก U_1 และ V_1

$\rho_c^{(2)} \dots \rho_c^{(q)}$ เป็นค่าสัมประสิทธิ์ลหสัมพันธ์ค่าโคโมคอลลที่มีค่ามากรองลงมาตามลำดับ

U_1 และ V_1 จะเรียกว่า First Canonical Variable

U_q และ V_q จะเรียกว่า q^{th} Canonical Variable

ซึ่งถ้าเขียนในรูปเมตริกซ์จะได้ว่า $U = x\alpha$

$$V = y\beta$$

กำหนดให้ $\Sigma = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix} \quad (p+q) \times (p+q)$

โดยที่ $\Sigma_{11} =$ เมตริกซ์ความแปรปรวนของกลุ่มตัวแปร x มีขนาด $p \times p$

$\Sigma_{22} =$ เมตริกซ์ความแปรปรวนของกลุ่มตัวแปร y มีขนาด $q \times q$

$\Sigma_{12} =$ เมตริกซ์ความแปรปรวนร่วมระหว่างกลุ่มตัวแปร x และ y มีขนาด $p \times q$

และ $\Sigma_{21} = \Sigma_{12}'$

หรือเขียนให้เห็นได้ง่ายดังนี้

$$\Sigma = \begin{bmatrix} \alpha_{x_1 x_1} & \alpha_{x_1 x_2} \cdots \alpha_{x_1 x_p} & \alpha_{x_1 y_1} & \alpha_{x_1 y_2} \cdots \alpha_{x_1 y_q} \\ \vdots & \vdots & \vdots & \vdots \\ \alpha_{x_p x_1} & \alpha_{x_p y_2} \cdots \alpha_{x_p x_p} & \alpha_{x_p y_1} & \alpha_{x_p y_2} \cdots \alpha_{x_p y_q} \\ \hline \alpha_{x_1 y_1} & \alpha_{x_2 y_1} \cdots \alpha_{x_p y_1} & \alpha_{y_1 y_1} & \alpha_{y_1 y_2} \cdots \alpha_{y_1 y_q} \\ \vdots & \vdots & \vdots & \vdots \\ \alpha_{x_1 y_q} & \alpha_{x_2 y_q} \cdots \alpha_{x_p y_q} & \alpha_{y_q y_1} & \alpha_{y_q y_2} \cdots \alpha_{y_q y_q} \end{bmatrix}$$

ดังนั้น $\rho_c = \frac{\text{Cov}(x\alpha, y\beta)}{\sqrt{\text{Var}(x\alpha) \cdot \text{Var}(y\beta)}}$

หรือ $\rho_c = \frac{\alpha' \Sigma_{12} \beta}{\sqrt{\alpha' \Sigma_{11} \alpha \cdot \beta' \Sigma_{22} \beta}}$

การหาค่า ρ_c ที่จะได้ ρ_c มีค่าสูงสุด จะทำโดยการ maximize ρ_c เทียบกับ α และ β วิธีการนี้จะง่ายขึ้นถ้าให้ Canonical Variable แต่ละตัวมีความแปรปรวนเป็น 1

นั่นคือ จะได้ว่า $\text{Var}(U) = \text{Var}(x\alpha) = \alpha' \Sigma_{11} \alpha = 1$ -----(1)

$\text{Var}(V) = \text{Var}(y\beta) = \beta' \Sigma_{22} \beta = 1$ -----(2)

ซึ่งเงื่อนไขดังกล่าวจะได้ว่า $\rho_c = \alpha' \Sigma_{12} \beta$ และเมื่อ maximize ρ_c โดยวิธี Least square จะได้ว่า

$$\Sigma_{12}\beta - \lambda \Sigma_{11}\alpha = 0 \quad \text{----- (3)}$$

$$\Sigma_{21}\alpha - \lambda \Sigma_{22}\beta = 0 \quad \text{----- (4)}$$

เมื่อ λ เป็น Lagrange multiplier

จาก (3) คูณด้วย λ จะได้ $\Sigma_{12} \lambda \beta = \lambda^2 \Sigma_{11} \alpha$ ----- (5)

จาก (4) คูณด้วย Σ_{22}^{-1} จะได้ $\Sigma_{22}^{-1} \Sigma_{21} \alpha = \lambda \beta$ ----- (6)

นำค่า $\lambda \beta$ ที่ได้จาก (2) แทนลงใน (5) จะได้

$$\Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21} \alpha = \lambda^2 \Sigma_{11} \alpha$$

คูณทั้งสองข้างด้วย Σ_{11}^{-1} , $(\Sigma_{11}^{-1} \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21} - \lambda^2 I) \alpha = 0$ --- (7)

ในทำนองเดียวกันจะได้ว่า $(\Sigma_{22}^{-1} \Sigma_{21} \Sigma_{11}^{-1} \Sigma_{12} - \lambda^2 I) \beta = 0$ --- (8)

ทั้งสมการ (7) และ (8) เป็น homogeneous equations ซึ่งสามารถหาคำตอบได้

จาก (3) $\alpha = \frac{\Sigma_{11}^{-1} \Sigma_{12} \beta}{\lambda}$ ----- (9)

จาก (3) คูณด้วย α' จะได้ $\alpha' \Sigma_{12} \beta = \lambda \alpha' \Sigma_{11} \alpha$

จาก (4) คูณด้วย β' จะได้ $\beta' \Sigma_{21} \alpha = \lambda \beta' \Sigma_{22} \beta$

จากเงื่อนไขที่กำหนดว่า $\alpha' \Sigma_{11} \alpha = \beta' \Sigma_{22} \beta = 1$

ดังนั้น $\alpha' \Sigma_{12} \beta = \beta' \Sigma_{21} \alpha = \lambda$ ----- (10)

นั่นคือ $\rho_c = \lambda = \alpha' \Sigma_{12} \beta$

และจาก (7) หรือ (8) รากที่สองของ Characteristic root coefficient (λ^2)
 ที่ให้ค่ามากที่สุดจะเป็น First canonical correlation

จาก (8) เราสามารถหาค่า λ^2 และ β ได้โดยที่

$$\lambda_1^2 \geq \lambda_2^2 \geq \dots \geq \lambda_q^2 \text{ เป็น characteristic root}$$

และ $\beta_1, \beta_2, \dots, \beta_q$ เป็น characteristic vectors ที่สอดคล้อง
 หรือสัมพันธ์กับ characteristic root ลำดับเดียวกัน

จาก (9) จะหาค่า α ได้ โดยที่

$\alpha_1, \alpha_2, \dots, \alpha_q$ เป็น characteristic vectors ที่คำนวณได้จากการแทนค่า

$$\lambda_i \text{ และ } \beta_i \text{ ลงใน (9)}$$

และ canonical correlation coefficient ที่ i คือ $\rho_c^{(i)}$ ซึ่งมีค่าระหว่าง
 0 ถึง 1

$$\text{canonical variables } U_i = x \alpha_i$$

$$U_i = y \beta_i$$

ศูนย์วิทยุวิทยากร
 จุฬาลงกรณ์มหาวิทยาลัย

ในการคำนวณ เนื่องจากเราไม่ทราบค่า Σ เราจะประมาณ Σ ด้วย S

โดยที่

$$S = \begin{bmatrix} s_{11} & \dots & s_{12} \\ \dots & \dots & \dots \\ s_{21} & \dots & s_{22} \end{bmatrix}$$

หรืออาจจะคำนวณได้จาก Correlation matrix (R) โดยที่

$$R = \begin{bmatrix} R_{11} & \vdots & R_{12} \\ \hline R_{21} & \vdots & R_{22} \end{bmatrix}$$

S และ R เป็น matrix ของความแปรปรวนร่วมและสหสัมพันธ์ของตัวอย่าง

S_{11} และ R_{11} เป็น matrix ของความแปรปรวนและสหสัมพันธ์ระหว่างตัวแปร X มีขนาด $p \times p$

S_{22} และ R_{22} เป็น matrix ของความแปรปรวนและสหสัมพันธ์ระหว่างตัวแปร Y มีขนาด $q \times q$

S_{12} และ S_{12} เป็น matrix ของความแปรปรวนและสหสัมพันธ์ระหว่างตัวแปร X และ Y
มีขนาด $p \times q$

$$\text{และ } S_{21} = S'_{12}, \quad R_{21} = R'_{12}$$

ค่าสัมประสิทธิ์สหสัมพันธ์คาโนนิกอล ที่คำนวณได้ไม่ว่าจะจาก S หรือ R นั้นจะได้ผลเช่นเดียวกัน จะต่างกันที่ค่าของ α และ β เท่านั้น กล่าวคือค่าของ α และ β ที่คำนวณได้จากการใช้ S จะเป็นค่าที่ได้จากการใช้คะแนนดิบ แต่ค่า α และ β ที่คำนวณได้จากการใช้ R จะเป็นค่าที่อยู่ในรูปคะแนนมาตรฐาน อย่างไรก็ตามเราสามารถเปลี่ยนค่าสัมประสิทธิ์ที่คำนวณได้จากการใช้ S ไปให้อยู่ในรูปคะแนนมาตรฐานได้ โดยการหารค่าสัมประสิทธิ์ที่ได้จากการใช้ S ด้วยค่าเบี่ยงเบนมาตรฐาน

การทดสอบนัยสำคัญของการวิเคราะห์คาโนนิกอล

ผลจากการวิเคราะห์คาโนนิกอลเราจะได้ตัวแปรประกอบใหม่ และค่าสัมประสิทธิ์สหสัมพันธ์คาโนนิกอล ซึ่งแสดงความสัมพันธ์ระหว่างตัวแปร 2 กลุ่ม ซึ่งถ้าเราทราบว่าตัวแปร 2 กลุ่ม มีความสัมพันธ์กันแล้ว ในการวิเคราะห์คราวต่อไปเราจะใช้ตัวแปรของกลุ่มวัดได้ง่ายกว่าไปใช้ ดังนั้นเราจึงจำเป็นต้องทราบว่าตัวแปรทั้ง 2 กลุ่มนี้มีความสัมพันธ์กันหรือไม่ โดยทำการทดสอบว่าความแปรปรวนร่วม (Σ_{12} หรือ Σ_{21}) เท่ากับศูนย์หรือไม่

$$\therefore H_0 : \Sigma_{12} = 0 \text{ หรือ } \Sigma_{21} = 0$$

$$H_A : \Sigma_{12} \neq 0 \text{ หรือ } \Sigma_{21} \neq 0$$

ในการทดสอบเราจะใช้วิธีของ Wilks (Likelihood Ratio Test)

$$U_{cal} = \frac{[S]}{[S_{11}][S_{22}]} = \frac{[R]}{[R_{11}][R_{22}]}$$

เราจะเปรียบเทียบ U_{cal} กับ $U_{table}(p, q, n-1-q)$

และเราจะ Reject เมื่อ $U_{cal} < U_{table}$

ในกรณีที่ทำการประมวลผลด้วยโปรแกรมสำเร็จรูป SAS เราจะพิจารณาว่าตัวแปรทั้ง 2 กลุ่ม มีความสัมพันธ์กันอย่างน้อยสำคัญทางสถิติหรือไม่ด้วยค่า PROB F หรือ P-VALUE.

สำหรับในการศึกษาครั้งนี้ ตัวแปรที่ใช้ในการวิเคราะห์ค่าโหนดคอลประกอบด้วยตัวแปร 11 ตัว ซึ่งในการวิเคราะห์เราจะแบ่งตัวแปรออกเป็น 2 กลุ่มคือกลุ่มตัวแปรทางด้านเศรษฐกิจ ซึ่งประกอบด้วยตัวแปร 3 ตัวคือจำนวนธนาคาร จำนวนสถานเริงรมย์ และจำนวนรถบรรทุก ตัวแปรอีกกลุ่มหนึ่งคือกลุ่มตัวแปรทางด้านสังคม ซึ่งประกอบด้วยตัวแปร 8 ตัวคือจำนวนผู้ติดยาเสพติดที่สมัครใจเข้ารับการรักษา จำนวนคดียาเสพติด อัตราการเพิ่มของประชากร ความหนาแน่นของประชากร จำนวนนักเรียนต่อครูหนึ่งคน จำนวนวัด จำนวนโรงงาน และน้ำหนักของกลาง

3.1.3 วิเคราะห์ถดถอยพหุ (Multiple Regression Analysis)

เป็นวิธีทางสถิติที่ใช้ในการวิเคราะห์ตัวแบบหรือรูปแบบของความสัมพันธ์เชิงเส้นระหว่างตัวแปรตามหนึ่งตัวกับตัวแปรอิสระหลายตัว จากตัวแบบที่ได้เราจะทราบว่าตัวแปรอิสระแต่ละตัวมีความสัมพันธ์กับตัวแปรตามมากน้อยเพียงใด เป็นไปในทิศทางเดียวกันหรือตรงกัน

ข้ามในการใช้วิธีนี้จะต้องสมมติว่าตัวแปรอิสระแต่ละตัวเป็นอิสระซึ่งกันและกัน และปฏิภน
ระหว่างตัวแปรอิสระด้วยกันไม่มีผลต่อตัวแปรตาม ซึ่งรูปแบบความสัมพันธ์ระหว่างตัวแปรตาม
และตัวแปรอิสระเป็นดังนี้

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon$$

โดยที่ β_0 = ค่าคงที่หรือจุดเริ่มต้น

$\beta_1 \dots \beta_k$ = ค่าสัมประสิทธิ์ถดถอย

Y = ค่าตัวแปรตามที่ต้องการจะศึกษา

$X_1 \dots X_k$ = ค่าตัวแปรอิสระ k ตัวที่นำมาศึกษา

ϵ = ค่าความคลาดเคลื่อน

ในการประมาณค่า β นั้น จะประมาณด้วยวิธีกำลังสองน้อยที่สุด (Least Square Method) ซึ่งโดยวิธีนี้ จะทำให้ผลรวมกำลังสองของส่วนเบี่ยงเบนของค่าสังเกตต่างจากค่าเฉลี่ยมีค่าน้อยที่สุด และทำให้ได้ตัวประมาณที่ไม่เอนเอียง ขั้นตอนในการคำนวณพอสรุปได้ดังต่อไปนี้

จากข้อมูลที่นำมาศึกษาในครั้งนี้มีจำนวนข้อมูล 64 รายการคือ $n = 64$
เขียนเป็นสมการได้ดังนี้

$$Y_1 = \beta_0 + \beta_1 X_{11} + \beta_2 X_{21} + \dots + \beta_k X_{k1} + \epsilon_1$$

$$Y_2 = \beta_0 + \beta_1 X_{12} + \beta_2 X_{22} + \dots + \beta_k X_{k2} + \epsilon_2$$

⋮
⋮

$$Y_n = \beta_0 + \beta_1 X_{1n} + \beta_2 X_{2n} + \dots + \beta_k X_{kn} + \epsilon_n$$

จากสมการข้างต้นสามารถเขียนอยู่ในรูปของเมทริกซ์ ได้ดังนี้

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

หรือ

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}_{n \times 1} = \begin{bmatrix} 1 & X_{11} & X_{21} & \cdots & X_{k1} \\ 1 & X_{12} & X_{22} & \cdots & X_{k2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{1n} & X_{2n} & \cdots & X_{kn} \end{bmatrix}_{(n, k+1)} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix}_{(k+1, 1)} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}_{(n \times 1)}$$

ถ้า \hat{Y} เป็นตัวประมาณของ Y

$\hat{\beta}$ เป็นตัวประมาณของ β

e เป็นตัวประมาณของ ϵ

เราจะได้สมการ $\hat{X} = X\hat{\beta} + e$

$$e = Y - X\hat{\beta}$$

$$\sum_{i=1}^n e_i^2 = e'e$$

$$= (X - X\hat{\beta})'(X - X\hat{\beta})$$

การหาค่า $\hat{\beta}$ จะทำโดยการ minimize ผลบวกกำลังสองของความคลาดเคลื่อน (e) ด้วยการหาอนุพันธ์ (differentiate) $\sum_{i=1}^n e_i^2$ เทียบกับค่า $\hat{\beta}$ แล้วให้เท่ากับศูนย์ จะได้ว่า

$$\frac{\partial}{\partial \beta} (e' e) = -2x' y + 2x' x \hat{\beta} = 0$$

$$\text{นั่นคือ } x' x \hat{\beta} = x' y$$

$$\therefore \hat{\beta} = (x' x)^{-1} (x' y)$$

และเมื่อทำการ differentiate อันดับที่ 2 จะได้

$$\frac{\partial}{\partial \beta} (e' e) = 2x' x$$

ซึ่งเป็น differentiate ทางบวก เพราะฉะนั้น $\hat{\beta} = (x' x)^{-1} (x' y)$ จึงเป็นตัวประมาณที่ได้จากการทำให้กำลังสองของความคลาดเคลื่อนมีค่าน้อยที่สุด

และจากการคำนวณจะได้ค่าความแปรปรวนของ $\hat{\beta}$ (S^2) ดังนี้

$$S^2 = e' e / (n-k-1)$$

โดยที่ S^2 เป็นตัวประมาณที่ไม่เอนเอียงของ σ^2

ข้อสมมติเบื้องต้นในการวิเคราะห์ถดถอยพหุ

ข้อสมมติเบื้องต้นสำหรับการประมาณโดยใช้วิธีกำลังสองน้อยที่สุด มีดังต่อไปนี้

$$1) \text{ จาก } y_i = x_i \beta + \epsilon_i$$

y_i เป็นฟังก์ชันเชิงเส้นของ x_{ij} กับ ϵ_i

โดยที่ $i = 1, 2 \dots n$

$j = 0, 1 \dots k$, และ $x_{0i} = 1$

$$2) E(\epsilon_i) = 0$$

นั่นคือ $E(\epsilon_i) = 0$ สำหรับทุกค่าของ i

$$3) E(\epsilon_i \epsilon_j) = \sigma^2 I$$

นั่นคือ $E(\epsilon_i^2) = \sigma^2$ สำหรับทุกค่าของ i นั่นคือ ϵ_i มีความแปรปรวนที่ $E(\epsilon_i \epsilon_j) = 0$ เมื่อ $i \neq j$ ซึ่งแสดงว่าแต่ละคู่ของ ϵ ไม่เกี่ยวข้องกัน

4) ϵ_i เป็นตัวแปรเชิงสุ่มที่มีการกระจายแบบปกติ $N(0, \sigma^2)$ ซึ่งเงื่อนไขข้อนี้จะใช้ในกรณีที่ต้องการสร้างช่วงความเชื่อมั่นของ $\beta_0, \beta_1, \dots, \beta_k$ หรือเมื่อต้องการทดสอบสมมติฐานใด ๆ เกี่ยวกับตัวประมาณ

5) X เป็นเมตริกซ์อันดับที่ $n \times (k+1)$ ซึ่งมีค่าคงที่ จึงทำให้ X และ ϵ เป็นตัวแปรอิสระกัน เราจึงได้ว่า

$$E(\epsilon/X) = E(\epsilon) = 0$$

$$E(X\epsilon) = X E(\epsilon) = 0$$

$$E(\epsilon \epsilon'/X) = E(\epsilon \epsilon') = \sigma^2 I$$

6) X มี rank $k+1$ ซึ่ง $(k+1) < n$ หมายความว่าจำนวนค่าสังเกต n จะต้องมากกว่าจำนวนพารามิเตอร์ $(k+1)$ ที่จะต้องประมาณค่า

เกณฑ์การคัดเลือกตัวแปรที่ใช้เป็นตัวบ่งชี้ถึงพื้นที่ที่มีปัญหาياهเล่พติด

เนื่องจากในการวิเคราะห์หัตถดถอยพหุคูณ ผู้วิเคราะห์จำเป็นต้องรู้ว่าตัวแปรใดเป็นตัวแปรตามหรือเป็นตัวแปรที่ต้องการจะศึกษา ซึ่งในที่นี้ก็คือเป็นตัวแปรที่ใช้เป็นตัวบ่งชี้ถึงพื้นที่ที่มีปัญหาياهเล่พติด แต่ในทางปฏิบัติจากการศึกษาเท่าที่ผ่านมายังไม่สามารถระบุได้ว่าตัวแปรใดที่จะใช้เป็นตัวบ่งชี้ถึงพื้นที่ที่มีปัญหาياهเล่พติดได้ ในการศึกษาครั้งนี้ตัวแปรที่จะใช้เป็นตัวแปรตามหรือตัวแปรที่บ่งชี้ถึงพื้นที่ที่มีปัญหาياهเล่พติด คือตัวแปรที่มีน้ำหนักความสำคัญสูงที่สุดในสมการที่คัดเลือกได้จากการเปรียบเทียบระหว่างผลการวิเคราะห์หัตถดถอยองค์ประกอบหลักกับการวิเคราะห์

คาโนดิกคอล ทั้งนี้ถือว่าตัวแปรนั้นสามารถอธิบายตัวแปรประกอบใหม่ ซึ่งจะใช้เป็นตัวบ่งชี้ถึงพื้นที่ที่มีปัญหาياهเล็ดลอดได้มากกว่าตัวแปรอื่น ๆ สำหรับการคัดเลือกสมัคร ซึ่ง เป็นผลจากการเปรียบเทียบระหว่างวิธีการวิเคราะห์องค์ประกอบหลักกับวิธีการวิเคราะห์คาโนดิกคอล จะพิจารณาจากค่าสัมประสิทธิ์สหสัมพันธ์แบบอันดับ (Spearman's Coefficient of rank Correlation ; r_s) ระหว่างค่าคะแนนความสำคัญจากวิธีการทั้งสอง ถ้าค่า r_s ที่ได้มีค่าสูงเราจะเลือกใช้สมัครที่ได้จากวิธีการวิเคราะห์ใดก็ได้ ทั้งนี้เพราะวิธีการทั้งสองให้ผลของลำดับความสำคัญ ของพื้นที่ที่มีปัญหาياهเล็ดลอดสอดคล้องกัน แต่ถ้าค่า r_s ที่ได้มีค่าต่ำ (ต่ำกว่า 0.5) แสดงว่าวิธีการวิเคราะห์ทั้งสองให้ผลไม่สอดคล้องกัน ดังนั้นการจะเลือกใช้วิธีการวิเคราะห์ใดจะพิจารณาจากค่า C.V. (Coefficient of Variation) เป็นหลัก

3.1.4 วิธีการวิเคราะห์จำแนกประเภท (Discriminant Analysis)

เป็นวิธีการทางสถิติที่ใช้ในการคัดเลือกตัวแปรกลุ่มหนึ่งออกจากตัวแปรทั้งหมดที่นำมาศึกษา ซึ่งตัวแปรที่ถูกคัดออกมานี้จะเป็นตัวแปรที่มีความสัมพันธ์กับสิ่งที่ต้องการศึกษา ผลที่ได้จากการวิเคราะห์จะได้สมการจำแนกประเภท (Discriminant Function) ซึ่งแสดงความสัมพันธ์ระหว่างตัวแปรอิสระของกลุ่มหนึ่งที่ถูกคัดเลือกว่ามีผลต่อสิ่งที่ต้องการศึกษา และค่าสัมประสิทธิ์ของตัวแปรที่อยู่ในสมการ จะบ่งชี้ถึงน้ำหนักหรือความสัมพันธ์ของตัวแปรอิสระที่มีต่อสิ่งที่ต้องการศึกษา ซึ่งเปรียบได้กับค่าสัมประสิทธิ์ถดถอยในการวิเคราะห์ถดถอยพหุ หรือเขียนเป็นตัวแบบได้ดังนี้

$$Y = \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p$$

โดยที่ Y = ค่าตัวแปรที่ใช้ในการจำแนกประเภทหรือที่ต้องการศึกษา

$\beta_1 \dots \beta_p$ = ค่าสัมประสิทธิ์ของสมการจำแนกประเภทระหว่างตัวแปรอิสระที่ถูกเลือกกับตัวแปรที่ต้องการศึกษา (Discriminant Function Coefficients)

$X_1 \dots X_p$ = ตัวแปรอิสระต่าง ๆ ที่ถูกคัดเลือกที่มีความสัมพันธ์กับตัวแปรที่ต้องการศึกษา

อย่างไรก็ตาม การสร้างตัวแบบหรือสมการวิเคราะห์จำแนกประเภทมี
2 วิธีคือ วิธีตรงและวิธีแบบขั้นตอน

วิธีตรง (Direct Method) วิธีนี้จะใช้ตัวแปรทุกตัวที่ผู้ศึกษาคิดว่ามีความสัมพันธ์กับสิ่งที่ต้องการศึกษา สามารถจำแนกประเภทออกเป็นกลุ่มต่าง ๆ ได้ มาใช้ในการสร้างสมการจำแนกประเภท

วิธีแบบขั้นตอน (Stepwise Method) วิธีนี้จะทำการคัดเลือกตัวแปรชุดหนึ่งที่เหมาะสมเพื่อใช้ในการสร้างสมการจำแนกประเภท การคัดเลือกตัวแปรเข้าสู่สมการ จะทำการคัดเลือกตัวแปรเข้าสู่สมการทีละหนึ่งตัว โดยตัวแปรตัวแรกที่ถูกเลือกจะเป็นตัวแปรที่มีอำนาจในการจำแนกกลุ่มมากที่สุด ตัวแปรตัวที่สองที่ถูกเลือกเป็นตัวแปรที่เมื่อรวมกับตัวแปรตัวแรกแล้วมีอำนาจในการจำแนกกลุ่มได้ดีขึ้น จากนั้นก็จะเลือกตัวแปรตัวต่อ ๆ ไป เข้าสู่สมการอีก โดยตัวแปรที่จะถูกเลือกเข้าสู่สมการ จะต้องเป็นตัวแปรที่ทำให้อำนาจในการจำแนกกลุ่มของสมการดีขึ้นตามลำดับและอย่างมีนัยสำคัญและก็เช่นเดียวกันการวิเคราะห์ถดถอยพหุแบบขั้นตอน กล่าวคือ ในแต่ละขั้นตอนตัวแปรที่ได้รับการคัดเลือกมาก่อนแล้วนั้น อาจจะถูกตัดทิ้งไปหากพบว่าเมื่อนำมารวมกับตัวแปรอื่น ๆ แล้วไม่ช่วยให้สมการจำแนกประเภทได้ดีขึ้น

ขั้นตอนในการวิเคราะห์จำแนกประเภท ในขั้นแรกจะทำการคัดเลือกตัวแปรชุดหนึ่งเพื่อสร้างสมการจำแนกประเภท (Discriminant Equation) ที่จะใช้ในการจำแนกประเภทออกเป็นกลุ่มต่าง ๆ ได้ จากนั้นก็จะใช้สมการจำแนกประเภทที่ได้จำแนกตัวอย่างเข้าเป็นสมาชิกของประชากรในแต่ละกลุ่ม

ในการศึกษาครั้งนี้จะใช้วิธีการของ Fisher มาใช้ในการจำแนกกลุ่ม
ถ้าให้ π_1 เป็นประชากรกลุ่มที่ 1

π_2 เป็นประชากรกลุ่มที่ 2

จากตัวแปรที่ใช้ในการศึกษา p ตัว $x = [x_1 \ x_2 \ \dots \ x_p]$ ทำการแปลงตัวแปร x ไปเป็นค่าของตัวแปร y ตัวเดียว โดยที่ y_1 และ y_2 เป็นค่าสังเกตที่ได้จากประชากร π_1 และ π_2 ตามลำดับ

ถ้า $\mu_{1y} =$ ค่าเฉลี่ยของค่า y ซึ่งได้มาจากค่า x ของประชากร π_1

$\mu_{2y} =$ ค่าเฉลี่ยของค่า y ซึ่งได้มาจากค่า x ของประชากร π_2

$\mu_1 = E(x/\pi_1)$ ค่าคาดหวังของตัวแปร x ที่ได้มาจากประชากร π_1

$\mu_2 = E(x/\pi_2)$ ค่าคาดหวังของตัวแปร x ที่ได้มาจากประชากร π_2

$\Sigma =$ Covariance Matrix

$$\Sigma = E(X_i - \mu_i)(X_i - \mu_i)'; \quad i = 1, 2$$

พิจารณาผลรวมเชิงเส้น

$$Y = \beta' X$$

(1x1) (1xp) (px1)

Y คือ Fisher's Linear Discriminant Function

β คือ ค่าน้ำหนักความสำคัญของตัวแปร x_1, x_2, \dots, x_p

$$\beta' = [\beta_1, \beta_2, \dots, \beta_p]$$

X คือ ตัวแปรที่นำมาศึกษา ซึ่งมีทั้งหมด p ตัว

$$X' = [x_1, x_2, \dots, x_p]$$

ดังนั้นจะได้ว่า $\mu_{1y} = E(Y/\pi_1) = E(\beta' X/\pi_1) = \beta' \mu_1$

$$\mu_{2y} = E(Y/\pi_2) = E(\beta' X/\pi_2) = \beta' \mu_2$$

$$\sigma_y^2 = \text{Var}(\beta' X) = \beta' \text{Cov}(X) \beta = \beta' \Sigma \beta$$

ตามหลักของวิธีการ Fisher ก็คือการพยายามหาผลรวมเชิงเส้นของค่า x ซึ่งจะทำให้ระยะทางระหว่าง μ_{1y} และ μ_{2y} มีค่ามากที่สุดที่จะเป็นไปได้

ค่าผลรวมเชิงเส้นซึ่งดีที่สุดในกรณีนี้จะต้องมีคุณสมบัติในการแบ่งแยกประชากรทั้ง 2 กลุ่ม ออกจากกันได้มากที่สุด ซึ่งวิธีการที่จะได้ผลรวมเชิงเส้นที่ดีนั้นก็โดยการหาค่า β ที่ทำให้อัตรา ส่วนระหว่าง (ระยะทางระหว่างค่าเฉลี่ยของ y)² กับ (ความแปรปรวนของ y) มีค่ามากที่สุด

$$\text{ถ้าให้ } \ell = \frac{(\text{ระยะทางระหว่างค่าเฉลี่ยของ } y)^2}{(\text{ความแปรปรวนของ } y)}$$

$$\begin{aligned} &= \frac{(\mu_{1y} - \mu_{2y})^2}{\sigma_y^2} \\ &= \frac{(\beta' \mu_1 - \beta' \mu_2)^2}{\beta' \Sigma \beta} \\ &= \frac{\beta' (\mu_1 - \mu_2) (\mu_1 - \mu_2)' \beta}{\beta' \Sigma \beta} \end{aligned}$$

ค่า β ที่ได้จะมีค่ามากที่สุดเมื่อ

$$\frac{\partial \ell}{\partial \beta} = 0$$

นั่นคือ $C(\mu_1 - \mu_2) - \Sigma \beta = 0$

$$\beta = C \Sigma^{-1} (\mu_1 - \mu_2)$$

กำหนดให้ $C = 1$ จะได้ผลรวมเชิงเส้นเป็น

$$\tilde{y} = \beta' x = (\mu_1 - \mu_2)' \Sigma^{-1} x \quad \text{----- (1)}$$

สมการ (1) สามารถใช้เป็นตัวจำแนกค่าสังเกตที่ได้มานั้นว่าจะอยู่ใน
ประชากรกลุ่ม π_1 หรือ π_2 ได้โดยให้

$$Y_0 = (\mu_1 - \mu_2)' \Sigma^{-1} X_0$$

เป็นค่าของ Discriminant function ของค่าสังเกต x_0 และให้

$$\begin{aligned} m &= \frac{1}{2} (\mu_{1y} + \mu_{2y}) \\ &= \frac{1}{2} (\beta\mu_1 + \beta\mu_2) \\ &= \frac{1}{2} (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 + \mu_2) \end{aligned}$$

m จะเป็นจุดกึ่งกลาง (Centriod) ระหว่างค่าเฉลี่ยของค่า y จากทั้ง 2
ประชากรสามารถเขียนกฎการจำแนกประเภทได้ดังนี้คือ

$$\text{จัด } x_0 \text{ ให้อยู่ } \pi_1 \text{ ถ้า } Y_0 = (\mu_1 - \mu_2)' \Sigma^{-1} X_0 < m$$

$$\text{จัด } x_0 \text{ ให้อยู่ } \pi_2 \text{ ถ้า } Y_0 = (\mu_1 - \mu_2)' \Sigma^{-1} X_0 > m$$

ในทางปฏิบัติเราจะไม่ทราบค่า μ_1 , μ_2 และ Σ ดังนั้นถ้าสุ่มตัวอย่าง
จาก π_1 และ π_2 มาเป็นจำนวน n_1 และ n_2 แล้ว

$$\bar{X}' = [x_1 \ x_2 \ \dots \ x_p]$$

จะได้ว่า

$$\bar{X}_1 = [x_{11} \ x_{12} \ \dots \ x_{1n_1}]$$

($p \times n_1$)

$$\bar{X}_2 = [x_{21} \ x_{22} \ \dots \ x_{2n_2}]$$

($p \times n_2$)

\bar{X}_1 , \bar{X}_2 และ S^{-1} pooled จะเป็นค่าประมาณของ μ_1 , μ_2 และ Σ^{-1}

ตามลำดับ

โดยที่ $\bar{x}_{\sim 1} = \frac{1}{n_1} \sum_{j=1}^{n_1} x_{\sim 1j}$ ----- (10)

$\bar{x}_{\sim 2} = \frac{1}{n_2} \sum_{j=1}^{n_2} x_{\sim 2j}$ ----- (11)

$$S = \left[\frac{n_1 - 1}{(n_1 - 1) + (n_2 - 1)} \right] S_1 + \left[\frac{n_2 - 1}{(n_1 - 1) + (n_2 - 1)} \right] S_2$$

$$= \frac{(n_1 - 1) S_1 + (n_2 - 1) S_2}{n_1 + n_2 - 2}$$

S_1 (p x p) = $\frac{1}{n_1 - 1} \sum_{j=1}^{n_1} (x_{\sim 1j} - \bar{x}_{\sim 1}) (x_{\sim 1j} - \bar{x}_{\sim 1})'$

S_2 (p x p) = $\frac{1}{n_2 - 1} \sum_{j=1}^{n_2} (x_{\sim 2j} - \bar{x}_{\sim 2}) (x_{\sim 2j} - \bar{x}_{\sim 2})'$

เมื่อแทนค่า $\bar{x}_{\sim 1}$, $\bar{x}_{\sim 2}$ และ S^{-1} pooled ลงใน (7) จะได้ Fisher's

Sample Linear Discriminant Function เป็น

$$y_{\sim} = \hat{\beta}'_{\sim} x_{\sim}$$

$$= (\bar{x}_{\sim 1} - \bar{x}_{\sim 2})' S^{-1} \text{ pooled } x_{\sim}$$

$$\begin{aligned}
 \text{และ } \hat{m} &= \frac{1}{2} (\bar{y}_{\hat{1}} + \bar{y}_{\hat{2}}) \\
 &= \frac{1}{2} (\hat{\beta}'\bar{x}_{\hat{1}} + \hat{\beta}'\bar{x}_{\hat{2}}) \\
 &= \frac{1}{2} (\bar{x}_{\hat{1}} + \bar{x}_{\hat{2}})' S^{-1} \text{ pooled } (\bar{x}_{\hat{1}} + \bar{x}_{\hat{2}})
 \end{aligned}$$

กฎการจำแนกประเภทจะเขียนได้เป็นดังนี้

จัด x_0 ให้อยู่ใน π_1 ถ้า $y_0 < m$

จัด x_0 ให้อยู่ใน π_2 ถ้า $y_0 > m$

$$\text{เมื่อ } y_0 = (\bar{x}_{\hat{1}} - \bar{x}_{\hat{2}})' S^{-1} \text{ pooled } x_0$$

จากสมการสามารถเขียนได้เป็น $y = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$

ค่า $\beta_1, \beta_2, \dots, \beta_p$ จะเป็นค่าแสดงถึงน้ำหนักความสำคัญของตัวแปร

x_1, x_2, \dots, x_p ซึ่งโดยปกติ x_i แต่ละค่าจะมีหน่วยไม่เหมือนกัน การเปรียบเทียบค่า

β_i เหล่านี้จะได้ทำได้โดยการปรับค่า β_i เหล่านี้ให้เป็นค่ามาตรฐาน (Standardized)

เสียก่อน การแปลงค่า β_i เหล่านี้สามารถทำได้โดยเอาสมาชิกในแนวเส้นทะแยงมุม (diagonal)

ของเมตริกซ์ W มาถอดรากที่สอง แล้วนำไปคูณกับค่า β_i ทุก ๆ ค่าตามสูตรต่อไปนี้

$$\beta_i^* = (\sqrt{w_{ii}}) (\beta_i)$$

เมื่อ β_i^* คือ Standardized Discriminant weight ของ Discriminant Function

$$W = (x_i - \bar{x}_{i_{go}}) (x_i - \bar{x}_{i_{go}})$$

เมื่อ W คือ Diagonal element ของเมตริกซ์ W โดยที่ $i = 1, 2, \dots, p$

$$\bar{X} = \begin{bmatrix} x_{111} & x_{121} & \dots & x_{1n1} & x_{112} & x_{122} & \dots & x_{1n2} \\ x_{211} & x_{221} & \dots & x_{2n2} & x_{212} & x_{222} & \dots & x_{2n2} \\ \vdots & \vdots & & \vdots & \vdots & \vdots & & \vdots \\ x_{p11} & x_{p21} & & x_{pn1} & x_{p12} & x_{p22} & & x_{pn2} \end{bmatrix}$$

$$\bar{X}_{go} = \begin{bmatrix} \bar{x}_{11} & \dots & \bar{x}_{11} & \bar{x}_{12} & \dots & \bar{x}_{12} \\ \bar{x}_{21} & \dots & \bar{x}_{21} & \bar{x}_{22} & \dots & \bar{x}_{22} \\ \vdots & & \vdots & \vdots & & \vdots \\ \bar{x}_{p1} & \dots & \bar{x}_{p1} & \bar{x}_{p2} & \dots & \bar{x}_{p2} \end{bmatrix}$$

การพิจารณาว่าล้มการจำแนกประเภทที่ได้มานั้นจะมีความสามารถในการแบ่งแยกกลุ่มได้ดีหรือไม่นั้นสามารถดูได้จากค่าความผิดพลาดเนื่องจากการจำแนกผิด (Mis Classification error)

การทดสอบนัยสำคัญของล้มการจำแนกประเภท

เมื่อได้ล้มการจำแนกประเภทมาแล้ว วิธีการตรวจสอบว่าล้มการที่ได้นี้มีอำนาจในการจำแนกกลุ่มได้อย่างมีนัยสำคัญทางสถิติหรือไม่ เราสามารถทดสอบได้จาก

$$V_m = [N - 1 - (p + k)/2] \ln(1 + \lambda_m)$$

โดยที่ V_m คือ Bartlett V Statistics ซึ่งมีการกระจายแบบ

Chi-Square ที่มี d.f เท่ากับ $(p + k - 2m)$

N = จำนวนตัวอย่างทั้งหมดจากประชากรทั้ง 2 กลุ่ม

p = จำนวนตัวแปรทั้งหมด

k = จำนวนกลุ่ม

λ_m = Characteristic root ตัวที่ m

ค่า λ_m นี้คำนวณได้จาก $|A - \lambda_m| = 0$

เมื่อ A = Covariance matrix ของ x

ค่า λ_m นี้จะเลือกเฉพาะค่าที่ไม่เป็นศูนย์เท่านั้น

สมการที่ได้จะเป็นสมการที่มีอำนาจในการจำแนกกลุ่มได้อย่างมีนัยสำคัญทางสถิติ ถ้าค่า V_m ที่คำนวณได้มีค่ามากกว่าค่า Chi-Square ที่ระดับนัยสำคัญที่กำหนดไว้

เกณฑ์การคัดเลือกตัวแปรที่จะใช้ในการจำแนกประเภท

ตัวแปรที่จะใช้ในการจำแนกประเภทคือตัวแปรซึ่งเป็นตัวบ่งชี้ถึงพื้นที่ที่มีปัญหาเฉลียด ซึ่งในทางปฏิบัติแล้วเราไม่สามารถทราบได้ ดังนั้นหลักเกณฑ์ในการคัดเลือกตัวแปรจำแนกประเภทก็ใช้เกณฑ์เช่นเดียวกันกับการคัดเลือกตัวแปรตามที่ใช้ในการวิเคราะห์ถดถอยพหุ กล่าวคือใช้ตัวแปรที่มีค่าน้ำหนักความสำคัญสูงสุดจากตัวแบบหรือสมการที่เลือกได้ระหว่างวิธีการวิเคราะห์องค์ประกอบหลักกับวิธีการวิเคราะห์ค่า โนมิคอล รายละเอียดดังกล่าวแล้วในหัวข้อเกณฑ์การคัดเลือกตัวแปรที่ใช้เป็นตัวบ่งชี้ถึงพื้นที่ที่มีปัญหาเฉลียดในหัวข้อที่ 3, 1, 3

3.2 วิธีการคัดเลือกตัวแบบที่เหมาะสมในการเลือกหรือจัดลำดับความสำคัญของพื้นที่ที่มีปัญหา ยาเสพติด

ในการคัดเลือกตัวแบบที่เหมาะสมกับการคัดเลือกหรือจัดลำดับความสำคัญของพื้นที่ที่มีปัญหา ยาเสพติด จะดำเนินการตามขั้นตอนดังต่อไปนี้

1) วิเคราะห์ผลตามวิธีการวิเคราะห์องค์ประกอบหลัก โดยใช้ตัวแปรทั้งหมด 11 ตัว ที่นำมาศึกษาในครั้งนี้

2) วิเคราะห์ผลตามวิธีการวิเคราะห์ค่า โนมิคอล ถ้าค่าสัมประสิทธิ์สหสัมพันธ์ โนมิคอลที่ได้มีค่าสูง จะใช้ตัวแบบที่ได้จากกลุ่มของตัวแปรที่วัดได้ง่ายกว่าไปเปรียบเทียบกับผลที่ได้จากวิธีการวิเคราะห์องค์ประกอบหลัก แต่ในกรณีที่ค่าสัมประสิทธิ์สหสัมพันธ์ โนมิคอลต่ำ จะใช้ตัวแบบที่ได้จากการนำตัวแปรทั้ง 2 กลุ่มมารวมกัน ซึ่งจะทำให้ผลที่ได้ถูกต้องมากยิ่งขึ้น

3) เปรียบเทียบผลการวิเคราะห์ระหว่างวิธีวิเคราะห์องค์ประกอบหลักกับวิธีวิเคราะห์ค่า โนมิคอล โดยพิจารณาจากค่าสัมประสิทธิ์สหสัมพันธ์แบบอันดับ (Spearman's Coefficient of rank Correlation ; r_s) ระหว่างค่าคะแนนของลำดับความสำคัญจากวิธีการทั้งสอง ถ้าค่า r_s ที่ได้มีค่าสูงจะเลือกใช้สมการใดก็ได้จาก 2 วิธีในการจัดลำดับความสำคัญของพื้นที่ที่มีปัญหา ยาเสพติดทั้งนี้ขึ้นอยู่กับความสะดวกเป็นหลัก ในทางตรงข้ามถ้า r_s ที่ได้มีค่าต่ำ (ต่ำกว่า 0.5) แสดงว่าวิธีการทั้งสองให้ผลไม่สอดคล้องกัน ดังนั้นการจะเลือกใช้สมการที่ได้จากวิธีการวิเคราะห์ใดจะพิจารณาจากค่า C.V. ของค่าคะแนนความสำคัญที่ได้เป็นหลัก และจากสมการที่คัดเลือกได้จากวิธีการทั้งสอง ตัวแปรที่มีค่าน้ำหนักความสำคัญสูงที่สุดในสมการ จะเป็นตัวแปรตามและตัวแปรจำแนกประเภทที่ใช้ในการวิเคราะห์ถดถอยพหุและวิธีการวิเคราะห์จำแนกประเภทต่อไป

4) วิเคราะห์ผลตามวิธีการวิเคราะห์ถดถอยพหุและวิธีการวิเคราะห์จำแนกประเภท

5) เปรียบเทียบผลที่ได้จากการวิเคราะห์ เพื่อเลือกตัวแบบที่เหมาะสมกับการคัดเลือกหรือจัดลำดับความสำคัญของพื้นที่ที่มีปัญหา ยาเสพติด

6) เลือกรูปแบบที่เหมาะสม

วิธีหาค่าสัมประสิทธิ์สหสัมพันธ์แบบอันดับของสเปียร์แมน (Spearman's Coefficient of rank Correlation ; r_s)

ในการหาความสัมพันธ์ระหว่างตัวแปร 2 ตัวโดยทั่วไปเราจะใช้ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) แต่ในกรณีที่ตัวแปรที่นำมาศึกษาเป็นตัวแปรประเภทจัดอันดับ ตัวสถิติที่ใช้ในการหาความสัมพันธ์จะมีหลายแบบด้วยกัน อาทิ สัมประสิทธิ์ความสัมพันธ์ครัสคาลและกุตแมน (G) สัมประสิทธิ์สหสัมพันธ์เชิงอันดับของเคนดัลล์ (τ) และสัมประสิทธิ์สหสัมพันธ์แบบอันดับของสเปียร์แมน (r_s) ในการศึกษาครั้งนี้เราจะใช้วิธีสุดท้ายที่กล่าวถึงทั้งนี้เพราะมีขั้นตอนที่ใช้ในการคำนวณที่สะดวกและรวดเร็ว ตามสูตรที่ปรากฏข้างล่างนี้

$$r_s = \frac{1 - 6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}$$

โดยที่ r_s = ค่าสัมประสิทธิ์สหสัมพันธ์แบบอันดับของสเปียร์แมน

d_i = ค่าของผลต่างระหว่างอันดับระหว่างตัวแปร 2 กลุ่ม

n = จำนวนตัวอย่าง

3.3 วิธีการเปรียบเทียบผลการวิเคราะห์องค์ประกอบหลักในกรณีที่ไม่ได้มีการตัดตัวแปรกับกรณีที่มีการตัดตัวแปร

ในการเปรียบเทียบผลการวิเคราะห์องค์ประกอบหลักระหว่างกรณีที่ไม่ได้มีการตัดตัวแปรกับกรณีที่มีการตัดตัวแปร จะดำเนินการขั้นตอนต่อไปนี้

- 1) วิเคราะห์ผลตามวิธีการวิเคราะห์องค์ประกอบหลัก โดยใช้ตัวแปรทั้งหมด 11 ตัวที่นำมาศึกษาในครั้งนี้
- 2) ดำเนินการตัดตัวแปรด้วยวิธีมัลติเพิลคอรัลเลน

- 3) จากตัวแปรที่คัดเลือกได้จากวิธีมัลติเพิลคอรัลเลชันแล้วนำตัวแปรเหล่านี้ไปวิเคราะห์ผลตามวิธีการวิเคราะห์องค์ประกอบหลักอีกครั้งหนึ่ง
- 4) เปรียบเทียบผลความเหมือนหรือความสัมพันธ์กันระหว่างเขตขององค์ประกอบที่ได้จากกรณีตัดและไม่ตัดตัวแปรโดยใช้สูตร

$$Q = \frac{\sum_{i=1}^m q_i r(i)}{\sum_{i=1}^m q_i}$$

ตามรายละเอียดที่ปรากฏในหัวข้อที่ 3.3.2 ซึ่งถ้าค่า Q ยังมีค่าสูงแสดงว่า ผลที่ได้จากการวิเคราะห์องค์ประกอบหลักระหว่างกรณีที่ไม่ได้มีการตัดตัวแปรกับกรณีที่มีการตัดตัวแปรให้ผลสอดคล้องหรือสัมพันธ์กันอย่างมาก กล่าวโดยสรุปก็คือความสอดคล้องหรือสัมพันธ์กันของผลการวิเคราะห์กรณีที่ไม่ได้มีการตัดตัวแปรกับกรณีที่มีการตัดตัวแปรแปรผันตามค่า Q

3.3.1 การตัดตัวแปรด้วยวิธีมัลติเพิลคอรัลเลชัน (Multiple Correlation Method)

เป็นวิธีการตัดตัวแปรที่เข้าช้อนก่อนที่จะดำเนินการวิเคราะห์องค์ประกอบหลัก โดยการตัดตัวแปรนั้นจะพิจารณาจากค่าสหสัมพันธ์พหุ (Multiple Correlation) เกณฑ์ในการตัดตัวแปร มีรายละเอียดดังต่อไปนี้

- 1) จากตัวแปร k ตัวที่นำมาศึกษา หากค่าสหสัมพันธ์พหุของตัวแปรแต่ละตัวกับตัวแปรที่เหลือ $(k-1)$ ตัว จะได้ค่าสหสัมพันธ์พหุ k ค่า
- 2) จากค่าสหสัมพันธ์พหุ k ค่า พิจารณาตัดตัวแปรที่มีค่าสหสัมพันธ์พหุสูงที่สุดออกไป จะเหลือตัวแปร $(k-1)$ ตัว
- 3) จากตัวแปรที่เหลือ $(k-1)$ ตัว หากค่าสหสัมพันธ์พหุของตัวแปรแต่ละตัวกับตัวแปรที่เหลือ $(k-2)$ ตัว จะได้ค่าสหสัมพันธ์พหุ $(k-1)$ ค่า
- 4) จากค่าสหสัมพันธ์พหุ $(k-1)$ ค่า พิจารณาตัดตัวแปรที่มีค่าสหสัมพันธ์พหุสูงที่สุดออกไปอีก จะเหลือตัวแปร $(k-2)$ ตัว

5) ต่ำเกินการหาค่าสหสัมพันธ์ของตัวแปรที่เหลือและตัดตัวแปรที่มีค่าสหสัมพันธ์สูงที่สุดออกไป ทำซ้ำ ๆ ไปเรื่อย ๆ จนกระทั่งค่าสหสัมพันธ์ของตัวแปรทุกตัวที่เหลือมีค่าต่ำกว่า 0.15 จึงหยุดการตัดตัวแปร

แต่อย่างไรก็ตามโวลลิเฟ้ (Jolliffe) ได้เสนอไว้ด้วยว่า ในการวิเคราะห์องค์ประกอบหลักนั้นควรจะเก็บตัวแปรไว้ในกรณีวิเคราะห์ไม่น้อยกว่า 4 ตัว ดังนั้นในการศึกษาครั้งนี้ การตัดตัวแปรจะหยุดกระทำเมื่อกรณีใดกรณีหนึ่งดังกล่าวข้างต้นเกิดขึ้น

3.3.2 หลักเกณฑ์ในการเปรียบเทียบผลระหว่างกรณีวิเคราะห์องค์ประกอบหลักในกรณีที่ไม่ได้มีการตัดตัวแปรกับกรณีที่มีการตัดตัวแปร (Comparison of Principal Components)

หลักเกณฑ์ในการเปรียบเทียบก็เช่นเดียวกับการหาความสัมพันธ์ของตัวแปรทั่วไป คือพิจารณาจากค่าสัมประสิทธิ์สหสัมพันธ์แบบอันดับ (Rank Correlation Coefficient)

$$\text{จาก } r_m = 1 - 6 \left\{ \sum_{i=1}^n (R_{mf_i} - R_{mr_i})^2 \right\} / \{ n(n^2 - 1) \}$$

โดยที่ r_m = ค่าสัมประสิทธิ์สหสัมพันธ์แบบอันดับขององค์ประกอบคู่ที่ m ระหว่างองค์ประกอบที่ได้จากกรณีที่ไม่ได้มีการตัดตัวแปรกับกรณีที่มีการตัดตัวแปร

R_{mf_i} = ค่าลำดับที่ของค่าสังเกตที่ i ในกรณีที่ไม่ได้มีการตัดตัวแปร

R_{mr_i} = ค่าลำดับที่ของค่าสังเกตที่ i ในกรณีที่มีการตัดตัวแปร

n = จำนวนค่าสังเกต

ค่า r_m นี้จะใช้วัดความเหมือนหรือความสัมพันธ์ขององค์ประกอบ
 คู่ที่ m ดังนั้นถ้าต้องการหาค่าเฉลี่ยของความเหมือนหรือความสัมพันธ์ระหว่าง
 เช่าขององค์ประกอบที่ได้จากกรณีที่ไม่ได้มีการตัดตัวแปรกับกรณีที่มีการตัดตัวแปรจะต้องทำการถ่วงน้ำหนักด้วย
 ความสามารถในการอธิบายความแปรปรวน ซึ่งเขียนเป็นสูตรได้ดังนี้

$$Q = \frac{\sum_{i=1}^m q_i r(i)}{\sum_{i=1}^m q_i}$$

โดยที่ q_i = ความสามารถในการอธิบายความแปรปรวนหรือสัดส่วนของความ
 แปรปรวนที่ได้จากองค์ประกอบที่ i ในกรณีที่ไม่ได้มีการตัดตัวแปร

$r(i)$ = ค่าสูงสุดของค่าสัมประสิทธิ์สหสัมพันธ์แบบอันดับระหว่างองค์ประกอบ
 ที่ i ของกรณีที่ไม่ได้มีการตัดตัวแปรกับองค์ประกอบใด ๆ ของ
 กรณีที่มีการตัดตัวแปร

m = จำนวนองค์ประกอบที่เราสนใจในกรณีการวิเคราะห์ที่ไม่ได้มีการ
 ตัดตัวแปร

และ Q = ค่าที่ใช้วัดความเหมือนหรือความสัมพันธ์ระหว่างชุดขององค์
 ประกอบที่ได้จากการวิเคราะห์ในกรณีที่ไม่ได้มีการตัดตัวแปรกับ
 กรณีที่มีการตัดตัวแปร ถ้าค่า Q ยิ่งมีค่ามากแสดงว่าผลจากการ
 วิเคราะห์ในกรณีที่ไม่ได้มีการตัดตัวแปรกับกรณีที่มีการตัดตัวแปร
 ก็ยิ่งใกล้เคียงกันมาก