

บทที่ 2

ผลงานวิจัยที่เกี่ยวข้อง

การวิเคราะห์การถดถอยเชิงพหุคาก្បแบบความสัมพันธ์

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

เมื่อ

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \\ \vdots \\ \vdots \\ Y_N \end{bmatrix}$$

$$X = \begin{bmatrix} 1 & x_{11} & \dots & x_{M1} \\ 1 & x_{12} & \dots & x_{M2} \\ 1 & x_{13} & \dots & x_{M3} \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{1N} & \dots & x_{MN} \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \vdots \\ \beta_M \end{bmatrix}$$

$$\varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \vdots \\ \vdots \\ \varepsilon_N \end{bmatrix}$$

โดยวิธีก้าสังล่องน้อยที่สุด (Least Square method) จะได้ลักษณะดังนี้

$$\hat{Y} = X\hat{\beta} \quad \text{ที่มีคุณลักษณะ} \quad \sum_{i=1}^N (\hat{Y}_i - Y_i)^2 \quad \text{มีค่าน้อยที่สุด} \quad \text{จากลักษณะดังนี้} \quad \text{จะได้ลักษณะ}$$

รักความเหมาะสม โดยใช้ค่าลักษณะประสีก์การตัดสินใจ แทนด้วยลัญญาลักษณ์ R^2 โดยที่

$$R^2 = \frac{\sum_{i=1}^N (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2}, \quad i = 1, 2, 3, \dots, N$$

และค่า $0 \leq R^2 \leq 1$

การใช้ค่า R^2 รักความเหมาะสม (Goodness of fit) ของลักษณะดังนี้

ระหว่างในการใช้มาก Hahn (1973) ได้แสดงให้เห็นว่าค่า R^2 จะมีค่ามากหรือน้อยขึ้นกับลักษณะของตัวแปรอิสระที่นำมาศึกษาด้วย โดยทำกิจกรรมการวิเคราะห์การถดถอย ในกรณี X เป็นตัวเดียวคือ $Y = \beta_0 + \beta_1 X_1 + \varepsilon$ พบร่วม

$$E(R^2) \approx \frac{\hat{\beta}_1^2 S_{XX}}{\hat{\beta}_1^2 S_{XX} + \sigma^2}, \quad S_{XX} = \sum_{i=1}^N (X_i - \bar{X})^2$$

$$\sigma^2 = \text{ความคลาดเคลื่อนในการประมาณ}$$

ซึ่งหมายถึงว่าค่า R^2 จะมีค่ามากหรือน้อยขึ้นกับ s_{xx} ถ้า s_{xx} มีค่ามากย่อมทำให้ R^2 มีค่ามาก ในทางกลับกัน s_{xx} มีค่าน้อย R^2 จะมีค่าน้อยด้วย เช่นในกรณีที่ x เป็นข้อมูลเชิงปริมาณที่มีหน่วยมาก กับ x ที่เป็นข้อมูลเชิงคุณภาพจะพบว่า R^2 ที่ได้จะมีความแตกต่างกัน ซึ่งแม้ว่า ตัวแปรอิสระทั้งสอง จะมีอิทธิพล ต่อค่า y เหมือน ๆ กัน แต่ให้ค่า R^2 ที่แตกต่างกัน

Rudolf J. Freund และ Paul D. Minton (1979) ในกรณีที่ตัวแปรอิสระไม่มีความลับพันธ์กับ y ค่า R^2 จะมีเพิ่มขึ้นได้ถ้าเพิ่มจำนวนตัวแปรอิสระเข้าไปในรูปแบบ เพราะว่า ค่า R^2 สามารถเขียนได้ในรูปแบบ

$$R^2 = \frac{MF}{MF+N-M-1}, \quad F = \frac{MSR}{MSE} = \frac{\text{mean square regression}}{\text{mean square error}}$$

ถ้า x ไม่มีความลับพันธ์กับ y ค่า F ควรมีค่าเข้าใกล้ 1 ดังนั้น R^2 จะมีค่ามาก หรือน้อยขึ้นกับ M ถ้าเพิ่มจำนวนตัวแปรอิสระเข้าไปย่อมทำให้ R^2 สูงได้ เพราะ M มีค่าเพิ่มขึ้น ในกรณีนี้ควรใช้ค่า R_1^2 (Adjusted- R^2) โดยที่

$$R_1^2 = 1 - \frac{(N-1)}{(N-M-1)} (1-R^2)$$

จากความลับพันธ์ระหว่าง R^2 กับ $s_{y.x}^2$ Thomas และ Ronald Wonnacott ได้แล้วด้วยความลับพันธ์ระหว่าง R_1^2 และ $s_{y.x}^2$ ไว้ดังนี้

$$\therefore R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}, \quad i = 1, 2, 3, \dots, N$$

$$1-R^2 = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$$

$$S_{Y \cdot X}^2 = \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{(N-M-1)}$$

$$\frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{(N-M-1)} = (1-R^2) \frac{\sum_{i=1}^N (Y_i - \bar{Y})^2}{(N-1)} \cdot \frac{(N-1)}{(N-M-1)}$$

$$S_{Y \cdot X}^2 = (1 - R^2) S_Y^2 \frac{(N-1)}{(N-M-1)}$$

$$R^2 = 1 - \frac{(1-R_1^2)}{N-M-1} \cdot \frac{(N-1)}{(N-M-1)}$$

$$\therefore s_{Y|X}^2 = (1-R_1^2) s_Y^2$$

$S_{v.x}^2$ គឺ mean square error of residual

S_y^2 គឺ mean square total

จากความสัมพันธ์ที่ได้ถ้า R_1^2 มีค่ามาก ค่า $S_{Y.X}^2$ มีค่าน้อย ซึ่งหมายถึงว่า X ที่เพิ่มเข้าไปมีความสัมพันธ์กับ Y จริง ในทำนองเดียวกัน ถ้า R_1^2 มีค่าน้อย ค่า $S_{Y.X}^2$ จะมีค่าเพิ่มขึ้นบ่อยมากยิ่งค่า X ที่เพิ่มเข้าไปไม่ได้มีผลต่อค่า Y ค่า R_1^2 มีข้อเสียก็คืออาจมีค่าเป็นลบได้ ถ้ารูปแบบของความสัมพันธ์ไม่เหมาะสม ดังนั้นในการถือค่าลักษณะประสิทธิภาพตัดสินใจ ติดลบก็ไม่สามารถนำไปปรับปรุงความหมายได้

ในทางปฏิบัติค่า R_1^2 ใช้เปรียบเทียบลักษณะการถดถอยเชิงพหุivar ลักษณะถดถอยเชิงพหุชปแบบใดที่
ใช้อธิบายลักษณะตัวแปรตามได้ดีกว่า เช่น ในกรณี จำนวนตัวแปรอิสระไม่เท่ากัน สามารถ
เปรียบเทียบลักษณะการถดถอยเชิงพหุโดยใช้ค่า R_1^2 ได้

Tarald O. Kvalseth (1985) ได้เล่นค่าล์สติส์มประสิทธิการตัดสินใจที่มีคุณสมบัติคงที่ (Resistance) Frederick Mosteller และ John W. Tukey (1977) ได้กล่าวถึงคุณสมบัติคงที่ว่าในกรณีที่มีข้อมูลผิดปกติ (outlier) ค่าล์สติได้ใจไม่ผลกระบวนการน่องมาจากการค่าผิดปกติ ค่าล์สตินั้นจะมีคุณสมบัติคงที่ ค่าล์สติส์มประสิทธิการตัดสินใจที่ Tarald O. Kvalseth เล่นอีก 2 ค่าด้วยกัน

ค่าล์สติส์มประสิทธิการตัดสินใจที่ใช้ค่ามัธยฐาน

$$R_2^2 = 1 - \frac{\text{Med} \frac{|y_i - \hat{y}_i|^2}{|y_i - \bar{y}|^2}}{\text{Med} \frac{|y_i - \bar{y}|^2}{|y_i - \bar{y}|^2}}, i = 1, 2, 3, \dots, N$$

Med = มัธยฐาน

ค่าล์สติส์มประสิทธิการตัดสินใจที่ใช้ค่ามัธยฐานและปรับค่า

$$R_3^2 = 1 - \frac{(N-1)}{(N-M-1)} \frac{\text{Med} \frac{|y_i - \hat{y}_i|^2}{|y_i - \bar{y}|^2}}{\text{Med} \frac{|y_i - \bar{y}|^2}{|y_i - \bar{y}|^2}}, i = 1, 2, 3, \dots, N$$

Med = มัธยฐาน

ค่า R_2^2 และ R_3^2 เป็นการศึกษาที่ปรับปรุงค่า R^2 โดยใช้มัธยฐานแทนการหาค่าเฉลี่ย

ทศมิย์ ช่างเก้า และล้มภพ ถาวรปิ่ง (2530) ได้กล่าวถึงประโยชน์ของ R^2 ไว้ดังนี้

2.1 ประโยชน์ของ R^2

2.1.1 ค่า R^2 เป็นเครื่องวัดความใกล้ชิดระหว่างเล้นทดสอบกับค่าของ \bar{Y} บนแผนภาพ การกระจายซึ่งหมายถึง

$R^2 = 1$ ค่า \bar{Y} จะอยู่บนเล้นทดสอบทุกจุด

R^2 มีค่ามาก \bar{Y} จะอยู่ใกล้ชิดกับเล้นทดสอบ

R^2 มีค่าน้อย \bar{Y} จะอยู่ห่างจากเล้นทดสอบ

R^2 มีค่าเท่ากับศูนย์ \bar{Y} จะกระจายต่างกันกับเล้นทดสอบมากจนหาแนวโน้มที่ถูกต้องไม่ได้

2.1.2 ค่า R^2 เป็นเครื่องวัดความเหมาะสมล้มของเล้นทดสอบว่าจะแลดูแนวโน้มของข้อมูลบนแผนภาพการกระจายได้มากน้อยเพียงใด ซึ่งหมายถึงถ้า

R^2 มีค่าใกล้เคียง 1 แลดูว่าแนวโน้มของข้อมูลจะเป็นลักษณะแนวเล้นตรงมากที่สุด

R^2 มีค่าใกล้เคียง 0 แลดูว่าแนวโน้มของข้อมูล มีลักษณะไม่เป็นเล้นตรง ซึ่งอาจเป็นเล้นโค้งก็ได้

2.1.3 ในทางปฏิบัติใช้ R^2 เป็นเครื่องแลดูอิทธิพลของตัวแปรอิสระ (X) ที่มีต่อตัวแปร (Y) ทั้งนี้ เพราะว่าจากค่า R^2 ที่คำนวณได้ จะบอกให้ทราบว่าการกระจายทั้งหมดของค่า Y สามารถอธิบายได้จากเล้นทดสอบกับเปอร์เซนต์ นั่นคือ อาจพูดได้อีกอย่างว่า ค่า R^2 นั้นเป็นค่า บอกให้ทราบว่าการกระจายของค่า Y ทั้งหมด นั้นจะสามารถอธิบายได้จากค่า X ได้กี่เปอร์เซนต์ หรือ X มีอิทธิพลต่อ Y กี่เปอร์เซนต์

2.2 การพิจารณาค่าผิดปกติ (outlier)

ถ้ามีค่าผิดปกติปนอยู่ภายในลักษณะของลักษณะเดียวกันว่า ค่าผิดปกตินั้นอาจมาจากการแตกแปรปนอยู่ เช่น ในข้อมูลชุดหนึ่งมีลักษณะเป็น a_i , $i = 1, 2, 3, \dots, N$ ที่อยู่ในการแจกแจง F ถ้ามีค่าผิดปกติ ลักษณะให้เป็นค่าที่มาจากการแตกแปร G และให้ความน่าจะเป็นที่เกิดการปนอยู่เป็น λ ดังนั้น a จะมีการแจกแจงแบบผสม (mixed distribution) โดยที่

$$a_i \in (1-\lambda) F + \lambda G, \quad i = 1, 2, 3, \dots, N \quad \text{ถ้า} \quad a_i \in \text{ค่าผิดปกติปนอยู่}$$

การทดสอบลักษณะจึงเป็น

$$H_0 : a_i \in F$$

$$H_a : a_i \notin (1-\lambda) F + \lambda G$$

Box และ Tiao (1968) ได้สรุปถึงการกำหนด λ และขนาดของ N ที่จะทำให้เกิดค่าผิดปกติค่าเดียว (single outlier) ว่าเมื่อ $N = 20$ λ ที่ใช้ควรมีค่าน้อย ๆ คือ 0.05 หรือบ่อยมากที่สุดไม่เกิน 0.10 ถ้า N มีค่ามากกว่านี้ค่า λ ที่ใช้ควรมีค่าน้อยมาก ๆ Guttman (1973) ได้พบว่า ถ้า λ มากการให้เกิดค่าผิดปกติค่าเดียว ค่า λ ที่ใช้ไม่จำเป็นต้องเป็นค่าน้อย แต่ไม่สามารถบอกได้ว่า λ ควรจะมีค่าเป็นเท่าใด จึงจะทำให้เกิดค่าผิดปกติค่าเดียว Vic Barnett และ Toby Lewis (1984) ได้สรุปว่า ถ้าต้องการที่จะให้ค่าผิดปกติค่าเดียว λ ควรมีค่าจะมีค่าน้อย ๆ

ตัวอย่างในการเลือกการแจกแจงผลลัม เช่น F มีการแจกแจงเป็น $N(\mu, \sigma^2)$ และ G เป็น $N(\mu, b\sigma^2)$, $b > 1$ ด้วยความน่าจะเป็น λ ($\lambda < 0.1$)

$$a_i \sim (1 - \lambda) N(\mu, \sigma^2) + \lambda N(\mu, b\sigma^2), i = 1, 2, 3, \dots, N$$

การกำหนดแบบนี้เป็นการกำหนดให้เกิดค่าผิดปกติที่เรียกว่า Scale-contaminated Normal distribution

2.3 การทดสอบค่าผิดปกติค่าเดียว

ในการวิเคราะห์การทดสอบโดยเชิงพหุจังหวะใช้ studentized residual

พิจารณาจาก

$$Y = X\beta + \varepsilon$$

$$\varepsilon \sim N(0, \sigma^2 I_N)$$

$$\hat{\beta} = (X'X)^{-1} X' Y$$

$$V(\hat{\beta}) = (X'X)^{-1} \sigma^2$$

$$\text{และ } \hat{\varepsilon} = Y - X\hat{\beta}$$

$$= (I_N - R) Y$$

$$= (I_N - R) \varepsilon$$

$$R = X(X'X)^{-1} X'$$

$$V(\hat{\varepsilon}) = (I_N - R) \sigma^2$$

$$V(\hat{\varepsilon}_j) = (1 - x_j'(X'X)^{-1} X_j) \sigma^2$$

$$= (1 - r_{jj}) \sigma^2 \text{ โดยที่ } x_j \text{ คือแอกว่าที่ } j \text{ ของ } x$$

ประมาณณาค่า σ^2 ด้วย $\hat{\sigma}^2$

$$\hat{\sigma}^2 = \frac{\hat{\epsilon}' \hat{\epsilon}}{(N-M-1)}$$

$$= \frac{\epsilon' (I_N - R) \epsilon}{(N-M-1)}$$

$$\text{ให้ } \hat{\epsilon}' \hat{\epsilon} = s^2$$

ประมาณ

$$V(\hat{\epsilon}) \text{ ด้วย } s^2(\hat{\epsilon})$$

$$s^2(\hat{\epsilon}) = (I_N - R) \hat{\sigma}^2$$

$$\text{ตัวประมาณ } V(\hat{\epsilon}_j) \text{ คือ } s_j^2$$

$$s_j^2 = (1 - r_{jj}) \hat{\sigma}^2$$

$$= (1 - r_{jj}) (\hat{\epsilon}' \hat{\epsilon}) / (N-M-1)$$

$$= (1 - r_{jj}) s^2 / (N-M-1)$$

Studentize residuals

$$e_j = \hat{\epsilon}_j / s_j$$

$$= \frac{\hat{\epsilon}_j}{s} \sqrt{\frac{(N-M-1)}{(1 - r_{jj})}}$$

จะพบค่าผิดปกติค่าเดียวที่มาจากการความปลอมปนถ้า

$$T = \max_j |e_j| > h \alpha, \quad j = 1, 2, 3, \dots, N$$

โดยที่ $h \alpha$ เป็นค่าที่ได้จากตารางของ Laund (1975) Vic Barnett และ Toby Lewis (1984)

Cook, Hol Schum และ Weisberg ได้ตรวจสอบค่าผิดปกติค่าเดียวที่เกิดจากการปลอมปนด้วยเล็กน้อย โดยที่ ϵ อยู่ในรูปเมตริกซ์ $\sigma^2(I_N + B)$ โดยที่ B เป็นเมตริกซ์ที่มีเพียงส่วนบน เปียงตัวเดียวในแนวทะแยง นอกนั้นเป็นศูนย์หมด พบว่าค่าสูงสุดของ Absolute Studentized residuals ไม่จำเป็นต้องเป็นค่าผิดปกติค่าเดียว นอกจักค่านั้น จะต้องให้ค่าสูงสุดของ absolute residual ด้วย

2.4 การลร้างการแจกแจงที่ไม่ล้มมาตรฐาน (Asymmetric Distribution)

Ramberge และ Sch meiser (1974) แนะนำการลร้างการแจกแจงที่ไม่ล้มมาตรฐานโดยใช้รีแปลงตัวแปรสุ่มที่มีการแจกแจงแบบยูนิฟอร์ม โดยใช้ตัวพารามิเตอร์ 4 ตัว เป็นตัวกำหนดค่าเฉลี่ย ตามแปรปรวน ความเบี้ย และความโด่ง ชื่นรีนี้เรียกว่า "Generalized Lamda Distribution" หรือ ชื่อย่อว่า GLD พงก์ษันที่ใช้ในการแปลงกำหนดตั้งนี้

$$x = R(p) = \lambda_1 + |\frac{\lambda_3}{p^3} - (1-p)^{\frac{\lambda_4}{4}}| / \lambda_2 ; \quad 0 \leq p \leq 1$$

โดยที่ $p =$ มีการแจกแจงแบบยูนิฟอร์มในช่วง $[0, 1]$

λ_3, λ_4 เป็นค่ากำหนดความเบี้ยและความโด่ง

λ_1, λ_2 เป็นค่ากำหนดค่าเฉลี่ยและความแปรปรวนคุณลักษณะ GLD

Ramberg และ Schmeiser ได้แสดงว่าโมเมนต์ที่ k ($\text{ที่ } \lambda_1 = 0$)

ของ GLD มีค่าเป็นดังนี้

$$E(X^k) = \lambda_2^{-k} \sum_{i=0}^k \binom{k}{i} (-1)^i \beta (\lambda_3(k-1)+1) \lambda_4 i + 1$$

โดย $\beta(m, n)$ คือ Beta function โมเมนต์ที่ k จะหาค่าได้
เมื่อ

$$-1/k < \min(\lambda_3, \lambda_4)$$

สำหรับค่าเฉลี่ย (μ) ความแปรปรวน (σ^2) ความเบ้ (α_3) และความ
โค้ง (α_4) Ramberg และ Schmeiser ได้แสดงไว้ดังนี้

$$\mu = \lambda_1 + A/\lambda_2$$

$$\sigma^2 = (B - A)^2 / \lambda_2^2$$

$$\mu_3 = (C - 3AB + 2A^3) / \lambda_2^3$$

$$\mu_4 = (D - 4AC + 6A^2B - 3A^4) / \lambda_2^4$$

$$\alpha_3 = \mu_3 / \sigma^2$$

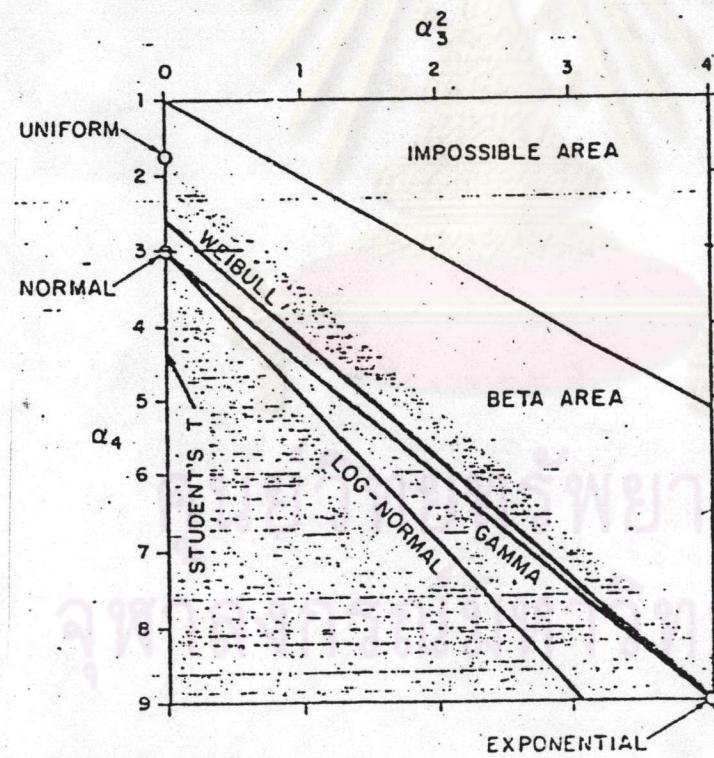
$$\alpha_4 = \mu_4 / \sigma^4$$

โดยที่ $A = \frac{1}{1+\lambda_3} = \frac{1}{1+\lambda_4}$

$$B = \frac{1}{1+2\lambda_3} + \frac{1}{1+2\lambda_4} - 2\beta(1+\lambda_3, 1+\lambda_4)$$

$$\begin{aligned}
 C &= \frac{1}{1+3\lambda_3} - 3(1+2\lambda_3, 1+\lambda_4) + 3\beta(1+\lambda_3, 1+2\lambda_4) \\
 &\quad - \frac{1}{1+3\lambda_4} \\
 D &= \frac{1}{1+4\lambda_3} - 4(1+3\lambda_3, 1+\lambda_4) + 6\beta(1+2\lambda_3, 1+2\lambda_4) \\
 &\quad - 4\beta(1+\lambda_3, 1+3\lambda_4) + \frac{1}{1+4\lambda_4}
 \end{aligned}$$

ค่าความเบ้และความโค้งของภาระแกนแบบ GLD ครอบคลุมพื้นที่ดังนี้



รูปที่ 1 Characterization of distributions by their third and fourth moments (the proposed distribution covers the screened region).

α_3 = ความเบ้

α_4 = ความโค้ง

จากรูปที่ 1 แล้วว่า ลักษณะภาระแกนแบบ GLD ประมาณ

การแกนแบบ Weibull Gramma Lognormal

และ Student's t แต่อย่างไรก็ตามไม่ลักษณะที่จะใช้

GLD สร้างภาระแกนที่มีความเบ้ และความโค้งตาม

ต้องการทุกกรณีได้

2.5 วิธีการสร้างการแจกแจงแบบ GLD

1. กำหนดค่า $\mu, \sigma^2, \alpha_3, \alpha_4$

2. หาค่า λ_3 และ λ_4 เพื่อให้ได้ค่า α_3, α_4 ตามที่ต้องการ

3. เมื่อทราบค่า λ_3 และ λ_4 แล้วจะหาค่า λ_2 เพื่อที่จะให้ได้ค่า σ^2 ตามที่กำหนด
ซึ่งมีสูตรในการหาดังนี้

$$\lambda_2 = \pm \left\{ \left[\frac{1}{(2\lambda_3 + 1)} - 2\beta (\lambda_3 + 1, \lambda_4 + 1) + \frac{1}{(2\lambda_4 + 1)} \right] \right.$$

$$\left. - \left[\frac{1}{(\lambda_3 + 1)} - \frac{1}{(\lambda_4 + 1)} \right]^2 \right\}^{1/2} / \sigma$$

4. คำนวณค่า λ_1 เพื่อที่จะได้ μ ตามที่ต้องการจากสูตร

$$\lambda_1 = \mu - \left[\frac{1}{(1+\lambda_3)} - \frac{1}{(1+\lambda_4)} \right] / \lambda_2$$

สำหรับค่า λ_3 และ λ_4 Ramberg และ Schmeiser ได้เล่นอเป็นตารางสำหรับกำหนด
ความเบ้และความโด่งบางค่า ต่อมาก็ Ramberg, Dudewicz, Ta dikamalla และ
Mykytka ได้เล่นอตารางกำหนดค่า $\lambda_1, \lambda_2, \lambda_3$ และ λ_4 สำหรับค่าเฉลี่ยความแปรปรวน
ความเบ้และความโด่ง ซึ่ค่าความเบ้และความโด่งจะเสียต่ำกว่าที่ Ramberg และ
Schmeiser เล่นไว้

2.6 การเลือกตัวอย่าง

ในการเลือกตัวอย่างที่มีประชากรขนาดจำกัด (Finite Population) ถ้าต้องการ
ลุ่มตัวอย่างขนาด n สามารถทำได้โดยลุ่มตัวอย่างแบบลำดับ (Sequential Sampling) William
J. Kenedy Jr. และ James E. Gentle (1980) ได้เล่นของการเลือกตัวอย่างแบบลำดับที่
มีประสิทธิภาพคือ การเลือกตัวอย่างแบบลำดับที่ไม่ได้ไล่ศั่น (Sequential Sampling
without replacement)

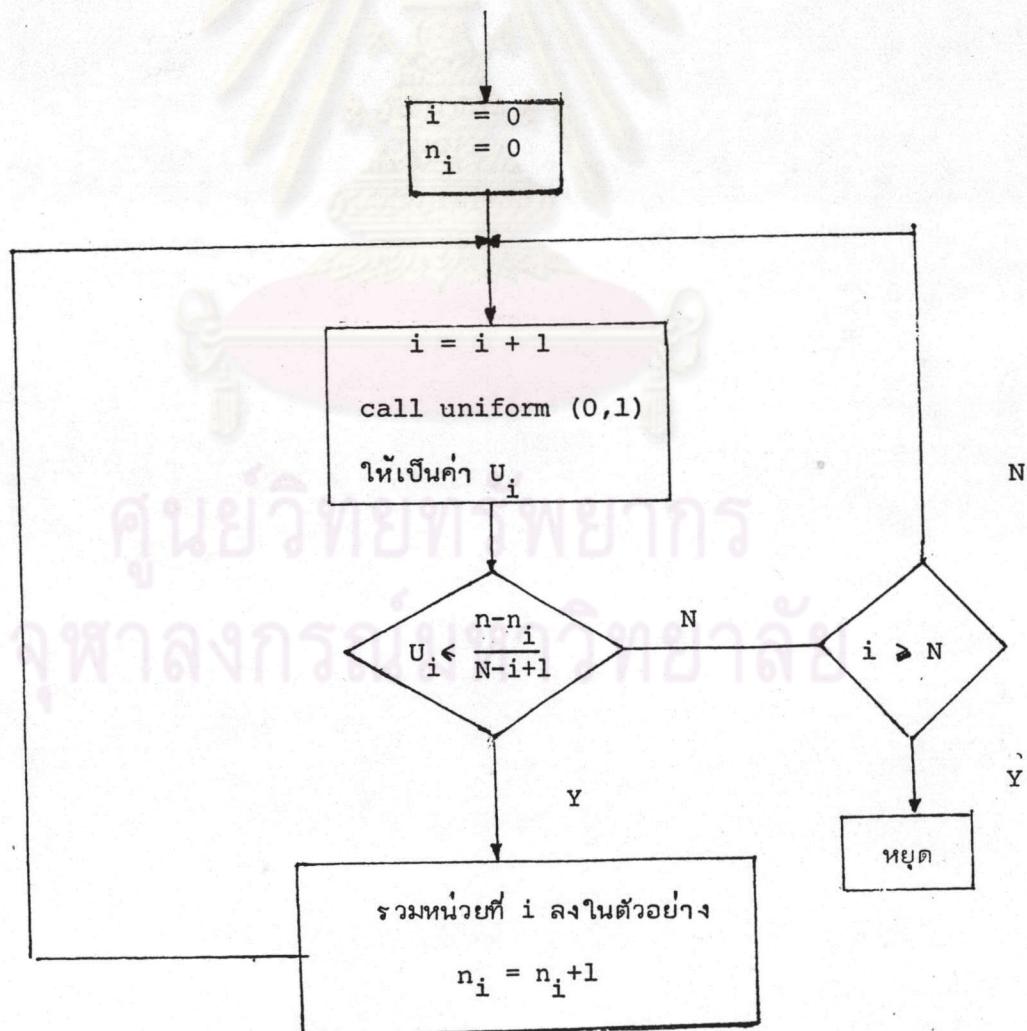
วิธีการสือ

1. ให้หมายเลขแต่ละหน่วยของประชากรเป็นหมายเลข $i = 1, 2, 3, \dots, N$
2. ให้แต่ละหน่วยในประชากรถูกเลือก ด้วยความน่าจะเป็นสือ

$$P(\text{หมายเลข } i \text{ ที่จะถูกเลือก}) = \begin{cases} \frac{n-n_i}{N-i+1} & , n \leq n_i \\ 0 & , \text{ ทึ่ง ๆ } \end{cases}$$

n_i คือจำนวนหน่วยทั้งหมดที่ถูกเลือกเข้ามาในตัวอย่างก่อนถึงหมายเลขที่ i

ผังการเลือกตัวอย่าง



2.7 การหาค่า Mean Square Error และ Relative Mean Square Error

ในการพิจารณาคุณภาพของตัวประมาณ มักจะพบว่าคุณลักษณะบางประการไม่เหมือนกัน เช่นความไม่แน่เรียงของตัวประมาณ กับความคลาดเคลื่อนต่างๆของตัวประมาณ

ถ้า $\hat{\theta}$ เป็นตัวประมาณของพารามิเตอร์ θ ความคลาดเคลื่อนก็สังล่องเฉลี่ยหรือ MSE ของ $\hat{\theta}$ คือ

$$\begin{aligned} \text{MSE} &= E(\hat{\theta} - \theta)^2 \\ &= V(\hat{\theta}) + (\text{Bias})^2 \\ &= V(\hat{\theta}) + [E(\hat{\theta}) - \theta]^2 \end{aligned}$$

ตัวประมาณ $\hat{\theta}$ เป็นตัวประมาณที่มีความคลาดเคลื่อนก่อสังล่องเฉลี่ยต่างๆ ถ้า θ มีค่า $E(\hat{\theta} - \theta)^2$ ต่างๆกันหรือ

$$\text{MSE} = \sum_{i=1}^n \frac{(\hat{\theta}_i - \theta)^2}{n}$$

2.8 การหาค่า Relative Mean Square Error

ค่า Relative Mean Square Error A เทียบกับ B

หมายถึง

MSE ของ A

MSE ของ B