



ตัวลัดิตและผลงานวิจัยที่เกี่ยวข้อง

การศึกษาวิธีการตรวจสอบค่าผิดปกติ และอิทธิพลของค่าสังเกต ในสมการการถดถอยเชิงเส้นพหุ ในงานวิจัยครั้งนี้ เป็นการศึกษาความน่าจะเป็นความคลาดเคลื่อนประเภทที่ 1 และอำนาจการทดสอบของตัวลัดิตทดสอบ ทั้ง 3 วิธี คือ วิธีของ จีแบร์รี่ วิธีของค็อก วิธีของแอนดรูและเพรตลิปอน โดยศึกษา 2 กรณีคือ กรณีที่ค่าผิดปกติมี 1 ค่าและกรณีที่ค่าผิดปกติมี 2 ค่า ซึ่งจะกล่าวรายละเอียดต่อไป

ในการศึกษาสมการการถดถอยเชิงเส้นพหุ

$$Y_{(n \times 1)} = X_{(n \times p)} \beta_{(p \times 1)} + \epsilon_{(n \times 1)}$$

โดยที่

Y เป็นเวกเตอร์ของตัวแปรตามที่มีขนาด $n \times 1$

X เป็นเมตริกซ์คองที่ของตัวแปรอิสระที่มีขนาด $n \times p$ และมี $\text{rank} = p$

β เป็นเวกเตอร์ของสัมประสิทธิ์การถดถอยที่ไม่ทราบค่าและมีขนาด $p \times 1$

ϵ เป็นเวกเตอร์ของความคลาดเคลื่อนที่มีขนาด $n \times 1$

$$E(\epsilon) = 0, V(\epsilon) = \sigma^2 I_n, \text{COR}(\epsilon_i, \epsilon_j) = 0, i \neq j$$

การประมาณค่าสัมประสิทธิ์การถดถอย โดยวิธีกำลังสองน้อยที่สุด จะได้ว่า

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

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

เมื่อ $H_{(n \times n)} = X(X^T X)^{-1} X^T$ เรียกว่า แฮทเมตริกซ์ (hat matrix)
ซึ่งมีบทบาทสำคัญ ในการศึกษาค่าผิดปกติ และอิทธิพลของค่าสังเกต ความคลาดเคลื่อน

$$\begin{aligned} R_i &= \hat{Y}_i - Y_i \\ &= Y_i - X(X^T X)^{-1} X^T Y_i = (I - H) Y_i \end{aligned}$$

ความแปรปรวนของความคลาดเคลื่อน คือ

$$V(R_i) = (I - H) s^2$$

ความแปรปรวนของความคลาดเคลื่อนที่ค่าสังเกต i คือ

$$V(R_{i_i}) = (1 - h_{ii}) s^2_{(i)}$$

เมื่อ h_{ii} เป็นสมาชิกแนวทแยงของ H

s^2 เป็นตัวประมาณที่ไม่เอนเอียงของ σ^2

ความคลาดเคลื่อนมาตรฐาน คือ

$$t_i = \frac{R_i}{s \sqrt{1 - h_{ii}}}$$

ในการศึกษาค่าผิดปกติ ค่าความคลาดเคลื่อนมาตรฐาน เป็นตัวสำคัญในการบ่งชี้ค่าผิดปกติของวิธีซีแบร์รี่และวิธีของคู๊ก

2.1 การคำนวณค่าแฮทเมตริกซ์

ในการศึกษาลมการการถดถอยเชิงเส้นพหุ เพื่อสะดวกในการคำนวณและประหยัดเวลาการคำนวณจะทำการแปลงตัวแปรอิสระ เป็นเมตริกซ์ตั้งฉาก (orthogonal matrix) โดยวิธี โคลลัมบี้ (Graybill 1976:229) ซึ่งจะทำให้ตัวแปรอิสระเป็นอิสระกัน การทำให้ตัวแปรอิสระตั้งฉากกันมีขั้นตอนดังนี้

ให้

$$A = X^T X = U^T U$$

$$\begin{bmatrix} A_{11} & A_{12} & \dots & A_{1p} \\ A_{21} & A_{22} & \dots & A_{2p} \\ \vdots & \vdots & & \vdots \\ A_{p1} & A_{p2} & \dots & A_{pp} \end{bmatrix} = \begin{bmatrix} u_{11} & 0 & 0 & \dots & 0 \\ u_{21} & u_{22} & 0 & \dots & 0 \\ \vdots & \vdots & & & \vdots \\ u_{p1} & u_{p2} & u_{p3} & \dots & u_{pp} \end{bmatrix} \begin{bmatrix} u_{11} & u_{12} & u_{13} & \dots & u_{1p} \\ 0 & u_{22} & u_{23} & \dots & u_{2p} \\ \vdots & \vdots & \vdots & & \vdots \\ 0 & 0 & 0 & \dots & u_{pp} \end{bmatrix}$$

สมาชิกของเมตริกซ์ U มีขั้นตอนการคำนวณ คือ

- 1) หาลำสมาชิกแถวที่ 1 คอลัมน์ที่ 1 ของเมตริกซ์โดย

$$u_{11} = \sqrt{A_{11}}$$

- 2) หาลำสมาชิกแถวที่ 1 คอลัมน์ 2 ถึงคอลัมน์ที่ p ของเมตริกซ์ U โดย

$$u_{1j} = \frac{A_{1j}}{u_{11}} = \frac{A_{1j}}{\sqrt{A_{11}}} \quad j = 2, 3, \dots, p$$

- 3) หาลำสมาชิกบนเส้นทะแยงมุม (diagonal) ของเมตริกซ์โดย

$$u_{ii} = \sqrt{A_{ii} - \sum_{p=1}^{i-1} u_{pi}^2} \quad i = 2, 3, \dots, p$$

4) หาลำมาชิกที่เหลือของ เมตริกซ์ 'U' โดย

$$u_{ij} = \frac{1}{u_{ii}} \left[A_{ij} - \sum_{p=1}^{i-1} u_{pi} \cdot u_{pj} \right] \quad j > i \text{ และ } i = 2, 3, \dots, p-1$$

$$u_{ij} = 0 \quad j < i \text{ และ } i = 2, 3, \dots, p$$

จากนั้นตัวแปรอิสระ ที่ถูกทำให้ตั้งฉากจะมีความแปรปรวนเดียวกัน แล้วนำมาแปลงให้อยู่ในรูปใหม่โดย

$$Q = X U^{-1}$$

$$\text{ดังนั้นการคำนวณ } H = X(X^T X)^{-1} X^T = Q Q^T$$

2.2 วิธีการตรวจสอบวิธีของซีแบร์รี่

วิธีการตรวจสอบค่าผิดปกติ ของวิธีซีแบร์รี่ เป็นการตรวจสอบค่าผิดปกติในกรณีที่ค่าผิดปกติและค่าอิทธิพล มี 1 ค่าหรือมากกว่าหนึ่งค่า ซึ่งเสนอโดย ซี แบร์รี่ (G. Barrie Wetherill - 1986) โดยมีหลักเกณฑ์คือ ค่าความคลาดเคลื่อนมาตรฐานเป็นตัวบ่งชี้ค่าผิดปกติ ถ้าค่าความคลาดเคลื่อนมาตรฐานมีค่าสูงมาก แสดงว่า ตัวแปรตาม Y เป็นค่าผิดปกติ ทำการตรวจสอบทีละค่า ตัวสถิติที่ทดสอบ คือ $d_i = \frac{t_i^2}{n-p}$ ซึ่งมีขั้นตอนการคำนวณดังนี้

- 1) คำนวณค่าความคลาดเคลื่อนมาตรฐาน t_i
- 2) เลือกค่าความคลาดเคลื่อนมาตรฐาน t_i ที่มีค่าสูงสุด $t = \max |t_i|$
- 3) ทำการตรวจสอบค่าสังเกตที่ตรงกับ t ว่าเป็นค่าผิดปกติ จากสมมติฐาน

$$H_0 : E(Y) = X\beta$$

$$H_a : E(Y) = X\beta + d$$

ตัวสถิติทดสอบ

$$d_i = \frac{t_i^2}{n-p}$$

ซึ่ง d_i เป็นตัวสถิติที่มีการแจกแจงเบต้า ที่มีพารามิเตอร์เป็น

$$\left(\frac{1}{2}, \frac{n-p-1}{2}\right)$$

4) นำค่า d_i เปรียบเทียบกับค่าขอบเขตวิกฤต จากตาราง Lund (1975):

ซึ่งมีความสัมพันธ์ คือ

$$t_o = \sqrt{(n-p) d_o}$$

เกณฑ์การตัดสินใจ : ถ้า $d_i > d_o$ ปฏิเสธสมมติฐาน H_o

แสดงว่า ค่าสังเกตที่ i เป็นค่าผิดปกติ

5) ในกรณีที่ปฏิเสธ H_o จะตัดค่าสังเกตที่ตรงกับค่า t แล้ววิเคราะห์ข้อมูลขนาด $n-1$ เช่นเดียวกับข้อ 1-4

2.3 วิธีการตรวจสอบวิธีของค็อก

วิธีการตรวจสอบค่าผิดปกติ และอิทธิพลของค่าสังเกต วิธีของค็อก เสนอโดย อาร์ เดนนิส ค็อก (R. Dennis Cook 1977 1979 1980) โดยมีหลักเกณฑ์ คือ ค่าผิดปกติย่อมมีอิทธิพลต่อสัมประสิทธิ์การถดถอยโดยตรง เมื่อพิจารณาผลต่างของกำลังสองค่าสัมประสิทธิ์การถดถอยจากข้อมูลขนาด n ($\hat{\beta}$) กับสัมประสิทธิ์การถดถอยจากข้อมูล $n-1$ ($\hat{\beta}_{(i)}$) ถ้าค่าสังเกตที่ตัดไปมีผลต่อสัมประสิทธิ์การถดถอยมาก แสดงว่าค่าสังเกตนั้นย่อมเป็นค่าผิดปกติ

ตัวสถิติที่ทดสอบคือ

$$C_i = \frac{(\hat{\beta}_{(i)} - \hat{\beta})^T X^T X (\hat{\beta}_{(i)} - \hat{\beta})}{ps^2} \quad (2.3.1)$$



เมื่อ $\hat{\beta}$ เป็นสัมประสิทธิ์การถดถอยที่ได้จากการประมาณค่าข้อมูลขนาด n

$\hat{\beta}_{(i)}$ เป็นสัมประสิทธิ์การถดถอยที่ได้จากการประมาณค่าข้อมูลขนาด $n-1$

จากสมการ (2.3.1) สามารถเขียนใหม่ได้เป็น

$$C_i = \frac{t_i^2}{p} \cdot w_i \quad \text{เมื่อ} \quad w_i = \frac{h_{ii}}{1-h_{ii}} \quad (2.3.2)$$

(การพิสูจน์ดูจากภาคผนวก)

ตัวสถิติ C_i มีการแจกแจงแบบเอฟ (Cook R.D. : 1980) ที่มีดีกรีแห่งความอิสระเป็น $(1, n-p-1, \alpha)$ ในการตรวจสอบสมมติฐาน $H_0 : E(y) = X\beta$

ตัวสถิติที่คำนวณคือ

$$F = \frac{t_i^2 (n-p-1)}{(n-p-t_i^2)} \quad (2.3.3)$$

นำมาเปรียบเทียบกับค่าวิกฤต $F_{(1, n-p-1, \alpha)}$ ในการคำนวณมีขั้นตอนคือ

- 1) คำนวณค่า t_i
- 2) เลือกค่า $t = \max |t_i|$
- 3) คำนวณค่าสถิติ F จากสมการ (2.3.3)
- 4) เปรียบเทียบค่า F กับ $F_{(1, n-p-1)}$ ซึ่งมีเกณฑ์การพิจารณาดังนี้
ปฏิเสธ H_0 : เมื่อ $F > F_{(1, n-p-1)}$
- 5) ในกรณีที่ปฏิเสธ จะทำการลบค่าสังเกตที่ตรงกับ t_i แล้วคำนวณค่าสถิติเช่นเดียวกับ ข้อ 1 - 4

2.4 วิธีการตรวจสอบของแอนดรูว์และเพรตจิบอน

เดวิด เอฟ แอนดรูว์ และ ดาร์ลิส เพรตจิบอน เล่นอในปี พ.ศ. 2521

(David F. Andrews & Daryl Pregibon : 1978) โดยพิจารณาจากหลักการที่ว่า ค่าสังเกตใดมีผลต่อค่าดีเทอร์มิแนนต์ของ $X^T X$ ($|X^T X|$) มากหรือน้อย เมื่อลบค่าสังเกตนี้ออกไป ย่อมมีผลต่อการเปลี่ยนแปลงค่าดีเทอร์มิแนนต์มากหรือน้อยตามลำดับ ซึ่งนำมารวมกับแนวคิดที่ว่า ค่าผิดปกติย่อมมีผลต่อผลบวกกำลังสองของความคลาดเคลื่อนลดลง เมื่อลบค่าผิดปกติสามารถแสดงความสัมพันธ์ในรูปสมการ

$$X^{*T} X^* = \text{RSS } X |X^T X| \quad (2.4.1)$$

$$X^*(n \times (p+1)) = (X : y) \text{ เป็นเมตริกซ์อิสระที่เพิ่มคอลัมน์เวกเตอร์}$$

ของตัวแปรตาม y ซึ่งมี $\text{rank} = p + 1$

ตัวสถิติของแอนดรูว์และเพรตจิบอน คือ

$$R_{ij..}^{(k)}(X^*) = \frac{D_{ij..}^{(k)} X^{*T} X^*}{X^{*T} X^*} \quad (2.4.2)$$

$D_{ij..}^{(k)}(*)$ หมายถึง กรณีที่ลบค่าสังเกต ที่ $i, j..$ จำนวน k ค่า

$\bar{D}_{ij..}^{(k)}(*)$ หมายถึง คอมพลีเมนต์ของ $D_{ij..}^{(k)}(*)$

ในการคำนวณค่าสถิติวิธีของแอนดรูว์และเพรตจิบอน อาศัยคุณสมบัติของเมตริกซ์ และดีเทอร์มิแนนต์ คือ

$$X^{*T} X^* = D_i^{(1)} (X^{*T} X^*) + \bar{x}_i^{*T} \bar{x}_i^*$$

สามารถคำนวณค่า $R_{ij..}^{(k)}(X^*)$ ได้จาก

1) กรณี $k > 1$

$$R_{ij}^{(k)} = \bar{D}_{ij..}^{(k)} \left| w^* \right| \quad (2.4.3)$$

2) กรณี $k = 1$

$$R_i^{(1)} = w_{ii}^* \quad (2.4.4)$$

$$\begin{aligned} \text{เมื่อ } w^* &= I - X^* (X^{*T} X^*)^{-1} X^{*T} \\ &= I - Q^* Q^{*T} \end{aligned}$$

(การพิสูจน์ดูจากภาคผนวก)

การคำนวณตัวสถิติทดสอบ วิธีของแอนดรูและเพรตลิบอน มีขั้นตอนการคำนวณดังนี้

- 1) คำนวณค่า $R_i^{(k)}$ โดยคำนวณจากสมการ (2.4.3) และ (2.4.4)
- 2) เลือก $R_{ij..}^{(k)} (X)^*$ ที่มีค่าต่ำสุด
- 3) คำนวณค่า $R_{ij..}^{(k)} (X)$ (คำนวณเฉพาะค่าของตัวแปรอิสระ)
- 4) คำนวณค่าความน่าจะเป็นที่แน่นอน (Exact probability) : α_k
- 5) นำค่า α_k เปรียบเทียบกับค่าระดับนัยสำคัญที่กำหนด (α) ซึ่งกำหนด 3 ระดับ คือ $\alpha = 0.01 \quad 0.05 \quad 0.10$
- 6) เกณฑ์การตัดสินใจ : จากสมมติฐาน

H_0 : ค่าสังเกตที่ k เป็นค่าผิดปกติ

H_a : ค่าสังเกตที่ k ไม่เป็นค่าผิดปกติ

ปฏิเสธ H_0 : เมื่อ $\alpha_k < \frac{\alpha}{2}$