

ตัวสถิติและผลงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงการประมาณค่าสัมประสิทธิ์การถดถอยของตัวแบบการถดถอยเชิงเส้นด้วยวิธีกำลังสองน้อยที่สุด วิธีวิธีจีเรสชันและการประมาณ ridge estimators ในกรณีที่ค่าความคลาดเคลื่อนมีการแจกแจงแบบเบ้จะทำการแปลงข้อมูลโดยการแปลงที่ใช้การยกกำลัง (power transformation) ของ Box และ Cox เพื่อแปลงข้อมูลให้มีการแจกแจงเข้าใกล้ภาวะปกติเสียก่อน ซึ่งรายละเอียดต่าง ๆ มีดังนี้

2.1 ตัวแบบทั่วไป

ตัวแบบทั่วไปของการวิเคราะห์การถดถอยเชิงเส้นสามารถเขียนได้ดังนี้

$$(2.1.1) \quad y = X\beta + \epsilon$$

- เมื่อ y เป็นเวกเตอร์ของตัวแปรตามขนาด $n \times 1$, n คือจำนวนค่าสังเกต
 - X เป็นเมทริกซ์ของตัวแปรอิสระขนาด $n \times (p+1)$, $p =$ จำนวนตัวแปรอิสระ $- 1$
 - β เป็นเวกเตอร์ของพารามิเตอร์ที่ไม่ทราบค่าขนาด $(p+1) \times 1$
 - ϵ เป็นเวกเตอร์ของความคลาดเคลื่อน ขนาด $n \times 1$ ซึ่งมีการแจกแจงแบบปกติ
- โดยที่ $E(\epsilon) = 0$, $E(\epsilon\epsilon') = \sigma^2 I_n$

จากตัวแบบ (2.1) ประมาณค่าพารามิเตอร์ β ด้วยวิธีกำลังสองน้อยที่สุดจะได้ค่าประมาณ

$$(2.1.2) \quad \hat{\beta} = (X'X)^{-1}X'y$$

ซึ่งการประมาณ $\hat{\beta}$ โดยวิธีนี้จะได้อัตราประมาณ $\hat{\beta}$ ที่มีคุณสมบัติไม่เอนเอียง กล่าวคือ

$$\begin{aligned} E(\hat{\beta}) &= E[(X'X)^{-1}X'Y] \\ &= E[(X'X)^{-1}X'(X\beta + \epsilon)] \\ &= E[(X'X)^{-1}X'X\beta + (X'X)^{-1}X'\epsilon] \\ &= E[\beta] + (X'X)^{-1}X'E[\epsilon] \\ &= \beta \end{aligned}$$

ตัวประมาณ $\hat{\beta}$ จะให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองน้อยที่สุดในบรรดาตัวประมาณที่ไม่เอนเอียง แต่ในการประมาณค่า β ด้วยวิธีกำลังสองน้อยที่สุดมีข้อสมมุติฐานที่จำเป็นข้อหนึ่งคือ ตัวแปรอิสระต้องไม่มีความสัมพันธ์กันซึ่งในทางปฏิบัติเป็นไปได้น้อย ในกรณีที่ตัวแปรอิสระมีความสัมพันธ์กันคือมีสภาพไม่เหมาะสม (ill-condition) การประมาณค่า $\hat{\beta}$ ด้วยวิธีกำลังสองน้อยที่สุดอาจจะไม่ให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำสุด ในการพิจารณาผลของตัวแปรอิสระที่มีพหุสัมพันธ์กันสามารถพิจารณาจากคุณสมบัติ 2 ข้อของตัวประมาณค่า $\hat{\beta}$ กล่าวคือ เมตริกซ์ความแปรปรวนของตัวประมาณ $\hat{\beta}$ และค่าเฉลี่ยกำลังสองของความแตกต่างระหว่าง $\hat{\beta}$ และ β ซึ่งสามารถเขียนให้อยู่ในรูปของ $X'X$ และ σ^2 * ได้ดังนี้

$$(2.1.3) \quad \text{Var}(\hat{\beta}) = \sigma^2 (X'X)^{-1}$$

ให้ L_1 คือความแตกต่างของ $\hat{\beta}$ และ β ดังนั้น

* ในกรณีที่ตัวแปรอิสระมีพหุสัมพันธ์กันจะมีผลทำให้ $|X'X|$ เข้าใกล้ศูนย์ ซึ่งมีผลทำให้ $\text{Var}(\hat{\beta})$ มากเพราะ $\text{Var}(\hat{\beta}) = \sigma^2 (X'X)^{-1}$ และค่าเฉลี่ยกำลังสองของความแตกต่างระหว่าง $\hat{\beta}$ และ $\beta [E(L_1^2)]$ มากเพราะ $E(L_1^2) = \sigma^2 \text{trace}(X'X)^{-1}$

$$(2.1.4) \quad L_1^2 = (\hat{\beta} - \beta)' (\hat{\beta} - \beta)$$

ค่าเฉลี่ยกำลังสองของความแตกต่างระหว่าง $\hat{\beta}$ และ β มีค่าเป็น

$$(2.1.5) \quad \begin{aligned} E[L_1^2] &= \sigma^2 \text{trace}(X'X)^{-1} \\ E[L_1^2] &= E[(\hat{\beta} - \beta)' (\hat{\beta} - \beta)] \\ &= E[\hat{\beta}' \hat{\beta}] - \beta' \beta \end{aligned}$$

$$(2.1.6) \quad E[\hat{\beta}' \hat{\beta}] = \beta' \beta + \sigma^2 \text{trace}(X'X)^{-1}$$

เมื่อ β มีการกระจายแบบปกติ จะได้ว่า

$$(2.1.7) \quad \text{Var}(L_1^2) = 2\sigma^4 \text{trace}(X'X)^{-2}$$

ให้ λ_i เป็น eigenvalue ของ $X'X$ เมื่อ $i = 1, 2, \dots, p$ เมื่อ p คือ จำนวนตัวแปรอิสระ

$$\sum_{i=1}^p \lambda_i = \text{Trace}(X'X)$$

โดยที่ $(\lambda_{\max} = \lambda_1) \gg \lambda_2 \gg \lambda_3 \gg \dots \gg (\lambda_p = \lambda_{\min}) \gg 0$

จากสมการ(2.1.5)และ(2.1.7)จะได้ว่า

$$E[L_1^2] = \sigma^2 \sum_{i=1}^p (1/\lambda_i)$$

$$\text{Var}[L_1^2] = 2\sigma^4 \sum_{i=1}^p (1/\lambda_i)^2$$

ในกรณีที่ตัวแปรอิสระมีสภาพไม่เหมาะสมกล่าวคือ eigenvalue บางค่าของเมตริกซ์

$X'X$ จะมีค่าน้อยมากๆ ซึ่งมีผลทำให้ความแตกต่างระหว่าง $\hat{\beta}$ และ β มีมาก

2.2 การประมาณค่าสัมประสิทธิ์การถดถอยหุโดยวิธีคิดจรีเกรสชัน

Hoerl และ Kennard (1970:55-67) ได้เสนอวิธีคิดจรีเกรสชันเพื่อแก้ปัญหา multicollinearity ซึ่งวิธีนี้จะให้ค่าประมาณสัมประสิทธิ์การถดถอยหุที่ให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำลง หลักการทั่วไปของวิธีนี้คือเมื่อพบว่า $|X'X|$ มีค่าเข้าใกล้ศูนย์ซึ่งมีผลทำให้ $(X'X)^{-1}$ หาค่าไม่ได้ ทำให้ผลบวกกำลังสองของ $\hat{\beta}$ มีค่ามากผิดจากความเป็นจริง ดังนั้นจึงพยายามทำให้ $|X'X|$ เพิ่มขึ้นโดยการบวกค่าคงที่ k ที่มากกว่าศูนย์เข้ากับสมาชิกทุกตัวบนเส้นทแยงมุม ซึ่งจะช่วยให้ characteristic root มีค่ามากขึ้นและผลบวกกำลังสองของ $\hat{\beta}$ ลดลง

กำหนดให้ค่าประมาณ $\hat{\beta}$ ด้วยวิธีกำลังสองน้อยที่สุดและวิธีคิดจรีเกรสชันมีค่าเป็น $\hat{\beta}$ และ $\hat{\beta}^*$ ตามลำดับ โดยที่

$$(2.2.1) \quad \hat{\beta}^*(k) = [X'X + kI]^{-1} X'y \quad ; k > 0$$

และ $[X'X + kI]^{-1} = W$ ดังนั้นจากสมการ (2.2.1) จะได้ว่า

$$(2.2.2) \quad \hat{\beta}^*(k) = WX'y$$

เราสามารถจัดตัวประมาณค่า $\hat{\beta}^*(k)$ ให้อยู่ในรูปของ $\hat{\beta}$ ได้ดังนี้

$$(2.2.3) \quad \hat{\beta}^*(k) = [I + k(X'X)^{-1}]^{-1} \hat{\beta}$$

$$(2.2.4) \quad = Z\hat{\beta}$$

โดยที่ $Z = [I + k(X'X)^{-1}]^{-1}$

ให้ $E_1(W)$ และ $E_1(Z)$ เป็นค่า eigenvalue ของ W และ Z ตามลำดับ ซึ่งได้จากการแก้สมการ characteristic equation

$$|W - E_1 I| = 0$$

$$\text{และ } |Z - E_1 I| = 0$$

$$(2.2.5) \quad E_1(W) = 1/(\lambda_1 + k)$$

$$(2.2.6) \quad E_1(Z) = \lambda_1/(\lambda_1 + k)$$

เราอาจเขียน Z ให้อยู่ในรูปฟังก์ชันของ W ได้ดังนี้

$$(2.2.7) \quad \begin{aligned} Z &= I - k(X'X + kI)^{-1} \\ &= I - kW \end{aligned}$$

จากสมการ (2.2.3) ผลบวกกำลังสองของ $\hat{\beta}(k)$ จะมีค่าน้อยกว่าผลบวกกำลังสองของ $\hat{\beta}$ เมื่อ $k > 0$ กล่าวคือ

$$(2.2.8) \quad \hat{\beta}'(k)\hat{\beta}(k) < \hat{\beta}'\hat{\beta}$$

เราสามารถพิสูจน์ข้อความข้างบนได้ดังนี้

จากนิยาม : $\hat{\beta}(k) = Z\hat{\beta}$ โดยที่ $X'X$ และ Z มีคุณสมบัติเป็นเมตริกซ์สมมาตรที่เป็นบวกแน่นอน (symmetric positive definite) จะได้ว่า

$$(2.2.9) \quad \begin{aligned} \hat{\beta}'(k)\hat{\beta}(k) &= (Z\hat{\beta})'(Z\hat{\beta}) \\ &= \sum_{i=1}^p E_1^2(Z)\hat{\beta}'\hat{\beta} \\ &< E_{1, \max}^2(Z)\hat{\beta}'\hat{\beta} \end{aligned}$$

เมื่อ $E_{\max}(Z) = \lambda_1/(\lambda_1 + k)$; λ_1 เป็น eigenvalue ที่มีค่ามากที่สุดของเมตริกซ์ $X'X$ ดังนั้น

$$\hat{\beta}'(k)\hat{\beta}(k) < \hat{\beta}'\hat{\beta}$$

โดยที่ $\hat{\beta}(k)$ มีคุณสมบัติดังนี้

ให้ $\hat{\beta}(k)$ คือ ridge regression estimators ของ β จากสมการนอร์มอล

$$(X'X + kI)\beta = X'y$$

โดยที่ k เป็นตัวคงที่ใดๆที่ไม่ติดลบคือ $0 \leq k < 1^{**}$ และ $\hat{\beta}(k)$ จะมีค่าเท่ากับ $\hat{\beta}$ เมื่อ $k = 0$ และเมื่อ k มีค่าสูงขึ้น $\hat{\beta}(k)$ จะมีค่าลดลงเมื่อ $k \rightarrow \infty$ แล้ว $\hat{\beta}'(k)\hat{\beta}(k) \rightarrow 0$

$\hat{\beta}(k)$ เป็นการแปลงเชิงเส้น (linear transformation) ของตัวประมาณกำลังสองน้อยที่สุด กล่าวคือ

$$\begin{aligned}\hat{\beta}(k) &= (X'X + kI)^{-1}X'y \\ &= (X'X + kI)^{-1}(X'X)(X'X)^{-1}X'y \\ &= (X'X + kI)^{-1}X'X[(X'X)^{-1}X'y] \\ &= [I + k(X'X)^{-1}]^{-1}\hat{\beta}\end{aligned}$$

โดยที่ $\hat{\beta}(k)$ สัมพันธ์กับ $\hat{\beta}$ ในลักษณะที่ว่า $\hat{\beta}(k) = [I + k(X'X)^{-1}]^{-1}\hat{\beta}$ และเมื่อ $k=0$ จะได้ว่า $\hat{\beta}(k) = \hat{\beta}$ กล่าวคือ ตัวประมาณกำลังสองน้อยที่สุดเป็นกรณีเฉพาะของริดจ์รีเกรสชัน เมื่อ

^{**} ในกรณีที่ standardized variable จะได้ว่าเมตริกซ์ $X'X$ ก็คือ correlation matrix ซึ่งสมาชิกในแนวทแยงมุมจะมีค่าอยู่ระหว่าง 0 ถึง 1 ดังนั้นจึงทำการปรับค่าเมตริกซ์ $X'X$ ในกรณีเกิดปัญหา multicollinearity ด้วยการบวกค่าคงที่ k ; $0 < k < 1$

$k = 0$ แต่ $\hat{\beta}(k)$ เป็นตัวประมาณที่เอนเอียงของ β โดยที่

$$\begin{aligned}
 E(\hat{\beta}(k)) &= E(Z\hat{\beta}) = Z\beta = \beta \\
 \text{และ} \quad \text{Cov}(\hat{\beta}(k)) &= E[\hat{\beta}(k) - E(\hat{\beta}(k))][\hat{\beta}(k) - E(\hat{\beta}(k))]^{\prime} \\
 &= E[\hat{\beta}(k) - Z\beta][\hat{\beta}(k) - Z\beta]^{\prime} \\
 &= E[Z(\hat{\beta} - \beta)][Z(\hat{\beta} - \beta)]^{\prime} \\
 &= E[Z(\hat{\beta} - \beta)][(\hat{\beta} - \beta)^{\prime}(Z)^{\prime}] \\
 \hat{\beta} - \beta &= [(X'X)^{-1}X'(X\beta + \epsilon) - \beta] \\
 &= \beta + (X'X)^{-1}X'\epsilon - \beta = (X'X)^{-1}X'\epsilon \\
 \text{Cov}(\hat{\beta}(k)) &= E[Z(X'X)^{-1}X'\epsilon(\epsilon'X(X'X)^{-1}Z')] \\
 &= Z(X'X)^{-1}X'E(\epsilon\epsilon')X(X'X)^{-1}Z' \\
 &= \sigma^2 Z(X'X)^{-1}Z'
 \end{aligned}$$

จากสมการ(2.2.3)และ(2.2.4)จะได้ว่า

$$\begin{aligned}
 Z &= [I+k(X'X)^{-1}]^{-1} \\
 &= [I+k(X'X)^{-1}]^{-1}(X'X)^{-1}(X'X) \\
 &= \{X'X[I+k(X'X)^{-1}]\}^{-1}(X'X) \\
 &= (X'X+kI)^{-1}(X'X) \\
 \text{ดังนั้น} \quad \text{Cov}(\hat{\beta}(k)) &= \sigma^2 Z(X'X)^{-1}Z' \\
 &= \sigma^2 (X'X+kI)^{-1}X'X(X'X)^{-1}(X'X)(X'X+kI)^{-1} \\
 (2.2.10) \quad &= \sigma^2 (X'X+kI)^{-1}(X'X)(X'X+kI)^{-1}
 \end{aligned}$$

จากการประมาณค่าสัมประสิทธิ์การถดถอย β ด้วยวิธีกำลังสองน้อยที่สุดจะได้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองดังนี้

$$\text{MSE}(\hat{\beta}) = \text{Var}(\hat{\beta}) + (\text{bias})^2$$

$$= \sigma^2 (X'X)^{-1} + 0$$

เนื่องจาก $E(\hat{\beta}) = \beta$ ดังนั้นค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของตัวประมาณ
สัมประสิทธิ์การถดถอยพบด้วยวิธีวิธีกำลังจรีเกรสชัน จะมีค่าดังนี้

$$\begin{aligned} \text{MSE}(\hat{\beta}(k)) &= \text{trace Cov}(\hat{\beta}(k)) + \beta'(Z-I)'(Z-I)\beta \\ &= \text{Variance} + (\text{bias})^2 \\ (2.2.11) \quad &= \sigma^2 \sum_{i=1}^p \frac{\lambda_i}{(\lambda_i + k)^2} + k^2 \beta'[X'X + kI]^{-2} \beta \end{aligned}$$

เราสามารถพิสูจน์ (2.2.11) ได้ดังนี้

$$\begin{aligned} \text{MSE}(\hat{\beta}(k)) &= E(\hat{\beta}(k) - \beta)'(\hat{\beta}(k) - \beta) \\ \hat{\beta}(k) &= [I + k(X'X)^{-1}]^{-1} \beta = Z\hat{\beta} \end{aligned}$$

$$\text{MSE}(\hat{\beta}(k)) = E[Z\hat{\beta} - \beta]'[Z\hat{\beta} - \beta]$$

พิจารณาจาก $Z\hat{\beta} - \beta$ จะได้ว่า $Z\hat{\beta} - \beta = Z\hat{\beta} - Z\beta + Z\beta - \beta$

$$= Z(\hat{\beta} - \beta) + (Z - I)\beta$$

นั่นคือ $(Z\hat{\beta} - \beta)' = (\hat{\beta} - \beta)'Z' + \beta'(Z - I)'$

ดังนั้น $\text{MSE}(\hat{\beta}(k)) = E[(\hat{\beta} - \beta)'Z' + \beta'(Z - I)'] [Z(\hat{\beta} - \beta) + (Z - I)\beta]$

$$= E[(\hat{\beta} - \beta)'Z'Z(\hat{\beta} - \beta) + (\hat{\beta} - \beta)'Z'(Z - I)\beta + \beta'(Z - I)'Z(\hat{\beta} - \beta) + \beta'(Z - I)'(Z - I)\beta]$$

เนื่องจาก $E(\hat{\beta} - \beta) = 0$

ดังนั้น $\text{MSE}(\hat{\beta}(k)) = E[(\hat{\beta} - \beta)'Z'Z(\hat{\beta} - \beta)] + \beta'(Z - I)'(Z - I)\beta$

$$= a + b$$

โดยที่ $a = E(\hat{\beta} - \beta)'Z'Z(\hat{\beta} - \beta)$

จะได้ว่า $\hat{\beta} - \beta = \beta + (X'X)^{-1}X'\epsilon - \beta$

$$\begin{aligned}
 \text{เมื่อ } a &= E(\hat{\beta} - \beta)' Z' Z (\hat{\beta} - \beta) = E[E' X (X' X)^{-1} Z' Z (X' X)^{-1} X' \epsilon] \\
 &= 6^2 \text{trace}[X (X' X)^{-1} Z' Z (X' X)^{-1} X'] \\
 (2.2.22) \quad &= 6^2 \text{trace}[(X' X)^{-1} Z' Z]^{***}
 \end{aligned}$$

$Z = [I + k(X' X)^{-1}]^{-1}$ เป็นเมตริกซ์สมมาตร

$$\begin{aligned}
 (X' X)^{-1} Z' Z &= (X' X)^{-1} Z Z = (X' X)^{-1} [I + k(X' X)^{-1}]^{-1} [I + k(X' X)^{-1}]^{-1} \\
 &= [I + k(X' X)^{-1}]^{-1} (X' X) [I + k(X' X)^{-1}]^{-1} \\
 &= (X' X + kI)^{-1} (X' X) (X' X)^{-1} [I + k(X' X)^{-1}]^{-1} \\
 &= (X' X + kI)^{-1} (X' X) [I + k(X' X)^{-1}]^{-1} (X' X) \\
 (2.2.23) \quad &= (X' X + kI)^{-1} (X' X) (X' X + kI)^{-1}
 \end{aligned}$$

กล่าวคือ จาก(2.2.22)และ(2.2.23)จะได้ $a = 6^2 \text{trace}[(X' X + kI)^{-1} (X' X) (X' X + kI)^{-1}]$

$$\begin{aligned}
 \text{MSE}(\hat{\beta}(k)) &= 6^2 \text{trace}[(X' X + kI)^{-1} (X' X) (X' X + kI)^{-1}] \\
 &\quad + \beta' (Z - I)' (Z - I) \beta \\
 &= \text{trace}[\text{Cov}(\hat{\beta}(k))] + \beta' (Z - I)' (Z - I) \beta \\
 &= \text{trace}[\text{Cov}(\hat{\beta}(k))] + (\text{bias})^2
 \end{aligned}$$

$$\text{MSE}(\hat{\beta}(k)) = 6^2 \sum_{i=1}^p \frac{\lambda_i}{(\lambda_i + k)^2} + k^2 \beta' (X' X + kI)^{-2} \beta$$

*** $\text{trace}(ABCDE) = \text{trace}(BCDEA)$ ดังนั้น $\text{trace}[X' (X' X)^{-1} Z' Z (X' X)^{-1} X]$
 $= \text{trace}[(X' X)^{-1} Z' Z (X' X)^{-1} X' X] = \text{trace}[(X' X)^{-1} Z' Z]$

2.3 ตัวประมาณวิดจ์ (Ridge Estimators)

ในการประมาณค่าสัมประสิทธิ์การถดถอยพหุด้วยวิธีวิดจ์วีเกรสชันนั้นจะต้องกำหนดค่าคงที่ k ซึ่งค่า k นี้จะอยู่ในช่วง 0 ถึง 1 การกำหนดค่า k นี้มีได้หลายวิธีด้วยกัน แต่จากการศึกษาของ Wichern และ Churchill, Gibbon, McDonald และ Galarneau, TZE-SAN-LEE พบว่าวิธีที่ดีในการประมาณ k มีอยู่ 3 วิธีคือ

1. วิธี HKB(Hoerl-Kennard-Baldwin method)

วิธีนี้เสนอโดย Hoerl Kennard และ Baldwin(1975) โดยกำหนดให้

$$k = \frac{p\hat{\sigma}^2}{\hat{\epsilon}'\hat{\epsilon}}$$

เมื่อ p = จำนวนตัวแปรอิสระ

$\hat{\epsilon}$ = $(X'X)^{-1}X'y$ เป็นค่าประมาณกำลังสองน้อยที่สุด

และ $\hat{\sigma}^2 = \frac{1}{n-p} (y'y - \hat{\epsilon}'X'y)$

2. วิธี TZE-SAN-LEE(TZE-SAN-LEE method)

วิธีนี้เสนอโดย TZE-SAN-LEE(1986) โดยกำหนดค่า k ดังนี้

$$k = \lambda_p$$

เมื่อ λ_p เป็นค่า eigenvalue ที่มีค่าน้อยที่สุดของ $(X'X)$

$$MSE(\hat{\beta}(k)) = \text{Variance} + (\text{bias})^2$$

$$= \hat{\sigma}^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^2 + k^2 \beta' (X'X + kI)^{-2} \beta$$

จะได้ว่าค่า bias เพิ่มขึ้นเมื่อ k มีค่าเพิ่มขึ้น ดังนั้นจึงควรเลือก k ที่มีค่าน้อยๆ เพื่อทำให้ bias มีค่าน้อย กล่าวคือ

$$\begin{aligned} k &= \lambda_p \\ &= \lambda_{\min} \end{aligned}$$

3. วิธี McD&G (McDonald-Galarneau method)

วิธีนี้เสนอโดย McDonald และ Galarneau โดยพิจารณาจากข้อเท็จจริงที่ว่า $\hat{\beta}'\hat{\beta}$ มากกว่า $\beta'\beta$ อยู่ $\sigma^2 \text{trace}(X'X)^{-1}$ กล่าวคือ

$$E(\hat{\beta}'\hat{\beta}) = \beta'\beta + \sigma^2 \text{trace}(X'X)^{-1}$$

$$\text{หรือ } E(\hat{\beta}'\hat{\beta}) - \sigma^2 \text{trace}(X'X)^{-1} = \beta'\beta$$

ดังนั้นจึงควรเลือกค่า k ที่มีผลทำให้ $\hat{\beta}(k)$ มีค่าใกล้เคียงกับ β โดยการหาจากสมการ

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

$$\text{เมื่อ } \sigma^2 = \frac{1}{n-p} (\mathbf{y}'\mathbf{y} - \hat{\beta}'X'\mathbf{y})$$

2.4 การแปลงข้อมูลโดยการแปลงที่ใช้การยกกำลัง (Power Transformation)

ในกรณีที่ความคลาดเคลื่อนมีการแจกแจงแบบเบ้ จะทำการแปลงข้อมูลโดยการแปลงที่ใช้การยกกำลังเพื่อที่จะทำให้ข้อสมมุติของความเป็นปกติใช้ได้

Box และ Cox (1964: 211-243) ได้เสนอการแปลงข้อมูลของตัวแปรตามดังนี้

$$y_i^{(\lambda)} = \begin{cases} \frac{y_i^{\lambda-1}}{\lambda} & ; \lambda \neq 0 \\ \log_e y_i & ; \lambda = 0 \end{cases}$$

ซึ่งการแปลงรูปตัวแปรตามในลักษณะนี้ทำให้ $Y_i^{(\lambda)}$ มีการแจกแจงแบบปกติซึ่งขั้นตอนการแปลงรูปตัวแปรตามมีดังนี้

1) จากสมการ $y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_D X_{Di} + E_i$; $i=1,2,\dots,n$ เมื่อ E_i มิได้มีการแจกแจงแบบปกติ เรานำ geometric mean ของ y_1, y_2, \dots, y_n คือ

$G = \sqrt[n]{y_1 y_2 \dots y_n}$ มาหาร y_i ; $i=1,2,\dots,n$ ทำให้ได้ $y_{i*} = y_i/G$; $i=1,2,\dots,n$

จะพบว่า $\sum_{i=1}^n \ln y_{i*} = 0$

2) จากสมการ $\frac{y_{i*}^{\lambda-1}}{\lambda} = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_D X_{Di} + E_i$; $i=1,2,\dots,n$

ซึ่ง Box และ Cox ถือว่ากรณีเช่นนี้ $E_i \sim N(0, \sigma^2)$ ทำให้

$$y_{i*}^{\lambda} \sim N(\beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_D X_{Di}, \sigma^2)$$

จะได้ว่าฟังก์ชันภาวะน่าจะเป็น (likelihood function) ของ $y_{i*}^{(\lambda)}$ คือ

$$L = \prod_{i=1}^n f(y_{i*}^{\lambda})$$

$$L = (1/2\pi\sigma^2)^{n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_{i*}^{(\lambda)} - \beta_1 - \beta_2 X_{2i} - \dots - \beta_D X_{Di})^2\right\} \cdot J$$

โดยที่ J คือ จาคอเบียนที่แปลงรูปจาก y_{i*} เป็น $y_{i*}^{(\lambda)}$ ดังนั้น

$$J = \prod_{i=1}^n \left| \frac{dy_{i*}^{(\lambda)}}{dy_{i*}} \right|$$

$$= \prod_{i=1}^n y_{i*}^{\lambda-1}$$

$$\text{นั่นคือ } L = (1/2\pi\sigma^2)^{n/2} \exp \left\{ -(1/2\sigma^2) \sum_{i=1}^n (y_{i*}^{(\lambda)} - \beta_1 - \beta_2 X_{2i} - \dots - \beta_p X_{pi})^2 \right\} \prod_{i=1}^n y_{i*}^{\lambda-1}$$

$$\ln L = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - (1/2\sigma^2) \sum_{i=1}^n (y_{i*}^{(\lambda)} - \beta_1 - \beta_2 X_{2i} - \dots - \beta_p X_{pi})^2 + (\lambda-1) \sum_{i=1}^n \ln y_{i*}$$

แต่ $\sum_{i=1}^n \ln y_{i*} = 0$ ดังนั้น

$$\ln L = \frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - (1/2\sigma^2) \sum_{i=1}^n (y_{i*}^{(\lambda)} - \beta_1 - \beta_2 X_{2i} - \dots - \beta_p X_{pi})^2$$

และ MLE ของ $\beta(\lambda)$ และ $\sigma^2(\lambda)$ ได้จาก $\frac{\partial \ln L}{\partial \beta} = 0$ และ $\frac{\partial \ln L}{\partial \sigma^2} = 0$ จะได้ว่า

$$\hat{\beta}(\lambda) = (X'X)^{-1} X' y_*^{(\lambda)}$$

$$\hat{\sigma}^2(\lambda) = \frac{1}{n} (y_*^{(\lambda)} - X\hat{\beta}(\lambda))' (y_*^{(\lambda)} - X\hat{\beta}(\lambda))$$

ดังนั้น ขั้นตอนต่างๆ มีดังนี้

- 1) หาค่า y แต่ละค่าด้วยค่ากลางเรขาคณิตของ y
- 2) สำหรับค่า λ ทำการถดถอย $y_{i*}^{(\lambda)}$ บน X_i และคำนวณ $\hat{\sigma}^2(\lambda)$
- 3) เลือกค่า λ ที่ให้ค่า $\hat{\sigma}^2(\lambda)$ ที่น้อยที่สุด จะได้ค่า λ ที่เป็น MLE ของ λ

2.5 ผลงานวิจัยที่เกี่ยวข้อง

ผลงานวิจัยที่เกี่ยวข้องกับตัวประมาณริตซ์ บางผลงานที่น่าสนใจมีดังนี้

Wichern และ Churchill(1978: 301-311) ได้ศึกษาเปรียบเทียบตัวประมาณริคจ์บางตัว ได้ผลสรุปว่าไม่มีวิธีใดที่ดีที่สุดในทุกกรณี แต่วิธี McG&D โดยทั่วไปจะให้ค่า MSE ต่ำในกรณีที่มี multicollinearity ระดับปานกลางและสูง

Gibbons(1981:131-139) ได้ศึกษาตัวประมาณริคจ์บางตัวได้ผลสรุปว่า โดยทั่วไปแล้ววิธี HKB จะให้ผลดี แต่ไม่มีวิธีใดที่จะเด่นกว่าวิธีอื่นในทุกระดับความสัมพันธ์

Hoerl Kennard และ Baldwin(1975:105-123) ได้ศึกษาตัวประมาณริคจ์แบบ HKB ได้ผลสรุปว่า

- (1) การใช้ ridge estimator โดยวิธี HKB นี้จะให้ MSE น้อยกว่าวิธีกำลังสองน้อยที่สุดมากกว่า 50% ขึ้นไป
- (2) ถ้าจำนวนตัวแปรอิสระเพิ่มขึ้น(p) จะทำให้ MSE มีค่าน้อยลง
- (3) หากตัวแปรอิสระ X มีความสัมพันธ์กันสูง จะทำให้ MSE มีค่าน้อยลง
- (4) MSE มีค่าน้อยลงขณะที่ δ^2 มีค่าเพิ่มขึ้น