


บทที่ ๒



ทฤษฎีเกี่ยวกับริคจ์ รีเกรสชัน

ในกรณีที่ตัวแปรอิสระในตัวแบบมีสภาพไม่เหมาะสม (ill-condition) ซึ่งในที่นี้จะหมายถึงตัวแปรอิสระมีค่าสหสัมพันธ์สูง การประมาณค่าสัมประสิทธิ์ความถดถอยด้วยวิธีกำลังสองน้อยที่สุดจะไม่ให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำสุด ดังจะเห็นได้จากการพิสูจน์ทฤษฎี ๒.๔.๒.๓ ต่อไป สำหรับการประมาณค่าสัมประสิทธิ์การถดถอยที่ให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำสุดนั้น

Hoerl และ Kennard ได้เสนอวิธีการที่ใช้การบวกค่าคงที่ที่มากกว่าศูนย์กับสมาชิกทุกตัวบนเส้นทะแยงมุมของเมทริกซ์  $X'X$  วิธีการดังกล่าวนี้จะได้ค่าประมาณของพารามิเตอร์มีลักษณะเอนเอียง และมีค่าเฉลี่ยความคลาดเคลื่อนกำลังสองน้อยกว่าวิธีกำลังสองน้อยที่สุด ซึ่งต่อมาในปี พ.ศ. ๒๕๑๘ Richard F. Gunst และ Robert L. Mason ได้นำวิธีการของ Hoerl และ Kennard ไปทดสอบกับตัวเลขจริง ซึ่งให้ผลเป็นจริงเหมือนกับที่กล่าวข้างต้น<sup>๑</sup>

รายละเอียดต่าง ๆ ในบทนี้จะกล่าวถึงการประมาณค่าพารามิเตอร์  $\beta$  โดยวิธีริคจ์ รีเกรสชันพร้อมทั้งการพิสูจน์ทฤษฎีเหล่านี้ด้วย

---

<sup>๑</sup>Richard F. Gunst and Robert L. Mason, "Biased Estimation in Regression : An Evaluation Using Mean Square Error," Journal of the American Statistical Association, (September 1977, vol.72, No. 359), p. 666.

๒.๑ ตัวแบบทั่วไป

จากตัวแบบทั่วไปของการวิเคราะห์การถดถอยพหุเชิงเส้นซึ่งเป็นดังนี้

$$Y = X\beta + \epsilon \quad \dots\dots\dots(2.1.1)$$

- เมื่อ Y เป็น เวกเตอร์ของตัวแปรตามขนาด  $n \times 1$
- X เป็น เมทริกซ์ของตัวแปรอิสระขนาด  $n \times p$  และมี **full rank** p
- $\beta$  เป็น เวกเตอร์ของพารามิเตอร์ที่ไม่ทราบค่าขนาด  $p \times 1$
- $\epsilon$  เป็น เวกเตอร์ของความคลาดเคลื่อนขนาด  $n \times 1$

โดยที่  $E(\epsilon) = 0$

และ  $E(\epsilon'\epsilon) = \sigma^2 I_n$

ถ้าประมาณค่าพารามิเตอร์  $\beta$  ด้วยวิธีกำลังสองน้อยที่สุดจะได้ตัวประมาณ

$$\hat{\beta} = [X'X]^{-1}X'Y \quad \dots\dots\dots(2.1.2)$$

ในกรณีที่ ไม่เกิดสภาพไม่เหมาะสมของตัวแปรอิสระ คือตัวแปรอิสระมีเมทริกซ์สหสัมพันธ์ อยู่ในรูปเมทริกซ์เอกลักษณ์การคูณ (Identity matrix) การประมาณค่า  $\beta$  โดยวิธีกำลังสองน้อยที่สุดจะให้ตัวประมาณ  $\hat{\beta}$  (ตามสมการ 2.1.2) ซึ่งมีลักษณะไม่เอนเอียง กล่าวคือ

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

---

<sup>๑</sup>Franklin A. Graybill, Introduction to Linear Statistical Models, vol. I, p. 111.

แต่ถ้าตัวแปรอิสระมีค่าสหสัมพันธ์สูงกล่าวคือสมาชิกของเมทริกซ์สหสัมพันธ์ของตัวแปรอิสระที่ไม่อยู่บนเส้นทแยงมุมมีค่าเข้าใกล้ ๑ (ไม่อยู่ในรูปเมทริกซ์เอกลักษณ์การคูณ) การประมาณค่า  $\beta$  ด้วยวิธีกำลังสองน้อยที่สุดจะมีผลทำให้เกิดข้อผิดพลาดของตัวประมาณ  $\hat{\beta}$  แต่ในทางปฏิบัติสหสัมพันธ์ของตัวแปรอิสระที่มีลักษณะดังกล่าวข้างต้นนี้อาจหลีกเลี่ยงไม่ได้ในบางกรณี ดังนั้นจึงควรพิจารณารูปวิธีการประมาณค่า  $\beta$  ที่เหมาะสมกว่านี้ ซึ่งในที่นี้จึงควรจะพิจารณารูปวิธีริคจ์ รีเกรสชัน แทนวิธีกำลังสองน้อยที่สุด

การคำนวณโดยวิธี ริคจ์ รีเกรสชัน จะให้ตัวประมาณ  $\hat{\beta}$  ดังนี้ ตัวประมาณค่าพารามิเตอร์  $\beta$

$$\hat{\beta}^* = (X'X + KI)^{-1} X'Y^0; \quad K > 0 \dots\dots\dots(2.1.3)$$

จากสมการ (2.1.3) ใช้หลักการคำนวณเหมือนกับสมการ (2.1.2) โดยที่ ริคจ์ รีเกรสชัน มีส่วนที่แตกต่างจากวิธีกำลังสองน้อยที่สุด คือ จะมี K เข้ามาปรับค่า  $(X'X)^{-1}$  โดยนำค่า K บวกกับสมาชิกทุกตัวบนเส้นทแยงมุมของเมทริกซ์  $X'X$  เพื่อให้ตัวประมาณ  $\hat{\beta}^*$  มีคุณสมบัติที่ให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองลดต่ำลง จากสมการ (2.1.3) กำหนดให้  $K > 0$  เราไม่อาจหาค่า K ที่แน่นอนได้นอกจากจะต้องมีการทดลองให้ K มีค่าเพิ่มจากศูนย์ทีละน้อยและแทนค่า K ในสมการ (2.1.3) จนกว่าจะได้ค่า K ที่เหมาะสม จะเห็นได้ว่าค่าตัวประมาณ  $\hat{\beta}^*$  จะได้จากการคำนวณหลายรอบ (Iterative) เพราะขึ้นกับค่า K ที่เปลี่ยนแปลงไปเรื่อย ๆ ทุกครั้งที่กำหนดค่า K เพื่อคำนวณค่าตัวประมาณ  $\hat{\beta}^*$  จะนำค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่เกิดขึ้นจากวิธีนี้และวิธีกำลังสองน้อยที่สุดมาเปรียบเทียบกันไปเรื่อย ๆ จนกว่าจะพบว่า ค่า K ใดที่ทำให้ค่าเฉลี่ยความคลาด

---

<sup>๑</sup>Arthur E. Hoerl and Robert W. Kennard; "Ridge Regression : Application to Nonorthogonal Problem"; Technometrics; (Vol. 12, No. 1, February 1970), p. 70

เคลื่อนกำลังสองของตัวประมาณค่า  $\beta$  ด้วยวิธี ริตจ์ รีเกรสชัน ให้ค่าน้อยกว่าค่าเฉลี่ย ความคลาดเคลื่อนกำลังสองของตัวประมาณค่า  $\beta$  ด้วยวิธีกำลังสองน้อยที่สุด เราจะถือ ว่าค่า  $K$  นั้น เริ่มจะเป็นค่า  $K$  ที่เหมาะสม แล้วจะค่อย ๆ เปลี่ยนค่า  $K$  ไปทีละน้อยอีก จนกว่าจะหาค่า  $K$  ที่เหมาะสมที่สุด ซึ่งจะให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองมีค่าต่ำ สุดได้ ดังนั้นอาจกล่าวได้ว่าจุดอ่อนของริตจ์ รีเกรสชัน คือไม่สามารถกำหนดค่า  $K$  ที่แน่นอนได้

๒.๒ คุณสมบัติของตัวประมาณค่า  $\hat{\beta}$  ด้วยวิธีกำลังสองน้อยที่สุด

จากวิธีกำลังสองน้อยที่สุด ซึ่งให้ตัวประมาณค่า  $\beta$  เป็น

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

โดยมีคุณสมบัติว่าตัวประมาณ  $\hat{\beta}$  มีค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำสุดในกลุ่มของ ตัวประมาณค่า  $\beta$  ที่ไม่เอนเอียง จากตัวแบบสามารถเขียนค่าความผิดพลาดในรูป  $X, Y$  ดังนี้

$$\epsilon = Y - X\beta \dots\dots\dots(2.2.1)$$

ดังนั้นจะได้ผลบวกของความคลาดเคลื่อนกำลังสอง มีค่าเท่ากับ  $\epsilon'\epsilon$  ถ้าให้  $\phi(\hat{\beta})$  เป็น ผลบวกความคลาดเคลื่อนกำลังสองเมื่อใช้ตัวประมาณ  $\hat{\beta}$  จะได้

$$\phi(\hat{\beta}) = (Y - X\hat{\beta})'(Y - X\hat{\beta}) \dots\dots\dots(2.2.2)$$

เนื่องจากข้อมูลตัวอย่างที่นำมาศึกษาความถดถอยพหุเชิงเส้นส่วนมากมีสหสัมพันธ์ของ ตัวแปรอิสระที่ไม่อยู่ในรูปเมทริกซ์เอกลักษณะการคูณ ถ้าประมาณ  $\beta$  ด้วย  $\hat{\beta}$  จากวิธีกำลัง สองน้อยที่สุดอาจมีผลทำให้เมทริกซ์ของค่าแปรปรวนและค่าแปรปรวนร่วมของตัวประมาณ  $\hat{\beta}$  ไม่มีขนาดเล็กที่สุด ดังนั้นเราควรพิจารณาคุณสมบัติของตัวประมาณค่า  $\beta$  ๒ ประการ คือ เมทริกซ์ค่าแปรปรวนและค่าแปรปรวนร่วมของตัวประมาณ  $\hat{\beta}$  และเฉลี่ย

กำลังสองจาก  $\hat{\beta}$  ไปยัง  $\beta$  ซึ่งสามารถเขียนอยู่ในรูปฟังก์ชันของ  $X'X$  และ  $\sigma^2$  ได้ดังต่อไปนี้

กำหนดให้ความแปรปรวนของค่าตัวประมาณ  $\hat{\beta}$  มีค่าเป็น  $\text{VAR}(\hat{\beta})$  ดังนั้น

$$\text{VAR}(\hat{\beta}) = \sigma^2 (X'X)^{-1} \quad \dots\dots\dots(2.2.3)$$

และให้ระยะทางจาก  $\hat{\beta}$  ถึง  $\beta$  มีค่าเป็น  $L_1$

$$\text{ดังนั้น } L_1^2 = (\hat{\beta} - \beta)' (\hat{\beta} - \beta) \quad \dots\dots\dots(2.2.4)$$

ค่าเฉลี่ยของกำลังสองระยะทางจาก  $\beta$  ไปยัง  $\hat{\beta}$  เป็นดังนี้

$$E[L_1^2] = \sigma^2 \text{Trace}^{\circ} (X'X)^{-1} \quad \dots\dots\dots(2.2.5)$$

$E[L_1^2]$  จะมีค่าสมมูล (Equivalent) กับ  $E[\hat{\beta}'\hat{\beta}]$

$$E[\hat{\beta}'\hat{\beta}] = \beta'\beta + \sigma^2 \text{Trace} (X'X)^{-1}{}^{\text{๒}} \quad \dots\dots\dots(2.2.5ก)$$

เมื่อ  $\epsilon$  มีการกระจายแบบปกติจะได้


$$\text{VAR}(L_1^2) = 2\sigma^4 \text{Trace} (X'X)^{-2}{}^{\text{๓}} \quad \dots\dots\dots(2.2.6)$$

จะเห็นได้ว่าจากสมการ (2.2.3), (2.2.5) และ (2.2.6) ค่าความแปรปรวนของตัวประมาณ  $\hat{\beta}$  [ $V(\hat{\beta})$ ] ค่าเฉลี่ยของกำลังสองระยะทางจาก  $\beta$  ไปยัง  $\hat{\beta}$  [ $E(L_1^2)$ ] และค่าความแปรปรวนของกำลังสองระยะทางจาก  $\beta$  ไปยัง  $\hat{\beta}$  [ $V(L_1^2)$ ] เหล่านี้

<sup>๑</sup>Trace = ผลบวกของสมาชิกทุกตัวบนเส้นทแยงมุมของเมทริกซ์  $(X'X)^{-1}$

<sup>๒</sup>Arthur E. Hoerl and Robert W. Kennard, "Ridge Regression Biased Estimation for Nonorthogonal Problems" Technometrics (Vol. 12, No.1, February 1970), p. 56.

<sup>๓</sup>Ibid.



เป็นฟังก์ชันของ  $\hat{\beta}$  เพื่อความสะดวกในการเปรียบเทียบการประมาณค่า  $\beta$  ระหว่างสองวิธีนี้ควรแปลงเมทริกซ์  $(X'X)^{-1}$  ให้อยู่ในรูปฟังก์ชันของค่า eigenvalue ของเมทริกซ์  $X'X$  โดยใช้คุณสมบัติที่สำคัญข้อหนึ่งของค่า eigenvalue ของ  $X'X$  กล่าวคือถ้า  $\lambda_i$  เป็นค่า eigenvalue ของ  $X'X$  เมื่อ  $i = 1, 2, \dots, n$   $n$  คือขนาดของเมทริกซ์  $X'X$  แล้ว  $\sum_{i=1}^n \lambda_i = \text{Trace} (X'X)$

สมมติให้ค่า eigenvalue  $X'X$  มีค่าเป็น

$$(\lambda_{\max} = \lambda_1) > \lambda_2 > \lambda_3 \dots (\lambda_p = \lambda_{\min}) \geq 0 \dots \dots \dots (2.2.7)$$

จากสมการ (2.2.5) ค่าเฉลี่ยของระยะทางจาก  $\beta$  ถึง  $\hat{\beta}$  กำลังสอง อาจเขียนอยู่ในรูปฟังก์ชันของค่า eigenvalue ของ  $X'X$  ดังนี้

$$E[L_1^2] = \sigma^2 \sum_{i=1}^p (1/\lambda_i) \dots \dots \dots (2.2.8)$$

และจากสมการ (2.2.6) ค่าความแปรปรวนของกำลังสองระยะทางจาก  $\beta$  ถึง  $\hat{\beta}$  อาจเขียนในรูปฟังก์ชันของ eigenvalue ของ  $X'X$  ดังนี้

$$\text{VAR} (L_1^2) = 2\sigma^4 \sum_{i=1}^p (1/\lambda_i)^2 \dots \dots \dots (2.2.9)$$

จากสมการ (2.2.8) และสมการ (2.2.9) จะได้ขีดจำกัดล่าง (Lower Bound) ของค่าเฉลี่ยของกำลังสองของระยะทางจาก  $\beta$  ไปยัง  $\hat{\beta}$  หรือ  $E[L_1^2]$  และค่าความแปรปรวนของกำลังสองของระยะทางจาก  $\beta$  ไปยัง  $\hat{\beta}$  หรือ  $\text{VAR}[L_1^2]$  มีค่าเป็น  $\sigma^2/\lambda_{\min}$  และ  $2\sigma^4/\lambda_{\min}^2$  ตามลำดับ

แต่ในการใช้ที่ตัวแปรอิสระเกิดมีสภาพที่ไม่เหมาะสม ค่า eigenvalue ของเมทริกซ์  $X'X$  จะมีค่าต่ำมาก ๆ มีผลทำให้ระยะทางจาก  $\beta$  ไปยัง  $\hat{\beta}$  มีค่ามาก<sup>๑</sup> พิจารณาว่า  $E[L_1^2]$  และ

<sup>๑</sup>Arthur E. Hoerl and Robert W. Kennard, "Ridge Regression Biased Estimation for Nonorthogonal Problems" Technometrics, (Vol 12, No.1, February 1970), p. 56.

$VAR [ L_1^2 ]$  จะเห็นว่าค่าทั้งสองสูงขึ้น สาเหตุที่เกิดเช่นนี้อาจมีผลมาจากการทำให้ค่าต่ำสุดของค่าผลบวกของความคลาดเคลื่อนกำลังสอง  $\phi(\beta)$  ยังขาดวิธีการทางคณิตศาสตร์ที่จะลดค่า  $E [ L_1^2 ]$  ให้ต่ำลงได้นั้นเอง

๒.๓ การประมาณค่า  $\beta$  โดยวิธีริคจ์ รีเกรสชัน (Ridge Regression)

A.E. Hoerl (2506) ได้ใช้วิธีการทางคณิตศาสตร์มาควบคุมคุณสมบัติของค่าความแปรปรวนของตัวประมาณค่า  $\hat{\beta}$  ที่คำนวณโดยวิธีกำลังสองน้อยที่สุดให้มีค่าลดต่ำลงได้ดังนี้คือ กำหนดให้ค่าประมาณของ  $\beta$  ด้วยวิธี ริคจ์ รีเกรสชัน และวิธีกำลังสองน้อยที่สุดมีค่าเท่ากับ  $\hat{\beta}^*$  และ  $\hat{\beta}$  ตามลำดับ จากสมการ (2.1.3) ค่า  $\hat{\beta}^* = [ X'X + KI ]^{-1} X'Y$  โดยที่  $K > 0$  สามารถแปลง  $\hat{\beta}^*$  ให้อยู่ในรูปฟังก์ชันใหม่ โดยกำหนดให้  $[ X'X + KI ]^{-1} = W$  ดังนี้

$$\hat{\beta}^* = W X'Y \dots\dots\dots(2.3.1)$$

เนื่องจาก  $K$  ไม่ใช่ค่าคงที่ที่จะต้องกำหนดค่า  $K$  หลายค่า ดังนั้นจะเห็นได้ว่า  $\hat{\beta}^*$  มีค่าหลายชุดซึ่งอาจเขียนค่า  $\hat{\beta}^*$  ให้อยู่ในรูป family ได้ดังนี้

$$\text{family } \hat{\beta}^* = \left\{ \begin{array}{l} \{ \hat{\beta}_i^* \} / \{ \hat{\beta}_i^* \} = W_i X'Y ; W = [ X'X + KI ]^{-1} \\ ; K > 0 , i = 1, 2, \dots, q \text{ เมื่อ } q \text{ หมายถึงจำนวนชุดของ } \hat{\beta} \end{array} \right\} \dots\dots\dots(2.3.2)$$

จากตัวประมาณค่า  $\hat{\beta}^*$  สามารถเขียนให้อยู่ในรูปความสัมพันธ์กับ  $\hat{\beta}$  เพื่อสะดวกในการเปรียบเทียบวิธีการประมาณค่า  $\beta$  ระหว่างวิธีทั้งสองดังนี้

$$\hat{\beta}^* = [ I + K(X'X)^{-1} ]^{-1} \hat{\beta} \dots\dots\dots(2.3.3)$$

$$= Z \hat{\beta} \dots\dots\dots(2.3.4)$$

จากความสัมพันธ์ของสมการ (2.3.1) และ (2.3.4) จะได้  $Z = [ I + K(X'X)^{-1} ]^{-1}$  และ  $W = [ X'X + KI ]^{-1}$  และค่า  $Z , \hat{\beta}^*$

และ  $W$  เหล่านี้จะนำไปใช้พิจารณาเปรียบเทียบคุณสมบัติต่าง ๆ ของการประมาณค่าพารามิเตอร์  $\beta$  ตลอดจนการพิสูจน์ทฤษฎีต่าง ๆ ที่สำคัญของการประมาณค่าสัมประสิทธิ์ความถดถอยของวิธีรีดจ์ รีเกรสชัน ต่อไป คุณสมบัติที่จำเป็นของ  $\hat{\beta}^*$ ,  $Z$ ,  $W$  มีดังนี้

๒.๓.๑ ให้  $E_i(W)$  และ  $E_i(Z)$  เป็นค่า eigenvalue ของ  $W$  และ  $Z$  ตามลำดับซึ่งจะคำนวณจาก Characteristic Equation

$$|W - E_i I| = 0$$

และ  $|Z - E_i I| = 0$

$$E_i(W) = 1/(\lambda_i + K) \quad \dots\dots\dots(2.3.5)$$

$$E_i(Z) = \lambda_i/(\lambda_i + K) \quad \dots\dots\dots(2.3.6)$$

๒.๓.๒ ได้ว่า  $Z$  อาจแสดงในรูปฟังก์ชันของ  $KW$  ได้ดังนี้

$$\begin{aligned} Z &= I - K(X'X + KI)^{-1} \\ &= I - KW^{\circ} \quad \dots\dots\dots(2.3.7) \end{aligned}$$

๒.๓.๓ ค่าตัวประมาณ  $\hat{\beta}^*$  จะมีค่าน้อยกว่า  $\hat{\beta}$  เมื่อ  $K > 0$

ตัวอย่างเช่น

$$(\hat{\beta}^*)'(\hat{\beta}^*) < \hat{\beta}'\hat{\beta} \quad \dots\dots\dots(2.3.8)$$

พิสูจน์จากนิยาม  $\hat{\beta}^* = Z\hat{\beta}$  และ  $X'X$ ,  $Z$  มีคุณสมบัติเป็น

Symmetric positive definite ฉะนั้นจะได้

---

<sup>๑</sup>Arthur E. Hoerl and Robert W. Kennard, "Ridge Regression Biased Estimation for Nonorthogonal Problems" Technometrics, (Vol 12, No.1, February 1970), p. 57.



$$\begin{aligned}
(\hat{\beta}^*)'(\hat{\beta}^*) &= (Z' \hat{\beta})'(Z \hat{\beta}) \\
&< \sum_{i=1}^p E_i^2(Z) \hat{\beta}' \hat{\beta} \\
&< E_{i(\max)}^2(Z) \hat{\beta}' \hat{\beta} \quad \dots\dots\dots(2.3.9)
\end{aligned}$$

เมื่อ  $E_{(\max)}(Z) = \lambda_1 / (\lambda_1 + K)$  เมื่อ  $\lambda_1$  เป็นค่า eigenvalue ที่มีค่ามากที่สุดของ  $X'X$

ดังนั้น  $(\hat{\beta}^*)'(\hat{\beta}^*) < \hat{\beta}' \hat{\beta}$

เนื่องจากผลบวกของความคลาดเคลื่อนกำลังสองของค่าตัวประมาณ  $\hat{\beta}^*$

เป็นดังนี้

$$\phi^*(K) = (Y - X \hat{\beta}^*)'(Y - X \hat{\beta}^*) \quad \dots\dots\dots(2.3.10)$$

จากการประมาณค่าพารามิเตอร์  $\beta$  ด้วยวิธีกำลังสองน้อยที่สุดเราสามารถเขียน  $\phi(\hat{\beta})$  ซึ่งเป็นผลบวกของความคลาดเคลื่อนกำลังสองของตัวประมาณ  $\hat{\beta}$  เป็น  $Y'Y - \hat{\beta}' X'Y$  ดังนั้น เพื่อให้เห็นความแตกต่างของ  $\phi^*(K)$  และ  $\phi(\hat{\beta})$  เราสามารถเขียน  $\phi^*(K)$  ในเทอมของ  $Y'Y$  และ  $X'Y$  ได้ดังนี้

$$\phi^*(K) = Y'Y - (\hat{\beta}^*)' X'Y - K(\hat{\beta}^*)'(\hat{\beta}^*) \quad \dots\dots\dots(2.3.11)$$

จาก  $\phi(\hat{\beta})$  และ  $\phi^*(K)$  สรุปได้ว่าผลบวกของความคลาดเคลื่อนกำลังสองของวิธีริคจ์ รีเกรสชันจะให้น้อยกว่าผลบวกของความคลาดเคลื่อนกำลังสองโดยวิธีกำลังสองน้อยที่สุด

**๒.๔ ริคจ์เทรซ (The Ridge Trace)**


กรณีที่เมทริกซ์ของตัวแปรอิสระเกิดสภาพไม่เหมาะสมจะมีผลทำให้

๑. ตัวประมาณค่าพารามิเตอร์  $\beta$  จะให้ค่าสัมบูรณ์มากเมื่อเปรียบเทียบกับค่าสังเกตแล้วพบว่าอาจเป็นไปได้<sup>๑</sup>

๒. ตัวประมาณ  $\beta$  จะไม่สมเหตุผลผล (Unreasonable) เมื่อ  $K = 0$  แต่ตัวประมาณค่า  $\beta$  อาจสมเหตุผลผล (reasonable) เมื่อคำนวณโดยกำหนดให้  $K > 0$  ดังตัวอย่างข้อมูลรูปข้างล่างนี้

รูปที่ ๑

แสดงการเปรียบเทียบการกระจายตัวประมาณค่าพารามิเตอร์  $\beta$  เมื่อประมาณค่าโดยวิธีริคจ์ รีเกรสชัน



จากรูป (ก) แสดงการกระจายของตัวประมาณค่า  $\beta$  พบว่าที่จุด  $a$  ซึ่งเป็นจุดที่ตกอยู่ในช่วงที่ยอมรับได้ในทางปฏิบัติแล้วอาจไม่เป็นจริง ดังนั้น อาจถือว่าเป็นการเสี่ยง หรือมีข้อผิดพลาดสูงหากยอมรับค่าสังเกต แต่หากเรากำหนดตัวประมาณ  $\beta^*$  ด้วยวิธี

<sup>๑</sup>Arthur E. Hoerl and Robert W. Kennard, "Ridge Regression Biased Estimation for Nonorthogonal Problems", Technometric, (Vol 12, No.1, February 1970), p. 55-56.

ริคค์ รีเกอร์สซัน ดังรูป (ข) จะเห็นว่า การกระจายของตัวประมาณ  $\hat{\beta}^*$  อยู่ในรูปปกติโค้ง ซึ่งมีความแปรปรวนค่า และจุด  $a$  จะอยู่ในช่วงที่เราไม่ยอมรับซึ่งหากเราไม่ยอมรับย่อมมีผลทำให้เกิดข้อผิดพลาดได้น้อย<sup>๑</sup>

เมื่อตัวแปรอิสระเกิดสภาพไม่เหมาะสมการประมาณค่าพารามิเตอร์  $\beta$  ด้วยวิธีกำลังสองน้อยที่สุดจะให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองสูง<sup>๒</sup>

หลักการในการหาค่าประมาณของพารามิเตอร์  $\beta$  คือจะเปลี่ยนค่า  $K$  ที่ละน้อย โดยให้  $K > 0$  เสมอแล้วคำนวณตัวประมาณค่า  $\hat{\beta}^*$  และค่าเฉลี่ยความคลาดเคลื่อนกำลังสองสำหรับค่า  $K$  ทุกค่า เพื่อให้ได้ค่า  $\hat{\beta}^*$  ที่เหมาะสม โดยจะหยุดที่ค่า  $K$  ที่ทำให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำกว่าค่าที่ได้ด้วยวิธีกำลังสองน้อยที่สุด ทั้งนี้ Arthur และ Robert W. Kennard<sup>๓</sup> และ Donald W. Marquart และ Ronald S. Snee<sup>๔</sup> ได้เสนอแนะค่า ที่ให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำสุดว่าส่วนใหญ่จะอยู่ระหว่าง  $(0, 1]$  ดังรูปที่ ๒

<sup>๑</sup>O.L. Obechain, "Classical F-test and Confidence Region for Ridge Regression" Technometrics, (Vol.10, No.4, November 1977), p. 429.


<sup>๒</sup>R.W. Farebrother, "The Minimum Mean Square Error Linear Estimator and Ridge Regression" Technometrics, (Vol.17, No.1, February 1975), p. 127.

<sup>๓</sup>Arthur E. Hoerl and Robert W. Kennard, "Ridge Regression Biased Estimation for Nonorthogonal Problems" Technometrics, (Vol.12, No.1, February 1970), p. 65.

<sup>๔</sup>Donald W. Marquart and Ronald D. Snee, "Ridge Regression in Practice" The American Statistician, (Vol. 29, No. 1, February 1975), p. 5.

## รูปที่ ๒

แสดงความสัมพันธ์ระหว่าง  $\hat{\beta}^*$  และ  $K$  เมื่อ  $K \in (0,1]$  ( $\hat{\beta}^*$  หมายถึงสัมประสิทธิ์ของ  $X_1$ )



ริตจ์เทรซหมายถึงกราฟที่แสดงความสัมพันธ์ระหว่าง  $\hat{\beta}^*$  และ  $K$  จากรูปที่ ๒ ริตจ์เทรซเป็นกราฟเส้นโค้ง ซึ่งในช่วงแรกกราฟของค่า  $\hat{\beta}^*$  จะเป็นเส้นโค้งที่มีค่า Slope สูงเมื่อ  $K \rightarrow 0$  และค่า Slope จะค่อย ๆ ลดลงจนถึงจุดคงที่ และเมื่อ  $K \rightarrow 1$  จะสังเกตเห็นว่าเส้นโค้งจะไม่มีการเปลี่ยนแปลง (ค่า Slope มีค่าเป็นศูนย์) จะสังเกตเห็นได้ว่า ณ  $K$  เริ่มจะคงที่ มีผลทำให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่ประมาณค่าโดยริตจ์ รีเกรสชัน ให้ค่าน้อยกว่าวิธีกำลังสองน้อยที่สุด และเมื่อ  $K$  มีค่าเข้าใกล้ 1 หรือเท่ากับ 1 จะมีผลทำให้ค่าตัวประมาณ  $\hat{\beta}^*$  เปลี่ยนแปลงน้อยมาก และเมื่อ  $K$  มีค่ามากกว่า 1 ค่าตัวประมาณ  $\hat{\beta}^*$  จะให้ค่าไม่แตกต่างจากค่า  $\hat{\beta}^*$  เมื่อ  $K = 1$  หรือเข้าใกล้ 1

ฉนั้นในทางปฏิบัติเมื่อนำวิธีคิดจรีเกรสชันมาวิเคราะห์กับข้อมูลทั่ว ๆ ไป จึงคาดได้ว่าค่า  $K$  ที่เหมาะสมส่วนใหญ่ควรจะอยู่ในช่วง  $(0, 1]$

ดังนั้นจะเห็นว่าเส้นโค้งรีดจ์เทรซ จึงเป็นตัวแทนที่สำคัญวิธีหนึ่งของการประมาณสัมประสิทธิ์ความถดถอยของวิธีคิดจรีเกรสชัน ในบางครั้ง เพราะสามารถช่วยในการตัดสินใจว่าจะใช้ค่า  $K$  ไต ( $K \in (0, 1]$ ) ที่ให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองน้อยลงเมื่อเปรียบเทียบกับวิธีกำลังสองน้อยที่สุด โดยพิจารณาการเปลี่ยนแปลงของตัวประมาณ  $\hat{\beta}^*$  เป็นเกณฑ์ด้วย

สมมติให้  $B$  เป็นค่าใด ๆ ที่ได้จากการประมาณค่าพารามิเตอร์  $\beta$  การพิจารณาผลบวกความคลาดเคลื่อนกำลังสองของตัวประมาณ  $B$  หรือ  $\phi(B)$  เมื่อเปรียบเทียบกับค่า  $\phi(\hat{\beta})$  ซึ่งมีค่าเท่ากับ  $(Y - X\hat{\beta})'(Y - X\hat{\beta})$  สามารถเขียนได้ดังนี้

$$\phi(B) = (Y - XB)'(Y - XB) \dots\dots\dots(2.4.1)$$

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

$$= \phi_{\min} + \phi_B \dots\dots\dots(2.4.2)$$

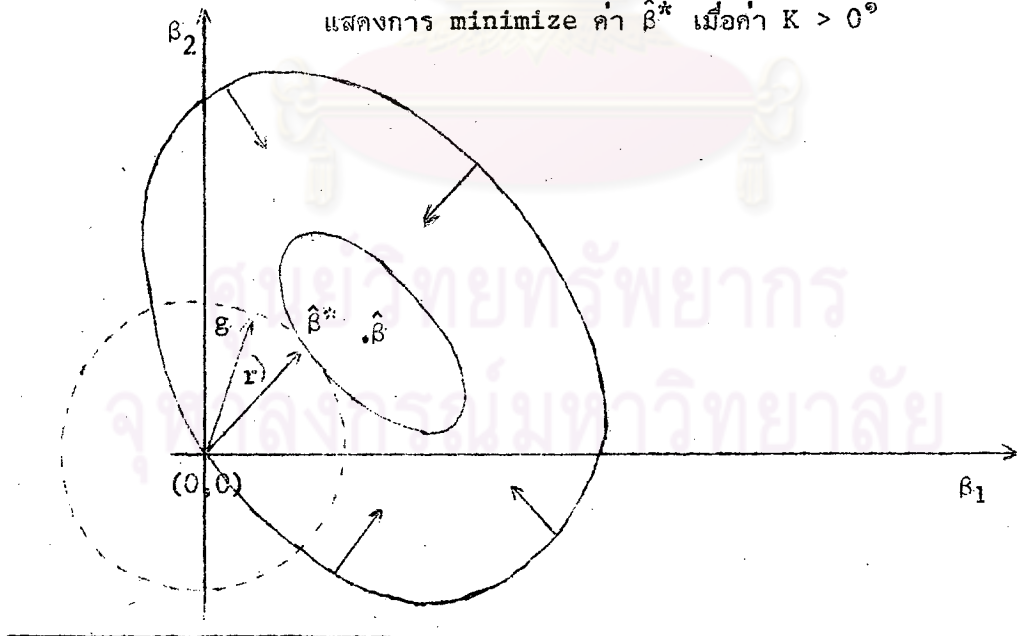
จากสมการ (2.4.2)  $\phi(B)$  เขียนอยู่ในเทอมของผลบวกของ  $\phi_{\min}$  (มีค่าเท่ากับ  $\phi(\hat{\beta})$ ) กับฟังก์ชันที่อยู่ในรูปกำลังสองของ  $(B - \hat{\beta})$  โดยที่  $\phi_{\min}$  เป็นค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของตัวประมาณ  $\hat{\beta}$  ที่คำนวณโดยวิธีกำลังสองน้อยที่สุด และถ้ากำหนดให้  $B_0$  เป็นตัวประมาณพารามิเตอร์  $\beta$  ที่สามารถคำนวณค่าได้ และเป็นตัวประมาณที่เหมาะสมที่สุด เมื่อพิจารณาผลบวกกำลังสองของความคลาดเคลื่อนของ  $B_0$  จะเห็นว่า มีค่าเท่ากับ  $\phi_{\min}$  กับ  $\phi_{B_0}$  โดยที่  $\phi_{B_0} > 0$  ดังนั้นจะสังเกตได้ว่า  $\phi_{\min}$  เป็นค่าคงที่ที่เกิดขึ้นเสมอ ไม่ว่าจะเป็นการประมาณค่าพารามิเตอร์  $\beta$  ด้วยวิธีใด ๆ ส่วน  $\phi_{B_0}$  เป็นฟังก์ชันกำลังสองของ  $(B_0 - \hat{\beta})$  มีค่าเพิ่มขึ้น จากสมการ (2.2.5 ก) ในกรณีตัวแปรอิสระเกิดสภาพไม่เหมาะสม Hoerl และ Kennard ได้ชี้จุดบกพร่องของวิธีกำลังสองน้อยที่สุดโดยให้ข้อสังเกตว่าค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของ  $\hat{\beta}$  จะมีค่าเท่ากับ

$\beta' \beta + \sigma^2 \text{Trace} (X'X)^{-1}$  โดยที่มีค่า  $\beta' \beta$  เพิ่มขึ้นจากเดิม ( $\sigma^2 \text{Trace} (X'X)^{-1}$ )  
 ค่า  $\beta' \beta + \sigma^2 \text{Trace} (X'X)^{-1}$  หรือ  $\beta' \beta + \sigma^2 \sum_{i=1}^P 1/\lambda_i$  เมื่อนำมาเปรียบเทียบกับวิธีริจด์ รีเกรสชัน จะสังเกตได้ว่าค่า eigenvalue ของ  $X'X$  จะมีค่าต่ำมาก ๆ

เมื่อตัวแปรอิสระเกิดสภาพไม่เหมาะสม ถ้าให้  $\lambda_{\min}$  เป็นค่า eigenvalue ของ  $X'X$  ที่มีค่าต่ำสุด อาจกล่าวได้ว่าค่า  $\beta' \beta + \sigma^2 \sum_{i=1}^P 1/\lambda_i > \beta' \beta + \sigma^2 1/\lambda_{\min}$  เสมอ เมื่อ  $\beta' \beta + \sigma^2/\lambda_{\min}$  เป็นค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่คำนวณโดยวิธีริจด์ รีเกรสชัน และผลที่ตามมาอีกคือ เวกเตอร์  $\hat{\beta}$  จะเพิ่มขึ้น วิธีที่จะลด  $\beta' \beta$  ให้ลดลงนี้คือพยายามลดเวกเตอร์  $\hat{\beta}$  ให้เล็กลง โดยไม่มีผลทำให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง ( $\phi(B)$ ) เพิ่มขึ้น วิธีการที่ทำให้  $\hat{\beta}$  มีค่าเล็กลงจึงควรมุ่งไปพิจารณาที่ริจด์เทรซ ซึ่งอาจหมายถึงระยะทางจากจุดกำเนิดใด ๆ ของเวกเตอร์  $\hat{\beta}^*$  ไปยังพื้นที่ผิวของรูปวงรี  $\phi(B)$  ให้มีค่าสั้นที่สุดดังรูปที่ ๓

รูปที่ ๓

แสดงการ minimize ค่า  $\hat{\beta}^*$  เมื่อค่า  $K > 0^{\circ}$



<sup>๑</sup>Donald, W. Marquart and Ronald, D. Snee, "Ridge Regression in Practice" The American Statistician, (Vol.29, No.1, February 1975), p. 6.

จากรูปที่ ๓ แสดงให้เห็นว่าค่า  $\phi(B)$  เป็นรูปวงรีที่มีจุดศูนย์กลางที่  $\hat{\beta}$  จะถูกทำให้มีค่าต่ำสุด เมื่อกำหนดให้  $\phi(B)$  เป็นรูปวงรีใหญ่จะมีค่าลดลงเรื่อย ๆ จนกระทั่งเป็นรูปวงรีขนาดเล็ก และเมื่อลากเส้นตรงจากจุดกำเนิดไปยังเส้นรอบวงรีขนาดเล็กนี้พบว่าเส้นตรงนี้มีค่าเท่ากับเวกเตอร์  $\hat{\beta}^*$  เป็นเส้นตรงที่สั้นที่สุดและอยู่ระหว่าง  $\hat{\beta}$  กับ  $g$  เสมอ เมื่อ  $g$  เป็นเวกเตอร์ที่ลากจากจุดกำเนิดไปตั้งฉากกับรูปวงรี  $\phi(B)$  และ  $g$  ทำมุมกับเวกเตอร์  $\hat{\beta}^*$  เท่ากับ  $\gamma$  ทุกครั้งที่  $K$  มีค่าเพิ่มขึ้นค่าของมุม  $\gamma$  จะมีค่าเล็กลง ๆ ดังนั้นในการคำนวณค่า  $B$  จึงพิจารณาจากการหาค่าต่ำสุดของระยะทางของเวกเตอร์  $B$  ไปยัง  $\phi(B)$  นั่นเอง การหาค่าต่ำสุดของ  $B^{\wedge}B$  เป็นดังนี้

$$\text{กำหนดให้ } (B - \hat{\beta})^{\wedge} (X^{\wedge}X) (B - \hat{\beta}) = \phi_B \dots\dots\dots(2.4.3)$$

การหาค่าต่ำสุดของ  $B^{\wedge}B$  จะใช้ทฤษฎีและหลักของ Lagrangian โดยกำหนดให้  $F$  ซึ่งเป็นฟังก์ชันที่จะหาค่าต่ำสุดดังนี้

$$F = B^{\wedge}B + 1/K [(B - \hat{\beta})^{\wedge} (X^{\wedge}X) (B - \hat{\beta}) - \phi_B] \dots\dots\dots(2.4.4)$$

เมื่อหาอนุพันธ์  $F$  เทียบกับ  $B$  แล้วกำหนดให้มีค่าเท่ากับศูนย์จะได้

$$\frac{\partial F}{\partial B} = 2B + 1/K [2(X^{\wedge}X) B - 2(X^{\wedge}X)\hat{\beta}] = 0 \dots\dots\dots(2.4.5)$$

$$\text{ฉะนั้น } B = \hat{\beta}^* = [X^{\wedge}X + KI]^{-1} X^{\wedge}Y \dots\dots\dots(2.4.6)$$

โดยที่  $K$  เป็นค่าที่ทำให้  $\phi_B$  ต่ำสุดและมีผลทำให้  $B^{\wedge}B$  ต่ำสุดและผลบวกของความคลาดเคลื่อนกำลังสองของตัวประมาณค่า  $\hat{\beta}^*$  สอดคล้องกับสมการ (๒.๔.๖) จากสมการ (๒.๔.๒) อาจเขียนอยู่ในเทอมของ  $\hat{\beta}^*$  ได้ดังนี้

$$\begin{aligned} \text{จาก } \phi^*(K) &= (Y - X\hat{\beta}^*)^{\wedge} (Y - X\hat{\beta}^*) \\ &= \phi_{\min} + (\hat{\beta}^* - \hat{\beta})^{\wedge} (X^{\wedge}X) (\hat{\beta}^* - \hat{\beta}) \dots\dots\dots(2.4.7) \end{aligned}$$

$$\text{จาก } (\hat{\beta}^* - \hat{\beta})^{\wedge} (X^{\wedge}X) (\hat{\beta}^* - \hat{\beta}) = \hat{\beta}^{*\wedge} (I - Z^{-1})^{\wedge} (X^{\wedge}X) (I - Z^{-1}) \hat{\beta}^* \dots\dots\dots(2.4.8)$$

$$= \hat{\beta}^* [ I - K(X'X)^{-1} ] (X'X) [ I - K(X'X)^{-1} ] \hat{\beta}^* \dots (2.4.9)$$

$$= K^2 \hat{\beta}^* (X'X)^{-1} \hat{\beta}^* \dots (2.4.10)$$

ดังนั้นสมการ (2.4.7) สามารถเขียนใหม่ได้ดังนี้

$$\phi^*(K) = \phi_{\min} + K^2 \hat{\beta}^* (X'X)^{-1} \hat{\beta}^* \dots (2.4.11)$$

โดยที่  $\phi^*(K)$  เป็นผลบวกของความคลาดเคลื่อนกำลังสองของตัวประมาณ  $\hat{\beta}^*$

จากสมมติฐานเบื้องต้นของการประมาณค่าพารามิเตอร์  $\beta$  คือ  $\epsilon \sim N(0, \sigma^2 I_n)$

ฟังก์ชันที่น่าจะเป็น (Likelihood function) ของความคลาดเคลื่อนคือ

$$(2\pi\sigma^2)^{-n/2} \exp\{(-1/2\sigma^2)(Y-X\beta)'(Y-X\beta)\} \dots (2.4.12)$$

$$(2\pi\sigma^2)^{-n/2} \exp\{(-1/2\sigma^2)[(Y-X\hat{\beta})'(Y-X\hat{\beta}) + (\hat{\beta}-\beta)'(X'X)(\hat{\beta}-\beta)]\} \dots (2.4.13)$$

เมื่อ  $\hat{\beta}^*$  เป็นตัวประมาณค่าใด ๆ ของพารามิเตอร์ ที่ประมาณค่าโดยวิธีริคค์ รีเกรสชัน น่าจะเป็นคือ

$$(2\pi\sigma^2)^{-n/2} \exp\{(-1/2\sigma^2)[(Y-X\hat{\beta})'(Y-X\hat{\beta}) + K^2 \hat{\beta}^* (X'X)^{-1} \hat{\beta}^*]\} \dots (2.4.14)$$

จากสมการ (2.4.13) อาจกล่าวได้ว่าฟังก์ชันที่น่าจะเป็นมีค่าเพิ่มขึ้นในเทอมของ  $(\hat{\beta}-\beta)'(X'X)(\hat{\beta}-\beta)$  แต่เมื่อพิจารณาสมการ (2.4.14) จะสังเกตได้ว่า  $K^2(\hat{\beta}^*)'(X'X)^{-1}\hat{\beta}^*$  มีค่าน้อยกว่าเทอม  $(\hat{\beta}-\beta)'(X'X)(\hat{\beta}-\beta)$  ดังนั้นจึงสรุปได้ว่าฟังก์ชันน่าจะเป็นเมื่อประมาณค่าพารามิเตอร์  $\beta$  ด้วยวิธีริคค์ รีเกรสชัน จะมีค่าลดลง (ซึ่งสังเกตได้จากรูปที่ ๓ เมื่อขนาดของรูปวงรีมีขนาดลดลงนั่นเอง) และฟังก์ชันน่าจะเป็น (การกระจายของค่าความคลาดเคลื่อนของตัวประมาณ  $\hat{\beta}^*$ ) จะมีค่าเฉลี่ย (Mean) เท่ากันและค่าความแปรปรวนเท่ากัน โดยที่ค่าความคลาดเคลื่อน ( $\epsilon$ ) มีการกระจายแบบปกติคือ  $\epsilon \sim N(0, \sigma^2 I_n)$



๒.๕ คุณสมบัติของผลบวกของความคลาดเคลื่อนกำลังสองของริดจ์ รีเกรสชัน

๒.๕.๑ จากการประมาณค่าสัมประสิทธิ์การถดถอย  $\beta$  ด้วยวิธีกำลังสองน้อยที่สุดจะได้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองดังนี้

$$\begin{aligned} \text{MSE} &= \text{VAR}(\hat{\beta}) + (\text{BIAS})^2 \quad \dots\dots\dots(2.5.1) \\ &= \sigma^2 (X'X)^{-1} + 0 \end{aligned}$$

เนื่องจาก  $E(\hat{\beta}) = \beta$  ดังนั้นการประมาณค่าพารามิเตอร์  $\beta$  ด้วยวิธีกำลังสองน้อยที่สุดจะได้ตัวประมาณค่า  $\hat{\beta}$  ที่ไม่เอนเอียง สำหรับค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของตัวประมาณสัมประสิทธิ์ความถดถอยด้วยวิธี ริดจ์ รีเกรสชัน ซึ่งมีค่าเป็น  $E [ L_1^2(K) ]$  อาจพิจารณาได้ดังนี้

ในการประมาณค่าพารามิเตอร์  $\beta$  ด้วยวิธีริดจ์ รีเกรสชัน จะได้  $E(\hat{\beta}^*) \neq \beta^{\circ}$  แสดงว่าค่าตัวประมาณ  $\hat{\beta}^*$  มีลักษณะเอนเอียง

$$E(\hat{\beta}^*) = E(Z\hat{\beta}) \quad \dots\dots\dots(2.5.2)$$

$$= ZE(\hat{\beta}) \quad \dots\dots\dots(2.5.3)$$

$$= Z\beta \quad \dots\dots\dots(2.5.4)$$

จาก

$$\begin{aligned} E [ L_1^2(K) ] &= E [ (\hat{\beta}^* - \beta) (\hat{\beta}^* - \beta)' ] \\ &= E [ (\hat{\beta} - \beta)' Z' Z (\hat{\beta} - \beta) ] + (Z\beta - \beta)' (Z\beta - \beta) \quad \dots\dots\dots(2.5.5) \end{aligned}$$

$$= \sigma^2 \text{Trace} (X'X) E'Z + \beta' (Z-I)' (Z-I) \beta \quad \dots\dots\dots(2.5.6)$$

---

<sup>๑</sup>Donald W. Marquart and Ronald D. Snee, "Ridge Regression in Practice" The American Statistician, (Vol.29, No.1, February 1975) p. 5.

$$= \sigma^2 [ \text{Trace } (X'X + KI)^{-1} - K \text{ Trace } (X'X + KI)^{-2} ] + K^2 \beta'(X'X + KI)^{-2} \beta \dots\dots\dots(2.5.7)$$

$$= \sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + K)^{-2} + K^2 \beta'(X'X + KI)^{-2} \beta \dots\dots\dots(2.5.8)$$

$$= \gamma_1(K) + \gamma_2(K) \dots\dots\dots(2.5.9)$$

จะเห็นว่า  $E [ L_1^2(K) ]$  เป็นค่าเฉลี่ยความคลาดเคลื่อนกำลังสองซึ่งอยู่ในรูปผลบวกของฟังก์ชัน  $\gamma_1(K)$  และ  $\gamma_2(K)$

โดยที่  $\gamma_1(K)$  เป็นค่าความแปรปรวนของตัวประมาณ  $\hat{\beta}^*$  และ  $\gamma_2(K)$  เป็นค่าความเอนเอียงของตัวประมาณค่า  $\hat{\beta}^*$  กำลังสอง เมื่อพิจารณาเทอม  $\gamma_2(K)$  ซึ่งเป็นระยะทางจาก  $Z\beta$  ไปยัง  $\beta$  จะเห็นว่ามีค่าเป็นศูนย์เมื่อ  $K = 0$  โดยที่  $Z$  เป็นเมทริกซ์เอกลักษณ์การคูณ ซึ่งสอดคล้องกับค่าความเอนเอียงกำลังสองของ  $\hat{\beta}$  ที่มีค่าเป็นศูนย์ สำหรับกรณีที่  $K > 0$  ถ้าพิจารณา  $\gamma_2(K)$  ในเทอมของความเอนเอียงของ  $\hat{\beta}$  กำลังสอง กล่าวคือ  $\gamma_2(K) = (\text{BIAS})^2$

ส่วนเทอม  $\gamma_1(K)$  นั้นเป็นผลบวกของความแปรปรวนของตัวประมาณค่า  $\hat{\beta}^*$  ซึ่งเขียนในเทอมของ  $Y$  ได้ดังนี้

$$\hat{\beta}^* = Z\hat{\beta} = Z(X'X)^{-1} X'Y \dots\dots\dots(2.5.10)$$

$$V(\hat{\beta}^*) = Z(X'X)^{-1} X' \text{VAR} [ Y ] X(X'X)^{-1} Z' = \sigma^2 \text{Trace } Z(X'X)^{-1} Z' \dots\dots\dots(2.5.11)$$

เนื่องจากความแปรปรวนของตัวประมาณ  $\hat{\beta}^*$  ทั้งหมด  $V(\hat{\beta}^*)$  คำนวณได้จากผลบวกของสมาชิกทุกตัวบนเส้นทะแยงมุมของเมทริกซ์  $\sigma^2 Z(X'X)^{-1} Z'$  เพื่อให้สอดคล้องกับ

$\gamma_1(K)$  ของสมการ (2.5.9) ซึ่งเป็นฟังก์ชันที่อยู่ในเทอมของ eigenvalue ของ  $X'X$  และ  $K$  ดังนั้นเมทริกซ์  $X'X$  และ  $Z$  สามารถปรับให้เป็นเมทริกซ์ที่อยู่ในรูปของ  $\lambda_i$  ซึ่งเป็นค่า eigenvalue ของ  $X'X$  เมื่อ  $i = 1, 2, \dots, p$  และ  $p$  หมายถึงจำนวนตัวแปรอิสระ  $X$

$$\text{Trace } (X'X)^{-1} = \sum_{i=1}^p (1/\lambda_i) \quad \dots\dots(2.5.12)$$

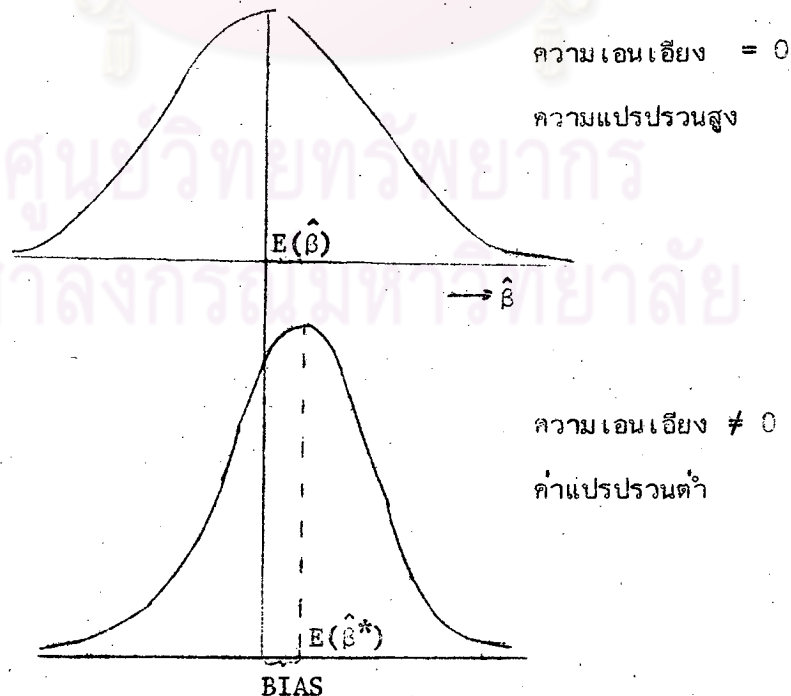
$$\text{และ Trace } (Z) = \sum_{i=1}^p (\lambda_i / (\lambda_i + K)) \quad \dots\dots(2.5.13)$$

$$\text{จากสมการ (2.5.11) จะได้ } \sigma^2 \text{ Trace } Z(X'X)^{-1} Z = \sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + K)^2$$

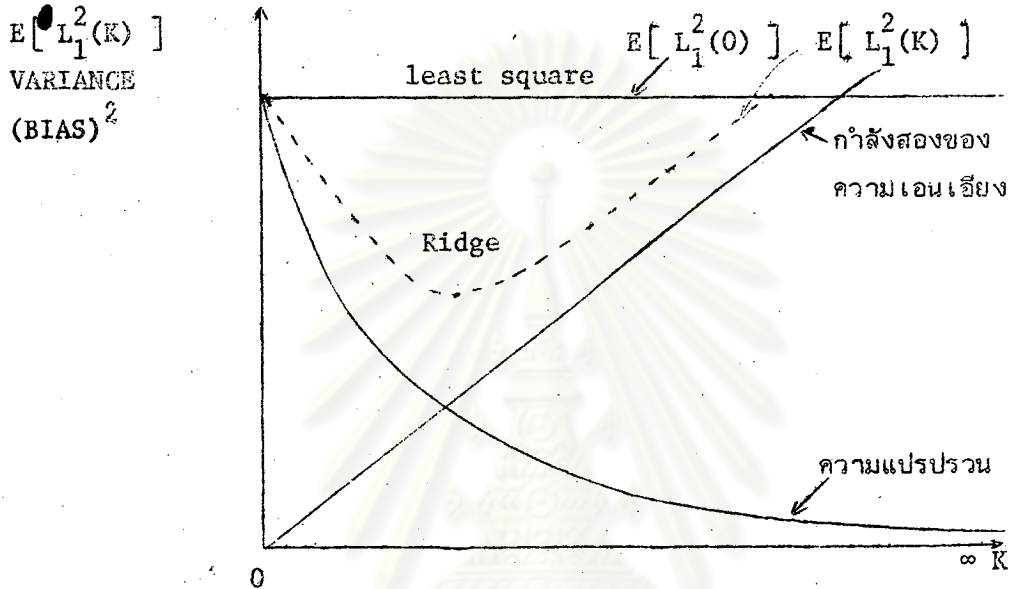
$$\text{ดังนั้นกล่าวได้ว่า } E[ L_1^2(K) ] = \text{VAR}(\hat{\beta}^*) + (\text{BIAS})^2$$

#### รูปที่ ๔

แสดงการกระจายของตัวประมาณพารามิเตอร์  $\beta$  ทั้ง ๒ วิธี



รูปที่ ๕

แสดงกราฟของ  $E[L_1^2(K)]$ 

จากรูปที่ ๕ เป็นกราฟแสดงความสัมพันธ์ระหว่างความแปรปรวนของตัวประมาณ  $\beta^*$  ความเอนเอียงกำลังสองกับค่า  $K$  เมื่อกำหนดให้  $K \in (0, 1]$  สรุปได้ดังนี้ คือความแปรปรวนทั้งหมดจะมีค่าลดลงเรื่อย ๆ ขณะที่  $K$  มีค่าเพิ่มขึ้น และความเอนเอียงกำลังสองจะมีค่าแปรผันตาม  $K$  จากรูปเส้นไขว้ปลาเป็นกราฟที่แสดงผลบวกของความแปรปรวนทั้งหมดของ  $\beta^*$  และความเอนเอียงกำลังสองของ  $\beta^*$  จะมีค่าเท่ากับ  $E[L_1^2(K)]$  ซึ่งเป็นค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่เกิดจากตัวประมาณค่า  $\beta^*$  เมื่อ  $K > 0$

กราฟของฟังก์ชัน  $\gamma_1(K)$  มีลักษณะเป็น monotonically decreasing ในรูปฟังก์ชันของ  $K$  และกราฟของฟังก์ชัน  $\gamma_2(K)$  มีลักษณะเป็น monotonically increasing ในรูปฟังก์ชันของ  $K$  ดังนั้นจากรูปที่ ๕ จะเห็นว่า  $E[L_1^2(K)]$  มีค่าน้อยกว่า  $E[L_1^2(0)]$  โดยที่  $E[L_1^2(0)]$  เป็นค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่เกิดจากการประมาณค่าพารามิเตอร์  $\beta$  โดยวิธีกำลังสองน้อยที่สุด

จากรูปที่ ๕ แสดงให้เห็นการเปลี่ยนแปลงของค่าต่าง ๆ ที่กล่าวมาแล้วข้างต้น ซึ่งสามารถคำนวณหาขีดจำกัด (Limit) ของความแปรปรวนของตัวประมาณ  $\hat{\beta}^*$  และความเอนเอียงกำลังสองของตัวประมาณ  $\hat{\beta}^*$  ได้จากอนุพันธ์ของแต่ละฟังก์ชันดังนี้

$$\lim_{k \rightarrow 0^+} (\partial \gamma_1 / \partial K) = -2\sigma^2 \sum_{i=1}^p (1/\lambda_i^2) \dots\dots\dots(2.5.14)$$

$$\lim_{k \rightarrow 0^+} (\partial \gamma_2 / \partial K) = 0 \dots\dots\dots(2.5.15)$$

ดังนั้นอนุพันธ์ของความเอนเอียงกำลังสองมีค่าเป็นลบ และเข้าใกล้  $-2F\sigma^2$  ขณะที่  $k \rightarrow 0^+$  เมื่อผลคูณของเมทริกซ์ของตัวแปรอิสระ ( $X'X$ ) เป็นออร์ธโทกอนอล และ  $\gamma_1(K)$  มีค่าเข้าใกล้ค่าอนันต์ลบ ( $-\infty$ ) กรณีที่เมทริกซ์ของตัวแปรอิสระเกิดมีสภาพไม่เหมาะสม ค่า eigenvalue  $\lambda_p \rightarrow 0$

ส่วน  $\lim_{k \rightarrow 0^+} (\partial \gamma_2 / \partial K)$  มีค่าค่อย ๆ ลดลงและเป็นศูนย์ที่จุดกำเนิดเมื่อ  $k \rightarrow 0^+$  คุณสมบัติของสมการ (2.5.14) และ (2.5.15) จะเป็นจริงเมื่อ  $K > 0$  ซึ่งสรุปได้ว่าค่าความเอนเอียงเพิ่มขึ้นเรื่อย ๆ ขณะที่ความแปรปรวนของตัวประมาณ  $\hat{\beta}^*$  ลดลง ซึ่งจะทำให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองลดลงด้วย

๒.๕.๒ ทฤษฎีต่าง ๆ ที่สำคัญของฟังก์ชันค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง

ทฤษฎี ๒.๕.๒.๑ ความแปรปรวนทั้งหมด  $\gamma_1(K)$  เป็นฟังก์ชันต่อเนื่อง และมีลักษณะเป็น monotonically decreasing ฟังก์ชันในรูปของ K

พิสูจน์ จาก (2.5.8)  $\gamma_1(K) = \sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + K)^2 \dots\dots(2.5.16)$

หาอนุพันธ์ของ  $\gamma_1(K)$  เทียบกับ K

$$\begin{aligned} \frac{\partial \gamma_1(K)}{\partial K} &= \sigma^2 \sum_{i=1}^p \frac{\partial \lambda_i (\lambda_i + K)^{-2}}{\partial K} \dots\dots\dots(2.5.17) \\ &= \sigma^2 \sum_{i=1}^p \lambda_i (-2) (\lambda_i + K)^{-3} \end{aligned}$$

$$\gamma_1'(K) = -2\sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + K)^3 \quad \dots\dots(2.5.18)$$

จาก  $K > 0$  ,  $\gamma_1(K)$  จะเป็นฟังก์ชันต่อเนื่องของ  $K$  และพบว่า  $\gamma_1(K)$  เป็นฟังก์ชันที่มีค่าเป็นลบ ดังนั้น  $\lim_{K \rightarrow \infty} \gamma_1'(K)$  จะมีลักษณะเป็น monotonically decreasing ฟังก์ชัน  $K$

ดังนั้นอนุพันธ์อันดับหนึ่งของ  $\gamma_1(K)$  เมื่อเทียบกับ  $K$  มีค่าเป็น  $\gamma_1'(K)$  จะเข้าใกล้  $-\infty$  เมื่อ  $k \rightarrow 0^+$  และ  $\lambda \rightarrow 0$

$$\text{ดังนั้น} \quad \lim_{k \rightarrow 0^+} \gamma_1'(K) = -\infty$$

ทฤษฎี ๒.๕.๒.๒ ความเอนเอียงกำลังสองของ  $\gamma_2(K)$  เป็นฟังก์ชันต่อเนื่องและ monotonically increasing ฟังก์ชันของ  $K$

พิสูจน์

$$\text{จาก (2.5.8)} \quad \gamma_2(K) = K^2 \beta' (X'X + KI_p)^{-2} \beta$$

ถ้า  $\lambda$  เป็นเมทริกซ์ของ eigenvalue  $X'X$  และ  $p$  เป็น orthogonal เมทริกซ์ที่มีคุณสมบัติ  $X'X = PAP$  ดังนั้น  $\gamma_2(K)$  อาจเขียนใหม่ได้ดังนี้

$$\gamma_2(K) = K^2 \sum_{i=1}^p \alpha_i^2 / (\lambda_i + K)^2 \quad \dots\dots(2.5.19)$$

$$\text{เมื่อ} \quad \alpha = P\beta \quad \dots\dots(2.5.20)$$

เนื่องจาก  $\lambda_i > 0$  ทุกค่าของ  $i$  และ  $K > 0$  ดังนั้น แต่ละเทอมของ  $(\lambda_i + K)$  จะเป็นบวก จาก (2.5.19) จะได้  $\gamma_2(0) = 0$  เมื่อ  $K = 0$  แล้วจะได้  $\gamma_2(K)$  เป็นฟังก์ชันต่อเนื่องเมื่อ  $K > 0$  อาจเขียน  $\gamma_2(K)$  ใหม่ดังนี้

$$\gamma_2(K) = \sum_{i=1}^p \alpha_i^2 / [1 + (\lambda_i/K)]^2 \quad \dots\dots(2.5.21)$$

ทุกค่าของ  $i$ ,  $\lambda_i > 0$  ดังนั้น  $\lambda_i/K$  จะเป็น monotonically decreasing  
เมื่อ  $K$  มีค่าเพิ่มขึ้น และแต่ละเทอมของ  $\gamma_2(K)$  เป็น monotonically increasing  
ดังนั้น  $\gamma_2(K)$  เป็น monotonically increasing สูงขึ้นของ  $K$

บทแทรก ๒.๕.๒.๒ (๑) ความเอนเอียงกำลังสอง  $\gamma_2(K)$  จะมีค่าเข้าใกล้  
 $\beta^{-\beta}$  ซึ่งเป็นขีดจำกัดบน

พิสูจน์

$$\begin{aligned} \text{จาก (2.5.21) } \lim_{k \rightarrow \infty} \gamma_2(K) &= \sum_{i=1}^p \alpha_i^2 \\ &= \alpha^{-\alpha} \\ &= \beta^{-\beta} \\ &= \beta^{-\beta} \end{aligned}$$



บทแทรก ๒.๕.๒.๒ (๒) อนุพันธ์  $\gamma_2'(K)$  จะมีค่าเข้าใกล้ 0 ขณะที่  $k \rightarrow 0^+$

พิสูจน์

$$\begin{aligned} \text{จาก (2.4.19) } \gamma_2(K) &= K^2 \sum_{i=1}^p \alpha_i^2 / (\lambda_i + K)^2 \\ \frac{\partial \gamma_2(K)}{\partial K} &= 2K \sum_{i=1}^p \lambda_i \alpha_i^2 / (\lambda_i + K)^3 \dots (2.5.22) \\ \text{พจน์บวกของแต่ละเทอม } &2K \alpha_i^2 \lambda_i / (\lambda_i + K)^3 ; i = 1, 2, \dots, p \end{aligned}$$

เป็นฟังก์ชันต่อเนื่อง และขีดจำกัด (Limit) ของแต่ละเทอมจะเข้าใกล้ 0 ขณะที่  $k \rightarrow 0^+$   
ดังนั้น  $\gamma_2'(K)$  จะเข้าใกล้ 0 ขณะที่  $k \rightarrow 0^+$

ทฤษฎี ๒.๕.๒.๓ สำหรับทุกค่าของ  $K > 0$

$$E[L_1^2(K)] < E[L_1^2(0)] \text{ เมื่อ } E[L_1^2(0)] = \sigma^2 \sum_{i=1}^p (1/\lambda_i)$$

พิสูจน์

จาก (2.5.8), (2.5.19) และ (2.5.22)

คำนวณค่าอนุพันธ์  $E[L_1^2(K)]$  เทียบกับ  $K$  ได้ดังนี้

$$\begin{aligned} \frac{\partial E[L_1^2(K)]}{\partial K} &= \frac{\partial \gamma_1(K)}{\partial K} + \frac{\partial \gamma_2(K)}{\partial K} \\ &= -2\sigma^2 \sum_{i=1}^P \lambda_i / (\lambda_i + K)^3 + 2K \sum_{i=1}^P \lambda_i \alpha_i^2 / (\lambda_i + K)^3 \\ &\dots\dots\dots(2.5.23) \end{aligned}$$

$$\begin{aligned} \frac{\partial E[L_1^2(0)]}{\partial K} &= \frac{\partial \gamma_1(K)}{\partial K} + \frac{\partial \gamma_2(K)}{\partial K} \\ &= \frac{\partial \left[ \sigma^2 \sum_{i=1}^P (1/\lambda_i) \right]}{\partial K} + 0 \\ &= 0 \quad \dots\dots\dots(2.5.24) \end{aligned}$$

เนื่องจาก  $K = 0$  จะได้  $\gamma_1(0) = \sigma^2 \sum_{i=1}^P (1/\lambda_i)$  และ  $\gamma_2(0) = 0$

การที่จะพิสูจน์ว่า  $E[L_1^2(K)] < E[L_1^2(0)]$  ต้องแสดงให้เห็น

เห็นจริงว่า  $\frac{\partial E[L_1^2(K)]}{\partial K} < \frac{\partial E[L_1^2(0)]}{\partial K}$  ;  $K > 0$

จาก (2.5.24)  $\frac{\partial E[L_1^2(0)]}{\partial K} = 0$  ดังนั้น  $\frac{\partial E[L_1^2(K)]}{\partial K} < 0$

จึงจะสรุปได้ว่าค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่คำนวณโดยวิธีดิฟเฟอเรนเชียลจะให้ค่าน้อยกว่า คำนวณโดยวิธีกำลังสองน้อยที่สุด

เนื่องจาก  $K < \sigma^2/\hat{\alpha}^2$  max จะเป็น  $K$  ที่เหมาะสม (optimum)

ดังนั้นแทนค่า  $K$  ในสมการ (2.5.23) จะได้  $\frac{\partial E[L_1^2(K)]}{\partial K} < 0$



$$\text{นั่นคือ } E[L_1^2(K)] < E[L_1^2(0)]$$

### ๒.๖ Generalized Ridge Regression

หลักการของ Generalized Ridge Regression จะแปลงผลคูณเมทริกซ์ของตัวแปรอิสระให้อยู่ในรูป diagonal เมทริกซ์ โดยสมมติให้ P เป็น orthogonal เมทริกซ์ซึ่งมีความสัมพันธ์กับผลคูณเมทริกซ์ของตัวแปรอิสระดังนี้คือ  $X'X = P' \Lambda P$  เมื่อ  $\lambda$  เป็นเมทริกซ์ของค่า eigenvalue ที่เป็น diagonal เมทริกซ์ ดังนั้น จากสมการลดรอยพหุเชิงเส้นทั่วไปเราสามารถแปลงให้อยู่ในรูป canonical form ได้ดังนี้

$$Y = X\beta + \epsilon \quad \dots\dots(2.6.1)$$

$$\text{กำหนดให้ } X^* = XP \quad \dots\dots(2.6.2)$$

$$\alpha = P'\beta \quad \dots\dots(2.6.3)$$

นำ (2.6.2) และ (2.6.3) แทนค่าใน (2.6.1) จะได้ Y ในรูปแบบ canonical form ดังนี้

$$Y = X^*\alpha + \epsilon \quad \dots\dots(2.6.4)$$

เมื่อ  $\alpha$  เป็นเวกเตอร์ของพารามิเตอร์ที่ไม่ทราบค่าขนาด  $P \times 1$

$X^*$  เป็นเมทริกซ์ของตัวแปรอิสระที่อยู่ในรูป Canonical ที่มีคุณสมบัติ

$$(X^*)'(X^*) = \lambda$$

จาก (2.6.4) ประมาณค่าพารามิเตอร์  $\alpha$  โดยวิธีริคจ์ รีเกรสชัน จะได้ดังนี้

$$\hat{\alpha}(K) = [X^{*'}X^* + KI_P]^{-1} (X^*)'Y \quad \dots\dots(2.6.5)$$

จาก (2.6.5) เมื่อ  $K = 0$ ,  $\hat{\alpha}(K)$  คือตัวประมาณค่าพารามิเตอร์  $\beta$  ที่ประมาณค่าด้วยวิธีกำลังสองน้อยที่สุด โดยที่  $\hat{\alpha}_1(0) = \hat{\alpha}_1$  ซึ่งพิจารณาได้จาก

$$\hat{\alpha}_i(K) = \frac{\lambda_i}{\lambda_i + K} \cdot \hat{\alpha}_i \quad i = 1, 2, \dots, p \quad \dots (2.6.6)$$

$$= \hat{\alpha}_i \quad \text{เมื่อ } K = 0 \quad \dots (2.6.7)$$

เมื่อ  $\lambda_1, \lambda_2, \dots, \lambda_p$  เป็นค่า eigenvalue ของ  $X'X$

ดังนั้นจะได้ค่าสัมประสิทธิ์ความถดถอยของ  $\beta$  คือ  $\hat{\beta}^*$  เขียนอยู่ในรูป

Generalized Ridge Regression คือ

$$\hat{\beta}^* = P \cdot \hat{\alpha}(K) \quad \dots (2.6.8)$$

จะเห็นว่า  $\hat{\beta}^*$  เป็นฟังก์ชันของ  $P$  และ  $\hat{\alpha}(K)$  การคำนวณตัวประมาณ  $\hat{\beta}^*$  นั้น จะต้องกำหนดค่า  $K$  ที่เหมาะสม เพื่อให้การประมาณค่า  $\beta$  มีค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำสุด

สำหรับการกำหนดค่า  $K$  นี้ มีหลายวิธีดังต่อไปนี้

วิธีที่ ๑ (Hoerl and Kennard [5])

$$K = \sigma^2 / \max (\hat{\alpha}_i^2(0)) \quad \dots (2.6.9)$$

ค่า  $K$  สามารถคำนวณค่าได้โดยที่  $\sigma^2, \hat{\alpha}_i(0)$  เป็นค่าที่ทราบ

วิธีที่ ๒ (Lawless and Wang [8])

$$K = P\sigma^2 / \sum_{i=1}^P \lambda_i \hat{\alpha}_i^2(0) \quad \dots (2.6.10)$$

ค่า  $K$  สามารถคำนวณค่าได้โดยที่  $\sigma^2, \lambda_i, \hat{\alpha}_i(0), P$  เป็นค่าที่ทราบ

<sup>๑</sup>W.J. Hermerle and T.F. Brantle, "Explicit and Constrain Generalized Ridge Estimation; Technometrics, (Vol. 20 No. 2 May 1978), p. 110.

วิธีที่ ๓ (Hoerl, Kennard and Badwin [7])

$$K = P\sigma^2 / \sum_{i=1}^P \hat{\alpha}_i^2(0) \dots\dots\dots(2.6.11)$$

ค่า K สามารถคำนวณค่าได้โดยที่ P,  $\sigma^2$ ,  $\hat{\alpha}_i(0)$  เป็นค่าที่ทราบ

วิธีที่ ๔ (McDonald and Galarneau [13])

$$Q = \hat{\alpha}'(0) \hat{\alpha}(0) - \hat{\sigma}^2 \left( \sum_{i=1}^P 1/\lambda_i \right) \text{ และ เลือก } K \dots(2.6.12)$$

ที่ให้ค่า  $\hat{\alpha}'(K) \hat{\alpha}(K) = Q$  โดยที่  $\hat{\alpha}$ ,  $\hat{\alpha}(K)$ ,  $\hat{\sigma}^2$ ,  $\lambda_i$  เป็นค่าที่ทราบ

สำหรับวิธีต่าง ๆ ดังกล่าวข้างต้นนี้ DEAN W. WICHERN AND GILBERT A. CHURCHILL ได้นำข้อมูลชุดเดียวกันซึ่งมีพหุสัมพันธ์ในตัวแปรอิสระทดลองใช้กับวิธีทั้งสี่ เพื่อเลือกหา K ที่เหมาะสม พบว่าวิธีที่ ๑ จะให้ค่า K ที่เหมาะสมที่มีผลทำให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองที่คำนวณโดยวิธีริจด์ รีเกรสชัน น้อยกว่าวิธีกำลังสองน้อยที่สุด<sup>๑</sup> ซึ่งค่า K ที่กำหนดในวิธีที่ ๑ คือ

$$K = \sigma^2 / \alpha^2 (\max(0)) \text{ สามารถพิสูจน์ได้ดังนี้}$$

$$\hat{\alpha}^* = [D + K]^{-1} (X^*)^{-1} Y \dots\dots\dots(2.6.13)$$

- เมื่อ  $\hat{\alpha}^*$  เป็นตัวประมาณค่าพารามิเตอร์  $\alpha$  ขนาด  $P \times 1$
- D เป็นไดเอโกนอลเมทริกซ์ที่สมาชิกทุกตัวมีค่าเป็น  $\lambda_i$  โดยที่  $\lambda_i$  เป็นค่า eigenvalue ของ  $X'X$ ,  $i = 1, 2, \dots, P$  และเมทริกซ์ D มีขนาด  $n \times n$
- K เป็นค่าคงที่ที่มากกว่าศูนย์

---

<sup>๑</sup>Dean W. Wichern and Gilbert A. Churchill, "Comparison of Ridge Estimators"; Technometrics, (Vol.20, No.3, August 1978), p. 303.

W.J. Hermerle และ T.F. Brantle ให้ข้อสังเกตไว้ คือ การเลือก  $K$  ที่เหมาะสมนั้นได้จากการหาค่าต่ำสุดของค่าเฉลี่ยของระยะทางจาก  $\hat{\alpha}^*$  ไปยัง  $\alpha$  กำลังสองดังนี้คือ

จากสมการ (2.6.13) ค่าเฉลี่ยของระยะทางของตัวประมาณ ค่า  $\hat{\alpha}^*$  ห่างจากค่าพารามิเตอร์  $\alpha$  กำลังสอง คือ

$$E[(\hat{\alpha}^* - \alpha)^2(\hat{\alpha}^* - \alpha)] = Q^0 \quad \dots\dots\dots(2.6.14)$$

และจากสมการ (2.6.14) William J. Hermerle ได้มีการพิสูจน์การหาค่า  $K$  ที่เหมาะสมดังนี้คือเทอม  $E[(\hat{\alpha}^* - \alpha)^2(\hat{\alpha}^* - \alpha)]$  สามารถกระจายให้อยู่ในรูปฟังก์ชันของ  $\lambda_i$ ,  $\alpha_i$ ,  $K$  และ  $\sigma^2$  ได้

$$Q = \sum_{i=1}^p (\sigma^2 \lambda_i + \alpha_i^2 K_i^2) / (\lambda_i + K_i)^2 \quad \dots\dots\dots(2.6.15)$$

เพื่อคำนวณค่า  $K$  ที่เหมาะสมจะหาค่าต่ำสุดของสมการ (2.6.15) ได้ โดยหาอนุพันธ์  $Q$  เทียบกับ  $K$  และกำหนดให้มีค่าเท่ากับศูนย์ จะได้

$$\frac{\partial Q}{\partial K_i} = \frac{2\lambda_i(\lambda_i + K)(K\alpha_i^2 - \sigma^2)}{(\lambda_i + K_i)^4} = 0 \quad \dots\dots\dots(2.6.16)$$

ศูนย์วิทยุทรัพยากร  
จุฬาลงกรณ์มหาวิทยาลัย

W.J. Hermerle and T.F. Brantle "Explicit and Constrained Generalized Ridge Estimation", Technometrics, (Vol. 20, No.2, May 1978), p. 109.

$$K_i = \sigma^2 / \hat{\alpha}_i^2 \quad ; \quad i = 1, 2, \dots, P \quad \dots\dots\dots(2.6.17)$$

เนื่องจาก  $\hat{\alpha}_i$  เป็นตัวประมาณค่าพารามิเตอร์  $\beta$  ที่ประมาณค่าโดยวิธีกำลังสองน้อยที่สุด ซึ่งมีค่า  $\hat{\alpha}_i(0)$  มีค่าเท่ากับ  $\hat{\beta}_i$  ดังนั้นจะสรุปได้ว่าค่า  $K$  เป็นฟังก์ชันที่ขึ้นกับค่า  $\sigma^2$ ,  $\hat{\beta}$ , ( $K = \sigma^2 / \hat{\beta}'\hat{\beta}$ ) ดังสมการ (2.6.17) เนื่องจากค่า  $\hat{\alpha}_i$  และ  $K_i$  มีหลายค่าเพื่อสะดวกในการกำหนดค่า  $K$  เราอาจกำหนดค่า  $K$  เพียงค่าเดียวที่สามารถปรับเมทริกซ์  $X'X$  ที่มีผลให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองให้มีค่าต่ำสุดจากสมการ (2.6.17) กำหนดค่า  $K$  ใหม่ดังนี้

$$K = \sigma^2 / \max \hat{\alpha}_i^2(0)$$

แต่ส่วนมากจะสังเกตได้ว่าค่า  $K$  optimum เมื่อ  $K = 2\sigma^2 / \hat{\beta}'\hat{\beta}$  <sup>๒</sup>

<sup>๑</sup>William J. Hemmerl, "An Explicit for Generalized Ridge Regression", Technometrics, (Vol. 17, No.13, August 1975), p. 309 - 310.

<sup>๒</sup>R.W. Farebrother, "Partitioned Ridge Regression". Technometrics, (Vol. 20, No. 2, May 1978), p. 121.

ในการวิจัยนี้ใช้สูตรในการคำนวณเพื่อเปรียบเทียบการประมาณค่าพารามิเตอร์  $\beta$  ระหว่างวิธีกำลังสองน้อยที่สุดและวิธีรีดจ์ รีเกรสชัน<sup>๑</sup> ดังนี้

ตารางที่ ๑

แสดงการเปรียบเทียบการประมาณค่า  $\beta$  ระหว่างวิธีกำลังสองน้อยที่สุดและวิธีรีดจ์ รีเกรสชัน

	วิธีกำลังสองน้อยที่สุด	วิธีรีดจ์ รีเกรสชัน
๑) ค่าประมาณค่าสัมประสิทธิ์ความถดถอย $\beta$	$\hat{\beta} = (X'X)^{-1}X'Y$	$\hat{\beta}^* = (X'X + KI_p)^{-1}X'Y ; K > 0$
๒) ค่าประมาณความเอนเอียงของตัวประมาณ $\beta$	ไม่เอนเอียงไปจากประชากร โดยที่ $E(\hat{\beta}) = \beta$	เอนเอียงไปจากประชากร $E(\hat{\beta}^*) = Z\beta$ โดยที่ $Z = (X'X + KI)^{-1}$
๓) ค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง	$MSE(\hat{\beta}) = \sigma^2 \text{Trace}(X'X)^{-1}$	$MSE(\hat{\beta}^*) = \text{Trace}[\text{VAR}(\hat{\beta}^*)] + \beta'(Z-I)(Z-I)\beta$
๔) ความแปรปรวนของสัมประสิทธิ์ความถดถอย $\beta$	$\text{VAR}(\hat{\beta}) = \sigma^2_{y.x} (X'X)^{-1}$	$\text{VAR}(\hat{\beta}^*) = \sigma^2_{y.x} [X'X + KI]^{-1} (X'X) [X'X + KI]$
๕) ความเอนเอียงกำลังสอง	$(\text{BIAS})^2 = 0$	$(\text{BIAS})^2 = \beta'(Z-I)'(Z-I)\beta$

<sup>๑</sup>Donald W. Marquart and Ronald D. Snee, "Ridge Regression in Practice", The American Statistician, (Vol. 29, No. 1, February 1975) p. 6.