

## บทที่ 2

### ทฤษฎีและวิธีการทางสถิติที่เกี่ยวข้อง

การวิจัยในครั้งนี้ผู้วิจัยได้เสนอตัวประมาณการถดถอยพหุคูณเชิงเส้น 3 ตัวประมาณ ในการประมาณค่าพารามิเตอร์ คือ ตัวประมาณกำลังสองน้อยสุดสามัญ (Ordinary Least Squares Estimator (OLS)) ตัวประมาณริดจ์สามัญ (Ridge Ordinary Least Squares Estimator (ROLS)) และตัวประมาณริดจ์ที่มีค่าสัมบูรณ์น้อยสุด (Ridge Least Absolute Value Estimator (RLAV)) ซึ่งรายละเอียดของตัวประมาณแต่ละตัวเป็นดังนี้

#### 2.1 การวิเคราะห์ความถดถอยพหุนามและตัวประมาณการถดถอยพหุนาม

##### 2.1.1 การวิเคราะห์ความถดถอยพหุนาม (Polynomial Regression Analysis)

ตัวแบบและข้อตกลงเบื้องต้นที่นำมาใช้ในการวิจัยครั้งนี้คือ ตัวแบบความถดถอยพหุนาม ซึ่งมีรูปแบบทั่วไปดังนี้

$$(2.1) \quad y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \dots + \beta_p x_i^p + \varepsilon_i, \quad i = 1, 2, \dots, n$$

เมื่อ  $\beta_j$  เป็นพารามิเตอร์ไม่ทราบค่าของพจน์พหุนามที่  $j$ ,  $j = 1, 2, \dots, p$

จากสมการที่ (2.1) เราสามารถเขียนให้อยู่ในรูปของการหาค่าประมาณของพารามิเตอร์ของตัวแบบเชิงเส้น ได้ดังนี้

1) เมื่อตัวแบบประกอบด้วยตัวแปรอิสระที่มีกำลังสูงสุดเป็น 6 ซึ่งมีตัวแบบดังนี้

$$(2.2) \quad y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \beta_4 x_i^4 + \beta_5 x_i^5 + \beta_6 x_i^6 + \varepsilon_i, \quad i = 1, 2, \dots, n$$

2) เมื่อตัวแบบประกอบด้วยตัวแปรอิสระที่มีกำลังสูงสุดเป็น 5 ซึ่งมีตัวแบบดังนี้

$$(2.3) \quad y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \beta_4 x_i^4 + \beta_5 x_i^5 + \varepsilon_i, \quad i = 1, 2, \dots, n$$

3) เมื่อตัวแบบประกอบด้วยตัวแปรอิสระที่มีกำลังสูงสุดเป็น 4 ซึ่งมีตัวแบบดังนี้

$$(2.4) \quad y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \beta_4 x_i^4 + \varepsilon_i, \quad i = 1, 2, \dots, n$$

4) เมื่อตัวแบบประกอบด้วยตัวแปรอิสระที่มีกำลังสูงสุดเป็น 3 ซึ่งมีตัวแบบดังนี้

$$(2.5) \quad y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \varepsilon_i, \quad i = 1, 2, \dots, n$$

5) เมื่อตัวแบบประกอบด้วยตัวแปรอิสระที่มีกำลังสูงสุดเป็น 2 ซึ่งมีตัวแบบดังนี้

$$(2.6) \quad y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \varepsilon_i, \quad i = 1, 2, \dots, n$$

ตัวแบบความถดถอยพหุนามในกรณีนี้เป็นตัวแบบเชิงเส้นในพารามิเตอร์ หมายความว่าในแต่ละเทอมของตัวแบบมีพารามิเตอร์เพียง 1 ตัว คุณด้วยค่าคงที่ของตัวแปรอิสระและเนื่องจากตัวแบบที่ใช้ในการพิจารณาเป็นตัวแบบเชิงเส้นในพารามิเตอร์ ดังนั้นการประมาณค่าพารามิเตอร์เราสามารถใช้อัตว์ประมาณกำลังสองน้อยสุดในการประมาณค่าพารามิเตอร์  $\beta$  ดังที่จะได้กล่าวต่อไป

### 2.1.2 ตัวประมาณกำลังสองน้อยสุดสามัญ (Ordinary Least Squares Estimator (OLS))

การประมาณค่าพารามิเตอร์ด้วยตัวประมาณกำลังสองน้อยสุดใช้หลักการประมาณค่าพารามิเตอร์ที่ทำให้ผลรวมของความคลาดเคลื่อนกำลังสอง (Sum Squares Error (SSE)) มีค่าน้อยที่สุด

จากรูปแบบสมการถดถอยเชิงเส้นพหุคูณ

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \dots + \beta_p x_i^p + \varepsilon_i, \quad i = 1, 2, \dots, n$$

หรือเขียนในรูปเมทริกซ์ ได้ดังนี้

$$y = X \beta + \varepsilon$$

เมื่อ	$y$	แทนเวกเตอร์ของตัวแปรตามที่มีขนาด $(n \times 1)$
	$X$	แทนเมทริกซ์ของตัวแปรอิสระที่มีขนาด $(n \times q)$
	$\beta$	แทนเวกเตอร์ของสัมประสิทธิ์ถดถอยที่มีขนาด $(q \times 1)$
	$\varepsilon$	แทนเวกเตอร์ของความคลาดเคลื่อนที่มีขนาด $(n \times 1)$
	$n$	แทนขนาดตัวอย่าง

$p$  แทนจำนวนพจน์พหุนามในสมการดังนี้ คือ 2, 3, 4, 5 และ 6  
 และ  $q$  แทนจำนวนพารามิเตอร์ในตัวแบบเป็น  $p+1$

โดยมีข้อกำหนดว่าค่าลำดับชั้น (rank) ของเมทริกซ์  $X$  เท่ากับ  $q$  เมื่อ  $q < n$   
 ความคลาดเคลื่อนเป็นตัวแปรสุ่มที่เป็นอิสระกันและมีการแจกแจงเดียวกันที่มีค่าเฉลี่ย  $E(\varepsilon) = 0$   
 และเมทริกซ์ความแปรปรวน  $E(\varepsilon \varepsilon') = \sigma^2 I_n$

ให้  $\hat{\beta}_{OLS}$  แทน เวกเตอร์ของตัวประมาณแบบกำลังสองน้อยสุดของค่าพารามิเตอร์  $\beta$

และ  $e$  แทน เวกเตอร์ของส่วนเหลือ (Residuals) ที่เป็นตัวประมาณของความคลาดเคลื่อน  
 $\varepsilon$  เมื่อแทนที่  $\beta$  ด้วย  $\hat{\beta}_{OLS}$  และแทน  $\varepsilon$  ด้วย  $e$  ในตัวแบบเชิงเส้น จะได้

$$y = X \hat{\beta}_{OLS} + e$$

และ

$$e = \hat{\varepsilon} = y - X \hat{\beta}_{OLS}$$

พิจารณามลบทวนของความคลาดเคลื่อนกำลังสอง

$$\begin{aligned} SSE &= (e' e) \\ &= (y - X \hat{\beta}_{OLS})' (y - X \hat{\beta}_{OLS}) \\ &= y' y - y' X \hat{\beta}_{OLS} - \hat{\beta}_{OLS}' X' y + \hat{\beta}_{OLS}' X' X \hat{\beta}_{OLS} \\ &= y' y - 2 \hat{\beta}_{OLS}' X' y + \hat{\beta}_{OLS}' X' X \hat{\beta}_{OLS} \end{aligned}$$

ผู้วิจัยทำการหาค่าของ  $\hat{\beta}_{OLS}$  ที่ทำให้ผลบวกกำลังสองของความคลาดเคลื่อนมีค่าต่ำสุด  
 โดยการหาอนุพันธ์ (Differentiate) ของ SSE เทียบกับ  $\hat{\beta}_{OLS h}$  เมื่อ  $h = 0, 1, \dots, p$  แล้ว  
 กำหนดให้เท่ากับ 0 จะได้

$$\begin{aligned} \frac{\partial}{\partial \hat{\beta}_{OLS h}} (y' y - 2 \hat{\beta}_{OLS h}' X' y + \hat{\beta}_{OLS h}' X' X \hat{\beta}_{OLS h}) &= 0, \quad h = 0, 1, \dots, p \\ -2X' y + 2X' X \hat{\beta}_{OLS} &= 0 \\ X' X \hat{\beta}_{OLS} &= X' y \\ \hat{\beta}_{OLS} &= (X' X)^{-1} X' y \end{aligned} \tag{2.7}$$

ตัวประมาณ  $\hat{\beta}_{OLS}$  จะให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำสุดในบรรดาตัวประมาณไม่เอนเอียงเชิงเส้น แต่ในการประมาณค่า  $\beta$  ด้วยวิธีกำลังสองน้อยสุดมีข้อสมมุติฐานสำคัญข้อหนึ่งคือตัวแปรอิสระแต่ละตัวต้องไม่มีความสัมพันธ์กับตัวแปรอิสระตัวอื่นซึ่งในทางปฏิบัติจะเป็นไปได้้น้อยมาก เมื่อตัวแปรอิสระมีพหุสัมพันธ์กันสูงจะทำให้เมทริกซ์  $X'X$  เกิดเงื่อนไขที่ไม่ดี (ill-condition) อาจมีผลทำให้การประมาณ  $\hat{\beta}$  ด้วยวิธีกำลังสองน้อยสุดแล้วไม่ได้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำสุด เราจึงควรตรวจสอบประสิทธิภาพของตัวประมาณที่ได้โดยเราพิจารณาประสิทธิภาพของตัวประมาณค่า  $\hat{\beta}$  สองส่วน กล่าวคือเมทริกซ์ความแปรปรวนร่วมของตัวประมาณ  $\hat{\beta}$  และค่าเฉลี่ยของกำลังสองของระยะทางจาก  $\hat{\beta}$  ไปยัง  $\beta$  ซึ่งเราสามารถเขียนเมทริกซ์ความแปรปรวนร่วมของ  $\hat{\beta}$  ในรูปฟังก์ชันของ  $X'X$  และ  $\sigma^2$  ดังต่อไปนี้

$$(2.8) \quad Cov(\hat{\beta}) = \sigma^2 (X'X)^{-1}$$

ให้  $L_1$  คือระยะทางจาก  $\hat{\beta}$  ไปยัง  $\beta$  ดังนั้น

$$(2.9) \quad L_1^2 = (\hat{\beta} - \beta)'(\hat{\beta} - \beta)$$

และเราจะได้ค่าเฉลี่ยของกำลังสองระยะทางจาก  $\hat{\beta}$  ไปยัง  $\beta$  ในรูปของ

$$(2.10) \quad \begin{aligned} E(L_1^2) &= \sigma^2 \text{trace}(X'X)^{-1} \\ E(L_1^2) &= E[(\hat{\beta} - \beta)'(\hat{\beta} - \beta)] \\ &= E[\hat{\beta}'\hat{\beta}] - \beta'\beta \end{aligned}$$

$$(2.11) \quad E[\hat{\beta}'\hat{\beta}] = \beta'\beta + \sigma^2 \text{trace}(X'X)^{-1}$$

เมื่อ  $\varepsilon$  มีการแจกแจงแบบปกติจะได้ว่า

$$(2.12) \quad Var(L_1^2) = 2\sigma^4 \text{trace}(X'X)^{-2}$$

จากสมการที่ (2.8), (2.10) และ (2.12) เราจะเห็นได้ว่า  $Cov(\hat{\beta})$ ,  $E[L_1^2]$  และ  $Var(L_1^2)$  ต่างก็เป็นฟังก์ชันของเมทริกซ์  $X'X$  ดังนั้นเพื่อความสะดวกในการทำความเข้าใจเราจึงแปลงเมทริกซ์  $X'X$  ให้อยู่ในรูปของค่าเฉพาะ (eigenvalue) ของเมทริกซ์  $X'X$  โดยใช้ทฤษฎีที่สำคัญข้อหนึ่งคือ ถ้า  $\lambda_i$  เป็นค่าเฉพาะของเมทริกซ์  $X'X$  แล้ว  $\sum_{i=1}^p \lambda_i = \text{trace}(X'X)$ ;  $i = 1, 2, \dots, p$  เมื่อ  $p$  เป็นจำนวนตัวแปรอิสระ

กำหนดให้ค่าเฉพาะของเมทริกซ์  $X'X$  มีค่าเป็น

$$(\lambda_{\max} = \lambda_1) \geq \lambda_2 \geq \dots \geq (\lambda_{\min} = \lambda_p) \quad ; \quad \lambda_1, \lambda_2, \dots, \lambda_p > 0$$

จากสมการที่ (2.10) เราสามารถเขียนค่าเฉลี่ยของกำลังสองระยะทางจาก  $\hat{\beta}$  ไปยัง  $\beta$  ในรูปฟังก์ชันของค่าเฉพาะได้ดังนี้

$$(2.13) \quad E(L_1^2) = \sigma^2 \sum_{i=1}^k \left( \frac{1}{\lambda_i} \right)$$

และจากสมการที่ (2.12) เราสามารถเขียนค่าความแปรปรวนของกำลังสองระยะทางจาก  $\hat{\beta}$  ไปยัง  $\beta$  อยู่ในรูปฟังก์ชันของค่าเฉพาะได้ดังนี้

$$(2.14) \quad \text{Var}(L_1^2) = 2\sigma^4 \sum_{i=1}^k \left( \frac{1}{\lambda_i} \right)^2$$

ในกรณีที่ตัวแปรอิสระมีสภาพไม่เหมาะสม กล่าวคือเกิดความสัมพันธ์ระหว่างตัวแปรอิสระในอัตราที่สูงจะทำให้  $|X'X|$  มีค่าเล็กลงเข้าใกล้ศูนย์ เนื่องจาก  $|X'X|$  มีค่าเท่ากับผลคูณของค่าเฉพาะของเมทริกซ์  $X'X$  จึงส่งผลให้ค่าเฉพาะบางค่าต่ำมาก ดังนั้นจากสมการที่ (2.12) และ (2.13) เราจะเห็นได้ว่า  $E(L_1^2)$  และ  $\text{Var}(L_1^2)$  จึงมีค่าสูงขึ้นตามไปด้วย นอกจากนี้การเกิดความสัมพันธ์ระหว่างตัวแปรอิสระส่งผลให้ความแปรปรวนของค่าประมาณสัมประสิทธิ์การถดถอยมีค่ามากและเกิดความสัมพันธ์กันสูง ระหว่างสัมประสิทธิ์การถดถอยที่ใช้ประมาณค่า<sup>1</sup>

### 2.1.3 ตัวประมาณค่าสัมบูรณ์น้อยสุด (Least Absolute Value Estimator)<sup>2</sup>

การประมาณค่าพารามิเตอร์ของตัวแบบการถดถอยพหุคูณด้วยตัวประมาณค่าสัมบูรณ์น้อยสุด จะใช้เทคนิคโปรแกรมเชิงเส้น (Linear Programming Technique) ในการประมาณค่าพารามิเตอร์ที่ทำให้ผลรวมของค่าสัมบูรณ์ของความคลาดเคลื่อนมีค่าต่ำสุด

จากรูปแบบสมการถดถอยเชิงเส้นพหุคูณ

$$(2.15) \quad y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \dots + \beta_p x_i^p + \varepsilon_i \quad , \quad i = 1, 2, \dots, n$$

ให้  $\hat{\beta}$  เป็นตัวประมาณแบบค่าสัมบูรณ์น้อยสุดของค่าพารามิเตอร์  $\beta$

และ  $e_i$  เป็นตัวประมาณของค่าความคลาดเคลื่อน  $\varepsilon_i$

เมื่อแทน  $\beta$  ด้วย  $\hat{\beta}$  และแทนที่  $\varepsilon_i$  ด้วย  $e_i$  ในสมการ (2.15) จะได้

<sup>1</sup> สมพล อารุณศักดิ์กูร. “การเปรียบเทียบวิธีการประมาณค่าพารามิเตอร์ในการวิเคราะห์ความถดถอยพหุคูณด้วยวิธีกำลังสองน้อยสุด วิธีริงรีเกรสชันที่ใช้ข้อมูลสมมติโดยหลักเกณฑ์ และวิธีลิวติเจินทั่วไป เมื่อเกิดความสัมพันธ์ระหว่างตัวแปรอิสระ”. (วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ ภาควิชาสถิติ บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2539), หน้า 9 – 11

<sup>2</sup> ปัทมาวี นันทานนทร. “การเปรียบเทียบตัวประมาณการถดถอยเมื่อมีพหุสัมพันธ์และหรือมีค่าผิดปกติ”. (วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ ภาควิชาสถิติ บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2544), หน้า 12 - 14

$$(2.16) \quad y_i = \hat{\beta}_{0,L,U} + \hat{\beta}_{1,L,U} x_i + \hat{\beta}_{2,L,U} x_i^2 + \dots + \hat{\beta}_{p,L,U} x_i^p + e_i, \quad i = 1, 2, \dots, n$$

$$\text{และ} \quad e_i = y_i - \hat{\beta}_{0,L,U} - \hat{\beta}_{1,L,U} x_i - \hat{\beta}_{2,L,U} x_i^2 - \dots - \hat{\beta}_{p,L,U} x_i^p$$

เราต้องการหาค่า  $\hat{\beta}_{0,L,U}, \hat{\beta}_{1,L,U}, \hat{\beta}_{2,L,U}, \dots, \hat{\beta}_{p,L,U}$  ที่ทำให้ผลรวมของค่าสัมบูรณ์ของความคลาดเคลื่อนมีค่าต่ำสุดกล่าวคือ

$$(2.17) \quad \text{Minimize} \quad \sum_{i=1}^n |e_i|$$

$$\text{ภายใต้เงื่อนไข} \quad e_i = y_i - \hat{\beta}_{0,L,U} - \hat{\beta}_{1,L,U} x_i - \hat{\beta}_{2,L,U} x_i^2 - \dots - \hat{\beta}_{p,L,U} x_i^p$$

จากสมการ (2.17) แปลงให้อยู่ในรูปโปรแกรมเชิงเส้นได้ดังนี้

$$\text{กำหนดให้} \quad Z = \sum_{i=1}^n |e_i|$$

เนื่องจาก  $e_i$  ไม่มีข้อจำกัดด้านเครื่องหมาย จะได้ว่า

$$e_i = e_i^+ - e_i^-, \quad e_i^+, e_i^- \geq 0$$

เมื่อ

$$e_i^+ = \begin{cases} e_i, & e_i \geq 0 \\ 0, & e_i < 0 \end{cases}$$

และ

$$e_i^- = \begin{cases} 0, & e_i \geq 0 \\ -e_i, & e_i < 0 \end{cases}$$

เพราะฉะนั้น จะได้ว่า  $(e_i^+)(e_i^-) = 0$

นั่นคือ อย่างน้อย 1 ตัวใน  $e_i^+$  และ  $e_i^-$  จะมีค่าเท่ากับ 0 เสมอ

ดังนั้น  $|e_i| = e_i^+ + e_i^-$

ให้  $u = e_i^+$  และ  $v = e_i^-$

เนื่องจากพารามิเตอร์  $\hat{\beta}_{0,L,U}, \hat{\beta}_{1,L,U}, \hat{\beta}_{2,L,U}, \dots, \hat{\beta}_{p,L,U}$  ไม่มีข้อจำกัดด้านเครื่องหมาย

จึงสามารถเขียนได้ในรูป

$$\hat{\beta}_{0,L,U} = \hat{\beta}_{0,L,U}^+ - \hat{\beta}_{0,L,U}^-$$

$$\hat{\beta}_{1,L,U} = \hat{\beta}_{1,L,U}^+ - \hat{\beta}_{1,L,U}^-$$

และ 
$$\hat{\beta}_{p_{L,U}} = \hat{\beta}_{p_{L,U}}^+ - \hat{\beta}_{p_{L,U}}^-$$

เมื่อ 
$$\hat{\beta}_{0_{L,U}}^+, \hat{\beta}_{0_{L,U}}^-, \hat{\beta}_{1_{L,U}}^+, \hat{\beta}_{1_{L,U}}^-, \hat{\beta}_{2_{L,U}}^+, \hat{\beta}_{2_{L,U}}^-, \dots, \hat{\beta}_{p_{L,U}}^+, \hat{\beta}_{p_{L,U}}^- \geq 0$$

ดังนั้น เราสามารถแปลงปัญหา (2.14) ได้เป็น

$$\text{Minimize } Z = \sum_{i=1}^n (u_i + v_i)$$

ภายใต้เงื่อนไข

$$(\hat{\beta}_{0_{L,U}}^+ - \hat{\beta}_{0_{L,U}}^-) + (\hat{\beta}_{1_{L,U}}^+ - \hat{\beta}_{1_{L,U}}^-)x_i + (\hat{\beta}_{2_{L,U}}^+ - \hat{\beta}_{2_{L,U}}^-)x_i^2 + K + (\hat{\beta}_{p_{L,U}}^+ - \hat{\beta}_{p_{L,U}}^-)x_i^p + u_i - v_i = y_i$$

$$\hat{\beta}_{0_{L,U}}^+, \hat{\beta}_{0_{L,U}}^-, \hat{\beta}_{1_{L,U}}^+, \hat{\beta}_{1_{L,U}}^-, \hat{\beta}_{2_{L,U}}^+, \hat{\beta}_{2_{L,U}}^-, \dots, \hat{\beta}_{p_{L,U}}^+, \hat{\beta}_{p_{L,U}}^- \geq 0, u_i, v_i \geq 0$$

$$; i = 1, 2, \dots, n$$

หรือหาค่าต่ำสุดของ

$$Z = (u_1 + \dots + u_n + v_1 + \dots + v_n) + 0(\hat{\beta}_{0_{L,U}}^+ - \hat{\beta}_{0_{L,U}}^-) + 0(\hat{\beta}_{1_{L,U}}^+ - \hat{\beta}_{1_{L,U}}^-) + \dots + 0(\hat{\beta}_{p_{L,U}}^+ - \hat{\beta}_{p_{L,U}}^-)$$

ภายใต้เงื่อนไข

$$(\hat{\beta}_{0_{L,U}}^+ - \hat{\beta}_{0_{L,U}}^-) + (\hat{\beta}_{1_{L,U}}^+ - \hat{\beta}_{1_{L,U}}^-)x_1 + (\hat{\beta}_{2_{L,U}}^+ - \hat{\beta}_{2_{L,U}}^-)x_1^2 + K + (\hat{\beta}_{p_{L,U}}^+ - \hat{\beta}_{p_{L,U}}^-)x_1^p + u_1 - v_1 = y_1$$

$$(\hat{\beta}_{0_{L,U}}^+ - \hat{\beta}_{0_{L,U}}^-) + (\hat{\beta}_{1_{L,U}}^+ - \hat{\beta}_{1_{L,U}}^-)x_2 + (\hat{\beta}_{2_{L,U}}^+ - \hat{\beta}_{2_{L,U}}^-)x_2^2 + K + (\hat{\beta}_{p_{L,U}}^+ - \hat{\beta}_{p_{L,U}}^-)x_2^p + u_2 - v_2 = y_2$$

$\Lambda$

$\Lambda$

$$(\hat{\beta}_{0_{L,U}}^+ - \hat{\beta}_{0_{L,U}}^-) + (\hat{\beta}_{1_{L,U}}^+ - \hat{\beta}_{1_{L,U}}^-)x_i + (\hat{\beta}_{2_{L,U}}^+ - \hat{\beta}_{2_{L,U}}^-)x_i^2 + K + (\hat{\beta}_{p_{L,U}}^+ - \hat{\beta}_{p_{L,U}}^-)x_i^p + u_i - v_i = y_i$$

$$\hat{\beta}_{0_{L,U}}^+, \hat{\beta}_{0_{L,U}}^-, \hat{\beta}_{1_{L,U}}^+, \hat{\beta}_{1_{L,U}}^-, \hat{\beta}_{2_{L,U}}^+, \hat{\beta}_{2_{L,U}}^-, \dots, \hat{\beta}_{p_{L,U}}^+, \hat{\beta}_{p_{L,U}}^- \geq 0, u_i, v_i \geq 0$$

$$; i = 1, 2, \dots, n$$

และหาค่า  $\hat{\beta}_{0_{L,U}}^+, \hat{\beta}_{0_{L,U}}^-, \hat{\beta}_{1_{L,U}}^+, \hat{\beta}_{1_{L,U}}^-, \hat{\beta}_{2_{L,U}}^+, \hat{\beta}_{2_{L,U}}^-, \dots, \hat{\beta}_{p_{L,U}}^+, \hat{\beta}_{p_{L,U}}^-$  โดยใช้วิธีการซิมเพล็กซ์ (Simplex Method) ซึ่งได้แสดงรายละเอียดวิธีคำนวณ และขั้นตอนต่าง ๆ ของวิธีการซิมเพล็กซ์

### 2.1.4 วิธีซิมเพล็กซ์ (Simplex Method)<sup>3</sup>

ปัญหาของโปรแกรมเชิงเส้น (Linear Programming) ไม่ได้จำกัดอยู่กับตัวแปรเพียง 2 ตัว หรือสมการข้อกำหนดเพียง 3 สมการ เราอาจขยายจำนวนตัวแปรและจำนวนสมการ ข้อกำหนดได้ตามลักษณะของปัญหาที่เป็นจริง ข้อกำหนดโดยทั่ว ๆ ไปนั้น อยู่ที่ขนาดและความสามารถของคอมพิวเตอร์ที่จะใช้เพื่อการคำนวณเป็นสำคัญ สำหรับในทางคณิตศาสตร์นั้น ไม่ว่าปัญหาที่ต้องการหาคำตอบจะเป็นอย่างไร เราก็ต้องจัดรูปให้อยู่ในรูปแบบของสมการทางคณิตศาสตร์ที่มีรูปแบบแน่นอนดังต่อไปนี้

สมมติให้มีตัวแปรจำนวน  $n$  ตัว และสมการข้อกำหนดจำนวน  $m$  สมการ เราจะสามารถเขียนรูปแบบมาตรฐานของโปรแกรมเชิงเส้นในรูปแบบเมทริกซ์ได้ดังนี้

$$\text{เป้าหมาย : } \text{Max } G = g'x$$

$$\text{ข้อกำหนด : } Ax \leq T$$

หรือเขียนในรูปแบบของสมการคือ

$$\text{สมการเป้าหมาย : } \text{MAX } G = g_0 + g_1x_1 + g_2x_2 + \dots + g_nx_n$$

สมการข้อกำหนด :

$$a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n \leq T_1$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n \leq T_2$$

⋮

⋮

$$a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mn}x_n \leq T_m$$

และต้องไม่ลืมข้อกำหนดที่ว่า  $x \geq 0$  (the nonnegativity constraint) คือตัวแปรทุกตัวมีค่าเป็นบวกนั่นเอง ปัญหาดังกล่าวจึงจัดอยู่ในรูปแบบของโปรแกรมเชิงเส้นแบบมาตรฐาน ซึ่งเราจะได้ศึกษากันถึงวิธีการแก้ปัญหาในรายละเอียดต่อไป

ก่อนที่จะเริ่มต้นวิธีการซิมเพล็กซ์นั้น มีปัญหาใหญ่ที่ต้องแก้ก่อนประการหนึ่งคือ ข้อกำหนดที่มีลักษณะเป็นอสมการนั้น จะต้องทำให้อยู่ในรูปของเครื่องหมาย "=" ก่อน วิธีการก็คือใช้ตัวแปรช่วย (slack variable)  $y$  บางคนเรียกว่าเป็นตัวแปรขาดซึ่งหมายถึง ตัวแปรที่ใส่ในสมการข้อกำหนดเพื่อให้สิ่งที่เราขาดอยู่เต็มนั่นเอง เพื่อให้ง่ายแก่การเข้าใจ จะยกตัวอย่างดังต่อไปนี้

$$\text{สมการเป้าหมาย : } \text{MAX } G = 10x_1 + 15x_2$$

<sup>3</sup> ปีทวดี นันทนาเนตร์. "การเปรียบเทียบตัวประมาณการลดขยเมื่อมีพหุสัมพันธ์และหรือมีค่าคิดปกติ", (วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ ภาควิชาสถิติ บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2544), หน้า 369 - 373



สมการข้อจำกัด :

$$(1) \quad 3x_1 + x_2 \leq 15$$

$$(2) \quad x_1 + 2x_2 \leq 10$$

$$(3) \quad 2x_1 \leq 9$$

เมื่อใช้ตัวแปรช่วย (slack variable)  $y$  ปัญหาจะเป็นดังนี้

สมการเป้าหมาย :  $MAX \ G = 10x_1 + 15x_2$

สมการข้อจำกัด :

$$(1) \quad 3x_1 + x_2 + y_1 = 15$$

$$(2) \quad x_1 + 2x_2 + y_2 = 10$$

$$(3) \quad 2x_1 + y_3 = 9$$

และต้องไม่ลืมข้อจำกัดที่ว่า  $y \geq 0$  เช่นเดียวกัน ในการคำนวณด้วยวิธีการซิมเพล็กซ์นั้น จะมีตัวแปรที่ต้องกำหนดค่าให้เป็นศูนย์ เราเรียกตัวแปรนี้ว่า " ตัวแปรไม่ตัวแปรฐาน " (nonbasis variables) และตัวแปรอื่นๆ นอกไปจากนี้ เราเรียกว่า " ตัวแปรฐาน " (basis variables) ถ้าตัวแปรฐานทุกตัวไม่มีค่าติดลบ เราเรียกว่า " คำตอบที่เป็นไปได้เบื้องต้น " (basis feasible solution)

วิธีการซิมเพล็กซ์เริ่มต้นด้วยนำสมการปัญหาที่จัดรูปแบบสมการทางคณิตศาสตร์แล้ว ไปสร้างตารางซิมเพล็กซ์ (Simplex Tables) ซึ่งมีลักษณะดังนี้

ตัวแปร	G	$x_1$	$x_2$	$y_1$	$y_2$	$y_3$	T
$y_1$	0	3	1	1	0	0	15
$y_2$	0	1	(2)	0	1	0	10
$y_3$	0	2	0	0	0	1	9
$g_1$	-	10	15	0	0	0	0
$K_1$	-	0	0	0	0	0	0
$(K_1 - g_1)$	-	-10	-15	0	0	0	0

ตารางที่ 1 แสดงตารางซิมเพล็กซ์ที่ได้จากสมการข้างต้น

ตารางซิมเพล็กซ์มีส่วนสำคัญอยู่ 4 ส่วน ด้วยกันคือ ส่วนที่ 1 เป็นตัวแปร  $g$  ซึ่งแทนสัมประสิทธิ์ของสมการเป้าหมาย ส่วนที่ 2 คือ ตัวแปรโครงสร้าง  $x$ , ซึ่งจะประกอบด้วย

สัมประสิทธิ์ของ  $x_i$  ในสมการข้อจำกัดทั้งหมดซึ่งเราตั้งชื่อให้ว่า เมทริกซ์ A ส่วนที่ 3 คือ ตัวแปรช่วย  $y$  ซึ่งจะเป็นเมทริกซ์เอกลักษณ์ (identity matrix) สอดคล้องกับวิธีการที่เราจะหาค่าเมทริกซ์ผกผันของ A นั้นเอง และส่วนที่ 4 คือ ตัวแปรทางด้านขวามือของสมการข้อจำกัด คือ T ในตารางที่ 1 นี้ เรากำหนดให้ตัวแปรช่วยเป็นตัวแปรฐานเริ่มต้น

วิธีการคำนวณนั้น เริ่มด้วยการใส่ค่าของ  $g_i$  ซึ่งเป็นค่าสัมประสิทธิ์ของสมการเป้าหมาย โดยสัมประสิทธิ์ของตัวแปรช่วยในสมการเป้าหมายมีค่าเป็นศูนย์ จากนั้นคำนวณหาค่า  $K_i$  ดังนี้

$$K_1 = 3.0 + 1.0 + 2.0 = 0 \quad (\text{ของ } x_1)$$

$$K_2 = 1.0 + 2.0 + 0.0 = 0 \quad (\text{ของ } x_2)$$

∞

∞

$$K_T = 15.0 + 10.0 + 9.0 = 0 \quad (\text{ของ } T)$$

ซึ่งก็คือ เอาค่าของ  $g$  คูณกับ A แล้วบวกเข้าด้วยกันนั่นเอง จากนั้น จึงหาค่า  $(K_i - g_i)$  เป็นอันเสร็จสิ้นตารางที่ 1

จากผลลัพธ์ของตารางที่ 1 นี้ มีสิ่งที่จะต้องสังเกต 2 ประการ

1. ให้เลือกค่า  $(K_i - g_i)$  ที่เป็นลบมากที่สุด ตามตัวอย่าง คือ -15 เป็น สดมภ์หลัก(pivot column)
2. ให้นำค่า T หารด้วยค่าของ A ใน สดมภ์หลัก (pivot column) เช่น  $15/1$  ,  $10/2$  โดยเลือกเฉพาะ A ที่มากกว่าศูนย์ ให้เลือกค่าน้อยที่สุดคือ  $10/2$  เป็น แถวหลัก (pivot row)

สดมภ์หลัก (pivot column) และ แถวหลัก (pivot row) พบกันที่ใด จะทำให้เราได้ เลขหลัก (pivot number) ซึ่งในที่นี้ คือ (2)

การแก้ปัญหาด้วยวิธีการซิมเพล็กซ์นั้น ใช้วิธีการทำซ้ำ (Iterative Step) ซึ่งเลียนแบบวิธีการของการหาเมทริกซ์ผกผันของ A โดยการนำ เลขหลัก (pivot number) ให้มีค่าเป็นหนึ่ง และตัวอื่น ๆ ของ A ในแถวตั้งนั้นมีค่าเป็นศูนย์ นั่นก็คือ เอา (2) หารตลอดแถวบนของ  $y_2$  จากนั้นหาค่า A ในแถวตั้ง  $x_2$  และแถวบน  $y_1$  และ  $y_3$  ให้เป็นศูนย์ เช่นกรณีของแถวบน  $y_1$  จะคำนวณได้ดังนี้

แถวนอน  $y_1 = 3 - 1(1/2), 1 - 1(2/2), 1 - 1(0/2), 0 - 1(1/2), 0 - 1(0/2), 15 - 1(10/2)$  สำหรับแถวนอน  $y_3$  ก็ทำด้วยวิธีการเดียวกัน เราจะได้ตารางที่ 2 ดังนี้คือ

ตัวแปร	G	$x_1$	$x_2$	$y_1$	$y_2$	$y_3$	T
$y_1$	0	(2.5)	0	1	-0.5	0	10
$x_2$	15	0.5	1	0	0.5	0	5
$y_3$	0	2	0	0	0	1	9
$(K_1 - g_1)$	-	-2.5	0	0	7.5	0	75

ตารางที่ 2 ตารางซิมเพล็กซ์แสดงการทำซ้ำในขั้นตอนก่อนหน้า

สิ่งที่เปลี่ยนไปอย่างเห็นได้ชัดในตารางที่ 2 นี้ก็คือ การนำ  $x_2$  ซึ่งเป็น สดมภ์หลัก (pivot column) เข้าไปอยู่ในฐาน (basis) โดยไปแทน  $y_2$  ซึ่งเป็น แถวหลัก (pivot row) มีความหมายทางเศรษฐศาสตร์ว่า ถ้าเราเพิ่มการผลิต  $x_2$  เป็นจำนวน 5 หน่วย จะทำให้กำไรซึ่งจากเดิมเป็นศูนย์นั้น เพิ่มขึ้นเป็น 75 ต่อวัน แต่กำไรรวมดังกล่าวนี้จะสูงที่สุดหรือไม่นั้น ให้ดูจากค่าของ  $(K_1 - g_1)$  ถ้าหากยังคงมีตัวใดตัวหนึ่งที่เป็นลบอยู่ ก็หมายถึงว่ายังสามารถเพิ่มกำไรรวมขึ้นได้อีก โดยการผลิตสินค้าดังกล่าวเพิ่มขึ้น เช่นในกรณีของตารางที่ 2 นี้  $(K_1 - g_1)$  เป็นลบที่แถวตั้ง  $x_1$  และจากการหา แถวหลัก (pivot row) ด้วยวิธีเดิม จะเห็นว่า ถ้าเอา  $x_1$  ไปแทน  $y_1$  โดยผลิต  $x_1$  เพิ่มขึ้น จะได้กำไรเพิ่มขึ้นด้วย เลขหลัก (pivot number) คือ (2.5) จากการทำซ้ำเช่นเดียวกัน จะได้ตารางที่ 3 ดังนี้

ตัวแปร	G	$x_1$	$x_2$	$y_1$	$y_2$	$y_3$	T
$x_1$	10	1	0	0.4	-0.2	0	4
$x_2$	15	0	1	-0.2	0.6	0	3
$y_3$	0	0	0	-0.8	0.4	1	1
$(K_1 - g_1)$	-	0	0	1	7.5	0	85

ตารางที่ 3 ตารางซิมเพล็กซ์ที่แสดงการทำขั้นตอนซ้ำจากขั้นตอนก่อน

คำตอบที่ได้ในตารางที่ 3 นี้ก็คือ การผลิต  $x_1$  ซึ่งจากเดิมเป็นศูนย์เพิ่มขึ้น 4 หน่วย ในขณะที่การผลิต  $x_2$  ซึ่งจากเดิมเป็น 5 ลดลงเป็น 3 หน่วยนั้น จะทำให้กำไรเพิ่มขึ้นเป็น 85 ต่อวัน ในขณะที่  $y_3$  เหลืออยู่อีก 1 หน่วย จากการตรวจสอบปรากฏว่า  $(K_1 - g_1)$  ทุกตัวมีค่าเป็นบวก คำตอบที่ได้นี้จึงเป็นค่าที่สูงที่สุดหรือกำไรสูงที่สุด

วิธีคำนวณซิมเพล็กซ์แบบมาตรฐานที่แสดงมาแล้วนี้ สามารถสรุปเป็นขั้นตอนในแบบ  
ทั่ว ๆ ไปได้ดังนี้

1. หาค่าสัมประสิทธิ์ที่มีค่าน้อยที่สุดในสมการเป้าหมาย หรือ  $(K_i - g_i)$   
ถ้า  $(K_i - g_i) \geq 0$  แสดงว่าได้กำไรสูงสุดแล้ว  
แต่ถ้า  $(K_i - g_i) < 0$  กำหนดแถวตั้งที่มีค่าสัมประสิทธิ์ในสมการเป้าหมายที่น้อย  
ที่สุดเป็น pivot column
2. หาข้อจำกัดที่แคบที่สุดบนแถวที่เป็น แถวหลัก (pivot column) เพื่อกำหนดแถวนอน  
เรียก แถวหลัก (pivot row)

คำนวณ  $T_j / a_{jk}$  สำหรับ  $a_{jk} > 0$

เลือก  $T_j / a_{jk} = \min(T_j / a_{jk}, a_{jk} > 0)$

ให้  $a_{pk}$  เป็น เลขหลัก (pivot number)

3. คำนวณ  $b_{pi} = a_{pi} / a_{pk}$  สำหรับทุกค่าของ  $i$  และคำนวณ  $T_p = T_p / a_{pk}$

4. คำนวณ  $b_{ji} = a_{ji} - a_{jk} b_{pi}$

$$T_j^* = T_j - a_{jk} T_p^*$$

$$(K_i - g_i)^* = (K_i - g_i) - (K_k - g_k) b_{pi}$$

สำหรับทุกค่าของ  $i$  และ  $j$  ไม่เท่ากับ  $p$

5. แทน  $a_{ji} = b_{ji}$  สำหรับทุกค่าของ  $j$  และ  $i$

$$T_j = T_j^* \text{ สำหรับทุกค่าของ } j$$

และ  $(K_i - g_i) = (K_i - g_i)^*$  สำหรับทุกค่าของ  $i$

6. ทำซ้ำตามข้อ 1.

### 2.1.5 ตัวประมาณริดจ์ (Ridge Estimator)

ในกรณีที่ตัวแปรอิสระในสมการถดถอยมีสหสัมพันธ์กันสูงนั้น ตัวประมาณกำลัง  
สองน้อยสุดจะให้ค่าประมาณที่ขาดความแม่นยำ (imprecise) ลักษณะของสหสัมพันธ์อาจจะ  
เป็นคู่ของตัวแปร หรือ อาจเป็นลักษณะที่ตัวแปรอิสระตัวหนึ่ง เป็นผลรวมเชิงเส้น (linear  
combination) ของตัวแปรอิสระตัวอื่น ๆ ในสมการการถดถอย ซึ่งในสถานการณ์เช่นนี้ จะมีตัว  
แปรอิสระอย่างน้อย 1 ตัวที่มีค่าความคลาดเคลื่อนมาตรฐานสูง ซึ่งจะส่งผลให้การทดสอบ  
สมมติฐานโดยใช้การทดสอบที (t-test) ของสัมประสิทธิ์การถดถอยของตัวแปรดังกล่าว มีโอกาส  
ผิดพลาดสูง

ในปี ค.ศ. 1962 โฮเอิล (Hoerl) เป็นผู้คิดค้นตัวประมาณการถดถอยริดจ์ขึ้นมาใช้เป็นครั้งแรก โดยในขั้นแรกนั้นการนำเทคนิคการถดถอยริดจ์มาใช้เพื่อทดสอบว่าการเปลี่ยนแปลงค่าของตัวแปรอิสระเพียงเล็กน้อยมีผลในการเปลี่ยนแปลงค่าประมาณของสัมประสิทธิ์การถดถอยอย่างไร และพบว่าในกรณีที่ข้อมูลมีพหุสัมพันธ์การเปลี่ยนแปลงค่าของตัวแปรอิสระเพียงเล็กน้อยจะส่งผลให้ค่าประมาณสัมประสิทธิ์การถดถอยเปลี่ยนไปอย่างมาก

ต่อมาในปี ค.ศ. 1970 โฮเอิล (Hoerl) และ เคนนาร์ด (Kennard) ได้ศึกษาหาตัวประมาณค่าพารามิเตอร์ในตัวแบบการถดถอยพหุคูณเชิงเส้นที่ให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำกว่าตัวประมาณกำลังสองน้อยสุดเมื่อข้อมูลเกิดพหุสัมพันธ์ระหว่างตัวแปรอิสระซึ่งหลักการโดยทั่วไปของตัวประมาณนี้คือเมื่อพบว่า  $|X'X| \rightarrow 0$  ซึ่งจะมีผลให้  $(X'X)^{-1}$  มีแนวโน้มที่จะไม่ปรากฏค่า และค่าประมาณของ  $\beta$  คือ  $\hat{\beta} = (X'X)^{-1} X'y$  มีค่าสูงผิดความจริงจึงพยายามปรับรูปเมทริกซ์  $X'X$  โดยการบวกค่าคงที่ใด ๆ ค่าหนึ่งที่ยากกว่าศูนย์ ( $k$ ) มาบวกกับสมาชิกทุกตัวในแนวทแยงมุมของเมทริกซ์  $X'X$  จะทำให้เมทริกซ์  $X'X$  ลดสภาพความเป็นเมทริกซ์ที่ไม่ดี (ill - condition) ลงได้ ก่อนจะหาเมทริกซ์ผกผันของ  $X'X$  ดังกล่าว

สมการปกติ (Normal Equation) ของตัวประมาณการถดถอยริดจ์ สามารถเขียนได้ในรูปแบบดังนี้

$$(X'X + kI_n) \hat{\beta}_{HKB} = X'y$$

ดังนั้นตัวประมาณการถดถอยริดจ์ (Ridge Regression Estimator) เขียนได้ในรูป

$$(2.18) \quad \hat{\beta}_{HKB} = (X'X + kI_n)^{-1} X'y, \quad k > 0$$

เมื่อ  $k$  เป็นค่าคงที่ หรือเรียกว่าเป็น พารามิเตอร์ที่เอนเอียง (biased parameter)

และ  $I_n$  เป็นเมทริกซ์เอกลักษณ์ (identity matrix) ที่มีขนาด  $(n \times n)$

ตัวประมาณการถดถอยริดจ์เป็นตัวประมาณที่เอนเอียง แต่จะมีค่าความแปรปรวนน้อยกว่าตัวประมาณกำลังสองน้อยสุด

ในการวิเคราะห์การถดถอยพหุคูณเมื่อข้อมูลมีพหุสัมพันธ์นั้น การเลือกค่า  $k$  ที่เหมาะสม จะสามารถทำให้ตัวประมาณริดจ์มีค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำกว่าตัวประมาณกำลังสองน้อยสุดได้ แต่ในหลายกรณีเราไม่ทราบว่าคุณค่า  $k$  ที่เหมาะสมควรเป็นเท่าไร ซึ่งนักวิจัยได้เสนอวิธีการหาค่า  $k$  ที่เหมาะสมหลายวิธีด้วยกัน โดยเริ่มแรกในปี ค.ศ. 1970 โฮเอิล (Hoerl) และเคนนาร์ด (Kennard) ใช้เทคนิคการหาค่า  $k$  โดยพิจารณาจากกราฟ (Graphical Technique) หรือเรียกว่า Ridge Trace แต่เป็นวิธีการที่อาจให้คำตอบไม่แน่นอนขึ้นอยู่กับ

เลือกกำหนดของผู้ใช้ จึงมีผู้คิดค้นวิธีการหาค่า  $k$  ที่เหมาะสมโดยไม่ใช้กราฟ (Nongraphical Technique) ไว้หลายวิธี ซึ่ง Gibbons (1981) ได้ทำการวิจัยเพื่อเปรียบเทียบวิธีการต่าง ๆ ในการหาค่า  $k$  ที่เหมาะสม ผลการวิจัยพบว่า โดยภาพรวม วิธีการประมาณค่า  $k$  ที่คิดค้นโดยในปี ค.ศ. 1975 โฮเอล (Hoerl) , เคนนาร์ด (Kennard) และ บลาดวิน (Bladwin) ซึ่งแทนด้วย  $k_{HKB}$  เป็นวิธีการหนึ่งที่มีประสิทธิภาพที่ดีในการประมาณค่า วิธีการประมาณค่า  $k_{HKB}$  ประมาณได้จาก

$$(2.19) \quad k_{HKB} = \frac{p\sigma^2}{\hat{\beta}'\hat{\beta}}$$

เมื่อ  $p$  แทนจำนวนตัวแปรอิสระในการวิเคราะห์ความถดถอยพหุคูณ

$\hat{\beta}$  แทนค่าสัมประสิทธิ์สมการถดถอยพหุคูณที่ประมาณ

และ  $\sigma^2$  แทนความแปรปรวนของสมการถดถอยพหุคูณ

### ตัวประมาณริตจ์สามัญ (ROLS)

สร้างจากตัวประมาณริตจ์เกรสชันและตัวประมาณกำลังสองน้อยสุดสามัญ ซึ่งเรียกดั้งเดิมว่า ตัวประมาณริตจ์สามัญ (ROLS) โดยมีรูปแบบตัวประมาณดังนี้

เมื่อสมการปกติ (Normal Equation) ของตัวประมาณการถดถอยริตจ์สามัญสามารถเขียนได้ในรูป

$$(X'X + k_{OLS}I_n)\hat{\beta}_{ROLS} = X'y$$

ดังนั้น ตัวประมาณการถดถอยริตจ์สามัญ (Ridge Ordinary Least Square Estimator) เขียนได้ในรูปแบบดังนี้

$$(2.20) \quad \hat{\beta}_{ROLS} = (X'X + k_{OLS}I_n)^{-1}X'y$$

การประมาณ  $k_{OLS}$  คำนวณได้จากสมการ (2.19) โดยแทนค่า  $\hat{\beta}$  ด้วยตัวประมาณกำลังสองน้อยสุดสามัญ ( $\hat{\beta}_{OLS}$ ) ที่คำนวณได้จากสมการ (2.7) และแทนค่า  $\sigma^2$  ด้วย  $s_{OLS}^2$  ดังนั้น  $k_{OLS}$  สามารถเขียนได้ในรูปแบบดังต่อไปนี้

$$(2.21) \quad k_{OLS} = \frac{qs_{OLS}^2}{\hat{\beta}_{OLS}'\hat{\beta}_{OLS}}$$

เมื่อ  $s_{OLS}^2 = \frac{\left( \begin{matrix} y - X\hat{\beta}_{OLS} \\ \vdots \end{matrix} \right)' \left( \begin{matrix} y - X\hat{\beta}_{OLS} \\ \vdots \end{matrix} \right)}{n-q}$  เป็นตัวประมาณพารามิเตอร์  $\sigma^2$

และ  $q = p + 1$

### 2.1.6 ตัวประมาณริตจ์ที่มีความแกร่ง (Robust Ridge Estimator)

ในการวิเคราะห์การถดถอยพหุคูณเชิงเส้นนั้น เมื่อข้อมูลมีพหุสัมพันธ์ระหว่างตัวแปรอิสระและมีค่าผิดปกติขึ้นพร้อมกัน ในกรณีเช่นนี้ตัวประมาณค่าพารามิเตอร์ที่เหมาะสมน่าจะเป็นตัวประมาณที่ได้จากการผสมผสานระหว่างตัวประมาณที่ใช้แก้ปัญหาพหุสัมพันธ์และตัวประมาณที่ใช้แก้ปัญหาที่มีค่าผิดปกติเกิดขึ้น ซึ่งในหัวข้อนี้จะกล่าวถึงตัวประมาณบางตัวที่ได้จากการผสมผสานระหว่างตัวประมาณการถดถอยริตจ์และตัวประมาณการถดถอยที่มีความแกร่งซึ่งเราเรียกตัวประมาณดังกล่าวว่า ตัวประมาณริตจ์ที่มีความแกร่ง (Robust Ridge Estimator) ซึ่งได้แก่ตัวประมาณริตจ์ที่มีค่าสัมบูรณ์น้อยสุด (Ridge Least Absolute Value Estimator (RLAV)) เป็นตัวประมาณที่นำมาใช้ในการวิจัยครั้งนี้ ซึ่งมีรายละเอียดดังต่อไปนี้

#### ตัวประมาณริตจ์ที่มีค่าสัมบูรณ์น้อยสุด (RLAV)

ในปี ค.ศ. 1984 และ 1985 ฟลาฟเฟนเบอร์เกอร์ (Pfaffenberger) และเดิลแมน (Dielman) ได้สร้างตัวประมาณริตจ์รีเกรสชันที่มีความแกร่ง โดยสร้างจากตัวประมาณริตจ์รีเกรสชันและตัวประมาณค่าสัมบูรณ์น้อยสุด ซึ่งเรียกว่าตัวประมาณดังกล่าวว่า ตัวประมาณริตจ์ที่มีค่าสัมบูรณ์น้อยสุด (RLAV) ซึ่งมีรูปแบบตัวประมาณดังนี้

เมื่อสมการปกติ (Normal Equation) ของตัวประมาณการถดถอยริตจ์ที่มีค่าสัมบูรณ์น้อยสุดสามารถเขียนได้ในรูป

$$(X'X + k_{RLAV} I_n) \hat{\beta}_{RLAV} = X' y$$

ดังนั้น ตัวประมาณการถดถอยริตจ์ที่มีค่าสัมบูรณ์น้อยสุด (Ridge Least Absolute Value Estimator) เขียนได้ในรูปแบบดังนี้

$$(2.22) \quad \hat{\beta}_{RLAV} = (X'X + k_{RLAV} I_n)^{-1} X' y$$

การประมาณ  $k_{RLAV}$  คำนวณได้จากสมการ (2.19) โดยแทนค่า  $\hat{\beta}$  ด้วยตัวประมาณค่าสัมบูรณ์น้อยสุด ( $\hat{\beta}_{LAV}$ ) ที่คำนวณได้จากสมการ (2.17) และแทนค่า  $\sigma^2$  ด้วย  $s_{LAV}^2$  ดังนั้น  $k_{RLAV}$  สามารถเขียนได้ในรูปแบบดังต่อไปนี้

$$(2.23) \quad k_{RLAV} = \frac{qs_{LAV}^2}{\hat{\beta}_{LAV}' \hat{\beta}_{LAV}}$$

เมื่อ  $s_{LAV}^2 = \frac{(y - X \hat{\beta}_{LAV})' (y - X \hat{\beta}_{LAV})}{n - q}$  เป็นตัวประมาณพารามิเตอร์  $\sigma^2$

และ  $q = p + 1$