

ทฤษฎีที่เกี่ยวข้องในการวิจัย

2.1 Ridge Regression

2.1.1 เหตุผลและความสำคัญ

พิจารณาสัมการถดถอยเชิงเส้น  $Y = X\beta + U$  เมื่อ  $X$  คือ เมตริกซ์ขนาด  $n \times (p + 1)$   $\beta$  คือ เวกเตอร์ของ Partial regression coefficient กล่าวคือ  $\beta = (\beta_0, \beta_1, \dots, \beta_p)$  และ  $U = (u_1, u_2, \dots, u_n)$  คือ เวกเตอร์ของ Stochastic term โดยเราควบคุมค่าของ  $u$  ไว้ด้วยข้อตกลงพื้นฐานว่า  $E(U) = 0$  และ  $E(U'U) = \sigma^2 I_n$  นั้น โดยปกติเราสามารถหา BLUE (Best Linear Unbiased Estimator) ของ  $\beta_i, i = 0, 1, 2, \dots, p$  หรือ เวกเตอร์  $\beta$  ได้โดยวิธี Least Square หรือ Maximum Likelihood Method แต่ทั้งนี้  $\hat{\beta}_i; i = 0, 1, \dots, p$  หรือ เวกเตอร์  $\hat{\beta}$  จะเป็นตัวประมาณค่าที่ดีที่สุดเฉพาะเมื่อเมตริกซ์  $X'X$  ซึ่งเล่นอยู่ในรูปมาตรฐาน (Standardized form) มีลักษณะหรือธรรมชาติใกล้เคียง  $I_n$  ทั้งนี้เพราะถ้าตัวแปรอิสระ  $X_i; i = 1, 2, \dots, p$  เป็นอิสระเชิงเส้นต่อกัน (Linearly Independent) โดยที่ตัวแปรอิสระ  $X_i$  ได้รับการจัดรูปให้อยู่ในรูปมาตรฐานแล้ว เมตริกซ์  $X'X$  จะเป็น Unit matrix และเมื่อใดก็ตามที่เมตริกซ์  $X'X$  เบนห่างไปจาก Unit matrix มากขึ้น ปัญหาต่าง ๆ ก็จะติดตามมา ปัญหาที่สำคัญคือ ปัญหา Multicollinearity ซึ่งปัญหาดังกล่าวนี้จะอยู่ในระดับที่รุนแรงที่สุดเมื่อเมตริกซ์มีลักษณะของ Singular matrix ทั้งนี้เพราะปัญหา Multicollinearity มีผลให้  $\hat{\beta}_i$  ขาดความน่าเชื่อถือ เนื่องจาก  $V(\hat{\beta}_i)$  มีค่าสูงมากทำให้การวิจัยที่ไม่ระมัดระวังคัดเอา  $X_i$  ทิ้งไปทั้ง ๆ ที่  $X_i$  อาจเป็นปัจจัยหลักของสมการถดถอยที่กำลังเกี่ยวข้องอยู่โดยนัยของการตรวจสอบนัยสำคัญทางสถิติของ  $\beta_i$  (โดยปกตินิยมใช้ t-test) และในอีกประการหนึ่งก็คือ ปัญหา Multicollinearity ทำให้ไม่อาจตัดสินใจได้ว่าปัจจัยใดควรเป็นปัจจัยที่ใช้ควบคุมความเคลื่อนไหวของตัวแปรตาม ทั้งนี้เพราะตัวแปรอิสระต่าง ๆ มีความสัมพันธ์กันในอัตราส่วนที่ค่อนข้างสูงและยิ่งตัวแปรอิสระหลายคู่ที่มีความสัมพันธ์ (สหสัมพันธ์) กันในเกณฑ์สูง ก็จะมีปัญหาในการตัดสินใจและอธิบายผล ทางออกที่นิยมประพาดปฏิบัติก็คือ การคัดเอาตัวแปรบางส่วนโดยเฉพาะในคู่ที่มีสหสัมพันธ์สูง ๆ ทิ้งไปคู่ละหนึ่งตัวโดยอาศัย Priori information เป็นเกณฑ์

เพื่อทำลายความสัมพันธ์ระหว่างตัวแปรอิสระ  $X_i$  ผลที่ติดตามมาก็จะไม่ต่างไปจากการตัดตัวแปรอิสระ  $X_i$  ที่ไม่มีนัยสำคัญทางสถิติทิ้งไปดังที่กล่าวมาแล้ว การแก้ปัญหามulticollinearity ตามแนวทางทั้ง 2 ประการข้างต้นซึ่งก่อให้เกิดปัญหาอย่างน้อย 2 ประการคือ

1. การตัดตัวแปรอิสระ  $X_i$  ทิ้งไปบางส่วนอาจทำให้ตัวแปรที่สำคัญถูกกำสัดโดยความรู้เท่าไม่ถึงการณ์
2. ทำให้สัมประสิทธิ์ประมาณค่า  $Y = X\hat{\beta}$  หย่อนคุณภาพในเชิงพยากรณ์เมื่อพิจารณาในรูปของ  $R^2$  ที่ลดปริมาณลงกว่าเดิมก่อนตัดตัวแปรอิสระทิ้งไปบางส่วนตามข้อ 1

ปัญหาทั้งหลายดังที่กล่าวมาสามารถพิสูจน์ให้เห็นได้ดังนี้

จากสมการถดถอย  $Y = X\beta + U$  โดยที่  $E(U) = 0$  และ  $E(UU')$   
 $= \sigma^2 I_n$  เราจะพบว่าค่าประมาณของ  $\beta$  คือ

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

และเมื่อพิจารณาคุณสมบัติของ  $\hat{\beta}$  จะพบว่า

$$(1) E(\hat{\beta}) = \beta \quad \dots\dots\dots (2)$$

$$(2) \text{Var}(\hat{\beta}) = \sigma^2 (X'X)^{-1} \quad \dots\dots\dots (3)$$

$$(3) \hat{\beta} \text{ เป็น BLUE} \quad \dots\dots\dots (4)$$

(4) Expected Square Length ของระยะห่างระหว่างเวกเตอร์  $\hat{\beta}$  และ  $\beta$  มีค่าเท่ากับ  $\sigma^2 \sum_{i=1}^p (1/\lambda_i)$  เมื่อ  $\lambda_i$  คือ Eigen value ของเมตริกซ์

$X'X$  หรือ Expected Square Length ของเฉพาะเวกเตอร์  $\hat{\beta}$  มีค่าเท่ากับ

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

หมายเหตุ การศึกษาและวิเคราะห์ในลำดับต่อจากนี้เป็นต้นไปจะศึกษาเฉพาะกรณีของ Standardized variable เท่านั้น

สำหรับคุณสมบัติข้อที่ 4 สามารถพิสูจน์ได้ดังนี้

กำหนดให้  $L_1 = (\hat{\beta} - \beta)$  คือ Error vector หรือระยะห่างระหว่าง  
 เวกเตอร์ของค่าประมาณ (Estimated vector) คือ  $\hat{\beta}$  กับเวกเตอร์ของค่าจริงของ  
 พารามิเตอร์ (True parameter vector) คือ  $\beta$

ดังนั้น Square Length ของ Error vector คือ  $L_1^2 = (\hat{\beta} - \beta)'$   
 $(\hat{\beta} - \beta)$

$$\begin{aligned} \text{ดังนั้น } E(L_1^2) &= E [(\hat{\beta} - \beta)'(\hat{\beta} - \beta)] \\ &= E [\{(X'X)^{-1} X'U\}' \{(X'X)^{-1} X'U\}] \\ &= E [U' X (X'X)^{-1} \{(X'X)^{-1} X'U\}] \\ &= \sigma^2 \text{ trace } [X (X'X)^{-1} (X'X)^{-1} X'] \\ &= \sigma^2 \text{ trace } (X'X)^{-1} \dots\dots\dots (5) \end{aligned}$$

$$\text{แต่ } (\hat{\beta} - \beta)'(\hat{\beta} - \beta) = \hat{\beta}'\hat{\beta} - 2\beta'\hat{\beta} + \beta'\beta$$

$$\begin{aligned} \text{ดังนั้น } E(\hat{\beta} - \beta)'(\hat{\beta} - \beta) &= E(\hat{\beta}'\hat{\beta}) - 2\beta'E(\hat{\beta}) + \beta'\beta \\ &= E(\hat{\beta}'\hat{\beta}) - \beta'\beta \end{aligned}$$

$$\text{นั่นคือ } E(L_1^2) = \sigma^2 \text{ trace } (X'X)^{-1} \dots\dots (6)$$

$$\text{หรือ } E(\hat{\beta}'\hat{\beta}) = \beta'\beta + \sigma^2 \text{ trace } (X'X)^{-1} \dots (7)$$

$$\text{แสดงว่า } E(L_1^2) = \sigma^2 \text{ trace } (X'X)^{-1} \text{ หรือ } E(\hat{\beta}'\hat{\beta}) = \beta'\beta$$

$+\sigma^2 \text{ trace } (X'X)^{-1}$  ซึ่งชี้ให้เห็นว่าโดยปกติแล้วเวกเตอร์  $\hat{\beta}$  มีความยาวตัวเฉลี่ยที่โน้มเอียง  
 ไปในทางที่จะมีค่าสูงกว่าเวกเตอร์  $\beta$  ซึ่งเป็นเวกเตอร์ของค่าจริงของพารามิเตอร์อยู่แล้ว

อย่างไรก็ตาม ในกรณีของ Orthogonality ซึ่งเป็นกรณีที่ตัวแปรอิสระ  
 เป็นอิสระเชิงเส้นต่อกันนั้น จะพบว่า

$$E(L_1^2) = n\sigma^2$$

$$E(\hat{\beta}'\hat{\beta}) = \beta'\beta + n\sigma^2$$

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

แต่เราสามารถคำนวณหาเมตริกซ์ P ที่มีผลให้  $P'(X'X)P = \Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p)$  โดยที่  $\lambda_i$  คือ Eigen value ของเมตริกซ์  $X'X$  ที่  $\lambda_i > 0$  ได้เสมอ

โดยอาศัยความรู้ดังกล่าวนี้ทำให้สมการที่ 6 และ 9 เปลี่ยนรูปไปเป็นฟังก์ชันของ  $\lambda_i$  ได้ดังนี้

$$E(L_1^2) = \sigma^2 \text{trace diag}(1/\lambda_1, 1/\lambda_2, \dots, 1/\lambda_p) = \sigma^2 \sum_{i=1}^p 1/\lambda_i \dots (10)$$

$$\text{Var}(L_1^2) = 2\sigma^4 \text{trace diag}(1/\lambda_1^2, 1/\lambda_2^2, \dots, 1/\lambda_p^2) = 2\sigma^4 \sum_{i=1}^p 1/\lambda_i^2 \dots (11)$$

และจากความรู้เกี่ยวกับ Rank of matrix และ Eigen value problem เราทราบว่าถ้าเมตริกซ์  $X'X$  เป็น Singular matrix หรือ Near-singular matrix แล้ว  $\lambda_{\min}$  จะมีค่าเท่ากับ 0 หรือ ใกล้ 0 ขณะที่ปัญหา Multicollinearity คือปัญหาที่  $X'X$  มีธรรมชาติของ Near-singularity หรือ Singularity ผลที่ติดตามมาก็คือ  $\lambda_{\min} \rightarrow 0$

จากสมการ (10) และ (11) ถ้า  $\lambda_{\min} \rightarrow 0$  หรือมี Eigen value หลายตัวที่มีค่าใกล้ 0 เราจะพบลักษณะของ Unboundedness ใน MSE หรือ  $E(L_1^2)$  กล่าวคือ

$$E(L_1^2) \rightarrow \infty \quad \text{และ} \quad \text{Var}(L_1^2) \rightarrow \infty$$

หรืออาจกล่าวได้ว่า เมื่อใดก็ตามที่  $X'X$  เป็น Ill-conditioning design matrix หรือ Near-singularity แล้วจะมีผลให้

(1)  $\hat{\beta}$  ประมาณค่า  $\beta$  ได้ไม่ดี เพราะเวกเตอร์  $\hat{\beta}$  ต่างจากเวกเตอร์  $\beta$  มาก

(2) ความผันแปรของ  $\hat{\beta}$  มีปริมาณสูงมากจนทำให้ไม่มั่นใจในความถูกต้อง และน่าเชื่อถือของค่าประมาณดังกล่าว (หรือ MSE ขาดลักษณะของ Boundedness)

(3) ทำให้ฟังก์ชัน  $W\hat{\beta} = w_1\beta_1 + w_2\beta_2 + \dots + w_p\beta_p$  เป็นตัวประมาณค่าที่เอนเอียง

อนึ่ง เมื่อพิจารณาสัมการ (7) จะพบว่าโดยปกติ  $\hat{\beta}$  จะต่างจากเวกเตอร์จริงอยู่แล้ว และเมื่อมีสถานการณ์ของ Ill-conditioning คือ  $X'X$  มีธรรมชาติของ Near - singularity ประกอบเพิ่มเติมเข้ามาอีก จะพบว่า

$$E(\hat{\beta}'\hat{\beta}) = \beta'\beta + \sigma^2 \sum_{i=1}^p 1/\lambda_i \rightarrow \infty \text{ ถ้า } \lambda_{\min} \rightarrow 0 \dots (12)$$

จากเหตุผลปัญหา และสิ่งที่เป็นไปได้ภายใต้สภาวะของ Ill-conditioning หรือ Near-Singularity ดังกล่าว ทำให้จำเป็นต้องคำนวณหาตัวประมาณค่าของพารามิเตอร์  $\beta$  ที่เหมาะสมกว่า  $\hat{\beta}$  ภายใต้สถานการณ์เดียวกัน โดยคาดว่าตัวประมาณค่าดังกล่าวมีค่าใกล้เคียงกับพารามิเตอร์  $\beta$

2.1.2 Ridge Regression

ให้ B คือ ตัวประมาณค่าใหม่ของเวกเตอร์  $\beta$  นอกเหนือไปจาก  $\hat{\beta}$  จะพบว่าเวกเตอร์ B ให้ค่า Residual Sum of Square

$$\begin{aligned} \Phi &= (Y - XB)'(Y - XB) \\ &= Y'Y - 2B'X'Y + B'X'XB \dots \dots \dots (13) \end{aligned}$$

นำ  $2\hat{\beta}'X'Y$  บวกเข้าและลบออกจากด้านขวาของเครื่องหมายเท่ากับในสมการ (13) จะพบว่า

$$\Phi = Y'Y - 2\hat{\beta}'X'Y + B'X'XB - 2\hat{\beta}'X'Y + 2\hat{\beta}'X'Y \dots \dots \dots (14)$$

$$= (Y'Y - 2\hat{\beta}'X'Y + \hat{\beta}'X'Y) + (B'X'XB - 2\hat{\beta}'X'Y + \hat{\beta}'X'Y) \dots (15)$$

แต่จาก (Normal Equation) ของ OLS เราทราบว่า  $X'Y = (X'X)\hat{\beta}$  ดังนั้นสมการ

(15) จึงเปลี่ยนรูปเป็น

$$\Phi = (Y'Y - 2\beta'X'Y + \hat{\beta}'X'X\hat{\beta}) + (B'X'X B - 2B'X'X\hat{\beta} + \hat{\beta}'X'X\hat{\beta})$$

นั่นคือ  $\Phi = (Y - X\hat{\beta})'(Y - X\hat{\beta}) + (B - \hat{\beta})'X'X(B - \hat{\beta}) \dots\dots\dots(16)$

หรือ  $\Phi = \Phi_{\min} + \Phi(B) \dots\dots\dots(17)$

โดยที่  $\Phi_{\min} = (Y - X\hat{\beta})'(Y - X\hat{\beta})$  คือ Residual Sum of Square ที่มีค่าต่ำที่สุด และ  $\Phi(B)$  คือ Quadratic form ของ  $(B - \hat{\beta})$

ผลที่ได้รับจากสมการ (17) ทำให้ทราบว่าเวกเตอร์ B ใดที่ให้ค่า  $\Phi$  ต่ำไปกว่า  $\hat{\beta}$  ได้ วิธีที่จะให้ได้ค่าประมาณของ  $\beta$  จึงควรเป็นวิธีที่ส่งผลให้เวกเตอร์ของค่าประมาณมีค่าใกล้เคียงกับพารามิเตอร์  $\beta$  ภายใต้อัจฉกัจฉว่า  $\Phi(B)$  มีค่าคงที่ หรือนัยหนึ่ง ค่าประมาณของ  $\beta$  คือ B ควรคำนวณได้มาจากการ minimize  $B'B$  ภายใต้อัจฉกัจฉว่า  $(B - \hat{\beta})'X'X(B - \hat{\beta})$  มีค่าคงที่เท่ากับ  $\Phi_0$

ดังนั้น โดยอาศัย Lagrangian Multiplier Method โดยกำหนดให้  $1/k$  คือ Lagrange Multiplier ;  $k > 0$  จะพบว่า

$$F = B'B + (1/k) [(B - \hat{\beta})'X'X(B - \hat{\beta}) - \Phi_0] \dots\dots(18)$$

$$\frac{\partial F}{\partial B} = 0 \quad 2B + (1/k) 2X'X(B - \hat{\beta}) = 0 \dots\dots(19)$$

$$kB + X'XB - X'X\hat{\beta} = 0$$

$$(kI_p + X'X)B = X'X\hat{\beta} \dots\dots(20)$$

แต่จาก OLS เราทราบว่า  $\hat{\beta} = (X'X)^{-1} X'Y$  ดังนั้นสมการ (20) จึงเปลี่ยนรูปไปดังนี้

$$(X'X + kI)B = X'Y$$

นั่นคือ  $B = \hat{\beta}^* = (X'X + kI)^{-1} X'Y \dots\dots(21)$

$\hat{\beta}^*$  ในสมการ (21) คือ Ridge Estimator

ตัวประมาณค่า  $\hat{\beta}^*$  หรือ B ในสมการ (21) เป็นตัวประมาณค่าที่มีคุณสมบัติหลายประการที่ดีกว่า OLS ซึ่งจะได้กล่าวถึงต่อไป และมีความเกี่ยวข้องกับ OLS ดังนี้

$$(1) \quad \hat{\beta}^* \text{ คือ ฟังก์ชันของ } \hat{\beta}$$

พิสูจน์

$$\text{จาก } \hat{\beta}^* = (X'X + kI)^{-1} X'Y = W X'Y \text{ จะพบว่า } \dots (22)$$

$$\begin{aligned} \hat{\beta}^* &= (X'X + kI)^{-1} (X'X)(X'X)^{-1} X'Y \\ &= [I + k(X'X)^{-1}]^{-1} (X'X)^{-1} X'Y \\ &= [I + k(X'X)^{-1}]^{-1} \hat{\beta} \\ &= Z\hat{\beta} \text{ เมื่อ } Z = [I + k(X'X)^{-1}]^{-1} \dots (23) \end{aligned}$$

(2) Eigen value ของเมตริกซ์ W และ Z คือ  $s_i(W) = 1/(\lambda_i + k)$  และ  $s_i(Z) = 1/(1 + k/\lambda_i)$  ตามลำดับ เมื่อ  $\lambda_i$  คือ Eigen value ค่าที่ i ของเมตริกซ์  $X'X$

พิสูจน์

จากความรู้เรื่อง Characteristic value problems และ Congruence เราสามารถคำนวณหาเมตริกซ์ P ที่มีผลให้  $P'(X'X)P = \Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p)$

$$\text{ดังนั้น } W = (X'X + kI)^{-1} \sim (\Lambda + kI)^{-1}$$

$$\sim \text{diag} [1/(\lambda_1 + k), 1/(\lambda_2 + k), \dots, 1/(\lambda_p + k)] \dots \dots \dots (24)$$

$$= \text{diag} [\xi_1(W), \xi_2(W), \dots, \xi_p(W)] \dots (25)$$

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

$$\sim [I + k\Lambda^{-1}]^{-1}$$

$$\sim \text{diag} [1/(1+k/\lambda_1), 1/(1+k/\lambda_2), \dots, 1/(1+k/\lambda_p)]$$

$$= \text{diag} [\lambda_1/(\lambda_1+k), \lambda_2/(\lambda_2+k), \dots, \lambda_p/(\lambda_p+k)] \dots \dots \dots (26)$$

$$= \text{diag} [\xi_1(Z), \xi_2(Z), \dots, \xi_p(Z)] \dots (27)$$

$$(3) \quad Z = [I + k(X'X)^{-1}]^{-1} \quad \text{สามารถเล่นได้อีกรูปแบบหนึ่งดังนี้คือ}$$

$$Z = I - k(X'X + kI)^{-1} = I - kW$$

### พิสูจน์

$$\text{จาก } W = (X'X + kI)^{-1} \quad \text{จะพบว่า}$$

$$(X'X + kI)^{-1} = (X'X + kI)^{-1} (X'X) (X'X)^{-1}$$

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

$$\text{นั่นคือ } (X'X + kI)^{-1} = Z(X'X)^{-1}$$

$$\text{จาก (28) แสดงว่า } (X'X + kI) Z = X'X$$

$$\text{หรือ } X'X Z + kZ = X'X$$

$$\text{นั่นคือ } X'X Z = X'X - kZ$$

$$\text{ดังนั้น } Z = (X'X)^{-1} (X'X - kZ)$$

$$= I - k(X'X)^{-1} Z \quad \dots \dots \dots (29)$$



แต่จาก (23) เราทราบว่า  $Z = [I + k(X'X)^{-1}]^{-1}$  เมื่อแทนค่า Z ลงในสมการ (29) จึงมีผลให้สมการ (29) เปลี่ยนรูปไปสู่รูปแบบใหม่ดังนี้

$$\begin{aligned} Z &= I - k(X'X)^{-1} [I + k(X'X)^{-1}]^{-1} \\ &= I - k [ \{ I + k(X'X)^{-1} \} (X'X) ]^{-1} \\ &= I - k(X'X + kI)^{-1} = I - kW \dots\dots\dots (30) \end{aligned}$$

(4) เวกเตอร์  $\hat{\beta}^*$  จะมีความยาวต่ำกว่าเวกเตอร์  $\hat{\beta}$  ในทุกค่าของ k

พิสูจน์ จาก  $\hat{\beta}^* = Z\hat{\beta}$  จะพบเวกเตอร์  $\hat{\beta}^*$  มีความยาวดังนี้

$$L(\hat{\beta}^*) = \hat{\beta}'^* \hat{\beta}^* = \hat{\beta}' Z' Z \hat{\beta} \dots\dots\dots (31)$$

แต่จากความรู้อธิบายเรื่อง Orthogonalization สามารถคำนวณหาเมตริกซ์ P ที่ให้ผลให้

$$P' Z P = \Lambda = \text{diag} [s_1(Z), s_2(Z), \dots, s_p(Z)]$$

$$Z' Z = \text{diag} [s_1^2(Z), s_2^2(Z), \dots, s_p^2(Z)] = \Lambda' \Lambda$$

$$\text{ดังนั้น } \hat{\beta}'^* \hat{\beta}^* = s_1^2(Z) \hat{\beta}_1^2 + s_2^2(Z) \hat{\beta}_2^2 + \dots + s_p^2(Z) \hat{\beta}_p^2 \dots\dots\dots (32)$$

จาก (32) ถ้าแทน  $s_1^2(Z)$  ด้วย  $s_{\max}^2(Z)$  เมื่อ  $s_{\max}(Z) = s_{(1)}(Z) > s_{(2)}(Z) > \dots > s_{(p)}(Z) = s_{\min}(Z)$ ,  $i = 1, 2, \dots, p$  เมื่อ  $s_{\max} = \lambda_1 / \lambda_1 + k$  สมการ (32)

จะเปลี่ยนรูปเป็นสมการดังนี้

$$\hat{\beta}'^* \hat{\beta}^* \leq s_{\max}^2(Z) \hat{\beta}' \hat{\beta} \dots\dots\dots (33)$$

แต่  $s_{\max} = \lambda_{(1)} / (\lambda_{(1)} + k)$  เมื่อ  $\lambda_{(1)} = \max(\lambda_1, \lambda_2, \dots, \lambda_p)$  จะพบว่า

$s_{\max}^2$  มีค่าต่ำกว่า  $s_i^2(Z)$ ;  $i = 1, 2, \dots, p$  ซึ่งแสดงว่าแม้แต่  $s_{\max}^2 \hat{\beta}' \hat{\beta}$  ยังมี

ค่าไม่น้อยกว่า  $\hat{\beta}'^* \hat{\beta}^*$  หากเปลี่ยนเป็น  $s_{\min}^2(Z)$  หรือ  $s_{(i)}^2(Z)$  ใด ๆ  $s_{\min}^2(Z) \hat{\beta}' \hat{\beta}$

และ  $s_{(i)}^2(Z) \hat{\beta}'^* \hat{\beta}^*$  ย่อมต้องมีค่าสูงกว่า  $\hat{\beta}'^* \hat{\beta}^*$

$$\text{นั่นคือ } \hat{\beta}'^* \hat{\beta}^* < \hat{\beta}' \hat{\beta} \dots\dots\dots (34)$$

หรือเวกเตอร์  $\hat{\beta}^*$  จะเป็นเวกเตอร์ที่มีระยะความยาวต่ำกว่า  $\hat{\beta}$  ซึ่งเป็น OLS-Estimator ของเวกเตอร์  $\beta$  เสมอ

2.1.3 MSE ของ Ridge Regression

พิจารณา  $L_1^2(k) = (\hat{\beta}^* - \beta)'(\hat{\beta}^* - \beta)$  จะพบว่า Expected Square Length ของ Error vector  $(\hat{\beta}^* - \beta)$  ก็คือ MSE ของ  $\hat{\beta}^*$  ซึ่งแสดงให้เห็นได้ ดังนี้

$$E [L_1^2(k)] = E [(\hat{\beta}^* - \beta)'(\hat{\beta}^* - \beta)] \dots\dots\dots (35)$$

$$\begin{aligned} \text{แต่จาก (23)} \hat{\beta}^* &= [I_p + k (X'X)^{-1}]^{-1} \hat{\beta} \\ &= Z\hat{\beta} \end{aligned}$$

$$\begin{aligned} \text{ดังนั้น } E[L_1^2(k)] &= E[(Z\hat{\beta} - \beta)'(Z\hat{\beta} - \beta)] \\ &= E[\hat{\beta}'Z'Z\hat{\beta} - 2\beta'Z\hat{\beta} + \beta'\beta] \\ &= E[(\hat{\beta}'Z'Z\hat{\beta})] - 2\beta'Z\beta + \beta'\beta \dots\dots\dots (36) \end{aligned}$$

เมื่อนำ  $2\beta'Z'Z\hat{\beta}$  บวกเข้าและลบออกจาก (36) จะพบว่า

$$E[L_1^2(k)] = E(\hat{\beta}'Z'Z\hat{\beta}) - 2\beta'Z'Z\hat{\beta} + 2\beta'Z'Z\hat{\beta} - 2\beta'Z\hat{\beta} + \beta'\beta$$

แต่  $2\beta'Z'Z\hat{\beta} = \beta'Z'Z\hat{\beta} + \beta'Z'Z\hat{\beta}$  และจาก (2)  $E(\hat{\beta}) = \beta$  จึงทำให้ได้  $E[L_1^2(k)]$  ดังนี้

$$\begin{aligned} E[L_1^2(k)] &= E(\hat{\beta}'Z'Z\hat{\beta}) - 2E(\beta'Z'Z\hat{\beta}) + \beta'Z'Z\hat{\beta} + \beta'Z'Z\hat{\beta} - 2\beta'Z\hat{\beta} + \beta'\beta \\ &= E[\hat{\beta}'Z'Z\hat{\beta} - \hat{\beta}'Z'Z\hat{\beta} - \beta'Z'Z\hat{\beta} + \beta'Z'Z\hat{\beta}] + (\beta'Z'Z\hat{\beta} - \beta'Z'Z\hat{\beta} \\ &\quad - \beta'Z\hat{\beta} + \beta'\beta) \\ &= E[(\hat{\beta} - \beta)'Z'Z(\hat{\beta} - \beta)] + (Z\beta - \beta)'(Z\beta - \beta) \dots\dots\dots (37) \end{aligned}$$

แต่  $(\hat{\beta} - \beta) = [\beta + (X'X)^{-1} X'U] - \beta = (X'X)^{-1} X'U$  ดังนั้น

$$\begin{aligned}
 E [L_1^2(k)] &= E [U' \{X(X'X)^{-1} Z'Z(X'X)^{-1}\} U] + (Z\beta - \beta)' (Z\beta - \beta) \\
 &= \sigma^2 \text{trace } (X'X)^{-1} Z'Z + (Z\beta - \beta)' (Z\beta - \beta) \\
 &= \sigma^2 \text{trace } (X'X)^{-1} Z'Z + \beta'(Z - I)' (Z - I)\beta \\
 &= a + b \dots\dots\dots (38)
 \end{aligned}$$

จาก (23) และ (29)  $Z = [I + k(X'X)^{-1}]^{-1} = I - k(X'X + kI)^{-1}$  และ

$$\begin{aligned}
 \sigma^2 \text{trace } (X'X)^{-1} Z'Z &= \sigma^2 \text{trace } Z (X'X)^{-1} Z' \\
 a &= \sigma^2 \text{trace } (X'X)^{-1} Z'Z \\
 &= \sigma^2 \text{trace } Z (X'X)^{-1} Z' \\
 &= \sigma^2 \text{trace } \left[ \{I + k(X'X)^{-1}\}^{-1} (X'X)^{-1} \{I + k(X'X)^{-1}\}^{-1} \right] \\
 &= \sigma^2 \text{trace } [(X'X + kI)^{-1} \{I + k(X'X)^{-1}\}^{-1}] \\
 &= \sigma^2 \text{trace } [(X'X + kI)^{-1} \{I - k(X'X + kI)^{-1}\}] \\
 &= \sigma^2 \text{trace } [(X'X + kI)^{-1} \{I - k(X'X + kI)^{-1}\}] \\
 &= \sigma^2 \text{trace } [(X'X + kI)^{-1} - k(X'X + kI)^{-2}]
 \end{aligned}$$

และเนื่องจากสามารถคำนวณหาเมตริกซ์ P ที่  $P'(X'X)P = \Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p)$

เมื่อ  $\lambda_i$  คือ Eigen value ที่  $i$  ของเมตริกซ์  $X$ ;  $i = 1, 2, \dots, p$

$$\begin{aligned}
 \text{ดังนั้น } a &= \sigma^2 \text{trace } [(\Lambda + kI)^{-1} - k(\Lambda + kI)^{-2}] \\
 &= \sigma^2 \left[ \sum_{i=1}^p 1/(\lambda_i + k) - \sum_{i=1}^p k/(\lambda_i + k)^2 \right] \\
 &= \sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^2
 \end{aligned}$$

พิจารณา  $b = \beta'(Z - I)' (Z - I)\beta \dots\dots\dots (39)$

และจาก (30) จะพบว่า  $Z = I - k(X'X + kI)^{-1}$

$$\begin{aligned} \text{ดังนั้น } b &= \beta' [-k(X'X + kI)^{-1}]' [-k(X'X + kI)^{-1}] \beta \\ &= \beta' [k^2(X'X + kI)^{-2}] \beta \\ &= k^2 \beta'(X'X + kI)^{-2} \beta \dots\dots\dots (40) \end{aligned}$$

$$\begin{aligned} \therefore \text{MSE} &= E [L_1^2(k)] = \sigma^2 \sum_{i=1}^P \lambda_i / (\lambda_i + k)^2 + [k^2 \beta'(X'X + kI)^{-2} \beta] \dots (41) \\ &= \gamma_1(k) + \gamma_2(k) \end{aligned}$$

หรือ  $\text{MSE} = \gamma_1(k) + \gamma_2(k)$  โดยที่  $\gamma_1(k) = \sigma^2 \sum_{i=1}^P \lambda_i / (\lambda_i + k)^2 = \text{Total}$

$\text{variance}$  ขณะที่  $\gamma_2(k) = k^2 \beta'(X'X + kI)^{-2} \beta = (Z\beta - \beta)'(Z\beta - \beta)$

= Square length ของระยะห่างระหว่าง  $Z\beta$  กับ  $\beta$

อนึ่งสำหรับ  $\gamma_2(k)$  เราทราบว่า  $Z = I - k(X'X + kI)^{-1}$  ซึ่งถ้าหาก

$k = 0$  จะพบว่า  $Z = I$  หรือ  $Z\beta = \beta$  แต่ถ้า  $k > 0$  จะพบว่า  $Z \neq I$  หรือ

$Z\beta \neq \beta$  แสดงว่า  $\gamma_2(k)$  ก็คือ  $(\text{bias})^2$  นั่นเอง

2.1.4 Mean, Variance และ SSE

$$\begin{aligned} (1) \text{ จาก } \hat{\beta}^* &= (X'X + kI_p)^{-1} X'Y \\ &= (X'X + kI)^{-1} (X'X)(X'X)^{-1} X'Y \\ &= [I + k(X'X)^{-1}] \hat{\beta} \text{ เมื่อ } \hat{\beta} \text{ คือ OLS - Estimator} \\ &= Z\hat{\beta} \end{aligned}$$

แต่  $E(\hat{\beta}) = \beta$

ดังนั้น  $E(\hat{\beta}^*) \neq \beta \dots\dots\dots (42)$

แสดงว่า  $\hat{\beta}^* = Z\hat{\beta} = [I - k(X'X + kI)^{-1}] \hat{\beta}$  เป็น Biased Estimator

(2) Variance ของ  $\hat{\beta}^*$

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



แสดงว่า  $\hat{\beta}^*$  เป็น Linear function ของ  $Y$  กล่าวคือ  $\hat{\beta}^* = [Z(X'X)^{-1} X'] Y$

$$\begin{aligned} \text{ดังนั้น } \text{Var}(\hat{\beta}^*) &= [Z(X'X)^{-1} X'] \text{Var}(Y) [Z(X'X)^{-1} X']' \\ &= \sigma^2 [Z(X'X)^{-1} X'] [X(X'X)^{-1} Z] \\ &= \sigma^2 [Z(X'X)^{-1} Z] \quad \dots\dots\dots (43) \end{aligned}$$

$$\begin{aligned} (3) \text{SSE}(\hat{\beta}^*) &= (Y - X\hat{\beta}^*)'(Y - X\hat{\beta}^*) \\ &= Y'Y - Y'X\hat{\beta}^* - \hat{\beta}^{*'}X'Y + \hat{\beta}^{*'}X'X\hat{\beta}^* \\ &= Y'Y - \hat{\beta}^{*'}X'Y - [Y'X\hat{\beta}^* - \hat{\beta}^{*'}X'X\hat{\beta}^*] \\ &= Y'Y - Y'X\hat{\beta}^* - [Y'X - \hat{\beta}^{*'}X'X] \hat{\beta}^* \\ &= Y'Y - Y'X\hat{\beta}^* - [X'Y - X'X\hat{\beta}^*]' \hat{\beta}^* \end{aligned}$$

แต่จาก (20) เราทราบว่าสมการปกติ คือ  $(X'X + kI) \hat{\beta}^* = X'Y$  ทำให้ทราบได้ว่า

$$X'Y - X'X\hat{\beta}^* = k\hat{\beta}^*$$

$$\begin{aligned} \text{SSE}(\hat{\beta}^*) &= Y'Y - Y'X\hat{\beta}^* - k\hat{\beta}^{*'}\hat{\beta}^* \\ &= (\text{SST} - \text{SSR}^*) - k [\text{Square Length of } \hat{\beta}^*] \quad \dots\dots (46) \end{aligned}$$

โดยที่ SSR = Sum of Square Regression

$\text{SSR}^*$  = Sum of Square Regression ของ  $\hat{\beta}^*$

2.1.5 คุณสมบัติของ MSE

$$\begin{aligned} \text{จาก (41) } \text{MSE}(\hat{\beta}^*) &= \gamma_1(k) + \gamma_2(k) \\ &= \sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^2 + k^2 \beta' (X'X + kI)^{-2} \beta \end{aligned}$$

จะมีคุณสมบัติที่สำคัญดังนี้

1)  $\gamma_1(k)$  เป็น Continuous monotonic decreasing function ของตัวคงที่  $k$

$$\begin{aligned} \text{พิสูจน์ } \gamma_1(k) &= \sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^2 \\ \gamma_1'(k) &= \frac{\partial}{\partial k} \gamma_1(k) = -2\sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^3 \dots (47) \end{aligned}$$

$$\begin{aligned} \lim_{k \rightarrow k'} [f(k) - f(k')] &= \lim_{k \rightarrow k} \left[ \sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^2 - \sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k')^2 \right] \\ &= 0 \end{aligned}$$

ดังนั้น  $\gamma_1(k)$  เป็น Continuous function ของ  $k$  และ  $\gamma_1'(k) = -ve$  ซึ่งแสดงว่า

$\gamma_1(k)$  เป็น Decreasing function ของ  $k$

เมื่อ  $\gamma_1'(k) \rightarrow -\infty$  เมื่อ  $k \rightarrow 0^+$  และ  $\lambda_{(p)} \rightarrow 0$  เมื่อ  $\lambda_{(p)} = \lambda_{\min}$

พิสูจน์

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

$$\begin{aligned} \text{ดังนั้น } \lim_{k \rightarrow 0^+} \gamma_1'(k) &= \lim_{k \rightarrow 0} \left[ -2\sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^3 \right] \\ &= -2\sigma^2 \sum_{i=1}^p 1/\lambda_i^2 \\ &= -2\sigma^2 \left[ 1/\lambda_1^2 + 1/\lambda_2^2 + \dots + 1/\lambda_p^2 \right] \dots \dots \dots (48) \end{aligned}$$

แต่จาก (48) จะพบว่า  $\lim_{k \rightarrow 0} \gamma_1'(k)$  มีค่าผันแปรไปตาม  $\lambda_{(p)}$  กล่าวคือ ถ้า  $X$

$\lambda_{(p)} \rightarrow 0$  จะส่งผลให้  $1/\lambda_{(p)} \rightarrow \infty$

2) Square bias คือ  $\gamma_2(k)$  เป็น Monotonic increasing function ของตัวคงที่  $k$

พิสูจน์ จากสมการ  $Y = X\beta + U$  เราสามารถคำนวณหา Orthogonal matrix  $P$  ในลักษณะที่  $P'(X'X)P = \Lambda = \text{diag.} (\lambda_1, \lambda_2, \dots, \lambda_p)$  เมื่อ  $\lambda_i$  คือ Eigen value ค่าที่  $i$  ของเมตริกซ์  $X'X$

ดังนั้นสมการถดถอย  $Y = X\beta + U$  จึงเปลี่ยนรูปใหม่ได้ดังนี้

$$Y = XPP'\beta + U$$

หรือ  $Y = X^*\alpha + U$  โดยที่  $X^* = XP$  และ  $\alpha = P'\beta$

และพบว่า Normal equation สำหรับ Ridge Regression

$$(X^{*'}X^* + kI)\hat{\alpha} = X^{*'}Y \dots\dots\dots(49)$$

จากสมการ (49) จะพบว่า

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

$$X^{*'}X^* = P'(X'X)P = \Lambda$$

$$\begin{aligned} MSE &= \sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^2 + k^2 \alpha' (\Lambda + kI)^{-2} \alpha \\ &= \gamma_1(k) + \gamma_2(k) \dots\dots\dots(50) \end{aligned}$$

จากสมการ (50) จะพบว่า

$$\begin{aligned} \gamma_2(k) &= k^2 \alpha' (\Lambda + kI)^{-2} \alpha \\ &= k^2 \alpha' D^{-1} \alpha \end{aligned}$$

โดยที่  $D^{-2} = D^{-1}D^{-1}$        $D^{-1} = \text{diag.} [1/(\lambda_1 + k), 1/(\lambda_2 + k), \dots, 1/(\lambda_p + k)]$

และจะเห็นได้ว่า  $D^{-2} = \text{diag.} [1/(\lambda_1 + k)^2, 1/(\lambda_2 + k)^2, \dots, 1/(\lambda_p + k)^2]$

$$\gamma_2(k) = k^2 \sum_{i=1}^p \alpha_i^2 / (\lambda_i + k)^2$$

ดังนั้น  $\gamma_2(k) = \sum_{i=1}^p \alpha_i^2 / [1 + (\lambda_i/k)]^2 \dots \dots \dots (51)$

จากสมการ (51) จะพบว่า  $\lim_{k \rightarrow k} [k^2 \sum_{i=1}^p \alpha_i^2 / (\lambda_i + k)^2 - k^2 \sum_{i=1}^p \alpha_i^2 / (\lambda_i + k)^2] = 0 \dots (52)$

$$\begin{aligned} \gamma_2'(k) &= \frac{\partial}{\partial k} \gamma_2(k) = \frac{\partial}{\partial k} \left[ \sum_{i=1}^p \alpha_i^2 / [1 + (\lambda_i/k)]^2 \right] \\ &= -2 \sum_{i=1}^p \alpha_i^2 / [1 + (\lambda_i/k)]^3 \cdot (-\lambda_i/k^2) \\ &= 2k \sum_{i=1}^p \lambda_i \alpha_i^2 / (\lambda_i + k)^3 \\ &= +ve \dots \dots \dots (53) \end{aligned}$$

จากสมการ (52) และ (53) ทำให้สรุปได้ว่า  $\gamma_2(k)$  เป็น Continuous monotonic increasing function ของตัวคงที่  $k$  เมื่อ  $k > 0$  และ  $\lambda_i > 0$

ขีดจำกัดบนของ  $\gamma_2(k)$  คือ  $\beta' \beta$

พิสูจน์  $\gamma_2(k) = \sum_{i=1}^p \alpha_i^2 / [1 + (\lambda_i/k)]^2$

$$\begin{aligned} \lim_{k \rightarrow \infty} \gamma_2(k) &= \lim_{k \rightarrow \infty} \sum_{i=1}^p \alpha_i^2 / [1 + (\lambda_i/k)]^2 = \sum_{i=1}^p \alpha_i^2 \\ &= \alpha' \alpha \\ &= (p' \beta)' (p' \beta) \\ &= \beta' p p' \beta \\ &= \beta' \beta \end{aligned}$$

แสดงว่าขีดจำกัดบนของ  $\gamma_2(k)$  คือ  $\beta' \beta$  หรือ  $\sum_{i=1}^p \beta_i^2 \dots \dots \dots (54)$



ถ้า  $k \rightarrow 0^+$  จะมีผลให้  $\gamma_2'(k) \rightarrow 0$

$$\text{พิสูจน์ } \gamma_2'(k) = 2k \sum_{i=1}^p \lambda_i \alpha_i^2 / (\lambda_i + k)^3$$

$$\lim_{k \rightarrow 0^+} \gamma_2'(k) = \sum_{i=1}^p \lim_{k \rightarrow 0^+} [2k \lambda_i \alpha_i^2 / (\lambda_i + k)^3] = 0$$

3) สามารถหาค่าคงที่  $k$  ที่มีผลให้  $E[L_1^2(k)] < E[L_1^2(0)]$  ได้เสมอ

$$\begin{aligned} \text{พิสูจน์ } \text{จาก MSE} &= E[L_1^2(k)] = \gamma_1(k) + \gamma_2(k) \\ &= \sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^2 + k^2 \beta' (X'X + kI)^{-2} \beta \\ &= \sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^2 + k^2 \sum_{i=1}^p \alpha_i^2 / (\lambda_i + k)^2 \quad \dots (56) \end{aligned}$$

$$\text{และ } \frac{\partial}{\partial k} E[L_1^2(k)] = -2\sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^3 + 2k \sum_{i=1}^p \lambda_i \alpha_i^2 / (\lambda_i + k)^3 \quad \dots (57)$$

$$\text{จากสมการ (56) จะพบว่า } E[L_1^2(0)] = \sigma^2 \sum_{i=1}^p 1/\lambda_i \quad \dots (58)$$

จากสมการ (57) เราทราบจาก 1) ว่า  $\gamma_1'(k)$  เป็น Monotonic decreasing function ของ  $k$  และจาก 2) เราทราบว่า  $\gamma_2'(k)$  เป็น Monotonic increasing function ของ  $k$  (หรือ  $\gamma_1'(k)$  เป็นลบเสมอ ขณะที่  $\gamma_2'(k)$  เป็นบวกเสมอ) ซึ่งจากสมการ (57) และ (58) ทำให้

$$\frac{\partial}{\partial k} E[L_1^2(k)] < \frac{\partial}{\partial k} E[L_1^2(0)] = 0$$

$$\text{หรือ } -2\sigma^2 \sum_{i=1}^p \lambda_i / (\lambda_i + k)^3 + 2k \sum_{i=1}^p \lambda_i \alpha_i^2 / (\lambda_i + k)^3 < 0 \quad \dots (59)$$

หรือเรามีความจำเป็นที่ต้องพิสูจน์ให้เห็นว่าเราสามารถหาค่าคงที่  $k$  ;  $k < 0$  ที่มีผลให้

$E[L_1^2(k)]$  เป็น Monotonic decreasing function

จากสมการ (59) จะพบว่า

$$2k \sum_{i=1}^P \alpha_i^2 \lambda_i / (\lambda_i + k)^3 < 2\sigma^2 \sum_{i=1}^P \lambda_i / (\lambda_i + k)^3 \dots\dots\dots(60)$$

พิจารณา Order value ของ  $\alpha_i^2$  ;  $i = 1, 2, \dots, P$  คือ

$$\alpha_{max} = \alpha_{(1)} > \alpha_{(2)} > \alpha_{(3)} > \dots > \alpha_{(p)} = \alpha_{min}$$

จะพบว่า เมื่อแทน  $\alpha_{(i)}$  ด้วย  $\alpha_{min}$  และถ้า  $\alpha_{min} \rightarrow 0$  จะทำให้  $k$  ไม่เป็น Finite value วิธีที่จะให้  $k$  เป็น Finite value (หรือ Bounded value) คือใช้  $\alpha_{max}$  เป็นตัวแทนของ  $\alpha_{(i)}$  ;  $i = 1, 2, \dots, P$

ดังนั้นจากสมการ (60) เมื่อแทนที่  $\alpha_{(i)}$  ด้วย  $\alpha_{max}$  จะทำให้ได้ค่าสูงสุดของ  $k$  ที่ผลิตให้  $E [L_1^2(k)] < E [L_1^2(0)]$

$$k < \sigma^2 / \alpha_{max}^2 \dots\dots\dots(61)$$

นั่นคือ ในกรณีของ Ridge Regression นั้น สามารถคำนวณหาค่าคงที่  $k$  ที่ผลิตให้ Ridge estimator มี MSE ต่ำกว่า OLS-estimator ได้เสมอ และค่าคงที่  $k$  ดังกล่าวจะเป็นค่าบวกที่มีค่าไม่เกินไปกว่า  $\sigma^2 / \alpha_{max}^2$

2.1.6 Generalized Ridge Regression

พิจารณาสมการถดถอย  $Y = X\beta + U$  จะพบว่าเราสามารถคำนวณหาเมตริกซ์  $P$  ที่ผลิตให้  $P'(X'X)P = \Lambda = \text{diag} (\lambda_1, \lambda_2, \dots, \lambda_p)$  ได้เสมอ

ดังนั้นสมการถดถอย  $Y = X\beta + U$  สามารถแปลงรูปไปสู่รูปใหม่ได้ดังนี้คือ

$$\begin{aligned} Y &= XPP'\beta + U \\ &= X^* \alpha + U \text{ เมื่อ } X^* = XP \text{ และ } \alpha = P'\beta \dots\dots\dots(62) \end{aligned}$$

จาก (62) จะเห็นได้ว่า

$$X^{*'} X^* = P' X' X P = \Lambda , \alpha' \alpha = \beta' P P' \beta = \beta' \beta$$

โดยอาศัยหลักเกณฑ์ที่ทำงานองเดียวกันกับตอน 2.2.2 จะพบว่า

$$\hat{\alpha} = [X^{*'} X^* + K]^{-1} X^{*'} Y$$

โดยที่  $K = (\delta_{ij} k_{ij})_{p \times p}$  เมื่อ  $\delta_{ij} = \text{kroncker delta}$  กล่าวคือ

$$\delta_{ij} = 0 ; i \neq j, \quad \delta_{ij} = 1 ; i = j \text{ หรือ } \text{นัยหนึ่ง } K = \text{diag.}(k_1, k_2, \dots, k_p)$$

และพบว่าค่าที่เหมาะสม (optimal) ของ  $k_i$  คือ

$$k_i = \sigma^2 / \alpha_i^2 ; i = 1, 2, \dots, p$$

$$\text{และ } \hat{k}_i = \hat{\sigma}^2 / \hat{\alpha}_i^2 ; i = 1, 2, \dots, p \quad \dots \dots \dots (63)$$

จากการศึกษาพบว่า ค่าประมาณที่ดีที่สุดของ  $\beta^*$  คือใช้  $k_i = k ; i = 1, 2, \dots, p$  หรือ

$$K = kI_p$$

#### 2.1.7 การประมาณค่าคงที่

จากการศึกษาของวิชเชอร์นและเชอร์ซิล (Wichern, D.W. and Churchill, G.A., 1978), กิบบอน (Gibbons, D.G., 1981) แมคโดนาลด์และกาลานู (McDonald, G.C. and Galarneau, D.I., 1975) พบว่า ในบรรดาวิธีประมาณค่า  $k$  กว่า 10 วิธีนั้น วิธีที่ดีที่สุดและเป็นที่ยอมรับกันทั่วไปมีอยู่ 2 วิธีคือ

1. วิธี Hoerl, Kennard and Baldwin
2. วิธี Lawless and Wang

ซึ่งการศึกษาคั้งนี้จะเปรียบเทียบโดยใช้อัลกอริทึมของการประมาณค่า  $k$  สำหรับ Ridge Estimator ตามวิธีทั้ง 2 ประการนี้เท่านั้น วิธีประมาณค่า  $k$  สำหรับแต่ละวิธีดังกล่าวมีหลักการโดยสรุปดังนี้

1. วิธี Hoerl, Kennard and Baldwin (HKB)

วิธีนี้เสนอโดยโฮเออร์ล เคนนาร์ด และบอลด์วิน (Hoerl, A.E., Kennard, R.W. and Baldwin, K.F., 1975) ซึ่งแนะนำให้เลือกค่า  $k$  ดังนี้

$$k = PS^2 / \hat{\beta}' \hat{\beta}$$

โดยที่  $S^2 = \hat{\sigma}^2 = \frac{1}{n-P} (Y - X\hat{\beta})' (Y - X\hat{\beta})$      $P =$  จำนวนตัวแปรอิสระ

$$\hat{\beta} = (X'X)^{-1} X'Y \quad \dots\dots\dots(64)$$

สำหรับวิธี HKB นี้เหมาะสำหรับการวิเคราะห์ความถดถอยเมื่อ  $P \geq 3$   
 เพราะถ้า  $P \leq 2$  แล้ว HKB จะไม่ดีไปกว่า OLS

สังเกตว่า  $k = PS^2 / \hat{\beta}'\hat{\beta}$  คือ Harmonic mean ของ  $k_i$  ;  $i = 1, 2, \dots, P$   
 ในตอน 2.1.6 นั้นเอง

## 2. วิธี Lawless and Wang (LW)

พิจารณาสัมการถดถอย  $Y = X\beta + U$

ให้  $P$  คือ Orthogonal modal matrix ที่  $P'P = PP' = I$

$$P'X'XP = \Lambda = \text{diag.} (\lambda_1, \lambda_2, \dots, \lambda_p)$$

ดังนั้น เมื่อจัดสัมการ  $Y = X\beta + U$  ให้อยู่ในรูปของ Canonical form

$$\begin{aligned} Y &= XPP'\beta + U \\ &= X^*\alpha + U \end{aligned}$$

เมื่อ  $X^* = XP$  และ  $\alpha = P'\beta$

ดังนั้น OLS-estimator ของ  $\alpha$  คือ

$$\begin{aligned} \hat{\alpha} &= (X^{*'}X^*)^{-1} X^{*'}Y \\ &= (P'X'XP)^{-1} P'X'Y \\ &= \Lambda^{-1} X^{*'}Y \end{aligned}$$

ลอว์เลสและแวง (Lawless and Wang, 1976) ใช้วิธีการของเบย์แล้วใช้สัดส่วน  
 ของความแปรปรวน คือ  $PS^2 / \hat{\alpha}'\Lambda\hat{\alpha}$   $\hat{\alpha}$  เป็นตัวประมาณค่าของ  $k$

ผลจากการศึกษาเปรียบเทียบพบว่า ค่าประมาณของ  $\beta$  ตามวิธีของ LW คือ

$$k = PS^2 / \hat{\alpha}'\Lambda\hat{\alpha}$$

โดยที่  $P =$  จำนวนพารามิเตอร์ และ  $S^2 = \frac{1}{n-p} [Y'Y - \hat{\beta}'X'Y]$  เป็นวิธีประมาณที่ดี  
ที่ลู่ดีวิธีหนึ่งในจำนวนวิธีประมาณค่าหลายวิธี

## 2.2 การประมาณค่าสัง เกตที่ลู่หาย

### 2.2.1 เหตุผลและความสำคัญ

ในการวิเคราะห์ความถดถอยเชิงเส้น

$$Y = X\beta + U$$

ปัญหาที่พบอยู่เสมอก็คือ ปัญหาอันเนื่องมาจากค่าสัง เกตลู่หายไปในบาง  
ช่วงของอนุกรมเวลา ทางออกสำหรับปัญหานี้ในทางปฏิบัติคือ ผู้วิเคราะห์ยังคงประมาณค่า  
สมการถดถอยโดยอาศัย Ordinary Least Square อยู่เช่นเดิมโดยตัดค่าตัวอย่างที่ไม่  
สมบูรณ์ทิ้งไป การกระทำดังกล่าวมีผลเสียที่เด่นชัด 2 ประการ ประการแรกค่าสัง เกตขาดความ  
ต่อเนื่อง ประการที่สองค่า Mean Square Error (MSE) มีค่าสูงกว่าความเป็นจริง เนื่อง  
จากการสูญเสีย degree of freedom ด้วยเหตุผลดังกล่าวจึงได้มีการสร้างข้อมูลทดแทน  
ขึ้นมาสำหรับข้อมูลที่ลู่หาย

### 2.2.2 วิธีการประมาณค่าสัง เกตที่ลู่หาย

จากวิธีการประมาณค่าสัง เกตที่ลู่หายซึ่งมีอยู่หลายวิธีนั้น วิธีที่ได้รับความนิยม  
นิยมนำไปใช้อยู่เสมอ มีอยู่ 2 วิธีคือ

1. วิธีแทนด้วยค่าเฉลี่ย (Mean Substitution)
2. วิธีสมการถดถอย (Regression)

ซึ่งวิธีทั้ง 2 มีหลักการดังนี้

1. วิธีแทนด้วยค่าเฉลี่ย

เป็นวิธีที่ง่ายที่สุดโดยใช้ค่า เฉลี่ยของตัวแปรแต่ละตัวจากข้อมูล  
เท่าที่มีอยู่แล้ว แทนที่ข้อมูลที่ลู่หาย กล่าวคือ

แทนที่ค่าของตัวแปร  $X_i$  ที่สูญหายไป  $m_i$  ค่าด้วย

$$\bar{X}_{i \cdot}^{(n_i)} = \frac{1}{n_i} \sum_{\ell}^n X_{i\ell}$$



โดยที่  $n_i$  = จำนวนค่าสังเกตของตัวแปร  $X_i$  ที่ปรากฏ ,  $i = 1, 2, \dots, P$

$m_i$  = จำนวนค่าสังเกตของตัวแปร  $X_i$  ที่สูญหาย คือ  $m_i = n - n_i$

$n$  = ขนาดตัวอย่างทั้งสิ้นของค่าสังเกต

$X_{i\ell}$  = คือ ค่าสังเกตที่ปรากฏของตัวแปรที่  $i$  และตัวอย่างที่  $\ell$

## 2. วิธีล้มการถดถอย

เป็นวิธีที่อาศัยความสัมพันธ์ของล้มการถดถอย มาใช้ในการประมาณค่าสังเกตที่สูญหายโดยมีแนวคิดพื้นฐาน คือ วิเคราะห์ล้มการถดถอยเชิงเส้น

$$X_i = f(X_j) ; i \neq j = 1, 2, \dots, P$$

แล้วใช้ค่าประมาณ  $\hat{X}_{i\ell}$  จาก Regression Function

$\hat{X}_{i\ell} = f(X_{j\ell}) ; i \neq j = 1, 2, \dots, P$  ประมาณค่า  $X_{i\ell}$  ที่สูญหาย โดยใช้ข้อมูลที่สมบูรณ์เท่านั้นมาสร้างล้มการถดถอย