



วิธีที่เกี่ยวข้องกับการวิจัย

1. วิธีกำลังสองน้อยที่สุด (Least-Squares Method)

โดยทั่วไปเมื่อมีข้อมูลอยู่อย่างครบถ้วน วิธีกำลังสองน้อยที่สุดในการประมาณสัมประสิทธิ์ของการถดถอยโดยทำให้ผลบวกของกำลังสองของความคลาดเคลื่อน มีค่าน้อยที่สุด

1.1 การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression)

แบบการถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression Model)

การหาความสัมพันธ์เชิงเส้นตรงระหว่างตัวแปรตาม (Y) และตัวแปรอิสระ (X)

เมื่อมีตัวแปรอิสระเพียงตัวเดียว จะเขียนความสัมพันธ์ระหว่างตัวแปรทั้งสองในรูปแบบ (Model)

$$Y = \beta_0 + \beta_1 X + \epsilon$$

เมื่อกำหนดให้ Y เป็นตัวแปรตาม (Dependent Variable)

X เป็นตัวแปรอิสระ (Independent Variable)

β_0 เป็นระยะระหว่างจุดกำเนิดกับจุดที่เส้นถดถอยตัดกับแกน Y (Y-intercept)

β_1 เป็นค่าสัมประสิทธิ์แห่งการถดถอยของประชากร (Population Regression Coefficient)

ซึ่งเป็นพารามิเตอร์ที่ยังไม่ทราบค่า

และ ϵ เป็นค่าความแตกต่างระหว่างเส้นถดถอยกับค่าจริงของ Y ซึ่งเป็นตัวแปรสุ่มที่ไม่ทราบค่า

$$E(\epsilon_i) = 0 ; i = 1, 2, \dots, n$$

$$E(\epsilon_i \epsilon_j) = \sigma^2 ; i = j = 1, 2, \dots, n$$

$$= 0 ; i \neq j$$

$$E(Y_i) = \beta_0 + \beta_1 X_i , i = 1, 2, \dots, n$$

$$\text{var}(Y_i) = \sigma^2 , i = 1, 2, \dots, n$$

การประมาณค่าพารามิเตอร์

$$\text{จากตัวแบบ } Y = \beta_0 + \beta_1 X + \epsilon$$

โดยวิธีกำลังสองน้อยที่สุด จะต้องทำให้ผลบวกของกำลังที่สองของความคลาดเคลื่อน (Error sum of squares)

$$\sum_{i=1}^n \epsilon_i^2 = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 X_i)^2 \quad (2.1.1)$$

มีค่าน้อยที่สุด เมื่อให้ b_0^{LS} และ b_1^{LS} เป็นค่าประมาณของ β_0 และ β_1 ตามลำดับ เราอาจจะหาค่า b_0^{LS} และ b_1^{LS} โดยใช้วิธีการทางคณิตศาสตร์ จะโคสมการปกติ (Normal Equations) เป็น

$$n b_0^{LS} + b_1^{LS} \sum_{i=1}^n X_i = \sum_{i=1}^n Y_i \quad (2.1.2)$$

$$b_0^{LS} \sum_{i=1}^n X_i + b_1^{LS} \sum_{i=1}^n X_i^2 = \sum_{i=1}^n X_i Y_i \quad (2.1.3)$$

เมื่อแก้สมการปกติจะได้

$$b_1^{LS} = \frac{\sum_{i=1}^n X_i Y_i - n \bar{X} \bar{Y}}{\sum_{i=1}^n X_i^2 - n \bar{X}^2} \quad (2.1.4)$$

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} , \quad \bar{Y} = \frac{\sum_{i=1}^n Y_i}{n}$$

$$\text{และ } b_0^{LS} = \bar{Y} - b_1^{LS} \bar{X} \quad (2.1.5)$$

$$\therefore \text{สมการถดถอยที่ได้ คือ } \hat{Y}_i^{LS} = b_0^{LS} + b_1^{LS} X_i \quad (2.1.6)$$

$$\text{หรือ} \quad \hat{Y}_i^{LS} = \bar{Y} + b_1^{LS}(X_i - \bar{X})$$

$$\text{โดยมี } E(b_1^{LS}) = \beta_1, \quad E(b_0^{LS}) = \beta_0,$$

$$\text{var}(b_1^{LS}) = \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X}_n)^2}$$

$$\text{และ } \text{var}(b_0^{LS}) = \left[\frac{1}{n} + \frac{\bar{X}^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \right] \sigma^2 = \frac{\sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2} \sigma^2$$

$$\text{จาก } \hat{Y}_i^{LS} = \bar{Y}_n + b_1^{LS}(X_i - \bar{X}_n) \quad \checkmark$$

$$\therefore \text{var}(\hat{Y}_i^{LS}) = \text{var}(\bar{Y}_n) + (X_i - \bar{X}_n)^2 \text{var}(b_1^{LS}) \\ + 2(X_i - \bar{X}_n) \text{cov}(\bar{Y}_n, b_1^{LS})$$

$$= \frac{\text{var}(Y_i)}{n} + (X_i - \bar{X}_n)^2 \frac{\text{var}(Y_i)}{\sum_{i=1}^n (X_i - \bar{X}_n)^2}$$

$$= \text{var} (Y_i) \frac{1}{n} + \frac{(X_i - \bar{X}_n)^2}{\sum_{i=1}^n (X_i - \bar{X}_n)^2}$$

$$= \frac{\sigma^2}{n} + \frac{(X_i - \bar{X}_n)^2}{\sum_{i=1}^n (X_i - \bar{X}_n)^2}$$

เมื่อพิจารณาความคลาดเคลื่อน (ϵ_i) จะได้ $\epsilon_i = Y_i - (\beta_0 + \beta_1 X_i)$

$$= (Y_i - \hat{Y}_i)$$

$$\therefore Y_i - \hat{Y}_i = (Y_i - \bar{Y}_n) - (\hat{Y}_i - \bar{Y}_n)$$

จะเห็นว่า ความคลาดเคลื่อนเกิดจากการที่ค่าจริงเบี่ยงเบนไปจากค่าเฉลี่ย และอีกส่วนหนึ่งเกิดจากค่าประมาณเบี่ยงเบนจากค่าเฉลี่ย

จาก $\epsilon_i = (Y_i - \bar{Y}_n) - (\hat{Y}_i - \bar{Y}_n)$

$$\sum_{i=1}^n \epsilon_i^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n [(Y_i - \bar{Y}_n) - (\hat{Y}_i - \bar{Y}_n)]^2$$

$$\therefore \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - \bar{Y}_n)^2 + \sum_{i=1}^n (\hat{Y}_i - \bar{Y}_n)^2 - 2 \sum_{i=1}^n (Y_i - \bar{Y}_n)(\hat{Y}_i - \bar{Y}_n) \quad (2.1.7)$$

พิจารณาเทอม $\sum_{i=1}^n (Y_i - \bar{Y}_n)(\hat{Y}_i - \bar{Y}_n)$

แทนค่า \hat{Y}_i ด้วย $\bar{Y}_n + b_1^{LS}(X_i - \bar{X}_n)$ ซึ่งหาได้จากสมการ (2.1.8)

$$\therefore \sum_{i=1}^n (Y_i - \bar{Y}_n)(\hat{Y}_i - \bar{Y}_n) = \sum_{i=1}^n (Y_i - \bar{Y}_n) [\bar{Y}_n + b_1^{LS}(X_i - \bar{X}_n) - \bar{Y}_n]$$

$$\begin{aligned}
 &= b_1^{LS} \sum_{i=1}^n (Y_i - \bar{Y}_n)(X_i - \bar{X}_n) \\
 &= (b_1^{LS})^2 \sum_{i=1}^n (X_i - \bar{X}_n)^2 \\
 &= \sum_{i=1}^n \left[b_1^{LS} (X_i - \bar{X}_n) \right]^2 \\
 &= \sum_{i=1}^n (\hat{Y}_i - \bar{Y}_n)^2; \\
 &\quad \left[\hat{Y}_i = \bar{Y}_n + b_1^{LS} (X_i - \bar{X}_n) \right]
 \end{aligned}$$

แทนค่า $\sum_{i=1}^n (Y_i - \bar{Y}_n)(\hat{Y}_i - \bar{Y}_n)$ ในสมการ (2.1.7) จะได้

$$\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - \bar{Y}_n)^2 - \sum_{i=1}^n (\hat{Y}_i - \bar{Y}_n)^2$$

$$\therefore \sum_{i=1}^n (Y_i - \bar{Y}_n)^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y}_n)^2 + \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2.1.8)$$

จะเห็นว่า $\sum_{i=1}^n (Y_i - \bar{Y}_n)^2$ ซึ่งเรียกว่าผลบวกกำลังสองของทั้งหมด (Total Sum of Squares) จะประกอบด้วย

ส่วนที่ 1 $\sum_{i=1}^n (\hat{Y}_i - \bar{Y}_n)^2$ ซึ่งเรียกว่าผลบวกกำลังสองเนื่องมาจากการถดถอย (Sum of Squares due to Regression)

และ ส่วนที่ 2 $\sum_{i=1}^n (Y_i - \hat{Y}_i)^2$ ซึ่งเรียกว่าผลบวกกำลังสองของความคลาดเคลื่อน (Error Sum of Squares)

$$\text{ถ้าให้ } R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y}_n)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_n)^2} = \frac{\text{ผลบวกกำลังสองเนื่องจากการถดถอย}}{\text{ผลบวกกำลังสองของทั้งหมด}}$$

ค่า R^2 จะมีค่าอยู่ระหว่าง 0 ถึง 1

ถ้าค่า R^2 ใกล้ศูนย์หมายถึงจุดต่าง ๆ กระจายห่างจาก \hat{Y}_i มาก ค่าของผลบวกกำลังสองเนื่องจากการถดถอยมีค่าต่ำมาก แต่ถ้าวัดค่า $R^2 \rightarrow -1$ จนถึง 1 หมายถึงสมการถดถอยที่ได้จะเป็นตัวอธิบายความเปลี่ยนแปลงทั้งหมดของ Y เพราะผลบวกกำลังสองของทั้งหมด จะมีค่าเท่ากับผลบวกกำลังสองเนื่องจากการถดถอย

การทดสอบสมมติฐานโดยใช้การทดสอบ F (F-test)

จากสมการถดถอยที่ได้ $\hat{Y}_i = b_0^{LS} + b_1^{LS} X_i$

เมื่อหาสมการถดถอยได้แล้ว เราก็ต้องทดสอบว่าสมการถดถอยที่ได้จะเหมาะสมหรือไม่ ก็จะทดสอบว่ามีการถดถอยหรือไม่ โดยตั้งสมมติฐานว่า

$H_0: \beta_1 = 0, H_A: \beta_1 \neq 0$ โดยมีข้อสมมติว่า ϵ_i มีการแจกแจงแบบปกติ มีค่าเฉลี่ยเป็น 0 และมีความแปรปรวนเป็น σ^2

ตารางวิเคราะห์ความแปรปรวน (Table of Analysis of Variance) สำหรับทดสอบสมมติฐานเรียกว่า ตาราง ANOVA

ตารางที่ 1

ANOVA

Source of Variation	df	Sum of Squares	Mean Squares	F
Due to Regression	1	$\sum_{i=1}^n (\hat{Y}_i - \bar{Y}_n)^2 = SSR$	$SSR/1 = MSR$	$\frac{MSR}{MSE}$
Error	$n-2$	$\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = SSE$	$SSE/(n-2) = MSE$	
Total	$n-1$	$\sum_{i=1}^n (Y_i - \bar{Y}_n)^2 = SST$		

นำค่า $F = \frac{MSR}{MSE}$ ที่คำนวณได้ มาเปรียบเทียบกับค่า F จากตาราง ที่ชั้นแห่งความ
เป็นอิสระ (d.f) = (1, n-2)

ถ้า $F_{\text{คำนวณ}} > F_{\text{ตาราง}}$ เราจะไม่ยอมรับสมมติฐานที่ว่า $\beta_1 = 0$
นั่นคือ $\beta_1 \neq 0$ แสดงว่ามีการถดถอย

ถ้า $F_{\text{คำนวณ}} < F_{\text{ตาราง}}$ เราจะยอมรับสมมติฐานที่ว่า $\beta_1 = 0$
นั่นคือ $\beta_1 = 0$ แสดงว่าไม่มีการถดถอย

1.2 การถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression)

ในการวิเคราะห์ปัญหาบางอย่างที่จำเป็นต้องใช้การถดถอยนั้น บางครั้งการศึกษาถึงการถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression) อาจจะไม่เพียงพอ ทั้งนี้เพราะการประมาณค่าของ Y ให้ได้ใกล้เคียงที่สุดนั้น เรามักจะต้องพิจารณาถึงตัวแปรอิสระ (X) ที่มีอิทธิพลหรือมีความสำคัญต่อ Y มากกว่าหนึ่งตัวขึ้นไป ดังนั้นเราจะใช้การถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression) ซึ่งเป็นการหาความสัมพันธ์ระหว่างข้อมูลตั้งแต่ 2 ชุดขึ้นไป เมื่อข้อมูลชุดหนึ่งเป็นตัวแปรตาม (Y) ส่วนข้อมูลชุดอื่นเป็นตัวแปรอิสระ (X) แล้วศึกษาความสัมพันธ์ของข้อมูลเหล่านี้ในรูปสมการ

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \epsilon \quad (2.1.9)$$

โดยที่ Y เป็นตัวแปรตาม (Dependent Variable)

X_i เป็นตัวแปรอิสระ (Independent variable)

ตัวที่ $i, i = 1, 2, \dots, p$

β_0 เป็นค่าคงที่

β_i เป็นค่าสัมประสิทธิ์แห่งการถดถอยของประชากรบางส่วน

(Population Partial Regression Coefficient)

ของ Y ต่อ X_i เมื่อให้ $X_1, X_2, \dots, X_{i-1}, X_{i+1}, \dots, X_p$

คงที่ นั่นคือ เมื่อ X_i เปลี่ยนแปลง 1 หน่วย จะมีผลทำให้

Y เปลี่ยนแปลง β_i หน่วย เมื่อตัวแปรอิสระตัวอื่นคงที่ ,

$i = 1, 2, \dots, p$

และ

ϵ เป็นค่าความแตกต่างระหว่างเส้นถดถอยกับค่าจริง ซึ่งเป็นตัวแปรสุ่มที่ไม่ทราบค่า

$$E(\epsilon_i) = 0, \quad i = 1, 2, \dots, n$$

$$E(\epsilon_i \epsilon_j) = \sigma^2; \quad i = j = 1, 2, \dots, n$$

$$= 0; \quad i \neq j$$



ค่าพารามิเตอร์ที่ไม่ทราบค่าในทันทีใดแก่

$$\beta_i, \quad i = 0, 1, 2, \dots, p \quad \text{และ} \quad \sigma^2$$

ในการประมาณค่าพารามิเตอร์ สำหรับการถดถอยพหุคูณนี้ เราจะใช้เมตริกซ์ช่วย จาก (2.1.9) เขียนตัวแบบให้อยู่ในรูปเมตริกซ์จะได้

$$Y = X\beta + \epsilon \quad (2.1.10)$$

โดยที่ $Y = n \times 1$ เวกเตอร์ที่มีคอมโพเนนต์เป็น Y_1, Y_2, \dots, Y_n
 $X = n \times (p + 1)$ เมตริกซ์ที่มีสมาชิกเป็น X_{ij} ซึ่งได้แก่ค่าที่ i ของตัวแปร X_j คือ

$$X = \begin{bmatrix} 1 & X_{11} & X_{12} & \dots & X_{1p} \\ 1 & X_{21} & X_{22} & \dots & X_{2p} \\ 1 & X_{31} & X_{32} & \dots & X_{3p} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & X_{n1} & X_{n2} & \dots & X_{np} \end{bmatrix}$$

$$\beta = (p + 1) \text{ เวกเตอร์ที่มีคอมโพเนนต์เป็น } \beta_0, \beta_1, \dots, \beta_p$$

$$= \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{bmatrix}$$

$$\epsilon = n \times 1 \text{ เวกเตอร์ของความคลาดเคลื่อน}$$

$$= \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

ถ้าให้ $\hat{\beta}^{LS}$ เป็นค่าประมาณของ β ในการหาค่า $\hat{\beta}^{LS}$ โดยวิธีกำลังสองน้อยที่สุดนี้ จะต้องทำให้ค่าลบวงกำลังสองของความคลาดเคลื่อนมีค่าน้อยที่สุด แล้วใช้วิธีทางคณิตศาสตร์ โดยการหาอนุพันธ์ของ $\epsilon'\epsilon$ เทียบกับ β

$$\text{จากตัวแบบ } Y = X\beta + \epsilon$$

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

$$\begin{aligned}\epsilon'\epsilon &= (Y - X\beta)'(Y - X\beta) \\ &= Y'Y - 2\beta'X'Y + \beta'X'X\beta\end{aligned}$$

$$\frac{\partial \epsilon'\epsilon}{\partial \beta} = -2X'Y + 2X'X\beta = 0$$

แทนค่า β ด้วย $\hat{\beta}^{LS}$

$$\therefore (X'X)\hat{\beta}^{LS} = X'Y \quad \checkmark$$

ถ้า $X'X$ เป็นเมทริกซ์แบบนอนซิงกูลาร์ จะได้

$$\hat{\beta}^{LS} = (X'X)^{-1} X'Y \quad \checkmark \quad (2.1.11)$$

$$\therefore \text{สมการถดถอยที่ได้ คือ } \hat{Y}^{LS} = X\hat{\beta}^{LS} \quad (2.1.12)$$

$$\text{โดยที่ } E(\hat{\beta}^{LS}) = \beta \quad \text{และ } \checkmark$$

$$\text{var}(\hat{\beta}^{LS}) = (X'X)^{-1}\sigma^2 \quad \checkmark$$

เมื่อจะทดสอบสมมติฐาน $H_0: \beta = 0$; $H_A: \beta \neq 0$ โดยใช้การทดสอบ F (F-test) เราใช้ตาราง ANOVA ต่อไปนี้

ตารางที่ 2
ANOVA

SOV	d.f	SS	MS	F
Regression	p+1	$\hat{\beta}^{LS} X' Y$ = SSR	$\frac{SSR}{p+1}$ = MSR	$\frac{MSR}{MSE}$
Error	n-p-1	$Y' Y - \hat{\beta}^{LS} X' Y$ = SSE	$\frac{SSE}{n-p-1}$ = MSE	
Total (uncorrected)	n	$Y' Y$		

2. วิธีการประมาณค่าของตัวแปรที่ขาดหายไปโดยวิธีกำลังสองต่ำสุด (The Classical Least-Squares Method)¹

การประมาณค่าสังเกตของตัวแปรที่ขาดหายไปในการวิเคราะห์การถดถอยโดยวิธีนี้ ใช้ค่าสังเกตที่มีครบทั้งตัวแปรตาม (Y) และตัวแปรอิสระ (X) หาสมการถดถอยโดยวิธีกำลังสองน้อยที่สุด และใช้สมการถดถอยที่ได้นี้ประมาณค่าสังเกตของตัวแปรตาม (Y) ที่ขาดหายไป แล้วจึงนำข้อมูลที่ได้นี้ไปหาสมการถดถอย

2.1 การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression)

จากตัวแบบ
$$Y = \beta_0 + \beta_1 X + \epsilon$$

ให้ $b_0^{(1)}$ และ $b_1^{(1)}$ เป็นค่าประมาณของ β_0 และ β_1 จะได้สมการถดถอยที่ต้องการ คือ

$$\hat{Y}_i^{(1)} = b_0^{(1)} + b_1^{(1)} X_i$$

เมื่อกำหนดให้ $n = (n_c + m_x + m_y) =$ จำนวนหน่วยตัวอย่างทั้งหมด

$n_c =$ จำนวนหน่วยตัวอย่างที่มีทั้งค่าของ X และ Y

$m_x = (n - n_x) =$ จำนวนหน่วยตัวอย่างที่มีค่าของ X ขาดหายไป

$m_y = (n - n_y) =$ จำนวนหน่วยตัวอย่างที่มีค่าของ Y ขาดหายไป

$n_x =$ จำนวนหน่วยตัวอย่างที่มีค่าของ X ทั้งหมด

$n_y =$ จำนวนหน่วยตัวอย่างที่มีค่าของ Y ทั้งหมด

¹ A.A. Afifi and R.M. Elashoff, "Missing Observation in Multivariate Statistics I. Review of the Literature," Journal of the American Statistical Association, 61 (1966), pp. 595-597.

จากข้อมูลที่รวบรวมมาได้ จะหาค่า b_1^{LS} และ b_0^{LS} ได้เช่นเดียวกับ b_1^{LS} และ b_0^{LS} ซึ่งหาได้จาก (2.1.4) และ (2.1.5) ตามลำดับ จะได้

$$b_1^{LS} = \frac{\sum_{i=1}^n X_i Y_i - n_c \bar{X}_c \bar{Y}_c}{\sum_{i=1}^n X_i^2 - n_c \bar{X}_c^2}; \quad \bar{X}_c = \frac{\sum_{i=1}^n X_i}{n_c}$$

003627

$$\text{และ } b_0^{LS} = \bar{Y}_c - b_1^{LS} \bar{X}_c \quad \bar{Y}_c = \frac{\sum_{i=1}^n Y_i}{n_c}$$

$$\text{สมการถดถอยที่ได้ คือ } \hat{Y}^{LS} = b_0^{LS} + b_1^{LS} X_i$$

ประมาณค่าสังเกต Y_i ที่ขาดหายไป โดยใช้สมการถดถอยซึ่งหาได้นี้ แล้วนำค่า \hat{Y}_i ที่ประมาณได้ แทนค่าสังเกต Y_i ที่ขาดหายไป ใช้วิธีกำลังสองน้อยที่สุดเหมือนเมื่อมีข้อมูลครบถ้วน หาค่า $b_1^{(1)}$ และ $b_0^{(1)}$ ซึ่งจะหาได้เช่นเดียวกับ b_1^{LS} และ b_0^{LS} ซึ่งหาได้จาก (2.1.4) และ (2.1.5) ตามลำดับ จะได้

$$b_1^{(1)} = \frac{\sum_{i=1}^n X_i Y_i - n_x \bar{Y}_{n_x} \bar{X}_{n_x}}{\sum_{i=1}^n X_i^2 - n_x \bar{X}_{n_x}^2}; \quad \bar{X}_{n_x} = \frac{\sum_{i=1}^n X_i}{n_x}$$

$$\text{และ } b_0^{(1)} = \bar{Y}_{n_x} - b_1^{(1)} \bar{X}_{n_x} \quad \bar{Y}_{n_x} = \frac{\sum_{i=1}^n Y_i}{n_x}$$

$$\text{สมการถดถอยที่ได้ใหม่ คือ } \hat{Y}_i^{(1)} = b_0^{(1)} + b_1^{(1)} X_i$$

เราใช้สมการถดถอยที่หาได้นี้ในการพยากรณ์ต่อไป

เมื่อจะทดสอบสมมติฐาน $H_0: \beta_1 = 0$; $H_A: \beta_1 \neq 0$ โดยใช้การทดสอบ F

(F-test) เราใช้ตาราง ANOVA ต่อไปนี้

ตารางที่ 3

ANOVA

Sov	df.	SS	MS	F
Reg	1	$\sum_{i=1}^n x (\hat{Y}_i - \bar{Y}_{n_x})^2 = SSR$	$SSR/1 = MRS$	$\frac{MSR}{MSE}$
Error	$n_c - 2$	$\sum_{i=1}^n x (Y_i - \hat{Y}_i)^2 = SSE$	$SSE/(n_c - 2) = MSE$	
Total	$n_c - 1$	$\sum_{i=1}^n x (Y - \bar{Y}_{n_x})^2 = SST$		

2.2 การถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression)

$$\text{จากตัวแบบ } Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \epsilon$$

$$\text{หรือเขียนในรูปเมทริกซ์จะได้ } Y = X\beta + \epsilon$$

ให้ $b_1^{(1)}$ และ $b_i^{(1)}$ เป็นค่าประมาณของ β_0 และ β_i ตามลำดับ จะได้

$$\text{สมการถดถอย } Y_i^{(1)} = b_0^{(1)} + b_1^{(1)} + b_1^{(1)} x_{1i} + b_2^{(1)} x_{2i} + \dots + b_p^{(1)} x_{pi}$$

$$\text{หรือเขียนในรูปเมทริกซ์จะได้ } \hat{Y}^{(1)} = X\hat{\beta}^{(1)}$$

สมมติว่าข้อมูลที่รวบรวมมาได้มีดังนี้

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \end{bmatrix}, \quad X = \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \end{bmatrix}, \quad \epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \epsilon_3 \end{bmatrix}$$

โดยที่ x_1	แทนเวกเตอร์ค่าสังเกตที่มีอยู่	ซึ่งตรงกับ x_1
x_2	แทนเวกเตอร์ค่าสังเกตที่สูญหาย	ซึ่งตรงกับ x_2
x_3	แทนเวกเตอร์ค่าสังเกตที่มีอยู่	ซึ่งตรงกับ x_3
x_4	แทนเวกเตอร์ค่าสังเกตที่สูญหาย	ซึ่งตรงกับ x_4
x_1	แทนเมทริกซ์ที่ไม่มีค่าสังเกตตัวใดตัวหนึ่งสูญหาย	
x_2	แทนเมทริกซ์ที่ไม่มีค่าสังเกตตัวใดตัวหนึ่งสูญหาย	
x_3	แทนเมทริกซ์ที่มีค่าสังเกตสูญหายอย่างน้อยหนึ่งตัว	
x_4	แทนเมทริกซ์ที่มีค่าสังเกตสูญหายอย่างน้อยหนึ่งตัว	

โดยวิธีกำลังสองน้อยที่สุด เช่นเดียวกับสมการจาก (2.1.2) จะได้สมการ
ถดถอย คือ

$$\hat{Y}^{LS} = X_0 \hat{\beta}_0^{LS} \quad (2.2.1)$$

$$X_0 = \begin{bmatrix} x_1 \\ x_2 \\ 0 \end{bmatrix} \quad Y = \begin{bmatrix} y_1 \\ 0 \\ y_3 \\ 0 \end{bmatrix}$$

โดยวิธีเช่นเดียวกับสมการที่ได้จาก (2.1.15) จะได้

$$\hat{\beta}_0^{LS} = (X_0' X_0)^{-1} X_0' Y$$

ถ้า y_2 ที่ขาดหายไปจะแทนด้วย \hat{y}_2 ซึ่งจะได้จาก (2.2.1) และ
Corrected ด้วย c^1 ซึ่งเป็น Matrix factor มีค่า

$$c = [I - X_2 (X_0' X_0)^{-1} X_2']^{-1}$$

¹ Ibid., p. 597.

$$\text{จะได้ } \hat{Y}_2 = c x_2 / \hat{\beta}_0^{LS}$$

นำค่า Y_2 ที่ได้ ไปแทนค่า Y_2 ที่ขาดหายไป แล้วหาค่า $\hat{\beta}_0^{LS}$ ใหม่ โดยแทน $Y_3, Y_4 = 0$ และแทน $X = X_0$ และทำเหมือนกับวิธีกำลังสองน้อยที่สุด

โดยวิธีเช่นเดียวกับสมการที่ได้จาก (2.1.11) และ (2.1.12) จะได้

$$\hat{\beta}^{(1)} = (X_0' X_0)^{-1} X_0' Y^{(1)}$$

และสมการถดถอยที่ได้ คือ $\hat{Y}^{(1)} = X_0 \hat{\beta}^{(1)}$

เมื่อจะทดสอบสมมติฐาน $H_0: \beta = 0; H_A: \beta \neq 0$ โดยใช้การทดสอบ F (F-test) เราใช้ตาราง ANOVA ต่อไปนี้

ตารางที่ 4

ANOVA

Sov	df.	SS	MS	F
Reg	p+1	$\hat{\beta}^{(1)'} X_0' \hat{Y}^{(1)} = SSR$	$\frac{SSR}{p+1} = MSR$	$\frac{MSR}{MSE}$
Error	$n_c - p - 1$	$\hat{Y}^{(1)'} \hat{Y}^{(1)} - \hat{\beta}^{(1)'} X_0' \hat{Y}^{(1)} = SSE$	$\frac{SSE}{n_c - p - 1} = MSE$	
Total (uncorrected)	n_c	$\hat{Y}^{(1)'} \hat{Y}^{(1)} = SST$		

ในที่นี้ n_c คือ จำนวนหน่วยตัวอย่างที่มีทั้งค่า X และ Y อยู่ครบถ้วน

3. วิธีการประมาณค่าของตัวแปรที่ขาดหายไปโดยวิธีอันดับศูนย์

(The Zero Order Method)¹

วิธีนี้จะประมาณค่า y ที่ขาดหายไปด้วย \bar{y}_{n_y} และประมาณค่า x ที่ขาดหายไปด้วย \bar{x}_{n_x} แล้วใช้วิธีกำลังสองน้อยที่สุด เหมือนเมื่อมีข้อมูลครบถ้วน ในการประมาณค่าพารามิเตอร์

$$\text{เพื่อ } \bar{y}_{n_y} = \frac{\sum_{i=1}^n y_i}{n_y}$$

$$\bar{x}_{n_x} = \frac{\sum_{i=1}^n x_i}{n_x}$$

3.1 การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression)

จากตัวแบบ $y_i = \beta_0 + \beta_1 x_i + \epsilon$

ให้ $b_0^{(2)}$ และ $b_1^{(2)}$ เป็นค่าประมาณของ β_0 และ β_1 จะได้สมการถดถอยที่ต้องการ คือ

$$\hat{y}_i^{(2)} = b_0^{(2)} + b_1^{(2)} x_i$$

เมื่อกำหนดให้ $n = (n_c + m_x + m_y) =$ จำนวนหน่วยตัวอย่างทั้งหมด

$n_c =$ จำนวนหน่วยตัวอย่างที่มีทั้งค่าของ x และ y

$m_x = (n - n_c) =$ จำนวนหน่วยตัวอย่างที่ค่าของ x ขาดหายไป

$m_y = (n - n_c) =$ จำนวนหน่วยตัวอย่างที่ค่าของ y ขาดหายไป

¹ A.A. Afifi and R.M. Elashoff, "Missing Observation in Multivariate Statistics II. Point Estimation in Simple Linear Regression," Journal of the American Statistical Association, 62 (1967), pp. 12-15.

n_x = จำนวนหน่วยตัวอย่างที่มีค่าของ X ทั้งหมด

n_y = จำนวนหน่วยตัวอย่างที่มีค่าของ Y ทั้งหมด

ค่า Y ที่ขาดหายไปจะประมาณด้วย $\bar{Y}_{n_y} = \frac{\sum_{i=1}^n Y_i}{n_y}$

ส่วนค่า X ที่ขาดหายไปจะประมาณด้วย $\bar{X}_{n_x} = \frac{\sum_{i=1}^n X_i}{n_x}$

เมื่อนำค่า \bar{Y}_{n_y} และ \bar{X}_{n_x} แทนค่าสังเกต Y_i และ X_i ที่ขาดหายไปตามลำดับแล้ว ใช้วิธีกำลังสองน้อยที่สุด เหมือนเมื่อมีข้อมูลครบถ้วน จะหาค่า $b_1^{(2)}$ และ $b_0^{(2)}$ ได้เช่นเดียวกับ b_1^{LS} และ b_0^{LS} ซึ่งหาได้จาก (2.1.4) และ (2.1.5) ตามลำดับ จะได้

$$b_1^{(2)} = \frac{\sum_{i=1}^n X_i Y_i - n \bar{X}_{n_x} \bar{Y}_{n_y}}{\sum_{i=1}^n X_i^2 - n \bar{X}_{n_x}^2}$$

$$\text{และ } b_0^{(2)} = \bar{Y}_{n_y} - b_1^{(2)} \bar{X}_{n_x}$$

$$\text{สมการถดถอยที่ได้คือ } \hat{Y}_i^{(2)} = b_0^{(2)} + b_1^{(2)} X_i$$

เมื่อจะทดสอบสมมติฐาน $H_0: \beta_1 = 0$; $H_A: \beta_1 \neq 0$ โดยใช้การทดสอบ F (F-test) เราใช้ตาราง ANOVA ต่อไปนี้

ตารางที่ 5
ANOVA



Sov	df.	SS	MS	F
Reg	1	$\sum_{i=1}^n (\hat{Y}_i^{(2)} - \bar{Y}_{n_y})^2 = SSR$	$SSR/1 = MSR$	$\frac{MSR}{MSE}$
Error	$n_c - 2$	$\sum_{i=1}^n (Y_i - \hat{Y}_i^{(2)})^2 = SSE$	$SSE/(n_c - 2)$ = MSE	
Total	$n_c - 1$	$\sum_{i=1}^n (Y_i - \bar{Y}_{n_y})^2 = SST$		

3.2 การถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression)

จากตัวแบบ $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \epsilon$

หรือเขียนในรูปเมทริกซ์ จะได้ $Y = X\beta + \epsilon$

ให้ $b_i^{(2)}$ เป็นค่าประมาณของ β_i , $i = 0, 1, 2, \dots, p$

ตามลำดับ จะได้สมการถดถอย เป็น

$$\hat{Y}_i^{(2)} = b_0^{(2)} + b_1^{(2)} X_{1i} + b_2^{(2)} X_{2i} + \dots + b_p^{(2)} X_{pi}$$

หรือเขียนในรูปเมทริกซ์ จะได้ $\hat{Y}^{(2)} = X\hat{\beta}^{(2)}$

สมมติว่าข้อมูลที่รวบรวมมาได้มีดังนี้

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \end{bmatrix}, \quad X = \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \end{bmatrix}, \quad \epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \epsilon_4 \end{bmatrix}$$

โดยที่ Y_1	แทนเวกเตอร์ค่าสังเกตที่มีอยู่ ซึ่งตรงกับ	X_1
Y_2	แทนเวกเตอร์ค่าสังเกตที่สูญหาย ซึ่งตรงกับ	X_2
Y_3	แทนเวกเตอร์ค่าสังเกตที่มีอยู่ ซึ่งตรงกับ	X_3
Y_4	แทนเวกเตอร์ค่าสังเกตที่สูญหาย ซึ่งตรงกับ	X_4
X_1	แทนเมตริกซ์ที่ไม่มีค่าสังเกตตัวใดตัวหนึ่งสูญหาย	
X_2	แทนเมตริกซ์ที่ไม่มีค่าสังเกตตัวใดตัวหนึ่งสูญหาย	
X_3	แทนเมตริกซ์ที่มีค่าสังเกตสูญหายอย่างน้อยหนึ่งตัว	
X_4	แทนเมตริกซ์ที่มีค่าสังเกตสูญหายอย่างน้อยหนึ่งตัว	

ค่า Y ที่ขาดหายไปจะประมาณด้วย $\bar{Y}_{n_y} = \frac{\sum_{i=1}^n y_{Y_i}}{n_y}$

ส่วนค่า X_j ที่ขาดหายไปจะประมาณด้วย $\bar{X}_j = \frac{\sum_{i=1}^n x_{j X_{ji}}}{n_{X_j}}$; $j = 1, 2, \dots, p$

นำค่า \bar{Y}_{n_y} และ \bar{X}_j แทนค่าสังเกต Y_i และ X_{ji} ที่ขาดหายไปตามลำดับแล้วใช้

วิธีกำลังสองน้อยที่สุดเหมือนเมื่อมีข้อมูลครบ จะหาค่า $\hat{\beta}^{(2)}$ ได้เช่นเดียวกับ $\hat{\beta}^{LS}$ นี้จะได้จาก (2.1.11) จะได้

$$\hat{\beta}^{(2)} = (X'X)^{-1} X'Y$$

สมการถดถอยที่ได้คือ $\hat{Y}^{(2)} = X\hat{\beta}^{(2)}$

เมื่อจะทดสอบสมมติฐาน $H_0 : \beta = 0$, $H_A : \beta \neq 0$ โดยใช้การทดสอบ F (F-test) เราใช้ตาราง ANOVA ต่อไปนี้

ตารางที่ 6

ANOVA

Sov	d.f	SS	MS	F
Reg	p+1	$\sum \hat{\beta}^{(2)} X \hat{Y}^{(2)} = SSR$	$\frac{SSR}{p+1} = MSR$	$\frac{MSR}{MSE}$
Error	$n_c - p - 1$	$\sum \hat{Y}^{(2)} \hat{Y}^{(2)} - \sum \hat{\beta}^{(2)} X \hat{Y}^{(2)} = SSE$	$\frac{SSE}{n_c - p - 1} = MSE$	
Total (uncorrected)	n_c	$\sum \hat{Y}^{(2)} \hat{Y}^{(2)}$		

n_c คือจำนวนหน่วยตัวอย่างที่มีค่า X, Y อยู่ครบถ้วน

4. วิธีการประมาณค่าของตัวแปรที่ขาดหายไปโดยวิธีอันดับศูนย์ดัดแปลง

(A Modified Zero Order Method) ¹

การประมาณค่าสังเกตของตัวแปรที่ขาดหายไปในการวิเคราะห์การถดถอยโดยวิธีนี้ ใจกับการถดถอยเชิงเส้นอย่างง่ายเท่านั้น โดยจะประมาณค่าสังเกต Y ที่ขาดหายไปด้วย u และประมาณค่าสังเกต X ที่ขาดหายไปด้วย v ใช้ค่าประมาณนี้แทนค่าสังเกตที่ขาดหายไป แล้วใช้วิธีกำลังสองน้อยที่สุดในการคำนวณเหมือนเมื่อมีข้อมูลครบในการประมาณค่าพารามิเตอร์

1.4 การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression)

จากตัวแบบ
$$Y_i = \beta_0 + \beta_1 X_i + \epsilon_i$$

¹ Ibid., pp 15-16.

ให้ $b_0^{(3)}$ และ $b_1^{(3)}$ เป็นค่าประมาณของ β_0 และ β_1 จะได้สมการถดถอยที่ต้องการ เป็น

$$\hat{y}_i^{(3)} = b_0^{(3)} + b_1^{(3)}x_i$$

เมื่อกำหนดให้ $n = (n_c + m_x + m_y) =$ จำนวนหน่วยตัวอย่างทั้งหมด

$n_c =$ จำนวนหน่วยตัวอย่างที่มีทั้งค่าของ X และ Y

$m_x = (n - n_c) =$ จำนวนหน่วยตัวอย่างที่ค่าของ X ซากหายไป

$m_y = (n - n_c) =$ จำนวนหน่วยตัวอย่างที่ค่าของ Y ซากหายไป

$n_x =$ จำนวนหน่วยตัวอย่างที่มีค่าของ X ทั้งหมด

$n_y =$ จำนวนหน่วยตัวอย่างที่มีค่า Y ทั้งหมด

$$\text{จากตัวแบบ } Y = \beta_0 + \beta_1 X + \epsilon$$

โดยวิธีกำลังสองน้อยที่สุด จะต้องทำให้ผลบวกของกำลังที่สองของความคลาดเคลื่อน (Error sum of Squares)

$$\sum_{i=1}^n \epsilon_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 \quad (2.4.1)$$

มีค่าน้อยที่สุด เมื่อแทนค่าสังเกต Y และ X ที่ซากหายไปด้วย u และ v ตามลำดับ จะเขียนสมการ (2.4.1) ได้ คือ

$$\begin{aligned} \sum_{i=1}^n \epsilon_i^2 &= \sum_{i=1}^{n_c} (y_i - \beta_0 - \beta_1 x_i)^2 + \sum_{i=1}^{m_y} (u - \beta_0 - \beta_1 x_i)^2 \\ &\quad + \sum_{i=1}^{m_x} (y_i - \beta_0 - \beta_1 v)^2 \end{aligned} \quad (2.4.2)$$

$$\begin{aligned} \frac{\partial}{\partial \beta_0} \sum_{i=1}^n \epsilon_i^2 &= -2 \sum_{i=1}^{n_c} (y_i - \beta_0 - \beta_1 x_i) - 2 \sum_{i=1}^{m_y} (u - \beta_0 - \beta_1 x_i) \\ &\quad - 2 \sum_{i=1}^{m_x} (y_i - \beta_0 - \beta_1 v) = 0 \end{aligned} \quad (2.4.3)$$

$$\begin{aligned}
 \frac{\partial}{\partial \beta_1} \sum_{i=1}^n \epsilon_i^2 &= -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)(x_i) \\
 &\quad - 2 \sum_{i=1}^m (u - \beta_0 - \beta_1 x_i)(x_i) \\
 &\quad - 2 \sum_{i=1}^m x_i (y_i - \beta_0 - \beta_1 v)(v) \\
 &= 0 \qquad (2.4.4)
 \end{aligned}$$

$$\frac{\partial}{\partial u} \sum_{i=1}^n \epsilon_i^2 = 2 \sum_{i=1}^m (u - \beta_0 - \beta_1 x_i) = 0 \qquad (2.4.5)$$

$$\frac{\partial}{\partial v} \sum_{i=1}^n \epsilon_i^2 = 2 \sum_{i=1}^m x_i (y_i - \beta_0 - \beta_1 v)(\beta_1) = 0 \qquad (2.4.6)$$

แทนค่า β_0 และ β_1 ด้วย b'_0 และ b'_1 ตามลำดับ

$$\text{จาก (2.4.5)} \quad \therefore \sum_{i=1}^m y_i u = \sum_{i=1}^m y_i b'_0 + \sum_{i=1}^m y_i b'_1 x_i$$

$$m_y \cdot u = m_y b'_0 + b'_1 m_y \bar{x}_{m_y}, \quad \bar{x}_{m_y} = \frac{\sum_{i=1}^m y_i x_i}{m_y}$$

$$\therefore u = b'_0 + b'_1 \bar{x}_{m_y} \qquad (2.4.7)$$

จาก (2.4.6) นำผลลดด้วย $2b'_1$ จะได้

$$\begin{aligned}
 \sum_{i=1}^m x_i (y_i - b'_0 - b'_1 v) &= 0 \\
 m_x \bar{y}_{m_x} - m_x b'_0 - m_x b'_1 v &= 0; \quad \bar{y}_{m_x} = \frac{\sum_{i=1}^m x_i y_i}{m_x}
 \end{aligned}$$

$$\therefore v = \frac{\bar{Y}_{m_x} - b'_0}{b'_1} \quad (2.4.8)$$

แทนค่า u และ v จากสมการ (2.4.7) และ (2.4.8) ⁶ ใน (2.4.3) จะได้

$$-2 \sum_{i=1}^n c (Y_i - b'_0 - b'_1 X_i) - 2 \sum_{i=1}^m y \left[(b'_0 + b'_1 \bar{X}_{m_y}) - b'_0 - b'_1 X_i \right] - 2 \sum_{i=1}^m x \left[Y_i - b'_0 - b'_1 \left(\frac{\bar{Y}_{m_x} - b'_0}{b'_1} \right) \right] = 0$$

$$\therefore \sum_{i=1}^n c (Y_i - b'_0 - b'_1 X_i) - b'_1 \sum_{i=1}^m y (X_i - \bar{X}_{m_y}) - \sum_{i=1}^m x (Y_i - \bar{Y}_{m_x}) = 0$$

$$\sum_{i=1}^n c (Y_i - b'_0 - b'_1 X_i) - b'_1 \left(\sum_{i=1}^m y X_i - m_y \bar{X}_{m_y} \right) - \left(\sum_{i=1}^m x Y_i - m_x \bar{Y}_{m_x} \right) = 0$$

$$\therefore n_c b'_0 = \sum_{i=1}^n c Y_i - b'_1 \sum_{i=1}^n c X_i$$

$$\therefore b'_0 = \bar{Y}_c - b'_1 \bar{X}_c \quad (2.4.9)$$

แทนค่า u และ v ใน (2.4.4) จะได้

$$-2 \sum_{i=1}^n c (Y_i - b'_0 - b'_1 X_i) (X_i) - 2 \sum_{i=1}^m y \left[(b'_0 - b'_1 \bar{X}_{m_y}) - b'_0 - b'_1 X_i \right] (X_i) - 2 \sum_{i=1}^m x \left[Y_i - b'_0 - b'_1 \frac{(\bar{Y}_{m_x} - b'_0)}{b'_1} \right] \frac{(\bar{Y}_{m_x} - b'_0)}{b'_1} = 0$$

$$\therefore \sum_{i=1}^n c (y_i - b'_0 - b'_1 x_i) (x_i) - b'_1 \sum_{i=1}^m y (x_i - \bar{x}_{m_y}) (x_i) + \left(\frac{\bar{y}_m - b'_0}{b'_1} \right) \sum_{i=1}^m x (y - \bar{y}_{m_x}) = 0$$

$$\therefore \sum_{i=1}^n c (y_i - b'_0 - b'_1 x_i) (x_i) - b'_1 \sum_{i=1}^m y (x_i - \bar{x}_{m_y}) (x_i) = 0$$

แทนค่า b'_0 จาก (2.4.9)

$$\therefore \sum_{i=1}^n c (y_i - \bar{y}_c + b'_1 \bar{x}_c - b'_1 x_i) (x_i) - b'_1 \sum_{i=1}^m y (x_i - \bar{x}_{m_y}) (x_i) = 0$$

$$\sum_{i=1}^n c x_i y_i - \bar{y}_c \sum_{i=1}^n c x_i - b'_1 \sum_{i=1}^n c (x_i - \bar{x}_c) (x_i) - b'_1 \sum_{i=1}^m y (x_i - \bar{x}_{m_y}) (x_i) = 0$$

$$\left(\sum_{i=1}^n c x_i y_i - n_c \bar{y}_c \bar{x}_c \right) - b'_1 \left[\left(\sum_{i=1}^n c x_i^2 - n_c \bar{x}_c^2 \right) + \left(\sum_{i=1}^m y x_i^2 - m_y \bar{x}_{m_y} \right) \right] = 0$$

$$\sum_{i=1}^n c (x_i - \bar{x}_c) (y_i - \bar{y}_c) - b'_1 \left[\sum_{i=1}^n c (x_i - \bar{x}_c)^2 + \sum_{i=1}^m y (x_i - \bar{x}_{m_y})^2 \right] = 0$$

$$\therefore b'_1 = \frac{\sum_{i=1}^n c (x_i - \bar{x}_c) (y_i - \bar{y}_c)}{\sum_{i=1}^n c (x_i - \bar{x}_c)^2 + \sum_{i=1}^m y (x_i - \bar{x}_{m_y})^2} \quad (2.4.10)$$

แทนค่า b'_0 ที่ได้จาก (2.4.9) ใน (2.4.7) และ (2.4.8) จะได้

$$\text{จาก (2.4.7)} \quad \therefore u = \bar{y}_c - b'_1 \bar{x}_c + b'_1 \bar{x}_{m_y}$$

$$u = \bar{y}_c + b'_1 (\bar{x}_{m_y} - \bar{x}_c) \quad (2.4.11)$$

$$\begin{aligned} \text{จาก (2.4.8) } \therefore v &= \frac{\bar{Y}_m - (\bar{Y}_c - b'_1 \bar{X}_c)}{b_1} \\ v &= \bar{X}_c + \frac{\bar{Y}_m - \bar{Y}_c}{b'_1} \end{aligned} \quad (2.4.12)$$

นำค่า n และ v ที่คำนวณได้จาก (2.4.11) และ (2.4.12) แทนค่า Y_i และ X_i ที่ขาดหายไปตามลำดับ แล้วใช้วิธีกำลังสองน้อยที่สุด เหมือนเมื่อมีข้อมูลครบถ้วน จะหาค่า $b_1^{(3)}$ และ $b_0^{(3)}$ ได้เช่นเดียวกับ b_1^{LS} และ b_0^{LS} ซึ่งหาได้จาก (2.1.4) และ (2.1.5) ตามลำดับจะได้อีก

$$b_1^{(3)} = \frac{\sum_{i=1}^n X_i Y_i - n \bar{X}_n \bar{Y}_n}{\sum_{i=1}^n X_i^2 - n \bar{X}_n^2}$$

$$\text{และ } b_0^{(3)} = \bar{Y}_n - b_1^{(3)} \bar{X}_n$$

$$\text{สมการถดถอยที่ได้คือ } \hat{Y}_i^{(3)} = b_0^{(3)} + b_1^{(3)} X_i$$

เมื่อจะทดสอบสมมติฐาน $H_0: \beta_1 = 0$; $H_A: \beta_1 \neq 0$ โดยใช้การทดสอบ F (F-test) เราใช้ตาราง ANOVA ต่อไปนี้

ตารางที่ 7

ANOVA

Sov	df.	SS	MS	F
Reg	1	$\sum_{i=1}^n (\hat{Y}_i^{(3)} - \bar{Y}_n)^2 = SSR$	$SSR/1 = MSR$	$\frac{MSR}{MSE}$
Error	$n-2$	$\sum_{i=1}^n (Y_i - \hat{Y}_i^{(3)})^2 = SSE$	$SSE/(n-2) = MSE$	
Total	$n-1$	$\sum_{i=1}^n (Y_i - \bar{Y}_n)^2 = SST$		

5. วิธีการประมาณค่าของตัวแปรที่ขาดหายไป โดยวิธีถดถอยอันดับหนึ่ง(A First Order Regression Method) ¹

การประมาณค่าสังเกตของตัวแปรที่ขาดหายไปในการวิเคราะห์การถดถอย โดยวิธีนี้จะกล่าวถึงวิธีการถดถอยเชิงเส้นอย่างง่ายเท่านั้น ซึ่งมีวิธีการที่สลับซับซ้อนพอสมควร โดยมีวิธีทำเป็นขั้น ๆ ดังนี้

จุฬาลงกรณ์มหาวิทยาลัย

¹ A.A. Afifi and R.M. Elashoff. "Missing Observation in Multivariate Statistics III. Large Sample Analysis of Simple Linear Regression," Journal of the American Statistical Association, 64 (Number 325) pp. 346-350.



- ก. คำนวณการถดถอยของ Y ในเทอม X จากข้อมูลซึ่งมีทั้งค่าของ Y และ X โดยวิธีกำลังสองน้อยที่สุด และประมาณค่า Y 's ที่ขาดหายไปโดยใช้สมการถดถอยที่ได้
- ข. คำนวณการถดถอยของ X ในเทอม Y จากข้อมูลซึ่งมีทั้งค่า Y และ X โดยวิธีกำลังสองน้อยที่สุด และประมาณค่า X 's ที่ขาดหายไป โดยใช้สมการถดถอยที่ได้
- ค. นำค่า Y_i ที่ประมาณได้จากข้อ ก. และค่า X_i ที่ประมาณได้จากข้อ ข. แทนค่า Y_i และ X_i ที่ขาดหายไปตามลำดับ
- ง. คำนวณการถดถอยของ Y ในเทอม X ใหม่ โดยใช้วิธีกำลังสองน้อยที่สุดในวิธีการคำนวณเหมือนเมื่อมีข้อมูลครบถ้วน

จากตัวแบบ
$$Y = \beta_0 + \beta_1 X + \epsilon$$

ให้ $b_0^{(4)}$ และ $b_1^{(4)}$ เป็นค่าประมาณของ β_0 และ β_1 จะได้สมการถดถอยที่ต้องการ คือ

$$\hat{Y}_i^{(4)} = b_0^{(4)} + b_1^{(4)} X_i$$

เมื่อกำหนดให้ $n = (n_c + m_x + m_y) =$ จำนวนหน่วยตัวอย่างทั้งหมด

$n_c =$ จำนวนหน่วยตัวอย่างที่มีทั้งค่าของ X และ Y

$m_x = (n - n_c) =$ จำนวนหน่วยตัวอย่างที่ค่าของ X ขาดหายไป

$m_y = (n - n_c) =$ จำนวนหน่วยตัวอย่างที่ค่าของ Y ขาดหายไป

n_x จำนวนหน่วยตัวอย่างที่มีค่าของ X ทั้งหมด

n_y จำนวนหน่วยตัวอย่างที่มีค่าของ Y ทั้งหมด

ให้นำข้อมูลที่รวบรวมมาได้ ซึ่งมีทั้งค่า X และ Y (n_c) จำนวนทางการถดถอยของ Y ต่อ X โดยหาค่า b_1^{LS} และ b_0^{LS} ได้เช่นเดียวกับ b_1^{LS} และ b_0^{LS} ซึ่งหาได้จาก (2.1.4) และ (2.1.5) ตามลำดับ จะได้

$$b_1^{LS} = \frac{\sum_{i=1}^{n_c} X_i Y_i - n_c \bar{Y}_c \bar{X}_c}{\sum_{i=1}^{n_c} X_i^2 - n_c \bar{X}_c^2} ; \quad \bar{X}_c = \frac{\sum_{i=1}^{n_c} X_i}{n_c}$$

$$\bar{Y}_c = \frac{\sum_{i=1}^{n_c} Y_i}{n_c}$$

และ $b_0^{LS} = \bar{Y}_c - b_1^{LS} \bar{X}_c$

ดังนั้นสมการถดถอยที่ได้คือ $\hat{Y}_i^{LS} = b_0^{LS} + b_1^{LS} X_i$ (2.5.1)

จากข้อมูลเดียวกันนี้ จะคำนวณการถดถอยของ X ต่อ Y ได้เช่นเดียวกัน โดยหาค่า d_1^{LS} และ d_0^{LS} ได้ เช่นเดียวกับ b_1^{LS} และ b_0^{LS} ซึ่งหาได้จาก (2.1.4) และ (2.1.5) ตามลำดับ จะได้

$$d_1^{LS} = \frac{\sum_{i=1}^{n_c} X_i Y_i - n_c \bar{Y}_c \bar{X}_c}{\sum_{i=1}^{n_c} Y_i^2 - n_c \bar{Y}_c^2}$$

$$d_0^{LS} = \bar{X}_c - d_1^{LS} \bar{Y}_c$$

สมการถดถอยที่ได้ คือ $\hat{X}_i^{LS} = d_0^{LS} + d_1^{LS} Y_i$ (2.5.2)

ประมาณค่าสังเกต Y 's และ X 's ที่ขาดหายไป โดยใช้สมการถดถอยซึ่งหาได้จาก (2.5.1) และ (2.5.2) ตามลำดับ แล้วให้นำค่า Y_i และ X_i ที่ประมาณได้ไป

แทนค่า สังเกต Y_i และ X_i ที่ขาดหายไปตามลำดับ แล้วใช้วิธีกำลังสองน้อยที่สุดเหมือนเมื่อมีข้อมูลครบถ้วน หาค่า $b_1^{(4)}$ และ $b_0^{(4)}$ ซึ่งจะหาได้เช่นเดียวกับ b_1^{LS} และ b_0^{LS} ซึ่งหาได้จาก (2.1.4) และ (2.1.5) ตามลำดับ จะได้

$$b_1^{(4)} = \frac{\sum_{i=1}^n X_i Y_i - n\bar{X}_n \bar{Y}_n}{\sum_{i=1}^n X_i^2 - n\bar{X}_n^2}$$

$$\text{และ } b_0^{(4)} = \bar{Y}_n - b_1^{(4)} \bar{X}_n$$

$$\text{สมการถดถอยที่ได้คือ } \hat{Y}_i^{(4)} = b_0^{(4)} + b_1^{(4)} X_i$$

$$\begin{aligned} \text{โดยที่ } \bar{Y}_n &= \frac{\sum_{i=1}^n Y_i}{n} = \frac{1}{n} \left\{ \sum_{i=1}^n Y_i + \sum_{i=1}^m Y_i + \sum_{i=1}^m Y_i \right\} \\ &= \frac{1}{n} \left\{ \sum_{i=1}^n Y_i + \sum_{i=1}^m Y_i + \sum_{i=1}^m [\bar{Y}_c + b_1^{LS}(X_i - \bar{X}_c)] \right\} \\ &= \frac{1}{n} \left\{ n\bar{Y}_c + m\bar{Y}_x + m\bar{Y}_c + m b_1^{LS}(\bar{X}_m - \bar{X}_c) \right\} \\ &= \frac{(n+m)}{n} \cdot \bar{Y}_c + \frac{m}{n} \bar{Y}_x + \frac{m}{n} b_1^{LS}(\bar{X}_m - \bar{X}_c) \\ &= \frac{n}{n} \cdot \bar{Y}_c + \frac{m}{n} \bar{Y}_x + \frac{m}{n} b_1^{LS}(\bar{X}_m - \bar{X}_c) \end{aligned}$$

$$\bar{X}_n = \frac{\sum_{i=1}^n X_i}{n} = \frac{1}{n} \left\{ \sum_{i=1}^n X_i + \sum_{i=1}^m X_i + \sum_{i=1}^m X_i \right\}$$

$$\begin{aligned}
&= \frac{1}{n} \left\{ \sum_{i=1}^n X_i + \sum_{i=1}^m \left[\bar{X}_c + d_1^{LS} (Y_i - \bar{Y}_c) \right] + \sum_{i=1}^m X_i \right\} \\
&= \frac{1}{n} \left\{ n_c \bar{X}_c + m \bar{X}_x + m d_1^{LS} (\bar{Y}_{m_x} - \bar{Y}_c) + m \bar{X}_{m_y} \right\} \\
&= \frac{(n_c + m)}{n} \cdot \bar{X}_c + \frac{m}{n} \bar{X}_{m_y} + \frac{m}{n} d_1^{LS} (\bar{Y}_{m_x} - \bar{Y}_c) \\
&= \frac{n}{n} \cdot \bar{X}_c + \frac{m}{n} \bar{Y}_{m_x} + \frac{m}{n} \cdot d_1^{LS} (\bar{Y}_{m_x} - \bar{Y}_c)
\end{aligned}$$

เมื่อจะทดสอบสมมติฐาน $H_0 : \beta_1 = 0$; $H_A : \beta_1 \neq 0$ โดยใช้การทดสอบ F (F-test) เราใช้ตาราง ANOVA ต่อไปนี้

ตารางที่ 8

ANOVA

SOV	df.	SS	MS	F
Reg	1	$\sum_{i=1}^n (\hat{Y}_i^{(4)} - \bar{Y}_n)^2 = SSR$	$SSR/1 = MSR$	$\frac{MSR}{MSE}$
Error	$n_c - 2$	$\sum_{i=1}^n (Y_i - \hat{Y}_i^{(4)})^2 = SSE$	$SSE/(n_c - 2) = MSE$	
Total	$n_c - 1$	$\sum_{i=1}^n (Y_i - \bar{Y}_n)^2 = SST$		

6. วิธีการประมาณค่าของตัวแปรที่ขาดหายไป โดยวิธีถดถอยสองชั้น

(Another First Order Regression Method or Two-Stage Regression Method) ¹

การประมาณค่าสังเกตของตัวแปรที่ขาดหายไปในการวิเคราะห์การถดถอยโดยวิธีนี้จะกล่าวถึงการถดถอยเชิงเส้นอย่างง่ายเท่านั้น มีวิธีการทำเป็นขั้น ๆ ดังนี้

- ก. คำนวณการถดถอยของ X ในเทอม Y จากข้อมูลซึ่งมีค่าทั้ง Y และ X โดยวิธีกำลังสองน้อยที่สุดและประมาณค่า X 's ที่ขาดหายไปโดยใช้สมการถดถอยที่ได้
- ข. นำค่า X_i ที่ประมาณได้จากข้อ ก. แทนค่า X_i ที่ขาดหายไป
- ค. คำนวณการถดถอยของ Y ในเทอม X ใหม่ จากข้อมูลทั้งหมด Y และ X ($=n_y$) โดยใช้วิธีกำลังสองน้อยที่สุด

จากตัวแบบ
$$Y = \beta_0 + \beta_1 X + \epsilon$$

ให้ $b_0^{(5)}$ และ $b_1^{(5)}$ เป็นค่าประมาณของ β_0 และ β_1 จะได้สมการถดถอยที่
ต้องการ คือ

$$\hat{Y}^{(5)} = b_0^{(5)} + b_1^{(5)} X_i$$

เมื่อกำหนดให้ $n = (n_c + m_x + m_y)$ = จำนวนหน่วยตัวอย่างทั้งหมด

n_c = จำนวนหน่วยตัวอย่างที่มีทั้งค่าของ X และ Y

$m_x = (n - n_c)$ = จำนวนหน่วยตัวอย่างที่ค่าของ X ขาดหายไป

¹ Ibid., pp. 350-351.

$n_y = (n - n_x) =$ จำนวนหน่วยตัวอย่างที่ค่าของ Y ซากหายไป

$n_x =$ จำนวนหน่วยตัวอย่างที่มีค่าของ X ทั้งหมด

$n_y =$ จำนวนหน่วยตัวอย่างที่มีค่าของ Y ทั้งหมด

ให้นำข้อมูลที่เรารวบรวมมาได้ ซึ่งมีทั้งค่า X และ Y (n_c) จำนวนหากการถดถอยของ X on Y โดยหาค่า d_1^{LS} และ d_0^{LS} ได้เช่นเดียวกับ b_1^{LS} และ b_0^{LS} ซึ่งหาได้จาก (2.1.4) และ (2.1.5) ตามลำดับจะได้

$$d_1^{LS} = \frac{\sum_{i=1}^{n_c} X_i Y_i - n_c \bar{Y}_c \bar{X}_c}{\sum_{i=1}^{n_c} Y_i^2 - n_c \bar{Y}_c^2} ; \quad \bar{X}_c = \frac{\sum_{i=1}^{n_c} X_i}{n_c}$$

$$\bar{Y}_c = \frac{\sum_{i=1}^{n_c} Y_i}{n_c}$$

$$\text{และ } d_1^{LS} = \bar{X}_c - d_1^{LS} \bar{Y}_c$$

$$\text{สมการถดถอยที่ได้ คือ } \hat{X}_i^{LS} = d_0^{LS} + d_1^{LS} Y_i$$

ประมาณค่าสังเกต x 's ที่ซากหายไป โดยใช้สมการถดถอย ซึ่งหาได้แล้วนำค่า x_i ที่ประมาณได้ แทนค่าสังเกต x_i ที่ซากหายไปตามลำดับ แล้วใช้วิธีกำลังสองน้อยที่สุด เหมือนเมื่อมีข้อมูลครบถ้วน หาค่า $b_1^{(5)}$ และ $b_0^{(5)}$ ซึ่งจะหาได้เช่นเดียวกับ b_1^{LS} และ b_0^{LS} ซึ่งหาได้จาก (2.1.4) และ (2.1.5) ตามลำดับ จะได้

$$b_1^{(5)} = \frac{\sum_{i=1}^{n_y} X_i Y_i - n_y \bar{Y}_{n_y} \bar{X}_{n_y}}{\sum_{i=1}^{n_y} Y_i^2 - n_y \bar{Y}_{n_y}^2} ;$$

$$b_0^{(5)} = \bar{Y}_{n_y} - b_1^{(5)} \bar{X}_{n_y}$$

$$\text{โดยที่ } \bar{Y}_{n_y} = \frac{\sum_{i=1}^{n_y} Y_i}{n_y}$$

$$\bar{X}_{n_y} = \frac{\sum_{i=1}^{n_y} X_i}{n_y}$$

$$= \frac{1}{n_y} \left\{ \sum_{i=1}^{n_c} X_i + \sum_{i=1}^{m_x} X_i \right\}$$

$$= \frac{1}{n_y} \left\{ n_c \bar{X}_c + \sum_{i=1}^{m_x} [X_c + d_1^{LS} (Y_i - \bar{Y}_c)] \right\}$$

$$= \frac{1}{n_y} \left\{ n_c \cdot \bar{X}_c + m_x \cdot \bar{X}_c + m_x d_1^{LS} (\bar{Y}_{m_x} - \bar{Y}_c) \right\}$$

$$= \frac{n_c + m_x}{n_y} \cdot \bar{X}_c + \frac{m_x}{n_y} \cdot d_1^{LS} (\bar{Y}_{m_x} - \bar{Y}_c)$$

$$= \bar{X}_c + \frac{m_x}{n_y} d_1^{LS} (\bar{Y}_{m_x} - \bar{Y}_c)$$

สมการถดถอยที่ได้ คือ $\hat{Y}_i^{(5)} = b_0^{(5)} + b_1^{(5)} X_i$

เมื่อจะทดสอบสมมติฐาน $H_0 : \beta_1 = 0$; $H_A : \beta_1 \neq 0$ โดยใช้
การทดสอบ F (F-test) เราใช้ตาราง ANOVA ต่อไปนี้

ตารางที่ 9

ANOVA

SOV	df.	SS	MS	F
Reg	1	$\sum_{i=1}^n (\hat{Y}_i^{(5)} - \bar{Y}_{n_y})^2 = SSR$	$SSR/1 = MSR$	$\frac{MSR}{MSE}$
Error	$n_c - 2$	$\sum_{i=1}^n (Y_i - \hat{Y}_i^{(5)})^2 = SSE$	$SSE/(n_c - 2) = MSE$	
Total	$n_c - 1$	$\sum_{i=1}^n (Y_i - \bar{Y}_{n_y})^2 = SST$		

7. วิธีการประมาณค่าของตัวแปรที่ขาดหายไปโดยวิธีผสม (Mixed Method)

การประมาณค่าสังเกตของตัวแปรที่ขาดหายไปในการวิเคราะห์การถดถอยโดยวิธีนี้ เป็นวิธีที่ผู้ทำวิจัยได้นำเสนอมาโดยอาศัยแนวความคิดจากวิธีอันดับศูนย์และวิธีถดถอยอันดับหนึ่ง มีวิธีการดำเนินการเป็นขั้น ๆ ดังนี้

- หาค่าเฉลี่ยของค่าสังเกต X และ Y เท้าที่ข้อมูล X และ Y มีอยู่ จะได้ค่า \bar{X}_{n_x} และ \bar{Y}_{n_y}
- แทนค่าสังเกต X และ Y ที่ขาดหายไปด้วย \bar{X}_{n_x} และ \bar{Y}_{n_y} ตามลำดับ

แล้วนำข้อมูลที่ได้ทั้งหมด คำนวณการถดถอยของ Y ในเทอม X และของ X ในเทอม Y โดยวิธีกำลังสองน้อยที่สุด ซึ่งจะได้สมการถดถอย คือ

$$\hat{Y}_i^o = b_0^o + b_1^o X_i$$

$$\hat{X}_i^o = d_0^o + d_1^o Y_i$$

ค. หาค่าสังเกต Y_i และ X_i ที่ขาดหายไปโดยใช้สมการถดถอยที่ได้จากข้อ ข.

ง. หาค่าเฉลี่ยของ $\frac{\bar{X}_n + \hat{X}_i^0}{2}$ และ $\frac{\bar{Y}_n + \hat{Y}_i^0}{2}$ แล้วนำค่าเฉลี่ยที่ได้มาแทนค่า สังเกต X_i และ Y_i ที่ขาดหายไปตามลำดับ

จ. กำหนดการถดถอยของ Y ในเทอม X ใหม่ โดยใช้วิธีกำลังสองน้อยที่สุด ทำเช่นเดียวกับกรณีที่มีข้อมูลครบถ้วน จึงจะได้สมการถดถอย คือ

$$\hat{Y}_i^{(6)} = b_0^{(6)} + b_1^{(6)} X_i$$

ฉ. ใช้สมการถดถอยที่ได้จากข้อ จ. ในการวิเคราะห์การถดถอย

7.1 การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression)

จากตัวแบบ $Y = \beta_0 + \beta_1 X + \epsilon$

ให้ $b_0^{(6)}$ และ $b_1^{(6)}$ เป็นค่าประมาณของ β_0 และ β_1 ตามลำดับ จะได้สมการถดถอยที่ต้องการ เป็น

$$\hat{Y}_i^{(6)} = b_0^{(6)} + b_1^{(6)} X_i$$

เมื่อกำหนดให้ $n = (n_c + m_x + m_y)$ จำนวนหน่วยตัวอย่างทั้งหมด

$n_c =$ จำนวนหน่วยตัวอย่างที่มีทั้งค่า ของ X และ Y

$m_x = (n - n_c)$ จำนวนหน่วยตัวอย่างที่มีค่าของ X ขาดหายไป

$m_y = (n - n_c)$ จำนวนหน่วยตัวอย่างที่มีค่าของ Y ขาดหายไป

$n_x =$ จำนวนหน่วยตัวอย่างที่มีค่าของ X ทั้งหมด

$n_y =$ จำนวนหน่วยตัวอย่างที่มีค่าของ Y ทั้งหมด

การประมาณค่าที่ขาดหายไปในการวิเคราะห์การถดถอยโดยวิธีผสมมีขั้นตอนดังนี้

(1) ให้นำข้อมูลที่รวบรวมมาได้มาหาค่า \bar{X}_{n_x} และ \bar{Y}_{n_y} โดยที่

$$\bar{X}_{n_x} = \frac{\sum_{i=1}^n X_i}{n_x}$$

$$\bar{Y}_{n_y} = \frac{\sum_{i=1}^n Y_i}{n_y}$$

(2) นำค่า \bar{X}_{n_x} และ \bar{Y}_{n_y} แทนค่าสังเกต X_i และ Y_i ที่ขาดหายไปตามลำดับ แล้วนำข้อมูลที่ได้ทั้งหมดไปหาสมการถดถอยของ Y ในเทอม X และของ X ในเทอม Y โดยวิธีกำลังสองน้อยที่สุด ซึ่งจะได้

$$\hat{Y}_i^o = b_0^o + b_1^o X_i \quad (2.7.1)$$

$$\text{และ} \quad \hat{X}_i^o = d_0^o + d_1^o Y_i \quad (2.7.2)$$

โดยที่ b_1^o , b_0^o , d_1^o และ d_0^o จะหาได้เช่นเดียวกับ b_1^{LS} และ b_0^{LS} ซึ่งหาได้จาก (2.1.4) และ (2.1.5) ตามลำดับ จะได้

$$b_1^o = \frac{\sum_{i=1}^n X_i Y_i - n_c \bar{Y}_{n_y} \bar{X}_{n_x}}{\sum_{i=1}^n X_i^2 - n_x \bar{X}_{n_x}^2}$$

$$b_0^o = \bar{Y}_{n_y} - b_1^o \bar{X}_{n_x}$$

$$d_1^o = \frac{\sum_{i=1}^n X_i Y_i - n_c \bar{Y}_{n_y} \bar{X}_{n_x}}{\sum_{i=1}^n Y_i^2 - n_y \bar{Y}_{n_y}^2}$$

$$d_0^o = \bar{X}_{n_x} - d_1^o \bar{Y}_{n_y}$$

(3) หาค่าสังเกต y_i และ x_i ที่ขาดหายไปโดยใช้สมการถดถอยที่ได้จาก (2.7.1) และ (2.7.2) ตามลำดับ

(4) ประมาณค่า y_i และ x_i ที่ขาดหายไปด้วย \hat{y}_i' และ \hat{x}_i' ตามลำดับ แลวนำค่าที่ได้นี้แทนค่า y_i และ x_i ที่ขาดหายไป ตามลำดับ โดยที่

$$\hat{y}_i' = \frac{\bar{y}_n + \hat{y}_i^o}{2}$$

$$\text{และ } \hat{x}_i' = \frac{\bar{x}_n + \hat{x}_i^o}{2}$$

(5) นำข้อมูลที่ได้นี้มาคำนวณการถดถอยของ y on x โดยวิธีกำลังสองน้อยที่สุดเหมือนเมื่อมีข้อมูลครบถ้วน ซึ่งจะหาค่า $b_1^{(6)}$ และ $b_0^{(6)}$ ได้เช่นเดียวกับ b_1^{LS} และ b_0^{LS} ซึ่งหาได้จาก (2.1.4) และ (2.1.5) ตามลำดับ จะได้

$$b_1^{(6)} = \frac{\sum_{i=1}^n X_i Y_i - n \bar{Y}_n \bar{X}_n}{\sum_{i=1}^n X_i^2 - n \bar{X}_n^2}$$

$$\text{และ } b_0^{(6)} = \bar{Y}_n - b_1^{(6)} \bar{X}_n$$

$$\text{โดยที่ } \bar{Y}_n = \frac{\sum_{i=1}^n Y_i}{n}$$

$$= \frac{1}{n} \left[\sum_{i=1}^n y_i Y_i + \sum_{i=1}^m y_i Y_i \right]$$

$$= \frac{1}{n} \left[n_y \cdot \bar{Y}_{n_y} + \sum_{i=1}^m y_i \frac{\bar{Y}_n + \hat{y}_i^o}{2} \right]$$

$$\begin{aligned}
&= \frac{1}{n} \left\{ n_y \cdot \bar{Y}_{n_y} + \frac{1}{2} \sum_{i=1}^m y \left[\bar{Y}_{n_y} + \bar{Y}_{n_y} + b_1^0 (X_i - \bar{X}_{n_x}) \right] \right\} \\
&= \frac{1}{n} \left[(n_y + m_y) \cdot \bar{Y}_{n_y} + \frac{1}{2} b_1^0 \sum_{i=1}^m y (X_i - \bar{X}_{n_x}) \right] \\
&= \bar{Y}_{n_y} + \frac{1}{2n} b_1^0 \sum_{i=1}^m y (X_i - \bar{X}_{n_x}) \\
\bar{X}_n &= \frac{\sum_{i=1}^n X_i}{n} \\
&= \frac{1}{n} \left[\sum_{i=1}^n X_i + \sum_{i=1}^m X_i \right] \\
&= \frac{1}{n} \left[n_x \cdot \bar{X}_{n_x} + \sum_{i=1}^m \frac{\bar{X}_{n_x} + \hat{X}_i^0}{2} \right] \\
&= \frac{1}{n} \left\{ n_x \cdot \bar{X}_{n_x} + \frac{1}{2} \sum_{i=1}^m x \left[\bar{X}_{n_x} + \bar{X}_{n_x} + d_1^0 (Y_i - \bar{Y}_{n_y}) \right] \right\} \\
&= \frac{1}{n} \left[(n_x + m_x) \bar{X}_{n_x} + \frac{1}{2} d_1^0 \sum_{i=1}^m x (Y_i - \bar{Y}_{n_y}) \right] \\
&= \bar{X}_{n_x} + \frac{1}{2n} \cdot d_1^0 \sum_{i=1}^m x (Y_i - \bar{Y}_{n_y})
\end{aligned}$$

สมการถดถอยที่ได้คือ $\hat{Y}_i^{(6)} = b_0^{(6)} + b_1^{(6)} X_i$

เมื่อจะทดสอบสมมติฐาน $H_0 : \beta_1 = 0 ; H_A : \beta_1 \neq 0$ โดยใช้การทดสอบ F (F-test) เราใช้ตาราง ANOVA ต่อไปนี้

ตารางที่ 10

ANOVA

SOV	df.	SS	MS	F
Reg	1	$\sum_{i=1}^n (\hat{Y}_i^{(6)} - \bar{Y}_n)^2 = SSR$	$SSR/1 = MSR$	$\frac{MSR}{MSE}$
Error	$n_c - 2$	$\sum_{i=1}^n (Y_i - \hat{Y}_i^{(6)})^2 = SSE$	$SSE/(n_c - 2) = MSE$	
Total	$n_c - 1$	$\sum_{i=1}^n (Y_i - \bar{Y}_n)^2 = SST$		

7.2 การถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression)

$$\text{จากตัวแบบ } Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \epsilon$$

$$\text{หรือเขียนในรูปเมทริกซ์จะได้ } Y = X\beta + \epsilon$$

ให้ $b_i^{(6)}$ เป็นค่าประมาณของ β_i , $i = 0, 1, 2, \dots, p$ ตามลำดับ
โดยวิธีสม จะได้สมการถดถอย เป็น

$$\hat{Y}_i^{(6)} = b_0^{(6)} + b_1^{(6)}X_{1i} + b_2^{(6)}X_{2i} + \dots + b_p^{(6)}X_{pi}$$

หรือเขียนในรูปเมทริกซ์จะได้ $\hat{Y}^{(6)} = X\beta^{(6)}$

สมมติว่าข้อมูลที่รวบรวมมาได้ มีดังนี้

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \end{bmatrix}, \quad X = \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \end{bmatrix}, \quad \epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \epsilon_4 \end{bmatrix}$$

โดยที่ Y_1 แทนเวกเตอร์ค่าสังเกตที่มีอยู่ ซึ่งตรงกับ X_1

Y_2 แทนเวกเตอร์ค่าสังเกตที่สูญหาย ซึ่งตรงกับ X_2

Y_3 แทนเวกเตอร์ค่าสังเกตที่มีอยู่ ซึ่งตรงกับ X_3

Y_4 แทนเวกเตอร์ค่าสังเกตที่สูญหาย ซึ่งตรงกับ X_4

X_1 แทนเมทริกซ์ที่ไม่มีค่าสังเกตตัวใดตัวหนึ่งสูญหาย

X_2 แทนเมทริกซ์ที่ไม่มีค่าสังเกตตัวใดตัวหนึ่งสูญหาย

X_3 แทนเมทริกซ์ที่มีค่าสังเกตสูญหายอย่างน้อยหนึ่งตัว

X_4 แทนเมทริกซ์ที่มีค่าสังเกตสูญหายอย่างน้อยหนึ่งตัว

เราประมาณค่าที่ขาดหายไปโดยใช้ขั้นตอนดังนี้

(1) ให้นำข้อมูลที่รวบรวมมาได้มาหาค่า \bar{y}_{n_y} และ $\bar{x}_{n_{x_j}}$ โดยที่

$$\bar{y}_{n_y} = \frac{\sum_{i=1}^n y_i}{n_y}; \quad n_y : \text{จำนวนหน่วยตัวอย่างที่มีค่า } y \text{ ทั้งหมด}$$

$$\bar{x}_j = \frac{\sum_{i=1}^n x_{ij}}{n_{x_j}}; \quad n_{x_j} = \text{จำนวนหน่วยตัวอย่างที่มีค่า } x_j \text{ ทั้งหมด}$$

$j = 1, 2, \dots, p$

(2) นำค่า \bar{y}_{n_y} และ \bar{x}_j แทนค่าสังเกต y และ x_{ij} ที่ขาดหายไปตามลำดับ แล้วนำข้อมูลที่ได้ทั้งหมดไปหาสมการถดถอยของ y on x และของ x_j on y โดยวิธีกำลังสองน้อยที่สุด ซึ่งจะได้อ

$$\hat{y} = x \hat{\beta}' \quad (2.7.3)$$

$$\text{และ } \hat{y}_j'' = x_0 \hat{\beta}'' \quad (2.7.4)$$

เมื่อ y_j คือค่า x_j โดยการแทนค่า y กับ x_j

$$\hat{\beta}' = [x'x]^{-1} x'y$$

$$\text{และ } \hat{\beta}'' = [x'_0 x_0]^{-1} x'_0 y$$

(3) หาค่าสังเกต y_i และ x_{ij} ที่ขาดหายไปโดยใช้สมการถดถอยที่ได้จาก (2.7.3) และ (2.7.4) ตามลำดับ

(4) ประมาณค่า y_i และ x_{ij} ที่ขาดหายไปด้วย \hat{y}_i' และ \hat{x}_{ij}' ตามลำดับ แล้วนำค่าที่ได้แทนค่า y_i และ x_{ij} ที่ขาดหายไปตามลำดับ โดยที่

$$\hat{y}_i' = \frac{\bar{y}_{n_y} + \hat{y}_i}{2}$$

$$\text{และ } \hat{x}_{ij}' = \frac{\bar{x}_{n_y} + \hat{x}_{ij}}{2}$$

(5) นำข้อมูลที่ได้นี้มาคำนวณการถดถอยของ Y on X โดยวิธีกำลังสองน้อยที่สุด เหมือนเมื่อมีข้อมูลครบถ้วน จะหาค่า $\hat{\beta}^{(6)}$ ได้เช่นเดียวกับ $\hat{\beta}^{LS}$ ซึ่งหาได้จาก (2.1.11) จะได้

$$\hat{\beta}^{(6)} = (X'X)^{-1}X'Y$$

$$\text{สมการถดถอยที่ได้คือ } \hat{Y}^{(6)} = X \hat{\beta}^{(6)}$$

เมื่อจะทดสอบสมมติฐาน $H_0 : \beta = 0 ; H_A : \beta \neq 0$ โดยใช้การทดสอบ F (F.test) ตามตาราง ANOVA ดังนี้

ตารางที่ 11

ANOVA

SOV	df	SS	MS	F
Reg	p+1	$\hat{\beta}^{(6)} X' \hat{Y}^{(6)}$	$\frac{SSR}{p+1} = MSR$	$\frac{MSR}{MSE}$
Error	$n_c - (p+1)$	$\hat{Y}'^{(6)} \hat{Y}^{(6)} - \hat{\beta}^{(6)} X' \hat{Y}^{(6)}$	$\frac{SSE}{n_c - (p+1)} = MSE$	
Total	n_c	$\hat{Y}'^{(6)} \hat{Y}^{(6)}$		