

บทที่ 9

ตัวแปรตามที่เป็นตัวแปรเชิงคุณภาพหรือมีค่าจำกัด (Qualitative and Limited Dependent Variables)

9.1 ความหมายและความสำคัญ

คำว่า Qualitative Dependent Variable หมายถึงการนี่ที่ตัวแปรตาม Y เป็นตัวแปรเชิงคุณภาพ หรือ Categorical Variable ซึ่งนักวิจัยจำเป็นต้องกำหนดด้วยสำหรับค่าตัวแปรดังกล่าวในรูปของตัวแปรด้มนี่ หรือกล่าวอย่างไม่เป็นทางการได้ว่า Qualitative Dependent Variable ก็คือตัวแปรตามที่เป็นตัวแปรดั้มมีนั้นเอง เราเรียกสมการ $Y = f(X's)$ ที่ Y เป็น Qualitative Dependent Variable ว่า Quantal Response Model

คำว่า Limited Dependent Variable คือตัวแปรตาม Y ที่มีค่าจำกัดอยู่เฉพาะในบางช่วงของ Real Line เช่น $Y > 0$ (เรียกว่าบัญหา Truncated Sample) หรือตัวแปร Y มีค่าได้ต่ำลดช่วงของ Real Line ยกเว้นบางช่วง (เรียกว่าบัญหา Censored Sample)

ทั้งกรณี Qualitative Dependent Variable และ Limited Dependent Variable เป็นสถานการณ์ที่มีผลให้ไม่อาจใช้ OLS -Estimator ตามปกติได้ เพราะ OLS - Estimator ในกรณีเหล่านี้จะเป็น Biased Estimator และ Inconsistent สำหรับการศึกษาในที่นี่เป็นการศึกษาถึงกรณีของ Qualitative Dependent Variable เท่านั้น ผู้สนใจสามารถศึกษาเรื่อง Limited Dependent Variable ได้จากเอกสารอ้างอิง

พิจารณาสมการถดถอย $Y_i = \alpha + \beta X_i + u_i ; i = 1, 2, \dots, M$ โดยที่ Y เป็นตัวแปรเชิงสุ่มที่มีค่าเป็น 0 และ 1 เท่านั้น เช่น $Y_i = 1$ ถ้าหน่วยสำรวจที่ i คือผู้ป่วยที่เป็นมะเร็งบริเวณศีรษะและลำคอ และ $Y_i = 0$ ถ้าหน่วยสำรวจคือผู้ป่วยที่เป็นมะเร็งบริเวณอื่น ๆ หรือ $Y_i = 0$ ถ้าหน่วยสำรวจคือผู้มีเงินได้ที่มีการศึกษาระดับอุดมศึกษา และ $Y_i = 1$ ถ้าหน่วยสำรวจคือผู้มีเงินได้ที่มีการศึกษาระดับอื่น ๆ

จากตัวอย่างนี้จะเห็นได้ว่า Y_i มีค่าได้ 2 ค่าคือ 0 และ 1 ผลกระทบทั้งหมดที่ตามมาก็คือ u_i จะมีค่าได้ 2 ค่าคือ $u_i = Y_i - (\alpha + \beta X_i) = 1 - (\alpha + \beta X_i)$ ถ้า $Y_i = 1$ และ $u_i = -(\alpha + \beta X_i)$ ถ้าบัญหาที่ปรากฏอย่างเด่นชัดก็คือ

1. เราไม่อาจควบคุมให้ $E(u_i) = 0$ ได้โดยง่าย กล่าวคือถ้าต้องการให้ข้อตกลงว่า $E(u_i) = 0$ เป็นจริงเรามีความจำเป็นต้องควบคุมให้ u_i ปราศจากค่าด้วยความน่าจะเป็น $(\alpha + \beta x_i) = p_i$ หรือ $1 - (\alpha + \beta x_i) = q_i$ เท่านั้น¹ แต่การควบคุมให้ $0 < p_i < 1$ และ $0 < q_i < 1$ เป็นเรื่องที่เป็นไปได้ยาก เพราะโดยปกติ $(\alpha + \beta x_i)$ อาจมีค่ามากกว่า 1 หรือแม้กระทั่งเป็นประมาณติดลบ คือ น้อยกว่า 0 ได้

2. $V(u_i)$ จะไม่คงที่ เพราะในกรณีตัวแปรสุ่ม Y มีการแจกแจงแบบเบอร์นูลลิ (Bernoulli Distribution) ดังนั้น $V(u_i) = p_i q_i = (\alpha + \beta x_i)(1 - \alpha - \beta x_i)$ ซึ่งจะไม่คงที่แต่จะเปลี่ยนไปตามค่าของตัวแปร X ปัญหา Heteroscedasticity จึงเกิดขึ้น

3. สมการประมาณค่า $y_i = \hat{\alpha} - \hat{\beta}x_i$ จะหวั่นไหว (Sensitive) ได้ง่ายเมื่อ X มีค่าเปลี่ยนแปลงไป

4. เราไม่อาจใช้ t-test, F-test ได้รวมทั้ง R^2 ก็ขาดความหมายที่แท้จริง และไม่ใช้เป็นดัชนีในการตัดสินใจได้อีกทั้ง $\hat{\sigma}^2$ ยังเป็น Inconsistent Estimator ของ σ^2 นอกจากนี้แล้วเรายังไม่อาจใช้วิธีการประมาณค่าต่างๆ ที่อาศัย Linear Function ของ Y มาประมาณค่าพารามิเตอร์ เช่น OLS, GLS ได้ เพราะ Y มิได้แจกแจงแบบปกติ เว้นแต่จะได้รับการปรับโครงสร้างและสภาพทั่วไปเสียก่อน

9.2 ตัวอย่าง

เพื่อความเข้าใจปัญหาและติดตามการพัฒนาทางทฤษฎีได้โดยไม่ติดขัดผู้เขียนขอยกตัวอย่างงานวิจัยที่ดำเนินการโดยที่ตัวแปร Y เป็นตัวแปรเชิงคุณภาพ (Dichotomous หรือ Binary Choice Model) ดังนี้

จากข้อมูลเกี่ยวกับความพอใจของทหารว่าพึงพอใจที่จะประจำกองพลในภาคเหนือ หรือภาคใต้ ($y_i = 1$ ถ้าท่านชายที่ i พอยใจจะประจำกองพลในภาคเหนือ $y_i = 0$ ถ้าท่านชายที่ i พอยใจจะประจำกองพลในภาคใต้) โดยที่ตัวแปรอิสระคือ $x_2 = ภูมิลำเนาเดิม ($x_2 = 1$ ถ้ามีภูมิลำเนาเดิมอยู่ภาคเหนือ $x_2 = 0$ ถ้าภูมิลำเนาเดิมอยู่ภาคใต้) $x_3 =$ ที่ตั้งปัจจุบันของกองพลที่สังกัด ($x_3 = 1$ ถ้าสังกัดปัจจุบันอยู่ในภาคเหนือ $x_3 = 0$ ถ้าสังกัดปัจจุบันอยู่ในภาคใต้)$

¹ ตัวแปร Y_i มีการแจกแจงแบบเบอร์นูลลิ กล่าวคือ โดยทั่วไปถ้า x มี pdf เป็น $f(x) = p^x q^{1-x}$; $x = 0, 1$ เราเรียกว่า $f(x)$ ว่า Bernoulli Distribution โดยที่ถ้า $x = 0$ จะได้ $f(x) = q$ และถ้า $x = 1$ จะได้ $f(x) = p$

ผลการบันทึกข้อมูลจากทหาร 8,036 นาย ปรากฏข้อมูลดังตาราง¹

j	k	λ	X_2 ภูมิลำเนาเดิม	X_3 ที่ตั้งสังกัดปัจจุบัน	Y ที่ตั้งสังกัดที่ต้องการ	ความถี่ (f_{jkl})
1	1	1	เหนือ	เหนือ	เหนือ	1342
1	1	0	เหนือ	เหนือ	ใต้	198
1	0	1	เหนือ	ใต้	เหนือ	1750
1	0	0	เหนือ	ใต้	ใต้	760
0	1	1	ใต้	เหนือ	เหนือ	487
0	1	0	ใต้	เหนือ	ใต้	446
0	0	1	ใต้	ใต้	เหนือ	472
0	0	0	ใต้	ใต้	ใต้	2581

และเมื่อจำแนกกลุ่มตัวอย่างจากตารางข้างต้นเพื่อพิจารณาความน่าจะเป็นจะพบว่าเราสามารถเสนอตารางได้ดังนี้

j	k	X_2 ภูมิลำเนาเดิม	X_3 ที่ตั้งสังกัดปัจจุบัน	Y : ที่ตั้งสังกัดที่ต้องการ				รวม (n_{jk})		
				ภาคเหนือ ($\lambda=1$)		ภาคใต้ ($\lambda=0$)				
				f_{jk1}	P_{jk}	ω_{jk}	f_{jk0}	q_{jk}		
1	1	เหนือ	เหนือ	1342	.871	6.778	198	.129	.148	1540
1	0	เหนือ	ใต้	1750	.697	2.303	760	.303	.434	2510
0	1	ใต้	เหนือ	487	.522	1.092	446	.478	.916	933
0	0	ใต้	ใต้	472	.155	0.183	2581	.845	5.468	3053
				4051	.504	1.020	3985	.496	.984	8036

¹ Goodman, Leo, A., Analyzing Qualitative Categorical Date • Log - Linear Models and Latent - Structure Analysis. (Addison • Wesley Publishing Company Advanced Book Program. London, 1978), p.27-56

ข้อสังเกต

$$1. P_{jk} \text{ (หรือ } P_{jk}^{X_2 X_3}) = \text{Prob}(\text{ต้องการสังกัดภาคเหนือ } | x_2 = x_{2j} \text{ และ } x_3 = x_{3k}) \\ = \frac{f_{jk1}}{n_{jk}} \text{ เช่น}$$

$$\hat{P}_{11} = \text{Pr}(\text{ต้องการสังกัดภาคเหนือ } | x_2 = 1, x_3 = 1) = \frac{1342}{1540} = .871$$

$$\hat{P}_{13} = \text{Pr}(\text{ต้องการสังกัดภาคเหนือ } | x_2 = 0, x_3 = 1) = \frac{487}{933} = .522$$

$$2. \omega_{jk} \text{ (หรือ } \omega_{jk}^{X_2 X_3}) = \text{Odds}(\text{ต้องการสังกัดภาคเหนือ } | x_2 = x_{2j}, x_3 = x_{3k}) \\ = \frac{f_{jk1}}{f_{jk0}} = \text{อัตราส่วน (Ratio)}$$

$$\hat{\omega}_{11} = \text{Odds}(\text{ต้องการสังกัดภาคเหนือ } | x_2 = 1, x_3 = 1) = \frac{1342}{198} = 6.778$$

= 6.778 : 1 หรือทหารที่มีภูมิลำเนาอยู่ภาคเหนือที่สังกัดกองพลในภาคเหนือ
แต่ต้องการสังกัดเหนือบ้างภาคใต้บ้างคิดเป็นอัตราส่วน 6.778 ต่อ 1

$$\hat{\omega}_{14} = \text{Odds}(\text{ต้องการสังกัดภาคเหนือ } x_2 = 0, x_3 = 0) = \frac{472}{2581} = .183$$

3. Odds และ Prob สามารถใช้คำนวณย้อนสู่กันและกันได้ดังนี้

$$\text{Odds} = \frac{\text{Prob}}{(1-\text{Prob})}$$

$$\text{Prob} = \frac{\text{Odds}}{(1+\text{Odds})}$$

เช่น

$$\hat{\omega}_{11} = 6.778 \quad \hat{P}_{11} = \hat{\omega}_{11} / (1 + \hat{\omega}_{11}) = 6.778 / 7.778 = .871$$

$$\hat{\omega}_{14} = .183 \quad \hat{P}_{14} = \hat{\omega}_{14} / (1 + \hat{\omega}_{14}) = .183 / 1.183 = .155$$

$$\hat{P}_{11} = .871 \quad \hat{\omega}_{11} = \hat{P}_{11} / (1 - \hat{P}_{11}) = .871 / .129 = 6.751$$

$$\hat{P}_{13} = .552 \quad \hat{\omega}_{13} = \hat{P}_{13} / (1 - \hat{P}_{13}) = .552 / .478 = 1.155$$

หมายเหตุ ค่า $\hat{\omega}_{11}$ และ $\hat{\omega}_{13}$ ตามตัวอย่างนี้คลาดเคลื่อนไปเพื่อการบัดเบซ ถ้าใช้ค่าที่ไม่บัดเบซจะได้เท่ากับในตารางซึ่งคำนวณโดยตรงตามข้อ 1 และ 2

ตัวอย่างนี้เป็นตัวอย่างที่ชี้ให้เห็นว่าในการวิเคราะห์สมการถดถอยที่ตัวแปร Y เป็น Quantal เราจำเป็นต้องจำแนกค่าสังเกตออกเป็นกลุ่ม ๆ (Subsample) เรียกว่า Setting ของตัวแปรอิสระ จากนั้นจึงคำนวณหาค่าความน่าจะเป็น p และ q หรือ Odds เพื่อนำไปใช้ประโยชน์ใน การวิเคราะห์ต่อไป ในขั้นต้นนี้ผู้เขียนขอแสดงตัวอย่างนี้เพียงระดับการกำหนด Setting ของตัวแปร อิสระ¹ และการหาค่าความน่าจะเป็นเท่านั้น ซึ่งคิดว่าจะมีประโยชน์เพียงพอที่จะใช้เป็นพื้นความรู้ ในการศึกษาเรื่องของ Probit และ Logit ต่อไป และจะเสนอการประมาณค่าพารามิเตอร์ต่อไปเมื่อ ศึกษาถึงเรื่องนั้น

9.3 การประมาณค่าสำหรับ Binary Choice Model

เมื่อ y_i ในสมการ $Y = f(X's)$ เป็นตัวแปรดั้มมีชื่อมีค่าได้ 2 ค่า (Binary Choice หรือ Dichotomous) คือ 0, 1 (หรือรหัสอื่น ๆ เช่น 1, 2 หรือ -1, 1 ตามที่ผู้วิจัยเห็นสมควร โดยที่ $X's$ อาจเป็น Quantal หรือมิใช่ก็ได้² เรา มีวิธีประมาณค่าได้หลายวิธีดังนี้

9.3.1 Linear Probability Model

วิธีนี้เสนอโดยโกลเดอร์เกอร์, เซลล์เนอร์ และ ลี (Goldberger, A.S., 1964; Zellner, A and Lee, T.H., 1965)³ วิธีปฎิบัติคือจากสมการ $y = X\beta + U$

ให้กำหนด Setting ของตัวแปรอิสระ x_2, x_3, \dots, x_k ออกเป็นส่วน ๆ รวม M ส่วน ๆ ละ n_i หน่วย ให้ $y_i = \sum_{j=1}^{n_i} y_{ij}$ เมื่อ $y_{ij} = 0, 1; i = 1, 2, \dots, M; j = 1, 2, \dots, n_i$ และ $p_i = \frac{y_i}{n_i}; i = 1, 2, \dots, M$ คือความน่าจะเป็นที่ $y_i = 1$ ใน Setting ที่ $i; i = 1, 2, \dots, M$ หรือ $p_i = \frac{Y}{n_i}$ ก็คือ Sample Proportion ใน Setting ที่ i ของ $X's$

¹ การกำหนด Setting ของตัวแปรอิสระก็คือการจัดกลุ่ม (Combination) ของรหัสของตัวแปรตามตัวอย่าง นี่ $x_2 = 0, 1$ และ $x_3 = 0, 1$ เราจึงสามารถจัดกลุ่มค่าสังเกตของ x_2 และ x_3 ได้ 2^2 กลุ่ม คือ $(0, 0), (0, 1), (1, 0), (1, 1)$ ด้วยเหตุนี้ถ้ามีตัวแปรอิสระที่เป็นตัวแปรดั้มมีทั้งสิ้น m ตัว เราสามารถจัดกลุ่มค่าสังเกตของ ตัวแปรอิสระได้ทั้งสิ้น 2^m กลุ่ม

² คำว่า Quantal มีความหมายเดียวกับคำว่า Discrete ในทางปฏิบัติเราใช้ในความหมายของ Dummy Variable

³ Judge, G.G., et. al., Op. Cit., p.587

ดังนั้นสมการถดถอยที่ต้องการคือ $p_i = x_i' \beta + u_i$ เมื่อ x_i' คือ Row ที่ i ของแมตริกซ์ X กล่าวคือ $p_i = \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + u_i$; $i = 1, 2, \dots, M$ หรือแสดงในรูปแมตริกซ์ได้เป็น $p = X\beta + u$ โดยที่ $p = [p_1, p_2, \dots, p_M]'$ คือเวกเตอร์ขนาด $M \times 1$, X คือแมตริกซ์ขนาด $M \times k$ และ $\beta = [\beta_1, \beta_2, \dots, \beta_k]'$

สำหรับการตรวจสอบคุณสมบัติของ u_i ในสมการ $p_i = x_i' \beta + u_i$ ให้พิจารณาดังนี้
ให้ true proportion P_i สัมพันธ์กับ Sample Proportion p_i ในลักษณะต่อไปนี้คือ

$$p_i = P_i + u_i \quad ; \quad i = 1, 2, \dots, M$$

จะพบว่า $u_i = p_i - P_i$; $i = 1, 2, \dots, M$ ซึ่งโดยอาศัยทฤษฎีความน่าจะเป็นเราทราบว่าตัวแปรสุ่ม $y_i = 0, 1$ มีการแจกแจงแบบบอร์นูลิ ดังนั้น u_i จึงมีการแจกแจงแบบทวินามที่มีค่าเฉลี่ยเท่ากับ 0 และมีความแปรปรวนเท่ากับ $\frac{P_i Q_i}{n_i}$ กล่าวคือ

$$E(u_i) = E(p_i) - P_i = P_i - P_i = 0$$

$$V(u_i) = V(p_i) = V\left(\frac{y_i}{n_i}\right) = \frac{n_i P_i Q_i}{n_i^2} = \frac{\sigma_i^2}{n_i} = \frac{P_i Q_i}{n_i} \quad ; \quad i = 1, 2, \dots, M$$

ดังนั้น

$$V(U) = \begin{vmatrix} P_1 Q_1 \\ \vdots \\ P_2 Q_2 \\ n_2 \\ \vdots \\ P_3 Q_3 \\ \vdots \\ P_M Q_M \\ n_M \end{vmatrix} = \Phi \neq \sigma^2 I_M$$

¹ จากสมการ $p = X\beta + u$ แสดงว่า $X\beta$ ทำหน้าที่เสมือน true proportion ถ้ากำหนดให้ $X\beta = P$ จึงพบว่า $p = P + u$ หรือ $p_i = P_i + u_i$; $i = 1, 2, \dots, M$

² ตามทฤษฎีความน่าจะเป็น ถ้า $x_i = 0, 1$ และ $\sum_i x_i$ จะมีการแจกแจงแบบทวินาม คือ $b(n, p)$

ดังนั้นมือพิจารณาแมตริกซ์ Φ เราจึงพบว่า $\Phi \neq \sigma^2 I_M$ หรือเกิดปัญหา Heteroscedasticity ทางออกก็คือประมาณค่า β โดยอาศัย GLS เมื่อทราบค่าของ Φ กล่าวคือ

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

และในการนี้ที่ไม่ทราบค่าของ Φ หรือนัยหนึ่งก็คือไม่ทราบค่าของ p_i ให้ดำเนินการประมาณค่าของ p_i เสียก่อนแล้วจึงประมาณค่าเวคเตอร์ β โดยวิธี EGLS ตามขั้นตอนต่อไปนี้

ขั้นที่ 1 จากสมการ $p = X\beta + u$ โดยที่ $p = [p_1, p_2, \dots, p_M]$ เมื่อ $p_i = \frac{y_i}{n_i}$
 $i = 1, 2, \dots, M$ ให้ประมาณค่าเวคเตอร์ β ตามวิธี OLS ได้

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

ขั้นที่ 2 แทนที่ β ด้วย $\hat{\beta}$ จะได้สมการประมาณค่า $p = X\hat{\beta}$ หรือ $\hat{p} = X\hat{\beta}$ สมาชิกของเวคเตอร์ \hat{p} คือ $\hat{p}_i ; i = 1, 2, \dots, M$

ขั้นที่ 3 ประมาณค่า $V(u_i)$ โดยใช้ \hat{p}_i แทน p_i ได้ $V(u_i) = \frac{\hat{p}_i \hat{q}_i}{n_i}; i = 1, 2, \dots, M$
 เมื่อ $\hat{q}_i = 1 - \hat{p}_i$ และพบว่า

$$\hat{\Phi} = \begin{bmatrix} \frac{\hat{p}_1 \hat{q}_1}{n_1} & & & \\ & \ddots & & \\ & & \frac{\hat{p}_2 \hat{q}_2}{n_2} & \\ & & & \ddots \\ & & & & \frac{\hat{p}_M \hat{q}_M}{n_M} \end{bmatrix} \quad \hat{\Phi}^{-1} = \begin{bmatrix} \frac{n_1}{\hat{p}_1 \hat{q}_1} & & & \\ & \ddots & & \\ & & \frac{n_2}{\hat{p}_2 \hat{q}_2} & \\ & & & \ddots \\ & & & & \frac{n_M}{\hat{p}_M \hat{q}_M} \end{bmatrix}$$

ขั้นที่ 4 ใช้ $\hat{\Phi}$ ในการประมาณค่าเวคเตอร์ β ตามวิธี EGLS กล่าวคือ

$$\hat{\hat{\beta}} = (X' \hat{\Phi}^{-1} X)^{-1} (X' \hat{\Phi}^{-1} p), \quad \hat{V}(\hat{\hat{\beta}}) = (X' \hat{\Phi}^{-1} X)^{-1}, \quad p = X\hat{\beta}$$

วิธีนี้เป็นวิธีที่ง่ายที่สุดแต่มีปัญหาซึ่งนับเป็นจุดอ่อน 2 ประการคือ

1. เราไม่อาจรับประกันได้ว่าค่า p_i จากขั้นที่ 2 จะมีค่าปراกฏในช่วง $[0, 1]$ เพราะอาจเป็นไปได้ที่ $\hat{p}_i > 1$ หรือ $\hat{p}_i < 0$

2. เราไม่อาจรับประทานได้ว่าค่าพยากรณ์ของ p_i จากสมการประมาณค่า $p = x\hat{\beta}$ จะมีค่าปراกฏิในช่วง $[0,1]$

วิธีแก้ปัญหาอันเป็นจุดอ่อนก็คือ ให้เปลี่ยนไปใช้เทคนิคการประมาณค่าแบบอื่น ขอให้สังเกตว่าเมื่อ Y เป็นตัวแปรดัชนีที่เราจะไม่พยากรณ์ค่าของ Y แต่จะพยากรณ์สัดส่วนของ Y ในแต่ละ Setting ของ X 's

9.3.2 Transformation Approach

ทางออกสำหรับปัญหาค่า \hat{p} ไม่ตกลอยู่ใน Unit Interval $[0,1]$ นั้นเราสามารถแก้ได้ 3 วิธีคือ วิธี Inequality - Restricted Least Square (IRLS) วิธี Normit analysis (หรือ Probit Analysis) และวิธี Logit Analysis

วิธี IRLS ก็คือวิธีกำหนดเงื่อนไขว่า $P_i \leq 1$ และ $P_i \geq 0$ ซึ่งก็คือ $x_i'\beta \leq 1$ และ $x_i'\beta \geq 0$ เมื่อ x_i' คือแถวที่ i ของแมตริกซ์ X ในสมการ $p = x\beta + u$ นั้นเอง ค่าประมาณของ β ตามวิธี IRLS ก็คือค่าประมาณที่เกิดขึ้นจาก

minimize $e'e$ ภายใต้ข้อจำกัดว่า

$$(1) \quad x\beta \leq 1_M \text{ เมื่อ } 1_M = [1, 1, \dots, 1]^T$$

$$(2) \quad x\beta \geq 0_M \text{ เมื่อ } 0_M = [0, 0, \dots, 0]^T$$

แต่ค่าประมาณของ β ตามวิธี IRLS ยังมีปัญหาคือ เรายังไม่ได้พัฒนา Sampling Property ของ $\hat{\beta}$ ไว้อย่างกว้างขวางเพียงพอแก่งานวิเคราะห์¹

วิธีประมาณค่า β อีกวิธีหนึ่งที่สามารถแก้ปัญหาระบุเรื่องค่าประมาณ \hat{p} ไม่ปراกฏิใน Unit Interval $[0,1]$ ก็คือ Normit Analysis และ Logit Analysis

¹ อ่าน Judge, G.G., et al., Ibid., p.78-94, 588-591

หลักการโดยสรุปของทั้งวิธี Normit Analysis และ Logit Analysis ก็คือการแปลงค่า P_i และ p_i ให้เป็น Quantile¹ ของ Distribution ใดๆ ที่พิจารณาเห็นว่าเหมาะสมแล้วนำค่า Quantile ดังกล่าวไปใช้ในเคราะห์สมการทดสอบ จากนั้นจึงแปลงค่า Quantile กลับสู่รูปความน่าจะเป็น P_i และ p_i ซึ่งมีผลให้ค่าประมาณและค่าพยากรณ์ของ P_i และ p_i ปรากฏอยู่ใน Unit Interval

9.3.2.1 Normit Analysis²

$$\text{จากสมการความสัมพันธ์ } p_i = P_i + u_i ; i = 1, 2, \dots, M \quad \dots \dots (1)$$

ให้ Normit ของ P_i คือ

Normit $P_i = I_i$ เมื่อ $I_i = x_i' \beta = \beta_1 + \beta_2 x_{2i} + \dots + \beta_k x_{ki}$ โดยถือว่า P_i มีความสัมพันธ์กับ I_i ดังนี้

$$P_i = F(I_i) = \int_{-\infty}^{I_i} \frac{1}{\sqrt{2\pi}} \exp(-\frac{1}{2} t^2) dt^3$$

$$\text{หรือ } I_i = F^{-1}(P_i) \quad \dots \dots (2)$$

จาก (1) คือ $P_i = P_i + u_i ; i = 1, 2, \dots, M$ จะพบว่า

$$F^{-1}(P_i) = F^{-1}(P_i + u_i) \quad \dots \dots (3)$$

โดยอาศัย Taylor's Series ของ $f(x)$ ที่กระจายรอบ a คือ

$$f(x) = f(a) + (x-a) f'(a) + \frac{(x-a)}{2!} f''(a) + R$$

ดังนั้นเมื่อกระจาย $F^{-1}(P_i + u_i)$ รอบ P_i จะพบว่า

¹ ถ้า $P_i = \int_{-\infty}^{I_i} f_x(x) dx = Pr(X < I_i) = F(I_i)$ เราเรียก I_i ว่าเป็น Quantile of Order P_i และว่า การแปลงรูป P_i เป็น I_i เป็นกระบวนการที่อาศัย CDF ของตัวแปรสุ่มเป็นตัวกลาง และเมื่องจาก CDF คือพังก์ชันของตัวแปรสุ่มที่มี Domain (ในที่นี้คือค่าของ I_i) ปรากฏอยู่ใน Real Line ขณะที่ Counter Domain (ในที่นี้ คือ P_i หรือ p_i) มีค่าปรากฏอยู่ช่วง $[0, 1]$ ดังนั้นปัญหา P_i และ p_i ไม่ปรากฏค่าใน Unit Interval จึงหมวดไป

² Zellner, A. and Lee, T.H., "Joint Estimation of Relationships Involving Discrete Random Variables", (Econometrica, 33, April, 1965) p. 382-394

³ Probit $P_i = I_i + 5$ และขอให้สังเกตว่า I_i คือ Quantile of Order P_i ของ Normal CDF

$$F^{-1}(P_i + u_i) = F^{-1}(P_i) + u_i \frac{d}{dP_i} F^{-1}(P_i) + R_i \quad \dots \dots (4)$$

นั่นคือ $F^{-1}(P_i) = F^{-1}(P_i) + u_i \frac{d}{dP_i} F^{-1}(P_i) + R_i$

$$I_i^0 = I_i + u_i \frac{d}{dP_i} F^{-1}(P_i) + R_i \quad \dots \dots (5)$$

โดยที่ $I_i^0 = F^{-1}(P_i)$ เรียกว่า Observed Normit และ $I_i = F^{-1}(P_i)$ เรียกว่า True Normit แต่ R_i (R_i คือ Remainder ของ Taylor's Series) มีค่าต่ำและสามารถตัดทิ้งไปได้ ขณะเดียวกันเราสามารถพิสูจน์ได้ว่า $u_i \frac{d}{dP_i} F^{-1}(P_i) = \frac{u_i}{Z(P_i)}$ เมื่อ $Z(P_i)$ คือค่าของ $f_Z(P_i)$ กล่าวคือ

$$Z(P_i) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2} P_i^2}$$

ดังนั้นสมการที่ 5 จึงเปลี่ยนรูปเป็น

$$I_i^0 = I_i + \frac{u_i}{Z(P_i)} ; i = 1, 2, \dots, M$$

หรือสมการถอยที่แปลงรูปแล้วก็คือ

$$I_i^0 = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + \frac{u_i}{Z(P_i)} ; i = 1, 2, \dots, M \quad \dots \dots (6)$$

พิจารณาสมการที่ 6 จะพบว่า

$$E\left(\frac{u_i}{Z(P_i)}\right) = \frac{E(u_i)}{Z(P_i)} = 0 , i = 1, 2, \dots, M$$

$$V\left(\frac{u_i}{Z(P_i)}\right) = \frac{1}{[Z(P_i)]^2} V(u_i) = \frac{1}{[Z(P_i)]^2 n_i} \frac{P_i Q_i}{n_i} ; i = 1, 2, \dots, M$$

$$V(U) = \phi = \begin{bmatrix} p_1 q_1 / n_1 [Z(p_1)]^2 \\ p_2 q_2 / n_2 [Z(p_2)]^2 \\ \vdots \\ p_M q_M / n_M [Z(p_M)]^2 \end{bmatrix}_{M \times M}$$

$$= \sigma^2 I_M$$

และเนื่องจาก p_i เป็นค่าประมาณของ P_i ดังนั้น

$$\hat{\phi} = \begin{bmatrix} p_1 q_1 / n_1 [Z(p_1)]^2 \\ p_2 q_2 / n_2 [Z(p_2)]^2 \\ \vdots \\ p_M q_M / n_M [Z(p_M)]^2 \end{bmatrix}_{M \times M}$$

ดังนั้นโดยอาศัย EGLS เราสามารถประมาณค่า β ได้ดังนี้

$$\hat{\beta} = (X' \hat{\phi}^{-1} X)^{-1} X' \hat{\phi}^{-1} I^0, \quad \hat{V}(\hat{\beta}) \approx (X' \hat{\phi}^{-1} X)^{-1}$$

โดยที่ $I^0 = [F^{-1}(p_1), F^{-1}(p_2), \dots, F^{-1}(p_M)]'$ คือเวคเตอร์ของ Observed Normit และ
 $\hat{\beta} = [\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_M]'$

9.3.2.2 Logit Analysis

Logit Analysis เป็นเทคนิคการแปลงค่า p_i สู่ดัชนี I_i โดยผ่าน Logistic Distribution
 คือ กำหนดให้

¹ อ่าน Zellner, A. and Lee, T.H., Ibid., p.384

$$P_i = \frac{1}{1+e^{-\beta' X_i}} = \frac{1}{1+e^{-X_i'\beta}} = \frac{1}{1+e^{-(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})}} ;$$

$$i = 1, 2, \dots, M \quad . \quad . \quad . \quad (1)$$

การพัฒนาวิธีประมาณค่า β ดำเนินการดังนี้

จากสมการ $P_i = P_i + u_i$ และ $1-P_i = 1 - (P_i + u_i)$ จะพบว่า

$$\begin{aligned} \frac{P_i}{1-P_i} &= \frac{P_i + u_i}{(1-P_i) - u_i} \\ &= \frac{P_i \cdot (1+u_i/P_i)}{1-P_i(1-u_i/Q_i)} \text{ เมื่อ } Q_i = 1 - P_i \end{aligned}$$

$$\text{ดังนั้น } \ln\left(\frac{P_i}{1-P_i}\right) = \ln\left(\frac{P_i}{1-P_i}\right) + \ln\left(1 + \frac{u_i}{P_i}\right) - \ln\left(1 - \frac{u_i}{Q_i}\right); i = 1, 2, \dots, M$$

¹ P_i คือ Probability ที่จะได้ Setting ที่ i ของ X 's และ $\frac{P_i}{1-P_i}$ เรียกว่า Observed Odd ของ Setting ที่ i ของ X 's หรือ Observed Logit ขณะที่ $1-P_i$ เรียกว่า True Odd หรือ True Logit

สำหรับ Logistic Distribution มี CDF และคุณลักษณะต่าง ๆ ดังนี้

$$1. F(x) = [1+e^{-(x-\alpha)/\beta}]^{-1}; -\infty < \alpha < \infty, \beta > 0 \text{ ขอให้สังเกต Parameter Space}$$

ของ α และ β จะเห็นว่ามีลักษณะเดียวกับ μ และ σ^2 ของ $N(\mu, \sigma^2)$

$$2. E(X) = \alpha$$

$$3. V(X) = \frac{\beta^2 \pi^2}{3}$$

$$4. M_x(t) = e^{\alpha t} \pi \beta t \operatorname{Cosec}(\pi \beta t)$$

ถ้าให้ $\alpha = 0, \beta = 1$ จะพบว่า

$$F(x) = [1+e^{-x}]^{-1}, E(X) = 0, V(X) = 3.29, M_x(t) = \pi t \operatorname{Cosec}(\pi t)$$

ขอให้สังเกตว่าในกรณีนี้ Logistic Distribution จะมีชาร์มชาติใกล้เคียง $N(0, 1)$ มาก

โดยอาศัย Taylor's Series กระจายรอบ $a = 0$ เราพบว่า

$$\ln(1+x) = x - \frac{x^2}{2} + \frac{x^3}{3} - \frac{x^4}{4} + \dots$$

$$\ln(1-x) = -x - \frac{x^2}{2} - \frac{x^3}{3} - \frac{x^4}{4} + \dots$$

$$\ln\left(\frac{p_i}{1-p_i}\right) = \ln\left(\frac{p_i}{1-p_i}\right) + \frac{u_1}{p_i} + R_{1i} - \left(-\frac{u_i}{Q_i} + R_{2i}\right); i = 1, 2, \dots, M$$

เมื่อ R_{1i} และ R_{2i} คือ Remainder ของ $\ln(1+\frac{1}{P_i})$ และ $\ln(1-\frac{1}{Q_i})$ ตามลำดับ

นั่นคือ

$$\ln\left(\frac{p_i}{1-p_i}\right) = \ln\left(\frac{p_i}{1-p_i}\right) + \frac{u_i}{p_i} + \frac{u_i}{Q_i} + R_i; i = 1, 2, \dots, M$$

$$= \ln\left(\frac{p_i}{1-p_i}\right) + \frac{u_i(p_i+Q_i)}{p_i Q_i} + R_i; i = 1, 2, \dots, M$$

$$\text{นั่นคือ } \ln\left(\frac{p_i}{1-p_i}\right) = \ln\left(\frac{p_i}{1-p_i}\right) + \frac{u_i}{p_i Q_i} + R_i; i = 1, 2, \dots, M \quad \dots \quad (2)$$

จากสมการที่ 1 เราทราบว่า

$$p_i = \frac{1}{1+\exp[-(\beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki})]}$$

และ

$$1 - p_i = \frac{\exp[-(\beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki})]}{1+\exp[-(\beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki})]}$$

$$\text{ดังนั้น } \frac{p_i}{1-p_i} = \frac{1}{\exp[-(\beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki})]}; i = 1, 2, \dots, M$$

$$\text{และ } \ln\left(\frac{p_i}{1-p_i}\right) = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} \quad \dots \quad (3)$$

แทนที่สมการ 3 ในสมการที่ 2 จะพบว่าสมการถูกอยู่ที่แปลงรูปแล้วคือ

$$\ln\left(\frac{p_i}{1-p_i}\right) = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \frac{u_i}{p_i Q_i} + R_i; i = 1, 2, \dots, M \quad \dots \quad (4)$$

พิจารณาสมการที่ 4 จะพบว่า

$$E\left(\frac{u_i}{P_i Q_i}\right) = 0 \text{ และ } V\left(\frac{u_i}{P_i Q_i}\right) = \frac{1}{P_i^2 Q_i^2} \cdot \frac{P_i Q_i}{n_i} = \frac{1}{n_i P_i Q_i} \text{ ดังนั้น}$$

$$V(U) = \phi = \begin{bmatrix} 1/n_1 P_1 Q_1 & & \\ & 1/n_2 P_2 Q_2 & \\ & & \ddots \\ & & 1/n_M P_M Q_M \end{bmatrix}_{M \times M}$$

$$\text{และ } \hat{V}(U) = \hat{\phi} = \begin{bmatrix} 1/n_1 P_1 Q_1 & & \\ & 1/n_2 P_2 Q_2 & \\ & & \ddots \\ & & 1/n_M P_M Q_M \end{bmatrix}_{M \times M}$$

ดังนั้นโดยอาศัย EGLS เราสามารถประมาณค่าเวคเตอร์ β ได้ดังนี้คือ

$$\hat{\beta} = (X' \hat{\phi}^{-1} X)^{-1} X' \hat{\phi} I^0, \quad \hat{V}(\hat{\beta}) \approx (X' \hat{\phi}^{-1} X)^{-1}$$

โดยที่ I^0 คือเวคเตอร์ของ Observed Logit กล่าวคือ $I^0 = [\ln \frac{p_1}{1-p_1}, \ln \frac{p_2}{1-p_2}, \dots, \ln \frac{p_M}{1-p_M}]'$

สมการประมาณค่าของทั้ง Normit Model และ Logit Model คือ

$$I_i = \hat{\beta}_1 + \hat{\beta}_2 x_{2i} + \dots + \hat{\beta}_k x_{ki}$$

แต่สิ่งที่เราต้องการพยากรณ์คือ p_i มิใช่ I_i ดังนั้น เมื่อแทนค่าในอนาคตของ X 's ลงในสมการประมาณค่าซึ่งจะทำให้ได้ค่า \hat{I}_i ให้แปลงค่า \hat{I}_i ที่ \hat{p}_i ดังนี้

$$\hat{p}_i = F(I_i)$$

นั่นคือ

$$\hat{p}_i = \begin{cases} F(\hat{I}_i) = \Pr(Z < \hat{I}_i) & \text{สำหรับ Normit Model} \\ F(\hat{I}_i) = 1/[1+e^{-\hat{I}_i}] & \text{สำหรับ Logit Model} \end{cases}$$

จากนั้นให้ย้อนค่า \hat{p}_i ที่ \hat{Y}_i ดังนี้¹

$$\text{Normit Model : } \hat{Y}_i = \begin{cases} 1 \text{ ถ้า } \hat{p}_i = \Pr(Z \leq \hat{I}_i) \\ 0 \text{ ถ้า } \hat{p}_i = \Pr(Z > \hat{I}_i) \end{cases}$$

$$\text{Logit Model : } \hat{Y}_i = \begin{cases} 1 \text{ ถ้า } \hat{p}_i = 1/[1+e^{-\hat{I}_i}] \\ 0 \text{ ถ้า } \hat{p}_i = 1 - 1/[1+e^{-\hat{I}_i}] \end{cases}$$

¹ Zellner, A and Lee, T.H., Ibid., p.384