

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

แนวคิดและทฤษฎี

การวิจัยครั้งนี้ได้เสนอวิธีการประมาณพารามิเตอร์แบบ Quasi-Likelihood ของตัวแบบ Generalized Linear Model และ ตัวแบบ Generalized Estimating Equations สำหรับข้อมูลระยะยาว เมื่อกำหนดให้ตัวแปรตามมีการแจกแจงปัวซองส์ ในบทนี้จะกล่าวถึงคุณสมบัติของตัวแบบและรายละเอียดของวิธีการประมาณค่าพารามิเตอร์เป็นลำดับต่อไป

2.1 ตัวแบบ Generalized Estimating Equations (GEE)

ตัวแบบ Generalized Estimating Equations (GEE) เป็นตัวแบบที่ถูกพัฒนาโดย Liang และ Zeger (1986) เพื่อใช้ในการวิเคราะห์การลดถอยซึ่งคำนึงถึงสหสัมพันธ์ภายในตัวเองของตัวแปรตามในการวิจัยข้อมูลระยะยาว ซึ่งตัวแบบ Generalized Estimating Equations (GEE) หมายความว่า สำหรับวิเคราะห์ข้อมูลระยะยาว หรือ ข้อมูลที่มีการวัดซ้ำ โดยวิธีการนี้ได้พัฒนาจาก Generalized Linear Model ซึ่งเป็นการลดความซับซ้อนในการวิเคราะห์การลดถอยในกรณีที่ตัวแปรตามไม่มีการแจกแจงปกติ และตัวแปรตามมีความสัมพันธ์ในตัวเองในการศึกษานี้ตัวแปรตามมีการแจกแจงแบบปัวซองส์ โดยจะสมมติให้ $y_{i(t)}$ คือ ค่าสังเกตของหน่วยศึกษาที่ i ระยะเวลาที่ t สามารถเขียนตัวแบบ Generalized Estimating Equations สำหรับการวิเคราะห์ Marginal Model คือ

$$\log_e(Y_{i(t)}) = \beta_0 + \beta_1 t + \beta_{2j} \sum_{j=1}^J x_{ijt} + \text{corr} + e_{i(t)} ;$$

$i = 1, 2, \dots, n$ $j = 1, 2, \dots, J$ $t = 1, 2, \dots, T$

$Y_{i(t)}$ คือ ตัวแปรตามของหน่วยศึกษาที่ i ระยะเวลาที่ t

x_{ijt} คือ ตัวแปรอิสระที่ j ของหน่วยศึกษาที่ i ระยะเวลาที่ t ที่ขึ้นกับเวลา

T คือ ระยะเวลาที่เก็บข้อมูลซ้ำ

corr คือ อัตราสัมพันธ์ของตัวแปรตาม

n คือ ขนาดตัวอย่าง

J คือ จำนวนตัวแปรอิสระที่ขึ้นกับเวลา

$e_{i(t)}$ คือ ความคลาดเคลื่อนของหน่วยที่ i ระยะเวลาที่ t

$\beta_0, \beta_1, \beta_{2j}$ คือ พารามิเตอร์ที่ไม่ทราบค่า (Unknown Parameter)

โดยค่าเฉลี่ยของตัวแปรตาม (μ_{it}) จะมีความสัมพันธ์กับตัวทำนายเชิงเส้นผ่านพังก์ชันเชื่อม (Link Function) คือ $\eta_{it} = x'_{it}\beta$ ดังนั้น $g(\mu_{it}) = \log_e(\mu_{it}) = \eta_{it} = x'_{it}\beta$ สามารถเขียนในรูปแบบเมทริกซ์ได้ดังนี้ $G(Y) = X\beta$

$$X = \begin{bmatrix} 1 & x_{111} & x_{122} & \cdots & x_{1jt} \\ 1 & x_{211} & x_{222} & \cdots & x_{2jt} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n11} & \cdots & \cdots & x_{ijt} \end{bmatrix}$$

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_{21} \\ \vdots \\ \beta_{2j} \end{bmatrix}_{(j+2) \times 1}$$

เมื่อ $j+2$ คือ จำนวนของพารามิเตอร์, i คือ ขนาดตัวอย่าง, j คือ จำนวนของตัวแปรอิสระ และ t คือ ระยะเวลาที่เก็บข้อมูลซ้ำ

เมื่อ $Var(Y_{it}) = \phi Var(\mu_{it})$ เมื่อ $Var(\mu_{it}) = \mu_{it}$, $\phi = 1$ จะได้ว่า

$$Var(Y_{it}) = Var(\mu_{it})$$

2.1.1 อัตตสัมพันธ์ของตัวแปรตาม (Working Correlation)

อัตตสัมพันธ์ของค่าสังเกตของหน่วยศึกษา (y) จะสมมติให้อยู่ในรูปแบบของ Exchangeable

Exchangeable เป็นความสัมพันธ์ของค่าสังเกตภายในหน่วยศึกษาเดียวกันจะมีค่าเท่ากัน ณ ช่วงเวลาที่ต่างกัน ซึ่งความสัมพันธ์จะอยู่ในรูปของ $Corr(y_{it}, y_{im}) = \rho ; t \neq m$ สามารถเขียนใน

รูปเมทริกซ์ คือ

$$\begin{pmatrix} 1 & \rho & \rho \dots & \rho \\ \rho & 1 & \rho \dots & \rho \\ \rho & \rho & 1 \dots & \rho \\ \vdots & \vdots & \vdots & \ddots \vdots \\ \rho & \rho & \rho \dots & 1 \end{pmatrix}$$

2.2 ตัวแบบ Generalized Linear Model (GLM)

ในการศึกษาตัวแบบ Generalized Linear Model นี้ จะใช้ ตัวแบบ Poisson Regression ซึ่งตัวแบบมีการแจกแจงแบบบัวชงส์ โดยการแจกแจงแบบบัวชงส์นั้นเป็นการแจกแจงบัวชงส์เป็นการแจกแจงที่เกิดขึ้นในตัวแปรสุ่มของการทดลองหรือว่าเหตุการณ์ที่เกิดขึ้นในช่วงระยะเวลาใดเวลาหนึ่งที่ต้องเนื่องกัน โดยหนึ่งหน่วยนั้นอาจจะเป็น วินาที นาที ชั่วโมง วัน สัปดาห์ เดือน หรือ ปี อาจจะเป็นความยาว พื้นที่ ปริมาตร โดยข้อมูลที่ได้จากตัวแปรสุ่มนี้เป็นแบบไม่ต่อเนื่องกันชนิดหนึ่ง สามารถเขียนตัวแบบ ได้ดังนี้

$$\log_e(Y_{i(t)}) = \beta_0 + \beta_1 t + \sum_{j=1}^J \beta_{2j} x_{ijt} + \varepsilon_{i(t)} ;$$

$$i = 1, 2, \dots, n \quad j = 1, 2, \dots, J$$

$$t = 1, 2, \dots, T$$

$Y_{i(t)}$ คือ ตัวแปรตามของหน่วยศึกษาที่ i ระยะเวลาที่ t

x_{ijt} คือ ตัวแปรอิสระที่ j ของหน่วยศึกษาที่ i ระยะเวลาที่ t ที่ขึ้นกับเวลา

T คือ ระยะเวลาที่เก็บข้อมูลสำหรับ

n คือ ขนาดตัวอย่าง

J คือ จำนวนตัวแปรอิสระที่ขึ้นกับเวลา

$\varepsilon_{i(t)}$ คือ ความคลาดเคลื่อนของหน่วยที่ i ระยะเวลาที่ t

$\beta_0, \beta_1, \beta_{2j}$ คือ พารามิเตอร์ที่ไม่ทราบค่า (Unknown Parameter)

โดยมีค่าเฉลี่ยของตัวแปรตาม คือ $E(Y_{it}) = \exp(x'_{ijt} \beta)$ ดังนั้น

$\log E(Y_{it}) = x'_{ijt} \beta$ และความแปรปรวนของตัวแปรตาม คือ $Var(Y_{it}) = \mu_{it}$ จะได้ว่า

$$g(\mu_{it}) = x'_{ijt} \beta$$

2.2.1 โครงสร้างความแปรปรวนร่วมของตัวแปรตาม

ในการศึกษานี้เป็นข้อมูลวัดซ้ำจะสมมติให้โครงสร้างความแปรปรวนร่วมให้อยู่ในรูปแบบของ Exchangeable

Exchangeable ความแปรปรวนร่วมระหว่างค่าสังเกต (σ_1) จะเท่ากันสำหรับบุคคลเดียวกัน สามารถเขียนในรูปเมทริกซ์ คือ

$$V_i = Var(y_{it}) = \begin{pmatrix} \sigma^2 & \sigma_1 & \sigma_1 & \dots & \sigma_1 \\ \sigma_1 & \sigma^2 & \sigma_1 & \dots & \sigma_1 \\ \sigma_1 & \sigma_1 & \sigma^2 & \dots & \sigma_1 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \sigma_1 & \sigma_1 & \sigma_1 & \dots & \sigma^2 \end{pmatrix}$$

2.3. Quasi – Likelihood

วิธี Quasi – Likelihood ถูกพัฒนาจาก Wedderburn (1974) เป็นวิธีที่มีคุณสมบัติเหมือนกับวิธี Maximum Likelihood แต่ Full Likelihood ไม่ต้องการเจาะจง เป็นวิธีการประมาณพารามิเตอร์ที่ใช้สำหรับการแจกแจงที่มีสมมติฐานอ่อน โดยเจาะจงเพียงรูปแบบของ Linear Parameter (β) และ Variance Function ($V(\mu)$) โดยการประมาณนี้จะใช้ได้กับทั้งสองรูปแบบ

2.3.1 โครงสร้างของ Quasi - Likelihood

พิจารณาส่วนประกอบเดียวของตัวแปรตัวสนอง Y โดยไม่มี subscript ภายใต้เงื่อนไขดังนี้

$$U = u(\mu | Y) = \frac{Y - \mu}{\sigma^2 V(\mu)}$$

ตามมาด้วยคุณสมบัติพื้นฐานที่ได้มาจาก log-likelihood

$$\begin{aligned} E(U) &= 0, \\ \text{var}(U) &= 1/\{\sigma^2 V(\mu)\}, \\ -E\left(\frac{\partial U}{\partial \mu}\right) &= 1/\{\sigma^2 V(\mu)\} \end{aligned}$$

โดยที่ Quasi – Likelihood Function หาได้จาก

$$Q(\mu; y) = \int_y^\mu u(y|t) dt = \int_y^\mu \frac{y-t}{\sigma^2 V(t)} dt \quad \text{ซึ่งมีลักษณะเหมือนฟังก์ชัน log-likelihood}$$

Quasi – likelihood สำหรับข้อมูลที่สมบูรณ์เป็นผลรวมของแต่ละ $Q_i(\mu_i; y_i)$ คือ

$$Q(\mu; y) = \sum Q_i(\mu_i; y_i) \quad \text{ให้ฟังก์ชัน quasi – deviance สำหรับค่าสังเกตเดียว คือ}$$

$$D(\mu; y) = 2\sigma^2 Q(\mu; y) = 2 \int_y^\mu \frac{y-t}{V(t)} dt \quad \text{ที่เป็นอย่างถูกต้องที่เชื่อถือได้ ยกเว้น } y = \mu \text{ ผลรวม}$$

ของ deviance $D(\mu; y)$ หากมาได้จากการผลรวมของแต่ละส่วนประกอบ คือ คำนวณจากฟังก์ชันที่ขึ้นอยู่กับ y และ μ แต่ไม่ขึ้นอยู่กับ σ^2

2.3.2 การประมาณพารามิเตอร์

Quasi - Likelihood Estimating Equation สำหรับพารามิเตอร์ (β) สามารถหาได้จาก $Q(\mu; y)$ อาจจะเขียนอยู่ในรูปของ $U(\beta) = 0$ ซึ่งจะได้

$$U(\beta) = \sum D^T V^{-1} (Y - \mu) = 0$$

ซึ่งเรียกว่า quasi - score function โดยที่

$$D_i = \frac{\partial \mu_{it}}{\partial \beta_t}$$

$$V_i = (A_i^{1/2} R_i A_i^{1/2})\phi$$

$$\phi = \frac{1}{n-p} \sum_i \sum_t \frac{y_{it} - \mu_{it}}{\sqrt{\text{var}(\mu_{it})}}$$

เมื่อ V_i คือ เมทริกซ์โครงสร้างความแปรปรวนร่วมของ Y_{it}

A_i คือ diagonal matrix ความแปรปรวนของ Y_{it} โดยเขียนให้อยู่ในรูปเมทริกซ์

$$\text{ได้ดังนี้ } \begin{bmatrix} \mu_{1t} & 0 & \cdots & 0 \\ 0 & \mu_{2t} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \mu_{nt} \end{bmatrix}$$

R_i คือ เมทริกซ์อัตตัลส์พันธ์ของ Y_{it} โดยเขียนให้อยู่ในรูปเมทริกซ์

$$\text{ได้ดังนี้ } \begin{pmatrix} 1 & \rho & \rho \dots & \rho \\ \rho & 1 & \rho \dots & \rho \\ \rho & \rho & 1 \dots & \rho \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho & \rho & \rho \dots & 1 \end{pmatrix}$$

เนื่องจากในงานวิจัยนี้สนใจศึกษาอัตตัลส์พันธ์แบบ Exchangeable

ϕ คือ overdispersion parameter = 1