

## บทที่ 2

### ทฤษฎีและสถิติที่เกี่ยวข้อง

การศึกษาเปรียบเทียบวิธีการคัดเลือกสมการถดถอยที่ดีที่สุดภายใต้แนวทางของเบส์ในการวิจัยครั้งนี้เป็นการพิจารณาหาวิธีการคัดเลือกสมการถดถอยที่ให้ค่าพยากรณ์ถูกต้องและแม่นยำมากที่สุด โดยวิธีการคัดเลือกสมการถดถอยที่นำมาศึกษามีดังนี้

- 1) วิธีการคัดเลือกตัวแบบที่ดีที่สุด โดยใช้เกณฑ์ข้อสนเทศของเบส์ (Bayes Information Criterion Method (BIC)) ซึ่งวิธีการนี้จะคำนวณค่า BIC สำหรับทุกตัวแบบที่เป็นไปได้แล้วนำมาเปรียบเทียบกัน ตัวแบบใดที่มีค่า BIC ต่ำสุดจะเป็นตัวแบบที่ดีที่สุด
- 2) วิธีการคัดเลือกตัวแปรของเบส์ (Bayesian Variable Selection Method (BVS)) เป็นวิธีการคัดเลือกตัวแปรโดยใช้หลักการค้นหาด้วยความน่าจะเป็น (Stochastic Search Variable Selection (SSVS)) ซึ่งใช้วิธีการสุ่มแบบกิบส์ (Gibbs Sampling)
- 3) วิธีการเฉลี่ยตัวแบบของเบส์ (Bayesian Model Averaging Method (BMA)) เป็นการนำตัวแบบต่าง ๆ ที่เป็นไปได้มาเฉลี่ยกันโดยใช้หลักการของเบส์ ซึ่งในการวิจัยครั้งนี้จะทำการศึกษาวิธีการเฉลี่ยตัวแบบของเบส์ภายใต้ 2 แนวทาง คือ
  - 3.1) วิธีการเฉลี่ยตัวแบบของเบส์โดยใช้การค้นหาปริภูมิตัวแบบด้วยวิธีออกัสแคมวินโดว์ (Occam 's Windows) ( $BMA_{occ}$ )
  - 3.2) วิธีการเฉลี่ยตัวแบบของเบส์ โดยการหาลำดับประกอบของตัวแบบด้วยเทคนิคมอนติคาร์โลโดยใช้ลูกโซ่มาร์คอฟ (Markov Chain Monte Carlo Model Composition ( $MC^3$ )) ( $BMA_{MC^3}$ )
- 4) วิธีการถดถอยแบบขั้นบันได (Stepwise Regression Method (SR))

เนื่องจากวิธีการเฉลี่ยตัวแบบของเบส์นั้นผู้วิจัยได้ทำการศึกษาภายใต้ 2 แนวทางดังกล่าวข้างต้น ดังนั้นวิธีการคัดเลือกสมการถดถอยที่นำมาศึกษาในการวิจัยครั้งนี้จะประกอบด้วย 5 วิธี คือ วิธี BIC BVS  $BMA_{occ}$   $BMA_{MC^3}$  และ SR

การนำเสนอแนวคิดและทฤษฎีในบทนี้จะประกอบด้วยแนวคิดและทฤษฎีเกี่ยวกับการวิเคราะห์ความถดถอยเชิงเส้นพหุคูณ ความน่าจะเป็นที่มีเงื่อนไข ความเป็นอิสระ ทฤษฎีของเบส์ และทฤษฎีของวิธีการคัดเลือกสมการถดถอยทั้ง 5 วิธีข้างต้น โดยมีรายละเอียดดังนี้

## 2.1 การวิเคราะห์ความถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression Analysis)

ตัวแบบและข้อตกลงเบื้องต้นที่ใช้ในการวิจัยครั้งนี้ คือ ตัวแบบความถดถอยเชิงเส้นพหุคูณซึ่งมีรูปแบบทั่วไปดังนี้

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \varepsilon_i \quad ; \quad i = 1, 2, \dots, n$$

เมื่อ  $\beta_j$  เป็นสัมประสิทธิ์การถดถอยที่  $j$  ;  $j = 1, 2, \dots, p$

ข้อตกลงเบื้องต้นของการวิเคราะห์ความถดถอยเชิงเส้นพหุคูณมีดังนี้

- 1)  $\varepsilon_i$  มีการแจกแจงแบบปกติที่มีค่าเฉลี่ยเป็น 0 และค่าความแปรปรวนเป็น  $\sigma^2$  คือ  $\varepsilon_i$  จ.ม.อ.(i.i.d)  $N(0, \sigma^2)$  กล่าวคือ  $\varepsilon_i$  และ  $\varepsilon_j$  สำหรับ  $i \neq j$  มีการแจกแจงที่เหมือนกันและเป็นอิสระกัน ซึ่งจะทำให้  $Cov(\varepsilon_i, \varepsilon_j) = 0$  สำหรับ  $i \neq j$
- 2) รูปแบบการถดถอยเป็นแบบเชิงเส้นตรงของพารามิเตอร์ ( $\beta_j$ )
- 3) ตัวแปรอิสระแต่ละตัวเป็นค่าคงที่ และไม่มีพหุสัมพันธ์กัน

เนื่องจากตัวแบบการถดถอยที่ใช้ในการพิจารณาเป็นตัวแบบเชิงเส้น ดังนั้นในการประมาณค่าพารามิเตอร์เราสามารถใช่วิธีกำลังสองน้อยสุด และวิธีความควรจะเป็นสูงสุด เพื่อประมาณค่าเวกเตอร์พารามิเตอร์สัมประสิทธิ์การถดถอย  $\beta$  ของตัวแบบความถดถอยเชิงเส้นพหุคูณซึ่งมีรูปแบบตัวประมาณสำหรับแต่ละวิธีดังนี้

ตัวประมาณค่ากำลังสองน้อยสุด (Least Square Estimator :  $\hat{\beta}$ ) คือ

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

เป็นตัวประมาณที่ใช้สำหรับวิธี BVS วิธี BMA<sub>MC3</sub> และวิธี SR

ตัวประมาณค่าความควรจะเป็นสูงสุด (Maximum Likelihood Estimator :  $\hat{\beta}_{ML}$ ) คือ

$$\hat{\beta}_{ML} = (X'X)^{-1} X'y$$

เป็นตัวประมาณที่ใช้สำหรับวิธี BIC และวิธี BMA<sub>occ</sub>

## 2.2 ความน่าจะเป็นที่มีเงื่อนไข (Conditional Probability)<sup>1</sup>

ความน่าจะเป็นที่มีเงื่อนไขเป็นการศึกษาความน่าจะเป็นเมื่อทราบข้อมูลเพิ่มเติมเกี่ยวกับเหตุการณ์ที่สนใจศึกษา

### นิยามที่ 1

ให้  $A$  และ  $B$  เป็นเหตุการณ์ซึ่ง  $P(A) > 0$  เราเรียก  $P(B | A)$  ว่าเป็น “ความน่าจะเป็นที่มีเงื่อนไขของ  $B$  เมื่อกำหนด  $A$  (the conditional probability of  $B$  given  $A$ )” ถ้า

$$P(B | A) = \frac{P(B \cap A)}{P(A)} \quad , \quad P(A) > 0$$

### ทฤษฎีบทที่ 1 ทฤษฎีการคูณ (Multiplication Theorem)

ถ้าในการทดลองชนิดหนึ่งเหตุการณ์  $A$  และ  $B$  สามารถเกิดขึ้นได้พร้อมกัน จะได้ว่า

$$P(B \cap A) = P(B | A) \cdot P(A)$$

### ทฤษฎีบทที่ 2

ถ้าในการทดลองชนิดหนึ่งซึ่งเหตุการณ์  $A_1, A_2, \dots, A_n$  สามารถเกิดขึ้นพร้อมกันได้ จะได้ว่า

$$P(A_1 \cap A_2 \cap \dots \cap A_n) = P(A_1) \cdot P(A_2 | A_1) \cdot P(A_3 | A_1, A_2) \cdot \dots \cdot P(A_n | A_1, A_2, \dots, A_{n-1})$$

---

<sup>1</sup>ธีระพร วีระถาวร, ความน่าจะเป็นกับการประยุกต์, พิมพ์ครั้งที่ 2 (กรุงเทพมหานคร : วิทยพัฒน์ ,2539), หน้า 100-106.

## 2.3 ทฤษฎีบทของเบส์ (Bayes' Theorem) <sup>1</sup>

### นิยามที่ 2

เหตุการณ์  $B_1, B_2, \dots$  จะแทนผลแบ่งกันของปริภูมิตัวอย่าง  $S$  ถ้า

$$1) B_i \cap B_j = \phi, \quad \forall i \neq j$$

$$2) \bigcup_{i=1}^{\infty} B_i = S$$

$$3) P(B_i) > 0, \quad \forall i$$

กล่าวคือเมื่อเราทำการทดลอง  $E$  จะได้ว่าเหตุการณ์  $B_i, i = 1, 2, \dots, n$  จะไม่เกิดขึ้นพร้อม ๆ กัน

### ทฤษฎีบทที่ 3

ให้  $B_1, B_2, \dots$  แทนผลแบ่งกันของปริภูมิตัวอย่าง  $S$  และถ้า  $A$  เป็นเหตุการณ์ซึ่ง  $P(A) > 0$  จะได้ว่า

$$P(B_k | A) = \frac{P(B_k)P(A|B_k)}{\sum_{i=1}^{\infty} P(B_i) \cdot P(A|B_i)}, \quad \forall k = 1, 2, 3, \dots$$

## 2.4 ความเป็นอิสระ (Independence) <sup>2</sup>

### นิยามที่ 3

เหตุการณ์ 2 เหตุการณ์  $A$  และ  $B$  เรียกว่า "เป็นอิสระต่อกัน (independence)" ก็ต่อเมื่อ

$$P(B|A) = P(B) \quad \text{และ} \quad P(A|B) = P(A) \quad \text{กล่าวคือ}$$

$$P(A \cap B) = P(A) \cdot P(B)$$

<sup>1</sup>ธีระพร วีระถาวร, ความน่าจะเป็นกับการประยุกต์, พิมพ์ครั้งที่ 2 (กรุงเทพมหานคร : วิทยพัฒน์, 2539), หน้า 107-108.

<sup>2</sup>ธีระพร วีระถาวร, ความน่าจะเป็นกับการประยุกต์, พิมพ์ครั้งที่ 2 (กรุงเทพมหานคร : วิทยพัฒน์, 2539), หน้า 114-116.

#### นิยามที่ 4

เหตุการณ์ 3 เหตุการณ์  $A$ ,  $B$  และ  $C$  เป็นอิสระซึ่งกันและกัน (mutually independent) ก็ต่อเมื่อ

1) แต่ละคู่ของเหตุการณ์เป็นอิสระต่อกัน (pairwise independent) กล่าวคือ

$$P(A \cap B) = P(A) \cdot P(B)$$

$$P(A \cap C) = P(A) \cdot P(C)$$

$$P(B \cap C) = P(B) \cdot P(C)$$

2) เหตุการณ์หนึ่งเหตุการณ์ใดเป็นอิสระจากสองเหตุการณ์ใด ๆ กล่าวคือ

$$P(A \cap B \cap C) = P(A) \cdot P(B) \cdot P(C)$$

## 2.5 วิธีการคัดเลือกตัวแบบที่ดีที่สุดโดยใช้เกณฑ์ข้อสนเทศของเบส์ (Bayes Information Criterion Method (BIC))

ในปี ค.ศ.1978 ชวาร์ซ (Schwarz) ได้เสนอเกณฑ์ที่ใช้ในการคัดเลือกตัวแบบ เพื่อใช้เป็นเครื่องมือในการหาตัวแบบที่ให้ค่าพยากรณ์ถูกต้องและแม่นยำมากที่สุด นั่นคือ วิธีการคัดเลือกตัวแบบที่ดีที่สุดโดยใช้เกณฑ์ข้อสนเทศของเบส์ (Bayes Information Criterion Method (BIC)) ซึ่งเป็นวิธีพื้นฐานในการหาเกณฑ์การคัดเลือกตัวแบบภายใต้แนวทางของเบส์ โดยเป็นการอนุมานด้วยความน่าจะเป็นภายหลัง (posterior probability) ซึ่งเกิดจากความน่าจะเป็นก่อน (prior probability) ร่วมกับฟังก์ชันความควรจะเป็น (likelihood function) สำหรับข้อกำหนดเบื้องต้นคือตัวประมาณได้มาจากการประมาณค่าด้วยวิธีการความควรจะเป็นสูงสุด และการแจกแจงก่อน (prior distribution) เป็นการแจกแจงแบบสมมาตร

เกณฑ์การคัดเลือกตัวแบบโดยใช้เกณฑ์ข้อสนเทศของเบส์ (Bayes Information Criterion Method (BIC)) คือ

$$BIC = -2 \sum_{i=1}^n \ln f(x_i | \hat{\beta}_{ML}) + p \ln(n) \quad \text{หรือ}$$

$$(2.1) \quad BIC_k = -2 \ln(ML_k) + p_k \ln(n)$$

เมื่อ  $ML_k$  เป็นฟังก์ชันความควรจะเป็นสูงสุด (maximum likelihood function) ของตัวแบบที่  $k$

$p_k$  เป็นจำนวนพารามิเตอร์ของตัวแบบที่  $k$

และ  $n$  เป็นขนาดตัวอย่าง

ซึ่งตัวแบบที่ให้ค่า BIC ต่ำสุด จะเป็นตัวแบบที่ให้ค่าพยากรณ์ถูกต้องและแม่นยำมากที่สุด

ในการวิจัยครั้งนี้พิจารณาเฉพาะกรณีที่ความคลาดเคลื่อนสุ่มมีการแจกแจงแบบปกติ ดังนั้นฟังก์ชันความควรจะเป็นสำหรับตัวแบบที่มีรูปแบบดังสมการ (1.1) จะเป็นดังนี้

$$\begin{aligned} ML_k &= L(\underline{\beta}_{ML}, \sigma^2; y) \\ &= f(y | \underline{\beta}_{ML}, \sigma^2 \mathbf{I}_n) \\ &= (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2}(y - X\underline{\beta}_{ML})'(y - X\underline{\beta}_{ML})\right\} \end{aligned}$$

$$\begin{aligned} \therefore \ln ML_k &= \frac{-n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2}(y - X\underline{\beta}_{ML})'(y - X\underline{\beta}_{ML}) \\ &= \frac{-n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2}(y - X\underline{\beta}_{ML})'(y - X\underline{\beta}_{ML}) \\ &= \frac{-n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) - \frac{n}{2} \\ &= \frac{-n}{2} (\ln(2\pi) + 1) - \frac{n}{2} \ln(\hat{\sigma}^2) \end{aligned}$$

เมื่อ  $\hat{\underline{\beta}}_{ML} = (X'X)^{-1} X'y$

และ  $\hat{\sigma}^2 = \frac{1}{n} (y - X\hat{\underline{\beta}}_{ML})' (y - X\hat{\underline{\beta}}_{ML})$

ดังนั้น BIC สำหรับการแจกแจงแบบปกติ คือ

$$\begin{aligned} BIC &= -2 \ln L(\hat{\underline{\beta}}_{ML}, \hat{\sigma}^2; y) + p \ln(n) \\ &= -2 \left( -\frac{n}{2} (\ln(2\pi) + 1) - \frac{n}{2} \ln(\hat{\sigma}^2) \right) + p \ln(n) \\ &= n(\ln(2\pi) + 1) + n \ln(\hat{\sigma}^2) + p \ln(n) \end{aligned}$$

## 2.6 วิธีการคัดเลือกตัวแปรของเบส์ (Bayesian Variable Selection Method (BVS))

ในปี ค.ศ.1993 จอร์จ (George) และ แมคคัลลอค (McCulloch) ได้เสนอวิธีการคัดเลือกตัวแปรของเบส์ (Bayesian Variable Selection Method (BVS)) สำหรับตัวแบบการถดถอยเชิงเส้นพหุคูณ โดยใช้หลักการคัดเลือกตัวแปรโดยการค้นหาด้วยความน่าจะเป็น (Stochastic

Search Variable Selection (SSVS)) ซึ่งใช้วิธีการสุ่มแบบกิบส์ (Gibbs Sampling) วิธีการนี้จะมีการกำหนดความน่าจะเป็นให้กับตัวแบบโดยใช้หลักการคัดเลือกตัวแปรเพื่อกำหนดตัวแบบที่เหมาะสมกับข้อมูล เมื่อทราบการแจกแจงความน่าจะเป็นของพารามิเตอร์ในตัวแบบ และนอกจากนั้นในปี ค.ศ.1996 จอร์จ (George) และ แมคคัลลอค (McCulloch) ยังได้มีการนำเสนอแนวคิดวิธีการคัดเลือกตัวแปรของเบส์สำหรับตัวแบบเชิงเส้นนัยทั่วไป (generalized linear models) ซึ่งยังคงใช้หลักการเดิมอีกด้วย

การนำเสนอแนวคิดและทฤษฎีของวิธีการคัดเลือกตัวแปรของเบส์จำเป็นต้องกล่าวถึงการแจกแจงความน่าจะเป็นก่อน (prior probability) การแจกแจงความน่าจะเป็นภายหลัง (posterior probability) และการคัดเลือกตัวแปรโดยการค้นหาด้วยความน่าจะเป็น ก่อนที่จะกล่าวถึงขั้นตอนของวิธีการคัดเลือกตัวแปรของเบส์ โดยมีรายละเอียดดังนี้

### 2.6.1 การแจกแจงความน่าจะเป็นก่อน (Prior Probability Distribution)

จากตัวแบบการถดถอยในสมการ (1.1) กำหนดให้  $\delta_i$  เป็นเวกเตอร์ที่ไม่ทราบค่าขนาด  $k \times 1$  มีสมาชิกเป็น 0 และ 1 โดยที่สมาชิกใน  $\delta_i$  จะสอดคล้องกับตัวแปรอิสระในสมการถดถอยในตำแหน่งที่ตรงกันดังนี้

$$(2.2) \quad \delta_i = \begin{cases} 0 & \cdot \beta_i \text{ มีอิทธิพลน้อย แสดงว่าตัวแปรอิสระนี้ไม่อยู่ในตัวแบบ} \\ 1 & \cdot \beta_i \text{ มีอิทธิพลมาก แสดงว่าตัวแปรอิสระนี้อยู่ในตัวแบบ} \end{cases}$$

จะได้ว่า  $\delta_i \sim \text{Ber}(p_i) \quad ; i = 1, 2, \dots, k$

ถ้าการแจกแจงความน่าจะเป็นก่อนเป็นอิสระกัน จะได้ว่าฟังก์ชันความหนาแน่นร่วมของ  $\delta_i$  คือ

$$(2.3) \quad f(\delta) = \prod_{i=1}^k p_i^{\delta_i} (1 - p_i)^{1 - \delta_i}$$

เมื่อ  $p_i = P(\delta_i = 1) = 1 - P(\delta_i = 0)$

ในตัวแบบการถดถอยเชิงเส้นพหุคูณ เราจะกำหนดการแจกแจงความน่าจะเป็นก่อนแบบผสม (mixture prior probability distribution) ของ  $\beta_i$  ได้ดังนี้

$$f(\beta_i | \delta_i) \sim \begin{cases} N(0, \tau_i^2) & \text{ถ้า } \delta_i = 0 \\ N(0, (c_i \tau_i)^2) & \text{ถ้า } \delta_i = 1 \end{cases}$$

นั่นคือ

$$(2.4) \quad \beta_i | \delta_i \sim (1 - \delta_i) N(0, \tau_i^2) + \delta_i N(0, (c_i \tau_i)^2)$$

จากสมการ (2.4) ถ้ากำหนด  $\tau_i > 0$  และ  $c_i > 1$  จะได้ว่า

ถ้า  $\delta_i = 0$  แล้ว  $\beta_i \sim N(0, \tau_i^2)$  กล่าวคือตัวแปรอิสระ  $X_i$  มีความเป็นไปได้น้อยที่จะอยู่ในตัวแบบ จึงกำหนดให้  $\beta_i$  มีค่าประมาณเป็นศูนย์

ถ้า  $\delta_i = 1$  แล้ว  $\beta_i \sim N(0, (c_i \tau_i)^2)$  กล่าวคือตัวแปรอิสระ  $X_i$  มีความเป็นไปได้สูงที่จะอยู่ในตัวแบบ ดังนั้นค่าประมาณของ  $\beta_i$  จึงไม่เท่ากับศูนย์ เมื่อ  $p_i$  เป็นความน่าจะเป็นก่อนของ  $\beta_i$  ที่มีค่าประมาณไม่เท่ากับศูนย์ ซึ่งจะสอดคล้องกับตัวแปรอิสระ  $X_i$  ที่ควรจะอยู่ในตัวแบบ

จากสมการ (2.4) จะได้หลักเกณฑ์เกี่ยวกับ  $\beta_i | \delta_i$  ที่มีการแจกแจงพหุแบบปกติ (multivariate normal prior) ดังนี้

$$(2.5) \quad \underline{\beta} | \underline{\delta} \sim N_k(\underline{0}, D_\delta R D_\delta)$$

เมื่อ  $\underline{\delta} = (\delta_1, \dots, \delta_k)'$

$R$  เป็นเมทริกซ์สหสัมพันธ์ก่อน (prior correlation matrix)

และ  $D_\delta \equiv \text{diag}[a_1 \tau_1, \dots, a_k \tau_k]$

โดยที่

$$a_i = \begin{cases} 1 & \text{ถ้า } \delta_i = 0 \\ c_i & \text{ถ้า } \delta_i = 1 \end{cases}$$

ความแปรปรวนของความคลาดเคลื่อน (residual variance) :  $\sigma^2$  มีหลักเกณฑ์สังยุคแบบแกมมาผกผัน (inverse gamma conjugate prior) ดังนี้

$$(2.6) \quad \sigma^2 | \underline{\delta} \sim \text{IG}\left(\frac{\nu_\delta}{2}, \frac{\nu_\delta \lambda_\delta}{2}\right)$$



ซึ่งจะสมมูลกับ  $\frac{v_\delta \lambda_\delta}{2} \sim \chi_{v_\delta}^2$  โดยที่  $v_\delta$  และ  $\lambda_\delta$  จะขึ้นอยู่กับ  $\delta$  ที่เป็นไปตามความสัมพันธ์ระหว่าง  $\beta$  และ  $\sigma^2$  กล่าวคือค่าของ  $\sigma^2$  จะลดลงเมื่อมิติของ  $\beta$  (คือจำนวนเทอมที่สมาชิกใน  $\delta$  ไม่เท่ากับศูนย์) เพิ่มขึ้น

## 2.6.2 การแจกแจงความน่าจะเป็นภายหลัง (Posterior Probability Distribution)

การแจกแจงความน่าจะเป็นภายหลังขอบ (marginal posterior distribution) แปรผันตามผลคูณระหว่างความควรจะเป็นของข้อมูล (likelihood) และการแจกแจงความน่าจะเป็นก่อน (prior distribution) ดังนี้

$$(2.7) \quad f(\delta | y) \propto f(y | \delta) \cdot f(\delta)$$

เมื่อกำหนดข้อมูล  $y$  ความน่าจะเป็นภายหลังจะปรับปรุงความน่าจะเป็นก่อนเมื่อกำหนดแต่ละค่าของ  $\delta$  จากค่าที่เป็นไปได้  $2^k$  ค่า  $\delta$  ที่มีความน่าจะเป็นภายหลัง  $f(\delta | y)$  สูง ๆ จะสอดคล้องกับตัวแบบที่เหมาะสมในการพยากรณ์

ปัจจัยต่าง ๆ ที่มีผลต่อความน่าจะเป็นภายหลัง ได้แก่

- 1) หลักเกณฑ์เกี่ยวกับ  $f(\delta)$
- 2) ค่าคงที่  $\tau_1, \dots, \tau_k$  และ  $c_1, \dots, c_k$  ของเมทริกซ์  $D_\delta$
- 3) เมทริกซ์สหสัมพันธ์ก่อน (prior correlation matrix) :  $R$  จากสมการ (2.5)
- 4) ค่าระดับขั้นความเสรี (degree of freedom)  $v_\delta$  และ  $\lambda_\delta$  จากสมการ (2.6)

ดังรายละเอียดต่อไปนี้

### 2.6.2.1 การกำหนดหลักเกณฑ์เกี่ยวกับ $f(\delta)$

การแจกแจงขอบของ  $\delta$  เมื่อตัวแปรอิสระเป็นอิสระซึ่งกันและกัน จะมีรูปแบบดังสมการ (2.3) ถ้ากำหนดให้มีหลักเกณฑ์แบบสม่ำเสมอ (uniform prior) แล้วตัวแปรอิสระแต่ละตัวแปรจะมีโอกาสเข้าสู่ตัวแบบเท่า ๆ กัน ดังนั้น  $f(\delta) = 2^{-k}$  ซึ่งเกิดจากการกำหนด  $p_i$  ให้เป็นหลักเกณฑ์ที่ไม่ทราบข้อมูลมาก่อน (non informative prior) กล่าวคือ

$$p_i = P(\delta_i = 1) = \frac{1}{2}, \quad \forall i = 1, 2, \dots, k$$

จากทฤษฎีของเบส์ เมื่อมีข้อมูล (information) เกี่ยวกับพารามิเตอร์เพิ่มขึ้น จะสามารถปรับปรุงหลักเกณฑ์ใหม่ด้วยความน่าจะเป็นภายหลังที่มีอยู่ก่อน เช่น เมื่อทราบว่า  $\delta$  มีการแจกแจงอื่นนอกจากการแจกแจงแบบสมมาตร เราสามารถสร้างความน่าจะเป็นภายหลังใหม่ เมื่อกำหนดความน่าจะเป็นภายหลังเดิมทำหน้าที่เป็นหลักเกณฑ์ใหม่ ดังนี้

ความน่าจะเป็นภายหลัง<sub>1</sub>  $\alpha$  ความน่าจะเป็นก่อน<sub>1</sub>  $\times$  ความควรจะเป็น<sub>1</sub>  
 ความน่าจะเป็นภายหลัง<sub>2</sub>  $\alpha$  ความน่าจะเป็นภายหลัง<sub>1</sub>  $\times$  ความควรจะเป็น<sub>2</sub>

### 2.6.2.2 การกำหนดค่าคงที่ $\tau_1, \dots, \tau_k$ และ $c_1, \dots, c_k$ ของเมทริกซ์ $D_\delta$

การเลือกค่าคงที่  $\tau_1, \dots, \tau_k$  และ  $c_1, \dots, c_k$  นั้นควรเลือกให้เป็นค่าคงที่ที่สามารถแบ่งแยกการแจกแจงของพารามิเตอร์  $\beta_i \sim N(0, \tau_i^2)$  และ  $\beta_i \sim N(0, (c_i \tau_i)^2)$  ได้อย่างชัดเจน วิธีการหนึ่งที่ใช้ในการเลือกค่าคงที่  $\tau_i$  และ  $c_i$  คือวิธีการลู่อู่เข้ากึ่งอัตโนมัติ (Semiautomatic Approach) โดยพิจารณาจุดตัด (intersection point) และความสูงสัมพัทธ์ (relative height) ณ ตำแหน่งศูนย์ของความหนาแน่นขอบ (marginal densities) ของ

$$\begin{aligned} (\hat{\beta}_i | \sigma_{\beta_i}, \delta_i = 0) &\sim N(0, \sigma_{\beta_i}^2 + \tau_i^2) && \text{และ} \\ (\hat{\beta}_i | \sigma_{\beta_i}, \delta_i = 1) &\sim N(0, \sigma_{\beta_i}^2 + c_i^2 \tau_i^2) \end{aligned}$$

กำหนดให้  $t_i, \sigma_{\beta_i}$  แทนจุดตัด  
 $X_i$  แทนตัวแปรอิสระตัวที่  $i$ ,  $i = 1, 2, \dots, k$   
 และ  $\sigma_{\beta_i}^2$  แทนความแปรปรวนของตัวประมาณค่าพารามิเตอร์  
 สัมประสิทธิ์การถดถอย  $\hat{\beta}_i$  โดยวิธีกำลังสองน้อยสุด

เนื่องจาก

$$(2.8) \quad P(\delta_i = 1 | \hat{\beta}_i, \sigma_{\beta_i}) > p_i (= P(\delta_i = 1)) \quad \text{ก็ต่อเมื่อ} \quad \frac{\hat{\beta}_i}{\sigma_{\beta_i}} > t_i$$

ดังนั้นจุด  $t_i$  จะเข้าสู่การแจกแจงแบบที (t – distribution) ซึ่งจะสอดคล้องกับการเพิ่มขึ้นของความน่าจะเป็นชอบ นั่นคือ  $X_i$  ควรจะอยู่ในตัวแบบ ดังนั้น  $t_i$  ที่มีค่ามาก ๆ จะเป็นตัวแบบที่เหมาะสม

ความสัมพันธ์ของความหนาแน่นส่วนรวม  $\beta_i$  ณ จุดศูนย์ คือ


$$(2.9) \quad r_i \equiv \sqrt{\frac{\sigma_{\beta_i}^2 / \tau_i^2 + c_i^2}{\sigma_{\beta_i}^2 / \tau_i^2 + 1}}$$

เมื่อ  $r_i$  แทนความน่าจะเป็นภายหลังชอบ (marginal posterior probability) ของ  $X_i$  ที่อยู่ในตัวแบบทั้ง ๆ ที่ค่า  $\beta_i = 0$

แม้ว่าการเลือกค่าคงที่  $\tau_1, \dots, \tau_k$  และ  $c_1, \dots, c_k$  ด้วยวิธีการลู่อู่เข้า กึ่งอัตโนมัติจะทำให้ได้ค่า  $t_i$  และ  $r_i$  ที่เหมาะสม แต่ขั้นตอนต่าง ๆ ค่อนข้างยุ่งยากและเสียเวลาในการคำนวณมาก ดังนั้นในการวิจัยครั้งนี้จะใช้วิธีการกำหนดให้  $\sigma_{\beta_i} / \tau_i$  และ  $c_i$  เป็นค่าคงที่ ซึ่งจากงานวิจัยของจอร์จ และแมคคัลลอค (George and McCulloch, 1993) ได้ชี้ให้เห็นว่าการกำหนดให้  $\sigma_{\beta_i} / \tau_i$  และ  $c_i$  เป็นค่าคงที่เป็นวิธีการหนึ่งที่จะทำให้ได้ค่า  $t_i$  และ  $r_i$  ที่เหมาะสม นอกจากการกำหนดดังกล่าวจะทำให้ได้ผลลัพธ์ง่ายและรวดเร็วแล้ว ยังจะมีผลทำให้การแปลงขนาด (rescaling) ของ  $X_i$  มีความคงที่มาก และยังเป็นผลลัพธ์ที่ดีเหมือนกับการกำหนดด้วยวิธีการลู่อู่เข้า กึ่งอัตโนมัติ เพื่อให้ได้ข้อเสนอสืบค้นจะพิจารณากำหนดให้  $\sigma_{\beta_i} / \tau_i$  และ  $c_i$  มีค่าต่าง ๆ ดังนี้  $(\sigma_{\beta_i} / \tau_i, c_i) = (1,5) (1,10) (10,100)$  และ  $(10,500)$  เนื่องจากค่า  $(\sigma_{\beta_i} / \tau_i, c_i) = (1,5)$  จะให้การแจกแจงแบบปกติที่มีการกระจายของพารามิเตอร์แคบเกินไปเมื่อเปรียบเทียบกับ  $(\sigma_{\beta_i} / \tau_i, c_i) = (1,10)$  และค่า  $(\sigma_{\beta_i} / \tau_i, c_i) = (10,500)$  จะให้การแจกแจงแบบปกติที่มีการกระจายของพารามิเตอร์กว้างเกินไปเมื่อเปรียบเทียบกับ  $(\sigma_{\beta_i} / \tau_i, c_i) = (10,100)$  ซึ่งการกำหนดค่าคงที่  $(\sigma_{\beta_i} / \tau_i, c_i)$  ดังกล่าวจะทำให้ได้ค่า  $(t_i, r_i)$  ที่เหมาะสมคือ (2.4,1.7) (2.7,2.3) (2.1,3.2) และ (2.8,6.8) ตามลำดับ<sup>1</sup> ฟังก์ชันความหนาแน่นชอบ (marginal density function) ที่สอดคล้องกับการกำหนดค่าคงที่  $(\sigma_{\beta_i} / \tau_i, c_i)$  ดังกล่าวแสดงในรูปที่ 2.1 ซึ่งจะเห็นได้ว่า

<sup>1</sup> George, E.I. and McCulloch, R.E., "Variable Selection Via Gibbs Sampling," Journal of American Statistical Association 88 (September 1993): 881-889.

เมื่อค่า  $\sigma_{\beta_i} / \tau_i$  และ  $c_i$  มีค่าเพิ่มขึ้น จะทำให้การแจกแจงของพารามิเตอร์  $\beta_i$  เมื่อ  $\beta_i \sim N(0, \tau_i^2)$  และ  $\beta_i \sim N(0, (c_i \tau_i)^2)$  จะแยกออกจากกันอย่างชัดเจน



รูปที่ 2.1 แสดงความหนาแน่นของการแจกแจง  $N(0, \sigma_{\beta_i}^2 + \tau_i^2)$  และ  $N(0, \sigma_{\beta_i}^2 + c_i^2 \tau_i^2)$  เมื่อ  $(\sigma_{\beta_i} / \tau_i, c_i) = (1, 5) (1, 10) (10, 100) (10, 500)$

### 2.6.2.3 การกำหนดหลักเกณฑ์ของเมทริกซ์สหสัมพันธ์ก่อน (Prior Correlation Matrix : $R$ )

เมทริกซ์  $R$  เป็นเมทริกซ์สหสัมพันธ์ที่เป็นความรู้เดิมเกี่ยวกับ  $\underline{\beta}$  เมื่อกำหนด  $\underline{\delta}$  การเลือกเมทริกซ์  $R$  ที่แตกต่างกันจะมีผลกระทบต่อเมทริกซ์ความแปรปรวนร่วมภายหลัง (posterior covariance matrix) ของ  $\underline{\beta}$  ภายใต้การแจกแจง  $f(\underline{\beta} | y, \sigma, \underline{\delta})$  ดังนี้

$$f(\underline{\beta} | y, \sigma, \underline{\delta}) \propto (\sigma^{-2} X'X + D_{\delta}^{-1} R^{-1} D_{\delta}^{-1})^{-1}$$

ถ้า  $R = I$  สมาชิกใน  $\underline{\beta}$  จะเป็นอิสระต่อกันภายใต้การแจกแจง  $f(\underline{\beta} | \underline{\delta})$  ซึ่งสหสัมพันธ์ภายหลัง (posterior correlation) จะน้อยกว่ากรณีที่  $R \propto (X'X)^{-1}$  สำหรับการวิจัยครั้งนี้จะกำหนดให้  $R \propto (X'X)^{-1}$  ซึ่งจะมีผลให้สหสัมพันธ์ภายหลังจะมีลักษณะเป็นสหสัมพันธ์อย่างมีแบบแผน (design correlation)

### 2.6.2.4 การกำหนดค่าระดับชั้นความเสรี $\nu_{\delta}$ และ $\lambda_{\delta}$

การกำหนดค่า  $\nu_{\delta}$  และ  $\lambda_{\delta}$  สำหรับการแจกแจงก่อนแบบแกมมาผกผัน ดังสมการ (2.6) จะใช้แนวคิดของการวางแผนการทดลอง (experimental design) ซึ่งการกำหนดหลักเกณฑ์ที่ไม่ถูกต้อง (เช่น  $\nu_{\delta} = 0$ ) จะทำให้ได้ค่า  $\sigma^2$  ที่ไม่เหมาะสม เนื่องจากค่าของ  $\sigma^2$  จะอยู่รอบ ๆ ศูนย์ ดังนั้นเราจึงกำหนดค่า  $\nu_{\delta}$  ให้สอดคล้องกับหลักเกณฑ์ที่ไม่ทราบข้อมูลมาก่อน (non informative prior) โดยให้  $\nu_{\delta}$  มีค่าใกล้เคียง  $2^1$  ส่วนค่าของ  $\lambda_{\delta}$  เป็นฟังก์ชันลดของจำนวนสมาชิกใน  $\underline{\delta}$  ที่มีค่าไม่เป็นศูนย์ และ  $\left( \frac{\nu_{\delta}}{\nu_{\delta} - 2} \right) \lambda_{\delta}$  เป็นการประมาณโดยหลักเกณฑ์ของ  $\sigma^2$

ในการวิจัยครั้งนี้จะกำหนดให้  $\nu_{\delta}$  มีค่า 1.99 และ  $\lambda_{\delta}$  เป็นค่าคลาดเคลื่อนกำลังสองเฉลี่ยของตัวแบบที่ได้ ซึ่งค่า  $\lambda_{\delta}$  นี้จะมีการเปลี่ยนแปลงโดยขึ้นอยู่กับตัวแบบที่ได้ เนื่องจากค่า  $\lambda_{\delta}$  จะขึ้นอยู่กับขนาดของค่าพยากรณ์ที่ได้

<sup>1</sup> Chipman, H., Hamada, M. and Wu, C.F.J. "A Bayesian Variable Selection approach for Analyzing Designed Experiments with Complex Aliasing," University of Chicago, 1996.

### 2.6.3 การคัดเลือกตัวแปรโดยการค้นหาด้วยความน่าจะเป็น (Stochastic Search Variable Selection)<sup>1</sup>

การคัดเลือกตัวแปรโดยการค้นหาด้วยความน่าจะเป็น (Stochastic Search Variable Selection (SSVS)) จะใช้วิธีการสุ่มแบบกิบส์ (Gibbs Sampling) ซึ่งเป็นกรณีหนึ่งของโครงสร้างแบบลูกโซ่มาร์คอฟ (Markov Chain Structure) การสร้างเลขสุ่มโดยอาศัยโครงสร้างดังกล่าว เรียกว่า การสร้างเลขสุ่มแบบลูกโซ่มาร์คอฟ (Markov Chain Simulation)

แนวคิดของการสร้างเลขสุ่มแบบลูกโซ่มาร์คอฟ คือ การสร้างแนวเดินเชิงสุ่ม (random walk) ในปริภูมิของพารามิเตอร์  $\theta$  ที่เข้าสู่การแจกแจงที่คงที่ (stationary distribution) ซึ่งก็คือ การแจกแจงภายหลังร่วม (joint posterior distribution)  $f(\theta | y)$  การสร้างเลขสุ่มวิธีนี้เป็นการสร้างกระบวนการมาร์คอฟ (Markov Process) ของการแจกแจงที่คงที่คือ  $f(\theta | y)$  ที่สนใจ และมีรัน (run) ในการสร้างเลขสุ่มให้มีความยาวเพียงพอเพื่อให้การแจกแจงของเลขสุ่มในปัจจุบันเข้าใกล้กับการแจกแจงที่คงที่ได้อย่างเพียงพอ

วิธีการสุ่มแบบกิบส์หรือวิธีการสุ่มที่มีเงื่อนไขอื่น (Alternative Conditional Sampling) เป็นโครงสร้างของลูกโซ่มาร์คอฟเมื่อกำหนดให้เป็นการสุ่มแบบมีเงื่อนไข ซึ่งเป็นประโยชน์อย่างมากในการศึกษาปัญหาแบบหลายมิติ (Multidimensional problem)

ขั้นตอนของการสร้างเลขสุ่มโดยวิธีการสุ่มแบบกิบส์ เป็นดังนี้

- 1) นิยามเวกเตอร์พารามิเตอร์  $\theta$  ที่ถูกแบ่งออกเป็นเวกเตอร์ย่อยจำนวน  $d$  เวกเตอร์ ดังนี้

$$\underline{\theta}_m = (\theta_{1m}, \theta_{2m}, \dots, \theta_{dm})'$$

- 2) ในแต่ละรอบของการสุ่มแบบกิบส์ รอบที่  $t$  ใด ๆ จะได้ค่าของเวกเตอร์ย่อยทั้งหมด  $d$  เวกเตอร์ย่อยตามลำดับ

$$\underline{\theta}'_m = (\theta'_{1m}, \theta'_{2m}, \dots, \theta'_{dm})' \quad \text{เมื่อ } t = 1, 2, \dots$$

---

<sup>1</sup> นุชรินทร์ ทิพย์วรรณกร, "การเปรียบเทียบค่าพยากรณ์ที่ได้จากตัวแบบที่คัดเลือกตัวแปรด้วยวิธีเบสส์เซียน วิธีการกำจัดตัวแปรแบบถอยหลัง และวิธีการถดถอยแบบขั้นบันได ในการวิเคราะห์ความถดถอยพหุนามแบบลำดับชั้น," (วิทยานิพนธ์ปริญญาโทมหาบัณฑิต ภาควิชาสถิติ บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2540), หน้า 18-19.

- 3) ค่าสุ่มของแต่ละเวกเตอร์ย่อยจะถูกกำหนดเงื่อนไขค่าสุ่มของเวกเตอร์ย่อยอื่นๆ ทั้งหมด นั่นคือ ค่าของเวกเตอร์ย่อยปัจจุบันถูกสุ่มจากการแจกแจงแบบมีเงื่อนไขเมื่อกำหนดเวกเตอร์ย่อยอื่นทั้งหมดของ  $\underline{\theta}$

$$f(\underline{\theta}_j | \underline{\theta}_{-j}^{-1}, y)$$

เมื่อ  $\underline{\theta}_{-j}^{-1}$  แทนเวกเตอร์ย่อยทั้งหมดของ  $\underline{\theta}$  ยกเว้น  $\theta_j$  ซึ่งเป็นค่าสุ่มปัจจุบัน กล่าวคือ

$$\underline{\theta}_{-j}^{-1} = (\theta_1', \dots, \theta_{j-1}', \theta_{j+1}', \dots, \theta_d')$$

ดังนั้นแต่ละเวกเตอร์ย่อย  $\theta_j$  จะถูกปรับเงื่อนไขในค่าของ  $\theta$  ค่าล่าสุด นั่นคือค่าเวกเตอร์ย่อยที่ถูกสุ่มมาในรอบที่  $t$  จะถูกปรับค่าด้วยค่าของเวกเตอร์ย่อยที่ปรับแล้วในรอบที่  $t$  และค่าของเวกเตอร์ทั้งหมดที่มีอยู่ในรอบที่  $t-1$

#### 2.6.4 ขั้นตอนของวิธีการคัดเลือกตัวแปรของเบส์ (Bayesian Variable Selection Method (BVS))

ขั้นตอนแรกของวิธีการนี้เริ่มต้นจากสมการถดถอยแบบเต็มรูป คือ ประกอบด้วยตัวแปรอิสระครบทุกตัว แล้วทำการสุ่มแบบกิบส์ เพื่อสร้างลำดับ

$$(2.10) \quad \underline{\delta}^1, \underline{\delta}^2, \dots, \underline{\delta}^t, \dots$$

ลำดับในสมการ (2.10) จะเข้าสู่การแจกแจงของ  $\underline{\delta} \sim f(\underline{\delta} | y)$  ซึ่งเป็นลำดับที่มีความน่าจะเป็นค่อนข้างสูง เพราะบรรจุข้อมูลที่สอดคล้องกับการคัดเลือกตัวแปร โดย  $\underline{\delta}^t$  ใดๆ ที่มีความน่าจะเป็นสูงสุด ทำให้ง่ายต่อการตัดสินใจในการเลือกตัวแปรที่ดีที่สุด

เราใช้วิธีการสุ่มแบบกิบส์เพื่อสร้างเวกเตอร์เป็นลำดับแบบกิบส์ ดังนี้

$$(2.11) \quad \underline{\beta}^0, \sigma^0, \underline{\delta}^0, \underline{\beta}^1, \sigma^1, \underline{\delta}^1, \dots, \underline{\beta}^t, \sigma^t, \underline{\delta}^t, \dots$$

เมื่อ  $\underline{\beta}^0, \sigma^0$  เป็นค่าเริ่มต้นที่ได้จากการประมาณค่าด้วยวิธีกำลังสองน้อยสุดของสมการ (1.1)

และ  $\underline{\delta}^0$  ถูกกำหนดค่าเริ่มต้นให้เป็น  $\underline{\delta}^0 \equiv (1, 1, \dots, 1)'$

ในแต่ละรอบของการสุ่มค่าของลำดับ  $\underline{\beta}^j, \sigma^j, \underline{\delta}^j$  ได้จากการสร้างค่าที่สอดคล้องกับขั้นตอนต่อไปนี้

1) สุ่มเวกเตอร์ของสัมประสิทธิ์การถดถอย  $\underline{\beta}^j$  จากการแจกแจง

$$(2.12) \quad f(\underline{\beta}^j | y, \sigma^{j-1}, \underline{\delta}^{j-1}) = N_p(A_{\delta^{j-1}}(\sigma^{j-1})^{-2} X'X \underline{\beta}_{LS}^{j-1}, A_{\delta^{j-1}})$$

เมื่อ 
$$A_{\delta^{j-1}} = ((\sigma^{j-1})^{-2} X'X + D_{\delta^{j-1}}^{-1} R^{-1} D_{\delta^{j-1}}^{-1})^{-1}$$

และ 
$$D_{\delta^{j-1}}^{-1} = \text{diag}[(a_1 \tau_1)^{-1}, (a_2 \tau_2)^{-1}, \dots, (a_k \tau_k)^{-1}]$$

2) สุ่มค่าความแปรปรวน  $\sigma^j$  จากการแจกแจง

$$(2.13) \quad f(\sigma^j | y, \underline{\beta}^j, \underline{\delta}^{j-1}) = IG\left(\frac{n + \nu_{\delta^{j-1}}}{2}, \frac{|y - X\underline{\beta}^j|^2 + \nu_{\delta^{j-1}} \lambda_{\delta^{j-1}}}{2}\right)$$

3) ค่าเวกเตอร์  $\underline{\delta}^j$  ได้จากการแยกองค์ประกอบ (componentwise) โดยการสุ่มอย่างต่อเนื่อง (sampling consecutively) จากการแจกแจงแบบมีเงื่อนไขดังนี้

$$(2.14) \quad \delta_i^j \sim f(\delta_i^j | y, \underline{\beta}^j, \sigma^j, \delta_{-i}^j) = f(\delta_i^j | \underline{\beta}^j, \sigma^j, \delta_{-i}^j)$$

เมื่อ 
$$\delta_{-i}^j = (\delta_1^j, \dots, \delta_{i-1}^j, \delta_{i+1}^j, \dots, \delta_k^j)$$

จะเห็นได้ว่าการแจกแจงในสมการ (2.14) จะไม่ขึ้นอยู่กับค่าของ  $y$

ในสมการ (2.14)  $\delta_i^j$  แต่ละตัวจะมีการแจกแจงแบบแบร์นูลลี (Bernoulli distribution) ด้วยความน่าจะเป็น

$$(2.15) \quad P(\delta_i^j = 1 | \underline{\beta}^j, \sigma^j, \delta_{-i}^j) = \frac{a}{a+b}$$

$$(2.16) \quad \text{เมื่อ} \quad a = f(\underline{\beta}^j | \delta_{-i}^j, \delta_i^j = 1) \times f(\sigma^j | \delta_{-i}^j, \delta_i^j = 1) \times f(\delta_{-i}^j, \delta_i^j = 1)$$

$$(2.17) \quad \text{และ} \quad b = f(\underline{\beta}^j | \delta_{-i}^j, \delta_i^j = 0) \times f(\sigma^j | \delta_{-i}^j, \delta_i^j = 0) \times f(\delta_{-i}^j, \delta_i^j = 0)$$



ความยาวของลำดับในสมการ (2.10) จะเพิ่มขึ้นเรื่อย ๆ ทำให้การแจกแจงของค่าที่แท้จริงของ  $\theta$  จะเข้าสู่การแจกแจงภายหลัง  $f(\theta|y)$  การลู่เข้านี้จะเร็วไปอย่างรวดเร็ว ถ้า  $f(\theta|y)$  เป็นค่าสูงสุด ตัวแบบที่มีน้ำหนักมาก ๆ มีจำนวนไม่มาก ตัวแบบเหล่านี้จะมีความแม่นยำสูง เมื่อ  $f(\theta|y)$  บรรจุข้อมูลส่วนใหญ่ของการคัดเลือกตัวแปร

ข้อมูลที่สอดคล้องกับการคัดเลือกตัวแปรจะอยู่ในลำดับของสมการ (2.11) ค่าของ  $\theta$  ที่สอดคล้องกับกลุ่มย่อยของ  $X_1, X_2, \dots, X_k$  จะมีความถี่สูงสุด เพราะว่าลำดับย่อยนี้จะเหมาะสมกับตัวแบบที่มีค่าความน่าจะเป็นภายหลังสูงสุดภายใต้  $f(\theta|y)$  กล่าวคือ ตัวแบบที่เหมาะสมจะเป็นตัวแบบที่มีความถี่สูงสุดและจะมีค่าความน่าจะเป็นภายหลังสูงสุดด้วย

## 2.7 วิธีการเฉลี่ยตัวแบบของเบส์ (Bayesian Model Averaging Method (BMA))

วิธีการเฉลี่ยตัวแบบของเบส์ (Bayesian Model Averaging Method (BMA)) สำหรับตัวแบบการถดถอยเชิงเส้น เสนอโดยราฟเทอร์รี เมดิแกน และ โฮเอ็ททิง (Raftery Madigan and Hoeting ,1997) เป็นวิธีการพิจารณาค่าความน่าจะเป็นภายหลัง (posterior probability) สำหรับทุก ๆ ตัวแบบที่เราสนใจ และนำตัวแบบทุกตัวแบบที่เราสนใจมาเฉลี่ยกันโดยใช้ความน่าจะเป็นภายหลังของแต่ละตัวแบบเป็นตัวถ่วงน้ำหนัก เพื่อหาค่าพยากรณ์ที่เหมาะสม

วิธีการเฉลี่ยตัวแบบของเบส์นี้เป็นการพิจารณาโดยคำนึงถึงความไม่แน่นอนของตัวแบบ (Model Uncertainty) และมีแนวคิดว่าการคัดเลือกตัวแบบที่ดีที่สุดเพียงตัวแบบเดียวจากทุกตัวแบบที่เป็นไปได้ ถือเป็นการละเลยตัวแบบอื่น ๆ ซึ่งบ่อยครั้งเราจะพบว่า มีตัวแบบหลายรูปแบบที่มีประสิทธิภาพในการพยากรณ์ใกล้เคียงกัน แต่วิธีการคัดเลือกตัวแบบ และวิธีการคัดเลือกตัวแปรอิสระที่นิยมใช้กันอย่างแพร่หลายในปัจจุบัน เป็นการนำตัวแบบเพียงรูปแบบเดียวมาใช้ในการพยากรณ์เท่านั้น ดังนั้นเมื่อพิจารณาถึงหลักการเกี่ยวกับความไม่แน่นอนของตัวแบบแล้ว วิธีการเฉลี่ยตัวแบบของเบส์น่าจะทำได้ค่าพยากรณ์ที่มีประสิทธิภาพมากกว่าค่าพยากรณ์ที่ได้จากตัวแบบเดียว ซึ่งจากงานวิจัยของนักสถิติหลายท่าน เช่น เมดิแกน และ ราฟเทอร์รี (Madigan and Raftery ,1994) เมดิแกน และ ยอร์ค (Madigan and York ,1995) และ ราฟเทอร์รี (Raftery ,1996) เป็นต้น ได้ชี้ให้เห็นว่าความไม่แน่นอนของตัวแบบเป็นสิ่งที่สำคัญและควรนำมาพิจารณาในการคัดเลือกตัวแบบสำหรับการวิเคราะห์ความถดถอยเชิงเส้นพหุคูณ

การแจกแจงความน่าจะเป็นภายหลังของสิ่งที่สนใจ เมื่อมีข้อมูลจะเป็นดังนี้

$$(2.18) \quad p(\Delta | D) = \sum_{k=1}^K p(\Delta | M_k, D) p(M_k | D)$$

เมื่อ  $\Delta$  เป็นปริมาณของสิ่งที่สนใจ เช่น ค่าพยากรณ์ที่สนใจ

$D$  เป็นข้อมูลของตัวแบบที่สนใจ

และ  $M_1, \dots, M_k$  เป็นตัวแบบที่พิจารณา

ซึ่งสมการ (2.18) เป็นการเฉลี่ยการแจกแจงความน่าจะเป็นภายหลัง ถ่วงน้ำหนักด้วยความน่าจะเป็นภายหลังของแต่ละตัวแบบ โดยเรียกแนวคิดนี้ว่า "การเฉลี่ยตัวแบบของเบส์ (Bayesian Model Averaging (BMA))"

ความน่าจะเป็นภายหลังของตัวแบบ  $M_k$  คือ

$$(2.19) \quad p(M_k | D) = \frac{p(D | M_k) p(M_k)}{\sum_{i=1}^K p(D | M_i) p(M_i)}$$

โดยที่

$$(2.20) \quad p(D | M_k) = \int p(D | \theta_k, M_k) p(\theta_k | M_k) d\theta_k$$

ซึ่งเป็นความควรจะเป็นขอบ (marginal likelihood) ของตัวแบบ  $M_k$

เมื่อ  $\theta_k$  เป็นเวกเตอร์ของพารามิเตอร์ สำหรับการวิเคราะห์ความถดถอย หมายถึง  $\beta$  และ  $\sigma^2$

$p(\theta_k | M_k)$  เป็นความหนาแน่นก่อนของ  $\theta_k$  ภายใต้ตัวแบบ  $M_k$

$p(D | \theta_k, M_k)$  เป็นฟังก์ชันความควรจะเป็น

และ  $p(M_k)$  เป็นความน่าจะเป็นก่อน สำหรับตัวแบบ  $M_k$

ค่าเฉลี่ยและความแปรปรวนภายหลังของสิ่งที่สนใจ  $\Delta$  เป็นดังนี้

$$(2.21) \quad E[\Delta | D] = \sum_{k=0}^K \hat{\Delta}_k p(M_k | D)$$

$$(2.22) \quad \text{Var}[\Delta | D] = \sum_{k=0}^K (\text{Var}[\Delta | D, M_k] + \hat{\Delta}_k^2) p(M_k | D) - E[\Delta | D]^2$$

โดยที่  $\hat{\Delta}_k = E[\Delta | D, M_k]$

นั่นคือจากสมการ (2.21) เราสามารถสรุปได้ว่า ถ้าสิ่งที่เราสนใจ  $\Delta$  เป็นค่าพยากรณ์  $\hat{Y}$  ค่าคาดหวังของค่าพยากรณ์  $\hat{Y}$  เมื่อมีข้อมูล คือ การเฉลี่ยค่าพยากรณ์ของแต่ละตัวแบบ ถ่วงน้ำหนักด้วยความน่าจะเป็นภายหลังของแต่ละตัวแบบ  $M_k$  จะทำให้เราได้ค่าพยากรณ์  $\hat{Y}$  ตามที่ต้องการ

นอกจากนี้ในงานวิจัยของ เมดิแกน และราฟเทอร์รี่ (Madigan and Raftery, 1994) ยังแสดงให้เห็นว่าการเฉลี่ยตัวแบบจะทำให้การพยากรณ์มีประสิทธิภาพสูงกว่าการใช้ตัวแบบเดียวในการพยากรณ์ โดยใช้กฎของคะแนนลอการิทึม และแนวคิดเกี่ยวกับรูปแบบข้อสนเทศของ คูลล์แบ็ค-ไลเบอร์ (Kullback-Leibler, 1951) จะได้ว่า

$$-E \left[ \log \left\{ \sum_{k=1}^K P(\Delta | M_k, D) P(M_k | D) \right\} \right] \leq -E \left[ \log \{ P(\Delta | M_j, D) \} \right] \quad ; j=1, \dots, K$$

ซึ่งเป็นการยืนยันว่าวิธีการเฉลี่ยตัวแบบจะมีประสิทธิภาพในการพยากรณ์สูงกว่าการใช้ตัวแบบเดียวในการพยากรณ์

2.7.1 ความน่าจะเป็นก่อน (prior probability) และความน่าจะเป็นภายหลังขอบ (marginal posterior probability) ของตัวแบบ

ในการหาความน่าจะเป็นภายหลัง (posterior probability) ของแต่ละตัวแบบ จำเป็นต้องทราบถึงความน่าจะเป็นก่อน (prior probability) และความน่าจะเป็นภายหลังขอบ (marginal posterior probability) ของตัวแบบ ซึ่งมีรายละเอียดดังนี้

2.7.1.1 ความน่าจะเป็นก่อน (prior probability) ของตัวแบบ

ความน่าจะเป็นก่อนของแต่ละตัวแบบจะอยู่ในรูปแบบดังนี้

$$(2.23) \quad p(M_j) = \prod_{j=1}^k p_j^{\delta_j} (1 - p_j)^{1 - \delta_j}$$

เมื่อ	$p_j$	เป็นความน่าจะเป็นที่ตัวแปรอิสระที่ $j$ จะรวมอยู่ในตัวแบบ $M_j$
	$\delta_j$	เป็นตัวบ่งชี้ที่มีค่า 0 หรือ 1
โดย	$\delta_j$	เป็น 0 เมื่อตัวแปรอิสระที่ $j$ ไม่อยู่ในตัวแบบ $M_j$
และ	$\delta_j$	เป็น 1 เมื่อตัวแปรอิสระที่ $j$ อยู่ในตัวแบบ $M_j$

สำหรับการวิจัยครั้งนี้จะกำหนด  $p_i$  สำหรับทุก ๆ ตัวแปรอิสระเป็น  $(\frac{1}{2})$  กล่าวคือเป็นหลักเกณฑ์แบบสม่ำเสมอ (uniform prior) หรือตัวแปรอิสระทุกตัวจะมีโอกาสอยู่ในตัวแบบหรือไม่อยู่ในตัวแบบเท่า ๆ กันนั่นเอง

### 2.7.1.2 ความน่าจะเป็นภายหลังขอบ (marginal posterior probability) ของตัวแบบ

จากสมการ (2.20) การหาค่าความน่าจะเป็นภายหลังขอบของตัวแบบ  $M_k$  คือ  $p(D|M_k)$  จะทำได้ดังนี้

เนื่องจากความน่าจะเป็นภายหลังขอบของตัวแบบ  $M$  ใด ๆ จะแปรผันตามฟังก์ชันความควรจะเป็นคู่กับการแจกแจงก่อนของพารามิเตอร์ กล่าวคือ

$$p(D|M) \propto \text{likelihood} \times \text{prior}$$

ดังนั้นในขั้นแรกต้องทำการกำหนดการแจกแจงก่อน (prior distribution) ของพารามิเตอร์ซึ่งมีรายละเอียดดังนี้<sup>1</sup>

การกำหนดการแจกแจงก่อนของพารามิเตอร์ได้ใช้แนวคิด Maximal Data Informative Prior (Zellner, 1971) ซึ่งเป็นแบบไม่มีข้อมูล (non informative prior) กล่าวคือ เราไม่ทราบลักษณะพื้นฐานของข้อมูล หรือข้อมูลมีลักษณะคลุมเครือ ไม่ชัดเจน ซึ่งเหตุผลในการใช้การแจกแจงก่อนของพารามิเตอร์เป็นแบบไม่มีข้อมูล เนื่องจาก

- 1) เป็นการใช้ข้อมูลที่มีอยู่อธิบายลักษณะของข้อมูลเอง
- 2) บ่อยครั้งเราไม่สามารถจัดการแจกแจงก่อนที่เกิดจากความเชื่อของแต่ละบุคคลหรือที่เรียกว่า จิตวิสัย (subjective prior) ได้ เนื่องจากข้อจำกัดด้านเวลาและค่าใช้จ่าย หรือเนื่องจากความไม่ชำนาญของผู้กำหนด ดังนั้นการแจกแจงก่อนของ  $\beta$  และ  $\log(\sigma)$  จะเป็นการแจกแจงแบบสม่ำเสมอ (uniform distribution) และมีความเป็นอิสระซึ่งกันและกัน โดยมีรูปแบบดังนี้

$$p(\beta, \sigma) \propto \frac{1}{\sigma} \quad ; -\infty < \beta < \infty, \quad 0 < \sigma < \infty$$

---

<sup>1</sup> พจนา แว่วสวัสดิ์, "การเปรียบเทียบเกณฑ์การคัดเลือกตัวแบบความถดถอยพหุนามแบบติดกลุ่ม," (วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ สาขาวิชาสถิติ บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2543), หน้า 24.

ฟังก์ชันความหนาแน่นน่าจะเป็นร่วมภายหลังสำหรับตัวแบบ  $M$  คือ

$$p(D|M) \propto \text{likelihood} \times \text{prior}$$

$$p(D|M) \propto l(\underline{\beta}_{ML}, \sigma | \underline{y}) \times p(\underline{\beta}_{ML}, \sigma)$$

$$p(D|M) \propto \frac{1}{\sigma^{n+1}} \exp\left[-\frac{1}{2\sigma^2} (\underline{y} - X\underline{\beta}_{ML})' (\underline{y} - X\underline{\beta}_{ML})\right]$$

$$p(D|M) \propto \frac{1}{\sigma^{n+1}} \exp\left[-\frac{1}{2\sigma^2} \left[ \nu s^2 + (\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})' X'X (\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML}) \right]\right]$$

เมื่อ  $\hat{\underline{\beta}}_{ML} = (X'X)^{-1} X'Y$

$$s^2 = \frac{(\underline{y} - X\underline{\beta}_{ML})' (\underline{y} - X\underline{\beta}_{ML})}{\nu}$$

และ  $\nu = n - p$

โดยที่  $\nu$  เป็นระดับขั้นความเสรี

$n$  เป็นขนาดตัวอย่าง

$p$  เป็นจำนวนพารามิเตอร์ในตัวแบบ

และ  $M$  เป็นตัวแบบที่นำมาพิจารณา

การแจกแจงความน่าจะเป็นภายหลังของตัวแบบความถดถอย  $M$  คือ

$$p(D|M) \propto \int_0^{\infty} \text{likelihood} \times \text{prior} \, d\sigma$$

$$\propto \int_0^{\infty} l(\underline{\beta}_{ML} | \sigma, M) \times p(\underline{\beta}_{ML}, \sigma) \, d\sigma$$

$$\propto \int_0^{\infty} \frac{1}{\sigma^n} \exp\left[-\frac{1}{2\sigma^2} (\underline{y} - X\underline{\beta}_{ML})' (\underline{y} - X\underline{\beta}_{ML})\right] \cdot \left(\frac{1}{\sigma}\right) \, d\sigma$$

$$\propto \int_0^{\infty} \frac{1}{\sigma^{n+1}} \exp\left[-\frac{1}{2\sigma^2} (\underline{y} - X\underline{\beta}_{ML})' (\underline{y} - X\underline{\beta}_{ML})\right] \, d\sigma$$

$$\begin{aligned}
p(D|M) &\propto \int_0^\infty \frac{1}{\sigma^{n+1}} \exp\left[-\frac{1}{2\sigma^2} \left(\underline{y} - X\hat{\underline{\beta}}_{ML} - X(\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})\right)' \left(\underline{y} - X\hat{\underline{\beta}}_{ML} - X(\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})\right)\right] d\sigma \\
&\propto \int_0^\infty \frac{1}{\sigma^{n+1}} \exp\left[-\frac{1}{2\sigma^2} \left(\left(\underline{y} - X\hat{\underline{\beta}}_{ML}\right)' \left(\underline{y} - X\hat{\underline{\beta}}_{ML}\right) + (\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})' X'X(\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})\right)\right] d\sigma \\
&\text{(เนื่องจากพจน์ } (\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})' X'(\underline{y} - X\hat{\underline{\beta}}_{ML}) = (\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})' [X'\underline{y} - X'X(X'X)^{-1}X'\underline{y}] = 0) \\
&\propto \int_0^\infty \frac{1}{\sigma^{n+1}} \exp\left[-\frac{1}{2\sigma^2} \left(u\sigma^2 + (\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})' X'X(\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})\right)\right] d\sigma
\end{aligned}$$

ใช้เทคนิคการอินทิเกรตของแกมมา

กำหนดให้  $u = \left(u\sigma^2 + (\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})' X'X(\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})\right)$  จะได้ว่า

$$p(D|M) \propto \int_0^\infty \frac{1}{\sigma^{n+1}} \exp\left[-\frac{u}{2\sigma^2}\right] d\sigma$$

จากนั้นกำหนดให้  $v = \frac{u}{2\sigma^2}$  จะได้ว่า

$$p(D|M) \propto \int_0^\infty \frac{1}{\sigma^{n+1}} \exp[-v] d\sigma$$

$$\begin{aligned}
p(D|M) &\propto \int_0^\infty \left(\frac{u}{2v}\right)^{-\frac{1}{2}(n+1)} \exp[-v] \left(\frac{u}{2}\right)^{\frac{1}{2}} v^{-\frac{3}{2}} dv \\
&\propto \int_0^\infty \left(\frac{u}{2}\right)^{-\frac{1}{2}(n+1)} \bullet v^{\frac{n}{2}-\frac{1}{2}} \exp[-v] \left(\frac{u}{2}\right)^{\frac{1}{2}} \frac{v^{-\frac{3}{2}}}{2} dv \\
&\propto \int_0^\infty \left(\frac{u}{2}\right)^{-\frac{n}{2}} \bullet v^{\frac{n}{2}-1} \exp[-v] \bullet \frac{1}{2} dv \\
&\propto \frac{2^{\frac{(n-2)}{2}}}{u^{\frac{n}{2}}} \int_0^\infty v^{\frac{(n-2)}{2}} e^{-v} dv
\end{aligned}$$

$$p(D|M) \propto \frac{2^{\binom{n-2}{2}} \Gamma\left(\frac{n}{2}\right)}{u^2}$$

$$p(D|M) \propto 2^{\binom{n-2}{2}} \Gamma\left(\frac{n}{2}\right) \left( u^2 + (\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML})' X'X (\underline{\beta}_{ML} - \hat{\underline{\beta}}_{ML}) \right)^{-\frac{n}{2}}$$

## 2.7.2 การค้นหาปริภูมิตัวแบบด้วยวิธีออกัสแคม วินโดว์ (Occam 's Window)

เนื่องจากวิธีการเฉลี่ยตัวแบบของเบส์จะพิจารณาหาค่าความน่าจะเป็นภายหลังสำหรับทุก ๆ ตัวแบบที่เราสนใจ ในบางครั้งปริภูมิตัวแบบที่เป็นไปได้มีขนาดใหญ่ ทำให้เสียเวลาในการคำนวณมากถึงแม้ว่าในปัจจุบันความก้าวหน้าทางเทคโนโลยีคอมพิวเตอร์จะช่วยลดปัญหานี้ได้ก็ตาม วิธีการหนึ่งที่น่ามาใช้ในการค้นหาปริภูมิตัวแบบ ทำให้ปริภูมิตัวแบบที่ได้มีขนาดเล็กลงก็คือการค้นหาปริภูมิตัวแบบด้วยวิธีออกัสแคม วินโดว์ (Occam 's Window) เสนอโดย เมดิแกน และราฟเทอร์รี่ (Madigan and Raftery ,1994) ซึ่งนำมาใช้สำหรับตัวแบบการถดถอย วิธีการนี้ถ้าตัวแบบมีความน่าจะเป็นภายหลังห่างจากตัวแบบที่ดีที่สุดตัวแบบนั้นจะไม่น่าเชื่อถือ และไม่นำมาพิจารณาอีกต่อไป

$$(2.24) \quad A = \left\{ M_k \mid \frac{\max_i \{p(M_i | D)\}}{p(M_k | D)} \leq a \right\}$$

ดังนั้นตัวแบบที่ไม่เป็นไปตามสมการ (2.24) จะถูกตัดออกจากปริภูมิตัวแบบ ในสมการ (2.24) ค่า  $a$  เป็นค่าคงที่ที่มีขนาดใหญ่ และเป็นค่าที่ถูกเลือกโดยผู้วิจัย การเลือกค่าคงที่  $a$  จะมีผลต่อจำนวนตัวแบบในปริภูมิตัวแบบ โดยจำนวนตัวแบบในปริภูมิตัวแบบจะแปรผันตามค่าคงที่  $a$  ซึ่งจากงานวิจัยของเมดิแกน และราฟเทอร์รี่ (Madigan and Raftery ,1994) แนะนำว่าค่าคงที่  $a$  ควรอยู่ระหว่าง 10 ถึง 100 ในการวิจัยครั้งนี้ผู้วิจัยกำหนดให้  $a = 20$  สำหรับการเปรียบเทียบกรณีที่ระดับนัยสำคัญ เท่ากับ 0.05 และ  $a = 100$  สำหรับการเปรียบเทียบกรณีที่ระดับนัยสำคัญเท่ากับ 0.01 (Jeffreys ,1961 : Appendix B.)

สำหรับตัวแบบที่ได้รับการสนับสนุนน้อยจากข้อมูลเมื่อเทียบกับตัวแบบอย่างง่ายกว่า ก็จะถูกตัดออกจากปริภูมิตัวแบบดังสมการ (2.25)

$$(2.25) \quad B = \left\{ M_k \mid \exists M_i \in A, M_i \subset M_k, \frac{p(M_i | D)}{p(M_k | D)} > 1 \right\}$$

ซึ่งจะทำให้การเฉลี่ยตัวแบบของเบสในสมการ (2.18) เปลี่ยนเป็น

$$(2.26) \quad p(\Delta | D) = \sum_{M_k \in S} p(\Delta | M_k, D) \cdot p(M_k | D)$$

เมื่อ  $S = A - B$

นั่นคือการเฉลี่ยตัวแบบจะอยู่ภายใต้ปริภูมิตัวแบบที่ผ่านการค้นหาปริภูมิตัวแบบด้วยวิธีออกแคมส์ วินโดว์ แทนที่การเฉลี่ยตัวแบบภายใต้ตัวแบบที่เป็นไปได้ทั้งหมด

หลักการของออกแคมส์วินโดว์ (Occam's Window) จะเป็นการยืนยันการแปลผล อัตราส่วนความน่าจะเป็นภายหลังของตัวแบบ  $\frac{p(M_0 | D)}{p(M_1 | D)}$  เมื่อตัวแบบ  $M_0$  เป็นตัวแบบ ที่มีตัวแปรอิสระน้อยกว่าตัวแบบ  $M_1$  อย่างน้อย 1 ตัว สำหรับหลักการในการพิจารณา อัตราส่วนความน่าจะเป็นภายหลังของการเปรียบเทียบ 2 ตัวแบบ มีดังนี้

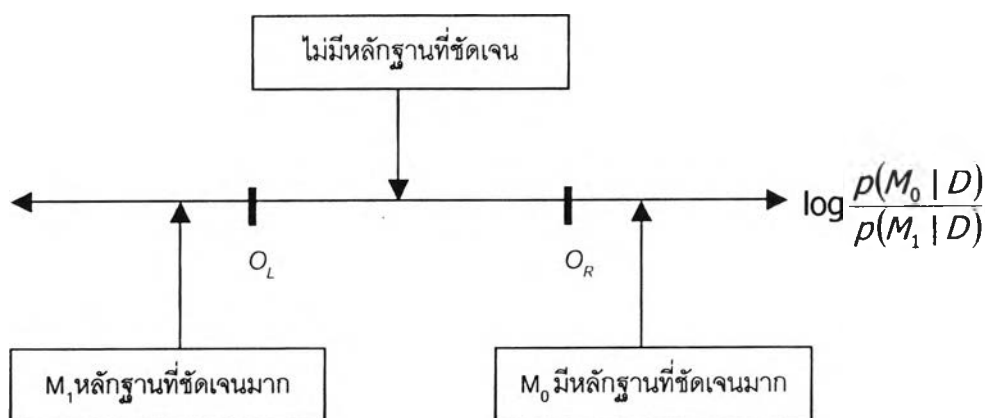
1) ถ้าล็อกออดส์ภายหลัง (Log Posterior Odds) มีค่าเป็นบวก แสดงว่าข้อมูลมีความชัดเจนในการสนับสนุนตัวแบบอย่างง่าย ดังนั้นเราจะปฏิเสธ  $M_1$  และมาพิจารณา  $M_0$  เราสามารถกำหนดล็อกออดส์ภายหลัง (Log Posterior Odds) เป็นค่าคงที่บวก  $O_R = a$  เมื่อ  $a$  เป็นค่าคงที่ที่กำหนดจากสมการ (2.24) ก่อนที่จะปฏิเสธ  $M_1$

2) ถ้าล็อกออดส์ภายหลัง (Log Posterior Odds) มีค่าน้อยและเป็นลบ แสดงว่าข้อมูลที่มีอยู่ไม่มีความชัดเจนในการสนับสนุนตัวแบบอย่างง่าย ดังนั้นเราจะเก็บตัวแบบทั้งสองนี้เอาไว้ก่อน

3) ถ้าล็อกออดส์ภายหลัง (Log Posterior Odds) มีค่ามากและเป็นลบ นั่นคือมีค่าน้อยกว่า  $O_L = -\log(a)$  เมื่อ  $a$  เป็นค่าคงที่ที่กำหนดจากสมการ (2.24) ดังนั้นเราจะปฏิเสธ  $M_0$  และจะพิจารณา  $M_1$

การเปรียบเทียบตัวแบบจากหลักการข้างต้นสามารถพิจารณาได้จากรูปที่ 2.2





รูปที่ 2.2 แสดงการแปลผลของล็อกออดส์ภายหลัง (Log Posterior Odds) สำหรับวิธีออกส์แคม วินโดว์ (Occam's Window)

วิธีการที่จะใช้หาปริภูมิตัวแบบตามหลักการของออกส์แคม วินโดว์ (Occam's Window) ข้างต้น เรียกว่า “กระบวนการ Up - Down” ซึ่งเป็นการใช้กระบวนการ Up และกระบวนการ Down ในการค้นหาตัวแบบ โดยกระบวนการ Up เป็นการค้นหาตัวแบบโดยการเพิ่มตัวแปร ส่วนกระบวนการ Down เป็นการค้นหาตัวแบบโดยการลดตัวแปร ซึ่งมีรายละเอียดดังนี้

#### กระบวนการ Up - Down

ขั้นตอนแรกของการเลือกตัวแบบเริ่มต้น ในทางปฏิบัติเราจะเลือกตัวแบบเริ่มต้นจากตัวแบบที่เป็นไปได้ทั้งหมด ซึ่งวิธีการในการค้นหาตัวแบบเริ่มต้นจะมี 2 วิธี นั่นคือ

“Up” เป็นกระบวนการในการค้นหาตัวแบบเริ่มต้นโดยการเพิ่มตัวแปร และ “Down” เป็นกระบวนการในการค้นหาตัวแบบเริ่มต้นโดยการลดตัวแปร เมื่อเริ่มจากตัวแบบที่ได้จากการกำหนดตัวแปร ขั้นตอนแรกจะใช้กระบวนการ Up และจะทำการกำหนดตัวแบบเริ่มต้นจากกระบวนการ Down

กำหนดให้  $A$  และ  $C$  เป็นสมาชิกของปริภูมิตัวแบบ  $M$  เมื่อ  $A$  แทนตัวแบบที่ได้รับการยอมรับ และ  $C$  แทนตัวแบบภายใต้การพิจารณา สำหรับทั้งสองกระบวนการจะเริ่มจากการกำหนด  $A = \phi$  และ  $C$  เท่ากับตัวแบบเริ่มต้นที่ได้จากการกำหนดโดยหลักการของออกแคมส์ วินโดว์ (Occam's Window) ข้างต้น

กระบวนการ Down สำหรับการคัดเลือกตัวแบบ

- 1) เลือกตัวแบบ  $M$  จาก  $C$
- 2)  $C \leftarrow C - M$  และ  $A \leftarrow A + M$
- 3) เลือกตัวแบบย่อย  $M_0$  จาก  $M$  โดยการลดตัวแปรออกจาก  $M$
- 4) คำนวณค่า  $B = \log \frac{p(M_0 | D)}{p(M | D)}$
- 5) ถ้า  $B > O_R$  แล้ว  $A \leftarrow A - M$  และถ้า  $M_0 \notin C$  แล้ว  $C \leftarrow C + M_0$
- 6) ถ้า  $O_L \leq B \leq O_R$  แล้วถ้า  $M_0 \notin C$  ดังนั้น  $C \leftarrow C + M_0$
- 7) ถ้ามีตัวแบบย่อย  $M$  ให้กลับไปทำในขั้นตอนที่ 3
- 8) ถ้า  $C \neq \emptyset$  ให้กลับไปทำในขั้นตอนที่ 1

กระบวนการ Up สำหรับการคัดเลือกตัวแบบ

- 1) เลือกตัวแบบ  $M$  จาก  $C$
- 2)  $C \leftarrow C - M$  และ  $A \leftarrow A + M$
- 3) เลือกตัวแบบ  $M_1$  จาก  $M$  โดยการเพิ่มตัวแปรเข้าไปใน  $M$
- 4) คำนวณค่า  $B = \log \frac{p(M | D)}{p(M_1 | D)}$
- 5) ถ้า  $B > O_L$  แล้ว  $A \leftarrow A - M$  และถ้า  $M_1 \notin C$  แล้ว  $C \leftarrow C + M_1$
- 6) ถ้า  $O_L \leq B \leq O_R$  แล้วถ้า  $M_1 \notin C$  ดังนั้น  $C \leftarrow C + M_1$
- 7) ถ้ามีตัวแบบย่อย  $M$  ให้กลับไปทำในขั้นตอนที่ 3
- 8) ถ้า  $C \neq \emptyset$  ให้กลับไปทำในขั้นตอนที่ 1

**2.7.3 วิธีการเจ็ลี่ยตัวแบบของเบส์โดยการหาค่าประกอบของตัวแบบด้วยเทคนิคมอนติคาร์โลโดยใช้ลูกโซ่มาร์คอฟ (Markov Chain Monte Carlo Model Composition (MC<sup>3</sup>))**

วิธีการเจ็ลี่ยตัวแบบของเบส์นั้นมีสิ่งสำคัญ 2 ประการ คือ การหาค่าความน่าจะเป็นภายหลัง และการหาปริภูมิตัวแบบ สำหรับวิธีการหาปริภูมิตัวแบบนั้นนอกจากวิธีออกส์แคมวินโดว์ (Occam's Window) ที่ได้กล่าวมาแล้วข้างต้น ราวฟเทอริ เมดิแกน และ โฮเอ็ทิง (Raftery Madigan and Hoeting, 1997) ยังได้แนะนำการใช้วิธีการเจ็ลี่ยตัวแบบของเบส์โดยการหาค่าประกอบของตัวแบบด้วยเทคนิคมอนติคาร์โลโดยใช้ลูกโซ่มาร์คอฟ (BMA<sub>MC<sup>3</sup></sub>) สำหรับการหาค่าความน่าจะเป็นภายหลัง และการหาปริภูมิตัวแบบสำหรับการเจ็ลี่ยตัวแบบ ซึ่งเป็นการ

นำเทคนิคมอนติคาร์โล โดยอาศัยโครงสร้างของลูกโซ่มาร์คอฟมาประยุกต์ใช้เพื่อหาค่าประกอบของตัวแบบ หลักการของวิธี  $BMA_{MC3}$  จะเหมือนกับหลักการของวิธีการคัดเลือกตัวแปรของเบส์ (BVS) ดังนั้นจะไม่ขอกล่าวถึงแนวคิดและทฤษฎีต่าง ๆ อีก (สามารถดูรายละเอียดเกี่ยวกับแนวคิดและทฤษฎีได้ในหัวข้อ 2.6) แต่วิธี BVS นั้นจะคัดเลือกตัวแบบเพียงรูปแบบเดียวที่มีความดีในการถูกเลือกสูงสุด ซึ่งจะเป็นตัวแบบที่มีค่าความน่าจะเป็นภายหลังสูงสุดด้วย ในขณะที่วิธีการ  $BMA_{MC3}$  จะนำตัวแบบในทุกรูปแบบที่ปรากฏอยู่ในปริภูมิตัวแบบมาเฉลี่ยกัน โดยใช้ความน่าจะเป็นภายหลังเป็นตัวถ่วงน้ำหนัก เพื่อความเข้าใจที่ชัดเจน ผู้วิจัยขอยกตัวอย่างประกอบเพื่อเปรียบเทียบความแตกต่างระหว่างวิธี BVS และวิธี  $BMA_{MC3}$  ดังนี้

สมมติว่าใช้ข้อมูลนำเข้าชุดเดียวกัน โดยที่กำหนด

1)  $y$  เป็นเวกเตอร์ที่บรรจุข้อมูลตัวแปรตาม

2)  $X$  เป็นเมทริกซ์ของตัวแปรอิสระ

3) จำนวนรอบในการค้นหาพารามิเตอร์ หรือความยาวของลูกโซ่มาร์คอฟ สมมติให้เท่ากับ 10,000

การเปรียบเทียบวิธี BVS และวิธี  $BMA_{MC3}$  ดังแสดงในรูปที่ 2.3



## 2.8 วิธีการถดถอยแบบขั้นบันได (Stepwise Regression Method (SR))

วิธีการนี้เป็นวิธีการคัดเลือกตัวแปรอิสระแบบเลือกเข้า โดยในแต่ละขั้นตอนของการเลือกตัวแปรอิสระเข้าสู่สมการถดถอยจะตรวจสอบตัวแปรอิสระที่มีในสมการถดถอยก่อนที่ตัวแปรอิสระตัวล่าสุดจะเพิ่มเข้าในสมการโดยวิธีการกำจัดตัวแปรอิสระแบบถดถอยหลังเสียก่อน ซึ่งสามารถแสดงขั้นตอนของวิธีการถดถอยแบบขั้นบันไดได้ดังนี้<sup>1</sup>

1) สร้างสมการถดถอยโดยเริ่มจากไม่มีตัวแปรอิสระอยู่ในสมการ

2) เลือกตัวแปรอิสระที่มีสัมประสิทธิ์สหสัมพันธ์ (correlation coefficient) กับตัวแปรตาม ( $y$ ) สูงสุดเข้าสู่สมการเป็นตัวแปรแรก และทดสอบว่าตัวแปรอิสระดังกล่าวมีนัยสำคัญหรือไม่ หากตัวแปรอิสระดังกล่าวไม่มีนัยสำคัญ จะได้สมการถดถอยที่เหมาะสมคือ  $y = \bar{y}$  แต่ถ้าตัวแปรอิสระดังกล่าวมีนัยสำคัญจะทำในขั้นตอนต่อไป

3) คำนวณค่าสถิติเอฟบางส่วนสำหรับทุกตัวแปรอิสระที่ไม่อยู่ในสมการ

4) ค่าสถิติเอฟบางส่วนที่มากที่สุด ( $F_U$ ) จะถูกเปรียบเทียบกับค่า  $F$  ณ ระดับนัยสำคัญที่กำหนด ( $F_o$ )

- ถ้า  $F_U < F_o$  จะไม่นำตัวแปรอิสระที่มีค่าสถิติเอฟบางส่วนมากที่สุดนั้นเข้าสู่สมการถดถอย
- ถ้า  $F_U > F_o$  จะนำตัวแปรอิสระที่มีค่าสถิติเอฟบางส่วนมากที่สุดนั้นเข้าสู่สมการถดถอย และคำนวณค่าสัมประสิทธิ์ของสมการถดถอยเมื่อนำตัวแปรอิสระนั้นเข้าสู่สมการ ด้วยวิธีกำลังสองน้อยสุด

5) คำนวณค่าสถิติเอฟบางส่วนของทุกตัวแปรอิสระที่อยู่ในสมการถดถอย

6) ค่าสถิติเอฟบางส่วนที่น้อยที่สุด ( $F_L$ ) จะถูกเปรียบเทียบกับค่า  $F$  ณ ระดับนัยสำคัญที่กำหนด ( $F_o$ )

- ถ้า  $F_L < F_o$  จะตัดตัวแปรอิสระที่มีค่าสถิติเอฟบางส่วนน้อยที่สุดนั้นออกจากสมการถดถอย และคำนวณค่าสัมประสิทธิ์ของสมการถดถอย เมื่อตัดตัวแปรอิสระนั้นแล้ว

---

<sup>1</sup> นุชรินทร์ ทิพย์วรรณกร, "การเปรียบเทียบค่าพยากรณ์ที่ได้จากตัวแบบที่คัดเลือกตัวแปรด้วยวิธีเบสส์เซียน วิธีการกำจัดตัวแปรแบบถดถอยหลัง และวิธีการถดถอยแบบขั้นบันได ในการวิเคราะห์ความถดถอยพหุนามแบบลำดับขั้น," (วิทยานิพนธ์ปริญญาโทมหาบัณฑิต ภาควิชาสถิติ บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2540), หน้า 20.

- ถ้า  $F_L > F_0$  จะไม่ตัดตัวแปรอิสระที่มีค่าสถิติเอฟบางส่วนน้อยที่สุดนั้น  
ออกจากสมการถดถอย

7) ถ้าไม่มีตัวแปรใดเข้าและออกจากสมการถดถอยแล้ว จะได้สมการถดถอยที่เหมาะสม แต่ถ้ายังมีตัวแปรอิสระใดที่เป็นไปตามเงื่อนไขของการเข้าหรือออกจากสมการ ให้กลับไปทำในขั้นตอนที่ 3

จากขั้นตอนของวิธีการถดถอยแบบขั้นบันไดจะเห็นได้ว่าต้องอาศัยวิธีการทดสอบเอฟบางส่วน และการหาสัมประสิทธิ์สหสัมพันธ์ ซึ่งจะกล่าวถึงรายละเอียดดังนี้

### 2.8.1 การทดสอบเอฟบางส่วน (Partial F-test)<sup>1</sup>

การทดสอบเอฟบางส่วนเป็นการทดสอบที่ใช้ตรวจสอบนัยสำคัญของ  $\beta_j$  เพื่อตัดสินใจว่าตัวแปรอิสระใดควรอยู่ในสมการหรือตัวแปรอิสระใดควรตัดออกจากสมการถดถอย โดยที่  $\beta_j$  จะปรากฏอยู่ ณ ตำแหน่งใดในแบบจำลองก็ได้ แต่ในทางปฏิบัติจะทำโดยถือว่าตัวแปรอิสระนั้นเข้าสู่สมการถดถอยเป็นตัวสุดท้าย

จากสมการถดถอยแสดงความสัมพันธ์ระหว่างตัวแปรตาม ( $y$ ) กับตัวแปรอิสระ ( $x_j$ ) คือ

$$(2.27) \quad y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon$$

เราสามารถหาค่าตัวประมาณ  $\hat{\beta} = (\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k)'$  โดยวิธีกำลังสองน้อยสุด และค่าผลบวกกำลังสองที่เกี่ยวข้องเป็นดังนี้

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

เมื่อ  $X$  คือเมทริกซ์ของตัวแปรอิสระขนาด  $n \times (k+1)$  ซึ่งรวมเทอมของค่าคงที่

$$2) \quad SSR_1 = \hat{\beta}' X'y$$

$$3) \quad SSE_1 = y'y - \hat{\beta}' X'y \quad \text{และ}$$

$$MSE_1 = \hat{\sigma}_1^2$$

$$= \frac{1}{n - (k + 1)} (y'y - \hat{\beta}' X'y)$$

---

<sup>1</sup> นพมาศ อัครจันท์โชติ, "การเปรียบเทียบวิธีการสร้างตัวแบบในการวิเคราะห์ความถดถอยพหุนามกรณีที่มี 2 ตัวแปรอิสระซึ่งเกิดอันตรกิริยา," (วิทยานิพนธ์ ปริญญาโทบริหารธุรกิจ สาขาวิชาสถิติ บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2539), หน้า 15-17.

กำหนดให้

$$(2.28) \quad y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \beta_{k+1} x_{k+1} + \dots + \beta_p x_p + \varepsilon$$

เป็นสมการถดถอยแสดงความสัมพันธ์ระหว่างตัวแปรตาม ( $y$ ) กับตัวแปรอิสระ ( $x_j$ ) โดยที่  $p > k$  จากสมการ (2.28) สามารถหาค่าตัวประมาณ  ${}_2\hat{\beta} = ({}_2\hat{\beta}_0, {}_2\hat{\beta}_1, \dots, {}_2\hat{\beta}_k, {}_2\hat{\beta}_{k+1}, \dots, {}_2\hat{\beta}_p)'$  โดยวิธีกำลังสองน้อยสุด และค่าผลบวกกำลังสองที่เกี่ยวข้องเป็นดังนี้

$$1) \quad {}_2\hat{\beta} = ({}_2X'{}_2X)^{-1} {}_2X'y$$

เมื่อ  ${}_2X$  คือเมทริกซ์ของตัวแปรอิสระขนาด  $n \times (p+1)$  ซึ่งรวมเทอมของค่าคงที่

$$2) \quad SSR_2 = {}_2\hat{\beta}'{}_2X'y$$

$$3) \quad SSE_2 = y'y - {}_2\hat{\beta}'{}_2X'y \quad \text{และ}$$

$$MSE_2 = \hat{\sigma}_2^2$$

$$= \frac{1}{n - (p+1)} (y'y - {}_2\hat{\beta}'{}_2X'y)$$

จากผลลัพธ์ข้างต้นพบว่า Extra Sum of Squares Regression (ESSR) คือ

$$ESSR = SSR_2 - SSR_1$$

$$= {}_2\hat{\beta}'{}_2X'y - {}_1\hat{\beta}'{}_1X'y$$

ซึ่ง Extra Sum of Squares นี้เป็นค่าผลบวกกำลังสองของตัวแปรอิสระ  $x_{k+1}, x_{k+2}, \dots, x_p$  ที่เพิ่มขึ้นมาจากสมการ (2.27)

โดยอาศัยความรู้เรื่อง Distribution of Quadratic Form เราสามารถพิสูจน์ได้ว่า

$$\frac{ESSR}{\sigma^2} \sim \chi^2_{(p-k)}$$

$$\frac{SSE_2}{\sigma^2} \sim \chi^2_{(n-(p+1))}$$

$$\begin{aligned} \text{ดังนั้น ค่าทดสอบเอฟบางส่วน} &= \frac{ESSR / (p-k)\sigma^2}{SSE_2 / (n-p-1)\sigma^2} \\ &= \frac{ESSR / (p-k)}{\hat{\sigma}_2^2} \end{aligned}$$

จะมีการแจกแจงเอฟบางส่วน ณ ระดับชั้นความเสรี  $(p-k, n-p-1)$ <sup>1</sup> และเราจะปฏิเสธสมมติฐาน  $H_0 : \beta_{k+1} = \beta_{k+2} = \dots = \beta_p = 0$  ณ ระดับนัยสำคัญ  $\alpha$  เมื่อค่าทดสอบเอฟบางส่วน มากกว่า  $F_{1-\alpha, p-k, n-p-1}$

จากความรู้ในเรื่องการทดสอบเอฟบางส่วนนี้ เราสามารถนำมาประยุกต์ใช้กับวิธีการหาสมการถดถอยที่ดีที่สุด โดยวิธีการถดถอยแบบขั้นบันไดได้ดังนี้

จากสมการถดถอย  $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \varepsilon$  เราจะหาค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Squares Error (MSE)) และผลบวกกำลังสองของความถดถอย (Sum of Squares Regression) ของเฉพาะ  $X_j$  ได้จากสมการต่อไปนี้

$$MSE = \hat{\sigma}^2 = \frac{1}{(n-p-1)} (y'y - \hat{\beta}'x'y)$$

$$\text{เมื่อ } SS(x_j | x_1, x_2, \dots, x_{j-1}, x_{j+1}, \dots, x_p) = SS(x_1, x_2, \dots, x_p) - SS(x_1, x_2, \dots, x_{j-1}, x_{j+1}, \dots, x_p)$$

ดังนั้นค่าสถิติเอฟบางส่วน คือ

$$F_c = \frac{SS(x_j | x_1, x_2, \dots, x_{j-1}, x_{j+1}, \dots, x_p)}{\hat{\sigma}^2}$$

โดยจะปฏิเสธสมมติฐาน  $H_0 : \beta_j = 0$  ณ ระดับนัยสำคัญ  $\alpha$  เมื่อ  $F_c > F_{1-\alpha, p-k, n-p-1}$

<sup>1</sup>  $U = \frac{\chi_1^2 / \nu_1}{\chi_2^2 / \nu_2} \sim F(\nu_1, \nu_2)$



## 2.8.2 สัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) <sup>1</sup>

สัมประสิทธิ์สหสัมพันธ์เป็นตัวสถิติที่ใช้วัดความสัมพันธ์เชิงเส้นของตัวแปรว่ามีความสัมพันธ์กันมากน้อยเพียงใด ซึ่งค่าสัมประสิทธิ์สหสัมพันธ์จะเป็นค่าที่บอกทั้งทิศทางและขนาดของสหสัมพันธ์ โดยจะมีค่าอยู่ระหว่าง -1 ถึง 1 ถ้าค่าสัมประสิทธิ์สหสัมพันธ์เข้าใกล้ -1 แสดงว่าตัวแปรทั้งสองมีความสัมพันธ์เชิงเส้นกันมากในทางตรงกันข้าม ถ้าเข้าใกล้ 1 แสดงว่าตัวแปรทั้งสองมีความสัมพันธ์เชิงเส้นกันมากในทิศทางเดียวกัน แต่ถ้าค่าสัมประสิทธิ์สหสัมพันธ์มีค่าเป็นศูนย์หรือเข้าใกล้ศูนย์ แสดงว่าตัวแปรทั้งสองไม่มีความสัมพันธ์เชิงเส้นต่อกัน หรือมีความสัมพันธ์เชิงเส้นกันน้อย สำหรับสัมประสิทธิ์สหสัมพันธ์ที่ใช้วัดความสัมพันธ์ระหว่างตัวแปรสองตัวสามารถจำแนกได้ดังนี้

1) สัมประสิทธิ์สหสัมพันธ์เชิงเดียว (Simple Correlation Coefficient) เป็นตัวสถิติที่ใช้วัดความสัมพันธ์ระหว่าง 2 ตัวแปรใด ๆ ซึ่งมีสูตรดังนี้

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

เมื่อ  $n$  เป็นขนาดตัวอย่าง  
 $y_i$  เป็นตัวแปรตามที่  $i$   
 และ  $x_i$  เป็นตัวแปรอิสระที่  $i$

2) สัมประสิทธิ์สหสัมพันธ์บางส่วน (Coefficient of Partial Correlation) เป็นตัวสถิติที่ใช้เป็นค่าวัดระดับและทิศทางของความสัมพันธ์เชิงเส้นระหว่างตัวแปร 2 ตัวแปร โดยที่ควบคุมให้ตัวแปรอื่น ๆ คงที่ เช่น กรณีตัวแปรอิสระ 3 ตัวแปร ได้แก่  $x_1, x_2, x_3$  และตัวแปรตาม  $y$  ถ้าต้องการหาสัมประสิทธิ์สหสัมพันธ์บางส่วนของตัวแปรตาม  $y$  กับตัวแปรอิสระ  $x_1$  โดยควบคุมให้  $x_2$  และ  $x_3$  คงที่ จะใช้สัญลักษณ์  $r_{y1.23}$  สำหรับการคำนวณหาค่าของสัมประสิทธิ์สหสัมพันธ์บางส่วนระหว่างตัวแปรคู่ใด ๆ นั้นหาได้จาก

<sup>1</sup> นพมาศ อัครจันทโชติ, "การเปรียบเทียบวิธีการสร้างตัวแบบในการวิเคราะห์ความถดถอยพหุนามกรณีที่มี 2 ตัวแปรอิสระซึ่งเกิดอันตรกิริยา," (วิทยานิพนธ์ ปริญญาโทบริหารธุรกิจ สาขาวิชาสถิติ บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2539), หน้า 17-18.

$$r_{ij,1,2,3,\dots,i-1,j+1,\dots,j-1,j+1,\dots,k}^2 = \left( \frac{a_{ij}^2}{a_{ii}a_{jj}} \right)$$

และ

$$r_{ij,1,2,3,\dots,j-1,i+1,\dots,j-1,j+1,\dots,k} = \text{sign} \sqrt{r^2}$$

$$R = \begin{bmatrix} 1 & a_{12} & \dots & r_{1k} \\ a_{21} & 1 & \dots & r_{2k} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ r_{k1} & r_{k2} & \dots & 1 \end{bmatrix}_{k \times k}$$

$$A = R^{-1} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1k} \\ a_{21} & a_{22} & \dots & a_{2k} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ a_{k1} & a_{k2} & \dots & a_{kk} \end{bmatrix}_{k \times k}$$

เมื่อ  $r_{ij,1,2,3,\dots,j-1,i+1,\dots,j-1,j+1,\dots,k}$  เป็นค่าสัมประสิทธิ์สหสัมพันธ์บางส่วนระหว่างตัวแปรที่  $i$  และ  $j$  โดยตัวแปรอื่นคงที่

$r_{ij}$  เป็นสัมประสิทธิ์สหสัมพันธ์เชิงเดียวระหว่างตัวแปรที่  $i$  และ  $j$

$k$  เป็นจำนวนตัวแปรทั้งหมด

$a_{ij}$  เป็นสมาชิกแถวที่  $i$  แนวตั้งที่  $j$  ของเมทริกซ์ผกผันของเมทริกซ์สหสัมพันธ์ ( $R$ )

$R$  เป็นเมทริกซ์สหสัมพันธ์

และ  $A$  เป็นเมทริกซ์ผกผันของเมทริกซ์สหสัมพันธ์

ส่วนเครื่องหมายของสัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปรตามกับตัวแปรอิสระใด ๆ นั้นกำหนดตามเครื่องหมายของสัมประสิทธิ์การถดถอยของตัวแปรอิสระนั้น