



## บทที่ 2

### การทบทวนผลงานที่ผ่านมา

แบบจำลองรูปแบบการเดินทาง (Modal Split Model) เป็นแบบจำลองหนึ่งในแบบจำลองต่อเนื่อง (Sequential Model) ซึ่งเป็นแบบจำลองที่นิยมใช้ในการศึกษาและวางแผนคมนาคมขนส่งในเมือง แบบจำลองต่อเนื่องจะประกอบด้วยแบบจำลองการเกิดการเดินทาง (Trip Generation Model) แบบจำลองการกระจายการเดินทาง (Trip Distribution Model) แบบจำลองแนวเส้นทางการเดินทาง (Traffic Assignment Model) และแบบจำลองรูปแบบการเดินทาง (Modal Split Model)

แบบจำลองรูปแบบการเดินทาง (Modal Split Model) คือแบบจำลองที่ใช้ในการอธิบายการเลือกรูปแบบของการเดินทางและขนส่ง ในการวิจัยนี้จะเน้นการศึกษาถึงรูปแบบการขนส่งสินค้า โดยเริ่มจากการจำลองสภาพการขนส่งด้วยระบบขนส่งทางรถบรรทุก รถไฟ หรือเรือ ในสภาพปัจจุบัน (โดยคิดออกมาเป็นจำนวนร้อยละของการขนส่งสินค้าทั้งหมดที่เกิดขึ้น) จากนั้นจึงทดลองพยากรณ์ตัวแปรต่างๆย้อนกลับโดยแทนค่าในแบบจำลอง ซึ่งจะทำให้ทราบปริมาณการขนส่งสินค้าโดยรูปแบบต่างๆ ว่าใกล้เคียงกับที่เป็นจริงหรือไม่ ซึ่งต่อไปอาจใช้แบบจำลองนี้พยากรณ์ไปในอนาคต จะทำให้ได้ปริมาณการขนส่งในอนาคต ปริมาณการขนส่งนี้จะช่วยให้สามารถวางแผนการคมนาคมขนส่งให้มีความเหมาะสมกับสภาพการณ์ที่ควรจะเป็นมากยิ่งขึ้น พร้อมกันนั้นก็สามารถใช้เป็นข้อพิจารณาเพื่อปรับปรุงระบบการคมนาคมขนส่งและทดสอบระบบใหม่ๆ ด้วย

#### 2.1 ชนิดของแบบจำลองรูปแบบการเดินทาง (Type of Modal Split Model) (1)

การพัฒนาแบบจำลองรูปแบบการเดินทาง (Modal Split Model) พอดีแบ่งออกได้เป็น 3 ลักษณะ คือ

1. แบบจำลองการเกิดการเดินทางและจำแนกรูปแบบโดยตรง (Direct Generation and Modal Split Trips)

2. แบบจำลองรูปแบบการเดินทางที่จุดปลาย (Trip End Modal Split Model)

3. แบบจำลองการเดินทางแบบสับเปลี่ยนกัน (Trip Interchange Modal Split Model)

ในการศึกษาดังนี้ จะทำการศึกษารูปแบบการเดินทางของสินค้าของแต่ละรูปแบบการขนส่ง ทางถนน ทางรถไฟ และทางเรือ โดยคิดเป็นร้อยละของการขนส่งทั้งหมดที่ใช้ในระบบการขนส่งสินค้า ฉะนั้นจึงใช้วิธีแบบจำลองการเดินทางแบบสับเปลี่ยนกัน เพราะแบบจำลองนี้จะประมาณอัตราส่วนของการเดินทางระหว่างพื้นที่ได้อย่างเหมาะสม รูปที่ 2.1 แสดงตำแหน่งแบบจำลองรูปแบบการเดินทางแบบสับเปลี่ยนกัน

การสร้างแบบจำลองรูปแบบการเดินทาง สามารถจำแนกเป็นวิธีการใหญ่ๆ ได้ 2 วิธี คือ

2.1.1 Aggregate Analysis

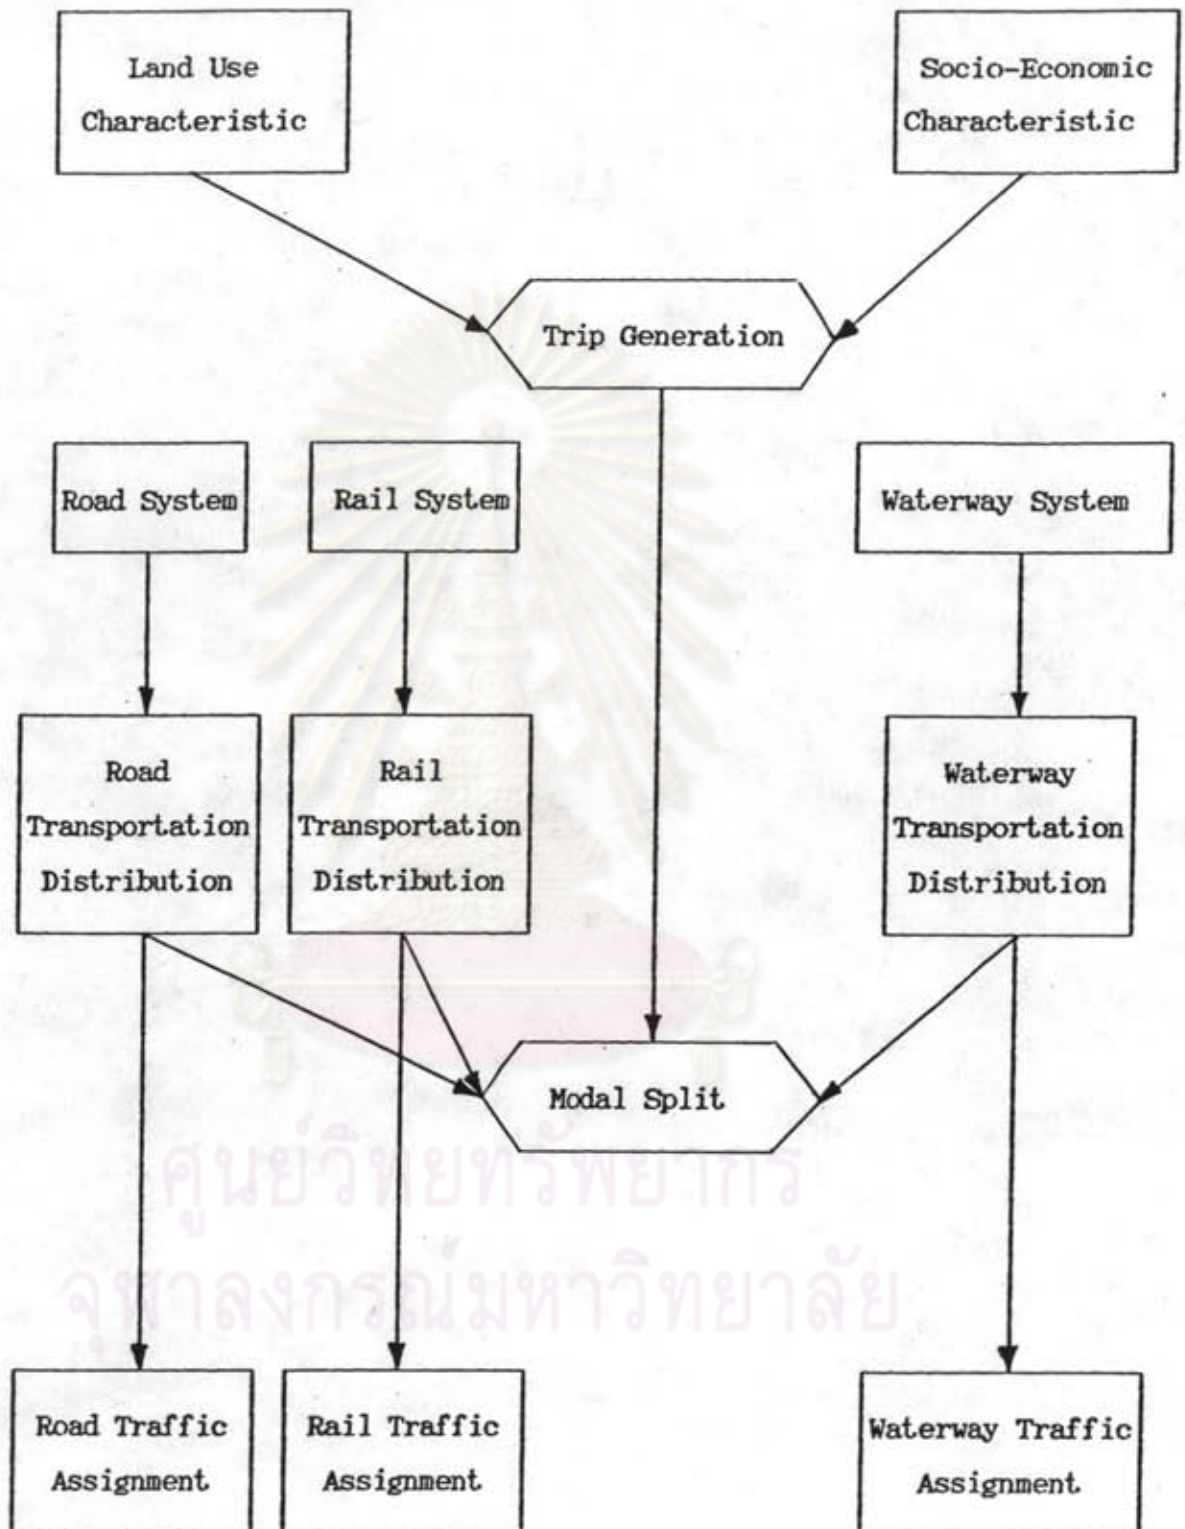
2.1.2 Disaggregate Analysis

วิธีการแรกเป็นการวิเคราะห์หารูปแบบการเดินทางอย่างกว้างๆ ซึ่งนิยมใช้มากในการศึกษาเพื่อวางแผนระบบระดับภูมิภาค โดยจะทำการแบ่งพื้นที่ที่ทำการศึกษาออกเป็นพื้นที่ย่อยๆ (Zone) หลายพื้นที่ย่อยซึ่งนิยมใช้กันมากในเขตเมือง ประชากรอยู่หนาแน่นและรูปลักษณะในการใช้ที่ดิน สภาพเศรษฐกิจและสังคมแตกต่างกัน ส่วนวิธีหลังเป็นวิธีการที่ต้องดำเนินการให้ลึกซึ้งกว่าและให้ผลที่มีความละเอียดมากกว่า เพราะเป็นการศึกษาในระดับหน่วยย่อยคือ ครอบครัว หรือบุคคล ในศึกษานี้จะใช้วิธี Aggregate Analysis เนื่องจากเป็นการวิเคราะห์ในระดับพื้นที่กรุงเทพมหานครและปริมณฑล ซึ่งมีลักษณะของการใช้ที่ดินแตกต่างกันมากทั้งยังมีลักษณะการพัฒนาเมืองที่เปลี่ยนแปลงได้อย่างรวดเร็ว

## 2.2 แบบจำลอง Transportation Choice Models (2)

การพัฒนาแบบจำลองประเภทนี้ เริ่มต้นโดยอาดิยทฤษฎี "Utility Maximization" เป็นหลัก นั่นก็คือผู้ตัดสินใจในการเลือกรูปแบบการขนส่ง สามารถจะให้มูลค่าหรือจัดลำดับให้กับแนวทางเลือกต่างๆ (รูปแบบการขนส่ง หรือวิธีการขนส่ง) ในรูปของตัวแปรอธิบายความพอใจของตนเอง (ซึ่งก็มีพื้นที่





รูปที่ 2.1 แสดงตำแหน่งของแบบจำลองรูปแบบการเดินทางแบบสลับเปลี่ยนกัน

ฐานมาจากผลประโยชน์สูงสุดที่เกิดขึ้น) หรือบุคคลทั่วไปจะเลือกเดินทางโดยรูปแบบหรือวิธีการที่ให้ความสะดวก รวดเร็ว ปลอดภัย และประหยัด นั่นคือได้ผลประโยชน์มากที่สุด ฉะนั้นเนื้อหาของทฤษฎีนี้จึงถูกประยุกต์ใช้เพื่อสร้างแบบจำลองอธิบายแนวทางการตัดสินใจของผู้เดินทาง โดยอาศัยตัวแปรที่อธิบายมูลค่าการเดินทางต่างๆ เช่น เวลาในการเดินทาง ค่าใช้จ่ายในการเดินทาง ฯลฯ เป็นหลัก

ตามปกติผู้ตัดสินใจในลักษณะข้างต้นจะต้องมีข้อมูลที่ค่อนข้างครบ เพื่อสามารถตัดสินใจได้ถูกต้อง แต่เรื่องนั้นคงเป็นไปได้ในสาขาการคมนาคมขนส่ง เนื่องจากรูปแบบและวิธีการขนส่งชนิดต่างๆที่จะเลือกต้องเน้นประสิทธิภาพที่เกิดขึ้นกับตนเองจึงมีความเข้าใจละเอียด อย่างไรก็ตามเราสามารถประยุกต์แนวทาง "Random Utility" เพื่อช่วยอธิบายปรากฏการณ์หรือสภาพการตัดสินใจของผู้เดินทางได้

แนวทางดังกล่าวอธิบายว่า "ในสภาพที่เป็นจริง ประชากรไม่จำเป็นต้องเลือกเป้าหมายที่ดีที่สุดในการกระทำที่ดีที่สุด หรือเขาไม่แน่ว่าจะเลือกแนวทางเลือกที่ดีที่สุดเพื่อการกระทำอย่างเดิมอีกทุกครั้ง หรืออีกนัยก็คือ แนวทาง Random Utility เน้นอธิบายว่าประชากรแต่ละคนจะเลือกแนวทางเลือกของเขาซึ่งเขาคิดว่าน่าจะเป็นดีที่สุด ณ ขณะนั้น"

ในการเลือกแนวทางเลือกนั้น จะทำการหาค่า Utility ของแต่ละแนวทางเลือกแล้วจะทำการเลือกแนวทางเลือกที่ให้ค่า Utility มากที่สุด โดย Utility จะประกอบด้วย 2 ส่วนคือ

1. Observed Attributes หรือบางทีก็เรียกว่า Systematic Utility หรือ Representative Utility ค่าของส่วนนี้จะสามารถหาได้ โดยการสำรวจ เก็บข้อมูล รวบรวมข้อมูลต่างๆที่เกี่ยวข้อง และบ่งบอกออกมาเป็นมูลค่าได้

2. Unobserved Component หรือบางทีก็เรียกว่า Random Utility ค่าของส่วนนี้จะไม่สามารถหาได้ เพราะเป็นความไม่แน่นอน

### วิธีการทางคณิตศาสตร์

ให้  $U_{it}$  = Utility ของแนวทางเลือก  $i$  จากแนวทางเลือกทั้งหมด  $t$   
 $V_{it}$  = Representative Utility ของแนวทางเลือก  $i$   
 $E_{it}$  = Random Utility ของแนวทางเลือก  $i$

$$\therefore U_{it} = V_{it} + E_{it}$$

ในการเลือกแนวทางการเลือกนั้น จะเลือกแนวทางเลือกที่ให้ค่า Utility สูงที่สุด ดังนั้นในแต่ละแนวทางเลือกของแนวทางเลือกทั้งหมด  $t$  แนวทางเลือก จะเลือกแนวทางเลือก  $i$  ดีกว่าแนวทางเลือก  $j$  ของแนวทางเลือกทั้งหมด  $t$  แนวทางเลือก ก็ต่อเมื่อ Utility ของแนวทางเลือก  $i$  มีค่ามากกว่า Utility ของแนวทางเลือก  $j$  ของแนวทางเลือกทั้งหมด  $t$  แนวทางเลือก

$$U_{it} > U_{jt}$$

ให้ probability ของการเลือกแนวทางเลือก  $i$  เป็น  $P_{it}$

$$P_{it} = P(U_{it} > U_{jt})$$

### Utility Function

$$U_{it} = V_{it} + E_{it}$$

$$U_{jt} = V_{jt} + E_{jt}$$

$$\begin{aligned} \therefore P_{it} &= P(V_{it} + E_{it} > V_{jt} + E_{jt}) \\ &= P(E_{jt} - E_{it} < V_{it} - V_{jt}) \end{aligned}$$

ในการเลือกแนวทางเลือก  $i$  หรือแนวทางเลือก  $j$  นั้นเราไม่สามารถบอกได้ว่าแนวทางเลือกไหนจะดีกว่ากัน ถึงแม้ว่าเราจะทราบค่า  $V_{it}$  และ  $V_{jt}$  ก็ตาม แต่เราไม่สามารถหาค่า  $E_{it}$  และ  $E_{jt}$  ได้ แต่เราสามารถทำการหาค่า probability ที่  $E_{jt} - E_{it}$  น้อยกว่า  $V_{it} - V_{jt}$  ได้ โดยการสมมติให้  $E's = E_{jt} - E_{it}$

1. ถ้า  $E's$  มีการกระจายเป็นแบบ Normally Distribution

โดยมี

mean	=	0
variance	=	$\sigma_i^2$ , $\sigma_j^2$
covariance	=	$\sigma_{i,j}^2$



จะได้ probability ของการเลือกแนวทางเลือก  $i$  เป็น  $P_{it}$

$$P_{it} = \int_{-\infty}^{\left(\frac{v_{it}-v_{jt}}{\sigma}\right)} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}u^2} du$$

$$\text{โดย } \sigma^2 = \sigma_1^2 + \sigma_2^2 - 2\sigma_{1,2}$$

โดยทั่วไปจะกำหนดให้  $\sigma = 1$  เพื่อความสะดวกในการใช้งาน  
แบบจำลองชนิดนี้เรียกว่า "Binary Probit Model"

2. E's มีการกระจายเป็นแบบ Gumbel Distribution โดย  
ฟังก์ชันการแจกแจงสะสม (Cumulative Distribution Function) เป็น

$$F(E) = \frac{1}{1 + e^{-\mu E}}$$

$$\text{โดย } \mu > 0, -\infty < E < \infty$$

$$P_{it} = P\{U_{it} > U_{jt}\}$$

$$= \frac{e^{v_{it}}}{e^{\mu v_{it}} + e^{\mu v_{jt}}}$$

$$\text{โดยทั่วไป จะกำหนดให้ } \mu = 1$$

$$P_{it} = \frac{e^{v_{it}}}{e^{v_{it}} + e^{v_{jt}}}$$

แบบจำลองชนิดนี้เรียกว่า "Binary Logit Model" ในกรณีของ  
Multinomial Logit Model สมการจะเป็น

$$P_i = \frac{e^{v_i}}{\sum_{j \in C_t} e^{v_j}}$$

โดย  $C_t$  คือเซตของแนวทางเลือกทั้งหมด

ตัวอย่างของการใช้สมการ Logit Model พิจารณารูปแบบการเดินทาง 3 รูปแบบที่คนต้องเลือกในการเดินทางไปทำงาน คือ รถยนต์ส่วนตัว รถเมล์ และการเดิน โดย Systematic Utility Function ของแต่ละรูปแบบเป็นดังนี้

$$V_{\text{auto}} = 1.0 - 0.1 (TT_{\text{auto}}) - 0.05 (TC_{\text{auto}})$$

$$V_{\text{bus}} = -0.1 (TT_{\text{bus}}) - 0.05 (TC_{\text{bus}})$$

$$V_{\text{walk}} = -0.5 - 0.1 (TT_{\text{walk}})$$

โดย  $TT_i$  = เวลาการเดินทางของรูปแบบ  $i$ , (นาที)

$TC_i$  = ค่าใช้จ่ายในการเดินทางของรูปแบบ  $i$ , (ดอลลาร์)

สมมติให้เวลาในการเดินทางของรถยนต์ส่วนตัว, รถเมล์ และการเดินทางเป็น 5, 15 และ 20 นาที ตามลำดับ และค่าใช้จ่ายในการเดินทางของรถยนต์ส่วนตัวและรถเมล์เป็น \$ 0.60 และ \$ 0.50 ตามลำดับ

เมื่อแทนค่า  $TT_i$  และ  $TC_i$  ลงในสมการข้างบน ก็จะสามารของ Systematic Utility Function ได้ดังนี้

$$V_{\text{auto}} = 0.47, V_{\text{bus}} = -1.525, V_{\text{walk}} = -2.50$$

จากสมการ Logit Model

$$P_{\text{auto}} = \frac{e^{0.47}}{e^{0.47} + e^{-1.525} + e^{-0.50}} = \frac{1.6000}{1.8993} = 0.843$$

$$P_{\text{bus}} = \frac{e^{-1.525}}{e^{0.47} + e^{-1.525} + e^{-0.50}} = \frac{0.2172}{1.8993} = 0.114$$

$$\text{และ } P_{\text{walk}} = \frac{e^{-0.50}}{e^{0.47} + e^{-1.525} + e^{-0.50}} = \frac{0.0821}{1.8993} = 0.043$$

## 2.3 การประมาณค่าพารามิเตอร์ (Model Estimation)

การประมาณค่าพารามิเตอร์มีวิธีทำอยู่หลายวิธีคือ Least Square Method, Maximum Likelihood Method ฯลฯ ในการเลือกใช้วิธีการประมาณค่าพารามิเตอร์ ต้องพิจารณาจากรูปแบบของ Probability Function ซึ่งจะมีวิธีการประมาณค่าพารามิเตอร์ที่เหมาะสมแตกต่างกันออกไปในกรณีของแบบจำลองการเลือกรูปแบบการขนส่งสินค้าโดยใช้ Logit Model วิธีการที่เหมาะสมที่นิยมใช้ในการประมาณค่าพารามิเตอร์ Least Square Method ซึ่งจะประมาณค่าพารามิเตอร์ได้ใกล้เคียงความจริงที่สุด

วิธีการประมาณค่าพารามิเตอร์โดยใช้ Maximum Likelihood Method และ Least Square Method มีรายละเอียดดังต่อไปนี้

### 2.3.1 Maximum Likelihood Method

#### 1. Binary Logit Model

เป็นแบบจำลองที่ใช้สำหรับกรณีที่มีแนวทางเลือก 2 แนวทางเลือก คือ แนวทางเลือก  $i$  และทางเลือก  $j$  โอกาสที่คนที่  $n$  จะเลือกแนวทางเลือก  $i$  คือ

$$P_n(i) = P(U_{in} > U_{jn})$$

$$= \frac{1}{1 + e^{-\mu(V_{in} - V_{jn})}}$$

..... สมการที่ 1  
เพื่อความสะดวกในการคำนวณ โดยทั่วไปจะกำหนดให้  $\mu = 1$

$$\text{จะได้ } P_n(i) = \frac{1}{1 + e^{-\beta'X_n}}$$

$$\begin{aligned} \text{โดยที่ } \beta' &= \text{เวกเตอร์ของค่า } \beta = (\beta_1, \beta_2, \dots, \beta_k) \\ X_n &= \text{เวกเตอร์ผลต่างของค่า Attributes} \\ &= X_{in} - X_{jn} \end{aligned}$$

จากสมการที่ 1 จะเห็นว่าโอกาสที่คนที่  $n$  จะเลือกแนวทางเลือก 1 ขึ้นอยู่กับค่า  $\beta'$  ซึ่งเป็นค่าพารามิเตอร์นั่นเอง ในการประมาณค่าพารามิเตอร์



โดยใช้วิธี Maximum Likelihood มีขั้นตอนดังต่อไปนี้

ก. จัดทำ Likelihood Function

$$L^*(\beta_1, \beta_2, \dots, \beta_k) = \prod_{n=1}^N P_n(i)^{y_{in}} P_n(j)^{y_{jn}}$$

โดย  $L^*$  = Likelihood Function

$\beta_k$  =  $k_{th}$  Parameter

$N$  = จำนวนข้อมูล

$y_{in} = \begin{cases} 0 & \text{ในกรณีที่คนที่ } n \text{ เลือกแนวทางเลือก } i \\ 1 & \text{ในกรณีที่คนที่ } n \text{ เลือกแนวทางเลือก } j \end{cases}$

ข. จัดให้อยู่ในรูปแบบของ log ดังสมการ

$$\text{Log } L^*(\beta) = L(\beta) = \sum_{n=1}^N (Y_{in} \text{Log } P_n(i) + Y_{jn} \text{Log } P_n(j))$$

ค. Maximize Likelihood Function โดยการ derivative  $L(\beta)$  เกี่ยวกับ  $\beta_k$  แล้วให้เท่ากับศูนย์

$$\frac{\partial L(\beta)}{\partial \beta_k} = 0 \quad ; \quad k = 1, 2, 3, \dots, k$$

ซึ่งจากการทำ derivative ข้างต้น จะทำให้ได้สมการ  $k$  สมการ มีตัวแปร  $k$  ตัว คือ  $(\beta_1, \beta_2, \dots, \beta_k)$  แล้วแก้สมการหา  $\beta'$  ได้

## 2. Multinomial Logit Model

เป็นแบบจำลองที่ใช้ในกรณีที่ มีแนวทางเลือกมากกว่า 2 แนวทางเลือก คือมีแนวทางเลือกได้  $C_c$  ตัว รูปแบบของแบบจำลอง คือ

$$P_n(i) = \frac{e^{\beta'x_n}}{\sum_{j \in C_1} e^{\beta'x_{jn}}}$$

ขั้นตอนการคำนวณค่าพารามิเตอร์ โดยใช้ Maximum Likelihood Method มีดังนี้

ก. จัดทำ Likelihood Function

$$L^*(\beta') = \prod_{n=1}^N \prod_{i \in C_t} P_n(i)^{y_{in}}$$

$$= \prod_{n=1}^N \prod_{i \in C_t} \left( \frac{e^{\beta' x_{in}}}{\sum_{j \in C_t} e^{\beta' x_{jn}}} \right)$$

ข. จัดให้อยู่ในรูปแบบของ Natural Logarithm

$$\text{Log}_e L^*(\beta') = L(\beta') = \sum_{n=1}^N \sum_{i \in C_t} y_{in} (\beta' x_{in} - \text{Log}_e \sum_{j \in C_t} e^{\beta' x_{jn}})$$

ค. Maximize Likelihood Function โดยการ derivative  $L(\beta')$  เกี่ยวกับ  $\beta_k$  แล้วให้เท่ากับศูนย์

$$\frac{\partial L(\beta')}{\partial \beta} = \sum_{n=1}^N \sum_{i \in C_t} y_{in} \left( x_{ink} - \frac{\sum_{j \in C_t} e^{\beta' x_{jn}} x_{jnk}}{\sum_{j \in C_t} e^{\beta' x_{jn}}} \right)$$

หรือจัดอีกรูปแบบหนึ่งได้ดังนี้

$$\frac{\partial L(\beta')}{\partial \beta_k} = \sum_{n=1}^N \sum_{i \in C_t} (y_{in} - P_n(i)) x_{ink} = 0$$

### 2.3.2 Least Square Method

เมื่อพล็อตค่าตัวแปร  $x$  และ  $y$  ลงในกราฟแล้ว การลากเส้นตรงผ่านกลุ่มข้อมูลอาจจะลากเส้นตรงได้หลายเส้นขึ้นกับค่า  $\alpha$  และ  $\beta$  ซึ่งคือค่าเฉลี่ยของ  $y$  เส้นที่ดีที่สุดจะต้องเป็นเส้นที่ลากผ่านข้อมูลโดยมีความผิดพลาดน้อยที่สุด ค่าแตกต่างระหว่างค่าที่ได้จากข้อมูล ( $Y_1$ ) และค่าจากเส้นตรง  $Y'_1 = \alpha + \beta x$  คือ  $|Y_1 - Y'_1|$  ดังนั้นเส้นที่มีข้อผิดพลาดทั้งหมดน้อยที่สุดสามารถหาได้โดยการคำนวณหาผลรวมของ Squared Error

$$\Delta^2 = \sum_{i=1}^n (Y_i - Y'_i)^2 = \sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2$$

ในการหาค่า  $\alpha$  และ  $\beta$  ของข้อมูล  $n$  ตัวอย่าง จะหาได้โดยวิธี Least Square

$$\frac{\partial \Delta^2}{\partial \alpha} = \sum_{i=1}^n 2(Y_i - \alpha - \beta X_i)(-1) = 0$$

$$\frac{\partial \Delta^2}{\partial \beta} = \sum_{i=1}^n 2(Y_i - \alpha - \beta X_i)(-X_i) = 0$$

จากการประมาณค่าโดยวิธี Least Square Method จะได้ค่า  $\alpha$  และ  $\beta$  ดังนี้

$$\alpha = \frac{1}{n} \sum Y_i - \frac{\beta}{n} \sum X_i = \bar{Y}_i - \beta \bar{X}$$

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

ดังนั้น Least Square Regression Line คือ

$$Y = \alpha + \beta X$$

ข้อดีที่สำคัญที่สุดของการวิเคราะห์โดยวิธีการนี้คือ นักวิเคราะห์สามารถกำหนดความสัมพันธ์ระหว่างตัวแปรอิสระกับตัวแปรตาม และสามารถอธิบายความแน่นอนแม่นยำของสมการที่ใช้คาดการณ์ได้โดยตัวของมันเอง ค่าสถิติที่ใช้ในการอธิบายมีดังนี้

1. สัมประสิทธิ์ของการตัดสินใจ (coefficient of Multiple Determination,  $R^2$ ) คือ การวัดจำนวนของความแปรปรวนที่ถูกบรรยายไว้โดยสมการ ซึ่งแสดงไว้เป็นอัตราส่วนนิยมของผลรวมความแปรปรวนที่สังเกตในตัวแปรตาม (dependent Variable) ค่าสัมประสิทธิ์นี้มีขีดสูงสุด 1.0 ซึ่งจะเป็นค่าสำหรับสมการที่สมบูรณ์ที่สุด

2. สถิติคลาดเคลื่อนมาตรฐาน (The Standart Error Estimate,  $S_y$ ) คือ การวัดความเบี่ยงเบนของค่าที่ได้มาจากการสังเกต สถิติคลาดเคลื่อนมาตรฐาน จะถึงขีดต่ำสุดคือ ศูนย์ ซึ่งเป็นค่าสำหรับแบบจำลองที่สมบูรณ์ที่สุด



3. สัมประสิทธิ์สหสัมพันธ์ (The Partial Correlation Coefficient,  $R_j$ ) สัมประสิทธิ์สหสัมพันธ์ของตัวแปรอิสระบอกให้รู้ถึงความสัมพันธ์ระหว่างตัวแปรตามกับตัวแปรอิสระบางตัวที่อยู่ภายใต้การพิจารณา

ในกรณีของ Logit Model รูปแบบของแบบจำลอง คือ

$$P_i = \frac{e^{v_i}}{\sum_{j \in C_t} e^{v_j}}$$

เมื่อพิจารณาแนวทางเลือกแต่ละแนวทางเลือก คือ แนวทางเลือก  $i$  และ แนวทางเลือก  $k$

$$P_i = \frac{e^{v_i}}{\sum_{j \in C_t} e^{v_j}} \dots \dots \dots (2)$$

$$P_k = \frac{e^{v_k}}{\sum_{j \in C_t} e^{v_j}} \dots \dots \dots (3)$$

$$\frac{(2)}{(3)} ; \frac{P_i}{P_k} = \frac{e^{v_i}}{e^{v_k}}$$

จัดให้อยู่ในเทอมของ natural logarithm

$$\text{Log}_e (P_i/P_k) = v_i - v_k = \beta (X_i - X_k) + b$$

เมื่อนำค่า  $\text{Log}_e (P_i/P_k)$  กับ  $(X_i - X_k)$  ไปพล็อตกราฟ แล้วทำการจากเส้นผ่านกลุ่มข้อมูล โดยวิธี Least square ก็จะสามารถหาค่า  $\beta$  และ  $\alpha$  ได้