

บทที่ 3

วิธีคำนวณการวิจัย

ในการศึกษาครั้งนี้สิ่งที่ต้องการคือการประมาณค่าตัวแปรตามในสมการถดถอยเชิงเส้น พหุ เมื่อตัวแปรตามบางค่าถูกตัดทิ้งทางขวาประเภทที่ 1 ซึ่งประกอบไปด้วยการประมาณค่าพารามิเตอร์ ด้วยประสิทธิภาพความถดถอย 4 วิธี คือวิธีกำลังสองต่ำสุด วิธีการของแมทเทอร์จีและแมคกีซ วิธีการของบัคเลย์และเจมส์ และวิธีภาวะน่าจะเป็นสูงสุดด้วยขั้นตอนวิธีอีเอ็ม ในการศึกษาครั้งนี้ เกณฑ์ในการเปรียบเทียบการประมาณพารามิเตอร์ด้วยวิธีใดจะให้ค่าการประมาณค่าตัวแปรตามที่ถูกตัดทิ้งได้ดีกว่า จะพิจารณาโดยการเปรียบเทียบค่าประมาณของตัวแปรตามกับค่าจริงก่อนถูกตัดทิ้ง ด้วยรากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (RMSE) เป็นตัววัดวิธีไหนจะให้ค่า RMSE น้อยที่สุดในการประมาณค่าตัวแปรตามในสมการถดถอย โดยจะศึกษาเมื่อค่าความคลาดเคลื่อน มีการแจกแจงปกติ คับเบิลเอกซโพเนนเชียล และแบบล็อกนอร์มอล ทั้งนี้เพราะว่าเมื่อค่าความคลาดเคลื่อนแจกแจงปกติเป็นการแจกแจงที่เป็นไปตามข้อกำหนดพื้นฐาน จึงน่าสนใจศึกษาว่าเมื่อเปลี่ยนแปลงการแจกแจงความคลาดเคลื่อนเป็นการแจกแจงที่มีลักษณะการกระจายไปทางหางมากหรือหางยาวกว่าปกติ หรือการกระจายที่เบ้ไปทางขวา ฯลฯ แล้วจะมีแนวโน้มออกมาเหมือนหรือใกล้เคียงกับการกระจายปกติหรือไม่ เนื่องจากในการนำไปประยุกต์ใช้กับข้อมูลจริง ซึ่งมักจะไม่ทราบการแจกแจงของความคลาดเคลื่อน แต่ผู้ใช้จะตั้งข้อสมมติว่าค่าความคลาดเคลื่อนมีการแจกแจงปกติ สำหรับรูปแบบของการแจกแจงปกติ และการแจกแจงคับเบิลเอกซโพเนนเชียล จะศึกษาที่ค่าสูงสุดของตัวแปรตามถูกตัดทิ้งที่ 53, 58 และ 63 เมื่อความคลาดเคลื่อนแจกแจงล็อกนอร์มอล จะศึกษาที่ค่าสูงสุดของตัวแปรตามถูกตัดทิ้งที่ 55, 58 และ 61 ขนาดตัวอย่างที่สนใจศึกษาครั้งนี้ เป็น 20, 30, 40, 50, 60 และ 70 และจะศึกษาเมื่อเปอร์เซ็นต์การถูกตัดทิ้งเป็น 10%, 20%, 30% และ 40% ของขนาดตัวอย่าง และจำนวนตัวแปรอิสระ 2 ตัวแปร สำหรับการวิจัยครั้งนี้ จะใช้วิธีมอนติคาร์โลในการสร้างข้อมูลให้มีสภาพการแจกแจงตามที่ต้องการ

การวิจัยครั้งนี้ใช้เทคนิคการจำลองแบบมอนติคาร์โล (Monte Carlo Simulation Technique) สร้างสถานการณ์ต่างๆ ดังนั้นในตอนแรกขอบทนี้จะกล่าวถึงวิธีการจำลองโดยใช้เทคนิคมอนติคาร์โล แล้วจึงแสดงรายละเอียดของแผนการทดลอง ขั้นตอนการวิจัย และโปรแกรมที่ใช้ในการวิจัย ตามลำดับ

3.1 วิธีมอนติคาร์โล

เทคนิคในการจำลองตัวแบบทางคณิตศาสตร์นั้นเมื่ออยู่หลายวิธีด้วยกัน ซึ่งวิธีของมอนติคาร์โลเป็นวิธีหนึ่งที่เป็นที่นิยมใช้ในปัจจุบัน ซึ่งหลักการของมอนติคาร์โลนั้นต้องจำลองตัวเลขสุ่ม (Random Number) เพื่อช่วยในการหาคำตอบของปัญหาที่ต้องการศึกษา

ในการศึกษาวิจัยครั้งนี้จะใช้เทคนิคของมอนติคาร์โลดังกล่าวในการสร้างข้อมูลให้มีสภาพการแจกแจงตามที่ต้องการศึกษา ซึ่งขั้นตอนของวิธีมอนติคาร์โลที่ใช้กันอยู่ในปัจจุบันแบ่งได้เป็น 3 ขั้นตอนดังนี้

3.1.1 การสร้างตัวเลขสุ่ม การใช้ตัวเลขสุ่มเป็นสิ่งสำคัญมากในวิธีมอนติคาร์โลทั้งนี้ก็เพราะว่าหลักการของมอนติคาร์โลนั้นจะใช้ตัวเลขสุ่มมาช่วยในการหาคำตอบของปัญหา ซึ่งลักษณะของตัวเลขสุ่มจะมีการแจกแจงแบบยูนิฟอร์มในช่วง (0,1) สำหรับวิธีการสร้างตัวเลขสุ่มนี้มีผู้เสนอไว้หลายวิธีด้วยกัน แต่วิธีหนึ่งที่คือ ไวท์และสคิมิดท์ (White and Schmidt 1975 : 421) เสนอไว้คือ ลักษณะของตัวเลขสุ่มที่เกิดขึ้นมีการแจกแจงแบบยูนิฟอร์มในช่วง (0,1) และเป็นอิสระกัน ซึ่งรายละเอียดแสดงไว้ในภาคผนวก ก.

3.1.2 การประยุกต์ของปัญหาที่ต้องการศึกษามาใช้กับตัวเลขสุ่ม ซึ่งขั้นตอนนี้จะอยู่กับลักษณะของปัญหาที่ต้องการศึกษา บางปัญหาอาจไม่ใช้กับตัวเลขสุ่มโดยตรง แต่อาจมีขั้นตอนอื่นอีกหลายๆ ขั้นตอนซึ่งขั้นตอนเหล่านี้บางขั้นตอนต้องใช้ตัวเลขสุ่ม

3.2 แผนการทดลอง

ในการศึกษาครั้งนี้ต้องการเปรียบเทียบการประมาณค่าตัวแปรตามในสมการถดถอยเชิงเส้นพหุ เมื่อค่าสังเกตของตัวแปรตามเป็นค่าที่ถูกตัดทิ้งทางขวาประเภทที่ 1 ด้วยวิธีการประมาณพารามิเตอร์ 4 วิธี คือวิธีกำลังสองต่ำสุด วิธีการของแมกเทอร์จีและแมคคิสซ วิธีการของบัคเลย์และเจมส์ และวิธีภาวะน่าจะเป็นสูงสุดด้วยขั้นตอนวิธีอีเอ็ม ในการศึกษาครั้งนี้ ได้ทำการศึกษาเมื่อขนาดตัวอย่างมีค่าเป็น 20, 30, 40, 50, 60 และ 70 ซึ่งในแต่ละขนาดตัวอย่างจะเกิดเปอร์เซ็นต์การถูกตัดทิ้งเป็น 4 ระดับคือ 10%, 20%, 30% และ 40% โดยศึกษาภายใต้ค่าภาคเคลื่อนมีการแจกแจง 3 แบบ คือ การแจกแจงปกติ แจกแจงคัมเบิลเอกซโพเนนเชียล และแจกแจงถ้อยกนอร์มอล และแต่ละการแจกแจงกำหนดค่าสูงสุดที่ถูกตัดทิ้งของตัวแปรตาม 3 ระดับ รวมทั้งสิ้น 216 สถานการณ์ และทำการเปรียบเทียบความคลาดเคลื่อนระหว่างค่าประมาณของตัวแปรตามกับค่าจริงก่อนถูกตัดทิ้งในรูปของค่ารากที่สองของค่าเฉลี่ยของความคลาดเคลื่อนกำลังสอง (RMSE) ของทั้ง 4 วิธี เพื่อหาวิธีที่ดีที่สุดของแต่ละสถานการณ์ โดยมีข้อกำหนดดังนี้

1 ค่าสังเกต $T_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \varepsilon_i$ $i=1,2,\dots,N$ เมื่อ N คือ จำนวนค่าสังเกต โดยที่ X_{i1} เป็นค่าคงที่จำลองจากการแจกแจงไวบูลล์ (Weibull Distribution) $W(\alpha, \beta)$ เมื่อ α มีค่าเป็น 2 และ β มีค่าเป็น 2 และ X_{i2} เป็นค่าคงที่จำลองจากการแจกแจงปกติ (Normal Distribution) $N(\mu, \sigma^2)$ เมื่อ μ มีค่าเป็น 10 และ σ^2 มีค่าเป็น 12 และ ε_i มี 3 การแจกแจงคือ แจกแจงปกติ $N(0,100)$ แจกแจงคัมเบิลเอกซ์โพเนนเชียล $DB(0, \sqrt{50})$ และแจกแจงล็อกนอร์มอล $LN(1,1.1025)$ โดยกำหนด $\beta_0 = 2$ $\beta_1 = 3.5$ และ $\beta_2 = 3.5$

2 กำหนดค่าสูงสุด (T_c) ของตัวแปรตามถูกตัดทิ้ง 3 ระดับ โดยเมื่อค่าคาดเคลื่อนมีการแจกแจงปกติ $N(0,100)$ และแจกแจงคัมเบิลเอกซ์โพเนนเชียล $DB(0, \sqrt{50})$ กำหนดค่าสูงสุด T_c ที่ 53, 58 และ 63 และเมื่อแจกแจงแบบล็อกนอร์มอล $LN(1,1.1025)$ กำหนดค่าสูงสุด T_c ที่ 55, 58 และ 61

3 ขนาดตัวอย่างที่สนใจศึกษา คือ 20, 30, 40, 50, 60 และ 70

4 เปอร์เซ็นต์ของข้อมูลที่ถูกต้องทิ้งมี 4 ระดับ คือ 10%, 20%, 30% และ 40%

3.3 ขั้นตอนในการศึกษาวิจัย

ขั้นตอนในการศึกษาวิจัยมีดังนี้

1. จำลองค่าคงที่เป็นตัวแปรอิสระ X_{i1} และ X_{i2} โดย X_{i1} จำลองจากการแจกแจงไวบูลล์ $W(\alpha, \beta)$ และ X_{i2} การแจกแจงปกติ $N(\mu, \sigma^2)$ และจำลองค่าคาดเคลื่อนตามการแจกแจงที่ต้องการศึกษาและจำลอง T_i จากความสัมพันธ์เชิงเส้น

$$T_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \varepsilon_i$$

2. กำหนดค่าสูงสุดของ T_i ที่ถูกต้องทิ้งที่ T_c

3. หาค่าสังเกตของตัวแปรตาม Y_i : $i = 1, 2, 3, \dots, n+m$

$$Y_i = \begin{cases} T_i & ; T_i \leq T_c & ; i = 1, 2, \dots, n \\ T_c & ; T_i > T_c & ; i = n+1, n+2, \dots, n+m \end{cases}$$

n เป็นจำนวนตัวอย่างที่ไม่ถูกต้องทิ้ง

m เป็นจำนวนตัวอย่างที่ถูกต้องทิ้ง

4. นำค่า Y_i, X_{i1} และ X_{i2} ประมาณค่าพารามิเตอร์สัมประสิทธิ์ความถดถอยเชิงเส้นพหุคูณด้วยวิธี

- 4.1 วิธีการของบักเลย์และเจมส์
- 4.2 วิธีการของแรทเทอร์จีและแมคคิลิช
- 4.3 วิธีกำลังสองต่ำสุด
- 4.4 วิธีภาวะน่าจะเป็นสูงสุดด้วยขั้นตอนวิธีอีเอ็ม

5. หากความคลาดเคลื่อนจากการประมาณค่าตัวแปรตาม และทำการเปรียบเทียบ

สำหรับรายละเอียดแต่ละขั้นตอนเป็นดังนี้

3.3.1 การจำลองตัวแปรอิสระ X_{i1} และ X_{i2} ซึ่งเป็นค่าคงที่ โดยที่ X_{i1} จำลองจากการแจกแจงไวบูลต์ (Weibull Distribution) $W(\alpha, \beta)$ โดย α มีค่าเป็น 2 และ β มีค่าเป็น 2 และ X_{i2} จำลองจากการแจกแจงปกติ $N(\mu, \sigma^2)$ มีค่าเฉลี่ยเป็น 10 ความแปรปรวนเป็น 12 และจำลองค่าคลาดเคลื่อน ε_i จากการแจกแจง 3 แบบคือ

ก. การแจกแจงปกติ $N(\mu, \sigma^2)$ ด้วยค่าเฉลี่ยเป็น 0 และความแปรปรวนเท่ากับ 100 (รายละเอียดในภาคผนวก ก.)

ข. การแจกแจงหางยาวกว่าการแจกแจงปกติ โดยจำลอง ε_i จากการแจกแจงดับเบิลเอกซ์โพเนนเชียล $DB(\mu, \sigma)$ ด้วยค่าพารามิเตอร์ μ เป็น 0 และ σ เป็น $\sqrt{50}$ (รายละเอียดในภาคผนวก ก.)

ค. การแจกแจงที่เบ้ขวา โดยจำลอง ε_i จากการแจกแจงล็อกนอร์มอล $LN(1, 1.1025)$

3.3.2 กำหนดค่าสูงสุดของ T_i ที่จะถูกตัดทิ้ง ในการศึกษาครั้งนี้กำหนดค่าสูงสุดของ T_i ที่จะถูกตัดทิ้งไว้ที่ 3 ระดับทำได้โดยจากรูปแบบ $T_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \varepsilon_i$: $i=1, 2, \dots, n+m$ เมื่อจำลอง X_{i1}, X_{i2} และกำหนด β_0, β_1 และ β_2 ตามรายละเอียดในข้อ 3.3.1 และนำ T_i หาค่าเฉลี่ย ให้ μ_T ก็คือค่าเฉลี่ยของ T_i กำหนดค่าสูงสุดที่จะถูกตัดทิ้งระดับที่ 1, 2 และ 3 ที่ $\mu_T + \sigma_T, \mu_T + 1.5\sigma_T$ และที่ $\mu_T + 2\sigma_T$ ตามลำดับ เมื่อ σ_T^2 คือความแปรปรวนของค่าคลาดเคลื่อนที่มีการแจกแจงตามที่ต้องการศึกษา ดังนั้นค่าสูงสุดที่ถูกตัดทิ้งสรุปได้ดังนี้

ก. เมื่อ ε_i แจกแจงแบบปกติ ตัดทิ้งระดับที่ 1, 2, 3 ที่ $T_c=53, 58$ และที่ $T_c=63$ ตามลำดับ

ข. เมื่อ ε_i แจกแจงแบบคัมเบิลเอกซโพเนนเชียล ตัดทิ้งระดับที่ 1, 2, 3 ที่ $T_c = 53, 58$ และระดับที่ 3 ที่ $T_c = 63$

ก. เมื่อ ε_i แจกแจงแบบล็อกนอร์มอล ตัดทิ้งระดับที่ 1, 2, 3 ที่ $T_c = 55, 58$ และระดับที่ 3 ที่ $T_c = 61$

3.3.3 หากค่าสังเกตของตัวแปรตาม Y_i ; $i=1,2,\dots,n+m$ เมื่อ $n+m$ คือจำนวนตัวอย่างทั้งหมด n คือจำนวนตัวอย่างที่ไม่ถูกตัด m คือจำนวนตัวอย่างที่ถูกตัดทิ้ง

$$Y_i = \begin{cases} T_i & \text{ถ้า } T_i \leq T_c \text{ (ไม่ถูกตัดทิ้ง)} \\ T_c & \text{ถ้า } T_i > T_c \text{ (ถูกตัดทิ้ง)} \end{cases}$$

$$\delta_i = \begin{cases} 1 & \text{ถ้า } T_i \leq T_c \text{ (ไม่ถูกตัดทิ้ง)} \\ 0 & \text{ถ้า } T_i > T_c \text{ (ถูกตัดทิ้ง)} \end{cases}$$

เมื่อ T_c คือค่าสูงสุดที่ถูกตัดทิ้ง

การหาค่าสังเกตของตัวแปรตาม Y_i ทำได้โดยจำลอง T_i แล้วนำค่า T_i มาเปรียบเทียบกับค่า T_c จะได้ค่า $Y_i = T_i$ เมื่อ $T_i \leq T_c$ และให้ $\delta_i = 1$ แล้วนับเป็นค่าสังเกตที่ไม่ถูกตัดทิ้ง และจะได้ $Y_i = T_c$ เมื่อ $T_i > T_c$ และให้ $\delta_i = 0$ แล้วนับเป็นค่าสังเกตที่ถูกตัดทิ้ง และทำการทดลองเช่นนี้จนกระทั่งได้ค่าสังเกตที่ไม่ถูกตัดทิ้งและถูกตัดทิ้งครบตามจำนวน n และ m ตามที่กำหนด

3.3.4 นำค่า Y_i และ X_{i1}, X_{i2} ; $i=1,2,\dots,n+m$ จำนวนค่าประมาณพารามิเตอร์จากสมการถดถอยเชิงเส้นพหุ ด้วยวิธีกำลังสองต่ำสุด วิธีการของแครทเทอร์จีและแมกลิช วิธีการของบัคเลย์และเจมส์ และวิธีการภาวะน่าจะเป็นสูงสุดด้วยขั้นตอนวิธีอีเอ็ม เนื่องจากวิธีกำลังสองต่ำสุดและวิธีการของแครทเทอร์จีและแมกลิชสามารถประมาณพารามิเตอร์ได้ (Convergence) ทุกสถานการณ์ที่ศึกษา แต่วิธีการของบัคเลย์และเจมส์ และวิธีการภาวะน่าจะเป็นสูงสุดด้วยขั้นตอนวิธีอีเอ็ม จะมีบางชุดของข้อมูลเช่นข้อมูลที่มีเปอร์เซ็นต์การถูกตัดทิ้งจำนวนมาก ค่าประมาณพารามิเตอร์จะแกว่งอยู่ระหว่าง 2 ค่า ก็จะใช้ค่าเฉลี่ยระหว่าง 2 ค่านั้นเป็นค่าประมาณพารามิเตอร์หรือค่าประมาณของพารามิเตอร์ของรอบปัจจุบันกับรอบที่ผ่านมาต่างกันอย่างน้อยกว่า 0.005 ถือว่าค่าประมาณพารามิเตอร์นั้นหาค่าได้ ถ้าไม่เข้าข้างทั้ง 2 กรณี ก็จะทิ้งข้อมูลชุดนั้น และทำการจำลองข้อมูลที่หาค่าประมาณพารามิเตอร์ได้ทั้ง 4 วิธีจำนวน 1000 ชุด ข้อมูลในแต่ละสถานการณ์

การประมาณพารามิเตอร์แต่ละวิธีมีรายละเอียดดังนี้

3.3.4.1 กำลังสองต่ำสุด มีขั้นตอนเป็นดังนี้

ประมาณค่าพารามิเตอร์ β จากข้อมูลที่ถูกต้องและไม่ถูกต้อง โดยการหาอนุพันธ์ของผลบวกกำลังสองของความคลาดเคลื่อนเทียบกับ β แล้วกำหนดให้เท่ากับ 0

$$\text{จากนั้นแก้สมการหาค่า } \hat{\beta} \text{ ได้ดังนี้ } \frac{\partial}{\partial \beta} (YT - 2\hat{\beta} X'Y + \hat{\beta} XX\hat{\beta}) = 0$$

เพราะฉะนั้น
$$\hat{\beta} = (XX)^{-1}XY'$$

3.3.4.2 วิธีการของแมตเทอร์จีและแมคกีธ มีขั้นตอนดังนี้

1. เฉพาะข้อมูลที่ไม่วัดค่าพารามิเตอร์เริ่มต้น $\hat{\beta}$ โดยวิธีกำลังสองต่ำสุด

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

เมื่อ n หมายถึงค่าสังเกตที่ไม่วัดค่าพารามิเตอร์

X' เป็นเมทริกซ์ของตัวแปรอิสระของค่าสังเกตที่ไม่วัดค่าพารามิเตอร์

Y' เป็นเวกเตอร์ของตัวแปรตามของค่าสังเกตที่ไม่วัดค่าพารามิเตอร์

2. ประมาณค่าสังเกตที่วัดค่าพารามิเตอร์ $Y_i(\hat{\beta})$ โดย

$$Y_i(\hat{\beta}) = \hat{\beta}_0 + \hat{\beta}_1 X_{i1} + \hat{\beta}_2 X_{i2}$$

3. เปรียบเทียบค่า $Y_i(\hat{\beta})$ กับค่า T_c ถ้าค่า $Y_i(\hat{\beta})$ มีค่ามากกว่าค่า T_c ให้แทนที่ค่าที่วัดค่าพารามิเตอร์ด้วย $Y_i(\hat{\beta})$ แต่ถ้าค่า $Y_i(\hat{\beta})$ มีค่าน้อยกว่าหรือเท่ากับ T_c ก็ให้คงค่าสังเกตที่วัดค่าพารามิเตอร์ไว้

4. นำค่าสังเกตที่ไม่วัดค่าพารามิเตอร์และค่าสังเกตที่วัดค่าพารามิเตอร์ด้วยวิธีกำลังสองต่ำสุด

วิธีการของแมทเทอร์จีและแมคกีใช้การวนทำซ้ำจนกระทั่งได้พารามิเตอร์ของรอบปัจจุบันเท่ากับรอบที่ผ่านมาถ้าพารามิเตอร์ยังไม่เท่ากันก็จะทำการประมาณค่าสังเกตที่ถูกตัดทิ้งและนำข้อมูลทั้งหมดคำนวณหาพารามิเตอร์รอบใหม่ หรือถ้าพารามิเตอร์แกว่งอยู่ระหว่าง 2 ค่าก็จะใช้ค่าเฉลี่ยของ 2 ค่านั้นเป็นค่าประมาณพารามิเตอร์

3.3.4.3 วิธีของบัคเลย์และเจมส์ มีขั้นตอนดังนี้

1. เจาะข้อมูลที่ไมถูกตัดทิ้งประมาณพารามิเตอร์เริ่มต้น $\hat{\beta}$ ด้วย

วิธีกำลังสองต่ำสุด

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

เมื่อ n หมายถึงค่าสังเกตที่ไม่ถูกตัดทิ้ง

X'' เป็นเมทริกซ์ของตัวแปรอิสระของค่าสังเกตที่ไม่ถูกตัดทิ้ง

Y'' เป็นเวกเตอร์ของตัวแปรตามของค่าสังเกตที่ไม่ถูกตัดทิ้ง

2. หาค่าความคลาดเคลื่อนบางส่วน (Partial Residuals) โดยคำนวณ

ที่ $\hat{\beta}_0 = 0$, $\hat{\epsilon}_i = Y_i - \hat{\beta}_1 X_{i1} - \hat{\beta}_2 X_{i2}$; $i = 1, 2, \dots, n+m$ และนำ $\hat{\epsilon}_i$ มาเรียงลำดับจากน้อยไปมาก $\hat{\epsilon}_{(1)} < \hat{\epsilon}_{(2)} < \dots < \hat{\epsilon}_{(n+m)}$ แล้วคำนวณค่าประมาณ $\hat{P}(\hat{\epsilon}_i)$ โดยใช้ตัวประมาณที่แตก

$$\hat{P}(\hat{\epsilon}_i) = 1 - \prod_{t: \hat{\epsilon}_{(t)} \leq \hat{\epsilon}_i} \left(\frac{n+m-1}{n+m-1+t} \right)^{\delta(t)}$$

เมื่อ n คือจำนวนค่าสังเกตที่ไม่ถูกตัดทิ้ง

m คือจำนวนค่าสังเกตที่ถูกตัดทิ้ง

3. นำค่า $\hat{P}(\hat{\epsilon}_i)$ มาหาค่าถ่วงน้ำหนัก $W(\epsilon_i, \hat{\beta})$

4. ประมาณค่าสังเกตที่ถูกตัดทิ้งด้วยค่าคาดหวังอย่างมีเงื่อนไข

$$E(Y_i | Y_i > T_c, X, \beta) = Y_i(\hat{\beta})$$

$$Y_i(\hat{\beta}) = (\hat{\beta}_1 X_{i1} + \hat{\beta}_2 X_{i2}) + \frac{\sum W_k(\epsilon_k, \hat{\beta})(Y_k - \hat{\beta}_1 X_{k1} - \hat{\beta}_2 X_{k2})}{\{1 - \hat{P}(T_c - \hat{\beta}_1 X_{i1} - \hat{\beta}_2 X_{i2})\}}$$

5. นำค่าประมาณของค่าสังเกตที่ถูกตัดทิ้งรวมกับค่าสังเกตที่ไม่ถูกตัดทิ้ง มาคำนวณหาค่าประมาณพารามิเตอร์ด้วยวิธีกำลังสองต่ำสุด

วิธีการของบัคเลย์และเจมส์จะทำงานซ้ำจนกระทั่งได้ค่าประมาณพารามิเตอร์รอบปัจจุบันเท่ากับรอบที่ผ่านมาพารามิเตอร์ยังไม่เท่ากันก็จะทำการประมาณค่าสังเกตที่ถูกตัดทิ้งและนำข้อมูลทั้งหมดคำนวณหาพารามิเตอร์รอบใหม่ หรือถ้าพารามิเตอร์แกว่งอยู่ระหว่าง 2 ค่าก็จะใช้ค่าเฉลี่ยของ 2 ค่านั้นเป็นค่าประมาณพารามิเตอร์

3.3.4.4 วิธีการภาวนำจะเป็นสูงสุดด้วยขั้นตอนวิธีอีเอ็ม มีขั้นตอนดังนี้

1. นำข้อมูลทั้งหมดทั้งที่ไม่ถูกตัดทิ้งและถูกตัดทิ้งประมาณพารามิเตอร์ $\hat{\beta}$, $\hat{\sigma}^2$ เริ่มต้น ($k=1$) ด้วยวิธีกำลังสองต่ำสุด
2. นำพารามิเตอร์รอบที่ k แทนค่าเพื่อประมาณค่าสังเกตที่ถูกตัดทิ้ง ด้วย $E(Y_i / Y_i > T_c, \beta, \sigma) = \hat{\mu}_i^{(k)} + \hat{\sigma}_{(k)} h(\hat{z}_i^{(k)})$ แล้วนำค่าสังเกตที่ไม่ถูกตัดทิ้งและถูกตัดทิ้งประมาณ $\hat{\beta}$ รอบที่ $k+1$ ด้วยวิธีกำลังสองต่ำสุด
3. ประมาณ $\hat{\sigma}_{(k+1)}^2$ รอบที่ $k+1$ จาก

$$\hat{\sigma}_{(k+1)}^2 = \left[\sum_1^n (y_i - \hat{\mu}_i^{(k)}) + \hat{\sigma}_{(k)}^2 \sum_{m=1}^{m+m} (1 + \hat{z}_i^{(k)} h(\hat{z}_i^{(k)})) \right] / (n + m)$$

การประมาณด้วยภาวนำจะเป็นสูงสุดด้วยขั้นตอนวิธีอีเอ็มใช้กระบวนการวนทำซ้ำจนกระทั่งได้ค่าประมาณพารามิเตอร์รอบปัจจุบันเท่ากับรอบที่ผ่านมาพารามิเตอร์ยังไม่เท่ากันก็จะทำการประมาณค่าสังเกตที่ถูกตัดทิ้งและนำข้อมูลทั้งหมดคำนวณหาพารามิเตอร์รอบใหม่ หรือถ้าพารามิเตอร์แกว่งอยู่ระหว่าง 2 ค่าก็จะใช้ค่าเฉลี่ยของ 2 ค่านั้นเป็นค่าประมาณพารามิเตอร์

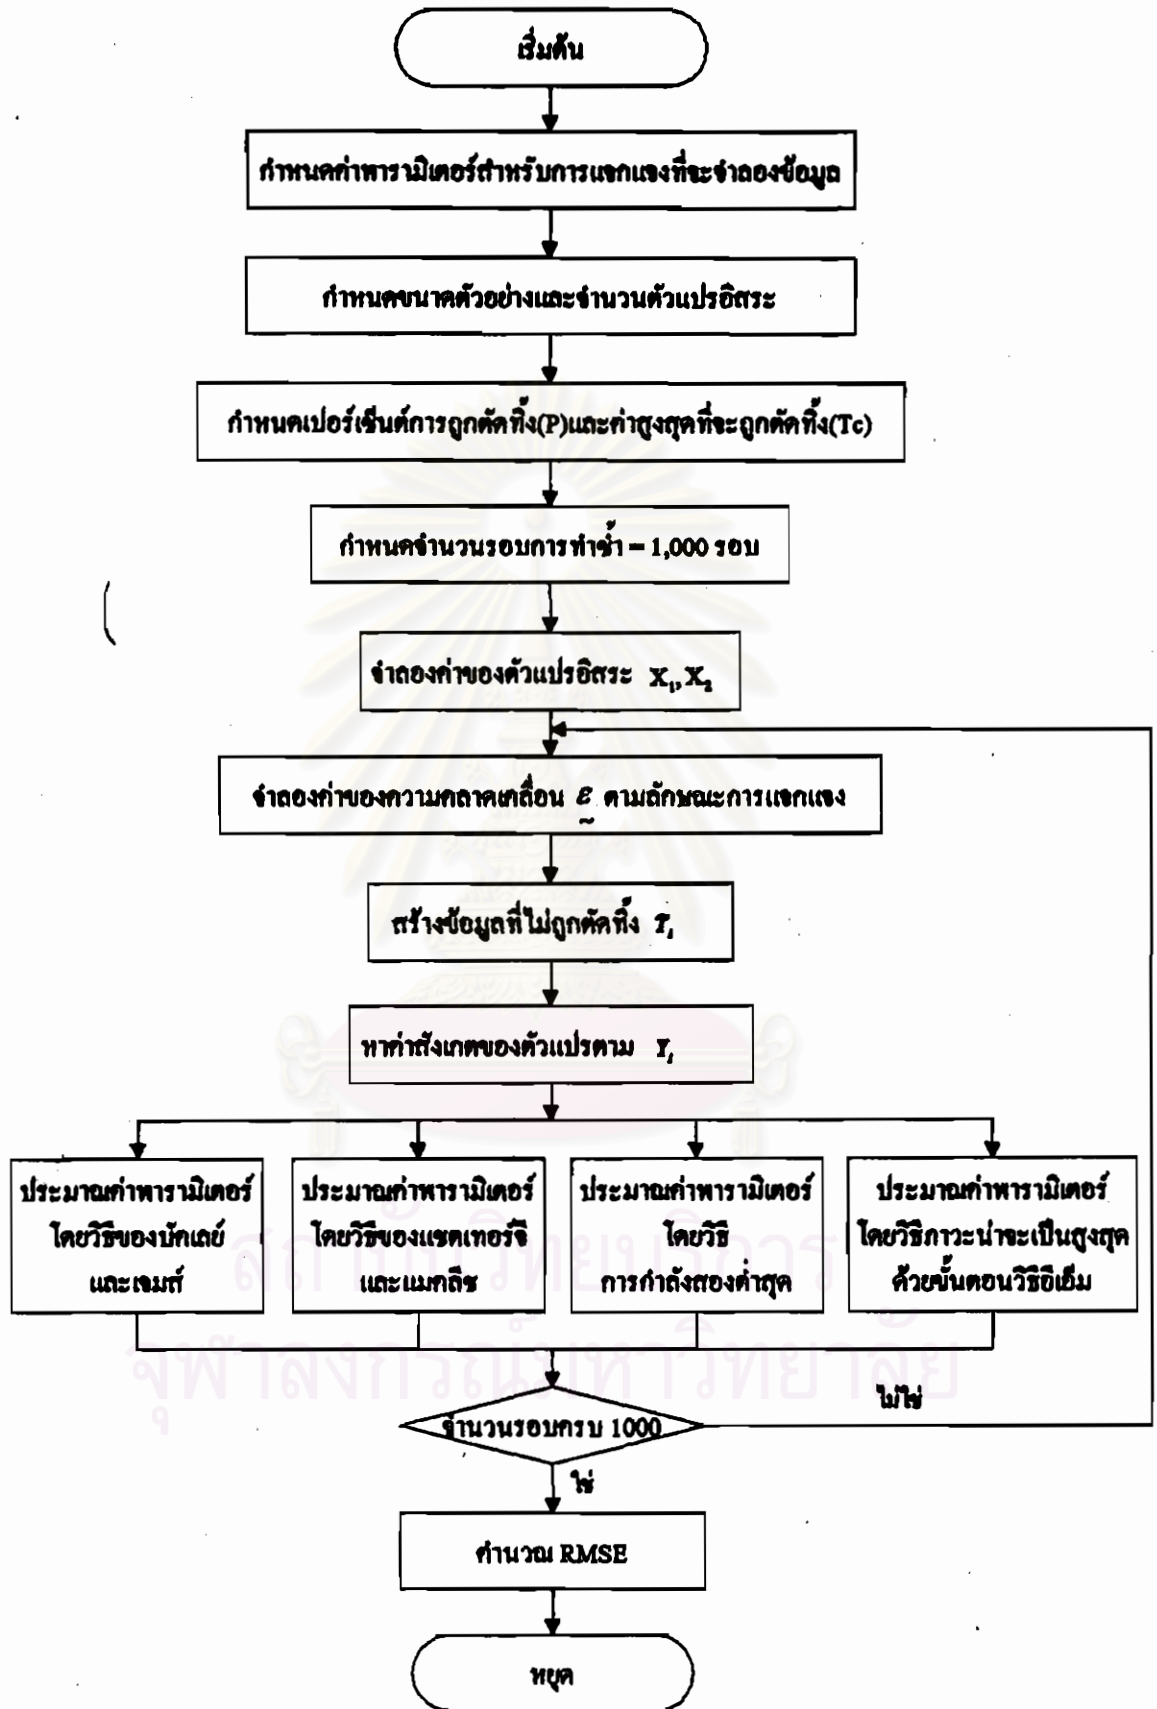
3.3.5 หากความคลาดเคลื่อนจากการประมาณค่าตัวแปรตาม โดยการเปรียบเทียบค่าจริงก่อนถูกตัดทิ้ง เพื่อนำมาคำนวณหาค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (RMSE) เนื่องจากการทดลองได้ทำซ้ำๆ กัน 1000 รอบ ดังนั้นในแต่ละสถานการณ์ให้ j แทนรอบที่ทำซ้ำ $j=1, 2, \dots, 1000$ ค่าความคลาดเคลื่อนที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสองหาได้จาก

$$\begin{aligned} \text{MSE}_j &= \frac{1}{m} \sum_{i=1}^m (T_i - \hat{f}_i)^2 \\ \text{RMSE}_j &= \sqrt{\text{MSE}_j} \\ \text{RMSE} &= \frac{1}{1000} \sum_{j=1}^{1000} \text{RMSE}_j \end{aligned}$$

▷ จากนั้นจึงนำ RMSE ของการประมาณค่าตัวแปรตามเปรียบเทียบกับทั้ง 4 วิธี เพื่อหาว่าวิธีการใดให้ค่า RMSE ของการประมาณค่าตัวแปรตามค่าที่ต่ำที่สุดจะเป็นวิธีที่ประมาณค่าตัวแปรตามได้ดีที่สุดในแต่ละสถานการณ์

ในการหาค่า RMSE ของการประมาณทั้งหมด 4 วิธี ในขนาดตัวอย่างต่างๆ จะเปลี่ยนเปอร์เซ็นต์การถูกตัดทิ้งเป็น 10%, 20%, 30% และ 40% และเปลี่ยนการแจกแจงของค่าคลาดเคลื่อน เป็น 3 การแจกแจงคือ แจกแจงปกติ แจกแจงคัมเบิลเอกซโพเนนเชียล และแจกแจงล็อกนอร์มอล โดยในแต่ละสถานการณ์ทำซ้ำๆ กัน 1000 รอบ ซึ่งขั้นตอนการทดลองสามารถสรุปเป็นผังงานได้ดังรูปที่ 3.1

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย



รูปที่ 3.1 แสดงผังงานสำหรับหาค่าความคลาดเคลื่อนจากการประมาณทั้ง 4 วิธีการ

3.4 โปรแกรมที่ใช้ในการวิจัย

โปรแกรมที่ใช้ในการวิจัยทั้งหมด เขียนด้วยภาษาฟอร์แทรน (FORTRAN) โดยใช้กับเครื่อง AMDAHL 5860 ซึ่งในแต่ละสถานการณ์ของการทดลองลักษณะการทำงานของโปรแกรมจะเหมือนกัน สำหรับรายละเอียดของโปรแกรมจะแสดงไว้ในภาคผนวก ข ซึ่งจะเป็โปรแกรมการทำงานของแต่ละวิธีการ คือ วิธีการของบัคเลย์และเจมส์ วิธีการของแรดเทอร์จีและแมกลีซ วิธีการก้างสองต่ำสุด และวิธีการจะน่าจะเป็นสูงสุดด้วยขั้นตอนวิธีอีเอ็ม



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย