



บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

การใช้เทคนิคการวิเคราะห์ความถดถอยเพื่อใช้เป็นเครื่องมือช่วยในการหาคำตอบในงานวิจัยโดยส่วนใหญ่ผู้วิจัยมักเลือกใช้วิธีกำลังสองน้อยที่สุดเนื่องจากเป็นวิธีการที่ใช้ง่ายและเป็นวิธีการที่ให้ตัวประมาณที่ดีคือได้ตัวประมาณเชิงเส้นที่ไม่อนเอียงและมีความแปรปรวนต่ำที่สุดภายใต้ข้อตกลงเบื้องต้นของการวิเคราะห์ความถดถอย ถ้าหากข้อมูลที่นำมาวิเคราะห์ เป็นข้อมูลที่ไม่สมบูรณ์ (Incomplete Data) คือไม่ทราบค่าสังเกตที่แท้จริงของตัวแปรที่สนใจหรือค่าสังเกตนั้นนิลักษณะเป็นข้อมูลที่ถูกตัดทิ้ง (Censored Data) ทำให้ต้องบันทึกค่าเท่าที่สังเกตได้ เมื่อทำการวิเคราะห์ข้อมูลอาจจะได้ตัวประมาณที่อนเอียง ส่งผลกระทบต่อการวิเคราะห์และสรุปผล นอกเหนื่อง ถ้าหากมีข้อมูลถูกตัดทิ้งเป็นจำนวนมากอาจส่งผลให้ความแม่นยำในการประมาณค่าลดน้อยลง ความคลาดเคลื่อนที่เกิดจากการประมาณก็จะมีมากขึ้น ดังนั้นจึงควรทำการประมาณค่าที่ถูกตัดทิ้ง โดยใช้วิธีการที่มีความเหมาะสมที่จะทำให้ได้ค่าประมาณที่ใกล้เคียงกับค่าจริง

ข้อมูลถูกตัดทิ้งจะพบมากในด้านการแพทย์ ด้านอุตสาหกรรม ด้านการประกันภัย เช่น ในโครงการทดลองเปลี่ยนหัวใจคนไข้¹ Standford Heart Transplantation Program เมื่อต้องการทดลองว่าจำนวนวันที่มีชีวิตอยู่รอดของคนไข้หลังการผ่าตัดหัวใจนี้อยู่กับอายุของคนไข้ที่เข้ารับการรักษาหรือไม่ ซึ่งในการทดลองนี้ตัวแปรอีสระคืออายุของคนไข้ที่ได้รับการรักษา ตัวแปรตามคือจำนวนวันที่มีชีวิตอยู่รอดของคนไข้หลังการผ่าตัดหัวใจ โดยเริ่มทำการทดลองเมื่อวันที่ 1 ตุลาคม 1967 และสิ้นสุดการทดลองในวันที่ 1 เมษายน 1974 ในระหว่างการทดลองมีคนไข้ 69 คน เข้ารับการเปลี่ยนหัวใจและสังเกตว่าคนไข้จะมีชีวิตอยู่หลังจากเปลี่ยนหัวใจ โดยนับจำนวนวันที่มีชีวิตอยู่ ดังนั้นคนไข้ที่เสียชีวิตในระยะเวลาที่ทำการทดลองจะเป็นข้อมูลที่ไม่ถูกตัดทิ้ง และคนไข้ที่มีชีวิตอยู่เมื่อสิ้นสุดการทดลองจะเป็นข้อมูลถูกตัดทิ้ง เนื่องจากเราไม่สามารถทราบได้เลยว่าคนไข้กลุ่มนี้จะมีชีวิตอีกนานเท่าใด ทราบเฉพาะจำนวนวันที่มีชีวิตอยู่เมื่อสิ้นสุดการทดลองเท่านั้น ตัวอย่างข้อมูลถูกตัดทิ้งด้านอุตสาหกรรม เช่น ศึกษาเกี่ยวกับอายุการใช้งาน

¹ Rupert G. Miller. 'Least Squares Regression with Censored Data'. *Biometrika* 63(3); (1976); 456-458.

ของเครื่องจักรชนิดหนึ่ง โดยศึกษาในระยะเวลา 8000 ช.ม. เริ่มทำการทดลองโดยให้เครื่องจักรเครื่องนี้ทำงานแล้วบันทึกเวลาไว้ตั้งแต่เริ่มทำงานจนกระทั่งเครื่องจักรเสื่อมสภาพ ในระหว่างการทดลองเครื่องจักรใดเสื่อมสภาพ จะเป็นค่าสังเกตที่ไม่ถูกตัดทิ้ง (Unensored data หรือ Survival Time) และเมื่อสิ้นสุดการทดลอง เครื่องจักรเครื่องใดที่ยังคงอยู่ในสภาพที่ใช้งานได้ก็จะเป็นเครื่องที่ไม่ทราบอายุการใช้งานที่แน่นอน จะบันทึกไว้ว่ามีอายุการใช้งาน 8000 ช.ม. ซึ่งข้อมูลนี้จะเป็นค่าสังเกตที่ถูกตัดทิ้ง (Censored data)

ในการวิจัยครั้งนี้จะประมาณค่าพารามิเตอร์ β จากสมการคดดอยเชิงเส้นตรงพหุโดยใช้วิเคราะห์กับข้อมูลที่ค่าสังเกตของตัวแปรตามมีค่าถูกตัดทิ้งทางขวาและเป็นค่าถูกตัดทิ้งประเภทที่ 1 (Type I Censoring) โดยทั่วไปแล้วการนำข้อมูลที่ถูกตัดทิ้งมาใช้ในการประมาณค่าพารามิเตอร์นั้นอาจจะทำได้ใน 2 กรณีคือ

กรณีแรก จะถือว่าค่าที่ถูกตัดทิ้งเสมือนเป็นค่าที่ไม่ถูกตัดทิ้งทำการวิเคราะห์ข้อมูลทั้งหมด

กรณีที่สอง ไม่สนใจข้อมูลที่ถูกตัดทิ้งจะทำการวิเคราะห์เฉพาะข้อมูลที่ไม่ถูกตัดทิ้งเท่านั้น ดังนั้นจำนวนข้อมูลที่นำมาวิเคราะห์จึงมีน้อยกว่าวิธีแรก

เมื่อทำการวิเคราะห์ข้อมูลด้วยวิธีกำลังสองน้อยที่สุดจากข้อมูลทั้งสองกรณีดังกล่าว จะทำให้ได้ตัวประมาณที่เอนเอียงและโดยเฉลี่ยแล้วการประมาณค่าจะต่ำกว่าความเป็นจริง หรือจะทำให้ได้ช่วงความเชื่อมั่นที่แคบกว่าความเป็นจริง² ด้วยเหตุนี้จึงได้มีผู้คิดวิธีการในการประมาณค่าพารามิเตอร์เมื่อเกิดปัญหาข้อมูลถูกตัดทิ้งในตัวแปรตามขึ้นมากนanya หลายวิธี เช่น วิธีการของบักเลย์ และเจมส์ (Jonathan Buckley & James : 1979) วิธีการของปีเตอร์ เจนส์ สมิธ (Peter James Smith : 1986) วิธีการของมิลเลอร์ (Rupert G. Miller : 1976) เป็นต้น

มิลเลอร์และเจอร์รี่ (Rupert Miller and Jerry Halpern : 1982) ได้ทำการเบรย์บเทียบวิธีการของมิลเลอร์กับวิธีการของบักเลย์และเจมส์ พนวิธีการของบักเลย์และเจมส์ จะให้ค่าประมาณพารามิเตอร์ที่น่าเชื่อถือกว่าวิธีการของมิลเลอร์ งดี รายงานประจำปี (2536) ได้ทำการเบรย์บเทียบพารามิเตอร์ในสมการคดดอยเชิงเส้นอย่างง่าย เมื่อข้อมูลค่าสังเกตของตัวแปรตามเป็นค่าที่ถูกตัดทิ้งทางขวา โดยประมาณค่าพารามิเตอร์จากวิธีการกำลังสองน้อยที่สุด วิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุด และวิธีการของบักเลย์และเจมส์ พนวิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุด เป็นวิธีการที่มีประสิทธิภาพในการประมาณค่าพารามิเตอร์ ในทุกสถานการณ์ที่ทำการศึกษา

² Josef Schmee and Gerald J.Hahn. 'A Simple Method for Regression Analysis with Censored Data.' Technometrics, 21(4) : (1979) ; 417-418.

ดังนั้นจึงเป็นที่น่าสนใจว่า เมื่อเกิดปัญหาตัวแปรตามบางค่าเป็นค่าที่ถูกตัดทิ้งและทราบค่าของ การถูกตัดทิ้งในการวิเคราะห์การถดถอย วิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุด วิธีการของสมิธ และวิธีการ โมดิไฟฟ์แอคชั่นเรียล วิธีการใดจะเป็นวิธีที่เหมาะสมในปัญหานี้

1.2 วัตถุประสงค์ของการวิจัย

เพื่อเปรียบเทียบวิธีการประมาณค่าพารามิเตอร์ในการวิเคราะห์การถดถอยเชิงเส้นตรงพหุเมื่อตัวแปรตามบางค่ามีค่าถูกตัดทิ้งทางขวาและเป็นการตัดทิ้งประเภทที่ 1 ด้วยวิธี

1.2.1 วิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุด (Maximum Likelihood Estimation Method)

1.2.2 วิธีการของสมิธ (Smith Method)

1.2.3 วิธีการ โมดิไฟฟ์แอคชั่นเรียล (Modified Acturial Method)

1.3 สมมติฐานทางการวิจัย

ในการประมาณค่าตัวแปรตามในสมการถดถอยเชิงเส้นตรงพหุ เมื่อตัวแปรตามมีค่าถูกตัดทิ้งทางขวาและเป็นการตัดทิ้งประเภทที่ 1 ในแต่ละวิธีจะให้ค่าประมาณที่แตกต่างกัน วิธีการของสมิธ จะให้ค่าประมาณที่ใกล้เคียงกับค่าจริงมากกว่าวิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุด และวิธีการ โมดิไฟฟ์แอคชั่นเรียล

1.4 ข้อกลุ่มนี้

1.4.1 ศึกษารูปแบบสมการถดถอยเชิงเส้นตรงพหุ

$$y = X \beta + \varepsilon$$

เมื่อ y เป็นเวกเตอร์ของตัวแปรตามขนาด $n \times 1$ โดยที่ n เป็นจำนวนค่าสังเกต

X เป็นเมตริกซ์ของตัวแปรอิสระขนาด $n \times p$ ($p < n$) และมี full rank= p

β เป็นเวกเตอร์ของพารามิเตอร์ที่ไม่ทราบค่าขนาด $p \times 1$

ε เป็นความคลาดเคลื่อนที่มีขนาด $n \times 1$

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}_{nx1} \quad X = \begin{bmatrix} 1 & X_{11} \dots X_{1p} \\ 1 & X_{12} \dots X_{2p} \\ \vdots & \vdots \\ 1 & X_{n1} \dots X_{np} \end{bmatrix}_{n \times p} \quad \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix}_{p \times 1} \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}_{n \times 1}$$

1.4.2 ตัวแปรตามเท่านั้นที่เป็นค่าที่ถูกตัดทิ้ง

1.4.3 ศึกษากรณีที่ค่าที่ถูกตัดทิ้งเป็นการถูกตัดทิ้งทางขวาและเป็นการตัดทิ้งประเภทที่ 1

1.5 ข้อบกพร่องการวิจัย

1.5.1 ในการวิจัยครั้งนี้ จะทำการเปรียบเทียบการประมาณค่าตัวแปรตามในสมการลดด้วยเชิงเส้นตรงพหุ เมื่อตัวแปรตามบางค่ามีค่าถูกตัดทิ้งทางขวาและเป็นการตัดทิ้งประเภทที่ 1 คำยวิธีประมาณด้วยภาวะน่าจะเป็นสูงสุด (Maximum Likelihood Estimation Method) วิธีการของสมิธ (Smith Method) และวิธีการโมดิไฟด์แอคชัวเรียล (Modified Acturial Method)

1.5.2 ศึกษามเมื่อค่าที่ถูกตัดทิ้งเป็นค่าที่ถูกตัดทิ้งประเภทที่ 1 (Type I Censoring)

t_c เป็นค่าที่กำหนดไว้ล่วงหน้า

ค่าที่ไม่ถูกตัดทิ้ง T_i มีรูปแบบเป็น

$$T = \beta X + \varepsilon$$

กำหนด

$$\beta = 1$$

จำนวนตัวแปรอิสระที่ทำการศึกษามี 3 ระดับ คือ 3, 5, 7

$$X \sim N(0, 25)^3$$

$$\varepsilon \sim N(0, 25)^3$$

โดยที่ตัวแปรใหม่ที่นำมาใช้ในการวิเคราะห์มาจากการ

$$Y_i = \begin{cases} T_i & \text{เมื่อ } T_i \leq t_c \quad (\text{เป็นข้อมูลที่ไม่ถูกตัดทิ้ง}) \\ t_c & \text{เมื่อ } T_i > t_c \quad (\text{เป็นข้อมูลที่ถูกตัดทิ้ง}) \end{cases}$$

³ การวิจัยครั้งนี้กำหนดเป็นค่าดังกล่าวเนื่องจากทำการทดลองเปลี่ยนค่าเป็นค่าต่างๆ แล้ว ก็ยังทำให้ผลการเปรียบเทียบในแต่ละวิธีการนั้นไม่เปลี่ยนแปลง

1.5.3 ศึกษาเมื่อกรณีสัดส่วนของข้อมูลที่ถูกตัดทิ้งเป็น 0.1,0.2,0.3,0.4,0.5

1.5.4 ศึกษาเมื่อขนาดตัวอย่างเป็น 10,20,30,50,100

1.6 เกณฑ์การตัดสินใจ

เกณฑ์การตัดสินใจว่าการประมาณค่าพารามิเตอร์ด้วยวิธีใดจะเป็นวิธีที่ใช้ได้ จะพิจารณาโดยการเปรียบเทียบค่าความคลาดเคลื่อน ระหว่างค่าประมาณของตัวแปรตามกับค่าจริงในรูปของค่ารากที่สองของค่าเฉลี่ยของความคลาดเคลื่อนกำลังสอง (Square Root of Mean Square Error : RMSE) วิธีการใดให้ค่า RMSE ต่ำกว่าจะเป็นวิธีการประมาณค่าที่ดี

1.7 ประโยชน์ที่คาดว่าจะได้รับ

เพื่อเป็นแนวทางในการตัดสินใจเลือกวิธีการประมาณค่าพารามิเตอร์ในสมการถดถอยเชิงเส้นตรงพหุ เมื่อค่าสังเกตของตัวแปรตามมีค่าที่ถูกตัดทิ้งทางขวาและเป็นการตัดทิ้งประเภทที่ 1 (Type I Censoring)

**ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย**