

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ปัจจุบันเทคนิคการพยากรณ์มีบทบาทต่อวงการต่างๆ เป็นอย่างมาก ซึ่งเทคนิคการพยากรณ์จะมีโครงสร้าง 2 ส่วน ส่วนแรกคือ การสร้างสมการพยากรณ์ ส่วนที่สองคือ การนำสมการพยากรณ์ที่ได้จากส่วนแรกไปใช้ในการพยากรณ์ สำหรับส่วนของการสร้างสมการพยากรณ์นั้น ผู้วิจัยควรที่จะเลือกวิธีการประมาณค่าพารามิเตอร์ที่ให้ตัวประมาณที่ให้ค่าพยากรณ์มีความคลาดเคลื่อนต่ำ

เป็นที่ทราบกันดีว่า การใช้วิธีกำลังสองน้อยที่สุด (Ordinary Least Squares Method) ประมาณค่าพารามิเตอร์ในสมการถดถอยเชิงเส้นอย่างง่าย จะทำให้ตัวประมาณที่ได้เป็นตัวประมาณที่ไม่เอนเอียงเชิงเส้นมีความแปรปรวนต่ำสุด (Best Linear Unbiased Estimator (BLUE)) และโดยทั่วไปจะสมมติว่า ค่าคลาดเคลื่อนสุ่ม (random errors) ในสมการถดถอยมีการแจกแจงแบบปกติ (Normal Distribution) แต่ถ้าค่าคลาดเคลื่อนมิได้มีการแจกแจงแบบปกติ โดยเฉพาะในกรณีที่ค่าคลาดเคลื่อนมีการแจกแจงแบบหางยาว (Fat-tailed Distribution) ซึ่งมักจะแสดงถึงการเกิดค่าผิดปกติ (Outliers) ขึ้นในตัวแปรตาม (Y) จะได้ว่าวิธีกำลังสองน้อยที่สุดจะให้ตัวประมาณที่ให้ค่าพยากรณ์ที่มีความคลาดเคลื่อนสูง ดังนั้นจึงควรพิจารณาวิธีประมาณค่าพารามิเตอร์วิธีอื่นที่สามารถประมาณค่าพารามิเตอร์ได้ดีกว่าวิธีกำลังสองน้อยที่สุดในกรณีที่มีค่าผิดปกติเกิดขึ้นในตัวแปรตาม (Y)

ในการศึกษาครั้งนี้ สนใจที่จะใช้วิธีการประมาณค่าพารามิเตอร์ด้วยวิธีกำลังสองน้อยที่สุด (Ordinary Least Squares Method (OLS)) เปรียบเทียบกับวิธีค่าสัมบูรณ์ต่ำสุด (Least Absolute Value Method (LAV)) ภายใต้การแจกแจงของความคลาดเคลื่อนแบบต่างๆ

1.2 วัตถุประสงค์ของการวิจัย

ศึกษาเปรียบเทียบความคลาดเคลื่อนของการพยากรณ์ จากสมการถดถอยเชิงเส้นอย่างง่ายที่มีการประมาณค่าพารามิเตอร์ด้วยวิธีกำลังสองน้อยที่สุด และวิธีค่าสัมบูรณ์ต่ำสุด

1.3 ข้อยกเว้นเบื้องต้น

1. สมการถดถอยที่ใช้ในการศึกษาครั้งนี้จะใช้สมการถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression Equation) โดยมีรูปแบบสมการดังนี้

$$y_t = \beta_1 + \beta_2 x_t + \varepsilon_t, \quad t = 1, 2, \dots, n$$

y_t เป็นตัวแปรตาม

x_t เป็นตัวแปรอิสระ

β_i เป็นพารามิเตอร์ที่ไม่ทราบค่า $i = 1, 2$

ε_t เป็นค่าความคลาดเคลื่อนสุ่ม

2. ค่าความคลาดเคลื่อนสุ่ม (ε_t) เป็นตัวแปรสุ่มที่มีการแจกแจงเหมือนกัน และเป็นอิสระซึ่งกันและกัน

1.4 สมมติฐานทางการวิจัย

วิธีการค่าสัมบูรณ์ต่ำสุดจะให้ค่าพยากรณ์ที่มีความคลาดเคลื่อนน้อยกว่าวิธีการกำลังสองน้อยที่สุดในกรณีที่ข้อมูลมีค่าผิดปกติ (Outliers) เกิดขึ้นในตัวแปรตาม (Y)

1.5 ขอบเขตของการวิจัย

1. ศึกษาเปรียบเทียบความคลาดเคลื่อนของการพยากรณ์จากสมการถดถอยโดยใช้วิธีการประมาณค่าพารามิเตอร์ 2 วิธี คือ

1.1 วิธีการกำลังสองน้อยที่สุด (Ordinary Least Squares Method)

1.2 วิธีการค่าสัมบูรณ์ต่ำสุด (Least Absolute Value Method)

2. ลักษณะของตัวแปรอิสระที่นำมาศึกษามีรูปแบบดังต่อไปนี้

2.1 รูปแบบอัตตสหสัมพันธ์อันดับที่ 1 (AR(1))

$$X_t = 0.8X_{t-1} + U_t, \quad t = 1, \dots, n$$

$$U_t \sim N(0, 1)$$

$$X_0 \sim N(0, 1/(1-(0.8)^2))$$

2.2 รูปแบบเส้นตรงตามเวลา (Simple Time Trend)

$$X_t = t, \quad t = 1, 2, \dots, n$$

2.3 รูปแบบแนวโน้มไม่คงที่ (Stochastic Trend)

$$X_t = t + U_t, \quad t = 1, 2, \dots, n$$

$$U_t \sim N(0, 1)$$

2.4 รูปแบบแนวโน้มตามคาบเวลา (Periodic Trend)

$$X_t = t + \cos(2\pi t/12), \quad t = 1, 2, \dots, n$$


3. ค่า β_1 และ β_2 มีค่าเท่ากับ 1

4. ลักษณะการแจกแจงของความคลาดเคลื่อนสุ่ม (ε_t)

4.1 การแจกแจงแบบปกติ $N(0, 1)$


$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2} \quad -\infty < x < \infty$$

$$\sigma^2 = 1, \mu = 0$$



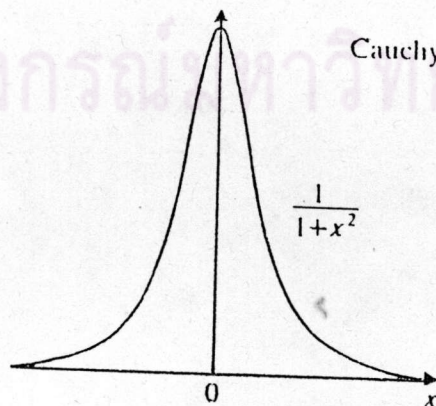
4.2 การแจกแจงแบบสม่ำเสมอ $U(-\sqrt{3}, \sqrt{3})$

$$f(x) = \begin{cases} \frac{1}{2\sqrt{3}} & -\sqrt{3} \leq x \leq \sqrt{3} \\ 0 & \text{อื่น ๆ} \end{cases}$$



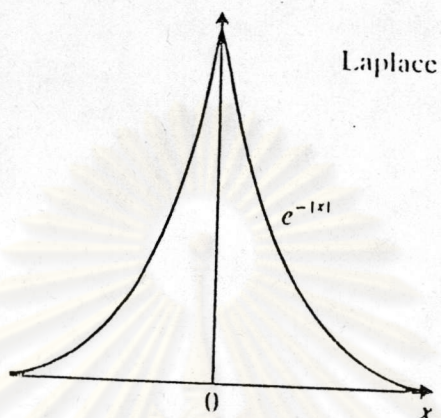
4.3 การแจกแจงแบบโคชี $C(0, 1)$

$$f(x) = \frac{1}{\pi(1+x^2)} \quad -\infty < x < \infty$$




4.4 การแจกแจงแบบลาปลาซ $L(0,1)$

$$f(x) = \frac{1}{2} e^{-|x|} \quad -\infty < x < \infty$$

4.5 การแจกแจงแบบปกติผสมกัน $0.85N(0,1) + 0.15N(0,25)$

$$f(x) = 0.85 \frac{1}{\sqrt{2\pi}} e^{-0.5x^2} + 0.15 \frac{1}{5\sqrt{2\pi}} e^{-0.5x^2/25} \quad -\infty < x < \infty$$



5. ขนาดตัวอย่างที่นำมาศึกษามี 3 ระดับ คือ 15 , 30 , 50
6. สร้างแบบจำลองข้อมูลให้มีสถานการณ์ตามที่ต้องการศึกษา ด้วยเทคนิคมอนติคาร์โลซิโมเลชัน (Monte Carlo Simulation Technique) โดยเครื่องคอมพิวเตอร์ AMDAHL 5860 และเขียนโปรแกรมด้วยภาษาฟอร์แทรน

1.6 ประโยชน์ที่คาดว่าจะได้รับ

1.6.1 ผลการศึกษาเปรียบเทียบสามารถบอกได้ว่า ถ้ามีข้อมูลอยู่ชุดหนึ่งซึ่งมีค่าผิดปกติเกิดขึ้นควรจะใช้วิธีกำลังสองน้อยที่สุดหรือวิธีค่าสัมบูรณ์ต่ำสุดในการประมาณค่าพารามิเตอร์เพื่อนำไปใช้สร้างสมการพยากรณ์ ที่จะให้ค่าพยากรณ์ที่มีค่าคลาดเคลื่อนต่ำ

1.6.2 เพื่อเป็นแนวทางในการศึกษาและวิจัยต่อไป

1.7 วิธีดำเนินการวิจัย

1.7.1 ศึกษาวิธีการประมาณค่าพารามิเตอร์ในสมการถดถอยเชิงเส้นอย่างง่าย และเขียนโปรแกรมจำลองค่าสังเกตของตัวแปรในตัวแทนที่ต้องการศึกษา และเขียนโปรแกรมสำหรับคำนวณค่าพารามิเตอร์ของสมการถดถอยเชิงเส้นอย่างง่ายของวิธีกำลังสองน้อยที่สุดและวิธีค่าสัมบูรณ์ต่ำสุด

1.7.2 ศึกษาเปรียบเทียบค่ารากที่สองของค่าเฉลี่ยของความคลาดเคลื่อนกำลังสองของการพยากรณ์ที่ได้จากการประมาณค่าพารามิเตอร์ด้วยวิธีกำลังสองน้อยที่สุด และวิธีค่าสัมบูรณ์ต่ำสุด ข้อมูลที่ใช้ในการวิจัยครั้งนี้ได้จากการจำลองขึ้นในเครื่องคอมพิวเตอร์ AMDAHL 5860 โดยใช้เทคนิคมอนติคาร์โลซิโมเลชัน และทำซ้ำ 200 รอบ ในแต่ละสถานการณ์

1.8 เกณฑ์ที่ใช้ในการเปรียบเทียบ

เกณฑ์ที่ใช้ในการเปรียบเทียบค่ารากที่สองของค่าเฉลี่ยของความคลาดเคลื่อนกำลังสองของการพยากรณ์ ($RMSFE_t$) ซึ่งค่า $RMSFE_t$ นี้คำนวณจาก

$$RMSFE_t = \sqrt{\frac{\sum_{i=1}^{200} (\hat{y}_{t,i} - y_{t,i})^2}{200}}, t=1, \dots, 12$$

เมื่อ t แทน คาบเวลาที่ทำการพยากรณ์

i คือ รอบที่ทำการพยากรณ์, i มีค่าตั้งแต่ 1 - 200 รอบ

$\hat{y}_{t,i}$ คือ ค่าพยากรณ์ ณ คาบเวลาที่ t รอบที่ i

$y_{t,i}$ คือ ค่าข้อมูลจริง ณ คาบเวลาที่ t รอบที่ i

โดยเกณฑ์ที่ใช้จะพิจารณาจากค่าเปอร์เซ็นต์ความแตกต่าง ($P.D._t$) ระหว่างค่ารากที่สองของค่าเฉลี่ยของความคลาดเคลื่อนกำลังสองจากการพยากรณ์ของวิธีค่าสัมบูรณ์ต่ำสุด ($RMSFE_t(LAV)$) และวิธีกำลังสองน้อยที่สุด ($RMSFE_t(OLS)$) นั่นคือ

$$P.D._t = \frac{RMSFE_t(OLS) - RMSFE_t(LAV)}{RMSFE_t(OLS)} \times 100$$

1.9 คำจำกัดความ

คำจำกัดความที่ใช้ในการวิจัยมีดังนี้

- ค่าผิดปกติ (Outliers) คือ ค่าสังเกตที่มีค่าสูง หรือต่ำกว่าปกติในกลุ่มค่าสังเกตเดียวกัน

- ค่ารากที่สองของค่าเฉลี่ยของความคลาดเคลื่อนกำลังสองของการพยากรณ์ (The Square Root of the Mean Squared Forecast Error (RMSFE_t)) หมายถึง

$$\text{RMSFE}_t = \sqrt{\frac{\sum_{i=1}^{200} (\hat{y}_{t,i} - y_{t,i})^2}{200}}, t=1, \dots, 12$$

เมื่อ t แทน คาบเวลาที่ทำการพยากรณ์

i คือ รอบที่ทำการพยากรณ์, i มีค่าตั้งแต่ 1 - 200 รอบ

$\hat{y}_{t,i}$ คือ ค่าพยากรณ์ ณ คาบเวลาที่ t รอบที่ i

$y_{t,i}$ คือ ค่าข้อมูลจริง ณ คาบเวลาที่ t รอบที่ i

ศูนย์วิทยพัชกร
จุฬาลงกรณ์มหาวิทยาลัย