

## บทที่ 3

# การวิเคราะห์ความถดถอยและสหสัมพันธ์อย่างง่าย (Simple Regression Analysis and Correlation)

### 3.1 การวิเคราะห์ความถดถอย (Regression Analysis)

เป็นการศึกษาถึงความสัมพันธ์ของตัวแปรตั้งแต่ 2 ตัวขึ้นไป โดยมีวัตถุประสงค์ที่จะประมาณหรือพยากรณ์ค่าของตัวแปรตัวหนึ่งจากตัวแปรตัวอื่น ๆ ที่มีความสัมพันธ์กับตัวแปรที่ต้องการพยากรณ์ โดยจะต้องมีการกำหนดหรือทราบค่าตัวแปรอื่น ๆ ล่วงหน้า เช่น ถ้าทราบความสัมพันธ์ระหว่างยอดขายกับค่าโฆษณาแล้ว จะทำให้สามารถประมาณ / พยากรณ์ยอดขายเมื่อกำหนดหรือทราบงบประมาณในการโฆษณา และจะศึกษาถึงการเปลี่ยนแปลงของยอดขายเมื่องบประมาณในการโฆษณาเปลี่ยนแปลงไป โดยอาศัยหลักการของการวิเคราะห์ความถดถอย การวิเคราะห์ความถดถอยมี 2 ประเภท คือ

1. การวิเคราะห์ความถดถอยอย่างง่าย
2. การวิเคราะห์ความถดถอยเชิงพหุ

เป็นการศึกษาถึงความสัมพันธ์ระหว่างตัวแปร 2 ตัว หรือลักษณะที่สนใจศึกษา 2 ลักษณะ โดยที่ต้องทราบค่าของตัวแปรตัวหนึ่งหรือต้องกำหนดค่าของตัวแปรตัวหนึ่งไว้ล่วงหน้า เช่น ถ้าศึกษาถึงความสัมพันธ์ระหว่างรายจ่ายกับรายได้ ยอดขายกับค่าโฆษณา ฯลฯ ซึ่งจะต้องทราบหรือกำหนดรายได้ และค่าโฆษณาไว้ล่วงหน้า เช่น ทราบว่าเงินเดือนพนักงานทำความสะอาดของบริษัทแห่งหนึ่งเป็น 2,000, 2,500, 3,000, 3,500, และ 4,000 บาท ผู้วิเคราะห์จะต้องสอบถามพนักงานทำความสะอาดที่มีเงินเดือนดังกล่าวถึงรายจ่ายต่อเดือน จึงจะสามารถหาความสัมพันธ์ระหว่างรายได้อับรายจ่ายได้ หรือในการหาความสัมพันธ์ระหว่างยอดขาย กับค่าโฆษณาจะต้องทราบถึงงบประมาณในการโฆษณาที่บริษัทกำหนดไว้หรือใช้ไปจริง แล้วจึงจะทราบถึงยอดขาย โดยจะเรียกว่ารายได้ และค่าโฆษณา ซึ่งเป็นตัวแปรที่ต้องกำหนดค่าไว้ล่วงหน้าว่า ตัวแปรอิสระ (Independent Variable) และมักจะใช้สัญลักษณ์  $x$  ส่วนยอดขายกับรายจ่ายจะเรียกว่า ตัวแปรตาม (Dependent Variable) และใช้สัญลักษณ์  $y$  ซึ่งหมายถึง ยอดขายเป็นตัวแปรที่ขึ้นอยู่กับค่าโฆษณา และรายจ่ายเป็นตัวแปรที่ขึ้นกับรายได้

วัตถุประสงค์ของการวิเคราะห์ความถดถอยและสหสัมพันธ์

การวิเคราะห์ความสัมพันธ์ของตัวแปรต่าง ๆ มีวัตถุประสงค์ดังนี้

1. เพื่อศึกษาความสัมพันธ์ระหว่างตัวแปรว่ามีความสัมพันธ์กันมากน้อยเพียงใด ถ้า  $x$  และ  $y$  มีความสัมพันธ์กันมากแสดงว่า ถ้า  $x$  มีค่าเปลี่ยนแปลงไปจะมีผลกระทบต่อค่าของ  $y$  เป็นอย่างมาก

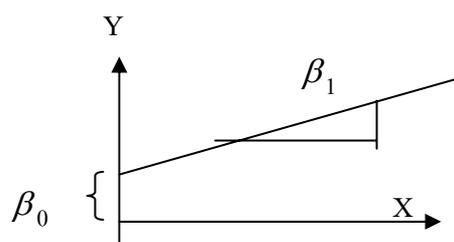
2. ใช้ความสัมพันธ์ที่วิเคราะห์ได้มาประมาณค่าหรือพยากรณ์ค่า  $y$  ในอนาคต เมื่อกำหนดค่า  $x$

สำหรับการหาแบบความสัมพันธ์ระหว่างตัวแปร  $y$  และ  $x$  นั้นในขั้นแรกจะนำเอาข้อมูลของตัวแปรทั้งสองมาเขียนกราฟแสดงความสัมพันธ์ ซึ่งจะเรียกกราฟนี้ว่า แผนภาพการกระจาย (Scatter Diagram) ผู้วิเคราะห์จะต้องพิจารณาจากแผนภาพการกระจายว่าความสัมพันธ์ของตัวแปรทั้งสองจะอยู่ในรูปแบบใด เช่น เส้นตรง พาราโบลา เส้นโค้ง ฯลฯ โดยที่จะต้องสามารถเขียนความสัมพันธ์อยู่ในรูปแบบทางคณิตศาสตร์ได้

### 3.2 การวิเคราะห์ความถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression Analysis)

เป็นการศึกษาถึงความสัมพันธ์ระหว่างตัวแปร 2 ตัว ที่ความสัมพันธ์อยู่ในรูปเชิงเส้น ซึ่งสามารถแสดงความสัมพันธ์ในรูปสมการเชิงเส้นได้ดังนี้

$$y_i = \beta_0 + \beta_1 x_i + e_i \quad ; i=1, 2, \dots,$$



รูปที่ 3.1 ความสัมพันธ์ 2 ตัวแปร ในรูปเชิงเส้น

โดยที่  $y$  คือตัวแปรตาม (Dependent Variable) เนื่องจากค่าของ  $y$  ขึ้นอยู่กับค่าของ  $x$

$x$  = ตัวแปรอิสระ (Independent Variable)

$\beta_0$  = ส่วนตัดแกน  $y$  หรือ คือค่าของ  $y$  เมื่อ  $x$  มีค่าเป็นศูนย์

$e$  = ความคลาดเคลื่อนอย่างสุ่ม (random error)

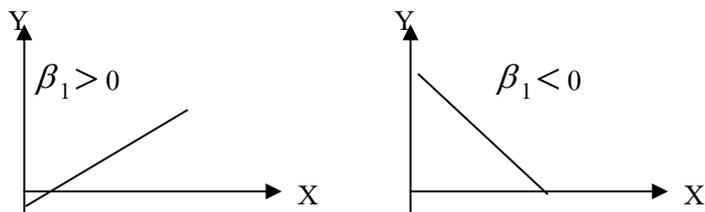
$\beta_1$  = ความชัน (slope) ของเส้นตรง ซึ่งเป็นค่าที่แสดงถึงอัตราการเปลี่ยนแปลงของ  $Y$

เมื่อ  $x$  เปลี่ยนไป 1 หน่วย และจะเรียก  $\beta_1$  ว่าสัมประสิทธิ์ความถดถอย (Regression Coefficient) ค่าของ  $\beta_1$  อาจจะเป็น

1.  $\beta_1 > 0$  แสดงว่า  $x$  และ  $y$  มีความสัมพันธ์ในทางเดียวกันคือถ้า  $x$  เพิ่ม  $y$  จะเพิ่มด้วย แต่ถ้า  $x$  ลดลง  $y$  จะลดลงด้วย

2.  $\beta_1 < 0$  แสดงว่า  $x$  และ  $y$  มีความสัมพันธ์ในทางตรงข้ามกันคือถ้า  $x$  เพิ่ม  $y$  จะลดลง แต่ถ้า  $x$  ลดลง  $y$  จะเพิ่มขึ้น

- $\beta_1$  มีค่าเข้าใกล้ศูนย์ แสดงว่าค่า  $x$  และ  $y$  มีความสัมพันธ์กันน้อย
- $\beta_1 = 0$  แสดงว่า  $x$  และ  $y$  ไม่มีความสัมพันธ์กัน



รูปที่ 3.2 แสดงค่า  $\beta_1$  เมื่อ  $x$  และ  $y$  มีความสัมพันธ์ในรูปเส้นตรง

หน่วยของ  $\beta_0$  และ  $\beta_1$  จะมีหน่วยเหมือนกับหน่วยของ  $Y$  ดังตัวอย่างเช่น

- ให้  $y =$  ยอดขาย มีหน่วยเป็นล้านบาท และ  $x$  เป็นค่าโฆษณาที่มีหน่วยเป็นแสนบาท จะทำให้  $\beta_0$  และ  $\beta_1$  มีหน่วยเป็นล้านบาท
- ให้  $y$  เป็นจำนวน (หน่วย) สินค้าที่ขายได้ และ  $x$  เป็นราคาขายต่อหน่วย (บาท) จะได้  $\beta_0$  และ  $\beta_1$  มีหน่วยเป็นจำนวนสินค้าที่ขายได้ เช่น  $x$  เป็นราคาขายทีวีต่อเครื่อง (บาท)  $y$  เป็นจำนวนทีวีที่ขายได้ (เครื่อง)  $\beta_0$  และ  $\beta_1$  จะมีหน่วยเป็นเครื่อง

### 3.3 สมมติฐานหรือเงื่อนไขของการวิเคราะห์ความถดถอย

- ค่า  $x$  จะต้องเป็นค่าที่กำหนดไว้ล่วงหน้าหรือทราบค่า
- ความคลาดเคลื่อน  $e_i$  เป็นตัวแปรที่มี ค่าเฉลี่ย  $= 0$  หรือ  $E(e_i) = 0$  ค่าแปรปรวนของ  $e_i$  มีค่าเท่ากันทุกค่าของ  $i$  และมีค่าเท่ากับค่าแปรปรวนของ  $y$ 

$$V(e_i) = V(y) = \sigma_{y,x}^2 = \sigma^2$$
- $e_i$  และ  $\theta_j$  เป็นอิสระกัน นั่นคือ  $\text{Cov}(e_i, \theta_j) = E(e_i, \theta_j) = 0; i \neq j$
- $\theta_j$  มีการแจกแจงแบบปกติที่มีค่าเฉลี่ยเป็นศูนย์และค่าแปรปรวน  $\sigma^2$  นั่นเอง

$$\theta_j \sim \text{normal}(0, \sigma^2)$$

จากข้อสมมติข้างต้น จะได้ว่า

$$y_i \sim \text{normal}(E(Y_i), \sigma^2)$$

$$\begin{aligned} \text{โดยที่ } E(y_i) &= E(\beta_0 + \beta_1 x_i + e_i) \\ &= \beta_0 + \beta_1 x_i + E(e_i) \\ &= \beta_0 + \beta_1 x_i \text{ เนื่องจาก } E(e_i) = 0 \end{aligned}$$

### 3.4 การประมาณค่าพารามิเตอร์ของสมการความถดถอย

เมื่อพิจารณาจากแผนภาพการกระจาย ซึ่งแสดงความสัมพันธ์ระหว่าง  $x$  และ  $y$  แล้วพบว่า  $x$  และ  $y$  สัมพันธ์กันในรูปเส้นตรง จะต้องคำนวณหาค่า  $\beta_0$  และ  $\beta_1$  ซึ่งจะทำให้ทราบถึงความสัมพันธ์ระหว่าง  $x$  และ  $y$  ว่ามีความสัมพันธ์ตามกันหรือตรงข้ามกันและความสัมพันธ์นั้นมากหรือน้อยเพียงใด ถ้า  $\beta_1$  มีค่ามากกว่าแสดงว่า  $y$  มีความสัมพันธ์กับ  $X$  มากด้วย

การที่จะหาค่า  $\beta_0$  และ  $\beta_1$  ได้จำเป็นต้องทราบค่า  $x$  และ  $y$  ทุกค่าที่ได้เกิดขึ้นแล้วในอดีตเช่น ถ้า  $x =$  รายได้ของคนกรุงเทพมหานคร (กทม.)  $y =$  รายจ่ายของคนกทม. การหาค่า  $\beta_0$  และ  $\beta_1$  จะต้องทราบถึงรายได้และรายจ่ายของคนกทม. ทุกคน ซึ่งเป็นไปได้ยากในทางปฏิบัติเราจึงใช้ข้อมูลตัวอย่างขนาด  $n$  ในการประมาณค่า  $\beta_0$  และ  $\beta_1$  ดังนั้นค่าประมาณของ  $y$  คือ

$$y_i = \beta_0 + \beta_1 x_i$$

$$\text{หรือ } \hat{y}_i = a + bx_i$$

$$\text{โดยที่ } \hat{\beta}_0 = a, \quad \hat{\beta}_1 = b$$

#### 3.4.1 การประมาณค่า $\beta_0$ และ $\beta_1$ โดยวิธีกำลังสองน้อยที่สุด

การประมาณค่า  $\beta_0$  และ  $\beta_1$  ด้วย  $a$  และ  $b$  ตามลำดับขั้น มีเป้าหมายเพื่อให้ความคลาดเคลื่อนในการประมาณค่า  $y_i$  ด้วย  $\hat{y}_i$  มีค่าต่ำสุด โดยใช้วิธีที่เรียกว่า วิธีกำลังสองน้อยที่สุด (Least Square Method) ซึ่งเป็นวิธีที่ต้องการหาค่า  $a$  และ  $b$  ที่ทำให้ผลบวกของค่าคลาดเคลื่อนยกกำลังสองมีค่าน้อยที่สุด

$$\text{เนื่องจาก } y_i = \beta_0 + \beta_1 x_i + e_i$$

$$\text{หรือ } \hat{y}_i = a + bx_i$$

$$\therefore y_i - \hat{y}_i = e_i$$

$$\text{ผลบวกของค่าคลาดเคลื่อนยกกำลังสอง} = \sum_{i=1}^n e_i^2 = \sum \left( y_i - \hat{y}_i \right)^2$$

ดังนั้นวิธีกำลังสองน้อยที่สุดคือการหาค่า  $a$  และ  $b$  ที่ทำให้  $\sum_{i=1}^n e_i^2$  มีค่าต่ำสุด

การที่ประมาณค่า  $\beta_0$  และ  $\beta_1$  ด้วยค่า  $a$  และ  $b$  โดยใช้วิธีกำลังสองน้อยที่สุดจะทำให้

1. ผลรวมของค่าคลาดเคลื่อนในการประมาณค่า  $y_i$  ด้วย  $\hat{y}_i$  เป็นศูนย์ คือ

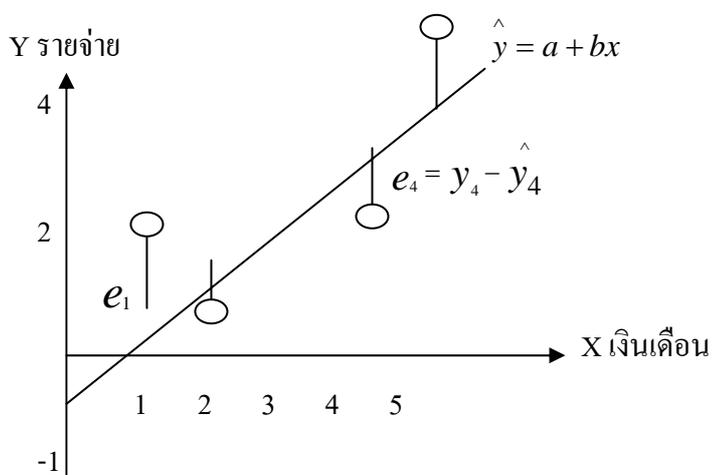
$$\sum \left( y_i - \hat{y}_i \right) = \sum e_i = 0$$

2. จุด  $(x, \bar{y})$  เป็นจุดที่อยู่บนเส้นความถดถอย

3.  $\sum (y_i - \hat{y}_i)^2$  มีค่าต่ำสุด

### 3.5 การประมาณค่าแปรปรวนของความคลาดเคลื่อน

ในการประมาณค่า  $y = \beta_0 + \beta_1 x + e$  ด้วย  $\hat{y} = a + bx$  ซึ่งจะเกิดค่าคลาดเคลื่อนในการประมาณ  $y_i$  ด้วย  $\hat{y}_i$  เป็น  $e = y_i - \hat{y}_i$  ดังแสดงในรูป



รูปที่ 3.3 แสดงค่าคลาดเคลื่อน

จากหัวข้อที่ 3.3 ได้ว่า  $e_j \sim \text{normal}(0, \sigma^2)$

และ  $Y_i \sim \text{normal}(E(Y_i), \sigma^2)$

$$\begin{aligned} \sigma^2 &= v(y_i) = v(e_i) = E(e_i - E(e_i))^2 \\ &= E(e_i - 0)^2 = E(e_i)^2 = E(y_i - \hat{y}_i)^2 = \sigma_{y,x}^2 \end{aligned}$$

การใช้สัญลักษณ์  $\sigma_{y,x}^2$  หมายถึงค่าแปรปรวนของ Y ที่เกิดขึ้นเนื่องจากอิทธิพลของ X โดยทั่วไปจะใช้สัญลักษณ์  $\sigma^2$  แทน  $\sigma_{y,x}^2$

ค่าประมาณของ  $\sigma_{y,x}^2$  คือ  $S_{y,x}^2$  หรือ  $S^2$  โดยที่  $S^2 = \frac{\sum (y_i - \hat{y}_i)^2}{n-2}$  หรือ

$$S^2 = \frac{SSE}{n-2}$$

### 3.6 สัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient)

จากหัวข้อที่ 3.1-3.5 เป็นการวิเคราะห์เพื่อหาความสัมพันธ์ของตัวแปร  $x$  และ  $y$  และเป็นการทดสอบว่า  $x$  และ  $y$  มีความสัมพันธ์กันหรือไม่ โดยการทดสอบสัมประสิทธิ์ความถดถอย ( $\beta_1$ ) โดยใช้ตัวประมาณ ( $b$ ) ซึ่งไม่สามารถระบุได้ว่า  $x$  และ  $y$  มีความสัมพันธ์กันมากหรือน้อย เนื่องจากค่า  $b$  ที่ได้มีหน่วยตามค่าของ  $y$  เช่น  $y$  มีหน่วยเป็นบาท ค่า  $b$  จะมีหน่วยเป็นบาทด้วย แต่ถ้าค่า  $y$  มีหน่วยเป็นล้านบาท ค่า  $b$  จะมีหน่วยเป็นล้านบาทด้วย การที่ค่า  $b$  ที่มีหน่วยเป็นบาทมีค่ามากกว่าค่า  $b$  ที่มีหน่วยเป็นล้านบาท ไม่ได้หมายความว่าความสัมพันธ์  $x$  และ  $y$  ที่  $y$  มีหน่วยเป็นบาทจะมีความสัมพันธ์กันมากกว่ากรณีที่  $y$  มีหน่วยเป็นล้านบาท นั่นคือการที่กำหนดให้หน่วยของ  $y$  แตกต่างกัน จะทำให้ค่า  $b$  แตกต่างกันได้ ( $x$  และ  $y$  ไม่จำเป็นต้องมีหน่วยเหมือนกัน)

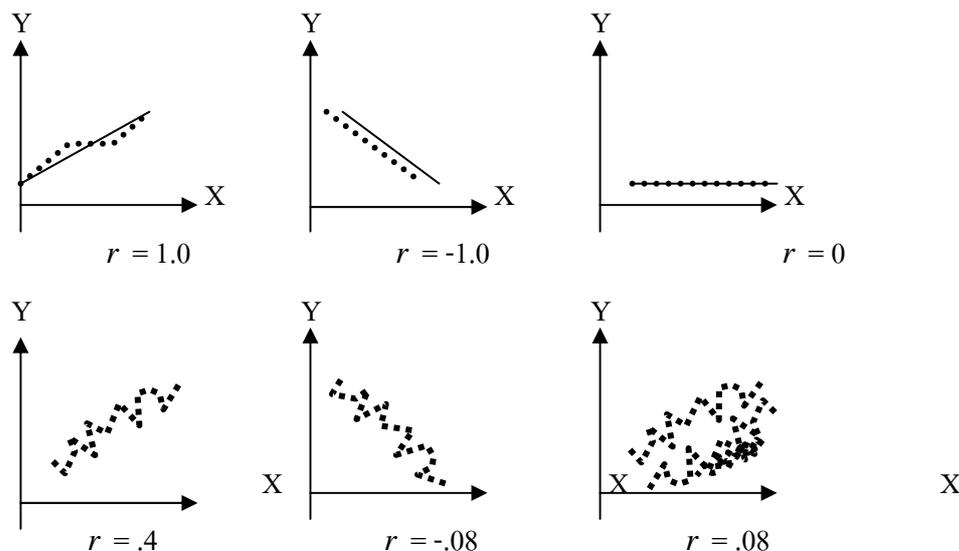
สำหรับสถิติที่ใช้วัดความสัมพันธ์ระหว่าง  $x$  และ  $y$  ว่ามากหรือน้อยนั้นจะเรียกว่า สัมประสิทธิ์สหสัมพันธ์ ( $\rho$ ) ซึ่งในกรณีที่ค่าของ  $y$  ขึ้นกับ  $x$  เพียงตัวเดียวจะเรียกว่า สัมประสิทธิ์สหสัมพันธ์อย่างง่าย (Simple Correlation Coefficient) โดยที่  $\rho$  จะไม่มีหน่วย จึงสามารถใช้วัดความสัมพันธ์ระหว่าง  $y$  และ  $x$  ได้ว่ามีความสัมพันธ์มากหรือน้อยเพียงใด เนื่องจากค่า  $\rho$  จะมีค่าสูงสุดเป็น 1 และต่ำสุดเป็น -1

นอกจากนั้นความถดถอยและสหสัมพันธ์ยังมีวิธีการในการเก็บข้อมูลที่แตกต่างกัน คือ สำหรับเรื่องความถดถอยตัวแปรอิสระ  $x$  จะต้องถูกกำหนดไว้ล่วงหน้า ในขณะที่เป็นตัวแปรตามหรือ  $y$  เป็นตัวแปรสุ่ม แต่สหสัมพันธ์นั้นทั้ง  $x$  และ  $y$  จะเป็นตัวแปรสุ่มทั้งคู่

เนื่องจากเราใช้ข้อมูลตัวอย่าง จึงประมาณค่า  $\rho$  ด้วยค่า  $r$  โดยที่  $r$  คือ สัมประสิทธิ์สหสัมพันธ์ตัวอย่าง

ความหมายของค่า  $r$

1. ค่า  $r$  เป็นลบ แสดงว่า  $x$  และ  $y$  มีความสัมพันธ์ในทิศทางตรงข้าม คือถ้า  $x$  เพิ่ม  $y$  จะลด แต่ถ้า  $x$  ลด  $y$  จะเพิ่ม
2. ค่า  $r$  เป็นบวกแสดงว่า  $x$  และ  $y$  มีความสัมพันธ์ในทางเดียวกัน คือ ถ้า  $x$  เพิ่ม  $y$  จะเพิ่มด้วย แต่ถ้า  $x$  ลด  $y$  จะลดลงด้วย
3. ถ้า  $r$  มีค่าเข้าใกล้ 1 หมายถึง  $x$  และ  $y$  สัมพันธ์ในทิศทางเดียวกันและมีความสัมพันธ์กันมาก
4. ถ้า  $r$  มีค่าเข้าใกล้ -1 หมายถึง  $x$  และ  $y$  สัมพันธ์ในทิศทางตรงกันข้ามและมีความสัมพันธ์กันมาก
5. ถ้า  $r = 0$  แสดงว่า  $x$  และ  $y$  ไม่มีความสัมพันธ์กัน
6. ถ้า  $r$  เข้าใกล้ 0 แสดงว่า  $x$  และ  $y$  มีความสัมพันธ์กันน้อย



รูปที่ 3.4 แสดงค่าของ  $r$  ที่มีค่า  $-1 < r < 1$

ในทางปฏิบัติที่พิจารณาว่าตัวแปร  $x$  และ  $y$  มีความสัมพันธ์กันมากหรือน้อย จะพิจารณาจากค่า  $r$  (ไม่ใช่จากค่า  $b$ ) เนื่องจาก  $r$  ไม่มีหน่วย และมีขอบเขตคือมีต่ำสุด = -1 ค่าสูงสุด = 1 นอกจากนั้น  $r$  และ  $b$  จะมีเครื่องหมายเดียวกัน คือ เป็นบวกเหมือนกันหรือเป็นลบเหมือนกัน เนื่องจากทั้ง  $r$  และ  $b$  เป็นค่าแสดงถึงความสัมพันธ์ระหว่าง  $x$  และ  $y$

ความสัมพันธ์ระหว่างสัมประสิทธิ์การตัดสินใจ และสัมประสิทธิ์สหสัมพันธ์ สำหรับเมื่อมี 2 ตัวแปร

$$\begin{aligned} \text{สัมประสิทธิ์สหสัมพันธ์} &= \sqrt{\text{สัมประสิทธิ์การตัดสินใจ}} \\ \text{หรือ} \quad r &= \sqrt{r^2} \end{aligned}$$

### 3.7 แนวทางการประมาณค่าพารามิเตอร์

เมื่อต้องการศึกษาธรรมชาติของประชากรหนึ่ง ผู้ศึกษาต้องทราบว่าใช้ตัวแปรสุ่มใดแสดงธรรมชาติของประชากรนั้น สมมติว่าผู้ศึกษาจะใช้ตัวแปรสุ่ม  $x$  ในการแสดงคุณสมบัติของประชากร  $x$  อาจจะเป็นตัวแปรสุ่มมิติเดียว หรือหลายมิติ (เวกเตอร์) ก็ได้ ในการนี้การแจกแจงความน่าจะเป็นของ  $x$  มีความสำคัญ นำไปสู่ธรรมชาติหรือคุณสมบัติของประชากรได้ เช่น ทำให้ทราบค่าเฉลี่ยและความแปรปรวนของประชากรได้ โดยทั่วไปแล้วฟังก์ชันการแจกแจง (ความน่าจะเป็น) หรือฟังก์ชันความหนาแน่น (ของความน่าจะเป็น) ของตัวแปรสุ่ม มักขึ้นอยู่กับค่าของพารามิเตอร์ตัวหนึ่งหรือมากกว่า พารามิเตอร์ดังกล่าวมักเป็นตัวไม่ทราบค่า ดังนั้นการประมาณ

ค่าพารามิเตอร์จึงเป็นสิ่งที่ควรศึกษา เมื่อประมาณค่าพารามิเตอร์ได้แล้ว จะทำให้ผู้ศึกษาสามารถประมาณพารามิเตอร์อื่น ๆ ที่สนใจได้อีก เช่น ถ้าตัวแปรสุ่ม  $x$  มีฟังก์ชันการแจกแจงขึ้นอยู่กับพารามิเตอร์  $\theta$  สิ่ง que แสดงคุณสมบัติบางประการของประชากรมักเป็นฟังก์ชันของ  $\theta$  ด้วย เช่น ค่าเฉลี่ยของประชากรหรือค่าคาดหมาย และความแปรปรวนของประชากร  $\mu = E(X)$  ก็จะเป็นฟังก์ชันของ  $\sigma^2 = E(X - \mu)^2$  การประมาณค่าของ  $\theta$  จึงทำให้ผู้ศึกษาสามารถประมาณ  $\mu$  และ  $\sigma^2$  ได้อีกด้วย

ในการประมาณพารามิเตอร์นั้น ต้องใช้ข้อมูลหรือค่าสังเกตจากตัวอย่าง กล่าวคือ จะใช้สถิติบางตัว มาเป็นตัวประมาณพารามิเตอร์ที่สนใจ ในการนี้จะต้องใช้ตัวอย่างสุ่ม เนื่องจากจะทำให้เราได้ข้อมูลโดยไม่ใช้ความรู้สึก ความเห็น ความชอบ ความเชื่อมั่น (ที่อาจผิด) หรือความเอนเอียงที่อาจมีของผู้ศึกษา หรือผู้ทำหน้าที่เก็บรวบรวมข้อมูล สามารถวัดระดับความคลาดเคลื่อนของค่าประมาณได้ นอกจากนี้ทฤษฎีสถิติที่ใช้ในการวิเคราะห์ข้อมูลล้วนมีพื้นฐานมาจากการใช้ตัวอย่างสุ่มทั้งสิ้น ดังนั้นหากใช้ข้อมูลจากตัวอย่างที่มีใช้ตัวอย่างสุ่มแล้ว อาจทำให้ผู้ศึกษาไม่สามารถใช้วิธีการทางสถิติที่มีผู้พัฒนาขึ้นมาแล้วอย่างถูกต้องได้ ไม่สามารถวัดระดับความคลาดเคลื่อนของการประมาณ ผลการศึกษาอาจไม่ใกล้เคียงความเป็นจริง ที่เราจะศึกษาต่อไปจึงอาศัยตัวอย่างสุ่มเป็นพื้นฐานสำคัญ

**นิยาม 1.** ให้  $x$  เป็นตัวแปรสุ่มที่มีฟังก์ชันความหนาแน่นขึ้นอยู่กับพารามิเตอร์  $\theta$  ที่ไม่ทราบค่า เซตของ  $\theta$  (ซึ่งอาจเป็นเวกเตอร์  $\theta = (\theta_1, \theta_2, \dots, \theta_n)$  ในกรณีทั่วไป) ที่เป็นไปได้ทั้งหมดเรียกว่า **ปริภูมิพารามิเตอร์** (Parameter space) และมักแทนด้วย  $\Omega$

ถ้า  $X$  มีฟังก์ชันความหนาแน่น  $f(x)$  ที่ขึ้นอยู่กับพารามิเตอร์  $\theta$  เรามักเขียนฟังก์ชันนั้นในรูป  $f(x; \theta)$  หรือ  $f(x|\theta)$  ดังนั้น เซต  $\{f(x; \theta) : \theta \in \Omega\}$  จึงหมายถึง วงศ์ (Family) ของฟังก์ชันความหนาแน่นของ  $x$  ที่เป็นไปได้ทั้งหมด

ถ้า  $f(x)$  มีการแจกแจงแบบปกติ ซึ่งมีค่าเฉลี่ย  $\mu$  และความแปรปรวน  $\sigma^2$  ฟังก์ชันความหนาแน่นของ  $X$  ได้แก่

$$f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}, \quad -\infty < x < \infty, \quad -\infty < \mu < \infty, \quad \sigma^2 > 0$$

ในกรณีนี้ปริภูมิพารามิเตอร์ คือ

$$\Omega = \{(\mu, \sigma^2) : -\infty < \mu < \infty, \sigma^2 > 0\}$$

หรือส่วนบนของระนาบนั้นเอง

ถ้า  $x$  มีการแจกแจงแบบปกติที่มีค่าเฉลี่ย  $\mu$  และความแปรปรวน  $\sigma^2 = \sigma_0^2 =$  ค่าคงที่ที่ทราบค่า

$$f(x; \mu) = \frac{1}{\sqrt{2\pi\sigma_0^2}} e^{-\frac{1}{2\sigma_0^2}(x-\mu)^2}, -\infty < x < \infty, -\infty < \mu < \infty$$

ในกรณีนี้ปริภูมิพารามิเตอร์ คือ

$$\begin{aligned}\Omega &= \{(\mu, \sigma_0^2) : -\infty < \mu < \infty\} \\ &= \{\mu : -\infty < \mu < \infty\}\end{aligned}$$

หรือเส้นจำนวนจริงนั่นเอง

ถ้า  $x$  มีการแจกแจงแบบปกติที่มีค่าเฉลี่ย  $\mu = 0$  และความแปรปรวน  $\sigma^2$

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

ในกรณีนี้ปริภูมิพารามิเตอร์ คือ

$$\begin{aligned}\Omega &= \{(0, \sigma^2) : \sigma^2 > 0\} \\ &= \{\sigma^2 : \sigma^2 > 0\}\end{aligned}$$

หรือครึ่งขวาของเส้นจำนวนจริงนั่นเอง

**การประมาณค่า (Estimation)** ในที่นี้ก็คือ การใช้ข้อมูลจากตัวอย่างสุ่ม ในรูปของค่าสถิติ เพื่อกะประมาณ หรือคาดหมายว่าพารามิเตอร์  $\theta$  ควรจะมีค่าเท่าใดหรืออยู่ในช่วงใด มีการสร้างตัวประมาณ หรือสูตร (ฟังก์ชัน) ที่ใช้ในการหาค่าประมาณ การดำเนินการประมาณพารามิเตอร์จึงมี 2 แนวทางด้วยกัน คือ

1) **การประมาณด้วยจุด (Point estimation)** หมายถึง การประมาณพารามิเตอร์ออกมาเป็นค่าเดียวหรือจุดเดียว

**นิยาม 2.** ให้  $X_1, \dots, X_n$  เป็นตัวอย่างสุ่มจากประชากรที่มีฟังก์ชันความหนาแน่น  $f(x; \theta)$ ,  $\theta \in \Omega$

**ตัวประมาณ (Estimator)** ของ  $\theta$  คือ ฟังก์ชันของตัวอย่างสุ่ม  $\hat{\theta} = \hat{\theta}(x_1, \dots, x_n)$

**ค่าประมาณ (Estimate)** ของ  $\theta$  คือ ค่าหนึ่งของตัวประมาณ  $\hat{\theta}$  ของ  $\theta$  นั่นคือ ถ้า  $X_1 = x_1, \dots, x_n = x_n$  เป็นข้อมูลจากตัวอย่างสุ่ม  $x_1, \dots, x_n$  ค่าประมาณของ  $\theta$  คือ  $\hat{\theta}(x_1, \dots, x_n)$

คำว่าตัวประมาณและค่าประมาณพารามิเตอร์  $\theta$  มีความแตกต่างกัน เช่นเดียวกับคำว่าฟังก์ชันและค่าของฟังก์ชัน ตัวประมาณเป็นฟังก์ชันของตัวอย่างสุ่ม แต่ค่าประมาณเป็นค่าของฟังก์ชันหรือค่าของตัวประมาณนั่นเอง

ตัวประมาณฟังก์ชันที่บอกหลักเกณฑ์หรือสูตรที่ใช้ในการหาค่าประมาณ

การประมาณด้วยจุด เป็นการค้นหาตัวประมาณที่เหมาะสม เพื่อใช้ประมาณพารามิเตอร์ การหาค่าประมาณกระทำเมื่อได้มีการเก็บรวบรวมข้อมูลมาแล้ว

อย่างไรก็ตาม มีผู้ใช้คำว่าค่าประมาณในความหมายของตัวประมาณด้วย แต่ไม่มีใครใช้ตัวประมาณในความหมายของค่าประมาณเลย

**2) การประมาณด้วยช่วง (Interval estimation)** หมายถึง การประมาณพารามิเตอร์  $\theta$  ออกมาเป็นหลายค่า มักเป็นช่วง(ของจำนวนจริง) หรือเซตของจุดหลายจุด เรียกว่า ช่วงความเชื่อมั่น (Confidence interval) หรือเซตความเชื่อมั่น (Confidence set) ช่วงหรือเซตดังกล่าวได้มาโดยอาศัยตัวประมาณ  $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$  ของ  $\theta$  มีการใช้การแจกแจงความน่าจะเป็นของ  $\hat{\theta}(X_1, \dots, X_n)$  ในการสร้างช่วงความเชื่อมั่นหรือเซตความเชื่อมั่น และใช้ข้อความที่เกี่ยวกับความน่าจะเป็นประกอบด้วย

### 3.8 คุณสมบัติที่พึงปรารถนาของตัวประมาณ

ในการประมาณพารามิเตอร์ด้วยจุด เป็นการใช้ฟังก์ชัน  $\hat{\theta} = \hat{\theta}(x_1, \dots, x_n)$  ของตัวอย่างสุ่ม  $X_1, \dots, X_n$  ซึ่งอาจใช้ฟังก์ชันที่มีคุณสมบัติที่พึงปรารถนาบางประการเป็นตัวประมาณของ  $\theta$  การพิจารณาคุณสมบัติของ  $\hat{\theta}$  ส่วนใหญ่อาศัยการแจกแจงของการสุ่มตัวอย่าง ในหลายกรณีจะมี  $\hat{\theta}$  ที่อาจใช้ได้หลายตัวหรือหลายฟังก์ชัน จึงควรมีหลักเกณฑ์ที่ใช้พิจารณาคุณสมบัติที่พึงปรารถนาของตัวประมาณ เพื่อให้เลือกใช้ตัวประมาณให้เหมาะสม แต่หลักเกณฑ์ที่ใช้เลือกตัวประมาณที่เหมาะสมมีอยู่หลายหลักเกณฑ์ ตัวประมาณตัวหนึ่งอาจมีคุณสมบัติที่พึงปรารถนาได้หลายประการด้วย

นักสถิติมีวิธีการหาตัวประมาณที่เหมาะสมอยู่หลายวิธี ดังจะพิจารณาต่อไป บางครั้งการใช้สามัญสำนึกอาจนำไปสู่ตัวประมาณที่มีคุณสมบัติที่พึงปรารถนาบางประการด้วยซ้ำ เช่น ในการแจกแจงแทบทุกชนิดมักใช้ค่าเฉลี่ยของตัวอย่างเป็นตัวประมาณของค่าเฉลี่ยของประชากร และค่าเฉลี่ยของตัวอย่างมักมีคุณสมบัติที่พึงปรารถนาหลายประการ หลายครั้งวิธีการหา ตัวประมาณของค่าเฉลี่ยของประชากรก็ให้ผลเป็นค่าเฉลี่ยของตัวอย่างด้วย อย่างไรก็ตามยังมีตัวประมาณอื่น ๆ ของค่าเฉลี่ยของประชากรอีก เช่น อาจใช้มัธยฐานตัวอย่าง ค่ากึ่งกลางพิสัยตัวอย่าง ค่าฐานนิยมตัวอย่าง ฯลฯ ในการประมาณค่าเฉลี่ยของประชากร จึงควรเลือกใช้ตัวประมาณให้เหมาะสมกับสถานการณ์ และมีคุณสมบัติที่พึงปรารถนาบางประการ

คุณสมบัติที่พึงปรารถนาของตัวประมาณที่อาจใช้เป็นเกณฑ์ในการประเมินการเลือกใช้ให้เหมาะสมมีหลายประการ ที่จะพิจารณาต่อไปได้แก่

- 1) ความไม่เอนเอียง (Unbiased ness)
- 2) ความคงเส้นคงวา หรือความไม่ขัดแย้งกัน (Consistency)
- 3) ความพอเพียง (Sufficiency)
- 4) ความมีความแปรปรวนต่ำสุด (Minimum Variance)
- 5) ความมีประสิทธิภาพ (Efficiency)
- 6) ความมีความคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุด (Minimum mean squared error)
- 7) ความยืนยง หรือความไม่เปลี่ยนแปลง (Invariance)

### 3.9 ตัวประมาณไม่เอนเอียง

นิยาม 3. ตัวประมาณ  $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$  เป็นตัวประมาณไม่เอนเอียง (Unbiased estimator) ของพารามิเตอร์  $\theta$  ก็ต่อเมื่อ

$$E(\hat{\theta}) = \theta$$

$\hat{\theta}$  เป็นตัวประมาณเอนเอียง (Biased estimator) ของ  $\theta$  ก็ต่อเมื่อ  $E(\hat{\theta}) \neq \theta$  และเรียกผลต่าง

$E(\hat{\theta}) - \theta$  ว่าค่าเอนเอียง (Bias) ของ  $\hat{\theta}$  ในการประมาณ  $\theta$

วิธีการหาตัวประมาณที่ไม่เอนเอียงของพารามิเตอร์ทำได้หลายวิธี เช่น

1) ใช้สามัญสำนึก โดยเลือกตัวประมาณ  $\hat{\theta}$  ของ  $\theta$  มาตัวหนึ่ง แล้วหาค่าคาดหวังของตัวประมาณนั้น ถ้า  $E(\hat{\theta}) = a\theta + b$  เมื่อ  $a, b$  เป็นค่าคงที่และ  $a \neq 0$  เราอาจปรับแก้ได้

$$\hat{\theta}_1 = \frac{1}{a}(\hat{\theta} - b)$$

เป็นตัวประมาณไม่เอนเอียงของ  $\theta$

2) ใช้คุณสมบัติของตัวประมาณของ  $\theta$  ที่ได้มาโดยวิธีการหนึ่ง (ตามรูปแบบ) ที่เป็นตัวประมาณไม่เอนเอียงของ  $\theta$  เช่น ตัวแบบเชิงเส้นอย่างง่ายของ  $Y$  บน  $X$  ที่  $Y = \alpha + \beta X + \varepsilon$  ภายใต้ข้อสมมติฐาน ตัวประมาณแบบกำลังสองต่ำสุด (Least squares estimators) ของ  $\alpha$  และ  $\beta$  เป็นตัวประมาณไม่เอนเอียง

3) เลือกตัวประมาณ  $\hat{\theta}$  ของ  $\theta$  มาตัวหนึ่ง แล้วหา  $E(\hat{\theta})$  ถ้าได้  $E(\hat{\theta}) = \theta$  แสดงว่า  $\hat{\theta}$  เป็นตัวประมาณไม่เอนเอียงของ  $\theta$  แต่ถ้า  $E(\hat{\theta}) \neq \theta$  พยายามหาตัวประมาณไม่เอนเอียงของค่าเอนเอียง  $b(\theta) = E(\hat{\theta}) - \theta$  นำมาปรับแก้  $\hat{\theta}$  จะได้ตัวประมาณไม่เอนเอียงของ  $\theta$

4) หาวิธีการลดค่าเอนเอียงของ  $\hat{\theta}$  ลง เช่น ใช้วิธีแจคไนฟ์ (Jackknife) ตามแบบของ เควนูลล์ (Quenouille) ที่จะกล่าวต่อไป

ตัวประมาณไม่เอนเอียงของ  $\theta$  ถ้ามี อาจมีได้หลายตัวก็ได้

**ทฤษฎีบทที่ 1.** ให้  $X_1, \dots, X_n$  เป็นตัวอย่างสุ่มจากประชากรหนึ่งที่มีค่าเฉลี่ย  $\mu$  และความแปรปรวน  $\sigma^2$  แล้ว

1)  $\hat{\mu} = \sum_{i=1}^n a_i X_i$  ที่  $\sum_{i=1}^n a_i = 1$  เป็นตัวประมาณไม่เอนเอียงของ  $\mu$  ที่มีความแปรปรวน  $\sigma^2 \sum_{i=1}^n a_i^2$

2)  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  เป็นตัวประมาณไม่เอนเอียงของ  $\mu$  ที่มีความแปรปรวน  $\frac{\sigma^2}{n}$

3)  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  เป็นตัวประมาณไม่เอนเอียงของ  $\sigma^2$  ที่มีความแปรปรวน  $\frac{1}{n} \left[ \mu_4 - \frac{n-3}{n-1} \sigma^4 \right]$  เมื่อ  $\mu_4 = E(X - \mu)^4$  คือ โมเมนต์ที่ 4 รอบ  $\mu$  ของประชากร

**ทฤษฎีบทที่ 2** ถ้า  $\hat{\theta}$  เป็นตัวประมาณไม่เอนเอียงของ  $\theta$  และ  $V(\hat{\theta})$  มากกว่า 0 แล้ว  $\sqrt{\hat{\theta}}$  เป็นตัวประมาณเอนเอียงของ  $\sqrt{\theta}$

พิสูจน์ จากอสมการโคชี-ชวอร์ท<sup>1</sup> (Cauchy-Schwartz inequality)

$$E\left(\sqrt{\hat{\theta}}\right) \cdot E\left(\sqrt{\hat{\theta}}\right) \leq E\left(\sqrt{\hat{\theta}} \cdot \sqrt{\hat{\theta}}\right) = 0$$

เราได้  $E\left(\sqrt{\hat{\theta}}\right) \leq \sqrt{\theta}$  ซึ่งจะเป็นสมการเมื่อ  $V(\hat{\theta}) = 0$

<sup>1</sup> อสมการนี้กล่าวว่าถ้า เป็นตัวแปรสุ่มใด ๆ ซึ่งอสมการจะเป็นสมการ ก็ต่อเมื่อ สำหรับค่าคงที่บางตัว

ดังนั้น  $E\sqrt{\hat{\theta}} \neq \sqrt{\theta}$  หรือ  $\sqrt{\hat{\theta}}$  เป็นตัวประมาณที่เอนเอียงของ  $\sqrt{\theta}$

ในบางกรณีอาจไม่มีตัวประมาณไม่เอนเอียงของพารามิเตอร์เลยก็ได้ เช่นเมื่อประชากรมีการแจกแจงแบบปัวส์ซองที่มีพารามิเตอร์  $\theta$  เราสามารถหาตัวประมาณไม่เอนเอียงของ  $\theta$  ได้ (คือ  $\bar{X}$ ) แต่จะไม่มีตัวประมาณไม่เอนเอียงของ  $\frac{1}{\theta}$

ถ้า  $\hat{\theta}$  เป็นตัวประมาณเอนเอียงของ  $\theta$  โดยใช้ตัวอย่างขนาด  $n$  เควนบูลล์ ได้เสนอวิธีการหาตัวประมาณของพารามิเตอร์  $\theta$  จาก  $\hat{\theta}$  ที่มีค่าเอนเอียงต่ำลงวิธีหนึ่ง วิธีการของเควนบูลล์เป็นดังนี้

ให้  $\hat{\theta}_{n-1}$  เป็นค่าประมาณที่คิดจากค่า  $n-1$  ค่าของตัวอย่างสุ่ม  $X_1, \dots, X_n$  โดยใช้ตัวประมาณ  $\hat{\theta}_n$  (รูปเดียวกัน)

ให้  $\hat{\theta}'_{n-1}$  เป็นค่าเฉลี่ย (เลขคณิต) ของ  $\hat{\theta}_{n-1}$  ที่เป็นไปได้ทั้งหมด (ซึ่ง  $\hat{\theta}_{n-1}$  จะมีทั้งสิ้น  $n$  ค่า) และให้

$$\hat{\theta}'_n = n\hat{\theta}_n - (n-1)\hat{\theta}_{n-1}$$

ผลปรากฏว่า  $\hat{\theta}'_n$  มีค่าเอนเอียงน้อยกว่า  $\hat{\theta}_n$

ในการทำงานเดียวกัน

$$\hat{\theta}''_n = \frac{n^2 \hat{\theta}'_n + (n-1)^2 \hat{\theta}'_{n-1}}{n^2 - (n-1)^2}$$

จะมีค่าเอนเอียงน้อยกว่า  $\hat{\theta}'_n$  ในการประมาณ  $\theta$

### 3.10 ตัวประมาณคงเส้นคงวา

นิยาม 4 ให้  $\hat{\theta}_n$  เป็นตัวประมาณของ  $\theta$  ที่มาจากตัวอย่างขนาด  $n$  เราถือว่า  $\hat{\theta}_n$  เป็นตัวประมาณคงเส้นคงวา หรือตัวประมาณไม่ขัดแย้งกัน (Consistent estimator) ของ  $\theta$  ก็ต่อเมื่อ  $\hat{\theta}_n$  ลู่เข้าในความน่าจะเป็น (Converge in probability or converge stochastically) ไปหา  $\theta$  นั่นคือ เมื่อ  $\epsilon$  เป็นจำนวนจริงบวกใด ๆ

$$\lim_{n \rightarrow \infty} P \left[ \left| \hat{\theta}_n - \theta \right| \geq \epsilon \right] = 0$$

หรือเมื่อ  $\epsilon$  และ  $\delta$  เป็นจำนวนจริงบวกใด ๆ จะมีจำนวนเต็มบวกที่ถ้า  $n$  มากกว่า  $N$  แล้ว

$$P\left[\left|\hat{\theta}_n - \theta\right| \geq \epsilon\right] \leq \delta$$

**ทฤษฎีบทที่ 3** ถ้า  $\hat{\theta}_n$  เป็นตัวประมาณของพารามิเตอร์  $\theta$  จากตัวอย่างขนาด  $n$  และ

$$\lim_{n \rightarrow \infty} E\left(\hat{\theta}_n\right) = \theta$$

$$\text{และ } \lim_{n \rightarrow \infty} V\left(\hat{\theta}_n\right) = 0$$

แล้ว  $\hat{\theta}_n$  เป็นตัวประมาณคงเส้นคงวาของ  $\theta$

**ทฤษฎีบทที่ 4** ถ้าประชากรมีโมเมนต์ที่  $K$  คือ  $\mu'_k = E(X^k)$  และความแปรปรวนของ  $X^k$  เป็นจำนวนจำกัดแล้วโมเมนต์ที่  $k$  ของตัวอย่าง  $M_k = \frac{1}{n} \sum_{i=1}^n X_i^k$  เป็นตัวประมาณคงเส้นคงวาของ  $\mu'_k$

**ทฤษฎีบทที่ 5** ถ้า  $\hat{\theta}_1$  และ  $\hat{\theta}_2$  เป็นตัวประมาณคงเส้นคงวาของ  $\theta_1$  และ  $\theta_2$  ตามลำดับ แล้ว  $\hat{\theta}_1 + \hat{\theta}_2$  เป็นตัวประมาณคงเส้นคงวาของ  $\theta$  และ เป็นตัวประมาณคงเส้นคงวาของ  $\theta_1 \cdot \theta_2$

**ทฤษฎีบทที่ 6** ผลบวกและผลคูณของตัวประมาณคงเส้นคงวาจำนวนหนึ่งเป็นตัวประมาณคงเส้นคงวาของผลบวกและผลคูณของพารามิเตอร์ที่สมนัยกัน

**ทฤษฎีบทที่ 7** พหุนาม (Polynomial) ของโมเมนต์ตัวอย่างเป็นตัวประมาณคงเส้นคงวาของพหุนามเดียวกันของโมเมนต์ประชากร

**นิยาม 5** ตัวประมาณ  $\hat{\theta}_n$  ของพารามิเตอร์  $\theta$  ที่ได้จากตัวอย่างสุ่มขนาด  $n$  เป็นตัวประมาณคงเส้นคงวาในความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean squared error consistent estimator) หรือตัวประมาณคงเส้นคงวาในค่าเฉลี่ยกำลังสอง (Consistent estimator in quadratic mean) ก็ต่อเมื่อ

$$\lim_{n \rightarrow \infty} E\left(\hat{\theta}_n - \theta\right)^2 = 0$$

**ทฤษฎีบทที่ 8** ถ้า  $\hat{\theta}_n$  เป็นตัวประมาณค่าเส้นตรงในความคลาดเคลื่อนกำลังสองเฉลี่ยของพารามิเตอร์  $\theta$  แล้ว  $\hat{\theta}_n$  เป็นตัวประมาณค่าเส้นตรงของ  $\theta$

**นิยาม 6** ตัวประมาณ  $\hat{\theta}_n$  ของพารามิเตอร์  $\theta$  ที่ได้จากตัวอย่างสุ่มขนาด  $n$  เป็นตัวประมาณที่ดีที่สุดและแจกแจงเชิงกำกับแบบปกติ (Best asymptotically normal-BAN estimator) ก็ต่อเมื่อ  $\hat{\theta}_n$  เป็นตัวประมาณค่าเส้นตรงของ  $\theta$  ที่มีการแจกแจงเชิงกำกับแบบปกติและมีความแปรปรวนต่ำที่สุด

ตัวประมาณ  $\hat{\theta}_n$  ของ  $\theta$  ที่มีคุณสมบัตินี้ จะต้องเป็นไปตามเงื่อนไข 3 ประการ คือ

$$1) \lim_{n \rightarrow \infty} P \left[ \left| \hat{\theta}_n - \theta \right| > \epsilon \right] = 0 \text{ เมื่อ } \epsilon > 0$$

2) เมื่อ  $n \rightarrow \infty$  แล้ว  $\sqrt{n}(\hat{\theta}_n - \theta)$  มีการแจกแจงใกล้ปกติที่มีค่าเฉลี่ย 0 และความแปรปรวน  $\sigma^2$  (ที่ขึ้นอยู่กับ  $\theta$ )

3) ถ้า  $\hat{\theta}_n^*$  เป็นตัวประมาณค่าเส้นตรงของ  $\theta$  ที่  $\sqrt{n}(\hat{\theta}_n^* - \theta)$  มีการแจกแจงใกล้ปกติที่มีค่าเฉลี่ย 0 และความแปรปรวน  $\sigma^{*2}$  เมื่อ  $n \rightarrow \infty$  แล้ว  $\sigma^2 \leq \sigma^{*2}$

### 3.11 ตัวประมาณที่มีความแปรปรวนต่ำสุด

**นิยาม 7** ตัวประมาณ  $\hat{\theta}$  ของพารามิเตอร์  $\theta$  เป็นตัวประมาณที่มีความแปรปรวนต่ำสุด (Minimum variance estimator - MVE) หรือตัวประมาณที่ดีที่สุด (Best estimator) ของ  $\theta$  ก็ต่อเมื่อ  $\hat{\theta}$  มีความแปรปรวนมากกว่าความแปรปรวนของตัวประมาณอื่นใดของ  $\theta$

ในการเปรียบเทียบความแปรปรวนของตัวประมาณของพารามิเตอร์  $\theta$  ควรเปรียบเทียบกับความแปรปรวนของตัวประมาณของ  $\theta$  ที่มีคุณสมบัติอื่น ๆ เหมือน ๆ กัน ที่นิยมพิจารณากันมาก ได้แก่ ความแปรปรวนของตัวประมาณที่ไม่เอนเอียงของ  $\theta$  หรือตัวประมาณที่เป็นฟังก์ชันเชิงเส้นของค่าสังเกตและไม่เอนเอียงของ  $\theta$

**นิยาม 8** ตัวประมาณ  $\hat{\theta}$  ของพารามิเตอร์  $\theta$  เป็นตัวประมาณไม่เอนเอียงที่มีความแปรปรวนต่ำสุด หรือเป็นตัวประมาณไม่เอนเอียงที่ดีที่สุด (Minimum variance unbiased estimator - MVUE) หรือเป็นตัวประมาณไม่เอนเอียงที่ดีที่สุด (Best unbiased estimator) ของ  $\theta$  ก็ต่อเมื่อ  $\hat{\theta}$  เป็นตัวประมาณไม่เอนเอียงของ  $\theta$  ที่มีความแปรปรวนต่ำสุดในบรรดาตัวประมาณไม่เอนเอียงของ  $\theta$  ด้วยกัน

**นิยาม 9** ตัวประมาณ  $\hat{\theta}$  ของพารามิเตอร์  $\theta$  เป็นตัวประมาณเชิงเส้นดีที่สุดในเชิงไม่เอนเอียง (Best linear unbiased estimator-BLUE) ของ  $\theta$  ก็ต่อเมื่อ  $\hat{\theta}$  เป็นฟังก์ชันกำลังที่หนึ่งของตัวอย่างสุ่มที่ไม่เอนเอียงของ  $\theta$  และมีความแปรปรวนต่ำสุดในบรรดาตัวประมาณที่เป็นฟังก์ชันกำลังที่หนึ่งของตัวอย่างสุ่มและไม่เอนเอียงของ  $\theta$  ด้วยกัน

ความแปรปรวนของตัวประมาณบางตัวของพารามิเตอร์  $\theta$  จะมีค่าขอบเขตต่ำ (Lower bound) ภายใต้งื่อนไขบางประการที่จะพิจารณาภายหลัง ค่าขอบเขตล่างเป็นค่าต่ำสุดของความแปรปรวนของตัวประมาณใด ๆ ของ  $\theta$

**นิยาม 10** ตัวประมาณ  $\hat{\theta}$  ของ  $\theta$  เป็นตัวประมาณที่มีความแปรปรวนถึงค่าขอบเขตต่ำสุด (Minimum variance bound estimator) ของ  $\theta$  ก็ต่อเมื่อ  $\hat{\theta}$  มีความแปรปรวนต่ำที่สุดและเท่ากับค่าขอบเขตล่างของความแปรปรวนของตัวประมาณใด ๆ ของ  $\theta$

**ทฤษฎีบทที่ 9** ถ้ามีตัวประมาณไม่เอนเอียงที่มีความแปรปรวนต่ำสุดของพารามิเตอร์  $\theta$  แล้ว จะต้องมีเพียงตัวเดียว

### 3.12 วิธีหาตัวประมาณพารามิเตอร์

ให้  $X_1, \dots, X_n$  เป็นตัวอย่างสุ่มจากประชากรที่มีฟังก์ชันความหนาแน่น  $f(x; \theta), \theta \in \Omega$  ในที่นี้ให้ถือว่าทราบรูปของฟังก์ชัน  $f$  แต่ไม่ทราบค่าพารามิเตอร์  $\theta$  โดยที่  $\Omega$  เป็นปริภูมิพารามิเตอร์ บางครั้งอาจถือว่า  $\theta = (\theta_1, \dots, \theta_k)$  เป็นเวกเตอร์ของพารามิเตอร์  $k$  ตัวที่  $\theta_i$  แต่ละตัวเป็นจำนวนจริง นั่นคือถือว่าปริภูมิพารามิเตอร์  $\square$  เป็นปริภูมิยูคลิเดียนที่มีมิติ  $k$

นักสถิติต้องการหาสถิติ (ฟังก์ชัน)  $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$  ของตัวอย่างสุ่ม  $X_1, \dots, X_n$  ที่ใช้ประมาณ  $\theta$  หรือฟังก์ชันของ  $\theta$  เช่น  $g_1(\theta), g_2(\theta), \dots, g_r(\theta)$  เป็นต้น

มีผู้เสนอวิธีการที่ใช้หา  $\hat{\theta}$  ไว้หลายวิธี แต่ละวิธีมักใช้สามัญสำนึกหรือมีเหตุผลประกอบ ในที่นี้จะพิจารณาวิธีหาตัวประกอบ  $\hat{\theta}$  ต่อไปนี้

1. วิธีโมเมนต์ (Method of moment)
2. วิธีภาวะน่าจะเป็นสูงสุด (Method of maximum likelihood)
3. วิธีไคกำลังสองต่ำสุด (Method of minimum chi-square)
4. วิธีระยะห่างต่ำสุด (Method of minimum distance)
5. วิธีของเบย์ (Method of Bayes)
6. วิธีมินิแมกซ์ (Method of minimax)
7. วิธีกำลังสองต่ำสุด (Method of least squares)
8. วิธีของพิทมัน (Method of Pitman)

### 3.13 วิธีโมเมนต์

วิธีการหาตัวประมาณด้วยวิธีโมเมนต์ ทำได้ง่ายมาก เป็นวิธีการหาตัวประมาณของพารามิเตอร์เก่าแก่ที่สุด นำเสนอครั้งแรกโดยคาร์ลเพียร์สัน (Karl Pearson) เมื่อประมาณปี ค.ศ. 1894 วิธีการนี้มักให้ตัวประมาณได้เสมอในหลายกรณี และมักจะทำให้ได้ตัวประมาณที่ยังปรับปรุงให้ดีขึ้นได้อีก แต่เป็นการเริ่มต้นที่ดีในกรณีที่วิธีอื่นทำให้หาตัวประมาณได้ยาก

แนวความคิดที่นำมาใช้หาตัวประมาณด้วยวิธีโมเมนต์ ได้แก่ การถือว่าโมเมนต์ตัวอย่างเป็นตัวประมาณที่ไม่เอนเอียงของโมเมนต์ของประชากรที่สมนัยกัน และฟังก์ชันของโมเมนต์ตัวอย่างก็อาจใช้เป็นตัวประมาณฟังก์ชันที่สมนัยกันของพารามิเตอร์ได้

ให้  $X_1, \dots, X_n$  เป็นตัวอย่างสุ่มจากประชากรที่มีฟังก์ชันความหนาแน่น  $f(x; \theta), \theta \in \Omega$  ซึ่งมีโมเมนต์ที่  $k$  คือ อาจหา  $\mu'_k = E(X^k) = \int_{-\infty}^{\infty} x^k f(x; \theta) dx$  ได้ อันจะทำให้มีโมเมนต์ที่  $1, 2, \dots,$

$k-1$  ด้วย

**นิยาม 11** เมื่อประชากรมีฟังก์ชันความหนาแน่นขึ้นอยู่กับพารามิเตอร์  $\theta_1, \theta_2, \dots, \theta_k$  และมีโมเมนต์ที่  $k$  คือ  $\mu'_k$  และให้โมเมนต์ที่  $k$  ของตัวอย่างเป็น  $M'_k = \frac{1}{n} \sum_{i=1}^n X_i^k$  ตัวประมาณแบบโมเมนต์ ของ  $\theta_1, \dots, \theta_k$  คือค่าของพารามิเตอร์เหล่านี้เทอมของค่าสังเกต  $X_1, \dots, X_n$  ที่ได้จากการแก้สมการ

$$\mu'_j = M'_j \quad j = 1, 2, \dots, k$$

### 3.14 ปัญหาในการหาตัวประมาณแบบโมเมนต์

การใช้วิธีโมเมนต์หาตัวประมาณพารามิเตอร์ หรือฟังก์ชันของพารามิเตอร์เป็นจุดเริ่มต้นที่ดี แต่ผลที่ได้ อาจไม่เป็นตัวประมาณที่มีคุณภาพพึงปรารถนาเสมอไปในการหาตัวประมาณอาจประสบปัญหาเกี่ยวกับการแก้สมการได้ ซึ่งอาจได้ใช้การประมาณด้วยตัวเลขให้ได้ค่าใกล้เคียงในบางกรณี

ในการประมาณฟังก์ชันของพารามิเตอร์ เช่น  $g_1(\theta_1, \dots, \theta_k), g_2(\theta_1, \dots, \theta_k), \dots, g_r(\theta_1, \dots, \theta_k)$  โดยวิธีโมเมนต์ อาจดำเนินการได้หลายทาง

1. ใช้วิธีโมเมนต์หาตัวประมาณของ  $\theta_1, \dots, \theta_k$  คือให้  $\mu'_j = M'_j, j = 1, \dots, k$  แล้วแก้สมการหาค่าของ  $\theta_j$  ในเทอมของค่าสังเกตเป็นตัวประมาณ  $\hat{\theta}_j$  ของ  $\theta_j, j = 1, \dots, k$  แล้วใช้  $\hat{\theta}_j$  ในการประมาณ  $g_1, \dots, g_r$  คือ  $\hat{g}_1 = g_1(\hat{\theta}_1, \dots, \hat{\theta}_k), \dots, \hat{g}_r = g_r(\hat{\theta}_1, \dots, \hat{\theta}_k)$

2. ใช้โมเมนต์  $\mu'_j = E(X^j), j = 1, 2, \dots, k$  ที่อยู่ในรูปฟังก์ชันของ  $g_1, \dots, g_r$  คือ  $\mu'_j = \mu'_j(g_1, \dots, g_r), j = 1, \dots, k$  แล้วหา  $g_1, \dots, g_r$  จากสมการ  $\mu'_j(g_1, \dots, g_r) = M'_j$  ในเทอมของค่าสังเกตเป็นตัวประมาณแบบโมเมนต์ของ  $g_1, \dots, g_r$   
วิธีการทั้งสองที่กล่าวนี้ ไม่จำเป็นต้องให้ผลลัพธ์เดียวกัน

### 3.15 คุณสมบัติของตัวประมาณแบบโมเมนต์

ตัวประมาณพารามิเตอร์ที่ได้มาโดยวิธีโมเมนต์มีคุณสมบัติที่น่าสนใจหลายประการ

1. โดยทั่วไปตัวประมาณแบบโมเมนต์เป็นตัวประมาณคงเส้นคงวา เนื่องจากตัวประมาณแบบนี้เป็นฟังก์ชันของโมเมนต์ตัวอย่าง และโมเมนต์ตัวอย่างเป็นตัวประมาณคงเส้นคงวาของโมเมนต์ของประชากร
2. ภายใต้งื่อนไขทั่วไป ตัวประมาณแบบโมเมนต์มีการแจกแจงเชิงกำกับแบบปกติ (Asymptotically normal)
3. ตัวประมาณแบบโมเมนต์อาจเอนเอียงหรือไม่เอนเอียงก็ได้ หากเป็นตัวประมาณเอนเอียง อาจลดค่าเอนเอียงลงได้ เช่น ใช้วิธีแจกไนฟ์ตามแบบของเคอูล์ทซ์ที่กล่าวมาแล้ว
4. ค่าเอนเอียงของตัวประมาณแบบโมเมนต์มักมีค่าน้อย (ในอันดับหรือขนาด  $n-1$ ) และส่วนเบี่ยงเบนมาตรฐานมักอยู่ในรูป  $c/\sqrt{n}$
5. ตัวประมาณแบบโมเมนต์มักมีประสิทธิภาพต่ำ บางครั้งอาจได้ตัวประมาณแบบโมเมนต์ที่ขัดแย้งกับความรูสึก หรือสามัญสำนึก

### 3.16 วิธีภาวน่าจะเป็นสูงสุด

วิธีการ การประมาณพารามิเตอร์ด้วยวิธีภาวน่าจะเป็นสูงสุด (เป็นวิธีการที่ใช้กันแพร่หลายมากที่สุด) มีแนวคิดมานานตั้งแต่คริสต์ศตวรรษที่ 18 คาร์ล ฟรีดริค เกาส์ (Karl Friedrich Gauss 1777-1855) และแดเนียล เฮอร์นูลลี (Daniel Bernoulli) ได้ใช้วิธีการนี้มาแล้ว ต่อมาในศตวรรษที่ 20 โรนัลด์ ฟิลเชอร์ (Ronald Aylmer Fisher 1890-1962) ได้ทำการศึกษาคุณสมบัติของวิธีการนี้ ทำให้มีผู้ใช้กว้างขวางขึ้น และถือว่าวิธีการนี้เป็นผลงานของ ฟิลเชอร์ โดยเขาได้นำเสนองานเกี่ยวกับวิธีการนี้ในปี ค.ศ. 1912 พร้อมทั้งมีการปรับปรุงแก้ไขส่วนที่เกี่ยวข้องให้เหมาะสมขึ้นอีกด้วย นักสถิติคนอื่น ๆ ก็มีส่วนทำให้วิธีการนี้เป็นที่นิยมแพร่หลายยิ่งขึ้นด้วย

**นิยาม 12.** ให้  $X_1, \dots, X_n$  เป็นตัวอย่างสุ่มจากประชากรที่มีฟังก์ชันความหนาแน่น  $f(x; \theta), \theta \in \Omega$  ฟังก์ชันภาวน่าจะเป็น (Likelihood function) ของตัวอย่างสุ่ม คือ ฟังก์ชันความหนาแน่นรวม  $L = L(\theta; x_1, \dots, x_n) = L(\theta)$  ของตัวอย่างสุ่มนั้นที่ถือว่าเป็นฟังก์ชันของพารามิเตอร์ นั่นเอง

$$L(\theta; x_1, \dots, x_n) = \prod_{i=1}^n f(x_i; \theta)$$

**นิยาม 13.** ค่าของพารามิเตอร์  $\theta$  ในเทอมของค่าสังเกตของตัวอย่างสุ่ม  $X_1, \dots, X_n$  ที่ทำให้ฟังก์ชันภาวะน่าจะเป็นมีค่าสูงสุด เรียกว่า ตัวประมาณแบบภาวะน่าจะเป็นสูงสุด (Maximum likelihood estimator-MLE) ของ  $\theta$  นั่นคือค่าของ  $\theta$  คือ  $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$  เป็น MLE ของ  $\theta$  ก็ต่อเมื่อ  $L(\hat{\theta}) = L(\hat{\theta}(X_1, \dots, X_n))$  มีค่าสูงสุด

**วิธีหาตัวประมาณแบบภาวะน่าจะเป็นสูงสุด** เป็นวิธีการหาค่าของพารามิเตอร์  $\theta$  ที่ทำให้ฟังก์ชัน  $L(\theta)$  สูงสุด ในการนี้มีข้อควรสังเกตดังต่อไปนี้

1. เป้าหมายในการหา MLE ของ  $\theta$  คือการหาค่า  $\theta$  เรียกว่า  $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$  ที่ทำให้

$$L(\hat{\theta}; x_1, \dots, x_n) \geq L(\theta; x_1, \dots, x_n)$$

เมื่อ  $\theta \in \Omega$  และ  $X_1 = x_1, \dots, X_n = x_n$

2. ถ้าฟังก์ชันภาวะน่าจะเป็น  $L(\theta)$  เป็นฟังก์ชันที่หาอนุพันธ์ได้ (Differentiable function) เมื่อเทียบกับ  $\theta$  อาจใช้อนุพันธ์หา MLE ของ  $\theta$  ได้ เมื่อเรนจ์ของ  $f(x; \theta)$  ไม่ขึ้นอยู่กับ  $\theta$  และ  $\theta$  อยู่ในช่วงจำนวนจริงช่วงหนึ่ง ในกรณีดังกล่าว  $\hat{\theta}$  คือรากของสมการ

$$\frac{\partial L}{\partial \theta} = 0$$

เงื่อนไขพอเพียง(Sufficient condition) ที่  $\hat{\theta}$  ทำให้  $L(\hat{\theta}) \geq L(\theta)$ ,  $\theta \in \Omega$  คือ

$$\frac{\partial^2 L}{\partial \theta^2} < 0 \quad \text{เมื่อ } \theta = \hat{\theta}$$

3. การใช้อนุพันธ์หา MLE ในหลายกรณีใช้  $\ln L$  จะสะดวกกว่าที่จะใช้  $L$  ควรสังเกตว่า

$$\frac{\partial \ln L}{\partial \theta} = \frac{1}{L} \frac{\partial L}{\partial \theta}$$

และ  $L > 0$  ดังนั้น เมื่อให้

$$\frac{\partial \ln L}{\partial \theta} = 0$$

เราจะได้  $\frac{\partial L}{\partial \theta} = 0$  ด้วย นอกจากนั้น เมื่อ

$$\frac{\partial^2 \ln L}{\partial \theta^2} < 0$$

ก็จะทำให้  $\frac{\partial^2 L}{\partial \theta^2} < 0$  ด้วย

**นิยาม 14.** สมการที่ใช้หา MLE คือ  $\frac{\partial L}{\partial \theta} = 0$  หรือ  $\frac{\partial \ln L}{\partial \theta} = 0$  เราเรียกว่า **สมการภาวะ**

**น่าจะเป็น** (Likelihood equation)

4. ในบางกรณี อาจไม่สามารถใช้อนุพันธ์ในการหา MLE เช่นเมื่อเรนจ์ของ  $f(x; \theta)$  ขึ้นอยู่กับ  $\theta$

**คุณสมบัติของตัวประมาณแบบภาวะน่าจะเป็นสูงสุด** ตัวประมาณแบบภาวะน่าจะเป็นสูงสุดมีคุณสมบัติที่น่าสนใจหลายประการ ซึ่งจะรวบรวมนำเสนอไว้บางประการต่อไปนี้

1. ตัวประมาณแบบภาวะน่าจะเป็นของพารามิเตอร์  $\theta$  เป็นฟังก์ชันของสถิติพอเพียงของ  $\theta$  (ซึ่งจะพิสูจน์ให้เห็นจริงภายหลัง)
2. ในกรณีที่มีตัวประมาณซึ่งมีความแปรปรวนต่ำสุดเท่าค่าขอบเขตล่างของพารามิเตอร์  $\theta$  ตัวประมาณนั้นอาจหาได้โดยวิธีภาวะน่าจะเป็นสูงสุด (ซึ่งจะพิสูจน์ให้เห็นจริงภายหลัง)
3. ตัวประมาณแบบภาวะน่าจะเป็นสูงสุดอาจมีได้มากกว่า 1 ตัว

**ทฤษฎีบทที่ 10** ถ้า  $\hat{\theta}_n$  เป็นตัวประมาณแบบภาวะน่าจะเป็นสูงสุดของพารามิเตอร์  $\theta$  แล้ว  $\lim_{n \rightarrow \infty} P\left[\hat{\theta}_n = \theta\right] = 1$

**ทฤษฎีบทที่ 11** ภายใต้เงื่อนไขธรรมดา ถ้า  $\hat{\theta}$  เป็นตัวประมาณแบบภาวะน่าจะเป็นสูงสุดของ  $\theta$  ที่คงเส้นคงวาแล้ว มีได้เพียงตัวเดียว  $\hat{\theta}$

**ทฤษฎีบทที่ 12** ถ้า  $\hat{\theta}$  เป็นตัวประมาณแบบภาวะน่าจะเป็นสูงสุดของพารามิเตอร์  $\theta$  และมีอนุพันธ์ของฟังก์ชันภาวะน่าจะเป็นอันดับที่ 1 และ 2 เทียบกับ  $\theta$  ในช่วงที่คลุมค่าแท้จริง  $\theta_0$  ของ  $\theta$  และ  $R^2(\theta) = E\left(\frac{\partial \ln L}{\partial \theta}\right)^2$  ต่างจาก 0 เมื่อ  $\theta$  อยู่ในช่วงดังกล่าว แล้ว  $\hat{\theta}$  มีการแจกแจงเชิงกำลังกับแบบปกติที่มีค่าเฉลี่ย  $\theta_0$  และความแปรปรวน  $1/R^2(\theta_0)$

**ปัญหาในการหาตัวประมาณแบบภาวะน่าจะเป็นสูงสุด** ในการหาตัวประมาณแบบภาวะน่าจะเป็นสูงสุดของพารามิเตอร์  $\theta$  เราจะพยายามหาค่าของ  $\theta$  ในเทอมของค่าสังเกต  $X_1, \dots, X_n$

ที่ทำให้ฟังก์ชันภาวะน่าจะเป็น  $L(\theta)$  มีค่าสูงสุด เมื่อใช้อนุพันธ์ นักสถิติจะหาค่าของ  $\theta$  ดังกล่าว จากสมการภาวะน่าจะเป็น  $\frac{\partial L}{\partial \theta} = 0$  หรือ  $\frac{\partial \ln L}{\partial \theta} = 0$  คือหาจุดวิกฤต (Critical point) ที่จะทำให้  $L$  สูงสุดนั่นเอง บางครั้งการแก้สมการดังกล่าวอาจทำได้ยากเช่นเมื่อสมการภาวะน่าจะเป็นเป็นสมการระดับชั้นสูง ๆ หรือเป็นสมการซับซ้อน

ในบางกรณี ไม่อาจใช้อนุพันธ์เพื่อหาค่าของพารามิเตอร์  $\theta$  ในเทอมของค่าสังเกต  $X_1, \dots, X_n$  ได้เช่นเมื่อ  $L$  หรือ  $\ln L$  เป็นฟังก์ชันของ  $\theta$  ที่หาอนุพันธ์ไม่ได้ หรือเมื่อเรนจ์ของฟังก์ชันขึ้นอยู่กับ  $\theta$  หรืออนุพันธ์ไม่มี  $\theta$  อยู่ด้วย จึงต้องใช้วิธีการอื่น ๆ เช่นการสังเกตว่า  $L(\theta)$  จะสูงสุดได้เมื่อไร หรือการเปรียบเทียบค่าของ  $L(\theta)$  เมื่อค่าของ  $\theta$  เปลี่ยนไป

แม้ในกรณีที่ใช้อนุพันธ์ในการหาตัวประมาณแบบภาวะน่าจะเป็นสูงสุด ควรมีการตรวจสอบเงื่อนไขพอเพียงที่ค่าของ  $\theta$  นั้นจะทำให้  $L(\theta)$  สูงสุด มิใช่ให้ค่าต่ำที่สุด

ในกรณีที่ใช้อนุพันธ์ในการหา  $\theta$  ที่ทำให้  $L(\theta)$  มีค่าสูงสุด แต่ไม่อาจแก้สมการภาวะน่าจะเป็น หรือแก้ได้ยาก อาจใช้การประมาณ (Approximation) ค่าของ  $\hat{\theta} = \hat{\theta}(x_1, \dots, x_n)$  โดยอาศัยค่าสังเกต  $X_1 = x_1, \dots, X_n = x_n$  ตามวิธีการของนิวตัน (Newton's approximation) ได้เมื่อ  $n$  มีค่ามาก

**ทฤษฎีบทที่ 13** ค่าประมาณของรากของสมการภาวะน่าจะเป็น  $\frac{\partial \ln L}{\partial \theta} = 0$  ได้แก่

$$\hat{\theta} = \theta_0 + \left( \frac{\partial \ln L}{\partial \theta} \right)_{\theta=\theta_0}^{-1} v(\hat{\theta})$$

$$\text{โดยที่ } v(\hat{\theta}) = -1 / E \left( \frac{\partial^2 \ln L}{\partial \theta^2} \right)$$

พิสูจน์ จากอนุกรมเทย์เลอร์ จะได้ คือ

$$0 = \left( \frac{\partial \ln L}{\partial \theta} \right)_{\theta=\hat{\theta}} = \left( \frac{\partial \ln L}{\partial \theta} \right)_{\theta=\theta_0} + \left( \hat{\theta} - \theta_0 \right) \left( \frac{\partial^2 \ln L}{\partial \theta^2} \right)_{\theta=\theta^*}$$

เมื่อ  $\theta^*$  อยู่ระหว่าง  $\hat{\theta}$  กับ  $\theta_0$  ซึ่งเป็นค่าที่แท้จริงของ  $\theta$

$$\lim_{n \rightarrow \infty} P[\hat{\theta} = \theta_0] = 1$$

$$\text{และ } \lim_{n \rightarrow \infty} P \left[ \frac{\partial^2 \ln L}{\partial \theta^2} \Big|_{\theta=\theta_0} = E \left( \frac{\partial^2 \ln L}{\partial \theta^2} \right) \right] = 1$$

$$\text{หรือ} \quad \lim_{n \rightarrow \infty} P \left[ \frac{\partial^2 \ln L}{\partial \theta^2} = -\frac{1}{v(\hat{\theta})} \right] = 1$$

ดังนั้น เมื่อ  $n$  มีค่ามาก จะได้

$$0 = \left( \frac{\partial \ln L}{\partial \theta} \right)_{\theta=\theta_0} - (\hat{\theta} - \theta_0) \frac{1}{v(\hat{\theta})}$$

$$\text{หรือ} \quad 0 = \theta_0 \left( \frac{\partial \ln L}{\partial \theta} \right)_{\theta=\theta_0} \cdot v(\hat{\theta})$$

$$\text{โดยที่} \quad v(\hat{\theta}) = -1 / E \left( \frac{\partial^2 \ln L}{\partial \theta^2} \right) = \frac{1}{E \left( \frac{\partial \ln L}{\partial \theta} \right)^2}$$

ให้  $\theta_0$  เป็นค่าประมาณเริ่มต้นของ  $\hat{\theta}$  ค่าของ  $\hat{\theta}$  ที่หาได้ในรอบแรกจะใช้เป็น  $\theta_0$  ในรอบที่ 2 เช่นนี้ซ้ำ ๆ ได้หลายรอบ จนกระทั่งได้ค่าของ  $\hat{\theta}$  ที่ค่อนข้างนิ่ง คือ มีค่าต่างจากค่าที่หาได้ในรอบก่อนไม่มากนัก

ตัวประมาณแบบภาวะน่าจะเป็นสูงสุดของพารามิเตอร์หลายตัว ในกรณีที่พารามิเตอร์  $\theta$  เป็นเวกเตอร์  $\underline{\theta} = (\theta_1, \theta_2, \dots, \theta_k)$  อาจหาตัวประมาณแบบภาวะน่าจะเป็นสูงสุดของ  $\theta_1, \dots, \theta_k$  ที่ปรากฏอยู่ในฟังก์ชันความหนาแน่น  $f(x; \theta_1, \dots, \theta_k)$  ได้ โดยใช้หลักเกณฑ์เดิม นอกจากนั้นตัวแปรสุ่มแต่ละตัวของตัวอย่างสุ่ม ยังอาจเป็นเวกเตอร์ได้ด้วย

**นิยาม 15.** เมื่อ  $X_1, \dots, X_n$  เป็นตัวอย่างสุ่มจากประชากรที่มีฟังก์ชันความหนาแน่น  $f(x; \theta_1, \dots, \theta_k)$  ค่าของ  $\theta_1, \dots, \theta_k$  ในเทอมของค่าสังเกตของตัวอย่างสุ่มที่ทำให้ฟังก์ชันภาวะน่าจะเป็น  $L(\theta_1, \dots, \theta_k)$  มีค่าสูงสุด เรียกว่า ตัวประมาณแบบภาวะน่าจะเป็นสูงสุด ของ  $\theta_1, \dots, \theta_k$  นั่นคือ  $\hat{\theta}_1(x_1, \dots, x_n), \dots, \hat{\theta}_k(x_1, \dots, x_n)$  เป็น MLE ของ  $\theta_1, \dots, \theta_k$  ตามลำดับ ก็ต่อเมื่อ  $L(\hat{\theta}_1, \dots, \hat{\theta}_k)$  มีค่าสูงสุด

เงื่อนไขจำเป็นที่ทำให้  $L(\theta_1, \dots, \theta_k)$  สูงสุด ได้แก่  $\frac{\partial L(\theta_1, \dots, \theta_k)}{\partial \theta_j} = 0, j = 1, \dots, k$  หรือที่สมมูลกันก็คือ  $\frac{\partial \ln L(\theta_1, \dots, \theta_k)}{\partial \theta_j} = 0, j = 1, \dots, k$  และเงื่อนไขพอเพียงที่จะได้  $L$  สูงสุดได้แก่ การที่

เมตริกซ์  $\left( \frac{\partial^2 \ln L}{\partial \theta_i \partial \theta_j} \right)$  เป็นเมตริกซ์นิเสธแน่ (Negative definite matrix) ขนาด  $k \times k$

เมื่อสามารถไขข้อพันธุในการหาตัวประมาณแบบภาวะน่าจะเป็นสูงสุดของพารามิเตอร์  $\theta_1, \dots, \theta_k$  ได้ เราเรียกกระบวนการ  $\frac{\partial L}{\partial \theta_j} = 0$  หรือ  $\frac{\partial \ln L}{\partial \theta_j} = 0$  ว่า ระบบสมการภาวะน่าจะเป็น

### 3.17 วิธีไคกำลังสองต่ำสุด

นิยาม 16. ให้  $X_1, \dots, X_n$  เป็นตัวอย่างสุ่มจากประชากรที่มีฟังก์ชันความหนาแน่น  $f(x; \theta)$  ให้  $S$  เป็นปริภูมิตัวอย่างของตัวแปรสุ่ม  $X$  ที่มีฟังก์ชันความหนาแน่นดังกล่าว มีการแบ่งกัน (Partition)  $S$  ออกเป็น  $S_1 \cup S_2, \dots, \cup S_k$  โดยที่  $S_i \cap S_j = \emptyset$  เมื่อ  $i \neq j$  ให้  $P_j = P_j(\theta)$  เป็นความน่าจะเป็นที่  $X_i$  มีค่าอยู่ใน  $S_i, \sum_{j=1}^k P_j = 1$  ให้  $n_j$  เป็นจำนวน  $X_i$  ในตัวอย่างมีค่าตกอยู่ใน  $S_i, \sum_{j=1}^k n_j = n$  ค่าของ  $\theta$  ในเทอมของค่าสังเกตที่ทำให้

$$X^2 = n \sum_{j=1}^k \left[ \frac{n_j}{n} - P_j(\theta) \right]^2 / P_j(\theta) \quad (1)$$

มีค่าต่ำสุด ที่เรียกว่า ตัวประมาณแบบไคกำลังสองต่ำสุด (Minimum chi-squares estimator) ของ  $\theta$  รูปอื่นของ  $X^2$  ใน (1) ได้แก่

$$X^2 = \sum_{j=1}^k [n_j - np_j(\theta)]^2 / np_j(\theta) \quad (2)$$

และฟังก์ชันการแจกแจงของตัวอย่าง คือ

$$F_n(x) = \begin{cases} 0 & \text{เมื่อ } x < 0 \\ \frac{n_0}{n} & \text{เมื่อ } 0 \leq x < 1 \\ 1 & \text{เมื่อ } x \geq 1 \end{cases}$$

ฟังก์ชันระยะห่างระหว่าง  $F(x; \theta)$  กับ  $F_n(x)$  คือ

$$d(F(x; \theta), F_n(x)) = \sup_x |F(x; \theta) - F_n(x)|$$

ดังนั้น  $d(F(x; \theta), F_n(x))$  มีค่าต่ำสุดเมื่อ  $1 - \theta = \frac{n_0}{n}$  หรือ  $\theta = 1 - \frac{n_0}{n} = \frac{n_1}{n} = \frac{1}{n} \sum_{i=1}^n x_i$

นั่นคือ ตัวประมาณแบบระยะห่างต่ำสุด คือ  $\hat{\theta} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{X}$

### 3.18 วิธีของเบย์

**แนวความคิด** สถิติตามแนวของเบย์ (Bayesian approach) แตกต่างจากสถิติตามแนวเดิม (Classical approach) ในแนวเดิม การประมาณพารามิเตอร์  $\theta$  มักถือว่าเริ่มจากการสุ่ม ตัวอย่างจากประชากรที่มีฟังก์ชันความหนาแน่น  $f(x; \theta)$  และถือว่าพารามิเตอร์  $\theta$  เป็นค่าคงที่ แต่ไม่ทราบค่า แต่ในแนวของเบย์จะมีความพยายามใช้ความรู้เดิมหรือข้อมูลเดิมเกี่ยวกับ  $\theta$  ให้เป็นประโยชน์ในการประมาณ  $\theta$  ให้ได้ดียิ่งขึ้น ดังนั้นจึงถือว่า  $\theta$  เป็นค่าของตัวแปรสุ่ม  $\Theta$  มีการแจกแจงความน่าจะเป็นรูปใดรูปหนึ่ง

ให้  $X_1, \dots, X_n$  เป็นตัวอย่างสุ่มจากประชากรที่มีฟังก์ชันความหนาแน่น  $f(x; \theta) = f(x|\theta)$  โดยที่  $\theta$  เป็นค่าของตัวแปรสุ่ม  $\Theta$

ในที่นี้ เราถือว่า  $f(x|\theta)$  เป็นฟังก์ชันความหนาแน่นเงื่อนไข (Conditional probability density function) ของตัวแปรสุ่ม เมื่อกำหนดให้ว่า  $\Theta = \theta$

**นิยาม 17.** ให้ตัวแปรสุ่ม  $\Theta$  มีฟังก์ชันความหนาแน่น  $g(\theta)$  ซึ่งเรียกว่า **ฟังก์ชันความหนาแน่นเริ่ม** (Prior or initial probability density function) ของ  $\Theta$

ให้  $h(\theta|X_1, \dots, X_n)$  เป็นฟังก์ชันความหนาแน่น แบบมีเงื่อนไขของตัวแปรสุ่ม  $\Theta$  เมื่อกำหนดให้ว่า  $X_1 = x_1, \dots, X_n = x_n$  มักเรียกฟังก์ชันนี้ว่า **ฟังก์ชันความหนาแน่นภายหลัง** (Posterior probability density function) หรือ **ฟังก์ชันความหนาแน่นปรับแก้** (Revised probability density function) ของ  $\Theta$

ในที่นี้ ฟังก์ชันความหนาแน่นร่วมของ  $X_1, \dots, X_n$  เมื่อกำหนดให้ว่า  $\Theta = \theta$  ได้แก่

$$f(x_1, \dots, x_n; \theta) = f(x_1, \dots, x_n | \theta) = \prod_{i=1}^n f(x_i | \theta)$$

อาจหาฟังก์ชันความหนาแน่นภายหลังของ  $\Theta$  ได้จากฟังก์ชันความหนาแน่นเริ่มต้น และฟังก์ชันความหนาแน่นแบบมีเงื่อนไขของตัวอย่างสุ่ม โดยใช้ความรู้เกี่ยวกับฟังก์ชันความหนาแน่นแบบมีเงื่อนไข

ให้  $\Theta$  มีฟังก์ชันความหนาแน่นเริ่มต้นเป็น  $g(\theta)$

ดังนั้น ฟังก์ชันความหนาแน่นร่วมของ  $X_1, \dots, X_n$  และ  $\Theta$  ได้แก่

$$f(x_1, \dots, x_n | \theta)g(\theta) = \prod_{i=1}^n f(x_i | \theta)g(\theta)$$

ฟังก์ชันความหนาแน่นร่วมของ  $X_1, \dots, X_n$  (ไม่มีเงื่อนไข คือ  $f(x_1, \dots, x_n | \theta)g(\theta)d\theta$ )

ดังนั้น ฟังก์ชันความหนาแน่นภายหลังของ  $\Theta$  ได้แก่

$$h(\theta | x_1, \dots, x_n) = \frac{f(x_1, \dots, x_n | \theta)g(\theta)}{\int f(x_1, \dots, x_n | \theta)g(\theta)d\theta} \quad (3.33)$$

หรือ

$$h(\theta | x_1, \dots, x_n) = \frac{\prod_{i=1}^n f(x_i | \theta)g(\theta)}{\int \prod_{i=1}^n f(x_i | \theta)g(\theta)d\theta} \quad (3.34)$$

**ตัวประมาณแบบเบส์ภายหลัง**

**นิยาม 18** ให้  $X_1, \dots, X_n$  เป็นตัวอย่างสุ่มจากประชากรที่มีฟังก์ชันความหนาแน่น  $f(x|\theta)$  โดยที่  $\theta$  เป็นค่าของตัวแปรสุ่ม  $\Theta$  ที่มีฟังก์ชันความหนาแน่นเริ่มต้น  $g(\theta)$

**ตัวประมาณแบบเบส์ภายหลัง** (Posterior Bayes estimator) ของฟังก์ชัน  $t(\theta)$  ของ  $\theta$  เทียบกับฟังก์ชันเริ่มต้น  $g(\theta)$  ได้แก่  $\hat{t}(\theta) = E(t(\Theta) | X_1, \dots, X_n)$  นั่นคือ

$$\hat{t}(\theta) = \int t(\theta)h(\theta | x_1, \dots, x_n)d\theta$$

หรือ

$$\hat{t}(\theta) = \frac{\int t(\theta) \prod_{i=1}^n f(X_i | \theta)g(\theta)d\theta}{\int \prod_{i=1}^n f(X_i | \theta)g(\theta)d\theta}$$

### 3.19 วิธีมินิแมกซ์

ในการประมาณค่าของพารามิเตอร์ โดยการพิจารณาฟังก์ชันสูญเสีย มักต้องการตัวประมาณที่มีความสูญเสียต่ำ สิ่งที่ควรพิจารณาจึงได้แก่ ค่าคาดหมายของความสูญเสีย หรือการเสี่ยง นั่นเอง

**นิยาม 19** ตัวประมาณ  $T_1(X_1, \dots, X_n)$  ของ  $g(\theta)$  ดีกว่า ตัวประมาณ  $T_2(X_1, \dots, X_n)$  ก็ต่อเมื่อ  $R(\theta, T_1) \leq R(\theta, T_2)$  ทุกค่า  $\theta$  และ  $R(\theta, T_1) < R(\theta, T_2)$  อย่างน้อย  $\theta$  ค่าหนึ่ง

ตัวประมาณ  $T_1(X_1, \dots, X_n)$  ของ  $g(\theta)$  เป็นตัวประมาณที่ยอมรับได้ ก็ต่อเมื่อไม่มีตัวประมาณใดของ  $g(\theta)$  ที่ดีกว่า  $T_1(X_1, \dots, X_n)$

**นิยาม 20** ตัวประมาณ  $T_0(X_1, \dots, X_n)$  ของ  $g(\theta)$  เป็นตัวประมาณแบบมินิแมกซ์ (Minimax Estimator) ก็ต่อเมื่อ

$$\sup_{\theta \in \Omega} R(\theta, T_0) \leq \sup_{\theta \in \Omega} R(\theta, T) \quad (3.43)$$

ไม่ว่า  $T_1(X_1, \dots, X_n)$  จะเป็นตัวประมาณใด ๆ ของ  $g(\theta)$

ตัวประมาณแบบมินิแมกซ์ จึงเป็นตัวประมาณที่มีความเสี่ยงสูงสุด ต่ำกว่าหรือเท่ากับการเสี่ยงสูงสุดของตัวประมาณใด ๆ ของฟังก์ชันของพารามิเตอร์ที่สนใจ

**ทฤษฎีบทที่ 14** ถ้า  $T_0(X_1, \dots, X_n)$  เป็นตัวประมาณแบบเบส์ของ  $t(\theta)$  ที่มีความเสี่ยง คงที่ แล้ว  $T_0$  เป็นตัวประมาณแบบมินิแมกซ์ของ  $t(\theta)$

### 3.20 วิธีกำลังสองต่ำสุด

แนวความคิดและวิธีการหาตัวประมาณแบบกำลังต่ำสุด วิธีการนี้เป็นวิธีการสำคัญมีรากฐานมาจากทฤษฎีการประมาณเชิงเส้น (Theory of linear estimation) โดยไม่จำเป็นต้องทราบรูปการแจกแจงความน่าจะเป็น แต่อาศัยผลต่างระหว่างค่าสังเกตและค่าคาดหมายเป็นสำคัญ วิธีการนี้คิดขึ้นโดย คาร์ล ฟรีดริค เกาส์ (Karl Friedrich Gauss 1777-1855) และ อังเดร อังเดรเยวิช มาร์คอฟ (Andrei Andreevich Markov 1856-1922)

**นิยาม 21** ให้  $X_1, \dots, X_n$  เป็นตัวอย่างสุ่มจากประชากรหนึ่งที่มีค่าคาดหมาย  $E(X)$  ค่าของพารามิเตอร์ในเทอมของค่าสังเกตที่ทำให้ผลบวกของกำลังที่ 2 ของผลต่างระหว่างค่าสังเกตกับค่าคาดหมายต่ำสุด จะเรียกว่า **ตัวประมาณแบบกำลังสองต่ำสุด** (Least-squares estimator) ของพารามิเตอร์ที่เกี่ยวข้อง

นั่นคือ ตัวประมาณแบบกำลังสองต่ำสุดของพารามิเตอร์  $\theta$  (อาจเป็นเวกเตอร์) ที่ปรากฏอยู่ในค่าคาดหมาย  $E(X)$  ได้แก่ ค่าของ  $\theta$  ในเทอมของค่าสังเกต ที่ทำให้

$$Q = \sum_{i=1}^n (x_i - E(X_i))^2$$

ต่ำที่สุด

มักหาตัวประมาณดังกล่าว โดยการใช้อนุพันธ์กล่าวคือ ใช่ว่า

$$\frac{\partial Q}{\partial \theta} = 0$$

และเรียกสมการ ว่า **สมการปกติ** (Normal equation(s))