

ทฤษฎีทางสถิติที่ใช้ในการตรวจสอบเครื่องมือและวิเคราะห์ข้อมูล

ในการตรวจสอบเครื่องมือและวิเคราะห์ข้อมูล ใช้ทฤษฎีทางสถิติที่สำคัญ

ดังนี้

1. ค่าเฉลี่ยหรือตัวกลางเลขคณิต (Arithmetic mean)

เมื่อมีข้อมูลอยู่ชุดหนึ่ง เช่นค่าพลังจากเครื่องกำเนิดสัญญาณเทียบความ  
 ลำดับวันต่างๆ ถ้าเราต้องการหาตัวเลขตัวหนึ่งซึ่งใช้แทนข้อมูลชุดนี้ โดยปกติจะใช้ค่าเฉลี่ย  
 ของข้อมูลชุดนี้ ซึ่งหาได้ดังนี้

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (6.1)$$

เมื่อ  $\bar{x}$  = ค่าเฉลี่ย

$x_i$  = ค่าของข้อมูลแต่ละตัว

$n$  = จำนวนข้อมูล

(Topping ,1971)

2. ความเบี่ยงเบนมาตรฐาน (Standard deviation)

เมื่อเราใช้ค่าเฉลี่ยของข้อมูลชุดหนึ่งเป็นตัวแทนของข้อมูลชุดนั้น ข้อมูล  
 แต่ละตัวอาจมีค่าเท่ากับหรือแตกต่างไปจากค่าเฉลี่ย ปริมาณที่ต่างออกไปจากค่าเฉลี่ย  
 คือค่าเบี่ยงเบนเฉลี่ย ( $d_i$ ) เขียนเป็นสูตรได้ว่า

$$d_i = x_i - \bar{x} \quad (6.2)$$

ขนาดของการกระจาย (dispersion) ของค่าเบี่ยงเบนนี้ จะบอกโดยค่าเบี่ยงเบนมาตรฐาน ( $\sigma$ ) ซึ่งเขียนเป็นสูตรได้ว่า

$$\sigma = \left( \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{(n-1)} \right)^{\frac{1}{2}} \quad (6.3)$$

ในกรณีที่มีข้อมูล 2 ชุด คือ  $x_1, x_2, \dots, x_n$  และ  $y_1, y_2, \dots, y_n$  ซึ่งเป็นอิสระต่อกัน มีความเบี่ยงเบนมาตรฐานเป็น  $\sigma_x$  และ  $\sigma_y$  ตามลำดับ ถ้า  $Z = x + y$  และ  $\sigma_z$  เป็นความเบี่ยงเบนมาตรฐานของ  $Z$  จะได้ว่า

$$\sigma_z^2 = \sigma_x^2 + \sigma_y^2 \quad (\text{Topping, 1971}) \quad (6.4)$$

### 3. การเปรียบเทียบการกระจายระหว่างหมู่

ในการเปรียบเทียบการกระจายของข้อมูลตั้งแต่ 2 ชุดขึ้นไป เราจะพิจารณาเฉพาะค่าความเบี่ยงเบนมาตรฐานเพียงอย่างเดียวไม่ได้ เพราะว่าข้อมูลแต่ละชุดอาจมีขนาดหรือสเกลแตกต่างกัน ดังนั้นจึงบอกขนาดของการกระจายในหน่วยของค่าเฉลี่ยของข้อมูลชุดนั้น ซึ่งเรียกว่าสัมประสิทธิ์การกระจาย ( $D$ ) (coefficient of dispersion) เขียนเป็นสูตรได้ว่า

$$D = \frac{\sigma}{\bar{x}} \quad (6.5)$$

ถ้าสัมประสิทธิ์การกระจายของข้อมูลชุดหนึ่งมีค่ามากกว่าอีกชุดหนึ่ง แสดงว่าข้อมูลชุดแรกมีการกระจายมากกว่าชุดหลัง (โดยปกติข้อมูล 2 ชุดนี้จะเป็นข้อมูลประเภทเดียวกัน)

(Topping, 1971)

### 4. การกระจายของความผิดพลาด (Distribution of error)

ในการวัดปริมาณทางฟิสิกส์ใด ๆ ค่าที่สังเกตการณ์ได้ (observed values) หรือค่าที่วัดได้ อาจแตกต่างจากค่าที่แท้จริง (actual values) ได้เล็กน้อยต่างกัน เรียกความแตกต่างนี้ว่าความผิดพลาดของการสังเกตการณ์ (error of observation) ซึ่งแบ่งได้เป็น 2 แบบ คือ ความผิดพลาดที่เป็นระบบ (systematic error) เป็น

ความผิดพลาดที่เกิดขึ้นอย่างเป็นระบบ มีกฎเกณฑ์แน่นอน ถ้าทราบกฎเกณฑ์นี้ก็จะสามารถคำนวณแก้ไขได้ ความผิดพลาดอีกแบบหนึ่ง คือ ความผิดพลาดแบบไม่แน่นอน ( random error ) เป็นความผิดพลาดที่ไม่เป็นระบบ ไม่มีระเบียบ และไม่มีกฎเกณฑ์ที่แน่นอน สำหรับการวัดแต่ละครั้ง ไม่สามารถคำนวณแก้ไขได้ สำหรับการวัดปริมาณทางฟิสิกส์ใด ๆ ถ้าเกิดความผิดพลาดแบบไม่แน่นอนเพียงอย่างเดียว ค่าที่วัดได้จะมีการกระจายในรูปแบบของการกระจายแบบปกติ ( normal distribution ) หรือการกระจายตามแบบของเกาส์ ( Gaussian distribution ) ซึ่งเขียนเป็นสมการได้ดังนี้

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\bar{x}}{\sigma}\right)^2} \quad (6.6)$$

เมื่อ  $\bar{x}$  = ค่าเฉลี่ย  
 $\sigma$  = ความเบี่ยงเบนมาตรฐาน

ในการบอกปริมาณมากน้อยของความผิดพลาดที่เกิดขึ้นเป็นร้อยละ เราสามารถบอกได้ด้วยอัตราส่วนระหว่างความเบี่ยงเบนมาตรฐานกับค่าเฉลี่ยของข้อมูลที่วัดได้ ซึ่งเขียนเป็นสูตรได้ว่า

$$E = 100 \frac{\sigma}{\bar{x}} \quad (6.7)$$

เมื่อ  $E$  = ความผิดพลาดสัมพัทธ์เป็นร้อยละ ( Topping, 1971 )

##### 5. การปรับเส้นตรงด้วยวิธีกำลังสองน้อยที่สุด ( Linear fitting )

หลักการกำลังสองน้อยที่สุด ( least square ) กล่าวโดยสรุปได้ว่า ในการวัดปริมาณ ๆ หนึ่งหลาย ๆ ครั้งจะได้ข้อมูลกลุ่มหนึ่ง เราอาจหาค่าที่จะมาแทนข้อมูลกลุ่มนี้ คือค่าที่น่าจะเป็นมากที่สุด ( most probable value ) ซึ่งถ้าเราวัดปริมาณดังกล่าวหลาย ๆ ครั้ง ค่าที่วัดได้จะมีแนวโน้มเข้าใกล้ค่า ๆ หนึ่งมากกว่าค่าอื่น ๆ มีหลักการเป็นคณิตศาสตร์ว่า ผลบวกกำลังที่สองของความเบี่ยงเบนจากค่าที่น่าจะเป็นนี้ จะมีค่าน้อยที่สุด โดยอาศัยหลักการดังกล่าวหาแนวโน้มของความสัมพันธ์ระหว่างปริมาณ 2 ชุดได้ดังนี้

ถ้ามีผลการทดลองชุดหนึ่งวัดปริมาณ  $y$  ได้  $y_1, y_2, \dots, y_n$  ซึ่งสอดคล้องกับปริมาณ  $x_1, x_2, \dots, x_n$  เมื่อนำค่าต่าง ๆ ของ  $y$  มาเขียนกราฟกับ  $x$  ถ้ากราฟที่ได้มีแนวโน้มเป็นเส้นตรง จากหลักการกำลังสองน้อยที่สุด เราสามารถหาสมการเส้นตรงที่แทนแนวโน้มของความสัมพันธ์ระหว่าง  $x$  กับ  $y$  ได้ว่า

$$y = a + bx \quad (6.8)$$

เมื่อ

$$a = \frac{\sum_{i=1}^n y_i \sum_{i=1}^n x_i^2 - \sum_{i=1}^n x_i \sum_{i=1}^n x_i y_i}{n \sum_{i=1}^n x_i^2 - \left( \sum_{i=1}^n x_i \right)^2}; b = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - \left( \sum_{i=1}^n x_i \right)^2}$$

## 6. สหสัมพันธ์ (Correlation)

6.1 การหาสหสัมพันธ์ระหว่างข้อมูล 2 ชุด ในข้อ 5 นอกจากเราจะสามารถหาเส้นตรงซึ่งใช้แทนแนวโน้มดังกล่าวแล้ว ยังสามารถบอกว่าข้อมูล 2 ชุดนี้มีความสัมพันธ์กันแบบเส้นตรงมากน้อยเพียงใด โดยหาค่าสัมประสิทธิ์สหสัมพันธ์ (coefficient of correlation) ซึ่งเขียนเป็นสูตรได้ว่า

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (6.9)$$

เมื่อ  $r =$  สัมประสิทธิ์สหสัมพันธ์ ค่าของ  $r$  จะอยู่ระหว่าง 1 และ -1 ถ้า  $r$  มีค่าใกล้ 1 มาก แสดงว่า  $x_i$  และ  $y_i$  มีสหสัมพันธ์กันมาก (Hoel, 1967)

6.2 การทดสอบนัยสำคัญของสัมประสิทธิ์สหสัมพันธ์ เมื่อมีข้อมูลจับคู่อยู่ชุดหนึ่ง

$\{x_1, y_1; x_2, y_2; x_3, y_3; \dots; x_n, y_n\}$

ซึ่งประชากร (population) มีจำนวนข้อมูลมาก แต่ละส่วนคือ  $\{x_i\}$  กับ  $\{y_i\}$

มีการกระจายแบบปกติ ถ้าข้อมูล 2 ส่วนนี้มีสหสัมพันธ์กัน โดยมีค่าสัมประสิทธิ์สหสัมพันธ์

เป็น  $\rho$  และถ้าสุ่มเอาตัวอย่างจากประชากรชุดนี้มา 1 กลุ่ม เป็น  $\{x_\alpha, y_\alpha, x_\beta, y_\beta, \dots\}$  มีจำนวนข้อมูล  $N$  ค้นหาหาสัมประสิทธิ์สหสัมพันธ์ได้  $r$  ซึ่ง  $r$  ไม่จำเป็นต้องเท่ากับ  $\rho$  เมื่อสุ่มตัวอย่างหลาย ๆ ครั้ง (สมมติว่าจำนวนข้อมูลในกลุ่มเท่ากันทุกครั้ง) ก็จะได้ค่า  $r$  แตกต่างกันไป โดยทั่วไปแล้วการกระจายของค่า  $r$  ไม่เป็นแบบปกติ (normal distribution) ในทางปฏิบัติ การหาสหสัมพันธ์ของประชากรของข้อมูลจับคู่ มักจะหาจากตัวอย่างที่สุ่มออกมาจากประชากร ค่าสัมประสิทธิ์สหสัมพันธ์ที่คำนวณได้ถึงแม้มีค่าไม่เท่า  $\rho$  แต่เพื่อความสะดวก เรามักจะใช้  $r$  แทน  $\rho$  เนื่องจากค่า  $r$  จะกระจายรอบ ๆ ค่า  $r = \rho$  เราสามารถบอกขอบเขตการกระจายของค่า  $r$  ได้โดยการแปลงค่า  $r$  ให้อยู่ในรูปของ  $z$  ด้วยสมการ 6.10 และ 6.11 ซึ่งถ้า  $z$  นี้จะมีการกระจายใกล้เคียงกับการกระจายแบบปกติ (Hoel, 1967) และเพื่อความสะดวกในที่นี้จะยอมรับว่า การกระจายของ  $z$  เป็นแบบปกติจริง

ในการแปลง  $r$  เป็น  $z$  ดังกล่าวคือ การแปลงของฟิชเชอร์ (Fisher transformation) (Hoel, 1967) เขียนเป็นสมการได้ดังนี้

$$z = 0.5 \ln \frac{1+r}{1-r} \quad (\text{Hoel, 1967}) \quad (6.10)$$


ได้มีขนิมเลขคณิตของ  $z$  เป็น  $\mu_z = 0.5 \ln \frac{1+\rho}{1-\rho}$  (Hoel, 1967) (6.11)

และได้ความเบี่ยงเบนมาตรฐานของ  $z$  เป็น  $\sigma_z = \frac{1}{\sqrt{N-3}}$  (Hoel, 1967) (6.12)

เมื่อ  $N$  เป็นจำนวนค่าของ  $r$  หรือจำนวนค่าของ  $z$  เราอาจแปลง  $z$  ต่อไปให้อยู่ในรูปของ  $Z$  ซึ่งมีการกระจายแบบปกติเช่นกัน เพื่อนำไปใช้ในการทดสอบ ได้ว่า

$$Z = \frac{z - \mu_z}{\sigma_z} \quad (6.13)$$

เนื่องจากค่าของ  $Z$  มีการกระจายแบบปกติดังในรูป 6.1 จึงสามารถคำนวณหาโอกาสหรือความน่าจะเป็น (probability) ที่จะพบ  $Z$  ในช่วงต่าง ๆ ได้ ความน่าจะเป็นที่จะพบ  $Z$  ในช่วงต่าง ๆ นี้ได้มีการคำนวณไว้เป็นตารางสำเร็จแล้ว

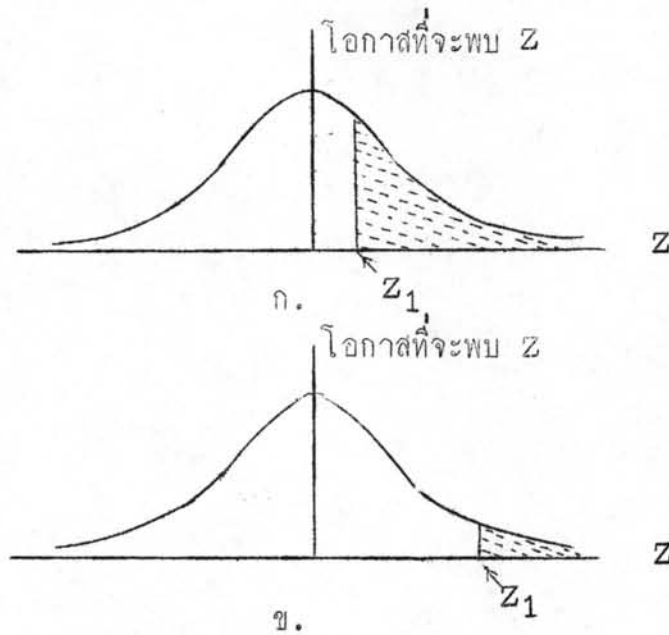


รูป 6.1 แสดงลักษณะของการกระจายแบบปกติ

จากการคำนวณหาโอกาสที่จะได้ค่า  $Z$  ในช่วงต่าง ๆ พบว่า โอกาสที่  $Z$  จะมีค่าอยู่ระหว่าง  $Z_1$  และ  $Z_2$  ก็คือพื้นที่ใต้โค้งปกติที่มีขอบเขตอยู่ระหว่าง  $Z_1$  และ  $Z_2$  สำหรับช่วงจาก  $-1$  ถึง  $1$  จะมีโอกาสที่จะพบค่า  $Z$  อยู่ในช่วงนี้เท่ากับ 68% อาศัยสมการ 6.13 หาได้ว่า ช่วงจาก  $-1$  ถึง  $1$  จะสอดคล้องกับค่า  $z$  ในช่วงจาก  $\mu_z - \sigma_z$  ถึง  $\mu_z + \sigma_z$  ดังนั้นโอกาสที่  $z$  จะอยู่ระหว่าง  $\mu_z - \sigma_z$  ถึง  $\mu_z + \sigma_z$  จึงมีค่าเท่ากับ 68% ซึ่งโดยทั่วไปถือว่า  $z$  ที่มีค่าอยู่ในช่วงนี้ไม่แตกต่างกันอย่างมีนัยสำคัญ

เนื่องจากค่า  $r$  ที่หาได้จากตัวอย่างที่สุ่มจากระชากร อาจมาจากประชากรที่ 2 ส่วนไม่มีสหสัมพันธ์กันเลยก็ได้ (คือ  $\rho = 0$ ) ถ้าเราได้ค่า  $r$  อยู่ค่าหนึ่ง เช่นค่าเป็น  $r_1$  เราต้องการทดสอบว่า ประชากรที่มี  $\rho = 0$  จะมีโอกาสได้ค่า  $r=r_1$  มากน้อยเพียงใด การทดสอบทำโดยใช้สมการ 6.10 แปลงค่า  $r_1$  เป็น  $z_1$  และถือว่า  $z$  มีการกระจายแบบปกติ ซึ่งมี  $\mu_z = 0$  (เพราะ  $\rho = 0$ ) และมี  $\sigma_z = \frac{1}{\sqrt{N-3}}$  หลังจากนั้นอาศัยสมการ 6.13 แปลง  $z_1$  ให้เป็น  $Z_1$  แล้วพิจารณาว่า โอกาสที่  $Z \geq Z_1$  มีค่ามากน้อยเพียงใด

(สมมติกรณีนี้  $Z_1 > 0$ ) ถ้าโอกาสที่  $Z \geq Z_1$  มีค่าน้อย (โปรดดูรูป 6.2 ก และ ข ประกอบ) ก็แสดงว่า  $r_1$  ไม่น่าจะมาจากประชากรซึ่ง 2 ส่วนไม่มีสหสัมพันธ์กันเลย และสรุปได้ว่าประชากรที่สัมพันธ์อย่างมาแน่น มีสหสัมพันธ์กัน



รูป 6.2 กราฟเปรียบเทียบโอกาสที่  $Z_1$  หรือ  $r_1$  จะมาจากประชากรที่  $\rho = 0$   
 ก. แสดงว่า  $Z_1$  หรือ  $r_1$  น่าจะมาจากประชากรที่  $\rho = 0$   
 ข. แสดงว่า  $Z_1$  หรือ  $r_1$  ไม่น่าจะมาจากประชากรที่  $\rho = 0$