

บทที่ 2

วิธีทางคณิตศาสตร์เบื้องต้น

ประวัติและความเป็นมาของการวิเคราะห์ความแปรปรวน

การทดสอบเออฟ หรือ การวิเคราะห์ความแปรปรวน (ANOVA) เป็นวิธีการหนึ่งที่ Sir Ronald A. Fisher คิดค้นขึ้น (Kruskal and Tanur 1978 352 - 357) ในตอนแรกงานที่ใช้เทคนิคนี้ในการวิเคราะห์ คือ งานใน้านเก่าครกรรม และชีววิทยา แต่ปัจจุบันนิยมใช้กันมาในทุก ๆ สาขาวิชา โดยเฉพาะอย่างยิ่งในสาขาสังคมศาสตร์ ศาสติก F นี้ Snedecor ได้เป็นผู้เสนอขึ้นเพื่อให้เป็นเกียรติแก่

R.A. Fisher

การทดสอบเออฟ (F - Test) เป็นกระบวนการหนึ่งทางคณิตศาสตร์ เพื่อใช้ในการทดสอบสมมติฐานความเท่ากันของมัธยมเลขคณิตจากผลการทดลองของแต่ละทรัพยากร (Treatment Population Mean) โดยทางทฤษฎีค่า F เป็นการแจกแจงที่ได้มาจากการสักส่วนของ χ^2 2 คา คือ

$$F = \frac{\chi_1^2 / v_1}{\chi_2^2 / v_2} = \frac{s_1^2 / b_1^2}{s_2^2 / b_2^2} = \frac{b_2 s_2^2}{b_1 s_1^2}$$

ซึ่ง χ_1^2 เป็นการแจกแจงของ Chi - Square มีชั้นแห่งความเป็นอิสระ $v_1 = n_1 - 1$

χ_2^2 เป็นการแจกแจงของ Chi - Square มีชั้นแห่งความเป็นอิสระ $v_2 = n_2 - 1$

แต่ χ^2 นั้นไม่สามารถคำ Z^2 และค่า Z มีข้อคดีงบอย่างหนึ่งว่า ลักษณะการแจกแจงของประชากรต้องเป็นโค้งปกติ (Normal Distribution) ดังนั้น ค่า F จึงคงจะบุกคลงเบื้องตนอย่างเข้มงวดค่าย

ศาสติก F จะมีการแจกแจงแบบ F (F - Distribution) โดยมีลักษณะการแจกแจงเป็นโค้งเบี้ยงขวา (positive Skewed Distribution) ค่าพิสัยอยู่ระหว่าง 0 กับ ∞ ค่ามัธยฐานเท่ากับหรือน้อยกว่า 1 ค่ามัธยมเลขคณิตเท่ากับ $v_2 / (v_2 - 2)$ โดยที่ v_2 มากกว่า 2 ค่าความแปรปรวนเท่ากับ $\frac{2 v_2^2 (v_1 + v_2 + 2)}{v_2 (v_2 - 2) (v_2 - 4)}$ โดยที่ v_2 มากกว่า 4 ค่าฐานนิยมเท่ากับ $\frac{v_2 (v_1 - 2)}{v_1 (v_2 + 2)}$ โดยที่ v_1 มากกว่า 2 ซึ่งค่า

v_1, v_2 เป็นค่าซึ้นแห่งความเป็นอิสระ (degree of freedom) ของผลบวกกำลังสองระหว่างกลุ่ม (Sum of Square between Groups) และผลบวกกำลังสองภายในกลุ่ม

(Sum of Square Within Groups) (Kruskal and Tanur 1978 : 164)

ตารางค่า F สร้างขึ้นโดย P.C. Tang (1938) (Feldt 1958 : 871)

และต่อมาในปี ก.ศ. 1967 M.L. Tiku ได้พัฒนารายละเอียดของตาราง F ให้ดีขึ้น โดยตาราง F และพื้นที่ใต้โถงที่รวมกันเท่ากับ 1 การใช้ตาราง F ต้องทราบค่าซึ้นแห่งความเป็นอิสระของ เชย์และส่วน พื้นที่ที่เกี่ยวข้องกับ F นิยมใช้เฉพาะที่อยู่ปลายทางขวา มือของโถง

โน้ตเกลล์สำหรับการวิเคราะห์ความแปรปรวน

การวิเคราะห์ความแปรปรวนมีหลายแบบคือ กันขึ้นอยู่กับการออกแบบการทดลองดังนี้ คือ

1. ตัวแปรอิสระ 1 ตัว หลักๆ คือ การทดลอง แต่ละตัวมีผลต่อตัวแปรตาม 1 ตัว มีตัวแปรอิสระ 1 ตัว

1.1 การวิเคราะห์ความแปรปรวนแบบสุ่มสมมูล

(Completely Randomized Design)

1.2 การวิเคราะห์ความแปรปรวนแบบกลุ่มสุ่ม (Randomized Block Design)

1.3 การวิเคราะห์ความแปรปรวนแบบจตุรัส ลาติน (Latin Square Design)

2. ตัวแปรอิสระหลายตัว แต่ละตัวมีผลต่อตัวแปรตาม 1 ตัว มีตัวแปรอิสระหลายตัว แต่ละตัวมีผลต่อตัวแปรตาม 1 ตัว มีตัวแปรอิสระ 2 ตัว

2.1 การวิเคราะห์ความแปรปรวนแบบเพคทอเรียล (Factorial Design)

2.2 การวิเคราะห์ความแปรปรวนแบบแยกส่วน (Split - Plot Design)

การวิเคราะห์ความแปรปรวนตามโน้ตเกลล์ก็ตามแล้ว สามารถจะจำแนกเป็นโน้ตเกลล์เชิงเส้นตรงของผลทดลองตามกำหนด (Fixed Effects Linear Model) และโน้ตเกลล์เชิงเส้นตรงของผลทดลองตามการสุ่ม (Random Effects Linear Model) สำหรับงานวิจัยนี้จะไถ่อกตัวอย่าง เนพาะโน้ตเกลล์ที่ใช้กันมาก คือ โน้ตเกลล์เชิงเส้นตรงของผลทดลองตามกำหนด (Fixed Effect Linear Model) มีรูปแบบดังนี้

$$x_{ij} = \mu + \alpha_j + \epsilon_{ij}$$

เมื่อ x_{ij} ก็อ ผลการวัดตัวแปรตามซึ่งได้จากตัวอย่างที่สุ่มมาจากประชากร

μ ก็อ มัชณิมเลขคณิตของประชากร

α_j ก็อ ผลจากการทดลอง (Treatment Effects) ซึ่งจะมีค่าคงที่สำหรับตัวอย่างทั้งหมดภายในประชากร

ϵ_{ij} ก็อ ความคลาดเคลื่อนทางการทดลอง (Error Effect) ซึ่งเป็นอิสระสำหรับค่าความคลาดเคลื่อนอื่นๆ

และการางวิเคราะห์ความแปรปรวน มีรูปแบบ ดังนี้ ก็อ

แหล่งความแปรปรวน	SS	df	MS	F
ระหว่างกลุ่ม (B)	$n \sum_{j=1}^k (\bar{x}_{\cdot j} - \bar{x}_{\cdot \cdot})^2$	$k - 1$	SS_B / df	MS_B / MS_W
ภายในกลุ่ม (W)	$\sum_{j=1}^k \sum_{i=1}^n (x_{ij} - \bar{x}_{\cdot j})^2$	$N - k$	SS_W / df	
ทั้งหมด (T)	$SS_B + SS_W$	$N - 1$		
โดยที่ N	จำนวนชุดข้อมูลทั้งหมด			
n	จำนวนชุดข้อมูลในแต่ละระดับการทดลอง			
k	จำนวนระดับการทดลอง			
x_{ij}	คะแนนแต่ละตัวซึ่งจะเป็นที่ i ของกลุ่มที่ j			
$\bar{x}_{\cdot j}$	มัชณิมเลขคณิตของชุดข้อมูลในแต่ละระดับการทดลอง			
$\bar{x}_{\cdot \cdot}$	มัชณิมเลขคณิตของชุดข้อมูลทั้งหมด			

ข้อตกลงเบื้องต้นของ ANOVA

- ข้อตกลงเบื้องต้น เกี่ยวกับประชากรมีการแจกแจงแบบปกติ (Assumption of Normally Distributed Population) หมายความว่า เช่นและส่วนของอัตราส่วน F (F - Ratio) ต้องเป็นอิสระกัน โดยข้อมูลต้องได้รับเลือกอย่างสุ่มจากประชากรที่มีการแจกแจงปกติ นอกจากนี้ความคลาดเคลื่อนทางการทดลองในไม่เกล

ผลการทดลองตามกำหนดและตามการสุ่ม (Fixed - Effects and Random - Effects Models) ต้องมีการแจกแจงแบบปกติในแต่ละประชากรทดลอง

2. ข้อตกลงเบื้องต้นของความเป็นเอกพันธุ์ของความแปรปรวนคลาดเคลื่อนของประชากร (Assumption of Homogeneity of Population Error Variance) หมายความว่า ความแปรปรวนที่เนื่องจากความคลาดเคลื่อนภายในประชากรทดลองแต่ละกลุ่มเท่ากัน (Kirk 1969 : 61)

3. ข้อตกลงเบื้องต้นของการรวมกันโดยของผลการทดลอง (Assumption Additivity of Effects) หมายความว่า แรงปะทะ (Interaction) ระหว่างระดับการทดลองและกลุ่มนี้ค่าเท่ากันญี่ หรือหมายถึงความแปรปรวนรวมระหว่างระดับการทดลองแต่ละคู่เท่ากัน (Schoffé 1970 : 94)

4. ข้อตกลงเบื้องต้นเกี่ยวกับความเป็นอิสระในการสุ่มตัวอย่าง (Assumption of Independence Within Samples) และความเป็นอิสระระหว่างกลุ่มตัวอย่าง (Assumption of Independence Between Samples) ในกรณีของการสุ่มแบบสัมบูรณ์ (Marascuilo 1971 : 344)

สถิติที่ใช้ทดสอบชี้ทางเบื้องต้นของ ANOVA

สถิติที่ใช้ทดสอบชี้ตกลงเบื้องต้นเกี่ยวกับความเป็นเอกพันธุ์ของความแปรปรวนความคลาดเคลื่อนของประชากร โดยตั้งสมมติฐานว่า

$$H_0 : \hat{b}_1^2 = \hat{b}_2^2 = \dots = \hat{b}_k^2$$

ได้แก่ Bartlett's Test , Hartley's Test and Cochran's Test (Kirk 1969 : 61 - 62)

1. Bartlett's Test (1937) สถิติที่ใช้คือ

$$\frac{B}{\text{โดยที่}} = \frac{2.30259}{C} \left[V \log_{10} \frac{M_S}{k} - \sum_{j=1}^k (V_j \log_{10} \hat{b}_j^2) \right]$$

$$C = 1 + \frac{\sum_{j=1}^k 1/V_j - 1/N}{3(k-1)}$$

$$V_j = \text{ชี้ของความเป็นอิสระ } \hat{b}_j^2$$

$$V = \text{ชี้ของความเป็นอิสระ } M_S$$

$$\hat{b}_j^2 = \text{ตัวประมาณค่าที่ไม่คำนึงถึงของความแปรปรวนของประชากร}$$

คำนวณจาก

$$\hat{\sigma}_j^2 = \left[\frac{n}{k} \sum_{j=1}^k x_j^2 - (\bar{x})^2/n \right] / (n-1)$$

$$MS_e = \sum_{j=1}^k \hat{\sigma}_j^2 / v$$

k = จำนวนความแปรปรวน

ถ้า v_j มากกว่าหรือเท่ากับ 5 ค่า B จะมีการแจกแจงเป็น χ^2 ที่ชันแห่ง

ความเป็นอิสระเท่ากับ $k-1$

ถ้า v_j น้อยกว่า 5 ให้ใช้ตารางที่คำนวณโดย McCrrington และ

Thompson (1946)

2. Hartley's F - Max Test (1940 & 1950)

สถิติที่ใช้คือ

$$F_{\max} = \frac{\hat{\sigma}_{\max}^2}{\hat{\sigma}_{\min}^2}$$

โดยชันแห่งความเป็นอิสระเท่ากับ k และ $n-1$

เมื่อ k = จำนวนความแปรปรวน

n = จำนวนการสังเกตในแต่ละระดับของการทดลอง

สมมติฐานที่ว่าความเท่ากันของความแปรปรวนจะได้รับการปฏิเสธ ถ้า F_{\max} มากกว่า F จากตาราง ถ้าจำนวน n ในแต่ละระดับของการทดลองแตกต่างกันเพียงเล็กน้อย ให้ใช้ค่า n ค่าที่มากที่สุด เพื่อกำหนดชันแห่งความมีนัยสำคัญสำหรับการทดลองนั้น ซึ่งอาจทำให้เกิดเปลี่ยนแปลงไปเพียงเล็กน้อย คือทำให้จำนวนครั้งในการปฏิเสธสมมติฐานมากกว่าที่ควรจะเป็น

3. Cochran's Test (1941)

สถิติที่ใช้คือ

$$C = \frac{\sum_{j=1}^k \hat{\sigma}_j^2}{\sum_{j=1}^k \hat{\sigma}_j^2}$$

โดยที่ $\hat{\sigma}_j^2$ มากที่สุด คือ ความแปรปรวนที่ใหญ่ที่สุดในจำนวนความแปรปรวนทั้งหลาย

$\sum_{j=1}^k \hat{\sigma}_j^2$ คือ ผลรวมของความแปรปรวนทั้งหมด

C มีการแจกแจงเป็น F โดยสมมติฐานที่ว่าความเท่ากันของความแปรปรวนจะได้รับการปฏิเสธ ถ้าค่า C มากกว่า F จากตาราง และชันแห่งความเป็น

อิสระสำหรับการทดสอบนี้ เท่ากับ k และ $n - 1$ เมื่อนักวิชาชีวะ F_{max}

ซึ่งคิดเห็นเกี่ยวกับการฝ่าฝืนข้อตกลงเบื้องตนในการวิเคราะห์ความแปรปรวน

(Effects of Failure To Meet Assumptions in Analysis of Variance)

Cochran (1947) (Kirk 1969:60) ซึ่งให้เห็นว่ามันเป็นไปไม่ได้
ที่จะแน่ใจว่า ข้อมูลที่ได้ตรงตามข้อตกลงเบื้องตนที่ต้องการ การวิเคราะห์ความแปรปรวน
จึงไก่ค้าประมาณมากกว่าไก่ค้าที่แท้จริง

Eisenhart , Cochran และ Bartlett ในยุคปัจจุบันเนื่องจากเพื่อ
กันว่า การฝ่าฝืนข้อตกลงเบื้องตนมีผลต่อระดับความมั่นคงสำคัญและความไว (Sensitivity)
ของการทดสอบเอฟ (Cochran and Cox 1957 : 91 - 92) กล่าวคือ ถ้าผู้วิจัย
ทดสอบที่ระดับนัยสำคัญ .05 ซึ่งแท้จริงอาจจดอยู่ที่ระดับ .04 หรือ .07 ก็ได้ การขาดความ
ไวก็จะทำให้มีผลต่ออำนาจในการทดสอบเอฟลดลง และการแจกแจง F นั้นถูกข้อตกลง
เบื้องต้นบางส่วน ก็จะทำให้เกิดผลลัพธ์อีบีงในการทดสอบด้วย

Bartlett (1937) , Cochran (1947) และ Edwards
(1960 , 1968) ในยุคปัจจุบันเนื่องจากเพื่อ
กันว่า การวิเคราะห์ความแปรปรวนมีความแกร่ง
(Robust) ถึงแม่ว่าจะฝ่าฝืน (Violate) ข้อตกลงเบื้องตนเกี่ยวกับความเป็น
เอกพันธุ์ในการแปรปรวนของความคลาดเคลื่อนของประชากร หรือฝ่าฝืนข้อตกลงเบื้องตน
เกี่ยวกับประชากรนี้การแจกแจงปกติเพียงเล็กน้อย

ANOVA สำหรับผลการทดลองตามกำหนด (Fixed - Effects ANOVA)
มีความแกร่งสำหรับอัตราความคลาดเคลื่อนประเทที่ 1 ถึงแม่ว่าจะฝ่าฝืนข้อตกลงเบื้องตน
ของการทดสอบเอฟ โดยเฉพาะข้อตกลงเบื้องตนเกี่ยวกับความเป็นเอกพันธุ์ของความ
แปรปรวนของประชากร ไม่มีผลกระทบต่อการทดสอบเอฟเลย (Kruskal and Tanur 1978:550)

จากการศึกษาของ Wayne Lee (1975 : 282 - 283) พนิช ข้อตกลง
เบื้องต้นทั้ง 3 ข้อ ตามเหลวเพียงข้อเดียวหรือหลายข้อ อัตราส่วน F (F - Ratio)
ก็ยังคงมีการแจกแจงความน่าจะเป็นภายใต้การศึกษาซ้ำ (Replication) แต่การแจกแจง
นี้จะแตกต่างมากบ้างน้อยบ้างจากการแจกแจง F (F - Distribution) อย่างจริงๆ
ข้อนี้ยังคงความน่าจะเป็นภายใต้การศึกษาซ้ำ แต่ต่างจากข้อตกลงเบื้องตนมากน้อยแค่ไหน เราเรียก การแจกแจง
ของอัตราส่วน F ในสถานการณ์การทดสอบจริง ๆ ว่า การแจกแจงประสิทธิภาพของอัตรา

ส่วน F (Effective Distribution of the F - Ratio) ซึ่งจะแตกต่างไปจากการแจกแจง F ในทางทฤษฎี (Theoretical F - Distribution) เมื่อข้อตกลงเป็นอย่างเดียว ภายใต้สมมติฐานสูตร (Null Hypothesis) อัตราส่วน F จะใหญ่กว่า $F_{100(1-\alpha)}$ (df_1, df_2) ที่ระดับนัยสำคัญ α ความน่าจะเป็นที่แท้จริงก็คืออัตราส่วน F จะใหญ่กว่า $F_{100(1-\alpha)}$ (df_1, df_2) เท่ากับสัดส่วนของการแจกแจงประสิทธิภาพที่ใหญ่กว่า $F_{100(1-\alpha)}$ (df_1, df_2) สัดส่วนนี้อาจใหญ่กว่าหรือเล็กกว่า α ได้ เมื่อสัดส่วนนี้ใหญ่กว่า α รายการว่า การทดสอบ F มีความเอนเอียงทางบวก (Positively Biased) ส่วนสัดส่วนที่เล็กกว่า α รายการว่า การทดสอบ F มีความเอนเอียงทางลบ (Negatively Biased) ปัญหาสาหัสในการทดสอบความเอนเอียงทางบวก ก็คือ สมมติฐานสูตรถูกปฏิเสธอย่างรังสรรค นั่นก็คืออัตราส่วน F ที่มีขนาดใหญ่เกินขีดจำกัดความน่าจะเป็นที่มากกว่าในทางทฤษฎี ดังนั้นผู้วิจัยจึงมักเขียนรายงานผิด ก็คือ เกิดความคลาดเคลื่อนประเภทที่ 1 (Type I Error) ขึ้น ในทางตรงกันข้าม สำหรับปัญหาการทดสอบที่เอนเอียงทางลบ สมมติฐานสูตรที่ผิดถูกยอมรับอย่างง่ายดาย นั่นคือ อัตราส่วน F ที่เสียเกินขีดจำกัดความน่าจะเป็นที่มากกว่าในทางทฤษฎี ผู้วิจัยจึงมักเขียนรายงานผิด เกิดความคลาดเคลื่อนประเภทที่ 2 (Type II Error)

Norton (Lee 1975 : 284) พบว่า การแจกแจงของอัตราส่วน F สำหรับการแจกแจงของคะแนนที่ไม่เป็นปกติ (Non - Normal Score Distribution)

ไม่แตกต่างกับการแจกแจงของ F ในทางทฤษฎี ดังนั้นประสิทธิภาพของอัตราความเหลาด เคลื่อนประเภทที่ 1 จากผลการทดลอง (Actual Type I Error) ในกรณีนี้จึงไม่ผิดไปจากอัตราความคลาดเคลื่อนที่ระบุ (Nominated α) และnorทันไกศึกษาผลงานของความเบี้ยว (Skewness) และความโค้ง (Kurtosis) ที่มีประสิทธิภาพของอัตราความคลาดเคลื่อนประเภทที่ 1 จากผลการทดลอง พบว่า เมื่อข้อมูลมีการแจกแจงแบบโลจิสติก (Logistic) อัตราความคลาดเคลื่อนประเภทที่ 1 จากผลการทดลอง มีค่าประมาณ .08 และ .03 เมื่อเปรียบเทียบกับอัตราความคลาดเคลื่อนที่ระบุเท่ากับ .05 และ .01 ตามลำดับ ส่วนการแจกแจงแบบ Highly Platykurtic คืออัตราความคลาดเคลื่อนประเภทที่ 1 จากผลการทดลอง มีค่าใกล้เคียงกับค่าอัตราความคลาดเคลื่อนที่ระบุ นอกเหนือนอร์ทัน พบว่า การทดสอบ F มีความแกร่งสำหรับ

ข้อมูลที่ฝ่าฝืนข้อตกลง เป็นตน ที่เกี่ยวกับประชากรที่มีการแจกแจงแบบปกติ หรือที่เกี่ยวกับความเป็นเอกพันธุ์ของความแปรปรวนค่าคาดเดื่อนของประชากร หรือทั้ง 2 อย่าง

Pearson (1931) ในหนังสือ Lindquist (Kirk 1969 : 60 - 61) เสนอแนะว่าประชากรอาจแตกต่างไปจากการแจกแจงแบบปกติในลักษณะที่มีความเบี้ยว (Skewness) และความโค้ง (Kurtosis) หรือทั้ง 2 ลักษณะใดและเมื่อนำมาวิเคราะห์ความแปรปรวนพบว่า การแจกแจงของ F จะไม่ได้รับความกราบทบกระเทือนมากนักเมื่อประชากรไม่สมมาตร และถึงแม้ว่ามีความเบี้ยวหรือความโค้งก็ตาม ยกเว้นในกรณีที่แตกต่างกันออกไปมาก เช่น ประชากรมีการแจกแจงโค้งมากหรือแบบมากยิ่งปักศ์โน้มเคลบลดการทดลองตามกำหนด (Fixed - Effect Model) ถึงแม้ว่าประชากรจะมีการแจกแจงแตกต่างจากปกติมากพอประมาณก็ตามแต่ประชากรมีการแจกแจงรูปทรงคล้ายกันมาก เช่น เบี้หงบวกทุกกลุ่ม การวิเคราะห์ความแปรปรวนก็ยังคงมีความแกร่ง (Robust)

การแปลงข้อมูล (Transformation of Data)

เป็นการเปลี่ยนแปลงข้อมูลอย่างมีระบบ เพื่อมุ่งหวังที่จะช่วยให้อ่านจากการทดสอบมีค่าสูงสุด (Kirk 1969 : 556) จุดประสงค์หลักของการแปลงข้อมูลก็เพื่อทำให้ข้อมูลที่ได้จากการวิจัยเป็นไปตามข้อตกลง เป็นตนของการทดสอบที่ทองการใช้ เช่น แบบทดสอบเอฟ

Wayne Lee (1975 : 288) กล่าวว่าจุดประสงค์ของการแปลงข้อมูล มี 2 ประการ คือ

1. เพื่อทำให้ข้อมูลมีการแจกแจงปกติ และความแปรปรวนมีความเป็นเอกพันธุ์
2. กำจัดเหตุของแรงประทะ (Interaction) เพื่อจะได้ข้อมูลเป็นโน้มเกลี่ยที่มีความเป็นบาง (Additive Model)

Kirk (1969 : 63) ระบุว่าจุดประสงค์ของการแปลงข้อมูลมี 3 ประการ

คือ

1. เพื่อให้โควตาข้อมูลมีความแปรปรวนความคลาดเคลื่อน เป็นเอกพันธุ์
2. เพื่อให้โควตาการแจกแจงข้อมูลในระดับของการทดลองหรือการแจกแจงภายในเซลล์เป็นปกติ (Normality of Treatment - Level Distribution or within - Cell Distribution)

ภายในเซลล์เป็นปกติ (Normality of Treatment - Level Distribution or within - Cell Distribution)

3. เพื่อให้ได้ผลของการทดลองมีความเป็นกลาง (Additivity of Treatment Effect)

Schlesselman

(1973 : 369) กล่าวว่าจุดประสงค์ของ

การแปลงข้อมูลมี 2 ประการ คือ

1. เพื่อให้ได้ข้อมูลที่ถูกต้องโดยประมาณตามทฤษฎี (Theoretical Approximation)

2. เพื่อจากการกับข้อมูลเพื่อให้เป็นไปตามข้อกลงเบื้องต้นภายใต้การวิเคราะห์ข้อมูลตามระเบียบแบบแผน (Conventional Analysis).

ประโยชน์ของการแปลงข้อมูล

การแปลงข้อมูลในรูปแบบทาง ๆ มีประโยชน์ดังนี้ คือ (Kruskal and Tanur 1978 : 1044 - 1048)

1. ทำให้ก้าวสัมพันธ์ของตัวแปร 2 ตัว เป็นเส้นโค้งที่เกลี้ยกลาย คืออยู่ในลักษณะของเส้นตรง หรือกราฟของเส้นโค้ง

2. ทำให้ก้าวความแปรปรวนของข้อมูลมีค่าคงที่ เพื่อสะดวกในการวิเคราะห์ความแปรปรวน

3. เทคนิคของการวิเคราะห์ความแปรปรวนจะถูกต้องตามข้อมูลมีการแจกแจงปกติ ดังนั้นการแปลงข้อมูลจะช่วยปรับปรุงลักษณะการแจกแจงของประชากรให้ดีขึ้น ตัวอย่าง เช่น ข้อมูลมีการแจกแจงเบื้องต้น การแปลงข้อมูลโดยใช้ล็อกฐาน 10 จะช่วยให้การแจกแจงเป็นปกติ

4. การแปลงข้อมูลในรูปแบบทาง ๆ ช่วยในการศึกษาความของข้อมูล (Interpretation) เพื่อให้การวิเคราะห์ภายนลังได้ข้อมูลที่ถูกต้อง และมีความหมายชัดเจนยิ่งขึ้น

5. ข้อมูลอยู่ในรูปแบบทาง ๆ เช่น เศษส่วนหรือเปอร์เซนต์ การแปลงข้อมูลในรูปแบบทาง ๆ จะช่วยทำให้สามารถวิเคราะห์ความแตกต่างได้ถูกต้อง ตัวอย่าง เช่น ตามข้อมูลมีการแจกแจงแบบพัซซอง (Poisson Distribution) ก็ใช้การแปลงข้อมูลโดยใช้รากที่สองของการวิเคราะห์ ซึ่งประโยชน์ที่จะได้รับ ก็คือทำให้ข้อมูลเป็นไปตามข้อตกลงเบื้องต้นของการวิเคราะห์ความแปรปรวน

6. ปรับปรุงข้อกลงเบื้องตนของการวิเคราะห์ความแปรปรวนที่วิภาคการทดลองนี้ความเป็นบวก หมายความว่าช่วยทำให้การแปรปรวนระหว่างระดับการทดลองแต่ละคู่มีความเท่ากัน

ลักษณะการแปลงข้อมูลในรูปแบบต่าง ๆ

การแปลงข้อมูลเชิงเส้นตรง (Linear Transformation)

การแปลงข้อมูลเชิงเส้นตรง เรียกอีกชื่อว่า Coding มีรูปแบบคือ

$Y = c_1x + c_2$, $c_1 \neq 0$ หรือ $Y = c_1x$ โดย Y เป็นการแปลงรูปข้อมูลเชิงเส้นของ x และ c_1, c_2 เป็นค่าคงที่ เมื่อข้อมูลถูกแปลงรูปเชิงเส้นตรง คำนวณเลขคณิตและการแปรปรวนของข้อมูลจะถูกเปลี่ยนไปด้วย ดังนี้

$$\begin{aligned} \mu' &= c_1\mu + c_2 \\ \text{และ } b^2 &= c_1^2 b^2 \end{aligned}$$

โดยที่ μ และ b^2 เป็นการคำนวณเลขคณิตและการแปรปรวนของข้อมูลเดิม (Kreyszig 1970 : 89 - 90)

เมื่อข้อมูลถูกแปลงรูปเชิงเส้นตรง จะไม่มีผลกระทบของการวิเคราะห์ความแปรปรวน เพราะหาก Mean Square ของเศษและส่วนเปลี่ยนไปในอัตราที่เท่ากัน นอกจากนี้การแปลงข้อมูลเชิงเส้นตรงยังไม่สามารถทำให้ความลับหรือของข้อกลงเมื่อ กันของการทดสอบ เอฟดีซีนได้

Non - Linear and Monotonic Transformation

การแปลงรูปแบบข้อมูล 2 ชนิด คือ ถ้าความตัวของตัวอย่างที่เปลี่ยนไปเป็นอันต้นกันแทนกันเรียกว่า transformation คือ Kruskal and Tanur การแปลงรูปแบบนี้เรียกว่า Non - Linear Transformation และ Schlesselman เรียกว่า Monotonic Transformation การแปลงรูปทั้ง 2 แบบนี้ เป็นการแปลงข้อมูลที่เมื่อค่า x มีการเปลี่ยนแปลง ก็ มีการเปลี่ยนแปลงตาม ซึ่งอาจอยู่ในลักษณะที่เปลี่ยนแปลงไปในทางเดียวกัน หรือในทางตรงกันข้ามกันได้

Monotonic Transformation (Kruskal and Tanur 1978 : 1050) แบ่งออก

เป็น 2 ลักษณะ คือ

1. Increasing Monotonic Transformation คือ การแปลงข้อมูลที่เมื่อกำ y มีค่าเพิ่มขึ้น เมื่อ x มีค่าเพิ่ม เมื่อนำไปเขียนกราฟ เส้นโค้งจะขึ้นเรื่อยๆ ไปทางขวา (Go To Right)

ตัวอย่างเช่น $Y = \log x$

$$Y = \ln x$$

$$Y = \sqrt{x}$$

2. Decreasing Monotonic Transformation คือ การแปลงข้อมูลที่ y จะลดลง เมื่อ x มีค่าเพิ่มขึ้น ตัวอย่างเช่น $Y = 1/x$

Non - Linear Transformation

การแปลงข้อมูลแบบ Non - Linear

ที่น่าใช้ มีดังนี้ คือ

① การแปลงข้อมูลโดยใช้รากสอง (Square Root Transformation)

รูปแบบคือ $Y' = \sqrt{y}$ เมื่อ Y' เป็นข้อมูลที่ถูกแปลงขึ้นโดยใช้รากสอง มักใช้กับข้อมูลที่มีการแจกแจงแบบพัชอง (Poisson Distribution) โดยค่ามีคุณิตเลขคณิตและความแปรปรวนของทรีทเม้นท์เป็นสัดส่วนกันคือ $\sigma^2_y = k \bar{Y}$ การแจกแจงแบบนี้เป็นผลเนื่องจากตัวแปรตาม (Dependent Variable) เป็นความลับของเหตุการณ์ที่มีโอกาสเกิดขึ้นได้น้อยมาก เช่น การนับจำนวนเหตุการณ์ใดๆ หรืออุบัติเหตุบาง ๗ เป็นตน (Kirk 1969 : 64 - 65) การแปลงข้อมูลโดยวิธีนี้จะมีประสิทธิภาพ มากกว่า แปรปรวนของข้อมูลเมื่อเทียบกับ 0.25 ถ้าข้อมูลนี้นาคเล็กมาก Freeman และ Turkey (1950) ได้เสนอให้ใช้รูปแบบการแปลงดังนี้คือ $Y' = \sqrt{y + 1}$ หรือ $Y' = \sqrt{y} + \sqrt{y+1}$ ซึ่งจะให้ผลลัพธ์กว้าง และคงมาในปี ค.ศ. 1954 Mosteller และ Bush ได้สร้างตาราง $\sqrt{y} + \sqrt{y+1}$ ขึ้น เพื่อสะดวกในการคำนวณ

การแปลงข้อมูลโดยใช้รากสอง มีผลอยู่ปัจจัยของการแจกแจงความถี่ของความคลาดเคลื่อน (Shape of the frequency Distribution of Error)

และการรวมกันไกของผลการทดลอง (Additivity of Effects) ถ้าผลการทดลอง

ระหว่างทรีเมนต์และกลุ่มมีค่าความเป็นนาภในข้อมูลเดิมเมื่อแปลงข้อมูลโดยใช้รูทสองแล้ว จะไม่พบค่าการรวมกันไม่นักอีก (Snedecor and Cochran 1976 : 325 - 327) นอกจากนั้นยังช่วยให้ค่าเฉลี่ยและความแปรปรวนเป็นอิสระจากกัน

(2.) การแปลงข้อมูลโดยใช้รูทฐาน 10 (Logarithemic Transformation)

รูปแบบคือ $Y = \log y$ หรือ $Y' = \log (y + 1)$ เมื่อ Y' เป็นข้อมูลที่ถูกแปลงโดยใช้รูทฐาน 10 โดยรูปแบบหลังจะเมื่อข้อมูลบางตัวมีค่าน้อยมาก หรือเท่ากับ 0 (Kirk 1969 : 64) การแปลงข้อมูลโดยใช้รูทฐาน 10 ใช้ในการที่ความแปรปรวนมีค่าเป็นสัดส่วนกำลัง 2 ของค่าเฉลี่ยของการทดลองหรืออีกนัยหนึ่ง สัมประสิทธิ์ของความแปรปรวนของค่าเฉลี่ยของทรีเมนต์เป็นค่าคงที่ ซึ่งจะช่วยให้ค่าความแปรปรวนของข้อมูลมีค่าเท่ากัน นอกจากนี้จะทำให้อิทธิพลต่าง ๆ ที่มีผลแบบคูณ (Multiplicative) ในข้อมูลเดิมเปลี่ยนเป็นข้อมูลใหม่ที่มีผลความเป็นนาภ (Additivity) (Steel and Torrie 1960 : 235)

การแปลงข้อมูลแบบนี้มีประดิษฐิกภาพส่วนรับการแจกแจงปกติที่มีความเบี้ยเป็นนาภ

(Positive Skewness) ซึ่งการแจกแจงแบบนี้มักเกิดขึ้นกับงานวิจัยทางจิตวิทยา เมื่อเกณฑ์ที่วัดเป็นสเกลของเวลา เช่น จำนวนเวลาที่เป็นวินาทีที่ทำงานเสร็จ (Winer 1971 : 400)

(3.) การแปลงข้อมูลโดยใช้รูทฐานอี (Natural Logarithemic Transformation)

รูปแบบคือ $Y' = \ln y$ เมื่อ Y' เป็นข้อมูลที่ถูกแปลงโดยใช้รูทฐานอี หลักการและประโยชน์คล้ายกับการแปลงข้อมูลโดยใช้รูทฐาน 10

(4.) การแปลงข้อมูลโดยใช้วิธีกลับเศษส่วน (Reciprocal Transformation)

รูปแบบ คือ $Y' = 1/y$ เมื่อ Y' เป็นข้อมูลที่ถูกแปลงโดยวิธีกลับเศษส่วน ใช้เมื่อค่ากำลังสองของมาร์โซน เลขคณิตของทรีเมนต์ และค่าส่วนเบี่ยงเบนมาตรฐาน เป็นสัดส่วนกัน ถ้าข้อมูลมีค่าน้อยมาก หรือเท่ากับ 0 จะใช้รูปแบบกันนี้คือ $Y' = 1/(y+1)$ ซึ่งจะให้ผลที่ค่อนข้าง (Kirk 1969 : 66) การแปลงข้อมูลแบบนี้จะมีประดิษฐิกภาพ ถ้าคัวแปร เป็นเวลาที่ใช้ตอบโต้กลับ (Reaction)

(5.) การแปลงข้อมูลโดยใช้อาร์ค 一角 (Arcsine of Angular Transformation)

รูปแบบคือ $y' = 2 \arcsine y$ เมื่อ y' เป็นข้อมูลที่แปลงรูปโดยใช้
การคูณ และ y เป็นค่าสัดส่วน (Proportion) ผู้จัดไม่จำเป็นต้องคำนวณค่า y'
จากสูตร เพราะมีตารางสำหรับคำนวณค่า y' เมื่อค่า y มีค่าตั้งแต่ .001 ถึง
.999 และค่า y' มีหน่วยเป็นเรเดียน ในปี ก.ศ. 1947 Bartlett เสนอแนะ
ว่าสำหรับข้อมูลที่มีค่าใกล้ 0 หรือ 1 ให้ใช้รูปแบบการแปลงดังนี้คือ

$$y' = 2 \arcsine \sqrt{y \pm 1/2n}$$

โดยที่ n เป็นจำนวนข้อมูล เครื่องหมาย + ใช้สำหรับค่า y ที่มีค่าใกล้ 0 และเครื่องหมาย
- ใช้สำหรับค่า y ที่มีค่าใกล้ 1 (Winer 1971 : 399 - 400)

การแปลงข้อมูลแบบนี้จะมีประสิทธิภาพเมื่อค่านั้นผิดเส้นควิตรและความแปรปรวน
เป็นสัดส่วนกัน คั่งนี้ $\sigma_{ij}^2 = \mu_{ij} (1 - \mu_{ij})$ และการแจกแจงเป็นแบบไบโนเมียล
กรณีเช่นนี้ใช้เมื่อจำนวนของการทดสอบคงที่ และ y เป็นความน่าจะเป็นในการสังเคราะห์
ซึ่งแปรเปลี่ยนไปตามระดับการทดลอง (Kirk 1969 : 66)

นอกจากรูปแบบการแปลงข้อมูลข้างบนแล้ว (Kruskal and Tanur
ได้แบ่งออกเป็น 2 ลักษณะ คั่งนี้

1. One - Bend Transformation เป็นการแปลงข้อมูลที่เมื่อนำมาเขียน
กราฟ จะได้รูปกราฟมีลักษณะเป็นเส้นโค้ง มีเพียงโง่เดียวเท่านั้น (Kruskal
Tanur 1978 : 1051)

ตัวอย่าง เช่น	$y = \log(x+k)$	เรียกว่า Logarithemic Family
	$y = \sqrt{x+k}$	เรียกว่า Square Root Family
	$\sqrt{y} = x^c$	เรียกว่า Power Family
	$\sqrt{y} = e^{cx}$	เรียกว่า Exponential Family
	$y = (x+k)^c$	เรียกว่า Simple Family

โดยที่ k , c เป็นค่าคงที่ และ $e = 2.718$

2. Two - Bend Transformation เป็นการแปลงข้อมูลที่เมื่อนำมา
เขียนกราฟ จะได้รูปกราฟมีลักษณะเป็นเส้นโค้ง มี 2 โง่ (bend) (Kruskal and
Tanur 1978 : 1051)

ตัวอย่าง เช่น $y = \arcsine x$	เรียกว่า Angular or Arcsine Transformation
$y = 1/2 \log x/1 - x$	เรียกว่า Logit Transformation
$y = 1/2 \log 1+r/1-r$	เรียกว่า Fisher's Z Transformation
$y = \text{arc tan} r$	เรียกว่า Hyperbolic Arctangent Transformation

การวิจัยที่เกี่ยวข้อง

1974

Freeman และ Tukey (1939 : 607 - 611) ได้ทดสอบความสามารถในการแปลงข้อมูลโดยใช้รากสอง (Square Root Transformation) ในลักษณะต่าง ๆ

5 แบบด้วยกัน คือ

$$1. Y = \sqrt{x}$$

$$2. Y = \sqrt{x+1}$$

$$3. Y = \sqrt{x} + \sqrt{x+1}$$

$$4. Y = \sqrt{x+3/8}$$

$$5. Y = \sqrt{x+1/2}$$

เมื่อ x เป็นข้อมูลที่มีการแจกแจงแบบพื้นของ (Poisson Distribution)

เพื่อเปรียบเทียบดูว่า การแปลงข้อมูลโดยใช้รากสองในลักษณะแบบใดที่ทำให้เกิดความแปรปรวนความคลาดเคลื่อนมีมากที่สุด โดยใช้กลุ่มตัวอย่างขนาดต่าง ๆ กัน คือ 5, 10, 20 ผลปรากฏว่า การแปลงข้อมูลโดยใช้รากสองแบบ $Y = \sqrt{x} + \sqrt{x+1}$ ให้ผลการวิเคราะห์ที่สุดที่สุด

Bartlett (Kempthrone 1952 : 156) เสนอแนะว่า การที่ผู้วิจัย จะวิเคราะห์ความแปรปรวนเพื่อสรุปผลงานการวิจัย จะต้องคำนึงถึงข้อมูลว่า ข้อมูลที่ได้มานั้นเป็นไปตามข้อตกลงเบื้องต้นหรือไม่ โดยเฉพาะข้อตกลงเบื้องต้นที่เกี่ยวกับความเป็นเอกพันธุ์ของความแปรปรวน ถ้าข้อมูลไม่เป็นไปตามข้อตกลงเบื้องต้น เช่น ให้เปลี่ยนข้อมูลในรูปแบบต่าง ๆ เสียก่อนที่จะวิเคราะห์ โดยพิจารณาความลับพันธุ์ระหว่างค่าความแปรปรวนและมัชณิตเลขคณิต เป็นหลักในการแปลงข้อมูล และได้เสนอตารางการแปลงข้อมูล ดังนี้

ค่าความแปรปรวนในเหตุการณ์เดียวกัน (m)	วิธีการแปลงข้อมูล	ความแปรปรวนของข้อมูล ที่แปลง
$\lambda^2 \frac{n^2}{n-1}$	$\sqrt{x} \text{ or } \sqrt{x + 1/2}$	0.25
$\lambda^2 \frac{n^2}{n(n-1)}$	$\log_e x$ $\log_{10} x, \log_{10}(x+1)$	$\lambda^2 \text{ or } 0.189 \lambda^2$
$\lambda^2 \frac{n^2(1-n^2)}{n-1}$	$\log_e x$ $\sin^{-1} x(\text{degree})$ $\sin^{-1} x(\text{radian})$	$2/(n-1)$
$\frac{(1-n^2)^2}{n-1}$	$\log_e \frac{x}{1+x}$ $1/2 \log_e \frac{(1+x)}{(1-x)}$	$0.25/n$ $0.25/n$ λ^2 $1/(n-3)$

Steal และ Torrie (1960 : 236 - 237) เสนอแนะว่า การแปลงข้อมูล มีประโยชน์มากสำหรับข้อมูลที่มีขนาดเล็ก เพื่อกันหาว่ามีการสหสัมพันธ์ระหว่างค่านี้กับความแปรปรวนของกลุ่มทดลองและการแปรปรวนภายในกลุ่มหรือไม่ (Correlation between the treatment Mean and their Within Treatment Variance) แต่ถ้าพบว่าความแปรปรวนของข้อมูล มีการแตกต่างกันเพียงเล็กน้อย ค่าของการแปลงข้อมูลด้วยวิธีต่าง ๆ ก็อาจไร้ผล ถ้าอาจจะไม่ได้ผลลัพธ์ที่คิดที่สุด憎เสนอไป ทำให้ผู้อ่านไม่กระจ่างในรายงานผลการวิจัย ดังนั้นจึงจำเป็นคงเปลี่ยน ข้อมูลที่ถูกแปลงนั้นกลับคืนดูข้อมูลเดิม

Ekoblad (1962 : 200 - 202) ไก่ทดสอบความสามารถในการแปลง การแจกแจงของข้อมูลที่เบี้ยวให้เป็นข้อมูลที่มีการแจกแจงอย่างสมมาตร โดยใช้วิธีการแปลง ข้อมูลโดยใช้ล็อกฐาน 10 พmv ด้วยกลุ่มตัวอย่างขนาดเล็ก และมีการแจกแจงที่เบี้ยว มากกับความน่าจะเป็นที่ต่ำ สามารถทำให้ข้อมูลมีการแจกแจงปกติໄก โดยวิธี การทางคณิตศาสตร์ (Standard Mathematical Procedure) คือใช้วิธีการแปลง ข้อมูลโดยใช้ล็อกฐาน 10 และไกเสนอแนะว่าวิธีการแปลงข้อมูลโดยใช้รูหส่องและโดยวิธี กลับเศษส่วน ถ้าสามารถทำให้ข้อมูลมีการแจกแจงปกติໄก

Budescu และ Appelbaum (1981 : 55 – 74) ใช้เทคนิคของมอนติการ์โล ชิมูเลร์น เพื่อศึกษาผลของการแปลงข้อมูลเพื่อให้ได้ถ้าความแปรปรวนมีเสถียรภาพ (Variance Stabilizing Transformation) ที่มีค่าอ่านใจ การทดสอบเอฟ โดยจำแนกการแจกแจงของประชากรเป็น 5 สถานการณ์ คือ แบบไนโนเมี่ยล แบบปกติที่มีค่ามัธยมิเตอร์และค่าความแปรปรวนเท่ากับการแจกแจงแบบไนโนเมี่ยล แบบพัวซอง แบบปกติที่มีค่ามัธยมิเตอร์และค่าความแปรปรวนเท่ากับการแจกแจงแบบพัวซอง และการแจกแจงปกติ ใช้กลุ่มตัวอย่าง 4 กลุ่ม มีขนาดไม่เท่ากัน คำว'y แผนการทดลองแบบ CR - k ทำการจำลองการทดลองซ้ำ 1500 ครั้ง พนว่า การแปลงข้อมูลไม่มีผลต่ออ่านใจ การทดสอบเอฟที่ระดับนัยสำคัญ .01 และ .05 นอกจากนี้ยังทำให้อ่านใจการทดสอบเอฟ มีค่าลดลง โดยเฉพาะในกรณีกลุ่มตัวอย่างขนาดเล็กมากจากประชากรที่มีค่าความแปรปรวนสูง และกลุ่มตัวอย่างขนาดใหญ่มากจากประชากรที่มีค่าความแปรปรวนต่ำ

Srisukho (1974 : 1 – 3) ใช้เทคนิคของมอนติการ์โล ชิมูเลร์น เพื่อศึกษา จำนวนการทดสอบเอฟจากข้อมูลที่มีการแจกแจงของประชากร 6 รูปแบบ คือ แบบปกติ, แบบบูนิฟอร์ม, แบบ Double Exponential แบบ Moderate Negatively Skewed แบบ Extreme Negatively Skewed และแบบ Bimodal ขนาดกลุ่มตัวอย่างเท่ากับ 5, 10, 15 และ 20 ทำการจำลองการทดลองซ้ำ 1000 ครั้ง และตั้งระดับนัยสำคัญที่ .01 และ .05 พนว่า อ่านใจการทดสอบเอฟมีความแกร่ง (Robust) สำหรับข้อมูลที่มีการเพาฟินช์อ็อกลุง เป็นตน ก็ยังกับประชากรมีการแจกแจงแบบปกติ นอกจากนั้นพนว่าอ่านใจความคลาดเคลื่อนปะนีรุ่นในระดับนัยสำคัญเท่ากับ .01 เมื่อกลุ่มตัวอย่างมีขนาดเท่ากับ 5 และ 10 ซึ่งมีการแจกแจงแบบบูนิฟอร์ม และกลุ่มตัวอย่างขนาดเท่ากับ 15 ที่มีการแจกแจงแบบ Bimodal และแบบเบน (Skewed Distribution)