

$$(Y_{ij} - \bar{Y})^2 = r \sum (\bar{Y}_i - \bar{Y})^2 + \sum (Y_{ij} - \bar{Y}_i)^2$$

(SStotal) (SStrt) (SSE)

$\sum (Y_{ij} - \bar{Y})^2$

การวิเคราะห์ ความแปรปรวน

: ทำไมจึงเรียกการวิเคราะห์ความแปรปรวน

(What is Analysis of Variance)

๕๔๘๒๐๓

$(V_1, V_2), \alpha$

ดร.พหล ศักดิ์กะทศน์

ผู้ช่วยศาสตราจารย์, ภาควิชาคณิตศาสตร์
และสถิติ คณะวิทยาศาสตร์,
มหาวิทยาลัยแม่โจ้.



บทนำ

ในการวิเคราะห์ความแปรปรวนที่มีการแจกแจงทางเดียว (One - way Classification Analysis of Variance) หรือ แผนการทดสอบแบบสุ่มสมบูรณ์ (Completely Randomized Design, CRD) มีรูปแบบสมการเชิงเส้นตรง (Linear Equation Model) คือ

$$Y_{ij} = \mu + \tau_i + \epsilon_{ij}$$

เมื่อ

Y_{ij} คือ ค่าสังเกตที่วัดได้

μ คือ ค่าเฉลี่ยรวมทั้งหมด

τ_i คือ อิทธิพลของ Treatment ที่ i โดยที่ $i = 1, 2, 3, \dots, t$ (t คือ จำนวนซ้ำ)

ϵ_{ij} คือ ความคลาดเคลื่อนของหน่วยทดลองที่ได้รับ Treatment ที่ i ซ้ำที่ j โดยที่ $j = 1, 2, 3, \dots, r$ (r คือ จำนวนซ้ำ)

สมมติฐานที่ต้องการทดสอบคือ

H_0 : $\mu_1 = \mu_2 = \mu_3 = \dots = \mu_t$ (ค่าเฉลี่ยทุก treatment เท่ากัน)

H_1 : มีค่าเฉลี่ยอย่างน้อย 1 ค่าที่ต่างจากค่าอื่นๆ หรือ

H_2 : $\tau_i = 0$ (ไม่มีอิทธิพลของ treatments)

H_1 : มี τ_i อย่างน้อย 1 ค่าที่ไม่เท่ากับ 0

จากสมมติฐานหลัก H_0 เรามองว่าค่าเฉลี่ยทุก treatments เท่ากัน หรือ อิทธิพลของ treatment ไม่มี จึงอาจมีบางคนสงสัยว่า เมื่อดูชื่อเรื่องแล้วเป็นการวิเคราะห์ความแปรปรวน จะเห็นว่าไม่เกี่ยวกับสมมติฐานที่จะทดสอบ เพราะจากสมมติฐานเป็นการทดสอบค่าเฉลี่ย ของข้อมูลหลายๆ กลุ่ม ดังนั้นก่อนอื่นจึงขอให้พิจารณาเกี่ยวกับลักษณะของข้อมูลในแผนการทดลองแบบสุ่มสมบูรณ์ก่อน

2. แหล่งความแปรปรวน ของข้อมูล

ในการทดลองแบบสุ่มสมบูรณ์นี้ หน่วยทดลองต้องสม่ำเสมอมากที่สุด แผนการทดลองนี้จึงจะมีประสิทธิภาพ ขอให้สังเกตข้อมูลตัวอย่างข้อมูลการทดลองปลูกข้าว 12 แปลง โดยข้าวที่ปลูกเป็นข้าวพันธุ์เดียวกัน อายุเท่ากัน สภาพแวดล้อมต่างๆ เหมือนกัน (สม่ำเสมอ) ทำการปลูกโดยไม่ใส่ปุ๋ยทุกแปลง ถ้าหน่วยทดลองสม่ำเสมอหรือได้รับการปฏิบัติเหมือนกันจริง ผลผลิตหรือค่าสังเกตที่ได้ต้องเท่ากัน ดังตารางที่ 1

	(i)			
	20	20	20	20
(j)	20	20	20	20
	20	20	20	20

ตารางที่ 1 หน่วยทดลองได้รับการปฏิบัติเหมือนกัน

จากตารางที่ 1 จะพบว่าผลผลิตข้าวแต่ละแปลงหรือ $Y_{ij} = 20$ ยังไม่มีอิทธิพล treatment และความแปรปรวนภายในกลุ่ม แต่เมื่อมีอิทธิพลของ treatments (ปุ๋ย) ดังตารางที่ 2 โดยที่ treatment ที่ 1 ไม่ใช้ปุ๋ยหรือปฏิบัติต่อหน่วยทดลองเหมือนเดิม จึงไม่ทำให้ผลผลิตเปลี่ยนแปลง ส่วน treatment ที่ 2, 3 และ 4 สมมติให้มีอิทธิพลของ treatment (ปุ๋ย) ที่ทำให้ผลผลิตเพิ่ม 2, 4 และ 5 กก. ต่อแปลง ตามลำดับ ผลที่ได้ดังตารางที่ 2 ดังนี้

	Treatments (i)				
	1	2	3	4	←
	(0)	(+2)	(+4)	(+5)	อิทธิพลของ treatments
ข้า (j)	20	22	24	25	
	20	22	24	25	

ตารางที่ 2 หน่วยทดลองได้รับ treatments ที่แตกต่างกันหรือมีความแปรปรวนระหว่าง treatment แต่ยังไม่มีความแปรปรวนภายในกลุ่มหรือภายใน treatment (error)

ดังนั้น $Y_{ij} = \mu + \tau_i$

เช่น ผลผลิตข้าวใน treatment ที่ 3 จะมีผลผลิตเท่ากับ $20 + 4 = 24$ เป็นต้น

แต่ในสภาพความเป็นจริง แม้ว่าเราจะเลือกข้าวที่มาปลูกสม่ำเสมอแล้วก็ตาม อาจมีความแตกต่างกันบ้างที่ผู้ทดลองไม่สามารถควบคุมได้ทั่วถึง เช่น การได้รับแสง ปริมาณน้ำที่ได้รับไม่สม่ำเสมอ มีแมลงมากัดกินบางต้น เป็นต้น ดังนั้นผลผลิตข้าวจากการทดลองจริงๆ แล้วอาจจะเป็นได้ดังตารางที่ 3 ดังนี้

	Treatments (i)				
	1	2	3	4	←
	(0)	(+2)	(+4)	(+5)	อิทธิพลของ treatments
ข้า (j)	19.2	22.5	24.8	26.3	} ความแปรปรวนภายใน treatment (error)
	21.3	23.1	23.4	25.2	
	18.6	21.2	24.1	24.5	

ตารางที่ 3 หน่วยทดลองที่ได้รับ treatments ที่ต่างกันและมีความแปรปรวนภายในกลุ่ม (สภาพการทดลองโดยทั่วไป)

$$\text{ดังนั้น } Y_{ij} = \mu + \tau_i + \epsilon_{ij}$$

จะพบว่าภายใน treatment เดียวกัน มีความแตกต่างหรือความแปรปรวนระหว่างหน่วยทดลองเกิดขึ้น นั่นก็คือ มีความคลาดเคลื่อนภายในกลุ่ม (error) เกิดขึ้น

ดังนั้นรูปแบบสมการเชิงเส้นตรง ของแผนการทดลองแบบสุ่มสมบูรณ์ ค่าสังเกต

$$Y_{ij} = \mu + \tau_i + \epsilon_{ij}$$

จะพบว่าถ้าวิเคราะห์ข้อมูลของแผนการทดลองแบบสุ่มสมบูรณ์นั้น ความแปรปรวนทั้งหมดแบ่งออกเป็น 2 ส่วน คือ ความแปรปรวนระหว่าง treatments หรือ ความแปรปรวนระหว่างกลุ่ม กับ ความแปรปรวนระหว่างหน่วยทดลองภายใน treatments เดียวกัน หรือความแปรปรวนภายในกลุ่ม (error)

3. ตารางการวิเคราะห์ความแปรปรวน (ตาราง ANOVA) และการทดสอบ

แหล่งของความแปรปรวน ที่ทำให้ค่าสังเกตที่ได้ไม่เท่ากันทุกค่า ก็คือ อิทธิพลของ treatments และ error

SOV	df.	SS	MS	F
Treatments	t - 1	SSt _{trt}	MSt _{trt}	MSt _{trt} /MSE
Error	n - t	SSE	MSE	
Total	n - 1			

เมื่อ n คือจำนวนข้อมูลหรือหน่วยทดลองทั้งหมด

ถ้าพิจารณาค่า Expected Mean Square (EMS) ของ treatments และ error จะพบว่าแต่ละส่วนประกอบด้วยความคลาดเคลื่อนดังนี้


SOV	EMS
Treatments	$\sigma^2 + r\sigma_{\tau}^2$
Error	σ^2
Total	

ซึ่ง $SS(\text{total}) = SS(\text{Treatments}) + SS(\text{error})$

หรือ

$$\sum (Y_{ij} - \bar{Y})^2 = r \sum (\bar{Y}_i - \bar{Y}_{..})^2 + \sum (Y_{ij} - \bar{Y}_i)^2$$

(SStotal) (SSt_{trt}) (SSE)



เมื่อ v_1 คือ degree of freedom ของ treatments เท่ากับ t - 1

v_2 คือ degree of freedom ของตัวหาร error เท่ากับ n - t

\bar{Y} เป็นค่าเฉลี่ยรวมทั้งหมดของตัวอย่าง และใช้ประมาณค่า μ หรือค่าเฉลี่ยประชากร

\bar{Y}_i เป็นค่าเฉลี่ยของ treatment ที่ i

SStotal หรือ ความคลาดเคลื่อนทั้งหมด คือ ผลรวมของกำลังสองของผลต่างระหว่างค่าสังเกตแต่ละค่า กับค่าเฉลี่ยทั้งหมด = $\sum(Y_{ij} - \bar{Y})^2$

SSE คือ ผลรวมของกำลังสองของผลต่างระหว่างค่าสังเกตแต่ละค่า กับค่าเฉลี่ยของ treatment นั้นๆ ทั้งหมดทุก treatment = $\sum(Y_{ij} - \bar{Y}_i)^2 = EMS(\text{error}) = \sigma^2$

SStreat หรือ ความคลาดเคลื่อนระหว่าง treatment คือ ผลรวมของกำลังสองของผลต่างระหว่าง treatment กับค่าเฉลี่ยทั้งหมด = $\sum(Y_{ij} - \bar{Y})^2 = EMS(\text{error}) = \sigma^2 + r\sigma_t^2$

ในการวิเคราะห์ข้อมูลแบบสุ่มสมบูรณ์นั้น ถ้าความแปรปรวนระหว่าง treatments ซึ่งค่า EMS ประกอบด้วย $\sigma^2 + r\sigma_t^2$ เปรียบเทียบกับความแปรปรวนของ Error ซึ่งประกอบด้วย σ^2 หรือเท่ากับอัตราส่วนของ $(\sigma^2 + r\sigma_t^2) / \sigma^2$ ถ้าค่าเฉลี่ยระหว่าง treatments ใกล้เคียงกันมากๆ หรือความแปรปรวนเนื่องจาก treatments น้อย ค่า $r\sigma_t^2$ จะมาก อัตราส่วน $(\sigma^2 + r\sigma_t^2) / \sigma^2$ จะมากกว่า 1 มากๆ ซึ่งค่าอัตราส่วน $(\sigma^2 + r\sigma_t^2) / \sigma^2$ เรียกว่า F - ratio ซึ่งในการคำนวณจะใช้ค่า MStreat/MSE แทน

ถ้าค่า F - ratio มีค่ามากเกินไปจุดวิกฤติ หรือ $F > F_{\alpha}(V_1, V_2)$ เราจะสรุปว่าความคลาดเคลื่อนระหว่าง Treatments มีค่ามากกว่าความคลาดเคลื่อนระหว่างหน่วยทดลอง (error) เกินจุดที่จะยอมรับได้ (จุดวิกฤติ) เราจะปฏิเสธสมมติฐานหลักว่า ค่าเฉลี่ยแต่ละ treatments เท่ากัน ซึ่งก็คือ ความคลาดเคลื่อนระหว่าง treatments มีค่ามากนั่นเองหรือสรุปได้ว่าค่าเฉลี่ยแต่ละ treatments แตกต่างกัน

4. สรุป

จากสมมติฐานที่ทดสอบว่า ค่าเฉลี่ยเท่ากันหรือไม่มีความแตกต่างระหว่างค่าเฉลี่ยสมมติฐาน

$H_0: \mu_1 = \mu_2 = \mu_3 = \dots = \mu_t$ (ค่าเฉลี่ยทุก treatment เท่ากัน)

$H_1: T_i$ มีค่าเฉลี่ยอย่างน้อย 1 ค่าที่ต่างจากค่าอื่นๆ

หรือ

$H_0: T_i = 0$ (ไม่มีอิทธิพลของ treatments)

$H_1: \text{มี } T_i \text{ อย่างน้อย 1 ค่าที่ไม่เท่ากับ 0}$

เราอาจจะเขียนสมมติฐานในรูปแบบของการทดสอบความแปรปรวนเหมือนกับชื่อเรื่องการวิเคราะห์ความแปรปรวนก็ได้ คือ

$H_0: \sigma_t^2 = 0$ หรือความแปรปรวนของ treatments เท่ากับ 0 หรือไม่มีความแตกต่างระหว่าง treatment หรือค่าเฉลี่ยเท่ากัน และ

$H_1: \sigma_t^2 \neq 0$

จากบทความที่กล่าวมา หลายท่านคงเกิดความเข้าใจบ้างว่าการทดสอบความแตกต่างระหว่างค่าเฉลี่ยของข้อมูลตั้งแต่ 2 กลุ่มขึ้นไป ซึ่งเราเรียกว่าการวิเคราะห์ความแปรปรวนนั้นแท้ที่จริงใช้เทคนิคการวิเคราะห์ความแปรปรวนมาสรุปผลต่างค่าเฉลี่ย

บรรณานุกรม

- พหล ศักดิ์คะหัตน์. (2548). **หลักสถิติ**. เอกสารประกอบการสอนวิชาหลักสถิติ ภาควิชาคณิตศาสตร์ และสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยแม่โจ้.
เชียงใหม่: มหาวิทยาลัยแม่โจ้.
- Cochran, W. G. and G. M. Cox. (1957). **Experimental Design**. New York: John Wiley and Sons.
- Cooper, B. E. (1975). **Statistics for Experimentalist**. Oxford: Pergamon.