

บทที่ 2

เอกสาร และผลงานวิจัยที่เกี่ยวข้อง

ขนาดของกลุ่มตัวอย่างและการสูญหายของข้อมูล

ในการวิจัยเชิงทดลองโดยเฉพาะทางจิตวิทยานั้นส่วนมากมักจะเผชิญกับปัญหาในด้านข้อจำกัดเกี่ยวกับขนาดของกลุ่มตัวอย่างที่ใช้ในการทดลอง คือมักเป็นการทดลองกับกลุ่มตัวอย่างขนาดเล็กหรือมีจำนวนไม่มากนัก เนื่องจากสาเหตุหลาย ๆ ประการ (Sims 1973: 2-3) คือ

1. เป็นการศึกษารายกรณีหรือกลุ่มย่อย ๆ ที่ผู้วิจัยจะทำการศึกษาสภาพการณ์ต่าง ๆ อย่างเข้มข้นและลึกซึ้ง (Intensive Study) เพื่อให้ตัวแปรทดลองส่งผลต่อตัวแปรตามมากที่สุด และสามารถควบคุมตัวแปรแทรกซ้อนที่อาจจะส่งผลต่อตัวแปรตามด้วย
2. ลักษณะตามธรรมชาติของข้อมูลมีจำนวนน้อย เพราะการศึกษาลักษณะทางจิตวิทยาบางสภาพการณ์ ผู้วิจัยไม่สามารถที่จะหาจำนวนของตัวอย่างหรือข้อมูลที่มีสภาพตามที่ต้องการได้มากเพียงพอ
3. ประหยัดในด้านค่าใช้จ่ายจากเครื่องมือและอุปกรณ์ที่ใช้ในการทดลอง เพราะบางงานวิจัยต้องศึกษากันในระยะยาว (Longitudinal Study) เพื่อให้สามารถสรุปผลการวิจัยที่แน่ชัดและแม่นยำว่าผลที่เกิดขึ้นนั้น เนื่องจากตัวแปรทดลองอย่างแน่นอน

จากเหตุผลดังกล่าว การวิจัยเชิงทดลองจึงใช้ข้อมูลจำนวนน้อยเป็นกลุ่มขนาดเล็ก ดังนั้น เมื่อมีข้อมูลบางส่วนสูญหายไปจากการทดลอง จึงเกิดปัญหาในการสรุปผลเป็นอย่างมาก เพราะว่าจะได้ข้อมูลจากกลุ่มตัวอย่างลดลงไป ซึ่งมีผลต่อค่าความแปรปรวนและความถูกต้องแม่นยำในการวิเคราะห์ข้อมูล (Morrison 1976: 120) ซึ่งการสูญหายของข้อมูลเกิดจากการที่ผู้วิจัยไม่สามารถเก็บรวบรวมข้อมูลเกี่ยวกับตัวแปรที่ศึกษาได้ครบถ้วนเมื่อเสร็จสิ้นงานวิจัย โดยเกิดขึ้นได้ในหลายกรณีต่อไปนี้เช่น ผลวิจัยเกิดการเจ็บป่วยหรือตายในระหว่างทำการทดลอง หรือเกิดจากการอพยพย้ายสถานที่อยู่ หรือเกิดจากการไม่ตอบสนองของผลวิจัยต่อการวัด หรือการเก็บรวบรวมข้อมูล หรือเกิดจากการที่ผู้วิจัยไม่ได้บันทึกข้อมูลในวาระนั้น

เวลช์ แฟรงค์ และคอสเทลโล (Welch, Frank and Costello 1983: 177-180) กล่าวว่ากรณีข้อมูลสูญหาย เป็นปัญหาที่สำคัญมากอย่างหนึ่งในงานวิจัยทางด้านจิตบ้ำบิค (Psychiatric Research) มักเกิดขึ้นเสมอ ๆ ในกลุ่มตัวอย่างที่ทำการศึกษา และที่สำคัญประการหนึ่งก็คือข้อมูลที่สูญหายนั้นไม่เป็นลักษณะแบบสุ่ม จะเฉพาะเจาะจงกับคนไข้ที่มีปัญหา มาก ๆ เท่านั้น ทำให้การวิเคราะห์ทางสถิติในการสรุปผลและการอภิปรายเกิดลำเอียง อย่างเห็นได้ชัด

โคเฮน และโคเฮน (Cohen and Cohen 1983: 278) กล่าวว่าถ้าข้อมูลที่สูญหาย มีลักษณะแบบสุ่ม การทดสอบความสัมพันธ์ของผลลัพธ์ที่ได้จะไม่ลำเอียงไปจากสมมติฐานขณะเมื่อมี ข้อมูลครบถ้วน แต่จะมีผลทำให้เกิดความคลาดเคลื่อนของชั้นแห่งความเป็นอิสระ เป็นผลให้อำนาจ การทดสอบลดต่ำลง และยังมีผลให้ค่าความคลาดเคลื่อนมาตรฐานใหญ่ขึ้น คือไปลดค่าความแม่นยำ (precision)

ซาร์โควิช (Zarkovich 1966: 148-149) ได้ทำการวิจัยเชิงสำรวจ ซึ่งในชั้น การเก็บรวบรวมข้อมูล เขาได้พบว่ามีข้อมูลสูญหายเป็นจำนวนมาก และเขาได้ใช้วิธีประมาณค่าแทน ข้อมูลที่สูญหาย พบว่าการประมาณค่าแทนข้อมูลที่สูญหาย จะมีผลต่อค่าของความแปรปรวนมากกว่า การตัดข้อมูลที่สูญหายออกจากการวิเคราะห์ข้อมูล คือทำให้ได้ค่าความแปรปรวนที่ใกล้เคียงกับ ความเป็นจริงตรงกับข้อมูลที่ เขา เก็บรวบรวมเพิ่มจากครั้งก่อน

แบบบี (Babbie 1986: 372-373) ได้ให้ข้อเสนอแนะแนวทางปฏิบัติเกี่ยวกับข้อมูลที่ สูญหายไว้หลายวิธีคือ ถ้าผู้วิจัยมีข้อมูลที่สัมพันธ์กับที่สูญหายสัก 2-3 ข้อมูล และข้อมูลที่ใช้ใน การวิเคราะห์มีจำนวนมากเพียงพอ ควรแยกข้อมูลที่สัมพันธ์กับที่สูญหายออกจากการวิเคราะห์ ข้อมูลเบื้องต้นด้วย หรือผู้วิจัยควรวางแผนทางปฏิบัติเตรียมไว้สำหรับกรณีมีข้อมูลสูญหายเกิดขึ้น และข้อสำคัญควรระมัดระวังในการวิเคราะห์และตีความหมายจากข้อมูลที่มีการสูญหาย แบบบี ได้ศึกษาต่อมา พบว่าถ้าจะอนุรักษ์ผลการวิเคราะห์ข้อมูล (Conservative) การประมาณค่าแทน ข้อมูลที่สูญหายจะให้ผลการวิเคราะห์ดีกว่าการตัดข้อมูลในส่วนที่สมบูรณ์ของกลุ่มอื่นออก เพื่อให้ เหลือข้อมูลในแต่ละกลุ่มการทดลองเท่ากัน หรือวิเคราะห์ข้อมูลไปโดยไม่คำนึงถึงข้อมูลส่วนที่สูญหาย

คอคแครน และคอกซ์ (Cochran and Cox 1957: 80-82) ได้แนะนำให้ผู้วิจัยเลือกใช้วิธีประมาณค่าแทนข้อมูลที่สูญหาย ซึ่งสอดคล้องกับกลีสันและสแตลลิน (Gleason and Staelin 1975: 230-231) มอร์ริสัน (Morrison 1976: 120) มาร์ชโล (Marascuilo 1983: 65-66) เคปเพล (Keppel 1982: 100-101) ที่เสนอแนะให้ผู้วิจัยเลือกใช้การประมาณค่าแทนข้อมูลที่สูญหายเช่นกัน

ยัง (Young 1981: 367) กล่าวว่า เพื่อให้การวิเคราะห์ข้อมูลมีคุณภาพสูงที่สุด ผู้วิจัยจำเป็นต้องมีความคิดรวบยอด และศึกษาค้นคว้าเกี่ยวกับสถานการณ์ทั่ว ๆ ไปของตัวข้อมูลที่สูญหายให้มากที่สุด เพื่อสามารถจะอธิบายเกี่ยวกับข้อมูลที่สูญหายได้อย่างเต็มที่ ก่อนที่จะเลือกใช้วิธีประมาณค่าวิธีหนึ่งวิธีใด

วิธีประมาณค่าข้อมูลที่สูญหาย 3 วิธี

1. วิธีประมาณค่าข้อมูลที่สูญหายโดยใช้ค่าเฉลี่ยจากกลุ่มตัวอย่าง (Estimated by Sampling mean)

ถ้าผู้วิจัยกำหนดขนาดกลุ่มตัวอย่างในการวิจัยไว้เป็น n แต่เมื่อสิ้นสุดการวิจัยปรากฏว่ามีข้อมูลสูญหายไปและสามารถเก็บรวบรวมข้อมูลได้เพียง n_x หน่วย โดยที่ n_x มีค่าน้อยกว่า n จากสถานการณ์นี้สามารถประมาณค่าแทนข้อมูลที่สูญหายไป $(n - n_x)$ หน่วยได้ด้วยค่า \bar{X}_{n_x} ซึ่งเป็นวิธีประมาณค่าโดยใช้ค่าเฉลี่ยจากกลุ่มตัวอย่างที่เหลือ นักสถิติส่วนใหญ่จะรู้จักกันดีในชื่อของ The Zero Order method กล่าวได้ว่าเป็นเทคนิควิธีที่ง่ายไม่มีขั้นตอนยุ่งยากซับซ้อนในการคำนวณ ในปี ค.ศ. 1959 เดียร์ (Dear, R.E. 1959, Cited by Afifi, A.A. and Elashoff, R.M. 1966: 598-599) เป็นผู้เสนอการอภิปรายการคำนวณสำหรับวิธีนี้ โดยคำนวณหาค่าเฉลี่ยจากข้อมูลที่มีอยู่ทั้งหมดแล้วนำค่าที่ได้แทนค่าของข้อมูลที่สูญหายซึ่งเขียนอยู่ในรูปสมการได้ดังนี้

$$\bar{X}_{n_x} = \frac{\sum_{i=1}^{n_x} X_i}{n_x}$$

เมื่อ \bar{X}_{n_x} คือ ค่าเฉลี่ยจากข้อมูลที่ยังคงเหลืออยู่

n_x คือ จำนวนหน่วยตัวอย่างที่มีค่าของคะแนน X ทั้งหมด

2. วิธีประมาณค่าข้อมูลที่สูญหายโดยใช้สมการถดถอย (Estimated by Regression equation)

ในปี ค.ศ. 1966 อะฟีฟี และอีลาสฮอฟฟ์ (Afifi and Elashoff 1966: 599-600) ได้เสนอวิธีประมาณค่าแทนข้อมูลที่สูญหายด้วยสมการถดถอย โดยใช้ชื่อว่า The First Order Regression เป็นวิธีประมาณค่าที่ตัวแปรต้นและตัวแปรตามหรือตัวแปรควบคุม (Covariate Variable) มีความสัมพันธ์กันในลักษณะ เชิงเส้น เท่านั้น ในกรณีที่ตัวแปรตามมีข้อมูลสูญหายไปจะสามารถประมาณค่าได้จากตัวควบคุมที่มีข้อมูลเหลืออยู่

ทาแบชนิค และฟิเดล (Tabachnick and Fidell 1983: 72) ได้เสนอแนะว่า การใช้สมการถดถอยสำหรับทำนายค่าที่ขาดหายไปควรจะมีความสัมพันธ์สูง ๆ กับตัวแปรที่ขาดหายไป โดยใช้ค่าประมาณที่ตกอยู่ในช่วงของพิสัยของค่ารวม ๆ ระหว่างค่าที่ใช้สร้างสมการถดถอยเท่านั้น และควรใช้ข้อมูลจากกลุ่มตัวอย่างที่มีสภาพคล้ายคลึงกันและมีการสูญหายของข้อมูลไม่มากนัก

ในการทดลองหนึ่งที่ขนาดกลุ่มตัวอย่างเท่ากับ 10 ผู้วิจัยเก็บรวบรวมข้อมูลของตัวแปรตาม (Y) ได้บางส่วน ซึ่งเขามีข้อมูลของตัวแปรควบคุม (X) ที่มีความสัมพันธ์เชิงเส้นกับตัวแปรตามดังนี้

ตัวแปร	1	2	3	4	5	6	7	8	9	10
ตัวแปรควบคุม	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10
ตัวแปรตาม	Y1	Y2	Y3	—	Y5	Y6	—	Y8	Y9	Y10

ผู้วิจัยสามารถประมาณค่า Y4 และ Y7 แทนข้อมูลที่สูญหายด้วยสมการถดถอย โดยมีวิธีการคำนวณดังนี้

$$Y_i = \alpha + \beta X_i \dots \dots \dots (1)$$

โดยใช้เทคนิค Least Square Method คำนวณหาค่า α และ β ได้ดังนี้

$$\alpha = \frac{1}{N} \sum_{i=1}^N Y_i - \beta \frac{1}{N} \sum_{i=1}^N X_i$$

$$\alpha = \bar{Y} - \beta \bar{X}$$

$$\text{และ } \beta = \frac{\sum_{i=1}^N Y_i X_i - \bar{Y} \sum_{i=1}^N X_i}{\sum_{i=1}^N X_i^2 - \bar{X} \sum_{i=1}^N X_i}$$

$$\beta = \frac{\sum_{i=1}^N Y_i X_i - N \bar{Y} \bar{X}}{\sum_{i=1}^N X_i^2 - N \bar{X}^2}$$

(Mararcuilo 1971: 480-481)

ต่อจากนั้นนำค่า α , β และ X_4 แทนลงในสมการ (1) เพื่อคำนวณหาค่า \hat{Y}_4 แล้วนำไปแทนตัวที่ขาดหายไป ซึ่งค่าที่เหลือคือ \hat{Y}_7 ก็ทำนองเดียวกัน

3. วิธีประมาณค่าข้อมูลที่สูญหายโดยใช้ค่าเฉลี่ยระหว่างค่าเฉลี่ยจากกลุ่มตัวอย่างและสมการถดถอย (Estimated by mean of Sampling mean and Regression equation)

ในปี ค.ศ. 1967 อะฟีฟี และอีลาสซอฟท์ เป็นผู้คิดค้นเสนอวิธีประมาณค่านี้ไว้ (Afifi and Elashoff 1967: 16) โดยใช้แนวความคิดที่ว่า วิธีประมาณค่าข้อมูล โดยใช้สมการถดถอยช่วยทำนาย เป็นวิธีที่มีลักษณะเฉพาะที่ดี คือใช้ค่าสัมประสิทธิ์สหสัมพันธ์ในการทำนายข้อมูลได้อย่างดีเมื่อตัวแปรต้นและตัวแปรตามมีความสัมพันธ์กัน และสำหรับวิธีประมาณค่าข้อมูลโดยใช้ค่าเฉลี่ยจากกลุ่มตัวอย่าง เป็นวิธีที่มีคุณสมบัติลดค่าความแปรปรวน ดังนั้น อะฟีฟี และอีลาสซอฟท์ จึงได้รวมวิธีประมาณค่าทั้งสองเข้าด้วยกัน โดยใช้ค่าเฉลี่ยระหว่างค่าเฉลี่ยจากกลุ่มตัวอย่างและค่าจากสมการถดถอย ซึ่งแทนค่าที่สูญหายด้วยค่าเฉลี่ยก่อนคำนวณค่าจากสมการถดถอย วิธีประมาณค่านี้มีลำดับขั้นในการคำนวณดังนี้

1. คำนวณหาค่าเฉลี่ยจากกลุ่มตัวอย่าง จะได้ค่า
2. แทนข้อมูล X_i ที่สูญหายไปด้วย X_{n_x} แล้วนำข้อมูลที่ได้ทั้งหมดคำนวณการถดถอยของ X ในเทอม Y โดยวิธีกำลังสองน้อยที่สุด จะได้สมการถดถอย

$$\text{คือ } X_i^{LS} = d_0^{LS} + d_1^{LS} Y_i$$

3. คำนวณหาค่า X_i ที่สูญหายโดยใช้สมการจากข้อ 2 จะได้ค่า \hat{X}_i^{LS}
4. หาค่า $(\bar{X}_{n_x} + \hat{X}_i^{LS})/2$ ซึ่งเป็นค่าประมาณที่ได้จากวิธีประมาณค่านี้

คุณสมบัติของวิธีประมาณค่าที่ดี

ในการประมาณค่าพารามิเตอร์หรือลักษณะต่าง ๆ ของประชากรที่ใช้ในการวิเคราะห์ข้อมูล วิธีที่ใช้ในการประมาณค่ามี 2 แบบ คือ การประมาณค่าแบบจุดและการประมาณค่าแบบช่วง (point and interval estimates) สำหรับวิธีการประมาณค่าแบบจุดเป็นการประมาณค่าพารามิเตอร์ของประชากรที่สนใจศึกษาด้วยค่าเพียงค่าเดียวเท่านั้น เช่น ใช้ \bar{X} ประมาณค่า μ หรือใช้ s^2 ประมาณค่า σ^2 เป็นต้น ส่วนวิธีการประมาณค่าแบบช่วงเป็นการประมาณค่าพารามิเตอร์ของประชากรที่สนใจศึกษาด้วยช่วงค่าช่วงหนึ่ง ซึ่งมีคุณสมบัติว่าค่าของประชากรที่แท้จริงจะตกอยู่ในช่วงค่าที่ประมาณนี้ ด้วยความเชื่อมั่นระดับหนึ่ง โดยจะต้องอาศัยการประมาณค่าแบบจุด และการแจกแจงความน่าจะเป็นของตัวประมาณเป็นพื้นฐานในการคำนวณ การประมาณค่าทั้งสองแบบจะเหมาะสมกับกรณีการใช้งานที่ต่างกัน กรณีที่มีตัวประมาณค่า (Estimators) อยู่หลายวิธีที่สามารถนำมาใช้ในการประมาณค่าสิ่งใดสิ่งหนึ่งได้ จึงมีการกำหนดคุณสมบัติของวิธีประมาณค่าที่ดีควรมีคุณสมบัติครบ 4 ประการดังต่อไปนี้ (Hays 1963: 196-201 Yamane 1967: 239-245, and Wilks 1962: 256-261)

1. ความไม่เอนเอียง (Unbiasness) หมายถึง ถ้า $\hat{\theta}$ เป็นตัวประมาณค่าที่ไม่เอนเอียงของพารามิเตอร์ θ แล้ว

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

นั่นคือ ค่าคาดหวัง (Expected Value) ของตัวประมาณค่า $\hat{\theta}$ มีค่าเท่ากับค่าของพารามิเตอร์ตัวที่ต้องการประมาณหรือกล่าวอีกนัยหนึ่งได้ว่า ตัวประมาณค่านั้นไม่เอนเอียงถ้า Expectation ของการแจกแจงของ $\hat{\theta}$ มีค่าเท่ากับพารามิเตอร์ θ และตัวประมาณค่าที่ไม่

เอน เอียงนั้นมีความสมบัติที่คืออยู่ว่า ถ้ามีชุดของค่าประมาณที่ไม่เอน เอียงที่เป็นอิสระต่อกันอยู่แล้ว ค่าเฉลี่ยของค่าเหล่านั้นย่อมไม่เอน เอียงด้วย และในทางตรงข้ามกันค่าเฉลี่ยของค่าประมาณที่เอน เอียงย่อม เอน เอียงด้วยไม่ว่าจะเฉลี่ยมาจากที่ค่าก็ตาม

2. ความสอดคล้อง (Consistency) หมายถึง ถ้าประมาณค่าพารามิเตอร์ θ ด้วย $\hat{\theta}$ เมื่อขนาดของกลุ่มตัวอย่างใหญ่ขึ้น ตัวประมาณ $\hat{\theta}$ ที่มีความสมบัตินี้ จะประมาณค่าเข้าไปใกล้ค่าพารามิเตอร์มากขึ้นด้วย สามารถเขียนอยู่ในรูปประโยคสัญลักษณ์ทั่วไปได้คือ ถ้า $P(\hat{\theta} \rightarrow \theta) \rightarrow 1$ เมื่อ $n \rightarrow \infty$ แล้ว $\hat{\theta}$ จะเรียกว่า เป็นตัวประมาณค่าที่มีความสอดคล้องของ θ ซึ่งก็หมายความว่า ความน่าจะเป็นที่ค่า $\hat{\theta}$ จะประมาณค่าเข้าใกล้ θ มีค่าสูงขึ้น เมื่อขนาดกลุ่มตัวอย่าง (n) มีค่าเพิ่มมากขึ้น ๆ คือมีค่าความน่าจะเป็นเข้าใกล้ 1

3. ความมีประสิทธิภาพ (Efficiency) หมายถึง ตัวประมาณค่าหนึ่ง ๆ สามารถประมาณค่าพารามิเตอร์ได้ถูกต้องแม่นยำ (Accuracy) เพียงใด ซึ่งเกณฑ์ที่ใช้พิจารณาความมีประสิทธิภาพของตัวประมาณค่าก็คือ ค่าความแปรปรวนของตัวประมาณที่เปรียบเทียบกับกลุ่มของตัวประมาณที่ไม่เอน เอียงด้วยกัน

โดยทั่วไปจะนิยามประสิทธิภาพของตัวประมาณค่าใด ๆ ว่าเป็นอัตราส่วนระหว่างค่าความแปรปรวนของตัวประมาณที่มีประสิทธิภาพนั้นกับค่าความแปรปรวนของตัวประมาณตัวอื่น ๆ กล่าวคือถ้าค่าความแปรปรวนของ $\hat{\theta}_i$ ($\text{Var}(\hat{\theta}_i)$) น้อยกว่าค่าความแปรปรวนของ $\hat{\theta}_j$ ($\text{Var}(\hat{\theta}_j)$) เมื่อทั้ง $\hat{\theta}_i$ และ $\hat{\theta}_j$ เป็นตัวประมาณค่าที่ไม่เอน เอียงแล้ว จะได้ว่า $\hat{\theta}_i$ เป็นตัวประมาณค่าที่มีประสิทธิภาพของ $\hat{\theta}_i$ หรือ $\hat{\theta}_j$ จะดีกว่า $\hat{\theta}_j$ ใด ๆ

$$\text{เมื่อ } E_f = \frac{\text{Var}(\hat{\theta}_i)}{\text{Var}(\hat{\theta}_j)} \quad \text{และ } 0 \leq E_f \leq 1$$

และประสิทธิภาพของตัวประมาณค่า $\hat{\theta}_i$ จะเรียกว่า ตัวประมาณที่มีความแปรปรวนน้อยที่สุดของ θ (minimum variance estimator)

4. ความพอเพียง (Sufficiency) หมายถึง ตัวประมาณค่า $\hat{\theta}$ จะเป็นตัวประมาณค่าที่มีความพอเพียง ถ้ามันให้สารสนเทศที่ก่อให้เกิดประโยชน์ได้ทั้งหมดที่ต้องการเกี่ยวกับพารามิเตอร์ที่ต้องการประมาณ เช่น \bar{x} เป็นตัวประมาณที่มีความพอเพียงของ μ ก็หมายความว่าไม่มีตัวประมาณค่าของ μ ตัวอื่น ตัวอย่างเช่น มัธยฐาน (Median) ที่จะสามารถให้ข่าวสารเกี่ยวกับ μ เพิ่มขึ้นได้อีก

สำหรับคุณสมบัติของวิธีประมาณค่าที่ติดตั้ง 4 ประการดังกล่าว เป็นเกณฑ์ที่ใช้ในการตัดสินใจเลือกวิธีประมาณค่าทางทฤษฎีการที่มีวิธีประมาณค่าอยู่หลายวิธี และวิธีนั้นจะมีคุณสมบัติข้อใดบ้างสามารถใช้หลักการพิสูจน์ให้เห็นจริงได้

การแจกแจงแบบปกติสองตัวแปร (Bivariate Normal Distribution)

ถ้า X และ Y เป็นตัวแปรสุ่มแบบต่อเนื่อง มีการแจกแจงแบบปกติสองตัวแปร ฟังก์ชันความน่าจะเป็นของตัวแปรทั้งสอง เขียนเป็นสมการได้ดังนี้

$$f(X, Y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{2(1-\rho^2)}\left[\frac{(X-\mu_1)^2}{\sigma_1^2} - 2\rho\frac{(X-\mu_1)(Y-\mu_2)}{\sigma_1\sigma_2} + \frac{(Y-\mu_2)^2}{\sigma_2^2}\right]\right\}$$

เมื่อ $-\infty < X < \infty$, $-\infty < Y < \infty$

การแจกแจงแบบปกติสองตัวแปรตามสมการดังกล่าว จะประกอบด้วยพารามิเตอร์

μ_1 , μ_2 , σ_1 , σ_2 และ ρ โดยที่ $-\infty < \mu_1 < \infty$, $-\infty < \mu_2 < \infty$, $\sigma_1 > 0$, $\sigma_2 > 0$ และ $-1 < \rho < 1$. จะได้ X และ Y เป็นตัวแปรที่มีการแจกแจงแบบปกติสองตัวแปรที่มี

ค่าเฉลี่ย $\mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix}$

และ เมตริกความแปรปรวนร่วม $\Sigma = \begin{bmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{bmatrix}$

โดยที่ ρ คือ ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปร X และ Y

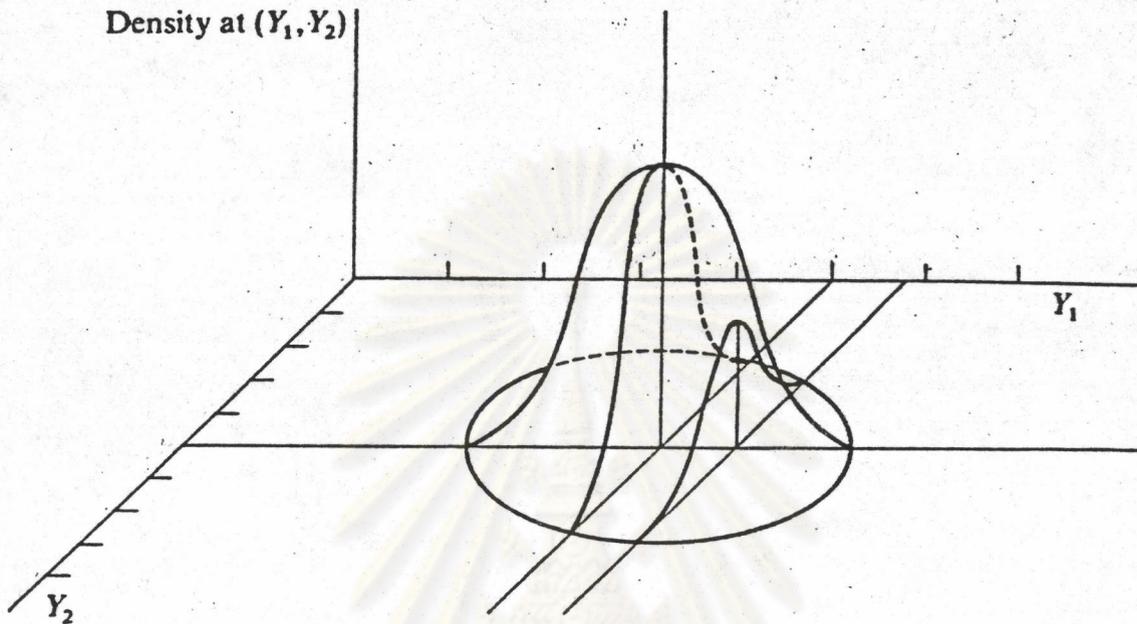
μ_1 คือ ค่าเฉลี่ยของตัวแปร X

μ_2 คือ ค่าเฉลี่ยของตัวแปร Y

σ_1^2 คือ ค่าความแปรปรวนของตัวแปร X

σ_2^2 คือ ค่าความแปรปรวนของตัวแปร Y

ฟังก์ชันความน่าจะเป็นของตัวแปร X และ Y ที่มีค่าเฉลี่ยและเมตริกความแปรปรวนร่วมดังกล่าวสามารถเขียนแสดงได้ ดังแผนภาพที่ 1



แผนภาพที่ 1 การแจกแจงแบบปกติสองตัวแปร

ถ้าตัวแปรสุ่ม X และ Y มีการแจกแจงแบบปกติสองตัวแปร การแจกแจงแบบมีเงื่อนไขของตัวแปร X เมื่อกำหนดค่า $Y = y$ หรือเขียนแทนด้วยสัญลักษณ์ $X|Y = y$ จะมีลักษณะเป็นการแจกแจงแบบปกติที่มีค่าเฉลี่ยเท่ากับ $\mu_1 + (\rho\sigma_1/\sigma_2)(y - \mu_2)$ และค่าความแปรปรวนเท่ากับ $\sigma_1^2(1 - \rho^2)$ และการแจกแจงแบบมีเงื่อนไขของตัวแปร Y เมื่อกำหนดค่า $X = x$ ซึ่งเขียนแทนด้วยสัญลักษณ์ $Y|X = x$ จะมีลักษณะการแจกแจงแบบปกติที่มีค่าเฉลี่ยเท่ากับ $\mu_2 + (\rho\sigma_2/\sigma_1)(x - \mu_1)$ และค่าความแปรปรวนเท่ากับ $\sigma_2^2(1 - \rho^2)$ (Brownlee 1965: 404) และเพราะว่า (X, Y) มีการแจกแจงแบบปกติสองตัวแปร ที่มีค่าเฉลี่ย

μ_1, μ_2 ค่าความแปรปรวน σ_1^2, σ_2^2 และค่าสัมประสิทธิ์สหสัมพันธ์ ρ จะสรุปได้ว่า

$Z_1 = \frac{X - \mu_1}{\sigma_1}$ และ $Z_2 = \frac{Y - \mu_2}{\sigma_2}$ จะมีการแจกแจงแบบปกติสองตัวแปรที่มีค่าเฉลี่ย

$\mu_{Z_1} = \mu_{Z_2} = 0, \sigma_{Z_1}^2 = \sigma_{Z_2}^2 = 1$ และ $\rho(Z_1, Z_2) = \rho$ (กรรณิกา เลียงเจริญสิทธิ์ 2527: 10)

$$\text{จากสมการ } \mu_{Y|X=x} = \mu_2 + (\rho\sigma_2/\sigma_1)(x - \mu_1)$$

$$\text{และ } \sigma_{Y|X=x}^2 = \sigma_2^2(1 - \rho^2)$$

$$\text{จะได้ } Y \sim N(\sigma_2^2(1 - \rho^2), \mu_2 + (\rho\sigma_2/\sigma_1)(x - \mu_1))$$

จากแผนผังการสร้างตัวแปรสุ่มปกติสองตัวแปร ค่าตัวแปร Y จะขึ้นอยู่กับค่าตัวแปร X สามารถสร้างค่าตัวแปรทั้งสองได้จาก สมการต่อไปนี้

$$Y = \mu_2 + (\rho\sigma_2/\sigma_1)(x - \mu_1) + \sqrt{\sigma_2^2(1 - \rho^2)} \cdot Y_1$$

เมื่อ Y_1 คือ ค่าตัวแปรอิสระจากค่าตัวแปร X มี $E(Y_1) = 0$

$$\text{และ } \text{Var}(Y_1) = 1$$

งานวิจัยที่เกี่ยวข้อง

ชะไมพร ธรรมวัฒน์ไพศาล (2522 : 124-126) ได้ศึกษาเกี่ยวกับวิธีการประมาณค่าข้อมูลที่สูญหายในการวิเคราะห์การถดถอยวิธีต่าง ๆ 6 วิธีด้วยกัน คือ วิธีกำลังสองน้อยที่สุด วิธีอันดับศูนย์หรือวิธีใช้ค่าเฉลี่ยจากกลุ่มตัวอย่าง วิธีอันดับศูนย์ตัดแปลง วิธีถดถอยอันดับหนึ่งหรือวิธีใช้สมการถดถอย วิธีถดถอยสองชั้น และวิธีผสมหรือวิธีใช้ค่าเฉลี่ยระหว่างค่าเฉลี่ยจากกลุ่มตัวอย่างและสมการถดถอย โดยใช้ข้อมูลที่รวบรวมมาได้และกระทำให้สูญหายไปโดยวิธีสุ่มใช้เกณฑ์เปรียบเทียบคือค่าความแปรปรวนร่วมที่สามารถอธิบายได้หรือ (R^2) (a coefficient of determination) ซึ่งค่านี้สามารถใช้เป็นดัชนีในการตัดสินใจได้ว่าวิธีประมาณค่าใดสามารถประมาณค่าได้ใกล้เคียงกับค่าที่สูญหายมากกว่ากัน ถ้า (R^2) มีค่าเพิ่มมากขึ้น (Ozer 1985: 307-308) จากงานวิจัยนี้สรุปได้ว่าวิธีที่ให้ค่า (R^2) สูงกว่าวิธีอื่นมีอยู่ 3 วิธีด้วยกันเรียงตามลำดับจากมากไปน้อย คือ วิธีถดถอยสองชั้น วิธีถดถอยอันดับหนึ่งหรือวิธีใช้สมการถดถอย และวิธีกำลังสองน้อยที่สุด

พรศิริ หมื่นไชยศรี (2529 : 75-76) ได้ศึกษาเกี่ยวกับการ เปรียบ เทียบวิธีประมาณค่า ข้อมูลที่สูญหายในการวิเคราะห์ตัวแปรพหุคูณ 4 วิธี คือ วิธีใช้ค่าเฉลี่ยจากกลุ่มตัวอย่าง วิธี วิเคราะห์ความถดถอยพหุคูณเชิง เส้น วิธีวิเคราะห์ความถดถอยพหุคูณเชิง เส้นตัดแปลง และวิธี วิเคราะห์ส่วนประกอบหลัก ทำการศึกษาโดยใช้เทคนิคมอนติคาร์โลซิมูเลชัน และใช้เกณฑ์ในการ เปรียบเทียบ คือ ค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (mean square error) และคะแนน รวมจากการถ่วงน้ำหนักของทั้ง 4 วิธีที่ได้ลำดับ 1, 2, 3 และ 4

เมื่อเรียงลำดับค่าเฉลี่ยความคลาดเคลื่อนกำลังสองจากน้อยไปหามาก โดยศึกษา ที่ขนาดกลุ่มตัวอย่าง 30, 50, 70, 100 และ 200 จำนวนตัวแปรเท่ากับ 3, 5, 7 และ 10 ตัวแปร ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปร (ρ) เท่ากับ 0.1, 0.2 ..., 0.9 และกำหนดสัดส่วนข้อมูลที่สูญหายของแต่ละตัวแปรมีค่าใกล้เคียงกันคือ 10 % จากการศึกษาพบว่า วิธีประมาณค่าข้อมูลที่สูญหายในการวิเคราะห์ตัวแปรพหุคูณทั้ง 4 วิธี ให้ค่าเฉลี่ยความคลาดเคลื่อน กำลังสองไม่แตกต่างกันอย่างมีนัยสำคัญที่ระดับ .05 ไม่ว่าจะ เป็นสถานการณ์ใดก็ตามที่มีข้อมูล สูญหาย เกิดขึ้น

ชานและดันน (Chan and Dunn 1972 : 473-477) ใช้เทคนิคมอนติคาร์โลซิมูเลชัน ทำการศึกษาเปรียบเทียบวิธีการประมาณค่าข้อมูลที่สูญหายในการวิเคราะห์จำแนกประเภท (Discriminant Analysis) จำนวน 5 วิธีด้วยกัน คือ 1. ศึกษาเมื่อไม่มีข้อมูลสูญหายเลย 2. วิธีตัดตัวอย่างที่มีข้อมูลสูญหายออก 3. วิธีใช้ค่าเฉลี่ยจากกลุ่มตัวอย่าง 4. วิธีใช้สมการ ถดถอย และ 5. วิธีวิเคราะห์ส่วนประกอบหลัก (principal component) โดยศึกษาข้อมูล ที่มีลักษณะการแจกแจงแบบปกติสองตัวแปร และประชากรทั้งสองกลุ่มมีความแปรปรวนเท่ากัน ใช้ เกณฑ์ในการพิจารณาเปรียบเทียบคือ ร้อยละของการจำแนกข้อมูลผิด พบว่าโดยทั่ว ๆ ไป ค่า R^2 (Coefficient of determination) ของวิธีใช้สมการถดถอย จะสูงกว่าวิธีใช้ค่าเฉลี่ย จากกลุ่มตัวอย่าง วิธีวิเคราะห์ส่วนประกอบหลัก และวิธีตัดตัวอย่างที่มีข้อมูลสูญหายออก และ ถ้าจำนวนตัวแปรเพิ่มขึ้นวิธีใช้สมการถดถอยจะให้ค่า R^2 เพิ่มสูงขึ้น

อะฟีฟี และอีลาสฮอฟฟ์ (Afifi and Elashoff 1967: 18-28) ได้ทำการศึกษา เปรียบเทียบวิธีประมาณค่า คือ วิธีใช้ค่าเฉลี่ยจากกลุ่มตัวอย่าง (The Zero Order method) วิธีใช้ค่าเฉลี่ยตัดแปลง (A modified Zero Order method) และวิธีผสม หรือวิธีใช้ค่าเฉลี่ย ระหว่างค่าเฉลี่ยจากกลุ่มตัวอย่างและสมการถดถอย (Mixed method) โดยเปรียบเทียบ

ประสิทธิภาพของค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของแต่ละวิธี เทียบกับวิธีกำลังสองน้อยที่สุด ในกลุ่มตัวอย่างขนาดใหญ่คือมากกว่าหรือเท่ากับ 200 พบว่าเมื่อค่าสัมประสิทธิ์สหสัมพันธ์ และจำนวนการสูญหาย เท่ากับประสิทธิภาพของวิธี Zero order และวิธี Modified Zero order จะลดลงเมื่อกลุ่มตัวอย่างเพิ่มขึ้น ถ้ากำหนดขนาดกลุ่มตัวอย่างให้คงที่โดยเปลี่ยนแปลงจำนวนการสูญหายของตัวแปรอิสระ (m_x) และจำนวนการสูญหายของตัวแปรตาม (m_y) พบว่าวิธี Zero order มีประสิทธิภาพสูงที่สุดเมื่อการสูญหายของตัวแปรอิสระน้อยกว่าตัวแปรตาม ($m_x < m_y$) ที่ค่าสัมบูรณ์ของสัมประสิทธิ์สหสัมพันธ์เล็กน้อย ($|p|$) ซึ่งตรงข้ามกับ Mixed method จะมีประสิทธิภาพสูงที่สุดเมื่อการสูญหายของตัวแปรตามน้อยกว่าการสูญหายของตัวแปรอิสระ ($m_x > m_y$) ที่ค่าสัมบูรณ์ของสัมประสิทธิ์สหสัมพันธ์อยู่ในช่วงกลาง ๆ

ฟิงค์เบนเนอร์ (Finkbeiner 1979: 416-420) ใช้เทคนิคมอนติคาร์โลซิมูเลชัน ทำการศึกษาเปรียบเทียบความแม่นยำของวิธีประมาณค่าข้อมูลที่สูญหายในการวิเคราะห์ตัวแปร พหุคูณ 6 วิธีด้วยกันคือ 1. วิธี maximum likelihood (ML) 2. วิธีใช้ค่าเฉลี่ยจากกลุ่มตัวอย่าง (MR) 3. วิธีใช้เฉพาะตัวอย่างที่ไม่มีข้อมูลสูญหาย (CD) 4. วิธีใช้สมการถดถอย (REG) 5. วิธีวิเคราะห์องค์ประกอบหลัก (PC) และ 6. วิธีใช้เฉพาะคู่ตัวอย่างที่สมบูรณ์ (CPO) ใช้เกณฑ์ในการเปรียบเทียบต่อไปนี้คือ ใช้ค่าเฉลี่ยจากกลุ่มตัวอย่างและการกระจายของค่า พารามิเตอร์ และใช้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของวิธีที่มีค่าน้อยที่สุด โดยศึกษาที่ขนาดกลุ่มตัวอย่างเท่ากับ 64 จำนวนการสูญหายของข้อมูล 2 รูปแบบ (pattern) ทำการทดลองซ้ำ 50 ครั้ง จากการศึกษาพบว่า ค่าเฉลี่ยจากกลุ่มตัวอย่างและค่าส่วนเบี่ยงเบนมาตรฐานของทุกวิธี ไม่แตกต่างกัน แต่ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองแตกต่างกัน เรียงลำดับจากน้อยไปมาก คือ ML , MR , CPO และ REG ซึ่งสรุปได้ว่าวิธีที่สามารถประมาณค่าข้อมูลที่สูญหายไปในรูปแบบ การวิเคราะห์ตัวแปรพหุคูณ และมีความแม่นยำอยู่ในเกณฑ์ดีมากที่สุดมีอยู่สามวิธีคือวิธี maximum likelyhook มีความแม่นยำในการประมาณมากที่สุด รองลงมาคือ วิธีแทนด้วยค่าเฉลี่ย (MR) และวิธีใช้เฉพาะคู่ตัวอย่างที่สมบูรณ์ (CPO) ส่วนวิธีใช้สมการถดถอย (REG) ยังอยู่ในขั้นต่ำกว่า เกณฑ์ที่กำหนด