

วิธีการประมาณค่าสัดส่วนของประชากรที่มีลักษณะปกปิดและผลงานวิจัยที่เกี่ยวข้อง

การประมาณค่าสัดส่วนของประชากรที่มีลักษณะปกปิดที่นำมาศึกษาครั้งที่ 3 วิธีคือ

1. วิธีของวอร์เนอร์
2. วิธีของสรชัย
3. วิธีที่พัฒนาจากวิธีที่ 2

ซึ่งแต่ละวิธีแบ่งออกเป็น 2 กรณีคือกรณีที่ผู้ถูกสัมภาษณ์ทุกคนตอบตามความเป็นจริง (completely truthful) และกรณีที่บางส่วนของผู้ถูกสัมภาษณ์ที่มีลักษณะปกปิดตอบไม่ตรงตามความจริง (less than completely truthful)

2.1 วิธีของวอร์เนอร์

2.1.1 กรณีที่ผู้ถูกสัมภาษณ์ทุกคนตอบตามความจริง (completely truthful)

ในการประมาณค่าสัดส่วนของประชากรที่มีลักษณะปกปิดด้วยวิธีนี้ใช้ตัวอย่างชนิดแทนที่ขนาด n เครื่องมือสุ่มเลือก (randomizing device) ที่ให้ผู้ถูกสัมภาษณ์เลือกคำถามขึ้นมาตอบคือ โฉนด 1 ชุด ซึ่งประกอบด้วยโผลสีแดง และ โผล่สีดำ ในอัตราส่วนที่ผู้สำรวจได้กำหนดไว้ล่วงหน้าแล้ว ในการตอบคำถามผู้สัมภาษณ์จะให้ผู้ถูกสัมภาษณ์สุบโผล่จนเข้ากันดี เพื่อให้โผล่แต่ละใบมีโอกาสสุบสุ่มด้วยความน่าจะเป็นเท่าๆ กัน แล้วดึงโผล่ 1 ใบจากโผล่ชุดนั้น โดยไม่ให้ผู้สัมภาษณ์ทราบว่า เป็นโผล่สีอะไร ถ้าผู้ถูกสัมภาษณ์ดึงได้โผล่สีแดง จะต้องตอบคำถามข้อแรกซึ่งเป็นเรื่องปกปิดที่ต้องการศึกษา เช่น "คุณเคยทำแท้ง ใช่หรือไม่" แต่ถ้าผู้ถูกสัมภาษณ์ดึงได้โผล่สีดำ จะต้องตอบคำถามข้อสองซึ่งเป็นนิเสธของคำถามข้อแรก เช่น "คุณไม่เคยทำแท้ง ใช่หรือไม่" เมื่อผู้ถูกสัมภาษณ์ทุกคนเข้าใจในวิธีการนี้ และตอบคำถามตามความจริงแล้ว การประมาณค่าสัดส่วนของประชากรที่มีลักษณะปกปิดด้วยวิธีนี้จะน่าจะเป็นสูงสุด (maximum likelihood estimate) หาได้ดังนี้

ให้ r เป็นสัดส่วนของประชากรที่มีลักษณะปกปิด

r และ b เป็นจำนวนโผล่สีแดงและจำนวนโผล่สีดำในโผล่ 1 ชุด

ตามลำดับ โดยที่ผู้สำรวจได้กำหนดไว้ล่วงหน้าแล้ว

p เป็นสัดส่วนของโผล่สีแดงในโผล่ 1 ชุดนั้น หรือ ความน่าจะเป็นที่จะสุบได้คำถามปกปิดที่ต้องการศึกษา

$$X_i = \begin{cases} 1 & \text{ถ้าผู้ถูกสัมภาษณ์คนที่ } i \text{ ตอบว่า "ใช่"} \\ 0 & \text{ถ้าผู้ถูกสัมภาษณ์คนที่ } i \text{ ตอบว่า "ไม่ใช่"} \end{cases}$$

$$\text{ดังนั้น } \text{pr} \cdot [X_i = 1] = \pi p + (1-\pi)(1-p)$$

$$\text{pr} \cdot [X_i = 0] = [1 - \{\pi p + (1-\pi)(1-p)\}]$$

ให้ n_1 แทนจำนวนผู้ถูกสัมภาษณ์ที่ตอบว่า "ใช่" จากจำนวนผู้ถูกสัมภาษณ์ทั้งหมด n คน จะได้ฟังก์ชันภาวะน่าจะเป็น (likelihood function)

$$L(\pi) = [\pi p + (1-\pi)(1-p)]^{n_1} [1 - \{\pi p + (1-\pi)(1-p)\}]^{n-n_1}$$

$$\begin{aligned} \log L(\pi) &= n_1 \log [\pi p + (1-\pi)(1-p)] + \\ &\quad (n - n_1) \log [1 - \{\pi p + (1-\pi)(1-p)\}] \end{aligned}$$

$$\frac{d}{d\pi} \log L(\pi) = \frac{n_1 [p - (1-p)]}{\pi p + (1-\pi)(1-p)} + \frac{(n - n_1) [-p + (1-p)]}{[1 - \{\pi p + (1-\pi)(1-p)\}]}$$

$$= \frac{n_1 (2p - 1)}{\pi p + (1-\pi)(1-p)} - \frac{(n - n_1) (2p - 1)}{[1 - \{\pi p + (1-\pi)(1-p)\}]}$$

$$\frac{n_1 (2p - 1)}{\pi p + (1-\pi)(1-p)} - \frac{(n - n_1) (2p - 1)}{[1 - \{\pi p + (1-\pi)(1-p)\}]} = 0$$

$$\frac{n_1 (2p - 1)}{\pi p + (1-\pi)(1-p)} = \frac{(n - n_1) (2p - 1)}{[1 - \{\pi p + (1-\pi)(1-p)\}]}$$

$$\frac{[1 - (\pi p + (1 - \pi)(1 - p))]}{\pi p + (1 - \pi)(1 - p)} = \frac{n - n_1}{n_1}$$

$$= \frac{n}{n_1} - 1$$

$$\frac{[1 - \pi p + (1 - \pi)(1 - p)]}{\pi p + (1 - \pi)(1 - p)} + 1 = \frac{n}{n_1}$$

$$\frac{1}{\pi p + (1 - \pi)(1 - p)} = \frac{n}{n_1}$$

$$\pi p + (1 - \pi)(1 - p) = \frac{n_1}{n}$$

นั่นคือ ค่าประมาณภาวะน่าจะเป็นสูงสุด (maximum likelihood estimate) ของ π เท่ากับ

$$\hat{\pi}_w = \frac{p-1}{2p-1} + \frac{n_1}{n(2p-1)} ; p \neq \frac{1}{2}$$

ค่าคาดหวัง (expected value) และความแปรปรวนของค่าประมาณ π คือ

$$E(\hat{\pi}_w) = \frac{p-1}{2p-1} + \frac{E(n_1)}{n(2p-1)}$$

$$= \frac{p-1}{2p-1} + \frac{n[\pi p + (1-\pi)(1-p)]}{n(2p-1)}$$

$$= \pi$$

$$\begin{aligned}
 \text{Var}(\hat{\pi}_w) &= \frac{\text{Var}(n_1)}{n^2(2p-1)^2} \\
 &= \frac{[\pi p + (1-\pi)(1-p)] [1 - (\pi p + (1-\pi)(1-p))]}{n(2p-1)^2} \\
 &= \frac{\pi(1-\pi)}{n} + \frac{p(1-p)}{n(2p-1)^2} \quad ; p \neq \frac{1}{2}
 \end{aligned}$$

นั่นคือ $\hat{\pi}_w$ เป็นค่าประมาณที่ไม่เอนเอียง (unbiased estimate) ของ π และความแปรปรวนของ $\hat{\pi}_w$ สามารถเขียนได้ในรูปของผลรวมระหว่างความแปรปรวนเนื่องจากการสุ่มตัวอย่าง (variance due to sampling) และความแปรปรวนเนื่องมาจากเครื่องมือสุ่มเลือก (variance due to randomizing device)

2.1.2 กรณีที่บางส่วนของผู้ถูกสัมภาษณ์ที่มีลักษณะปกปิดตอบไม่ตรงตามความจริง (less than completely truthful)

ให้ T_w แทนความน่าจะเป็นที่ผู้ถูกสัมภาษณ์ที่มีลักษณะปกปิดตอบคำถามปกปิดตามความจริง โดยที่ $0 < T_w \leq 1$

$$\text{pr} [X_i=1] = \pi T_w + \pi(1-p)(1-T_w) + (1-\pi)(1-p)$$

$$\text{pr} [X_i=0] = [1 - (\pi T_w + \pi(1-p)(1-T_w) + (1-\pi)(1-p))]$$

ให้ n_2 แทนจำนวนผู้ถูกสัมภาษณ์ที่ตอบว่า "ใช่" จากจำนวนผู้ถูกสัมภาษณ์ทั้งหมด n คน ค่าประมาณของ π เท่ากับ

$$\hat{\pi}'_w = \frac{p-1}{2p-1} + \frac{n_2}{n(2p-1)} \quad ; \quad p \neq \frac{1}{2}$$

ค่าคาดหวัง (expected value) ของค่าประมาณ π คือ

$$\begin{aligned} E(\hat{\pi}'_w) &= \frac{p-1}{2p-1} + \frac{E(n_2)}{n(2p-1)} \\ &= \frac{p-1}{2p-1} + \frac{\pi p T_w + \pi(1-p)(1-T_w) + (1-\pi)(1-p)}{2p-1} \end{aligned}$$

นั่นคือ $\hat{\pi}'_w$ เป็นค่าประมาณที่เอนเอียง (bias) ของ π

ดังนั้น ค่าความเอนเอียง และ ความแปรปรวนของค่าประมาณ π คือ

$$\begin{aligned} \text{Bias}(\hat{\pi}'_w) &= E(\hat{\pi}'_w) - \pi \\ &= \frac{p-1}{2p-1} + \frac{\pi p T_w + \pi(1-p)(1-T_w) + (1-\pi)(1-p)}{2p-1} - \pi \\ &= \pi(T_w - 1) \end{aligned}$$

$$\text{Var}(\hat{\pi}'_w) = \frac{\text{Var}(n_2)}{n^2(2p-1)^2}$$

$$= \frac{1}{n^2(2p-1)^2} \cdot [\pi p T_w + \pi(1-p)(1-T_w) + (1-\pi)(1-p)] \cdot$$

$$[1 - (\pi p T_w + \pi(1-p)(1-T_w) + (1-\pi)(1-p))]]$$

$$= \frac{\pi T_w(1-\pi T_w)}{n} + \frac{p(1-p)}{n(2p-1)^2} \quad ; \quad p \neq \frac{1}{2}$$

2.2 วิธีของसरชัย

2.2.1 กรณีที่ผู้ถูกสัมภาษณ์ทุกคนตอบตามความจริง (completely truthful)

การประมาณค่าสัดส่วนของประชากรที่มีลักษณะปกปิดด้วยวิธีการนี้ใช้ขนาดตัวอย่าง และเครื่องมือสุ่มเลือกเช่นเดียวกับวิธีของวอร์เนอร์ ในการตอบคำถาม ถ้าผู้ถูกสัมภาษณ์ตั้งใจได้ไม่สับสน จะต้องตอบคำถามข้อแรกซึ่งเป็นเรื่องปกปิดที่ต้องการศึกษา แต่ถ้าตั้งใจได้ไม่สับสน จะต้องตอบว่า "ใช่" เสมอ ซึ่งเหมือนกับถามคำถามที่สองว่า "ไม่ที่ท่านตั้งใจได้เป็นไม่สับสน ใช่หรือไม่" วิธีการนี้คือรูปแบบหนึ่งของการใช้คำถามที่ไม่เกี่ยวข้องกัน โดยกำหนดสัดส่วนของประชากรในคำถามที่สองให้เท่ากับ 1 เมื่อผู้ถูกสัมภาษณ์ทุกคนเข้าใจในวิธีการและตอบคำถามตามความจริงแล้ว การประมาณค่าสัดส่วนของประชากรที่มีลักษณะปกปิดด้วยวิธีการนี้จะน่าจะเป็นสูงสุด (maximum likelihood estimate) หาได้ดังนี้

$$P r [X_i = 1] = \pi p + (1-p)$$

$$P r [X_i = 0] = [1 - (\pi p + (1-p))]$$

ให้ n_1 แทนจำนวนผู้ถูกสัมภาษณ์ที่ตอบว่า "ใช่" จากจำนวนผู้ถูกสัมภาษณ์ทั้งหมด n คน จะได้ฟังก์ชันน่าจะเป็น (likelihood function)

$$L(\pi) = [\pi p + (1-p)]^{n_1} [1 - (\pi p + (1-p))]^{n-n_1}$$

$$\log L(\pi) = n_1 \log [\pi p + (1-p)] + (n-n_1) \log [1 - (\pi p + (1-p))]$$

$$\frac{d}{d\pi} \log L(\pi) = \frac{n_1 p}{\pi p + (1-p)} - \frac{(n - n_1) p}{[1 - (\pi p + (1-p))]}$$

$$\frac{n_1 P}{\pi p + (1-p)} - \frac{(n - n_1) P}{[1 - \{\pi p + (1-p)\}]} = 0$$

$$\frac{n_1 P}{\pi p + (1-p)} = \frac{(n - n_1) P}{[1 - \{\pi p + (1-p)\}]}$$

$$\frac{[1 - \{\pi p + (1-p)\}]}{\pi p + (1-p)} = \frac{n - n_1}{n_1}$$

$$\frac{[1 - \{\pi p + (1-p)\}]}{\pi p + (1-p)} + 1 = \frac{n}{n_1}$$

$$\frac{1}{\pi p + (1-p)} = \frac{n}{n_1}$$

$$\pi p + (1-p) = \frac{n_1}{n}$$

นั่นคือ ค่าประมาณภาวะน่าจะเป็นสูงสุดของ π เท่ากับ

$$\hat{\pi}_s = 1 - \frac{1}{p} + \frac{n_1}{np}$$

ค่าคาดหวัง (expected value) และความแปรปรวนของค่าประมาณ π

คือ

$$\begin{aligned} E(\hat{\pi}_s) &= 1 - \frac{1}{p} + \frac{E(n_1)}{np} \\ &= 1 - \frac{1}{p} + \frac{n \cdot [\pi p + (1-p)]}{np} \\ &= \pi \end{aligned}$$

$$\begin{aligned} \text{Var}(\hat{\pi}_s) &= \frac{\text{Var}(n_1)}{n^2 p^2} \\ &= \frac{n \cdot [\pi p + (1-p)] [1 - \{\pi p + (1-p)\}]}{n^2 p^2} \\ &= \frac{\pi(1-\pi)}{n} + \frac{(1-\pi)(1-p)}{np} \end{aligned}$$

นั่นคือ $\hat{\tau}_s$ เป็นค่าประมาณที่ไม่เอนเอียง (unbiased estimate) ของ τ และความแปรปรวนของ $\hat{\tau}_s$ สามารถเขียนได้ในรูปของผลรวมระหว่างความแปรปรวน เนื่องจากการสุ่มตัวอย่างและความแปรปรวนเนื่องมาจากเครื่องมือสุ่มเลือก

2.2.2 กรณีที่บางส่วนของผู้ถูกสัมภาษณ์ที่มีลักษณะปกปิดตอบไม่ตรงตามความจริง (less than completely truthful)

ให้ T_s แทนความน่าจะเป็นที่ผู้ถูกสัมภาษณ์ที่มีลักษณะปกปิดตอบคำถามปกปิดตามความจริง โดยที่ $0 < T_s \leq 1$

$$\begin{aligned} \text{ดังนั้น } \Pr [X_i = 1] &= \tau p T_s + (1-p) \\ \Pr [X_i = 0] &= [1 - \{\tau p T_s + (1-p)\}] \end{aligned}$$

ให้ n_2 แทนจำนวนผู้ถูกสัมภาษณ์ที่ตอบว่า "ใช่" จากจำนวนผู้ถูกสัมภาษณ์ทั้งหมด n คน ค่าประมาณของ τ เท่ากับ

$$\hat{\tau}'_s = 1 - \frac{1}{p} + \frac{n_2}{np}$$

ค่าคาดหวังของค่าประมาณ τ คือ

$$\begin{aligned} E(\hat{\tau}'_s) &= 1 - \frac{1}{p} + \frac{E(n_2)}{np} \\ &= 1 - \frac{1}{p} + \frac{n \cdot [\tau p T_s + (1-p)]}{np} \\ &= 1 - \frac{1}{p} + \frac{[\tau p T_s + (1-p)]}{p} \end{aligned}$$

นั่นคือ $\hat{\tau}'_s$ เป็นค่าประมาณที่เอนเอียง (bias) ของ τ

ดังนั้น ค่าความเอนเอียงและความแปรปรวนของค่าประมาณ τ คือ

$$\begin{aligned} \text{Bias}(\hat{\tau}'_s) &= E(\hat{\tau}'_s) - \tau \\ &= 1 - \frac{1}{p} + \left| \frac{\tau p T_s + (1-p)}{p} \right| - \tau \\ &= \tau(T_s - 1) \end{aligned}$$

$$\begin{aligned}
 \text{Var}(\hat{T}'_s) &= \frac{\text{Var}(n_2)}{n^2 p^2} \\
 &= \frac{n \cdot [pT_s + (1-p)] [1 - (pT_s + (1-p))]}{n^2 p^2} \\
 &= \frac{T_s(1 - T_s)}{n} + \frac{(1 - T_s)(1-p)}{np}
 \end{aligned}$$

2.3 วิธีที่พัฒนาจากวิธีที่ 2

2.3.1 กรณีที่ผู้ถูกสัมภาษณ์ทุกคนตอบตามความจริง (completely truthful)

การประมาณค่าสัดส่วนของประชากรที่มีลักษณะปกปิดด้วยวิธีนี้ใช้ขนาดตัวอย่างและเครื่องมือสุ่มเลือก เช่นเดียวกับวิธีของวอร์เนอร์ การตอบคำถามนั้น ผู้สัมภาษณ์จะให้ผู้ถูกสัมภาษณ์สับไพ่จนเข้ากันดี แล้วดึงไพ่ 2 ครั้ง ๆ ละใบแบบแทนที่ (with replacement) โดยไม่บอกให้ผู้สัมภาษณ์ทราบว่าดึงได้ไพ่สีอะไรในการดึงแต่ละครั้ง ถ้าผู้ถูกสัมภาษณ์ดึงได้ไพ่สีแดงในครั้งแรกและดึงได้ไพ่สีแดงหรือไพ่สีดำในครั้งที่สอง จะต้องตอบคำถามปกปิดที่ต้องการศึกษาตามความจริงว่า "ใช่" หรือ "ไม่ใช่" ถ้าผู้ถูกสัมภาษณ์ดึงได้ไพ่สีดำในครั้งแรกและไพ่สีแดงในครั้งที่สอง ผู้ถูกสัมภาษณ์จะต้องตอบว่า "ใช่" เสมอ แต่ถ้าดึงได้ไพ่สีดำในครั้งแรกและไพ่สีดำในครั้งที่สองจะต้องตอบว่า "ไม่ใช่" เสมอ ซึ่งเหมือนกับถามคำถามที่สองว่า ไพ่ที่ท่านดึงได้ใบแรกเป็นสีดำและใบที่สองเป็นสีแดง "ใช่หรือไม่" และสัดส่วนของประชากรในคำถามนี้เท่ากับความน่าจะเป็นที่สุ่มไพ่ใบแรกได้สีดำและสุ่มไพ่ใบที่สองได้สีแดงต่อผลบวกของความน่าจะเป็นที่สุ่มไพ่ใบแรกได้สีดำและสุ่มไพ่ใบที่สองได้สีแดงกับความน่าจะเป็นที่สุ่มไพ่ใบแรกได้สีดำและใบที่สองได้สีดำ สำหรับค่าประมาณสัดส่วนของประชากรที่มีลักษณะปกปิดด้วยวิธีนี้จะน่าจะเป็นสูงสุด หาได้ดังนี้

ให้ T เป็นสัดส่วนของประชากรที่มีลักษณะปกปิด

r และ b เป็นจำนวนไพ่สีแดงและไพ่สีดำในไพ่ 1 ชุด ตามลำดับ ซึ่งผู้สำรวจได้กำหนดไว้ล่วงหน้าแล้ว

p_r แทนความน่าจะเป็นที่สุ่มไพ่ใบแรกได้สีแดงและสุ่มไพ่ใบที่สองได้ไพ่สีแดง หรือสีดำ เท่ากับความน่าจะเป็นที่สุ่มได้ไพ่สีแดง (p) ในวิธีของวอร์เนอร์หรือวิธีของสรชัชยนั้นเอง

p_{br} แทนความน่าจะเป็นที่สุ่มไพ่ใบแรกได้สีดำและสุ่มไพ่ใบที่สองได้ไพ่สีแดง

p_{bb} แทนความน่าจะเป็นที่สุ่มไพ่ใบแรกได้สีดำและสุ่มไพ่ใบที่สองได้ไพ่สีดำ

$$\text{ดังนั้น } Pr [X_i = 1] = \pi p + p_{br}$$

$$Pr [X_i = 0] = [1 - (\pi p + p_{br})]$$

ให้ n_1 แทนจำนวนผู้ถูกสัมภาษณ์ที่ตอบว่า "ใช่" จากจำนวนผู้ถูกสัมภาษณ์ทั้งหมด n คน จะได้ฟังก์ชันภาวะน่าจะเป็น (likelihood function)

$$L(\pi) = [\pi p + p_{br}]^{n_1} [1 - (\pi p + p_{br})]^{n - n_1}$$

$$\log L(\pi) = n_1 \log [\pi p + p_{br}] + (n - n_1) \log [1 - (\pi p + p_{br})]$$

$$\frac{d}{d\pi} \log L(\pi) = \frac{n_1 p}{\pi p + p_{br}} - \frac{(n - n_1) p}{[1 - (\pi p + p_{br})]}$$

$$\frac{n_1 p}{\pi p + p_{br}} - \frac{(n - n_1) p}{[1 - (\pi p + p_{br})]} = 0$$

$$\frac{n_1 p}{\pi p + p_{br}} = \frac{(n - n_1) p}{[1 - (\pi p + p_{br})]}$$

$$\frac{[1 - (\pi p + p_{br})]}{\pi p + p_{br}} = \frac{n - n_1}{n_1}$$

$$= \frac{n}{n_1} - 1$$

$$\frac{[1 - (\pi p + p_{br})]}{\pi p + p_{br}} + 1 = \frac{n}{n_1}$$

$$\frac{1}{\pi p + p_{br}} = \frac{n}{n_1}$$

$$\pi p + p_{br} = \frac{n_1}{n}$$

นั่นคือ ค่าประมาณภาวะน่าจะเป็นสูงสุด (maximum likelihood estimate) ของ τ เท่ากับ

$$\hat{\tau}_m = \frac{n_1}{np} - \frac{p_{br}}{p}$$

ค่าคาดหวังและความแปรปรวนของค่าประมาณ τ คือ

$$\begin{aligned} E(\hat{\tau}_m) &= \frac{E(n_1)}{np} - \frac{p_{br}}{p} \\ &= \frac{n[\tau p + p_{br}]}{np} + \frac{p_{br}}{p} \\ &= \tau \end{aligned}$$

$$\begin{aligned} \text{Var}(\hat{\tau}_m) &= \frac{\text{Var}(n_1)}{n^2 p^2} \\ &= \frac{n \cdot [\tau p + (1-p)] [1 - (\tau p + (1-p))]}{n^2 p^2} \\ &= \frac{\tau(1-p)}{n} + \frac{p_{br}^2 - p_{br}^2 + \tau p - \tau p^2 - 2\tau p p_{br}}{np^2} \end{aligned}$$

นั่นคือ $\hat{\tau}_m$ เป็นค่าประมาณที่ไม่เอนเอียง (unbiased estimate) ของ τ และความแปรปรวนของ $\hat{\tau}_m$ สามารถเขียนได้ในรูปของผลรวมระหว่างความแปรปรวนเนื่องจากการสุ่มตัวอย่าง และความแปรปรวนเนื่องจากเครื่องมือสุ่มเลือก

2.3.2 กรณีที่บางส่วนของผู้ถูกสัมภาษณ์ที่มีลักษณะปกปิดตอบ ไม่ตรงตามความจริง (less than completely truthful)

ให้ T_m แทนความน่าจะเป็นที่ผู้ถูกสัมภาษณ์ที่มีลักษณะปกปิดตอบคำถามปกปิดตามความจริง โดยที่ $0 < T_m < 1$

$$\text{ดังนั้น } \Pr[X_i = 1] = \tau p T_m + p_{br}$$

$$\Pr[X_i = 0] = [1 - (\tau p T_m + p_{br})]$$

ให้ n_2 แทนจำนวนผู้ถูกสัมภาษณ์ที่ตอบว่า "ใช่" จากจำนวนผู้ถูกสัมภาษณ์ทั้งหมด n คน ค่าประมาณของ τ เท่ากับ

$$\hat{\tau}'_m = \frac{n_2}{np} - \frac{p_{br}}{p}$$

ค่าคาดหวังของค่าประมาณ τ คือ

$$\begin{aligned} E(\hat{\tau}'_m) &= \frac{E(n_2)}{np} - \frac{p_{br}}{p} \\ &= \frac{n [\tau p T_m + p_{br}]}{np} - \frac{p_{br}}{p} \end{aligned}$$

นั่นคือ $\hat{\tau}'_m$ เป็นค่าประมาณที่เอนเอียงของ τ

ดังนั้น ค่าความเอนเอียงและความแปรปรวนของค่าประมาณ τ คือ

$$\begin{aligned} \text{Bias}(\hat{\tau}'_m) &= E(\hat{\tau}'_m) - \tau \\ &= \tau T_m - \tau \\ &= \tau (T_m - 1) \end{aligned}$$

$$\begin{aligned} \text{Var}(\hat{\tau}'_m) &= \frac{\text{Var}(n_2)}{n^2 p^2} \\ &= \frac{n \cdot [\tau p T_m + p_{br}] [1 - (\tau p T_m + p_{br})]}{n^2 p^2} \\ &= \frac{\tau T_m (1 - \tau T_m)}{n} + \frac{p_{br} - p_{br}^2 + \tau p T_m - \tau p^2 T_m - 2\tau p p_{br} T_m}{np^2} \end{aligned}$$

2.4. ผลงานวิจัยที่เกี่ยวข้อง

กรีนเบอร์กและคณะ (1969 : 520-539) ได้ศึกษาการประมาณค่าสัดส่วนของประชากรที่มีลักษณะปกปิดในเชิงทฤษฎี โดยใช้คำถามที่ไม่เกี่ยวข้องกันนั้น กรณีที่ทราบสัดส่วนของประชากรที่มีลักษณะทั่ว ๆ ไป ซึ่งไม่จำเป็นต้องปกปิด π_u จะใช้ตัวอย่างขนาด n เพียงตัวอย่างเดียวในการประมาณค่าสัดส่วนของประชากรที่มีลักษณะปกปิด (π) ค่าประมาณภาวะน่าจะเป็นสูงสุดและความแปรปรวนของค่าประมาณ π คือ

$$\hat{\pi} = \frac{[\hat{\phi} - (1-p) \pi_u]}{p}$$

$$\text{และ Var}(\hat{\pi}) = \frac{\phi(1-\phi)}{np^2}$$

เมื่อ $\hat{\phi}$ คือ ความน่าจะเป็นที่ผู้ถูกสัมภาษณ์จะตอบว่า "ใช่" ซึ่งเท่ากับ $p\pi + (1-p)\pi_u$

$\hat{\phi}$ คือ สัดส่วนของผู้ถูกสัมภาษณ์ที่ตอบว่า "ใช่" จากตัวอย่างทั้งหมด n คน

p คือ ความน่าจะเป็นที่จะสุ่มได้คำถามปกปิดที่ต้องการศึกษา

กรณีที่ไมทราบ π_u จะต้องใช้ตัวอย่าง 2 ชุด ขนาด n_1 และ n_2 ที่เป็นอิสระต่อกัน (independent) และไม่คาบเกี่ยวกัน (non-overlapping) โดยกำหนดให้ความน่าจะเป็นที่ผู้ถูกสัมภาษณ์ในตัวอย่างที่ 1 และตัวอย่างที่ 2 จะสุ่มได้คำถามปกปิดเป็น p_1 และ p_2 ตามลำดับ ค่าประมาณภาวะน่าจะเป็นสูงสุดและความแปรปรวนของค่าประมาณ π คือ

$$\hat{\pi} = \frac{\hat{\phi}_1(1-p_2) - \hat{\phi}_2(1-p_1)}{p_1 - p_2}$$

$$\text{Var}(\hat{\pi}) = \frac{1}{(p_1 - p_2)^2} \left[\frac{\phi_1(1-\phi_1)(1-p_2)^2}{n_1} + \frac{\phi_2(1-\phi_2)(1-p_1)^2}{n_2} \right]$$

เมื่อ ϕ_1 และ ϕ_2 ความน่าจะเป็นที่ผู้ถูกสัมภาษณ์ในตัวอย่างที่ 1 และตัวอย่างที่ 2 จะตอบว่า "ใช่" ซึ่งเท่ากับ

$$\phi_1 = p_1\pi + (1-p_1)\pi_u$$

$$\phi_2 = p_2\pi + (1-p_2)\pi_u$$

$\hat{\phi}_1$ และ $\hat{\phi}_2$ คือสัดส่วนของผู้ถูกสัมภาษณ์ที่ตอบว่า "ใช่" ในตัวอย่างที่ 1 และ ตัวอย่างที่ 2 ตามลำดับ

การศึกษาค้างนี้ เขาพบว่าค่าประมาณที่ได้อาจตกอยู่นอกช่วง $[0, 1]$ ถ้า $p_1 - p_2$ แตกต่างกันน้อย และ n มีขนาดเล็ก ดังนั้น จึงควรเลือก $p_1 - p_2$ ให้แตกต่างกันมากที่สุด โดยให้ p_1 เข้าใกล้ 1 มากที่จะไม่ทำให้ผู้ถูกสัมภาษณ์เกิดความไม่ไว้วางใจแล้วจึงเลือก p_2 ให้ห่างจาก p_1 มากที่สุด ในทางปฏิบัติเขาแนะนำให้เลือก p_1 อยู่ในช่วง 0.8 ± 0.1 แล้วเลือก p_2 โดยมีข้อจำกัดว่า $p_1 + p_2 = 1$ สำหรับความแปรปรวนของตัวประมาณนั้น เขาพบว่า ถ้า $p_1 > 0.5$ แล้ว $\text{var}(\hat{\phi})$ จะมีค่าต่ำสุดเมื่อ $p_2 = 0$ ซึ่งตรงกับผลการศึกษาของมัวร์ (1971 : 627-629) แต่ในทางปฏิบัติเขาแนะนำให้ใช้กฎ $p_1 + p_2 = 1$ เพราะ การใช้ $p_2 = 0$ อาจทำให้ผู้ถูกสัมภาษณ์ให้ความร่วมมือน้อยลง

ดาวลิ่งและซีซท์แมน (1975 : 84-89) แสดงให้เห็นว่าความแปรปรวนของตัวประมาณที่ใช้คำถามซึ่งไม่เกี่ยวข้องกันมีค่าต่ำกว่าความแปรปรวนของตัวประมาณที่ใช้คำถามซึ่งเกี่ยวข้องกัน เมื่อ p หรือ $\max(p_1, p_2)$ ในกรณีใช้ 2 ตัวอย่างมีค่ามากกว่า $\frac{1}{3}$ โดยประมาณ สำหรับทุกค่า τ และ τ_u

ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย