

ลักษณะของปัญหาทางสถิติ (Nature of Statistical Problems)

๒.๑ คำนำ

ปัญหาทางสถิติที่เราประสบอยู่ขณะนี้อาจจำแนกได้เป็นสองปัญหาใหญ่ ๆ ด้วยกัน อันได้แก่ปัญหาทางด้านการประมาณค่า (Estimation problems) เป็นการประมาณค่าของพารามิเตอร์ที่เรายังไม่ทราบค่าด้วย statistic ตัวหนึ่งซึ่งเป็นฟังก์ชันของข้อมูล ตัวอย่างที่ถูกเลือกขึ้นมา พารามิเตอร์ที่กล่าวนี้อาจเป็นค่ารวมทั้งหมด เช่นจำนวนประชากรทั้งประเทศ หรือเป็นค่าเฉลี่ย เช่น รายได้เฉลี่ยต่อบุคคลต่อปี หรือเป็นอัตราส่วน เช่น อัตราส่วนของรายได้ต่อรายจ่ายของครอบครัวในจังหวัดพระนครและธนบุรี

อีกปัญหาหนึ่งที่เราสนใจก็คือ ปัญหาทางด้านการทดสอบสมมติฐาน เกี่ยวกับพารามิเตอร์ที่เรามีอยู่ พารามิเตอร์ดังกล่าวนี้อาจได้มาจากการสังเกตหรือจากการทดลองก็ตาม เราสนใจที่จะทดสอบในแง่ที่ว่า สมมติฐานที่เรายอมรับกันมานั้นมีความถูกต้องหรือไม่เพียงใด หรือในบางครั้งอาจมุ่งหมายที่จะทดสอบแบบของฟังก์ชันของการกระจายของความน่าจะเป็นของข้อมูล ตัวอย่าง เป็นต้น

๒.๒ ความหมายของค่าเฉลี่ย

ค่าที่นับว่ามีความสำคัญมากในบทนี้อาจกล่าวว่ามีอยู่สองค่าคือ Estimator คือสูตร หรืออยู่ในรูปของฟังก์ชัน

ตัวอย่างที่ ๒.๒.๑ สมมติว่าเรามีประชากรอยู่จุดหนึ่งประกอบด้วย

$$x_1, x_2, \dots, x_n$$

$\mu = \frac{1}{n} \sum_{i=1}^n x_i$ ซึ่งเป็นค่าเฉลี่ยที่หาไปสามารถหาค่าได้

x_1, x_2, \dots, x_n เป็นตัวอย่างขนาด n หน่วยที่ถูกเลือกขึ้นมา

$$\text{ถ้า } g(x) = \frac{1}{n} \sum_{i=1}^n x_i$$

แล้ว $g(x)$ ก็คือ estimator สำหรับค่าเฉลี่ย μ

หรือถ้าเราจะทำการจัดเรียงข้อมูลตัวอย่างชุดนั้นเสียใหม่ตามขนาดของค่า

จากสูงสุดไปยั้งค่าต่ำสุด สมมติให้เป็น $X(1), X(2), \dots, X(n)$ โดยที่

$$X(1) \leq X(2) \leq X(3) \leq \dots \leq X(n)$$

ถ้า $g(x) = \frac{X(1) + X(n)}{2}$ แล้ว $g(x)$ ก็คือ estimator สำหรับค่าเฉลี่ย μ ด้วย

เป็นที่น่าสังเกตว่าในประชากรชุดหนึ่ง ๆ เราสามารถมี estimator ได้หลายตัวด้วยกัน ทั้งนี้เป็นไปหน้าที่นักสถิติจะต้องพิจารณาว่า estimator ไหนจะเป็นตัวที่ดีที่สุด ซึ่งจะได้อกล่าวถึงการเปรียบเทียบ estimator ที่ดีต่อไป

Estimate คือค่าตัวเลขจำนวนหนึ่ง ได้จากการแทนค่าตัวเลขจริง ๆ ที่ได้จากข้อมูลตัวอย่างลงในสูตรหรือฟังก์ชันที่เป็น estimator

เช่นจากตัวอย่างที่ ๒.๒.๑ ให้ตัวอย่างมีขนาด ๕ หน่วยประกอบด้วย

$$๑๒๘, ๑๓๒, ๑๔๑, ๑๔๔, ๑๕๑.$$

ถ้าใช้สูตร $g(x) = \frac{1}{n} \sum_{i=1}^n x_i$ จะได้อค่าประมาณเป็น

$$\frac{๑๒๘ + ๑๓๒ + ๑๔๑ + ๑๔๔ + ๑๕๑}{๕} = ๑๔๐.๒$$

ถ้าใช้สูตร
$$g(x) = \frac{x_{(1)} + \dots + x_{(n)}}{n}$$
 จะได้ค่าประมาณเป็น $\frac{๑๒๕ + \dots + ๑๕๑}{๒} = ๑๔๐$

๒.๑ การประมาณค่า (Estimation)

การประมาณค่าคือการใช้ค่า statistic มาประมาณค่าของพารามิเตอร์^{*} เมื่อใดก็ตามที่เราสามารถหาค่าจากข้อมูลตัวอย่างมาแทนใน statistic ซึ่งเป็นฟังก์ชันของข้อมูลตัวอย่างได้ เราพยายามหาค่าประมาณสำหรับพารามิเตอร์นั้น ๆ ได้ ค่าประมาณ (estimate) แยกได้เป็นสองประเภทคือค่าเดี่ยว เช่น ค่าประมาณของค่าเฉลี่ยของอายุของนิสิตในจุฬาลงกรณ์มหาวิทยาลัยเป็น ๒๐ ปี ค่าประมาณของอายุการปฏิบัติงานของหลอดไฟฟ้าชนิดหนึ่งเป็น ๒๔๐.๗ ชั่วโมง เป็นต้น ค่าประมาณอีกประเภทหนึ่งเป็นค่าในช่วง คือค่าประมาณจะอยู่ในระหว่างค่าสองค่า เช่น ค่าประมาณของอุปสงค์ที่มีคอมพิวเตอร์ในปืหน้าจะอยู่ระหว่าง ๑๒๓.๔ ถึง ๑๔๓.๖ ล้านคัน เครื่องจักรชนิดใหม่จะให้ผลผลิตที่เสียเป็นค่าประมาณ ๔ ถึง ๔.๕ เปอร์เซ็นต์ของผลิตภัณฑ์ทั้งหมด เป็นต้น

๒.๔ Unbiased Estimates

ถ้า $\hat{\theta}(x)$ เป็น estimator สำหรับพารามิเตอร์ θ เราจะกล่าวว่า $\hat{\theta}(x)$ เป็น unbiased estimate ของ θ ถ้า

^{*} Paul G. Hoel, Introduction to Mathematical Statistics (3rd ed.; New York: John Wiley and Sons, Inc., 1968), p.96.

$$E[\hat{e}(x)] = e \quad 2$$

ตัวอย่างที่ ๒.๔.๑ ประชากรชุดหนึ่งประกอบด้วย x_1, x_2, \dots, x_n .

และค่าตัวกลางเลขคณิต (mean) $= \mu = \frac{1}{n} \sum_{i=1}^n x_i$

ถ้าเราสุ่มตัวอย่างขนาด n หน่วยออกมาชุดหนึ่งเป็น x_1, x_2, \dots, x_n โดยที่ $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ แล้ว เราสามารถกล่าวได้ว่า \bar{x} เป็น Unbiased estimate สำหรับ μ เพราะ

$$\begin{aligned} E(\bar{x}) &= E\left[\frac{1}{n} \sum_{i=1}^n x_i\right] \\ &= E\left[\frac{1}{n}(x_1 + x_2 + \dots + x_n)\right] \\ &= \frac{1}{n} [E(x_1 + x_2 + \dots + x_n)] \\ &= \frac{1}{n} [E(x_1) + E(x_2) + \dots + E(x_n)] \\ &= \frac{1}{n} [\mu + \mu + \dots + \mu] \\ &= \frac{n}{n} \mu = \mu \end{aligned}$$

2.5 Minimum Variance Unbiased Estimator

$\hat{e}(x)$ จะเป็น minimum variance unbiased estimator สำหรับ $e(x)$ ถ้า $\text{var } \hat{e}(x) \leq \text{var } \hat{e}'(x)$ โดยที่ $\hat{e}'(x)$ เป็น unbiased estimator ใด ๆ สำหรับ $e(x)$ ³

² Ibid., p. 223.

³ Alexander M. Mood and Franklin A. Graybill, Introduction to the Theory of Statistics (2nd ed.; New York: Mc Graw-Hill Book Company, Inc., 1963), p. 175.

ตัวอย่างที่ ๒.๕.๑ ถ้าเราต้องการประมาณค่า $\bar{Y} = \frac{1}{N} \sum_{i=1}^N Y_i$

ก. ถ้าเราทำแบบ simple random sampling

$$\bar{y} = \frac{1}{n} \sum Y_i \quad (๒.๕.๑)$$

ซึ่ง

$$E(\bar{y}) = \bar{Y}$$

และ

$$\text{Var}(\bar{y})_{\text{ran}} = \frac{S^2}{n} \quad (๒.๕.๒)$$

ข. ถ้าเราทำแบบ proportional stratified random sampling

$$\bar{y} = \frac{1}{n} \sum_{h=1}^L n_h \bar{y}_h \quad (๒.๕.๓)$$

ซึ่ง

$$E(\bar{y}) = \bar{Y}$$

แต่

$$\begin{aligned} \text{Var}(\bar{y})_{\text{prop}} &= \frac{\sum N_h S_h^2}{nN} \\ &= \frac{S^2}{n} - \frac{\sum N_h (\bar{y}_h - \bar{Y})^2}{nN} \\ &= \text{Var}(\bar{y})_{\text{ran}} - \frac{\sum N_h (\bar{y}_h - \bar{Y})^2}{nN} \quad (๒.๕.๔) \end{aligned}$$

ดังจะเห็นได้ว่าการประมาณค่าของ \bar{Y} นั้นจะทำแบบ simple random sampling หรือ proportional stratified random sampling ก็จะได้ unbiased estimator เช่นเดียวกัน แต่จาก (๒.๕.๔) แสดงให้เห็นได้ว่า ถ้าเราประมาณค่า \bar{Y} ด้วย (๒.๕.๓) จะให้ค่าความแปรปรวนน้อยกว่าการใช้ (๒.๕.๑)

เป็นที่น่าสังเกตว่าในการประมาณค่าทางสถิติขั้นนี้ เราสามารถจะมีตัวประมาณค่า (estimator) ได้มากกว่าหนึ่งตัวเสมอไป และในระหว่างบรรดาตัวประมาณค่าทั้งหลายนี้การจะตัดสินใจว่าตัวใดจะดีอย่างไรนั้นโดยปกติก็จะดูจากคุณสมบัติต่าง ๆ ที่นับว่าสำคัญพวกคือเปรียบเทียบด้วย ๒.๔ และ ๒.๕ นอกจากนั้นก็เปรียบเทียบด้วยคุณสมบัติอื่น ๆ ซึ่งเป็นคุณสมบัติทางทฤษฎีคณิตศาสตร์ เช่น ความ consistency ความ asymptotic และความสะดวกในการคำนวณ (ease of computation) เป็นต้น

๒.๒ การทดสอบสมมติฐาน

ในการแก้ปัญหาทางสถิตินั้น นอกจากเราจะสนใจในการประมาณค่าของพารามิเตอร์แล้ว เรายังอาจสนใจที่จะทดสอบสมมติฐานเกี่ยวกับพารามิเตอร์ที่เราเมื่อพบ พารามิเตอร์ดังกล่าวเราอาจได้มาจากประสิทธิภาพหรือจากการทดลองก็ตาม เราสนใจทดสอบสมมติฐานของพารามิเตอร์ในค่านี้นั้นว่าจะมีการเปลี่ยนแปลงไปหรือไม่ หรืออาจทดสอบว่าสมมติฐานที่ยอมรับกันมานั้นถูกต้องหรือไม่เพียงใด หรือในบางครั้งอาจมุ่งหมายที่จะทดสอบแบบของฟังก์ชันของการกระจายของความน่าจะเป็นก็ได้

ตัวอย่าง กองส่งเสริมการเกษตรของกระทรวงเกษตร ต้องการจะสนับสนุนนโยบายการเพิ่มรายได้ประชาชาติของรัฐบาล โดยพยายามเพิ่มรายได้ในส่วนของผลิตภัณฑ์การเกษตรให้สูงขึ้น และสนใจที่จะส่งเสริมการปลูกข้าวฟ่างนอกเหนือไปจากการส่งเสริมการปลูกข้าวเจ้าที่โตทำอยู่แล้ว จึงต้องการเปรียบเทียบผลตอบต่อไร่ของข้าวเจ้าและข้าวฟ่างดู

เช่นนี้จะเห็นได้ว่า กองส่งเสริมการเกษตรฯ จะต้องยุ่งเกี่ยวกับประชากรถึงสองชุดคือข้าวเจ้ากับข้าวฟ่าง สมมติว่าจากผลการทำนาข้าวเจ้าแต่ละปีที่ผ่านมา ผลตอบแทนต่อไร่โดยเฉลี่ยประมาณปีละ ๑,๔๐๐ บาท ปัญหาที่มีว่าถ้าปลูกข้าวฟ่างจะได้ผลตอบแทนต่อไร่มากกว่าหรือน้อยกว่าการปลูกข้าวเจ้า เพื่อขจัดข้อข้องใจนี้ เราก็ตั้งข้อสมมติฐานขึ้นว่า การเพาะปลูกพืชชนิดใดจะให้ผลตอบแทนต่อไร่สูงกว่า จากนั้นโดยการอาศัยการเลือกตัวอย่างจากการปลูกข้าวเจ้าและจากการทดลองปลูกข้าวฟ่าง เราก็สามารถจะเห็นพ้องหรือปฏิเสธข้อสมมติฐานของเราได้

ในทางปฏิบัติเราทดลองปลูกข้าวฟ่างแต่เพียงอย่างเดียว เพราะเรามีข้อมูลในด้านการเพาะปลูกข้าวเจ้าอยู่แล้ว สมมติว่าผลเฉลี่ยของการปลูกข้าวฟ่างได้ผลตอบแทนต่อไร่เป็น ๑,๕๕๐ บาทต่อปี โดยผลสรุปอย่างหยาบ เราก็สามารถสรุปได้ว่า การปลูกข้าวฟ่างจะให้ผลตอบแทนต่อไร่สูงกว่าการปลูก

ชาวจำว แต่ถาเราจะหันมาพิจารณาค่าเบี่ยงเบนมาตรฐานประกอบด้วยแล้ว
 สมมติว่าคำนวณออกมาได้ค่าจากกระตงนา ตัวอย่างเป็น ๑๒๕ ($6/\sqrt{n} = ๑๒๕$
 เมื่อ n เป็นขนาดของจำนวนกระตงนาตัวอย่าง) ด้วยการใช้ ๕๕ %
confidence interval แล้ว สำหรับการปลุกชาวฟางจะมี interval
 อยู่ระหว่าง ๑,๓๐๐ ถึง ๑,๕๐๐ บาทต่อไร่ ถ้าสมมติฐานของเรากล่าวว่
 "การปลุกชาวฟางใหม่ผลตอบแทนสูงกว่าการปลุกชาวจำว" แล้ว เราก็จะต้อง
 ปฏิเสธสมมติฐานดังกล่าว ด้วยเหตุผลที่ว่าผลตอบแทนต่อไร่ปีละ ๑,๕๕๐ บาท
 นั้นมีโอกาสสูงที่จะมาจากประชากรที่มีค่าเฉลี่ยเป็น ๑,๔๐๐ บาท แต่ในทาง
 ตรงกันข้าม ถ้าค่าเบี่ยงเบนมาตรฐานเป็น ๒๕ ($6/\sqrt{n} = ๒๕$) เราจะต้องยอม
 รับข้อสมมติฐานที่ว่า การปลุกชาวฟางใหม่ผลตอบแทนสูงกว่าการปลุกชาวจำว