

ทฤษฎีที่อ้างอิงกับกลุ่มตัวอย่างขนาดใหญ่ (Large-Sample Theories)

รศ.ดร. วีระชาติ กิเลนทอง
มหาวิทยาลัยหอการค้าไทย

©Kilenthong 2019

บทนี้นำเสนอทฤษฎีบทที่เป็นรากฐานที่สำคัญในทางสถิติสองอัน

- กฎว่าด้วยตัวอย่างขนาดใหญ่ (Law of Large Numbers)
- ทฤษฎีบทลิมิตของค่ากลาง (Central Limit Theorem)

กฎว่าด้วยจำนวนมาก (Law of Large Numbers)

- กฎว่าด้วยตัวอย่างขนาดใหญ่ (Law of Large Numbers) เป็นทฤษฎีบทที่สำคัญทางสถิติที่ทำให้สามารถประมาณค่า (estimate) ค่าคาดหวัง (mean) ของตัวแปรที่สนใจ (ซึ่งเป็นค่าทางทฤษฎี) ด้วย ค่าเฉลี่ย (average)
- กฎว่าด้วยตัวอย่างขนาดใหญ่ (Law of Large Numbers) เกี่ยวข้องกับการลู่เข้าเชิงความน่าจะเป็น (converge in probability)

นิยาม: การลู่เข้าเชิงความน่าจะเป็น (converge in probability)

Definition

อันดับของตัวแปรสุ่ม X_1, X_2, \dots ลู่เข้าสู่ตัวแปรสุ่ม X ในเชิงความน่าจะเป็น (converge to X in probability) ถ้า สำหรับทุกๆ ค่า $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} Pr(|X_n - X| < \varepsilon) = 1 \Leftrightarrow \lim_{n \rightarrow \infty} Pr(|X_n - X| \geq \varepsilon) = 0 \quad (1)$$

ซึ่งอาจจะเขียนแทนด้วย $X_n \xrightarrow{P} X$ หรือ $plim X_n = X$

- การลู่เข้าเชิงความน่าจะเป็น (converge in probability) คือ ความน่าจะเป็นที่ X_n จะมีค่าใกล้เคียงกับ c นั้นมีค่าเข้าใกล้หนึ่งเมื่อ n ลู่เข้าสู่อนันต์ หรือ เมื่อ n มีค่าสูงมากๆ แล้วโอกาสที่ค่าของตัวแปรสุ่ม X_n จะแตกต่างจาก c นั้นจะมีค่าเข้าใกล้ศูนย์มากๆ
- เหตุผลที่สำคัญที่ทำให้ต้องพิจารณาในรูปแบบของการลู่เข้าเชิงความน่าจะเป็น (converge in probability) เพราะในโลกของความน่าจะเป็นหรือความไม่แน่นอน ไม่สามารถระบุค่าอะไรได้อย่างแน่นอน
- เหตุการณ์อื่นๆ ที่มีความน่าจะเป็นลู่เข้าสู่ศูนย์ไม่ได้หมายความว่า เป็นไปไม่ได้

ทฤษฎี: กฎว่าด้วยจำนวนมาก (Law of Large Numbers)

Theorem

สมมติให้ X_1, \dots, X_n คือกลุ่มตัวอย่างขนาด n ตัวอย่างที่สุ่มมาจากการแจกแจงที่มีค่าคาดหวัง (mean) $E[X] = \mu$ และค่าความแปรปรวน (variance) มีค่าจำกัด และกำหนดให้ $\bar{X}_n = \frac{\sum_{i=1}^n X_i}{n}$ คือค่าคาดหวังจากตัวอย่าง (sample mean) แล้ว

$$\bar{X}_n \xrightarrow{P} E[X] = \mu \quad (2)$$

Proof.

- จากทฤษฎีที่ว่า $E[\bar{X}_n] = \mu$ และ $\text{Var}[\bar{X}_n] = \frac{\sigma^2}{n}$ สามารถประยุกต์ **อสมการเชบิเชฟ (Chebyshev Inequality)**
 $\left(\Pr(|\bar{X}_n - \mu| \geq \varepsilon) \leq \frac{\frac{\sigma^2}{n}}{\varepsilon^2} \right)$ เพื่อแสดงว่า สำหรับทุกๆ ค่าจำนวนจริง $\varepsilon > 0$

$$\Pr(|\bar{X}_n - \mu| \leq \varepsilon) = 1 - \Pr(|\bar{X}_n - \mu| \geq \varepsilon) \geq 1 - \frac{\frac{\sigma^2}{n}}{\varepsilon^2}$$

- ซึ่งเข้าสู่หนึ่งเมื่อ n เข้าสู่อนันต์แล้ว $\lim_{n \rightarrow \infty} \Pr(|\bar{X}_n - \mu| \leq \varepsilon) \geq \lim_{n \rightarrow \infty} 1 - \frac{\frac{\sigma^2}{n}}{\varepsilon^2} = 1$
- เนื่องจากความน่าจะเป็นมีค่าไม่เกินหนึ่ง ดังนั้น จึงสามารถสรุปได้ว่า สำหรับทุกๆ ค่าจำนวนจริง $\varepsilon > 0$ แล้ว

$$\lim_{n \rightarrow \infty} \Pr(|\bar{X}_n - \mu| \leq \varepsilon) = 1$$

การประยุกต์ใช้กฎว่าด้วยจำนวนมาก (Law of Large Numbers)

- กฎว่าด้วยตัวอย่างขนาดใหญ่ (Law of Large Numbers) ระบุว่า “ ค่าคาดหวังจากตัวอย่าง (sample mean) \bar{X}_n จะมีค่าใกล้เคียงกับค่าคาดหวัง (mean) $E[X] = \mu$ เมื่อกลุ่มตัวอย่างมีขนาดใหญ่”
- หมายความว่า หากมีข้อมูลขนาดใหญ่มากพอแล้ว ค่าเฉลี่ยเลขคณิต (arithmetic average) \bar{x}_n ที่คำนวณจากตัวอย่างสุ่ม (random sample) จะมีค่าใกล้เคียงกับ ค่าคาดหวัง (mean) $E[X] = \mu$
- การประมาณค่าคาดหวัง (mean) ของตัวแปรต่างๆ นิยมใช้ค่าเฉลี่ยเลขคณิต (arithmetic average) ของตัวแปรนั้น
- การประยุกต์ใช้กฎว่าด้วยตัวอย่างขนาดใหญ่ (Law of Large Numbers) ที่น่าสนใจอันหนึ่ง คือ การสร้างกราฟแสดงความถี่ (histogram)

นิยาม: กราฟแสดงความถี่ (histogram)

Definition

กำหนดให้ x_1, \dots, x_n คือค่าจำนวนจริงที่ $a < x_i < b$ สำหรับทุก i และ a, b คือค่าคงที่ เราสามารถสร้างกราฟแสดงความถี่ (histogram) จากเซตของจำนวนจริงดังกล่าวได้โดยเลือกจำนวนเต็ม $k > 1$ และแบ่งช่วง $[a, b]$ เป็น k ช่วงที่มีความกว้างเท่ากันที่ $\frac{b-a}{k}$ หลังจากนั้น ให้นับดูว่ามีกี่จำนวนจากเซตดังกล่าวที่มีค่าตกอยู่ในช่วงย่อย (subinterval) แต่ละช่วง $j = 1, \dots, k$ และแทนจำนวนที่นับได้ด้วย c_j ขั้นตอนต่อไปคือการเลือกรูปแบบของกราฟแสดงความถี่ (histogram) ซึ่งทำได้ด้วยการเลือกจำนวนจริง r (โดยทั่วไปใช้ $r = n$) เพื่อกำหนดระดับความสูงของแต่ละแท่งตามสมการ

$$\text{ระดับความสูงของแท่ง}_j = \frac{c_j}{n} \quad (3)$$

- ระดับความสูงเท่ากับสัดส่วนของจำนวนที่ตกอยู่ในแต่ละช่วง ซึ่งเป็นกรณีที่ได้รับค่านิยมมากที่สุดเพราะมีความสัมพันธ์กับฟังก์ชันความหนาแน่นความน่าจะเป็น (p.d.f.)
- ทฤษฎีบทต่อไปนี้ ประยุกต์ใช้กฎว่าด้วยตัวอย่างขนาดใหญ่ (Law of Large Numbers) เพื่อบอกว่า ในกรณีที่ $r = n$ นั้นลู่เข้าสู่ค่าความน่าจะเป็นที่จะสุ่มได้จำนวนที่มีค่าอยู่ในช่วงนั้น

ทฤษฎี: กราฟแสดงความถี่ (histogram)

Theorem

กำหนดให้ X_1, X_2, \dots เป็นอันดับของตัวแปรสุ่มที่มีการแจกแจงเหมือนกันและเป็นอิสระต่อกัน (i.i.d.) และค่าคงที่ $c_1 < c_2$ พร้อมทั้งกำหนดให้ $Y_i = 1$ ถ้า $c_1 \leq X_i < c_2$ และ $Y_i = 0$ ถ้าไม่ใช่ แล้ว $\bar{Y}_n = \frac{1}{n} \sum_{i=1}^n Y_i$ คือสัดส่วนของ X_1, X_2, \dots ที่มีค่าอยู่ในช่วง $[c_1, c_2)$ และ

$$\bar{Y}_n \xrightarrow{P} Pr(c_1 \leq X_i < c_2) \quad (4)$$

Proof.

จากนิยามที่กำหนดให้ จะเห็นได้ว่า Y_1, Y_2, \dots เป็นตัวแปรสุ่มแบบเบอร์นูลลี (Bernoulli) ด้วยค่าพารามิเตอร์ $p = Pr(c_1 \leq X_i < c_2)$ ที่มีการแจกแจงเหมือนกันและเป็นอิสระต่อกัน (i.i.d.) ดังนั้น สามารถประยุกต์ใช้กฎว่าด้วยตัวอย่างขนาดใหญ่ (Law of Large Numbers) เพื่อสรุปว่า $\bar{Y}_n \xrightarrow{P} p$ เพราะ p คือค่าคาดหวังของ Y_i ในขณะเดียวกัน $p = Pr(c_1 \leq X_i < c_2)$ □



ตัวอย่าง: การสร้างกราฟแสดงความถี่ (histogram)

- ตัวอย่างต่อไปนี้แสดงการสร้างกราฟแสดงความถี่ (histogram) ของอัตราผลตอบแทน (returns) ของตลาดหลักทรัพย์แห่งประเทศไทย
- ประเด็นสำคัญของตัวอย่างนี้คือ บทบาทของความกว้างแถบความถี่ (bandwidth) $[c_1, c_2)$ ต่อความราบเรียบ (smoothness) ของกราฟแสดงความถี่ (histogram) โดยจะเห็นว่า กราฟแสดงความถี่จะมีความราบเรียบมากขึ้นเมื่อความกว้างแถบความถี่ (bandwidth) มีค่าสูงขึ้น

ตัวอย่าง: การสร้างกราฟแสดงความถี่ (histogram) ของอัตราผลตอบแทนต่อปี

Example

พิจารณาข้อมูลรายวันของอัตราผลตอบแทนต่อปี (annualized returns) ของตลาดหลักทรัพย์แห่งประเทศไทยระหว่าง 1 มกราคม 2015 ถึง 30 กันยายน 2018 โดยในกราฟแรกกำหนดให้ความกว้างแถบความถี่ (bandwidth) แต่ละแถบมีความกว้างเท่าๆ กันที่ 0.005 หรือร้อยละ 0.5 และเพื่อความสะดวก กำหนดให้ค่าต่ำสุดเท่ากับ -0.05 และสูงสุดเท่ากับ 0.05 ส่วนในกราฟที่สองกำหนดให้กว้าง 0.001 หรือร้อยละ 0.1



ตัวอย่าง: การสร้างกราฟแสดงความถี่ (histogram) ของอัตราผลตอบแทนต่อปี

Example

- บทเรียนที่สำคัญจากตัวอย่างนี้คือ **กราฟแรกมีความราบเรียบมากกว่ากราฟที่สอง** ซึ่งสามารถอธิบายได้โดยพิจารณา
 - ▶ ตัวแปรสุ่ม X มีการแจกแจงทวินาม (binomial distribution) ด้วยค่าพารามิเตอร์ n และ p
 - ▶ ตัวแปรสุ่ม Y ซึ่งมีการแจกแจงทวินาม (binomial distribution) ด้วยค่าพารามิเตอร์ n และ $\frac{p}{m}$ โดยที่ $m > 1$
 - ▶ เราสามารถสร้างตัวแปรใหม่ $Z = mY$ ที่มีค่าคาดหวัง (mean) เท่ากับ $\mu_Z = np$ ซึ่งมีค่าเท่ากับค่าคาดหวังของ X แต่มีค่าความแปรปรวน (variance) เท่ากับ $\sigma_Z^2 = m^2 n \frac{p}{m} (1 - \frac{p}{m}) = mnp (1 - \frac{p}{m})$ ในขณะที่ค่าความแปรปรวน (variance) ของ X มีค่าเท่ากับ $\sigma_X^2 = np(1 - p)$
- หากพิจารณาในกรณีที่มี p มีค่าน้อยมาก (กรณีที่กำหนดให้ความกว้างแถบความถี่ (bandwidth) $[c_1, c_2]$ มีค่าน้อยมาก) จนทำให้สามารถกำหนดให้ค่า $p^2 \approx 0$ ซึ่งมีผลทำให้สามารถแสดงได้ว่า $\sigma_X^2 \approx np$ และ $\sigma_Z^2 \approx mnp$ นั่นคือ ค่าความแปรปรวน (variance) ของ Z มีค่าประมาณ k เท่าของค่าความแปรปรวน (variance) ของ X
- ผลการคำนวณในตัวอย่างนี้แสดงให้เห็นว่า ตัวแปร X และ Z มีค่าคาดหวังที่เท่ากัน แต่มีช่วงความกว้างแถบความถี่ (bandwidth) ที่แตกต่างกัน โดยตัวแปร X นำไปสู่กราฟแสดงความถี่ (histogram) ที่มีช่วงความกว้างแถบความถี่ (bandwidth) ที่กว้างกว่าเพราะ $m > 1$ นอกจากนี้ การที่ค่าความแปรปรวน (variance) ของ Z มีค่ามากกว่าค่าความแปรปรวน (variance) ของ X สะท้อนให้เห็นว่า กราฟแสดงความถี่จะมีความราบเรียบมากขึ้นเมื่อความกว้างแถบความถี่ (bandwidth) มีค่าสูงขึ้น

การลู่เข้าเชิงความน่าจะเป็น (converge in probability)

- ทฤษฎีบทต่อไปนี้เป็น การขยายผลการลู่เข้าเชิงความน่าจะเป็น (converge in probability) สำหรับฟังก์ชันเชิงเส้นและฟังก์ชันต่อเนื่อง (continuous) ที่ลู่เข้าเชิงน่าจะเป็น ซึ่งทำให้สามารถประยุกต์ใช้กฎว่าด้วยตัวอย่างขนาดใหญ่ (Law of Large Numbers) กับค่าสถิติที่เป็นฟังก์ชันของค่าคาดหวังจากตัวอย่าง (sample mean)

ทฤษฎี: การลู่เข้าเชิงความน่าจะเป็น (converge in probability) สำหรับตัวอย่างขนาดใหญ่ (Law of Large Numbers)

Theorem

สมมติว่า $X_n \xrightarrow{P} X$ และ $Y_n \xrightarrow{P} Y$ แล้ว $X_n + Y_n \xrightarrow{P} X + Y$

Proof.

- กำหนดให้ $\epsilon > 0$ ที่สอดคล้องกับอสมการต่อไปนี้

$$|(X_n + Y_n) - (X + Y)| \geq \epsilon \quad (5)$$

- ดังนั้น อสมการสามเหลี่ยม (triangular inequality) ช่วยให้เราสามารถบอกได้ว่า

$$|X_n - X| + |Y_n - Y| \geq |(X_n + Y_n) - (X + Y)| \geq \epsilon \quad (6)$$

- เราสามารถประยุกต์ใช้กับค่าความน่าจะเป็นได้ว่า

$$Pr(|(X_n + Y_n) - (X + Y)| \geq \epsilon) \leq Pr(|X_n - X| + |Y_n - Y| \geq \epsilon) \quad (7)$$



การพิสูจน์: การลู่เข้าเชิงความน่าจะเป็นสำหรับตัวอย่างขนาดใหญ่

Proof.

- เพื่อให้สามารถเขียนพจน์ด้านขวาในรูปของ $|X_n - X|$ และ $|Y_n - Y|$ จำเป็นต้องพิสูจน์ว่าเหตุการณ์

$$A = \{|X_n - X| + |Y_n - Y| \geq \epsilon\} \quad (8)$$

- กำหนดให้ $\epsilon > 0$ ที่สอดคล้องกับอสมการ $|(X_n + Y_n) - (X + Y)| \geq \epsilon$ ดังนั้น อสมการสามเหลี่ยม (triangular inequality) ช่วยให้เราสามารถบอกได้ว่า

$$|X_n - X| + |Y_n - Y| \geq |(X_n + Y_n) - (X + Y)| \geq \epsilon$$

- เราสามารถประยุกต์ใช้กับค่าความน่าจะเป็นได้ว่า

$$Pr(|(X_n + Y_n) - (X + Y)| \geq \epsilon) \leq Pr(|X_n - X| + |Y_n - Y| \geq \epsilon)$$

- เพื่อให้สามารถเขียนพจน์ด้านขวาในรูปของ $|X_n - X|$ และ $|Y_n - Y|$ จำเป็นต้องพิสูจน์ว่าเหตุการณ์

$$A = \{|X_n - X| + |Y_n - Y| \geq \epsilon\}$$

เป็นสับเซตของเหตุการณ์ $B = \{|X_n - X| \geq \frac{\epsilon}{2}\} \cup \{|Y_n - Y| \geq \frac{\epsilon}{2}\}$

- เลือก $\frac{\epsilon}{k}$ สำหรับ X และ $\frac{(k-1)\epsilon}{k}$ สำหรับ Y โดยที่ค่าจำนวนจริง $k > 1$ ซึ่งเห็นได้อย่างชัดเจนจากรูปถัดไป

การพิสูจน์: สรุปผลการพิสูจน์การลู่เข้าเชิงความน่าจะเป็นสำหรับตัวอย่างขนาดใหญ่

Proof.

- ผลที่ตามมาก็คือ

$$\begin{aligned}Pr(|X_n - X| + |Y_n - Y| \geq \epsilon) &\leq Pr\left(|X_n - X| \geq \frac{\epsilon}{2}\right) + Pr\left(|Y_n - Y| \geq \frac{\epsilon}{2}\right) \\ &\quad + Pr\left(|X_n - X| \geq \frac{\epsilon}{2} \text{ และ } |Y_n - Y| \geq \frac{\epsilon}{2}\right) \\ &\leq Pr\left(|X_n - X| \geq \frac{\epsilon}{2}\right) + Pr\left(|Y_n - Y| \geq \frac{\epsilon}{2}\right)\end{aligned}$$

- ดังนั้น

$$Pr(|(X_n + Y_n) - (X + Y)| \geq \epsilon) \leq Pr\left(|X_n - X| \geq \frac{\epsilon}{2}\right) + Pr\left(|Y_n - Y| \geq \frac{\epsilon}{2}\right)$$

- ในขณะเดียวกัน คุณสมบัติการลู่เข้าเชิงความน่าจะเป็นของ X_n และ Y_n ทำให้สรุปได้ว่า

$$\lim_{n \rightarrow \infty} Pr(|(X_n + Y_n) - (X + Y)| \geq \epsilon) \leq \lim_{n \rightarrow \infty} Pr\left(|X_n - X| \geq \frac{\epsilon}{2}\right) + \lim_{n \rightarrow \infty} Pr\left(|Y_n - Y| \geq \frac{\epsilon}{2}\right) = 0$$

- หมายความว่า

$$X_n + Y_n \xrightarrow{P} X + Y$$

ทฤษฎี: การลู่เข้าเชิงความน่าจะเป็น (converge in probability) เมื่อมีค่าคงที่คูณกับตัวแปรสุ่ม

Theorem

สมมติว่า $X_n \xrightarrow{P} X$ และ a เป็นค่าคงที่ แล้ว $aX_n \xrightarrow{P} aX$

Proof.

ถ้า $a = 0$ ค่าลิมิตต้องเท่ากับศูนย์อย่างแน่นอน ดังนั้น จำเป็นต้องพิสูจน์เพิ่มเติมเฉพาะในกรณีที่ $a \neq 0$ โดยเริ่มจากการกำหนดให้ $\epsilon > 0$ ดังนั้น

$$\lim_{n \rightarrow \infty} \Pr(|aX_n - aX| \geq \epsilon) = \lim_{n \rightarrow \infty} \Pr(|a|X_n - X| \geq \epsilon) = \lim_{n \rightarrow \infty} \Pr\left(|X_n - X| \geq \frac{\epsilon}{|a|}\right) = 0$$



ทฤษฎี: การลู่เข้าเชิงความน่าจะเป็น (converge in probability) สำหรับฟังก์ชันของตัวแปรสุ่ม

Theorem

ถ้า $X_n \xrightarrow{P} c$ และ $g(x)$ เป็นฟังก์ชันที่ต่อเนื่องที่จุด $x = c$ แล้ว $g(X_n) \xrightarrow{P} g(c)$

Proof.

- กำหนดให้ $\epsilon > 0$ เนื่องจาก $g(x)$ เป็นฟังก์ชันที่ต่อเนื่องที่จุด c ดังนั้น จะต้องมีค่าคงที่ $\delta > 0$ ที่ทำให้ $|g(x) - g(c)| < \epsilon$ สำหรับทุกๆ ค่า x ที่สอดคล้องกับเงื่อนไข $|x - c| < \delta$ ดังนั้น

$$|g(x) - g(c)| \geq \epsilon \Rightarrow |x - c| \geq \delta \quad (9)$$

- เราสามารถเขียนในรูปของเหตุการณ์ได้ว่า

$$\{|g(x) - g(c)| \geq \epsilon\} \subset \{|x - c| \geq \delta\} \quad \text{ดังนั้น} \quad Pr(|g(x) - g(c)| \geq \epsilon) \leq Pr(|x - c| \geq \delta)$$

โดยนิยามของการลู่เข้าเชิงความน่าจะเป็น $X_n \xrightarrow{P} c$ ค่าลิมิตของพจน์ด้านขวามีค่าเท่ากับ

$$\lim_{n \rightarrow \infty} Pr(|x - c| \geq \delta) = 0$$

- สรุปได้ว่า $\lim_{n \rightarrow \infty} Pr(|g(x) - g(c)| \geq \epsilon) = 0 \Rightarrow g(X_n) \xrightarrow{P} g(c)$



ทฤษฎี: การลู่เข้าเชิงความน่าจะเป็น (converge in probability) สำหรับการคูณกันของตัวแปรสุ่ม

- ทฤษฎีบทนี้สามารถขยายผลสู่กรณีของเวกเตอร์ของตัวแปรสุ่ม Z_n นั่นคือ ถ้า $Z_n \xrightarrow{P} z$ และ $g(x)$ เป็นฟังก์ชันที่ต่อเนื่องที่จุด $x = z$ แล้ว $g(Z_n) \xrightarrow{P} g(z)$ ดังแสดงตัวอย่างในรูปของฟังก์ชันผลคูณในทฤษฎีบทต่อไปนี้

Theorem

สมมติว่า $X_n \xrightarrow{P} X$ และ $Y_n \xrightarrow{P} Y$ แล้ว $X_n Y_n \xrightarrow{P} XY$

Proof.

พิจารณาผลคูณ

$$X_n Y_n = \frac{1}{2} X_n^2 + \frac{1}{2} Y_n^2 - \frac{1}{2} (X_n + Y_n)^2 \xrightarrow{P} \frac{1}{2} X^2 + \frac{1}{2} Y^2 - \frac{1}{2} (X + Y)^2 = XY$$

□

- ตัวอย่างต่อไปนี้แสดงการประยุกต์กฎว่าด้วยตัวอย่างขนาดใหญ่ (Law of Large Numbers) และคุณสมบัติการลู่เข้าเชิงความน่าจะเป็นเพื่อหาค่าลิมิตของค่าความแปรปรวนจากตัวอย่าง (sample variance)

ตัวอย่าง: การประยุกต์กฎว่าด้วยตัวอย่างขนาดใหญ่

Example

สมมติว่า X_1, \dots, X_n คือตัวอย่างสุ่มที่สุ่มเลือกมาจากการแจกแจงที่ค่าคาดหวังเท่ากับ μ และค่าความแปรปรวนเท่ากับ σ^2 พิจารณาค่าความแปรปรวนจากตัวอย่าง (sample variance)

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 = \frac{n}{n-1} \left[\frac{\sum_{i=1}^n X_i^2}{n} - \bar{X}_n^2 \right]$$

- กฎว่าด้วยตัวอย่างขนาดใหญ่ (Law of Large Numbers) ช่วยให้สรุปได้ว่า

$$\begin{aligned} \bar{X}_n &\xrightarrow{P} \mu \\ \frac{\sum_{i=1}^n X_i^2}{n} &\xrightarrow{P} E[X_i^2] = \sigma^2 + \mu^2 \end{aligned}$$

- ในขณะเดียวกัน ทฤษฎีบทก่อนหน้านี้อาจช่วยให้สามารถสรุปได้ว่า

$$\bar{X}_n^2 \xrightarrow{P} \mu^2$$

- ดังนั้น
$$S_n^2 = \frac{n}{n-1} \left[\frac{\sum_{i=1}^n X_i^2}{n} - \bar{X}_n^2 \right] \xrightarrow{P} \left(\lim_{n \rightarrow \infty} \frac{n}{n-1} \right) [\sigma^2 + \mu^2 - \mu^2] = \sigma^2$$

ทฤษฎีบทลิมิตของค่ากลาง (The Central Limit Theorem)

- ทฤษฎีบทลิมิตของค่ากลาง (Central Limit Theorem หรือที่เรียกสั้นๆ ว่า CLT) เป็นทฤษฎีทางสถิติที่มีความสำคัญมากอันหนึ่ง ถึงแม้ว่าทฤษฎีบทนี้จะมีข้อจำกัดในกรณีทีกลุ่มตัวอย่างมีขนาดเล็ก (finite sample)
- ทฤษฎีบทนี้ตั้งอยู่บนพื้นฐานของการหาค่าลิมิต เมื่อกลุ่มตัวอย่างมีขนาดใหญ่มากพอ (large sample)
- ในปัจจุบัน ความสามารถของคอมพิวเตอร์ที่พัฒนาอย่างก้าวกระโดดได้ช่วยให้เราสามารถคำนวณหาการแจกแจงของค่าสถิติในกรณีที่ตัวอย่างมีขนาดจำกัด (finite sample) ได้สะดวกมากยิ่งขึ้น (ยกตัวอย่างเช่น วิธี bootstrapping)
- ทฤษฎีบทลิมิตของค่ากลาง (CLT) ก็ยังไปสิ่งที่นักสถิติหรือนักวิเคราะห์ข้อมูล ต้องทำความเข้าใจ เพราะเป็นรากฐานที่สำคัญ ที่นำไปสู่วิธีการทางสถิติและสูตรที่ใช้ในการคำนวณการแจกแจงของค่าสถิติในโปรแกรมทางสถิติที่ใช้อยู่ในปัจจุบัน

ทฤษฎีบทลิมิตของค่ากลาง (The Central Limit Theorem)

- ทฤษฎีบทนี้ถูกเรียกว่า ทฤษฎีบทลิมิตของค่ากลาง (CLT) ก็เพราะมันเกี่ยวข้องกับค่ากลาง ซึ่งในที่นี้หมายถึงค่าคาดหวังจากตัวอย่าง (sample mean) $\bar{X}_n = \frac{\sum_{i=1}^n X_i}{n}$
- ทฤษฎีบทนี้กล่าวว่า สำหรับตัวอย่างสุ่ม (random sample) ขนาด n ตัวอย่าง ที่ถูกสุ่มมาจากการแจกแจงที่มีค่าคาดหวัง μ และค่าความแปรปรวน σ^2 เราสามารถประมาณค่าการแจกแจงของค่าคาดหวังจากตัวอย่าง (sample mean) ได้โดยใช้การแจกแจงปกติ (normal distribution)
 - ▶ ค่าคาดหวังเท่ากับ μ และค่าความแปรปรวน $\frac{\sigma^2}{n}$
 - ▶ สุ่มตัวอย่าง n ตัวอย่างมาจากการแจกแจงปกติ (normal distribution)
 - ▶ การสุ่มจากการแจกแจงใดๆ ขอเพียงแค่ว่า เป็นการสุ่มอย่างอิสระจากการแจกแจงเดียวกัน

ทฤษฎี: ทฤษฎีบทลิมิตของค่ากลาง (The Central Limit Theorem) ของ Lindeberg and Levy

Theorem (Lindeberg and Levy)

ถ้าตัวแปรสุ่ม X_1, \dots, X_n เป็นตัวอย่างสุ่ม (random sample) ขนาด n ตัวอย่าง ซึ่งสุ่มมาจากการแจกแจงเดียวกัน ที่มีค่าคาดหวัง μ และค่าความแปรปรวน $\sigma^2 < \infty$ แล้ว สำหรับค่าคงที่ x ใดๆ

$$\lim_{n \rightarrow \infty} Pr \left(\frac{\bar{X}_n - \mu}{\frac{\sigma}{\sqrt{n}}} \leq x \right) = \Phi(x) \quad (10)$$

โดยที่ Φ แทนฟังก์ชันความน่าจะเป็นสะสม (C.D.F.) ของการแจกแจงปกติมาตรฐาน (standard normal distribution)

- ยิ่งไปกว่านั้น ในทางทฤษฎี เราสามารถเขียนทฤษฎีบทลิมิตของค่ากลาง (CLT) โดยใช้หลักการลู่เข้าเชิงการแจกแจง (convergence in distribution) ซึ่งมีนิยามดังต่อไปนี้

นิยาม: การลู่เข้าเชิงการแจกแจง (Convergence in Distribution)

Definition (Convergence in Distribution หรือ Asymptotic Distribution)

กำหนดให้ Y_1, Y_2, \dots เป็นอันดับของตัวแปรสุ่ม และ F_n แทนฟังก์ชันความน่าจะเป็นสะสม (C.D.F.) ของ Y_n สำหรับ $n = 1, 2, \dots$ และกำหนดให้ F^* เป็นฟังก์ชันความน่าจะเป็นสะสม (C.D.F.) อันหนึ่ง ดังนั้น อันดับของ Y_1, Y_2, \dots ลู่เข้าเชิงการแจกแจง (converge in distribution) ลู่ F^* ถ้า

$$\lim_{n \rightarrow \infty} F_n(y) = F^*(y) \quad (11)$$

สำหรับทุกๆ ค่า y ที่ $F^*(y)$ ต่อเนื่อง (continuous) และเพื่อความกระชับ เราอาจจะกล่าวสั้นๆ แทนได้ว่า Y_n ลู่เข้าเชิงความน่าจะเป็นสู่ F^* ซึ่งอาจจะเขียนแทนได้ด้วย

$$Y_n \xrightarrow{d} F^* \quad (12)$$

และเรียก F^* ว่าการแจกแจงที่ลิมิต (asymptotic distribution) ของ Y_n

- ทฤษฎีบทลิมิตของค่ากลาง (CLT) สำหรับตัวอย่างสุ่มสามารถเขียนใหม่ในรูปของการลู่เข้าเชิงการแจกแจงได้ดังต่อไปนี้

ทฤษฎี: ทฤษฎีบทลิมิตของค่ากลาง (The Central Limit Theorem) ของ Lindeberg and Levy

Theorem (Lindeberg and Levy)


ถ้าตัวแปรสุ่ม X_1, \dots, X_n เป็นตัวอย่างสุ่ม (random sample) ขนาด n ตัวอย่าง ซึ่งสุ่มมาจากการแจกแจงเดียวกัน ที่มีค่าคาดหวัง μ และค่าความแปรปรวน $\sigma^2 < \infty$ แล้ว สำหรับค่าคงที่ x ใดๆ

$$\sqrt{n} \left(\frac{\bar{X}_n - \mu}{\sigma} \right) \xrightarrow{d} N(0, 1) \quad (13)$$


- เพื่อให้เข้าใจทฤษฎีบทลิมิตของค่ากลาง (CLT) ได้ดี ขอนำเสนอผลการจำลอง (simulation) ทั้ง 1000 ครั้ง จากการแจกแจงรูปแบบต่างๆ ดังตัวอย่างต่อไปนี้

ตัวอย่าง: การทำ simulation ของฟังก์ชันการกระจายแบบ uniform:
 $f(x) = 1$ for $0 \leq x \leq 1$


uniform with n=1




uniform with n=10



uniform with n=100




uniform with n=10,000




ตัวอย่าง: การทำ simulation ของฟังก์ชันการกระจายแบบ log-normal :
 $\log X \sim N(0, 1)$ for $x > 0$


lognormal with n=1




lognormal with n=10



lognormal with n=100




lognormal with n=10,000




ตัวอย่าง: การทำ simulation ของฟังก์ชันการกระจายแบบ poisson:

$$f(x) = \frac{e^{-1}}{x!} \text{ for } x = 0, 1, 2, \dots$$


poisson with n=1




poisson with n=10



poisson with n=100




poisson with n=10,000




ตัวอย่าง: การทำ simulation ของฟังก์ชันการกระจายแบบ exponential:
 $f(x) = e^{-x}$ for $x \geq 0$


exponential with n=1




exponential with n=10



exponential with n=100



exponential with n=10,000



ทฤษฎีบทต่อไปนี้จะช่วยให้สามารถประยุกต์ทฤษฎีบทลิมิตของค่ากลาง (CLT) ได้กว้างขวางมากยิ่งขึ้น

ทฤษฎี: ทฤษฎีบทลิมิตของค่ากลาง (The Central Limit Theorem)

Theorem

ถ้า $X_n \xrightarrow{p} X$ แล้ว $X_n \xrightarrow{d} X$

Theorem

ถ้า $X_n \xrightarrow{d} c$ โดยที่ c เป็นค่าคงที่ แล้ว $X_n \xrightarrow{p} c$

Theorem

ถ้า $X_n \xrightarrow{d} X$ และ $Y_n \xrightarrow{p} 0$ แล้ว $X_n + Y_n \xrightarrow{d} X$

Theorem (Slutsky's Theorem)

กำหนดให้ X, X_n, A_n, B_n เป็นตัวแปรสุ่ม (random variable) ส่วน a และ b เป็นค่าคงที่ ดังนั้น

ถ้า $X_n \xrightarrow{d} X, A_n \xrightarrow{p} a$ และ $B_n \xrightarrow{p} b$ แล้ว

$$A_n + B_n X_n \xrightarrow{d} a + bX \quad (14)$$

ทฤษฎีบทลิมิตของค่ากลาง (The Central Limit Theorem)

Theorem

สมมติว่า $X_n \xrightarrow{d} X$ และ g เป็นฟังก์ชันที่ต่อเนื่องตลอดช่วงค่าจุน (support) ของ X แล้ว $g(X_n) \xrightarrow{d} g(X)$

- ในทางคณิตศาสตร์ ทฤษฎีบทนี้กล่าวว่า การลู่เข้าเชิงการแจกแจง (convergence in distribution) สามารถส่งผ่านฟังก์ชันต่อเนื่องได้ โดยมีทฤษฎีบทของ Slutsky (Slutsky's Theorem) เป็นกรณีพิเศษสำหรับฟังก์ชันเชิงเส้นซึ่งต่อเนื่องตลอดช่วงค่าจุน
- ถึงแม้ว่าทฤษฎีบทนี้จะช่วยให้สามารถหาการแจกแจงที่ลิมิตของฟังก์ชันต่อเนื่องของตัวแปรสุ่มที่ลู่เข้าเชิงการแจกแจงได้ แต่ในทางปฏิบัติก็ยังมีคามยุ่งยากพอสมควร เพราะต้องแปลงการแจกแจงของ X ให้เป็นการแจกแจงของ $g(X)$ ซึ่งก็ขึ้นอยู่กับรูปแบบของฟังก์ชัน g
- ในทางปฏิบัติ จึงนิยมใช้วิธีการเดลต้า (Delta method) ซึ่งสามารถประยุกต์ใช้กับการแจกแจงปกติได้อย่างสะดวก ดังแสดงในทฤษฎีบทต่อไปนี้

วิธีการเดลต้า (Delta method)

Theorem

สมมติว่า g เป็นฟังก์ชันที่หาค่าอนุพันธ์อันดับหนึ่ง (first-order derivative) ได้ที่จุด θ และค่าอนุพันธ์อันดับหนึ่ง $g'(\theta) \neq 0$ และ

$$\sqrt{n}(X_n - \theta) \xrightarrow{d} N(0, \sigma^2) \quad (15)$$

แล้ว

$$\sqrt{n}(g(X_n) - g(\theta)) \xrightarrow{d} N(0, [g'(\theta)]^2 \sigma^2) \quad (16)$$

- สังเกตว่าวิธีการเดลต้า (Delta method) นี้ใช้ได้กับการแจกแจงปกติ (normal distribution) และฟังก์ชันที่หาค่าอนุพันธ์อันดับหนึ่ง (first-order derivative) ไม่เท่ากับศูนย์ ณ จุดที่สนใจเท่านั้น

ตัวอย่าง: การประยุกต์ใช้วิธีการเดลต้า (Delta method)

Example

กำหนดให้ X_1, X_2, \dots, X_n เป็นตัวแปรสุ่ม ที่มี ค่าคาดหวัง คือ μ และความแปรปรวน คือ σ^2
จงหาว่า ฟังก์ชันการแจกแจง ของ $\frac{1}{\bar{X}_n}$

- วิธีการเดลต้า (Delta method) เรากำหนดให้

$$g(\bar{X}_n) = \frac{1}{\bar{X}_n} \quad \text{และ} \quad g'(\bar{X}_n) = - \left(\frac{1}{\bar{X}_n} \right)^2$$

- ดังนั้น

$$\begin{aligned} \sqrt{n} (g(X_n) - g(\theta)) &\xrightarrow{d} N(0, [g'(\theta)]^2 \sigma^2) \\ \sqrt{n} \left(\frac{1}{\bar{X}_n} - \frac{1}{\mu} \right) &\xrightarrow{d} N \left(0, \left[- \left(\frac{1}{\mu^2} \right) \right]^2 \sigma^2 \right) \end{aligned}$$

- สรุปได้ว่า $\frac{1}{\bar{X}_n}$ มีการแจกแจงปกติที่มีค่าคาดหวังคือ $\frac{1}{\mu}$ และความแปรปรวน คือ $\frac{\sigma^2}{n\mu^4}$