

หลักการประมาณด้วยความเป็นไปได้สูงสุด (Maximum Likelihood Estimation) และ โมเมนต์ (Method of Moments)

รศ.ดร. วีระชาติ กิเลนทอง
มหาวิทยาลัยหอการค้าไทย

©Kilenthong 2019

- หัวข้อนี้จะนำเสนอหลักการพื้นฐานของการประมาณค่า (estimation) โดยพิจารณาวิธีการประมาณค่าอีก 2 วิธี
 - ▶ วิธีการประมาณค่าด้วยความเป็นไปได้สูงสุด (Maximum Likelihood Estimation หรือเรียกสั้นๆ ว่า MLE)
 - ▶ วิธีการประมาณค่าด้วยโมเมนต์ (Method of Moments หรือเรียกสั้นๆ ว่า MM)

นิยาม: ฟังก์ชันความเป็นไปได้ (likelihood function)

- หลักการสำคัญของการประมาณค่าด้วยความเป็นไปได้สูงสุด (Maximum Likelihood Estimation หรือเรียกสั้นๆ ว่า MLE) คือ ข้อมูลที่ได้จากการสังเกตเกิดจากการสุ่มเลือกมาจากประชากรที่มีการแจกแจงที่ **ขึ้นอยู่กับค่าพารามิเตอร์เฉพาะค่าหนึ่ง** ซึ่งควรจะเป็นค่าที่ทำให้ความเป็นไปได้ (likelihood) ที่จะสุ่มเลือกได้ตัวอย่างดังกล่าวมีค่าสูงสุด

Definition

ฟังก์ชันความเป็นไปได้ (likelihood function) คือ ฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.) หรือ ฟังก์ชันความน่าจะเป็นร่วม (joint p.f.) $f(\mathbf{x}|\theta)$ โดยที่ $\mathbf{x} = (x_1, \dots, x_n)$ คือ ค่าที่เกิดขึ้นจริงที่ได้จากข้อมูล

นิยาม: ฟังก์ชันความเป็นไปได้ (likelihood function)

- รูปแบบของฟังก์ชันความเป็นไปได้ (likelihood function) ขึ้นอยู่กับ ข้อมูลที่ได้จากการสังเกต
 - ▶ หากตัวแปรที่เกี่ยวข้องเป็นแบบไม่ต่อเนื่อง (discrete) ฟังก์ชันความเป็นไปได้ (likelihood function) ก็จะอยู่ในรูปแบบฟังก์ชันความน่าจะเป็นร่วม (joint p.f.) ถึงแม้ว่าตัวแปรสุ่มพื้นฐานที่ระบุในแบบจำลองจะเป็นแบบต่อเนื่องก็ตาม
- อีกด้านหนึ่ง ฟังก์ชันความเป็นไปได้ (likelihood function) ก็เป็น ฟังก์ชันของ พารามิเตอร์ที่ต้องการทราบค่า θ โดยมองว่าค่าของ $\mathbf{x} = (x_1, \dots, x_n)$ เป็นเพียงค่าคงที่ซึ่ง ทราบค่าแล้วจากข้อมูลที่มีอยู่
- ตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE) หมายถึง การแก้ปัญหาการหาค่าสูงสุดซึ่งมีฟังก์ชันความเป็นไปได้ (likelihood function) เป็นฟังก์ชันจุดประสงค์ (objective function) และพารามิเตอร์ที่ต้องการทราบค่า θ เป็นตัวแปรที่ต้องเลือก

นิยาม: ตัวประมาณด้วยความเป็นไปได้สูงสุด (Maximum Likelihood Estimation)

Definition

พิจารณาข้อมูลที่สังเกตได้ (observed data) \mathbf{x} ชุดหนึ่ง และ $\hat{\theta}_{MLE}(\mathbf{x})$ เป็นคำตอบของปัญหาการหาค่าสูงสุด (maximization problem) ต่อไปนี้

$$f(\mathbf{x}|\hat{\theta}_{MLE}(\mathbf{x})) = \max_{\theta} f(\mathbf{x}|\theta) \quad (1)$$

หรือเขียนอีกรูปแบบหนึ่งได้เป็น

$$\hat{\theta}_{MLE}(\mathbf{x}) = \operatorname{argmax}_{\theta} f(\mathbf{x}|\theta) \quad (2)$$

แล้ว ฟังก์ชัน $\hat{\theta}_{MLE}(\mathbf{X})$ คือ ตัวประมาณค่า ด้วยความเป็นไปได้สูงสุด (Maximum Likelihood Estimator หรือเรียกสั้นๆ ว่า MLE) และ $\hat{\theta}_{MLE}(\mathbf{x})$ คือ ค่าประมาณด้วยความเป็นไปได้สูงสุดของ θ เมื่อข้อมูลที่ใช้ในการประมาณค่าคือ \mathbf{x}

การประมาณค่าด้วยความเป็นไปได้สูงสุด (Maximum Likelihood Estimation)

- ฟังก์ชันความเป็นไปได้ (likelihood function) มักอยู่ในรูปของ ผลคูณของฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) หรือฟังก์ชันความน่าจะเป็น (p.f.)
- เพื่อความสะดวกจึงมักจะ แปลงฟังก์ชันจุดประสงค์ (objective function) ให้อยู่ในรูปของลอการิทึม แทน ซึ่งจะอยู่ในรูปของผลบวกซึ่งจัดการได้ง่ายกว่ามาก และที่สำคัญยังได้คำตอบเท่าเดิม
- การแปลงค่าฟังก์ชันจุดประสงค์โดยใช้ ฟังก์ชันที่เพิ่มขึ้นทางเดียว (monotonically increasing) จะ **ไม่** ทำให้คำตอบของปัญหาการหาค่าสูงสุดเปลี่ยนไป

ตัวอย่าง: การประมาณค่าด้วยการแจกแจงแบบเบอร์นูลลี (Bernoulli distribution)

Example

พิจารณาตัวอย่าง X_1, \dots, X_n โดยที่ X_i มีการแจกแจงแบบเบอร์นูลลี (Bernoulli distribution) สำหรับพารามิเตอร์ θ ซึ่งเป็นสิ่งที่ต้องการประมาณค่า และกำหนดให้ $\mathbf{x} = (x_1, \dots, x_n)$ คือค่าที่เกิดขึ้นจริงที่ได้จากข้อมูล

- ฟังก์ชันความเป็นไปได้ (likelihood function) ในกรณีนี้เท่ากับ

$$\mathcal{L} = \prod_{i=1}^n \theta^{x_i} (1 - \theta)^{1-x_i} \quad (3)$$

- ฟังก์ชันลอการิทึมของความเป็นไปได้ (log-likelihood function) เท่ากับ

$$\begin{aligned} \log \mathcal{L} &= \sum_{i=1}^n [x_i \log \theta + (1 - x_i) \log (1 - \theta)] \\ &= \left(\sum_{i=1}^n x_i \right) \log \theta + \left(n - \sum_{i=1}^n x_i \right) \log (1 - \theta) \end{aligned}$$

สรุป: การประมาณค่าด้วยการแจกแจงแบบเบอร์นูลลี (Bernoulli distribution)

Example

- ปัญหาการหาค่าสูงสุดในกรณีคือ

$$\max_{\theta} \left(\sum_{i=1}^n x_i \right) \log \theta + \left(n - \sum_{i=1}^n x_i \right) \log (1 - \theta)$$

- เราสามารถหาคำตอบได้โดยการกำหนดให้ค่าอนุพันธ์อันดับที่หนึ่งของฟังก์ชันจุดประสงค์ (objective function) หรือฟังก์ชันล็อกการริ้มของความเป็นไปได้ (log-likelihood function) เท่ากับศูนย์ หรือที่เรียกว่า เงื่อนไขอันดับที่หนึ่ง (first-order conditions)

$$\begin{aligned} \frac{\partial \log \mathcal{L}}{\partial \theta} \Big|_{\hat{\theta}_{MLE}(\mathbf{x})} = 0 &\Rightarrow \left(\sum_{i=1}^n x_i \right) \frac{1}{\hat{\theta}_{MLE}(\mathbf{x})} - \left(n - \sum_{i=1}^n x_i \right) \frac{1}{1 - \hat{\theta}_{MLE}(\mathbf{x})} = 0 \\ &\Rightarrow \hat{\theta}_{MLE}(\mathbf{x}) = \frac{\sum_{i=1}^n x_i}{n} = \bar{x}_n \end{aligned}$$

- ตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE): $\hat{\theta}_{MLE}(\mathbf{X}) = \frac{\sum_{i=1}^n X_i}{n} = \bar{X}_n$
- ตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE) $\hat{\theta}_{MLE}(\mathbf{X})$ เป็น ฟังก์ชันของตัวอย่าง \mathbf{X} แต่หลังจากนี้ต่อไป จะขอไม่เขียนส่วนนี้ ทั้งนี้เพื่อความกระชับ โดยจะเขียนสั้นๆ เป็น $\hat{\theta}_{MLE}$ แต่ขอให้เข้าใจว่ามันคือ $\hat{\theta}_{MLE}(\mathbf{X})$

ตัวอย่าง: การประมาณค่าด้วยการแจกแจงแบบปกติ (normal distribution)

Example

สมมติให้ X_1, \dots, X_n เป็นกลุ่มตัวอย่างสุ่มที่เลือกมาจากการแจกแจงแบบปกติ (normal distribution) ที่มีค่าคาดหวัง μ และค่าความแปรปรวน σ^2 โดยทั้งสองเป็นพารามิเตอร์ที่ต้องการทราบค่า และกำหนดให้ $\mathbf{x} = (x_1, \dots, x_n)$ คือค่าที่เกิดขึ้นจริงที่ได้จากข้อมูล

- ฟังก์ชันความเป็นไปได้ (likelihood function) ในกรณีนี้เท่ากับ

$$\mathcal{L} = \prod_{i=1}^n \phi\left(\frac{x_i - \mu}{\sigma} \mid \mu, \sigma^2\right) \quad (4)$$

- ฟังก์ชันลอการิทึมของความเป็นไปได้ (log-likelihood function) เท่ากับ

$$\log \mathcal{L} = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \quad (5)$$

- ปัญหาการหาค่าสูงสุดในกรณีคือ

$$\max_{\mu, \sigma^2} -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

สรุป: การประมาณค่าด้วยการแจกแจงแบบปกติ (normal distribution)

Example

- เงื่อนไขอันดับที่หนึ่ง (first-order conditions) ของปัญหานี้เท่ากับ

$$\left. \frac{\partial \log \mathcal{L}}{\partial \mu} \right|_{\hat{\mu}_{MLE}, \hat{\sigma}_{MLE}^2} = 0 \Rightarrow \frac{1}{\hat{\sigma}_{MLE}^2} \sum_{i=1}^n (x_i - \hat{\mu}_{MLE}) = 0 \quad (6)$$

$$\left. \frac{\partial \log \mathcal{L}}{\partial \sigma^2} \right|_{\hat{\mu}_{MLE}, \hat{\sigma}_{MLE}^2} = 0 \Rightarrow -\frac{n}{2\hat{\sigma}_{MLE}^2} + \frac{1}{2(\hat{\sigma}_{MLE}^2)^2} \sum_{i=1}^n (x_i - \hat{\mu}_{MLE})^2 = 0 \quad (7)$$

- ระบบสมการข้างต้นมีสองตัวแปร และสามารถหาคำตอบได้เป็น

$$\hat{\mu}_{MLE} = \frac{\sum_{i=1}^n x_i}{n} = \bar{x}_n, \quad \hat{\sigma}_{MLE}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2 \quad (8)$$

- เรามักเรียกตัวประมาณค่าสำหรับค่าคาดหวัง \bar{x}_n ว่า ค่าคาดหวังจากตัวอย่าง (sample mean)
- ตัวประมาณค่าสำหรับค่าความแปรปรวน $\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2$ ว่า ค่าความแปรปรวนจากตัวอย่าง (sample variance) ซึ่งแตกต่างจาก $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$ ตรงที่ส่วนตัวหารที่ $\hat{\sigma}_{MLE}^2$ นั้นหารด้วย n แต่ S_n^2 หารด้วย $n-1$
- ตัวประมาณค่าทั้งสองของความแปรปรวนนี้มี คุณสมบัติคู่เข้าเชิงความน่าจะเป็นที่เหมือนกัน เพราะ n และ $n-1$ นั้นมีพฤติกรรมที่ลิมิตเหมือนกัน แต่มี คุณสมบัติความไม่เียงเบน (unbiasness) ต่างกัน อภิปรายในรายละเอียดในหัวข้อถัดไป

ตัวอย่าง: การประมาณค่าด้วยการแจกแจงแบบเอกรูป (uniform distribution)

Example

สมมติให้ X_1, \dots, X_n เป็นกลุ่มตัวอย่างสุ่มที่เลือกมาจากการแจกแจงแบบเอกรูป (uniform distribution) ในช่วง $[0, c]$ โดยในที่นี้ c คือพารามิเตอร์ที่ต้องการทราบค่า และกำหนดให้ $\mathbf{x} = (x_1, \dots, x_n)$ คือค่าที่เกิดขึ้นจริงที่ได้จากข้อมูล

- ฟังก์ชันความเป็นไปได้ (likelihood function) ในกรณีนี้เท่ากับ

$$\mathcal{L} = \prod_{i=1}^n \frac{1}{c} = \frac{1}{c^n}, \text{ สำหรับ } 0 \leq x_i \leq c \text{ สำหรับทุก } i = 1, \dots, n \quad (9)$$

- ส่วนกรณีอื่นๆ $\mathcal{L} = 0$ ปัญหาการหาค่าสูงสุดในกรณีคือ

$$\max_c \frac{1}{c^n}, \text{ โดยที่ } 0 \leq x_i \leq c \text{ สำหรับทุก } i = 1, \dots, n$$

สรุป: การประมาณค่าด้วยการแจกแจงแบบเอกกรุป (uniform distribution)

- ปัญหานี้เป็นปัญหาการหาค่าสูงสุด แบบมีข้อจำกัด (constrained optimization problem)
 - ▶ หากไม่มีข้อจำกัด ค่าตอบของ c ที่ทำให้ค่าฟังก์ชันความเป็นไปได้ (likelihood function) มีค่าสูงสุดคือ $c = 0$
 - ▶ แต่จากข้อจำกัด $0 \leq x_i \leq c$ ทำให้ค่า c จะต้องไม่น้อยกว่าค่า x_i แต่ละค่า ซึ่งทำให้ $c = 0$ เป็นไปไม่ได้ (ยกเว้น $X_i = 0$ ทุกค่า ซึ่งเป็นกรณีที่ไม่น่าสนใจ)
 - ▶ ค่าตอบของปัญหานี้จึงถูกกำหนดโดยข้อจำกัดเป็นหลัก นั่นคือ $\hat{c}_{MLE} \geq x_i$ สำหรับทุก $i = 1, \dots, n$
 - ▶ แต่ในขณะเดียวกันฟังก์ชันวัตถุประสงค์ก็ต้องการให้ค่า \hat{c}_{MLE} มีค่าต่ำที่สุดเท่าที่จะเป็นไปได้ ดังนั้น คำตอบ ที่ได้คือ $\hat{c}_{MLE} = \max(x_1, \dots, x_n)$
- บทเรียนทางคณิตศาสตร์อันหนึ่งในตัวอย่างนี้คือ บางครั้งเราอาจจะ **ไม่สามารถแก้ปัญหาการหาค่าสูงสุดแบบมีข้อจำกัด (constrained optimization problem) ได้โดยใช้ เงื่อนไขอันดับที่หนึ่ง (first-order conditions)** โดยตรงเหมือนกับตัวอย่างที่ผ่านมา
- ทั้งนี้เพราะบางครั้ง คำตอบที่ได้อาจจะอยู่บนขอบ (boundary) ของขอบเขตที่เป็นไปได้ ในขณะที่ เงื่อนไขอันดับที่หนึ่ง (first-order conditions) ใช้ได้กับกรณีที่คำตอบอยู่ภายในขอบเขตที่เป็นไปได้ (interior solution)

ทฤษฎี: คุณสมบัติไม่แปรเปลี่ยน (invariance property) ของตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE)

- ตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE) มีคุณสมบัติอย่างหนึ่งที่สำคัญที่ช่วยให้สามารถประยุกต์ใช้ได้อย่างกว้างขวาง โดยเรามักเรียกคุณสมบัตินี้ว่า **คุณสมบัติไม่แปรเปลี่ยน (invariance property)** ซึ่งมีความหมายดังแสดงในทฤษฎีบทต่อไปนี้

Theorem

ถ้า $\hat{\theta}_{MLE}$ คือตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE) ของ θ และ g เป็นฟังก์ชันที่กำหนดโดย $\gamma = g(\theta)$ แล้ว $g(\hat{\theta}_{MLE})$ เป็นตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE) ของ γ

การพิสูจน์: คุณสมบัติไม่แปรเปลี่ยน (invariance property) ของตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE)

Proof.

- เพื่อความสะดวก ขอนำเสนอ การพิสูจน์ในกรณีที่ g เป็นฟังก์ชันหนึ่งต่อหนึ่ง (one-on-one) เท่านั้น โดยเริ่มจาก การที่ $\hat{\theta}_{MLE}$ เป็นตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE) ของ θ หมายความว่า

$$\hat{\theta}_{MLE} = \operatorname{argmax}_{\theta} \prod_{i=1}^n f_i(x_i|\theta) \quad (10)$$

- การที่ g เป็นฟังก์ชันหนึ่งต่อหนึ่ง (one-on-one) หมายความว่า เราสามารถใช้ฟังก์ชันส่วนกลับได้เป็น $\theta = g^{-1}(\gamma)$ ดังนั้น เราสามารถเขียนฟังก์ชันความเป็นไปได้ (likelihood function) ในรูปฟังก์ชันของ γ ได้เป็น

$$\mathcal{L}(\gamma|\mathbf{x}) = \operatorname{argmax}_{\gamma} \prod_{i=1}^n f_i(x_i|g^{-1}(\gamma)) \quad (11)$$

- ดังนั้น เนื่องจากฟังก์ชันความเป็นไปได้ (likelihood function) ในสมการที่ 10 มีค่าสูงสุดเมื่อพารามิเตอร์ θ มีค่าเท่ากับ $\hat{\theta}_{MLE}$ ดังนั้น ฟังก์ชันความเป็นไปได้ (likelihood function) ในสมการที่ 11 จะมีค่าสูงสุด ถ้าพารามิเตอร์ γ มีค่าเท่ากับ $\hat{\gamma}_{MLE}$ ที่ทำให้ $\hat{\theta}_{MLE} = g^{-1}(\hat{\gamma}_{MLE})$ นั่นคือ $\hat{\gamma}_{MLE} = g(\hat{\theta}_{MLE})$
- ส่วนในกรณีที่ฟังก์ชัน g ไม่ใช่ฟังก์ชันหนึ่งต่อหนึ่ง ก็สามารถพิสูจน์ได้ด้วยวิธีการที่คล้ายคลึงกัน แต่ต้องตระหนักว่า สิ่งที่ต้องการคือค่าที่ต้องการนำไปสู่ค่าสูงสุด ถึงแม้ว่าอาจมีค่าพารามิเตอร์ที่ทำให้ได้ค่าสูงสุดหลายค่า



ตัวอย่าง: คุณสมบัติไม่แปรเปลี่ยน (invariance property) ของตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE)

Example

สมมติให้ X_1, \dots, X_n เป็นกลุ่มตัวอย่างสุ่มที่เลือกมาการแจกแจงแบบเอกรูป (uniform distribution) ในช่วง $[0, c]$ เช่นเดียวกับตัวอย่างที่แล้วซึ่งพิสูจน์แล้วว่า ตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE) ของ c มีค่าเท่ากับ $\hat{c}_{MLE} = \max(X_1, \dots, X_n)$

เราสามารถประยุกต์ใช้คุณสมบัติไม่แปรเปลี่ยน (invariance property) เพื่อหา ตัวประมาณค่าของความแปรปรวน (variance) ของ X ได้โดยเริ่มจากการที่ทราบว่า $\text{Var}[X] = \frac{c^2}{12}$ ในขณะเดียวกันเราก็ตราพบว่า ตัวประมาณค่า $\hat{c}_{MLE} = \max(X_1, \dots, X_n)$ ดังนั้น

$$\widehat{\text{Var}}[X] = \frac{\hat{c}_{MLE}^2}{12} = \frac{\max(X_1, \dots, X_n)^2}{12}$$

ความคงเส้นคงวา (consistency) ของตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE)

- คุณสมบัติอันหนึ่งที่สำคัญของ ตัวประมาณค่า ด้วยความเป็นไปได้สูงสุด (MLE) คือ ความคงเส้นคงวา (consistency) นั่นคือ เมื่อ กลุ่มตัวอย่างมีขนาดใหญ่มากพอ แล้ว ตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE) จะมี ค่าใกล้เคียงกับค่าที่แท้จริง
- ทฤษฎีบทและการพิสูจน์ด้านล่างนี้ตัดแปลงมาจาก Hogg et al.(2005) โดยเริ่มจากการกำหนดเงื่อนไขปกติ (regularity conditions) ต่อไปนี้
 - RC1 ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) $f(x, \theta)$ แตกต่างกันชัดเจน หมายความว่า ถ้า $\theta \neq \theta'$ แล้ว $f(x, \theta) \neq f(x, \theta')$
 - RC2 ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) $f(x, \theta)$ มีส่วนค้ำจุน (support) S เหมือนกันสำหรับทุกๆ ค่าพารามิเตอร์ θ
 - RC3 ค่าที่แท้จริง θ_0 ของพารามิเตอร์ θ เป็น จุดภายใน (interior point) ของเซต Θ

ทฤษฎี: ความคงเส้นคงวา (consistency) ของตัวประมาณค่าด้วยความ
เป็นไปได้สูงสุด (MLE)

Theorem

สมมติว่าตัวแปรสุ่ม X_1, \dots, X_n สอดคล้องกับเงื่อนไขปกติ (regularity conditions) RC1-RC3 โดยที่ θ_0 เป็นค่าพารามิเตอร์ที่แท้จริง (true parameter) และ $f(x|\theta)$ สามารถหาค่าอนุพันธ์เทียบกับ θ ได้ แล้ว คำตอบของสมการความเป็นไปได้ (likelihood equation) $\hat{\theta}$ ซึ่งสอดคล้องกับสมการต่อไปนี้

$$\frac{\partial \log \mathcal{L}(\hat{\theta}|\mathbf{x})}{\partial \theta} = 0 \quad (12)$$

จะมีความคงเส้นคงวา (consistent) นั่นคือ $\hat{\theta} \xrightarrow{P} \theta_0$


ตัวอย่าง: ความคงเส้นคงวา (consistency) ของตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE)

Example

พิจารณาตัวอย่าง X_1, \dots, X_n โดยที่ X_i มีการแจกแจงแบบเบอร์นูลลี (Bernoulli distribution) สำหรับพารามิเตอร์ θ ดังนั้นตัวประมาณค่าด้วยความเป็นไปได้สูงสุด (MLE)

$$\hat{\theta}_{MLE}(X) = \frac{\sum_{i=1}^n X_i}{n} = \bar{x}_n \quad (13)$$

- เราสุ่มตัวอย่างจากการแจกแจงแบบเบอร์นูลลี (Bernoulli distribution) โดยกำหนดพารามิเตอร์ $\theta = 0.4$ แล้วนำข้อมูลจากการสุ่มนั้นมาประมาณพบว่า



บทนำ: การประมาณค่าด้วยโมเมนต์ (Method of Moments)

- การประมาณค่าด้วยโมเมนต์ (method of moments หรือเรียกสั้นๆ ว่า MM) เป็นวิธีประมาณค่าอย่างง่ายที่อาศัยหลักการพื้นฐานที่ว่า ค่าคาดหวังจากตัวอย่าง (sample mean) \bar{X}_n คือตัวประมาณค่า (estimator) ที่ดีสำหรับค่าคาดหวัง (population mean) $E[X]$ ซึ่งเป็นหลักการที่ประยุกต์ใช้อย่างกว้างขวาง แม้แต่ในกรณีของการประมาณค่าที่ซับซ้อน
- ข้อดีอีกอย่างหนึ่งของการประมาณค่าด้วยโมเมนต์ (MM) ก็คือการศึกษาหาตัวประมาณค่า (estimator) ได้ค่อนข้างแน่นอน ซึ่งต่างจากวิธีการประมาณค่าด้วยความเป็นไปได้สูงสุด (Maximum Likelihood Estimation หรือเรียกสั้นๆ ว่า MLE) ที่อาจจะไม่สามารถหาตัวประมาณค่าได้ (estimator)

การประมาณค่าด้วยโมเมนต์ (Method of Moments)

- กำหนดให้ X_1, \dots, X_n เป็น ตัวอย่างที่สุ่มมาจากประชากร ที่มีฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) หรือฟังก์ชันความน่าจะเป็น (p.f.) $f(\mathbf{x}|\theta_1, \dots, \theta_k)$
- วิธีการประมาณค่าด้วยโมเมนต์ (MM) ของพารามิเตอร์ $\theta = (\theta_1, \dots, \theta_k)$ เริ่มได้ด้วยการกำหนดให้ k โมเมนต์จากตัวอย่าง (sample moments) มีค่าเท่ากับ k โมเมนต์จากประชากร (population moments) ซึ่งเป็นฟังก์ชันของพารามิเตอร์ θ
- ผลลัพธ์จากขั้นตอนนี้คือ ระบบสมการของ k สมการที่มีตัวไม่ทราบค่า (unknown) ทั้งหมด k ตัว ขั้นตอนสุดท้ายคือการแก้ระบบสมการนี้ โดยที่ผลลัพธ์ที่ได้จะอยู่ในรูปของฟังก์ชัน $\theta_j(X_1, \dots, X_n)$

โมเมนต์จากตัวอย่าง (sample moments)

- กำหนดให้ $M_j = \frac{1}{n} \sum_{i=1}^n X_i^j$ แทน โมเมนต์จากตัวอย่าง (sample moments) อันดับที่ $j = 1, \dots, k$ และ $\mu_j(\theta_1, \dots, \theta_k) = E[X^j]$ แทน โมเมนต์จากประชากร (population moments) อันดับที่ $j = 1, \dots, k$
- การประมาณค่าด้วยโมเมนต์ (MM) คือการแก้ระบบสมการต่อไปนี้

$$\frac{1}{n} \sum_{i=1}^n X_i = \mu_1(\theta_1, \dots, \theta_k) \quad (14)$$

$$\frac{1}{n} \sum_{i=1}^n X_i^2 = \mu_2(\theta_1, \dots, \theta_k) \quad (15)$$

$$\vdots \quad (16)$$

$$\frac{1}{n} \sum_{i=1}^n X_i^k = \mu_k(\theta_1, \dots, \theta_k) \quad (17)$$

- นี่คือระบบสมการที่มีทั้งหมด k สมการและมีตัวไม่ทราบค่าทั้งหมด k ตัว

ตัวอย่าง: การประมาณค่าด้วยโมเมนต์ (Method of Moments)

Example

สมมติว่า เป็นตัวอย่างสุ่มที่มีการแจกแจงเหมือนกันและเป็นอิสระต่อกัน (i.i.d.) แบบปกติ $N(\mu, \sigma^2)$ นั่นคือ พารามิเตอร์ที่ต้องการทราบค่าในตัวอย่างนี้มีทั้งหมด 2 ตัวคือ $\theta_1 = \mu$ $\theta_2 = \sigma^2$

- เราจำเป็นต้องใช้โมเมนต์ที่หนึ่งและโมเมนต์ที่สอง

$$\frac{1}{n} \sum_{i=1}^n X_i = \mu \quad , \quad \frac{1}{n} \sum_{i=1}^n X_i^2 = E[X^2] = \sigma^2 + \mu^2$$

- ตัวประมาณค่าด้วยโมเมนต์ (MM estimators) ในกรณีนี้เท่ากับ

$$\mu = \frac{1}{n} \sum_{i=1}^n X_i \equiv \bar{X} \quad , \quad \sigma^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

- ตัวประมาณค่าสำหรับค่าคาดหวังและค่าความแปรปรวนที่ใช้กันอยู่ทั่วไป อาจจะแตกต่างบ้างเล็กน้อยในกรณีของค่าความแปรปรวนที่หารด้วย n ไม่ใช่ $n - 1$
- ความแตกต่างตรงนี้มีผลต่อความเบี่ยงเบน (bias) ของตัวประมาณค่าในทางทฤษฎี แต่ในทางปฏิบัติหาก n มีค่ามากพอแล้ว ค่าประมาณที่ได้จะมีค่าใกล้เคียงกันมาก

การประมาณค่าด้วยโมเมนต์ (Method of Moments)

- อย่างไรก็ตาม วิธีการประมาณค่าด้วยโมเมนต์ (MM) ก็มีจุดอ่อน ทั้งนี้ส่วนหนึ่งเป็นเพราะโมเมนต์เพียงไม่กี่อันอาจจะ**ไม่สามารถบอกคุณสมบัติของการแจกแจงได้ดีพอ** เพราะหากต้องการให้ครอบคลุมทั้งหมดต้องใช้โมเมนต์ทุกอัน
- ทฤษฎีบทต่อไปนี้จะสรุปว่า ตัวประมาณค่าด้วยโมเมนต์ (MM) มีความคงเส้นคงวา (consistent) นั่นคือ เมื่อจำนวนตัวอย่างมากพอแล้ว ค่าประมาณด้วยโมเมนต์ (MM) จะมีค่าใกล้เคียงกับค่าพารามิเตอร์ที่แท้จริง (true parameter)

ทฤษฎี: ความคงเส้นคงวา (consistency) ของการประมาณค่าด้วยโมเมนต์ (Method of Moments)

Theorem

สมมติว่าตัวแปรสุ่ม X_1, \dots, X_n ที่เป็นอิสระต่อกันและมีการแจกแจงเหมือนกัน (i.i.d.) โดยมี θ_0 เป็นค่าพารามิเตอร์ที่แท้จริง (true parameter) ซึ่งมีทั้งหมด k ตัว และสมมติว่า k โมเมนต์ของการแจกแจงหาค่าได้และมีค่าจำกัด แล้ว ตัวประมาณค่าด้วยโมเมนต์ (MM) จะมีความคงเส้นคงวา (consistent) นั่นคือ $\hat{\theta} \xrightarrow{P} \theta_0$

การพิสูจน์: ความคงเส้นคงวา (consistency) ของการประมาณค่าด้วยโมเมนต์ (Method of Moments)

Proof.

กฎว่าด้วยตัวอย่างขนาดใหญ่ (Law of Large Numbers) ทำให้สรุปได้ว่า สำหรับค่าจำนวนเต็ม $0 < j \leq k$

$$plim M_j = plim \frac{1}{n} \sum_{i=1}^n X_i^j = E[X_i^j]$$

ซึ่งมีค่าเท่ากับ $\mu_j(\theta_0)$ ในขณะเดียวกัน เมื่อเราประยุกต์ใช้การลู่เข้าเชิงความน่าจะเป็นกับระบบสมการที่ (15)-(18) จะสามารถสรุปได้ว่า

$$plim M_j = plim \mu_j(\hat{\theta}) = \mu_j(plim \hat{\theta})$$

ดังนั้นเราจึงสามารถสรุปได้ว่า

$$\mu_j(plim \hat{\theta}) = \mu_j(\theta_0) \Rightarrow plim \hat{\theta} = \theta_0$$

ตัวอย่างความคงเส้นคงวา (consistency) ของการประมาณค่าด้วยโมเมนต์ (Method of Moments)

Example

จากตัวอย่างที่แล้ว ถ้าเรารวมตัวอย่างที่มีการแจกแจงเหมือนกันและเป็นอิสระต่อกัน (i.i.d.) แบบปกติ $N(\mu, \sigma^2)$ ดังนั้น ตัวประมาณค่าด้วยโมเมนต์ (MM estimators) ในกรณีนี้เท่ากับ

$$\mu = \frac{1}{n} \sum_{i=1}^n X_i \equiv \bar{X} \quad , \quad \sigma^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

- ถ้าตัวอย่างที่สุ่ม คือ การแจกแจงเหมือนกันและเป็นอิสระต่อกัน (i.i.d.) แบบปกติ ที่มี $\mu = 50$ และ $\sigma^2 = 50$

