



บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

2.1 แนวคิดและทฤษฎี

2.1.1 การสุ่มตัวอย่างแบบฮิตแอนด์รัน (Hit-and-Run Sampler)

ขั้นตอนวิธีของการสุ่มตัวอย่างแบบฮิตแอนด์รัน ถูกนำเสนอโดย Smith R.L. โดยเป็นการสร้างลำดับของจุดตัวอย่างซึ่งผ่านการแจกแจงแบบสม่ำเสมอ (uniform distribution) บนบริเวณเปิดที่มีขอบเขตจำกัด \mathbb{R}^k ใดๆ ซึ่งต่อมาได้ถูกทำให้สามารถสร้างลำดับของจุดตัวอย่างที่มีการแจกแจงที่ต่อเนื่องของหลายตัวแปรใดๆ ได้ (Bélisle C.J.P., Romeijn H.E. and Smith R.L.(1993) และ Romeijn H.E. and Smith R.L.(1994)) โดยการสุ่มตัวอย่างแบบฮิตแอนด์รันนี้จัดว่าเป็นหนึ่งในวิธีที่เร็วที่สุดในการสร้างจุดตัวอย่างในหลายมิติบนบริเวณรูปร่างนูน (Lovász L.(1998))

สำหรับการแจกแจงเป้าหมาย (target distribution) ทั่วไป การสุ่มตัวอย่างแบบฮิตแอนด์รันจะเป็นดังนี้

ให้ $S \subset \mathbb{R}^k$ และให้การแจกแจงเป้าหมายมีฟังก์ชันความน่าจะเป็น π บน S

สร้าง X_n ด้วยขั้นตอนวิธี ดังนี้

กำหนด $n = 0$ และ $X_n = x_0 \in S$

1.) ที่ $x = x_n \in S$ สุ่มเลือกทิศทาง d บนพื้นผิวทรงกลมรัศมี 1 หน่วย ลากเส้นตรง L_n ผ่าน x และตัดกับ S

$$L_n = S \cap \{l : l = x + \lambda d, \lambda \in \mathbb{R}\}$$

2.) สุ่มเลือกจุด x_{n+1} บนเส้นตรง L_n ด้วยการแจกแจงแบบ π โดยมีเงื่อนไขบน L_n

3.) เพิ่ม n เป็น $n + 1$ และกลับไป 1.)

2.1.2 การสุ่มตัวอย่างแบบกิบส์ (Gibbs Sampler)

การสุ่มตัวอย่างแบบกิบส์ เป็นขั้นตอนวิธีในการสร้างลำดับของจุดตัวอย่างจากฟังก์ชันการแจกแจงร่วม ของตัวแปรสุ่มตั้งแต่ 2 ตัวขึ้นไป ขั้นตอนวิธีของการสุ่มตัวอย่างแบบกิบส์ ถูกอธิบายโดย Stuart and Donald Geman ในปีค.ศ.1984

สำหรับการแจกแจงเป้าหมายทั่วไป การสุ่มตัวอย่างแบบกิบส์จะเป็นดังนี้

ให้ S เป็นปริภูมิสถานะของ $\underline{X} = (X^{(1)}, \dots, X^{(k)})$

ให้ π เป็นการแจกแจงเป้าหมาย ซึ่งมีฟังก์ชันความน่าจะเป็น $\pi'(x^{(1)}, \dots, x^{(k)})$

ให้ $\underline{X}^{(-i)} = (X^{(1)}, \dots, X^{(i-1)}, X^{(i+1)}, \dots, X^{(k)})$ เป็นเวกเตอร์ \underline{X} ซึ่งไม่มี $X^{(i)}$

สมมติว่า เราสามารถสุ่มตัวอย่างจาก full conditional distribution $\pi'(x^{(i)} | \underline{x}^{(-i)})$

ขั้นตอนวิธีของการสุ่มตัวอย่างแบบกิบส์มีดังนี้

กำหนด $n = 0$ และเริ่มต้นที่ $\underline{X}_0 = (X_0^{(1)}, \dots, X_0^{(k)})$

- 1.) สุ่มตัวอย่าง j แจกแจงแบบสม่ำเสมอ บน $\{1, \dots, k\}$
- 2.) สุ่มตัวอย่าง $X_{n+1}^{(j)}$ จาก $\pi'(x_n^{(j)} | \underline{x}_n^{(-j)})$
- 3.) ให้ $\underline{X}_{n+1} = (X_n^{(1)}, \dots, X_{n+1}^{(j)}, \dots, X_n^{(k)})$ เพิ่ม n เป็น $n + 1$ และกลับไป 1.)

2.1.3 วิธีค่าเฉลี่ยกลุ่ม (Batch Means)

วิธีค่าเฉลี่ยกลุ่ม เป็นวิธีการหนึ่งที่ใช้ประมาณค่าคาดหวัง โดยให้การคำนวณ Monte Carlo standard error (MCSE) สมมติว่าเราสนใจประมาณค่าคาดหวัง $E_\pi(g(\underline{X}))$ เมื่อ \underline{X} มีการแจกแจง π

ขั้นตอนของวิธีค่าเฉลี่ยกลุ่ม มีดังนี้

1.) จำลองลูกโซ่มาร์คอฟ $\{X_i, i = 1, 2, \dots, n\}$ จำนวน $n = ab$ รอบ โดยที่ a และ b เป็นจำนวนเต็ม a เป็นจำนวนกลุ่ม และแต่ละกลุ่มมีจำนวน b

2.) หาค่าเฉลี่ยของตัวอย่าง ในกลุ่มที่ j

$$\bar{y}_j = \frac{\sum_{i=(j-1)b+1}^{jb} g(x_i)}{b}$$

3.) ให้ $\sigma_g^2 = \frac{b}{a-1} \sum_{j=1}^a (\bar{Y}_j - \bar{g}_n)^2$ โดยที่ $\bar{g}_n = \frac{\sum_{j=1}^a \bar{Y}_j}{a}$

จะได้ว่า ค่าประมาณของ Monte Carlo standard error คือ $\frac{\hat{\sigma}_g}{\sqrt{n}}$

4.) ทำการจำลองจนกระทั่ง $t_{\frac{\alpha}{2}, (a-1)} \frac{\hat{\sigma}_g}{\sqrt{n}}$ มีค่าน้อยกว่าความคลาดเคลื่อนที่กำหนด

2.1.4 ค่า MPSRF ของ บรูคส์-เกลแมน (Brooks–Gelman MPSRF)

การวิเคราะห์ของเกลแมนกับรูบิน (The Gelman-Rubin Diagnostic หรือ GRD) ถูกนำเสนอโดย Gelman and Rubin (1992) เป็นหนึ่งในวิธีที่ได้รับความนิยมที่สุดในการวิเคราะห์การลู่เข้าของลูกโซ่มาร์คอฟมอนติคาร์โล ได้ถูกปรับปรุงใหม่และนำเสนอเพิ่มเติมโดย Brooks and Gelman (1998)

ขั้นตอนของวิธีของเกลแมนกับรูบิน มีดังนี้

1.) ทำการจำลองลูกโซ่มาร์คอฟที่อิสระกันจำนวน m ลูกโซ่ (m independent parallel Markov Chains) $m \geq 2$ ซึ่งมีการแจกแจง π แต่ละลูกโซ่มีความยาว $2l$ ดังนั้นต้องทำการจำลองทั้งหมด $2lm$ รอบ Gelman and Rubin (1992) ได้แนะนำว่า การจำลอง l ค่าแรก ให้ตัดทิ้งไป และทำการอนุมานบนการจำลอง l ค่าสุดท้าย สำหรับลูกโซ่ที่ j แทนด้วย $\{X_{1j}, X_{2j}, \dots, X_{lj}\}$ โดยที่ $j = 1, 2, \dots, m$

2.) ให้ $Y_{ij} = g(X_{ij})$ ทำการคำนวณค่า

ความแปรปรวนระหว่างลูกโซ่ (between-chain variance)

$$\frac{B}{l} = \frac{1}{m-1} \sum_{j=1}^m (\bar{Y}_j - \bar{Y}_{..})^2$$

ค่าเฉลี่ยของความแปรปรวนภายในลูกโซ่ (the average of the m within-chain variance)

$$W = \frac{1}{m} \sum_{j=1}^m s_j^2$$

$$\text{โดยที่ } \bar{Y}_j = \frac{1}{l} \sum_{i=1}^l Y_{ij}, \bar{Y}_{..} = \frac{1}{m} \sum_{j=1}^m \bar{Y}_j \text{ และ } s_j^2 = \frac{1}{(l-1)} \sum_{i=1}^l (Y_{ij} - \bar{Y}_j)^2$$

$\bar{Y}_{..}$ เป็นผลการประมาณแบบจุดของ $E_{\pi}g$

3.) ประมาณค่าความแปรปรวนเป้าหมาย (target variance) โดยการเฉลี่ยถ่วงน้ำหนัก (weighted average) ค่า W และ B ได้เป็นดังนี้

$$\hat{\sigma}_+^2 = \frac{l-1}{l} W + \frac{1}{l} B$$

$$4.) \text{ ให้ } \hat{V} = \hat{\sigma}_+^2 + \frac{B}{ml} = \frac{l-1}{l} W + \frac{(m+1)B}{ml}, d \approx \frac{2\hat{V}^2}{\text{var}(\hat{V})}$$

$$\begin{aligned} \text{เมื่อ } \text{var}(\hat{V}) &= \left(\frac{l-1}{l}\right)^2 \frac{1}{m} \text{var}(s_j^2) + \left(\frac{m+1}{ml}\right)^2 \frac{2}{m-1} B^2 \\ &\quad + 2 \frac{(m+1)(l-1)}{ml^2} \frac{l}{m} \left[\hat{\text{cov}}(s_j^2, \bar{Y}_j^2) - 2\bar{Y}_{..} \hat{\text{cov}}(s_j^2, \bar{Y}_j) \right] \end{aligned}$$

นิยาม scale reduction factor

$$R = \frac{\hat{V}}{\sigma^2}$$

และประมาณค่า R โดย

$$\hat{R} = \frac{\hat{V}}{W}$$

นิยาม potential scale reduction factor ดังนี้

$$\frac{d}{d-2} \frac{\hat{V}}{W}$$

ต่อมา Brooks and Gelman (1998) ได้ปรับปรุงค่า potential scale reduction factor ใหม่เป็น

$$\hat{R}_c = \frac{d+3}{d+1} \hat{R} = \frac{d+3}{d+1} \frac{\hat{V}}{W}$$

ซึ่งเรียกว่า corrected scale reduction factor

เนื่องจาก ค่า \hat{R}_c เป็นค่าอัตราส่วนระหว่างตัวประมาณของความแปรปรวน 2 ตัว โดยที่ตัวเศษเป็นตัวประมาณของความแปรปรวนที่มีค่าสูงเกินไป (overestimate) และตัวส่วนเป็นตัวประมาณของความแปรปรวนที่มีค่าต่ำเกินไป (underestimate) ดังนั้นการจำลองจะลู่เข้าเมื่อค่า \hat{R}_c มีค่าเข้าใกล้ (และมากกว่า) 1

สำหรับในกรณีหลายตัวแปร ซึ่งเราสนใจที่จะประมาณค่าของเวกเตอร์ของพารามิเตอร์ Y_{ij} บรูซ และเกลแมน (Brooks and Gelman (1998)) ได้นำเสนอค่า multivariate

potential scale reduction factor หรือ MPSRF ซึ่งเท่ากับ $\max_{\tilde{a}} \frac{\tilde{a}^T \hat{V} \tilde{a}}{\tilde{a}^T W \tilde{a}}$ โดยที่

$$\hat{V} = \frac{l-1}{l} W + \left(1 + \frac{1}{m}\right) \frac{B}{l}$$

$$W = \frac{1}{m(l-1)} \sum_{j=1}^m \sum_{i=1}^l \left(\tilde{Y}_{ij} - \tilde{\bar{Y}}_{.j} \right) \left(\tilde{Y}_{ij} - \tilde{\bar{Y}}_{.j} \right)^T$$

$$\frac{B}{l} = \frac{1}{m-1} \sum_{j=1}^m \left(\tilde{\bar{Y}}_{.j} - \tilde{\bar{Y}}_{..} \right) \left(\tilde{\bar{Y}}_{.j} - \tilde{\bar{Y}}_{..} \right)^T$$

ซึ่งใช้ตรวจสอบในลักษณะเดียวกับค่า potential scale reduction factor แต่เป็นในรูปแบบของหลายตัวแปร การจำลองจะลู่เข้าเมื่อค่า MPSRF มีค่าเข้าใกล้ (และมากกว่า) 1 (ในทางปฏิบัติเราอาจทำการจำลองจนค่า MPSRF มีค่าน้อยกว่า 1.2 จึงจะถือว่าลู่เข้า)

2.2 เอกสารและงานวิจัยที่เกี่ยวข้อง

หมิงฮุย เชน และ บรูซ ชไมเซอร์ (Chen M.-H. and Schmeiser B.W., 1993) ได้ศึกษาเปรียบเทียบประสิทธิภาพของการสุ่มตัวอย่างแบบฮิตแอนดรันกับการสุ่มตัวอย่างแบบกิบส์ในกรณีที่เป็นการแจกแจงแบบปกติของ 2 ตัวแปร