

การแจกแจงที่เป็นที่นิยม (Popular Distributions)

รศ.ดร. วีระชาติ กิเลนทอง
มหาวิทยาลัยหอการค้าไทย

©Kilenthong 2019

ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของการแจกแจงปกติ มาตรฐานหลายตัวแปร (Multivariate Normal Distribution)

- สิ่งที่ขาดหายไปจากฟังก์ชันความหนาแน่นความน่าจะเป็น (p.d.f.) ของตัวแปรสุ่มตัวเดียว คือ ความแปรปรวน (covariance) หรือสหสัมพันธ์ (correlation) ซึ่งจะปรากฏในกรณีที่มีตัวแปรหลายตัว
- เริ่มจากตัวแปรสุ่มปกติมาตรฐานที่เป็นอิสระต่อกัน ซึ่งเขียนแทนด้วยเวกเตอร์สุ่ม (random vector) $Z = [Z_1, \dots, Z_n]'$ โดยที่ X' หมายถึง เมทริกซ์สลับเปลี่ยน (transpose matrix) ของ X และ $Z_i \sim N(0, 1)$ มีการแจกแจงปกติมาตรฐาน (standard normal) และเป็นอิสระต่อกัน (independent)
- นั่นคือตัวแปรสุ่มเหล่านี้มีการแจกแจงเหมือนกันและเป็นอิสระต่อกัน (identically and independently distributed หรือ i.i.d.) ซึ่งในกรณีที่การแจกแจงเป็นแบบปกติมาตรฐาน สามารถเขียนแทนด้วย $Z \sim N(\mathbf{0}, I_n)$
- ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของ Z คือ

$$\begin{aligned} f(\mathbf{z}) &= \prod_{i=1}^n \phi(z_i) = \prod_{i=1}^n \left(\frac{1}{\sqrt{2\pi}} \right) \exp \left\{ -\frac{1}{2} z_i^2 \right\} = \left(\frac{1}{\sqrt{2\pi}} \right)^n \exp \left\{ -\frac{1}{2} \sum_{i=1}^n z_i^2 \right\} \\ &= \frac{1}{(2\pi)^{\frac{n}{2}}} \exp \left\{ -\frac{1}{2} \mathbf{z}' \mathbf{z} \right\} \end{aligned} \quad (1)$$

ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของการแจกแจงปกติมาตรฐานหลายตัวแปร (Multivariate Normal Distribution)

- สมการข้างต้นเป็นผลมาจากการที่ตัวแปรทั้งหมดมีการแจกแจงปกติมาตรฐานเหมือนกันและเป็นอิสระต่อกัน (i.i.d.)
- ชัดเจนว่า ค่าคาดหวัง (mean) และเมทริกซ์ของค่าความแปรปรวนร่วม (covariance matrix) ของ Z มีค่าเท่ากับ $\mathbf{0}$ และ I_n ตามลำดับ
- ส่วนฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ Z สามารถเขียนได้เป็น

$$\begin{aligned}\psi_Z(t) &= E \left[\exp \{ Z' t \} \right] = E \left[\exp \left\{ \sum_{i=1}^n Z_i t_i \right\} \right] = E \left[\prod_{i=1}^n \exp \{ Z_i t_i \} \right] \\ &= \prod_{i=1}^n E \left[\exp \{ Z_i t_i \} \right] = \prod_{i=1}^n \psi_Z(t_i) = \prod_{i=1}^n e^{\frac{1}{2} t_i^2} \\ &= \exp \left\{ \frac{1}{2} \sum_{i=1}^n t_i^2 \right\} = \exp \left\{ \frac{1}{2} t' t \right\}\end{aligned}\tag{2}$$

- เราสามารถสร้างเวกเตอร์ของตัวแปรสุ่มปกติ (normal random vector) X ที่มีค่าคาดหวัง (mean) เท่ากับ μ และเมทริกซ์ของค่าความแปรปรวนร่วม (covariance matrix) เท่ากับ Σ

การสร้างเวกเตอร์ของตัวแปรสุ่มปกติ (normal random vector) ของการแจกแจงปกติหลายตัวแปร (Multivariate Normal Distribution)

- ในการสร้างเวกเตอร์ของตัวแปรสุ่มปกติ (normal random vector) จะคล้ายกับตัวแปรสุ่มตัวเดียวที่มีการแจกแจงปกติแบบมาตรฐาน แต่มี ความยุ่งยากทางเทคนิค ในการนิยามค่าความเบี่ยงเบนในรูปของเมทริกซ์ ซึ่งต้องใช้เทคนิคที่เรียกว่า การแยกส่วนสเปกตรัล (spectral decomposition)
- เริ่มจากคุณสมบัติที่สำคัญอันหนึ่งของเมทริกซ์ของค่าความแปรปรวนร่วม (variance-covariance matrix) Σ คือ มันเป็น เมทริกซ์จัตุรัสและสมมาตร (symmetric square matrix) และ คุณสมบัติเป็นบวกเกือบแน่นอน (positive semidefinite) ซึ่งทำให้สามารถใช้หลักการทางพีชคณิตเชิงเส้น (linear algebra) แยกส่วน Σ ออกได้เป็น

$$\Sigma = \Gamma' \Lambda \Gamma \quad (3)$$

โดยที่ Λ เป็นเมทริกซ์แนวทแยง (diagonal matrix)

$$\Lambda = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 & 0 \\ 0 & \lambda_2 & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & \lambda_{n-1} & 0 \\ 0 & 0 & \cdots & 0 & \lambda_n \end{bmatrix} \quad (4)$$

และ Γ เป็นเมทริกซ์ตั้งฉาก (orthogonal matrix) นั่นคือ $\Gamma^{-1} = \Gamma'$

- สรุปได้ว่า $\Gamma' \Gamma = I$ โดยทั่วไปเพื่อความสะดวก เรามักจะเรียงลำดับ λ_i จากมากไปหาน้อย นั่นคือ $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_n \geq 0$ และเรียก λ_i แต่ละตัวว่า ค่าลักษณะเฉพาะ (eigenvalue) ส่วนคอลัมน์ที่ i แต่ละอัน (สอดคล้องกับ λ_i) ซึ่งแทนด้วย γ_i มักเรียกว่าเวกเตอร์ลักษณะเฉพาะ (eigenvector) ของ Σ

การสร้างเวกเตอร์ของตัวแปรสุ่มปกติ (normal random vector) ของการแจกแจงปกติหลายตัวแปร (Multivariate Normal Distribution) Con' t

- จากการที่เราสามารถเขียนเมทริกซ์ของค่าความแปรปรวนร่วม (variance-covariance matrix) Σ ในรูปของค่าลักษณะเฉพาะ (eigenvalue) และเวกเตอร์ลักษณะเฉพาะ (eigenvector) ได้ดังนี้

$$\Sigma = \Gamma' \Lambda \Gamma = \sum_{i=1}^n \lambda_i \gamma_i \gamma_i' \quad (5)$$

- ประโยชน์ที่สำคัญของการแยกส่วนนี้ก็คือ การได้มาซึ่งเมทริกซ์แนวทแยง (diagonal matrix) Λ ซึ่งค่าลักษณะเฉพาะ (eigenvalue) λ_i แต่ละค่ามีค่าไม่ติดลบ (nonnegative) ซึ่งช่วยให้สามารถนิยามรากที่สอง (square root) ของ Λ ได้เป็น

$$\Lambda^{\frac{1}{2}} = \begin{bmatrix} \sqrt{\lambda_1} & 0 & \cdots & 0 & 0 \\ 0 & \sqrt{\lambda_2} & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & \sqrt{\lambda_{n-1}} & 0 \\ 0 & 0 & \cdots & 0 & \sqrt{\lambda_n} \end{bmatrix} \quad (6)$$

- ซึ่งมีคุณสมบัติคล้ายกับรากกำลังสองของจำนวนจริง นั่นคือ

$$\Lambda^{\frac{1}{2}} \Lambda^{\frac{1}{2}} = \Lambda \quad (7)$$

การสร้างเวกเตอร์ของตัวแปรสุ่มปกติ (normal random vector) ของการแจกแจงปกติหลายตัวแปร (Multivariate Normal Distribution) Con' t

- เราสามารถเขียนสมการการแยกส่วนสเปกตรัล (spectral decomposition) ใหม่ได้เป็น

$$\Sigma = \Gamma' \Lambda^{\frac{1}{2}} \Lambda^{\frac{1}{2}} \Gamma = (\Gamma' \Lambda^{\frac{1}{2}} \Gamma) (\Gamma' \Lambda^{\frac{1}{2}} \Gamma) \quad (8)$$

- ใช้คุณสมบัติการตั้งฉาก (orthogonal) ของเมทริกซ์ Γ นั่นคือ $\Gamma \Gamma' = I$ ผลที่ตามมาจากการที่ 8 คือ ทำให้สามารถนิยามรากที่สอง (square root) ของ Σ ได้เป็น

$$\Sigma^{\frac{1}{2}} = \Gamma' \Lambda^{\frac{1}{2}} \Gamma \quad (9)$$

- หากเมทริกซ์ของค่าความแปรปรวนร่วม (variance-covariance matrix) Σ เป็นบวกแน่นอน (positive definite หรือ p.d.) แล้วค่าลักษณะเฉพาะ (eigenvalue) มีค่าเป็นบวกทุกค่า นั่นคือ $\lambda_i > 0$ สำหรับทุกๆ $i = 1, \dots, n$ ซึ่งผลทำให้ค่าดีเทอร์มิแนนต์ (determinant) ของ $\Lambda^{\frac{1}{2}}$ มีค่ามากกว่าศูนย์อย่างแน่นอน ทำให้สามารถหาเมทริกซ์ส่วนกลับ (inverse matrix) ของ $\Lambda^{\frac{1}{2}}$ ได้ ดังนั้น จึงสามารถนิยามเมทริกซ์ส่วนกลับ (inverse matrix) ของ $\Sigma^{\frac{1}{2}}$ ได้เป็น

$$\Sigma^{-\frac{1}{2}} = \Gamma' \Lambda^{-\frac{1}{2}} \Gamma \quad (10)$$

โดยที่ $\Lambda^{-\frac{1}{2}}$ แทนเมทริกซ์ส่วนกลับ (inverse matrix) ของ $\Lambda^{\frac{1}{2}}$

ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของการแจกแจงปกติหลายตัวแปร (Multivariate Normal Distribution)

- สร้างเวกเตอร์ของตัวแปรสุ่มปกติ (normal random vector) $X \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ ที่มีค่าคาดหวัง (mean) เท่ากับ $\boldsymbol{\mu}$ และเมทริกซ์ของค่าความแปรปรวนร่วม (covariance matrix) เท่ากับ $\boldsymbol{\Sigma}$ โดยกำหนดให้

$$X = \boldsymbol{\Sigma}^{\frac{1}{2}} Z + \boldsymbol{\mu} \quad (11)$$

- ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ X เท่ากับ

$$\begin{aligned} \psi_X(t) &= E \left[\exp \{ X' t \} \right] = E \left[\exp \left\{ \left(\boldsymbol{\Sigma}^{\frac{1}{2}} Z + \boldsymbol{\mu} \right)' t \right\} \right] = \exp \{ \boldsymbol{\mu}' t \} E \left[\exp \left\{ Z' \left(\boldsymbol{\Sigma}^{\frac{1}{2}} t \right) \right\} \right] \\ &= \exp \{ \boldsymbol{\mu}' t \} \exp \left\{ \frac{1}{2} \left(\boldsymbol{\Sigma}^{\frac{1}{2}} t \right)' \left(\boldsymbol{\Sigma}^{\frac{1}{2}} t \right) \right\} = \exp \left\{ \boldsymbol{\mu}' t + \frac{1}{2} t' \boldsymbol{\Sigma} t \right\} \end{aligned} \quad (12)$$

- ประยุกต์ใช้ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ Z ในสมการที่ 2 โดยใช้ $\boldsymbol{\Sigma}^{\frac{1}{2}} t$ แทน t สังเกตด้วยว่า ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ในที่นี้สามารถหาค่าได้ตรงเท่ากับเมทริกซ์ของค่าความแปรปรวนร่วม (variance-covariance matrix) $\boldsymbol{\Sigma}$ เป็นบวกเกือบแน่นอน (p.s.d.) ในขณะที่ ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของ X จะหาค่าได้ก็ต่อเมื่อ $\boldsymbol{\Sigma}$ เป็นบวกแน่นอน (p.d.) ทั้งนี้เพราะการแปลงฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) จำเป็นต้องใช้ค่าดีเทอร์มิแนนต์ (determinant) ของ $\boldsymbol{\Sigma}^{-\frac{1}{2}}$

ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของการแจกแจงปกติหลายตัวแปร (Multivariate Normal Distribution)

หาก Σ เป็นบวกแน่นอน (p.d.) แล้ว จะสามารถเขียนสมการที่ 11 ใหม่ได้เป็น

$$Z = \Sigma^{-\frac{1}{2}} (\mathbf{x} - \boldsymbol{\mu}) \quad (13)$$

ดังนั้น ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของ \mathbf{X} คือ

$$f(\mathbf{x}) = \frac{1}{(2\pi)^{\frac{n}{2}} |\det \Sigma|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})' \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\} \quad (14)$$

ทฤษฎี: ความสัมพันธ์เชิงเส้นของการแจกแจงปกติหลายตัวแปร (Multivariate Normal Distribution)

Theorem

กำหนดให้ X เป็นเวกเตอร์ของตัวแปรสุ่ม n ตัว ซึ่งมีการแจกแจงร่วมแบบปกติ นั่นคือ

$X \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ และ $Y = AX + \mathbf{b}$ โดยที่ A เป็นเมทริกซ์ของค่าคงที่ขนาด $m \times n$ และ \mathbf{b} เป็นเวกเตอร์ของค่าคงที่ m ตัว แล้ว $Y \sim N(A\boldsymbol{\mu} + \mathbf{b}, A\boldsymbol{\Sigma}A')$

Proof.

ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ Y เท่ากับ

$$\begin{aligned}\psi_Y(t) &= E\left[\exp\{Y't\}\right] = E\left[\exp\{(AX + \mathbf{b})'t\}\right] \\ &= \exp\{\mathbf{b}'t\} E\left[\exp\{X'(A't)\}\right] = \exp\{\mathbf{b}'t\} \exp\left\{\boldsymbol{\mu}'(A't) + \frac{1}{2}(A't)'\boldsymbol{\Sigma}(A't)\right\} \\ &= \exp\left\{(A\boldsymbol{\mu} + \mathbf{b})'t + \frac{1}{2}t'(A\boldsymbol{\Sigma}A')t\right\}\end{aligned}$$

นั่นคือ $Y \sim N(A\boldsymbol{\mu} + \mathbf{b}, A\boldsymbol{\Sigma}A')$



ประโยชน์ในการแปลงตัวแปรสุ่มในรูปแบบฟังก์ชันเชิงเส้น (linear transformation)

- ทฤษฎีบทด้านบนยังช่วยให้สามารถหาการแจกแจงของตัวแปรสุ่มเพียงบางส่วนในกรณีที่การแจกแจงรวมเป็นแบบปกติ โดยเริ่มจากการที่สามารถแบ่งเวกเตอร์ X ออกได้เป็นสองส่วน คือ

$$X = \begin{bmatrix} X_m \\ X_k \end{bmatrix} \quad (15)$$

โดยที่ X_m คือเวกเตอร์ของตัวแปรสุ่มที่สนใจ โดยในที่นี้กำหนดให้มีขนาด m ในขณะที่ตัวแปรสุ่ม X_k มีขนาด $k = n - m$

- กำหนดให้ $b = \mathbf{0}$ และ

$$A = \begin{bmatrix} I_{mm} & \mathbf{0}_{mk} \\ \mathbf{0}_{km} & \mathbf{0}_{kk} \end{bmatrix} \quad (16)$$

จะทำให้ฟังก์ชันที่เกิดจากการแปลงค่าโดยใช้ A และ b เท่ากับ

$$Y = \begin{bmatrix} I_{mm} & \mathbf{0}_{mk} \end{bmatrix} \begin{bmatrix} X_m \\ X_k \end{bmatrix} = X_m$$

สรุป: การแปลงตัวแปรสุ่มในรูปแบบฟังก์ชันเชิงเส้น (linear transformation)

- เราสามารถแบ่ง ค่าคาดหวัง (mean) และเมทริกซ์ความแปรปรวนร่วม (variance-covariance matrix) ของ X ได้เป็น

$$\boldsymbol{\mu} = \begin{bmatrix} \boldsymbol{\mu}_m \\ \boldsymbol{\mu}_k \end{bmatrix} \quad (17)$$

และ

$$\boldsymbol{\Sigma} = \begin{bmatrix} \boldsymbol{\Sigma}_{mm} & \boldsymbol{\Sigma}_{mk} \\ \boldsymbol{\Sigma}_{km} & \boldsymbol{\Sigma}_{kk} \end{bmatrix} \quad (18)$$

โดยที่ $\boldsymbol{\Sigma}_{mk}$ คือเมทริกซ์ความแปรปรวนร่วม (variance-covariance matrix) ระหว่าง X_m และ X_k

- ค่าคาดหวัง (mean) และเมทริกซ์ความแปรปรวนร่วม (variance-covariance matrix) ของ Y สามารถแบ่งส่วนได้เป็น

$$\begin{bmatrix} I_{mm} & \mathbf{0}_{mk} \end{bmatrix} \begin{bmatrix} \boldsymbol{\mu}_m \\ \boldsymbol{\mu}_k \end{bmatrix} = \boldsymbol{\mu}_m \quad (19)$$

และ

$$\begin{bmatrix} I_{mm} & \mathbf{0}_{mk} \end{bmatrix} \begin{bmatrix} \boldsymbol{\Sigma}_{mm} & \boldsymbol{\Sigma}_{mk} \\ \boldsymbol{\Sigma}_{km} & \boldsymbol{\Sigma}_{kk} \end{bmatrix} \begin{bmatrix} I_{mm} \\ \mathbf{0}_{mk} \end{bmatrix} = \boldsymbol{\Sigma}_{mm} \quad (20)$$

- สรุปได้ว่า $Y = X_m \sim N(\boldsymbol{\mu}_m, \boldsymbol{\Sigma}_{mm})$ กล่าวคือ การแจกแจงร่วมเป็นแบบปกติ แล้วการแจกแจงของตัวแปรสุ่มบางส่วนก็จะมีแจกแจงปกติเช่นกัน โดยที่ค่าคาดหวัง (mean) และค่าความแปรปรวน (variance) ของชุดตัวแปรบางส่วนสามารถหาได้จากค่าสถิติของตัวแปรสุ่มทั้งหมดได้ไม่ยากนัก

ตัวอย่าง: การหาฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (p.d.f.) ของ X_1 และ X_2

Example

พิจารณาตัวแปรสุ่มสองตัว X_1 และ X_2 ที่มีการแจกแจงปกติ (normally distributed) ด้วยค่าคาดหวัง (μ_1, μ_2) และเมทริกซ์ความแปรปรวนร่วม (variance-covariance matrix)

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{12} & \sigma_2^2 \end{bmatrix}$$

จะเห็นว่า $\det \Sigma = \sigma_1^2 \sigma_2^2 - \sigma_{12}^2 = \sigma_1^2 \sigma_2^2 (1 - \rho^2)$ โดยที่ ρ แทนค่าสหสัมพันธ์ระหว่าง X_1 และ X_2 ดังนั้น ส่วนกลับ (inverse) ของ Σ เท่ากับ

$$\Sigma^{-1} = \frac{1}{\sigma_1^2 \sigma_2^2 (1 - \rho^2)} \begin{bmatrix} \sigma_2^2 & -\sigma_{12} \\ -\sigma_{12} & \sigma_1^2 \end{bmatrix}$$

- สามารถคำนวณได้ว่า

$$\begin{aligned} (x - \mu)' \Sigma^{-1} (x - \mu) &= [x_1 - \mu_1, x_2 - \mu_2] \frac{1}{\sigma_1^2 \sigma_2^2 (1 - \rho^2)} \begin{bmatrix} \sigma_2^2 & -\sigma_{12} \\ -\sigma_{12} & \sigma_1^2 \end{bmatrix} \begin{bmatrix} x_1 - \mu_1 \\ x_2 - \mu_2 \end{bmatrix} \\ &= \frac{1}{1 - \rho^2} \left[\left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 - 2\rho \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \left(\frac{x_2 - \mu_2}{\sigma_2} \right) + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right] \end{aligned}$$

วิธีทำ: การหาฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (p.d.f.) ของ X_1 และ X_2

Example

- ฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (p.d.f.) ของ X_1 และ X_2 คือ

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} e^{-\frac{Q}{2}} \quad (21)$$

โดยที่

$$Q = \frac{1}{1-\rho^2} \left[\left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 - 2\rho \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \left(\frac{x_2 - \mu_2}{\sigma_2} \right) + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right] \quad (22)$$

- ถ้า $\rho = 0$ แล้ว ฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (p.d.f.) ของ X_1 และ X_2 คือ

$$\begin{aligned} f(x_1, x_2) &= \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2} \left[\left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right] \right\} \\ &= \left[\frac{1}{\sqrt{2\pi\sigma_1^2}} e^{-\frac{1}{2} \left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2} \right] \left[\frac{1}{\sqrt{2\pi\sigma_2^2}} e^{-\frac{1}{2} \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2} \right] = f_1(x_1) f_2(x_2) \end{aligned}$$

- หมายความว่า X_1 และ X_2 เป็นอิสระต่อกัน กล่าวคือ ในกรณีของการแจกแจงปกติ (normal distribution) การไม่มีสหสัมพันธ์ (uncorrelated) หมายถึงการเป็นอิสระต่อกัน (independent) ด้วย

ทฤษฎี: ความเป็นอิสระต่อกัน (independent) ของตัวแปรสุ่ม

Theorem

กำหนดให้ $X \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ และสามารถแยกส่วนได้เป็นสองส่วนคือ $X = (X_m, X_k)$ ซึ่งสอดคล้องกับสมการที่ 15, 17, และ 18 ดังนั้น X_m และ X_k เป็นอิสระต่อกัน (independent) ก็ต่อเมื่อ (if and only if) $\boldsymbol{\Sigma}_{mk} = \mathbf{0}$

Proof.

พิจารณาฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ X ในรูปของ t_m และ t_k

$$\begin{aligned}\psi(t_m, t_k) &= \exp \left\{ \boldsymbol{\mu}_m' t_m + \boldsymbol{\mu}_k' t_k + \frac{1}{2} \left[t_m' \boldsymbol{\Sigma}_{mm} t_m + t_k' \boldsymbol{\Sigma}_{mm} t_k + t_m' \boldsymbol{\Sigma}_{mk} t_k + t_k' \boldsymbol{\Sigma}_{km} t_m \right] \right\} \\ &= \exp \left\{ \boldsymbol{\mu}_m' t_m + \boldsymbol{\mu}_k' t_k + \frac{1}{2} \left[t_m' \boldsymbol{\Sigma}_{mm} t_m + t_k' \boldsymbol{\Sigma}_{mm} t_k \right] \right\} \exp \left\{ \frac{1}{2} \left[t_m' \boldsymbol{\Sigma}_{mk} t_k + t_k' \boldsymbol{\Sigma}_{km} t_m \right] \right\}\end{aligned}\quad (23)$$

$$\begin{aligned}\psi(t_m, t_k) &= \exp \left\{ \boldsymbol{\mu}_m' t_m + \frac{1}{2} \left[t_m' \boldsymbol{\Sigma}_{mm} t_m \right] \right\} \exp \left\{ \boldsymbol{\mu}_k' t_k + \frac{1}{2} \left[t_k' \boldsymbol{\Sigma}_{mm} t_k \right] \right\} \\ &= \exp \left\{ \boldsymbol{\mu}_m' t_m + \boldsymbol{\mu}_k' t_k + \frac{1}{2} \left[t_m' \boldsymbol{\Sigma}_{mm} t_m + t_k' \boldsymbol{\Sigma}_{mm} t_k \right] \right\}\end{aligned}\quad (24)$$

$$\exp \left\{ \frac{1}{2} \left[t_m' \boldsymbol{\Sigma}_{mk} t_k + t_k' \boldsymbol{\Sigma}_{km} t_m \right] \right\} = 1 \Rightarrow t_m' \boldsymbol{\Sigma}_{mk} t_k + t_k' \boldsymbol{\Sigma}_{km} t_m = 0$$

ซึ่งจะเป็นจริงก็ต่อเมื่อ $\boldsymbol{\Sigma}_{mk} = \boldsymbol{\Sigma}_{km}' = \mathbf{0}$

□

ทฤษฎี: การแจกแจงแบบมีเงื่อนไข (conditional distribution) เป็นการแจกแจงแบบปกติ (normal)

Theorem

กำหนดให้ $X \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ และสามารถแยกส่วนได้เป็นสองส่วนคือ $X = (X_m, X_k)$ ซึ่งสอดคล้องกับสมการที่ 15, 17, และ 18 และสมมุติว่า $\boldsymbol{\Sigma}$ เป็นบวกแน่นอน (positive definite) ดังนั้น การแจกแจงแบบมีเงื่อนไข (conditional distribution) ของ X_m เมื่อทราบ X_k เป็นแบบปกติ (normal) นั่นคือ

$$X_m | X_k \sim N(\boldsymbol{\mu}_m + \boldsymbol{\Sigma}_{mk} \boldsymbol{\Sigma}_{kk}^{-1} (X_k - \boldsymbol{\mu}_k), \boldsymbol{\Sigma}_{mm} - \boldsymbol{\Sigma}_{mk} \boldsymbol{\Sigma}_{kk}^{-1} \boldsymbol{\Sigma}_{km}) \quad (25)$$

การพิสูจน์: การแจกแจงแบบมีเงื่อนไข (conditional distribution) เป็นการแจกแจงแบบปกติ (normal)

Proof.

- กำหนดให้ $W = X_m - \Sigma_{mk} \Sigma_{kk}^{-1} X_k$ และ

$$\begin{bmatrix} W \\ X_2 \end{bmatrix} = \begin{bmatrix} I_m & -\Sigma_{mk} \Sigma_{kk}^{-1} \\ \mathbf{0} & I_k \end{bmatrix} \begin{bmatrix} X_1 \\ X_2 \end{bmatrix}$$

- คำนวณหาเมทริกซ์ของค่าความแปรปรวน (variance-covariance matrix) ได้เป็น

$$\begin{bmatrix} I_m & -\Sigma_{mk} \Sigma_{kk}^{-1} \\ \mathbf{0} & I_k \end{bmatrix} \begin{bmatrix} \Sigma_{mm} & \Sigma_{mk} \\ \Sigma_{km} & \Sigma_{kk} \end{bmatrix} \begin{bmatrix} I_m & \mathbf{0} \\ -\Sigma_{mk} \Sigma_{kk}^{-1} & I_k \end{bmatrix} = \begin{bmatrix} \Sigma_{mm} - \Sigma_{mk} \Sigma_{kk}^{-1} \Sigma_{km} & \mathbf{0} \\ \mathbf{0} & \Sigma_{kk} \end{bmatrix}$$

- เห็นได้ว่า W และ X_k เป็นอิสระต่อกัน (independent) ดังนั้น การแจกแจงแบบมีเงื่อนไข $W|X_k$ จะเหมือนกับการแจกแจงของ W ซึ่งเป็นการแจกแจงปกติ (normal distribution) ด้วยค่าคาดหวัง (mean) เท่ากับ $\mu_m - \Sigma_{mk} \Sigma_{kk}^{-1} \mu_k$ และสามารถสรุปได้ว่า

$$W|X_k \sim N\left(\mu_m - \Sigma_{mk} \Sigma_{kk}^{-1} \mu_k, \Sigma_{mm} - \Sigma_{mk} \Sigma_{kk}^{-1} \Sigma_{km}\right)$$

- ในขณะเดียวกัน เนื่องจากสิ่งที่เราสนใจคือการแจกแจงแบบมีเงื่อนไขเมื่อทราบ X_k ดังนั้น การบวกเพิ่มด้วยฟังก์ชันของ X_k เข้าไปย่อมมีผลต่อเช่นเดียวกับการบวกเพิ่มด้วยค่าคงที่ ซึ่งมีผลต่อค่าคาดหวัง แต่ไม่มีผลต่อค่าความแปรปรวน
- เราสามารถคำนวณหา X_m ได้จาก $W + \Sigma_{mk} \Sigma_{kk}^{-1} X_k = X_m$ ดังนั้น การแจกแจงแบบมีเงื่อนไข (conditional distribution) ของ X_m เมื่อทราบ X_k เท่ากับ

$$X_m|X_k \sim N\left(\mu_m - \Sigma_{mk} \Sigma_{kk}^{-1} \mu_k + \Sigma_{mk} \Sigma_{kk}^{-1} X_k, \Sigma_{mm} - \Sigma_{mk} \Sigma_{kk}^{-1} \Sigma_{km}\right)$$

ตัวอย่าง: การคำนวณหาค่าคาดหวังแบบมีเงื่อนไข (conditional mean)

Example

เช่นเดียวกับตัวอย่างที่แล้ว สมมติให้ตัวแปรสุ่ม X_1 และ X_2 มีการแจกแจงปกติ (normally distributed) ด้วยค่าคาดหวัง (μ_1, μ_2) และเมทริกซ์ความแปรปรวนร่วม (variance-covariance matrix)

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{12} & \sigma_2^2 \end{bmatrix}$$

- ใช้สมการที่ 25 เพื่อคำนวณหาค่าคาดหวังแบบมีเงื่อนไข (conditional mean) ของ X_1 เมื่อทราบ $X_2 = x_2$ ได้เป็น

$$\begin{aligned} E[X_1|X_2 = x_2] &= \mu_1 + \Sigma_{12}\Sigma_{22}^{-1}(x_2 - \mu_2) = \mu_1 + (\rho\sigma_1\sigma_2)(\sigma_2^2)^{-1}(x_2 - \mu_2) \\ &= \mu_1 + \rho\frac{\sigma_1}{\sigma_2}(x_2 - \mu_2) \end{aligned}$$

- ฟังก์ชันเชิงเส้น (linear function) ของ x_2 สังเกตว่าเราไม่ได้กำหนดหรือบังคับให้ค่าคาดหวังแบบมีเงื่อนไข (conditional mean) นี้มีความสัมพันธ์เชิงเส้นแต่อย่างใด แต่คุณสมบัติของการแจกแจงปกติ นอกจากนี้ ยังสามารถเขียนในรูปของตัวแปรสุ่มได้เป็น

$$E[X_1|X_2] = \mu_1 + \rho\frac{\sigma_1}{\sigma_2}(X_2 - \mu_2) \quad (26)$$

การแจกแจงไคกำลังสอง (Chi-square distribution)

- การแจกแจงไคกำลังสอง (chi-square distribution) เป็นการแจกแจงอีกแบบหนึ่งที่ได้รับ ความนิยม และเป็นหนึ่งในการแจกแจงแบบแกมมา (gamma distribution)
- คุณสมบัติหนึ่งที่มีความสำคัญในทางสถิติและจะมีประโยชน์สำหรับการหาการแจกแจงของ ค่าสถิติที่ใช้ในการทดสอบสมมุติฐานในอนาคต
- เราสามารถสร้างตัวแปรสุ่มที่มีการแจกแจงไคกำลังสอง (chi-square distribution) ได้ด้วย การนำเอาตัวแปรสุ่มที่มีการแจกแจงปกติมาตรฐาน (standard normal) มายกกำลัง สอง กล่าวคือ ตัวแปรไคกำลังสอง (chi-square) คือกำลังสองของตัวแปรปกติ (normal)
- กำหนดให้ X เป็นตัวแปรสุ่มที่มีการแจกแจงไคกำลังสอง (chi-square distribution) ด้วย ระดับความอิสระ (degree of freedom) เท่ากับ r นั่นคือ $X \sim \chi^2(r)$ ดังนั้น ฟังก์ชัน ความหนาแน่นของความน่าจะเป็นร่วม (p.d.f.) ของ X คือ

$$f(x) = \begin{cases} \frac{1}{\Gamma(\frac{r}{2})2^{\frac{r}{2}}} x^{\frac{r}{2}-1} e^{-\frac{x}{2}}, & \text{สำหรับ } 0 < x < \infty, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases} \quad (27)$$

โดยที่ $\Gamma(z) = \int_0^{\infty} x^{z-1} e^{-x} dx$ แทนฟังก์ชันแกมมา (gamma function)

ฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (p.d.f.) และฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของการแจกแจงไคกำลังสอง (Chi-square distribution)

- ค่าแกมมาฟังก์ชันอันดับหนึ่งที่มีความสัมพันธ์กับการแจกแจงปกติมาตรฐานคือค่าที่มาจากกรณีที่ระดับความอิสระ (degree of freedom) $r = 1$ ซึ่งมีค่าเท่ากับ $\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$ ดังนั้นฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (p.d.f.) ของ $\chi^2(1)$ คือ

$$f(x) = \begin{cases} \frac{1}{\sqrt{2\pi x}} e^{-\frac{x}{2}}, & \text{สำหรับ } 0 < x < \infty, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases} \quad (28)$$

- ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ X เท่ากับ

$$\psi(t) = (1 - 2t)^{-\frac{r}{2}}, \quad \text{สำหรับ } t < \frac{1}{2} \quad (29)$$

- ค่าคาดหวัง (mean) ของ $\chi^2(r)$ เท่ากับ $\psi^1(0) = r$ และค่าความแปรปรวน (variance) ของ $\chi^2(r)$ เท่ากับ $\psi^2(0) - r^2 = r(r + 2) - r^2 = 2r$

กำลังสองของการแจกแจงปกติเป็นการแจกแจงไคกำลังสอง (Chi-square distribution) ด้วยระดับความอิสระ (degree of freedom) $r = 1$

Theorem

สมมติให้ $X \sim N(0, 1)$ แล้ว ตัวแปรสุ่ม $Y = X^2 \sim \chi^2(r)$

Proof.

- เริ่มจากฟังก์ชันความน่าจะเป็นสะสม (C.D.F.) ของ Y เท่ากับ

$$G(y) = \Pr(Y \leq y) = \Pr(X^2 \leq y) = \Pr(-\sqrt{y} \leq X \leq \sqrt{y}), \text{ สำหรับ } y > 0$$

- เนื่องจาก $X \sim N(0, 1)$ ดังนั้น สำหรับ $y > 0$

$$G(y) = \Pr(-\sqrt{y} \leq X \leq \sqrt{y}) = \int_{-\sqrt{y}}^{\sqrt{y}} \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} dz = 2 \int_0^{\sqrt{y}} \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} dz$$

- สมการสุดท้ายเป็นผลมาจากความสมมาตรของการแจกแจงปกติ หลังจากนั้นคือการเปลี่ยนตัวแปรการอินทิเกรต โดยกำหนดให้ $w = z^2$ ซึ่งส่งผลให้ $dz = \frac{dw}{2\sqrt{w}}$ ดังนั้น

$$G(y) = \int_0^y \frac{1}{\sqrt{2\pi w}} e^{-\frac{w}{2}} dw$$

ซึ่งมีค่าเท่ากับฟังก์ชันความน่าจะเป็นสะสม (C.D.F.) ของ $\chi^2(1)$ ตามที่ต้องการ

ผลบวกของตัวแปรสุ่มที่เป็นอิสระต่อกัน (independent) เป็นการแจกแจงไคกำลังสอง (Chi-square distribution)

- คุณสมบัติอีกอันหนึ่งที่การแจกแจงไคกำลังสอง (chi-square) ที่คล้ายกับคุณสมบัติของการแจกแจงปกติ (normal) คือ คุณสมบัติการรักษารูปแบบการกระจาย กล่าวคือ ผลบวกของตัวแปรสุ่มที่เป็นอิสระต่อกัน (independent) และแต่ละตัวมีการแจกแจงไคกำลังสอง (chi-square) จะมีการแจกแจงไคกำลังสอง (chi-square)

Theorem

สมมติให้ $X_i \sim \chi^2(r_i)$ สำหรับ $i = 1, \dots, n$ และ X_1, \dots, X_n เป็นอิสระต่อกัน (independent) แล้ว ตัวแปรสุ่ม $Y = \sum_{i=1}^n X_i \sim \chi^2(R)$ โดยที่ $R = \sum_{i=1}^n r_i$

Proof.

เนื่องจาก X_1, \dots, X_n เป็นอิสระต่อกัน (independent) ดังนั้น ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ Y เท่ากับ

$$\psi_Y(t) = \prod_{i=1}^n (1 - 2t)^{-\frac{r_i}{2}} = (1 - 2t)^{-\frac{\sum_{i=1}^n r_i}{2}}$$

ซึ่งมีค่าเท่ากับฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของการแจกแจงไคกำลังสอง (chi-square) ที่มีระดับความอิสระ (degree of freedom) เท่ากับ $\sum_{i=1}^n r_i$ □

ทฤษฎีการแจกแจงไคกำลังสอง (Chi-square distribution)

Theorem

สมมติให้ $X \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ โดยที่ $\boldsymbol{\Sigma}$ เป็นบวกแน่นอน (positive definite) แล้ว ตัวแปรสุ่ม $Y = (X - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (X - \boldsymbol{\mu}) \sim \chi^2(n)$ โดยที่ n คือจำนวนตัวแปรสุ่มทั้งหมดใน X

Proof.

กำหนดให้ $Z = \boldsymbol{\Sigma}^{-\frac{1}{2}} (X - \boldsymbol{\mu})$ และจากที่อธิบายมาก่อนหน้านี้ ทำให้ทราบว่า $Z \sim N(\mathbf{0}, I_n)$ และกำหนดให้ $W = Z'Z = \sum_{i=1}^n Z_i^2$ เนื่องจาก $Z_i \sim N(0, 1)$ ส่งผลให้ $Z_i^2 \sim \chi^2(1)$ ดังนั้น จึงสามารถประยุกต์ใช้ทฤษฎีบทที่แล้ว สรุปได้ว่า $\sum_{i=1}^n Z_i^2 \sim \chi^2(n)$ นั่นคือ $W \sim \chi^2(n)$ ซึ่งเป็นผลลัพธ์ที่ต้องการ □

ตัวอย่างการแจกแจงไคกำลังสอง (Chi-square distribution)

Example

พิจารณาแบบจำลองเชิงเส้น

$$Y = X\beta + \varepsilon$$

โดยที่ β คือเวกเตอร์ของพารามิเตอร์ที่ต้องการประมาณค่า (vector of estimated parameters) และสมมุติให้ค่าคลาดเคลื่อน (error terms) $\varepsilon \sim N(\mathbf{0}, \Sigma)$ และสมมุติว่ามีข้อมูลแบบตัวอย่างสุ่มขนาด n ตัวอย่าง ดังนั้น ในการทดสอบสมมุติฐานที่เกี่ยวข้องกับแบบจำลองเชิงเส้นนี้ จำเป็นจะต้องหาการแจกแจงของ $\varepsilon' \Sigma^{-1} \varepsilon$ ซึ่งเมื่อประยุกต์ใช้ทฤษฎีบทที่ผ่านมาจะสามารถสรุปได้ว่า $\varepsilon' \Sigma^{-1} \varepsilon \sim \chi^2(n)$

- การแจกแจงไคกำลังสอง (chi-square) ยังมีความสำคัญเพราะเป็นส่วนสำคัญในการสร้างการแจกแจงที (t distribution) และการแจกแจงเอฟ (F distribution)

การแจกแจงที (t Distribution)

- กำหนดให้ $X \sim N(0, 1)$ และ $Y \sim \chi^2(r)$ และเป็นอิสระต่อกัน (independent) ดังนั้น

$$T = \frac{X}{\sqrt{\frac{Y}{r}}} \quad (30)$$


มีการแจกแจงที (t distribution) ด้วยระดับความอิสระ (degree of freedom) r ซึ่งมักแทนด้วย $t(r)$ นั่นคือ การแจกแจงที (t distribution) เกิดจากการผสมผสานกันของการแจกแจงปกติ (normal) และการแจกแจงไคกำลังสอง (chi-square)

- ฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (p.d.f.) ของ T ด้วยระดับความอิสระ (degree of freedom) r คือ

$$f(t) = \frac{\Gamma\left(\frac{1+r}{2}\right)}{\Gamma\left(\frac{r}{2}\right)\sqrt{\pi r}} \left(1 + \frac{t^2}{r}\right)^{-\frac{1+r}{2}} \quad (31)$$

ในทางปฏิบัติค่าสถิติจากการแจกแจงทีมีค่าใกล้เคียงค่าสถิติจากการแจกแจงปกติอย่างมาก โดยเฉพาะอย่างยิ่งเมื่อกลุ่มตัวอย่างหรือระดับความอิสระ (degree of freedom) มีค่ามากพอ นั่นคือ $\lim_{r \rightarrow \infty} t(r) \sim N(0, 1)$

กราฟแสดงการแจกแจงที (t Distribution)



การแจกแจงเอฟ (F Distribution)

- กำหนดให้ $X \sim \chi^2(r_1)$ และ $Y \sim \chi^2(r_2)$ และเป็นอิสระต่อกัน (independent) ดังนั้น

$$F = \frac{\frac{X}{r_1}}{\frac{Y}{r_2}} \quad (32)$$

มีการแจกแจงเอฟ (F distribution) ด้วยระดับความอิสระ (degree of freedom) r_1 และ r_2 ซึ่งมักแทนด้วย $F(r_1, r_2)$ นั่นคือ การแจกแจงที่ (F distribution) เป็น **ผลลัพธ์จากการหารกันของการแจกแจงไคกำลังสอง (chi-square) สองอัน**

- ฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (p.d.f.) ของ T ด้วยระดับความอิสระ (degree of freedom) r คือ

$$f(x) = \begin{cases} \frac{\Gamma(\frac{r_1+r_2}{2})\left(\frac{r_1}{r_2}\right)^{\frac{r_1}{2}}}{\Gamma(\frac{r_1}{2})\Gamma(\frac{r_2}{2})} x^{\frac{r_1}{2}-1} \left(1 + \frac{r_1}{r_2}x\right)^{-\frac{r_1+r_2}{2}}, & \text{สำหรับ } 0 < x < \infty, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases} \quad (33)$$

- นอกจากนี้ ยังสามารถแสดงได้ว่า ลิมิตของการแจกแจงเอฟ คือการแจกแจงไคกำลังสอง นั่นคือ

$$\lim_{r_2 \rightarrow \infty} F(r_1, r_2) \sim \chi^2(r_1) \quad (34)$$

$$\lim_{r_1 \rightarrow \infty} \lim_{r_2 \rightarrow \infty} F(r_1, r_2) \sim N(0, 1) \quad (35)$$

การแจกแจงของตัวแปรสุ่มไม่ต่อเนื่อง

- การแจกแจงแบบ Bernoulli (Bernoulli Distribution)
- การแจกแจงแบบ Binomial (Binomial Distribution)
- การแจกแจงแบบ Poisson (Poisson Distribution)

- Binomial Distribution

- แบบพอยซองน์ (Poisson Distribution)

การแจกแจงแบบ Bernoulli (Bernoulli Distribution)

- กำหนดให้ X เป็นตัวแปรสุ่มที่ไม่ต่อเนื่อง ดังนั้น ฟังก์ชันความน่าจะเป็น (p.f.) ของ X ที่พารามิเตอร์ p คือ

$$f(x) = \begin{cases} p^x(1-p)^{1-x}, & \text{สำหรับ } x \in \{0, 1\}, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases} \quad (36)$$

- ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ X สำหรับ $-\infty < t < \infty$ คือ

$$\psi(t) = E(e^{tx}) = pe^t + (1-p) \quad (37)$$

- ค่าคาดหวัง (mean) เท่ากับ $\psi^1(0) = p$
- ค่าความแปรปรวน (variance) เท่ากับ $\psi^2(0) - p^2 = p - p^2 = p(1-p)$

การแจกแจงแบบ Binomial (Binomial Distribution)

- กำหนดให้ X เป็นตัวแปรสุ่มที่ไม่ต่อเนื่อง ดังนั้น ฟังก์ชันความน่าจะเป็น (p.f.) ของ X ที่พารามิเตอร์ n และ p คือ

$$f(x) = \begin{cases} \binom{n}{x} p^x (1-p)^{n-x}, & \text{สำหรับ } x \in \{0, 1, 2, \dots\}, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases} \quad (38)$$

- ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ X สำหรับ $-\infty < t < \infty$ คือ

$$\psi(t) = E(e^{tx}) = (pe^t + (1-p))^n \quad (39)$$

- ค่าคาดหวัง (mean) เท่ากับ $\psi^1(0) = np$
- ค่าความแปรปรวน (variance) เท่ากับ $\psi^2(0) - (np)^2 = (n(n-1)p^2 + np) - (np)^2 = np(1-p)$

ความสัมพันธ์ระหว่าง Bernoulli Distribution และ Binomial Distribution

Theorem

สมมติให้ X_i มีการแจกแจงแบบ Bernoulli Distribution ที่พารามิเตอร์ p สำหรับ $i = 1, \dots, n$ และ X_1, \dots, X_n เป็นอิสระต่อกัน (independent) แล้ว ตัวแปรสุ่ม $Y = \sum_{i=1}^n X_i$ จะมีการแจกแจงแบบ Binomial Distribution ที่พารามิเตอร์ n และ p

Proof.

เนื่องจาก X_1, \dots, X_n เป็นอิสระต่อกัน (independent) ดังนั้น ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ Y เท่ากับ

$$\psi_Y(t) = E(e^{tY}) = E(e^{t \sum_{i=1}^n X_i}) = \prod_{i=1}^n E(e^{tX_i}) = (pe^t + (1-p))^n$$

ซึ่งมีค่าเท่ากับฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของการแจกแจงแบบ Binomial Distribution ที่พารามิเตอร์ n และ p □

การแจกแจงแบบ Poisson (Poisson Distribution)

- กำหนดให้ X เป็นตัวแปรสุ่มที่ไม่ต่อเนื่อง ดังนั้น ฟังก์ชันความน่าจะเป็น (p.f.) ของ X ที่พารามิเตอร์ λ คือ

$$f(x) = \begin{cases} \frac{e^{-\lambda} \lambda^x}{x!}, & \text{สำหรับ } x \in \{0, 1, 2, \dots\}, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases} \quad (40)$$

- ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ X สำหรับ $-\infty < t < \infty$ คือ

$$\psi(t) = E(e^{tX}) = \sum_{x=0}^{\infty} \frac{e^{tx} e^{-\lambda} \lambda^x}{x!} = e^{\lambda(e^t - 1)} \quad (41)$$

- ค่าคาดหวัง (mean) เท่ากับ $\psi^1(0) = \lambda$
- ค่าความแปรปรวน (variance) เท่ากับ $\psi^2(0) - \lambda^2 = (\lambda^2 + \lambda) - \lambda^2 = \lambda$

ผลรวมของตัวแปรสุ่มที่มีการแจกแจงแบบ Poisson จะมีการแจกแจงแบบ Poisson

Theorem

สมมติให้ X_i มีการแจกแจงแบบ Poisson (Poisson Distribution) ที่พารามิเตอร์ λ_i สำหรับ $i = 1, \dots, n$ และ X_1, \dots, X_n เป็นอิสระต่อกัน (independent) แล้ว ตัวแปรสุ่ม $Y = \sum_{i=1}^n X_i$ จะมีการแจกแจงแบบ Poisson (Poisson Distribution) ที่พารามิเตอร์ λ คือ $\lambda_y = \sum_{i=1}^n \lambda_i$

Proof.

เนื่องจาก X_1, \dots, X_n เป็นอิสระต่อกัน (independent) ดังนั้น ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ Y เท่ากับ

$$\psi_Y(t) = \prod_{i=1}^n e^{\lambda_i(e^t-1)} = e^{(\sum_{i=1}^n \lambda_i)(e^t-1)}$$

ซึ่งมีค่าเท่ากับฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของการแจกแจงแบบ Poisson (Poisson Distribution) ที่พารามิเตอร์ $\lambda_y = \sum_{i=1}^n \lambda_i$ □

ความสัมพันธ์ระหว่างการแจกแจงแบบ Poisson และ การแจกแจงแบบ Binomial

Theorem

ในกรณี พารามิเตอร์ n ของการแจกแจงแบบ Binomial มีค่ามาก ($n \rightarrow \infty$) ฟังก์ชันการแจกแจงจะเข้าสู่ การแจกแจงแบบทัวของ (Poisson Distribution) ที่พารามิเตอร์ $\lambda = np$

Proof.

ในกรณี พารามิเตอร์ n ของการแจกแจงแบบ Binomial มีค่ามาก ($n \rightarrow \infty$) ฟังก์ชันการแจกแจงจะเข้าสู่ การแจกแจงแบบ Poisson ที่พารามิเตอร์ λ

$$f(x) = \binom{n}{x} p^x (1-p)^{n-x} = \frac{(n)(n-1)(n-3)\dots(n-x+1)}{x!} p^x (1-p)^{n-x}$$

ให้ $\lambda = np$

$$f(x) = \frac{\lambda^x}{x!} \left(\frac{n}{n} \cdot \frac{n-1}{n} \cdot \frac{n-2}{n} \cdot \dots \cdot \frac{n-x+1}{n} \cdot (1 - \frac{\lambda}{n})^n \right) (1 - \frac{\lambda}{n})^{-x}$$

ถ้า ($n \rightarrow \infty$) แล้ว

$$\lim_{n \rightarrow \infty} \frac{n}{n} \cdot \frac{n-1}{n} \cdot \frac{n-2}{n} \cdot \dots \cdot \frac{n-x+1}{n} \cdot (1 - \frac{\lambda}{n})^n = 1 \quad \text{และ} \quad \lim_{n \rightarrow \infty} (1 - \frac{\lambda}{n})^{-x} = e^{-\lambda}$$

$$f(x) = \frac{\lambda^x}{x!} e^{-\lambda} \tag{42}$$