

การแจกแจงปกติ (Normal Distributions)




รศ.ดร. วีระชาติ กิเลนทอง
มหาวิทยาลัยหอการค้าไทย

©Kilenthong 2019

การแจกแจงปกติ (Normal Distribution)

- การแจกแจงปกติ (normal distribution) เป็นหนึ่งในรูปแบบของการแจกแจงที่ได้รับความนิยมสูงสุด ซึ่งมีเหตุผลหลักสามประการดังนี้
 - ❶ คุณสมบัติทางสถิติที่ทำให้สะดวกต่อการวิเคราะห์
 - ★ ผลรวมของตัวแปรสุ่มที่แต่ละตัวมีการแจกแจงปกติจะมีการแจกแจงปกติ
 - ★ การแจกแจงปกติสามารถอธิบายได้ด้วย พารามิเตอร์เพียงสองตัว คือ ค่าความคาดหวัง (mean) μ และค่าความแปรปรวน (variance) σ^2
 - ❷ การแจกแจงของตัวประมาณค่า (estimator) หรือตัวทำนาย (predictor) ส่วนใหญ่จะอยู่ในรูปแบบที่เกี่ยวข้องกับการแจกแจงปกติ เมื่อจำนวนตัวอย่างมากขึ้นเรื่อยๆ จาก “ทฤษฎีบทลิมิตของค่ากลาง (Central Limit Theorem)” ซึ่งจะนำเสนอในบทถัดๆ ไป ได้ระบุว่าค่าเฉลี่ยของตัวอย่างจะลู่เข้าสู่ (converge) การแจกแจงปกติ (normal distribution)
 - ❸ จากการสังเกตในธรรมชาติพบว่า มีปรากฏการณ์จำนวนมากไม่น้อยที่นำไปสู่การแจกแจงที่มีลักษณะคล้ายกับการแจกแจงปกติ (normal distribution)

รูปข้อมูลตัวอย่างของการแจกแจงปกติ (Normal Distribution)



การแจกแจงปกติมาตรฐาน (Standard Normal Distribution Function)

- การแจกแจงปกติที่มีความพิเศษคือ “การแจกแจงปกติมาตรฐาน (standard normal distribution)” ซึ่งมีฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) เท่ากับ

$$\phi(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} \quad (1)$$

- “ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของตัวแปรสุ่ม Z ” ที่มีการแจกแจงปกติมาตรฐาน (standard normal distribution) เท่ากับ

$$\begin{aligned} \psi_z(t) &= E[e^{tZ}] = \int_{-\infty}^{\infty} e^{tz} \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} dz \\ &= \int_{-\infty}^{\infty} e^{\frac{t^2}{2}} \frac{1}{\sqrt{2\pi}} e^{-\frac{(z^2 - 2tz + t^2)}{2}} dz = \int_{-\infty}^{\infty} e^{\frac{t^2}{2}} \frac{1}{\sqrt{2\pi}} e^{-\frac{(z-t)^2}{2}} dz \\ &= e^{\frac{t^2}{2}} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{\tilde{z}^2}{2}} d\tilde{z} = e^{\frac{t^2}{2}} \end{aligned}$$

โดยที่ในขั้นตอนก่อนสุดท้ายใช้เทคนิคการเปลี่ยนตัวแปร $\tilde{z} = z - t$

ค่าความคาดหวัง (mean) และค่าความแปรปรวน (variance) ของการแจกแจงปกติมาตรฐาน (standard normal distribution)

- ค่าความคาดหวัง (mean) และค่าความแปรปรวน (variance) หาได้จาก ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) จากทฤษฎีบทที่ก่อนหน้า

$$E[Z] = \left. \frac{d}{dt} \psi_z(t) \right|_{t=0} = \left. \frac{d}{dt} e^{\frac{t^2}{2}} \right|_{t=0} = \left. t e^{\frac{t^2}{2}} \right|_{t=0} = 0 \quad (2)$$

$$\text{Var}[Z] = E[Z^2] = \left. \frac{d^2}{dt^2} e^{\frac{t^2}{2}} \right|_{t=0} = \left. \left[e^{\frac{t^2}{2}} + t^2 e^{\frac{t^2}{2}} \right] \right|_{t=0} = 1 \quad (3)$$

- การแจกแจงปกติมาตรฐาน (standard normal distribution) คือ การแจกแจงแบบปกติที่มี “ค่าความคาดหวังเท่ากับศูนย์และค่าความแปรปรวนเท่ากับหนึ่ง” ซึ่งมักเขียนแทนการแจกแจงแบบนี้ด้วย $N(0, 1)$

ฟังก์ชันเชิงเส้นของการแจกแจงปกติ (Normal Distribution Function)

- เราสามารถสร้างตัวแปรสุ่ม X ที่มีการการแจกแจงปกติ (normal distribution) ที่มีค่าความคาดหวัง (mean) เท่ากับ μ และค่าความแปรปรวน (variance) เท่ากับ σ^2 ได้จากตัวแปรสุ่ม Z โดยใช้ความสัมพันธ์เชิงเส้นต่อไปนี้

$$X = \sigma Z + \mu \quad (4)$$

- ดังนั้น ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของตัวแปรสุ่ม X เท่ากับ

$$\psi_X(t) = e^{\mu t} e^{\frac{(\sigma t)^2}{2}} = e^{\mu t + \frac{1}{2}\sigma^2 t^2} \quad (5)$$

- ค่าความคาดหวัง (mean) และค่าความแปรปรวน (variance) คือ

$$\begin{aligned} E[X] &= \left. \frac{d}{dt} \psi_X(t) \right|_{t=0} = \left. \frac{d}{dt} e^{\mu t + \frac{1}{2}\sigma^2 t^2} \right|_{t=0} = (\mu + t\sigma^2) e^{\mu t + \frac{1}{2}\sigma^2 t^2} \Big|_{t=0} = \mu \\ \text{Var}[X] &= E[X^2] - \mu^2 = \left. \frac{d^2}{dt^2} e^{\mu t + \frac{1}{2}\sigma^2 t^2} \right|_{t=0} - \mu^2 \\ &= \left[\sigma^2 e^{\mu t + \frac{1}{2}\sigma^2 t^2} + (\mu + t\sigma^2)^2 e^{\mu t + \frac{1}{2}\sigma^2 t^2} \right] \Big|_{t=0} = \sigma^2 + \mu^2 - \mu^2 = \sigma^2 \end{aligned}$$

การแจกแจงปกติ (Normal Distribution Function)

- ตัวแปรสุ่ม $X = \sigma Z + \mu$ มีการแจกแจงปกติ (normal distribution) ที่ค่าความคาดหวัง (mean) เท่ากับ μ และค่าความแปรปรวน (variance) เท่ากับ σ^2 ซึ่งมีฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) เท่ากับ

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (6)$$

และสามารถเขียนแทนการแจกแจงแบบนี้ด้วย $N(\mu, \sigma^2)$

- หากทราบว่าตัวแปรสุ่ม X มีการแจกแจงปกติ (normal distribution) ที่ค่าความคาดหวัง (mean) เท่ากับ μ และค่าความแปรปรวน (variance) เท่ากับ $\sigma^2 \neq 0$ แล้วก็จะทราบทันทีว่าตัวแปรสุ่ม $Z = \frac{X-\mu}{\sigma}$ จะมีการแจกแจงปกติมาตรฐาน (standard normal distribution)
- การแปลงค่ารูปแบบนี้คือการปรับคะแนนมาตรฐาน (standardized score) ซึ่งนิยมใช้ในการปรับค่าผลลัพธ์หรือผลการทดสอบให้อยู่ในรูปของตัวแปรที่มีการแจกแจงปกติมาตรฐาน

ตัวอย่าง: การประยุกต์ใช้ในแบบจำลองทางการเงิน

Example

แบบจำลองทางการเงินมักสมมติให้มูลค่าของหลักทรัพย์ ณ เวลา t เป็นไปตามความสัมพันธ์ต่อไปนี้

$$V(t) = V_0 e^{tr}$$

โดยที่ V_0 คือมูลค่าของหลักทรัพย์ ณ เวลาที่ $t = 0$ และ r คืออัตราผลตอบแทนสุทธิ (net return) ของหลักทรัพย์ดังกล่าว ซึ่งเป็นตัวแปรสุ่มที่มีการแจกแจงปกติ (normal distribution) โดยที่ค่าคาดหวังมีค่าเท่ากับ μ และค่าความเบี่ยงเบนมาตรฐาน (standard deviation) ซึ่งในทางการเงินมักเรียกว่า ความผันผวน (volatility) มีค่าเท่ากับ σ ($r \sim N(\mu, \sigma^2)$)

- ค่าคาดหวัง (mean) ของมูลค่าของหลักทรัพย์ ณ เวลา t มีค่าเท่ากับ

$$E[V(t)] = E[V_0 e^{tr}] = V_0 E[e^{tr}]$$

- สังเกตได้ว่า $E[e^{tr}]$ คือฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของตัวแปรสุ่มที่มีการแจกแจงแบบปกติ $N(\mu, \sigma^2)$ ซึ่งมีค่าเท่ากับ $e^{\mu t + \frac{1}{2}\sigma^2 t^2}$ (ดูสมการที่ 5 ประกอบ) ดังนั้น ค่าคาดหวัง (mean) ของมูลค่าของหลักทรัพย์ ณ เวลา t มีค่าเท่ากับ

$$E[V(t)] = V_0 e^{\mu t + \frac{1}{2}\sigma^2 t^2}$$

ทฤษฎี: ความสมมาตรของการแจกแจงปกติ


Theorem (ความสมมาตรของการแจกแจงปกติ)

สำหรับค่าจำนวนจริง z ใดๆ

$$\Phi(-z) = 1 - \Phi(z) \quad (7)$$

และสำหรับ $0 < p < 1$

$$\Phi^{-1}(p) = -\Phi^{-1}(1 - p) \quad (8)$$



การพิสูจน์: ความสมมาตรของการแจกแจงปกติ

Proof.

- เริ่มจากความสัมพันธ์ที่ว่า

$$\Pr(Z \leq -z) + \Pr(Z > -z) = 1$$

- เนื่องจากการแจกแจงปกติเป็นการแจกแจงที่สมมาตร (symmetric) ทำให้ $\Pr(Z > -z) = \Pr(Z \leq z)$ ดังนั้น

$$\Pr(Z \leq -z) + \Pr(Z \leq z) = 1 \Rightarrow \Phi(-z) = 1 - \Phi(z)$$

- สมการที่ 8 พิสูจน์ได้ด้วยการแทนค่า $z = \Phi^{-1}(p)$ และส่วนกลับของมัน $\Phi(z) = p$ ลงในด้านซ้ายและด้านขวาสมการที่ 7 ตามลำดับ

$$\Phi(-\Phi^{-1}(p)) = 1 - p \Rightarrow -\Phi^{-1}(p) = \Phi^{-1}(1 - p)$$

- สอดคล้องกับสมการที่ 8



ทฤษฎี: ความสัมพันธ์ระหว่างการแจกแจงปกติและการแจกแจงปกติมาตรฐาน

Theorem

กำหนดให้ X เป็นตัวแปรสุ่มที่มีแจกแจงปกติ (normal distribution) ด้วยค่าคาดหวัง (mean) μ และค่าความแปรปรวน (variance) σ^2 และกำหนดให้ F แทนฟังก์ชันความน่าจะเป็นสะสม (C.D.F.) ของ X ดังนั้น ตัวแปรสุ่ม $Z = \frac{X - \mu}{\sigma}$ มีการแจกแจงปกติมาตรฐาน (standard normal distribution) โดยที่ สำหรับค่าจำนวนจริง x ใดๆ

$$F(x) = \Phi\left(\frac{x - \mu}{\sigma}\right) \quad (9)$$

และสำหรับค่าจำนวนจริง $0 < p < 1$ ใดๆ

$$F^{-1}(p) = \mu + \sigma\Phi^{-1}(p) \quad (10)$$

ตัวอย่าง: การหาความน่าจะเป็นของการแจกแจงแบบปกติ

Example


สมมติให้ตัวแปรสุ่ม X มีการแจกแจงแบบปกติ ด้วยด้วยค่าคาดหวัง (mean) $\mu = 10$ และค่าความแปรปรวน (variance) $\sigma^2 = 5$ คำถามก็คือ ความน่าจะเป็นที่ X จะมีค่าอยู่ในช่วง $5 < X < 15$ มีค่าเท่าใด?

เริ่มจากการแปลงตัวแปรสุ่มให้เป็นแบบปกติมาตรฐานด้วยฟังก์ชัน $Z = \frac{X - \mu}{\sigma}$

$$Pr(5 < X < 15) = Pr\left(\frac{5 - 10}{5} < \frac{X - 10}{5} < \frac{15 - 10}{5}\right) = Pr(-1 < Z < 1)$$

ซึ่งสามารถเขียนในรูปของ Φ ได้เป็น

$$Pr(-1 < Z < 1) = Pr(|Z| < 1) = \Phi(1) - \Phi(-1) \approx 0.6826$$



ทฤษฎี: ฟังก์ชันเชิงเส้น (linear) ของตัวแปรสุ่มปกติจะยังมีการแจกแจงปกติ

Theorem (ฟังก์ชันเชิงเส้น (linear) ของตัวแปรสุ่มปกติจะยังมีการแจกแจงปกติ)

ถ้า X เป็นตัวแปรสุ่มที่มีการแจกแจงปกติ (normally distributed) ด้วยค่าคาดหวัง (mean) μ และค่าความแปรปรวน (variance) σ^2 และ $Y = aX + b$ สำหรับค่าคงที่ a และ b โดยที่ $a \neq 0$ แล้ว Y จะมีการแจกแจงปกติ (normally distributed) ด้วยค่าคาดหวัง (mean) $a\mu + b$ และค่าความแปรปรวน (variance) $a^2\sigma^2$

Proof.

ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของตัวแปรสุ่ม X เท่ากับ

$$\psi_x(t) = e^{\mu t + \frac{1}{2}\sigma^2 t^2}$$

ดังนั้น ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของตัวแปรสุ่ม $Y = aX + b$ เท่ากับ

$$\psi_y(t) = e^{bt}\psi_x(at) = e^{bt}e^{\mu at + \frac{1}{2}\sigma^2 a^2 t^2} = e^{(a\mu + b)t + \frac{1}{2}(a^2\sigma^2)t^2}$$

ซึ่งเป็นฟังก์ชันที่ตรงกับรูปแบบของฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของการแจกแจงปกติ ที่มี ค่าคาดหวัง (mean) $a\mu + b$ และ ค่าความแปรปรวน (variance) $a^2\sigma^2$



ทฤษฎี: การแจกแจงปกติ (normally distributed) ของตัวแปรสุ่มที่เป็นอิสระต่อกัน

Theorem (ตัวแปรสุ่มที่เป็นอิสระต่อกัน)

ถ้าตัวแปรสุ่ม X_1, \dots, X_n เป็นอิสระต่อกัน และ X_i มีการแจกแจงปกติ (normally distributed) ด้วยค่าคาดหวัง (mean) μ_i และค่าความแปรปรวน (variance) σ_i^2 สำหรับ $i = 1, \dots, n$ แล้ว $Y = \sum_{i=1}^n a_i X_i + b$ มีการแจกแจงปกติ (normally distributed) ด้วยค่าคาดหวัง (mean) $\sum_{i=1}^n a_i \mu_i + b$ และค่าความแปรปรวน (variance) $\sum_{i=1}^n a_i^2 \sigma_i^2$

พิสูจน์: การแจกแจงปกติ (normally distributed) ของตัวแปรสุ่มที่เป็นอิสระต่อกัน

Proof.

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

$$\psi_i(t) = e^{\mu_i t + \frac{1}{2} \sigma_i^2 t^2}$$

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

$$\psi_Y(t) = \prod_{i=1}^n e^{bt} \psi_i(a_i t) = \prod_{i=1}^n e^{bt} e^{\mu_i a_i t + \frac{1}{2} \sigma_i^2 a_i^2 t^2} = e^{(\sum_{i=1}^n a_i \mu_i + b)t + \frac{1}{2} (\sum_{i=1}^n a_i^2 \sigma_i^2) t^2}$$

ซึ่งบ่งบอกว่า Y มีการแจกแจงปกติ (normally distributed) ด้วยค่าคาดหวัง (mean) $\sum_{i=1}^n a_i \mu_i + b$ และค่าความแปรปรวน (variance) $\sum_{i=1}^n a_i^2 \sigma_i^2$ □

นิยาม: ค่าเฉลี่ยของตัวอย่างสุ่ม (random sample)

Definition

กำหนดให้ X_1, \dots, X_n เป็นตัวแปรสุ่ม ค่าคาดหวังของตัวอย่าง (sample mean) นิยามได้เป็น

$$\bar{X}_n = \frac{\sum_{i=1}^n X_i}{n} \quad (11)$$

- หากพิจารณาจากข้อมูล (observed data) n ตัวอย่าง ค่าเฉลี่ย (average) นั้นหมายถึง $\bar{x}_n = \frac{\sum_{i=1}^n x_i}{n}$ โดยที่ x_i คือค่าที่เกิดขึ้นจริง (realized value) ของตัวแปรสุ่ม X_i หรือค่าตัวแปรของตัวอย่าง $1, \dots, n$
- ค่าเฉลี่ย (average) \bar{x}_n คือสำเนาจากตัวอย่าง (sample counterpart) ของค่าคาดหวังของตัวอย่าง (sample mean) \bar{X}_n สิ่งที่แตกต่างกันก็คือ ค่าเฉลี่ย (average) \bar{x}_n เป็นจำนวนจริงค่าหนึ่ง ส่วนค่าคาดหวังของตัวอย่าง (sample mean) \bar{X}_n เป็นตัวแปรสุ่ม

ทฤษฎี: ค่าเฉลี่ยของตัวอย่างสุ่ม (random sample) ที่สุ่มมาจากการแจกแจงปกติ (normal distribution) จะมีการแจกแจงปกติ

Theorem

สมมติให้ X_1, \dots, X_n เป็นตัวแปรสุ่มที่นำไปสู่ตัวอย่างสุ่ม (random sample) ขนาด n และแต่ละตัวเป็นตัวแปรสุ่มที่มีการแจกแจงปกติ (normally distributed) ด้วยค่าคาดหวัง (mean) μ และค่าความแปรปรวน (variance) σ^2 ดังนั้น ค่าคาดหวังของตัวอย่าง (sample mean) \bar{X}_n เป็นตัวแปรสุ่มที่มีการแจกแจงปกติ (normally distributed) ด้วยค่าคาดหวัง (mean) μ และค่าความแปรปรวน (variance) $\frac{\sigma^2}{n}$ นั่นคือ


$$\bar{X}_n \sim N\left(\mu, \frac{\sigma^2}{n}\right) \quad (12)$$

Proof.

ทฤษฎีบทนี้เป็นผลมาจากการประยุกต์ใช้ทฤษฎีบทที่แล้วโดยกำหนดให้ $a_i = \frac{1}{n}$ และ $b = 0$ ซึ่งช่วยให้สรุปได้ว่า $\bar{X}_n = \sum_{i=1}^n \frac{X_i}{n}$ เป็นตัวแปรสุ่มที่มีการแจกแจงปกติ (normally distributed) ด้วย ค่าคาดหวัง (mean) $\sum_{i=1}^n \frac{1}{n} \mu = \mu$ และ ค่าความแปรปรวน (variance) $\sum_{i=1}^n \left(\frac{1}{n}\right)^2 \sigma^2 = \frac{\sigma^2}{n}$ □

ความน่าจะเป็นและ σ

- การประยุกต์ใช้การแจกแจงปกติ (และการแจกแจงที) ในการทดสอบสมมุติฐานทำได้โดยง่าย
 - ▶ การใช้งานในลักษณะของเกณฑ์มาตรฐาน (benchmark) คือ ที่สองเท่าของค่าเบี่ยงเบนมาตรฐาน 2σ จะหมายถึงประมาณร้อยละ 95
 - ▶ สามเท่าของค่าเบี่ยงเบนมาตรฐาน 3σ จะหมายถึงมากกว่าร้อยละ 99
 - ▶ เกณฑ์มาตรฐานแบบนี้ช่วยให้นักวิเคราะห์สามารถอ่านผลการประมาณค่าได้อย่างรวดเร็วโดยไม่ต้องพึ่งตารางสถิติ



- การแจกแจงอันหนึ่งที่เชื่อมโยงกับการแจกแจงปกติคือ การแจกแจงปกติด้วยล็อก (lognormal distribution) ซึ่งหมายถึงการแจกแจงของตัวแปรสุ่มที่ล็อกการริเริ่มของตัวแปรนั้นมีการแจกแจงปกติ (normal distribution)

นิยาม: การแจกแจงปกติด้วยล็อก (lognormal distribution)

Definition

ถ้า $\ln X$ มีการแจกแจงปกติ (normal distribution) ด้วยค่าคาดหวัง (mean) μ และค่าความแปรปรวน (variance) σ^2 แล้ว ตัวแปรสุ่ม X จะมีการแจกแจงปกติด้วยล็อก (lognormal distribution) ที่มีพารามิเตอร์ μ และ σ^2

- ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของตัวแปรสุ่ม X ที่มีการแจกแจงปกติด้วยล็อก (lognormal distribution) สำหรับพารามิเตอร์ μ และ σ^2 เท่ากับ

$$f(x) = \begin{cases} \frac{1}{x\sqrt{2\pi\sigma^2}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}} & \text{สำหรับ } x > 0, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases} \quad (13)$$

- ฟังก์ชันความน่าจะเป็นสะสม (C.D.F.) เท่ากับ

$$F(x) = Pr(X \leq x) = Pr\left(\frac{\ln X - \mu}{\sigma} \leq \frac{\ln x - \mu}{\sigma}\right) = \Phi\left(\frac{\ln x - \mu}{\sigma}\right) \quad (14)$$

ค่าคาดหวัง (mean) และค่าความแปรปรวน (variance)ของการแจกแจงปกติด้วยล็อก (lognormal distribution)

- การหาค่าคาดหวัง (mean) และค่าความแปรปรวน (variance) นั้นมีเทคนิคหนึ่งซึ่งช่วยให้คำนวณหาค่าได้ง่ายคือ การใช้ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของตัวแปรที่มีการแจกแจงปกติ ซึ่งในที่นี้หมายถึง $Y = \ln X$

$$\psi_Y(t) = E[e^{tY}] = e^{\mu t + \frac{1}{2}\sigma^2 t^2}$$

- สมการสุดท้ายเป็นผลมาจากการที่ $Y = \ln X$ มีการแจกแจงปกติ (normal distribution) ด้วยค่าคาดหวัง (mean) μ และค่าความแปรปรวน (variance) σ^2 ในขณะเดียวกัน เราสามารถเขียนฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ในรูปของ X ได้เป็น

$$\psi_Y(t) = E[e^{tY}] = E[e^{t \ln X}] = E[X^t]$$

- ค่าคาดหวังของ X เท่ากับ

$$E[X] = \psi_Y(1) = e^{\mu + \frac{1}{2}\sigma^2}$$

- ค่าความแปรปรวนของ X เท่ากับ

$$\begin{aligned} \text{Var}[X] &= E[X^2] - E[X]^2 = \psi_Y(2) - \psi_Y(1)^2 \\ &= e^{2\mu + 2\sigma^2} - \left(e^{\mu + \frac{1}{2}\sigma^2}\right)^2 = e^{2\mu + \sigma^2} \left[e^{\sigma^2} - 1\right] \end{aligned}$$

ตัวอย่าง: การคำนวณราคาอนุพันธ์เพื่อซื้อ (call options)

Example

สมมติให้ราคาหลักทรัพย์ ณ เวลา t , S_t , มีการแจกแจงปกติด้วยล็อก (lognormal distribution) นั่นคือ $S_t = S_0 e^{Z_t}$ โดยที่ Z_t มีการแจกแจงปกติ (normal distribution) ที่มีค่าคาดหวัง (mean) μt และค่าความแปรปรวน (variance) $\sigma^2 t$

- ความสะดวกในการคำนวณ สามารถเขียน Z_t ในรูปของตัวแปรสุ่มที่มีการแจกแจงปกติมาตรฐาน (standard normal distribution) Z ได้เป็น

$$Z_t = \mu t + \sigma \sqrt{t} Z$$

- สามารถเขียนราคาหลักทรัพย์ในรูปการแจกแจงปกติมาตรฐาน (standard normal distribution) Z ได้เป็น

$$S_t = S_0 e^{\mu t + \sigma \sqrt{t} Z}$$

- พิจารณาอนุพันธ์เพื่อซื้อ (call options) ซึ่งหมายถึงอนุพันธ์ที่ให้สิทธิแก่ผู้ซื้อในการซื้อหลักทรัพย์ที่ราคาอ้างอิง (strike price) K ณ เวลาที่กำหนด T แต่ไม่จำเป็นต้องใช้สิทธินั้นถ้าไม่ต้องการ ดังนั้นมูลค่า (value) ของอนุพันธ์เพื่อซื้อ (call option) ณ เวลาที่กำหนด T มีค่าเท่ากับ

$$V(S) = \max \{S - K, 0\} = \begin{cases} S - K, & \text{ถ้า } S > K \\ 0, & \text{ถ้าเป็นอย่างอื่น} \end{cases}$$

วิธีทำ: การคำนวณราคาอนุพันธ์เพื่อซื้อ (call options)

Example

- การกำหนดราคาอนุพันธ์ (option pricing) ในที่นี้จะประยุกต์ใช้หลักการเป็นกลางต่อความเสี่ยง (risk neutrality)
- กำหนดว่า ค่าคาดหวังของมูลค่าของหลักทรัพย์ควรจะมีค่าเท่ากับผลลัพธ์ที่ได้จากการฝากเงินแบบไม่มีความเสี่ยงที่อัตราดอกเบี้ย r นั่นคือ $e^{rt}S_0 = E[S_t]$ ซึ่งมีผลทำให้สามารถสรุปได้ว่า

$$e^{rt}S_0 = E[S_0e^{\mu t + \sigma\sqrt{t}Z}] \Rightarrow e^{rt} = e^{\mu t + \frac{\sigma^2}{2}t} \Rightarrow \mu = r - \frac{\sigma^2}{2}$$

- หลักการเป็นกลางต่อความเสี่ยง (risk neutrality) ยังระบุว่าราคาอนุพันธ์เพื่อซื้อ, $C(K, T)$, ควรจะมีค่าเท่ากับค่าคาดหวังของมูลค่าของอนุพันธ์ที่ปรับส่วนลด (discount) ด้วยอัตราดอกเบี้ย r นั่นคือ

$$C(K, T) = e^{-rT}E[V(S_T)] = e^{-rT}E[\max\{S_T - K, 0\}]$$

วิธีทำ: การคำนวณราคาอนุพันธ์เพื่อซื้อ (call options) Con't

Example

- เพื่อจะคำนวณค่าคาดหวังนี้ จำเป็นต้องแยกออกเป็นสองกรณีคือ

- ① กรณีที่ $S_T > K$ ซึ่งจะเป็นจริงก็ต่อเมื่อ

$$S_0 e^{\mu T + \sigma \sqrt{T} Z} > K \Rightarrow Z > \frac{\ln \frac{K}{S_0} - \mu T}{\sigma \sqrt{T}} \equiv \bar{z}_T$$

- ② กรณีที่ $S_T > K$ ซึ่งจะเป็นจริงก็ต่อเมื่อ

$$Z < \frac{\ln \frac{K}{S_0} - \mu T}{\sigma \sqrt{T}} \equiv \bar{z}_T$$

- ราคาอนุพันธ์เพื่อซื้อ (call options) ที่สามารถใช้สิทธิได้ ณ เวลา T ที่ราคาอ้างอิง (strike price) K มีค่าเท่ากับ

$$\begin{aligned} C(K, T) &= e^{-rT} E[\max\{S_T - K, 0\}] = e^{-rT} \int_{\bar{z}_T}^{\infty} [S_0 e^{\mu T + \sigma \sqrt{T} z} - K] \phi(z) dz \\ &= e^{-rT + \mu T} S_0 \int_{\bar{z}_T}^{\infty} e^{\sigma \sqrt{T} z} \phi(z) dz - K e^{-rT} \int_{\bar{z}_T}^{\infty} \phi(z) dz \end{aligned} \quad (15)$$

วิธีทำ: การคำนวณราคาอนุพันธ์เพื่อซื้อ (call options), Black-Scholes Model

Example

- พิจารณาการอินทิเกรตในพจน์แรกด้านขวา ดังนี้

$$\begin{aligned}\int_{\bar{z}_T}^{\infty} e^{\sigma\sqrt{T}z} \phi(z) dz &= \int_{\bar{z}_T}^{\infty} e^{\sigma\sqrt{T}z} \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} dz = e^{\frac{\sigma^2}{2}T} \int_{\bar{z}_T}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{(z-\sigma\sqrt{T})^2}{2}} dz \\ &= e^{\frac{\sigma^2}{2}T} \int_{\bar{z}_T - \sigma\sqrt{T}}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} dz = e^{\frac{\sigma^2}{2}T} [1 - \Phi(\bar{z}_T - \sigma\sqrt{T})] = e^{\frac{\sigma^2}{2}T} \Phi(\sigma\sqrt{T} - \bar{z}_T)\end{aligned}$$

- เป็นผลมาจากการเปลี่ยนรูปให้เป็นกำลังสองสัมบูรณ์ ส่วนสมการที่สามเป็นผลมาจากการเปลี่ยนตัวแปรอินทิเกรตจาก z เป็น $z - \sigma\sqrt{T}$ และ สมการสุดท้ายเป็นผลมาจากคุณสมบัติความสมมาตรของการแจกแจงปกติมาตรฐาน เมื่อแทนค่ากลับเข้าไปในสมการราคาอนุพันธ์เพื่อซื้อ (call options) จะได้ว่า

$$\begin{aligned}C(K, T) &= e^{-rT + \mu T} S_0 e^{\frac{\sigma^2}{2}T} \Phi(\sigma\sqrt{T} - \bar{z}_T) - Ke^{-rT} \Phi(-\bar{z}_T) \\ &= e^{-rT + \mu T + \frac{\sigma^2}{2}T} \Phi(\sigma\sqrt{T} - \bar{z}_T) - Ke^{-rT} \Phi(-\bar{z}_T) \\ C(K, T) &= S_0 \Phi(\sigma\sqrt{T} - \bar{z}_T) - Ke^{-rT} \Phi(-\bar{z}_T)\end{aligned}$$

$$\text{เมื่อแทนค่า } \mu = r - \frac{\sigma^2}{2} \text{ และ } \bar{z}_T = \frac{\ln \frac{K}{S_0} - (r - \frac{\sigma^2}{2})T}{\sigma\sqrt{T}}$$

- สมการนี้คือสมการที่มีชื่อเสียงของ Black-Scholes สำหรับการกำหนดราคาอนุพันธ์ (option pricing)

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

$$\begin{aligned} f(\mathbf{z}) &= \prod_{i=1}^n \phi(z_i) = \prod_{i=1}^n \left(\frac{1}{\sqrt{2\pi}} \right) \exp \left\{ -\frac{1}{2} z_i^2 \right\} = \left(\frac{1}{\sqrt{2\pi}} \right)^n \exp \left\{ -\frac{1}{2} \sum_{i=1}^n z_i^2 \right\} \\ &= \frac{1}{(2\pi)^{\frac{n}{2}}} \exp \left\{ -\frac{1}{2} \mathbf{z}' \mathbf{z} \right\} \end{aligned} \quad (16)$$

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

$$\begin{aligned}\psi_Z(t) &= E \left[\exp \{ Z' t \} \right] = E \left[\exp \left\{ \sum_{i=1}^n Z_i t_i \right\} \right] = E \left[\prod_{i=1}^n \exp \{ Z_i t_i \} \right] \\ &= \prod_{i=1}^n E \left[\exp \{ Z_i t_i \} \right] = \prod_{i=1}^n \psi_Z(t_i) = \prod_{i=1}^n e^{\frac{1}{2} t_i^2} \\ &= \exp \left\{ \frac{1}{2} \sum_{i=1}^n t_i^2 \right\} = \exp \left\{ \frac{1}{2} t' t \right\}\end{aligned}\tag{17}$$

- 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

$$\Sigma = \Gamma' \Lambda \Gamma \quad (18)$$

โดยที่ Λ เป็นเมทริกซ์แนวทแยง (diagonal matrix)

$$\Lambda = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 & 0 \\ 0 & \lambda_2 & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & \lambda_{n-1} & 0 \\ 0 & 0 & \cdots & 0 & \lambda_n \end{bmatrix} \quad (19)$$

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

$$\Sigma = \Gamma' \Lambda \Gamma = \sum_{i=1}^n \lambda_i \gamma_i \gamma_i' \quad (20)$$

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

$$\Lambda^{\frac{1}{2}} = \begin{bmatrix} \sqrt{\lambda_1} & 0 & \cdots & 0 & 0 \\ 0 & \sqrt{\lambda_2} & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & \sqrt{\lambda_{n-1}} & 0 \\ 0 & 0 & \cdots & 0 & \sqrt{\lambda_n} \end{bmatrix} \quad (21)$$

- ซึ่งมีคุณสมบัติคล้ายกับรากกำลังสองของจำนวนจริง นั่นคือ

$$\Lambda^{\frac{1}{2}} \Lambda^{\frac{1}{2}} = \Lambda \quad (22)$$

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

- เราสามารถเขียนสมการการแยกส่วนสเปกตรัล (spectral decomposition) ใหม่ได้เป็น

$$\Sigma = \Gamma' \Lambda^{\frac{1}{2}} \Lambda^{\frac{1}{2}} \Gamma = (\Gamma' \Lambda^{\frac{1}{2}} \Gamma) (\Gamma' \Lambda^{\frac{1}{2}} \Gamma) \quad (23)$$

- ใช้คุณสมบัติการตั้งฉาก (orthogonal) ของเมทริกซ์ Γ นั่นคือ $\Gamma \Gamma' = I$ ผลที่ตามมาจากการที่ 23 คือ ทำให้สามารถนิยามรากที่สอง (square root) ของ Σ ได้เป็น

$$\Sigma^{\frac{1}{2}} = \Gamma' \Lambda^{\frac{1}{2}} \Gamma \quad (24)$$

- 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

$$\Sigma^{-\frac{1}{2}} = \Gamma' \Lambda^{-\frac{1}{2}} \Gamma \quad (25)$$

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

$$X = \boldsymbol{\Sigma}^{\frac{1}{2}} Z + \boldsymbol{\mu} \quad (26)$$

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

$$\begin{aligned} \psi_X(t) &= E \left[\exp \{ X' t \} \right] = E \left[\exp \left\{ \left(\boldsymbol{\Sigma}^{\frac{1}{2}} Z + \boldsymbol{\mu} \right)' t \right\} \right] = \exp \{ \boldsymbol{\mu}' t \} E \left[\exp \left\{ Z' \left(\boldsymbol{\Sigma}^{\frac{1}{2}} t \right) \right\} \right] \\ &= \exp \{ \boldsymbol{\mu}' t \} \exp \left\{ \frac{1}{2} \left(\boldsymbol{\Sigma}^{\frac{1}{2}} t \right)' \left(\boldsymbol{\Sigma}^{\frac{1}{2}} t \right) \right\} = \exp \left\{ \boldsymbol{\mu}' t + \frac{1}{2} t' \boldsymbol{\Sigma} t \right\} \end{aligned} \quad (27)$$

- ประยุกต์ใช้ฟังก์ชันก่อกำเนิดโมเมนต์ (m.g.f.) ของ Z ในสมการที่ 17 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 26 ใหม่ได้เป็น

$$Z = \Sigma^{-\frac{1}{2}} (\mathbf{x} - \boldsymbol{\mu}) \quad (28)$$

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

$$f(\mathbf{x}) = \frac{1}{(2\pi)^{\frac{n}{2}} |\det \Sigma|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})' \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\} \quad (29)$$

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

$$X = \begin{bmatrix} X_m \\ X_k \end{bmatrix} \quad (30)$$

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

- กำหนดให้ $b = \mathbf{0}$ และ

$$A = \begin{bmatrix} I_{mm} & \mathbf{0}_{mk} \\ \mathbf{0}_{km} & \mathbf{0}_{kk} \end{bmatrix} \quad (31)$$

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

$$\boldsymbol{\mu} = \begin{bmatrix} \boldsymbol{\mu}_m \\ \boldsymbol{\mu}_k \end{bmatrix} \quad (32)$$

และ

$$\boldsymbol{\Sigma} = \begin{bmatrix} \boldsymbol{\Sigma}_{mm} & \boldsymbol{\Sigma}_{mk} \\ \boldsymbol{\Sigma}_{km} & \boldsymbol{\Sigma}_{kk} \end{bmatrix} \quad (33)$$

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

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

$$\begin{bmatrix} I_{mm} & \mathbf{0}_{mk} \end{bmatrix} \begin{bmatrix} \boldsymbol{\mu}_m \\ \boldsymbol{\mu}_k \end{bmatrix} = \boldsymbol{\mu}_m \quad (34)$$

และ

$$\begin{bmatrix} I_{mm} & \mathbf{0}_{mk} \end{bmatrix} \begin{bmatrix} \boldsymbol{\Sigma}_{mm} & \boldsymbol{\Sigma}_{mk} \\ \boldsymbol{\Sigma}_{km} & \boldsymbol{\Sigma}_{kk} \end{bmatrix} \begin{bmatrix} I_{mm} \\ \mathbf{0}_{mk} \end{bmatrix} = \boldsymbol{\Sigma}_{mm} \quad (35)$$

- 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

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} e^{-\frac{Q}{2}} \quad (36)$$

โดยที่

$$Q = \frac{1}{1-\rho^2} \left[\left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 - 2\rho \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \left(\frac{x_2 - \mu_2}{\sigma_2} \right) + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right] \quad (37)$$

- 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 30, 32, และ 33 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

$$\begin{aligned}\psi(t_m, t_k) &= \exp \left\{ \boldsymbol{\mu}_m' t_m + \boldsymbol{\mu}_k' t_k + \frac{1}{2} \left[t_m' \boldsymbol{\Sigma}_{mm} t_m + t_k' \boldsymbol{\Sigma}_{mm} t_k + t_m' \boldsymbol{\Sigma}_{mk} t_k + t_k' \boldsymbol{\Sigma}_{km} t_m \right] \right\} \\ &= \exp \left\{ \boldsymbol{\mu}_m' t_m + \boldsymbol{\mu}_k' t_k + \frac{1}{2} \left[t_m' \boldsymbol{\Sigma}_{mm} t_m + t_k' \boldsymbol{\Sigma}_{mm} t_k \right] \right\} \exp \left\{ \frac{1}{2} \left[t_m' \boldsymbol{\Sigma}_{mk} t_k + t_k' \boldsymbol{\Sigma}_{km} t_m \right] \right\}\end{aligned}\quad (38)$$

$$\begin{aligned}\psi(t_m, t_k) &= \exp \left\{ \boldsymbol{\mu}_m' t_m + \frac{1}{2} \left[t_m' \boldsymbol{\Sigma}_{mm} t_m \right] \right\} \exp \left\{ \boldsymbol{\mu}_k' t_k + \frac{1}{2} \left[t_k' \boldsymbol{\Sigma}_{mm} t_k \right] \right\} \\ &= \exp \left\{ \boldsymbol{\mu}_m' t_m + \boldsymbol{\mu}_k' t_k + \frac{1}{2} \left[t_m' \boldsymbol{\Sigma}_{mm} t_m + t_k' \boldsymbol{\Sigma}_{mm} t_k \right] \right\}\end{aligned}\quad (39)$$

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

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

□

ทฤษฎี: การแจกแจงแบบมีเงื่อนไข (conditional distribution) เป็นการแจกแจงแบบปกติ (normal)

Theorem

กำหนดให้ $X \sim N(\mu, \Sigma)$ และสามารถแยกส่วนได้เป็นสองส่วนคือ $X = (X_m, X_k)$ ซึ่งสอดคล้องกับสมการที่ 30, 32, และ 33 และสมมุติว่า Σ เป็นบวกแน่นอน (positive definite) ดังนั้น การแจกแจงแบบมีเงื่อนไข (conditional distribution) ของ X_m เมื่อทราบ X_k เป็นแบบปกติ (normal) นั่นคือ

$$X_m | X_k \sim N(\mu_m + \Sigma_{mk} \Sigma_{kk}^{-1} (X_k - \mu_k), \Sigma_{mm} - \Sigma_{mk} \Sigma_{kk}^{-1} \Sigma_{km}) \quad (40)$$

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 40 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

$$E[X_1|X_2] = \mu_1 + \rho\frac{\sigma_1}{\sigma_2}(X_2 - \mu_2) \quad (41)$$