

# Conditional Distributions and Function of Random Variables

รศ.ดร. วีระชาติ กิเลนทอง  
มหาวิทยาลัยหอการค้าไทย

©Kilenthong 2019

# การแจกแจงแบบมีเงื่อนไข (Conditional Distributions)

- การวิเคราะห์ทางการเงินและเศรษฐศาสตร์มักให้ความสนใจในการพยากรณ์โดยมี “เงื่อนไขมาจากสิ่งที่เราทราบ” แล้ว
  - ▶ ต้องการทราบว่า ผลตอบแทนของหลักทรัพย์มีค่าเท่าไร หากเราทราบว่า “ธนาคารแห่งประเทศไทยประกาศขึ้นอัตราดอกเบี้ยนโยบาย”
  - ▶ ต้องการทราบว่า อัตราการออมของครัวเรือนในชนบท “ที่ระดับรายได้ต่างๆ” มีค่าเป็นเท่าใด
- รูปแบบเหล่านี้คือ “รูปแบบของการแจกแจงแบบมีเงื่อนไข (conditional distribution)”

## การแจกแจงแบบมีเงื่อนไขของตัวแปรสุ่มไม่ต่อเนื่อง

- การแจกแจงแบบมีเงื่อนไขของตัวแปรสุ่มไม่ต่อเนื่อง (discrete) “เป็นผลโดยตรง” จากหลักการความน่าจะเป็นแบบมีเงื่อนไข (conditional probability)
- ฟังก์ชันความน่าจะเป็นของตัวแปรสุ่ม  $X$  ภายใต้เงื่อนไขของตัวแปรสุ่ม  $Y = y$  นิยามได้เป็น

$$g_1(x|y) \equiv Pr(X = x|Y = y) = \frac{Pr(X = x \text{ และ } Y = y)}{Pr(Y = y)} = \frac{f(x, y)}{f_2(y)} \quad (1)$$

# นิยาม: การแจกแจงแบบมีเงื่อนไขของตัวแปรสุ่มไม่ต่อเนื่อง

## Definition

กำหนดให้  $X$  และ  $Y$  คือตัวแปรสุ่มไม่ต่อเนื่อง (discrete) ที่มี  $f(x, y)$  แทนฟังก์ชันความน่าจะเป็นร่วม (joint p.f.) และ  $f_2(y)$  แทนฟังก์ชันความน่าจะเป็นตามขอบ (marginal p.f.) ของตัวแปรสุ่ม  $Y$  ดังนั้น สำหรับค่าจำนวนจริง  $y$  ที่  $f_2(y) > 0$

$$g_1(x|y) \equiv \frac{f(x, y)}{f_2(y)} \quad (2)$$

เรามักเรียก  $g_1$  ว่าฟังก์ชันความน่าจะเป็นแบบมีเงื่อนไข (conditional p.f.) ของ  $X$  ภายใต้เงื่อนไขของ  $Y$  ส่วนฟังก์ชัน  $g_1(\cdot|y)$  คือการแจกแจงแบบมีเงื่อนไข (conditional distribution) ของ  $X$  เมื่อค่าของ  $Y = y$  ในทำนองเดียวกัน การแจกแจงแบบมีเงื่อนไข (conditional distribution) ของ  $Y$  เมื่อค่าของ  $X = x$  คือ

$$g_2(y|x) \equiv \frac{f(x, y)}{f_1(x)} \quad (3)$$

สำหรับค่าจำนวนจริง  $x$  ที่  $f_1(x) > 0$

# นิยาม: การแจกแจงแบบมีเงื่อนไขของตัวแปรสุ่มต่อเนื่อง

## Definition

กำหนดให้  $X$  และ  $Y$  คือตัวแปรสุ่มต่อเนื่อง (continuous) ที่มี  $f(x, y)$  แทนฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.) และ  $f_1(x)$  และ  $f_2(y)$  แทนฟังก์ชันความหนาแน่นของความน่าจะเป็นตามขอบ (marginal p.d.f.) ของตัวแปรสุ่ม  $X$  และ  $Y$  ตามลำดับ ดังนั้น สำหรับค่าจำนวนจริง  $y$  ที่  $f_2(y) > 0$  การแจกแจงแบบมีเงื่อนไข (conditional distribution) ของ  $X$  เมื่อค่าของ  $Y = y$

$$g_1(x|y) \equiv \frac{f(x, y)}{f_2(y)}, \text{ สำหรับ } -\infty < x < \infty \quad (4)$$

ในทำนองเดียวกัน สำหรับค่าจำนวนจริง  $x$  ที่  $f_1(x) > 0$  การแจกแจงแบบมีเงื่อนไข (conditional distribution) ของ  $Y$  เมื่อค่าของ  $X = x$  คือ

$$g_2(y|x) \equiv \frac{f(x, y)}{f_1(x)}, \text{ สำหรับ } -\infty < x < \infty \quad (5)$$

ส่วนกรณีที่  $f_2(y) = 0$  หรือ  $f_1(x) = 0$  เราสามารถกำหนดค่าของการแจกแจงแบบมีเงื่อนไข  $g_1(x|y)$  หรือ  $g_2(y|x)$  ตามลำดับ ได้โดยอิสระ ตราบเท่าที่การแจกแจงแบบมีเงื่อนไขนั้นเป็นฟังก์ชันความหนาแน่นของความน่าจะเป็น

## ทฤษฎี: การแจกแจงแบบมีเงื่อนไขเป็นการแจกแจงแบบหนึ่ง

### Theorem

กำหนดให้  $X$  และ  $Y$  คือตัวแปรสุ่มต่อเนื่อง (continuous) สำหรับค่า  $y$  ใดๆ การแจกแจงแบบมีเงื่อนไข (conditional distribution)  $g_1(x|y)$  มีคุณสมบัติเป็นฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ที่เป็นฟังก์ชันของตัวแปร  $x$  ในทำนองเดียวกัน สำหรับค่า  $x$  ใดๆ การแจกแจงแบบมีเงื่อนไข (conditional distribution)  $g_2(y|x)$  มีคุณสมบัติเป็นฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ที่เป็นฟังก์ชันของตัวแปร  $y$

# การพิสูจน์: การแจกแจงแบบมีเงื่อนไขเป็นการแจกแจงแบบหนึ่ง

## Proof.

- เราจะแสดงการพิสูจน์สำหรับ  $g_2(y|x)$  เท่านั้น โดยเริ่มจากกรณีที่  $f_1(x) > 0$ 
  - ▶ การแจกแจงแบบมีเงื่อนไข (conditional distribution)  $g_2(y|x)$  จะต้องสอดคล้องตามสมการที่ 5 ซึ่งมีผลทำให้  $g_2(y|x) \geq 0$
- เนื่องจากทั้งตัวตั้งมีค่าเป็นบวกหรือศูนย์ส่วนตัวหารมีค่ามากกว่าศูนย์ ส่วนที่เหลือคือการพิสูจน์ว่า  $g_2(y|x)$  สอดคล้องกับ “คุณสมบัติผลรวมเท่ากับหนึ่ง”

$$\int_{-\infty}^{\infty} g_2(y|x) dy = \int_{-\infty}^{\infty} \frac{f(x,y)}{f_1(x)} dy = \frac{1}{f_1(x)} \int_{-\infty}^{\infty} f(x,y) dy = \frac{1}{f_1(x)} f_1(x) = 1$$

- ความน่าจะเป็นตามขอบ (marginal p.d.f.) ของ ตัวแปรสุ่ม  $X$  คือ  $f_1(x) = \int_{-\infty}^{\infty} f(x,y) dy$
- กรณีที่  $f_1(x) = 0$  นิยามข้างต้น ได้กำหนดให้  $g_2(y|x)$  มีคุณสมบัติเป็นฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) อยู่แล้ว
- กรณีของตัวแปรสุ่มไม่ต่อเนื่อง (discrete) การแจกแจงแบบมีเงื่อนไขมีคุณสมบัติเป็นฟังก์ชันความน่าจะเป็น (p.f.) เช่นเดียวกัน

# ความสัมพันธ์ระหว่างการแจกแจงแบบมีเงื่อนไขกับการแจกแจงร่วม

## Theorem

กำหนดให้  $X$  และ  $Y$  เป็นตัวแปรสุ่มที่มีการแจกแจง  $f_1(x)$  และ  $f_2(y)$  ตามลำดับ ในทำนองเดียวกัน กำหนดให้  $g_1(x|y)$  และ  $g_2(y|x)$  แทนการแจกแจงแบบมีเงื่อนไขของ  $X$  เมื่อค่าของ  $Y = y$  และ การแจกแจงแบบมีเงื่อนไขของ  $Y$  เมื่อค่าของ  $X = x$  ตามลำดับ ดังนั้น การแจกแจงร่วมของ  $X$  และ  $Y$  สามารถหาค่าได้จาก

$$f(x, y) = g_1(x|y)f_2(y), \quad (6)$$

$$f(x, y) = g_2(y|x)f_1(x) \quad (7)$$

โดยที่สมการแรกเป็นจริงสำหรับทุกๆ ค่า  $x$  และค่า  $y$  ที่  $f_2(y) > 0$  และในทางกลับกันสมการที่สองเป็นจริงสำหรับทุกๆ ค่า  $y$  และค่า  $x$  ที่  $f_1(x) > 0$



# กฎของความน่าจะเป็นรวม (Law of total probability)

## Theorem

ฟังก์ชันความหนาแน่นของความน่าจะเป็นตามขอบ (marginal p.d.f.) และฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบมีเงื่อนไข (conditional p.d.f.) สำหรับตัวแปรสุ่ม  $X$  และ  $Y$  สอดคล้องกับกฎของความน่าจะเป็นรวม (Law of total probability) ดังต่อไปนี้

$$f_1(x) = \int_{-\infty}^{\infty} g_1(x|y)f_2(y) dy, \quad (8)$$

$$f_2(y) = \int_{-\infty}^{\infty} g_2(y|x)f_1(x) dx \quad (9)$$

โดยที่  $f_1(x)$  และ  $f_2(y)$  แทนฟังก์ชันความหนาแน่นของความน่าจะเป็นตามขอบ (marginal p.d.f.) ของ  $X$  และ  $Y$  ตามลำดับ และ  $g_1(x|y)$  แทนฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบมีเงื่อนไขของ  $X$  เมื่อค่าของ  $Y = y$  และ  $g_2(y|x)$  แทนฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบมีเงื่อนไขของ  $Y$  เมื่อค่าของ  $X = x$

# ทฤษฎีบทของเบส์ (Bayes' Theorem)

## Theorem (ทฤษฎีบทของเบส์ (Bayes' Theorem))

กำหนดให้  $X$  และ  $Y$  เป็นตัวแปรสุ่ม โดยที่  $f_1(x)$  และ  $f_2(y)$  แทนฟังก์ชันความหนาแน่นของความน่าจะเป็นตามขอบ (marginal p.d.f.) ของ  $X$  และ  $Y$  ตามลำดับ ความสัมพันธ์ระหว่างฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบมีเงื่อนไข (conditional p.d.f.) สามารถเขียนได้ในรูปสมการดังต่อไปนี้

$$g_1(x|y) = \frac{g_2(y|x)f_1(x)}{f_2(y)} \quad (10)$$

$$g_2(y|x) = \frac{g_1(x|y)f_2(y)}{f_1(x)} \quad (11)$$

- ในทางปฏิบัติทฤษฎีของเบส์ (Bayes' Theorem) ช่วยให้เราสามารถคำนวณหาฟังก์ชันการแจกแจง (distribution function) ที่เกี่ยวข้องในทุกรูปแบบ ไม่ว่าจะเป็นการแจกแจงร่วม การแจกแจงตามขอบของทุกตัวแปร ในกรณีที่ทราบการแจกแจงย่อยเพียงสองอย่าง คือ การแจกแจงตามขอบและการแจกแจงแบบมีเงื่อนไข โดยมักจะใช้ร่วมกับกฎของความน่าจะเป็นรวม (Law of total probability)

## ตัวอย่าง: การแจกแจงแบบมีเงื่อนไข

### Example

สมมติให้ค่า  $X$  คือค่าที่สุ่มจากการแจกแจงเอกรูป (uniform distribution) ในช่วง  $[0, 1]$  และ  $Y$  คือค่าที่สุ่มหลังจากที่ทราบว่าค่า  $X = x$  จากการแจกแจงเอกรูป (uniform distribution) ในช่วง  $[x, 1]$  ค่าถามก็คือ ฟังก์ชันความหนาแน่นของความน่าจะเป็นตามขอบ (marginal p.d.f.) ของ  $Y$  จะมีลักษณะอย่างไร?

- เนื่องจาก  $X$  มีการแจกแจงแบบเอกรูปในช่วง  $[0, 1]$  ดังนั้น เราสามารถเขียนฟังก์ชันความหนาแน่นของความน่าจะเป็นตามขอบ (marginal p.d.f.) ของ  $X$  ได้เป็น

$$f_1(x) = \begin{cases} 1, & \text{สำหรับ } 0 \leq x \leq 1, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases}$$

- ฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบมีเงื่อนไข (conditional p.d.f.) ของ  $Y$  เมื่อค่าของ  $X = x$  เท่ากับ

$$g_2(y|x) = \begin{cases} \frac{1}{1-x}, & \text{สำหรับ } x \leq y \leq 1, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases}$$

# วิธีทำ: การแจกแจงแบบมีเงื่อนไข

## Example

- ใช้กฎการคูณเราจะพบว่า ฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.) ของ  $(X, Y)$  เท่ากับ

$$f(x, y) = \begin{cases} \frac{1}{1-x}, & \text{สำหรับ } 0 < x \leq y \leq 1, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases}$$

- เราสามารถหาฟังก์ชันความหนาแน่นของความน่าจะเป็นตามขอบ (marginal p.d.f.) ของ  $Y$

$$f_2(y) = \begin{cases} \int_0^y \frac{1}{1-x} dx = -\ln(1-y) & \text{สำหรับ } 0 < y < 1, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases}$$

- เราสามารถหาฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบมีเงื่อนไข (conditional p.d.f.) ของ  $X$  เมื่อค่าของ  $Y = y$  โดยประยุกต์ใช้ทฤษฎีบทของเบส์ (Bayes' theorem)

$$g_1(x|y) = \begin{cases} \frac{\frac{1}{1-x}}{-\ln(1-y)} = -\frac{1}{(1-x)\ln(1-y)} & \text{สำหรับ } 0 < x \leq y \leq 1, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases}$$

- ผลลัพธ์เดียวกันนี้สามารถหาได้จากการใช้นิยามของฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบมีเงื่อนไข (conditional p.d.f.) เพราะเราทราบฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.)

# ความสัมพันธ์ระหว่างความเป็นอิสระต่อกันและการแจกแจงแบบมีเงื่อนไข

## Theorem

กำหนดให้  $X$  และ  $Y$  เป็นตัวแปรสุ่มที่มีการแจกแจง  $f_1(x)$  และ  $f_2(y)$  ตามลำดับ ในทำนองเดียวกัน กำหนดให้  $g_1(x|y)$  และ  $g_2(y|x)$  แทนการแจกแจงแบบมีเงื่อนไขของ  $X$  เมื่อค่าของ  $Y = y$  และการแจกแจงแบบมีเงื่อนไขของ  $Y$  เมื่อค่าของ  $X = x$  ตามลำดับ ดังนั้น  $X$  และ  $Y$  เป็นอิสระต่อกัน (independent) ก็ต่อเมื่อ สำหรับทุกๆ ค่าของ  $y$  ที่  $f_2(y) > 0$  และทุกๆ ค่าของ  $x$

$$g_1(x|y) = f_1(x) \quad (12)$$

และสำหรับทุกๆ ค่าของ  $x$  ที่  $f_1(x) > 0$  และทุกๆ ค่าของ  $y$

$$g_2(y|x) = f_2(y) \quad (13)$$

# ฟังก์ชันของตัวแปรสุ่ม (Functions of Random Variables)

- ตัวแปรพื้นฐานส่วนใหญ่มักจะอยู่ในรูปของ **ตัวแปรสุ่ม** เช่น รายได้, อัตราผลตอบแทน
- คำตอบที่ได้จากแบบจำลองของตัวแปรเหล่านี้เป็น **ตัวแปรสุ่ม** เช่นกัน
- ดังนั้น เพื่อให้เข้าใจคำตอบที่ได้ จึงจำเป็นจะต้องหาคุณสมบัติของคำตอบที่ได้ในฐานะที่เป็นตัวแปรสุ่ม
  - ▶ ต้องการหา “การแจกแจงของฟังก์ชันของตัวแปรสุ่ม”

## ทฤษฎี: การแจกแจงของฟังก์ชันของตัวแปรสุ่มไม่ต่อเนื่อง

### Theorem

กำหนดให้  $X$  เป็นตัวแปรสุ่มไม่ต่อเนื่องที่มีฟังก์ชันความน่าจะเป็น (p.f.)  $f$  และ  $Y = r(X)$  เป็นฟังก์ชัน ที่นิยามบนเซตของค่าที่เป็นไปได้ทั้งหมดของ  $X$  ดังนั้น ฟังก์ชันความน่าจะเป็น (p.f.) ของ  $Y$  ซึ่งแทนด้วย  $g$  มีค่าเท่ากับ

$$g(y) = Pr(Y = y) = Pr(r(X) = y) = \sum_{x:r(X)=y} f(x) \quad (14)$$

สำหรับแต่ละค่า  $y$  ที่เป็นไปได้สำหรับตัวแปรสุ่ม  $Y$

## ทฤษฎี: ฟังก์ชันการแจกแจงของฟังก์ชันของตัวแปรสุ่มต่อเนื่อง

- การแจกแจงของตัวแปรสุ่มต่อเนื่องสามารถคำนวณได้โดยใช้หลักการสองขั้นตอน
  1. หาฟังก์ชันการแจกแจงสะสม (C.D.F.)
  2. หาฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) จากอนุพันธ์ของฟังก์ชันการแจกแจงสะสม (C.D.F.)

### Theorem

กำหนดให้  $X$  เป็นตัวแปรสุ่มต่อเนื่องที่มีฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.)  $f$  และ  $Y = r(X)$  เป็นฟังก์ชันที่นิยามบนเซตของค่าที่เป็นไปได้ทั้งหมดของ  $X$  ดังนั้น ฟังก์ชันการแจกแจงสะสม (C.D.F.) ของ  $Y$  ซึ่งแทนด้วย  $G$  มีค่าเท่ากับ

$$G(y) = Pr(Y \leq y) = Pr(r(X) \leq y) = \int_{\{x:r(x) \leq y\}} f(x) dx \quad (15)$$

สำหรับแต่ละค่า  $y$  ที่เป็นไปได้สำหรับตัวแปรสุ่ม  $Y$  และถ้าฟังก์ชันการแจกแจงสะสม (C.D.F.) ของ  $Y$  สามารถหาค่าอนุพันธ์ได้ ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) จะมีค่าเท่ากับ

$$g(y) = \frac{dG(y)}{dy} \quad (16)$$



# ตัวอย่าง: การแจกแจงของฟังก์ชันของตัวแปรสุ่ม เมื่อ ตัวแปรสุ่ม $X$ มีการแจกแจงเอกรูป

## Example

สมมติว่าตัวแปรสุ่ม  $X$  มีการแจกแจงเอกรูป (uniform distribution) ในช่วง  $[0, 1]$  แล้วตัวแปรสุ่ม  $Y = X^2$  มีการแจกแจงอย่างไร?

- เนื่องจาก  $X$  มีการแจกแจงแบบเอกรูป ดังนั้น ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของ  $X$  มีค่าเท่ากับ

$$f(x) = \begin{cases} 1 & \text{สำหรับ } 0 \leq x \leq 1, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases}$$

- ในช่วง  $0 \leq x \leq 1$  แล้ว  $0 \leq y \leq 1$  ดังนั้น เราจะต้องคำนวณหาฟังก์ชันการแจกแจงสะสม (C.D.F.) ของ  $Y$  สำหรับค่า  $0 \leq y \leq 1$  ดังต่อไปนี้

$$\begin{aligned} G(y) &= Pr(Y \leq y) = Pr(X^2 \leq y) = Pr(-\sqrt{y} \leq X \leq \sqrt{y}) \\ &= Pr(0 \leq X \leq \sqrt{y}) = \int_0^{\sqrt{y}} f(x) dx = \sqrt{y}, \end{aligned}$$

โดยหนึ่งในขั้นตอนการคำนวณได้ประยุกต์ใช้การที่  $f(x) = 0$  เมื่อ  $x < 0$

- ค่ามหาาคค่าฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ได้จากอนุพันธ์ของ  $G(y)$

$$g(y) = \begin{cases} \frac{1}{2\sqrt{y}} & \text{สำหรับ } 0 \leq y \leq 1, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases}$$

ตัวอย่าง: การแจกแจงของฟังก์ชันของตัวแปรสุ่มเมื่อ ตัวแปรสุ่ม  $X$  มีการแจกแจงแบบปกติ

### Example

สมมติว่า  $X$  เป็นตัวแปรสุ่มที่มีการแจกแจงแบบปกติ (normal distribution) ที่มีพารามิเตอร์  $\mu$  และ  $\sigma$  ซึ่งมีฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) เท่ากับ

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

คำถามก็คือ ตัวแปรสุ่ม  $Y = aX + b$  ซึ่งเป็นฟังก์ชันเชิงเส้นของ  $X$  มีการแจกแจงอย่างไร?

- เช่นเดียวกับตัวอย่างก่อนหน้านี้ เราเริ่มจากการหาฟังก์ชันการแจกแจงสะสม (C.D.F.) ของ  $Y$  แล้วจึงหาฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) จากการหาอนุพันธ์
- ในทางเทคนิค เราจำเป็นต้องแยกออกเป็นสองกรณีคือ

วิธีทำ: การแจกแจงของฟังก์ชันของตัวแปรสุ่มเมื่อ ตัวแปรสุ่ม  $X$  มีการแจกแจงแบบปกติ กรณีที่  $a > 0$

### Example

กรณีที่  $a > 0$ :



$$\begin{aligned} G(y) &= Pr(Y \leq y) = Pr(aX + b \leq y) = Pr(aX + b \leq y) = Pr\left(X \leq \frac{y-b}{a}\right) \\ &= \int_{-\infty}^{\frac{y-b}{a}} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx \end{aligned}$$

- การหาอนุพันธ์

$$\begin{aligned} g(y) &= \frac{dG(y)}{dy} = \frac{d \int_{-\infty}^{\frac{y-b}{a}} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx}{dy} = \frac{1}{a\sqrt{2\pi\sigma^2}} e^{-\frac{(\frac{y-b}{a}-\mu)^2}{2\sigma^2}} \\ &= \frac{1}{\sqrt{2\pi}(\sigma a)^2} e^{-\frac{(y-(a\mu+b))^2}{2(\sigma a)^2}} \end{aligned}$$

วิธีทำ: การแจกแจงของฟังก์ชันของตัวแปรสุ่มเมื่อ ตัวแปรสุ่ม  $X$  มีการแจกแจงแบบปกติ กรณีที่  $a < 0$

### Example

กรณีที่  $a < 0$ :



$$\begin{aligned} G(y) &= Pr(Y \leq y) = Pr(aX + b \leq y) = Pr(aX + b \leq y) = Pr\left(X \geq \frac{y-b}{a}\right) \\ &= 1 - \int_{-\infty}^{\frac{y-b}{a}} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx \end{aligned}$$

- การหาอนุพันธ์

$$\begin{aligned} g(y) &= \frac{dG(y)}{dy} = -\frac{d \int_{-\infty}^{\frac{y-b}{a}} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx}{dy} = \frac{1}{a\sqrt{2\pi\sigma^2}} e^{-\frac{(\frac{y-b}{a}-\mu)^2}{2\sigma^2}} \\ &= \frac{1}{\sqrt{2\pi(a\sigma)^2}} e^{-\frac{(y-(a\mu+b))^2}{2(a\sigma)^2}} \end{aligned}$$

## ฟังก์ชันของตัวแปรสุ่มที่มีการแจกแจงแบบปกติ (normal distribution)

- ตัวแปรสุ่ม  $Y = aX + b$  ซึ่งเป็นฟังก์ชันเชิงเส้นของ  $X$  มีการแจกแจงแบบปกติ (normal distribution) ที่มีพารามิเตอร์  $a\mu + b$  และ  $a\sigma$
- **บทเรียน:** ผลลัพธ์ที่ได้จากกรณีที่  $a > 0$  และ  $a < 0$  นั้นเหมือนกัน แสดงว่า ค่าของพารามิเตอร์  $a$  ที่มีผลต่อการแปลงการแจกแจงในกรณีที่เป็นฟังก์ชันเชิงเส้นคือ “ค่าสมบูรณ์ (absolute value) ของ  $a$ ”

ทฤษฎี: เมื่อฟังก์ชันของตัวแปรสุ่มเป็นฟังก์ชันเชิงเส้น

### Theorem

สมมติให้  $X$  เป็นตัวแปรสุ่มต่อเนื่องที่มี  $f$  เป็นฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) และตัวแปรสุ่ม  $Y = aX + b$  โดยที่  $a \neq 0$  แล้ว ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของ  $Y$  เท่ากับ

$$g(y) = \frac{1}{|a|} f\left(\frac{y-b}{a}\right), \text{ สำหรับ } -\infty < y < \infty \quad (17)$$

- ทฤษฎีบทนี้เป็นกรณีพิเศษของทฤษฎีบทที่กล่าวถึงการแปลงการแจกแจงด้วยฟังก์ชันหนึ่งต่อหนึ่งที่หาอนุพันธ์ได้ (one-to-one and differentiable function)

## ทฤษฎี: การแปลงค่าของฟังก์ชันของตัวแปรสุ่ม

### Theorem

กำหนดให้  $X$  เป็นตัวแปรสุ่มต่อเนื่องที่มี  $f$  เป็นฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) โดยที่  $Pr(a < X < b) = 1$  และตัวแปรสุ่ม  $Y = r(X)$  โดยที่ฟังก์ชัน  $r(x)$  เป็นฟังก์ชันหนึ่งต่อหนึ่งที่ทำอนุพันธ์ได้ (one-to-one and differentiable function) สำหรับ  $a < x < b$  ซึ่งมีผลทำให้เกิดภาพฉาย<sup>๑</sup> (image) ของช่วง  $(a, b)$  เท่ากับ  $(\alpha, \beta)$

กำหนดให้  $s(y)$  คือฟังก์ชันผกผัน (inverse function) ของ  $r(x)$  นั่นคือ  $x = s(y)$  ดังนั้นฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของ  $Y$  มีค่าเท่ากับ

$$g(y) = \begin{cases} f(r(x)) \left| \frac{ds(y)}{dy} \right| & \text{สำหรับ } \alpha \leq y \leq \beta, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases} \quad (18)$$

<sup>๑</sup>หากพิจารณาอย่างไม่เป็นทางการ ภาพฉาย (image) หมายถึงเซตของจำนวนจริงที่เป็นผลลัพธ์ของฟังก์ชัน  $r$  ที่เป็นไปได้ทั้งหมด หรือในทางเทคนิค เราอาจจะเขียนได้เป็น  $r : (a, b) \rightarrow (\alpha, \beta)$

# การพิสูจน์: การแปลงค่าของฟังก์ชันของตัวแปรสุ่ม

## Proof.

การพิสูจน์แบ่งออกเป็นสองส่วน ดังต่อไปนี้

- 1 กรณีที่  $r$  เป็นฟังก์ชันที่เพิ่มขึ้น (increasing function): ผลที่ตามมาคือ  $s$  ก็เป็นฟังก์ชันที่เพิ่มขึ้น ซึ่งช่วยให้เราเขียนฟังก์ชันการแจกแจงสะสม (C.D.F.) ของ  $Y$  สำหรับ  $y \in (\alpha, \beta)$

$$G(y) = Pr(Y \leq y) = Pr(r(X) \leq y) = Pr(X \leq s(y)) = F(s(y))$$

เราสามารถประยุกต์ใช้กฎลูกโซ่ (chain rule) เพื่อหาอนุพันธ์ของ  $G$  ได้ดังต่อไปนี้

$$g(y) = \frac{dG(y)}{dy} = \frac{dF(s(y))}{dy} = \frac{dF(s(y))}{dx} \frac{ds(y)}{dy} = f(s(y)) \frac{ds(y)}{dy} = f(s(y)) \left| \frac{ds(y)}{dy} \right|$$

- 2 กรณีที่  $r$  เป็นฟังก์ชันที่ลดลง (decreasing function): ผลที่ตามมาคือ  $s$  ก็เป็นฟังก์ชันที่ลดลง ซึ่งช่วยให้เราเขียนฟังก์ชันการแจกแจงสะสม (C.D.F.) ของ  $Y$  สำหรับ  $y \in (\alpha, \beta)$

$$G(y) = Pr(Y \leq y) = Pr(r(X) \leq y) = Pr(X \geq s(y)) = 1 - F(s(y))$$

เราสามารถประยุกต์ใช้กฎลูกโซ่ (chain rule) เพื่อหาอนุพันธ์ของ  $G$  ได้ดังต่อไปนี้

$$g(y) = \frac{dG(y)}{dy} = -\frac{dF(s(y))}{dy} = -\frac{dF(s(y))}{dx} \frac{ds(y)}{dy} = -f(s(y)) \frac{ds(y)}{dy} = f(s(y)) \left| \frac{ds(y)}{dy} \right|$$





## ตัวอย่าง: การแปลงค่าของฟังก์ชันของตัวแปรสุ่ม

### Example

สมมติให้  $X$  เป็นตัวแปรสุ่มที่บอกถึงอัตราการให้บริการลูกค้าที่เข้าแถวรอของธนาคารแห่งหนึ่ง โดยกำหนดให้  $f$  แทนฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของ  $X$  คำถามที่สนใจก็คือ การแจกแจงของเวลาที่ใช้ในการรอ (waiting time) เป็นอย่างไร?

- กำหนดให้ เวลาที่ใช้ในการรอ (waiting time)  $Y$  เป็นส่วนกลับของอัตราการให้บริการ นั่นคือ  $Y = \frac{1}{X}$  โดยนิยามฟังก์ชัน  $r(x) = \frac{1}{x}$  ดังนั้น  $s(y) = \frac{1}{y}$  และอนุพันธ์ของ  $s$  เท่ากับ

$$\frac{ds(y)}{dy} = -\frac{1}{y^2}$$

- ซึ่งมีค่าน้อยกว่าศูนย์และ  $\left| \frac{ds(y)}{dy} \right| = \frac{1}{y^2}$  ดังนั้น ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของ  $Y$  เท่ากับ

$$g(y) = f\left(\frac{1}{y}\right) \frac{1}{y^2}$$

# ฟังก์ชันของตัวแปรสุ่มสองตัวขึ้นไป (Functions of Two or More Random Variables)

- หลักการที่ใช้ในการแปลงการแจกแจงในกรณีของฟังก์ชันของตัวแปรสุ่มสองตัวขึ้นไปก็ยังเป็นเช่นเดิม
  - ① หาฟังก์ชันการแจกแจงสะสม (C.D.F.)
  - ② หาฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) จากอนุพันธ์ของฟังก์ชันการแจกแจงสะสม (C.D.F.)
  - ③ มีความแตกต่างกันบ้างในทางเทคนิค โดยเฉพาะสูตรที่ใช้ในการแปลงโดยตรง (ในทำนองเดียวกับทฤษฎีบทที่แล้ว) ที่จำเป็นต้องใช้เครื่องมือที่เรียกว่าจาโคเบียนเมตริกซ์ (Jacobian matrix)

# ทฤษฎี: การแจกแจงของฟังก์ชันของตัวแปรสุ่มสองตัวขึ้นไป (Functions of Two or More Random Variables)

## Theorem

กำหนดให้  $X_1, \dots, X_n$  เป็นตัวแปรสุ่มต่อเนื่องที่มี  $f$  แทนฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.) สมมติให้เซต  $S \subset \mathbb{R}^n$  โดยที่  $\Pr((X_1, \dots, X_n) \in S) = 1$

พิจารณาตัวแปรสุ่ม  $Y_1, \dots, Y_n$  ซึ่งเป็นฟังก์ชันของ  $X_1, \dots, X_n$  ดังนี้

$$\begin{aligned} Y_1 &= r_1(X_1, \dots, X_n) \\ &\vdots \\ Y_n &= r_n(X_1, \dots, X_n) \end{aligned} \tag{19}$$

โดยที่  $r_i$  สำหรับ  $i = 1, \dots, n$  เป็นฟังก์ชันหนึ่งต่อหนึ่งที่หาอนุพันธ์ได้ (one-to-one and differentiable function) ซึ่งแปลงค่าจากเซต  $S$  ไปสู่เซต  $T \subset \mathbb{R}^n$  และกำหนดให้ฟังก์ชันผกผัน  $s_i$  ที่สอดคล้องกับฟังก์ชัน  $r_i$  สำหรับ  $i = 1, \dots, n$  เท่ากับ

$$\begin{aligned} x_1 &= s_1(y_1, \dots, y_n) \\ &\vdots \\ x_n &= s_n(y_1, \dots, y_n) \end{aligned} \tag{20}$$

## ทฤษฎี: การแจกแจงของฟังก์ชันของตัวแปรสุ่มสองตัวขึ้นไป (Functions of Two or More Random Variables) con't

### Theorem

ฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.) ของ  $Y_1, \dots, Y_n$  หาได้จาก

$$g(y_1, \dots, y_n) = \begin{cases} f(s_1, \dots, s_n) |J| & \text{สำหรับ } (y_1, \dots, y_n) \in T, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases} \quad (21)$$

โดยที่  $J$  แทนดีเทอร์มิแนนต์ (determinant) ของจาโคเบียนเมตริกซ์ (Jacobian matrix) ซึ่งมีค่าเท่ากับ

$$J = \det \begin{bmatrix} \frac{\partial s_1}{\partial y_1} & \dots & \frac{\partial s_1}{\partial y_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial s_n}{\partial y_1} & \dots & \frac{\partial s_n}{\partial y_n} \end{bmatrix} \quad (22)$$

ในที่นี้ สัญลักษณ์  $\det$  หมายถึงดีเทอร์มิแนนต์ (determinant) ของเมตริกซ์จัตุรัส

## ตัวอย่าง: การแจกแจงของฟังก์ชันของตัวแปรสุ่มสองตัวขึ้นไป

### Example

พิจารณาตัวแปรสุ่มต่อเนื่อง  $X$  และ  $Y$  ซึ่งมีฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.) เท่ากับ

$$f(x_1, x_2) = \begin{cases} 4xy & \text{สำหรับ } 0 < x_1 < 1 \text{ และ } 0 < y < 1, \\ 0, & \text{สำหรับกรณีอื่น} \end{cases}$$

สิ่งที่ต้องการทราบในตัวอย่างนี้คือ ฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.) ตัวแปรสุ่ม  $Z_1 = \frac{X}{Y}$  และ  $Z_2 = XY$

- เราสามารถเขียนฟังก์ชันที่เราสนใจได้เป็น

$$z_1(x, y) = \frac{x}{y} \text{ และ } z_2(x, y) = xy$$

- เราสามารถหาฟังก์ชันผกผันของฟังก์ชันทั้งสอง

$$x_1 = s_1(z_1, z_2) = \sqrt{\frac{z_1}{z_2}} \text{ และ } x_2 = s_2(z_1, z_2) = \sqrt{z_1 z_2}$$

# วิธีทำ: การแจกแจงของฟังก์ชันของตัวแปรสุ่มสองตัวขึ้นไป

## Example

- $S$  ในตัวอย่างนี้เท่ากับ  $S = \{(x, y) \in \mathbb{R}^2 : 0 < x_1 < 1 \text{ และ } 0 < y < 1\}$  เราหาเซต  $T$  ได้ดังต่อไปนี้ก่อนอื่น เนื่องจาก  $x > 0, y > 0, z_1 = \frac{x}{y}$  และ  $z_2 = xy$  ดังนั้น  $z_1, z_2 > 0$
- เราสามารถประยุกต์ใช้ฟังก์ชันผกผันร่วมกับเงื่อนไขของ  $x$  และ  $y$  ที่กำหนดให้  $0 < x_1 < 1$  และ  $0 < y < 1$  ในการคำนวณหาเซต  $T = \{(z_1, z_2) \in \mathbb{R}^2 : 0 < z_2 < \frac{1}{z_1} \text{ และ } 0 < z_2 < z_1\}$
- หาดีเทอร์มิแนนต์ (determinant) ของจาโคเบียนเมตริกซ์ (Jacobian matrix)

$$J = \det \begin{bmatrix} \frac{\partial s_1}{\partial z_1} & \frac{\partial s_1}{\partial z_2} \\ \frac{\partial s_2}{\partial z_1} & \frac{\partial s_2}{\partial z_2} \end{bmatrix} = \det \begin{bmatrix} \frac{1}{2} \sqrt{\frac{z_2}{z_1}} & \frac{1}{2} \sqrt{\frac{z_1}{z_2}} \\ -\frac{1}{2} \sqrt{\frac{z_2}{z_1^3}} & \frac{1}{2} \sqrt{\frac{1}{z_1 z_2}} = \frac{1}{2z_1} \end{bmatrix}$$

- เนื่องจาก  $z_1 > 0$  ดังนั้น  $|J| = \frac{1}{2z_1}$  และฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.) ตัวแปรสุ่ม  $Z_1 = \frac{X}{Y}$  และ  $Z_2 = XY$  เท่ากับ

$$g(z_1, z_2) = \begin{cases} 2 \frac{z_2}{z_1} \text{ สำหรับ } (z_1, z_2) \in T, \\ 0, \text{ สำหรับกรณีอื่น} \end{cases}$$

ทฤษฎี: การแจกแจงของฟังก์ชันของตัวแปรสุ่มสองตัวขึ้นไปของฟังก์ชันเชิงเส้น

### Theorem

กำหนดให้  $\mathbf{X} = (X_1, \dots, X_n)$  เป็นตัวแปรสุ่มต่อเนื่องที่มีฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.)  $f$  และนิยามฟังก์ชันเชิงเส้น

$$\mathbf{Y} = \mathbf{A}\mathbf{X} \quad (23)$$

โดยที่  $\mathbf{A}$  คือเมทริกซ์ไม่เอกฐาน (nonsingular matrix) ที่มีขนาด  $n \times n$  (บางครั้งเราเรียกว่าจำนวนจริงในเมทริกซ์นี้ว่าค่าสัมประสิทธิ์) ดังนั้น ฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.) ของ  $\mathbf{Y}$  หาได้จาก

$$g(\mathbf{y}) = \frac{1}{|\det \mathbf{A}|} f(\mathbf{A}^{-1}\mathbf{y}) \quad (24)$$

โดยที่  $\mathbf{A}^{-1}$  แทนส่วนผกผันของ  $\mathbf{A}$

# สรุป: การหาการแจกแจงของฟังก์ชันของตัวแปรสุ่มสองตัวขึ้นไป

- ทฤษฎีบทสองอันหลังนั้นมีประโยชน์ต่อการหาการแจกแจงของฟังก์ชันของตัวแปรสุ่มอย่างมาก
- มีข้อจำกัดในบางประการ
  - ▶ จำนวนฟังก์ชันที่พิจารณาต้องเท่ากับจำนวนตัวแปรสุ่มพื้นฐาน เพื่อให้จาโคเบียนเมตริกซ์ (Jacobian matrix) เป็นจัตุรัสจึงจะหาค่าได้
  - ▶ เราอาจจะสนใจปัญหาที่มีจำนวนฟังก์ชันแตกต่างจากจำนวนตัวแปรสุ่มพื้นฐาน ซึ่งโดยมากมักจะมีจำนวนฟังก์ชันน้อยกว่าจำนวนตัวแปร
- ยกตัวอย่างเช่น การประมาณการณสมการเชิงเส้นอย่างง่ายมักจะมีฟังก์ชันเดียวแต่มีตัวแปรสุ่มพื้นฐานจำนวนมาก
  - ▶ กรณีเช่นนี้เราสามารถกลับไปใช้หลักพื้นฐานที่เริ่มจากการหาฟังก์ชันการแจกแจงสะสม (C.D.F.)
  - ▶ แล้วจึงหาฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) จากอนุพันธ์ของฟังก์ชันการแจกแจงสะสม (C.D.F.)



ตัวอย่าง: การหาการแจกแจงของฟังก์ชันของตัวแปรสุ่มหลายตัวในกรณีที่ไม่สามารถหาจาโคเบียนเมตริกซ์ (Jacobian matrix) ได้

## Example

พิจารณาตัวอย่างสุ่ม (random sample) ขนาด  $n$  ซึ่งสุ่มเลือกมาจากตัวแปรสุ่ม  $X_1, X_2, \dots, X_n$  โดยที่แต่ละตัวมีฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.)  $f$  และฟังก์ชันการแจกแจงสะสมรวม (C.D.F.)  $F$  ที่เหมือนกัน พิจารณาตัวแปรสุ่มที่แทนค่าสูงสุด  $Y_m$  และค่าต่ำสุด  $Y_0$  ของตัวแปรสุ่มเหล่านั้นดังต่อไปนี้

$$Y_m = \max \{X_1, X_2, \dots, X_n\},$$

$$Y_0 = \min \{X_1, X_2, \dots, X_n\}$$

สิ่งที่ต้องการทราบคือ การแจกแจงของ  $Y_m$  และ  $Y_0$  ซึ่งสามารถคำนวณได้ตามขั้นตอนต่อไปนี้

- กำหนดฟังก์ชันการแจกแจงสะสม (C.D.F.) ของค่าสูงสุด  $Y_m$

$$G_m(y) = Pr(Y_m \leq y) = Pr(X_1 \leq y, X_2 \leq y, \dots, X_n \leq y)$$

- การที่ข้อมูลเป็นแบบตัวอย่างสุ่ม (random sample) ทำให้ทราบว่า  $X_1, X_2, \dots, X_n$  เป็นอิสระต่อกัน (independent) ดังนั้น

$$\begin{aligned} G_m(y) &= Pr(X_1 \leq y, X_2 \leq y, \dots, X_n \leq y) = Pr(X_1 \leq y) Pr(X_2 \leq y) \cdots Pr(X_n \leq y) \\ &= [F(y)]^n \end{aligned}$$

วิธีทำ: การหาการแจกแจงของฟังก์ชันของตัวแปรสุ่มหลายตัวในกรณีที่ไม่สามารถหาจาโคเบียนเมตริกซ์ (Jacobian matrix) ได้

## Example

- ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของ  $Y_n$  หาได้จากอนุพันธ์ของ  $G_n(y)$  ดังนี้

$$g_n(y) = \frac{dG_n(y)}{dy} = nf(y) [F(y)]^{n-1}$$

- การแจกแจงของฟังก์ชันค่าต่ำสุด  $Y_0$  เป็นดังนี้

$$\begin{aligned} G_0(y) &= Pr(Y_0 \leq y) = 1 - Pr(Y_0 > y) = 1 - Pr(X_1 > y, X_2 > y, \dots, X_n > y) \\ &= 1 - Pr(X_1 > y) Pr(X_2 > y) \cdots Pr(X_n > y) \\ &= 1 - [1 - F(y)]^n \end{aligned}$$

$$g(y) = \frac{dG(y)}{dy} = nf(y) [1 - F(y)]^{n-1}$$

- การแจกแจงร่วม (joint distribution) ของ  $(Y_0, Y_m)$  ได้ดังต่อไปนี้

$$G(y_0, y_m) = Pr(Y_0 \leq y_0, Y_m \leq y_m)$$

# วิธีทำ: การหาการแจกแจงของฟังก์ชันของตัวแปรสุ่มหลายตัวในกรณีที่ไม่สามารถหาจาโคเบียนเมตริกซ์ (Jacobian matrix) ได้

## Example

- กำหนดให้  $A$  แทนเหตุการณ์ที่  $Y_m \leq y_m$  นั่นคือเซต  $\{(x_1, \dots, x_n) : Y_m \leq y_m\}$  และ  $B$  แทนเหตุการณ์ที่  $Y_0 \leq y_0$
- นั่นคือเซต  $\{(x_1, \dots, x_n) : Y_0 \leq y_0\}$  และจากทฤษฎีบทที่ผ่านๆ มากล่าวว่า  $Pr(A \cap B) = Pr(A) - Pr(A \cap B^c)$  เราสามารถเขียน  $G$  ได้เป็น

$$\begin{aligned}G(y_0, y_m) &= Pr(Y_0 \leq y_0, Y_m \leq y_m) = Pr(Y_m \leq y_m) - Pr(Y_m \leq y_m, Y_0 > y_0) \\&= G_m(y_m) - Pr(y_0 < X_1 \leq y_m, \dots, y_0 < X_n \leq y_m) \\&= G_m(y_m) - \prod_{i=1}^n Pr(y_0 < X_i \leq y_m) = [F(y_m)]^n - [F(y_m) - F(y_0)]^n\end{aligned}$$

และฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.) ในกรณีที่  $-\infty < y_0 < y_m < \infty$  สามารถหาได้จากอนุพันธ์ของ  $G(y_0, y_m)$  ดังนี้

$$g(y_0, y_m) = \frac{\partial^2 G(y_0, y_m)}{\partial y_0 \partial y_m} = n(n-1)f(y_0)f(y_m)[F(y_m) - F(y_0)]^{n-2} \quad (25)$$

ส่วนในกรณีอื่นๆ จะกำหนดให้  $g(y_0, y_m) = 0$

## ตัวอย่าง: การแจกแจงของค่าพิสัย (range)

### Example

พิจารณาฟังก์ชัน  $Z = Y_m - Y_0$  ซึ่งเรียกว่าค่าพิสัย (range) คำถามก็คือ การแจกแจงของค่าพิสัยเป็นอย่างไร?

- เราทราบแล้วว่าฟังก์ชันความหนาแน่นของความน่าจะเป็นร่วม (joint p.d.f.) ของตัวแปรสุ่ม  $(Y_0, Y_m)$  เท่ากับ

$$g(y_0, y_m) = \frac{\partial^2 G(y_0, y_m)}{\partial y_0 \partial y_m} = n(n-1)f(y_0)f(y_m)[F(y_m) - F(y_0)]^{n-2}$$

- เราสามารถเทียบเคียงฟังก์ชันค่าพิสัย  $Z$  กับฟังก์ชันเชิงเส้นในตัวอย่างที่ 3.31 (ใน Lecture Note) ได้โดยกำหนดให้  $a_1 = -1, a_2 = 1$ , และ  $b = 0$  ดังนั้น ฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของ  $Z$  เท่ากับ

$$h(z) = \int_{-\infty}^{\infty} g(y_n - z, y_n) dy_n$$

- เรายังสามารถประยุกต์ใช้หลักการเปลี่ยนตัวแปรการอินทิเกรต (change of variable) โดยกำหนดให้  $w = y_n - z$  ดังนั้น  $dy_n = dw$  และ  $y_n = w + z$  เพื่อแปลงฟังก์ชันความหนาแน่นของความน่าจะเป็น (p.d.f.) ของ  $Z$  เป็น

$$h(z) = \int_{-\infty}^{\infty} g(w, w + z) dw$$