

## บทที่ 2 ทฤษฎีที่เกี่ยวข้อง

### 2.1 กระบวนการสโตแคสติก (Stochastic Processes)

#### นิยามที่ 2.1

กระบวนการสโตแคสติก เป็นเซตของกลุ่มของตัวแปรสุ่ม

กระบวนการสโตแคสติก จะเป็นตัวแปรสุ่มชนิดนับได้ที่มีจำนวนจำกัด เช่น การบันทึกอุณหภูมิในแต่ละวัน ซึ่งแต่ละรายการ(case) จะเรียกว่าเป็น พารามิเตอร์ชนิดไม่ต่อเนื่อง(discrete parameter process) และกระบวนการสโตแคสติกยังเป็นไปได้ที่จะเป็นตัวแปรสุ่มที่นับไม่ได้(infinite) ซึ่งในแต่ละรายการนี้จะเรียกว่าเป็นพารามิเตอร์ชนิดต่อเนื่อง(continuous parameter process) ตัวอย่าง สำหรับพารามิเตอร์ชนิดต่อเนื่อง เช่น สัญญาณการเตือนอย่างต่อเนื่องในการทำงานของเครื่องจักร ว่าทุกๆ จุดของเวลาในระหว่างวันจะเป็นตัวแปรสุ่มที่ถูกกำหนดในการออกแบบเครื่องจักร โดยตัวแปรสุ่มจะเท่ากับ 1 ถ้าเครื่องจักรทำงานและจะเท่ากับ 0 ถ้าเครื่องจักรไม่ทำงาน สมมติให้เครื่องทำงาน 55.78 นาที หลังจากทีเครื่องเริ่มสตาร์ท ดังนั้น  $X_{55.78} = 1$

#### นิยามที่ 2.2

เซตของจำนวนจริงที่ประกอบด้วยชุดของตัวแปรสุ่มทั้งหมดในกระบวนการสโตแคสติก เรียกว่าเป็นสถานะที่เป็นไปได้(state space) ในกระบวนการสโตแคสติก

สถานะที่เป็นไปได้ในกระบวนการสโตแคสติก อาจจะเป็นค่าที่มีลักษณะต่อเนื่อง หรือไม่ต่อเนื่องก็ได้ แต่จำนวนสมาชิกในสถานะที่เป็นไปได้นั้นต้องมีจำนวนจำกัด(finite)

กระบวนการสโตแคสติกอย่างง่ายจะพิจารณาจากตัวแปรสุ่มแบบอิสระ เช่น สมมติว่าเราจะตัดสินใจเล่นเกมสล็อตอย่างสุ่ม ด้วยเหรียญที่มีความเที่ยงตรง เริ่มต้นด้วยเรามีเงินอยู่ 5 บาท และเกมส์จะต้องทำการโยนเหรียญหลายๆครั้ง ถ้าเหรียญหงายขึ้นหัวเราก็จะได้เงิน 1 บาท แต่ถ้าหงายออกก็ยเราก็จะเสียเงิน 1 บาท เกมส์จะต้องเล่นไปเรื่อยๆ จนกระทั่งเหรียญเราหมด หรือเราได้กำไรเป็นเงิน 10 บาทจากฝ่ายตรงข้าม ดังนั้นเซตของผลการออกหัวและก้อยในการโยนเหรียญ ก็จะเป็นตัวแปรสุ่มแบบอิสระของกระบวนการสโตแคสติก

สมมติว่าบริษัทแห่งหนึ่งมีโทรศัพท์อยู่ 5 สาย และทั้ง 5 สาย จะถูกใช้ในเวลาที่กำหนดไว้ ภายในช่วงเวลาดังกล่าวจะถูกสังเกตจำนวนการใช้ในทุกๆ 2 นาที และจำนวนครั้งที่มีการใช้สายในแต่ละครั้งจะถูกบันทึกไว้

ให้  $X_1$  แทนจำนวนของสายที่ถูกใช้ครั้งแรก และ

$X_2$  คือจำนวนของสายที่ถูกใช้ครั้งที่ 2

ซึ่ง  $n=1, 2, \dots$  ดังนั้น  $X_n$  ก็คือจำนวนสายที่ถูกใช้ในเวลาที่  $n$

ลำดับของการสังเกต  $X_1, X_2, \dots, X_n$  คือกระบวนการสโตแคสติก หรือเป็นกระบวนการสุ่มเพราะค่าที่ได้จากการสังเกตแต่ละครั้ง ไม่สามารถที่จะคาดเดาได้ล่วงหน้า แต่มีความเป็นไปได้ที่จะระบุค่าที่แตกต่างกันได้ในแต่ละช่วงเวลา คือกระบวนการสโตแคสติกมีพารามิเตอร์ชนิดไม่ต่อเนื่อง (discrete time parameter) เพราะสายโทรศัพท์ที่ถูกใช้จะถูกสังเกตเฉพาะในช่วงเวลาใดเวลาหนึ่ง มากกว่าช่วงเวลาที่ต่อเนื่องกัน

ในกระบวนการสโตแคสติก การสังเกตครั้งที่ 1  $X_1$  เรียกว่าสถานะเริ่มต้นหรือสถานะเริ่มต้น และสำหรับ  $n=2, 3, \dots$  การสังเกตที่  $X_n$  เรียกว่าสถานะที่เป็นไปได้ในเวลา  $n$  ดังนั้นสถานะของกระบวนการในเวลา  $n$  ที่สายถูกใช้ จะอยู่ระหว่าง 0-5

ในกระบวนการสโตแคสติกที่มีพารามิเตอร์ชนิดไม่ต่อเนื่อง (discrete time parameter) นี้ สถานะของกระบวนการจะแตกต่างกันไปตามลักษณะของการสุ่ม เพื่อบรรยายแบบจำลองของความน่าจะเป็นนี้ จึงมีความจำเป็นที่จะต้องระบุความน่าจะเป็นของทุกๆ เงื่อนไขความน่าจะเป็น  $X_1$  และ  $X_{n+1}$  ดังนี้

$$P\{X_{n+1} = X_{n+1} | X_1 = X_1, X_2 = X_2, \dots, X_n = X_n\}$$

กล่าวอีกอย่างหนึ่ง คือ ทุกๆ ช่วงเวลาที่  $n$  แบบจำลองความน่าจะเป็นจะต้องระบุเงื่อนไขความน่าจะเป็นว่า กระบวนการอยู่ในสถานะ  $X_{n+1}$  ที่เวลา  $n+1$  ถ้าให้เวลาเป็น  $1, 2, \dots, n$  กระบวนการก็จะอยู่ในสถานะ  $X_1, X_2, \dots, X_n$

การวิเคราะห์ที่น่าสนใจอีกอย่างหนึ่งก็คือกระบวนการลูกโซ่มาร์คอฟ ซึ่งเป็นกระบวนการของพารามิเตอร์ชนิดไม่ต่อเนื่อง โดยอนาคตมาจากปัจจุบัน ปัจจุบันมาจากอดีต จากตัวอย่างที่ผ่านมา เรื่องเกมส์โยนเหรียญ พิจารณาแบบสโตแคสติกจากจำนวนเหรียญที่อีกฝ่ายจะมีได้ทันที หลังจากที่ยื่นเหรียญออกก็เลย ชุดผลลัพธ์ควรจะเริ่มที่ 5 และอาจจะเพิ่มขึ้น หรือลดลงทีละ 1 จนกระทั่ง

เกมส์จะยุติลงด้วยค่า 0 หรือ 10 สมมติว่าหลังจากการ โยนเหรียญ อีกฝ่ายหนึ่งได้ 3 เหรียญ ความน่าจะเป็นที่จะเกิดหลังจากการ โยนเหรียญครั้งต่อไปว่าจะได้ 4 เหรียญเป็น 0.5 และนั่นเป็นสิ่งที่รู้มาจากอดีต(ว่าอีกฝ่ายมีเหรียญตอนโยนครั้งที่ 1 หรือครั้งที่ 2 ผ่านมาแล้วเท่าไร) และในอนาคตก็มีความเป็นอิสระกับในอดีต เมื่อได้ค่าในปัจจุบันไปแล้ว

### นิยามที่ 2.3

กระบวนการลูกโซ่มาร์คอฟเป็นกระบวนการสโตแคสติกชนิดหนึ่ง ถ้าให้  $X_n = i$  เป็นกระบวนการที่สถานะ  $i$  ที่เวลา  $n$  สมมติว่ากระบวนการอยู่ในสถานะ  $i$  เราจะให้ความน่าจะเป็น  $P_{ij}$  เป็นสถานะต่อไปที่  $j$  นั่นคือ

$$P\{X_{n+1} = j | X_n = i, X_{n-1} = i_{n-1}, \dots, X_1 = i_1, X_0 = i_0\} = P_{ij}$$

สำหรับทุก ๆ สถานะ  $i_0, i_1, \dots, i_{n-1}, i, j$  และ  $n \geq 1$

ซึ่งอธิบายได้ว่า สถานะในอนาคต  $X_{n+1}$  จะขึ้นอยู่กับสถานะในปัจจุบัน  $X_n$  อย่างเดียว และสถานะปัจจุบัน  $X_n$  จะขึ้นอยู่กับสถานะในอดีต  $X_{n-1}$  อย่างเดียว ค่าของ  $P_{ij}$  จะเป็นความน่าจะเป็นของกระบวนการเมื่ออยู่ในสถานะ  $i$  และต่อไปจะเปลี่ยนแปลงไปในสถานะ  $j$  ดังนั้นจะได้ว่า

$$P_{ij} \geq 0, \quad i, j \geq 0 \quad \sum_{j=0}^{\infty} P_{ij} = 1, \quad i = 0, 1, \dots$$

ให้  $P$  เป็นเมตริกซ์การเปลี่ยนแปลงความน่าจะเป็นขั้นแรก  $P_{ij}$

$$P = \begin{bmatrix} P_{00} & P_{01} & P_{02} & \dots \\ P_{10} & P_{11} & P_{12} & \dots \\ \vdots & \vdots & \vdots & \\ P_{i0} & P_{i1} & P_{i2} & \dots \end{bmatrix}$$

## 2.2 สมการเชพแมนโคลโมโกรอฟ (Chapman-Kolmogorov Equations)

จากที่ได้กำหนดให้  $P_{ij}$  เป็นเมตริกซ์เริ่มแรกของการเปลี่ยนแปลงความน่าจะเป็น และในขณะนี้ถ้าความน่าจะเป็นเปลี่ยนไปจนถึงขั้นที่  $n$   $P_{ij}^n$  ก็จะเป็นเมตริกซ์ความน่าจะเป็นที่เกิดจากกระบวนการที่สถานะ  $i$  เปลี่ยนเป็นสถานะ  $j$  จนถึงเปลี่ยนไปเป็นสถานะที่  $n$

$$\text{นั่นหมายความว่า } P_{ij}^n = P\{X_{n+m} = j | X_m = i\}, n, i, j \geq 0 \quad (2.1)$$

เนื่องจากว่า  $P_{ij}^1 = P_{ij}$

สมการเชพแมนโคลโมโกรอฟ จึงเป็นวิธีสำหรับการหาความน่าจะเป็นที่เปลี่ยนแปลงในขั้นที่  $n$  ตามสมการ

$$P_{ij}^{n+m} = \sum_{k=0}^{\infty} P_{ik}^n P_{kj}^m \quad \text{สำหรับทุก } n, m \geq 0 \text{ และทุก } i, j \quad (2.2)$$

เพื่อความเข้าใจที่ง่ายขึ้นจะให้  $P_{ik}^n P_{kj}^m$  เป็นตัวแทนของความน่าจะเป็นที่เริ่มต้นที่  $i$  ไปยัง  $j$  จนเปลี่ยนแปลงไปถึง  $n+m$  ไปเรื่อย ๆ ในระหว่างนั้นจะผ่านสู่สถานะ  $k$  ที่การเปลี่ยนแปลงลำดับ  $n$  ดังนั้นผลรวมทั้งหมดของสถานะ  $k$  จะได้ความน่าจะเป็นว่ากระบวนการจะอยู่ในสถานะ  $j$  หลังจากการเปลี่ยนแปลงที่  $n+m$  ดังนี้

$$\begin{aligned} P_{ij}^{n+m} &= P\{X_{n+m} = j | X_0 = i\} \\ &= \sum_{k=0}^{\infty} P\{X_{n+m} = j, X_n = k | X_0 = i\} \\ &= \sum_{k=0}^{\infty} P\{X_{n+m} = j, X_n = k, X_0 = i\} P\{X_n = k | X_0 = i\} \\ &= \sum_{k=0}^{\infty} P_{kj}^m P_{ik}^n \end{aligned}$$

ถ้าให้  $P^n$  ใช้แทนเมตริกซ์ของการเปลี่ยนแปลงความน่าจะเป็น  $P_{ij}^n$  ขั้น  $n$  ตามสมการที่ (2.2) จะได้ว่า

$$P^{n+m} = P^n \cdot P^m$$

ใช้จุดเป็นตัวแทนการคูณเมตริกซ์ เช่น

$$P^2 = P^{(1+1)} = P \cdot P = P^2$$

และโดยการพิสูจน์จาก

$$P^n = P^{(n-1+1)} = P^{n-1} \cdot P = P^n$$

จะเห็นว่า การเปลี่ยนแปลงเมตริกซ์  $n$  ชั้น อาจหาได้จากการคูณกันของเมตริกซ์  $P$  ด้วยตัวมันเองถึง  $n$  ครั้ง

ตัวอย่างที่ 2.1 พิจารณาการพยากรณ์อากาศจาก

$$P = \begin{bmatrix} \alpha & 1-\alpha \\ \beta & 1-\beta \end{bmatrix}$$

โดย  $\alpha$  คือความน่าจะเป็นที่ฝนตกในวันนี้ แล้วฝนจะตกในวันพรุ่งนี้

$\beta$  คือความน่าจะเป็นที่ฝนไม่ตกในวันนี้ แต่ฝนจะตกในวันพรุ่งนี้

ถ้า  $\alpha = 0.7$  และ  $\beta = 0.4$  เป็นสถานะขั้นที่ 2 ให้คำนวณความน่าจะเป็นที่จะมีฝนตกอีก 4 วัน นับจากวันนี้โดยให้ฝนตกในวันนี้

การคำนวณ

$$P = \begin{bmatrix} 0.7 & 0.3 \\ 0.4 & 0.6 \end{bmatrix}$$

$$\text{ดังนั้น } P^2 = \begin{bmatrix} 0.7 & 0.3 \\ 0.4 & 0.6 \end{bmatrix} \cdot \begin{bmatrix} 0.7 & 0.3 \\ 0.4 & 0.6 \end{bmatrix}$$

$$\begin{aligned}
 &= \begin{bmatrix} 0.61 & 0.39 \\ 0.52 & 0.48 \end{bmatrix} \\
 P^4 &= (P^2)^2 = \begin{bmatrix} 0.61 & 0.39 \\ 0.52 & 0.48 \end{bmatrix} \begin{bmatrix} 0.61 & 0.39 \\ 0.52 & 0.48 \end{bmatrix} \\
 &= \begin{bmatrix} 0.5749 & 0.4251 \\ 0.5668 & 0.4332 \end{bmatrix}
 \end{aligned}$$

เพราะฉะนั้นความน่าจะเป็นที่ฝนจะตกในวันที่ 4 มีค่าเท่ากับ 0.5749

ดังนั้นความน่าจะเป็นทั้งหมด จะพิจารณาจากความน่าจะเป็นแบบเป็นเงื่อนไข ตัวอย่างเช่น  $P_{ij}^n$  เป็นความน่าจะเป็นที่สถานะเวลา  $n$  เป็น  $j$  ให้สถานะเวลาเริ่มต้น 0 เป็น  $i$  ถ้าการแจกแจงไม่เป็นแบบเป็นเงื่อนไข ก็จะได้การแจกแจงความน่าจะเป็นของสถานะเริ่มต้นเป็น

$$\alpha_i = P\{X_0 = i\}, \quad i \geq 0 \left( \sum_{i=0}^{\infty} \alpha_i = 1 \right)$$

ความน่าจะเป็นแบบไม่มีเงื่อนไขทั้งหมด อาจจะคำนวณ โดยเงื่อนไขของสถานะเริ่มต้นดังนี้

$$\begin{aligned}
 P\{X_n = j\} &= \sum_{i=0}^{\infty} P\{X_n = j | X_0 = i\} P\{X_0 = i\} \\
 &= \sum_{i=0}^{\infty} P_{ij}^n \alpha_i
 \end{aligned}$$

ตัวอย่างเช่น ถ้า  $\alpha_0 = 0.4$   $\alpha_1 = 0.6$  ในตัวอย่างที่ 2.1 และเมื่อความน่าจะเป็นเป็นแบบไม่มีเงื่อนไข ก็จะได้ความน่าจะเป็นที่ฝนจะตกในวันที่ 4 หลังจากที่เราบันทึกข้อมูลในวันแรก

$$\begin{aligned}
 P\{X_4 = 0\} &= 0.4P_{00}^4 + 0.6P_{10}^4 \\
 &= (0.4)(0.574) + (0.6)(0.5668) \\
 &= 0.5700
 \end{aligned}$$

### 2.3 การจำแนกสถานะ (Classification of States)

กล่าวได้ว่าสถานะ  $j$  ได้มาจากสถานะ  $i$  ถ้า  $P_{ij}^n > 0$  สำหรับบางค่าของ  $n \geq 0$  ซึ่งหมายความว่าสถานะ  $j$  ได้มาจากสถานะ  $i$  ถ้าเริ่มจากสถานะ  $i$  เท่านั้น และทำไปเรื่อยๆ จนถึงสถานะ  $j$

$$\begin{aligned} P\{\text{ทำจน ถึง } j \mid \text{เริ่มต้น } i\} &= P\left\{\bigcup_{n=0}^{\infty} \{X_n = j \mid X_0 = i\}\right\} \\ &\leq \sum_{n=0}^{\infty} P\{X_n = j \mid X_0 = i\} \\ &= \sum_{n=0}^{\infty} P_{ij}^n \\ &= 0 \end{aligned}$$

สถานะ  $i$  และสถานะ  $j$  จะต่อเนื่องถึงกันได้ (communicate) เขียนเป็น  $i \leftrightarrow j$  และสถานะอื่น ๆ ก็สามารถต่อเนื่องถึงกันได้ ด้วยตัวของมันเอง  
จากนิยาม

$$P_{ii}^0 = P\{X_0 = i \mid X_0 = i\} = 1$$

ความสัมพันธ์ของการต่อเนื่องถึงกันมีคุณสมบัติ 3 ข้อดังนี้

1. สถานะ  $i$  ต่อเนื่องถึงสถานะ  $i$  , ทุก ๆ  $i \geq 0$
2. ถ้าสถานะ  $i$  ต่อเนื่องกับสถานะ  $j$  แล้ว สถานะ  $j$  ก็จะต่อเนื่องกับสถานะ  $i$  ด้วย
3. ถ้าสถานะ  $i$  ต่อเนื่องกับสถานะ  $j$  และสถานะ  $j$  ต่อเนื่องกับสถานะ  $k$  แล้วสถานะ  $i$  ต่อเนื่องกับสถานะ  $k$  ด้วย

คุณสมบัติข้อที่ 1, 2 ก็เป็นไปตามนิยามของการต่อเนื่องถึงกัน ส่วนการพิสูจน์ในข้อที่ 3 สมมติว่าให้  $i$  ต่อเนื่องถึงกันกับ  $j$  และ  $j$  ต่อเนื่องถึงกันกับ  $k$  จะเป็นอยู่ 3 จำนวน ให้  $n$  และ  $m$  โดย  $P_{ij}^n > 0, P_{jk}^m > 0$  ใช้ สมการแซฟแมนโคลโมโกรอฟ จะได้ว่า

$$P_{ik}^{n+m} = \sum_{r=0}^{\infty} P_{ir}^n P_{rk}^m \geq P_{ij}^n P_{jk}^m > 0$$

ดังนั้นสถานะ  $k$  ก็จะได้มาจากสถานะ  $i$  ขณะเดียวกันสถานะ  $i$  ก็จะได้มาจากสถานะ  $k$  ดังนั้นสถานะ  $i$  และ  $k$  ก็จะต่อเนื่องถึงกันได้ (communicate)

2 สถานะที่ต่อเนื่องถึงกันได้จะเรียกว่าเป็นชั้นเดียวกัน (class) ผลที่ตามมาจากคุณสมบัติข้อ 1, 2 และ 3 ก็จะแบ่งสถานะออกเป็น 2 ชั้น หรือแยกต่างกันอย่างกล่าวได้ว่า แนวคิดของการต่อเนื่องถึงกัน ก็คือการแบ่งสถานะที่เป็นไปได้ทั้งหมดออกเป็นชั้นต่าง ๆ

กระบวนการลูกโซ่มาร์คอฟจะเรียกลักษณะนี้ว่า irreducible ถ้ามีเพียงชั้นเดียว นั่นคือถ้าทุกสถานะต่อเนื่องถึงกันและกัน

### ตัวอย่างที่ 2.2

พิจารณาลูกโซ่มาร์คอฟที่มีค่าคงที่ 3 สถานะ 0, 1, 2 มีเมตริกซ์การเปลี่ยนแปลงความน่าจะเป็นดังนี้

$$P = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} & 0 \\ \frac{1}{2} & \frac{1}{4} & \frac{1}{4} \\ 0 & \frac{1}{3} & \frac{2}{3} \end{bmatrix}$$

มันง่ายที่จะตรวจสอบว่า ลูกโซ่มาร์คอฟ เป็น irreducible หรือไม่ จากตัวอย่างนี้ มันเป็นไปได้ที่จะเริ่มต้นจากสถานะ 0 ไปสถานะ 2

$$0 \rightarrow 1 \rightarrow 2$$

นั่นคือจากสถานะ 0 ไปสถานะ 2 จะมีความน่าจะเป็นดังนี้ จากสถานะ 0 ไปสถานะ 1 ด้วยความน่าจะเป็น  $\frac{1}{2}$  และจากสถานะ 1 ไปสถานะ 2 ด้วยความน่าจะเป็น  $\frac{1}{4}$

### ตัวอย่างที่ 2.3

พิจารณาลูกโช่มาร์คอฟที่มีค่าคงที่ของ 4 สถานะ 0, 1, 2, 3 และมีเมตริกซ์การเปลี่ยนแปลงของความน่าจะเป็นดังนี้

$$P = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} & 0 & 0 \\ \frac{1}{2} & \frac{1}{2} & 0 & 0 \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

ชั้นของลูกโช่มาร์คอฟจะเป็น  $\{0, 1\}$ ,  $\{2\}$  และ  $\{3\}$  ในขณะที่สถานะ 0 หรือ (1) เป็นค่าที่ได้มาจากสถานะ 2 การกลับกันดังนี้ จะไม่เป็นความจริง

ดังนั้นสถานะที่ 3 จะเรียกว่าเป็นสถานะดูดกลืน (absorbing State) นั่นคือ  $P_{33} = 1$  ซึ่งสถานะที่ 3 นี้ ไม่สามารถที่จะเปลี่ยนเป็นสถานะอื่นได้อีก

สำหรับทุก ๆ สถานะ  $i$  จะให้  $f_i$  เป็นความน่าจะเป็นที่เริ่มต้นจากสถานะ  $i$  กระบวนการจะทำการเข้าไปในสถานะ  $i$  ใหม่ สถานะ  $i$  จะเรียกว่าเป็น recurrent ถ้า  $f_i = 1$  และ transient ถ้า  $f_i < 1$

สมมติว่ากระบวนการเริ่มที่สถานะ  $i$  และวนเกิดซ้ำที่  $i$  ดังนั้นด้วยความน่าจะเป็น 1 กระบวนการจะถูกวนกลับมาในสถานะ  $i$  ในที่สุด อย่างไรก็ตาม ตามคำจำกัดความหรือนิยามของลูกโช่มาร์คอฟ จะกล่าวว่ากระบวนการจะเริ่มขึ้นอีกครั้ง เมื่อวนกลับไปทำที่สถานะ  $i$  ใหม่ ดังนั้น ในที่สุดสถานะ  $i$  จะถูกทำอีกครั้ง

การทำซ้ำต่อเนื่องไปนาน ๆ ก็เป็นเหตุผลที่จะนำไปสู่ข้อสรุปว่า ถ้าสถานะ  $i$  เป็น recurrent แล้ว เริ่มต้นที่สถานะ  $i$  กระบวนการจะวนกลับมาที่สถานะ  $i$  อีกซ้ำแล้วซ้ำเล่าไม่มีที่สิ้นสุด

ส่วนอีกเรื่องหนึ่ง สมมติว่าถ้าสถานะเป็น transient ดังนั้นแต่ละเวลาของกระบวนการที่จะเข้าไปในสถานะ  $i$  จะมีความน่าจะเป็นเชิงบวก  $1 - f_i$  นั่นคือจะไม่เข้าไปในสถานะนั้นอีก ดังนั้นเมื่อเริ่มต้นที่สถานะ  $i$  ความน่าจะเป็นที่กระบวนการจะอยู่ในสถานะ  $i$  เป็นช่วงเวลา  $n$  อย่างแน่นอนมีค่าเท่ากับ  $f_i^{n-1}(1-f_i)$  ,  $n \geq 1$

อาจกล่าวได้ว่า ถ้าสถานะ  $i$  เป็น transient แล้วเริ่มต้นที่สถานะ  $i$  จำนวนของช่วงเวลาที่กระบวนการจะอยู่ในสถานะ  $i$  จะมีการแจกแจงแบบเรขาคณิตด้วยค่าเฉลี่ย  $1/(1-f_i)$

จากที่กล่าวมา จะได้ว่าสถานะ  $i$  เป็น recurrent ถ้าเริ่มต้นที่สถานะ  $i$  เท่านั้น จำนวนค่าคาดหวังของช่วงเวลาที่กระบวนการอยู่ในสถานะ  $i$  จะไม่มีที่สิ้นสุด (infinite) แต่จะทำให้เกิด

$$A_n = \begin{cases} 1 & \text{ถ้า } X_n = i \\ 0 & \text{ถ้า } X_n \neq i \end{cases}$$

จะใช้  $\sum_{n=0}^{\infty} A_n$  แสดงจำนวนของช่วงเวลาที่กระบวนการอยู่ในสถานะ  $i$

$$\begin{aligned} \text{ดังนั้น } E\left[\sum_{n=0}^{\infty} A_n \mid X_0 = i\right] &= \sum_{n=0}^{\infty} E[A_n \mid X_0 = i] \\ &= \sum_{n=0}^{\infty} P\{X_n = i \mid X_0 = i\} \\ &= \sum_{n=0}^{\infty} P_{ii}^n \end{aligned}$$

จะพิสูจน์ได้ตามนี้

ข้อเสนอที่ 2.1 สถานะ  $i$  เป็น

$$\text{recurrent ถ้า } \sum_{n=0}^{\infty} P_{ii}^n = \infty$$

$$\text{transient ถ้า } \sum_{n=0}^{\infty} P_{ii}^n < \infty$$

เหตุผลที่จะทำให้ข้อเสนอกี้กล่าวมามีความสำคัญมากขึ้น ในการแสดงให้เห็นว่าสถานะ transient จะถูกวนกลับมาทำด้วยจำนวนครั้งที่นับได้ (finite) เท่านั้น ตรงนี้จะนำไปสู่การสรุปว่า สถานะที่นับได้ในลูกโซ่มาร์คอฟนั้น ไม่ได้เป็นสถานะทั้งหมดที่จะเป็น transient จะเห็นว่าสมมติให้สถานะเป็น  $0, 1, \dots, M$  และให้สถานะทั้งหมดเป็น transient ดังนั้นหลังจากเวลาที่นับได้ ( $T_0$ ) สถานะที่ 0 จะไม่มีการกลับมาทำอีก และหลังจากเวลา ( $T_1$ ) สถานะที่ 1 ก็จะไม่มีการกลับมาทำอีก และหลังจากเวลา ( $T_2$ ) สถานะที่ 2 ก็จะไม่มีการกลับมาทำอีก ไปเรื่อย ๆ ดังนั้นหลังจากเวลาที่นับได้  $T = \text{Max}[T_0, T_1, \dots, T_M]$  จะไม่เป็นสถานะที่ถูกวนมาพบได้ แต่กระบวนการจะต้องมีบางสถานะหลังจาก  $T$  ที่จะมีการถูกทำซึ่งแสดงว่าอย่างน้อยที่สุด หนึ่งสถานะจะต้อง recurrent อีกประการหนึ่งที่ใช้ข้อเสนอ 2.1 ก็เพื่อจะแสดงถึงคุณสมบัติของชั้นการเกิดขึ้นซ้ำ ๆ (recurrence)

**บทพิสูจน์ 2.2** ถ้าสถานะ  $i$  เป็น recurrent และสถานะ  $i$  ต่อเนื่องถึงกันกับสถานะ  $j$  ดังนั้นสถานะ  $j$  เป็น recurrent

พิสูจน์ เริ่มแรกจะพิสูจน์ว่า เมื่อสถานะ  $i$  ต่อเนื่องถึงกันกับสถานะ  $j$  จำนวนเต็มที่มีอยู่ของ  $k$  และ  $m$  จะเป็นดังนี้

$$P_{ij}^{m+n+k} \geq P_{ji}^m P_{ii}^n P_{ij}^k$$

ดังนั้นด้านซ้ายมือเป็นความน่าจะเป็นจาก  $j$  ไป  $j$  ในขั้นที่  $m+n+k$  ขณะที่ด้านขวามือเป็นความน่าจะเป็นจาก  $j$  ไป  $j$  ในขั้นที่  $m+n+k$  โดยผ่านจาก  $j$  ไป  $i$  ในขั้นที่  $m$  แล้วจาก  $i$  ไป  $i$  ในขั้นที่  $n$  แล้วจาก  $i$  ไป  $j$  ในขั้นที่  $k$

จากสิ่งที่ได้มา โดยใช้การรวมด้วย  $n$  จะได้ว่า

$$\sum_{n=1}^{\infty} P_{ij}^{m+n+k} \geq P_{ji}^m P_{ij}^k \sum_{n=1}^{\infty} P_{ii}^n = \infty$$

เมื่อ  $P_{ji}^m P_{ij}^k > 0$  และ  $\sum_{n=1}^{\infty} P_{ii}^n$  เป็นค่าที่ไม่จำกัด (infinite) เมื่อสถานะ  $i$  เป็น recurrent ดังนั้นตามข้อเสนอที่ 2.1 จึงแสดงว่าสถานะ  $j$  เป็น recurrent ด้วย

**ข้อสังเกต** 1. บทพิสูจน์ที่ 2.2 มีความหมายว่า transience เป็นคุณสมบัติของชั้นชนิดหนึ่ง ถ้าสถานะ  $i$  เป็น transient และต่อเนื่องถึงกันกับสถานะ  $j$  แล้วสถานะ  $j$  จะต้องเป็น transient ด้วย และถ้า  $j$  เป็น recurrent แล้ว ตามบทพิสูจน์ที่ 2.2  $i$  จะต้องเป็น recurrent ด้วย ดังนั้นจะไม่เป็น transient

2. บทพิสูจน์ที่ 2.2 จะเป็นแนวทางที่ทำให้ได้ผลลัพธ์ว่า ไม่ใช่สถานะทั้งหมดที่นับได้ในลูกโซ่มาร์คอฟ ที่จะเป็น transient ซึ่งนำไปสู่การสรุปว่าสถานะทั้งหมดที่นับได้ในลูกโซ่มาร์คอฟชนิด irreducible เป็น recurrent

#### ตัวอย่างที่ 2.4

ให้ลูกโซ่มาร์คอฟที่มีสถานะคงที่ 0, 1, 2, 3 มีเมตริกซ์ความน่าจะเป็นของการเปลี่ยนแปลง

$$P = \begin{bmatrix} 0 & 0 & \frac{1}{2} & \frac{1}{2} \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$$

จะกำหนดว่าสถานะจะเป็น transient หรือเป็น recurrent

#### การวิเคราะห์

เนื่องจากสถานะทั้งหมดต่อเนื่องถึงกัน และเป็นลูกโซ่ที่สามารถนับได้ ดังนั้นสถานะทั้งหมดจะต้องเป็น recurrent

ตัวอย่างที่ 2.5 พิจารณาลูกโซ่มาร์คอฟที่มีสถานะ 0, 1, 2, 3, 4 และ

$$P = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} & 0 & 0 & 0 \\ \frac{1}{2} & \frac{1}{2} & 0 & 0 & 0 \\ 0 & 0 & \frac{1}{2} & \frac{1}{2} & 0 \\ 0 & 0 & \frac{1}{2} & \frac{1}{2} & 0 \\ \frac{1}{4} & \frac{1}{4} & 0 & 0 & \frac{1}{2} \end{bmatrix}$$

จะกำหนดให้เป็นสถานะ transient หรือ recurrent

การวิเคราะห์ ลูกโซ่นี้จะมีชั้นที่คงที่แบ่งได้เป็น 3 ชั้น  $\{0, 1\}$ ,  $\{2, 3\}$  และ  $\{4\}$  2 ชั้นแรกเป็น recurrent และชั้นที่ 3 เป็น transient

## 2.4 ลิมิตความน่าจะเป็น (Limiting Probabilities)

ทฤษฎีที่ 2.1 สำหรับลูกโซ่มาร์คอฟที่ irreducible ergodic

$\lim_{n \rightarrow \infty} P_{ij}^n$  มีค่าและ  $i$  เป็นอิสระแล้วจะได้ว่า

$$\pi_j = \lim_{n \rightarrow \infty} P_{ij}^n, \quad j \geq 0$$

เมื่อ  $\pi_j$  มีลักษณะเฉพาะในการคำนวณคือ

$$\pi_j = \sum_{i=0}^{\infty} \pi_i P_{ij}, \quad j \geq 0 \quad (2.3)$$

$$\sum_{j=0}^{\infty} \pi_j = 1$$

ข้อสังเกต 1. ให้  $\pi_j = \lim_{n \rightarrow \infty} P_{ij}^n$  และสถานะเริ่มต้นที่  $i$  เป็นอิสระ จะเห็นว่าค่าของ  $\pi$  ในสมการที่ 2.3 จะได้จาก  $P\{X_{n+1} = j\}$  โดยเป็นเงื่อนไขของสถานะ ณ เวลา  $n$  นั่นคือ

$$\begin{aligned} P\{X_{n+1} = j\} &= \sum_{i=0}^{\infty} P\{X_{n+1} = j | X_n = i\} P\{X_n = i\} \\ &= \sum_{i=0}^{\infty} P_{ij} P\{X_n = i\} \end{aligned}$$

ให้  $n \rightarrow \infty$  และเมื่อใส่ค่าลิมิตเข้าไป

$$\pi_j = \sum_{i=0}^{\infty} P_{ij} \pi_i$$

2. นั้นแสดงว่า  $\pi_j$  เป็นลิมิตความน่าจะเป็นของกระบวนการในสถานะ  $j$  ณ เวลา  $n$  ดังนั้นจะมีค่าเท่ากับสัดส่วนระยะยาวของเวลาที่กระบวนการจะอยู่ในสถานะ  $j$

3. ใน irreducible ที่ recurrent เกิดขึ้นแน่นอน ช่วงเวลาที่จะยังคงให้  $\pi_j, j \geq 0$  เป็นลักษณะเฉพาะในการคำนวณ

$$\pi_j = \sum_i \pi_i P_{ij}$$

$$\sum_j \pi_j = 1$$

แต่  $\pi_j$  จะต้องเป็นสัดส่วนระยะยาวของเวลาของลูกโซ่มาร์คอฟที่สถานะ  $j$

### ตัวอย่างที่ 2.6

พิจารณาตัวอย่างที่ 2.1 ซึ่งสมมติว่าถ้ามีฝนตกในวันนี้ จากนั้นแล้วจะตกในวันพรุ่งนี้ ด้วยความน่าจะเป็น  $\alpha$  ; และถ้าฝนไม่ตกในวันนี้ จากนั้นฝนจะตกในวันพรุ่งนี้ ด้วยความน่าจะเป็น  $\beta$  ถ้าให้ว่าสถานะที่ 0 เป็นฝนตก และให้สถานะที่ 1 เป็นฝนไม่ตก ดังนั้นโดยการใช้สมการที่ 2.3 ลิมิตความน่าจะเป็น  $\pi_0$  และ  $\pi_1$  จะเป็น

$$\pi_0 = \alpha\pi_0 + \beta\pi_1$$

$$\pi_1 = (1-\alpha)\pi_0 + (1-\beta)\pi_1$$

$$\pi_0 + \pi_1 = 1$$

$$\text{จะได้ } \pi_0 = \frac{\beta}{1+\beta-\alpha}, \quad \pi_1 = \frac{1-\alpha}{1+\beta-\alpha}$$

ในตัวอย่างถ้า  $\alpha = 0.7$  และ  $\beta = 0.4$  ดังนั้นลิมิตความน่าจะเป็นที่ฝนจะตก  $\pi_0 = \frac{4}{7} = 0.571$

### ตัวอย่างที่ 2.7

พิจารณาลูกโซ่มาร์คอฟที่มีเมตริกซ์การเปลี่ยนแปลงความน่าจะเป็นของสภาวะทางด้านอารมณ์ 3 ลักษณะดังนี้ ร่าเริง, ซึมเศร้า และเศร้าซึม ดังนี้

$$P = \begin{bmatrix} 0.5 & 0.4 & 0.1 \\ 0.3 & 0.4 & 0.3 \\ 0.2 & 0.3 & 0.5 \end{bmatrix}$$

ในระยะยาว สัดส่วนเวลาของกระบวนการนี้จะมีสถานะทั้ง 3 เป็นอย่างไร

$$\pi_0 = 0.5\pi_0 + 0.3\pi_1 + 0.2\pi_2$$

$$\pi_1 = 0.4\pi_0 + 0.4\pi_1 + 0.3\pi_2$$

$$\pi_2 = 0.1\pi_0 + 0.3\pi_1 + 0.5\pi_2$$

$$\pi_0 + \pi_1 + \pi_2 = 1$$

เมื่อแก้สมการแล้วจะได้

$$\pi_0 = 21/62 \quad \pi_1 = 23/62 \quad \pi_2 = 18/62$$

## ตัวอย่างที่ 2.8

เป็นปัญหาที่น่าสนใจของนักสังคมศาสตร์ที่มีข้อสรุปเกี่ยวกับการจัดระดับสังคมอาชีพระดับบนหรือระดับล่าง พบว่ามีรูปแบบทางคณิตศาสตร์ที่จะสมมติให้การเปลี่ยนแปลงระหว่างชั้นของสังคมเชื่อถือได้ โดยการใช้การเปลี่ยนแปลงแบบลูกโซ่มาร์คอฟ นั่นคือจะสมมติให้อาชีพของเด็กขึ้นอยู่กับครอบครัวของเขาเพียงอย่างเดียว สมมติว่าได้เมตริกซ์การเปลี่ยนแปลงแล้ว ดังนี้

$$P = \begin{bmatrix} 0.45 & 0.48 & 0.07 \\ 0.05 & 0.70 & 0.25 \\ 0.01 & 0.50 & 0.49 \end{bmatrix}$$

ตามตัวอย่างสมมติว่าเด็กที่ทำงานอยู่ในระดับกลาง ก็จะได้ทำงานอาชีพระดับบนระดับกลาง หรือระดับต่ำ ด้วยความน่าจะเป็น 0.05, 0.70, 0.25

ดังนั้นลิมิตความน่าจะเป็น  $\pi_i$  จะได้ดังนี้

$$\pi_0 = 0.45\pi_0 + 0.05\pi_1 + 0.01\pi_2$$

$$\pi_1 = 0.48\pi_0 + 0.70\pi_1 + 0.50\pi_2$$

$$\pi_2 = 0.07\pi_0 + 0.25\pi_1 + 0.49\pi_2$$

$$\pi_0 + \pi_1 + \pi_2 = 1$$

ดังนั้น

$$\pi_0 = 0.07 \quad \pi_1 = 0.62 \quad \pi_2 = 0.31$$

อาจจะกล่าวได้ว่า สังคมที่มีการเปลี่ยนแปลงระหว่างชั้นนั้นสามารถอธิบายได้ด้วยเมตริกซ์ความน่าจะเป็นของกระบวนการลูกโซ่มาร์คอฟ (ตามเมตริกซ์ที่ได้กล่าวไว้ข้างต้น) และในระยะยาวจะมีเพียง 7 เปอร์เซ็นต์ที่จะทำงานในระดับบน 62 เปอร์เซ็นต์ จะทำงานในระดับกลาง และ 31 เปอร์เซ็นต์จะทำงานในระดับล่าง

## 2.5 กระบวนการแตกแขนง(Branching Process)

ในเรื่องนี้จะพิจารณาชั้นของกระบวนการลูกโซ่มาร์คอฟด้วยกระบวนการแตกแขนง (Branching Process) ซึ่งจะมีการประยุกต์อย่างมากมายหลายด้านเช่นทางด้านชีววิทยา ด้านสังคมศาสตร์ ด้านวิศวกรรมศาสตร์ และวิทยาศาสตร์

เช่น ปัญหาการเจริญเติบโตของประชากร

ให้  $P_x$  เป็นความน่าจะเป็นในการผลิตลูกหลาน (off spring) ของแต่ละคน

ซึ่งถ้า  $P_x = 0$  หมายถึงการสูญสิ้นหรือการตายของแต่ละคน

$P_x > 0$  หมายถึงการที่แต่ละคน สามารถผลิตลูกหลานได้ต่อไป

การเกิดปฏิกิริยานิวเคลียร์

สมมติว่าเราปล่อยให้รังสีนิวตรอน ไปกระทบสารนิวเคลียร์มีผลทำให้เกิดการแตกสลายของนิวเคลียร์ เนื่องจากปฏิกิริยาการปะทะกัน ซึ่งผลจากการแตกสลายของนิวเคลียร์ ก็จะทำให้เกิดนิวตรอนใหม่ ๆ ขึ้นมา ซึ่งนิวตรอนเหล่านี้เกิดไปชนหรือปะทะกันอีก ก็จะมีผลทำให้เกิดเป็นนิวตรอนใหม่ ๆ เช่นนี้ไปเรื่อย ๆ

ปัญหาด้านชีววิทยา

กระบวนการสืบสกุล ซึ่งการสืบสกุลจะนับจากการมีบุตรชาย เนื่องจากเราจะถือว่าบุตรชายเป็นผู้สืบสกุล ซึ่งถ้า generation ใดไม่มีบุตรชายสำหรับสืบสกุล จะถือว่า generation นั้นสูญหายหรือหมดไป ในการผลิตลูกหลาน

พิจารณาประชากรที่ประกอบด้วยความสามารถในการที่จะผลิตของแต่ละอย่างที่ทำให้ผลผลิตคล้าย ๆ กัน สมมติให้แต่ละชนิดหรือแต่ละอย่างโดยชั่วชีวิตหรือเวลาการทำงานสุดท้ายมีผลผลิตเป็น  $j$  มีความน่าจะเป็นเป็น  $P_j$ ,  $j \geq 0$  และจำนวนผลผลิตของแต่ละอย่างต้องเป็นอิสระกัน สมมติว่า  $P_j < 1$  สำหรับทุก ๆ  $j \geq 0$  แต่ละจำนวนของผลผลิตที่เริ่มต้นจะให้ เป็น  $X_0$  เรียกว่าเป็นขนาดของ generation ที่ 0 ผลผลิตทั้งหมดของสถานะที่ 0 จะประกอบหรือก่อขึ้นเป็น generation ที่หนึ่ง และจำนวนของผลผลิตเหล่านี้ จะให้ เป็น  $X_1$  ลักษณะนี้ไปเรื่อย ๆ จึงให้  $X_n$  เป็นขนาดของ generation ที่  $n$  โดย  $\{X_n, n = 0, 1, \dots\}$  เป็นลูกโซ่มาร์คอฟ ที่มีสถานะที่เป็นไปได้เป็นจำนวนเต็มบวก

สังเกตได้ว่าสถานะที่ 0 จะเป็นสถานะที่เกิดซ้ำ ๆ กัน (recurrent) จึงให้  $P_{00} = 1$  ดังนั้น ถ้า  $P_0 > 0$  สถานะอื่น ๆ ทั้งหมดก็จะเป็นสถานะที่มีการเปลี่ยนแปลง (transient) จะเขียนด้วย  $P_{i0} = P_0^i$  ซึ่งมีความหมายว่า เริ่มต้นด้วยสถานะ  $i$  ที่มีความน่าจะเป็นเชิงบวก  $P_0^i$  เป็นอย่างน้อย ยิ่งไปกว่านั้นเซตของสถานะที่มีการเปลี่ยนแปลง  $\{1, 2, \dots, n\}$  จะถูกทำซ้ำจนบ่อยครั้ง ซึ่งนำไปสู่บทสรุปที่สำคัญว่า ถ้า  $P_0 > 0$  แล้วประชากรอาจจะหมดไปสูญไป หรืออาจมีขนาดที่ประมาณไม่ได้

ให้

$$\mu = \sum_{j=0}^{\infty} jP_j$$

เป็นค่าเฉลี่ยของผลผลิตในแต่ละอัน และให้

$$\sigma^2 = \sum_{j=0}^{\infty} (j - \mu)^2 P_j$$

เป็นความแปรปรวนของผลผลิตที่ผลิตได้ในแต่ละอัน

สมมติว่า  $X_0 = 1$  เป็นค่าเริ่มต้นของแต่ละอันในปัจจุบัน จะคำนวณ  $E[X_n]$  และ  $Var(X_n)$  โดยอาจจะเขียนเป็น

$$X_n = \sum_{i=0}^{X_{n-1}} Z_i$$

ให้  $Z_i$  เป็นจำนวนผลผลิตของแต่ละ  $i$  ครั้ง ณ. generation ที่  $(n-1)$  ตามเงื่อนไขของ  $X_{n-1}$  จะได้ว่า

$$\begin{aligned} E[X_n] &= E[E[X_n | X_{n-1}]] \\ &= E\left[E\left[\sum_{i=1}^{X_{n-1}} Z_i \mid X_{n-1}\right]\right] \end{aligned}$$

$$\begin{aligned}
 &= E[X_{n-1}\mu] \\
 &= \mu E[X_{n-1}] \quad (2.4)
 \end{aligned}$$

จะใช้  $E[Z_i] = \mu$  เนื่องจาก  $E[X_0] = 1$  ในสมการที่ 2.4 จะได้ว่า

$$\begin{aligned}
 E[X_1] &= \mu \\
 E[X_2] &= \mu E[X_1] = \mu^2 \\
 &\vdots \\
 E[X_n] &= \mu E[X_{n-1}] = \mu^n
 \end{aligned}$$

ในทำนองเดียวกัน  $Var(X_n)$  ก็จะหาได้จากการใช้เงื่อนไขของความแปรปรวนตามสูตร

$$Var(X_n) = E[Var(X_n|X_{n-1})] + Var(Var[X_n|X_{n-1}])$$

ให้  $X_{n-1}, X_n$  เป็นผลรวมของตัวแปรสุ่มอิสระ  $X_{n-1}$  ซึ่งมีการแจกแจง  $\{P_j, j \geq 0\}$  ดังนั้น

$$Var(X_n|X_{n-1}) = X_{n-1}\sigma^2$$

ดังนั้นเงื่อนไขความแปรปรวนก็จะได้ว่า

$$\begin{aligned}
 Var(X_n) &= E[X_{n-1}\sigma^2] + Var(X_{n-1}\mu) \\
 &= \sigma^2 \mu^{n-1} + \mu^2 Var(X_{n-1})
 \end{aligned}$$

จาก  $Var(X_0) = 0$  จะทำให้ได้

$$Var(X_n) = \begin{cases} \sigma^2 \mu^{n-1} \left( \frac{\mu^n - 1}{\mu - 1} \right) & \text{ถ้า } \mu \neq 1 \\ n\sigma^2 & \text{ถ้า } \mu = 1 \end{cases} \quad (2.5)$$

ให้  $\pi_0$  เป็นความน่าจะเป็นที่ประชากรมีโอกาสหมดไปสูญไป (ภายใต้ข้อสมมติว่า  $X_0 = 1$ )

$$\pi_0 = \lim_{n \rightarrow \infty} P\{X_n = 0 | X_0 = 1\}$$

ปัญหาในการกำหนดค่า  $\pi_0$  เป็นการรวมครั้งแรก ด้วยการทำให้หมดไป เริ่มแรกจะให้  $\pi_0 = 1$  ถ้า  $\mu < 1$  จะได้ดังนี้

$$\begin{aligned} m^n &= E[X_n] = \sum_{j=1}^{\infty} j P_j\{X_n = j\} \\ &\geq \sum_{j=1}^{\infty} 1 \cdot P\{X_n = j\} \\ &= P\{X_n \geq 1\} \end{aligned}$$

เนื่องจาก  $\mu^n \rightarrow 0$  เมื่อ  $\mu < 1$  จะทำให้  $P\{X_n \geq 1\} \rightarrow 0$  ดังนั้นจะได้  $P\{X_n = 0\} \rightarrow 1$  นั้นแสดงว่า  $\pi_0 = 1$  เสมอเมื่อ  $\mu < 1$

$\pi_0 < 1$  เมื่อ  $\mu > 1$  และในการกำหนดสมการ  $\pi_0$  อาจจะเป็นผลจากเงื่อนไขของจำนวนผลผลิตในสถานะเริ่มแรกเช่น

$$\begin{aligned}\pi_0 &= P \{ \text{ประชากรหมดไปสูญไป} \} \\ &= \sum_{j=0}^{\infty} P \{ \text{ประชากรหมดไปสูญไป} \mid X_1 = j \} P_j\end{aligned}$$

ให้  $X_1 = j$  เป็นประชากรที่มีโอกาสที่จะหมดไป ถ้าแต่ละ  $j$  เริ่มด้วยให้สมาชิกหมดไปตั้งแต่ใน generation ที่หนึ่ง เนื่องจากแต่ละ  $j$  จะถูกสมมติให้เป็นอิสระต่อกัน และความน่าจะเป็นของแต่ละ  $j$  ที่จะหมดไปเป็น  $\pi_0$  ดังนั้นจะได้ว่า

$$P \{ \text{ประชากรหมดไปสูญไป} \mid X_1 = j \} = \pi_0^j$$

ดังนั้น  $\pi_0$  ก็จะได้

$$\pi_0 = \sum_{j=0}^{\infty} \pi_0^j P_j \quad (2.6)$$

เมื่อ  $\mu > 1$  สามารถแสดงได้ว่า  $\pi_0$  จะเป็นจำนวนบวกที่น้อยที่สุดในสมการที่ 2.6

ตัวอย่างที่ 2.9

ถ้า  $P_0 = 1/2$ ,  $P_1 = 1/4$ ,  $P_2 = 1/4$  ดังนั้นจะได้ข้อสรุป  $\pi_0$  เป็นดังนี้

$$\begin{aligned}\text{จาก } \mu &= \sum_{j=0}^2 jP_j \\ &= 0 \cdot \frac{1}{2} + 1 \cdot \frac{1}{4} + 2 \cdot \frac{1}{4} = \frac{3}{4}\end{aligned}$$

ซึ่ง  $\mu$  มีค่า  $\leq 1$  ดังนั้น  $\pi_0 = 1$

## ตัวอย่างที่ 2.10

ถ้า  $P_0 = 1/4$ ,  $P_1 = 1/4$ ,  $P_2 = 1/2$  ดังนั้นจะได้ข้อสรุป  $\pi_0$  เป็นดังนี้

$$\begin{aligned} \text{จากสูตร } p_0 &= \sum_{j=0}^2 p_0^j P_j \\ \pi_0 &= \frac{1}{4} + \frac{1}{4} \pi_0 + \frac{1}{2} \pi_0^2 \end{aligned}$$

$$2\pi_0^2 - 3\pi_0 + 1 = 0$$

ค่าบวกที่น้อยที่สุดในสมการนี้ จะทำให้ได้ค่า  $\pi_0 = \frac{1}{2}$

ดังนั้นประชากรจะหมดไปสูญไป ถ้าแต่ละสถานะมีจำนวนสมาชิกหมดไป ตั้งแต่เริ่มต้นใน generation เริ่มแรก ซึ่งจะทำให้ได้ความน่าจะเป็น  $\pi_0^n$  ตามตัวอย่างที่ 2.9 จะได้  $\pi_0^n = 1$  และ

$$\text{ตัวอย่างที่ 2.10 } \pi_0^n = \left(\frac{1}{2}\right)^n$$

## 2.6 กระบวนการตัดสินใจมาร์คอฟ (Markov Decision Processes)

พิจารณากระบวนการที่มีค่าสังเกต ณ เวลาที่ไม่ต่อเนื่อง (discrete) ซึ่งให้เป็น  $M$  สถานะที่เป็นไปได้ และจะมีจำนวน  $1, 2, \dots, M$  หลังจากสังเกตสถานะของกระบวนการแล้ว มีการกระทำที่ต้องถูกเลือก จะให้เป็น  $A$  สมมติเป็นเซตของการกระทำที่เป็นไปได้อย่างมีจำนวนจำกัด (finite)

ถ้ากระบวนการในสถานะ  $i$  ณ เวลาที่  $n$  และการกระทำ  $a$  เป็นตัวที่ถูกเลือกมา ดังนั้นสถานะต่อไปของระบบจะได้ข้อสรุปตามนี้ คือเป็นความน่าจะเป็นที่มีการเปลี่ยนแปลง (transition)  $P_{ij}(a)$  ถ้าให้  $X_n$  แสดงเป็นสถานะของกระบวนการ ณ เวลาที่  $n$  และ  $a_n$  เป็นการกระทำที่ถูกเลือกที่เวลา  $n$

ดังนั้นสถานะจะมีผลลัพธ์เป็น

$$P\{X_{n+1} = j | X_0 = a_0, X_1 = a_1, \dots, X_n = i, a_n = a\} = P_{ij}(a)$$

ความน่าจะเป็นแบบ transition ก็จะเป็นฟังก์ชันสำหรับที่จะแสดงสถานะปัจจุบันและการกระทำหรือเหตุการณ์ที่เกิดขึ้นภายหลัง

ตามนโยบายหรือหลักการ เลือกเหตุการณ์หรือการกระทำที่อยู่ในสภาพที่ปกติ จะต้องควบคุมนโยบายให้เข้มงวด ด้วยรูปแบบการกระทำที่กำหนดไว้ว่าทุก ๆ เวลาจะขึ้นอยู่สถานะของกระบวนการ ณ เวลานั้น ๆ และไม่เกี่ยวข้องกับข้อมูลอื่นในสถานะและเหตุการณ์นั้น ๆ แม้ว่าจะยอมให้นโยบายเป็นแบบสุ่ม (randomized) แล้ว อาจจะต้องแนะนำให้เลือกการกระทำหรือเหตุการณ์ตามการแจกแจงของความน่าจะเป็น อาจจะถูกกล่าวได้อีกอย่างหนึ่งว่า นโยบาย  $\beta$  เป็นเซตของจำนวน  $\beta = \{\beta_i(a), a \in A, i = 1, \dots, M\}$  ในการอธิบายตีความว่าถ้ากระบวนการในสถานะที่  $i$  เนื่องจากมีการกระทำหรือเหตุการณ์  $a$  เป็นเหตุการณ์ที่ถูกเลือกและมีความน่าจะเป็น  $\beta_i(a)$  ดังนั้นจะได้ว่า

$$0 \leq \beta_i(a) \leq 1, \text{ สำหรับทุก ๆ } i, a$$

$$\sum_a \beta_i(a) = 1, \text{ สำหรับทุก ๆ } i$$

ภายใต้้นโยบายที่กำหนด  $\beta$  ลำดับการเกิดของสถานะ  $\{X_n, n = 0, 1, \dots\}$  จะเรียกว่าเป็นกระบวนการลูกโซ่มาร์คอฟ ที่มีความน่าจะเป็นเป็นแบบ transition ด้วย  $P_{ij}(\beta)$

$$P_{ij}(\beta) = P_\beta\{X_{n+1} = j | X_n = i\}$$

$$= \sum_a P_{ij}(a) \beta_i(a)$$

(จะใช้  $P_\beta$  เป็นสัญลักษณ์ของความน่าจะเป็นแบบมีเงื่อนไข ในกรณีที่นโยบาย  $\beta$  ได้ถูกนำมาใช้)

จะมีค่าตามเงื่อนไขของเหตุการณ์ที่ถูกเลือกเมื่ออยู่ในสถานะ  $i$  สมมติให้ทุก ๆ ทางเลือกของนโยบาย  $\beta$  ซึ่งเป็นผลมาจากกระบวนการลูกโซ่มาร์คอฟ  $\{X_n, n = 0, 1, \dots\}$  เป็น ergodic

สำหรับทุก ๆ นโยบาย  $\beta$  ให้  $\pi_{ia}$  เป็นลิมิตของความน่าจะเป็น (หรือสแตตีสเตท Steady state) กระบวนการจะอยู่ในสถานะ  $i$  และเหตุการณ์  $a$  จะถูกเลือกถ้านโยบาย ถูกใช้

$$\pi_{ia} = \lim_{n \rightarrow \infty} P_\beta \{X_n = i, a_n = a\}$$

คุณสมบัติของ  $\pi = (\pi_{ia})$  ต้องเป็นดังนี้

1.  $\pi_{ia} \geq 0$  สำหรับทุกค่าของ  $i, a$
2.  $\sum_i \sum_a \pi_{ia} = 1$
3.  $\sum_a P_{ja} = \sum_i \sum_a \pi_{ia} P_{ij}(a)$  สำหรับทุกค่าของ  $j$  (2.7)

สมการในข้อ 1, 2 ก็เป็นที่ชัดเจนคืออยู่แล้ว และสมการในข้อที่ 3 ซ้ำยมือก็จะมีค่าเท่ากับความน่าจะเป็นที่คงรูปหรือสแตตีสเตท (Steady-state) ของสถานะ  $j$  และด้านขวามือจะมีลักษณะเหมือนกับความน่าจะเป็นที่คำนวณด้วยเงื่อนไขของสถานะและเหตุการณ์ที่ถูกเลือกมาในระยะก่อนหน้านั้นแล้ว

ดังนั้นทุก ๆ นโยบาย  $\beta$  จะมีคุณสมบัติ  $\pi = (\pi_{ia})$  เป็นดังนี้ ① - ③ และในการอธิบายจะตีความว่า  $\pi_{ia}$  มีค่าเท่ากับความน่าจะเป็นสแตตีสเตท (Steady-state) ของสถานะ  $i$  และเลือกเหตุการณ์  $a$  เมื่อนโยบาย  $\beta$  ถูกใช้ นอกจากนั้น มันก็กลับกลายเป็นว่าเกิดการพลิกกลับเกิดเป็นความจริง นั่นก็คือสำหรับทุก ๆ Vector  $\pi = (\pi_{ia})$  ซึ่งมาจาก ① - ③ ซึ่งมีนโยบาย  $\beta$  อยู่จริง ถ้า  $\beta$  ถูกใช้ ดังนั้นความน่าจะเป็นแบบสแตตีสเตทของสถานะ  $i$  และเลือกเหตุการณ์  $a$  ก็จะเท่ากับ  $\pi_{ia}$  การตรวจสอบข้อความสุดท้าย สมมติว่า  $\pi = (\pi_{ia})$  เป็น vector ซึ่งมาจาก ① - ③ ดังนั้นให้นโยบาย  $\beta = (\beta_i(a))$  เป็นดังนี้

$$\beta_i(a) = P\{\beta \text{ chooses } a \mid \text{State is } i\}$$

$$= \frac{\pi_{ia}}{\sum_a \pi_{ia}}$$

ถ้าให้  $P_{ia}$  เป็น limiting ความน่าจะเป็นในสถานะ  $i$  และเลือกเหตุการณ์  $a$  เมื่อโยบาย  $\beta$  ถูกใช้ ต้องการแสดงให้เห็นว่า  $P_{ia} = \pi_{ia}$  ดังนั้นขั้นตอนการทำ เริ่มแรกจาก  $\{ P_{ia}, i = 1, \dots, M, a \in A \}$  เป็น limiting ความน่าจะเป็นของ 2 มิติในกระบวนการลูกโซ่มาร์คอฟ  $\{(X_n, a_n), n \geq 0\}$  ดังนั้นจากทฤษฎี 4.1 เบื้องต้น การคำนวณเป็นลักษณะเฉพาะดังนี้

$$(1') P_{ia} \geq 0$$

$$(2') \sum_i \sum_a P_{ia} = 1$$

$$(3') P_{ja} = \sum_i \sum_{a'} P_{ia'} P_{ij}(a') \beta_j(a)$$

(3') มีค่าตามนี้

$$P\{X_{n+1} = j, a_{n+1} = a \mid X_n = i, a_n = a'\} = P_{ij}(a') \beta_j(a)$$

นั่นคือ

$$\beta_i(a) = \frac{\pi_{ja}}{\sum_a \pi_{ja}}$$

จะเห็นว่า  $(P_{ia})$  เป็น การคำนวณลักษณะ โดยเฉพาะของ

$$P_{ia} \geq 0,$$

$$\sum_i \sum_a P_{ia} = 1,$$

$$P_{ja} = \sum_i \sum_{a'} P_{ia'} P_{ij}(a') \frac{\pi_{ja}}{\sum_a \pi_{ja}}$$

ดังนั้นจะแสดงว่า  $P_{ia} = \pi_{ia}$  นั่นคือ

$$\pi_{ia} \geq 0,$$

$$\sum_i \sum_a \pi_{ia} = 1,$$

$$\pi_{ja} = \sum_i \sum_{a'} \pi_{ia'} P_{ij}(a') \frac{\pi_{ja}}{\sum_a \pi_{ja}}$$

จุดสูงสุดของ 2 สมการจาก (1) และ (2) ในสมการที่ (2.7) และในขั้นที่ 3 จะมีผลเท่ากันกับ

$$\sum_a \pi_{ja} = \sum_i \sum_{a'} \pi_{ia'} P_{ij}(a')$$

จากเงื่อนไข (3) ของสมการที่ 2.7

จากนี้จะแสดงให้เห็นว่า Vector  $\pi = (\pi_{ia})$  จะเป็นไปตาม (1), (2) และ (3) ของสมการ 2.7 ด้านนโยบาย  $\beta$  มีอยู่จริงและ  $\pi_{ia}$  มีค่าเท่ากับความน่าจะเป็นแบบสแตตีสเตท (Steady-State) ของสถานะ  $i$  และเลือกเหตุการณ์  $a$  เมื่อ  $\beta$  ถูกใช้ ตามความเป็นจริง นโยบาย  $\beta$  จะถูกกำหนดให้เป็น

$$\beta_i(a) = \frac{\pi_{ia}}{\sum_a \pi_{ia}}$$

ความสำคัญจากที่กล่าวมาทั้งหมดก็จะสรุปได้ว่าเป็นนโยบายที่ดีที่สุด สำหรับตัวอย่างนี้ สมมติว่าผลตอบแทนที่หามาได้  $R(i, a)$  ไม่ว่าเมื่อใดเหตุการณ์  $a$  ถูกเลือกใช้ในสถานะ  $i$  จาก  $R(X_i, a_i)$  จะแสดงให้เห็นว่าผลตอบแทนที่หามาได้ในเวลา  $i$  ค่าคาดหวังเฉลี่ยของผลตอบแทนต่อเวลาภายใต้ นโยบาย  $\beta$  สามารถหาได้จาก

$$\beta = \lim_{n \rightarrow \infty} E_{\beta} \left[ \frac{\sum_{i=1}^n R(X_i, a_i)}{n} \right]$$

ถ้า  $\pi_{ia}$  เป็นความน่าจะเป็นแบบสแตตีสเตท (Steady-State) ของสถานะ  $i$  และเลือกเหตุการณ์  $a$  จะเห็นว่า limiting ค่าคาดหวังของผลตอบแทนที่เวลา  $n$  จะเท่ากับ

$$\lim_{n \rightarrow \infty} E[R(X_n, a_n)] = \sum_i \sum_a \pi_{ia} R(i, a)$$

และจะอธิบายได้ว่า

$$\text{ค่าคาดหวังเฉลี่ยของผลตอบแทนภายใต้ } \beta = \sum_i \sum_a \pi_{ia} R(i, a)$$

ดังนั้นข้อสรุปของปัญหา นโยบาย คือ ค่าคาดหวังเฉลี่ยสูงสุดของผลตอบแทนจะเป็น

$$\text{Maximize } \sum_i \sum_a \pi_{ia} R(i, a)$$

ภายใต้ข้อกำหนด  $\pi_{ia} \geq 0$ , สำหรับทุก ๆ  $i, a$

$$\sum_i \sum_a \pi_{ia} = 1,$$

$$\sum_a \pi_{ja} = \sum_i \sum_a \pi_{ia} P_{ij}(a), \text{ สำหรับทุก ๆ } j \quad (2.8)$$

อย่างไรก็ตาม ปัญหาการหาค่าสูงสุดดังกล่าวมาเป็นเรื่องพิเศษในความรู้เรื่อง linear program และสามารถแก้ปัญหาโดยวิธี Simplex algorithm ถ้า  $\pi^* = (\pi_{ia}^*)$  เมื่อนโยบายที่ดีที่สุดจะให้เป็น  $\beta^*$

$$\beta_i^*(a) = \frac{\pi_{ia}^*}{\sum_a \pi_{ia}^*}$$

ข้อสังเกต 1. สามารถแสดงได้ว่า  $\pi^*$  เป็นสมการที่ให้ค่าสูงสุดตามสมการ (2.8) มีคุณสมบัติว่า สำหรับแต่ละ  $i$   $\pi_{ia}^*$  เป็นศูนย์หมดทุกตัว แต่มี  $\alpha$  หนึ่งค่าซึ่งสามารถอธิบาย (ให้ความหมายว่า) เป็นนโยบายที่ดีที่สุด ที่ไม่ได้มาจากการสุ่ม (nonrandomized) นั่นคือเหตุการณ์ที่อ้างถึงเมื่ออยู่ในสถานะ  $i$  จะถูกกำหนดโดยฟังก์ชันของ  $i$

2. สูตรโปรแกรมเชิงเส้น linear Programming จะใช้งานเมื่อมีการจำกัดสถานะที่ชนิดชั้นของนโยบาย ตัวอย่างสมมติว่ามีการจำกัดเวลาเป็นส่วน ๆ ในการใช้ในสถานะ ให้เป็นสถานะ 1 สมมติว่าจะพิจารณาเฉพาะนโยบายที่มีคุณสมบัติว่า มีผลลัพธ์ในกระบวนการสถานะที่ 1 น้อยกว่า  $100\alpha$  เปอร์เซ็นต์ของเวลา ในการกำหนดนโยบายที่ดีที่สุดที่เราต้องการ เราจะใช้ปัญหา linear programming เป็นการบังคับเพิ่มเติม  $\sum_a \pi_{ia} \leq \alpha$

ดังนั้น  $\sum_a \pi_{ia}$  จะแสดงให้เห็นถึงสัดส่วนของเวลาในกระบวนการของสถานะที่ 1

## 2.7 การแจกแจงแบบเอกซ์โปเนนเชียล(The Exponential Distribution)

### นิยามที่ 2.4

ตัวแปรสุ่มอย่างต่อเนื่อง  $X$  จะมีการแจกแจงแบบเอกซ์โปเนนเชียล ด้วยพารามิเตอร์  $\lambda$  ,  $\lambda > 0$  ถ้า probability density function ; pdf. เป็น

$$f(x) = \begin{cases} \lambda e^{-\lambda x} & ; x \geq 0 \\ 0 & ; x < 0 \end{cases}$$

หรือจะมีผลเท่ากัน ถ้ามี cdf เป็น

$$f(x) = \int_{-\infty}^x f(y) dy = \begin{cases} 1 - e^{-\lambda x} & ; x \geq 0 \\ 0 & ; x < 0 \end{cases}$$

ค่าเฉลี่ยของการแจกแจงแบบเอกซ์โปเนนเชียล,  $E[X]$  เป็น

$$\begin{aligned} E[X] &= \int_{-\infty}^{\infty} xf(x)dx \\ &= \int_0^{\infty} \lambda x e^{-\lambda x} dx \end{aligned}$$

อินทิเกรต by parts ( $u = x, dv = \lambda e^{-\lambda x} dx$ ) จะได้

$$E[X] = -Xe^{-\lambda x} \Big|_0^{\infty} + \int_0^{\infty} e^{-\lambda x} dx = \frac{1}{\lambda}$$

The moment generating function  $\phi(t)$  ของการแจกแจงแบบเอกซ์โปเนนเชียล จะเป็น

$$\begin{aligned} \phi(t) &= E[e^{tx}] \\ &= \int_0^{\infty} e^{tx} \lambda e^{-\lambda x} dx \\ &= \frac{\lambda}{\lambda - t} \quad \text{สำหรับ } t < \lambda \end{aligned} \quad (2.9)$$

สำหรับ moment ทั้งหมดของ  $X$  สามารถหาได้จากการหาอนุพันธ์ในสมการ 2.9 เช่นตัวอย่าง

$$\begin{aligned} E[X^2] &= \frac{d^2}{dt^2} \phi(t) \Big|_{t=0} \\ &= \frac{2\lambda}{(\lambda - t)^3} \Big|_{t=0} \\ &= \frac{2}{\lambda^2} \end{aligned}$$

ดังนั้นจากที่ผ่านมา ทำให้ได้ว่า

$$\begin{aligned}
 \text{Var}(X) &= E[X^2] - (E[X])^2 \\
 &= \frac{2}{\lambda^2} - \frac{1}{\lambda^2} \\
 &= \frac{1}{\lambda^2}
 \end{aligned}$$

### 2.7.1 คุณสมบัติของการแจกแจงแบบเอกซ์โปเนนเชียล

ตัวแปรสุ่ม  $X$  ปราศจากความจำ (Memoryless)

$$\text{ถ้า } P\{X > s+t | X > t\} = P\{X > s\} \text{ สำหรับทุกๆ } s, t \geq 0 \quad (2.10)$$

ถ้าคิดว่า  $X$  เป็นระยะเวลาการใช้งานของเครื่องมือ ตามสมการ 2.10 ความน่าจะเป็นที่เครื่องมือจะยังมีอยู่สำหรับเวลาอย่างน้อย  $s+t$  ชั่วโมง ให้อายุได้  $t$  ชั่วโมง เป็นเหมือนความน่าจะเป็นเริ่มต้น และยังคงอยู่อย่างน้อย  $s$  ชั่วโมง อาจพูดได้ว่า ถ้าเครื่องมือที่มีอยู่ในเวลา  $t$  แล้วการแจกแจงของจำนวนเวลาที่ยังเหลืออยู่จะเป็นการอยู่รอด เหมือนกับการแจกแจงเริ่มแรกของชีวิต นั่นคือเครื่องมือที่ปราศจากความจำเวลาที่ใช้ไปแล้ว ในเวลา  $t$

$$\frac{P\{X > s+t, X > t\}}{P\{X > t\}} = P\{X > s\}$$

หรือ

$$P\{X > s+t\} = P\{X > s\}P\{X > t\} \quad (2.11)$$

ดังนั้นสมการ (2.11) จะนำไปตามนั้น เมื่อ  $X$  มีการแจกแจงแบบเอกซ์โปเนนเชียล (สำหรับ  $e^{-\lambda(s+t)} = e^{-\lambda s}e^{-\lambda t}$ ) มันก็จะนำไปตามการแจกแจงแบบเอกซ์โปเนนเชียล ตัวแปรสุ่มปราศจากความจำ (memoryless)

**ตัวอย่าง 2.11**

สมมติว่าระยะเวลาที่ลูกค้าใช้บริการในธนาคารมีการแจกแจงแบบเอกซ์โปเนนเชียล ด้วยค่าเฉลี่ยเป็น 10 นาที จะได้ว่า  $\lambda = \frac{1}{10}$  ต้องการทราบว่าความน่าจะเป็นที่ลูกค้าจะใช้เวลามากกว่า 15 นาที ในธนาคารเป็นเท่าไร และอยากทราบว่าความน่าจะเป็นที่ลูกค้าจะใช้เวลามากกว่า 15 นาที ในธนาคาร โดยให้พวกเขายังคงอยู่ในธนาคารหลังจาก 10 นาที

การวิเคราะห์ ถ้า  $X$  เป็นระยะเวลาที่ลูกค้าใช้เวลาในธนาคารแล้วความน่าจะเป็นค่าแรก จะได้

$$P\{X > 15\} = e^{-15\lambda} = e^{-3/2} \approx 0.220$$

สำหรับคำถามที่ 2 หากความน่าจะเป็นที่ลูกค้าที่ใช้เวลา 10 นาที ในธนาคารจะใช้อย่างน้อย 5 นาที อย่างไรก็ตาม เมื่อการแจกแจงแบบเอกซ์โปเนนเชียล ไม่ได้ปราศจากความจำ ลูกค้าที่ใช้เวลา 10 นาที ในธนาคารแล้ว จะต้องเท่ากับความน่าจะเป็นที่ลูกค้าจะเข้ามาใช้เวลาอย่างน้อย 5 นาที ในธนาคาร ดังนั้นความน่าจะเป็นที่จะได้

$$P\{X > 5\} = e^{-5\lambda} = e^{-1/2} \approx 0.604$$

**ตัวอย่าง 2.12**

พิจารณาในที่ทำการไปรษณีย์ ซึ่งมีเสมียนเป็นชาย 2 คน สมมติว่า เมื่อ Mr. Smith เข้ามาในระบบเข้า ก็พบว่า Mr. Jones กำลังบริการอยู่กับลูกค้าคนหนึ่ง ส่วน Mr. Brown ก็ให้บริการกับอีกคนหนึ่ง สมมติว่า Mr. Smith บอกว่าการให้บริการของเขาจะทำในไม่ช้านี้ โดยที่ไม่ใช่ Mr. Jones หรือ Mr. Brown ต้องเสร็จจากการบริการ ถ้าระยะเวลาที่เสมียนใช้กับลูกค้ามีการแจกแจงแบบเอกซ์โปเนนเชียล ด้วยค่าเฉลี่ย เป็น  $\frac{1}{\lambda}$  อยากทราบว่าความน่าจะเป็นของลูกค้ายก 3 คน เมื่อ Mr. Smith จะออกจากที่ทำการไปรษณีย์เป็นคนสุดท้ายเป็นเท่าไร

การวิเคราะห์ คำตอบที่จะได้ก็มาจากเหตุผลที่ว่า จะพิจารณาเวลาที่ซึ่ง Mr. Smith หาเสมียนที่ว่างคนแรก จุดสำคัญไม่ว่า Mr. Jones หรือ Mr. Brown จะเสร็จจากการบริการคนหนึ่ง ก็ต้องเหลืออีกคนหนึ่ง แม้ว่าความจำที่ขาดไปของเอกซ์โปเนนเชียล ที่ว่าจำนวนเวลาของชายอีกคนหนึ่ง (ไม่ว่าจะเป็น Jones หรือ Brown) จะยังคงถูกใช้ในที่ทำการไปรษณีย์ด้วยการแจกแจงแบบเอกซ์โปเนนเชียล มี ค่าเฉลี่ย  $\frac{1}{\lambda}$  ก็เหมือนกับว่า ถ้าเขาเริ่มให้บริการของเขา ดังนั้นในทำนองเดียวกัน ความน่าจะเป็นที่จะเสร็จจากการบริการก่อนที่จะบริการ Smith จะต้องเท่ากับ  $\frac{1}{2}$

ดังนั้นการแจกแจงแบบเอกซ์โปเนนเชียลเท่านั้นที่มีคุณสมบัติปราศจากความจำ (memoryless) นี้ จะเห็นว่า ถ้า  $X$  เป็น memoryless และให้  $\bar{F}(x) = P\{X > x\}$  แล้วสมการที่ 2.11 จะได้ว่า

$$\bar{F}(s+t) = \bar{F}(s)\bar{F}(t)$$

นั่นคือ  $\bar{F}(x)$  จะมีสมการฟังก์ชันเป็น  $g(s+t) = g(s)g(t)$

แม้ว่ามันจะกลายเป็นว่า การแก้สมการฟังก์ชันเป็นไปต่อเนื่องด้านขวา (ด้านบวก)

$$g(x) = e^{-\lambda x}$$

จะพิสูจน์ว่า ถ้า  $g(s+t) = g(s)g(t)$  แล้ว

$$g\left(\frac{2}{n}\right) = g\left(\frac{1}{n} + \frac{1}{n}\right) = g^2\left(\frac{1}{n}\right)$$

และจะได้ว่า  $g\left(\frac{m}{n}\right) = g^m\left(\frac{1}{n}\right)$  ด้วย ดังนั้น

$$g(1) = g\left(\frac{1}{n} + \frac{1}{n} + \dots + \frac{1}{n}\right) = g^n\left(\frac{1}{n}\right) \text{ หรือ } g\left(\frac{1}{n}\right) = (g(1))^{1/n}$$

ดังนั้น  $g(m/n) = (g(1))^{m/n}$  นั้นหมายถึง ให้  $g$  ต่อเนื่องไปทางบวก ให้  $g(x) = (g(1))^x$

$$\text{ถ้า } g(1) = \left(g\left(\frac{1}{2}\right)\right)^2 \geq 0 \text{ จะได้ว่า } g(x) = e^{-\lambda x} \text{ เมื่อ } \lambda = -\log(g(1))$$

และเมื่อฟังก์ชันการแจกแจงนี้เป็นแบบต่อเนื่องไปทางบวก เราจะได้ว่า

$$\bar{F}(x) = e^{-\lambda x}$$

หรือ

$$F(x) = P\{X \leq x\} = 1 - e^{-\lambda x}$$

ซึ่งเป็นการแสดงให้เห็นว่า  $X$  มีการแจกแจงแบบเอกซ์โปเนนเชียล

### 2.7.2 คุณสมบัติต่อไปของการแจกแจงแบบเอกซ์โปเนนเชียล

ให้  $X_1, \dots, X_n$  เป็นอิสระจากกัน และแต่ละตัวมีการแจกแจงแบบเอกซ์โปเนนเชียล ตัวแปรสุ่มมีค่าเฉลี่ยเป็น  $\frac{1}{\lambda}$  ให้  $X_1 + \dots + X_n$  มีการแจกแจงแบบแกมมา มีพารามิเตอร์  $n$  และ  $\lambda$  การพิสูจน์ผลลัพธ์ขั้นที่ 2 โดยการใช้การพิสูจน์ทางคณิตศาสตร์ และไม่มีการพิสูจน์เลย เมื่อ  $n = 1$  ให้เริ่มโดยสมมติว่า  $X_1 + \dots + X_{n-1}$  มีความหนาแน่น (density) ดังนี้

$$f_{X_1 + \dots + X_{n-1}}(t) = \lambda e^{-\lambda t} \frac{(\lambda t)^{n-2}}{(n-2)!}$$

$$\text{ดังนั้น } f_{X_1 + \dots + X_{n-1} + X_n}(t) = \int_0^{\infty} f_{X_n}(t-s) f_{X_1 + \dots + X_{n-1}}(s) ds$$

$$= \int_0^t \lambda e^{-\lambda(t-s)} \lambda e^{-\lambda s} \frac{(\lambda s)^{n-2}}{(n-2)!} ds$$

$$= \lambda e^{-\lambda t} \frac{(\lambda t)^{n-1}}{(n-1)!}$$

ประโยชน์ของการคำนวณอีกอันหนึ่งก็คือ จะได้ข้อสรุปความน่าจะเป็นว่าตัวแปรสุ่มแบบเอกซ์โปเนนเชียลตัวหนึ่งจะมีค่าน้อย หรือต่ำกว่าตัวอื่น ๆ นั่นคือ สมมติว่า  $X_1$  และ  $X_2$  เป็นตัวแปรสุ่มเอกซ์โปเนนเชียลแบบเป็นอิสระด้วยค่าเฉลี่ยแต่ละอัน  $\frac{1}{\lambda_1}$  และ  $\frac{1}{\lambda_2}$  ถ้าต้องการทราบ  $P\{X_1 < X_2\}$  เป็นเท่าไร ความน่าจะเป็นนี้สามารถคำนวณด้วยเงื่อนไขของ  $X_2$

$$\begin{aligned}
 P\{X_1 < X_2\} &= \int_0^{\infty} P\{X_1 < X_2 | X_2 = x\} \lambda_2 e^{-\lambda_2 x} dx \\
 &= \int_0^{\infty} P\{X_1 < x\} \lambda_2 e^{-\lambda_2 x} dx \\
 &= \int_0^{\infty} (1 - e^{-\lambda_1 x}) \lambda_2 e^{-\lambda_2 x} dx \\
 &= \int_0^{\infty} \lambda_2 e^{-\lambda_2 x} dx - \lambda_2 \int_0^{\infty} e^{-(\lambda_1 + \lambda_2)x} dx \\
 &= 1 - \frac{\lambda_2}{\lambda_1 + \lambda_2} = \frac{\lambda_1}{\lambda_1 + \lambda_2} \tag{2.12}
 \end{aligned}$$

### ตัวอย่าง 2.13

สมมติว่าสเตอริโอเครื่องหนึ่งมีระบบเป็น 2 ส่วนหลักคือ วิทยุ และลำโพง ถ้าอายุการใช้งานของวิทยุมีการแจกแจงเป็นเอกซ์โปเนนเชียล ด้วยค่าเฉลี่ย 1000 ชั่วโมง และอายุการใช้งานลำโพงมีการแจกแจงเป็นเอกซ์โปเนนเชียล ด้วยค่าเฉลี่ย 500 ชั่วโมง และยังเป็นอิสระกับการใช้งานของวิทยุ ดังนั้นต้องการทราบความน่าจะเป็นที่ระบบจะใช้งานไม่ได้ (เมื่อมันเกิดขึ้น) โดยที่วิทยุใช้งานไม่ได้

การวิเคราะห์ จากสมการที่ 2.12 (ด้วย  $\lambda_1 = \frac{1}{1000}$ ,  $\lambda_2 = \frac{1}{500}$ ) จะได้คำตอบว่า

$$\frac{1/1000}{1/1000 + 1/500} = \frac{1}{3}$$

## 2.8 กระบวนการปัวซอง(The Poisson Process)

### 2.8.1 กระบวนการที่นับได้(Counting Processes)

กระบวนการสโตแคสติก (Stochastic process)  $\{N(t), t \geq 0\}$  เรียกว่า กระบวนการที่นับได้ ถ้า  $N(t)$  เป็นผลรวมของจำนวน "เหตุการณ์" ที่จะเกิดขึ้นในเวลา  $t$

ตัวอย่างเกี่ยวกับกระบวนการที่นับได้ (Counting processes)

a) ถ้าให้  $N(t)$  มีค่าเท่ากับ จำนวนของคนที่เข้ามาร้านหรือก่อนเวลา  $t$  ดังนั้น  $\{N(t), t \geq 0\}$  เป็นกระบวนการที่นับได้ ซึ่งมีเหตุการณ์ที่สอดคล้องกันกับคนที่เข้ามาในร้าน

ข้อสังเกต ถ้าให้  $N(t)$  เท่ากับจำนวนคนที่อยู่ในร้าน ณ เวลา  $t$  ดังนั้น  $\{N(t), t \geq 0\}$  จะไม่เป็นกระบวนการที่นับได้

b) ถ้าให้ว่าเหตุการณ์ที่จะเกิดขึ้นเป็นเด็กแต่ละคนเกิด ดังนั้น  $\{N(t), t \geq 0\}$  จะเป็นกระบวนการที่นับได้ เมื่อ  $N(t)$  เท่ากับจำนวนคนทั้งหมดที่จะเกิดในเวลา  $t$  (แต่  $N(t)$  จะรวมคนที่ตายในเวลา  $t$ )

c) ถ้า  $N(t)$  เท่ากับจำนวนประตูที่นักฟุตบอลจะทำคะแนนได้ได้คะแนนในเวลา  $t$  ดังนั้น  $\{N(t), t \geq 0\}$  จะเป็นกระบวนการที่นับได้ เหตุการณ์ในกระบวนการนี้จะเกิดขึ้นก็ต่อเมื่อ นักฟุตบอลได้ประตู

จากความหมายของกระบวนการที่นับได้  $N(t)$  จะต้องเป็นตามนี้

- 1)  $N(t) \geq 0$
- 2)  $N(t)$  มีค่าเป็นจำนวนเต็ม
- 3) ถ้า  $s < t$  ดังนั้น  $N(s) \leq N(t)$
- 4) สำหรับ  $s < t$ ,  $N(t) - N(s)$  จะเท่ากับจำนวนเหตุการณ์ที่เกิดขึ้นในช่วงของ  $(s, t)$

กล่าวได้ว่ากระบวนการที่นับได้เป็นการเพิ่มขึ้นอย่างเป็นอิสระ(independent increments) ถ้าจำนวนเหตุการณ์ที่เกิดขึ้นที่แบ่งเป็นช่วงเวลานั้นเป็นอิสระกัน ตัวอย่างเช่น จำนวนเหตุการณ์ที่เกิดขึ้นในเวลา 10 (นั่นคือ  $N(10)$ ) จะต้องเป็นอิสระกับจำนวนเหตุการณ์ที่เกิดขึ้นระหว่างเวลา 10 และ 15 (นั่นคือ  $N(15) - N(10)$ )

ข้อสมมติของการเพิ่มขึ้นอย่างเป็นอิสระจะต้องเป็นเหตุผลของตัวอย่างที่  $a$  แต่มันน่าจะเป็นไปได้ที่จะไม่เป็นเหตุผลของข้อ  $b$  เหตุผลข้อนี้ถ้าเป็นตัวอย่าง  $b$   $N(t)$  จะต้องใหญ่มาก ดังนั้นมันน่าจะเป็นไปได้ว่ามีคนมากที่มีชีวิตอยู่ที่เวลา  $t$  ส่วนนี้จะทำให้เชื่อว่าจำนวนของคนเกิดใหม่ระหว่างเวลา  $t$  และเวลา  $t + s$  มีแนวโน้มที่ใหญ่ (มาก) (นั่นคือ มันไม่น่าจะเป็นเหตุผลที่  $N(t)$  จะเป็นอิสระกับ  $N(t + s) - N(t)$  และดังนั้น  $\{N(t), t \geq 0\}$  จะไม่เป็นการเพิ่มขึ้นอย่างเป็นอิสระในตัวอย่าง  $b$  ข้อสมมติของการเพิ่มขึ้นอย่างเป็นอิสระในตัวอย่าง  $c$  จะถูกต้องถ้าเชื่อว่านักฟุตบอลเล่นได้ประตูโดยบังเอิญในวันนี้ ซึ่งไม่ขึ้นอยู่กับว่าเขาจะเล่นอย่างไร มันจะไม่ใช้เรื่องของความเชื่อและเรื่องดวง

กล่าวได้ว่ากระบวนการที่นับได้เป็นการเพิ่มขึ้นอย่างคงที่(stationary increments) ถ้าการแจกแจงจำนวนเหตุการณ์ที่เกิดขึ้นเป็นช่วงเวลาที่ขึ้นอยู่กับความยาวของช่วงเวลา อาจจะได้ว่ากระบวนการมีการเพิ่มขึ้นอย่างคงที่ ถ้าจำนวนเหตุการณ์ในช่วง  $(t_1 + s, t_2 + s)$  นั่นคือ  $N(t_2 + s) - N(t_1 + s)$  มีการแจกแจงเหมือนกับจำนวนเหตุการณ์ในช่วง  $(t_1, t_2)$  และ  $N(t_2) + N(t_1)$  สำหรับทุก ๆ  $t_1 < t_2$  และ  $s > 0$

ข้อสมมติของการเพิ่มขึ้นอย่างคงที่ที่จะเป็นเหตุผลเดียวของตัวอย่าง  $a$  ถ้าไม่มีช่วงเวลาของวันที่มีคนชอบเข้ามาในร้าน

ตัวอย่างเช่น ถ้ามีชั่วโมงเร่งด่วน (ระหว่างเที่ยงถึงบ่ายโมง) ของแต่ละวัน ดังนั้นข้อสมมติของการคงที่ (Stationarity) จะไม่ถูกต้อง ถ้าเชื่อว่าข้อมูลพื้นฐานของประชากรโลกมีค่าคงที่ (ซึ่งมันน่าจะเป็นไปไม่ได้ในทางวิทยาศาสตร์) ดังนั้นข้อสมมติของการเพิ่มขึ้นอย่างคงที่ที่จะต้องเป็นเหตุผลของตัวอย่าง  $b$  การเพิ่มขึ้นอย่างคงที่จะไม่เหมือนข้อสมมติของเหตุผลในตัวอย่าง  $c$  สำหรับบางสิ่งบางอย่างคนส่วนมากจะเห็นด้วยว่า นักฟุตบอลขณะอายุ (25-30 ปี) จะทำคะแนนประตูได้มากกว่าอายุ (35-40 ปี)

### 2.8.2 คำจำกัดความของกระบวนการปัวซอง

สิ่งหนึ่งที่สำคัญที่สุดของกระบวนการที่นับได้ คือ กระบวนการปัวซอง มีคำนิยามดังนี้

#### นิยามที่ 2.5

กระบวนการที่นับได้  $\{N(t), t \geq 0\}$  คือ กระบวนการปัวซอง ที่มีอัตรา  $\lambda$ ,  $\lambda > 0$  ถ้า

1.  $N(0) = 0$
2. ขบวนการมีการเพิ่มขึ้นอย่างเป็นอิสระ และ
3. จำนวนเหตุการณ์ในช่วงความยาว  $t$  มีการแจกแจงแบบปัวซอง ด้วยค่าเฉลี่ย  $\lambda t$  สำหรับ  $s, t \geq 0$

$$P\{N(t+s) - N(s) = n\} = e^{-\lambda t} \frac{(\lambda t)^n}{n!}, \quad n = 0, 1, \dots$$

หมายเหตุ กระบวนการปัวซอง จะมีการเพิ่มขึ้นอย่างคงที่ ตามเงื่อนไขที่ 3 และจะได้ว่า

$$E[N(t)] = \lambda t$$

ซึ่งอธิบายได้ว่าทำไม จึงเรียกว่าเป็นอัตรา (rate) ของกระบวนการ

จะได้ข้อสรุปถ้ากระบวนการที่นับได้เกิดขึ้นจริง กระบวนการปัวซองจะต้องกำหนดให้มีเงื่อนไข 1, 2 และ 3 เงื่อนไขที่ 1 เป็นขั้นต้นซึ่งกล่าวถึงจำนวนของเหตุการณ์เริ่มต้นที่เวลา  $t = 0$  และเงื่อนไขที่ 2 สามารถที่จะตรวจสอบได้โดยตรงจากความรู้ความเข้าใจในเรื่องของกระบวนการ แม้ว่ามันอาจไม่ชัดเจนทั้งหมด แต่ก็สามารถได้ข้อสรุปว่าเงื่อนไขข้อที่ 3 เป็นจริง และสำหรับเหตุผลที่ให้นิยามของ กระบวนการปัวซองก็เพื่อจะได้ใช้เป็นประโยชน์ต่อไป

จากที่กล่าวมาจะทำให้ได้นิยามที่ 2 ของกระบวนการปัวซองซึ่งจะกำหนดแนวคิดของฟังก์ชัน  $f(\cdot)$  เป็น  $o(h)$

นิยามที่ 2.6 ฟังก์ชัน  $f(\cdot)$  จะเป็น  $o(h)$  ถ้า

$$\lim_{h \rightarrow 0} \frac{f(h)}{h} = 0$$

ตัวอย่างที่ 2.14

1. ฟังก์ชัน  $f(x) = x^2$  เป็น  $o(h)$

$$\lim_{h \rightarrow 0} \frac{f(h)}{h} = \lim_{h \rightarrow 0} \frac{h^2}{h} = \lim_{h \rightarrow 0} h = 0$$

2. ฟังก์ชัน  $f(x) = x$  ไม่ได้เป็น  $o(h)$

$$\lim_{h \rightarrow 0} \frac{f(h)}{h} = \lim_{h \rightarrow 0} \frac{h}{h} = \lim_{h \rightarrow 0} 1 = 1 \neq 0$$

3. ถ้า  $f(\cdot)$  เป็น  $o(h)$  และ  $g(\cdot)$  เป็น  $o(h)$  ดังนั้น  $f(\cdot) + g(\cdot)$  จะเป็นดังนี้

$$\lim_{h \rightarrow 0} \frac{f(h) + g(h)}{h} = \lim_{h \rightarrow 0} \frac{f(h)}{h} + \lim_{h \rightarrow 0} \frac{g(h)}{h} = 0 + 0 = 0$$

4. ถ้า  $f(\cdot)$  เป็น  $o(h)$  ดังนั้น  $g(\cdot) = cf(\cdot)$  เป็นดังนี้

$$\lim_{h \rightarrow 0} \frac{cf(h)}{h} = c \lim_{h \rightarrow 0} \frac{f(h)}{h} = c \cdot 0 = 0$$

5. จาก (3) และ (4) นำเอาฟังก์ชันมารวมกันเป็นเชิงเส้นตรงอย่างมีขีดจำกัด ซึ่งแต่ละ  $o(h)$  เป็น  $o(h)$

ถ้า ฟังก์ชัน  $f(\cdot)$  เป็น  $o(h)$  แล้ว  $f(h)/h$  จะเข้าใกล้ 0 เมื่อ  $h$  เข้าสู่ 0

นิยามที่ 2.7 กระบวนการที่นับได้  $\{N(t), t \geq 0\}$  เป็นกระบวนการปัวซองที่มีอัตรา  $\lambda, \lambda > 0$  ถ้า

1.  $N(0) = 0$
2. กระบวนการจะมีการคงที่และการเพิ่มขึ้นอย่างเป็นอิสระ
3.  $P\{N(h) = 1\} = \lambda h + o(h)$
4.  $P\{N(h) \geq 2\} = o(h)$

ทฤษฎีที่ 2.2 เท่ากับนิยาม 2.5 และ 2.7 รวมกัน

พิสูจน์ จะแสดงให้เห็นว่านิยาม 2.7 มีความหมายเดียวกับ 2.5 ดังนี้

$$P_n(t) = P\{N(t) = n\}$$

สำหรับ  $P_0(t)$  จะได้จาก การหาอนุพันธ์ สมการ

$$\begin{aligned} P_0(t+h) &= P\{N(t+h) = 0\} \\ &= P\{N(t) = 0, N(t+h) - N(t) = 0\} \\ &= P\{N(t) = 0\} P\{N(t+h) - N(t) = 0\} \\ &= P_0(t)[1 - \lambda h + o(h)] \end{aligned}$$

ในที่สุดจะมี 2 สมการจากข้อสมมติที่ 2 รวมกับค่าความจริงของข้อสมมติที่ 3 และ 4 จะมีความหมายว่า  $P\{N(h) = 0\} = 1 - \lambda h + o(h)$  ดังนั้น

$$\frac{P_0(t+h) - P_0(t)}{h} = -\lambda P_0(t) + \frac{o(h)}{h}$$

ให้  $h \rightarrow 0$  จะได้

$$P_0'(t) = -\lambda P_0(t)$$

หรือ

$$\frac{P_0'(t)}{P_0(t)} = -\lambda$$

โดยการ integrate จะได้ว่า

$$\log P_0(t) = -\lambda t + c$$

หรือ

$$P_0(t) = K e^{-\lambda t}$$

ดังนั้น  $P_0(0) = P\{N(0) = 0\} = 1$  จึงจะได้ว่า

$$P_0(t) = e^{-\lambda t} \quad (2.13)$$

โดยทำนองเดียวกับ สำหรับ  $n > 0$

$$\begin{aligned} P_n(t+h) &= P\{N(t+h) = n\} \\ &= P\{N(t) = n, N(t+h) - N(t) = 0\} + P\{N(t) = n-1, N(t+h) - N(t) = 1\} \\ &\quad + \sum_{k=2}^n P\{N(t) = n-k, N(t+h) - N(t) = k\} \end{aligned}$$

จากข้อสมมติที่ 4 เทอมสุดท้ายที่ได้มาก่อนนั้นเป็น  $o(h)$  ดังนั้นโดยการใช้ข้อสมมติที่ 2 จะได้

$$\begin{aligned} P_n(t+h) &= P_n(t)P_0(h) + P_{n-1}(t)P_1(h) + o(h) \\ &= (1-\lambda h)P_n(t) + \lambda h P_{n-1}(t) + o(h) \end{aligned}$$

$$\text{ดังนั้น } \frac{P_n(t+h) - P_n(t)}{h} = -\lambda P_n(t) + \lambda P_{n-1}(t) + \frac{o(h)}{h}$$

ให้  $h \rightarrow 0$  ผลที่จะได้

$$P_n'(t) = -\lambda P_n(t) + \lambda P_{n-1}(t)$$

หรือมีค่าเท่ากับ  $e^{\lambda t} [P_n'(t) + \lambda P_n(t)] = \lambda e^{\lambda t} P_{n-1}(t)$

$$\text{ดังนั้น } \frac{d}{dt}(e^{\lambda t} P_n(t)) = \lambda e^{\lambda t} P_{n-1}(t) \quad (2.14)$$

ด้วยสมการ 2.13 จะมี

$$\frac{d}{dt}(e^{\lambda t} P_1(t)) = \lambda$$

หรือ

$$P_1(t) = (\lambda t + c)e^{-\lambda t}$$

ซึ่ง  $P_1(0) = 0$  ผลที่ได้

$$P_1(t) = \lambda t e^{-\lambda t}$$

แสดงให้เห็นว่า  $P_n(t) = e^{-\lambda t} (\lambda t)^n / n!$  เราใช้การพิสูจน์โดยทางคณิตศาสตร์ และด้วยข้อสมมติข้อแรกสำหรับ  $n - 1$  ด้วยสมการ (2.14)

$$\frac{d}{dt}(e^{\lambda t} P_n(t)) = \frac{\lambda^n t^{n-1}}{(n-1)!}$$

หรือ

$$e^{\lambda t} P_n(t) = \frac{(\lambda t)^n}{n!} + c$$


ซึ่งจะอธิบายผลลัพธ์ ( $P_n(0) = 0$ ) การพิสูจน์นี้ใช้นิยาม 2.7 จะอธิบายนิยาม 2.5 ได้

## ข้อสังเกต

1) ผลลัพธ์ของ  $N(t)$  มีการแจกแจงแบบปัวซองซึ่งเป็นผลลัพธ์ของการประมาณแบบปัวซองไปเป็นการแจกแจงแบบทวินาม จะเห็นว่าการแบ่งช่วงย่อย  $[0, t]$  จะเป็น  $k$  ส่วนเท่า ๆ กัน โดย  $k$  จะมีค่ามากตามรูปที่ 2.1 ขณะนี้แสดงให้เห็นว่าการใช้ข้อความจริงที่ไม่ต้องพิสูจน์ข้อ 4 ของนิยามที่ 2.7 ว่า  $k$  จะเพิ่มไปเรื่อยจนไปถึง  $\infty$  ความน่าจะเป็นของการมี 2 เหตุการณ์ หรือมากกว่านั้นในทุกค่าของช่วง  $k$  จะเข้าสู่ 0 ดังนั้น  $N(t)$  (ด้วยความน่าจะเป็นเข้าสู่ 1) จะเท่ากับจำนวนของแต่ละช่วงของเหตุการณ์ที่จะเกิดขึ้น แม้ว่าจะโดยการคงที่และการเพิ่มขึ้นอย่างเป็นอิสระ จำนวนนี้จะมีการแจกแจงแบบทวินาม ด้วยค่าพารามิเตอร์  $k$  และ  $P = \lambda t / k + o(t/k)$  ดังนั้น โดยการประมาณแบบปัวซองให้เป็นแบบทวินาม จะให้  $k$  มีค่าเข้าใกล้  $\infty$   $N(t)$  จะมีการแจกแจงเป็นแบบปัวซองด้วยค่าเฉลี่ย เท่ากับ

$$\begin{aligned} \lim_{k \rightarrow \infty} k \left[ \lambda \frac{t}{k} + o\left(\frac{t}{k}\right) \right] &= \lambda t + \lim_{k \rightarrow \infty} \frac{to(t/k)}{t/k} \\ &= \lambda t \end{aligned}$$

โดยการใช้คำนิยามของ  $o(h)$  และความจริงที่ว่า  $t/k \rightarrow 0$  เมื่อ  $t \rightarrow \infty$



รูปที่ 2.1

2) ข้อสมมติที่ชัดเจนแน่นอนว่ากระบวนการมีการเพิ่มขึ้นอย่างคงที่จะถูกขจัดไปจากนิยาม 2.7 ภายใต้เงื่อนไขว่า เปลี่ยนข้อสมมติข้อ 3 และข้อ 4 เพื่อต้องการว่าสำหรับทุก ๆ  $t$  ความน่าจะเป็นของเหตุการณ์ในช่วง  $(t, t+h)$  เป็น  $\lambda h + o(h)$  และความน่าจะเป็นของ 2 เหตุการณ์ หรือมากกว่านั้นในช่วงเป็น  $o(h)$  นั่นคือสมมติฐานว่า 2, 3 และ 4 ของคำนิยามที่ 2.7 สามารถที่จะแทนได้โดย

- 2) กระบวนการมีการเพิ่มขึ้นอย่างเป็นอิสระ
- 3)  $P\{N(t+h) - N(t) = 1\} = \lambda h + o(h)$
- 4)  $P\{N(t+h) - N(t) \geq 2\} = o(h)$

### 2.8.3 หลักการทั่วไปของกระบวนการปัวซอง (Generalizations of the Poisson Process)

#### 2.8.3.1 กระบวนการปัวซองแบบนอนโฮโมจีเนียส (Nonhomogeneous Poisson Process)

##### นิยามที่ 2.8

กระบวนการที่นับได้  $\{N(t), t \geq 0\}$  จะเป็นกระบวนการปัวซองแบบนอนโฮโมจีเนียส ด้วย intensity function  $\lambda(t), t \geq 0$  ถ้า

1.  $N(0) = 0$ ,
2.  $\{N(t), t \geq 0\}$  มีการเพิ่มขึ้นอย่างเป็นอิสระ,
- 3)  $P\{N(t+h) - N(t) \geq 2\} = o(h)$ ,
- 4)  $P\{N(t+h) - N(t) = 1\} = \lambda(t)h + o(h)$

ถ้าให้  $m(t) = \int_0^t \lambda(s) ds$  ดังนั้นจะได้ว่า

$$P\{N(t+s) - N(t) = n\} = e^{-[m(t+s) - m(t)]} \frac{[m(t+s) - m(t)]^n}{n!}, \quad n \geq 0 \quad (2.14)$$

หรืออาจจะกล่าวได้ว่า  $N(t+s) - N(t)$  มีการแจกแจงแบบปัวซอง ด้วยค่าเฉลี่ย  $m(t+s) - m(t)$  ตัวอย่างเช่น  $N(t)$  มีการแจกแจงแบบปัวซอง ด้วยค่าเฉลี่ย  $m(t)$  และสำหรับเหตุผลที่  $m(t)$  ถูกเรียกว่าเป็นฟังก์ชันค่าเฉลี่ยของกระบวนการจะสังเกตได้ว่าถ้า  $\lambda(t) = \lambda$  (นั่นคือจะเป็นกระบวนการปัวซอง) ดังนั้น  $m(t) = \lambda t$  ตามสมการที่ (2.14) และค่า  $N(t+s) - N(t)$  จะมีการแจกแจงแบบปัวซอง ด้วยค่าเฉลี่ย  $\lambda s$

การพิสูจน์สมการ (2.14) จะทำตามการพิสูจน์ของทฤษฎี 2.2 โดยจะมีการเปลี่ยนแปลงเพิ่มเติมคือเจาะจงค่า  $t$  และกำหนด

$$P_n(s) = P\{N(t+s) - N(t) = n\}$$

เนื่องจาก

$$\begin{aligned} P_n(s+h) &= P\{N(t+s+h) - N(t) = n\} \\ &= P\{\text{เหตุการณ์ที่ } 0 \text{ ใน } (t, t+s), \text{ เหตุการณ์ที่ } 0 \text{ ใน } [t+s, t+s+h]\} \\ &= P\{\text{เหตุการณ์ที่ } 0 \text{ ใน } (t, t+s)P\{\text{เหตุการณ์ที่ } 0 \text{ ใน } [t+s, t+s+h]\} \\ &= P_0(s) [1 - \lambda(t+s)h + o(h)] \end{aligned}$$

ซึ่ง 2 สมการสุดท้ายเป็นผลจากการเพิ่มขึ้นอย่างเป็นอิสระ ของข้อความจริงที่ 3 และ 4 รวมกันและมีความหมายว่า  $P\{N(t+s+h) - N(t) = 0\} = 1 - \lambda(t+s)h + o(h)$  ดังนั้น

$$\frac{P_0(s+h) - P_0(s)}{h} = -\lambda(t+s)P_0(s) + \frac{o(h)}{h}$$

ให้  $h \rightarrow 0$  ผลที่จะได้

$$P_0'(s) = -\lambda(t+s)P_0(s)$$

$$\text{หรือ } \log P_0(s) = \int_0^s -\lambda(t+u)du = -\int_t^{t+s} \lambda(y)dy$$

$$\text{หรือ } P_0(s) = e^{-[m(t+s)-m(t)]}$$

ความสำคัญของกระบวนการปัวซองแบบนอนโฮโมจีเนียส จะอยู่ที่ว่าไม่ต้องการเงื่อนไขของการเพิ่มขึ้นอย่างคงที่

แต่จะต้องเป็นไปได้ว่า เหตุการณ์ที่น่าจะเป็นไปได้ อาจเกิดขึ้นระหว่างเวลาที่แน่นอนระหว่างวัน มากกว่าระหว่างเวลาอื่น ๆ

### 2.8.3.2 กระบวนการปัวซองแบบคอมพาวด์(Compound Poisson Process)

กระบวนการสโตแคสติก (Stochastic)  $\{X(t), t \geq 0\}$  จะกล่าวได้ว่าเป็นกระบวนการปัวซองแบบคอมพาวด์ และสามารถเขียนได้ดังนี้

$$X(t) = \sum_{i=1}^{N(t)} Y_i, \quad t \geq 0 \quad (2.15)$$

ซึ่ง  $\{N(t), t \geq 0\}$  เป็นกระบวนการปัวซอง และ  $\{Y_n, n \geq 0\}$  เป็นชุดของตัวแปรสุ่มที่อิสระและมีการแจกแจงเหมือนกัน ๆ กัน ซึ่งจะเหมือนกับความเป็นอิสระของ  $\{N(t), t \geq 0\}$

ตัวอย่างของกระบวนการปัวซองแบบคอมพาวด์

1. ถ้า  $Y_i = 1$  แล้ว  $X(t) = N(t)$  ดังนั้นเราจะมีกระบวนการปัวซองที่ปกติ
2. สมมติว่ารถประจำทางหลาย ๆ คันมาถึงสนามกีฬาเป็นเหตุการณ์ที่มีความสอดคล้องด้วยกระบวนการปัวซอง และสมมติว่าจำนวนของลูกค้าในรถประจำทางแต่ละคันเป็นอิสระและมีการแจกแจงที่เหมือนกัน ๆ กัน ดังนั้น  $\{X(t), t \geq 0\}$  เป็นกระบวนการปัวซองแบบคอมพาวด์ ซึ่ง  $X(t)$  แสดงถึงจำนวนของลูกค้าที่มาถึงใน  $t$  ในสมการ (5.21)  $Y_i$  จะแสดงถึงจำนวนของลูกค้าในรถประจำทางคันที่  $i$
3. สมมติว่าลูกค้าออกจากร้านขายของซึ่งสอดคล้องกับกระบวนการปัวซอง ถ้า  $Y_i$  จำนวนการใช้จ่ายของลูกค้าคนที่  $i$ ,  $i = 1, 2, \dots$  ซึ่งเป็นอิสระและมีการแจกแจงเหมือนกัน ดังนั้น  $\{X(t), t \geq 0\}$  จะเป็นกระบวนการปัวซองแบบคอมพาวด์ เมื่อ  $X(t)$  แสดงถึงจำนวนรวมทั้งหมดของเงินที่ใช้จ่ายในเวลา  $t$