

บทที่ 2

สถิติที่ใช้ในการวิจัย

โดยทั่วไปในการวิเคราะห์ข้อมูลเกี่ยวกับระยะเวลาที่ยังคงอยู่ (Lifetime) มักจะพบกับปัญหาว่าข้อมูลที่เก็บรวบรวมมาได้เป็นข้อมูลที่ไม่สมบูรณ์ ทั้งนี้เนื่องจากข้อจำกัดต่างๆ ที่เกิดขึ้นในการเก็บรวบรวมข้อมูล โดยจะพบว่าข้อมูลที่ไม่สมบูรณ์จะมีค่าถูกตัดทิ้งทางขวา ทั้งนี้ในการพิจารณาการเกิดข้อมูลที่มีค่าถูกตัดทิ้งนั้นสามารถแยกชนิดได้ตามวิธีการได้มาของข้อมูลซึ่งแบ่งได้เป็น 3 ชนิด คือ ถ้าข้อมูลได้จากการทดลองภายใต้การกำหนดเวลาที่จะสิ้นสุดการเก็บข้อมูลของแต่ละหน่วยตัวอย่างไว้ล่วงหน้า โดยที่เวลาที่ได้กำหนดไว้นี้เป็นเวลาเดียวกันแล้ว ข้อมูลที่ได้นี้จะเป็ข้อมูลที่ถูกตัดทิ้งประเภทที่ 1 (Type I Censoring) นั่นคือ จะสามารถทราบข้อมูลระยะเวลาที่ยังคงอยู่ที่แท้จริงได้เฉพาะกรณีที่มีข้อมูลมีค่าน้อยกว่าเวลาที่กำหนดไว้เท่านั้น ซึ่งพบว่าจำนวนข้อมูลที่ทราบค่าแท้จริงนี้จะไม่แน่นอน แต่ถ้ามีการกำหนดจำนวนดังกล่าวนี้ไว้ล่วงหน้าอย่างแน่นอนแล้ว ข้อมูลที่ได้จะเป็นข้อมูลที่ถูกตัดทิ้งประเภทที่ 2 (Type II Censoring) โดยข้อมูลประเภทนี้จะไม่ทราบเวลาที่ใช้ในการเก็บรวบรวมข้อมูลที่แน่นอน เพราะจะต้องดำเนินการทดลองต่อไปจนกระทั่งสามารถบันทึกข้อมูลได้ครบตามจำนวนที่ได้กำหนดไว้ล่วงหน้า ส่วนข้อมูลที่ถูกตัดทิ้งชนิดที่ 3 คือ ข้อมูลที่ถูกตัดทิ้งแบบสุ่ม (Random Censoring) ซึ่งเป็นลักษณะของข้อมูลที่มีการตัดข้อมูลในระหว่างการทดลองและภายหลังสิ้นสุดการทดลอง

สำหรับในงานวิจัยครั้งนี้ ผู้วิจัยได้ทำการศึกษากรณีที่ข้อมูลถูกตัดทิ้งประเภทที่ 1 เท่านั้น โดยศึกษาภายใต้การแจกแจงแบบไวบูลล์ และการแจกแจงแบบลอกนอรัมอล โดยการนำข้อมูลมาทำการวิเคราะห์ทางสถิติ เพื่อประมาณค่าฟังก์ชันการอยู่รอดตามวิธีต่างๆ ดังนั้นในบทนี้จะกล่าวถึงรายละเอียดเกี่ยวกับการแจกแจงการอยู่รอด และฟังก์ชันต่างๆ รวมทั้งวิธีการประมาณฟังก์ชันการอยู่รอดโดยวิธีการประมาณที่ไม่ใช้พารามิเตอร์ ซึ่งมีรายละเอียดดังนี้

การแจกแจงการอยู่รอด

ให้ T เป็นตัวแปรสุ่มเวลาที่จะเกิดเหตุการณ์ที่สนใจศึกษา หรือเวลาการอยู่รอด

$f(t)$ เป็นฟังก์ชันความหนาแน่น (Density Function)

$F(t)$ เป็นฟังก์ชันการแจกแจง (Distribution Function)

$$\text{โดยที่ } F(t) = \Pr(T \leq t)$$

$S(t)$ เป็นฟังก์ชันการอยู่รอด (Survival Function) มีค่าเท่ากับความน่าจะเป็นที่หน่วยตัวอย่างมีการอยู่รอดนานกว่าเวลา t นั่นคือ

$$\begin{aligned} S(t) &= \Pr(\text{หน่วยตัวอย่างมีการอยู่รอดนานกว่าเวลา } t) \\ &= \Pr(T > t) \\ &= 1 - F(t) \end{aligned}$$

โดยที่ $S(t)$ มีคุณสมบัติดังนี้

1. $S(t)$ เป็นฟังก์ชันไม่เพิ่ม (Nonincreasing function)
2. $S(t)$ เป็นฟังก์ชันต่อเนื่องของ t
3. $S(t) = 1$ เมื่อ $t = 0$
4. $S(t) = 0$ เมื่อ $t = \infty$

$h(t)$ เป็นฟังก์ชันภาวะภัย (Hazard Function) ซึ่งมีค่าเท่ากับลิมิตของความน่าจะเป็นที่หน่วยตัวอย่างจะสูญเสียในช่วงเวลาสั้นๆ จาก t ถึง $t + \Delta t$ ต่อหน่วยเวลา Δt เมื่อแต่ละหน่วยตัวอย่างมีการอยู่รอดถึงเวลา t นั่นคือ

$$h(t) = \lim_{\Delta t \rightarrow 0} \Pr\{\text{หน่วยตัวอย่างที่มีอายุ } t \text{ จะสูญเสียในช่วง } (t, t + \Delta t)\} / \Delta t$$

โดยที่ $h(t)$ มีคุณสมบัติดังนี้

1. $h(t) \geq 0$; $-\infty < t < \infty$
2. $\lim_{t \rightarrow -\infty} \int_{-\infty}^t h(t) dt = 0$ และ $\lim_{t \rightarrow \infty} \int_{-\infty}^t h(t) dt = \infty$

$E(T)$ เป็นค่าเฉลี่ยของตัวแปรสุ่ม T

สามารถเขียนความสัมพันธ์ระหว่างฟังก์ชันการอยู่รอด ฟังก์ชันความหนาแน่นฟังก์ชันการแจกแจง และฟังก์ชันภาวะภัยได้ดังนี้

1. $f(t) = F'(t) = -S'(t)$
2. $h(t) = \frac{f(t)}{S(t)} = -\frac{S'(t)}{S(t)}$
3. $H(t) = \int_0^t h(u) du = -\ln S(t)$

$$\text{หรือ } S(t) = \exp\left(-\int_0^t h(u) du\right) = \exp(-H(t))$$

สำหรับในงานวิจัยนี้พิจารณารูปแบบการแจกแจงการอยู่รอด 2 รูปแบบ คือ

1. การแจกแจงแบบไวบูลล์ (Weibull Distribution)

เมื่อตัวแปรสุ่ม T มีการแจกแจงแบบไวบูลล์แล้ว สามารถเขียนฟังก์ชันต่างๆ ได้ดังนี้

$$f(t) = \begin{cases} \lambda\gamma(\lambda t)^{\gamma-1} \exp(-(\lambda t)^\gamma) & 0 < t < \infty, \lambda > 0, \gamma > 0 \\ 0 & \text{อื่นๆ} \end{cases}$$

$$F(t) = 1 - \exp(-(\lambda t)^\gamma)$$

$$S(t) = \exp(-(\lambda t)^\gamma)$$

$$h(t) = \lambda\gamma(\lambda t)^{\gamma-1}$$

$$E(T) = \frac{\Gamma(1+1/\gamma)}{\lambda}$$

เมื่อ $\Gamma(\nu)$ เป็นฟังก์ชันแกมมา (Gamma Function) ซึ่งสามารถคำนวณได้ดังนี้

$$\begin{aligned} \Gamma(\nu) &= \int_0^\infty y^{\nu-1} e^{-y} dy \\ &= (\nu-1)\Gamma(\nu-1) \\ &= (\nu-1)! \quad \text{เมื่อ } \nu \text{ เป็นจำนวนเต็ม} \end{aligned}$$

และ $\Gamma(0.5) = \sqrt{\pi}$

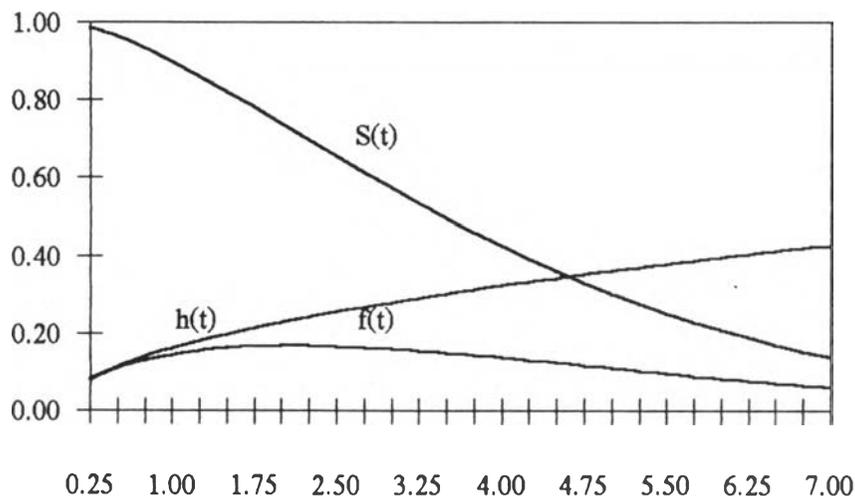
โดยที่ เมื่อกำหนดให้พารามิเตอร์ λ คงที่แล้ว ลักษณะรูปแบบของฟังก์ชันภาวะภัยจะขึ้นอยู่กับพารามิเตอร์ γ ดังนี้

ถ้า $\gamma < 1.0$ แล้ว ฟังก์ชันภาวะภัย $h(t)$ จะลดลงเมื่อ t เพิ่มขึ้น

$\gamma = 1.0$ แล้ว ฟังก์ชันภาวะภัย $h(t)$ จะคงที่เมื่อ t เพิ่มขึ้น

$\gamma > 1.0$ แล้ว ฟังก์ชันภาวะภัย $h(t)$ จะเพิ่มขึ้นเมื่อ t เพิ่มขึ้น

สำหรับรูปแบบของฟังก์ชัน $f(t)$, $S(t)$ และ $h(t)$ เมื่อการแจกแจงการอยู่รอดเป็นแบบไวบูลล์ที่มีค่าเฉลี่ยของการแจกแจง $E(t)$ เป็น 4.0 และ $\gamma = 1.5$ แสดงได้ดังรูปที่ 2.1



รูปที่ 2.1

2. การแจกแจงแบบลอการิธึม (Lognormal Distribution)

เมื่อตัวแปรสุ่ม T มีการแจกแจงแบบลอการิธึมแล้ว สามารถเขียนฟังก์ชันต่างๆ ได้ดังนี้

$$f(t) = \begin{cases} \frac{1}{t\sigma\sqrt{2\pi}} \exp\left[-\frac{(\ln(t) - \mu)^2}{2\sigma^2}\right] & t > 0, -\infty < \mu < \infty, \sigma > 0 \\ 0 & \text{อื่นๆ} \end{cases}$$

$$F(t) = \Phi\left[\frac{\ln(t) - \mu}{\sigma}\right]$$

เมื่อ $\Phi(x)$ คือ ฟังก์ชันการแจกแจงปกติมาตรฐาน

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_0^x \exp\left(-\frac{u^2}{2}\right) du$$

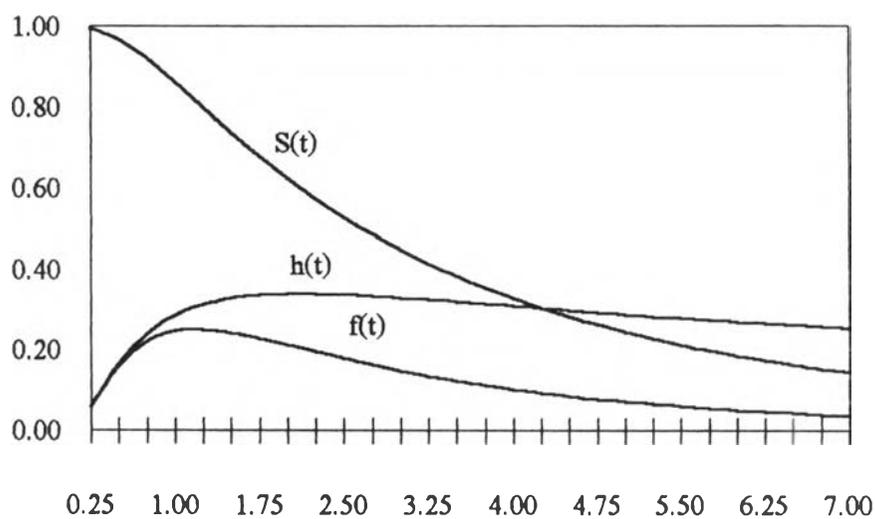
$$\text{ดังนั้น } S(t) = 1 - \Phi\left[\frac{\ln(t) - \mu}{\sigma}\right]$$

$$E(T) = \exp\left(\mu + \frac{\sigma^2}{2}\right)$$

เมื่อกำหนดให้ μ คงที่แล้ว ลักษณะรูปแบบของฟังก์ชันภาวะภัยจะขึ้นอยู่กับ σ ดังนี้

ถ้า $\sigma \geq 2.0$ แล้วฟังก์ชันภาวะภัย $h(t)$ จะลดลงเมื่อ t เพิ่มขึ้น
 $\sigma < 0.5$ แล้วฟังก์ชันภาวะภัย $h(t)$ จะเพิ่มขึ้นเมื่อ t เพิ่มขึ้น
 σ ใกล้เคียงกับ 1.0 แล้วฟังก์ชันภาวะภัย $h(t)$ ก่อนข้างจะคงที่ โดยจะเพิ่มขึ้นอย่างรวดเร็วจนในช่วงต้นๆ และจะคงที่เมื่อ t เพิ่มขึ้น

สำหรับรูปแบบของฟังก์ชัน $f(t)$, $S(t)$ และ $h(t)$ เมื่อการแจกแจงการอยู่รอดเป็นแบบลอกนอรั่มอลที่มีค่าเฉลี่ยของการแจกแจง $E(t)$ เป็น 4.0 และ $\sigma = 0.9$ แสดงได้ดังรูปที่ 2.2



รูปที่ 2.2

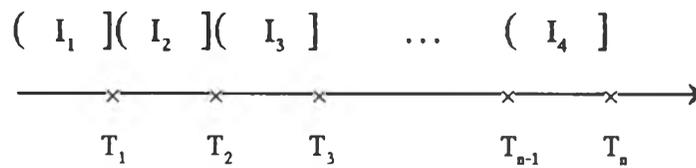
สถิติที่ใช้ในการวิจัย

1. วิธีพีแอล (Product Limit (PL) Method)¹

วิธีพีแอล เป็นวิธีการประมาณฟังก์ชันการอยู่รอดสำหรับข้อมูลที่ไม่สมบูรณ์ ซึ่งถูกพัฒนาขึ้นโดย แคปแลนและไมเออร์ (Kaplan and Meier, 1958) ซึ่งมีแนวความคิดและรายละเอียดในการคำนวณ ดังนี้

สมมติว่า ค่าสังเกตของเวลาที่อยู่รอด (Survival Time) จำนวน n ตัวอย่าง มีค่าสังเกตเป็น X_1, X_2, \dots, X_n นำค่าสังเกตมาเรียงลำดับค่าน้อยไปมากจะได้ $T_1 < T_2 < \dots < T_n$

¹ Kaplan EL, and Meier P. "Nonparametric Estimation From Incomplete Observations," Journal of the American Statistical Association 53 (1958): 457-481.



ให้ n_i เป็นจำนวนค่าสังเกตที่ถูกรอด ณ จุดเริ่มต้นของช่วงเวลา I_i

d_i เป็นจำนวนตัวอย่างที่เสียชีวิตระหว่างช่วงเวลา I_i

p_i เป็นความน่าจะเป็นที่จะอยู่รอดถึงช่วงเวลา I_i โดยที่อยู่รอดมาแล้ว ณ จุดเริ่มต้นของช่วงเวลา I_i นั่นคือ

$$p_i = \Pr(T > t_i | T > t_{i-1})$$

$$q_i = 1 - p_i$$

โดยที่ $\hat{q}_i = \frac{d_i}{n_i}$

เมื่อความน่าจะเป็นของการมีชีวิตอยู่รอด t_k ปี คือ

$$\begin{aligned}
 S(t_k) &= \Pr(T > t_k) \\
 &= \Pr(T > t_1) * \Pr(T > t_2 | T > t_1) * \dots * \Pr(T > t_k | T > t_{k-1}) \\
 &= p_1 \cdot p_2 \cdots p_k
 \end{aligned}$$

ดังนั้น สำหรับกรณีทั่วไป

$$\begin{aligned}
 \hat{S}(t) &= \prod_{(i, t_i \leq t)} \hat{p}_i \\
 &= \prod_{(i, t_i \leq t)} \left(1 - \frac{d_i}{n_i} \right)^{\delta_i}
 \end{aligned} \tag{2.1}$$

และถ้าข้อมูลไม่มีค่าสังเกตซ้ำ (Tied Observations) ในช่วงเวลา I_i

จะได้ว่า $\hat{q}_i = \frac{1}{n_i}$

$$\hat{p}_i = 1 - \hat{q}_i$$

$$\hat{p}_i = 1 - \frac{1}{n_i}$$

$$= 1$$

เมื่อ $\delta_i = 1$ ข้อมูลไม่ถูกตัดทิ้ง

เมื่อ $\delta_i = 0$ ข้อมูลถูกตัดทิ้ง

$$\begin{aligned}
\text{ดังนั้น} \quad \hat{S}(t) &= \prod_{\{i; t \leq t\}} \hat{p}_i \\
&= \prod_{\{i; t \leq t\}} \left(1 - \frac{1}{n_i}\right)^{\delta_i} \\
&= \prod_{\{i; t \leq t\}} \left(1 - \frac{1}{n-i+1}\right)^{\delta_i} \\
\hat{S}_{PL}(t) &= \prod_{\{i; t \leq t\}} \left(\frac{n-i}{n-i+1}\right)^{\delta_i} \quad (2.2)
\end{aligned}$$

เมื่อ n เป็นจำนวนข้อมูลทั้งหมดที่ถูกตัดทิ้งและไม่ถูกตัดทิ้ง
 i เป็นลำดับที่ของข้อมูลในการเรียงลำดับค่าจากน้อยไปมาก

2. วิธีฟังก์ชันภาวะภัย (Hazard Function Method)²

วิธีนี้จะประมาณฟังก์ชันการอยู่รอดจากการประมาณฟังก์ชันภาวะภัยสะสม (Cumulative Hazard Function; $\Lambda(t)$) ก่อน โดยอาศัยความสัมพันธ์ระหว่างฟังก์ชันการอยู่รอดและฟังก์ชันภาวะภัยสะสม ดังนี้

$$\begin{aligned}
\text{เนื่องจาก} \quad h(t) &= \frac{f(t)}{1-F(t)} = \frac{F'(t)}{1-F(t)} = -\frac{S'(t)}{S(t)} \\
\Lambda(t) &= \int_0^t h(u) du \\
&= \int_0^t -\frac{S'(t)}{S(t)} dt \\
&= -\ln S(t)
\end{aligned}$$

$$\text{ดังนั้น} \quad S(t) = e^{-\Lambda(t)} \quad (2.3)$$

$$\text{และ} \quad \hat{\Lambda}(t) = -\ln \hat{S}(t) \quad (2.4)$$

และจากการประมาณ $\hat{S}(t)$ ด้วยวิธีพีแอลในสมการที่ (2.1) และสมการ (2.4) จะได้

$$\hat{\Lambda}(t) = -\ln \left[\prod_{\{i; t \leq t\}} \left(1 - \frac{d_i}{n_i}\right)^{\delta_i} \right] \quad (2.5)$$

² Rupert G. Miller, Jr., Survival Analysis New York : John Wiley & sons, 1981.

$$\hat{\Lambda}(t) = -\delta_i \sum_{i: t_i \leq t} \ln\left(1 - \frac{d_i}{n_i}\right) \quad (2.6)$$

และเพราะว่า $-\ln\left(1 - \frac{d_i}{n_i}\right) = \frac{d_i}{n_i} + \frac{1}{2}\left(\frac{d_i}{n_i}\right)^2 + \dots$

เมื่อพิจารณาเฉพาะพจน์ที่มีกำลังเป็น 1 ดังนั้นจะได้ว่า

$$-\ln\left(1 - \frac{d_i}{n_i}\right) \approx \frac{d_i}{n_i}$$

จาก (2.6) จะสามารถประมาณฟังก์ชันภาวะภัยสะสมได้เป็น

$$\hat{\Lambda}(t) = -\delta_i \sum_{i: t_i \leq t} \frac{d_i}{n_i} \quad (2.7)$$

ดังนั้น จากสมการ (2.3) และ (2.7) จะได้ตัวประมาณฟังก์ชันการอยู่รอด ซึ่งเรียกว่าตัวประมาณเนลสัน-อาเลน (Nelson-Aalen Estimator) เป็น

$$\hat{S}(t) = \exp\left(-\delta_i \sum_{i: t_i \leq t} \frac{d_i}{n_i}\right) \quad (2.8)$$

และเมื่อข้อมูลไม่มีค่าสังเกตซ้ำ จะได้

$$\hat{\Lambda}(t) = \sum_{i: t_i \leq t} \frac{\delta_i}{n - i + 1} \quad (2.9)$$

ดังนั้น จากสมการที่ (2.3) และ (2.9) จะได้ตัวประมาณฟังก์ชันการอยู่รอด คือ

$$\hat{S}_{HA}(t) = \exp\left(-\sum_{i: t_i \leq t} \frac{\delta_i}{n - i + 1}\right) \quad (2.10)$$

3. วิธีเบย์ (Bayes Method)³

วิธีเบย์นี้ เป็นวิธีทางสถิติที่ต้องอาศัยข้อมูลจากกลุ่มตัวอย่างที่นำมาศึกษา และข้อมูลหรือประสบการณ์ในอดีตเข้าช่วยในการประมาณค่า โดยจากข้อมูลหรือประสบการณ์ในอดีตนี้ทำให้สามารถประมาณการแจกแจงก่อน (Prior Distribution) ได้ และเมื่อทราบการแจกแจงก่อน และข้อมูลจากกลุ่มตัวอย่างที่นำมาศึกษาแล้ว จะสามารถทราบการแจกแจงภายหลัง (Posterior Distribution) ได้ โดยจะนำการแจกแจงดังกล่าวนี้ไปใช้ในการประมาณค่าที่ต้องการได้

สำหรับการวิจัยครั้งนี้ กำหนดให้ T_1, T_2, \dots, T_n เป็นตัวอย่างสุ่มจากฟังก์ชันการแจกแจงสะสม (Cumulative Distribution Function) F และ T_c เป็นค่าคงที่ซึ่งทราบค่า และให้ $Z_i = \min(T_i, T_c)$ เมื่อ $i = 1, 2, \dots, n$

ในที่นี้จะหาตัวประมาณเบย์ภายใต้การกำหนดให้ฟังก์ชันความสูญเสียเป็นความคลาดเคลื่อนกำลังสอง (squared-error loss function)

$$l(F(t) - \hat{F}(t)) = (F(t) - \hat{F}(t))^2$$

ดังนั้น ตัวประมาณเบย์สามารถหาได้จากการหาค่าคาดหวังของการแจกแจงภายหลังของ F เมื่อกำหนด (Z_i, δ_i)

สำหรับการประมาณค่าฟังก์ชันการอยู่รอด ด้วยวิธีตัวประมาณเบย์โดยวิธีการประมาณที่ไม่ใช่พารามิเตอร์ ในที่นี้พิจารณาการแจกแจงก่อนของ F เป็นกระบวนการนิวทรัลทางขวา (Process neutral to the right)

เมื่อ $F(t)$ เป็นฟังก์ชันการแจกแจงสุ่มที่เป็นนิวทรัลทางขวา (neutral to the right) แล้ว $F(t)$ สามารถเขียนได้ในรูปของ

$$F(t) = 1 - e^{-\lambda t} \quad (2.11)$$

³ Ferguson Thomas S. and Eswar G. Phadia, "Bayesian Nonparametric Estimation Based on Censored Data," *The Annals of Statistics* 7 (1979): 163-186.

โดยที่ Y_t เป็นกระบวนการซึ่งมีการเพิ่มขึ้นอย่างอิสระ (Independent increment) ซึ่งมีคุณสมบัติดังนี้

- 1) Y_t เป็นฟังก์ชันไม่ลดลง (Nondecreasing)
- 2) Y_t ต่อเนื่องทางขวา (Right-continuous)
- 3) $\lim_{t \rightarrow -\infty} Y_t = 0$
- 4) $\lim_{t \rightarrow +\infty} Y_t = \infty$

กำหนดให้ $S(t)$ เป็นฟังก์ชันการอยู่รอดซึ่งนิยามได้ดังนี้

$$S(t) = 1 - F(t) \quad (2.12)$$

ดังนั้น จากสมการ (2.11) และ (2.12) จะได้ว่า การหาค่าคาดหวังของการแจกแจงภายหลังของ F เมื่อกำหนด (Z_i, δ_i) คือ การหาโมเมนต์ที่ 1 ของ Y_t

$$\begin{aligned} E[S(t)|(Z_i, \delta_i)] &= E[(1 - F(t)|(Z_i, \delta_i)] \\ &= E[(1 - (1 - e^{-Y_t}))|(Z_i, \delta_i)] \\ &= E[e^{-Y_t}|(Z_i, \delta_i)] \end{aligned}$$

นั่นคือ
$$E[S(t)|(Z_i, \delta_i)] = M_t(1|(Z_i, \delta_i)) \quad (2.13)$$

โดยที่ $M_t(\theta|(Z_i, \delta_i))$ เป็นฟังก์ชันที่ให้โมเมนต์ภายหลัง (Posterior Moment Generating function) ของ Y_t ซึ่งในที่นี้ นิยามฟังก์ชันที่ให้โมเมนต์เป็น

$$M_t(\theta) = E(e^{-\theta Y_t})$$

กำหนดให้ u_1, u_2, \dots, u_k คือ ค่าที่แตกต่างกันของ t_1, t_2, \dots, t_k โดยที่ $u_1 < u_2 < \dots < u_k$
 $\rho_1, \rho_2, \dots, \rho_k$ คือ จำนวนของค่าสังเกตที่ไม่ถูกตัดทิ้งที่ u_1, u_2, \dots, u_k ตามลำดับ
 $\lambda_1, \lambda_2, \dots, \lambda_k$ คือ จำนวนของค่าสังเกตที่มีค่าถูกตัดทิ้งที่ u_1, u_2, \dots, u_k ตามลำดับ
 h_j เป็นจำนวนของ t ที่มีค่ามากกว่า u_j
 $j(t)$ เป็นจำนวนของ u_i ที่มีค่าน้อยกว่าหรือเท่ากับ t

ดังนั้น จะได้ว่า
$$h_j = \sum_{i=j+1}^k (\rho_i + \lambda_i)$$

เมื่อ F เป็นฟังก์ชันการแจกแจงกลุ่มที่เป็นนิพจน์ทางขวา และให้ T_1, T_2, \dots, T_n เป็นตัวอย่างสุ่มขนาด n จาก F แล้วจะได้ว่า การแจกแจงภายหลังของ F เมื่อกำหนดข้อมูล (Z_i, δ_i) จะเป็น นิพจน์ทางขวา และมีฟังก์ชันที่ให้โมเมนต์ภายหลังของ Y_i เป็น

$$M_i(\theta | (Z_i, \delta_i)) = \frac{M_i(\theta + h_{j(i)})}{M_i(h_{j(i)})} \cdot \prod_{i=1}^{j(i)} \left[\frac{M_u^-(\theta + h_{i-1})}{M_u^-(h_{i-1})} \cdot \frac{C_u(\theta + h_i + \lambda_i, \rho_i)}{C_u(h_i + \lambda_i, \rho_i)} \cdot \frac{M_u(h_i)}{M_u(\theta + h_i)} \right] \quad (2.14)$$

โดยที่ ถ้า u เป็นจุดที่กำหนดไว้ล่วงหน้าของ Y_i

$$C_u(\alpha, \beta) = \int_0^\infty e^{-\alpha s} (1 - e^{-s})^\beta dG_u(s) \quad (2.15)$$

และ ถ้า u ไม่ได้เป็นจุดที่กำหนดไว้ล่วงหน้าของ Y_i

$$\begin{aligned} C_u(\alpha, \beta) &= \int_0^\infty e^{-\alpha s} (1 - e^{-s})^{\beta-1} dH_u(s) && \text{ถ้า } \beta \geq 1 \\ &= 1 && \text{ถ้า } \beta = 0 \end{aligned} \quad (2.16)$$

เมื่อ S เป็นค่าที่เพิ่มขึ้นของ Y_i ที่ u , นั่นคือ $S = Y_i - Y_i^-$

$G_u(s)$ เป็นการแจกแจงก่อนของ S ที่ u

$H_u(s)$ เป็นการแจกแจงภายหลังของ S ที่ u เมื่อกำหนด $T = u$

ดังนั้น จากสมการ (2.13) และ (2.14) จะได้ว่า

$$M_i(1 | (Z_i, \delta_i)) = \frac{M_i(1 + h_{j(i)})}{M_i(h_{j(i)})} \cdot \prod_{i=1}^{j(i)} \left[\frac{M_u^-(1 + h_{i-1})}{M_u^-(h_{i-1})} \cdot \frac{C_u(1 + h_i + \lambda_i, \rho_i)}{C_u(h_i + \lambda_i, \rho_i)} \cdot \frac{M_u(h_i)}{M_u(1 + h_i)} \right] \quad (2.17)$$

⁴ Doksum, K., "Tailfree and neutral random probabilities and their posterior distributions," The Annals of Probability 2 (1974): 183-201.

และเมื่อกำหนดให้

$$R_t(h) = \frac{M_t(h+1)}{M_t(h)} \quad (2.18)$$

$$r_u(\alpha, \beta) = C_u(\alpha+1, \beta)/C_u(\alpha, \beta) \quad (2.19)$$

ดังนั้น $E[S(t)|(Z_i, \delta_i)] = M_t(1|(Z_i, \delta_i))$

$$= R_t(h_{j(t)}) \prod_{i=1}^{j(t)} \frac{R_u^-(h_{i-1})}{R_u^-(h_i)} \cdot r_u(h_i + \lambda_i, \rho_i) \quad (2.20)$$

กำหนดให้ $Y_t^- = \lim_{s \rightarrow t} Y_s$

$M_t^-(\theta)$ เป็นฟังก์ชันที่ให้โมเมนต์ (Moment Generating Function) ของ Y_t^-

$M_t(\theta)$ เป็นฟังก์ชันที่ให้โมเมนต์ (Moment Generating Function) ของ Y_t

โดยที่ ฟังก์ชันที่ให้โมเมนต์ของ Y_t สามารถเขียนให้อยู่ในรูป

$$M_t(\theta) = e^{\int_0^{\infty} (e^{-z\theta} - 1) dN(z)} \quad (2.21)$$

เมื่อ $\gamma(t)$ เป็นฟังก์ชันต่อเนื่องที่ไม่ลดลง ที่มี $\lim_{t \rightarrow \infty} \gamma(t) = 0$ และ $\lim_{t \rightarrow \infty} \gamma(t) = +\infty$

$N(z)$ เป็นฟังก์ชันต่อเนื่องที่ไม่ลดลงซึ่งเป็นตัววัด (measure) ใดๆ บน $(0, \infty)$

สำหรับในการวิจัยครั้งนี้ พิจารณาการแจกแจงก่อนเป็น 2 แบบ ดังนี้ คือ

3.1) แบบกระบวนการแกมมา (Gamma Process)

โดยทั่วไปเมื่อ Y_t มีการแจกแจงแบบแกมมาแล้ว จะเรียก Y_t เป็นกระบวนการแกมมา ซึ่งสามารถเขียนฟังก์ชันที่ให้โมเมนต์ของ Y_t ได้ในรูป

$$\begin{aligned} M_t(\theta) &= \frac{\tau^{\gamma(t)}}{\Gamma(\gamma(t))} \int_0^{\infty} e^{-\theta y} e^{\gamma y} y^{\gamma(t)-1} dy \\ &= \left(\frac{\tau}{\tau + \theta} \right)^{\gamma(t)} \\ &= e^{\int_0^{\infty} (e^{-z\theta} - 1) e^{-\alpha z} dz} \end{aligned} \quad (2.22)$$

$$\begin{aligned} \text{ในที่นี้ ถ้าให้ } \varphi(\alpha, \beta, N) &= \int_0^{\infty} e^{-z\alpha} (1 - e^{-z})^{\beta} dN(z) && \text{เมื่อ } \beta \geq 1 \\ &= 1 && \text{เมื่อ } \beta = 0 \end{aligned} \quad (2.23)$$

ดังนั้น สามารถเขียนทุกฟังก์ชันในสมการ (2.20) ให้อยู่ในรูปของฟังก์ชัน φ ได้ดังนี้

$$\begin{aligned} C_u(\alpha, \beta) &= \varphi(\alpha, \beta, N) / \varphi(0, 1, N) && \text{เมื่อ } \beta \geq 1 \\ &= 1 && \text{เมื่อ } \beta = 0 \end{aligned} \quad (2.24)$$

และ จากสมการ (2.18) และ (2.21) จะได้ว่า

$$R_i(h) = e^{-\gamma(t)\varphi(h, 1, N)} \quad (2.25)$$

และ จากสมการ (2.19) และ (2.24) จะได้ว่า

$$r_u(\alpha, \beta) = \varphi(\alpha + 1, \beta, N) / \varphi(\alpha, \beta, N) \quad (2.26)$$

จาก (2.22) จะกล่าวได้ว่า Y_t มีการแจกแจงแบบแกมมาที่มีพารามิเตอร์เป็น $\gamma(t)$ และ τ โดยที่

$$dN(z) = e^{-z\tau} z^{-1} dz$$

ดังนั้น จากสมการ (2.23) สามารถเขียนฟังก์ชัน $\varphi(\alpha, \beta, N)$ ได้เป็น

$$\varphi(\alpha, \beta, N) = \int_0^{\infty} e^{-z\alpha} (1 - e^{-z})^{\beta} e^{-z\tau} z^{-1} dz$$

ในที่นี้ ฟังก์ชัน N จะหาได้จากพารามิเตอร์ τ ซึ่งสามารถนำไปรวมกับ α ได้ ดังนั้น สำหรับกระบวนการแกมมาแล้ว จะได้

$$\begin{aligned} \varphi_{\alpha}(\alpha, \beta) &= \int_0^{\infty} e^{-z\alpha} (1 - e^{-z})^{\beta} z^{-1} dz && \text{เมื่อ } \beta \geq 1 \\ &= 1 && \text{เมื่อ } \beta = 0 \end{aligned} \quad (2.27)$$

นั่นคือ $\varphi(\alpha, \beta, N) = \varphi_G(\alpha + \tau, \beta)$ และจาก (2.22) และ (2.27) เมื่อ $\theta = 1$ จะได้

$$\varphi_G(\alpha, 1) = \log\left(\frac{\alpha + 1}{\alpha}\right) \quad (2.28)$$

และจาก (2.25) และ (2.28) สามารถเขียน $R_i(h)$ ได้เป็น

$$R_i(h) = \left(\frac{h + \tau}{h + \tau + 1}\right)^{r^{(i)}} \quad (2.29)$$

ดังนั้น จาก (2.20), (2.26) และ (2.29) จะได้ว่า เมื่อ Y_i เป็นกระบวนการแกมมาด้วยพารามิเตอร์ $r^{(i)}$ และ τ สามารถคำนวณฟังก์ชันการอยู่รอด $S_G(t)$ จากการหาค่าคาดหวังภายหลังของ $S(t)$ ดังนี้

$$E(S(t) | Z_i, \delta_i) = \left(\frac{h_{j^{(i)}} + \tau}{h_{j^{(i)}} + \tau + 1}\right)^{r^{(i)}} \prod_{i=1}^{j^{(i)}} \left[\left(\frac{(h_{i-1} + \tau)(h_i + \tau + 1)}{(h_{i-1} + \tau + 1)(h_i + \tau)}\right)^{r^{(i)}} \frac{\varphi_G(h_i + \lambda_i + \tau + 1, \rho_i)}{\varphi_G(h_i + \lambda_i + \tau, \rho_i)} \right] \quad (2.30)$$

ในทางปฏิบัติแล้ว จะต้องมีการกำหนดการแจกแจงก่อนการทดลอง (Prior guess) ของ $S(t)$ โดยนำความรู้จากข้อมูลในอดีตมาช่วยในการตัดสินใจ และเพื่อเป็นประโยชน์ในการประมาณค่าพารามิเตอร์ โดยที่การแจกแจงก่อนการทดลองของ $S(t)$ สำหรับกระบวนการแกมมาสามารถคำนวณได้ดังนี้คือ

$$E(S(t)) = M_t(1) = \left(\frac{\tau}{\tau + 1}\right)^{r^{(t)}}$$

ถ้าให้การแจกแจงก่อนการทดลองของ $S(t)$ คือ $S_0(t)$ แล้ว จะได้

$$S_0(t) = \left(\frac{\tau}{\tau + 1}\right)^{r^{(t)}}$$

และเมื่อกำหนดค่าให้กับพารามิเตอร์ τ จะสามารถคำนวณค่าพารามิเตอร์ $\gamma(t)$ สำหรับทุกค่าของ t ได้ดังนี้

$$\gamma(t) = \log(S_0(t))/\log(\tau/(\tau+1)) \quad (2.31)$$

3.2) แบบกระบวนการดิริชเลต์ (Dirichlet Process)

ในที่นี้พิจารณากระบวนการดิริชเลต์ ($\mathcal{D}(\alpha)$) ซึ่งมี α เป็นพารามิเตอร์ โดยที่ α เป็นฟังก์ชันต่อเนื่องทางขวาที่ไม่ลดลง (nondecreasing right-continuous function) บนจำนวนจริง (R) โดยมี $\lim_{t \rightarrow -\infty} \alpha(t) = 0$ และ $\lim_{t \rightarrow +\infty} \alpha(t) = \alpha(R) < \infty$

เมื่อ $\mathcal{D}(\alpha)$ เป็นฟังก์ชันการแจกแจงกลุ่มที่เป็นนิวทรัลทางขวาแล้ว จะสามารถเขียนฟังก์ชันที่ให้โมเมนต์ของ Y_t ได้ในรูป

$$\begin{aligned} M_t(\theta) &= \frac{\Gamma(\alpha(R))}{\Gamma(\alpha(t))\Gamma(\alpha(R)-\alpha(t))} \int_0^\infty e^{-(\alpha(R)-\alpha(t)+\theta)y} (1-e^{-y})^{\alpha(t)-1} dy \quad (2.32) \\ &= \frac{\Gamma(\alpha(R))\Gamma(\alpha(R)-\alpha(t)+\theta)}{\Gamma(\alpha(R)-\alpha(t))\Gamma(\alpha(R)+\theta)} \\ &= e^{\int_0^\infty (e^{-z}-1)dN_t(z)} \end{aligned}$$

$$\text{โดยที่ } dN_t(z) = \frac{e^{-\alpha(R)z} (e^{-\alpha(t)z} - 1)}{z(1-e^{-z})} dz$$

เมื่อ $0 < \alpha(t) < \alpha(R)$ และจากฟังก์ชันที่ให้โมเมนต์ของ Y_t ในสมการที่ (2.32) กำหนดให้มีการแจกแจงเป็น $\Pi(\alpha(t), \alpha(R)-\alpha(t))$ ดังนั้น สำหรับ $s < t$ จะได้ $Y_t - Y_s \in \Pi(\alpha(t)-\alpha(s), \alpha(R)-\alpha(t))$

โดยที่สามารถหาค่าของฟังก์ชัน R และ r ได้ นั่นคือ จากสมการ (2.18) และ (2.32) จะได้

$$R_t(h) = \frac{\alpha(R) - \alpha(t) + h}{\alpha(R) + h} \quad (2.33)$$

และสำหรับการหาค่าของ $r_u(a, b)$ จะพิจารณาแยกเป็น 2 กรณี คือ

1. เมื่อ u เป็นจุดที่ถูกกำหนดไว้ล่วงหน้า (prior fixed point) ของ Y_i

ดังนั้น u จะเป็นจุดที่ไม่ต่อเนื่องของ α และถ้าให้ $\Delta(u) = \alpha(u) - \alpha^-(u)$ แล้วฟังก์ชันการแจกแจงก่อนของ $Y_u - Y_u^-$ คือ $\Pi(\Delta(u), \alpha(R) - \alpha(u))$ และจากสมการ (2.15) และ (2.32) จะได้

$$C_u(a, b) = \frac{\Gamma(\alpha(R) - \alpha(u) + \Delta(u))\Gamma(\Delta(u) + b)\Gamma(\alpha(R) - \alpha(u) + a)}{\Gamma(\Delta(u))\Gamma(\alpha(R) - \alpha(u))\Gamma(\alpha(R) - \alpha(u) + \Delta(u) + a + b)} \quad (2.34)$$

$$\text{ดังนั้น } r_u(a, b) = \frac{\alpha(R) - \alpha(u) + a}{\alpha(R) - \alpha(u) + \Delta(u) + a + b} \quad (2.35)$$

2. เมื่อ u ไม่ใช่จุดที่กำหนดไว้ล่วงหน้าของ Y_i สามารถคำนวณได้จากสมการ (2.34) โดยพิจารณาที่ $\Delta(u) = 0$

ดังนั้นค่าคาดหวังภายหลังของ $S(t)$ เมื่อการแจกแจงก่อนของ F เป็นกระบวนการคิริชเลต์ จะคำนวณได้จาก

$$E(S(t) | (Z_i, \delta_i)) = \frac{\alpha(R) - \alpha(t) + h_{j(t)}}{\alpha(R) + n} \cdot \prod_{i=1}^{j(t)} \frac{(\alpha(R) - \alpha^-(u_i) + h_{i-1})(\alpha(R) - \alpha(u_i) + h_i + \lambda_i)}{(\alpha(R) - \alpha(u_i) + h_i)(\alpha(R) - \alpha^-(u_i) + h_i + \lambda_i + \rho_i)} \quad (2.36)$$

$$\text{ให้ } K = \prod_{i=1}^{j(t)} \frac{(\alpha(R) - \alpha^-(u_i) + h_{i-1})(\alpha(R) - \alpha(u_i) + h_i + \lambda_i)}{(\alpha(R) - \alpha(u_i) + h_i)(\alpha(R) - \alpha^-(u_i) + h_i + \lambda_i + \rho_i)}$$

จากสมการ (2.36) พบว่า ถ้า u_i เป็นจุดที่เกิดการตัดทิ้งของข้อมูล (Censoring point) แล้วจะได้ว่า $\rho_i = 0$ และทำให้ $h_{i-1} = h_i + \lambda_i$ ดังนั้น

$$K = \prod_{i=1}^{j(t)} \frac{(\alpha(R) - \alpha(u_i) + h_i + \lambda_i)}{(\alpha(R) - \alpha(u_i) + h_i)}$$

และเมื่อ u_i ไม่ใช่จุดที่เกิดการตัดทิ้งของข้อมูล จะได้ว่า $\lambda_i = 0$ และทำให้ $h_{i-1} = h_i + \rho_i$ ดังนั้น

$$K = 1$$

นั่นคือ สามารถคำนวณฟังก์ชันการอยู่รอด $\hat{S}_D(t)$ จากค่าคาดหวังภายหลังของ $S(t)$ เมื่อการแจกแจงก่อนของ F เป็นกระบวนการดิริชเลต์ ดังนี้

$$E(S(t) | (Z_i, \delta_i)) = \frac{\alpha(R) - \alpha(t) + h_{j(t)}}{\alpha(R) + n} \cdot \prod_{i=1}^{j(t)} \frac{(\alpha(R) - \alpha(u_i) + h_i + \lambda_i)}{(\alpha(R) - \alpha(u_i) + h_i)} \quad (2.37)$$

ในทางปฏิบัติแล้ว จะต้องมีกำหนดการแจกแจงก่อนการทดลอง (Prior guess) ของ $S(t)$ โดยนำความรู้จากข้อมูลในอดีตมาช่วยในการตัดสินใจ และเพื่อเป็นประโยชน์ในการประมาณค่าพารามิเตอร์ โดยที่การแจกแจงก่อนการทดลองของ $S(t)$ สำหรับกระบวนการดิริชเลต์สามารถคำนวณได้ดังนี้ คือ

$$E(S(t)) = \frac{\alpha(t)}{\alpha(R)}$$

ถ้าให้การแจกแจงก่อนการทดลองของ $S(t)$ คือ $S_0(t)$ และ $\alpha(R)$ เป็นขนาดตัวอย่างก่อนการทดลอง (prior sample size)⁵ แล้ว จะได้ว่า

$$\alpha(t) = S_0(t) \cdot \alpha(R) \quad (2.38)$$

⁵ Ferguson, Thomas S, "A Bayesian analysis of some nonparametric problem," The Annals of Statistics 1(1973) : 209-230.