

บทที่ 2 สถิติที่ใช้ในการวิจัย

การวิจัยครั้งนี้สิ่งที่สนใจศึกษาคือ การเปรียบเทียบการประมาณค่าพารามิเตอร์สำหรับการแจกแจงที่ถูกตัดปลายทางซ้ายเมื่อไม่ทราบจุดตัดปลาย ด้วยวิธีโมเมนต์ตัดแปลง วิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุด และวิธีกำลังสองต่ำสุดเทียม ในที่นี้จะศึกษาเปรียบเทียบค่ารากที่สองของค่าเฉลี่ยของความคลาดเคลื่อนกำลังสองของการประมาณค่าพารามิเตอร์ในแต่ละวิธี โดยจะกล่าวถึงในรายละเอียดในหัวข้อต่อไป

การประมาณค่าพารามิเตอร์

สำหรับการวิจัยครั้งนี้ทำการศึกษารูปแบบของข้อมูลที่ถูกตัดปลายเป็นดังนี้

$$W = X, \quad X > d$$

โดยที่ W, X เป็นตัวแปรสุ่ม และ d เป็นจุดตัดปลาย ซึ่งมีฟังก์ชันความหนาแน่นและฟังก์ชันการแจกแจงสะสมเป็นดังนี้

$$f_w(x) = \frac{f_x(x)}{1 - F_x(d)}, \quad X > d$$

และ

$$F_w(x) = \frac{F_x(x) - F_x(d)}{1 - F_x(d)}$$

1. วิธีโมเมนต์ตัดแปลง

วิธีโมเมนต์เป็นวิธีการประมาณค่าพารามิเตอร์ที่เก่าแก่ที่สุดเสนอโดย คาร์ล เพียร์สัน (Karl Pearson) เมื่อประมาณปี ค.ศ. 1894 หลักเกณฑ์ที่สำคัญที่มาใช้ได้แก่ การถือว่าโมเมนต์ของตัวอย่าง (Sample Moments) เป็นตัวประมาณของโมเมนต์ของประชากร (Population Moments) ที่สมนัยกัน และฟังก์ชันของโมเมนต์ของตัวอย่าง ก็ใช้เป็นตัวประมาณพารามิเตอร์ของประชากรที่เป็นฟังก์ชัน

สมนัยกันของโมเมนต์ของประชากร¹

การประมาณค่าตัดแปลง(Modified Estimations) ขั้นตอนในการประมาณค่าตัดแปลง มีดังนี้

1.1 ประมาณค่าเริ่มต้นของจุดตัดปลาย ด้วยค่าที่น้อยกว่าหรือเท่ากับค่า ข้อมูลที่มีค่าต่ำที่สุด หรือตัวสถิติอันดับที่ 1 $Y_1 = \min(X(1), \dots, X(N))$

$$d_1 \leq Y_1$$

1.2 ในการประมาณค่าพารามิเตอร์โดยการใช้ตัวประมาณค่าตัดแปลง(Modified Estimator) นั้นมี 2 ทางเลือกในการคำนวณค่าจุดตัดปลาย(truncated point) ในการประมาณค่าพารามิเตอร์ คือ

$$1.2.1 E(Y_1) = y_1 \text{ หรือ}$$

$$1.2.2 E(F(Y_1)) = F(y_1)$$

1.3 นำสมการดังกล่าวข้างต้นมาเปรียบเทียบกับสมการที่ได้จากวิธีโมเมนต์

กรณีที่มี 2 พารามิเตอร์รวมจุดตัดปลาย

$$E(X) = \bar{X} \tag{2.1}$$

$$E(Y_1) = y_1 \text{ หรือ } E(F(Y_1)) = F(y_1) \tag{2.2}$$

กรณีที่มี 3 พารามิเตอร์รวมจุดตัดปลาย

$$E(X) = \bar{X} \tag{2.3}$$

$$E(X^2) = \frac{1}{n} \sum_{i=1}^n X^2 \tag{2.4}$$

$$E(Y_1) = y_1 \text{ หรือ } E(F(Y_1)) = F(y_1) \tag{2.5}$$

ในการแก้สมการ ถ้าหากสมการยุ่งยากให้ใช้วิธีการเชิงตัวเลข (Numerical Method) เข้าช่วยในการแก้สมการเพื่อให้ได้ค่าประมาณพารามิเตอร์

2. วิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุด

วิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุด เป็นการประมาณค่าพารามิเตอร์ที่ไม่ใช่ค่าฟังก์ชันการเสี่ยงในการคัดเลือกตัวประมาณที่เหมาะสม แต่ใช้การวิเคราะห์จากสมการความเป็นจริง ผู้ที่ค้นพบวิธีนี้เป็นคนแรกคือ เกาส์ ซี เอฟ (C.F. Gauss 1821) ซึ่งเป็นนักคณิตศาสตร์ชาวเยอรมัน ต่อมานักสถิติชาวอังกฤษชื่อ อาร์ เอ ฟิชเชอร์ (R.A. Fisher 1922) ได้ปรับปรุงวิธีการและตรวจ

¹ ประชุม สุวดี, คร., ทฤษฎีอนุมานเชิงสถิติ.(กรุงเทพมหานคร:2527) หน้า 96-97.

สอบคุณสมบัติต่าง ๆ วิธีการนี้จะใช้ได้เมื่อตัวอย่างสุ่มมีการแจกแจงแบบมีพารามิเตอร์ (Parametric Distribution)²

3. วิธีกำลังสองต่ำสุดเทียม

การประมาณค่าพารามิเตอร์ด้วยวิธีกำลังสองต่ำสุดเทียมนี้มาจากบทความของ สัตยา ดี.คูเบย์ (Satya D. Dubey:1995)³ ซึ่งใช้หลักการเดียวกับวิธีกำลังสองต่ำสุดคือหาค่าประมาณของพารามิเตอร์ที่ทำให้ ผลบวกกำลังสองของผลต่างระหว่างค่าสังเกตกับค่าประมาณมีค่าต่ำสุดสำหรับวิธีกำลังสองต่ำสุดเทียมนี้ เป็นวิธีการหาตัวประมาณที่ทำให้ผลบวกกำลังสองของผลต่างระหว่างค่า $\ln([1-F_n(x_i)]^{-1})$ โดยที่ $F_n(x_i)$ ฟังก์ชันการแจกแจงของตัวอย่าง (Sample Distribution Function) กับค่า $\ln([1-F_w(x_i)]^{-1})$ โดยที่ $F_w(x_i)$ ฟังก์ชันการแจกแจงของข้อมูลที่มีการตัดปลายทางซ้าย

กำหนดให้สมการกำลังสองของวิธีการกำลังสองต่ำสุดเทียมคือ

$$LQ = \sum_{i=1}^n (y_i - \ln([1 - F_w(x_i)]^{-1}))^2$$

โดยที่

$$y_i = ([1 - F_n(x_i)]^{-1})$$

$$F_n(x_i) = \frac{k_i}{n}$$

k_i คือจำนวนข้อมูลที่มีค่าน้อยกว่าหรือเท่ากับ x_i

²ธีระพร วีระถาวร, คร., การอนุมานเชิงสถิติขั้นกลาง: โครงสร้างและความหมาย (พิทักษ์การพิมพ์ : 2531) หน้า 99.

³Satya D. Dubey. "Asymptotic Properties of Several Estimations of Weibull Parameters." *Technometrics* 7(3) : 1965 : 423-434.

การแจกแจงที่ใช้ในการวิจัย

1. การแจกแจงแบบลอกนอร์มอล

เมื่อ X มีการแจกแจงแบบลอกนอร์มอล (Lognormal Distribution) โดยมีฟังก์ชันความหนาแน่นเป็นดังนี้

$$f(x) = \begin{cases} \frac{1}{\alpha x \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{\ln(x) - \mu}{\sigma}\right)^2\right) & , x > 0 \\ 0 & , \text{อื่น ๆ} \end{cases} \quad (2.1)$$

โดยที่ μ เป็นพารามิเตอร์กำหนดขนาด (Scale Parameter) , $-\infty < \mu < \infty$ และ σ เป็นพารามิเตอร์กำหนดรูปร่าง (Shape Parameter) , $\sigma > 0$ และมีฟังก์ชันการแจกแจงสะสมเป็นดังนี้

$$F_x(x) = \int_0^x \frac{1}{x \sigma \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left[\frac{\ln(x) - \mu}{\sigma}\right]^2\right) \quad (2.2)$$

กำหนดให้

$$z(x) = \left(\frac{\ln(x) - \mu}{\sigma}\right)$$

$$\Psi(z(x)) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{z(x)^2}{2}\right)$$

$$\Phi(z(x)) = \int_0^{z(x)} \Psi(z(x)) dz(x)$$

จากสมการที่ 2.2 จะได้ว่าฟังก์ชันการแจกแจงสะสมเป็นดังนี้

$$F_x(x) = \Phi(z(x)) \quad (2.3)$$

กรณีข้อมูลที่มีการตัดปลายทางซ้าย (Left-Truncated Data) เมื่อไม่ทราบจุดตัดปลายเป็นดังนี้

$$W = X \quad , X > d \quad (2.4)$$

โดยที่ w และ x เป็นตัวแปรสุ่ม ซึ่งมีฟังก์ชันความหนาแน่นของข้อมูลเป็นดังนี้

$$f_w(x) = \frac{f_x(x)}{1 - F_x(d)} = \frac{1}{(1 - \Phi(z(d)))} \frac{1}{\alpha x \sqrt{2\pi}} \exp\left(-\frac{z(x)^2}{2}\right) \quad (2.5)$$

มี μ, σ และ d เป็นพารามิเตอร์ ที่ $\sigma > 0$, $-\infty < \mu < \infty$ และ $d > 0$ และมีฟังก์ชันการแจกแจงสะสม เป็นดังนี้

$$F_w(x) = \frac{F_x(x) - F_x(d)}{1 - F_x(d)} = \frac{\Phi(z(x)) - \Phi(z(d))}{1 - \Phi(z(d))} \quad (2.6)$$

1.1 วิธีโมเมนต์ตัดแปลง

สำหรับวิธีโมเมนต์ตัดแปลงเราสามารถหาค่าประมาณได้ดังนี้

m_i คือโมเมนต์ที่ i

$$m1 = \frac{1}{n} \sum_{i=1}^n x_i = E(X) \quad (2.7)$$

$$m2 = \frac{1}{n} \sum_{i=1}^n x_i^2 = E(X^2) \quad (2.8)$$

กำหนดให้

$$zd1 = \left(\frac{\ln(d) - (\mu + \sigma^2)}{\sigma} \right) \quad (2.9)$$

$$zd2 = \left(\frac{\ln(d) - (\mu + 2\sigma^2)}{\sigma} \right) \quad (2.10)$$

$$m1 = E(X) = \frac{1 - \Phi(zd1)}{1 - \Phi(z(d))} \exp\left(\mu + \frac{\sigma^2}{2}\right) \quad (2.11)$$

$$m2 = E(X^2) = \frac{1 - \Phi(zd2)}{1 - \Phi(z(d))} \exp(2\mu + 2\sigma^2) \quad (2.12)$$

จากสมการที่ 2.11 และ 2.12 ย้ายข้างเพื่อให้ได้สมการใหม่ที่มีค่าเท่ากับ 0 เป็น

ดังนี้

$$H(1) = m1(1 - \Phi(z(d))) - (1 - \Phi(zd1)) \exp\left(\mu + \frac{\sigma^2}{2}\right) \quad (2.13)$$

$$H(2) = m2(1 - \Phi(z(d))) - (1 - \Phi(zd2)) \exp(2\mu + 2\sigma^2) \quad (2.14)$$

ในการประมาณค่าพารามิเตอร์ $E(Y_1)=y_1$ หรือ $E(F(Y_1))=F(y_1)$ แต่ในที่นี้เราใช้

$E(F(Y_1))=F(y_1)$ โดยที่ $y_1 = \min(X(1), \dots, X(n))$

$$z(y_1) = \frac{(\ln(y_1) - \mu)}{\sigma} \quad (2.15)$$

$$z(d) = \frac{(\ln(d) - \mu)}{\sigma} \quad (2.16)$$

$$\frac{(\Phi(z(y_1)) - \Phi(z(d)))}{(1 - \Phi(z(d)))} = \frac{1}{n+1} \quad (2.17)$$

ทำการย้ายข้างสมการที่ 2.17 เพื่อให้ได้สมการที่เท่ากับ 0

$$H(3) = (n+1)(1 - \Phi(z(y_1))) - n(1 - \Phi(z(d))) \quad (2.18)$$

ทำการหาอนุพันธ์สมการที่ 2.13, 2.14 และ 2.18 เทียบกับ μ, σ และ d เพื่อใช้

ในวิธีนิวตัน-ราฟสัน (Newton-Raphson Method) ในการหาค่าประมาณพารามิเตอร์ μ, σ และ d

$$A(1) = \frac{\partial H(1)}{\partial \mu} = \frac{m1}{\sigma} \Psi(z(d)) - \exp\left(\mu + \frac{\sigma^2}{2}\right) \left(\frac{1}{\sigma} \Psi(zd1) + (1 - \Phi(zd1)) \right) \quad (2.19)$$

$$A(2) = \frac{\partial H(2)}{\partial \mu} = \frac{m2}{\sigma} \Psi(z(d)) - \exp(2\mu + 2\sigma^2) \left(\frac{1}{\sigma} \Psi(zd1) + 2(1 - \Phi(zd1)) \right) \quad (2.20)$$

$$A(3) = \frac{\partial H(3)}{\partial \mu} = \frac{(n+1)}{\sigma} \Psi(z(y_1)) - \frac{n}{\sigma} \Psi(z(d)) \quad (2.21)$$

$$B(1) = \frac{\partial H(1)}{\partial \sigma} = \frac{m1}{\sigma} z(d) \Psi(z(d)) - \exp\left(\mu + \frac{\sigma^2}{2}\right) \left(\frac{1}{\sigma} \left(\frac{zd1}{\sigma} + 2 \right) \Psi(zd1) + \sigma(1 - \Phi(zd1)) \right) \quad (2.22)$$

$$B(2) = \frac{\partial H(2)}{\partial \sigma} = \frac{m2}{\sigma} z(d) \Psi(z(d)) - \exp(2\mu + 2\sigma^2) \left(\frac{1}{\sigma} \left(\frac{zd2}{\sigma} + 4 \right) \Psi(zd1) + 4\sigma(1 - \Phi(zd1)) \right) \quad (2.23)$$

$$B(3) = \frac{\partial H(3)}{\partial \sigma} = \frac{(n+1)}{\sigma} z(y_1) \Psi(z(y_1)) - \frac{n}{\sigma} z(d) \Psi(z(d)) \quad (2.24)$$

$$C(1) = \frac{\partial H(1)}{\partial d} = \frac{1}{\sigma d} \left(\Psi(zd1) \exp\left(\mu + \frac{\sigma^2}{2}\right) - m1 \Psi(z(d)) \right) \quad (2.25)$$

$$C(2) = \frac{\partial H(2)}{\partial d} = \frac{1}{\sigma d} \left(\Psi(zd2) \exp(2\mu + 2\sigma^2) - m2 \Psi(z(d)) \right) \quad (2.26)$$

$$C(3) = \frac{\partial H(3)}{\partial d} = \frac{n}{\sigma d} \Psi(z(d)) \quad (2.27)$$

หาค่าประมาณพารามิเตอร์ μ, σ และ d โดยใช้วิธีการของนิวตัน-ราฟสัน

(Newton - Raphson Method) สามารถหาค่าประมาณพารามิเตอร์ได้ดังนี้

$$\begin{pmatrix} \mu_{k+1} \\ \sigma_{k+1} \\ d_{k+1} \end{pmatrix} = \begin{pmatrix} \mu_k \\ \sigma_k \\ d_k \end{pmatrix} - \begin{pmatrix} \frac{\partial H(1)}{\partial \mu_k} & \frac{\partial H(1)}{\partial \sigma_k} & \frac{\partial H(1)}{\partial d_k} \\ \frac{\partial H(2)}{\partial \mu_k} & \frac{\partial H(2)}{\partial \sigma_k} & \frac{\partial H(2)}{\partial d_k} \\ \frac{\partial H(3)}{\partial \mu_k} & \frac{\partial H(3)}{\partial \sigma_k} & \frac{\partial H(3)}{\partial d_k} \end{pmatrix}^{-1} \begin{pmatrix} H_k(1) \\ H_k(2) \\ H_k(3) \end{pmatrix} \quad (2.28)$$

จากสมการข้างต้นเราสามารถหาค่าประมาณโดยการกำหนด μ_0, σ_0 และ d_0 เป็นค่าเริ่มต้น แล้วใช้กระบวนการซ้ำ (Iteration Method) จนกระทั่งได้ค่าพารามิเตอร์ μ, σ และ d

1.2 วิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุด

ฟังก์ชันภาวะน่าจะเป็นสูงสุด (Likelihood Function) สำหรับการแจกแจงแบบลอกนอร์มอลเป็นดังนี้

$$L = \prod_{i=1}^n f_w(x_i) \quad (2.29)$$

$$L = \left(\sigma \sqrt{2\pi} (1 - \Phi(z(d))) \right)^{-n} \left(\prod_{i=1}^n \frac{1}{x_i} \right) \exp\left(-\frac{1}{2} \sum_{i=1}^n z(x_i)^2 \right) \quad (2.30)$$

$$\ln(L) = -n \left(\ln(1 - \Phi(z(d))) + \frac{1}{2} \ln(2\pi) + \ln(\sigma) \right) - \frac{1}{2} \sum_{i=1}^n z(x_i)^2 - \sum_{i=1}^n \ln(x_i) \quad (2.31)$$

ทำการหาอนุพันธ์บางส่วน สมการที่ 2.31 ($\ln(L)$) เทียบกับ μ และ σ เป็นดังนี้

$$H(1) = \frac{\partial \ln(L)}{\partial \mu} = \sum_{i=1}^n z(x_i) - \frac{n\Psi(z(d))}{1 - \Phi(z(d))} = 0 \quad (2.32)$$

$$H(2) = \frac{\partial \ln(L)}{\partial \sigma} = \sum_{i=1}^n z(x_i)^2 - n - \frac{nz(d)\Psi(z(d))}{1 - \Phi(z(d))} = 0 \quad (2.33)$$

จากสมการที่ 2.32 และสมการที่ 2.33 สามารถหาค่าประมาณ σ เป็นดังนี้

$$\hat{\sigma} = \sqrt{\frac{\sum_{i=1}^n (\ln(x_i) - \mu)^2 - (\ln(d) - \mu) \sum_{i=1}^n (\ln(x_i) - \mu)}{n}} \quad (2.34)$$

แทนค่าลงในสมการที่ 2.32 เพื่อหาค่า μ ดังนี้

$$z(\hat{d}) = \frac{\ln(\hat{d}) - \mu}{\hat{\sigma}} \quad (2.35)$$

$$g(\mu) = \sum_{i=1}^n \left(\frac{\ln(x_i) - \mu}{\hat{\sigma}} \right) - \frac{n\Psi(z(\hat{d}))}{1 - \Phi(z(\hat{d}))} \quad (2.36)$$

โดยที่ในวิธีการประมาณด้วยภาวน่าจะเป็นสูงสุดให้

$\hat{d} = y_1 = \min(X(1), \dots, X(n))$ เนื่องจากค่าข้อมูลต่ำสุดจะมีค่าใกล้เคียงจุดตัดปลายที่สุด หาอนุพันธ์ของสมการเพื่อใช้ ในวิธีนิวตัน-ราฟสัน (Newton-Raphson Method) ในการหาค่าประมาณพารามิเตอร์

กำหนดให้

$$\hat{\sigma} = \frac{\partial \hat{\sigma}}{\partial \mu} = \frac{n(\ln(\hat{d}) - \mu) - \sum_{i=1}^n (\ln(x_i) - \mu)}{2\hat{\sigma}} \quad (2.37)$$

$$z'(\hat{d}) = \frac{\partial z(\hat{d})}{\partial \mu} = \frac{(1 - z(\hat{d}))\hat{\sigma}}{\hat{\sigma}} \quad (2.38)$$

$$\Psi'(z(\hat{d})) = \Psi(z(\hat{d}))z'(\hat{d}) \quad (2.39)$$

$$\Phi'(z(\hat{d})) = -\Psi(z(\hat{d}))z'(\hat{d}) \quad (2.40)$$

แทนค่าสมการที่ 2.37 - 2.40 เพื่อให้ได้สมการอนุพันธ์สมการที่ 2.36

$$g'(\mu) = \frac{n}{\hat{\sigma}} + \hat{\sigma} \sum_{i=1}^n \frac{(\ln(x_i) - \mu)}{\hat{\sigma}^2} - n \frac{\left((1 - \Phi(z(\hat{d})))\Psi'(z(\hat{d})) - \Psi(z(\hat{d}))\Phi'(z(\hat{d}))) \right)}{\left(1 - \Phi(z(\hat{d})) \right)^2} \quad (2.41)$$

เราสามารถหาค่าประมาณพารามิเตอร์ μ ได้จากวิธีการของนิวตัน-ราฟสัน ดังสมการต่อไปนี้

$$\mu_{k+1} = \mu_k - \frac{g(\mu_k)}{g'(\mu_k)}$$

จากสมการข้างต้นเราสามารถหาค่าประมาณโดยการกำหนด μ_0 เป็นค่าเริ่มต้น แล้วใช้กระบวนการซ้ำ (Iteration Method) จนกระทั่งได้ค่าพารามิเตอร์ μ แทนค่าประมาณ พารามิเตอร์ μ ลงในสมการที่ 2.34 จะได้ค่าประมาณพารามิเตอร์ σ

1.3 วิธีกำลังสองต่ำสุดเทียม

กำหนดให้สมการกำลังสองของวิธีการกำลังสองต่ำสุดเทียมคือ

$$LQ = \sum_{i=1}^n \left(y_i - \ln \left(\frac{1}{1 - F_w(x_i)} \right) \right)^2 \quad (2.42)$$

โดยที่

$$y_i = \ln \left(\frac{1}{1 - F_n(x_i)} \right) \quad (2.43)$$

$$F_n(x_i) = \frac{k_i}{n} \quad (2.44)$$

เมื่อ k_i คือจำนวนข้อมูลที่มีค่าน้อยกว่าหรือเท่ากับ x_i ,

$$F(x) = \frac{F_x(x) - F_x(d)}{1 - F_x(d)} = \frac{\Phi(z(x)) - \Phi(z(d))}{1 - \Phi(z(d))} \quad (2.45)$$

$$\ln \left(\frac{1}{1 - F_w(x)} \right) = \ln(1 - \Phi(z(d))) - \ln(1 - \Phi(z(x))) \quad (2.46)$$

แทนค่า สมการที่ 2.46 ลงในสมการที่ 2.42 จะได้

$$LQ = \sum_{i=1}^n \left(y_i + \ln(1 - \Phi(z(x))) - \ln(1 - \Phi(z(d))) \right)^2 \quad (2.47)$$

ทำการหาอนุพันธ์ LQ เทียบกับ μ และ σ

กำหนดให้

$$Y_i = \ln(1 - \Phi(z(\hat{d}))) - \ln(1 - \Phi(z(x_i))) \quad (2.48)$$

$$\frac{\partial Y_i}{\partial \mu} = \frac{1}{\sigma} \left(\frac{\Psi(z(\hat{d}))}{(1 - \Phi(z(\hat{d})))} - \frac{\Psi(z(x_i))}{(1 - \Phi(z(x_i)))} \right) \quad (2.49)$$

$$\frac{\partial Y_i}{\partial \sigma} = \frac{1}{\sigma} \left(\frac{z(\hat{d})\Psi(z(\hat{d}))}{(1 - \Phi(z(\hat{d})))} - \frac{z(x_i)\Psi(z(x_i))}{(1 - \Phi(z(x_i)))} \right) \quad (2.50)$$

โดยที่ ค่าประมาณพารามิเตอร์ $\hat{d} = y_1 = \min(X(1), \dots, X(n))$

เนื่องจากค่าข้อมูลต่ำสุดเป็นตัวประมาณที่มีค่าใกล้เคียงจุดตัดปลายทางซ้ายมากที่สุด จะได้ว่าอนุพันธ์ LQ เทียบกับ μ และ σ เป็นดังนี้

$$H(1) = \frac{dQ}{d\mu} = \sum_{i=1}^n y_i \left(\frac{\partial Y_i}{\partial \mu} \right) - \sum_{i=1}^n Y_i \left(\frac{\partial Y_i}{\partial \mu} \right) \quad (2.51)$$

$$H(2) = \frac{dQ}{d\sigma} = \sum_{i=1}^n y_i \left(\frac{\partial Y_i}{\partial \sigma} \right) - \sum_{i=1}^n Y_i \left(\frac{\partial Y_i}{\partial \sigma} \right) \quad (2.52)$$

กำหนดให้

$$\frac{\partial \Psi(z(x))}{\partial \mu} = \frac{1}{\sigma} z(x) \Psi(z(x)) \quad (2.53)$$

$$\frac{\partial \Psi(z(\hat{d}))}{\partial \mu} = \frac{1}{\sigma} z(\hat{d}) \Psi(z(\hat{d})) \quad (2.54)$$

$$\frac{\partial \Psi(z(x))}{\partial \sigma} = \frac{1}{\sigma} z(x)^2 \Psi(z(x)) \quad (2.55)$$

$$\frac{\partial \Psi(z(\hat{d}))}{\partial \sigma} = \frac{1}{\sigma} z(\hat{d})^2 \Psi(z(\hat{d})) \quad (2.56)$$

$$\frac{\partial Y_i}{\partial \mu^2} = \frac{1}{\sigma(1-\Phi(z(\hat{d})))^2} \left\{ (1-\Phi(z(\hat{d}))) \left(\frac{\partial \Psi(z(\hat{d}))}{\partial \mu} \right) - \frac{\Psi(z(\hat{d}))^2}{\sigma} \right\} \quad (2.57)$$

$$- \frac{1}{\sigma(1-\Phi(z(x_i)))^2} \left\{ (1-\Phi(z(x_i))) \left(\frac{\partial \Psi(z(x_i))}{\partial \mu} \right) - \frac{\Psi(z(x_i))^2}{\sigma} \right\}$$

$$\frac{\partial Y_i}{\partial \mu \partial \sigma} = \frac{1}{(1-\Phi(z(\hat{d})))^2} \left\{ \sigma(1-\Phi(z(\hat{d}))) \left(\frac{\partial \Psi(z(\hat{d}))}{\partial \sigma} \right) - \Psi(z(\hat{d})) (z(\hat{d}) \Psi(z(\hat{d})) + (1-\Phi(z(\hat{d})))) \right\} \quad (2.58)$$

$$- \frac{1}{(1-\Phi(z(x_i)))^2} \left\{ \sigma(1-\Phi(z(x_i))) \left(\frac{\partial \Psi(z(x_i))}{\partial \sigma} \right) - \Psi(z(x_i)) (z(x_i) \Psi(z(x_i)) + (1-\Phi(z(x_i)))) \right\}$$

$$\frac{\partial Y_i}{\partial \sigma \partial \mu} = \frac{1}{\sigma(1-\Phi(z(\hat{d})))^2} \left\{ (1-\Phi(z(\hat{d}))) \left(z(\hat{d}) \left(\frac{\partial \Psi(z(\hat{d}))}{\partial \mu} \right) - \frac{\Psi(z(\hat{d}))}{\sigma} \right) - \frac{z(\hat{d}) \Psi(z(\hat{d}))^2}{\sigma} \right\} \quad (2.59)$$

$$- \frac{1}{\sigma(1-\Phi(z(x_i)))^2} \left\{ (1-\Phi(z(x_i))) \left(z(x_i) \left(\frac{\partial \Psi(z(x_i))}{\partial \mu} \right) - \frac{\Psi(z(x_i))}{\sigma} \right) - \frac{z(x_i) \Psi(z(x_i))^2}{\sigma} \right\}$$

$$\frac{\partial Y}{\partial \sigma} = \left\{ \alpha(1 - \Phi(z(\hat{d}))) \left(\left(\frac{\partial \Phi(z(\hat{d}))}{\partial \sigma} \right) - \frac{1}{\sigma} \Psi(z(\hat{d})) \right) - \Psi(z(\hat{d})) (z(\hat{d}) \Psi(z(\hat{d})) + (1 - \Phi(z(\hat{d})))) \right\}$$

$$* \left\{ \frac{z(\hat{d})}{(1 - \Phi(z(\hat{d})))^2} \right\} \left\{ \alpha(1 - \Phi(z(x))) \left(\left(\frac{\partial \Phi(z(x))}{\partial \sigma} \right) - \frac{1}{\sigma} \Psi(z(x)) \right) - \Psi(z(x)) (z(x) \Psi(z(x)) + (1 - \Phi(z(x)))) \right\} \quad (2.60)$$

$$* \left\{ \frac{z(x)}{(1 - \Phi(z(x)))^2} \right\}$$

ทำการอนุพันธ์สมการที่ 2.51 และ 2.52 เทียบกับ μ และ σ โดยแทนค่าสมการที่ 2.53 ถึง สมการที่ 2.60 ที่กำหนดให้ ซึ่งจะได้ดังนี้

$$A(1) = \sum_{i=1}^n y_i \left(\frac{\partial Y_i}{\partial \mu^2} \right) - \sum_{i=1}^n Y_i \left(\frac{\partial Y_i}{\partial \mu^2} \right) - \sum_{i=1}^n \left(\frac{\partial X_i}{\partial \mu} \right)^2 \quad (2.61)$$

$$A(2) = \sum_{i=1}^n y_i \left(\frac{\partial Y_i}{\partial \sigma \partial \mu} \right) - \sum_{i=1}^n Y_i \left(\frac{\partial Y_i}{\partial \sigma \partial \mu} \right) - \sum_{i=1}^n \left(\frac{\partial X_i}{\partial \mu} \right) \left(\frac{\partial X_i}{\partial \sigma} \right) \quad (2.62)$$

$$B(1) = \sum_{i=1}^n y_i \left(\frac{\partial Y_i}{\partial \mu \partial \sigma} \right) - \sum_{i=1}^n Y_i \left(\frac{\partial Y_i}{\partial \mu \partial \sigma} \right) - \sum_{i=1}^n \left(\frac{\partial X_i}{\partial \sigma} \right) \left(\frac{\partial X_i}{\partial \mu} \right) \quad (2.63)$$

$$B(2) = \sum_{i=1}^n y_i \left(\frac{\partial Y_i}{\partial \sigma^2} \right) - \sum_{i=1}^n Y_i \left(\frac{\partial Y_i}{\partial \sigma^2} \right) - \sum_{i=1}^n \left(\frac{\partial X_i}{\partial \sigma} \right)^2 \quad (2.64)$$

หาค่าประมาณพารามิเตอร์ μ และ σ โดยใช้วิธีการของนิวตัน-ราฟสัน (Newton-Raphson Method) สามารถหาค่าประมาณพารามิเตอร์ได้ดังนี้

$$\begin{pmatrix} \mu_{k+1} \\ \sigma_{k+1} \end{pmatrix} = \begin{pmatrix} \mu_k \\ \sigma_k \end{pmatrix} - \begin{pmatrix} \frac{\partial H(1)}{\partial \mu_k} & \frac{\partial H(1)}{\partial \sigma_k} \\ \frac{\partial H(2)}{\partial \mu_k} & \frac{\partial H(2)}{\partial \sigma_k} \end{pmatrix}^{-1} \begin{pmatrix} H_k(1) \\ H_k(2) \end{pmatrix} \quad (2.65)$$

จากสมการข้างต้นเราสามารถหาค่าประมาณโดยการกำหนด μ_0 และ σ_0 เป็นค่าเริ่มต้น แล้วใช้กระบวนการซ้ำ (Iteration Method) จนกระทั่งได้ค่าพารามิเตอร์ μ และ σ

2. การแจกแจงแบบเอกซโพเนนเชียล

เมื่อ X มีการแจกแจงเอกซโพเนนเชียล (Exponential Distribution) ฟังก์ชันความหนาแน่นเป็นดังนี้

$$f_x(x) = \begin{cases} \frac{1}{\theta} \exp\left(-\frac{1}{\theta}x\right) & , x > d \\ 0 & , \text{อื่น ๆ} \end{cases} \quad (2.66)$$

เมื่อ θ เป็นพารามิเตอร์กำหนดขนาด (Scale Parameter) ที่มีค่ามากกว่า 0, d เป็นจุดตัดปลาย และมีฟังก์ชันการแจกแจงสะสมเป็นดังนี้

$$F_x(x) = 1 - \exp\left(-\frac{1}{\theta}x\right) \quad (2.67)$$

กรณีข้อมูลที่มีการตัดปลายทางซ้าย (Left-Truncated Data) เมื่อไม่ทราบจุดตัดปลายเป็นดังนี้

$$W > X \quad , X > d \quad (2.68)$$

โดยที่ W และ X เป็นตัวแปรสุ่ม d หมายถึงพารามิเตอร์ที่เกิดจากการตัดปลาย (Truncated Parameter) ความหนาแน่นของการแจกแจงที่ถูกตัดปลายทางซ้ายเป็นดังนี้

$$f_w(x) = \frac{1}{\theta} \exp\left(-\frac{1}{\theta}(x-d)\right) \quad , \theta > 0 \quad (2.69)$$

ฟังก์ชันการแจกแจงสะสม ของการแจกแจงที่ถูกตัดปลายทางซ้ายเป็นดังนี้

$$F_w(x) = 1 - \exp\left(-\frac{1}{\theta}(x-d)\right) \quad (2.70)$$

2.1 วิธีโมเมนต์ตัดแปลง¹

สำหรับวิธีโมเมนต์ตัดแปลงเราสามารถหาค่าประมาณได้ดังนี้

กำหนดให้ m_i คือโมเมนต์ที่ i

$$E(X) = \frac{1}{n} \sum_{i=1}^n x_i = \bar{X} = d + \theta \quad (2.71)$$

ในการประมาณค่าพารามิเตอร์ $E(Y_1)=y_1$ หรือ $E(F(Y_1))=F(y_1)$ แต่ในที่นี้เราใช้ $E(Y_1)=y_1$ ให้ $y_1 = \min(X(1), \dots, X(n))$ ซึ่งสามารถความหนาแน่นได้ดังนี้

$$g(y_1) = nf(y_1)[1 - F(y_1)]^{n-1} = n \frac{1}{\theta} \exp\left(-\frac{n}{\theta}(y_1 - d)\right) \quad (2.72)$$

เราสามารถหาค่าคาดหวังของ y_1 ได้ดังนี้

¹Dusit Charemkavanich, "Estimation in Truncated Distribution when Points of Truncation are unknown" (Ph.D. dissertation, University of Georgia, 1978), p. 9-14.

$$E(Y_1) = \int_d^{\infty} n \frac{1}{\theta} \exp\left(-\frac{n}{\theta}(y_1 - d)\right) dy_1 = d + \frac{\theta}{n} = y_1 \quad (2.73)$$

ทำการย้ายข้างสมการที่ 2.73 เพื่อให้ได้ค่าประมาณพารามิเตอร์เป็นดังนี้

$$\hat{d} = \frac{(ny_1 - \bar{X})}{n-1} \quad (2.74)$$

แทนค่า สมการที่ 2.74 ลงในสมการที่ 2.71 ได้ค่าประมาณพารามิเตอร์ θ

$$\hat{\theta} = \frac{n(\bar{X} - y_1)}{n-1} \quad (2.75)$$

2.2 วิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุด²

ฟังก์ชันภาวะน่าจะเป็น (Likelihood Function) สำหรับการแจกแจงแบบเอกซ์โพเนนเชียล เป็นดังนี้

$$L = \prod_{i=1}^n f_w(x_i) = \left(\frac{1}{\theta}\right)^n \exp\left(-\frac{1}{\theta} \sum_{i=1}^n (x_i - d)\right) \quad (2.76)$$

$$\ln(L) = -n \ln(\theta) - \frac{1}{\theta} \sum_{i=1}^n (x_i - d) \quad (2.77)$$

ทำการอนุพันธ์ $\ln(L)$ เทียบกับ θ

$$\frac{\partial \ln(L)}{\partial \theta} = -\frac{n}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n (x_i - d) \quad (2.78)$$

จากสมการที่ 2.78 ให้ $\frac{\partial \ln(L)}{\partial \theta} = 0$ เราสามารถหาค่าพารามิเตอร์ θ ได้ดังนี้

$$\hat{\theta} = \bar{X} - \hat{d} = \bar{X} - y_1 \quad (2.79)$$

สำหรับวิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุดนั้นสามารถประมาณค่าพารามิเตอร์ d ด้วย $y_1 = \min(X(1), \dots, X(n))$ เนื่องจากค่าข้อมูลต่ำสุดจะมีค่าใกล้เคียงจุดตัดปลายมากที่สุด

2.3 วิธีกำลังสองต่ำสุดเทียม

กำหนดให้สมการกำลังสองของวิธีการกำลังสองต่ำสุดเทียมคือ

$$LQ = \sum_{i=1}^n (y_i - \ln([1 - F_w(x_i)]^{-1}))^2 \quad (2.80)$$

โดยที่

²Dusit Charemkavanich, "Estimation in Truncated Distribution when Points of Truncation are unknown" (Ph.D. dissertation, University of Georgia, 1978), pp. 11.

$$y_i = [1 - F_n(x_i)]^{-1} \quad (2.81)$$

$$F_n(x_i) = \frac{k_i}{n+1} \quad (2.82)$$

k_i คือจำนวนข้อมูลที่มีค่าน้อยกว่าหรือเท่ากับ x_i

สำหรับวิธีกำลังสองต่ำสุดเทียบนี้เป็นวิธีการหาตัวประมาณที่ทำให้ผลบวก

กำลังสองของผลต่างระหว่างค่า $\ln([1-F_n(x_i)]^{-1})$ โดยที่ $F_n(x_i)$ ฟังก์ชันการแจกแจงของตัวอย่าง

(Sample Distribution Function) กับค่า $\ln([1-F_w(x_i)]^{-1})$ โดยที่ $F_w(x_i)$ ฟังก์ชันการแจกแจงของ

ข้อมูลที่มีการตัดปลายทางซ้าย โดยใช้ อนุพันธ์ช่วย

$$F_w(x_i) = 1 - \exp\left(-\frac{1}{\theta}(x_i - d)\right) \quad (2.83)$$

$$\ln([1 - F_w(x_i)]^{-1}) = \frac{1}{\theta}(x_i - d) \quad (2.84)$$

แทนค่าสมการที่ 2.83-2.84 ลงในสมการที่ 2.82 จะได้

$$LQ = \sum_{i=1}^n \left(y_i - \frac{1}{\theta}(x_i - d) \right)^2 \quad (2.85)$$

ทำการอนุพันธ์ LQ เทียบกับ θ

$$\frac{dLQ}{d\theta} = -2 \sum_{i=1}^n (x_i - d) \left(y_i - \frac{1}{\theta}(x_i - d) \right) \quad (2.86)$$

ให้ สมการที่ 2.86 เท่ากับ 0 เราสามารถหาค่าพารามิเตอร์ θ ได้ดังนี้

$$\hat{\theta} = \frac{\sum_{i=1}^n (x_i - \hat{d})^2}{\sum_{i=1}^n y_i (x_i - \hat{d})} = \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n y_i (x_i - y_i)} \quad (2.87)$$

สำหรับวิธีกำลังสองต่ำสุดเทียบนั้นสามารถประมาณค่าพารามิเตอร์ d ด้วย

$y_1 = \min(X(1), \dots, X(n))$ เนื่องจากข้อมูลต่ำสุดเป็นค่าที่ใกล้เคียงกับจุดตัดปลายที่สุด

3. การแจกแจงแบบพारेโต้

เมื่อ X มีการแจกแจงแบบพारेโต้ (Pareto Distribution) ฟังก์ชันความหนาแน่นเป็น
ดังนี้

$$f_x(x) = \begin{cases} \frac{\alpha \lambda^\alpha}{(\lambda + x)^{(\alpha+1)}} & , x > 0 \\ 0 & , \text{อื่น ๆ} \end{cases} \quad (2.88)$$

เมื่อ α เป็นพารามิเตอร์กำหนดรูปร่าง (Shape Parameter) , $\alpha > 0$ และ λ เป็นพารามิเตอร์กำหนดขนาด (Scale Parameter) , $\lambda > 0$ และมีฟังก์ชันการแจกแจงสะสมเป็นดังนี้

$$F(x) = 1 - \left(\frac{\lambda}{\lambda + x} \right)^\alpha \quad (2.89)$$

กรณีข้อมูลที่มีการตัดปลายทางซ้าย (Left-Truncated Data) เมื่อไม่ทราบจุดตัดปลาย
เป็นดังนี้

$$w > x \quad , x > d \quad (2.90)$$

โดยที่ w และ x เป็นตัวแปรสุ่มที่มีค่ามากกว่า 0 และ d หมายถึงพารามิเตอร์ที่เกิดจากการตัดปลาย (Truncated Parameter) ความหนาแน่นของการแจกแจงที่ถูกตัดปลายทางซ้ายเป็น
ดังนี้

$$f_w(x) = \frac{f_x(x)}{1 - F_x(d)} = \frac{\alpha(\lambda + d)^\alpha}{(\lambda + x)^{(\alpha+1)}} \quad \alpha, \lambda, d > 0 \quad (2.91)$$

ฟังก์ชันการแจกแจงสะสม ของการแจกแจงที่ถูกตัดปลายทางซ้ายเป็นดังนี้

$$F_w(x) = \frac{F_x(x) - F_x(d)}{1 - F_x(d)} = 1 - \left(\frac{\lambda + d}{\lambda + x} \right)^\alpha \quad (2.92)$$

3.1 วิธีโมเมนต์คัดแปลง

สำหรับวิธีโมเมนต์คัดแปลงเราสามารถหาค่าประมาณได้ดังนี้

กำหนดให้ m_i คือโมเมนต์ที่ i

$$m_1 = \frac{1}{n} \sum_{i=1}^n x_i = E(X) \quad (2.93)$$

$$m_2 = \frac{1}{n} \sum_{i=1}^n x_i^2 = E(X^2) \quad (2.94)$$

$$E(X) = \int_d^\infty \alpha x \frac{(\lambda + d)^\alpha}{(\lambda + x)^{\alpha+1}} dx = d + \left(\frac{\lambda + d}{\alpha - 1} \right) = m_1 \quad (2.95)$$

$$E(X^2) = \int_d^\infty \alpha x^2 \frac{(\lambda + d)^\alpha}{(\lambda + x)^{\alpha+1}} dx = d^2 + 2d \left(\frac{\lambda + d}{\alpha - 1} \right) + \frac{(\lambda + d)^2}{(\alpha - 1)(\alpha - 2)} = m_2 \quad (2.96)$$

เป็นการย้ายข้างสมการที่ 2.95 และ 2.96 เพื่อให้ได้สมการใหม่ที่มีค่าเท่ากับ 0
เป็นดังนี้

$$H(1) = (\lambda + d) - (m1 - d)(\alpha - 1) \quad (2.97)$$

$$H(2) = 2d(\lambda + d)(\alpha - 1) + (\lambda + d)^2 - (m2 - d^2)(\alpha - 1)(\alpha - 2) \quad (2.98)$$

ในการประมาณค่าพารามิเตอร์ $E(Y_1)=y_1$ หรือ $E(F(Y_1))=F(y_1)$ แต่ในที่นี้เราใช้ $E(Y_1)=y_1$ ให้ $y_1 = \min(X(1), \dots, X(n))$ ซึ่งสามารถความหนาแน่นได้ดังนี้

$$g(y_1) = nf'(y_1)[1 - F(y_1)]^{n-1} = \frac{n\alpha(\lambda + d)^{n\alpha}}{(\lambda + y_1)^{n\alpha+1}} \quad (2.99)$$

เราสามารถหาค่าคาดหวังของ y_1 ได้ดังนี้

$$E(Y_1) = \int_d^{\infty} n\alpha y_1 \frac{(\lambda + d)^{n\alpha}}{(\lambda + y_1)^{n\alpha+1}} dy_1 = d + \left(\frac{\lambda + d}{n\alpha - 1} \right) = y_1 \quad (2.100)$$

ทำการย้ายข้างเพื่อให้ได้สมการที่เท่ากับ 0

$$H(3) = (n\alpha - 1)(y_1 - d) + (d + \lambda) \quad (2.101)$$

จาก H(1) และ H(3) ทำการย้ายข้างเพื่อให้ได้ค่าประมาณพารามิเตอร์ λ และ d
ในรูปของ α ได้ค่าประมาณพารามิเตอร์ดังนี้

$$\hat{d} = \frac{(n\alpha - 1)y_1 + (\alpha - 1)m1}{\alpha(n + 1)} \quad (2.102)$$

$$\hat{\lambda} = \frac{(n\alpha - 1)y_1 + (\alpha - 1)m1}{\alpha(n + 1)} n\alpha - (n\alpha - 1)y_1 = \hat{d}n\alpha - (n\alpha - 1)y_1 \quad (2.103)$$

แทนค่าประมาณพารามิเตอร์ λ และ d ลงใน H(3) เพื่อให้ได้สมการในรูป
ของ α ได้สมการใหม่เป็นดังนี้

$$g(\alpha) = 2\hat{d}(\alpha - 2)(\hat{\lambda} + \hat{d}) + (\hat{\lambda} + \hat{d})^2 + (\alpha - 1)(\alpha - 2)(\hat{d}^2 - m2) \quad (2.104)$$

ทำการอนุพันธ์เทียบกับ α เพื่อใช้ในวิธีการนิวตัน-ราฟสันเป็นดังนี้

$$\hat{d}' = \frac{\partial \hat{d}}{\partial \alpha} = \frac{(y_1 - m1)}{(n + 1)\alpha^2} \quad (2.105)$$

$$\hat{\lambda}' = \frac{\partial \hat{\lambda}}{\partial \alpha} = n(\hat{d} + \alpha \hat{d}') - ny_1 \quad (2.106)$$

$$g'(\alpha) = \frac{\partial g(\alpha)}{\partial \alpha} = 2\left(\hat{d}(\hat{\lambda} + \hat{d}) + (\alpha - 2)\left((\hat{\lambda} + \hat{d})\hat{d}' + \hat{d}(\hat{d}' + \hat{\lambda}')\right)\right) + 2(\hat{\lambda} + \hat{d})(\hat{d}' + \hat{\lambda}') + (\hat{d}^2 - m2)(2\alpha - 3) + 2(\alpha - 1)(\alpha - 2)\hat{d}^2 \quad (2.107)$$

เราสามารถหาค่าประมาณพารามิเตอร์ α ได้จากวิธีการของนิวตัน-ราฟสัน
ดังสมการต่อไปนี้

$$\alpha_{k+1} = \alpha_k - \frac{g(\alpha_k)}{g'(\alpha_k)}$$

จากสมการข้างต้นเราสามารถหาค่าประมาณโดยการกำหนด α_0 เป็นค่าเริ่มต้น แล้วใช้กระบวนการซ้ำ (Iteration Method) จนกระทั่งได้ค่าพารามิเตอร์ α นำค่าประมาณพารามิเตอร์ แทนค่าลงในสมการที่ 2.102 และ 2.103 ซึ่งจะได้ค่าประมาณพารามิเตอร์ λ และ d

3.2 วิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุด

ฟังก์ชันภาวะน่าจะเป็น (Likelihood Function) สำหรับการแจกแจงแบบพาราได้เป็นดังนี้

$$L = \prod_{i=1}^n f_w(x_i) = (\alpha(\lambda + d)^\alpha)^n \prod_{i=1}^n \frac{1}{(\lambda + x_i)^{\alpha+1}} \quad (2.108)$$

$$\ln(L) = n \ln(\alpha) + n\alpha \ln(\lambda + d) - (\alpha + 1) \sum_{i=1}^n \ln(\lambda + x_i) \quad (2.109)$$

ทำการอนุพันธ์ $\ln(L)$ เทียบกับ λ และ α

$$H(1) = \frac{\partial \ln(L)}{\partial \alpha} = \frac{n}{\alpha} + n \ln(\lambda + d) - \sum_{i=1}^n \ln(\lambda + x_i) \quad (2.110)$$

$$H(2) = \frac{\partial \ln(L)}{\partial \lambda} = \frac{n\alpha}{(\lambda + d)} - (\alpha + 1) \sum_{i=1}^n \frac{1}{(\lambda + x_i)} \quad (2.111)$$

ทำการอนุพันธ์สมการที่ H(1) และ H(2) เทียบกับ λ และ α เพื่อใช้ในวิธีนิวตัน-ราฟสัน (Newton-Raphson Method) เพื่อใช้ในการหาค่าประมาณพารามิเตอร์ λ และ α

$$A(1) = \frac{\partial H(1)}{\partial \alpha} = \frac{-n}{\alpha^2} \quad (2.112)$$

$$A(2) = \frac{\partial H(2)}{\partial \alpha} = \frac{n}{(\lambda + d)} - \sum_{i=1}^n \frac{1}{(\lambda + x_i)} \quad (2.113)$$

$$B(1) = \frac{\partial H(1)}{\partial \lambda} = \frac{n}{(\lambda + d)} - \sum_{i=1}^n \frac{1}{(\lambda + x_i)} = A(2) \quad (2.114)$$

$$B(2) = \frac{\partial H(2)}{\partial \lambda} = \frac{-n\alpha}{(\lambda + d)^2} + (\alpha + 1) \sum_{i=1}^n \frac{1}{(\lambda + x_i)^2} \quad (2.115)$$

สำหรับวิธีการประมาณด้วยภาวะน่าจะเป็นสูงสุดนั้นสามารถประมาณค่าพารามิเตอร์ d ด้วย $y_1 = \min(X(1), \dots, X(n))$ เนื่องจากเป็นตัวที่มีค่าเข้าใกล้จุดตัดปลายมากที่สุด หาค่าประมาณพารามิเตอร์ λ และ α โดยใช้วิธีการของนิวตัน-ราฟสัน (Newton-Raphson Method) สามารถหาค่าประมาณพารามิเตอร์ได้ดังนี้

$$\begin{pmatrix} \alpha_{k+1} \\ \lambda_{k+1} \end{pmatrix} = \begin{pmatrix} \alpha_k \\ \lambda_k \end{pmatrix} - \begin{pmatrix} \frac{\partial H(1)}{\partial \alpha_k} & \frac{\partial H(1)}{\partial \lambda} \\ \frac{\partial H(2)}{\partial \alpha_k} & \frac{\partial H(2)}{\partial \lambda_k} \end{pmatrix}^{-1} \begin{pmatrix} H_k(1) \\ H_k(2) \end{pmatrix} \quad (2.116)$$

จากสมการข้างต้นเราสามารถหาค่าประมาณโดยการกำหนด λ_0 และ α_0 เป็นค่าเริ่มต้น แล้วใช้กระบวนการซ้ำ (Iteration Method) จนกระทั่งได้ค่าพารามิเตอร์ λ และ α

3.3 วิธีกำลังสองต่ำสุดเทียม

กำหนดให้สมการกำลังสองของวิธีการกำลังสองต่ำสุดเทียมคือ

$$LQ = \sum_{i=1}^n (y_i - \ln([1 - F_w(x_i)]^{-1}))^2 \quad (2.117)$$

โดยที่

$$y_i = ([1 - F_n(x_i)]^{-1}) \quad (2.118)$$

$$F_n(x_i) = \frac{k_i}{n} \quad (2.119)$$

k_i คือจำนวนข้อมูลที่มีค่าน้อยกว่าหรือเท่ากับ x_i

สำหรับวิธีกำลังสองต่ำสุดนี้เป็นวิธีการหาตัวประมาณที่ทำให้ผลบวกกำลังสองของผลต่างระหว่างค่า $\ln([1 - F_n(x_i)]^{-1})$ โดยที่ $F_n(x_i)$ ฟังก์ชันการแจกแจงของตัวอย่าง (Sample Distribution Function) กับค่า $\ln([1 - F_w(x_i)]^{-1})$ โดยที่ $F_w(x_i)$ ฟังก์ชันการแจกแจงของข้อมูลที่มีการหักปลายทางซ้าย โดยใช้ อนุพันธ์เข้าช่วย

$$F_w(x_i) = 1 - \left(\frac{\lambda + d}{\lambda + x_i} \right)^\alpha \quad (2.120)$$

$$\ln([1 - F_w(x_i)]^{-1}) = \alpha(\ln(\lambda + x_i) - \ln(\lambda + d)) \quad (2.121)$$

แทนค่าลงในสมการจะได้

$$LQ = \sum_{i=1}^n (y_i - \alpha(\ln(\lambda + x_i) - \ln(\lambda + d)))^2 \quad (2.122)$$

ทำการอนุพันธ์ LQ เทียบกับ λ และ α

$$H(1) = \frac{\partial LQ}{\partial \alpha} = \alpha \sum_{i=1}^n (\ln(\lambda + x_i) - \ln(\lambda + \hat{d}))^2 - \sum_{i=1}^n y_i (\ln(\lambda + x_i) - \ln(\lambda + \hat{d})) \quad (2.123)$$

$$H(2) = \frac{\partial LQ}{\partial \lambda} = \alpha^2 \sum_{i=1}^n (\ln(\lambda + x_i) - \ln(\lambda + \hat{d})) \left(\frac{1}{(\lambda + x_i)} - \frac{1}{(\lambda + \hat{d})} \right) - \alpha \sum_{i=1}^n y_i \left(\frac{1}{(\lambda + x_i)} - \frac{1}{(\lambda + \hat{d})} \right) \quad (2.124)$$

ทำการอนุพันธ์สมการที่ H(1) และ H(2) เทียบกับ α, λ เพื่อใช้ใน

วิธีนิวตัน-ราฟสัน (Newton-Raphson Method) เพื่อใช้ในการหาค่าประมาณพารามิเตอร์ α, λ

$$A(1) = \frac{\partial H(1)}{\partial \alpha} = \sum_{i=1}^n (\ln(\lambda + x_i) - \ln(\lambda + \hat{d}))^2 \quad (2.125)$$

$$A(2) = \frac{\partial H(2)}{\partial \alpha} = 2\alpha \sum_{i=1}^n (\ln(\lambda + x_i) - \ln(\lambda + \hat{d})) \left(\frac{1}{(\lambda + x_i)} - \frac{1}{(\lambda + \hat{d})} \right) - \sum_{i=1}^n y_i \left(\frac{1}{(\lambda + x_i)} - \frac{1}{(\lambda + \hat{d})} \right) \quad (2.126)$$

$$B(1) = \frac{\partial H(1)}{\partial \lambda} = 2\alpha \sum_{i=1}^n (\ln(\lambda + x_i) - \ln(\lambda + \hat{d})) \left(\frac{1}{(\lambda + x_i)} - \frac{1}{(\lambda + \hat{d})} \right) - \sum_{i=1}^n y_i \left(\frac{1}{(\lambda + x_i)} - \frac{1}{(\lambda + \hat{d})} \right) \quad (2.127)$$

$$B(2) = \frac{\partial H(2)}{\partial \lambda} = \alpha^2 \left\{ \sum_{i=1}^n \left(\frac{1}{\lambda + x_i} - \frac{1}{\lambda + \hat{d}} \right)^2 - \sum_{i=1}^n (\ln(\lambda + x_i) - \ln(\lambda + \hat{d})) \left(\frac{1}{(\lambda + x_i)^2} - \frac{1}{(\lambda + \hat{d})^2} \right) \right\} + \alpha \sum_{i=1}^n \left(\frac{1}{(\lambda + x_i)} - \frac{1}{(\lambda + \hat{d})} \right) \quad (2.128)$$

สำหรับวิธีกำลังสองต่ำสุดเทียบนั้นสามารถประมาณค่าพารามิเตอร์ d ด้วย

$y_i = \min(X(1), \dots, X(n))$ เนื่องจากเป็นตัวที่มีค่าเข้าใกล้จุดตัดปลายมากที่สุด หาค่าประมาณ

พารามิเตอร์ λ และ α โดยใช้วิธีการของนิวตัน-ราฟสัน (Newton-Raphson Method) สามารถ

หาค่าประมาณพารามิเตอร์ได้ดังนี้

$$\begin{pmatrix} \alpha_{k+1} \\ \lambda_{k+1} \end{pmatrix} = \begin{pmatrix} \alpha_k \\ \lambda_k \end{pmatrix} - \begin{pmatrix} \frac{\partial H(1)}{\partial \alpha_k} & \frac{\partial H(1)}{\partial \lambda} \\ \frac{\partial H(2)}{\partial \alpha_k} & \frac{\partial H(2)}{\partial \lambda_k} \end{pmatrix}^{-1} \begin{pmatrix} H_k(1) \\ H_k(2) \end{pmatrix} \quad (2.129)$$

จากสมการข้างต้นเราสามารถหาค่าประมาณโดยการกำหนด λ_0 และ α_0 เป็นค่าเริ่มต้น แล้วใช้กระบวนการซ้ำ (Iteration Method) จนกระทั่งได้ค่าพารามิเตอร์ λ และ α