



ตัวสถิติและผลงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงรายละเอียดเกี่ยวกับความรู้พื้นฐานของชนิดของข้อมูลขาดหาย (type of censoring) และอัตราการเสีย (hazard rate) ของข้อมูลรวมทั้งตัวสถิติที่ใช้ทดสอบการแจกแจงแบบเอกซ์โปเนนเชียล พร้อมทั้งตัวอย่างการใช้ตัวสถิติและผลงานวิจัยที่เกี่ยวข้อง ซึ่งรายละเอียดต่าง ๆ มีดังนี้

2.1 ความรู้พื้นฐาน

2.1.1 ชนิดของข้อมูลขาดหาย (type of censoring)

ก. ข้อมูลขาดหายประเภทที่ 1 (type 1 censoring) เรียกอีกอย่างหนึ่งว่า time censoring ข้อมูลขาดหายประเภทนี้จะกำหนดเวลาของการเกิดข้อมูลขาดหายไว้ล่วงหน้าแล้ว เช่น การศึกษาอายุการใช้งานของเครื่องจักรจำนวนหนึ่ง กำหนดอายุใช้งานของเครื่องจักร คือ 20,000 ชั่วโมง ถ้าเครื่องจักรทำงานเกิน 20,000 ชั่วโมงถือว่าอายุการใช้งานของเครื่องจักรเครื่องที่เกินเป็นข้อมูลขาดหาย (censored data) เนื่องจากไม่สามารถบันทึกข้อมูลได้ กรณีที่เครื่องจักรบางเครื่องมีอายุการใช้งานยาวนานและชั่วโมงที่กำหนดถือว่าเป็น time censoring

ข. ข้อมูลขาดหายประเภทที่ 2 (type 2 censoring) ในบางกรณีผู้วิจัยไม่สามารถกำหนด time censoring ที่เหมาะสมได้ ดังนั้นจึงกำหนดข้อมูลที่ไม่ขาดหายแทน โดยจะหยุดการทดลองเมื่อข้อมูลที่ไม่ขาดหายเกิดขึ้นครบตามจำนวนที่กำหนดไว้

ค. ข้อมูลขาดหายแบบสุ่ม (random censoring) ข้อมูลขาดหายประเภทนี้ ส่วนใหญ่พบในข้อมูลที่เกี่ยวข้องกับการแพทย์ หลังจากได้รับการรักษาแล้วซึ่งจะทำให้ไม่สามารถได้ข้อมูลที่แน่นอน

2.1.2 อัตราการเสีย (hazard rate หรือ hazard function) -

ให้ T เป็นตัวแปรสุ่มซึ่งแทนอายุใช้งาน (time to failure)

$f(t)$ แทน ฟังก์ชันความหนาแน่น

$F(t)$ แทน ฟังก์ชันการแจกแจงสะสม

และ $R(t)$ (reliability function) คือความน่าจะเป็นที่หน่วยตัวอย่างมีอายุใช้งานได้นานกว่าเวลา t

$$\begin{aligned} \text{ดังนั้น } R(t) &= p(T > t) \\ &= 1 - F(t) \end{aligned}$$

$h(t)$ แทนอัตราการเสียชีวิต หรือฟังก์ชันการเสียชีวิตมีค่าเท่ากับค่าจำกัด (limit) ของความน่าจะเป็นที่แต่ละหน่วยตัวอย่างเสียชีวิตในช่วงเวลาสั้น ๆ จาก t ถึง $t + \Delta t$ ต่อหน่วยเวลา Δt เมื่อแต่ละหน่วยตัวอย่างมีอายุใช้งานมากกว่า t นั่นคือ

$$\begin{aligned} h(t) &= \lim_{\Delta t \rightarrow 0} \frac{p(t < T < t + \Delta t \mid T > t)}{\Delta t} \\ &= \lim_{\Delta t \rightarrow 0} \frac{F(t + \Delta t) - F(t)}{(1 - F(t)) \cdot \Delta t} \\ &= \lim_{\Delta t \rightarrow 0} \frac{R(t) - R(t + \Delta t)}{R(t) \cdot \Delta t} \\ &= - \frac{R'(t)}{R(t)} \\ &= \frac{f(t)}{R(t)} \\ &= \frac{f(t)}{1 - F(t)} \end{aligned}$$

โดย $h(t)$ มีคุณสมบัติดังนี้

$$\text{ก. } h(t) > 0 \text{ เมื่อ } -\infty < t < \infty$$

$$\text{ข. } \lim_{t \rightarrow -\infty} \int_{-\infty}^t h(t) dt = 0 \text{ และ } \lim_{t \rightarrow \infty} \int_{-\infty}^t h(t) dt = \infty$$

โดยทั่วไปฟังก์ชันการเสียชีวิตมีรูปแบบเป็นฟังก์ชันลด ฟังก์ชันเพิ่ม และฟังก์ชันคงที่ ดังแสดงไว้ในบทที่ 1 และเมื่อทราบฟังก์ชันการเสียชีวิตของข้อมูลชุดหนึ่ง สามารถบอกได้ว่าข้อมูลมีฟังก์ชันความหนาแน่น $f(t)$ และฟังก์ชันการแจกแจงสะสม $F(t)$ โดยใช้คุณสมบัติต่อไปนี้

$$\text{จาก } h(t) = \frac{f(t)}{1 - F(t)}$$

$$= \frac{-R'(t)}{R(t)}$$

$$= -\frac{1}{R(t)} \frac{dR(t)}{dt}$$

$$h(x) = -\frac{1}{R(x)} \frac{dR(x)}{dx}$$

$$-\int_0^t h(x)dx = \int_0^t \frac{1}{R(x)} dR(x)$$

$$= \ln R(t) - \ln(R(0))$$

เพราะว่า $F(0) = 0$ ดังนั้น $R(0) = 1 - F(0) = 1$

$$-\int_0^t h(x)dx = \ln R(t) \quad (\ln R(0) = \ln(1) = 0)$$

ดังนั้น $R(t) = \exp\left(-\int_0^t h(x)dx\right)$

นั่นคือ $F(t) = 1 - \exp\left(-\int_0^t h(x)dx\right)$

นั่นคือเมื่อทราบว่าฟังก์ชันการเสียเป็นค่าคงที่เท่ากับ $1/\beta$ สามารถหาฟังก์ชันการแจกแจงสะสมได้ดังนี้

$$F(t) = 1 - \exp\left(-\int_0^t (1/\beta)dx\right)$$

$$F(t) = 1 - \exp(-t/\beta) \quad , t > 0$$

ซึ่งก็คือ ฟังก์ชันการแจกแจงสะสมของการแจกแจงแบบเอกซ์โปเนนเชียล

2.2 ตัวสถิติทดสอบ

2.2.1 ตัวสถิติทดสอบ Z (Regression Test)

Brain และ Shapriro (ค.ศ 1983) ได้เสนอตัวสถิติทดสอบการแจกแจง

แบบเอกซ์โปเนนเชียล โดยตัวสถิติทดสอบ Z เป็นฟังก์ชันค่าความชันของเส้นถดถอยซึ่งเป็นความสัมพันธ์ของตัวแปรตาม y_i กับตัวแปรอิสระ i กล่าวคือ ตัวสถิติทดสอบอยู่ในรูปของ

$$Z = \frac{[12 / (m-2)]^{1/2} \sum_{i=1}^{m-1} a_i Y_{r_1+i+1}}{\sum_{i=1}^{m-1} Y_{r_1+i+1}}$$

เมื่อ $x_1 < x_2 < \dots < x_n$ เป็นข้อมูลอันดับขนาด n

กำหนด $Y_i = (n-i+1)(x_i - x_{i-1})$, $i=2,3,\dots,n$

ซึ่ง Pyke (ค.ศ 1965) สามารถแสดงได้ว่าในกรณีตัวอย่างขนาดใหญ่ Y_i เป็นตัวแปรสุ่มแบบเอกซ์โปเนนเชียลและเป็นอิสระต่อกัน

$$a_i = i - m/2 \quad , i= 1,2,\dots,m-1$$

$$m = n - r_1 - r_2$$

x_{r_1+1} = ค่าสังเกตที่เล็กที่สุด

x_{n-r_2} = ค่าสังเกตที่ใหญ่ที่สุด

เมื่อ r_1 เป็นจำนวนข้อมูลขาดหายทางซ้าย (left censored data)

r_2 เป็นจำนวนข้อมูลขาดหายทางขวา (right censored data)


เราจะปฏิเสธสมมติฐาน H_0 : ข้อมูลมีการแจกแจงแบบเอกซ์โปเนนเชียล

เมื่อ $|Z| > Z^*_{\alpha/2}$, $Z^*_{\alpha/2} \sim N(0,1)$

ตัวอย่างที่ 1 การทดสอบอายุการใช้งานของเครื่องจักร 35 เครื่อง บันทึกข้อมูลโดยคิดเวลาในการทำงานเป็นชั่วโมงกำหนดการทดสอบให้หยุดภายหลัง 30 ชั่วโมงของการทดสอบปรากฏว่ามีเครื่องจักร 4 เครื่องที่หยุดทำงาน ก่อนที่จะบันทึกข้อมูล และหลังจาก 30 ชั่วโมงมีเครื่องจักร 10 เครื่องที่ยังทำงานต่อซึ่งไม่สามารถเก็บข้อมูลได้ สำหรับข้อมูลที่เก็บได้เป็นดังนี้

-, -, -, -, 16.3, 16.7, 16.9, 17.0, 17.1, 17.3, 17.8, 17.9, 18.3, 18.4, 18.6, 19.1, 19.5, 20.6, 21.4, 22.9, 23.0, 24.6, 25.9, 28.6, -, -, -, -, -, -, -, -, -, -

ซึ่งสามารถเขียนเป็นรูปกราฟได้ดังนี้



รูปที่ 2.1

แสดงกราฟของข้อมูลได้จากตัวอย่างที่ 1

กำหนด H_0 : ข้อมูลมีการแจกแจงแบบเอกซ์โปเนนเชียล

H_1 : ข้อมูลไม่มีการแจกแจงแบบเอกซ์โปเนนเชียล

จากตัวอย่างนี้ $n = 35$, $r_1 = 4$, $r_2 = 10$, $m = 35 - 10 - 4 = 21$

จาก $Y_i = (n-i+1)(x_i - x_{i-1})$

สามารถจัดเรียงข้อมูลใหม่ได้ดังนี้

i	x_t	y_t	$a_t = i - m/2$	$a_t * y_{s+t}$
5	16.0	-	-	-
6	16.3	9.0	-9.5	-85.5
7	16.7	11.6	-8.5	-98.5
8	16.9	5.6	-7.5	-42.00
9	17.0	2.7	-6.5	-17.55
10	17.1	2.6	-5.5	-14.30
11	17.3	5.0	-4.5	-22.50
12	17.8	12.0	-3.5	-42.00
13	17.9	2.3	-2.5	-5.75
14	18.3	8.8	-1.5	-13.20
15	18.4	2.1	-0.5	-1.05
16	18.6	4.0	0.5	2.00
17	19.1	9.5	1.5	14.25
18	19.5	7.2	2.5	18.00
19	20.6	18.7	3.5	65.45
20	21.4	12.8	4.5	57.60
21	22.9	22.5	5.5	123.75
22	23.0	1.4	6.5	9.10
23	24.6	20.8	7.5	156.00
24	25.9	15.6	8.5	132.60
25	28.6	29.7	9.5	282.15
		מגד 203.9		מגד 518.45

จากตารางจะได้ว่า $\sum_{t=1}^{20} a_t Y_{s+t} = 518.45$ และ $\sum_{t=1}^{20} a_t Y_{s+t} = 203.9$

$$Z = \frac{[12 / 21 - 2]^{1/2} \cdot 518.45}{203.9}$$

$$= 2.021$$

จากตารางการแจกแจงปกติมาตรฐาน เมื่อกำหนดระดับนัยสำคัญ 0.05

จะได้ว่า $Z_{\alpha/2}^* = 1.96$

ดังนั้น $Z > Z_{\alpha/2}^*$

เราจะปฏิเสธสมมติฐาน H_0 ณ ระดับนัยสำคัญ 0.05

2.2.2 ตัวสถิติทดสอบ Gnedenko F Test

Gnedenko และคณะ (ค.ศ.1969) ได้เสนอตัวสถิติทดสอบ F เพื่อทดสอบการแจกแจงแบบเอกซ์โปเนนเชียล โดยตัวสถิติทดสอบ F หาได้จากอัตราส่วนของผลรวมเฉลี่ยของข้อมูล 2 ชุด ชุดแรก (s_1) มี k ข้อมูล ชุดที่ 2 (s_2) มี $m-1-k$ ข้อมูล ตัวสถิติทดสอบคือ

$$F = s_1 / s_2$$

โดยที่ $s_1 = \sum_{t=2}^{k+1} Y_{r_1+t} / k$

$$s_2 = \sum_{t=k+2}^m Y_{r_1+t} / (m-1-k)$$

$$m = n - r_1 - r_2$$

และ $k =$ จำนวนเต็มใด ๆ $= (m-1) / 2$



เราจะปฏิเสธสมมุติฐาน H_0 เมื่อ $F > F^*_{\alpha/2} [2k, 2(m-1-k)]$
หรือ $1/F > F^*_{\alpha/2} [2(m-1-k), 2k]$

โดยที่ $F^*_{\alpha/2} (m, n)$ คือค่าในตาราง F ณ ระดับความเป็นอิสระ m และ n

ตัวอย่างที่ 2 จากข้อมูลในตัวอย่างที่ 1 ได้ $m=21, n=35, r_1=4, r_2=10, k=(21-1)/2 = 10$

กำหนดให้ H_0 : ข้อมูลมีการแจกแจงแบบเอกซ์โปเนนเชียล

H_1 : ข้อมูลไม่มีการแจกแจงแบบเอกซ์โปเนนเชียล

นิจรรณาค่า s_1 และ s_2

$$\begin{aligned} s_1 &= \sum_{i=2}^{11} Y_{4+i} / 10 \\ &= (9+11.6+5.6+2.7+2.6+5.0+12.0+8.3+8.8+2.1)/10 \\ &= 6.17 \end{aligned}$$

$$\begin{aligned} s_2 &= \sum_{i=10+2}^{21} Y_{4+i} / (21-1-10) \\ &= (4.0+9.5+7.2+18.7+12.8+22.5+1.4+20.8+15.6+29.7)/10 \\ &= 14.22 \end{aligned}$$

$$\begin{aligned} \text{ดังนั้นได้ค่า} \quad F &= s_1 / s_2 \\ &= 6.17 / 14.22 \\ &= 0.4338 \end{aligned}$$

จากตาราง F ได้ $F^*_{0.05} [2(10), 2(21-1-10)] = F^*_{0.05} (20, 20) = 2.12$

$$\text{ดังนั้น } 1/F = 2.3047 > F^*_{0.05} = 2.12$$

เราจึงปฏิเสธสมมุติฐาน H_0 ณ ระดับนัยสำคัญ 0.10

2.2.3 ตัวสถิติทดสอบ K (Kolmogorov-Smirnov Test)

Stephen (ค.ศ 1974) ได้เสนอตัวสถิติทดสอบ K เพื่อทดสอบการแจกแจงแบบเอกซ์โปเนนเชียล โดยพิจารณาจากค่าแตกต่างที่สูงที่สุดระหว่างฟังก์ชันการแจกแจงสะสมของตัวอย่างที่จะวิเคราะห์กับฟังก์ชันการแจกแจงสะสมของการแจกแจงที่ต้องการเปรียบเทียบ ตัวสถิติทดสอบคือ

$$K = \max (D^+, D^-)$$

โดยที่ $D^+ = \max (i/n , F(x_i))$

$$D^- = \max (F(x_i) , (i-1)/n)$$


และ $F(x_i)$ คือฟังก์ชันการแจกแจงสะสม , $(i=1,2,\dots,n)$ และ n =จำนวนข้อมูล

เราจะปฏิเสธสมมติฐาน H_0 เมื่อ $K > K^*_{\alpha/2,n}$ (จากตาราง)

ตัวอย่างที่ 3 ถ้าอายุการใช้งานของเครื่องจักรชุดหนึ่งเป็นดังนี้

8, 20, 34, 46, 63, 86, 111, 141, 186, 266

ซึ่งสามารถแสดงเป็นรูปกราฟได้ดังนี้



รูปที่ 2.20

แสดงกราฟของข้อมูลจากตัวอย่างที่ 3

กำหนด H_0 : ข้อมูลมีการแจกแจงแบบเอกซ์โปเนนเชียล H_1 : ข้อมูลไม่มีการแจกแจงแบบเอกซ์โปเนนเชียล

จากข้อมูลที่กำหนดให้เราสามารถจัดเรียงข้อมูลใหม่ได้ตามตารางต่อไปนี้

i	x_i	$(i-1)/n$	i/n	$F(x_i)$	$i/n - F(x_i)$	$F(x_i) - (i-1)/n$
1	8	0.00	0.10	0.077	0.023	0.077
2	20	0.10	0.20	0.181	0.019	0.081
3	34	0.20	0.30	0.288	0.012	0.088
4	46	0.30	0.40	0.369	0.031	0.064
5	63	0.40	0.50	0.467	0.033	0.067
6	86	0.50	0.60	0.577	0.023	0.072
7	111	0.60	0.70	0.670	0.030	0.070
8	141	0.70	0.80	0.756	0.044	0.056
9	186	0.80	0.90	0.844	0.056	0.044
10	266	0.90	1.00	0.930	0.070	0.030

จากตาราง $F(x_i) = 1 - \exp(-x_i / x)$

$$\text{เมื่อ } x = \frac{\sum_{i=1}^n x_i}{n}$$

$$\begin{aligned} \text{เพราะฉะนั้น } D^+ &= \max (i/n , F(x_i)) \\ &= 0.070 \end{aligned}$$

$$\begin{aligned} D^- &= \max (F(x_i) , (i-1)/n) \\ &= 0.088 \end{aligned}$$

$$\begin{aligned} \text{ดังนั้น } K &= \max (D^+ , D^-) \\ &= 0.088 \end{aligned}$$

พิจารณาค่า $K_{\alpha, 1/2}^*$ จากตาราง Kolmogorov-Smirnov

$$\text{ได้ } K_{(0.05, 10)}^* = 0.3244$$

$$\text{ดังนั้น } K = 0.088 < K_{(0.05, 10)}^* = 0.3244$$

จึงไม่เหตุผลที่จะปฏิเสธสมมติฐาน H_0 กล่าวคือ ข้อมูลชุดนี้มีการแจกแจงแบบ
เอกซ์โปเนนเชียล
จากตัวอย่างเดียวกันนี้ เมื่อทดสอบโดยใช้ตัวสถิติทดสอบ Z สามารถแสดงได้จากตาราง
ต่อไปนี้

i	x_i	$Y_i = (n - i + 1)(X_i - X_{i-1})$	$a_i = i - m/2$	$a_i \cdot Y_i$
1	8			
2	20	108	- 3	- 324
3	34	112	- 2	- 224
4	46	84	- 1	- 84
5	63	102	0	0
6	86	115	1	115
7	111	100	2	200
8	141	90	3	270
9	186	90	4	360
10	266	80	5	400
		รวม 881		รวม 713

$$\text{จาก } Z = \frac{[12 / (m-2)]^{1/2} \sum_{i=1}^{m-1} a_i Y_{r_{i+1}+1}}{\sum_{i=1}^{m-1} Y_{r_{i+1}+1}}$$

$$= \frac{[12 / (10-2)]^{1/2} \times 713}{881}$$

$$= 0.991$$

ดังนั้น $Z = 0.991 < Z_{\alpha/2}^* = 1.64$ ($\alpha = 0.10$)
 ดังนั้นจึงไม่มีเหตุผลที่จะปฏิเสธสมมติฐาน H_0 เช่นเดียวกันกับตัวสถิติทดสอบ K

2.3 ผลงานวิจัยที่เกี่ยวข้อง

ผลงานวิจัยของนักสถิติที่สนใจทดสอบการแจกแจงแบบเอกซ์โปเนนเชียลมีมากมาย ในที่นี้จะเสนอผลงานวิจัยบางผลงานวิจัยเท่านั้น

Danny Dyer และ Mickie Sui Habin (ค.ศ 1981:278-291) ได้ศึกษาอำนาจการทดสอบของตัวสถิติทดสอบ 3 ตัวที่ใช้ทดสอบการแจกแจงแบบเอกซ์โปเนนเชียล คือ Tiku Test , Shapiro-Wilk Test และ Durbin Test ภายใต้ประชากรศึกษา 16 ประชากร โดยศึกษาเฉพาะขนาดตัวอย่างขนาดเล็ก คือ $n = 5, 10, 15$ และ 25 ได้ผลสรุปดังนี้

- 1) โดยทั่วไป Tiku Test มีอำนาจการทดสอบสูงกว่าตัวสถิติทดสอบตัวอื่น
- 2) เมื่อขนาดตัวอย่างขนาดเล็ก ($n=5, 10$) พบว่าตัวสถิติทดสอบ Shapiro-Wilk Test มีอำนาจการทดสอบสูงในบางกรณีของการแจกแจงแย้ง¹ (alternative distributions)
- 3) โดยเฉลี่ยตัวสถิติทดสอบ Durbin Test ให้อำนาจการทดสอบต่ำ เมื่อเทียบกับตัวสถิติทดสอบ Tiku Test และ Shapiro-Wilk Test

1 การแจกแจงแย้ง ในที่นี้หมายถึง การแจกแจงของข้อมูลที่กำหนดให้มีการแจกแจงเป็นแบบอื่น ๆ ที่ไม่ใช่การแจกแจงแบบเอกซ์โปเนนเชียล