

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

การหาจุดแบ่งที่เหมาะสมที่สุดสำหรับการพยากรณ์การจำแนกข้อมูลไม่จัดกลุ่ม สำหรับ การวิจัยครั้งนี้จะใช้หาจุดแบ่งที่เหมาะสมที่สุดในตัวแบบการถดถอยโลจิสติกแบบ 2 ประเภท ซึ่งจุด แบ่งที่เหมาะสมที่สุดจะให้ค่าอัตราความผิดพลาดในการจำแนกกลุ่มมีค่าต่ำสุด และใช้ตัวแบบการ ถดถอยพหุคูณเพื่อประมาณค่าพารามิเตอร์สำหรับใช้ในการประมาณค่าจุดแบ่งที่เหมาะสมที่สุดใน สถานการณ์อื่นๆ ต่อไป ซึ่งในบทนี้จะกล่าวถึงรายละเอียดเกี่ยวกับตัวแบบการถดถอยโลจิสติก แบบ 2 ประเภท การประมาณค่าสัมประสิทธิ์การถดถอยในตัวแบบการถดถอยโลจิสติกแบบ 2 ประเภท ด้วยวิธีภาวะน่าจะเป็นสูงสุด (Maximum Likelihood Estimation) การหาจุดแบ่งโดยใช้ ทฤษฎี Hadjicostas P. (2006) การหาอัตราความผิดพลาดในการจำแนกกลุ่มหรือสัดส่วนความ ถูกต้องในการจำแนกกลุ่ม

แนวคิดและทฤษฎี

2.1 ตัวแบบการถดถอยโลจิสติกแบบ 2 ประเภท (Binary Logistic Regression Model)

ตัวแบบการถดถอยโลจิสติกแบบ 2 ประเภทเป็นตัวแบบที่ศึกษาถึงความสัมพันธ์ของตัว แปร 2 กลุ่ม ได้แก่ กลุ่มตัวแปรอิสระ (X) และกลุ่มของตัวแปรตาม (Y) ซึ่งตัวแปรตามนี้เป็นตัว แปรเชิงคุณภาพมีค่าได้เพียง 2 ค่า โดยพิจารณาในรูปของความสำเร็จและความล้มเหลว โดยที่ $Y=1$ เมื่อพบความสำเร็จ และ $Y=0$ เมื่อพบความล้มเหลว ซึ่งเมื่อได้ตัวแบบความสัมพันธ์ ระหว่างตัวแปรแล้วจะสามารถนำไปใช้พยากรณ์โอกาสที่แต่ละหน่วยจะอยู่ในกลุ่มใดกลุ่มหนึ่งได้

ตัวแบบการถดถอยโลจิสติกแบบ 2 ประเภท สำหรับการพยากรณ์การจำแนกกลุ่ม เป็น ดังนี้

$$\text{จาก } Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi} + \varepsilon_i \quad ; i = 1, 2, \dots, n$$

เนื่องจากตัวแปรตาม Y มีค่าได้เพียง 2 ค่า คือ 0 และ 1 ดังนั้น จึงมีการแจกแจงแบบเบอร์

นูลลี (Bernoulli Distribution)

$$\text{โดย } \Pr(Y_i = 1 | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi}) = \pi_i$$

$$\Pr(Y_i = 0 | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi}) = 1 - \pi_i \quad ; 0 < \pi_i < 1$$

Y_i มีค่าเฉลี่ยและค่าความแปรปรวน ดังนี้

$$E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi}) = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi}$$

$$\text{Var}(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi}) = \pi_i(1 - \pi_i) \quad ; i = 1, 2, \dots, n$$

เมื่อ π_i คือความน่าจะเป็นที่จะเกิดความสำเร็จของลักษณะที่สนใจศึกษา

$1 - \pi_i$ คือความน่าจะเป็นที่จะเกิดความล้มเหลวของลักษณะที่สนใจศึกษา

เนื่องจากถ้าตัวแบบการถดถอยเชิงเส้นคือ $Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi} + \varepsilon_i$

$; i = 1, 2, \dots, n$ ซึ่งมีข้อตกลงเบื้องต้นคือ $E(\varepsilon) = 0$ นั่นคือ

$$E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi}) = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi} \quad ; i = 1, 2, \dots, n$$

ฟังก์ชันโลจิท (logit function) จะอยู่ในรูปของ

$$\begin{aligned} \text{Logit}[E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi})] &= \ln \left(\frac{E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi})}{1 - E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi})} \right) \\ &= \ln \left(\frac{\pi_i}{1 - \pi_i} \right) \end{aligned}$$

ซึ่งฟังก์ชันโลจิทจะทำการแปลงค่า π_i จากช่วง $(0, 1)$ เป็นค่าที่อยู่ในช่วง $(-\infty, \infty)$ โดยฟังก์ชันผกผันของฟังก์ชันโลจิท จะแปลงค่า $\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi}$ เป็นค่าที่อยู่ในช่วง $[0, 1]$ ซึ่งเรียกว่า ฟังก์ชันโลจิสติก (logistic function) และจะได้ตัวแบบการถดถอยโลจิสติกแบบ 2 ประเภท ดังนี้

$$\begin{aligned} \ln \left(\frac{E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi})}{1 - E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi})} \right) &= \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi} \\ \left(\frac{E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi})}{1 - E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi})} \right) &= \exp(\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi}) \\ E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi}) &= \frac{\exp(\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi})}{1 + \exp(\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi})} \\ \pi_i &= \frac{\exp(\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi})}{1 + \exp(\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi})} \end{aligned}$$

ซึ่งตัวแบบนี้สามารถทำให้อยู่ในรูปของเชิงเส้นได้ ดังนี้

$$\text{Logit}(\pi_i) = \ln \left[\frac{E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi})}{1 - E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi})} \right] = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi}$$

$$Y_i^* = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi} + \varepsilon_i$$

$$Y_i^* = \ln \left(\frac{E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi})}{1 - E(Y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi})} \right) \quad \text{โดย } \varepsilon_i \sim N(0, \sigma^2); i = 1, 2, \dots, n$$

2.2 ฟังก์ชันภาวะน่าจะเป็น (Likelihood function) ของข้อมูลการถดถอยโลจิสติกแบบ 2 ประเภท

เมื่อแต่ละค่าสังเกต $(x_{1i}, x_{2i}, \dots, x_{pi}, y_i)$; $i = 1, 2, \dots, n$ คือตัวแปรสุ่มแบบเบอร์นูลลี ซึ่ง

$$\Pr(Y_i = 1 | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi}) = \pi_i(x_{1i}, x_{2i}, \dots, x_{pi})$$

$$\Pr(Y_i = 0 | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi}) = 1 - \pi_i(x_{1i}, x_{2i}, \dots, x_{pi})$$

การแจกแจงความน่าจะเป็น คือ

$$f_i(Y_i = y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi}) = [\pi_i(x_{1i}, \dots, x_{pi})]^{y_i} [1 - \pi_i(x_{1i}, \dots, x_{pi})]^{1-y_i}$$

เมื่อ $y_i = 0, 1$; $i = 1, 2, \dots, n$

จะได้ฟังก์ชันภาวะน่าจะเป็น คือ

$$l(\beta_0, \beta_1, \dots, \beta_p | \{Y_i = y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi}\} ; i = 1, 2, \dots, n) = \prod_{i=1}^n [\pi_i(x_{1i}, \dots, x_{pi})]^{y_i} [1 - \pi_i(x_{1i}, \dots, x_{pi})]^{1-y_i}$$

ลอการิทึมธรรมชาติของฟังก์ชันภาวะน่าจะเป็น (log-likelihood function) คือ

$$\begin{aligned} L(\beta_0, \beta_1, \dots, \beta_p) &= \ln \left\{ l(\beta_0, \beta_1, \beta_2, \dots, \beta_p | \{Y_i = y_i | X_{1i} = x_{1i}, X_{2i} = x_{2i}, \dots, X_{pi} = x_{pi}\} ; i = 1, 2, \dots, n) \right\} \\ &= \ln \left\{ \prod_{i=1}^n [\pi_i(x_{1i}, \dots, x_{pi})]^{y_i} [1 - \pi_i(x_{1i}, \dots, x_{pi})]^{1-y_i} \right\} \\ &= \sum_{i=1}^n \{ y_i \ln[\pi_i(x_{1i}, \dots, x_{pi})] + (1 - y_i) \ln[1 - \pi_i(x_{1i}, \dots, x_{pi})] \} \\ &= \sum_{i=1}^n \{ y_i \ln[\pi_i(x_{1i}, \dots, x_{pi})] + \ln[1 - \pi_i(x_{1i}, \dots, x_{pi})] - y_i \ln[1 - \pi_i(x_{1i}, \dots, x_{pi})] \} \\ &= \sum_{i=1}^n \{ y_i \{ \ln[\pi_i(x_{1i}, \dots, x_{pi})] - \ln[1 - \pi_i(x_{1i}, \dots, x_{pi})] \} + \ln[1 - \pi_i(x_{1i}, \dots, x_{pi})] \} \\ &= \sum_{i=1}^n y_i \ln \left(\frac{\pi_i(x_{1i}, \dots, x_{pi})}{1 - \pi_i(x_{1i}, \dots, x_{pi})} \right) + \sum_{i=1}^n \ln[1 - \pi_i(x_{1i}, \dots, x_{pi})] \end{aligned}$$

$$\text{เมื่อ } \pi_i = \frac{\exp(\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi})}{1 + \exp(\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi})}$$

$$1 - \pi_i = \frac{1}{1 + \exp(\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi})}$$

$$\ln \left(\frac{\pi_i}{1 - \pi_i} \right) = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_p X_{pi}$$

ดังนั้น ลอการิทึมธรรมชาติของฟังก์ชันภาวะน่าจะเป็น คือ

$$L(\beta_0, \beta_1, \dots, \beta_p) = \sum_{i=1}^n y_i (\beta_0 + \beta_1 X_{1i} + \dots + \beta_p X_{pi}) - \sum_{i=1}^n \ln[1 + \exp(\beta_0 + \beta_1 X_{1i} + \dots + \beta_p X_{pi})]$$

2.3 การประมาณค่าพารามิเตอร์ด้วยวิธีภาวะน่าจะเป็นสูงสุด (Maximum Likelihood Estimation)

การหาค่าตัวประมาณค่าสัมประสิทธิ์การถดถอยด้วยวิธีภาวะน่าจะเป็นสูงสุด คือต้องทำให้ L มีค่ามากที่สุดโดยทำการหาอนุพันธ์เทียบกับ β ต่างๆ เมื่อเราทราบการแจกแจงของ Y เราจะสามารถสร้างฟังก์ชันภาวะน่าจะเป็นได้ เนื่องจากการประมาณค่าไม่ได้เป็นไปตามรูปแบบ เราจึงต้องใช้วิธีการประมาณเชิงตัวเลข (จำเป็นต้องทำซ้ำเพื่อให้ได้มาซึ่งตัวประมาณภาวะน่าจะเป็นสูงสุด (MLE)) โดยในการทำซ้ำ 1 ครั้งจะได้ตัวประมาณภาวะน่าจะเป็นสูงสุด $b_0, b_1, b_2, \dots, b_p$ แล้วทำการคำนวณค่าประมาณของ π_i ; $i=1,2,\dots,n$ ดังนี้

$$\hat{\pi}_i = \frac{\exp(b_0 + b_1 x_{1i} + b_2 x_{2i} + \dots + b_p x_{pi})}{1 + \exp(b_0 + b_1 x_{1i} + b_2 x_{2i} + \dots + b_p x_{pi})} \quad ; i=1,2,\dots,n$$

เมื่อประมาณค่าพารามิเตอร์ด้วยวิธีภาวะน่าจะเป็นสูงสุดในตัวแบบการถดถอยโลจิสติกแบบ 2 ประเภทแล้ว จะสามารถนำไปใช้ในการพยากรณ์การจำแนกกลุ่มของตัวแบบ ดังนี้

- หน่วยที่ i จะถูกจัดให้อยู่ในกลุ่มของความสำเร็จของลักษณะที่สนใจศึกษา ($Y=1$) ถ้า

$$\hat{\pi}_i = \frac{\exp(b_0 + b_1 x_{10} + b_2 x_{20} + \dots + b_p x_{p0})}{1 + \exp(b_0 + b_1 x_{10} + b_2 x_{20} + \dots + b_p x_{p0})} > c \quad ; 0 \leq c \leq 1$$

- หน่วยที่ i จะถูกจัดให้อยู่ในกลุ่มของความล้มเหลวของลักษณะที่สนใจศึกษา ($Y=0$) ถ้า

$$\hat{\pi}_i = \frac{\exp(b_0 + b_1 x_{10} + b_2 x_{20} + \dots + b_p x_{p0})}{1 + \exp(b_0 + b_1 x_{10} + b_2 x_{20} + \dots + b_p x_{p0})} \leq c \quad ; 0 \leq c \leq 1$$

เมื่อ c คือ จุดแบ่งหรือระดับของความน่าจะเป็นที่ใช้ในการพิจารณาการจำแนกกลุ่มว่าแต่ละหน่วยจะอยู่ในกลุ่มใดระหว่างกลุ่มของความสำเร็จและกลุ่มของความล้มเหลวของลักษณะที่สนใจศึกษา

2.4 การตรวจสอบความเหมาะสมของตัวแบบ

เนื่องจากตัวแบบที่เป็นไปได้มีหลายตัวแบบ ดังนั้นจึงมีวิธีการวัดทางสถิติที่หลากหลายสำหรับใช้ในการวัดว่าตัวแบบโลจิสติกมีความสามารถในการจำแนกกลุ่มให้แต่ละหน่วยอยู่ในกลุ่มใดกลุ่มหนึ่งระหว่างกลุ่มของความสำเร็จและกลุ่มของความล้มเหลวของลักษณะที่สนใจศึกษาเหมาะสมมากน้อยเพียงใด ดังนี้

- Chi-square goodness of fit test และสถิติ Deviance
- Hosmer-Lomeshow test
- Classification table

- Receiver Operating Characteristic Curve (ROC)
- สัมประสิทธิ์การตัดสินใจสำหรับการถดถอยโลจิสติก (R^2)
- การตรวจสอบความถูกต้องของตัวแบบ (Model validation) ด้วยวิธีการใช้ชุดข้อมูลภายนอกหรือโดยแบ่งชุดข้อมูลออกเป็น 2 ส่วน

Classification table จะสอดคล้องกับแต่ละจุดแบ่งที่ถูกคัดเลือกซึ่งจะถูกใช้เป็นเกณฑ์สำหรับการคัดเลือกจุดแบ่งที่ทำให้อัตราความผิดพลาดในการจำแนกกลุ่มมีค่าต่ำสุด

Classification table สำหรับแต่ละจุดแบ่งแสดงดังนี้

		ค่าสังเกต		
		$y_i = 1$	$y_i = 0$	
ค่าพยากรณ์ (เกณฑ์ที่ใช้ในการตัดสินใจ คือ $\hat{\pi}_i > c$)	$\hat{y}_i = 1$	A	C	A+C
	$\hat{y}_i = 0$	B	D	B+D
		A+B	C+D	A+B+C+D

โดย “A” คือ จำนวนของค่าสังเกตที่ถูกจัดให้อยู่ในกลุ่มของความสำเร็และค่าสังเกตที่แท้จริงอยู่ในกลุ่มของความสำเร็ด้วย

“B” คือ จำนวนของค่าสังเกตที่ถูกจัดให้อยู่ในกลุ่มของความล้มเหลวในขณะที่ค่าสังเกตที่แท้จริงอยู่ในกลุ่มของความสำเร็

“C” คือ จำนวนของค่าสังเกตที่ถูกจัดให้อยู่ในกลุ่มของความสำเร็ในขณะที่ค่าสังเกตที่แท้จริงอยู่ในกลุ่มของความล้มเหลว

“D” คือ จำนวนของค่าสังเกตที่ถูกจัดให้อยู่ในกลุ่มของความล้มเหลวและค่าสังเกตที่แท้จริงอยู่ในกลุ่มของความล้มเหลวด้วย

สำหรับแต่ละจุดแบ่ง c การคัดเลือกจุดแบ่งจะต้องทำให้อัตราความผิดพลาดในการจำแนกกลุ่มมีค่าต่ำสุดหรืออัตราความถูกต้องในการจำแนกกลุ่มมีค่าสูงสุด โดยแสดงดังนี้

อัตราความผิดพลาดในการจำแนกกลุ่ม (Classification Error Rate: CER)

$$CER = \frac{B + C}{A + B + C + D}$$

ถ้า CER มีค่าต่ำกว่าแสดงว่ามีความเหมาะสมมากกว่า

สัดส่วนความถูกต้องในการจำแนกกลุ่ม ($p(c)$)

$$p(c) = \frac{A + D}{A + B + C + D} = 1 - CER$$

ถ้า $p(c)$ มีค่ามากแสดงว่ามีความเหมาะสมมากกว่า



2.5 สถิติ Kaiser-Meyer-Olkin (KMO)

Kaiser (1970) ได้เสนอสถิติ KMO ในการศึกษานี้ สถิติ KMO เป็นสถิติที่ใช้วัดระดับความสัมพันธ์ระหว่างตัวแปรอิสระ

$$0 \leq KMO = \frac{\sum_{i=1}^p \sum_{j=1}^p r_{ij}^2}{\sum_{i=1}^p \sum_{j=1}^p r_{ij}^2 + \sum_{i=1}^p \sum_{j=1}^p a_{ij}^2} \leq 1$$

โดยที่ r_{ij} คือสัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปรอิสระตัวที่ i และตัวแปรอิสระตัวที่ j
 a_{ij} คือสัมประสิทธิ์สหสัมพันธ์บางส่วนระหว่างตัวแปรอิสระตัวที่ i และตัวแปรอิสระตัวที่ j สำหรับ $i < j = 1, 2, \dots, p$

ระดับความสัมพันธ์ระหว่างตัวแปรอิสระแบ่งเป็น 5 ระดับ ดังนี้

- ตัวแปรอิสระไม่มีความสัมพันธ์กัน เมื่อ $KMO = 0$
- ความสัมพันธ์ระหว่างตัวแปรอิสระอยู่ในระดับต่ำ เมื่อ $0 < KMO \leq 0.50$
- ความสัมพันธ์ระหว่างตัวแปรอิสระอยู่ในระดับปานกลาง เมื่อ $0.50 < KMO \leq 0.75$
- ความสัมพันธ์ระหว่างตัวแปรอิสระอยู่ในระดับสูง เมื่อ $0.75 < KMO < 1.00$
- ตัวแปรอิสระมีความสัมพันธ์กันอย่างสมบูรณ์ เมื่อ $KMO = 1$

2.6 ช่วงความเชื่อมั่น (Confidence Interval)

การประมาณค่าแบบช่วงหรือช่วงความเชื่อมั่นเป็นการประมาณค่าพารามิเตอร์ของประชากรในรูปแบบช่วงโดยใช้ข้อมูลตัวอย่าง การประมาณแบบช่วงนั้นจะบอกถึงค่าต่ำสุดและค่าสูงสุดของพารามิเตอร์ที่เป็นไปได้

ระดับของค่าความเชื่อมั่นที่ใช้ในการสร้างช่วงความเชื่อมั่นนั้นจะกำหนดเป็นค่าควบคู่กับระดับนัยสำคัญ นั่นคือ $1 - \alpha$ ที่เรียกว่าช่วงความเชื่อมั่น $(1 - \alpha)100\%$ จะได้ว่า

$$P(L < \theta < U) = 1 - \alpha$$

เรียก L ว่าขีดจำกัดความเชื่อมั่นล่าง (lower confidence limit)

U ว่าขีดจำกัดความเชื่อมั่นบน (upper confidence limit)

ในงานวิจัยนี้กำหนดให้ L มาจากค่าที่ตำแหน่งเปอร์เซ็นต์ไทล์ที่ $100(\alpha/2)$

U มาจากค่าที่ตำแหน่งเปอร์เซ็นต์ไทล์ที่ $100(1 - \alpha/2)$



2.7 เปอร์เซนต์ไทล์ (Percentile)

เป็นค่าที่แบ่งข้อมูลออกเป็น 100 ส่วนเท่าๆ กัน เมื่อข้อมูลถูกเรียงจากน้อยไปหามาก เนื่องจากค่าที่แบ่งจำนวนข้อมูลออกเป็น 100 ส่วนเท่าๆ กัน มีอยู่ 99 ค่า ดังนั้นเราจึงตั้งชื่อแต่ละค่าว่า เปอร์เซนต์ไทล์ที่หนึ่ง (P_1) เปอร์เซนต์ไทล์ที่สอง (P_2) และเปอร์เซนต์ไทล์ที่เก้าสิบเก้า (P_{99}) ตามลำดับ

การหาเปอร์เซนต์ไทล์ คือต้องหาดำแหน่งของเปอร์เซนต์ไทล์ก่อน

ให้ N เป็นจำนวนข้อมูลทั้งหมด ตำแหน่งต่างๆ ของเปอร์เซนต์ไทล์หาได้ดังนี้

$$\begin{aligned} P_1 & \text{ อยู่ในตำแหน่งที่ คือ } \frac{1(N+1)}{100} \\ P_2 & \text{ อยู่ในตำแหน่งที่ คือ } \frac{2(N+1)}{100} \\ & \vdots \\ P_{99} & \text{ อยู่ในตำแหน่งที่ คือ } \frac{99(N+1)}{100} \end{aligned}$$

โดยทั่วไป ตำแหน่งของเปอร์เซนต์ไทล์ที่ r คือ

$$P_r \text{ อยู่ในตำแหน่งที่ คือ } \frac{r(N+1)}{100}$$



2.8 วิธีการหาจุดแบ่งที่เหมาะสมที่สุดสำหรับตัวแบบการถดถอยโลจิสติกแบบ 2 ประเภท

โดยทฤษฎีของ Hadjicostas P. (2006)

วิธีการนี้ Hadjicostas P. (2006) ได้เสนอไว้โดยใช้ผลลัพธ์ทางคณิตศาสตร์ที่ง่ายแต่มีความถูกต้องแม่นยำในการหาจุดแบ่งที่ทำให้สัดส่วนความถูกต้องในการจำแนกกลุ่มมีค่าสูงสุดดังนี้

ให้ $M(i)$ คือ $\max j \in \{1, 2, \dots, n\}$ ถ้า $\hat{\pi}_i = \hat{\pi}_j$ โดย $M(0) = 0$; $i \leq M(i) \leq n$
สำหรับแต่ละ $i \in \{1, 2, \dots, n\}$ ใดๆ และสำหรับ $i \in \{0, 1, 2, \dots, n\}$

$$\begin{aligned} \text{ให้ } A_i &= [0, \hat{\pi}_1) & \text{ถ้า } i = 0 \\ A_i &= [\hat{\pi}_i, \hat{\pi}_{i+1}) & \text{ถ้า } \hat{\pi}_i < \hat{\pi}_{i+1} \text{ และ } 1 \leq i < n \\ A_i &= \{\hat{\pi}_i\} = \{\hat{\pi}_{M(i)}\} & \text{ถ้า } \hat{\pi}_i = \hat{\pi}_{i+1} \text{ และ } 1 \leq i < n \\ A_i &= [\hat{\pi}_n, 1] & \text{ถ้า } i = n \end{aligned}$$

ข้อสังเกต $\bigcup_{i=0}^n A_i = [0, 1]$

ให้ $p(c)$ คือสัดส่วนความถูกต้องในการจำแนกกลุ่มที่จุด c ที่ซึ่ง $c \in [0, 1]$

$$p(c) = \frac{N(c)}{n}$$

บทตั้ง สำหรับ $i \in \{0, 1, 2, \dots, n\}$ ใดๆ และ $c \in A_i$

$$N(c) = \sum_{j=1}^{M(i)} (1 - y_j) + \sum_{j=M(i)+1}^n y_j \quad \dots\dots\dots(1)$$

พิสูจน์ บทตั้งนี้มาจากความจริงที่ว่า $N(c)$ คือผลรวมของจำนวนของค่าศูนย์(ความล้มเหลว)ใน $(y_1, y_2, \dots, y_{M(i)})$ และจำนวนของค่าหนึ่ง (ความสำเร็จ) ใน $(y_{M(i)+1}, \dots, y_n)$ (ถ้า $M(i) = 0$ แล้ว $(y_1, y_2, \dots, y_{M(i)})$ จะไม่มี เช่นเดียวกับ ถ้า $M(i) = n$ แล้ว $(y_{M(i)+1}, \dots, y_n)$ จะไม่มี)

ทฤษฎีบท ให้ $a_i = \sum_{k=1}^{M(i)} (-1)^{y_k}$ สำหรับ $i = 0, 1, 2, \dots, n$ ให้ I_0 เป็นเซตของ j ทั้งหมด $j \in \{0, 1, 2, \dots, n\}$ ที่ซึ่ง $a_j = \max_{0 \leq i \leq n} a_i$ และให้ C_0 เป็นเซตของ c_0 ทั้งหมด $c_0 \in [0, 1]$ ที่ซึ่ง $p(c_0) = \max_{c \in [0, 1]} p(c)$ แล้ว $C_0 = \bigcup_{i \in I_0} A_i$

พิสูจน์ ให้ e_i เป็นด้านขวาของสมการ (1) นั่นคือ $e_i = \sum_{j=1}^{M(i)} (1 - y_j) + \sum_{j=M(i)+1}^n y_j$ โดยการใช้

เอกลักษณ์ $1 - 2y_j = (-1)^{y_j}$ จะได้ว่า $e_i = \sum_{j=1}^n y_j + a_i$ สำหรับ $i \in \{0, 1, 2, \dots, n\}$

จากบทตั้ง สำหรับ $c_0 \in [0, 1]$ ใดๆ จะได้ว่า

$$c_0 \in C_0 \Leftrightarrow N(c_0) = \max_{c \in [0, 1]} N(c) = \max_{0 \leq i \leq n} \max_{c \in A_i} N(c) = \max_{0 \leq i \leq n} e_i = \sum_{j=1}^n y_j + \max_{0 \leq i \leq n} a_i$$

(i) ให้ $c_0 \in \bigcup_{i \in I_0} A_i$ หา $i_0 \in I_0$ ที่ซึ่ง $c_0 \in A_{i_0}$

$$\text{ดังนั้น } N(c_0) = e_{i_0} = \sum_{j=1}^n y_j + a_{i_0} = \sum_{j=1}^n y_j + \max_{0 \leq i \leq n} a_i$$

นั่นคือ $c_0 \in C_0$ ดังนั้น $\bigcup_{i \in I_0} A_i \subseteq C_0$

(ii) ให้ $c_0 \in C_0$ เนื่องจาก $\bigcup_{i=0}^n A_i = [0, 1]$ นั่นคือ $i_1 \in \{0, 1, 2, \dots, n\}$ ที่ซึ่ง

$$c_0 \in A_{i_1}$$

$$\text{แล้ว } N(c_0) = e_{i_1} = \sum_{j=1}^n y_j + a_{i_1} \text{ แต่ } N(c_0) = \sum_{j=1}^n y_j + \max_{0 \leq i \leq n} a_i$$

ดังนั้น $a_{i_1} = \max_{0 \leq i \leq n} a_i$ แสดงว่า $i_1 \in I_0$

$$\text{ดังนั้น } c_0 \in \bigcup_{i \in I_0} A_i \text{ และ } C_0 \subseteq \bigcup_{i \in I_0} A_i$$

โดยมีรายละเอียดและวิธีการดังนี้

1. เรียงอันดับค่า $\hat{\pi}_i$ จากน้อยไปหามาก $\hat{\pi}_1 < \hat{\pi}_2 < \dots < \hat{\pi}_n$ โดยถ้า $\hat{\pi}_i$ คือจุดแบ่งแล้ว จะพยากรณ์ให้เป็นกลุ่มของความล้มเหลวของลักษณะที่สนใจศึกษา ($Y=0$)
2. สำหรับแต่ละ $i \in \{1, 2, \dots, n\}$ ใดๆ หาค่า $M(i)$ ซึ่ง $M(i)$ คือ $\max j \in \{1, 2, \dots, n\}$ ถ้า $\hat{\pi}_i = \hat{\pi}_j$ โดย $M(0) = 0 ; i \leq M(i) \leq n$
3. สำหรับ $i = 0, 1, 2, \dots, n$ หาค่า $a_i = \sum_{k=1}^{M(i)} (-1)^{y_k}$ โดยแบ่งเป็น 2 กรณี คือ
 - 3.1 $a_{i+1} = a_i + \sum_{k=M(i)+1}^{M(i+1)} (-1)^{y_k}$ ถ้า $M(i) < i+1$
 - 3.2 $a_{i+1} = a_i$ ถ้า $i+1 \leq M(i)$
4. หา I_0 ซึ่งเป็นเซตของ j ทั้งหมด โดย $j \in \{0, 1, 2, \dots, n\}$ ที่ซึ่ง $a_j = \max_{0 \leq i \leq n} a_i$
5. หา C_0 ซึ่งเป็นเซตของ c_0 ทั้งหมด โดย $c_0 \in [0, 1]$ ที่ซึ่ง $p(c_0) = \max_{c \in [0, 1]} p(c)$
แล้ว $C_0 = \bigcup_{i \in I_0} A_i$