

การถดถอย

ความหมาย

การถดถอย (Regression) หมายถึง กระบวนการของการพยากรณ์ (prediction) ของตัวแปรตัวหนึ่ง จากตัวแปรตัวอื่นที่มีอยู่ ๑ ตัว ตัวแปรที่ถูกพยากรณ์ เรียกว่า “ตัวแปรตาม (dependent variable)” หรือ “ตัวเกณฑ์ (criterion)” ส่วนตัวแปรที่ใช้ในการพยากรณ์ ตัวแปรตามหรือตัวเกณฑ์ เรียกว่า “ตัวแปรอิสระ (independent variable)” หรือ “ตัวพยากรณ์ (predictor)”

การพยากรณ์ตัวแปรตามโดยใช้ตัวพยากรณ์จะต้องสร้างสมการการถดถอย (regression equation) สมการการถดถอยนี้จะเป็นความสัมพันธ์เชิงคณิตศาสตร์ ระหว่างตัวแปรตามและตัวแปรอิสระ การสร้างสมการ การถดถอยจะต้องสร้างให้ได้สมการการถดถอยที่เหมาะสมที่สุดของข้อมูล การที่จะให้ได้สมการการถดถอยที่เหมาะสมที่สุดจะต้องมีการวิเคราะห์ข้อมูล ซึ่งจะเรียกว่า “การวิเคราะห์การถดถอย (regression analysis)” ตัวแปรที่จะนำมารวิเคราะห์การถดถอยจะต้องมีลักษณะการแจกแจงปกติ และเป็นอิสระต่อกัน

ความเป็นมา

การถดถอยได้ถูกนำมาใช้ในวิชาสถิติครั้งแรก ในปี ก.ศ.๑๘๗๗ โดย เชอร์ฟรานซิส แกลตัน (Sir Francis Galton) เชอร์ฟรานซิส แกลตัน ได้ศึกษาเรื่องเกี่ยวกับพันธุกรรมเพื่อแสดงว่าเด็กซึ่งเกิดจากพ่อแม่ที่สูงมีแนวโน้มจะมีความสูงเท่ากับความสูงเฉลี่ยของพ่อแม่ และได้นำคำว่า “การถดถอย” มาใช้โดยให้ความหมาย การถดถอยว่า หมายถึงกระบวนการของการพยากรณ์ตัวแปรตัวหนึ่ง (ความสูงของเด็ก) จากตัวแปรอีกตัวหนึ่ง (ความสูงของพ่อแม่) ต่อมาก็

นักสถิติได้นำคำว่า “การถดถอยพหุคุณ (multiple regression) มาใช้และได้เรียกการถดถอยของเชอร์ฟรานซิส แกลตัน ว่า การถดถอยข่ายง่ายหรือการถดถอยเชิงเดียว (simple regression)

ชนิดของการถดถอย

การถดถอยมี ๒ ชนิด คือ

๑. การถดถอยเชิงเดียว เป็นการถดถอยที่มีสมการการถดถอยประกอบด้วยตัวแปรตาม ๑ ตัว และตัวแปรอิสระ ๑ ตัว เช่น ถ้าให้ y แทนตัวแปรตาม ให้ x แทนตัวแปรอิสระ และให้ b_0 , b_1 และ b_2 แทนค่าคงที่ จะได้ว่า

๑.๑ สมการการถดถอยที่มีกราฟเป็นเส้นตรง (Straight line) แทนด้วย

$$Y = b_0 + b_1 X$$

๑.๒ สมการการถดถอยที่มีกราฟเป็นเส้นโค้ง พาราโบลา (parabola curve) แทนด้วย

$$Y = b_0 + b_1 X + b_2 X^2$$

๑.๓ สมการการถดถอยที่มีกราฟเป็นเส้นโค้ง ไฮเพอร์โบลา (hyperbola curve) แทนด้วย

$$Y = \frac{1}{b_0 + b_1 X}$$

๑.๔ สมการการถดถอยที่มีกราฟเป็นเส้นโค้ง ชี้กำลัง (exponential curve) แทนด้วย

$$Y = b_0 b_1^X$$

๑.๕ สมการการถดถอยที่มีกราฟเป็นเส้นโค้ง เรขาคณิต (geometric curve) แทนด้วย

$$Y = b_0 X^{b_1}$$

เป็นต้น

ข้อ ๑.๑ เรียกว่าการถดถอยเชิงเดียวแบบเชิงเส้น (simple linear regression) ส่วนข้อ ๑.๒ ถึง ๑.๕ เรียกว่าการถดถอยเชิงเดียวแบบไม่ใช่เชิงเส้น (simple non-linear regression)

๑. การถดถอยพหุคุณ เป็นการถดถอยที่มีสมการการถดถอยคู่วัวตัวแปรตาม ๑ ตัวและตัวแปรอิสระมากกว่า ๑ ตัว เช่น ถ้าให้ Y แทนตัวแปรตาม ให้ $X_1, X_2 \dots$ และ X_k แทนตัวแปรอิสระ k ตัว และให้ $b_0, b_1 \dots$ และ b_k แทนค่าคงที่จะได้ว่า

$$\text{๑.๑ } Y = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_k X_k \quad \text{เรียกว่าการถดถอยพหุคุณ}$$

แบบเชิงเส้น (multiple linear regression)

$$\text{๑.๒ } Y = b_0 + b_1 X_1 + b_2 X_2 + b_3 X_1 X_2 + b_4 X_1^2 + b_5 X_2^2$$

เรียกว่า การถดถอยพหุคุณแบบไม่ใช่เชิงเส้น (multiple non-linear regression) เป็นดัง

ตัวแบบและสมการการพยากรณ์ของการถดถอย

ให้ \hat{Y}_i แทนค่าที่ i ของตัวแปรตาม Y \hat{Y} แทนค่าพยากรณ์ (predicted value) ของตัวแปรตาม Y X_i แทนค่าที่ i ของตัวแปรอิสระ X $X_{i,1} X_{i,2} \dots$ และ $X_{i,k}$ แทนค่าที่ i ของตัวแปรอิสระที่ ๑, ๒, ..., และ k ค่าคงตัว e_i แทนค่าที่ i ของค่าพิเศษแบบสุ่ม (random error) หรือ เศษตกค้าง (residual) n แทนจำนวนค่าสังเกตของ Y หรือ X $\beta_0, \beta_1 \dots$ และ β_k แทนพารามิเตอร์ (parameter) $k+1$ ตัว และให้ $b_0, b_1 \dots$ และ b_k แทนค่าประมาณของ $\beta_0, \beta_1 \dots$ และ β_k ค่าคงตัว จะได้ตัวแบบ (model) ของการถดถอย สมการการพยากรณ์ (prediction equation) ของการถดถอยและชนิดของการถดถอยซึ่งสอดคล้องกันดังนี้ คือ

$$1. \text{ ตัวแบบของ } Y = b_0 + b_1 X \quad \text{คือ}$$

$$Y_i = \beta_0 + \beta_1 X_i + e_i,$$

$i = 1, 2, \dots, n$
จะมีสมการการพยากรณ์ของการถดถอยคือ

$$\hat{Y} = b_0 + b_1 X$$

$$2. \text{ ตัวแบบของ } Y = b_0 + b_1 X + b_2 X^2 \quad \text{คือ}$$

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + e_i, \\ i = 1, 2, \dots, n$$

จะมีสมการการพยากรณ์ของการถดถอยคือ

$$\hat{Y} = b_0 + b_1 X + b_2 X^2$$

$$3. \text{ ตัวแบบของ } Y = \frac{1}{b_0 + b_1 X} \quad \text{คือ}$$

$$Y_i = \frac{1}{\beta_0 + \beta_1 X_i} + e_i, \\ i = 1, 2, \dots, n$$

จะมีสมการการพยากรณ์ของการถดถอยคือ

$$\hat{Y} = \frac{1}{b_0 + b_1 X}$$

$$4. \text{ ตัวแบบของ } Y = b_0 b_1 X \quad \text{คือ}$$

$$Y_i = \beta_0 \beta_1 X_i + e_i, \\ i = 1, 2, \dots, n$$

จะมีสมการการพยากรณ์ของการถดถอยคือ

$$\hat{Y} = b_0 b_1 X$$

$$5. \text{ ตัวแบบของ } Y = b_0 X^{\frac{b_1}{b_1}} \quad \text{คือ}$$

$$Y_i = \beta_0 X_i^{\frac{b_1}{b_1}} + e_i, \\ i = 1, 2, \dots, n$$

จะมีสมการการพยากรณ์ของการถดถอยคือ

$$\hat{Y} = b_0 X^{\frac{b_1}{b_1}}$$

$$6. \text{ ตัวแบบของ } Y = b_0 + b_1 X_1 +$$

$$b_2 X_2 + \dots + b_k X_k \quad \text{คือ}$$

$\dots + \beta_k$

จะมีสมการ
 $\hat{Y} = b_0$

7. ตัวแบบ

$b_3 X_1 X_2 +$

Y

$\beta_3 X_i, 1 X_j$

จะมีสมการ
 $\hat{Y} = b_0$

$b_4 X_1^2 + b$

เราจะเป็น

predicted v:
สามารถจะหา
value) ของตัว
เชื่อมั่น (con:
จะเรียกค่าพยา
(prediction i

เราจะเป็น

ค่าของ $b_0, 1$
และ b_k จะ
(method of l

หลักการ

ต้องหา b_0, b
 n
 Σ (ค'
 $i=1$
มีค่าน้อยที่สุด

เช่น ถ้าสมการ

$$\begin{aligned} Y_i &= \beta_0 + \beta_1 X_{i,1} + \beta_2 X_{i,2} + \\ &\dots + \beta_k X_{i,k} + e_i, \\ i &= 1, 2, \dots, n \end{aligned}$$

จะมีสมการการพยากรณ์ของการถดถอยที่คือ

$$\hat{Y} = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_k X_k$$

$$\begin{aligned} 7. \text{ ตัวแบบของ } Y &= b_0 + b_1 X_1 + b_2 X_2 + \\ &b_3 X_1 X_2 + b_4 X_1^2 + b_5 X_2^2 \text{ คือ} \end{aligned}$$

$$\begin{aligned} Y_i &= \beta_0 + \beta_1 X_{i,1} + \beta_2 X_{i,2} + \\ &\beta_3 X_{i,1} X_{i,2} + \beta_4 X_{i,1}^2 + \beta_5 X_{i,2}^2 + e_i, \\ i &= 1, 2, \dots, n \end{aligned}$$

จะมีสมการการพยากรณ์ของการถดถอยที่คือ

$$\begin{aligned} \hat{Y} &= b_0 + b_1 X_1 + b_2 X_2 + b_3 X_1 X_2 + \\ &b_4 X_1^2 + b_5 X_2^2 \end{aligned}$$

เราจะเรียก \hat{Y} ว่าค่าพยากรณ์แบบจุด (point predicted value) ของตัวแปรตาม Y นอกจากนี้เรายังสามารถหาค่าพยากรณ์แบบช่วง (interval predicted value) ของตัวแปรตาม Y ได้โดยวิธีการหาช่วงความเชื่อมั่น (confidence interval) ของพารามิเตอร์ และจะเรียกว่าพยากรณ์แบบช่วงของ Y นี้ว่า ช่วงพยากรณ์ (prediction interval)

เราจะเห็นว่าการหาค่าของ \hat{Y} นั้น เราต้องทราบค่าของ b_0, b_1, \dots และ b_k การหาค่าของ b_0, b_1, \dots และ b_k จะหาได้โดยเมธอดวิธีกำลังสองน้อยที่สุด (method of least squares)

หลักการของระเบียบวิธีกำลังสองน้อยที่สุดคือต้องหา b_0, b_1, \dots และ b_k ซึ่งทำให้

$$\sum_{i=1}^n (\text{ค่าสังเกต } Y_i - \text{ค่าท่านาย } \hat{Y}_i)^2$$

มีค่าน้อยที่สุด

เข่น ถ้าสมการการพยากรณ์ของการถดถอย คือ

$$\begin{aligned} \hat{Y} &= b_0 + b_1 X \\ \text{จะต้องหา } b_0 \text{ และ } b_1 \text{ ที่ทำให้} \end{aligned}$$

$$\sum_{i=1}^n [Y_i - (b_0 + b_1 X_i)]^2 \text{ มีค่าน้อยที่สุด}$$

โดยวิธีการทางคณิตศาสตร์เราสามารถหา b_0 และ b_1 ได้ดังนี้

$$b_1 = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} =$$

$$\frac{\sum_{i=1}^n X_i Y_i - [(\sum X_i)(\sum Y_i)]/n}{\sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2/n}$$

$$\text{และ } b_0 = \bar{Y} - b_1 \bar{X}$$

$$\text{เมื่อ } \bar{Y} = \frac{\sum_{i=1}^n Y_i}{n}$$

$$\text{และ } \bar{X} = \frac{\sum_{i=1}^n X_i}{n}$$

ในทำนองเดียวกัน ถ้าสมการการพยากรณ์ของการถดถอย คือ $\hat{Y} = b_0 + b_1 X + b_2 X^2$ จะต้องหา b_0, b_1 และ b_2 ที่ทำให้

$$\sum_{i=1}^n [Y_i - (b_0 + b_1 X_i + b_2 X_i^2)]^2$$

มีค่าน้อยที่สุด เป็นต้น

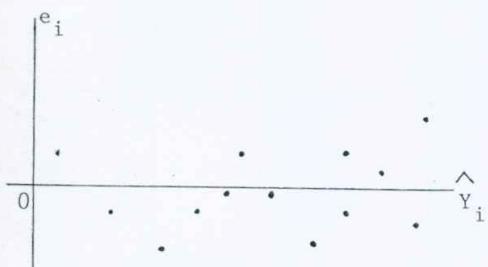
ข้อตกลงเบื้องต้นของการถดถอย

๑. ค่าเฉลี่ยของแต่ละ e_i เท่ากับศูนย์ เมื่อ $i=1, 2, \dots, n$
๒. ความแปรปรวนของแต่ละ e_i เท่ากัน เมื่อ $i=1, 2, \dots, n$
๓. แต่ละ e_i เป็นอิสระต่อกัน เมื่อ $i=1, 2, \dots, n$
๔. e_i เมื่อ $i = 1, 2, \dots, n$ มีการแจกแจงปกติ (normal distribution)

การตรวจสอบข้อตกลงเบื้องต้นของการถดถอยมีหลายวิธี แต่ในที่นี้จะกล่าวถึงเพียงวิธีเดียว คือ การ

ทำแผนภาพกระจาย (scatter – diagram) ระหว่างค่าพิเศษแบบสุ่ม (e_i) และค่าพยากรณ์ (\hat{Y}_i) ซึ่ง $e_i = Y_i - \hat{Y}_i$

ถ้าแผนภาพกระจายมีรูปร่างเป็นแถวนอน (horizontal band) ดังแสดงในรูป ๑ แสดงว่ามีข้อคลوغเบื้องต้นทุกๆ ข้อของการทดสอบ



รูป ๑ แผนภาพกระจายระหว่าง e_i และ \hat{Y}_i

ขั้นตอนของการวิเคราะห์การทดสอบ

๑. เลือกตัวแบบของการทดสอบ (หรือชนิดของการทดสอบ) ที่คาดว่าจะเหมาะสมกับข้อมูล

๒. ตรวจสอบข้อคลوغเบื้องต้นของการทดสอบ

๒.๑ ถ้าข้อมูลมีข้อคลوغเบื้องต้นของการทดสอบทุกๆ ข้อแล้ว ข้อมูลอาจจะมีตัวแบบของการทดสอบที่คาดว่าจะเหมาะสมกับข้อมูลตามข้อ ๑ หรือไม่ก็ได้ จะทราบว่าข้อมูลมีตัวแบบของการทดสอบตามที่คาดไว้หรือไม่นั้น จะต้องทดสอบนัยสำคัญของการทดสอบ (significance of regression) เช่น การวิเคราะห์ความแปรปรวนของการทดสอบ (analysis of variance of regression) เป็นต้น ถ้าข้อมูลมีตัวแบบของการทดสอบตามที่ได้คาดไว้แล้ว จะได้สมการพยากรณ์ของ การทดสอบและหาค่าพยากรณ์ของตัวแปรได้ แต่

ตาราง ๑ คะแนนของวิชาชีวทางสถิติและวิชาสถิติกศาสตร์ของนักเรียน

วิชา	นักเรียนคนที่											
	1	2	3	4	5	6	7	8	9	10	11	12
สถิติกศาสตร์ (X)	65	63	67	64	68	62	70	66	68	67	69	71
วิชาทางสถิติ (Y)	68	66	68	65	69	66	68	65	71	67	68	70

ถ้าข้อมูลไม่มีตัวแบบของการทดสอบตามที่คาดไว้แล้ว จะต้องเลือกตัวแบบของการทดสอบใหม่ต่อไป

๒.๒ ถ้าข้อมูลไม่มีข้อคลوغเบื้องต้นทุกๆ ข้อของการทดสอบแล้ว อาจจะต้องเลือกตัวแบบของการทดสอบใหม่ต่อไป

เทคนิคของการเลือกการทดสอบที่เหมาะสมที่สุด

เทคนิคของการเลือกการทดสอบที่เหมาะสมที่สุดสำหรับข้อมูลมีหลาภิชี คือ

๑. กระบวนการกำจัดข้อนหลัง (backward elimination procedure)

๒. กระบวนการเลือกไปข้างหน้า (forward selection procedure)

๓. กระบวนการทดสอบเด็พไวร์ส (stepwise regression procedure)

๔. กระบวนการทดสอบเดจไวร์ส (stagedewise regression procedure)

ตัวอย่าง

การศึกษาเพื่อหาสมการพยากรณ์ของการทดสอบของคณะวิชาวิทยาศาสตร์ (statistical method) ของนักศึกษาโดยจะนำรายคะแนนของวิชานี้จากคะแนนของวิชาสถิติกศาสตร์ (mathematical statistics) สุ่มตัวอย่างนักศึกษาที่เรียนทั้งวิชาวิทยาศาสตร์และวิชาสถิติกศาสตร์ จำนวน ๑๒ คน ซึ่งคะแนนที่ได้จากการสอบวิชาทั้งสองแสดงในตาราง ๑

วิชาที่ ๑
คะแนนข้อ
คะแนนข้อ
ดัง
ขั้นตอนที่
๑.
แบบของ

๒.
สมมติว่า
๓.
การศึกษา
ตามที่คาด
การทดสอบ

และ
ระเบียบวิ
 $b_1 = d_0$
เป้า
คะแนนวิ
การตีค
 b_0

วิธีทำ จากตาราง ๑ จะเห็นว่า ตัวแปรอิสระ X คือ คะแนนของวิชาสถิติกพัฒนาศรี ตัวแปรตาม Y คือ คะแนนของวิชาวิธีทางสถิติ

ดังนั้น การศึกษาครั้งนี้จะเป็นการทดลองเชิงเดียว ขั้นตอนของการวิเคราะห์การทดลองมีดังนี้ คือ

๑. ในกรณีที่เป็นการทดลองเชิงเดียว จะเลือกตัวแบบของการทดลองที่คาดว่าจะเหมาะสม คือ

$$\hat{Y}_i = \beta_0 + \beta_1 X_i + e_i, \\ i = 1, 2, \dots, 12$$

๒. ตรวจสอบข้อคล้องเนื้องต้นของการทดลอง สมมติว่ามีข้อคล้องเนื้องต้นของการทดลองทุก ๆ ข้อ

๓. ทดสอบนัยสำคัญของการทดลอง สมมติว่า การศึกษาครั้งนี้มีตัวแบบของการทดลองที่เหมาะสม ตามที่คาดไว้ในข้อ ๑ ดังนั้น สมการการพยากรณ์ของ การทดลอง คือ

$$y = b_0 + b_1 X$$

และสามารถหา b_0 และ b_1 จากสูตรซึ่งได้จาก ระเบียบวิธีกำลังสองน้อยที่สุด ได้ $b_0 = 35.82$ และ

$b_1 = d_0 \cdot 0.476$ และจะได้ว่า

$$\hat{Y} = 35.82 + 0.476X$$

เป็นสมการการพยากรณ์ของการทดลองของ คะแนนวิชาวิธีทางสถิติของนักศึกษา

การศึกษา b_0 และ b_1

$$b_0 = 35.82 \text{ หมายความว่า ถ้า} n \text{ นักศึกษา} \rightarrow \text{คะแนน}$$

วิชาสถิติกพัฒนาศรีเท่ากับศูนย์แล้ว นักศึกษาจะได้ คะแนนวิชาวิธีทางสถิติเท่ากับ ๓๕.๘๒ คะแนน

$b_1 = 0.476$ หมายความว่า ถ้า n นักศึกษาได้คะแนน วิชาสถิติกพัฒนาศรีเพิ่มขึ้น ๑ คะแนนแล้ว นักศึกษา จะได้คะแนนวิชาวิธีทางสถิติเพิ่มขึ้นเท่ากับ ๐.๔๗๖ คะแนน

ประโยชน์ของการทดลอง

การทดลองนับว่ามีประโยชน์ในการพยากรณ์ เหตุการณ์ในอนาคตเกี่ยวกับการศึกษา การวิจัย การวัดผล ประเมินผล และธุรกิจต่าง ๆ เป็นอันมาก กล่าวคือ ใช้สำหรับการพยากรณ์ของการทดลองของ ตัวแปร เพื่อพยากรณ์ค่าของตัวแปรตัวหนึ่งจากตัวแปร ตัวหนึ่ง หรือจากตัวแปรอีกหลายตัว เช่น

๑. ต้องการพยากรณ์คะแนนวิชาภาษาอังกฤษ (ตัวแปรตาม) จากจำนวนปีที่นักเรียนได้เรียนภาษา อังกฤษ (ตัวแปรอิสระ)

๒. ต้องการพยากรณ์เกรดเฉลี่ยของนักเรียน (ตัวแปรตาม) จาก I.Q. ของนักเรียน (ตัวแปรอิสระ)

๓. ต้องการพยากรณ์ความสูงของลูก (ตัวแปรตาม) จากความสูงของพ่อและแม่ (ตัวแปรอิสระ ๒ ตัว)

๔. ต้องการพยากรณ์ปริมาณสินค้าที่จะขายได้ (ตัวแปรตาม) จากราคาของสินค้า (ตัวแปรอิสระ)

อรพินท์ เจียรพงษ์

บรรณานุกรม

Conover, W.J. and Ronald L. Iman. Introduction to Modern Business Statistics. New York: John Wiley & Sons, 1983.

គរ

Ferguson, George A. Statistical Analysis in Psychology and Education. Tokyo: McGraw-Hill International Book Company, 1981.

ແສດ
ກຳເກ
ໜີ

Freund, John E. Modern Elementary Statistics. London: Prentice-Hall International Inc., 1979.

ແລະ

Levin, Richard I. Statistics for Management. New Jersey: Prentice-Hall, Inc., 1981

ກືອ

Pfaffenberger, Roger C. and James H. Patterson. Statistical Methods for Business and Economics. Illinois: Richard D. Irwin, Inc., 1977.

rela
ແປ
ເປົ້າ
ດ້ານ
ຫຼານ
ຫ່ວະ
ຈະໄ
ດັ່ງນິරາ

ind
ຮາຄ
ກຳນ
ກືອ
agg
ນໍາ

ຫຼາ
ທຶກ
 Q_i
ຂອ