

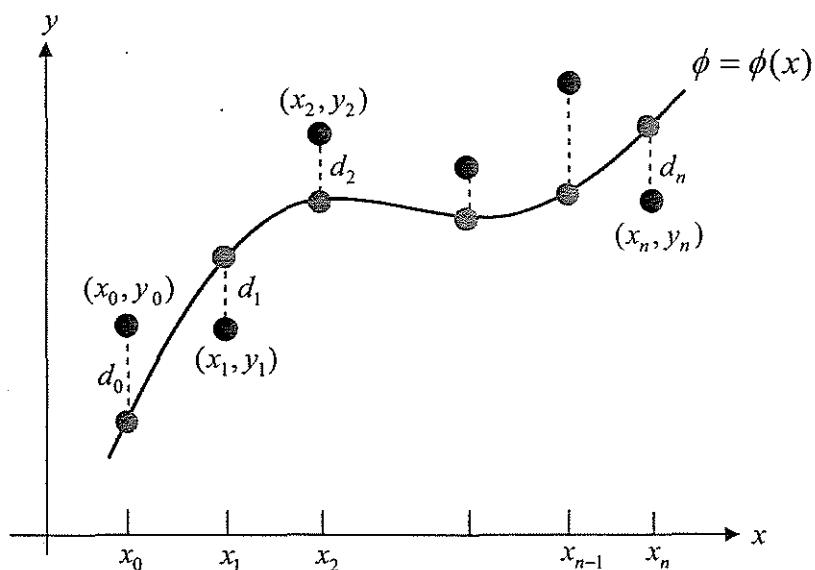
สำหรับเขตของจุดข้อมูล

$$\{(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)\}$$

ให้ $\phi = \phi(x)$ เป็นฟังก์ชันที่สร้างขึ้นเพื่อเชื่อมโยงค่า x_k กับ y_k หรือพิจารณาจุดนี้ดังนั้น ค่าคลาดเคลื่อนที่แต่ละ x_0, x_1, \dots, x_n คือ

$$\begin{aligned} d_0 &= y_0 - \phi_0 = y_0 - \phi(x_0) \\ d_1 &= y_1 - \phi_1 = y_1 - \phi(x_1) \\ &\vdots \\ d_n &= y_n - \phi_n = y_n - \phi(x_n) \end{aligned} \tag{5.1.1}$$

ค่า $d_0, d_1, d_2, \dots, d_n$ เป็นระยะในแนวตั้งจากจุดข้อมูลไปยังจุดที่อยู่บนกราฟของ $\phi = \phi(x)$ ดังแสดงในรูปที่ 5.1.1



รูปที่ 5.1.1

เพื่อให้ค่าคลาดเคลื่อน $d_0, d_1, d_2, \dots, d_n$ น้อยที่สุด มีแนวทางในการวัดค่าคลาดเคลื่อนเหล่านี้ในรูปผลรวมได้ ดังนี้

$$S = \sum_{k=0}^n d_k \quad (5.1.2)$$

$$S = \sum_{k=0}^n |d_k| \quad (5.1.3)$$

$$S = \sum_{k=0}^n d_k^2 \quad (5.1.4)$$

สำหรับค่า S ในสมการ (5.1.2) อาจมีการหักล้างกันของค่า $d_0, d_1, d_2, \dots, d_n$ ได้ ในขณะที่ S ในสมการ (5.1.3) ในทางคณิตศาสตร์เป็นฟังก์ชันที่ไม่เรียบ "ไม่เหมาะสมที่จะหาอนุพันธ์" สำหรับ S ในสมการ (5.1.4) มีความเหมาะสมที่จะนำมาใช้เป็นเงื่อนไขในการสร้างฟังก์ชัน $\phi(x)$ โดยให้ค่า S ในสมการ (5.1.4) มีค่าน้อยที่สุด ทำให้การพิจารณาด้วยเงื่อนไขนี้มีชื่อเรียกว่า วิธีกำลังสองน้อยสุด

ดังนั้น โดยสรุปแล้ว การพิจารณาโดยวิธีกำลังสองน้อยสุดคือ การสร้างฟังก์ชัน $\phi = \phi(x)$ สำหรับข้อมูล $\{(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)\}$ โดยทำให้ผลรวมของค่าคลาดเคลื่อนกำลังสอง

$$S = \sum_{k=0}^n d_k^2 \quad \text{มีค่าน้อยที่สุด}$$

เมื่อ $d_k = y_k - \phi(x_k)$, $k = 0, 1, 2, \dots, n$ การหาเงื่อนไขที่ทำให้ S นี้มีค่าต่ำสุด คือ การหาอนุพันธ์แล้วหาค่าวิกฤต กรณีเฉพาะของฟังก์ชัน $\phi = \phi(x)$ จะเสนอในหัวข้อ 5.2 - 5.4

5.2 การถดถอยเชิงเส้น (Linear Regression)

การถดถอยเชิงเส้นคือ วิธีกำลังสองน้อยสุดสำหรับฟิตข้อมูล

$$\{(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)\}$$

ด้วยพังก์ชันเชิงเส้น

$$\phi(x) = a_0 + a_1 x \quad (5.2.1)$$

โดยเงื่อนไขของวิธีกำลังสองน้อยสุดในทวาร 5.1 ต้องหาค่า a_0 และ a_1 ที่ทำให้

$$S = \sum_{k=0}^n d_k^2 \quad (5.2.2)$$

มีค่าต่ำสุด โดยที่ d_k ในกรณีนี้คือ ระยะในแนวตั้งจากจุดข้อมูล (x_k, y_k) ไปยังจุด $(x_k, \phi(x_k))$ ซึ่งอยู่บนกราฟของเส้นตรง $\phi(x) = a_0 + a_1 x$ ดังแสดงในรูปที่ 5.1.2 แทนค่า d_k ได้

$$S = \sum_{k=0}^n d_k^2 = \sum_{k=0}^n (y_k - \phi(x_k))^2 = \sum_{k=0}^n (y_k - (a_0 + a_1 x_k))^2 \quad (5.2.3)$$

ซึ่งแสดงว่า S เป็นพังก์ชันของ a_0 และ a_1 ต่อไปหาจุดวิกฤตของ S ซึ่งในกรณีนี้เป็นจุดต่ำสุดสมบูรณ์ โดยหาอนุพันธ์ของ S

$$\frac{\partial S}{\partial a_0} = -2 \sum_{k=0}^n (y_k - a_0 - a_1 x_k) \quad (5.2.4)$$

$$\frac{\partial S}{\partial a_1} = -2 \sum_{k=0}^n x_k (y_k - a_0 - a_1 x_k) \quad (5.2.5)$$

ให้อนุพันธ์อย่างสองเท่ากับศูนย์ ทำให้ได้สมการ

$$(n+1)a_0 + \left(\sum_{k=0}^n x_k \right) a_1 = \sum_{k=0}^n y_k \quad (5.2.6)$$

$$\left(\sum_{k=0}^n x_k \right) a_0 + \left(\sum_{k=0}^n x_k^2 \right) a_1 = \sum_{k=0}^n x_k y_k \quad (5.2.7)$$

สมการ (5.2.6) และ (5.2.7) มีชื่อเรียกว่า สมการปรกติ (normal equations) สำหรับการ
ทดถอยเชิงเส้น เอา $n+1$ หารสมการทั้งสอง แก้สมการได้ค่า a_1 และ a_0 ดังนี้

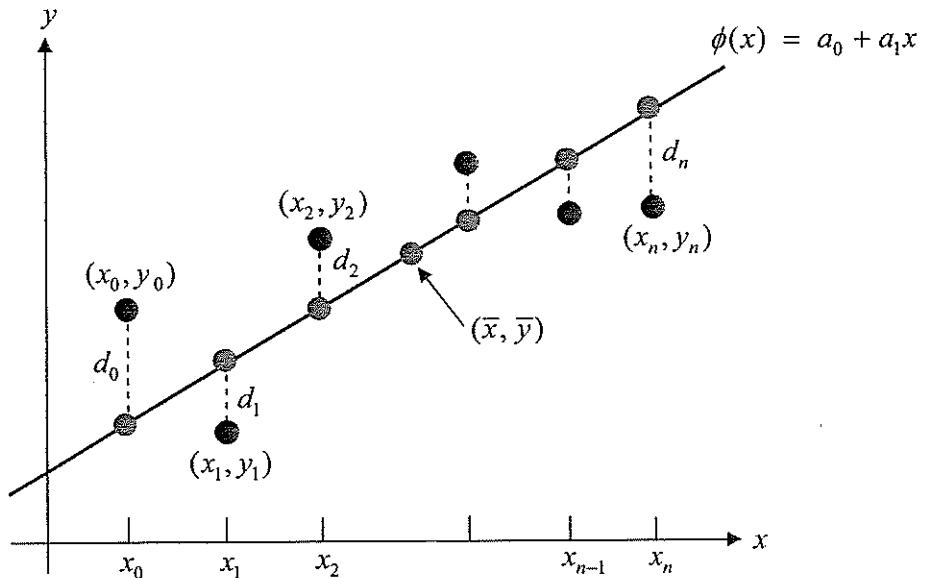
$$a_1 = \frac{\bar{x}\bar{y} - \bar{xy}}{(\bar{x})^2 - \bar{x}^2} \quad (5.2.8)$$

$$a_0 = \bar{y} - a_1 \bar{x} \quad (5.2.9)$$

โดยที่

$$\begin{aligned} \bar{x} &= \frac{1}{n+1} \sum_{k=0}^n x_k, & \bar{y} &= \frac{1}{n+1} \sum_{k=0}^n y_k, \\ \bar{xy} &= \frac{1}{n+1} \sum_{k=0}^n x_k y_k, & \bar{x^2} &= \frac{1}{n+1} \sum_{k=0}^n x_k^2, \end{aligned}$$

นั่นคือ ค่าเหล่านี้คือค่าเฉลี่ยนั่นเอง จากสมการ (5.2.9) ยังได้ว่า จะ (\bar{x}, \bar{y}) อยู่บนเส้นตรง $\phi(x) = a_0 + a_1 x$ ซึ่งเรียกว่า เส้นตรงกำลังสองน้อยสุด (least-squares line) หรือ เส้นตรงทดถอย (regression line) ดูรูปที่ 5.2.1



รูปที่ 5.2.1 เส้นตรงทดถอย

การคำนวณค่า a_1 และ a_0 สำหรับเส้นตรงทดถอย $y = a_0 + a_1x$ เพื่อพิจข้อมูล $\{(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)\}$ สามารถจัดระเบียบการคำนวณในรูปดังตารางที่ 5.2.1 โดยสองคอลัมน์แรกบันทึกข้อมูล x_k และ y_k สำหรับคอลัมน์ที่ 3 และ 4 คำนวณค่า x_k^2 และผลคูณ $x_k y_k$ ตามลำดับ

	x_k	y_k	x_k^2	$x_k y_k$
	x_0	y_0	x_0^2	$x_0 y_0$
	x_1	y_1	x_1^2	$x_1 y_1$
	\vdots	\vdots	\vdots	\vdots
	x_n	y_n	x_n^2	$x_n y_n$
ผลรวม	$\sum_{k=0}^n x_k$	$\sum_{k=0}^n y_k$	$\sum_{k=0}^n x_k^2$	$\sum_{k=0}^n x_k y_k$
ค่าเฉลี่ย	\bar{x}	\bar{y}	$\bar{x^2}$	\bar{xy}

ตารางที่ 5.2.1

ตัวอย่างที่ 5.2.1 จงพิจารณาข้อมูลในตารางด้วยเส้นตรงกำลังสองน้อยสุด และประมาณค่าของ $g(0.05)$

x_k	0.0	0.1	0.3	0.4	0.5
$g(x_k)$	0.5	1.4	2.0	2.5	3.1

วิธีทำ

บันทึกข้อมูล x_k และ $y_k = g(x_k)$ จากตารางที่กำหนดมาให้ คำนวณค่า x_k^2 และ ผลคูณ $x_k y_k$ ดังรูปแบบในตารางที่ 5.2.1 และคำนวณผลรวมและค่าเฉลี่ยในแต่ละ คอลัมน์ ได้ผลดังนี้

	x_k	y_k	x_k^2	$x_k y_k$
	0.0	0.5	0.00	0.00
	0.1	1.4	0.01	0.14
	0.3	2.0	0.09	0.60
	0.4	2.5	0.16	1.00
	0.5	3.1	0.25	1.55
ผลรวม	1.3	9.5	0.51	3.29
ค่าเฉลี่ย	0.26	1.9	0.102	0.658

แทนค่าในสมการ (5.2.8) และ (5.2.9) ได้

$$a_1 = \frac{(0.26)(1.9) - 0.658}{(0.26)^2 - 0.102} = 4.8$$

$$a_0 = 1.9 - (0.26)(4.8) = 0.65$$

ดังนั้น เส้นตรงกำลังสองน้อยสุด คือ

$$\phi(x) = 0.65 + 4.8x$$

ประมาณค่าของ $g(0.05)$ ได้

$$g(0.05) \approx \phi(0.05) = 0.65 + 4.8(0.05) = 0.89$$

□

ตัวอย่างที่ 5.2.2 จงพิจารณาข้อมูลในตารางด้วยเส้นตรงกำลังสองน้อยสุด และคำนวณผลบวกของค่าคลาคเคลื่อนกำลัง

x_k	0.25	0.50	0.75	1.00	1.25	1.50	1.75
y_k	3.10	1.70	1.00	0.68	0.42	0.26	0.14

วิธีทำ

บันทึกข้อมูล x_k และ y_k จากตารางที่กำหนดมาให้ คำนวณค่า x_k^2 และผลคูณ $x_k y_k$ ตั้งรูปแบบในตารางที่ 5.2.1 และคำนวณผลบวกและค่าเฉลี่ยในแต่ละคอลัมน์ ได้ผลตั้งนี้

	x_k	y_k	x_k^2	$x_k y_k$
	0.25	3.10	0.0625	0.7750
	0.50	1.70	0.2500	0.8500
	0.75	1.00	0.5625	0.7500
	1.00	0.68	1.0000	0.6800
	1.25	0.42	1.5625	0.5250
	1.50	0.26	2.2500	0.3900
	1.75	0.14	3.0625	0.2450
ผลบวก	7.0000	7.3000	8.7500	4.2150
ค่าเฉลี่ย	1.0000	1.0429	1.2500	0.6021

แทนค่าในสมการ (5.2.8) และ (5.2.9) ได้

$$a_1 = \frac{(1.0000)(1.0429) - (0.6021)}{(1.0000)^2 - (1.2500)} = -1.7629$$

$$a_0 = 1.0429 - (-1.7629)(1.0000) = 2.8057$$

ตั้งนั้น เส้นตรงกำลังสองน้อยสุด คือ

$$\phi(x) = 2.8057 - 1.7629x$$

ค่าคลาดเคลื่อนกำลังสองที่จุดต่อแต่ละจุดคือ

$$d_k^2 = (y_k - \phi(x_k))^2 = (y_k - (2.8057 - 1.7629 x_k))^2$$

ได้ผลการคำนวณเด้งตาราง

x_k	0.25	0.50	0.75	1.00	1.25	1.50	1.75
d_k^2	0.5402	0.0503	0.2338	0.1317	0.0332	0.0097	0.1758

และผลบวกของค่าคลาดเคลื่อนกำลังสองคือ

$$\sum_{k=0}^6 d_k^2 = 1.1747$$

□

5.3 การแปลงให้เป็นเชิงเส้น (Linearization)

การฟิตข้อมูล $\{(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)\}$ ในการนี้ที่ความสัมพันธ์ของ y_k และ x_k ไม่เป็นแบบเชิงเส้น เช่น กรณีที่อัตราการเปลี่ยนแปลงของ y ประมาณปีริมาณของ y ตัวมันเอง ซึ่งเกิดขึ้นในปัญหาทางวิศวกรรม ในกรณีเช่นนี้ พังก์ชันที่ใช้ฟิตข้อมูลเป็นแบบพังก์ชันเลขชี้กำลัง(exponential model)

$$\phi(x) = Ae^{Bx} \quad (5.3.1)$$

ซึ่งสามารถแปลงให้เป็นเชิงเส้นได้ โดยใช้พังก์ชันลอการิทึมดังนี้

$$\begin{aligned} \ln(\phi(x)) &= \ln(Ae^{Bx}) \\ &= \ln A + Bx \end{aligned}$$

โดยให้

$$Y = \ln(\phi(x)), \quad X = x, \quad a_0 = \ln A, \quad a_1 = B$$

ผลที่ตามมาคือ การแปลงพังก์ชันเลขชี้กำลังในสมการ (5.3.1) เป็นรูปแบบพังก์ชันเชิงเส้น

$$Y = a_0 + a_1 X \quad (5.3.2)$$

ซึ่งทำให้สามารถคำนวณค่า a_0 และ a_1 จากสูตรของเส้นตรงกำลังสองน้อยสุดได้ เมื่อได้ค่าทั้งสองแล้ว ก็สามารถหาค่า A และ B แล้วแปลงกลับไปที่พังก์ชันเลขชี้กำลังในสมการ (5.3.1) ได้

ในการนี้ฟิตข้อมูลด้วยพังก์ชันกำลังหรือกรณีอื่นๆ พิจารณาการแปลงให้เป็นแบบเชิงเส้น ดังสรุปไว้ในตารางที่ 5.3.1

พัγκซันไม่เชิงเส้น	การแปลงให้เป็นพัγκซันเชิงเส้น
$y = A e^{Bx}$	$Y = a_0 + a_1 X$ $X = x, \quad Y = \ln y, \quad a_0 = \ln A, \quad a_1 = B$
$y = Ax^n$	$Y = a_0 + a_1 X$ $X = \ln x, \quad Y = \ln y, \quad a_0 = \ln A, \quad a_1 = n$
$y = A + \frac{B}{x}$	$Y = a_0 + a_1 X$ $X = \frac{1}{x}, \quad Y = y, \quad a_0 = A, \quad a_1 = B$
$y = \frac{1}{A + Bx}$	$Y = a_0 + a_1 X$ $X = x, \quad Y = \frac{1}{y}, \quad a_0 = A, \quad a_1 = B$
$y = A \frac{x}{B + x}$	$Y = a_0 + a_1 X$ $X = \frac{1}{x}, \quad Y = \frac{1}{y}, \quad a_0 = \frac{1}{A}, \quad a_1 = \frac{B}{A}$

ตารางที่ 5.3.1

ด้วยที่ 5.3.1 จงพิจารณาในตารางด้วยฟังก์ชันเลขซึ่งกำลัง $\phi(x) = Ae^{Bx}$ และค่านวนผลบวกของค่าคลาดเคลื่อนกำลังสอง

x_k	0.25	0.50	0.75	1.00	1.25	1.50	1.75
y_k	3.10	1.70	1.00	0.68	0.42	0.26	0.14

ซึ่งเป็นข้อมูลเดียวกันด้วยที่ 5.2.2 โดยเปรียบเทียบผลบวกของค่าคลาดเคลื่อนกำลังสอง กับผลของการพิจารณาเดียวกันนี้ด้วยฟังก์ชันเชิงเส้น

วิธีทำ

ฟังก์ชันที่ใช้พิจารณาคือ

$$\phi(x) = Ae^{Bx}$$

แปลงเป็นแบบเชิงเส้นโดย

$$\ln \phi(x) = \ln(Ae^{Bx}) = \ln A + Bx$$

ให้ $Y = \ln \phi(x)$, $X = x$, $a_0 = \ln A$ และ $a_1 = B$ ดังนั้น

$$Y = a_0 + a_1 X$$

จากตารางที่กำหนดมาให้ ค่านวน $Y_k = \ln y_k$ และ $X_k = x_k$ และ Y_k ใน คอลัมน์ที่ 1 และ 2 ของตาราง ค่านวนค่า X_k^2 และผลคูณ $X_k Y_k$ บันทึกใน ตารางในคอลัมน์ที่ 3 และ 4 แล้วค่านวนผลบวกและค่าเฉลี่ยในแต่ละคอลัมน์ได้ผล ดังแสดงในตาราง

	$X_k = x_k$	$Y_k = \ln(y_k)$	X_k^2	$X_k Y_k$
	0.25	1.131402	0.062500	0.282851
	0.50	0.530628	0.250000	0.265314
	0.75	0.000000	0.562500	0.000000
	1.00	-0.385662	1.000000	-0.385662
	1.25	-0.867501	1.562500	-1.084376
	1.50	-1.347074	2.250000	-2.020610
	1.75	-1.966113	3.062500	-3.440697
ผลรวม	7.00	-2.904319	8.750000	-6.383182
ค่าเฉลี่ย	1.00	-0.414903	1.250000	-0.911883

แทนค่าในสมการ (5.2.8) และ (5.2.9) ได้

$$a_1 = \frac{(1.00)(-0.414903) - (-0.911883)}{(1.00)^2 - (1.250000)} = -1.987921$$

$$a_0 = -0.414903 - (-1.987921)(1.00) = 1.573019$$

ดังนั้น เส้นตรงกำลังสองน้อยสุด $Y = a_0 + a_1 X$ คือ

$$Y = 1.573019 - 1.987921X$$

เพร率为 $a_0 = \ln A$ ดังนั้น

$$A = e^{a_0} = e^{1.573019} = 4.821179$$

และ

$$B = a_1 = -1.987921$$