

บทที่ 5
การหาโค้งกระชับ
(Curve Fitting)

หน้า

- 5.1 การหาโค้งกระชับสำหรับข้อมูลแบบไม่ต่อเนื่อง (Discrete)
 - 5.1A อภิปรายปัญหา
 - 5.1B เกณฑ์กำลังสองของความคลาดเคลื่อนน้อยที่สุด
(Least Square Error Criterion)
 - 5.1C โค้งกระชับที่เป็นเส้นตรง (Straight Line)
 - 5.1D ชั้นรูปในภาษาฟอร์นทรนสำหรับการหาโค้งกระชับที่เป็นเส้นตรง
- 5.2 การหาโค้งกระชับ (ซึ่งมีพารามิเตอร์ 2 ตัว) สำหรับข้อมูลที่เป็น Monotone และ Convex
 - 5.2A Normal Equations สำหรับฟังก์ชันเดาซึ่งมีพารามิเตอร์ 2 ตัว
(Two-Parameter Guess Function)
 - 5.2B การปรับให้เป็นเส้นตรง (Linearizing) สำหรับข้อมูลที่เป็น Monotone และ Convex
 - 5.2C โปรแกรมคอมพิวเตอร์สำหรับการหาโค้งกระชับสำหรับข้อมูลที่เป็น Monotone และ Convex
- 5.3 การหาโค้งกระชับซึ่งเป็นเชิงเส้นในพารามิเตอร์ n ตัว :
Polynomial Fitting
 - 5.3A Normal Equations สำหรับ $g(x) = \sum_{j=1}^n \alpha_j \phi_j(x)$
 - 5.3B Normal Equations สำหรับ $g(x) = \sum_{j=1}^n \alpha_j x^{j-1}$

บทที่ 5 การหาโค้งกระชับ (Curve Fitting)

ปัญหาทางคณิตศาสตร์: เมื่อกำหนดจุด $P_k(x_k, y_k)$ ให้เพียงพอ แล้วหา
สมการแสดงความสัมพันธ์ $y = g(x)$ ที่เกี่ยวข้องกับปริมาณ x และ y
ในลักษณะที่กราฟของฟังก์ชัน g go near (not through) P_k 's

ปัญหาข้างต้นนั้นเราเรียกว่า การหาโค้งกระชับ

เมื่อเราทราบรูปทั่วไปของ $g(x)$ เช่น

$$g(x) = \alpha + \beta x$$

$$\text{หรือ } g(x) = \alpha \exp(\beta x)$$

$$\text{หรือ } g(x) = \alpha + \beta x + \gamma x^2$$

สิ่งที่เราจะทำคือหาค่า α, β, γ (ซึ่งเรียกว่า พารามิเตอร์) ซึ่งจะทำได้
curve $y = g(x)$ fit กับ data อย่างไร

วิธีหนึ่งที่จะใช้กับปัญหาข้างต้นคือ วิธีกำลังสองน้อยที่สุด (least square method)
ซึ่งทำได้โดยการหาผลเฉลยของระบบของ normal equations

ถ้าไม่ทราบรูปของฟังก์ชันซึ่งแสดงความสัมพันธ์ระหว่าง y และ x เราจะใช้
วิธีเดา $g(x)$'s จนกว่าจะได้ $g(x)$ ที่เหมาะสมหรือพอดี (fit) กับข้อมูลเป็นอย่างดี

5.1 การหาโค้งกระชับสำหรับข้อมูลแบบไม่ต่อเนื่อง (Discrete)

5.1A อภิปรายปัญหา

$$\text{ข้อมูล } n \text{ จุด : } P_1(x_1, y_1), P_2(x_2, y_2), \dots, P_n(x_n, y_n) \quad \dots (1)$$

พลอต n จุด บนแกน-xy ถ้าจำนวนจุด (data) พอเพียงและ
แม่นยำพอ เราก็สามารถเดารูปร่างของ ฟังก์ชันเดา (guess function) $g(x)$ ซึ่ง
 $g(x) \approx$ นิพจน์แสดงความสัมพันธ์ ของ y บน x ได้

ตัวอย่าง จากจุด 5 จุด

$$P_1(1, 5.12), P_2(3, 3), P_3(6, 2.48), P_4(9, 2.34), P_5(15, 2.18) \dots (2)$$

พลอต ทั้ง 5 จุดลงบนแกน-xy ดังแสดงในรูปข้างล่าง จะเห็นว่า
เส้นตรงนั้นไม่พอดีกับจุดทั้ง 5 จุด

ฟังก์ชันเคาแบบ linear : $\alpha + \beta x$, $\alpha = y\text{-intercept} \approx 4$

$$\text{และ } \beta = \text{slope} \approx -1/6 \dots (3a)$$

exponential curve นั้น fit ดีขึ้นเล็กน้อย

ฟังก์ชันเคาแบบ exponential : $\alpha \exp(\beta x)$,

$$\alpha = y\text{-intercept} \approx 4 \frac{1}{2}$$

$$\text{และ } \beta = \text{damping factor} \approx -1/10$$


$$\dots (3b)$$

power (of x) curve นั้น fit ดีขึ้นอีกเล็กน้อย

ฟังก์ชันเคาแบบ power (ของ x) : αx^β , $\alpha = y\text{-scale-factor} \approx 4 \frac{1}{2}$

$$\text{และ } \beta = \text{power} \approx -1/3$$

$$\dots (3c)$$



รูป 5.1-1 ฟังก์ชันเคา 3 ฟังก์ชันสำหรับ P_1, P_2, \dots, P_5

เมื่อเลือกฟังก์ชันเดาแล้ว เราต้องหาค่าของพารามิเตอร์ และต้องพิจารณาว่า ฟังก์ชันนั้น good fit แล้วหรือยัง หรือฟังก์ชันใดที่ fit กับข้อมูลได้ดีที่สุด

5.1B เกณฑ์กำลังสองของความคลาดเคลื่อนน้อยที่สุด


(Least Square Error Criterion)

ปริมาณใด ๆ ที่ใช้วัดว่าฟังก์ชันเดา $g(x)$ นั้น fit กับข้อมูล P_1, \dots, P_m ได้ดีหรือไม่ ควรจะเกี่ยวข้องกับจำนวนต่าง ๆ คือ

$$\delta_k = g(x_k) - y_k = \text{ส่วนเบี่ยงเบนของ } g(x) \text{ ที่ } x_k \quad \dots (4)$$

$$k = 1, \dots, m$$

ภาพต่อไปนี้จะแสดง $\delta_k, k = 1, \dots, m$



รูป 5.1-2 การ fit ฟังก์ชัน $g(x)$ กับ P_1, \dots, P_m

เพื่อเป็นตัวอย่าง พิจารณาจำนวนซึ่งไม่เป็นลบ (nonnegative numbers) ต่อไปนี้คือ

$$E_1(g) = |\delta_1| + \dots + |\delta_m| = \sum_{k=1}^m |\delta_k|,$$

ผลบวกสัมบูรณ์ (absolute sum) ของ δ_k 's ... (5a)

$$E_2(g) = \delta_1^2 + \dots + \delta_m^2 = \sum_{k=1}^m \delta_k^2,$$

ผลบวกกำลังสอง (square sum) ของ δ_k 's ... (5b)

$$E_{\infty}(g) = \max\{|\delta_1|, \dots, |\delta_m|\} = \max_{1 \leq k \leq m}\{|\delta_k|\},$$

ค่าสูงสุด (maximum) ของ $|\delta_k|$'s ... (5c)

ซึ่งจะมีค่าเป็นศูนย์ทุกตัวถ้า $g(x_k) = y_k$ สำหรับทุก x_k และจะมีค่าเพิ่มขึ้นเมื่อ δ_k 's เริ่มมีค่าต่างไปจากศูนย์ ไม่ว่าจะ $g(x_k) > y_k$ หรือ $g(x_k) < y_k$ ดังนั้นค่าเล็กของ $E_1(g)$, $E_2(g)$, $E_{\infty}(g)$ หรือ $E(g)$ อื่น ๆ แสดงว่า $g(x)$ fit กับข้อมูลอย่างดี

คำถามที่เกิดขึ้นคือเราควรจะใช้ $E(g)$ ตัวใดช่วยในการตัดสินใจว่า $g(x)$ ใดดีที่สุด

จากวิชาสถิติเราทราบว่า

ถ้าสำหรับแต่ละ k

ตัวแปรเชิงสุ่ม $e_k =$ ความคลาดเคลื่อนของ y_k

มีการแจกแจงแบบปกติ นั่นคือมี Gaussian density function ซึ่งเป็นรูประฆัง แล้ว กำลังสองของความคลาดเคลื่อน (square error) $E_2(g)$ จะเป็นตัวชี้ที่ดีที่สุด เพื่อเป็นตัวกำหนดว่า $g(x)$ จะประมาณ "ความสัมพันธ์ที่แท้จริงของ y บน x " (actual dependence of y on x) ได้ดีหรือไม่ นอกจากนั้นการ minimize $E(g)$ นั้นทำได้ง่ายมากเมื่อ $E(g)$ เป็น $E_2(g)$ ดังนั้นถ้าไม่ระบุเป็นอย่างอื่น $E(g)$ จะหมายถึง $E_2(g)$ และ จะได้ best fit เมื่อเรา

$$\text{minimize } E(g), \text{ โดยที่ } E(g) = \sum_{k=1}^m [g(x_k) - y_k]^2 \quad \dots (6)$$

นั่นคือ เมื่อเราได้ กำลังสองของความคลาดเคลื่อนน้อยที่สุด (least square error)

5.1C ฟังก์ชันที่เป็นเส้นตรง (Straight Line)

เพื่อแสดงการประมาณโดยวิธีกำลังสองของความคลาดเคลื่อนน้อยที่สุด เราจะพิจารณาปัญหาสำคัญของการ fit สมการเส้นตรง โดยจะใช้ฟังก์ชันเดา ในรูปพิเศษดังนี้

$$L(x) = a + bx \quad (a=y\text{-intercept, } b=\text{slope}) \quad \dots(7)$$

กำหนดข้อมูล m จุดคือ $P_1(x_1, y_1), \dots, P_m(x_m, y_m)$ เราต้องการหาค่าของพารามิเตอร์ a และ b ซึ่งทำให้กำลังสองของความคลาดเคลื่อนมีค่าต่ำสุด

$$E(L) = \sum_{k=1}^m [a + bx_k - y_k]^2 = [a + bx_1 - y_1]^2 + \dots + [a + bx_m - y_m]^2 \quad \dots(8)$$

จากวิชาแคลคูลัส เราทราบว่าสิ่งนี้จะเกิดขึ้นเมื่อ

$$\partial E(L)/\partial a = 0 \quad \text{และ} \quad \partial E(L)/\partial b = 0 \quad \dots(9)$$

เนื่องจากว่า x_k 's และ y_k 's เป็นค่าคงที่

$$\begin{aligned} \partial E(L)/\partial a &= \sum_{k=1}^m 2[a + bx_k - y_k] \cdot \partial[a + bx_k - y_k]/\partial a \\ &= 2 \sum_{k=1}^m [a + bx_k - y_k] \\ &= 2[m a + b(\sum_{k=1}^m x_k) - \sum_{k=1}^m y_k] \quad \dots(10a) \end{aligned}$$

$$\begin{aligned} \partial E(L)/\partial b &= \sum_{k=1}^m 2[a + bx_k - y_k] x_k \\ &= 2[a(\sum_{k=1}^m x_k) + b(\sum_{k=1}^m x_k^2) - \sum_{k=1}^m x_k y_k] \quad \dots(10b) \end{aligned}$$

ให้ (10a) และ (10b) เทียบกับศูนย์ ทำให้ได้ระบบเชิงเส้นขนาด (2 x 2)
ซึ่งเรียกว่า **Normal equations**

$$\text{mat} (\Sigma x_k) b = \Sigma y_k \quad \dots (11a)$$

$$(\Sigma x_k) a + \text{mat} (\Sigma x_k^2) b = \Sigma x_k y_k \quad \dots (11b)$$

เขียน (11a) และ (11b) ในรูปเมทริกซ์ดังนี้

$$\begin{bmatrix} m & \Sigma x_k \\ \Sigma x_k & \Sigma x_k^2 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} \Sigma y_k \\ \Sigma x_k y_k \end{bmatrix} \quad \dots (11c)$$

การหาผลเฉลยรูปเดียวของระบบขนาด (2 x 2) (11) คือ $[\hat{a} \ \hat{b}]'$ ให้นำ
จาก $A^{-1}b$

$$\begin{bmatrix} \hat{a} \\ \hat{b} \end{bmatrix} = \frac{1}{m \Sigma x_k^2 - (\Sigma x_k)^2} \begin{bmatrix} \Sigma x_k^2 & -\Sigma x_k \\ -\Sigma x_k & m \end{bmatrix} \begin{bmatrix} \Sigma y_k \\ \Sigma x_k y_k \end{bmatrix}$$

... (12)

เราจะเรียก \hat{a} และ \hat{b} ว่า **least square linear parameters**

ดังนั้นฟังก์ชันค่าเชิงเส้นตรง โดยใช้พารามิเตอร์เหล่านี้คือ

$$\hat{L}(x) = \hat{a} + \hat{b}x \quad \dots (13)$$

ซึ่งจะถูกเรียกว่า เส้นกำลังสองน้อยที่สุด (least square line) หรือ
เส้นของถดถอย (regression line)

ตัวอย่าง จงหาเส้นกำลังสองน้อยที่สุด สำหรับข้อมูลต่อไปนี้

$$P_1(1, 5.12), P_2(3, 3), P_3(6, 2.48), P_4(9, 2.34), P_5(15, 2.18) \dots (14)$$

Solution $n = 5$

$$\Sigma x_k = 34, \Sigma x_k^2 = 352, \Sigma y_k = 15.12, \text{ และ } \Sigma x_k y_k = 62.76 \dots (15)$$

Normal equations (11) คือ

$$\begin{bmatrix} 5 & 34 \\ 34 & 352 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} 15.12 \\ 62.76 \end{bmatrix} \dots (16a)$$

ดังนั้นโดย (12)

$$\begin{bmatrix} \hat{a} \\ \hat{b} \end{bmatrix} = (1/604) \begin{bmatrix} 352 & -34 \\ -34 & 5 \end{bmatrix} \begin{bmatrix} 15.12 \\ 62.76 \end{bmatrix} = \begin{bmatrix} 4.15298 \\ -0.166027 \end{bmatrix} \dots (16b)$$

ดังนั้นเส้นกำลังสองน้อยที่สุดที่ต้องการคือ

$$\hat{L}(x) = \hat{a} + \hat{b}x = 4.153 - 0.1660 x \dots (17)$$

ความคลาดเคลื่อนกำลังสองที่ค่อนข้างใหญ่คือ

$$E(\hat{L}) = \sum_{k=1}^n [\hat{a} + \hat{b}x_k - y_k]^2 = 2.54 \dots (18)$$

ซึ่งค่านี้คือความคลาดเคลื่อนกำลังสองที่เล็กที่สุดที่ *straight-line fit* จะมีค่าได้
แต่เพื่อให้ได้ *a better fit* เราต้องลองใช้ฟังก์ชันเคาแบบ *curved*

5.1D ซึบรoutines ในภาษาฟอร์แทรน สำหรับการหาโค้งกระชับที่เป็นเส้นตรง

ซึบรoutines LINFIT คือ FORTRAN subroutine ซึ่งจะหาค่า slope (SLOPE) y-intercept (YCEPT) และ square error (SQUERR) ของ least square line สำหรับ $(X(K), Y(K))$, $K=1, \dots, M$ SLOPE และ YCEPT ถูกคำนวณโดย (12) ของ 5.1C SQUERR ถูกคำนวณโดยสูตร

$$E(\hat{L}) = \sum_k y_k^2 - [YCEPT \cdot \sum_k y_k + SLOPE \cdot \sum_k x_k y_k] \quad \dots (19)$$

\sum_k ถูกคำนวณใน extended precision เพื่อหลีกเลี่ยงการขาดนัยสำคัญ เมื่อทำการลบใน (19) เมื่อ $E(\hat{L})$ มีขนาดเล็ก

```

00100      SUBROUTINE LINFIT(M, XDAT, YDAT, SQUERR, YCEPT, SLOPE)
00200      DIMENSION XDAT(M), YDAT(M)
00300      DOUBLE PRECISION SIGMAX, SIGMAY, SIGMXY, SIGMX2, SIGMY2
00400      C -----
00500      C THIS SUBROUTINE FINDS THE LEAST SQUARE LINE Y = SLOPE*X + YCEPT C
00600      C FROM DATA PAIRS (XDAT(I), YDAT(I)) AND SQUERR, THE SQUARE C
00700      C (ERROR FOR THIS FIT. IT RETURNS SQUERR, YCEPT AND SLOPE. C
00800      C ----- VERSION 1: 5/1/81 -----
00900      C FORM THE SUMS NEEDED TO SOLVE THE NORMAL EQUATIONS
01000      SIGMAX = 0.00
01100      SIGMAY = 0.00
01200      SIGMXY = 0.00
01300      SIGMX2 = 0.00
01400      SIGMY2 = 0.00
01530      DO 100 K=1, M
01600          SIGMAX = SIGMAX + DBLE(XDAT(K))
01700          SIGMAY = SIGMAY + DBLE(YDAT(K))
01800          SIGMXY = SIGMXY + DBLE(XDAT(K))*DBLE(YDAT(K))
01900          SIGMX2 = SIGMX2 + DBLE(XDAT(K))**2
02000          SIGMY2 = SIGMY2 + DBLE(YDAT(K))**2
02100      100 CONTINUE
02200      C
02300      C SOLVE NORMAL EQUATIONS FOR SLOPE AND YCEPT, AND GET SQUERR
02400      DETER = SNGL(M*SIGMX2 - SIGMAX**2)
02500      YCEPT = SNGL(SIGMX2*SIGMAY - SIGMAX*SIGMXY)/DETER
02600      SLOPE = SNGL(M*SIGMXY - SIGMAX*SIGMAY)/DETER
02100      SQUERR = SNGL(SIGMY2 - YCEPT*SIGMAY - SLOPE*SIGMXY)
02800      C
02900      RETURN
03000      END

```

รูป 5.1-3 LINFIT: ซึบรoutines สำหรับการหาโค้งกระชับที่เป็นเส้นตรง

5.2 การหาโค้งกระชับ (ซึ่งมีพารามิเตอร์ 2 ตัว) สำหรับข้อมูลที่เป็น

Monotone และ Convex

เราจะจำกัดความสนใจของเรากับข้อมูลที่อาจจะ fit กับฟังก์ชันเคา
 $g(x)$ ซึ่งมีลักษณะดังนี้

1) Monotone ซึ่งอาจเป็น strictly increasing หรือ strictly decreasing

2) Convex ซึ่งอาจเป็น concave up หรือ concave down
ในตลอดช่วง fitting interval $[x_1, x_n]$ ดังนั้นเราจะพิจารณาเฉพาะข้อมูล
ที่ไม่มี turning points และไม่มี inflection points ในช่วง $[x_1, x_n]$

ข้อมูลในรูปใน 5.1A เป็น monotone และ convex ทั้งนี้เพราะมีลักษณะ
เป็น strictly decreasing และ concave up ในช่วง $[1, 15]$

ในทางปฏิบัติข้อมูลมักจะเป็น Monotone และ convex ดังนั้นเราจะใช้
ฟังก์ชันเคาดังตัวอย่างต่อไปนี้

$$g(x) = \alpha \exp(\beta x), \quad g(x) = \alpha x^m, \quad g(x) = \alpha t (\beta/x)$$

ซึ่งมีพารามิเตอร์ 2 ตัว คือ α และ β

5.2A Normal Equations สำหรับฟังก์ชันเคาซึ่งมีพารามิเตอร์ 2 ตัว

(Two-Parameter Guess Function)

กำหนด $P_k(x_k, y_k), k=1, \dots, n$ และฟังก์ชันเคาซึ่งมีพารามิเตอร์ 2 ตัวคือ
 $g(x)$ เราต้องการที่จะ

$$\text{minimize } E(g) \quad \text{โดยที่} \quad E(g) = \sum_{k=1}^n [g(x_k) - y_k]^2 \quad \dots(1)$$

ซึ่งทำได้โดยการแก้ normal equations (ซึ่งจะไม่เป็นเชิงเส้นใน α และ β)

$$\partial E(g)/\partial \alpha = 0 \quad \text{และ} \quad \partial E(g)/\partial \beta = 0 \quad \dots (2)$$

เพื่อหา least square parameters $\hat{\alpha}$ และ $\hat{\beta}$ ดังนั้น $g(x)$ ที่ใช้พารามิเตอร์เหล่านี้จะถูกเรียกว่า least square $g(x)$ [$\hat{g}(x)$]

ตัวอย่าง จงหา normal equations สำหรับฟังก์ชันเคาแบบ exponential

$$g(x) = \alpha \exp(\beta x) \quad \dots (3)$$

Solution เราต้องการทำให้กำลังสองของความคลาดเคลื่อนน้อยที่สุด

$$\begin{aligned} E(g) &= \sum_{k=1}^m [\alpha \exp(\beta x_k) - y_k]^2 \\ &= [\alpha \exp(\beta x_1) - y_1]^2 + \dots + [\alpha \exp(\beta x_m) - y_m]^2 \end{aligned}$$

ทำการแก้สมการ normal equations

$$\begin{aligned} 0 = \partial E(g)/\partial \alpha &= \sum_{k=1}^m 2[\alpha \exp(\beta x_k) - y_k] \partial[\alpha \exp(\beta x_k) - y_k]/\partial \alpha \\ &= 2 \sum_{k=1}^m [\alpha \exp(\beta x_k) - y_k] \exp(\beta x_k) \end{aligned}$$

$$\begin{aligned} 0 = \partial E(g)/\partial \beta &= \sum_{k=1}^m 2[\alpha \exp(\beta x_k) - y_k] \partial[\alpha \exp(\beta x_k) - y_k]/\partial \beta \\ &= 2 \alpha \sum_{k=1}^m [\alpha \exp(\beta x_k) - y_k] x_k \exp(\beta x_k) \end{aligned}$$

$$\begin{aligned} &\alpha [\exp(2\beta x_1) + \exp(2\beta x_2) + \dots + \exp(2\beta x_m)] \\ &\quad - [y_1 \exp(\beta x_1) + y_2 \exp(\beta x_2) + \dots + y_m \exp(\beta x_m)] = 0 \quad \dots (4a) \end{aligned}$$

$$\begin{aligned} &\alpha [x_1 \exp(2\beta x_1) + \dots + x_m \exp(2\beta x_m)] \\ &\quad - [x_1 y_1 \exp(\beta x_1) + \dots + x_m y_m \exp(\beta x_m)] = 0 \quad \dots (4b) \end{aligned}$$

ระบบ (4) ไม่เป็นเชิงเส้นใน α และ β ซึ่งในการหาผลเฉลยของ (4) นั้นทำได้โดย

- 1) ไขจุด α แล้ว ใช้วิธีเซแคนต์เพื่อหา β
- หรือ 2) ใช้ NRSYS โดยตรง

ไม่ว่าเราจะใช้วิธีใด เราอาจหาค่าเดาเริ่มต้น $\alpha \approx 4 \frac{1}{2}$ และ $\beta \approx -1/10$ จากกราฟ exponential $g(x)$ อย่างหยาบ ๆ แล้วใช้คอมพิวเตอร์ทำการทำซ้ำต่อไป

สำหรับข้อมูลใน 5.1 นั้นคือ

$$P_1(1, 5.12), P_2(3, 3), P_3(6, 2.48), P_4(9, 2.34), P_5(15, 2.18) \dots (5)$$

least square parameters (to 4s) คือ $\hat{\alpha} \doteq 4.677$ และ $\hat{\beta} \doteq -0.07472$

ดังนั้น least square exponential สำหรับข้อมูลเหล่านั้นคือ

$$\hat{g}(x) \doteq 4.677 \exp(-0.07472 x)$$

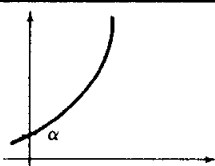
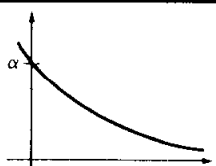
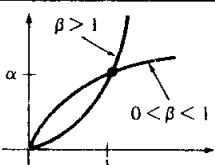
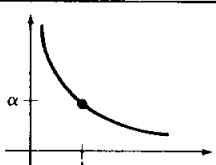
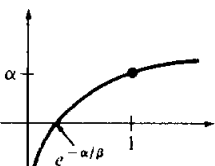
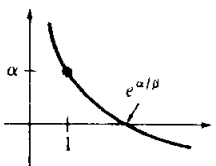
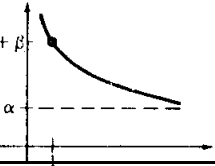
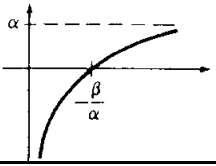
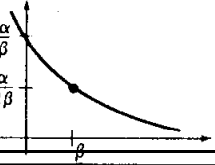
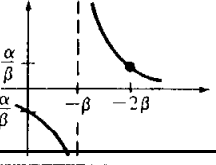
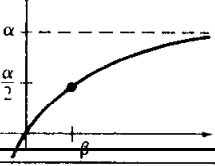
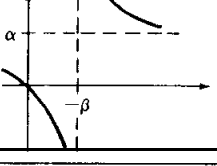
$$\text{จึง } E(\hat{g}) = \sum_{k=1}^n [g(x_k) - y_k]^2 \doteq 1.84 \dots (6)$$

โปรดสังเกตว่า $E(\hat{g})$ ไม่ได้เล็กกว่า $E(\hat{L}) = 2.54$ มากนัก แสดงว่า least square exponential ไม่ได้ fit กับข้อมูลดีกว่า least square line ซึ่งรูป 5.1-1 ก็ยืนยันสิ่งนี้ด้วย

ในหัวข้อนี้ได้แสดงให้เห็นว่า จะเกิดความยุ่งยากมากเมื่อ normal equations ไม่เป็นเชิงเส้น แต่โชคดีที่เราสามารถหา good fit กับข้อมูลที่เป็น monotone และ convex $P_n(x_k, y_k)$ ได้อย่างรวดเร็วโดยการ fit เส้นตรงกับข้อมูล $Q_n(X_k, Y_k)$ ซึ่งจะได้อธิบายในหัวข้อถัดไป


5.2B การปรับให้เป็นเส้นตรง (Linearizing) สำหรับข้อมูลที่ เป็น
Monotone และ Convex

รูปต่อไปคือกราฟของฟังก์ชันเดา 6 ฟังก์ชัน ซึ่งอาจถูกใช้เพื่อ fit กับข้อมูลที่ เป็น monotone และ convex

i	Guess Function	Graph of $g_i(x)$ when $\alpha > 0$	
		$\beta > 0$	$\beta < 0$
1	$g_1(x) = \alpha e^{\beta x}$		
2	$g_2(x) = \alpha x^\beta$		
3	$g_3(x) = \alpha + \beta \ln x$		
4	$g_4(x) = \alpha + \frac{\beta}{x}$		
5	$g_5(x) = \frac{\alpha}{\beta + x}$		
6	$g_6(x) = \frac{\alpha x}{\beta + x}$		

รูป 5.2-1 รูปแสดงฟังก์ชันเดา 6 ฟังก์ชัน สำหรับข้อมูลที่ เป็น Monotone และ convex

ตัวอย่าง สำหรับ P_1, \dots, P_5 ใน (5)



รูป 5.2-2 การปรับให้เป็นเส้นตรงสำหรับ P_1, \dots, P_5 โดยการใช้การเปลี่ยนแปลง

$$Y = y, X = 1/x$$

จากรูปแสดงให้เห็นว่า

- 1) y-axis ($x=0$) เป็น vertical asymptote
- 2) line $y = 2$ เป็น horizontal asymptote
- 3) ไม่มี x- หรือ y-intercepts

จากรูป 5.2-1 curve ที่เป็นไปตามเงื่อนไขทั้ง 3 คือ

$$y = g_a(x) = a + \frac{\beta}{x} \quad (\alpha > 0, \beta > 0) \quad \dots(7a)$$

ดังนั้นเราจึงคาดว่าฟังก์ชันเดาแบบ *hyperbolic* $a + (\beta/x)$ จะ fit กับ P_1, \dots, P_5 ได้ดีกว่า $a + bx$, $\alpha \exp(\beta x)$ หรือ curve ใด ๆ ในรูป 5.2-1 เพื่อเป็นการยืนยัน โปรดสังเกตว่าเราอาจเขียน (7a) ในรูป linear equation ดังนี้

$$Y = L(X) = a + bX, \text{ โดยที่ } a = \alpha \text{ และ } b = \beta, Y = y \text{ และ } X = 1/x \quad \dots(7b)$$

ดังนั้นถ้าเราแปลงจุด $P_k(x_k, y_k)$ ไปเป็นจุด $Q_k(X_k, Y_k)$ โดยที่

$$X_k = 1/x_k \text{ และ } Y_k = y_k \text{ นั่นคือแปลงไปเป็น}$$

$$Q_1(1/1, 5.12), Q_2(1/3, 3), Q_3(1/6, 2.48), Q_4(1/9, 2.34),$$

$$Q_5(1/15, 2.18) \dots (8)$$

แล้ว Q_1, \dots, Q_5 คือเป็นเส้นตรงเมื่อพลอตลงบนแกน-XY [ดูรูป 5.2-2(b)]

พิจารณา (7) จากความจริงที่ว่า $Y_k \approx L(X_k)$ แสดงว่า

$$y_k \approx g_4(x_k) = \alpha + \beta/x_k \text{ สำหรับ } k = 1, \dots, 5$$

โดยการใช้ Natural logarithm กับทั้งสองข้างของสมการ

$$y = g_1(x) = \alpha \exp(\beta x) \text{ และ } y = g_2(x) = \alpha x^n$$

และโดยการจัดการใหม่อย่างตรงไปตรงมากับ $y = g_3(x), \dots, y = g_6(x)$

$y = g_1(x) \text{ อาจถูกแปลงเป็นรูป linear } Y = L(X) = a + bX$

... (9)

เพื่อเป็นตัวอย่าง การแปลง $y = g_5(x)$ คือ

$$y = \alpha / (\beta + x) \langle \text{---} \rangle \beta y = xy = \alpha \langle \text{---} \rangle y = (\alpha/\beta) - (1/\beta)xy$$

นิพจน์สุดท้ายอยู่ในรูป $Y = a + bX$ โดยที่ $a = \alpha/\beta$, $b = -1/\beta$, $X = xy$, และ

$Y = y$ เราเรียกการแปลง $y = g(x)$ ไปเป็น $Y = L(X)$ ว่า **linearizing**

$$y = g(x)$$

ตาราง 5.2-1 การเปลี่ยนแปลง (Transformation) สำหรับการปรับให้เป็นเส้นตรง
ของกราฟ 6 รูป ในรูป 5.2-1

<i>i</i>	$y = g_i(x)$	<i>Linearized Form</i> $Y = L(X) = a + bX$	<i>Transformation Relations</i>					
			$X =$	$Y =$	$a =$	$b =$	$\alpha =$	$\beta =$
1	$y = \alpha e^{\beta x}$	$\ln y = \ln \alpha + \beta x$	x	$\ln y$	$\ln \alpha$	β	e^a	b
2	$y = \alpha x^\beta$	$\ln y = \ln \alpha + \beta(\ln x)$	$\ln x$	$\ln y$	$\ln \alpha$	β	e^a	b
3	$y = \alpha + \beta \ln x$	$y = \alpha + \beta(\ln x)$	$\ln x$	y	a	β	a	b
4	$y = a + \frac{\beta}{x}$	$y = \alpha + \beta \left(\frac{1}{x}\right)_x$	$\frac{1}{x}$	Y	α	β	a	b
5	$y = \frac{\alpha}{\beta + x}$	$y = \frac{\alpha}{\beta} + \frac{-1}{\beta}(xy)$	xy	Y	$\frac{\alpha}{\beta}$	$-\frac{1}{\beta}$	$\frac{-a}{b}$	$\frac{-1}{b}$
6	$y = \frac{\alpha x}{\beta + x}$	$y = \alpha + (-\beta) \frac{y}{x}$	$\frac{y}{x}$	Y	α	$-\beta$	a	$-b$

จากการพิจารณาที่ผ่านมาได้แนะนำเราว่า เราอาจหลีกเลี่ยงการหาผลเฉลยของ normal equations ซึ่งเป็นระบบไม่เป็นเชิงเส้นโดยการให้ Linearization Algorithm ต่อไปนี้

Linearization Algorithm

Purpose: To fit a two-parameter $g(x)$ to the monotone, convex data $P_1(x_1, y_1), \dots, P_m(x_m, y_m)$ when $g(x)$ is one of $g_1(x), \dots, g_6(x)$ in Table 5.2-t.

GET $m, \mathbf{x}, \mathbf{y}$ (arrays of x_k, y_k values)

{linearize} Form the "linearized points" $Q_k(X_k, Y_k)$ from the given points $P_k(x_k, y_k)$ as indicated in the "X =" and "Y =" columns of Table 5.2-l.

(get \hat{a}, b) Get \hat{a} and b for the least square line $\hat{L}(X) = \hat{a} + bX$ for the linearized points $Q_k(X_k, Y_k)$ using the formula

$$\begin{bmatrix} \hat{a} \\ b \end{bmatrix} = \frac{1}{m(\sum X_k^2) - (\sum X_k)^2} \begin{bmatrix} \sum X_k^2 & -\sum X_k \\ -\sum X_k & m \end{bmatrix} \begin{bmatrix} \sum Y_k \\ \sum X_k Y_k \end{bmatrix} \quad (10)$$

{get α, β } Get α and β from \hat{a} and b using the last two columns of Table 5.2-l.

OUTPUT (α and β are the desired parameters of $g(x)$.)

(Note: The $g(x)$ obtained by using α and β of the get α, β step will generally not be the least square $g(x)$, that is, $g(x) \neq \hat{g}(x)$. However, this $g(x)$ will give good fit to the given data P_1, \dots, P_m whenever $\hat{L}(X)$ obtained in the get \hat{a}, b step gives good fit to the linearized data Q_1, \dots, Q_m .)

รูป 5.2-3 รหัสเทียมสำหรับขั้นตอนวิธีในการปรับให้เป็นเส้นตรง
(Linearizing Algorithm)

ตัวอย่าง จงใช้ Linearization Algorithm เพื่อ fit

$$(a) g_4(x) = \alpha t \quad (\beta/x) \quad (b) g_1(x) = \alpha \exp(\beta x)$$

กับข้อมูล

$$P_1(1, 5.12), P_2(3, 3), P_3(6, 2.48), P_4(9, 2.34), P_5(15, 2.18) \quad \dots (11)$$

Solution

(a) Linearize: สำหรับ $g_4(x)$, $X_k = 1/x_k$ และ $Y_k = y_k$

ดังนั้นจุดที่ถูกแปลงแล้วคือ

$$Q_1(1/1, 5.12), Q_2(1/3, 3), Q_3(1/6, 2.48), Q_4(1/9, 2.34), Q_5(1/15, 2.18) \quad \dots (12)$$

Get \hat{a} , \hat{b} : เพื่อหา $\hat{L}(X) = \hat{a} + \hat{b}X$ สำหรับ Q_1, \dots, Q_5 ี่ (10)

$$\begin{bmatrix} \hat{a} \\ \hat{b} \end{bmatrix} = \frac{1}{5(9361/8100) - (151/90)^2} \begin{bmatrix} 9361/8100 & -151/90 \\ -151/90 & 5 \end{bmatrix} \begin{bmatrix} 15.12 \\ 6.9387 \end{bmatrix}$$

$$\doteq \begin{bmatrix} 1.9681 \\ 3.1468 \end{bmatrix}$$

$$\text{ดังนั้น } \hat{L}(X) \doteq 1.968 + 3.147 x$$

Get 4. β : สำหรับฟังก์ชันเคาน์ $\alpha = \hat{a}$ และ $\beta = \hat{b}$

$$g_4(x) \doteq 1.968 + (3.147/x) \quad \dots (13)$$

(b) Linearize: สำหรับ $g_1(x)$, $X_k = x_k$ และ $Y_k = \ln y_k$

ดังนั้นจุดที่ถูกแปลงแล้วคือ

$$Q_1(1, 1.6332), Q_2(3, 1.0986), Q_3(6, 0.90826), Q_4(9, 0.85015), \\ Q_5(15, 0.77832) \quad \dots (14)$$

Get \hat{a}, \hat{b} : เนื่องจากว่า $X_k = x_k$ เมตริกซ์สัมประสิทธิ์จะเหมือนกับใน (16) ใน 5.1C แต่ $[\sum Y_k \quad \sum X_k Y_k]' = [5.2695 \quad 29.7201]'$

ดังนั้น

$$\begin{bmatrix} \hat{a} \\ \hat{b} \end{bmatrix} = (1/604) \begin{bmatrix} 352 & -34 \\ -34 & 5 \end{bmatrix} \begin{bmatrix} 5.2695 \\ 29.720 \end{bmatrix} \doteq \begin{bmatrix} 1.3980 \\ -0.050601 \end{bmatrix} \quad \dots (15)$$

$$\hat{L}(X) \doteq 1.398 - 0.0506 X$$

Get α, β : จากตาราง 5.2-1 $\alpha = \exp(\hat{a}) \doteq \exp(1.398) \doteq 4.047$ และ $\beta = \hat{b} \doteq -0.0506$

ดังนั้น $g_1(x) \doteq 4.047 \exp(-0.0506 x) \quad \dots (16)$

ค่าของพารามิเตอร์ของ $g_1(x)$ ใกล้เคียงกับของ least square

exponential guess function $\hat{g}_1(x) = 4.677 \exp(-0.07472 x)$ ซึ่ง

ได้จากตัวอย่างใน 5.2A


จากรูป 5.2-4 แสดงให้เห็นว่า $g_1(x)$ และ $\hat{g}_1(x)$ fit กับข้อมูลดีพอ ๆ กัน แต่อย่างไรก็ดี

$$E(\hat{g}_1) = 1.64 < 2.24 = \sum_{k=1}^5 [4.047 \exp(-0.0506 x_k) - y_k]^2 = E(g_1) \quad \dots (17)$$

จาก linearized hyperbola $g_4(x)$ ใน (13) จะสอดคล้องกับ

$$E(g_4) = \sum_{k=1}^5 C(1.966 + 3.147/x_k - y_k)^2 = 0.00097 \quad \dots (18)$$

ซึ่งแสดงว่า fit ดีกว่าทั้ง $g_1(x)$ และ $\hat{g}_1(x)$ อย่างมาก ความจริงคือ y_1, \dots, y_5 นั้นได้มาจากการตัดแปลง $2 + 3/x_k$ สำหรับ $k=1, \dots, 5$



รูป 5.2-4 รูปของ \hat{g}_1 , g_1 , และ g_4

5.2C โปรแกรมคอมพิวเตอร์สำหรับการหาโค้งกระชับ สำหรับข้อมูลที่เป็น

Monotone และ Convex

คอมพิวเตอร์ส่วนมากมักจะมีโปรแกรมเพื่อ fit สมการเส้นตรงซึ่งใช้

Linearization Algorithm ในการ fit monotone, convex curves

ทั้ง 6 ในรูป 5.2-1

ต่อไปนี้เป็นตัวอย่างการใช้โปรแกรมในลักษณะดังกล่าว ข้อมูลคือ P_1, \dots, P_5 จากรูป 5.2-5 ในคอลัมน์ SQUARE ERROR นั้นคือค่าของ $E(\hat{L})$ [แทนที่จะเป็น $E(g_1)$] ซึ่งถูกใช้เป็นตัวชี้ว่า $g_1(x)$ นั้น fit กับข้อมูลดีเพียงใด

```

RUN CURFIT

INPUT NUMBER OF DATA PAIRS
3

INPUT X[I] , Y[I] (I=1,N)
1, 5.12
f c 7 - -
6, 2.48
9, 2.34
15, 2.18

CURRENT LISTING OF DATA PAIRS:
1      X[I]      Y[I]
1      1.0000    5.1200
2      3.0000    3.0000
3      6.0000    2.4800
4      9.0000    2.3400
5      15.0000   2.1800

INPUT:          0  IF DATA OK
                -K TO REMOVE (X[K],Y[K])
                K  TO REPLACE (X[K],Y[K])

0

CURVE TYPE      SQUARE ERROR      A      B
1. Y = A + B*X      2.54009      0.41530E+01      -0.16603E+00
2. Y = A*EXP(B*X)    0.16632      0.40471E+01      -0.50603E-01
3. Y = A*(X**B)      0.03069      0.47037E+01      -0.31713E+00
4. Y = A + B*LN(X)   0.68486      0.47119E+01      -0.10826E+01
5. Y = A + B/X       0.011097     0.19681E+01      0.31468E+01
6. Y = A/(B + X)     2.54757     0.52580E+02      0.11914E+02
7. Y = A*X/(B + X)   0.06007     0.22322E+01      -0.57059E+00

EQUATION #5. Y = A + B/X      HAS THE BEST LINEARIZED FIT

INPUT EQUATION # (1-7) FOR DETAILS OF FIT (TYPE "0" FOR NO DETAILS).
5

DETAILS: YCALC IS OBTAINED USING CURVE #5. Y = A + B/X
XDATA      YDATA      YCALC      % DIFF.
1.0000     5.1200     5.1149     0.1
3.0000     3.0000     3.0170     -0.6
6.0000     2.4800     2.4925     -0.5
9.0000     2.3400     2.3177     1.0
15.0000    2.1800     2.1779     0.1
    
```

รูป 5.2-5 การวิ่งโปรแกรม CURFIT

5.3 การหาโค้งกระชับซึ่งเป็นเชิงเส้นในพารามิเตอร์ n ตัว :

Polynomial Fitting

ถ้าข้อมูลที่มีอยู่มีลักษณะที่มี turning points หรือ inflection points แล้วฟังก์ชันเคาซึ่งมีพารามิเตอร์มากกว่า 2 ตัว จึงจะ fit กับข้อมูลอย่างดี

เราพิจารณาฟังก์ชันเคาซึ่งมีพารามิเตอร์ n ตัว: $g(x)$'s โดยที่ $g(x)$ เป็น linear combination ของฟังก์ชันที่ระบุไว้ n ฟังก์ชัน $\phi_j(x)$ นั่นคือ

$$g(x) = \alpha_1 \phi_1(x) + \alpha_2 \phi_2(x) + \dots + \alpha_n \phi_n(x) = \sum_{j=1}^n \alpha_j \phi_j(x) \quad \dots(1)$$

ฟังก์ชันเคาในรูปแบบนี้เป็น linear function ของพารามิเตอร์ $\alpha_1, \alpha_2, \dots, \alpha_n$ และ normal equations ก็จะเป็นระบบเชิงเส้นด้วย ดังนั้นเราสามารถหาผลเฉลยได้โดยวิธีที่ 3

กรณีพิเศษกรณีหนึ่งที่สำคัญคือ การให้ $\phi_j(x) = x^{j-1}$ ซึ่งทำให้ $g(x)$ กลายเป็น $(n-1)$ st-degree polynomial นั้นเอง

$$g_n(x) = \alpha_1 + \alpha_2 x + \alpha_3 x^2 + \dots + \alpha_n x^{n-1} = \sum_{j=1}^n \alpha_j x^{j-1} \quad \dots(2)$$

5.3A Normal Equations สำหรับ $g(x) = \sum_{j=1}^n \alpha_j \phi_j(x)$

สำหรับข้อมูล m จุด : $P_k(x_k, y_k), k=1, \dots, m$

Normal equations คือระบบเชิงเส้นซึ่งอยู่ในรูปเมตริกซ์ต่อไปนี้

$$A_{n \times n} \alpha_{n \times 1} = b_{n \times 1} \quad \dots(3)$$

$$\begin{bmatrix} \Sigma \phi_1(x_k)\phi_1(x_k) & \dots & \Sigma \phi_1(x_k)\phi_n(x_k) \\ \Sigma \phi_2(x_k)\phi_1(x_k) & \dots & \Sigma \phi_2(x_k)\phi_n(x_k) \\ \dots & \dots & \dots \\ \Sigma \phi_n(x_k)\phi_1(x_k) & \dots & \Sigma \phi_n(x_k)\phi_n(x_k) \end{bmatrix} \begin{bmatrix} \hat{\gamma}_1 \\ \hat{\gamma}_2 \\ \vdots \\ \hat{\gamma}_n \end{bmatrix} = \begin{bmatrix} \Sigma \phi_1(x_k)y_k \\ \Sigma \phi_2(x_k)y_k \\ \dots \\ \Sigma \phi_n(x_k)y_k \end{bmatrix}$$

Least square parameter vector $\hat{\gamma} = A^{-1}b = [\hat{\gamma}_1 \ \hat{\gamma}_2 \ \dots \ \hat{\gamma}_n]^T$

ดังนั้น
$$\hat{g}(x) = \sum_{j=1}^n \hat{\gamma}_j \phi_j(x) \quad \dots (4)$$

5.3B Normal Equations สำหรับ $g(x) = \sum_{j=1}^n \gamma_j x^{j-1}$

จากข้อมูล m จุด

$$P_1(x_1, y_1), P_2(x_2, y_2), \dots, P_m(x_m, y_m) \quad \dots (5)$$

และ n ที่ได้กำหนดค่าไว้ก่อนแล้ว ($n =$ จำนวนพารามิเตอร์ นั่นคือ

$$\gamma_1, \gamma_2, \dots, \gamma_n)$$

เราต้องการหา least square parameters $\hat{\gamma}_1, \hat{\gamma}_2, \dots, \hat{\gamma}_n$ ซึ่ง

$$\text{ทำให้กำลังสองของความคลาดเคลื่อนน้อยที่สุด } E(g) = \sum_{k=1}^m (g(x_k) - y_k)^2$$

เราใช้วิธีการทางแคลคูลัส แล้วหาผลเฉลยของ normal equations ซึ่งประกอบด้วย n สมการซึ่งได้จาก (6)

$$\frac{\partial E(g)}{\partial \gamma_i} = 0, \quad i = 1, \dots, n$$

$$\dots (6)$$

$$\text{ถ้า } g_n(x) = \gamma_1 + \gamma_2 x + \gamma_3 x^2 + \dots + \gamma_n x^{n-1} = \sum_{j=1}^n \gamma_j x^{j-1}$$

แล้ว normal equations ในรูปเมทริกซ์คือ $A_{n \times n} \hat{\gamma}_{n \times 1} = b_{n \times 1}$

$$\begin{bmatrix} n & \sum x_k & \sum x_k^2 & \dots & \sum x_k^{n-1} \\ \sum x_k & \sum x_k^2 & \sum x_k^3 & \dots & \sum x_k^n \\ \sum x_k^2 & \sum x_k^3 & \sum x_k^4 & \dots & \sum x_k^{n+1} \\ \dots & \dots & \dots & \dots & \dots \\ \sum x_k^{n-1} & \sum x_k^n & \sum x_k^{n+1} & \dots & \sum x_k^{2n-2} \end{bmatrix} \begin{bmatrix} \hat{\gamma}_1 \\ \hat{\gamma}_2 \\ \hat{\gamma}_3 \\ \vdots \\ \hat{\gamma}_n \end{bmatrix} = \begin{bmatrix} \sum y_k \\ \sum x_k y_k \\ \sum x_k^2 y_k \\ \vdots \\ \sum x_k^{n-1} y_k \end{bmatrix}$$

... (7)

หาผลเฉลยของ (7); $\hat{\gamma} = A^{-1} b$

ตัวอย่าง จงหา least square polynomials $\hat{g}_2(x)$, $\hat{g}_3(x)$, $\hat{g}_4(x)$

สำหรับ $P_1(1,6), P_2(2,1), P_3(4,2), P_4(5,3), P_5(10,4), P_6(16,5)$

... (8)

Solution สำหรับ $g_2(x) = \gamma_1 + \gamma_2 x$ ($n = 2$) และข้อมูลใน (8)

จาก (7) ได้

$$\begin{bmatrix} n & \sum x_k \\ \sum x_k & \sum x_k^2 \end{bmatrix} \begin{bmatrix} \hat{\gamma}_1 \\ \hat{\gamma}_2 \end{bmatrix} = \begin{bmatrix} \sum y_k \\ \sum x_k y_k \end{bmatrix}$$

นั่นคือ

$$\begin{vmatrix} 6 & 38 \\ 38 & 402 \end{vmatrix} \begin{bmatrix} \hat{\gamma}_1 \\ \hat{\gamma}_2 \end{bmatrix} = \begin{vmatrix} 21 \\ 151 \end{vmatrix}$$

... (9)

เมื่อกำหนดผลเฉลยของ (9) คือ $\hat{\gamma}_1$ และ $\hat{\gamma}_2$ ดังนั้น $\hat{g}_2(x) = \hat{\gamma}_1 + \hat{\gamma}_2 x$

สำหรับ $g_3(x) = \gamma_1 + \gamma_2 x + \gamma_3 x^2$ ($n = 3$) และข้อมูลใน (8)
จาก (7) ได้

$$\begin{bmatrix} 6 & 38 & 402 \\ 35 & 402 & 5294 \\ 402 & 5294 & 76434 \end{bmatrix} \begin{bmatrix} \hat{\gamma}_1 \\ \hat{\gamma}_2 \\ \hat{\gamma}_3 \end{bmatrix} = \begin{bmatrix} 21 \\ 151 \\ 1797 \end{bmatrix} \quad \dots(10)$$

เมื่อกำหนดผลเฉลยของ (10) คือ $\hat{\gamma}_1$, $\hat{\gamma}_2$ และ $\hat{\gamma}_3$

ดังนั้น $\hat{g}_3(x) = \hat{\gamma}_1 + \hat{\gamma}_2 x + \hat{\gamma}_3 x^2$

สำหรับ $g_4(x) = \gamma_1 + \gamma_2 x + \gamma_3 x^2 + \gamma_4 x^3$ ($n = 4$) และข้อมูลใน (8)
จาก (7) ได้

$$\begin{bmatrix} 6 & 36 & 402 & 5294 \\ 36 & 402 & 5294 & 76434 \\ 402 & 5294 & 76434 & 1152758 \\ 5294 & 76434 & 1152758 & 17797002 \end{bmatrix} \begin{bmatrix} \hat{\gamma}_1 \\ \hat{\gamma}_2 \\ \hat{\gamma}_3 \\ \hat{\gamma}_4 \end{bmatrix} = \begin{bmatrix} 21 \\ 151 \\ 1797 \\ 24997 \end{bmatrix} \quad \dots(11)$$

เมื่อกำหนดผลเฉลยของ (11) คือ $\hat{\gamma}_1$, $\hat{\gamma}_2$, $\hat{\gamma}_3$, $\hat{\gamma}_4$

ดังนั้น $\hat{g}_4(x) = \hat{\gamma}_1 + \hat{\gamma}_2 x + \hat{\gamma}_3 x^2 + \hat{\gamma}_4 x^3$

แบบฝึกหัดบทที่ 5

5.1 Find "a, \hat{b} and $E(\hat{L})$ for $\hat{L}(x) = \hat{a} + \hat{b}x$, the least square straight line for the data shown in (a) and (b).

(a)	x	0	1	2	3
	y	3.0	1.2	-0.3	-1.5

(b)	x	1.0	1.2	1.4	1.6	1.8
	y	-5	-3	-2	0	3

5.2 Find the normal equations for the following guess functions. Are they linear?

(a) $g(x) = \alpha x^\beta$

[Note: $dx^\beta/d\beta = x^\beta \ln x$]

(b) $g(x) = \alpha x / (\beta + x)$

(c) $g(x) = \alpha \exp(-x) + \beta \exp(-4x)$

(d) $g(x) = \alpha + \beta \sin(\gamma x)$

[Note: The answer is a 3 x 3 systems.]

5.3 (a) Determine graphically from Figure 5.2-1 which of $g(x) = \alpha \exp(\beta x)$ or $h(x) = \alpha x^\beta$ seems best suited to fit the following data:

$P_1(1, 2.3), P_2(2, 6.1), P_3(3, 10.7), P_4(4, 16.0), P_5(5, 21.9), P_6(6, 28.3)$

(b) Use the Linearization Algorithm to fit $g(x)$ and $h(x)$ to the data, and find $E(g)$ and $E(h)$. Do your results confirm your answer to part (a)?

$$\text{Note: } E(g) = E[g(x)] = \sum_{k=1}^n [g(x_k) - y_k]^2$$

$$E(h) = E[h(x)] = \sum_{k=1}^n [h(x_k) - y_k]^2$$

Ans. $g(x) \doteq 1.9942 \exp(0.47962 x)$

$$h(x) \doteq 2.3032 x^{1.3995}$$

(c) Find $E(\hat{L})$ for the linearized data [i.e., $Q_k(X_k, Y_k)$] for $g(x)$ and for $h(x)$. Do your results confirm your answer to part (a)?

$$\text{Note: } E(\hat{L}) = \sum_{k=1}^n [\hat{a} + \hat{b} X_k - Y_k]^2$$

5.4 Do (a)-(c) of the Exercise 5.3 for $g(x) = \alpha/(\beta+x)$,

$$h(x) = \alpha x/(\beta+x), \text{ and } P_1(0.1, 0.04), P_2(1, 0.51), P_3(2, 1.2), \\ P_4(3, 2.2), P_5(4, 3.8), P_6(6, 13.2).$$

Ans. (b) $g(x) \doteq -4.5772/(-6.2710+x);$

$$h(x) \doteq -3.1629 x/(-7.4254 + x)$$

5.5 Do (a)-(c) of Exercise 5.3 for $g(x) = \alpha + \beta \ln x$,

$$h(x) = \alpha + (\beta/x), \text{ and } P_1(1, 0.2), P_2(2, 1.8), P_3(3, 2.6), \\ P_4(5, 3.8), P_5(7, 4.5), P_6(10, 5.3).$$

Ans. (b) $g(x) \doteq 0.21887 + 2.2075 \ln x;$

$$h(x) \doteq 5.0403 - 5.2902 / x$$

5.6 Do (a)-(c) of Exercise 5.3 for $g(x) = \alpha/(\beta+x)$,

$$h(x) = \alpha \exp(\beta x), \text{ and } P_1(1, 0.9), P_2(2, 2.2), P_3(3, 5.4), \\ P_4(4, 13.2), P_5(5, 32.6), P_6(6, 77.4).$$

Ans. (b) $g(x) \doteq -17.499/(-6.1252+x);$

$$h(x) \doteq 0.36979 \exp(0.89295 x)$$