

บทที่ 1
คอมพิวเตอร์ ความคลาดเคลื่อน
และขั้นตอนวิธี

- 1.1 วิธีเคราะห์ใช้ตัวเลข (Numerical Method) คืออะไร ?
- 1.2 เครื่องคำนวณแบบดิจิตอล (digital devices) ทำผิดหรือไม่ ?
- 1.3 เครื่องคอมพิวเตอร์เก็บเลขจำนวนจริง (real numbers)
อย่างไร ?
- 1.4 ความคลาดเคลื่อนในการคำนวณแบบ Fixed-Precision
- 1.5 การหลอกเลี้ยงความคลาดเคลื่อนจากการปัดเศษ
(Roundoff Error)
- 1.6 ความคลาดเคลื่อน ความแม่นยำ และ การทดสอบเบื้องต้น
ความใกล้เคียง
- 1.7 ขั้นตอนวิธีของการทำซ้ำ (Iterative Algorithms)

บทที่ 1

คอมพิวเตอร์ ความคลาดเคลื่อน และขั้นตอนวิธี

1.1 วิธีการวิเคราะห์เชิงตัวเลข (Numerical Method) คืออะไร ?

ในวิชาแคลคูลัสเบื้องต้น เราเรียนวิธีการหาอุปนิสัยและการอินทิเกรตเพื่อให้ได้ผลลัพธ์แน่นอน (exact answers) แต่ใช้ไม่ได้ที่เทคนิคเบื้องต้นทางแคลคูลัส (และไม่ว่าจะซึ้งสูง) เพื่องอ่องอาจเดียวดันไปมุ่งเพื่อใช้งานวิธีการแก้ปัญหาแคลคูลัสตามตัวอย่างต่อไปนี้

ปัญหาที่ 1 หา maximum และ minimum values ชั้งอยู่ในช่วง $[0, 1]$ ของ

$$F(x) = x^6 + 5x^4 - 9x + 1$$

ในการทำนั้นเราต้องแก้สมการ polynomial degree 5 นั่นคือ

$$\frac{dF(x)}{dx} = F'(x) = 6x^5 + 20x^3 - 9$$

ปัญหาที่ 2 หาค่า $\int_a^b e^{-x} dx$ และ $\int_a^b \sin(x)/x dx$ สำหรับค่า $b > 0$

ปัญหาที่ 3 หา $y = y(t)$ ชั้งสอดคล้องกับสมการเชิงอนุพันธ์

$$\frac{dy}{dx} = y^2 + t^2, \quad y(0) = 1 \quad (\text{i.e., } y = 1 \text{ at } t = 0)$$

ปัญหาที่ 4 หา local extrema ของฟังก์ชันของตัวแปร 2 ตัว

$$f(x, y) = xe^y - \ln(2x^2 + y^2) \quad [\ln = \log_e]$$

ชั้งต้องการทำนายการหารากของสมการ 2 สมการต่อไปนี้คือ

$$\frac{\partial f}{\partial x} = e^y - [4x/(2x^2 + y^2)] = 0$$

$$\frac{\partial f}{\partial y} = xe^y - [2y/(2x^2 + y^2)] = 0$$

ถ้าเราลองแก้ปัญหาที่ 1-4 โดยวิธีที่เรียนมา จะพบว่าเป็นไปไม่ได้ที่จะหา

สูตรที่ใช้จะเน้นชี้งจะใช้กับแต่ละปัญหาเพื่อให้ได้ค่าตอบที่ถูกต้อง

ในสภาพการณ์จริงๆนั้นเรามักไม่ต้องการผลลัพธ์ม่นตรง แต่ต้องการผลลัพธ์ซึ่งมีความแม่นยำถึงระดับที่ต้องการเท่านั้น เราจึงใช้วิธีการวิเคราะห์เชิงตัวเลขช่วยในการหาค่าตอบของปัญหา เช่นดังกล่าวข้างต้นได้

1.1A วิธีวิเคราะห์เชิงตัวเลข และการทดสอบเพื่อหยุดการทำงาน (Termination Tests)

คำ **Algorithm** ถูกใช้เพื่ออธิบายวิธีการเป็นขั้นๆ (step-by-step) ซึ่งต้องใช้จำนวนขั้นซึ่งมีจำนวนจำกัด (finite number of step)

วิธีการวิเคราะห์เชิงตัวเลข (Numerical method) คือ ขั้นตอนวิธี (Algorithm) หนึ่งสำหรับการหาค่าเชิงตัวเลขซึ่งมีระดับความแม่นยำตามระดับที่ต้องการ

ตัวอย่าง a. จงอธิบายวิธีวิเคราะห์เชิงตัวเลขสำหรับการหาอนพันธ์

ของฟังก์ชัน f ณ จุด x ให้ได้ที่มีความแม่นยำถึงกศนิยม
ตัวหนึ่งที่ 4* (four-decimal-place accuracy)

b. จงใช้วิธีวิเคราะห์เชิงตัวเลขสำหรับการประมาณ $d \sin x/dx \Big|_{x=0}$
ให้ได้ที่มีความแม่นยำถึงกศนิยมตัวหนึ่งที่ 4

* เมื่อกล่าวว่า " x ประมาณค่า x ด้วยความแม่นยำถึงกศนิยมตัวหนึ่งที่ d "

(x approximates x to d decimal places) หมายความว่า x และ x ต่างกันน้อยกว่า $1/2$ unit. ในกศนิยมตัวหนึ่งที่ d

$$\text{ที่นี่คือ } |x - x| < (1/2) \cdot 10^{-d}$$

ตัวอย่างเช่น $x = 12.45672$, $\bar{x} = 12.45676$

$$|\bar{x} - x| = .00004 < .5 * .0001 = .00005$$

แสดงว่า x ประมาณค่า x ด้วยความแม่นยำถึงกศนิยมตัวหนึ่งที่ 4

Solution

a. เมื่อเราไม่มีสูตรที่ว่าไปสานหับการหาอนุพันธ์ เราจะพิจารณา

ค่าจำากัดความของ

$$f'(x) = df(x)/dx = \lim_{h \rightarrow 0} \Delta f(x)/h$$

(if it exists)

โดยที่ $\Delta f(x)/h = [f(x+h)-f(x)]/h$ (difference quotient
of f at x)

วิธีแก้ปัญหาแบบปกติคือ ประมาณ $f'(x)$ ด้วย $\Delta f(x)/h$ สานหับ h เล็กๆ ค่าของ h ที่เล็กพอจะทำให้แน่ใจว่า $\Delta f(x)/h$ ประมาณค่า $f'(x)$ ถึงกึ่งหนึ่ง ตัวแหน่งที่ 4 นั้นขึ้นอยู่กับฟังก์ชัน ที่กำหนดให้ และจุด x ที่ระบุ เพื่อเป็น การซ้อมก่อนค่าที่เหมาะสมของ h เราเพียงแค่หาค่า $\Delta f(x)/h$ สานหับค่า h ที่ลองเป็นครั้งต้น และหยุดเมื่อ $E(h) = f'(x) - \Delta f(x)/h$ มีค่าเข้าใกล้ 0 ($E(h)$ คือความคลาดเคลื่อนของ การประมาณ)

ถ้าแม้วิธีการห้ามตั้นจะดูง่ายๆ แต่เราต้องทราบค่าของ $f'(x)$ ซึ่งจริงๆแล้ว เราไม่ทราบค่า เพราะเราถ้าลังจะหาค่าของ $f'(x)$ และถ้าเราทราบเราก็ไม่ต้องใช้วิเคราะห์เชิงด้วยเห็นได้ชัด ดังนั้นเราจะทำการหาค่า $\Delta f(x)/h$ ต่อไป เท่านั้น จะก่อว่าค่าที่ "close enough"

เนื่องจากว่าเราต้องคำนวณ $\Delta f(x)/h$ ซึ่งสานหับค่าต่างๆของ h 's จะได้ ทดสอบวิธีคิดกล่าวในโปรแกรม DERIV

ในการใช้ DERIV เราต้องระบุ initial h , a shrinking ratio r และ จำนวนครั้งที่ต้องการคำนวณ ของขั้นต่อไป

```

Calculate and print h and  $\Delta f(x)/h$ 

h <-- h/r { replace h by 'current h)/r }

C*****DERIV: A FORTRAN PROGRAM FOR ESTIMATING F'(X)

C      APPROXIMATE F'(X) BY DQ(H), H=H0,H0/R,...,
C      H0/R**(NREPS-1)

F(X)=SIN(X)           -- Statement function

WRITE(6,1)

1   FORMAT(1X,'ENTER X,H0,SHRINKING RATIO.8 REPETITIONS')

READ(5,*)X,H,R,NREPS

WRITE(6,2)

2   FORMAT(1X,      H',11X,'DQ(H')')

DO 10 N =1,NREPS

DQ=(F(X+H)-F(X))/H

WRITE(6,3)H,DQ

3   FORMAT(E13.5,2X,F11.6)

H=H/R

10  CONTINUE

STOP

END

```

Solution

b. เราพบปัญหาในการหาค่า h ซึ่งต้องเลือกพื้นที่จากให้ $\Delta f(x)/h$ ประมาณ $f'(x)$ ได้ตามความแม่นยำที่ต้องการ

เนื่อง $f(x) = \sin x$ และ $x = 0$

จ้าเราเลือก $H_{\text{initial}} = 1$

R : shrinking ratio 4

และ NREPS = 8

run DERIV ด้วยค่าข้างต้นได้ผลดังนี้

ENTER X, H0, SHRINKING RATIO, # REFETTTIONS

0,1,4,8

คอลัมน์ที่ ^{ที่} เลื่อนเพรากระบค่า $F'(X) = 1$

H	DQ(H)	$E(H) = F'(X) - DQ(H)$
0.10000E+01	0.841471	0.156529
0.25000E+00	0.989616	0.010384
1/16 = 0.62500E-01	0.999349	0.000651 ≈ E(1/16)
1/64 = 0.15625E-01	0.999959	0.000041 ≈ E(1/64)
1/256 = 0.39063E-02	0.999997	0.000003
0.97656E-03	1.000000	0.000000
0.24414E-03	1.000000	0.000000
0.61035E-04	1 .000000	0.000000

$$h = 1/16 = 0.0625 \rightarrow DQ(h) = 0.999; \text{ (เข้าศูนย์ 4 ตำแหน่ง)}$$

$$h = 1/64 = 0.015625 \rightarrow DQ(h) = 1.0000 \text{ (เข้าศูนย์ 4 ตำแหน่ง)}$$

ดังนั้น $h = 1/64$ จึงเลือกพอก็จะทำให้แน่ใจว่า $\Delta f(x)/h$ ประมาณ $\sin'(0)$
ได้แม่นยำถึงศูนย์มตำแหน่งที่ 4

(*) โปรดสังเกตว่า

$$DQ(1/64) - DQ(1/16) = 0.999959 - 0.999349 = 0.000610 \approx E(1/16)$$

$$DQ(1/256) - DQ(1/64) = 0.999997 - 0.999959 = 0.000038 \approx E(1/64)$$

โดยทั่วไป ผลต่างระหว่างค่าประมาณที่ต่อเนื่องกัน
นั้นคือ $\Delta DQ = DQ(h) - DQ(\text{preceding } h)$

คือเลขจำนวนซึ่งสามารถหาได้โดยไม่ทราบ $f'(x)$ และจะถูกใช้เพื่อประมาณค่า error of DQ (preceding h) สิ่งที่ตามมาคือ แทนที่จะห้องบัญชีช้าทั้ง NREPS ครั้ง เราจะหดเวลาที่ทำเนื่องจากของ ΔDQ นี้ค่าเล็กมาก

(**) เงื่อนไขที่เหมาะสมสำหรับ four-place accuracy คือ

$$|\Delta DQ| < 10^{-4}$$

เมื่อพิจารณา (*) แล้ว จะพบว่า termination test (**) จะเป็นเหตุให้หยุดการทำซ้ำหลังจากพิมพ์ $H = 1/256$ และ $DQ = 0.999997$ แล้ว

1.1B ทำไมต้องใช้ Programmable Device สานรับการวิเคราะห์ใช้ตัวเลข ?

จากตัวอย่างที่ผ่านมาได้แสดงให้เห็นว่าลักษณะ 3 ประการของคอมพิวเตอร์ (หรือ programmable calculator) ตั้งต่อไปนี้เหมาะสมกับวิเคราะห์ที่ใช้ตัวเลข คือ

1. ความยืดหยุ่น (Flexibility)

โปรดสังเกตว่าเราสามารถเปลี่ยน $F(X)$ ในบรรทัดที่ 4 ของโปรแกรม DERIV ได้ เพื่อปรับกรณีถูกเก็บในหน่วยความจำ เราประมาณ $f'(x)$ ที่ค่าของ x ใดๆด้วยความแม่นยำถึงทศนิยมห้าหลักที่ต้องการได้ง่ายๆโดยการเปลี่ยน $F(X)$ ตามต้องการ แล้ว enter ค่าต่างๆของ H , R และ NREPS จะหัวงการปฎิบัติงาน

2. ความนีประสึกภาพ (Efficiency)

ขั้นตอนวิธีใน DERIV เป็นแบบอย่างของขั้นตอนของวิธีการวิเคราะห์ที่ใช้ตัวเลข ในการคำนวณการหนึ่ง (calculate the next DQ, output H and DQ แล้ว shrink H) ถูกกระทำจนกระทั่งนิพจน์ที่ใช้เป็นเงื่อนไขของการหยุดทำงาน เป็นจริง ขั้นตอนวิธีดังกล่าวถูกเรียกว่า ขั้นตอนวิธีสานรับการทำซ้ำ ("iterative" algorithm) การใช้โปรแกรมอย่างนี้ประสึกภาพ นั้นทำได้โดยใช้ loop ดังในตัวอย่าง

โปรแกรม DERIV ตั้งแต่

DO 10 N = 1,NREPS

:

10 CONTINUE

3. ความเร็ว และ ความเชื่อถัน (Speed and Reliability).

หลังจากที่โปรแกรมดูก็ใช้แล้วและให้ข้อมูลเข้าที่จำเป็น โปรแกรมจะดูกับมีผลตามด้วยความเร็วที่เร็วกว่าและเชื่อถือได้มากกว่าที่คนคนใดคนหนึ่งจะทำได้

1.2 เครื่องคานวณแบบดิจิตอล (Digital Devices) ทำผิดหรือไม่ ?

Digital devices often give erroneous answers.

ข้อศรี๊บหื่นเกิดขึ้นบ่อยทั้งหมดของ ค่าตอบที่ไม่ถูกต้อง เกิดจาก human error เช่น

เกิดจาก Programmer กำหนดตรรกะ (logic) ผิดในโปรแกรม

เกิดจาก Keypuncher พิมพ์โปรแกรมผิดหรือข้อมูลเข้าผิด

เกิดจาก User ให้ข้อมูลเข้าผิดๆ ใช้สูตรหรือวิธีการที่ผิด

ความคลาดเคลื่อนทั้งหลายนั้นแก้ได้โดยการค้นหาให้พบแล้วแก้ไขถูกต้อง

1.2A ตัวอย่างของความคลาดเคลื่อนซึ่งเกิดจากเครื่องคานวณแบบดิจิตอล

ตัวอย่าง

$$\text{ให้ } A = (1-\cos x)/x^2, \quad B = \sin^2 x/[x^2(1+\cos x)]$$

ถ้าคุณ A ตัวอย่าง $(1+\cos x)/(1+\cos x)$ จะเห็นว่า A และ B เท่ากัน
สำหรับ x ที่ไม่เป็น 0 ทั้งนี้ $\cos x \neq -1$

If $x = 0 + 0.11$, then $A = B = 0.499583$; if $x = \pi + 0.1$, then $A = B = 0.189857$
 If $x = 0 + 0.01$, then $A = B = 0.499996$; if $x = \pi + 0.01$, then $A = B = 0.201353$
 If $x = 0 + 0.001$, then $A = B = 0.500000$; if $x = \pi + 0.001$, then $A = B = 0.202513$
 If $x = 0 + 0.0001$, then $A = B = 0.500000$; if $x = \pi + 0.0001$, then $A = B = 0.202629$
 If $x = 0 + 0.00001$, then $A = B = 0.500000$; if $x = \pi + 0.00001$, then $A = B = 0.202641$

ค่า A และ B ก็แสดงไว้ได้ถูกบัดเศษให้เหลือทศนิยมเพียง 6 ตำแหน่ง
ต่อไปนี้เป็นตัวอย่างโปรแกรมที่ทำการหาค่าของ A และ B จากค่าของ x ทึ้ง

10 ค่าใช้จ่ายต้น

```

00100 C * * * * * ★ * * ERROR * ★ * * * * * ★ * * *
00200 C THIS PROGRAM DEMONSTRATES DIGITAL DEVICE ERRORS
00300 C
00400 DATA IW, IR /5, 5/
00500 WRITE(IW,1)
00600 I FORMAT('ENTER THE LIMITING VALUE OF X')
00700 READ(IR,*) XLIMIT
00800 C
00900 H = 0.1
01000 DO 10 K=1, 5
01100 X = XLIMIT + H
01200 C
01300 A = (1 - COS(X))/X**2
01400 B = (SIN(X)/X)**2/(1 + COS(X))
01500 C
01600 WRITE (IW,2) X, A, B
01700 2 FORMAT(' IF X=^,F9.6,' THEN A='E13.6,
01800 & ,1 AND B='E13.6)
01900 H = H/10
02000 10 CONTINUE
02100 STOP
02200 END

ENTER THE LIMITING VALUE OF X
0

IF X= 0.100000 THEN A= 0.499584E+00 AND B= 0.499583E+00
IF X= 0.010000 THEN A= 0.500008E+00 AND B= 0.499996E+00
IF X= 0.001000 THEN A= 0.506639E+00 AND B= 0.500000E+00
IF X= 0.000100 THEN A= 0.745058E+00 AND B= 0.500000E+00
IF X= 0.000010 THEN A= 0.000000E+00 AND B= 0.500000E+00

ENTER THE LIMITING VALUE OF X
3.14159265

IF X= 3.241593 THEN A= 0.189857E+00 AND B= 0.189857E+00
IF X= 3.151593 THEN A= 0.201353E+00 AND B= 0.201346E+00
IF X= 3.142593 THEN A= 0.202513E+00 AND B= 0.199852E+00
IF X= 3.141693 THEN A= 0.202629E+00 AND B= 0.135837E+00
%FRSAPR Floating divide check PC= 235

IF X= 3.141603 THEN A= 0.202641E+00 AND B= 0.170141E+39

```

รูป 1.2-1 โปรแกรมภาษาฟอร์TRAN เพื่อหาค่า A และ B ให้ล 0 และ 1

จากตัวอย่างการวิ่งโปรแกรมจะเห็นว่า คอมพิวเตอร์คำนวณค่าของ B ได้
แทนค่าเมื่อ x มีค่าิกล์ 0 และค่าน้ำผล A ได้แทนค่าเมื่อ x มีค่าิกล์ π
และให้ค่าที่ใช้ไม่ได้เมื่อค่าน้ำผล A จากค่า x ิกล์ 0 และค่าน้ำผล B จากค่า
x ิกล์ π

ดังนี้จากตัวอย่างแสดงว่า

Computers make no judgment about the correctness of the values they produce; they will display nonsensical answers as neatly and authoritatively as correct ones.

เราจะประสมปัญหา ก้าเราเขื่อว่า A = 0 เมื่อ x = 0.00001 เพราะว่า
คอมพิวเตอร์ให้ค่าตอบเช่นนี้

1.2B ความคลาดเคลื่อนในการใช้สูตรกำลังสอง (Quadratic Formula)

ในการหาราก 2 รากของสมการกำลังสอง $ax^2 + bx + c = 0$ ($a \neq 0$)
โปรแกรมและตัวอย่างการวิ่งโปรแกรมต่อไปนี้แสดงความคลาดเคลื่อนที่อาจเกิดขึ้นเมื่อ
ห้ากของสมการข้างต้น

```

00100 C * * * * * * * * * QUAD   ☐ ☐ * * ☐ • • • * * * ☐ * *
00200 C THIS PROGRAM DEMONSTRATES ERRORS THAT CAN OCCUR WHEN USING
00300 C THE QUADRATIC FORMULA TO FIND THE REAL ROOTS OF A*X**2+B*X+C
00400 C
00500 DATA IW, IR /5, 5/
00600 WRITE(IW,1)
00700 1 FORMAT('FOR REAL ROOTS OF AX**2+BX+C, INPUT A, B, C')
00800 READ(IR,*) A, B, C
00900 C
01000 E1 = -0.5*B/A
01100 CI = CIA
01200 DISC = B1*B1 - CI
01300 IF (DISC .GE. 0.) GOTO 20
01400 WRITE(IW,2)
01500 2 FORMAT(' ROOTS ARE COMPLEX')
01600 STOP
01700 C
01800 C     REAL ROOTS: FIND THEM AS R(+), C1/R(+) AND AS R(-), C1/R(-)
01900 20 D1 = SQRT(DISC)
02000 RPLUS = B1 + D1
02100 RMNU = B1 - D1
02200 R2PLUS = CI/RPLUS
02300 R2MINU = CI/RMINU
02400 C
02500 WRITE(IW,3) RPLUS, RMNU, R2PLUS, R2MINU
02600 3 FORMAT(' ROOTS:      R(+) = ',E13.6,5X,', R(-) = ',E13.6,
02700 &           /'          C1/R(+) = ',E13.6,5X,',C1/R(-) = ',E13.6)
02800 STOP
02900 END

```

รูป 1.2-2 โปรแกรมภาษาฟอร์tran เพื่อคำนวณ $r(+)$, $r(-)$, $c_1/r(+)$,
และ $c_1/r(-)$

FOR REAL ROOTS OF $AX^{**}2+BX+C$, INPUT A, B, C
2, 9, -5

ROOTS: $R(+)$ = $0.500000E+00$ $R(-)$ = $-0.500000E+01$
 $C1/R(+)$ = $-0.500000E+01$ $C1/R(-)$ = $0.500000E+00$

FOR REAL ROOTS OF $AX^{**}2+BX+C$, INPUT A, B, C
1, -100.01, ~

ROOTS: $R(+)$ = $0.100000E+03$ $R(-)$ = $0.100002E-01$
 $C1/R(+)$ = $0.100000E-01$ $C1/R(-)$ = $0.999977E+02$

FOR REAL ROOTS OF $AX^{**}2+BX+C$, INPUT A, B, C
1, +100.01, 1

ROOTS: $R(+)$ = $-0.100002E-01$ $R(-)$ = $-0.100000E+03$
 $C1/R(+)$ = $-0.999977E+02$ $C1/R(-)$ = $-0.100000E-01$

ในที่นี้ $b_1 = -b/2a$, $c_1 = c/a$ และ $d_1 = \sqrt{b_1^2 - c_1}$

$$r(+) = b_1 + d_1, \quad r(-) = b_1 - d_1$$

$$r(+)r(-) = b_1^2 - d_1^2 = c_1$$

ดังนั้น $r(+) = c_1/r(-)$, $r(-) = c_1/r(+)$ ทั้งนี้ห้ามต้อง ≠ 0

จากตัวอย่างที่ผ่านมาใน 1.2A และ 1.2B ความคลาดเคลื่อนที่เกิดขึ้นจะไม่เป็น⁴
เอกลักษณ์ (unique) สำหรับคอมพิวเตอร์ทุกเครื่อง

เราต้องทราบที่มากของความคลาดเคลื่อนแล้วแก้ไขหรือทำให้เกิดน้อยที่สุด และเรา⁵
ต้องรู้วิธีการเก็บเลขจำนวนจริงในหน่วยความจำของคอมพิวเตอร์ รวมทั้งการ
คำนวณโดยใช้คอมพิวเตอร์ที่ทำการคำนวณด้วย Fixed-Precision

1.3 เครื่องคิดเลขเชิงเส้นและจำนวนจริง (Real Numbers) あたりไร?

1.3A ເລກຕານສອງ (Binary Numbers)

เลขฐานสองจำนวนหนึ่งคือเลขจำนวนจริง x ซึ่งอาจถูกเขียนได้ในรูป

$$X = \lfloor (b_n 2^n + b_{n-1} 2^{n-1} + \dots + b_1 2^1 + b_0) \rfloor + (b_{-1} 2^{-1} + b_{-2} 2^{-2} + \dots + b_{-k} 2^{-k})$$

integer part of X fractional part of X

..... (*)

ໄດຍກ່ b_i ດີວ່າ bit (binary digit) ຊິ້ງຄວາມເປັນ 0 ມີກໍາ 1

นิพจน์ (*) เราก็เรียกว่า binary expansion of X หรือเรียกชื่อ ๆ ว่า

binary representation

୧୯୮୫

$$X = \pm(b_n b_{n-1} \dots b_1 b_0.b_{-1} b_{-2} \dots b_{-k})_2 \quad \text{ถ้า } b_i \text{ มีค่า } 0 \text{ หรือ } 1$$

binary point

(n+1)-bit integer k-bit fraction

๕๒๙๖

$(11\dots1)_2 = 2^m - 1$ is the largest m-bit integer

三

ตัวอักษร

$(11111)_2 = 2^5 - 1 = 31$ เป็น the largest 5-bit integer
 และ $(0.111)_2 = 1 - 2^{-3} = 7/8$ เป็น the largest 3-bit fraction

1.3B การเก็บเลขจำนวนเต็ม (Integers)

1 word = 32 bits

เลขจำนวนเต็ม X ที่จะเก็บได้ในที่ 32 bits คือ

$$|X| \leq (2^{31} - 1) = 2,147,483,647$$

การพยายามที่จะเก็บเลขจำนวนเต็มที่มีขนาดใหญ่กว่า $(2^{31} - 1)$ จะทำให้เกิด

integer overflow

bit no.	31	30	29	28	27	26	25	24	23	22	21	20	...	3	2	1	0
	0	0	0	1	0	1	1	0	0	1	0	0		0	0	0	1

← 31 bits for the integer's binary →
 sign bit(0 for +, 1 for -) representation

รูปแสดงการเก็บเลขจำนวนเต็มในที่ขนาด 32 bits

1.3C การเก็บ Floating-Point Representations ของเลขฐานสอง (Binary Numbers)

ทุกๆ nonzero binary number X ถูกแสดงไว้ด้วย

$$X = \pm M \cdot 2^e \text{ โดยที่ } M = + (0.1b_{-2} b_{-3} \dots b_{-k})_2$$

และ e = เลขจำนวนเต็มตัวหนึ่ง

เรียกว่า normalized floating-point (binary) representation ของ X

ตัวอย่าง

ตาราง 1.3-1 การเปลี่ยนในรูป Normalized Floating-Point

<i>X</i>	<i>Binary Representation</i>	<i>Normalized Binary</i>	<i>Floating-Point Representation</i>
-3.5	'(1 1.1) ₂	-(0.1 11) ₂ • 2 ² , that is, $M = (0.1 11)_2$ and $c = 2$	
$\frac{7}{8}$	(0.111) ₂	(0.1 11) ₂ • 2 ⁰ , that is, $M = (0.111)_2$ again, but $c = 0$	
$\frac{1}{16}$	(0.0001) ₂	(0.1) ₂ • 2 ⁻³ , that is, $M = (0.1)_2$, and $c = -3$	

ค่าว่า Normalized นั้นมาจากค่าที่ k-bit fraction M (ซึ่งเรียกว่า mantissa) ที่ $b_{-1} = 1$ ดังนั้น $M \geq 1/2$

ส่วนค่าว่า floating point นั้นอ้างถึงค่าที่เลขจำนวนเต็ม c (ซึ่งเรียกว่า characteristic หรือ exponent ของ X) ถูกปรับค่าเพื่อทำให้ binary point นั้นอยู่ทางซ้ายของ 1 (คือ b_{-1}) ใน binary representation ของ X (นั่นคือเพื่อทำให้ $b_{-1} = 1$ นั่นเอง)

เครื่องคำนวณแบบคิดตัลกุ่กเครื่องจะเก็บ mantissa ในรูปที่ normalized แล้ว ทั้งนี้เพื่อให้แน่ใจว่าได้เก็บ bit ของ M มากที่สุดเท่าที่จะเป็นได้

ตัวอย่าง

$$1/5 = 0.2 = (0.0011001100110011\dots)_2$$

นั้นอาจถูกเก็บใน 6-bit mantissa device ดังนี้

$$\text{Not normalized: } (0.001100)_2 \cdot 2^0 = 1/8 + 1/16 = 3/16$$

$$(\text{error} = 1/5 - 3/16 = 1/80)$$

$$\text{Normalized: } (0.110011)_2 \cdot 2^{-2} = (1/2 + 1/4 + 1/32 + 1/64) \cdot 1/4 = 51/256$$

$$(\text{error} = 1/5 - 51/256 = 1/1280)$$

Normalized representation มีความแม่นยำมากกว่า
Not normalized representation ถึง 16 เท่า ทั้งนี้ เพราะไม่เสีย 2 bits
เพื่อเก็บ (nonsignificant) leading zeros ของ M

Bit no.	31	30	29	28	27	26	25	...	9	8	7	6	5	4	3	2	1	0
	0	1	1	1	0	1	0		0	0	0	0	0	0	1	1	0	

23-bit for M 7-bit for $|c| \rightarrow$
 sign of X (+) bit ที่ไม่ปรากฏ คือ 0 sign of c (+)

รูปแสดงการเก็บ a floating point binary representation ใน a 32-bit word

$$\text{จากรูป } c = +(0000011)_2 = +3$$

$$M = (0.11101)_2 \text{ และ sign bit ของ } X \text{ คือ } 0 \text{ (ส่วนบวก +)}$$

$$\text{ดังนั้น } x = +(0.11101)_2 \cdot 2^3 = +(111.01)_2 = 7.114$$

1.3D 23-bit Mantissa Device สามารถเก็บเลขจำนวนใดได้บ้าง ?

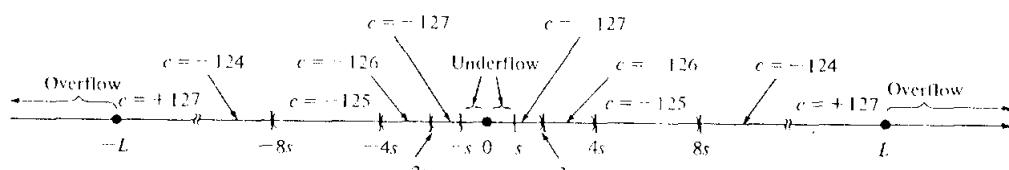
เราจะเขียน nonzero binary number ว่า X representable
ถ้าเลขฐานสองจำนวนนั้นสามารถถูกเก็บได้ตามรูปบน มันคือถ้า

$$X = \pm M \cdot 2^c \text{ โดยที่ } M \text{ คือ normalized 23-bit fraction}$$

$$\text{และ } |c| \leq 127 \quad \dots (7)$$

$$\frac{1}{2} = (0.10 \dots 0)_2 \leq M \leq (0.11 \dots 1)_2 = 1 - 2^{-23} \text{ (ทั้งนี้ } b_{-1} \text{ ต้องเป็น } 1)$$

$$\text{ดังนั้น } (1/2)2^c \leq M \cdot 2^c \leq 1 \cdot 2^c \text{ (ทั้งนี้เพื่อ } M < 1)$$



รูป 1.3-1 ช่วงส่วนบวก c ค่าต่างๆ กัน

และเนื่องจากว่า $-127 < c < 127$

และ $1/2 < M \leq 1 - 2^{-23}$

ดังนั้น $s = (1/2)2^{-127} = 2^{-128} = 2.938736... \times 10^{-39}$ คือ smallest

representable $X > 0 \quad \dots (8)$

และ $L = (1 - 2^{-23})2^{127} = 1.70141... \times 10^{38}$ คือ largest

representable $X \quad \dots (9)$

ถ้าพอยต์อเวฟฟ์ $x = \frac{\text{ชิ้ง } x}{2^k} > L$ แล้ว จะทำให้เกิด
floating-point overflow

ในท่านองเดียวถ้า ถ้าพอยต์อเวฟฟ์ $x = \frac{\text{ชิ้ง } x}{2^k} < 0$ $\frac{\text{ชิ้ง } x}{2^k} < s$ จะทำให้เกิด
floating-point underflow

1.3E ความคลาดเคลื่อนแบบผึ่งติด (Inherent Error)

เลขจำนวนจริง x ส่วนมากจะไม่สามารถถูกเก็บอย่าง exactly ใน k -bit mantissa device เครื่องจะเก็บค่าประมาณ คือ $x = \pm M \cdot 2^c$ ซึ่งมี error ใน the least significant bit ของ M (นั่นคือ b_{k-1})
เราเรียก error นี้ว่า ความคลาดเคลื่อนแบบผึ่งติดในการเก็บค่า x ซึ่งจะมีค่าน้อยกว่า 2^{-k}

ถ้า $k = 23$ และ M จะมีความคลาดเคลื่อนน้อยกว่า $2^{-23} \approx 1.2 \times 10^{-7}$
ดังนั้น 23-bit mantissa device จะเก็บเลขจำนวนจริง x ได้แม่นยำถึง
ประมาณ 7 ตัวเลขหลัง小数 (7 significant digits)

ตัวอย่าง

$$x = 0.1 = 0.8 \times 2^{-3}, \quad x = M \cdot 2^c$$

23 bits

$$M = \underbrace{(0.11001100110011001100110)}_e = 6,710,886/8,388,608 \\ = 0.7999999523...$$

ดังนั้น $x = 0.1$ จะเก็บอยู่ในค่าซึ่งเล็กกว่าค่าจริง

$$x = (0.7999999523\ldots).(1/8) = 0.09999999404\ldots$$

*To minimize inherent roundoff, variables x that are input as decimals should be entered rounded to as many significant digits as can possibly be stored on the device used.

จากตัวอย่างการวิ่งโปรแกรมในหัวข้อ 1.2A นั้น สำหรับเครื่องที่เก็บได้ 8 significant digits เราจะ enter ค่า $\pi = 3.1415927$

1.4 ความคลาดเคลื่อนในการคำนวณแบบ Fixed-Precision

1.4A Decimal-Place UP:: Significant-Digit Accuracy

“leading significant digit” ของเลขคณิตคือ “leftmost nonzero digit”

ตั้งนี้ $-0.\overbrace{00666667}^{8d}$ approximates $-1/150$
 $\underbrace{}_{6s}$

นั่นคือ $-1/150 = -0.00666667(6s)$

หรือ $-1/150 = -0.00666667(8d)$

$4 \frac{1}{9} = 4.011111\ldots = 4.01(2d \text{ หรือ } 3s)$

$4 \frac{1}{9} = 4.011(3d \text{ หรือ } 4s)$

ที่สำคัญ, ชื่อ

$-1/150 \approx -0.00666667$

$4 \frac{1}{9} \approx 4.01 \text{ และ } 4 \frac{1}{9} \approx 4.011$

Every digital device has a fixed precision that can be described in terms of the number of significant digits that it can accurately store in one word.

ตัวอย่าง ส่วนรับ 23-bit mantissa device ที่สามารถเก็บเลขจํานวนได้ด้วย
ความแม่นยำประมาณ 7 ตัวเลขหลังคาบตัวที่ 7s device

real numbers: x, y, z, ... (ใช้ lower case)

ค่า approximate: X, Y, Z, ... (ใช้ upper case)

ตั้งขึ้นใน 7s device: $x = X(7s)$

1.4B การคำนวณแบบ Fixed-Precision

พิจารณาเครื่องคิดเลขชนิด 4s, ฐาน 10

$$X = \pm M \cdot 10^c, \quad M = +0.d_1 d_2 d_3 d_4 \quad (d_1 \neq 0 \text{ if } X \neq 0)$$

c เลขจํานวนเดียวซึ่งมีค่าระหว่าง -9 ถึง 9

(Normalized floating-point(decimal) representation)

ตั้งขึ้น $x = -1/150$ จะถูกเก็บเป็น $X = -0.6667 \times 10^{-2}$ ($M = 0.6667, c = -2$)
 $y = 4 \frac{1}{9}$ จะถูกเก็บเป็น $Y = 0.4011 \times 10^1$ ($M = 0.4011, c = +1$)

ค่าบวกที่เล็กที่สุดและใหญ่ที่สุดคือ $S = 0.1000 \times 10^{-9} = 10^{-10}$
 และ $L = 0.9993 \times 10^9 = 999,900,000$

ให้ "o" แทน $+$, $-$, $*$, $/$

ในการคำนวณหา $x o y$ จะหา $x \hat{o} y$ แทน โดยที่

$(**) x \hat{o} y$ หมายความว่า: WI $\times 0$ Y อย่างน้อย 5s แล้วปัดเศษให้เหลือ 4s

เราเรียกว่า "4s arithmetic" ซึ่งอาจเป็นผลให้เกิดความคลาดเคลื่อน
หล่ายุทธนิต

1.4C ความคลาดเคลื่อนในการคำนวณแบบ Fixed-Precision

ban 5 จำนวนศูนย์

$x=8846.4, y=0.0012495, z=0.40366, u=0.4037681, w=50$ และจะถูกเก็บ
ใน 4s device ดังนี้

$$X=0.8846 \times 10^4, Y=0.1250 \times 10^{-2}, Z=0.4037 \times 10^0, W=0.4038 \times 10^0
และ U=0.5000 \times 10^2$$

การคำนวณตาม (**) ในหัวข้อ 1.4B จะเกิด errors ต่างๆ เช่น

$$x+y=8846.4012495 \neq x, \quad \text{แต่ } \hat{x} + \hat{y} = 8846 = X \quad (1)$$

$$z+w=0.8074281 \neq 0.8074, \quad \text{แต่ } \hat{z} + \hat{w} = \hat{z}+\hat{w} = 0.8075 \quad (2)$$

$$z-y=0.4024105 \neq 0.4024, \quad \text{แต่ } \hat{z} - \hat{y} = 0.4025 \quad (3)$$

$$x^2=78,258,793(8s) \neq 0.7826 \cdot 10^8, \quad \text{แต่ } \hat{x} \cdot \hat{x} = 0.7825 \cdot 10^8 \quad (4)$$

$$u/y=40016.0(6s) \neq 0.4002 \cdot 10^5, \quad \text{แต่ } \hat{u} / \hat{y} = 0.4000 \cdot 10^5 \quad (5)$$

$$z-w=-0.0001081 \neq -0.1081 \cdot 10^{-3}, \quad \text{แต่ } \hat{z} - \hat{w} = -0.0001 = -0.1000 \cdot 10^{-3} \quad (6)$$

(1)-(5) แสดงความคลาดเคลื่อนแพร์โซริจจากรากของผลการปัดเศษ

(propagated roundoff error)

(1) แสดงการบวกเลขที่มีขนาดใหญ่มากๆ กับเลขที่มีขนาดเล็กมากๆ ซึ่งผลบวกก็คือ
เลขจำนวนที่มีขนาดใหญ่ที่สุดของ

(2)-(5) แสดงว่า ถึงแม้ว่าเราจะปัดเศษ X และ Y ให้มีตัวเลขหลังคาถอย s ตัว
 $\hat{x} + \hat{y}$ ก็อาจเกิดความคลาดเคลื่อนในตัวเลขหลังคาถอยตัวที่ s ได้ ดังนั้น
digital device จึงมักเก็บตัวเลขไว้มากกว่าที่จะแสดงได้

(4)-(5) แสดงว่าความคลาดเคลื่อนจะถูกขยายขนาดขึ้นโดยการคูณด้วยจำนวนที่มี
ขนาดใหญ่ หรือโดยการหารด้วยจำนวนที่มีขนาดเล็ก

$$(\hat{x} \cdot \hat{x}) - x^2 = -8793 \quad \text{แสดงว่าเกิดความไม่แม่นยำเล็กน้อยใน}$$

$$(\hat{u} / \hat{y}) - (u/y) = -16 \quad \text{least significant digit แต่จริงๆ}
แล้ว ค่าความแตกต่างค่อนข้างใหญ่$$

เราเรียกความคลาดเคลื่อนนี้ว่าการขยายตัวของความคลาดเคลื่อน

(error magnification) ซึ่งอาจจะเสียหายมากในบางสถานการณ์

(6) แสดงความคลาดเคลื่อนที่เกิดเมื่อทำการลบเลขสองจำนวนซึ่งมีค่าใกล้เคียงกัน ใน (6) เมื่อเอา W ไปลบจาก Z ตัวเลขนัยสำคัญสามตัวแรกถูกตัดทิ้งไป ตัวเลขนัยสำคัญที่เป็นตัวนำของผลลบ (คือของ $Z-W$) มาจากหลักที่ 4 ของ W และ Z เท่านั้น แสดงให้เห็นว่าเกิดความคลาดเคลื่อนมากเนื่องจากการปัดเศษ (roundoff) นั้นคือ loss of significance หรือ catastrophic cancellation

สรุปเกี่ยวกับความคลาดเคลื่อน

- 1) Underflow/Overflow การปัญมิคการที่ทำให้ได้เลขจำนวนที่มีขนาดเล็กเกินไปหรือใหญ่เกินไปที่จะถูกเก็บในเครื่องได้
- 2) ความคลาดเคลื่อนจากการปัดเศษ (Roundoff error) เกิดเมื่อทำการคำนวณใน fixed-precision digital device ซึ่งเป็นผลมาจากการ
 - a) ความคลาดเคลื่อนแบบฝั่งเดียว (Inherent roundoff) คือการเก็บเลขฐานสองซึ่งเป็นเพียงค่าประมาณของเลขจำนวนจริง
 - b) ความคลาดเคลื่อนพากำจาย (Propagate roundoff) คือการใช้ fixed precision arithmetic กับเลขจำนวนที่ถูกเก็บไว้
 - b.1) Negligible addition การบวกหรือลบเลขที่มีขนาดต่างกันมาก
 - b.2) การขยายตัวของความคลาดเคลื่อน (Error magnification) การคูณด้วยเลขที่มีขนาดใหญ่หรือ การหารด้วยเลขที่มีขนาดเล็ก
 - b.3) การขาดนัยสำคัญ (Loss of significance) การลบเลขสองจำนวนที่มีขนาดใกล้เคียงกันมาก (nearly equal)

1.4D ฟังก์ชันภายใน (Internal Functions)

บล็อกฟังก์ชัน (built-in function) เช่น \sin , \cos , \exp , \ln นั้นทดสอบว่าไบเบิลจะทำให้เกิดความคลาดเคลื่อนแพร์เซอร์จะซึ่งเนื่องมาจาก การปัดเศษมากกว่าที่เกิดจาก การคำนวณโดยใช้ตัวค่าเนินทางเลขคณิตตัวหนึ่งๆ (+, -, *, /)

ตัวอย่าง การคำนวณ x^z นั้นจะคำนวณโดยการใช้สูตร

$$x^z = e^{z \ln x} \quad \text{ทั้งนี้โดยที่ฐาน } x \text{ ต้องมีค่าเป็นบวก นั่นคือ}$$

การคำนวณตามค่าสั่งในภาษาต่างๆ เช่น

FORTRAN : $X**Z$

BASIC : X^Z

เครื่องคอมพิวเตอร์ : x^z

ถ้า Z เป็นเลขจำนวนเต็มบวก (positive integer) แล้ว $x^z = e^{z \ln x}$ จะแทนที่น้อยกว่า $X*X*X*...*X$ (Z ครั้ง) สำหรับ Z ใดๆ ($2 \leq Z \leq 4$)
ความคลาดเคลื่อนแพร่กระจายซึ่งเนื่องมาจากการปัดเศษจะลดลงได้โดยเรื่อยๆ
 $X*X*X*...*X$ แทน x^z ทั้งนี้นอกเสียจากว่า เราทราบว่าคอมพิวเตอร์ทำการคำนวณ
ตามนี้โดยอัตโนมัติอยู่แล้ว

1.5 การหลีกเลี่ยงความคลาดเคลื่อนจากการปัดเศษ (Roundoff Error)

กูหัวใจในการหลีกเลี่ยงการเกิดความคลาดเคลื่อนหรืออย่างน้อยก็ทำให้เกิด
น้อยที่สุด

1.5A กูหัวใจการลดความคลาดเคลื่อนจากการปัดเศษ

กฎที่ 1 เพื่อกำหนดความคลาดเคลื่อนแบบฝังติดน้อยที่สุด จงใช้เลขจำนวนจริง
โดยใช้ตัวเลขนัยสำคัญจำนวนเท่ากับที่เครื่องเก็บได้... (1.3E)

กฎที่ 2 เพื่อกำหนดความคลาดเคลื่อนแบบฝังติดน้อยที่สุด จงใช้เลขจำนวนจริง

น้อยที่สุด ให้พยายามเก็บค่าที่เกิดจาก การคำนวณในทุกขั้นตอนการคำนวณ
ให้ใกล้ ± 1 (นั่นคือพยายามให้ characteristic มีค่าใกล้ศูนย์)

ตัวอย่าง ถ้าทราบค่าของ x, y, z แล้ว

นิจจน์ xy/z ควรจะถูกคำนวณดังนี้

$$(xy)/z \text{ ถ้า } |x| \text{ หรือ } |y| \text{ มีตัวค่าหานั่งใหม่ๆ และอีกตัวเล็ก } \\ x(y/z) \text{ ถ้า } |y| \text{ และ } |z| \text{ ก็งส่องตัวเล็ก หรือก็งส่องตัวใหญ่ } \\ (x/z)y \text{ ถ้า } |x| \text{ และ } |y| \text{ ก็งส่องตัวเล็ก หรือก็งส่องตัวใหญ่}$$

ในเครื่องคอมพิวเตอร์ 32-bit word ส่วนมาก overflow (หรือ underflow) จะเกิดขึ้นเมื่อค่าน้ำดู e^x สำหรับ $x > 40$ ($x < -40$) จึงทำให้จำเป็นและสำคัญมากที่จะลอง ให้ argument ทาง exponential function นั้นไม่สูงมากเท่าที่จะทำได้

ตัวอย่าง ถ้าทราบว่า $x > 0, z > 0$ และ $n > 1$

ในการคำนวณหรือเปลี่ยนค่าสิ่งในโปรแกรมควรจะทำดังนี้

หาค่าของ e^x/e^z ด้วยค่าสิ่งหา e^{x-z}

และหาค่าของ z^n/e^{nx} ด้วยค่าสิ่งหา $(z/e^x)^n$

กฎที่ 3 เพื่อช่วยทำให้ความคลาดเคลื่อนแพรว่ากระจายน้อยลง ให้ใช้ injunction สำหรับ การคำนวณที่ต้องใช้การคำนวณทางเลขคณิตน้อยครั้งที่สุด

ตัวอย่าง เช่น $B = \sin^2 x / [x^2(1+\cos x)] \quad (*)$

ถ้าค่าวนะโดยใช้ $(\sin x / x)^2 / (1+\cos x)$ จะลดการคูณลงได้หนึ่งครั้ง จากการคำนวณโดยตรงตามสูตร $(*)$

กฎที่ 3 นี้จะใช้กับการคำนวณหาค่า polynomial ต่อไปนี้

Nested Multiplication Rule:

Polynomial:

Exponential form: $p_{exponent}(x) = a_1 x^5 + a_2 x^4 + a_3 x^3 + a_4 x^2 + a_5 x + a_6$

Nested form: $p_{nested}(x) = (((a_1 x + a_2) x + a_3) x + a_4) x + a_5) x + a_6$

$p_{\text{exp}}(x)$ นั้นการคำนวณต้องใช้ x^3 subroutine ซึ่งมีความแม่นยำน้อยกว่า (less accurate) และถ้า x เป็นลบจะคำนวณไม่ได้

ตารางค่าไปร์เซนเทจความแม่นยำของ $p_{\text{exp}}(x)$ และ $p_{\text{nest}}(x)$
(ใช้ 23-bit mantissa device)

4th-degree polynomial

$$P_{\text{exp}}(x) = x^4 - 9.5x^3 + 28.49x^2 - 28.417x + 2.5662$$

$$P_{\text{nest}}(x) = (((x-9.5)x + 28.49)x - 28.417)x + 2.5662$$

$$P_{\text{exp}}(x) = P_{\text{nest}}(x) = (x-0.1)(x-2.1)(x-2.6)(x-4.7)$$

ตาราง 1.5-1 การเปรียบเทียบความแม่นยำของ $p_{\text{exp}}(x)$ และ $p_{\text{nest}}(x)$

x	Calculated $p_{\text{exp}}(x)$	Calculated $p_{\text{nest}}(x)$	Exact Value
2.4	0.317401'	0.317399	0.3174
2.5	0.211199	0.211200*	0.2112
2.7	-0.312001	-0.312000*	-0.3120
2.8	-0.718201	-0.718200*	-0.7182
2.9	-1.209599*	-1.209601	-1.2096
3.1	-2.399997	-2.400001'	-2.4000
3.2	-3.069001	-3.068999"	-3.0690
3.3	-3.763199	-3.763200*	-3.7632
3.5	-5.140801	-5.140800*	-5.1408
3.6	-5.775004	-5.775001'	-5.7750
3.7	-6.335999	-6.336001*	-6.3360
3.8	-6.793202	-6.793201*	-6.7932
3.9	-7.113601*	-7.113602	-7.1136
4.3	-6.283200*	-6.283197	-6.2832
4.4	-5.340597	-5.340602*	-5.3406
4.6	-2.250000*	-2.249999	-2.2500
4.7	0.000010	0.000001*	0.0000
4.8	2.791805	2.791802*	2.7918
4.9	6.182398	6.182401*	6.1824

* แสดงค่าที่แม่นยำกว่า ในตารางแสดงค่า x ซึ่งมีช่วงระหว่าง 0.0(0.1)5.0

$$\left| \frac{\text{ฟัง } p_{\text{nest}}(x) - p_{\text{exp}}(x)}{p_{\text{exp}}(x)} \right| > 10^{-6}$$

รากของสมการ polynomial คือ 0.1, 2.1, 2.6 และ 4.7

จากตารางเราจะเห็นว่า

1. $p_{\text{nested}}(x)$ ส่วนมากมีน้อยกว่า $p_{\text{exp}}(x)$
2. ทั้ง $p_{\text{exp}}(x)$ และ $p_{\text{nested}}(x)$ มีความคลาดเคลื่อนใกล้ๆ มากตัวที่ใหญ่ที่สุดของสมการ polynomial (นั่นคือ $x = 4.7$)

โดยทั่วไป แนววิธีนี้เรียกว่า nested ในการหา nth-degree polynomial

$$p(x) = a_1 x^n + a_2 x^{n-1} + a_3 x^{n-2} + \dots + a_n x + a_{n+1} \quad (a_1 \neq 0)$$

ซึ่งมีความล้ำมากที่จะให้ได้ความแม่นยำเมื่อค่าของ x อายุใกล้รากจริงที่มีขนาดใหญ่

โดยเฉพาะอย่างยิ่งถ้าสัมประสิทธิ์บางตัวมีขนาดใหญ่ตัวเดียว (เป็นสาเหตุของการแยกตัวของความคลาดเคลื่อน) หรือ slope ใกล้ๆ รากนี้ค่าเข้าใกล้ศูนย์ และตั้ง n นิ่งๆ ๆ สถานการณ์จะซึ่งเลวร้าย

รูปแบบการหาร Synthetic Division Algorithm (Horner's method)

เพื่อหาค่า polynomial ในรูป nested

(a) Algorithm: Synthetic Division (Horner's Method)

Purpose: To evaluate $\text{PolValue} = a_1 x^n + a_2 x^{n-1} + \dots + a_n x + a_{n+1}$

GET $n, a_1, a_2, \dots, a_{n+1}, x$

$\text{Pol Value} \leftarrow 0$

DO FOR $i = 1$ TO $n + 1$

$\text{PolValue} \leftarrow \text{PolValue} * x + a_i$

(b) Find $p(x) = (((9.5)x + 28.49)x - 28.417)x + 2.5662$ when $x = -2$

$$\begin{array}{r} -2 \\ \oplus \\ \hline 1 & -9.5 & 28.49 & -28.417 & 2.5662 \\ & -2.0 & 23.0 & -102.98 & 262.794 \\ \hline 1 & -11.5 & 51.49 & -131.397 & 265.3602 = p(-2) \end{array}$$

Note 1: Diagonal arrows indicate multiplication by $x = -2$.

Note 2: $\frac{p(x)}{x - (-2)} = x^3 - 11.5x^2 + 51.49x - 131.397 + \frac{265.3602}{x - (-2)}$,

ปุ่ม 1.5-1 (a) SYNTHETIC Division Algorithm สำหรับการหา $p(x)$;
 (b) $p(-2)$; (c) POLVAL

```

(c) 00100.      FUNCTION POLVAL(X, NP1, A)
00200          DIMENSION A(NP1)
00300  C - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - C
00400  C POLVAL = A(1)*X**N + . . . + A(N)*X + A(NP1) C
00500  C WHERE N = DEGREE OF POLYNOMIAL C
00600  C NP1 = NUMBER OF COEFFICIENTS = N+1 C
00700  C - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - C
00800          POLVAL = 0.0
00900          DO 1 I=1, NP1
01000          1   POLVAL = POLVAL*X + A(I)
01100          RETURN
01200          END

```

กฎที่ 4 ออกแบบบีโพรограмเพื่อหลีกเลี่ยงการขาดนัยสำคัญ (loss of significance)

ที่อาจเกิดขึ้นเมื่อทำการบวกหรือการลบ

ตัวอย่างใน $1.5B-1.5D$ จะแสดงการใช้กฎข้อ 4 นี้

1.5B การจัดนิพจน์ตรีโกณมิติเสียงใหม่ (Trigonometric Rearrangement)

เพื่อหลีกเลี่ยงการขาดนัยสำคัญ (Loss of Significance)

ปัญหา

อธิบายการหาค่า $f(x) = (1-\cos x)/x^2$ อย่างถูกต้องแม่นยำ สำหรับ
ทุกค่าของ $x \neq 0$

Solution

จาก 1.2A การคำนวณค่าของ $A = (1-\cos x)/x^2$ นั้นค่าจะ

ไม่แม่นยำเมื่อ $x \approx 0$ เนื่องจาก $\cos x \approx 1$ เมื่อ $(x \approx 0)$ เนื่องจากนั้น
การขาดนัยสำคัญ และเมื่อหารด้วย x^2 ซึ่งมีค่าน้อยกว่าความคลาดเคลื่อนจะมีมากขึ้น
ส่วนการหาค่าของ $B = (\sin x/x)^2 [1/(1+\cos x)]$ จะไม่แม่นยำ

เมื่อ $x \approx \pi$ ทั้งนี้ เพราะ $\cos x \approx -1$ เมื่อ $(x \approx \pi)$ ทำให้ตัวหารขาด
นัยสำคัญและค่าของ B ก็จะเล็กลง (ค่าตอบจนดู absurd)

ดังนั้นเมื่อเข้าใจปัญหาที่เกิดขึ้น เราอาจหลีกเลี่ยงสิ่งที่จะเกิดโดยการคำนวณ $f(x)$
ดังนี้

$$f(x) = \begin{cases} B & \text{ถ้า } (1-\cos x) \approx 0 \\ A & \text{ถ้า } \frac{1-\cos x}{x} > 0.01 \end{cases}$$

1.5C การจัดนิเวน์พีชคณิตเมื่อใหม่ (Algebraic Rearrangement)

เพื่อนเล็กเรื่องการหาค่านัยสำคัญ

จาก 1.2B เรายรู้ว่า ถ้า $b_1^2 > c$, และ $b_1^2 - c_1$ จะไม่ต่างจาก b_1^2
 หากดังนั้น $r(-) = b_1 - \sqrt{b_1^2 - c_1}$ จะ loss of significance ถ้า $b_1 > 0$
 $r(+) = b_1 + \sqrt{b_1^2 - c_1}$ จะ loss of significance ถ้า $b_1 < 0$

ถ้าหากจะหารากของ $ax^2 + bx + c = 0$ ($a \neq 0$) โดยที่ไม่ให้หาค่านัยสำคัญ
 โดยใช้สูตร $\text{root}_1 = (\pm) (\left| b_1 \right| + \sqrt{b_1^2 - c_1})$ และ
 $\text{root}_2 = c_1 / \text{root}_1$

โดยที่ $b_1 = -b/2a$, $c_1 = c/d$ และ (\pm) คือ (+) นอกจาก $b_1 < 0$

ต่อไปนี้เป็นโปรแกรมย่ออยู่ในภาษา FORTRAN เพื่อหารากของสมการ

กำลังสอง $ax^2 + bx + c = 0$, $a \neq 0$ ตามวิธีกล่าวข้างต้น

```

00100      SUBROUTINE QROOTS(A, B, C, ROOT1, ROOT2, COMPLX, IY, PRINT)
00200      LOGICAL PRINT, COMPLX
00300      C - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - C
00400      C THIS SUBROUTINE FINDS THE TWO ROOTS OF THE QUADRATIC      C
00500      C          AX**2 + BX + C                               C
00600      C IF PRINT = TRUE, IT PRINTS THEM ON OUTPUT DEVICE IW.          C
00700      C REAL ROOTS (COMPLX=FALSE) ARE RETURNED AS ROOT1 AND ROOT2, C
00800      C AND COMPLEX ROOTS (COMPLX=TRUE) AS ROOT1 +OR- I*ROOT2.   C
00900      C - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - C
01000      B1 = -0.5*B/A
01100      C1 = C/A
01200      DISCR = B1*B1 - C1
01300      IF (DISCR .LT. 0.) GOTO 10
01400      C
01500      C      REAL ROOTS: ROOT1 AND ROOT2
01600          COMPLX = .FALSE.
01700          ROOT1 = ABS(B1) + SQRT(DISCR)
01800          IF (B1 .LT. 0.) ROOT1 = -ROOT1
01900          ROOT2 = 0.0
02000          IF (ROOT1 .NE. 0.) ROOT2 = C1/ROOT1
02100      C
02200          IF (PRINT) WRITE(IW,1) ROOT1, ROOT2
02300      1      FORMAT(' REAL ROOTS: ',E14.7,' AND ',E14.7)
02400          RETURN
02500      C
02600      C      COMPLEX CONJUGATE ROOTS: ROOT1 +OR- I*ROOT2
02700      10     COMPLX = .TRUE.
02800          ROOT1 = B1
02900          ROOT2 = SQRT(-DISCR)
03000      C
03100          IF (PRINT) WRITE(IW,2) ROOT1, ROOT2
03200      2      FORMAT(' COMPLEX ROOTS:',E15.7,' +OR- I*(',E14.7,')')
03300          RETURN
03400      C
03500      END

```

รูป 1.5-2 ชิ้นรูปภาษาฟอร์แทรนชื่อ QROOTS สำหรับหารากของสมการกำลังสอง

โปรแกรมหลักเพื่อหารากจริงของสมการ $x^2 + 100.01x + 1 = 0$ และ
รากเชิงซ้อน (complex roots) ของสมการ $x^2 - 2x + 3 = 0$ การคำนวณแม่นยำ
อย่างน้อยที่สุด 7 ตัวเลขหลัง小数 (7s)

```

00100 C * * * * * * * * * TESTQR • ┌─────────────────┐
00200 C INTERACTIVE PROGRAM TO TEST SUBROUTINE QROOTS (IW = 5)
00300 LOGICAL COMPLX
00400 C
00500 WRITE (5,1)
00600 1 FORMAT('TO FIND ROOTS OF AX**2+BX+C, INPUT A, B, C')
00700 READ (5,*) A, B, C
00800 C
00900 CALL QROOTS (A, B, C, RI, R2, COMPLX, 5, .TRUE.)
01000 C
01100 STOP
01200 END

```

TO FIND ROOTS OF AX**2+BX+C, INPUT A, B, C
1, -100.01, 1

REAL ROOTS: 0.1000000E+03 AND 0.1000000E-01

TO FIND ROOTS OF AX**2+BX+C, INPUT A, B, C
1, +100.01, 1

REAL ROOTS: -0.1000000E+03 AND -0.1000000E-01

TO FIND ROOTS OF AX**2+BX+C, INPUT A, B, C
1, -2, 3

COMPLEX ROOTS: 0.1000000E+01 +0R- 1*(0.1414214E+01)

รูป 1.5-3 โปรแกรมชิงเรือกใช้ QROOTS

1.5D การใช้งานของแมคคลอลินเพื่อหลักเลี้ยงการหาค่าสัมประสิทธิ์

ปัญหา ค่านาฬิกา $f(x) = (e^x - 1)/x$ อย่างถูกต้องแม่นยำสำหรับทุก $x \neq 0$

Solution เพราฯว่า $e^x \rightarrow 1$ เมื่อ $x \rightarrow 0$ เศษของ $f(x)$ จะขาดนัยสัมประสิทธิ์

และจะขยายตัวมากขึ้น (magnified) โดยตัวส่วนที่มีขนาดเล็ก

เมื่อ $x \approx 0$ ปัญหานี้ต่างไปจาก 1.5B เพราฯเราไม้อาจหา equivalent expression เพื่อช่วยหลักเลี้ยงปัญหานี้ได้ด้วยตัวเดียว ในสถานการณ์เช่นนี้เราจะใช้
อนุการณ์ของแมคคลอลินที่เหมาะสมเข้าช่วย

อนุการณ์ของแมคคลอลินสໍາหารับ

$$e^x \text{ คือ } [1 + x + x^2/2! + x^3/3! + R_3(x)]$$

$$f(x) = (1/x) \{ [1+x+x^2/2!+x^3/3!+R_3(x)] - 1 \} = 1+x/2!+x^2/3!+R_3(x)/x$$

โดยที่ $R_3(x)$ คือ แบบลากของจี้ของเท่าน (Lagrange form of the remainder)

$$R_3(x) = [\exp(\lambda)/4!] x^4 \quad \text{โดยที่ } \lambda \text{ อยู่ระหว่าง } 0 \text{ และ } x$$

โดยที่ $\frac{x}{\lambda} < 0.01$ แล้ว $R_3(x)/x$ (นี่คือความคลาดเคลื่อนจากการตัดปaley (truncation error) ของการประมาณ $f(x)$ ด้วย $1 + x/2! + x^2/3!$) จะสอดคล้องกัน

$$\left| R_3(x)/x \right| = [\exp(\lambda) |x|^3]/24 < \exp(0.01) (0.01)^3/24 < 0.00000005$$

ฉันนี้รับประทานว่า $1 + x/2! + x^2/3!$ ประมาณ $[\exp(x)-1]/x$ ถึง 7d ถ้า

$$|x| < 0.01$$

ดังนั้นถ้าเราหาค่า $f(x)$ ดังนี้

$$f(x) = \begin{cases} [\exp(x) - 1]/x & \text{ถ้า } |x| \geq 0.01 \\ 1 + (1/2)x[1 + (1/3)x] & \text{ถ้า } |x| < 0.01 \end{cases}$$

แล้ว $f(x)$ จะถูกคำนวณที่ความแม่นยำของเครื่องเมื่อ $|x| \geq 0.01$

และด้วยความแม่นยำถึง 7d เมื่อ $|x| < 0.01$

1.5E Extended Precision

การขยายพื้นที่เก็บเลขจำนวนจาก 1 เวิร์ด (word) เป็น 2 เวิร์ด นั้นทำให้สามารถเก็บตัวเลขน้อยสักตัวได้มากกว่าเดิม ทั้งนี้เพราะเวิร์ดที่ถูกเพิ่มเข้าไปนั้น จะใช้ขยายส่วนที่เก็บ mantissa จึงทำให้เก็บตัวเลขน้อยสักตัวได้อีกสองเท่าของขนาดปกติ

ตัวอย่าง FORTRAN: กำหนดที่ขนาด 2 เวิร์ด ด้วยคำสั่ง

DOUBLE PRECISION variable list

การคำนวณโดยความเที่ยงตรงสองชั้น (double precision) ใช้เวลาเป็นสองเท่าของ การคำนวณโดยความเที่ยงตรงชั้นเดียว (single precision) ดังนั้นจึงควรใช้กูที่ 1-4 ก่อนเพื่อทำให้การใช้การคำนวณโดยความเที่ยงตรงชั้นเดียวมีประสิทธิภาพ นอกจากนี้ต้องการความแม่นยำสูง และไม่สามารถใช้กูทั้ง 4 ได้

1.6 ความคลาดเคลื่อน ความแม่นยำ และ การทดสอบเพื่อตรวจสอบความใกล้เคียง

ในหัวข้อนี้จะศึกษาเกบนต่างๆ ที่ใช้ และหมายถึงการเพื่อกำให้ได้ ความแม่นยำเท่าที่ต้องการ

1.6A ความคลาดเคลื่อนสัมบูรณ์ (Absolute Error) ความคลาดเคลื่อนสัมพัทธ์ (Relative Error) และ ความคลาดเคลื่อนสัมพัทธ์คิดเป็นร้อยละ (Percent Error)

x เป็นค่าประมาณของค่าจริง X

ความแตกต่าง $\epsilon_x = x - X$ = (exact value) - (approximate value)

คือ ความคลาดเคลื่อนสัมบูรณ์ (absolute error หรือ error) (บางเล่มอาจใช้ $\epsilon_x = X - x$) ดังนั้น $x = X + \epsilon_x$

ถ้า $x \neq 0$ แล้วอัตราส่วน

$$\rho_x = \frac{\epsilon_x}{x} = \frac{(x-X)}{x} \text{ คือ ความคลาดเคลื่อนสัมพัทธ์ (relative error) } \\ \text{สำหรับการประมาณ } x \text{ ด้วย } X$$

ในสถานการณ์ที่ทราบค่า ρ_x แล้วความคลาดเคลื่อนสัมบูรณ์อาจหาได้โดย

$$\epsilon_x = x\rho_x$$

ความคลาดเคลื่อนสัมพัทธ์ ρ_x มากกว่าส่วนได้ของ x ยังผิดพลาดอยู่

ตัวอย่าง
$$\left| \rho_x \right| = 0.02 \\ \left| \epsilon_x \right| < 0.02 |x|$$

หรือกล่าวว่า X ประมาณค่า x ด้วยความคลาดเคลื่อนไม่เกิน 2 %

โดยทั่วไป $100\rho_x = 100 \epsilon_x / x$ คือ ความคลาดเคลื่อนสัมพัทธ์คิดเป็นร้อยละ (percent error) ของการประมาณ x ด้วย X

ตัวอย่าง ถ้า $x = 1/30$ ถูกประมาณค่าด้วย $\hat{x} = 0.033(2s)$ ดังนี้
 $\epsilon_x = 1/30 - 0.033 = 1/30 - 99/3000 = 1/3000$ และ
 $\rho_x = (1/3000)/(1/30) = 1/100 = .01$
ดังนั้น 0.033 ประมาณ $1/30$ ด้วยความคลาดเคลื่อนไม่เกิน 1%

1.6B ความกําของข้องณ์กันของ ϵ และ ρ ต่อความผันผวนของ X

ถ้า $X = 2.3579 \rightarrow 0.2358(4s)$
หรือ $X = 2.357682 \rightarrow 0.2358(4s)$
เราต้องหาวิธีนอกคอมพิวเตอร์ให้เลือก X ที่ตรงกับความผันผวนยังไง
ดังนี้

การทดสอบความคลาดเคลื่อนสัมบูรณ์ (Absolute Error Test)

d = เลขจำนวนเต็มบวกใด ๆ

$$\left| \epsilon_x \right| = \left| \frac{x-\hat{x}}{x} \right| < (1/2) \cdot 10^{-d} \rightarrow \text{จะประกันว่า } X \text{ ประมาณค่า } \hat{x} \text{ ได้แม่นยำถึง } d \text{ ตำแหน่งหลังคา_dot}$$

ถ้า $x \neq 0$ แล้วความคลาดเคลื่อนสัมพัทธ์ $\rho_x = \epsilon_x/x$ สามารถใช้เพื่อให้ได้
ความผันผวนยังไงเป็นจำนวนเต็มบวกใด ๆ ที่ต้องการ

การทดสอบความคลาดเคลื่อนสัมพัทธ์ (Relative Error Test)

s = เลขจำนวนเต็มบวกใด ๆ

$$(1) \quad \left| \rho_x \right| < (1/2) \cdot 10^{-s} \rightarrow \text{จะประกันว่า } x \text{ ประมาณค่า } \hat{x} \text{ ได้แม่นยำถึง } s \text{ ตำแหน่งหลังคา_dot}$$

$$(2) \quad \text{หรือ } \left| \frac{x-\hat{x}}{x} \right| < (1/2) \cdot 10^{-s} \quad \text{ได้แม่นยำถึง } s \text{ ตำแหน่งหลังคา_dot}$$

ทิสชัน จาก $x = \pm M \cdot 10^c$

$$\text{โดยที่ } 0.1 \leq M = 0.d_1 d_2 d_3 \dots d_s \dots < 1 \quad \dots (3)$$

ถ้า (1) และ (2) จะงแล้ว จาก (2) และ (3)

$$|\epsilon_x| = \left| \frac{x - \bar{x}}{x} \right| < (1/2) \cdot 10^{-8} \left| \frac{x}{\bar{x}} \right| = ((1/2) \cdot 10^{-8}) (M \cdot 10^6) < ((1/2) \cdot 10^{-8}) 10^6$$

แสดงว่า ขนาดของความคลาดเคลื่อนของ $\bar{x} < 1/2$ ล ทศนิยมตัวหนึ่งที่ s ของ M
ใน (3) (นั่นคือ x มีความแม่นยำถึงจำนวนตัวเลขน้อยสักกี่ = s ตัว)

1.7 ขั้นตอนวิธีของการทําซ้ำ (Iterative Algorithms)

ทุกขั้นตอนวิธีของการทําซ้ำสำหรับหาค่าที่ต้องการ (\bar{x}) นั้นจะทำ 2 ขั้นตอน
ต่อไปนี้

(1) **ขั้นเริ่มต้น:** หา ค่าเดาวินัยต์ค่าหนึ่ง (initial guess) คือ x_0 ซึ่ง
จะประมาณค่า \bar{x}

(2) **ขั้นทําซ้ำ :** สำหรับ $k = 0, 1, 2, \dots$ ไปจนกระทั่งการทดสอบเพื่อหยุดการ
ทําซ้ำเป็นจริง

ให้ x_k เป็นหา x_{k+1} ซึ่งเป็นค่าประมาณที่ถูกปรับปรุงแล้ว
เราเรียก x_k ว่า การทําซ้ำที่ k (kth iterate) และให้
 $\epsilon_k = \bar{x} - x_k$ ความคลาดเคลื่อนของ x_k ดังนั้น ϵ_k คือค่าที่จะบอกกัน x_k
เพื่อให้ได้ \bar{x} ($\bar{x} = x_k + \epsilon_k$)
ขั้นตอนวิธีจะสำเร็จ (success) ถ้า $x_k \rightarrow \bar{x}$ (นั่นคือ $\epsilon_k \rightarrow 0$) เมื่อ $k \rightarrow \infty$

ขั้นตอนวิธีจะแสดงลักษณะต่อไปนี้

1) Robustness

x_k จะมีค่าลุ้นเข้า \bar{x} ถ้ามันว่า x_0 จะไม่ใช่ค่าเดาวินัยต์ที่

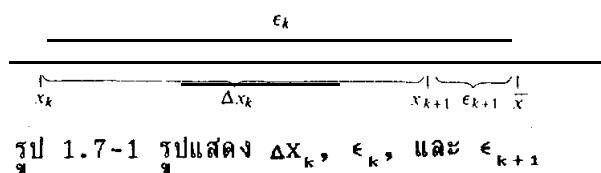
2) Rapid Convergence

เมื่อ x_k เข้าใกล้ \bar{x} , x_{k+1} จะเข้าใกล้มากกว่า

$$\text{นั่นคือ } \left| \frac{\epsilon_{k+1}}{\epsilon_k} \right| = \left| \frac{\bar{x} - x_{k+1}}{\bar{x} - x_k} \right| \ll \left| \frac{\bar{x} - x_k}{\bar{x} - x_k} \right| = \left| \frac{\epsilon_k}{\epsilon_k} \right|$$

ดังนั้น

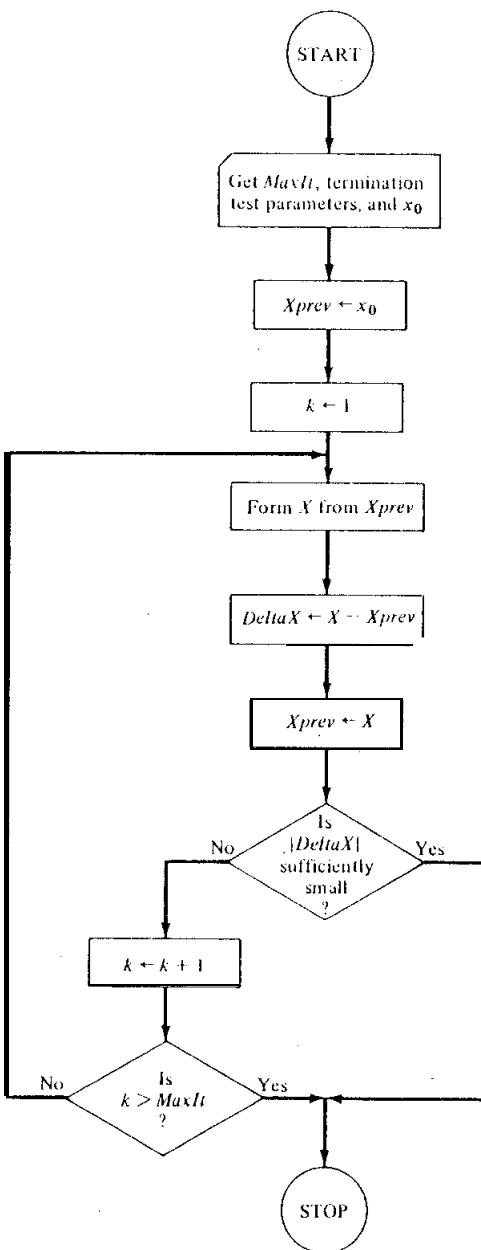
$\Delta x_k = x_{k+1} - x_k \approx \bar{x} - x_k = \epsilon_k$ (ความคลาดเคลื่อนที่แท้จริงซึ่งไม่ทราบค่า)
คือ increment จาก x_k ถึง x_{k+1}



รูป 1.7-1 รูปแสดง Δx_k , ϵ_k , และ ϵ_{k+1}

การทดสอบเพื่อหยุดการทำซ้ำ (Termination test) ส่วนมากสำหรับขั้นตอนวิธีของการทำซ้ำซึ่งรวมการหยุดงาน (และใช้ $x_{k+1} \approx \bar{x}$) เมื่อ Δx_k มีค่าเล็กมากพอ

1.7A ผังโปรแกรมสำหรับขั้นตอนวิธีของการทําซ้ำ



รูป 1.7-2 ผังภาพสำหรับ General Iterative Algorithm

General Iterative Algorithm

Purpose: To find \bar{x} to a desired accuracy by repeatedly forming an improved approximation X from a current approximation X_{prev} until either X is sufficiently close to X_{prev} (**termination test**) or $MaxIt$ iterations occur.

(*initialize*)

GET $MaxIt$, termination parameters, x_0 [initial guess]

$X_{prev} \leftarrow x_0$

{ *iterate*}

DO FOR $k = 1$ TO $MaxIt$ **UNTIL** termination test is satisfied

BEGIN

(form X) $X \leftarrow$ (formula involving X_{prev})

$DeltaX \leftarrow X - X_{prev}$ { $DeltaX$ is $\Delta x_{k-1} = x_k - x_{k-1}$ }

[update] $X_{prev} \leftarrow X$ (ready for next iteration)

(termination test: $|DeltaX| \approx 0$, as specified by termination parameters)

END

(If termination test succeeded, then $\bar{x} \doteq X$ to the desired accuracy. If not, $MaxIt$ iterations failed to yield an X close enough to \bar{x} .)

รูป 1.7-3 รหัสเทอมสำหรับ **General Iterative Algorithm**

1.7B การทดสอบเพื่อหยุดการทำงานที่ถูกต้อง (Termination Tests) สำหรับขั้นตอนวิธี ของการคำนวณ

จากการประมาณค่า: $\Delta x_k \approx \epsilon_k$ และ ความคลาดเคลื่อนสัมบูรณ์จะความคลาดเคลื่อนสัมพัทธ์ (ในข้อ 1.6B) ทำให้เราได้การทดสอบเพื่อหยุดการทำงานที่ถูกต้อง ดังนี้

Absolute Difference Test (For NumDec decimal-place accuracy)

ถ้า $|DeltaX| \leq AbsTol$ โดยที่ $AbsTol = Const * 10^{-NumDec}$
แล้ว X จะประมาณ \bar{x} ได้แม่นยำถึงทศนิยมตัวหนึ่งที่ $NumDec$

Relative Difference Test (For NumSig significant-digit Accuracy)

ถ้า $\frac{|X - X_{\text{prev}}|}{|X|} \leq \text{RelTol}$ โดยที่ $\text{RelTol} = \text{Const} \cdot 10^{-\text{NumDec}}$
 แล้ว X จะประพน \bar{x} ได้แม่นยำถึงตัวเลขนัยสำคัญเท่ากับ NumSig ตัว

$$\Delta X = X - X_{\text{prev}}$$

Const เราปักไว้ค่า 1 ถ้าการลู่เข้า (convergence) ช้า จะเลือกค่าเข้าใกล้ 0.5 และถ้าคาดว่ามีความคลาดเคลื่อนจากการปัดเศษมาก จะเลือกค่ามากกว่า 1 (คือ 2-9)

ถ้าเราต้องการความแม่นยำถึง 5 ตัวเลขนัยสำคัญ $\bar{x} \approx 3000$ เรายากำหนด NumDec = 1 ใน Absolute Difference Test แต่ถ้าทราบว่า $\bar{x} \approx -0.003$ เรายากำหนด NumDec = 7 ส่วนใน Relative Difference Test เราจะใช้ NumSig = 5 ในทั้ง 2 กรณี นั้นแสดงว่า Relative Difference Test มักจะถูกใช้ในโปรแกรมซึ่งจะหาค่า \bar{x} 's ที่มีขนาดต่างๆ กันไป

อย่างไรก็ได้ Relative Difference Test นั้นไม่ใช้กับการทดสอบการเข้าใกล้ศูนย์ อันที่จริงแล้ว ถ้า $\bar{x} = 0$ และ หันตอนวิธีลู่เข้าเร็ว (i.e., $x_n \rightarrow 0$ อย่างเร็ว) และ $|x| \ll |x_{\text{prev}}|$ ผลที่ตามมาคือ ถ้าไม่มีความคลาดเคลื่อนจากการปัดเศษแล้ว $|\Delta x| \approx |x_{\text{prev}}|$ และสมการใน Relative Difference Test จะไม่เป็นจริง

คอมพิวเตอร์อาจพบ ลูปอันดับ (infinite loop) อย่างที่เราไม่คาดฝัน เรายากจะป้องกันโดยขัดหลักต่อไปนี้

For **any** iterative algorithm, no matter how **sure you are** that a termination **test will be set, put an upper limit (e.g., MaxIt)** on the **number of iterations (just in case you are wrong)**.

1.7C การลู่เข้าแบบเชิงเส้น (Linear Convergence) และ การลู่เข้าแบบอันดับสอง (Quadratic Convergence)

$$(*) \quad (\Delta x / \text{preceding } \Delta x) \approx \text{Constant} = C \quad \text{นั่นคือ } \Delta x_k \approx C \Delta x_{k-1}$$

ถ้าเป็นไปตาม (*) นั่นคือเมื่อ $(x_{k+1} - x_k)$ is (approximately) proportional to $(x_k - x_{k-1})$ เราเรียกการลู่เข้าของ x_k to \bar{x} ว่า **การลู่เข้าแบบเชิงเส้น (linear convergence)**

เหตุการณ์ข้างต้นตรงข้ามกับเมื่อการทําซํา satisfied
 $(\Delta x / \text{preceding } \Delta x) \rightarrow 0$ เมื่อ k เพิ่มขึ้น

$$(**) \quad \Delta x / (\text{preceding } \Delta x)^2 \approx \text{Constant} = C \quad \text{นั่นคือ } \Delta x_k \approx C(\Delta x_{k-1})^2$$

ถ้าเป็นไปตาม (**) นั่นคือเมื่อ $(x_{k+1} - x_k)$ is (approximately) proportional to $(x_k - x_{k-1})^2$ เราเรียกการลู่เข้าของ x_k to \bar{x} ว่า **การลู่เข้าแบบอันดับสอง (quadratic convergence)**

เราจะใช้ **การลู่เข้าแบบอันดับสอง** เพื่อเป็นมาตรฐานของเราสำหรับ **การลู่เข้าอย่างเร็ว (rapid convergence)**

และจะใช้ **การลู่เข้าแบบเชิงเส้น** เพื่อเป็นมาตรฐานของเราสำหรับ **การลู่เข้าอย่างช้า (slow convergence)**