


w09-Lec

Data Representation

Part II – Floating Point

Assembled for 204111
by Kittipitch Kuptavanich


Floating Point



- Fractional Binary Number
- IEEE Floating Point
- Normalized Value
- Denormalized Value
- Special Value
- Rounding
- Floating Point Operation
- Floating Point in C

Fractional Binary Numbers

- เลขเศษส่วนฐานสอง



Fractional Binary Numbers [2]

- พิจารณาการแทนข้อมูลฐาน 10
 - เราไม่สามารถใช้เลขทศนิยมที่มีการจำกัดตำแหน่ง เพื่อแทนค่าที่แท้จริงของ $1/3$ หรือ $5/7$
 - เมื่อจากเป็นทศนิยมไม่รู้จบ: $0.\dot{3}$ และ $0.\dot{7}1428\dot{5}$
 - 0.33333 ใกล้เคียงค่าจริงมากกว่า 0.33
- ในระบบเลขฐาน 2 นั้นมีข้อจำกัดเช่นเดียวกัน
 - แทนค่าจริงของตัวเลขได้เฉพาะตัวเลขที่สามารถเขียนในรูป $x \times 2^y$ เท่านั้น
 - นอกจากนั้นจะเป็นค่าประมาณ - ความใกล้เคียงกับค่าจริงขึ้นกับจำนวนตำแหน่งที่ใช้แสดงค่า


Fractional Binary Number [3]

Representation	Value	Decimal
0.0_2	$\frac{0}{2}$	0.0_{10}
0.01_2	$\frac{1}{4}$	0.25_{10}
0.010_2	$\frac{2}{8}$	0.25_{10}
0.0011_2	$\frac{3}{16}$	0.1875_{10}
0.00110_2	$\frac{6}{32}$	0.1875_{10}
0.001101_2	$\frac{13}{64}$	0.203125_{10}
0.0011010_2	$\frac{26}{128}$	0.203125_{10}
0.00110011_2	$\frac{51}{256}$	0.19921875_{10}

5

Floating Point

- Fractional Binary Number
- IEEE Floating Point
- Normalized Value
- Denormalized Value
- Special Value
- Rounding
- Floating Point Operation
- Floating Point in C



7

Practice Problem 1

เติมตารางต่อไปนี้ให้สมบูรณ์

Fractional value	Binary representation	Decimal representation
$\frac{1}{8}$	0.001	0.125
$\frac{3}{4}$	_____	_____
$\frac{25}{16}$	_____	_____
_____	10.1011	_____
_____	1.001	_____
_____	_____	5.875
_____	_____	3.1875

6

IEEE Floating Point

- ในอดีตผู้ผลิตคอมพิวเตอร์แต่ละราย ต่างก็มีวิธีการแสดงค่าเลข Floating Point ที่แตกต่างกันออกไป (ไม่มีมาตรฐานกลาง)
 - ให้ความสนใจกับความเร็วมากกว่าค่าที่ถูกต้อง [-_-]
- IEEE standard 754
 - ตั้งขึ้นในปี 1985
 - มาตรฐานกลางสำหรับ Floating Point
 - รองรับโดย CPU ส่วนมาก

8

Floating Point Representation

- การแทนค่า Floating Point อยู่ในรูปแบบ

$$(-1)^s \times M \times 2^E$$

ลักษณะเดียวกันกับการเขียน
 $204111 = 2.04111 \times 10^5$
 ในฐาน 10

- Sign Bit s เป็น bit ที่บอกว่าเป็นจำนวนบวกหรือลบ
- Significand M เป็นจำนวนในช่วง 1.0 ถึง 2.0 (M : mantissa)
- Exponent E กำหนดขนาดของจำนวนที่ต้องการแทนค่า ในรูปกำลังที่ E ของ 2 (E สามารถมีค่าเป็น +0 หรือ - ได้)

9

Precision options

- Single precision: 32 bits




- Double precision: 64 bits



11

Bit-Level Representation

- MSB ใช้แทน **Sign Bit** s
- Bit ในช่วง exp ใช้แสดงค่า E ด้วย วิธีแปลงค่า
- Bit ในช่วง frac ใช้แสดงค่า M ด้วย วิธีแปลงค่า



10

3 Cases of Value Represented


เราสามารถแบ่งจำนวนที่สามารถแสดงค่าด้วย มาตรฐาน floating point ได้ออกเป็น 3 กรณี โดยพิจารณาจากค่า exp เป็นหลัก

- Case 1: Normalized Value**
 - กรณี exp ไม่ได้มีค่าเป็น 0 ทุก bit หรือ 1 ทุก bit ($exp \neq 000\dots0$ and $exp \neq 111\dots1$)
 - เป็นกรณีที่พนได้น้อยที่สุด
- Case 2: Denormalized Value**
 - กรณี exp มีค่าเป็น 0 ทุก bit ($exp = 000\dots0$)
 - ใช้แทนค่า 0 และตัวเลขที่ใกล้เคียง 0 มาก ๆ
- Case 3: Special**
 - กรณี exp มีค่าเป็น 1 ทุก bit ($exp = 111\dots1$)
 - NaN (Not a number), infinities (∞ หรือ $-\infty$)



12

Visualization: Floating Point Encodings



13

Case 1: Normalized Value

- กรณี: $\text{exp} \neq 000\dots0$ and $\text{exp} \neq 111\dots1$
- ค่า E คำนวณได้โดยการ แปลงจาก exp :

$$E = \text{exp} - \text{Bias}$$

- exp : unsigned value
- $\text{Bias} = 2^{k-1} - 1$, where k จำนวน bit ของ exp
 - Single precision: 127 (exp : 1...254, E : -126...127)
 - Double precision: 1023 (exp : 1...2046, E : -1022...1023)


s	exp	frac
1	8-bits	23-bits

s	exp	frac
1	11-bits	52-bits

15

Floating Point

- Fractional Binary Number
- IEEE Floating Point
- Normalized Value
- Denormalized Value
- Special Value
- Rounding
- Floating Point Operation
- Floating Point in C



14

Case 1: Normalized Value [2]



- ค่า M คำนวณได้จาก สูตร:


$$M = \underline{1}.xxx\dots x_2$$

- $xxx\dots x$: bit จากส่วน frac
- ค่า minimum เมื่อ $\text{frac} = 000\dots0$ ($M = 1.0$)
- ค่า maximum เมื่อ $\text{frac} = 111\dots1$ ($M = \text{almost } 2.0$)
- เนื่องจากตัวเลขตัวแรก (หน้าสุด) มีค่า $\underline{1}$ เสมอ
 - ทำให้ไม่จำเป็นต้องใส่ bit นี้ลงไปในการแทนค่าระดับ bit (เพิ่มเข้าไปอัตโนมัติตอนคำนวณ)

 $(-1)^s \times M \times 2^E$ 16

Example 1: Decoding

- 8 bit format



- 4 exp bit (k)

$$\text{Bias} = 2^{k-1} - 1$$

- 3 frac bit (n)

$$E = \text{exp} - \text{Bias}$$

- คำนวณหาค่า 0 0110 111

$$M = 1.x_{n-1}x_{n-2}\dots x_0$$

- bias = $2^{4-1} - 1 = 7$

e: exponent bits
f: fraction bits


Bit representation	Exponent			Fraction		Value		
	<i>e</i>	<i>E</i>	2^E	<i>f</i>	<i>M</i>	$2^E \times M$	<i>V</i>	Decimal
0 0110 111	6	-1	1/2	7/8	15/8	15/16	15/16	0.9375



17

Practice Problem 2

เติมตารางให้สมบูรณ์



$$\text{Bias} = 2^{k-1} - 1$$

$$E = \text{exp} - \text{Bias}$$

$$M = 1.x_{n-1}x_{n-2}\dots x_0$$

Bit Representation	Exponent			Fraction		Value		
	<i>e</i>	<i>E</i>	2^E	<i>f</i>	<i>M</i>	$2^E \times M$	<i>V</i>	Decimal
0 0001 000								
0 0110					14/8			
0	000			1				
0	010	7						
0	110				1792/8			
0 1110						240.0		

e: exponent bits
f: fraction bits

19

Example 2: Encoding



- Value: float $F = 204111.0$;

$$204111_{10} = 110001110101001111_2 = 1.10001110101001111 \times 2^{17}$$

- Significand

$$M = 1.\underline{10001110101001111}$$

$$\text{frac} = \underline{10001110101001111}00000$$


- Exponent

$$E = 17$$

$$\text{Bias} = 127$$

$$\text{exp} = 144 = 10010000_2$$

- Result



18

Floating Point

- Fractional Binary Number

- IEEE Floating Point

- Normalized Value


- Denormalized Value

- Special Value

- Rounding

- Floating Point Operation

- Floating Point in C



Bryant • O'Hallaron

20

Case 2: Denormalized Value

- กรณี: $exp = 000\dots0$
- ค่า E คำนวณได้โดยการ แปลงจาก exp :

$$E = \underline{1} - \underline{\text{Bias}}$$

- ค่า M คำนวนได้จาก สูตร:

$$M = \underline{0}.xxx\dots x_2$$

- $xxx\dots x$: bit จากส่วน $frac$

21

Practice Problem 3

เติมตารางให้สมบูรณ์

Bit Representation	Exponent			Fraction			Value	
	e	E	2^E	f	M	$2^E \times M$	V	Decimal
0 0000 000								
0 0000 001								
0 0000 010								
0 0000 011								
0 0000 110								
0 0000 111								

$\bullet \text{Bias} = 2^{k-1} - 1$
 $E = \underline{1} - \underline{\text{Bias}}$
 $M = \underline{0}.xxx\dots x_2$

23


Case 2: Denormalized Value

- แบ่งเป็น 2 กรณี
 - $exp = 000\dots0$ และ $frac = 000\dots0$
 - แทนค่า 0
 - สังเกตการมีค่า +0 และ -0
 - $exp = 000\dots0$ และ $frac \neq 000\dots0$
 - จำนวนที่มีค่าใกล้เคียง 0
 - ช่วงห่างระหว่างจำนวนเท่ากัน

22

Floating Point

- Fractional Binary Number
- IEEE Floating Point
- Normalized Value
- Denormalized Value
- Special Value
- Rounding
- Floating Point Operation
- Floating Point in C



24

case 3: Special Value

- กรณี: $\text{exp} = 111\dots1$
- แบ่งเป็น 2 กรณี
 - $\text{exp} = 111\dots1$ และ $\text{frac} = 000\dots0$
 - แทนค่า ∞ (infinity)
 - สำหรับ operation ที่ทำให้เกิดการ overflow
 - ทั้งกรณี $+\infty$ และ $-\infty$
 - เช่น $1.0/0.0 = -1.0/-0.0 = +\infty$, $1.0/-0.0 = -\infty$
 - $\text{exp} = 111\dots1$ และ $\text{frac} \neq 000\dots0$
 - Not-a-Number (NaN)
 - กรณีที่ไม่สามารถแทนผล Operation ด้วยตัวเลข Floating Point ได้
 - เช่น $\sqrt{(-1)}$, $\infty - \infty$, $\infty \times 0$

25

Dynamic Range (Positive Only)

	s	exp	frac	E	Value	
Denormalized numbers	0	0000	000	-6	0	
	0	0000	001	-6	$1/8*1/64 = 1/512$	closest to zero
	0	0000	010	-6	$2/8*1/64 = 2/512$	
	...					
	0	0000	110	-6	$6/8*1/64 = 6/512$	
	0	0000	111	-6	$7/8*1/64 = 7/512$	largest denorm
	0	0001	000	-6	$8/8*1/64 = 8/512$	smallest norm
	0	0001	001	-6	$9/8*1/64 = 9/512$	
	...					
	0	0110	110	-1	$14/8*1/2 = 14/16$	
Normalized numbers	0	0110	111	-1	$15/8*1/2 = 15/16$	closest to 1 below
	0	0111	000	0	$8/8*1 = 1$	
	0	0111	001	0	$9/8*1 = 9/8$	closest to 1 above
	0	0111	010	0	$10/8*1 = 10/8$	
	...					
	0	1110	110	7	$14/8*128 = 224$	
	0	1110	111	7	$15/8*128 = 240$	largest norm
	0	1111	000	n/a	inf	
	...					

27

Visualization of 6 Bit Representation




Figure 2.33 Representable values for 6-bit floating-point format. There are $k = 3$ exponent bits and $n = 2$ fraction bits. The bias is 3.

26


Special Properties of the IEEE Encoding

- Floating Point Zero ($+0$) is Same as Integer Zero
 - ทุก bit = 0
- สามารถใช้การเปรียบเทียบจำนวน ในลักษณะใกล้เคียงกับ Unsigned Integer
 - ต้องพิจารณา sign bit ก่อน
 - ต้องพิจารณา -0 ว่ามีค่า = 0
- ปัญหากรณี NaNs
 - Will be greater than any other values
 - What should comparison yield?
- กรณีอื่น ๆ เป็นไปตามปกติ
 - Denormalized vs. normalized
 - Normalized vs. infinity

28

Floating Point

- Fractional Binary Number
- IEEE Floating Point
- Normalized Value
- Denormalized Value
- Special Value
- Rounding
- Floating Point Operation
- Floating Point in C



29

Rounding

- เมื่อongจากการแสดงค่าแบบ Floating Point สามารถแทนค่าได้ในช่วงความละเอียดที่จำกัด ทำให้จำเป็นต้องมีการประมาณค่าโดยการปัดเศษทิ้ง (Rounding) เช่น ปัด 1.4 → 1 หรือ ปัด 1.6 → 2
- ต้องพิจารณาตัดสินใจ กรณีค่าที่ต้องการปัดเศษอยู่กึ่งกลางระหว่างผลลัพธ์ที่เป็นไปได้ 2 จำนวน
 - เช่น 1.5 (1 vs 2)
 - ปัดไปทางไหน? เพราะอะไร?
 - $1.5 + 2.5 + 3.5 + 4.5 \text{ VS } 2 + 3 + 4 + 5$

30

Rounding [2]

- ใน IEEE floating-point format มีวิธีการปัดเศษที่ต่างกันถึง 4 วิธี

	IEEE Default Mode				
Mode	\$1.40	\$1.60	\$1.50	\$2.50	\$-1.50
Round-to-even	\$1	\$2	\$2	\$2	\$-2
Round-toward-zero	\$1	\$1	\$1	\$2	\$-1
Round-down	\$1	\$1	\$1	\$2	\$-2
Round-up	\$2	\$2	\$2	\$3	\$-1

31

- การปัดเศษเลขคู่ เป็น Default Mode

- แก้ปัญหากรณีค่าความคลาดเคลื่อนจากการปัดเศษของเลขหลาย ๆ จำนวน (ลงเสมอ หรือ ขึ้นเสมอ) สะสมรวมกัน

- ใช้ในกรณีตัวเลขที่ต้องการปัดอยู่กึ่งกลางเท่านั้น

- เช่น กรณีปัดให้เป็นทศนิยม 2 ตำแหน่ง

1.2349999	1.23 (Less than half way)
-----------	---------------------------

1.2350001	1.24 (Greater than half way)
-----------	------------------------------

1.2350000	1.24 (Half way—round up)
-----------	--------------------------

1.2450000	1.24 (Half way—round down)
-----------	----------------------------

กรณีอื่น ๆ ปัดตามหลักคณิตศาสตร์ปกติ

32

Rounding Binary Numbers

- Binary Fractional Numbers

- เป็นเลขคู่ก์ต่อเมื่อบนทขวासุดหลังจากการปัดเศษ มีค่าเป็น 0
- เช่นที่ต้องการปัดจะมีค่ากึ่งกลางก็ต่อเมื่อยูในรูป = 100...0₂

- Examples

- ปัดเหลือแค่ 2 ตำแหน่งหลัง binary point

Value	Binary	Rounded	Action	Rounded Value
2 3/32	10.00011 ₂	10.00 ₂	(<1/2—down)	2
2 3/16	10.00110 ₂	10.01 ₂	(>1/2—up)	2 1/4
2 7/8	10.11100 ₂	11.00 ₂	(1/2—up)	3
2 5/8	10.10100 ₂	10.10 ₂	(1/2—down)	2 1/2

33

Floating Point Operations


- Basic Idea

- ให้ x และ y เป็นจำนวน floating point
- ผลลัพธ์ของ operation \odot ได ๆ ระหว่าง x และ y จะได้จาก
 - การหาค่าจริงของ $x \odot y$
 - แล้วนำผลลัพธ์ที่ไดมาปัดเศษ (Round) ใหเข้ากับ จำนวนตำแหน่งที่แสดงค่าได้ (frac)

35

Floating Point

- Fractional Binary Number
- IEEE Floating Point
- Normalized Value
- Denormalized Value
- Special Value
- Rounding
- Floating Point Operation
- Floating Point in C



34

Floating Point Addition

การบวก

- กำหนดให้

- $x +^f y$ แทน Round($x + y$)
- มีสมบัติการสลับที่ของการบวก (Commutative)
 - $x +^f y = y +^f x$
- ไม่มีสมบัติการเปลี่ยนกลุ่ม (Associative)
 - $(3.14 + 1e10) - 1e10 \neq 3.14 + (1e10 - 1e10)$
 - เนื่องจากการปัดเศษ

36

Floating Point Addition [2]

// ดังนั้นในการคำนวณ จาก code:

```
x = a + b + c;
y = b + c + d;
```

// มีค่าไม่เท่ากัน

```
t = b + c;
x = a + t;
y = t + d;
```


Floating Point Operation จะมีการ Round ทุกครั้ง

//why?

37

Floating Point

- Fractional Binary Number
- IEEE Floating Point
- Normalized Value
- Denormalized Value
- Special Value
- Rounding
- Floating Point Operation
- Floating Point in C



39

Floating Point Multiplication

การคูณ

- Monotonicity Properties

$$a \geq b \text{ and } c \geq 0 \Rightarrow a \times^f c \geq b \times^f c$$

$$a \leq b \text{ and } c \leq 0 \Rightarrow a \times^f c \leq b \times^f c$$

- Also guaranteed that

$$a \times^f a \geq 0$$

As long as $a \neq NaN$

เครื่องหมายไม่เปลี่ยน แม้จะเกิดการ overflow

38

Floating Point in C

C Guarantees Two Levels

- `float` single precision
- `double` double precision

Conversions/Casting

- Casting between `int`, `float`, and `double` ทำให้มีการเปลี่ยนแปลงรูปแบบของ bit
 - `int` \rightarrow `float`
 - ไม่มีการ overflow แต่มีการปัดเศษ
 - `int/float` \rightarrow `double`
 - คงค่าเดิมไว้ เนื่องจาก `double` สามารถแสดงค่าได้ในช่วงที่กว้างกว่า และมีความเที่ยงตรง (precision) มากกว่า

40

Floating Point in C [2]

- Conversions/Casting [ต่อ]

- `double → float`

- อาจมีการ overflow หากเกินช่วงค่าของ float หากไม่เกิน
อาจมีการปัดเศษ เนื่องจาก precision ที่น้อยกว่า (จำนวน bit `frac` น้อยกว่า)

- `float/double → int`

- ค่าจะถูก round toward 0 (truncate) - ตัดหลังจุดทศนิยม
ให้เหลือแต่จำนวนเต็ม
- กรณี overflow หรือ NaN ไม่ define ใน C

41

Practice Problem 1: KEY

Fractional value	Binary representation	Decimal representation
$\frac{1}{8}$	0.001	0.125
$\frac{3}{4}$	0.11	0.75
$\frac{25}{16}$	1.1001	1.5625
$\frac{43}{16}$	10.1011	2.6875
$\frac{9}{8}$	1.001	1.125
$\frac{47}{8}$	101.111	5.875
$\frac{51}{16}$	11.0011	3.1875

43

Summary

- Floating Point เป็นค่าประมาณของจำนวนจริง ในรูปของ $x \times 2^y$
- มาตรฐาน IEEE 754 เป็นมาตรฐานของ floating point ที่ใช้กันมากที่สุดโดย single precision = 32 bit และ double precision = 64 bit
- IEEE floating point สามารถแทนค่าพิเศษ ได้แก่ $+\infty$ และ $-\infty$ รวมถึง NaN
- การคำนวณต่าง ๆ ที่เกี่ยวข้องกับ floating point ควรทำด้วยความระมัดระวังเนื่องจาก range และ precision ที่จำกัด อีกทั้งยังขาดคุณสมบัติทางคณิตศาสตร์บางประการ

42

Practice Problem 2: KEY

$$\begin{aligned} \text{Bias} &= 2^{k-1} - 1 \\ E &= \text{exp} - \text{Bias} \\ M &= 1.\text{xxx...}x_2 \end{aligned}$$

เติมตารางให้สมบูรณ์

Bit Representation	Exponent			Fraction		Value		
	e	E	2^E	f	M	$2^E \times M$	V	Decimal
0 0001 000	1	-6	$1/64$	0/8	8/8	$8/512$	$1/64$	0.015625
0 0110 110	6	-1	$1/2$	6/8	14/8	$14/16$	$7/8$	0.875
0 0111 000	7	0	1	0/8	8/8	$8/8$	1	1.0
0 0111 010	7	0	1	2/8	10/8	$10/8$	$5/4$	1.25
0 1110 110	14	7	128	6/8	14/8	$1792/8$	224	224.0
0 1110 111	14	7	128	7/8	15/8	$1920/8$	240	240.0

44

Practice Problem 3: KEY

- $\text{Bias} = 2^{k-1} - 1$
- $E = \underline{1} - \text{Bias}$
- $M = \underline{0}.xxx\dots x_2$

เติมตารางให้สมบูรณ์



Bit Representation	Exponent			Fraction		Value		
	E	E	2^E	f	M	$2^E \times M$	V	Decimal
0 0000 000	0	-6	1/64	0/8	0/8	0/512	0	0.0
0 0000 001	0	-6	1/64	1/8	1/8	1/512	1/512	0.001953
0 0000 010	0	-6	1/64	2/8	2/8	2/512	1/256	0.003906
0 0000 011	0	-6	1/64	3/8	3/8	3/512	3/512	0.005859
0 0000 110	0	-6	1/64	6/8	6/8	6/512	3/256	0.011719
0 0000 111	0	-6	1/64	7/8	7/8	7/512	7/512	0.013672