

信息的表示和处理(4)

谢旻晖

2025.9

Floating Point

Outline

- Background: Fractional binary numbers
- IEEE floating point standard: Definition
- Example and properties
- Rounding, addition, multiplication
- Floating point in C
- Summary

Fractional binary numbers

- What is 1011.101_2 ?


定点数计算

What is 1011.101_2 ?

[填空1]

作答

Fractional Binary Numbers



$$\sum_{k=-j}^i b_k \times 2^k$$

Fractional Binary Numbers: Examples

■ Value Representation

5 3/4	101.11_2
2 7/8	10.111_2
1 7/16	1.0111_2

■ 观察

- 通过左移小数点可以除以2（无符号数）
- 通过右移小数点可以乘以2
- 数字 $0.111111\dots_2$ 刚刚比1.0小一点
 - $1/2 + 1/4 + 1/8 + \dots + 1/2^i + \dots \rightarrow 1.0$
 - Use notation $1.0 - \epsilon$

Representable Numbers

- Limitation #1

- 只能精确表示 $x/2^k$ 形式的数字（ x 为整数）
 - 其他数字会是无限小数（循环小数）形式
- Value Representation
 - $1/3$ $0.0101010101[01]..._2$
 - $1/5$ $0.001100110011[0011]..._2$
 - $1/10$ $0.0001100110011[0011]..._2$

- Limitation #2

- 位数有效（ w bits），表达的数字大小范围有限
 - Limited range of numbers (very small values? very large?)

课堂练习

爱国者导弹系统中有一个内置的时钟，其实现类似一个计数器，每 0.1 秒就加 1。为了以秒为单位来确定时间，程序将用一个 24 位的近似于 $1/10$ 的二进制小数值来乘以这个计数器的值。特别地， $1/10$ 的二进制表达式是一个无穷序列 $0.000110011[0011]\cdots_2$ ，其中，方括号里的部分是无限循环的。程序用值 x 近似地表示 0.1， x 只考虑这个序列的二进制小数点右边的前 23 位： $x = 0.00011001100110011001100$ 。（参考练习题 2.51，里面有关于如何更精确地近似表示 0.1 的讨论。）

- A. $0.1 - x$ 的二进制表示是什么？
- B. $0.1 - x$ 的近似的十进制值是多少？
- C. 当系统初始启动时，时钟从 0 开始，并且一直保持计数。在这个例子中，系统已经运行了大约 100 个小时。程序计算出的时间和实际的时间之差为多少？
- D. 系统根据一枚来袭导弹的速率和它最后被雷达侦测到的时间，来预测它将在哪里出现。假定飞毛腿导弹的速率大约是 2000 米每秒，对它的预测偏差了多少？

通过一次读取时钟得到的绝对时间中的一个轻微错误，通常不会影响跟踪的计算。相反，它应该依赖于两次连续的读取之间的相对时间。问题是爱国者导弹的软件已经升级，可以使用更精确的函数来读取时间，但不是所有的函数调用都用新的代码替换。结果就是，跟踪软件一次读取用的是精确的时间，而另一次读取用的是不精确的时间 [100]。

答案

A. 0.1的二进制表示是 $0.000110011[0011]$, 程序中的x是 $0.00011001100110011001100$ 。将两者对齐之后互相减一下:



```
0.0001100110011001100110011001100110011001100110011....
0.000110011001100110011001100
```

得到结果是 $0.000000000000000000000000[1100]$

B. 近似的10进制值是2的24次幂分之一加上2的25次幂分之一。

C. 100个小时之后, 系统计数的次数运行了 $100 * 3600 * 10 = 3600000$ 次。误差大概是0.343秒。

D. $2000 * 343 = 686$ 米

Today: Floating Point

- Background: Fractional binary numbers
- **IEEE floating point standard: Definition**
- Example and properties
- Rounding, addition, multiplication
- Floating point in C
- Summary

定点数的问题

- 无法高效表示非常大的数字，例如 $5 * 2^{100}$ 需要 **101** 后面跟 **100** 个 **0** 的位模式
- 能否仅用 $\langle 5, 100 \rangle$ 两个数代表形如 $x * 2^y$ 的数

Floating Point Representation

- 浮点表示法
 - 举例: $(-1101.0101)_2, m=9, n=3$
 - -0.11010101×2^4

S	Es	E	M
1位	1位	3位	9位
1	0	100	110101010

- -0.011010101×2^5

S	Es	E	M
1位	1位	3位	9位
1	0	101	011010101

IEEE Floating Point

- IEEE Standard 754
 - 在1985年建立，作为浮点数运算的统一标准
 - 在此之前，有很多不同（古怪）的设计
 - 所有主流CPU都支持
- William (Velvel) Morton Kahan 威廉·卡亨
 - 1933 -
 - UC Berkeley
 - 1989年图灵奖，因为数值计算方面的贡献
 - Kahan是浮点运算IEEE标准IEEE 754，IEEE 854的主要设计师



IEEE Floating Point Representation

- Numerical Form:

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

- Sign bit **s** determines whether number is negative or positive
- 尾数Significand **M** normally a fractional value in range [1.0,2.0).
- 阶码Exponent **E** weights value by power of two

- Encoding

- MSB **s** is sign bit **s**
- exp field encodes **E** (but is not equal to E)
- frac field encodes **M** (but is not equal to M)



Precision options


- Single precision: 32 bits (float)



- Double precision: 64 bits (double)




- Extended precision: 80 bits (Intel only, long double)



浮点数编码

- 三种情况


- 1. 规格化的




- 2. 非规格化的



- 3a. 无穷大



- 3b. NaN



"Normalized" Values(规格化)

$$v = (-1)^s M 2^E$$

- When: $\text{exp} \neq 000\dots 0$ and $\text{exp} \neq 111\dots 1$
- E coded as a biased value: $E = \text{Exp} - \text{Bias}$ (移码/偏置)
 - Exp: unsigned value of exp field
 - $\text{Bias} = 2^{k-1} - 1$, where k is number of exponent bits
 - Single precision: **127** (Exp: 1...254, E : -126...127)
 - Double precision: **1023** (Exp: 1...2046, E : -1022...1023)
- M coded with **implied** leading 1: $M = 1.\text{xxx}\dots\text{x}_2$
 - xxx...x: bits of frac field
 - Minimum when $\text{frac}=000\dots 0$ ($M = 1.0$)
 - Maximum when $\text{frac}=111\dots 1$ ($M = 2.0 - \epsilon$)
 - Get **extra** leading bit for "**free**"

Normalized Encoding Example

$$v = (-1)^s M 2^E$$
$$E = \text{Exp} - \text{Bias}$$

- Value: float $F = 15213.0$;
- $15213_{10} = 11101101101101_2$
= $1.1101101101101_2 \times 2^{13}$


- Significand

$$M = 1.\underline{1101101101101}_2$$
$$\text{frac} = \underline{110110110110100000000000}_2$$

- Exponent

$$E = 13$$
$$\text{Bias} = 127$$
$$\text{Exp} = 140 = 10001100_2$$

- Result:



Denormalized Values (非规格化)


$$v = (-1)^s M 2^E$$
$$E = 1 - \text{Bias}$$

- Condition: $\text{exp} = 000\dots 0$
- 阶码 **Exponent value**: $E = 1 - \text{Bias}$ (instead of $E = 0 - \text{Bias}$)
 - 为了平滑过度到规格化浮点数 ($1.\text{xxx} * 2^{-126}$)
 - 非规格化: $0.\text{xxx} * 2^{-126}$
- **M**没有隐藏的1, 方便表示0及接近0的数字: $M = \underline{0}.\text{xxx}\dots\text{x}_2$
- **Cases**
 - **exp** = 000...0, **frac** = 000...0
 - 表示0
 - 但是根据S为0或1, 可以表示 +0 and -0
 - **exp** = 000...0, **frac** $\neq$ 000...0
 - 用于表示接近于 0.0的数字

Special Values

- Condition: **exp** = 111...1
- Case: **exp** = 111...1, **frac** = 000...0
 - Represents value ∞
 - 用来表示overflow
 - 包括 $+\infty$ 和 $-\infty$
 - E.g., $1.0/0.0 = -1.0/-0.0 = +\infty$, $1.0/-0.0 = -\infty$
- Case: **exp** = 111...1, **frac** $\neq$ 000...0
 - Not-a-Number (NaN)
 - 表示无法得到一个数值（出错/未定义）
 - E.g., $0/0$, $\text{sqrt}(-1)$, $\infty - \infty$, $\infty \times 0$


1. 规格化的




2. 非规格化的




3a. 无穷大



3b. NaN



Visualization: Floating Point Encodings




有限范围内的一些采样点，与实数完全不同

Today: Floating Point

- Background: Fractional binary numbers
- IEEE floating point standard: Definition
- **Example and properties**
- Rounding, addition, multiplication
- Floating point in C
- Summary

Tiny Floating Point Example



- 8-bit Floating Point Representation
 - 符号为S是最左边的1位
 - 下面4位是阶码，偏置 $\text{bias}=2^3-1=7$
 - 最后三位是尾数
- 其他规则采用IEEE 754标准
 - 规格化、非规划化
 - 0, NaN, 无穷大的表示

Dynamic Range (Positive Only)

$$v = (-1)^s M 2^E$$

n: $E = \text{Exp} - \text{Bias}$
d: $E = 1 - \text{Bias}$
 $\text{Bias} = 2^3 - 1 = 7$

Denormalized numbers


Normalized numbers

s	k位 exp	m位 frac	E	Value	
0	0000	000	-6	0	
0	0000	001	-6	$1/8 * 1/64 = 1/512$	closest to zero 2^{-m*2}
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 $(1 - 2^{-m})$
0	0001	000	-6	$8/8 * 1/64 = 8/512$	smallest norm $1 * 2^{-m}$
0	0001	001	-6	$9/8 * 1/64 = 9/512$	
...					
0	0110	110	-1	$14/8 * 1/2 = 14/16$	
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 $(2 - 2^{-m})$
0	1111	000	n/a	inf	


Distribution of Values

- 6-bit IEEE-like format

- $e = 3$ exponent bits
- $f = 2$ fraction bits
- Bias is $2^{3-1}-1 = 3$





- Notice how the distribution gets denser toward zero.



Distribution of Values (close-up view)

- 6-bit IEEE-like format


- $e = 3$ exponent bits
- $f = 2$ fraction bits
- Bias is 3



Special Properties of the IEEE Encoding

- 浮点数0和整型0在二进制形式上一样
 - 所有bits都是0 (+0)
- 几乎总可以使用unsigned integer的比较大小的方式
 - 必须首先比较符号位
 - 必须考虑 $-0 = 0$
 - NaNs的问题
 - 比任何其他值都大
 - NaNs有多个值
 - 其他情况OK
 - 非规格化 < 规格化
 - 规格化 < 无穷大

Creating Floating Point Number



- Steps

- 规格化, 首位为 1
- 尾数部分进行round
- 后规格化(Postnormalize)处理round带来的问题


- Case Study

- Convert 8-bit unsigned numbers to tiny floating point format

Example Numbers

128	10000000
15	00001101
33	00010001
35	00010011
138	10001010
63	00111111

Normalize



- Requirement

- Set binary point so that numbers of form 1.xxxxxx
- Adjust all to have leading one
 - Decrement exponent as shift left

Value	Binary	Fraction	Exponent
128	10000000	1.00000000	7
15	00001101	1.10100000	3
17	00010001	1.00010000	4
19	00010011	1.00110000	4
138	10001010	1.00010100	7
63	00111111	1.11111100	5

Rounding

- 向偶数舍入

Value	Fraction	Rounded
128	1.000 0000	1.000
15	1.101 0000	1.101
17	1.000 1000	1.000
19	1.001 1000	1.010
138	1.000 1010	1.001
63	1.111 1100	10.000

方式	1.40	1.60	1.50	2.50	-1.50
向偶数舍入	1	2	2	2	-2
向零舍入	1	1	1	2	-1
向下舍入	1	1	1	2	-2
向上舍入	2	2	2	3	-1

Rounding

- Rounding Modes (illustrate with \$ rounding)

•	\$1.40	\$1.60	\$1.50	\$2.50	-\$1.50
- 向0舍入	\$1	\$1	\$1	\$2	-\$1
- 向下舍入($-\infty$)	\$1	\$1	\$1	\$2	-\$2
- 向上舍入($+\infty$)	\$2	\$2	\$2	\$3	-\$1
- 就近舍入(default)	\$1	\$2	\$2	\$2	-\$2
• 向偶数舍入（距离两边一样的中间结果，向偶数舍入）					

Closer Look at Round-To-Even

- 默认的舍入模式
 - 如果不用汇编语言，很难改为其他round模式
 - 其他模式都是静态偏移
 - round的方向是确定的
 - 所以round-to-even的好处是数字有两个round方向，可以避免/减小统计偏差
- 应用在10进制数字上的例子
 - E.g., round to nearest hundredth

7.8949999	7.89	(Less than half way)
7.8950001	7.90	(Greater than half way)
7.8950000	7.90	(Half way—round up)
7.8850000	7.88	(Half way—round down)

Rounding Binary Numbers

- 二进制小数
 - “Even” 当最小的数字是0时
 - “Half way” 当bits正好在中间位置时 = $100..._2$
- Examples
 - Round to nearest $1/4$ (2 bits right of binary point)

Value	Binary	Rounded	Action	Rounded
Value				
2 3/32	10.00 011 ₂	10.00 ₂	(<1/2—down)	2
2 3/16	10.00 110 ₂	10.01 ₂	(>1/2—up)	2 1/4
2 7/8	10.11 100 ₂	11.00 ₂	(1/2—up)	3
2 5/8	10.10 100 ₂	10.10 ₂	(1/2—down)	2 1/2

Postnormalize

- Issue
 - 舍入时可能导致 **overflow**
 - 可能需要右移 M , 增加 E

Value	Rounded	Exp	Adjusted	Result
128	1.000	7		128
15	1.101	3		15
17	1.000	4		16
19	1.010	4		20
138	1.001	7		134
63	10.000	5	1.000/6	64

Interesting Numbers

{single, double}

<i>Description</i>	<i>exp</i>	<i>frac</i>	<i>Numeric Value</i>
• Zero	00...00	00...00	0.0
• Smallest Pos. Denorm.	00...00	00...01	$2^{-\{23,52\}} \times 2^{-\{126,1022\}}$
- Single $\approx 1.4 \times 10^{-45}$			
- Double $\approx 4.9 \times 10^{-324}$			
• Largest Denormalized	00...00	11...11	$(1.0 - \epsilon) \times 2^{-\{126,1022\}}$
- Single $\approx 1.18 \times 10^{-38}$			
- Double $\approx 2.2 \times 10^{-308}$			
• Smallest Pos. Normalized	00...01	00...00	$1.0 \times 2^{-\{126,1022\}}$
- Just larger than largest denormalized			
• One	01...11	00...00	1.0
• Largest Normalized	11...10	11...11	$(2.0 - \epsilon) \times 2^{\{127,1023\}}$
- Single $\approx 3.4 \times 10^{38}$			
- Double $\approx 1.8 \times 10^{308}$			

宇宙所有原子的数量 10^{80}

课堂练习

- 假设浮点数共**16**位，其中阶码**6**位，采用类**IEEE 754**标准
 - 1) 求浮点数**20.625**的二进制形式
 - 2) 求浮点数能够表示的规格化的最大负数和最小负数，以及非规格化的最大负数和最小负数（二进制+真值）

$$v = (-1)^s M 2^E$$

n: $E = \text{Exp} - \text{Bias}$
d: $E = 1 - \text{Bias}$
 $\text{Bias} = 2^3 - 1 = 7$


假设浮点数共**16**位，其中阶码**6**位，采用类**IEEE 754**标准

- 1) 求浮点数**20.625**的二进制形式
- 2) 求浮点数能够表示的规格化的最大负数和最小负数，以及非规格化的最大负数和最小负数（二进制+真值）

$$v = (-1)^s M 2^E$$

$n: E = \text{Exp} - \text{Bias}$
 $d: E = 1 - \text{Bias}$
 $\text{Bias} = 2^5 - 1 = 31$

16 bit float . 20.625




$$\text{Bias} = 2^{k-1} - 1 = 2^{6-1} - 1 = 31$$

$$20.625_{10} = 10100.101_2$$

↓

$$\underbrace{1.0100101}_{\text{frac}} \times 2^{\textcircled{4}E}$$

$$\text{exp} = E + \text{Bias} = 4 + 31 = 35 = 100011_2$$



课堂练习（答案）

$1.0100101 * 2^4$, 阶码 $4+31= 35$

$\text{Bias} = 2^{\{6-1\}}-1 = 31$

	S	E	M	Value
非规格化	1	000 000	000 000 001	$-2^{(-9)}*2^{(-30)}$
	1	000 000	111 111 111	$-(1-2^{(-9)})*2^{(-30)}$
规格化	1	000 001	000 000 000	$-1*2^{(-30)}$
	1	111 110	111 111 111	$-(2-2^{(-9)})*2^{31}$
特殊情况	1	111 111	0 != 0	Infinite NaN

Today: Floating Point

- Background: Fractional binary numbers
- IEEE floating point standard: Definition
- Example and properties
- **Rounding, addition, multiplication**
- Floating point in C
- Summary

Floating Point Operations: Basic Idea

- $x +_f y = \text{Round}(x + y)$
- $x \times_f y = \text{Round}(x \times y)$
- Basic idea
 - 首先计算精确结果
 - 然后去适配精度，进行溢出/舍入
 - 当阶过大时，可能溢出，变为 $+/- \infty$
 - 尾数可能需要舍入

Floating Point Multiplication


- $(-1)^{s1} M1 2^{E1} \times (-1)^{s2} M2 2^{E2}$
- Exact Result: $(-1)^s M 2^E$
 - Sign s : $s1 \wedge s2$
 - Significand M : $M1 \times M2$
 - Exponent E : $E1 + E2$
- 结果修正
 - 如果 $M \geq 2$, M 右移, 对应增大 E
 - 如果 E 越界, 就 **overflow**
 - 最后 M 的值再进行舍入
- 实现
 - 复杂度最高的部分是尾数的乘法

Floating Point Addition

- $(-1)^{s1} M1 2^{E1} + (-1)^{s2} M2 2^{E2}$
-假设 $E1 > E2$, 首先对阶, $E2 \rightarrow E1$, $M2$ 变小

Get binary points lined up

- 准确结果: $(-1)^s M 2^E$
-Sign s , significand M :
 - Result of signed align & add
- Exponent E : $E1$



- 修正:
 - 如果 $M \geq 2$, 右移 M , 增加 E
 - 如果 $M < 1$, 将 M 左移 k 位到合法区间, E 减小 k (可能规格化, 可能非规格化)
 - 如果 E 超过边界, 则 **overflow**
 - 如果 M 位数过长, 则进行舍入

Mathematical Properties of FP Add

- 是否符合阿贝尔群的特征
 - 加法的封闭性?
• 但是有可能产生无穷或NaN
Yes
 - 交换律?
Yes
 - 结合律?
No
 - Overflow and inexactness of rounding
 - $(3.14+1e10)-1e10 = 0$, $3.14+(1e10-1e10) = 3.14$
 - 0 是加法单位元?
Yes
 - 每个元素都有加法逆元?
Almost
 - Yes, 除了infinities & NaNs
- 单调性
 - $a \geq b \Rightarrow a+c \geq b+c$?
Almost
 - 除了infinities & NaNs

Mathematical Properties of FP Add

- FP加法不具有结合律
 - 对编译器有很大影响
 - 例如 $x = a + b + c$; $y = b + c + d$;
 - 编译器试图优化, 减少一次运算
 - $t = b + c$;
 - $x = a + t$;
 - $y = t + d$
 - 这样可能产生不同的值, 编译器一般会做保守的选择, 避免对程序功能产生影响

Mathematical Properties of FP Mult

- 属性

- 乘法是否封闭?

Yes

- 但可能产生 infinity or NaN

- 交换律?

Yes

- 结合率?

No

- 可能导致溢出, 或者由于舍入带来的不精确

- Possibility of overflow, inexactness of rounding

- Ex: $(1e20 * 1e20) * 1e-20 = \text{inf}$, $1e20 * (1e20 * 1e-20) = 1e20$

- 1是乘法的单位元?

Yes

- 乘法对加法的分配率?

No

- 可能导致溢出, 或者由于舍入带来的不精确

- $1e20 * (1e20 - 1e20) = 0.0$, $1e20 * 1e20 - 1e20 * 1e20 = \text{NaN}$

- 单调性

Almost

- $a \geq b \ \& \ c \geq 0 \Rightarrow a * c \geq b * c$?

- 除了 infinities & NaNs

Ariane 5: 浮点溢出的高昂代价

- 1996.6.4, Ariane 5火箭发射37秒后爆炸（损失5亿美金）



Ariane 5: 浮点溢出的高昂代价

- 原因：导航系统向控制引擎喷嘴的计算机发送了一个无效数据，没有发送飞行控制信息，而是发送了一个诊断位模式，表明将**64**位浮点数转为**16**位有符号位时溢出；
- **Ariene 4**火箭的速度不会超过**16**位浮点数；
- **Ariene 5**速度比**Ariene 4**高出**5**倍，但直接重用了**Ariene 4**的代码；
- 将大的浮点数转换为整数是一种常见的程序错误来源

Today: Floating Point

- Background: Fractional binary numbers
- IEEE floating point standard: Definition
- Example and properties
- Rounding, addition, multiplication
- Floating point in C
- Summary

Floating Point in C

- **C Guarantees Two Levels**

- **float** single precision
- **double** double precision

- **Conversions/Casting**

- **int, float**和**double**之间的转换会改变bit值

- **double/float → int**

- 去掉小数部分
- 向0舍入
- 当超过范围或NaN时没有定义，一般设为**Tmin**（可能过大整数得到负数**Tmin**）

- **int → double**

- 精确的转换，**int**数值 < 53 bit

- **int → float**

- 按照舍入模式来进行舍入

Floating Point Comparison

- 不能用`==`, `!=`判定浮点数相等或不等
 - 0.1这样10进展整齐的数在二进制下可能无法精确表示
 - 要进行近似；而且数字在处理几次之后，会得到一些误差（舍入导致）
 - 所以，可能两个0.1的二进制的表达不完全一样
- 采用`fabs(f1-f2) <= precision`
 - `precision`为自己预设的精度，如`1e-6`
- 但以上`precision`是绝对精度，如果浮点数非常大，可能用`1e-6`就不合适了
 - 应该用相对精度

Floating Point Comparison

- 相对误差和绝对误差结合的方式
 - `bool IsEqual(float a, float b, float absError, float relError) {`
 - `if (a==b) return true;`
 - `if (fabs(a-b)<absError) return true;`
 - `if (fabs(a)<fabs(b)) return (fabs((a-b)/a)<relError) ? true`
 `: false;`
 - `return (fabs((a-b)/b)<relError) ? true : false;`
 - `}`

Floating Point Puzzles (课堂练习)

- 对于下面的每一个C语言表达式:

- 或者证明各种情况都为真
- 或者解释为什么不为真

```
int x = ...;  
float f = ...;  
double d = ...;
```

- `x == (int)(float) x`
- `x == (int)(double) x`
- `f == (float)(double) f`
- `d == (double)(float) d`
- `f == -(-f);`

假设d和f都不是NaN

- `2/3 == 2/3.0`
- `d > f` $\Rightarrow$ `-f > -d`
- `d * d >= 0.0`
- `(d+f) - d == f`

Summary

- IEEE浮点数标准有清晰的数学属性
- 浮点数表示数字的形式是 $M \times 2^E$
- 和实数代数不一样
 - 违反结合率和分配率
 - 使**compiler**和一些严格的计算型应用程序很难做

课堂练习

- 分配给你一个任务，编写一个**C**函数用来计算 2^x 的浮点表示。你意识到完成这个任务的最好方法是直接创建结果的**IEEE**单精度表示。
- 当 x 太小时返回**0.0**；当 x 太大时返回 $+\infty$ 。
- 填写下面的代码空白，以计算出正确的结果。
- 假设函数**u2f**返回的浮点值与它的无符号参数有相同的位表示。
- ```
float fpwr2(int x) {
 - unsigned exp, frac, u;
 - if (x < _____) {
 • exp = _____;
 • frac = _____;
 - } else if (x < _____) {
 • exp = _____;
 • frac = _____;
 - } else if (x < _____) {
 • exp = _____;
 • frac = _____;
 - } else {
 • exp = _____;
 • frac = _____;
 - }
 - u = exp<<23 | frac;
 - return u2f(u);
 • }
```

# 练习答案

- 分配给你一个任务，编写一个**C**函数用来计算 $2^x$ 的浮点表示。你意识到完成这个任务的最好方法是直接创建结果的**IEEE**单精度表示。
- 当 $x$ 太小时返回0.0；当 $x$ 太大时返回 $+\infty$ 。
- 填写下面的代码空白，以计算出正确的结果。
- 假设函数u2f返回的浮点值与它的无符号参数有相同的位表示。
- ```
float fpwr2(int x) {  
    - unsigned exp, frac, u;  
    - if (x < -149) { //太小，返回0  
        • exp = 0;  
        • frac = 0;  
    - } else if (x < -126) { //非规格化  
        • exp = 0;  
        • frac = 1<<(x+149);  
    - } else if (x < 128) { //规格化  
        • exp = x+127;  
        • frac = 0;  
    - } else {  
        • exp = 255; // 太大，返回 $+\infty$   
        • frac = 0;  
    - }  
    - u = exp<<23 | frac;  
    - return u2f(u);  
    • }
```