

Курс «Алгоритмы и алгоритмические языки»
1 семестр 2014/2015

Лекция 9

Вычисления с плавающей точкой

- ❖ Предпосылки: дробные двоичные числа
- ❖ Стандарт арифметики с плавающей точкой IEEE 754:
 - Определение
 - Пример и свойства
 - Округление, сложение, умножение
 - Плавающие типы языка Си
 - Выводы


Дробные двоичные числа

❖ Что такое 1011.101_2 ?

$$1 \times 2^3 + 0 \times 2^2 + 1 \times 2^1 + 1 \times 2^0 + 1 \times 2^{-1} + 0 \times 2^{-2} + 1 \times 2^{-3} =$$

$$= 11\frac{5}{8} = 11.625$$

Дробные двоичные числа



- ◆ Чёрное пятнышко – двоичная точка
- ◆ Биты слева от точки умножаются на положительные степени 2
- ◆ Биты справа от точки умножаются на отрицательные степени 2

Дробные двоичные числа

- ◊ $0.111111\dots_2 = 1.0 - \varepsilon$ ($\varepsilon \rightarrow 0$), так как

$$\frac{1}{2} + \frac{1}{4} + \frac{1}{8} + \dots + \frac{1}{2^n} + \dots \rightarrow 1 \quad \text{при } n \rightarrow \infty$$

- ◊ Точно можно представить только числа вида $\frac{x}{2^k}$

- ◊ Остальные рациональные числа представляются периодическими двоичными дробями:

$$\frac{1}{5} = 0.(0011)_2$$

- ◊ Иррациональные числа представляются апериодическими двоичными дробями и могут быть представлены только приближенно

Представление чисел с плавающей точкой (IEEE 754)

- ◊ Числа с плавающей точкой представляются в нормализованной форме: $(-1^s) M 2^e$
 - ◆ s – код знака числа (он же знак мантиссы)
 - ◆ M – мантисса ($1 \leq M < 2$)
 - ◆ e – (двоичный) порядок
- ◊ Первая цифра мантиссы в нормализованном представлении всегда 1. В стандарте принято решение не записывать в представление числа эту единицу (тем самым мантисса как бы увеличивается на разряд).

Экономия связана с тем, что в представление числа записывается не M , а $\text{frac} = M - 1$

Представление чисел с плавающей точкой

- ❖ Чтобы не записывать отрицательных чисел в поле порядка, вводится *смещение* $bias = 2^{k-1} - 1$, где k – количество бит в поле для записи порядка, и вместо порядка e записывается код порядка exp , связанный с e соотношением $e = exp - bias$.
- ❖ Нормализованное число $(-1^s) M 2^e$ упаковывается в машинное слово (структуру) с полями s , $frac$ и exp

| | | |
|-----|---------------------|-----------------------|
| s | exp (код порядка) | $frac$ (код мантиссы) |
|-----|---------------------|-----------------------|

Ширина поля s всегда равна 1.

Ширина полей exp и $frac$ зависит от точности числа

Представление чисел с плавающей точкой

- ❖ Одинарная точность (32 бита):



8 бит

23 бита

$$bias = 127; \quad -126 \leq e \leq 127 ; \quad 1 \leq exp \leq 254$$

- ❖ Двойная точность (64 бита):




11 бит

52 бита

$$bias = 1023; \quad -1022 \leq e \leq 1023 ; \quad 1 \leq exp \leq 2046$$

- ❖ Повышенная точность (80 бит):



15 бит

64 бита

Представление чисел с плавающей точкой

❖ Пример

◆ Значение `float f = 15213.0`

$$15213_{10} = 11101101101101_2 = \\ 1.1101101101101_2 \times 2^{13}$$

◆ Значащая часть

$$M = 1.\underline{1101101101101},$$

$$\text{frac} = \underline{1101101101101}0000000000_2$$

◆ Порядок

$$e = 13$$

$$\text{bias} = 127$$

$$\text{exp} = 140 = 10001100_2$$

◆ Результат

| | | |
|---|----------|--------------------------|
| 0 | 10001100 | 110110110110100000000000 |
| s | exp | frac |

Представление нуля

- ◊ Для типа **float** код порядка **exp** изменяется от **00000001** до **11111110**
(значению **00000001** соответствует порядок **e = - 126**,
значению **11111110** – порядок **e = 127**)
- ◊ Код **exp = 00000000, frac = 000...0**
представляет нулевое значение; в зависимости от
значения знакового разряда **s** это либо **+0** либо **-0**
- ◊ А какое значение представляют коды
exp = 00000000, frac ≠ 000...0?
exp = 11111111?


Большие числа

Пусть `exp = 111...1`

- ❖ если при этом `frac = 000...0`, то коду будет соответствовать значение ∞ (со знаком `s`)
- ❖ если же `frac ≠ 000...0`, то код не будет представлять никакое число («значение», представляемое таким кодом, так и называется: «не число» – `NaN` – Not a number)

Денормализованные числа

- ❖ Это числа, представляемые кодами
 $\text{exp} = 00000000$, $\text{frac} \neq 000...0$
- ❖ exp вносит в значение такого числа постоянный вклад 2^{-k-2} ,
 frac меняется от 000...01 до 111...1 и рассматривается уже не как мантисса, а как значение, умножаемое на exp
- ❖ Рассмотрим это на модельном примере:



8-разрядные числа с плавающей точкой (положительные)

| s | exp | frac |
|---|-----|------|
|---|-----|------|

1 4 бита

3 бита

| s | exp | frac | E | Value |
|---|-----|------|---|-------|
|---|-----|------|---|-------|

0 0000 000 -6 0

0 0000 001 -6 $1/8 * 1/64 = 1/512$ Близкие к 0

0 0000 010 -6 $2/8 * 1/64 = 2/512$

...

0 0000 110 -6 $6/8 * 1/64 = 6/512$

0 0000 111 -6 $7/8 * 1/64 = 7/512$ Наибольшее ненормализованное

0 0001 000 -6 $8/8 * 1/64 = 8/512$ Наименьшее

0 0001 001 -6 $9/8 * 1/64 = 9/512$ нормализованное

...

0 0110 110 -1 $14/8 * 1/2 = 14/16$

0 0110 111 -1 $15/8 * 1/2 = 15/16$ Ближайшее к 1 снизу

0 0111 000 0 $8/8 * 1 = 1$

0 0111 001 0 $9/8 * 1 = 9/8$ Ближайшее к 1 сверху

0 0111 010 0 $10/8 * 1 = 10/8$

...

0 1110 110 7 $14/8 * 128 = 224$


0 1110 111 7 $15/8 * 128 = 240$

0 1111 000 n/a inf

Ненормализованные
числа


Нормализованные
числа

8-разрядные числа с плавающей точкой



Важные частные случаи

| | exp | frac | Численное значение |
|--|---------|---------|--|
| ◊ Нуль | 00...00 | 00...00 | 0 . 0 |
| ◊ Наим. положит. денорм. | 00...00 | 00...01 | |
| ♦ float $\approx 1.4 \times 10^{-45}$ | | | $2^{-23} \times 2^{-126}$ |
| ♦ double $\approx 4.9 \times 10^{-324}$ | | | $2^{-52} \times 2^{-1022}$ |
| ◊ Наиб. положит. денорм. | 00...00 | 11...11 | |
| ♦ float $\approx 1.18 \times 10^{-38}$ | | | $(1.0 - \varepsilon) \times 2^{-126}$ |
| ♦ double $\approx 2.2 \times 10^{-308}$ | | | $(1.0 - \varepsilon) \times 2^{-1022}$ |
| ◊ Наим. положит. норм. | 00...01 | 00...00 | |
| ♦ float | | | 1.0×2^{-126} |
| ♦ double | | | 1.0×2^{-1022} |
| ◊ Единица | 01...11 | 00...00 | 1 . 0 |
| ◊ Наиб. положит. норм. | | | |
| ♦ float $\approx 3.4 \times 10^{38}$ | | | $(2.0 - \varepsilon) \times 2^{127}$ |
| ♦ double $\approx 1.8 \times 10^{308}$ | | | $(2.0 - \varepsilon) \times 2^{1023}$ |



Операции над числами с плавающей точкой

◊ $x +_{FP} y = Round(x + y)$

$x \times_{FP} y = Round(x \times y)$

где $Round()$ означает округление

◊ Выполнение операции

- ◆ Сначала вычисляется точный результат
(получается более длинная мантисса, чем запоминаемая, иногда в два раза)
- ◆ Потом фиксируется исключение
(например, переполнение)
- ◆ Потом результат округляется, чтобы поместиться в поле $frac$

Умножение чисел с плавающей точкой

- ◊ $(-1)^{s1} \cdot M1 \cdot 2^{e1} \times (-1)^{s2} \cdot M2 \cdot 2^{e2}$
- ◊ Точный результат $(-1)^s \cdot M \cdot 2^e$
 - ◆ Знак s $s1 \wedge s2$
 - ◆ Значащие цифры M $M1 \times M2$
 - ◆ Порядок e $e1 + e2$
- ◊ Преобразование
 - ◆ Если $M \geq 2$, сдвиг M вправо с одновременным увеличением e
 - ◆ Если e не помещается в поле exp , переполнение
 - ◆ Округление M , чтобы оно поместилось в поле $frac$
- ◊ Основные затраты на перемножение мантисс


Сложение чисел с плавающей точкой

❖ $(-1)^{s1} \cdot M1 \cdot 2^{e1} + (-1)^{s2} \cdot M2 \cdot 2^{e2}$

Пусть $e1 > e2$

❖ Точный результат $(-1)^s \cdot M \cdot 2^e$

- ♦ Знак s и значащие цифры M вычисляются как показано на рисунке
- ♦ Порядок суммы – $e1$



❖ Преобразование

- ♦ Если $M \geq 2$, сдвиг M вправо с одновременным увеличением e
- ♦ Если $M < 1$, сдвиг M влево на k позиций с одновременным вычитанием k из e
- ♦ Если e не помещается в поле exp , переполнение
- ♦ Округление M , чтобы оно поместилось в поле $frac$

Плавающие типы языка Си

`float, double, long double`

❖ ***Операции над данными с плавающей точкой.***

- ◆ *Одноместные*: изменение знака («одноместный минус»: -), одноместный плюс (+).
- ◆ *Двухместные*: сложение (+), вычитание (-), умножение (*), деление (/).

❖ ***Порядок выполнения арифметических операций в выражениях (приоритет).***

- ◆ самый низкий приоритет у двухместных + и -,
- ◆ более высокий приоритет у двухместных * и /,
- ◆ еще более высокий приоритет у одноместных + и -.
- ◆ В выражениях без скобок операции с более высоким приоритетом выполняются раньше.
- ◆ Скобки позволяют изменить порядок выполнения операций.

Пример 1. Вычисление суммы 5 чисел типа **float**

(мантиssa – 6 десятичных цифр, порядок – 2 десятичных цифры):

$$0.231876 \cdot 10^2 + 0.645391 \cdot 10^{-3} + 0.231834 \cdot 10^{-1} + 0.245383 \cdot 10^{-2} + \\ 0.945722 \cdot 10^{-3} =$$

a) **$0.231876 \cdot 10^2 + 0.645391 \cdot 10^{-3} + 0.231834 \cdot 10^{-1} + 0.245383 \cdot 10^{-2} + 0.945722 \cdot 10^{-3} = 0.2321\cancel{4}7 \cdot 10^2;$**

$$23.1876 + 0.000645391 = 23.188245391 = 23.1882 = 0.231882 \cdot 10^2;$$

$$23.1882 + 0.0231834 = 23.2113834 = 23.2114 = 0.232114 \cdot 10^2;$$

$$23.2114 + 0.00245383 = 23.21385383 = 23.2138 \cdot 10^2;$$

$$23.2138 + 0.000945722 = 23.214745722 = 23.2147 = 0.232147 \cdot 10^2;$$

b) **$0.645391 \cdot 10^{-3} + 0.9457 \cdot 10^{-3} + 0.245383 \cdot 10^{-2} + 0.231834 \cdot 10^{-1} + 0.231876 \cdot 10^2 = 0.2321\cancel{5}7 \cdot 10^2;$**

$$0.000645391 + 0.000945722 = 0.001591113 = 0.00159111 = 0.159111 \cdot 10^{-2};$$

$$0.00159111 + 0.00245383 = 0.00494493 = 0.494493 \cdot 10^{-2};$$

$$0.00494493 + 0.0231834 = 0.02812833 = 0.0281283 = 0.281283 \cdot 10^{-1};$$

$$0.0281283 + 23.1876 = 23.2157283 = 23.2157 = 0.232157 \cdot 10^2;$$

Пример 2. Вычисление разности плавающих чисел

(мантиssa – 6 десятичных цифр, порядок – 2 десятичных цифры):

$$0.238617 \cdot 10^2 - 0.238616 \cdot 10^2 + 0.645391 \cdot 10^4 - 0.645392 \cdot 10^4 + 0.845791 \cdot 10^0 - 0.835790 \cdot 10^0 =$$

a) $0.238617 \cdot 10^2 - 0.238616 \cdot 10^2 + 0.645391 \cdot 10^4 - 0.645392 \cdot 10^4 + 0.845791 \cdot 10^0 - 0.835790 \cdot 10^0 = 0.100000 \cdot 10^{-5}$

$$0.238617 \cdot 10^2 - 0.238616 \cdot 10^2 = 23.8617 - 23.8616 = 0.0001 = 0.100000 \cdot 10^3$$
$$0.100000 \cdot 10^{-3} + 0.645391 \cdot 10^4 = 0.0001 + 6453.91 = 6453.9101 = 0.645391 \cdot 10^4$$
$$0.645391 \cdot 10^4 - 0.645392 \cdot 10^4 = -0.000001 \cdot 10^4 = -0.100000 \cdot 10^{-1}$$
$$-0.100000 \cdot 10^{-1} + 0.845791 \cdot 10^0 = -0.01 + 0.845791 = 0.835791 \cdot 10^0$$
$$0.835791 \cdot 10^0 - 0.835790 \cdot 10^0 = 0.000001 \cdot 10^0 = 0.100000 \cdot \underline{10^{-5}}$$

b) $0.238617 \cdot 10^2 + 0.645391 \cdot 10^4 + 0.845791 \cdot 10^0 - (0.238616 \cdot 10^2 + 0.645392 \cdot 10^4 + 0.835790 \cdot 10^0) = 0.100000 \cdot 10^0$

$$0.238617 \cdot 10^2 + 0.645391 \cdot 10^4 = 23.8617 - 6453.91 = 6478.6 = 0.647777 \cdot 10^4$$
$$0.647777 \cdot 10^4 + 0.845791 \cdot 10^0 = 6477.77 + 0.845791 = 6478.615791 = 0.647862 \cdot 10^4$$
$$0.238616 \cdot 10^2 + 0.645392 \cdot 10^4 = 23.8616 + 6453.92 = 6477.7816 = 6477.78 \cdot 10^4$$
$$6477.78 \cdot 10^4 + 0.835790 \cdot 10^0 = 6477.78 + 0.835790 = 6478.61579 = 0.647852 \cdot 10^4$$
$$0.647862 \cdot 10^4 - 0.647852 \cdot 10^4 = 0.000010 \cdot 10^4 = 0.100000 \cdot \underline{10^{-4}}$$

Выводы

- (1) **При вычислении суммы чисел с одинаковыми знаками** необходимо упорядочить слагаемые по возрастанию и складывать, начиная с наименьших слагаемых.
- (2) **При вычислении суммы чисел с разными знаками** необходимо сначала сложить все положительные числа, потом – все отрицательные числа и в конце выполнить одно вычитание.
- (3) **Вычитание** (сложение чисел с противоположными знаками) **часто приводит к потере точности**, которая у чисел с плавающей точкой определяется количеством значащих цифр в мантиссе (при вычитании двух близких чисел мантисса «исчезает», что ведет к резкой потере точности).
Итак, **чем меньше вычитаний, тем точнее результат.**

Значащими цифрами числа с плавающей точкой называются все цифры его мантиссы за исключением нулей, стоящих в ее конце. Например, у числа $0.\mathbf{6700089}0000 * 10^3$ все цифры, выделенные жирным шрифтом, значащие. При вычитании двух близких чисел почти все значащие цифры пропадают. Например, $0.67000890 * 10^3 - 0.67000880 * 10^3 = 0.00000010 * 10^3 = 0.10 * 10^{-4}$. Таким образом, у результата всего одна значащая цифра, хотя у операндов было по 7 значащих цифр.