

Лекция №1  
по курсу  
«Машинная арифметика в рациональных чисел»

Москва, 2020

# Литература

1. Overton, Michael L. Numerical computing with IEEE floating point arithmetic
2. Behrooz Parhami. Computer arithmetic
3. Koren Izrael. Computer arithmetic algorithms/ 2<sup>nd</sup> ed.
4. Поспелов Д.А. Арифметические основы вычислительных машин дискретного действия. Учеб. пособие. - М.: Изд-во "Высш. школа", 1970. - 308 с.
5. Яглом И., Системы счисления. Журнал Квант

# Компьютерная арифметика

Было бы ошибкой считать, что компьютерная арифметика необходима только разработчикам процессоров. Мы рассмотрим дальше примеры, как более эффективно точнее составлять расчётные программы, избегать вычислительных ошибок, свойственных арифметики с плавающей точкой.

Основные вопросы предмета компьютерная арифметика – это:

1. Разработка эффективных цифровых схем.
2. Ускорение арифметических операций и вычисление специальных функций.
3. Разработка алгоритмов быстрого выполнения арифметических операций.
4. Анализ ошибок округления,
5. Аппаратная реализация.
6. Тестирование, верификация программ

# Требования к системам счисления

1. Возможность представления чисел в заданном диапазоне
2. Однозначность представления
3. Простоту записи
4. Удобство работы человека с машиной
5. Трудоёмкость выполнения арифметических операций
6. Экономичность системы (количество элементов, необходимое для представления многоразрядных чисел)
7. Удобство аппаратной реализации

# Вычислительная машина «Сетунь»




Брусенцов Николай Петрович  
(1925 г – 2014 г)

60-е года прошлого века  
(-1, 0, 1)

$$-5 = (-1)(0)(-1)$$

# Сетунь – первый в мире троичный компьютер



# Представление чисел в системах счисления

Любое число в позиционной системе счисления с основанием  $q$  можно представить в виде

$$a_{n-1}q^{n-1} + \dots + a_1q^1 + a_0,$$

где

$a_0, \dots, a_{n-1}$  — цифры,

$q$  — основание системы счисления

# Представление в смешанной системе счисления

Рассмотрим упорядоченный набор из  $n$  целых чисел

$$\rho = [r_1, r_2, \dots, r_n],$$

компоненты которого  $r_1, r_2, \dots, r_n$  назовем *основаниями*. Пусть  $R$  есть произведение оснований, т. е.

$$R = \prod_{i=1}^n r_i.$$

Хорошо известно (например, см. [Szabó, Такака, 1967, с. 41]), что каждое целое число  $s$ , такое, что

$$0 \leq s < R,$$

можно единственным образом представить в виде

$$s = d_0 + d_1(r_1) + d_2(r_1 r_2) + \dots + d_{n-1}(r_1 r_2 \dots r_{n-1}),$$

# Представление в смешанной системе счисления

$$0 \leq d_i < r_{i+1}, \quad i = 0, 1, \dots, n-1.$$

Заметим, что основная роль  $r_n$  служить границей для  $d_{n-1}$ .

Упорядоченный набор цифр  $d_0, d_1, \dots, d_{n-1}$  для данного  $s$  записывается в виде

$$\langle s \rangle_\rho = \langle d_0, d_1, \dots, d_{n-1} \rangle.$$

Например, если  $\rho = [2, 3, 5]$ , то  $R = 30$ : Следовательно, из

$$29 = 1 + 2(2) + 4(2 \cdot 3)$$

имеем  $d_0 = 1, d_1 = 2, d_2 = 4$ . Отсюда

$$\langle 29 \rangle_\rho = \langle 1, 2, 4 \rangle.$$

# Представление в смешанной системе счисления

$$S = d_0 + r_1(d_1 + d_2 (r_2) + \dots + d_{n-1} (r_2 * r_3 * \dots * r_{n-1}) )$$

$$t_1 = (d_1 + d_2 (r_2) + \dots + d_{n-1} (r_2 * r_3 * \dots * r_{n-1}) )$$

$$S = d_0 + r_1 * t_1$$

$$d_0 =$$

$$S - d_0 = r_1(d_1 + d_2 (r_2) + \dots + d_{n-1} (r_2 * r_3 * \dots * r_{n-1}) )$$

$$(S - d_0) * r_1^{-1} = d_1 + d_2 (r_2) + \dots + d_{n-1} (r_2 * r_3 * \dots * r_{n-1})$$

# Система счисления с отрицательным основанием

Система счисления с отрицательным основанием  $-q$ , множество цифр  $[0, q - 1]$ .

$$\sum_i x_i \cdot (-q)^i = \sum_{i \text{ четн}} x_i \cdot (q)^i - \sum_{i \text{ не четн}} x_i \cdot (q)^i$$

# Экономичность систем счисления

Четкое размещение максимума экономичности может быть установлено методом последующих рассуждений. Пусть имеется  $n$  символов для записи чисел, а основание системы счисления  $p$ . Тогда количество разрядов числа  $k = n/p$ , а полное количество чисел ( $N$ ), которые могут быть составлены, равно:

$$N = p^k. \quad (4.10)$$

Если считать  $N(p)$  непрерывной функцией, то можно отыскать то значение  $p_m$ , при котором  $N$  воспринимает наибольшее значение. Функция имеет вид, представленный на рис.4.3.




Рис. 4.1. Зависимость количества чисел от основания системы счисления при использовании 12-ти возможных цифр для записи чисел

# ДОПОЛНИТЕЛЬНЫЙ КОД

Дополнительный код позволяет заменить операцию вычитания на операцию сложения и сделать операции сложения и вычитания одинаковыми для знаковых и беззнаковых чисел, чем упрощает архитектуру ЭВМ. В англоязычной литературе обратный код называют первым дополнением, а дополнительный код называют

Положительное целое число  $x$ , где  $0 \leq x \leq 2^{31} - 1$  записывается как  $x$ , отрицательное число  $-y$ , где  $1 \leq y \leq 2^{31}$  как положительное  $2^{32} - y$ .

При записи числа в дополнительном коде старший разряд является знаковым. Если его значение равно 0, то в остальных разрядах записано положительное двоичное число, совпадающее с прямым кодом.

Двоичное 3-разрядное число со знаком в дополнительном коде может представлять любое целое в диапазоне от  $-4$  до  $+3$ . Если старший разряд равен нулю, то наибольшее целое число, которое может быть записано в оставшихся 2 разрядах, равно  $2^2 - 1 = 3$ .

Активация Wind

# ДОПОЛНИТЕЛЬНЫЙ КОД

Десятичное представление	Двоичное	Дополнительный код
0	000	0
1	001	1
2	010	2
3	011	3
4	100	-4
5	101	-3
6	110	-2
7	111	-1

Умножение может дать целочисленное переполнение.

Целочисленное деление на ноль обычно приводит к завершению программы и сообщению об ошибке для пользователя

# ДОПОЛНИТЕЛЬНЫЙ КОД


## Упражнение 1.

Покажите, что если целое число  $x$  между и представлено в дополнительном коде, самый левый бит равен 1, если  $x$  отрицателен, и 0, если  $x$  равен 0 или положительный.

## Упражнение 2.

Простой способ преобразовать представление неотрицательного целого числа  $x$  к представлению в дополнительный код  $-x$  начинается с изменения всех нулевых битов на единичные и всех единичных бит в нулевые. Еще один шаг необходим для завершения процесса. Какой шаг и зачем?

# Формат с фиксированной точкой



$$11/2 = 0\ 000000000000101\ 1000000000000000$$

$$x = (0000\ 0000.0000\ 1001)_2,$$

$$y = (1001\ 0000.0000\ 0000)_2$$

## 2. ФОРМАТ С ПЛАВАЮЩЕЙ ТОЧКОЙ

В формате представления чисел с плавающей точкой имеем:

$$x = (-1)^s \cdot m \cdot q^e,$$

где

$s \in \{0, 1\}$  - знак числа,

$m$  - мантисса,  $m \geq 0$ ,

$e$  - экспонента (целое число).

Число с плавающей запятой имеет четыре компонента: знак  $s$ , мантиссу  $m$ , основание системы счисления  $q$  и показатель  $e$ . Вместе эти четыре компонента представляют собой число.

Мантисса числа  $x$  имеет  $n$  значащих цифр.

Специальный случай, когда  $m = 0$  служит для представления нуля.

# Нормализованный формат с плавающей точкой



$$x = \pm S \cdot 10^E, \quad 1 \leq S < 10$$

$$x = \pm S \cdot 2^E, \quad 1 \leq S < 2$$

$$0,123 = 0,123 \cdot 10^0$$

$$0,123 = 123 \cdot 10^{-3}$$

$$0,123 = 1.23 \cdot 10^{-1}$$

# Формат с плавающей точкой

Двоичное представление мантиссы имеет вид:

$$S = (b_0 . b_1 b_2 b_3 \dots)_2, \text{ с } b_0 = 1$$

Например,

$$\frac{13}{2} = 6 + \frac{1}{2} = (1.101) \cdot 2^2$$

Так как бит  $b_0 = 1$ , то

$$S = (1 . b_1 b_2 b_3 \dots)_2,$$

~~Часть числа, следующая после двоичной точки называют~~ дробной частью мантиссы.

Представление вида (1) с мантиссой заданной в виде (2) называется нормализованным представлением чисел в формате с плавающей точкой. Процесс получения нормализованных чисел называется нормализацией.

# Формат с плавающей точкой

Знаковый бит равен 0 для положительных чисел и 1 для отрицательных.

Поскольку поле экспоненты составляет 8 битов, то в нём можно представить значения в диапазоне от -128 до 127.

Нет необходимости хранения бита  $b_0$ , т.к. он всегда равен единице и является скрытым битом.

При представлении вещественных чисел в формате с плавающей точкой, не имеющих конечного двоичного представления, лишние разряды отбрасываются, например, для чисел с плавающей точкой длиной 32 бит, число

$$1/10 = (0.0001100110\ 011 \dots)_2$$

Алгоритмы ИИИ

# Формат с плавающей точкой

Пусть значение экспоненты принадлежит диапазону  $e_{\min} \leq e < e_{\max}$ . Число называется представимым в формате с плавающей точкой, если его можно представить в виде:

$$(-1)^s \cdot m \cdot q^e, \text{ с } e_{\min} \leq e < e_{\max}$$

Пусть рассматривается случай 1, когда мантисса удовлетворяет неравенству  $q^{-1} \leq m < 1$ , тогда минимальное представимое число равно  $q^{e_{\min} - 1}$  и максимальное  $q^{e_{\max}} (1 - q^{-n})$ .

## Нарушение законов алгебры

- No associative property for floats
- $(a + b) + (c + d)$  (parallel)  $\neq ((a + b) + c) + d$  (serial)
- Looks like a “wrong answer”

# ПРИМЕР ЗАДАЧИ, ИМЕЮЩЕЙ РЕЗКИЙ РОСТ ОШИБОК ОКРУГЛЕНИЯ

Матрица Гильберта  $A = \{a_{ij}\}$ ,  $a_{ij} = \frac{1}{i+j-1}$

## Обращение матрицы Гильберта порядка 3

С точностью 2 знака после запятой

$$A = \begin{bmatrix} 1 & 1/2 & 1/3 \\ 1/2 & 1/3 & 1/4 \\ 1/3 & 1/4 & 1/5 \end{bmatrix}$$

$$A_{\text{прибл}}^{-1} = \begin{bmatrix} -1,17 & 19,51 & -23 \\ 19,51 & -112,94 & 112 \\ -23 & 112 & -100 \end{bmatrix}$$

Макс. относ. погрешн. более 100%.

С точностью 3 знака после запятой


$$A_{\text{прибл}}^{-1} = \begin{bmatrix} 10,101 & 29,598 & 64,798 \\ -41,039 & -192,78 & -202,4 \\ 34,6 & 202,4 & 200 \end{bmatrix}$$

Макс. относ. погрешность более 100%.

**Точный результат:**

$$A_{\text{точн}}^{-1} = \begin{bmatrix} 9 & -36 & 30 \\ -36 & 192 & -180 \\ 30 & -180 & 180 \end{bmatrix}$$

# Рост разрядности и тактовой частоты процессоров по годам



**Гипотеза: Технологические трудности создания процессоров высокой разрядности**

## Пример нарушения алгебраического свойства ассоциативности

$$(a \oplus b) \oplus c \neq a \oplus (b \oplus c) \quad \oplus - \text{ сложение чисел с плавающей точкой}$$

Любое число с плавающей точкой в нормальной форме можно представить в следующем виде:

$$a \cdot q^b,$$

где

$q$  – основание системы счисления,

$b$  – порядок числа,

$a$  – мантисса числа и  $q^{-1} \leq |a| < 1$ .

$$q = 2,$$

Мантисса числа с плав. точкой	Порядок числа			
	$b = 0$	$b = 1$	$b = 2$	$b = 3$
100	1/2	1	2	4
101	5/8	5/4	5/2	5
110	3/4	3/2	3	6
111	7/8	7/4	7/2	7

## Задачи

1. Доказать, что

$$\left(\frac{1}{2} \oplus \frac{1}{2}\right) \oplus 6 \neq \frac{1}{2} \oplus \left(6 \oplus \frac{1}{2}\right)$$

2. Найти диапазон представления чисел с плавающей точкой