

浮点数取整

考虑 C 语言中对双精度浮点数 (double d) 取整的不同方法，尤其是魔数取整的原理。

强制类型转换

直接使用 `int(d)` 进行强制类型转换会向零截断 (`int(-3.7)=-3`)，但是超出 `int` 范围的转换是未定义行为，可能得到错误结果。

标准库函数

`math` 库提供了 `round` (四舍五入)、`rint` (四舍六入五取偶)、`trunc` (向零截断) 等不同语义的取整函数。

在 x87 (早期 x86 CPU 的浮点指令集) 中，浮点取整的硬件指令 `FRNDINT` 默认使用“取偶”语义，但是存在以下问题：

1. 非单周期指令，延迟大；
2. 通过一个不精确标志处理浮点数中的特殊值等情况；
3. 使用浮点栈，需要在寄存器和内存间来回搬运。

导致基于 `FRNDINT` 实现 `rint` 需要生成其他指令，执行效率低。

在支持 SSE/AVX (SIMD 指令集) 的现代 CPU 上，`rint` 会被直接编译成一条硬件指令，且速度极快，不再需要魔数取整。

魔数取整

针对 x87 上存在的问题，编译器开始用魔数取整法实现 `rint`，以替代缓慢的 `FRNDINT` 实现。即 $\text{rint}(d) = d + A - A$ ，其中魔数 $A = 2^{52}$ 。

设 `double d = 1.75`，在 IEEE-754 标准下，其机器数如下：

s (1位)	e (11位)	m (52位)
0	011 1111 1111	110...0

$$d = (-1)^s \times 1.m \times 2^{(e-1023)}$$

$$1.75_D = 1.11 \times 2^0_B = (-1)^0 \times 1.11 \times 2^{(1023-1023)}$$

$$\begin{aligned} & 1.75 + 2^{52} \\ &= 1.11 \times 2^0 + 1.0 \times 2^{52} \\ &= 0.0 \cdots 0111 (\text{小数点后} 51 \text{个} 0) \times 2^{52} + 1.0 \times 2^{52} \\ &= 1.0 \cdots 0111 (\text{小数点后} 51 \text{个} 0) \times 2^{52} \\ &= 1.0 \cdots 010 (\text{舍入，小数点后} 50 \text{个} 0 + 10) \times 2^{52} \end{aligned}$$

$$\begin{aligned}
& 1.75 + 2^{52} - 2^{52} \\
&= 1.0 \cdots 010 (\text{小数点后50个0} + 10) \times 2^{52} - 1.0 \times 2^{52} \\
&= 0.0 \cdots 010 (\text{小数点后50个0} + 10) \times 2^{52} \\
&= 1.0 \times 2^1 (\text{规格化}) \\
&= 2.0D
\end{aligned}$$

-1.75、1.5 等类似，可以得到正确的结果。

不太一样地， $-1.5 + 2^{52} - 2^{52} = -1.5$ ，而不是预期的 -2.0。

$$\begin{aligned}
& -1.5 + 2^{52} \\
&= -1.1 \times 2^0 + 1.0 \times 2^{52} \\
&= -0.0 \cdots 011 (\text{小数点后51个0}) \times 2^{52} + 1.0 \times 2^{52} \\
&= 0.1 \cdots 101 (\text{小数点后51个1} + 01) \times 2^{52} \\
&= 1.1 \cdots 101 (\text{规格化，小数点后50个1} + 01) \times 2^{51} \\
& -1.5 + 2^{52} - 2^{52} \\
&= 1.1 \cdots 101 (\text{小数点后50个1} + 01) \times 2^{51} - 1.0 \times 2^{52} \\
&= 0.1 \cdots 101 (\text{小数点后51个1} + 01) \times 2^{52} - 1.0 \times 2^{52} \\
&= -0.0 \cdots 011 (\text{小数点后51个0}) \times 2^{52} \\
&= -1.1 \times 2^0 (\text{规格化}) \\
&= -1.5D
\end{aligned}$$

由于双精度浮点数的尾数部分只有 52 位，当 $|d + A| > 2^{52}$ 时，浮点数 $|d + A|$ 的最低有效位单位（ULP）为 1.0，即小数部分会被舍入到临近整数，再减 A 就实现了对 d 取整。

当 $d = -1.5$ 时， $|d + A| < 2^{52}$ 其小数部分能够保留，取整失败，所以对于负数 d ，正确的顺序是 $d - A + A$ 。为了避免判断正负的开销，可以设置魔数 $A = 2^{52} + 2^{51}$ ，这样对于任意 $|d| \leq 2^{51}$ ， $\text{rint}(d) = d + A - A$ 。当 $|d| > 2^{51}$ 时， $|d + A| > 2^{53}$ ，ULP=2.0，此时对于所有奇数 d 取整的结果是错误的。

参考

1. <https://gcc.gnu.org/legacy-ml/gcc/2004-04/msg00872.html>
2. https://cgit.freebsd.org/src/tree/lib/msun/src/s_rint.c