

本レジюмеは竹澤照著「Fortran II」第3章, 第4章」を主に参考にしている. またある数 ( $\beta$  進表記) の  $k$  桁目の数  $f_k$  を  $\alpha$  進表記に変換したものを  $({}^\beta f_k)_\alpha$  と表記している.

## 浮動小数点操作

### 実数の数体系

#### 実数の数体系の定義

実数の数体系を

$$x = \begin{cases} 0 \\ \text{または} \\ s \times b^e \times \sum_{k=1}^p (({}^b f_k)_{10} \times b^{-k}) \end{cases} \quad (1)$$

と定義する. ここで  $b$  および  $p$  は2以上の整数<sup>1)</sup>,  $f_k$  は  $b$  未満の非負の整数 (ただし,  $f_1 \neq 0^{2)}$ ,  $s$  は  $-1$  または,  $+1$  であり,  $e$  はある最小値の整数  $e_{\min}$  からある最大値の整数  $e_{\max}$  までの間の整数である. これは実数  $x$  を指数部  $b^e$  と仮数部  $\sum_{k=1}^p ({}^b f_k)_{10} \times b^{-k}$  に分けて表現する正規化した浮動小数点表現である<sup>3)</sup>.

#### 単精度 (32bit 2 進数) での表現

32bit 2 進数の場合 (??) は,

<sup>1)</sup>  $p$  は1でもいいと思われる.

<sup>2)</sup> 常に小数部を小数点以下1桁からの表現にするため

<sup>3)</sup> レジюме「実数の浮動小数点表現と誤差」(1)式を, 本レジюме (??) 式の形で表すと,

$$\begin{aligned} x &= \pm {}^\beta 0.f_1 f_2 \dots f_m \beta^{\pm E} \\ &= 0 \quad \text{or} \quad s \times \beta^{\pm E} \times \sum_{k=1}^m (({}^\beta f_k)_{10} \times \beta^{-k}). \end{aligned}$$

となる. 竹澤照著「Fortran II」第3章, 第4章」では, 仮数部を小数部と表現しているが, このレジюмеでは前のレジюмеにあわせて仮数部としている.

$$x = \begin{cases} 0 \\ \text{または} \\ s \times 2^e \times \left( \frac{1}{2} + \sum_{k=2}^{24} ((^2f_k)_{10} \times 2^{-k}) \right) \end{cases} \quad (2)$$

となる<sup>4)</sup>. ここで,  $-125 \leq e \leq 128$  である. 指数部  $e$  は 8bit 分の領域があるため, 本来 -127 から 128 までを表現できるはずである. しかしながら, 無限大と非数 (not-a-number, NaN) を表すために 2 つ少なくなっている.

図 1: 単精度浮動小数点数体系の模式図.  $s$  は符号,  $e$  は指数部,  $f_k$  は仮数部をそれぞれ表している.

### 倍精度 (64bit 2 進数) での表現

倍精度実数の数体系は, (??) によって定義した数体系の  $p$  を, 単精度のときの約 2 倍にしたものである. (??) の形で倍精度実数の数体系を表すと,

$$x = \begin{cases} 0 \\ \text{または} \\ s \times 2^e \times \left( \frac{1}{2} + \sum_{k=2}^{53} ((^2f_k)_{10} \times 2^{-k}) \right) \end{cases} \quad (3)$$

### 組み込み関数での表現

使用している計算機の  $e_{\max}$ ,  $e_{\min}$ ,  $b$  の値, および指数を 10 進数に換算した値は, それぞれ数値問合せ組み込み関数 MAXEXPONENT, MINEXPONENT, RADIX および RANGE によって出力できる. (??) の  $p$  の値は数値問合せ組み込み関数 DIGITS と PRECISION によって知ることができる. これらの値から基本実数型の数体系

<sup>4)</sup>項に  $\frac{1}{2}$  が入るのは  $f_1 \neq 0$  であるため. 2 進数の場合は  $f_1 = 1$  と固定される.

図 2: 倍精度浮動小数点数体系の模式図.  $s$  は符号,  $e$  は指数部,  $f_k$  は仮数部をそれぞれ表している.

で扱える数の範囲が決まる. また, 最大の数および最小の正の数は, 組み込み関数 HUGE および TINY によって知ることができる.

## マシンイプシロン

$p$  の値が有限であることにより,

$$1 + \varepsilon_M \neq 1 \quad (4)$$

となる最小の数  $\varepsilon_M (> 0)$  が存在する. この  $\varepsilon_M$  を「マシンイプシロン (machine epsilon)」という. マシンイプシロンは組み込み関数 EPSILON を用いて調べることができる. 関数 epsilon(x) での値は  $x$  の数体系でのマシンイプシロン  $b^{1-p}$  となる<sup>5)</sup>.

## 数値問い合わせ組み込み関数の利用

以下のプログラムを実行することにより, 使用している計算機の実数についての諸量を知ることができる.

5)

$$1 \approx {}^b 0.1f_2 \dots f_p \times b^1.$$

この桁より小さな桁では桁落ちを起こしてしまう. よって, この値に桁落ちを起こさないぎりぎりの数  $\varepsilon$  は小数部  $(0.1f_2 \dots f_p)_b$  の最小値である. よって,

$$\begin{aligned} \varepsilon &= {}^b 0.00 \dots 1 \times b^1 \\ &= {}^b 0.100 \dots 0 \times b^{1-(p-1)} \\ &= \frac{1}{b} \times b^{1-(p-1)} \\ &= b^{1-p} \end{aligned}$$

である.