

ε -pT_EX の浮動小数点演算の超簡易説明書

北川 弘典

2008 年 1 月

本文章では、 ε -pT_EX で実装されている浮動小数点演算について概説する．詳細な実装方法についてはソースや../ks2/resume.* 他に譲ることにして，ここでは簡単に使い方のみ述べる．

0.1 準備

本文章でいう浮動小数点数とは，よくあるように $-235.673578432E-534$ のように，符号と 10 進小数からなる仮数部に，必要に応じて E or e で始まる指数部が続いたものである．符号は複数あってもよく，そのときは全部掛け算したものが最終的な符号となる．小数点は日米などで使われるピリオドも，欧州大陸で使われるコンマも許容される．

浮動小数点数に纏わるエラーは，オーバーフロー (Floating arithmetic overflow) と例外 (Floating arithmetic exception) の 2 種類のみである．エラーメッセージを出して一旦停止するが，無限大値や NaN 値をそれぞれ代入して続けることができる．

なお，浮動小数点演算を使う場合は， ε -T_EX でいうところの extended mode で処理しなければならない．README.txt にそってフォーマットファイルを作り，それを使った場合は，extended mode は最初から on になっている．

0.2 初期化

浮動小数点演算を行うときには，計算に使用する一時領域や定数 π などを確保する必要がある．これは自動では行われない．

<code>\fpinit</code>	前段落に書いた一時領域その他を確保する．
<code>\fpdest</code>	前段落に書いた一時領域その他を解放する．

初期化を忘れて演算を行おうとしても，特に T_EX 側でエラーチェックは行わない．そのため，セグメンテーション違反のようなエラーを引き起こす危険性がある．解放忘れや二重確保は単にメモリを無駄にするだけ^{*1}で，それ以外に問題はない．

0.3 代入，型変換，入出力

<code>\real <real></code>	浮動小数点数を表現する glue (以下， $\langle f\text{-}glue \rangle$ と称する) を返す．
---------------------------------	--

^{*1} それも，T_EX の枠内において．

<code>\fpfrac</code> $\langle f\text{-}glue \rangle$	引数の仮数部を返す．
<code>\fpexpr</code> $\langle f\text{-}glue \rangle$	引数の指数部を返す．
<code>\fptoint</code> $\langle f\text{-}glue \rangle$	引数を整数に変換したものを返す．範囲内に収まらないときは, <code>Number too big</code> エラーを返す．なお, 引数が整数でないときは, 0 に近い方に丸められる．
<code>\fptodim</code> $\langle f\text{-}glue \rangle$	引数を <code>dimension</code> に, 1.0 がちょうど 1pt になるように変換したものを返す．範囲内に収まらないときは, <code>Dimension too large</code> エラーを返す．なお, 引数が $1/65536$ (1sp に対応) でないときは, 同じように 0 に近い方に丸められる．

0.4 四則演算等

<code>\fpadd</code> $\langle f\text{-}reg \rangle$ $\langle real \rangle$	$\langle f\text{-}glue \rangle$ が格納された skip レジスタ (以下, $\langle f\text{-}reg \rangle$ と称する) と浮動小数点数を引数にとり, 2 つの浮動小数点数の和を計算して, $\langle f\text{-}glue \rangle$ に上書きする．
<code>\fpsub</code> $\langle f\text{-}reg \rangle$ $\langle real \rangle$	同様に差を計算して, $\langle f\text{-}glue \rangle$ に上書きする．
<code>\fpmul</code> $\langle f\text{-}reg \rangle$ $\langle real \rangle$	同様に積を計算して, $\langle f\text{-}glue \rangle$ に上書きする．
<code>\fpdiv</code> $\langle f\text{-}reg \rangle$ $\langle real \rangle$	同様に商を計算して, $\langle f\text{-}glue \rangle$ に上書きする．
<code>\fppow</code> $\langle f\text{-}reg \rangle$ $\langle real \rangle$	同様に累乗を計算して, $\langle f\text{-}glue \rangle$ に上書きする． $x^y = \exp(y \log x)$ で計算するため, 第 1 引数が負ではエラーが生じる．
<code>\fppowi</code> $\langle f\text{-}reg \rangle$ $\langle number \rangle$	<code>\fppow</code> と同様に累乗を計算するが, 第 2 引数, つまり指数部分は整数に限られる．その代わり, 第 1 引数は負でもかまわない．

0.5 単項演算

以下は単項演算で, $\langle f\text{-}reg \rangle$ を 1 つとり, 演算をし, 結果をその $\langle f\text{-}reg \rangle$ に上書きする．よって, 以下はコマンドの引数も省略し, 演算内容しか書かない．引数の内容は便宜的に x で表す．

<code>\fpneg</code>	-1 倍を計算する．
<code>\fpsqr</code>	平方根 \sqrt{x} を計算する．
<code>\fpexp</code>	指数関数 $\exp x$ を計算する．
<code>\fplog</code>	対数関数 $\log x$ を計算する．
<code>\fpabs</code>	絶対値を計算する．
<code>\fpceil</code>	天井関数 $\lceil x \rceil$, つまり x を越えない最小の整数を計算する．
<code>\fpfloor</code>	床関数 $\lfloor x \rfloor$, つまり x 以下の最大の整数を計算する．
<code>\fpsin, \dots, \fptan</code>	それぞれ三角関数 $\sin x, \cos x, \tan x$ を計算する．
<code>\fpsinh, \dots, \fptanh</code>	それぞれ双曲線関数 $\sinh x, \cosh x, \tanh x$ を計算する．
<code>\fpasin, \dots, \fpatan</code>	それぞれ逆三角関数 $\arcsin x, \arccos x, \arctan x$ を計算する． 結果は $\arcsin x, \arctan x \in [-\pi/2, \pi/2]$, $\arccos x \in [0, \pi]$ である (主値をとって) ．
<code>\fpasinh, \dots, \fpatanh</code>	それぞれ逆双曲線関数 $\operatorname{arsinh} x, \operatorname{arcosh} x, \operatorname{artanh} x$ を計算する． 結果は $\operatorname{arsinh} x, \operatorname{artanh} x \in \mathbf{R}$, $\operatorname{arcosh} x \in [0, \infty]$ の範囲に収まる．

0.6 数値積分によるサンプル

本節では、 $f(x) = 1/(x+3)$ を $[-1, 1]$ で、区間を 40 等分に分割して台形則、中点則、Simpson 法による数値積分を行う。当然ながら真値は $\log 2 \simeq 6.93147180559945309417 \times 10^{-1}$ である。

たたき台として、以下の Fortran 90 のプログラムを使用した。これは 2007 年度夏学期の東京大学理学部数学科の講義「計算数理 I」で僕が提出したレポートの中にあったプログラムを簡略化したものである。

```
PROGRAM main
  IMPLICIT REAL*8 (a-h,o-z)
  a=-1d0; b=1d0; n=40; d=0d0; u=0d0
  DO i=0,n-1
    u=u+1d0/(3d0+a+(b-a)*i/n)
    d=d+1d0/(3d0+a+(b-a)*(i+5d-1)/n)
  END DO
  u=u+5d-1*1d0/(3d0+b)-5d-1*1d0/(3d0+a)
  WRITE(*,*) 'DAIKEI: ', u*(b-a)/n
  WRITE(*,*) 'CHUTEN: ', d*(b-a)/n
  WRITE(*,*) 'SIMPSON: ', (u+2d0*d)*(b-a)/n/3d0
  END
```

これの実行結果は以下である。

```
[h7k doc]$ gfortran -o ks1 ks1.f90
[h7k doc]$ ./ks1
DAIKEI:    0.693186240009141
CHUTEN:    0.693127651979310
SIMPSON:    0.693147181322587
```

これを ϵ -pTeX の浮動小数点演算で書き直して計算させたところ、以下の結果になった：

台形則での計算結果：	$6.93186240009140538665 \times 10^{-1}$
中点則での計算結果：	$6.9312765197931015099 \times 10^{-1}$
Simpson 則での計算結果：	$6.93147181322586946883 \times 10^{-1}$
真値：	$6.93147180559945309417 \times 10^{-1}$

本文書のソースを示す。ε-TeX の `\numexpr` 相当の機能がまだ準備されていないので、ソースは無残な姿である。

```
1  %!eplatex fp.tex
   \documentclass[a4j,papersize]{jsarticle}
   \def\epTeX{$\varepsilon$-pTeX}\def\etex{$\varepsilon$-TeX}
   \def<#1>{${\langle\hbox{\it #1}/}\rangle$}
5  \def\.#1{{\tt\char'134 #1}}
   \def\listx{\def\makelabel{\selectfont } \def\@{\hfill}
   \labelwidth=14zw\labelsep1zw\itemindent11zw\leftmargin=4zw}
   \def\arcsinh{\mathop{\rm arcsinh}}
   \def\arccosh{\mathop{\rm arccosh}}
10  \def\arctanh{\mathop{\rm arctanh}}
   \fpinit % 浮動小数点演算を使用するため
   \usepackage{moreverb}
   \title{\epTeX の浮動小数点演算の超簡易説明書}
   \author{北川 弘典}
15  \date{2008 年 1 月}
   \begin{document}

   \maketitle
   本文章では、\epTeX で実装されている浮動小数点演算について概説する。
20  詳細な実装方法についてはソースや{\tt ../ks2/resume.*}\, 他に譲ることにして、
   ここでは簡単に使い方のみ述べる。

   \subsection{準備}
   本文章でいう{\gt 浮動小数点数}とは、よくあるように
25  \.{-235.673578432E-534}のように、符号と 10 進小数からなる仮数部に、必要に
   応じて{\tt E} or {\tt e}で始まる指数部が続いたものである。符号は複数あってもよく、
   そのときは全部掛け算したものが最終的な符号となる。小数点は日米などで使わ
   れるピリオドも、欧州大陸で使われるコンマも許容される。

30  浮動小数点数に纏わるエラーは、オーバフロー ({\tt Floating arithmetic
   overflow}) と例外 ({\tt Floating arithmetic exception}) の 2 種類のみである。エ
   ラーメッセージを出して一旦停止するが、無限大値や NaN 値をそれぞれ代入して
   続けることができる。

35  なお、浮動小数点演算を使う場合は、\etex でいうところの extended mode で処
   理しなければならない。{\tt README.txt}にそってフォーマットファイルを作り、
   それを使った場合は、extended mode は最初から on になっている。

   \subsection{初期化}
40  浮動小数点演算を行うときには、計算に使用する一時領域や定数$\pi$などを確保
   する必要がある。これは自動では行われない。
   \begin{list}{}{\listx}
   \item[{\fpinit}\@] 前段落に書いた一時領域その他を確保する。
   \item[{\fpdest}\@] 前段落に書いた一時領域その他を解放する。
45  \end{list}
   初期化を忘れて演算を行おうとしても、特に\TeX 側でエラーチェックは行わない。
```

そのため、セグメンテーション違反のようなエラーを引き起こす危険性がある。
解放忘れや二重確保は単にメモリを無駄にするだけ\footnote{それも、\TeX の枠
内において。}で、それ以外に問題はない。

50

```
\subsection{代入，型変換，入出力}
\begin{list}{}{\listx}
\item[\.{freal}\ \<real>\@] 浮動小数点数を表現する glue (以下，\<f-glue>と称
する) を返す。
```

55 \item[\.{ffrac}\ \<f-glue>\@] 引数の仮数部を返す。

```
\item[\.{fpexpr}\ \<f-glue>\@] 引数の指数部を返す。
```

```
\item[\.{fpint}\ \<f-glue>\@] 引数を整数に変換したものを返す。範囲内に
収まらないときは，{\tt Number too big}エラーを返す。なお，引数が整数でな
いときは，0 に近い方に丸められる。
```

60 \item[\.{fptodim}\ \<f-glue>\@] 引数を dimension に，\$1.0\$ がちょうど
\$1\,\$pt になるように変換したものを返す。範囲内に収まらないときは，{\tt
Dimension too large}エラーを返す。なお，引数が\$1/65536\$ (1\,sp に対応) で
ないときは，同じように 0 に近い方に丸められる。

```
\end{list}
```

65

```
\subsection{四則演算等}
```

```
\begin{list}{}{\listx}
```

```
\item[\.{fpadd}\ \<f-reg>\ \<real>\@]
```

```
\<f-glue>が格納された skip レジスタ (以下，\<f-reg>と称する) と浮動小数点
数を取引数にとり，2 つの浮動小数点数の和を計算して，\<f-glue>に上書きする。
```

70 \item[\.{fpsub}\ \<f-reg>\ \<real>\@]

```
同様に差を計算して，\<f-glue>に上書きする。
```

```
\item[\.{fpmul}\ \<f-reg>\ \<real>\@]
```

```
同様に積を計算して，\<f-glue>に上書きする。
```

75 \item[\.{fpdiv}\ \<f-reg>\ \<real>\@]

```
同様に商を計算して，\<f-glue>に上書きする。
```

```
\item[\.{fppow}\ \<f-reg>\ \<real>\@] 同様に累乗を計算して，\<f-glue>に
上書きする。$x^y=\exp(y\log x)$で計算するため，第 1 引数が負ではエラーが生じる。
```

```
\item[\.{fppow}\ \<f-reg>\ \<number>\@]\.{fppow}と同様に累乗を計算する
```

80 が，第 2 引数，つまり指数部分は整数に限られる。

```
その代わり，第 1 引数は負でもかまわない。
```

```
\end{list}
```

```
\subsection{単項演算}
```

85 以下は単項演算で，\<f-reg>を 1 つとり，演算をし，結果をその\<f-reg>に上
書きする。よって，以下はコマンドの引数も省略し，演算内容しか書かない。引
数の内容は便宜的に\$x\$で表す。

```
\begin{list}{}{\listx}
```

90 \item[\.{fpneg}\@] \$-1\$倍を計算する。

```
\item[\.{fpsqr}\@] 平方根$\sqrt{x}$を計算する。
```

```
\item[\.{fpexp}\@] 指数関数$\exp x$を計算する。
```

```
\item[\.{fplog}\@] 対数関数$\log x$を計算する。
```

```
\item[\.{fpabs}\@] 絶対値を計算する。
```

95 \item[\.{fpceil}\@] 天井関数\$\lceil x \rceil\$，つまり\$x\$を越えない最小の

整数を計算する .

```
\item[\.{fppfloor}\@] 床関数 $\lfloor x \rfloor$ , つまり $x$ 以下の最大の
```

整数を計算する .

```
\item[\.{fpsin}, \ldots, \., \.{fptan}\@]
```

100 それぞれ三角関数 $\sin x$, $\cos x$, $\tan x$ を計算する .

```
\item[\.{fpsinh}, \ldots, \., \.{fptanh}\@]
```

それぞれ双曲線関数 $\sinh x$, $\cosh x$, $\tanh x$ を計算する .

```
\item[\.{fpasin}, \ldots, \., \.{fpatan}\@] それぞれ逆三角関数 $\arcsin$ 
```

105 $x \in [-\pi/2, \pi/2]$, $\arccos x \in [0, \pi]$ である (主値をとてる) .

```
\item[\.{fpasinh}, \ldots, \., \.{fpatanh}\@] それぞれ逆双曲線関数
```

$\operatorname{arcsinh} x$, $\operatorname{arccosh} x$, $\operatorname{arctanh} x$ を計算する . \\結果は $\operatorname{arcsinh} x$,
 $\operatorname{arctanh} x \in \mathbb{R}$, $\arccos x \in [0, \infty]$ の範囲に収まる .

```
\end{list}
```

110

\subsection{数値積分によるサンプル}

本節では, $f(x)=1/(x+3)$ を $[-1,1]$ で, 区間を 40 等分に分割して台形則, 中
点則, Simpson 法による数値積分を行う . 当然ながら真値は

```
\skip300=\real2\fplog\skip300\log2\simeq\fpfrac\skip300\times
```

115 $10^{\operatorname{fpexpr}\skip300}$

である .

たたき台として, 以下の Fortran 90 のプログラムを使用した . これは 2007 年度夏
学期の東京大学理学部数学科の講義「計算数理 I」で僕が提出したレポートの中

120 にあったプログラムを簡略化したものである .

```
\begin{verbatim}
PROGRAM main
  IMPLICIT REAL*8 (a-h,o-z)
  a=-1d0; b=1d0; n=40; d=0d0; u=0d0
125  DO i=0,n-1
    u=u+1d0/(3d0+a+(b-a)*i/n)
    d=d+1d0/(3d0+a+(b-a)*(i+5d-1)/n)
  END DO
  u=u+5d-1*1d0/(3d0+b)-5d-1*1d0/(3d0+a)
130  WRITE(*,*) 'DAIKEI: ', u*(b-a)/n
  WRITE(*,*) 'CHUTEN: ', d*(b-a)/n
  WRITE(*,*) 'SIMPSON: ', (u+2d0*d)*(b-a)/n/3d0
  END
\end{verbatim}
```

135 これの実行結果は以下である .

```
\begin{verbatim}
[h7k doc]$ gfortran -o ks1 ks1.f90
[h7k doc]$ ./ks1
DAIKEI:   0.693186240009141
140  CHUTEN:   0.693127651979310
  SIMPSON:   0.693147181322587
\end{verbatim}
```

```

145 % 以降にプログラムに入る．とりあえずは上のものを逐語訳する方向でいこう．
    これを\epTeX の浮動小数点演算で書き直して計算させたところ，以下の結果に
    なった：

    \par\vskip0.5\baselineskip\par
150 \newskip\nia\newskip\nib\newskip\nid
    \newskip\niu\newcount\nin\newcount\nii
    %
    \nia=\real-1 \nib=\real1 \nin=40 \nid=\real0 \niu=\nid % line 3
    %
155 \nii=0
    \loop \ifnum\nii<\nin\relax
        \skip300=\real3 \fpadd\skip300\nia % \skip300 = 3+a
        \skip301=\real\nii \fpdiv\skip301\nin % \skip301=i/n
        \skip302=\nib \fpsub\skip302\nia \fpmul\skip302\skip301 % \skip302=(b-a)*i/n
160 \skip301=\skip300 \fpadd\skip301\skip302 % \skip301=3+a+(b-a)*i/n
        \fppowi\skip301 by -1 \fpadd\niu\skip301 % line 5
        \skip301=\real\nii \fpadd\skip301by0.5 \fpdiv\skip301\nin
        \skip302=\nib \fpsub\skip302\nia \fpmul\skip302\skip301
        \skip301=\skip300 \fpadd\skip301\skip302
165 \fppowi\skip301 by -1 \fpadd\nid\skip301 % line 6
        \advance\nii by1
    \repeat
    %
    \skip300=\real0.5 \skip301=\real3 \fpadd\skip301\nib
170 \fpdiv\skip300\skip301
    \skip301=\real0.5 \skip302=\real3 \fpadd\skip302\nia
    \fpdiv\skip301\skip302
    \fpsub\skip300\skip301 \fpadd\niu\skip300 % line 8
    %
175 \skip300=\nib \fpsub\skip300\nia \fpdiv\skip300by\nin
    \fpmul\niu\skip300 \fpmul\nid\skip300 % 先に (b-a)/n で掛けておく
    %
    \noindent
    \leavevmode\hbox to 13zw{台形則での計算結果：\hss}%
180 $\fpfrac\niu\times 10^{\fpexpr\niu}$\\
    %
    \leavevmode\hbox to 13zw{中点則での計算結果：\hss}%
    $\fpfrac\nid\times 10^{\fpexpr\nid}$\\
    %
185 \leavevmode\hbox to 13zw{Simpson 則での計算結果：\hss}%
    \skip300=\niu\fpadd\skip300\nid\fpadd\skip300\nid\fpdiv\skip300by3
    $\fpfrac\skip300\times 10^{\fpexpr\skip300}$\\
    %
    \leavevmode\hbox to 13zw{真値：\hss}%
190 \skip300=\real2\fplog\skip300
    $\fpfrac\skip300\times 10^{\fpexpr\skip300}$

    \newpage

```

本文書のソースを示す．\eTeX の\verb+\numexpr+ 相当の機能がまだ準備されて
195 いないので，ソースは無残な姿である．
\small
\listinginput[5]{1}{fp.tex}
\end{document}