

あふれのない浮動小数点表示について

東京大学 工学部 伊理 正夫
松井 正一

要旨

従来の浮動小数点表現方式で問題となっていた指数部あふれを解決する新しい表現方式の提案を行う。新表現方式は、指数部と仮数部との境界を動的に変化させることにより、指数部あふれを防ぐとともに、普通の大きさの数に対しこれより高い精度を確保することができる。また普通の数ではない数をいくつか考えるとともに、“数の体系”を閉じたものとすと、新しい表現方式が効果を發揮するよう計算例も示す。

1. はじめに

数値計算と計算機を使う際には、実数(の近似値)を一語中に“浮動小数点”の形で表すのが慣習になっている。初期の計算機では“固定小数点”が用いられたが、“桁取り(スケーリング)”の繁雜さのために、有効桁数の少々(指數部に割当て三分)の犠牲を払っても任意の大きさの数が同じ相対精度で取扱える浮動小数点方式は完全に軍配が上がった。浮動小数点方式にも多くの変種があるが、最近では、IBM型の16進、指数部絶対値、指數部ケビット“げたばき”式の型が優勢である。経験が積まれるにつれて、このIBM型に対する多くの不満が数値計算家の間で広じてゐる。

最も切実な問題の一つは“あふれ(overflow, underflow)”である。一枚の解説[6]にも二のようないくつかの問題の指摘がある。一般に、Hamming[4]も述べているように、計算が進むにつれて扱われる数の指數部の絶対値の範囲は広がるので、扱える数の範囲がたとえば $(16^{-26}, 16^{26})$
 $\approx (10^{-77}, 10^{77})$ のようだ。それ限られていくと、それからはみ出す数が生じ易い。これを防ぐため計算途上での数の大きさを常に検査するのではなく「スケーリング」の心配無用」という浮動小数点方式の最大の特長が失なわれてしまう。一枚[6]に紹介されてゐるKahanの提案は一言でいえば、(i)一語中の指數部に割当てる部分を増大させ、(ii)“非数”を導入してあふれた後の面倒をもみ子にしてある。

その他、記数法の在(=2, 4, 8, 16等)の良し悪しについての議論^[1], [2] (およびその参考文献), 通常のものとは異なる表示体系の提案^[3], [4] 等々, 浮動小数点方式の本質的な問題への関心が最近高まりつつあるようだ。

可変語長にすれば問題はすべて解決するといふ議論もあるが^[5], 非常に特殊な目的を除けば, 通常の数値計算では一つの数値の扱うべき“情報量”には当然限度があり, 計算時間, 記憶場所の経済性の点からも, これらは考慮の外としてよいであろう。

本論文では, 「固定語長内で実数を近似的に表現する」^[6] 大前提のもとで, 一つの理想的な方式を提案し, その特徴を調べ, それを具体的に実現し, これによる数値計算例を示す。

本論文で提案する方式の基本的な考え方を形式(ばらす)述べると次の2点となる。(i)与えられた一語中に数を表現する際, より重要な情報を順に必要なビットを割当てる(指数部に必要なだけのビット数を必ず確保した後, 残りを仮数部に用い, 指数部だけでも入り切らなくなったら, 仮数部を更に浮動小数点表示にして, “指数部, 指数部”に優先的に割当てる; 以下同様を二と繰り返す)。(ii)数値演算の結果が常にプログラム取り扱い可能な形である(あふれたよ子寄辻斗が生じたときに)ために導入すべき必要な十分な“非数”をも含んだ“数の体系”を確定させよ。(二の隠四則演算に関する対称性を重視する。)

(i) は \rightarrow (ii) は Morris [10] に類似の着想が認められ、また Knuth [9] の演習問題(第4章2.1節の17番)にそのような方向への示唆があるが、本論文ではその可能性を徹底的に追求してみる。(ii) は (i) とほとんど“独立を考え方”で、Kahan 等が部分的に論じてある [8]、いくつかの妥当と考えられる前提のもとで必然的に一つの体系が確定されることを指摘する。

2. 基本的考え方

2.1. 指数部可変長方式とその一般化

実数 x の浮動小数点表現は、底を $\beta (= 2, 4, 10, 16 \text{ 等})$ とすとき、
 < レベル 0 >
$$x = (-1)^{\alpha_0} F \times \beta^{(-1)^{\alpha_1} E_1} \quad (2.1)$$
 の形となる。 $\alpha_0, \alpha_1 \neq 0$ あるいは 1, E_1 は非負整数で、 F は正規化条件

$$1 > F \geq 1/\beta \quad (2.2)$$

あるいは

$$\beta > F \geq 1 \quad (2.3)$$

を満たす実数である。(通常は前者が多くの用いられているが、ここで §2.3 で述べる要求をも考慮して後者を採用する。) $x \neq 0$ に対して α_0, E_1, F は ($E_1 \neq 0$ なら $\alpha_1 \neq 0$) 一意に定まる。固定語長の一語中に E_1 と F を表現する際にいくらかの近似誤差が不可避であるとすれば、この誤差は F のみに負わせるのが明らかとなり。(正規化

条件の範囲で F が変化しても E_1 が ± 1 変化するよりも、 F と $\log_{\beta}|x|$ の影響は小さいから。)

$|\log_{\beta}|x||$ が小さいときは E_1 の桁数は少いから、 E_1 は少しビット数で正確に表せ、一語中の大きな部分を F に割当てるとが“できる。

$|\log_{\beta}|x||$ が大きくなつて、 E_1 の桁数が増すので、それと割当される部分が増加し、 F に割当される部分は次第に減少する。

E_1 だけでは一語を占有するといふ $|\log_{\beta}|x||$ が大きくなつた後は、(2.1) の代わりに、

$$\langle \text{レベル } 1 \rangle \quad x = (-1)^{\alpha_0} F \times \beta^{(-1)^{\alpha_1} E_1} \times \beta^{E_2} \quad (2.4)$$

という表示を採用する。このときは、 F は“正规化条件を満たすある数”という情報しか有しない（これを表すための場所は不用）。 E_1, E_2 は (2.1) の表示をしたときの E_1 （これを E と書く）が

$$E_1 \times \beta^{E_2} \leq E < E_1 \times (\beta^{E_2+1} - 1) \quad (2.5)$$

を満足し、かつ E_1, E_2 が一語中に收まる範囲内で E_1 の桁数がなるべく大きくならぬよう選ぶ。

同様にして、更に高次の“レベル”的表示へ進むことが“できる。

すなはち (2.4) において E_2 が一語を占めるまで、その後には、

$$\langle \text{レベル } 2 \rangle \quad x = (-1)^{\alpha_0} F \times \beta^{(-1)^{\alpha_1} E_1} \times \beta^{E_2} \times \beta^{E_3} \quad (2.6)$$

という表示を採用する。ここで、 F は“正規化条件を満たすある数”， E_1 は“条件

$$1 \leq E_1 < \beta^{E_2} \times \beta^{E_3} - 1 \quad (2.7)$$

を満たすある数”， E_2, E_3 は(2.1)の表示をしたときの E_1 (これを E_2 と記す)が

$$E_1 \times \beta^{E_2} \times \beta^{E_3} \leq E < E_1 \times \beta^{E_2} \times (\beta^{E_3} - 1) \quad (2.8)$$

を満足し、かつ $E_2 \times E_3$ が一語中に収まる範囲内で E_2 の桁数があるべく大きくないように選ぶ。レベル3, 4…も同様に定めよ。

実際には、

- (i) どのレベルで表示しているか、
- (ii) F と E に割当てられている場所の境界(レベル0の場合, E_i と E_{i+1} の境界(レベル*i*(≥ 1)の場合)はどうか、

等のための情報を同じ語中に収めねばならぬ。

2.2. 在の選択

浮動小数点表示の在 β については、(03)の観点が現在では $\beta=2$ (2進法)を採用するのが最も良いとされており[1][2]。また、正規化数の先頭ビットが「1」ということを利用してビット数の複約を企てるなど見逃せない長所である。

2.3. 符号付き絶対値表示の採用

上記の§2.1, §2.2の原則の長所を發揮させためには、(2.1)の仮数部 $\pm F$, 指数部 $\pm E$ は，“補数表示”，“ゲーテ表示”等ではなく、

符号付き絶対値表示でなければならぬ)。これを正規化条件(2.3)と組み合わせることにより、数の表示法にとって望ましい[11]、加法逆元、乗法逆元に関する対称性も確保できる。(指教部の絶対値が最大の数では $F = 1$ であることに注意。)

2.4. カメの方式

カメの方式は特殊な目的(たとえば区間演算)を除けば四捨五入(2進で0捨1入)が良いから、これを採用する。他のカメの方式でも本質的な差異はない。以下では“0捨1入”を前提とする。

2.5. “非数”的役割

固定長の一語で区别でききる数の個数は有限であるが、一方ではいくつでも大きい(小さい)数が現れるるので、“ある数よりも大きい(小さい)数”というようなものも一つの“数”として扱わざるを得ない。これにはいは“ $\pm\infty$ ”のようなものである。これが不可避であるならば、これを積極的に“数”的体系に入れて、四則演算に関して閉じた、“あふれ”が起きたときもOSの厄介にならない体系を考えるのがよい。(この方向への試みはKahan[8]にも見られるが、いくつかの曖昧性が残されている。) 四則演算に関する対称性を要請すれば、“非数”的体系は一意に確定する(2.4を参照)。

3. 新浮動小数点方式の実現法

レベルを無限にとることは不可能であり、実際的上などいかで打ち切る

ばならない。本節ではレベル0の実現についてまず考察する。より高次のレベルNについてもほぼ同じ方針で実現可能である。

3.1. レベル0の実現法

2進法で正規化条件(2.3)のもとで、(2.1)の形で数 $x(\neq 0)$ を表わせば、次の形のビット並びとなる。

$$F = 1.f_2f_3 \dots f_m \quad (3.1)$$

$$E = 1e_{n-1}e_{n-2} \dots e_1 \quad (\text{あるいは } E=0) \quad (3.2)$$

そこで数 x を表わす情報としては、次の $L=m+n$ ビットが必要である:

$$\therefore f_2f_3 \dots f_m e_{n-1}e_{n-2} \dots e_1$$

($n=1$ のときは $E=1$; $n=0$ のときは $E=0$ とするのは不用)。しが固定されなければ、 n は $0, 1, \dots, L-1$ のいずれかの値をとる。仮数部 F と指数部 E との"境界"を示す二の値 n のため、 $\lceil \log_2 L \rceil$ ビットが足りるとある。 $z=z'$,

$$L + \lceil \log_2 L \rceil \quad (3.3)$$

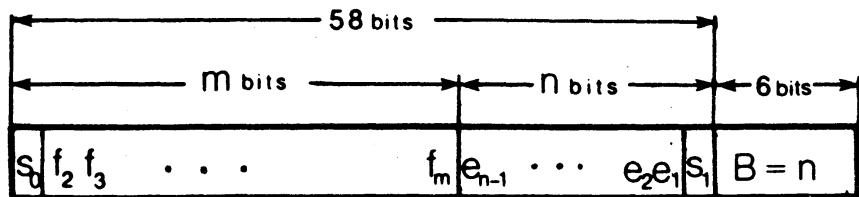
が一語長を超えないよう L を選べばよい。数 x に対し、このように表現が一意に定まるとは明らかである。(なお、理想的な"0"は本体系では"非数"として扱う。§4を参照。)

3.2. 具体的実現例

一語64ビットの場合を具体的に考えよ。(3.3)の条件から、 $L=58$, $\lceil \log_2 L \rceil = 6$ となり、図-1のようないデータ構造を得る。

仮数部(の絶対値)の長さは58~1ビット(明示しない先頭ビット

を含む), 指数部(符号も含む)の長さは $0 \sim 57$ ビット ($B=1 \neq 0$ のとき明示している) 先頭ビットも含む)となり, 1エオが約 $10^{-10^{16}}$ から $10^{10^{16}}$ までの数Xがレベル0で表現可能である。(表現誤差については85参照) B の値の3558~63は無意味とあるが, これらは(i) 非数, (ii) 高次レベルの数, 等を表わすのに使用できます。



仮数部 $(-1)^{\delta_0} f = (-1)^{\delta_0} (1.f_2f_3 \dots f_m)_2$, 指数部 $(-1)^{\delta_1} E = (-1)^{\delta_1} (1e_{n-1} \dots e_2e_1)_2$

$B = n$ は仮数部と指数部の境界を表わす, ($B=0, 1, \dots, 57; B=0$ のとき $E=0$)

図-1. 新しい表現の浮動小数点数の一々構造(レベル0)

二のようない(内部)表現を持つ(レベル0)の出力上際には, 印字用のみを指定し, この内で指数部(10進整数)の場所を必ず確保し, 残りを($x.x \dots$ の形に正規化された)仮数部に割当てねばよい。(具体的には86の例を参照。)

数の入力の場合の表現は, 従来許されていふ諸形式をすべて許容するなどとする。

4. 非数を含む数の体系

計算機で数値計算を行う際に扱う"数"は少くとも四則演算に

閉じて閉じた体系をなしていき（演算が“合法的でない”となる被演算数の組がある、てもプログラムの正常な流れがそれによつて妨げられない）ことが望ましい。そもそも“一語中に表現された数”は、数直線上の一点といふ時は、ある区間（区間代数におけるようにそれを明示するかどうかを別として）を表わすと考へるべきである。ところがまず考へべき実数は $R^+ \cup R^-$ である。ここで

$$R^+ = \{ \text{正の実数} \}, \quad R^- = \{ \text{負の実数} \}. \quad (4.1)$$

§3の表現法では $R^+ \cup R^-$ の一部分が表現可能である。考へるべき区間の“型”としては少くとも次のもの（および“≤”を用いたもの）が必要である。

- (i) $\{x | a \leq x \leq b ; a, b \in R^+\}$, $\{x | a \leq x \leq b ; a, b \in R^-\}$;
- (ii) $\{x | a \leq x ; a \in R^+\}$, $\{x | x \leq a ; a \in R^-\}$;
- (iii) $\{x | x \leq a ; a \in R^+\}$, $\{x | a \leq x ; a \in R^-\}$;
- (iv) $\{x | x \leq a \text{ or } b \leq x ; a \in R^-, b \in R^+\}$;
- (v) $\{x | a \leq x \leq b ; a \in R^-, b \in R^+\}$;
- (vi) R^+, R^- ;
- (vii) $R (= R^+ \cup R^- \cup \{0\})$.

なぜならば、基本的な型(i)から出発して演算を繰返していくと上記のすべての型が生起する可能性があるからである。これらを、それぞれ

- (i) +num, -num,

- (ii) $+\infty, -\infty;$
- (iii) $+0, -0;$
- (iv) $\infty;$
- (v) $0;$
- (vi) $+?, -?;$
- (vii) $?$

と略記し(図-2), 型(i)以外のものを"非数"と呼ぶ.

この表現方式で表現可能な数±numの代表点であるとみなすし, これらの間の演算は, 代表点間の普通の意味での演算と考え, 演算結果は,

- a. この方法で表現可能ならば(必要ならめを行なった後) $\pm num$,
- b. 絶対値が大きすぎて表現不能ならば $\pm \infty$,
- c. 絶対値が小さすぎて表現不能ならば,

 - c1. 仮数部に符号の情報が残っていれば ± 0 ,
 - c2. 仮数部に符号の情報が残っていないければ 0,

である約束する. その他他の非数がどのように出現するかを, また型(i)~(vii)を考えれば"四則演算に関する閉じた体系が(厳密には"最小の体系")が得られることを, 表-1~表-4に示す.

数(および非数) x と y の大小関係は, 上記 a, b, c および表-2の減算の結果の約束を用いて, $x-y$ の演算結果が + (あるいは -) の符号を有するとき $x > y$ ($x < y$) であると約束する. $x = y$ は $x > y$ が

同一のビットパターンで表現されていけるときのみ有限とします。こうす

れば、たとえば「 $-\infty < -\text{num} < -0 < +0 < +\text{num} < +\infty$ 」、 $[-\text{num}, +\text{num}]$ 、
 $x < y$ 、 $u < v$ なら $x+u < y+v$ 等は成立する。しかし、 $x=y$ 、 $u < v$
 なら $x+u < y+v$ 等が成立するとは限らない。

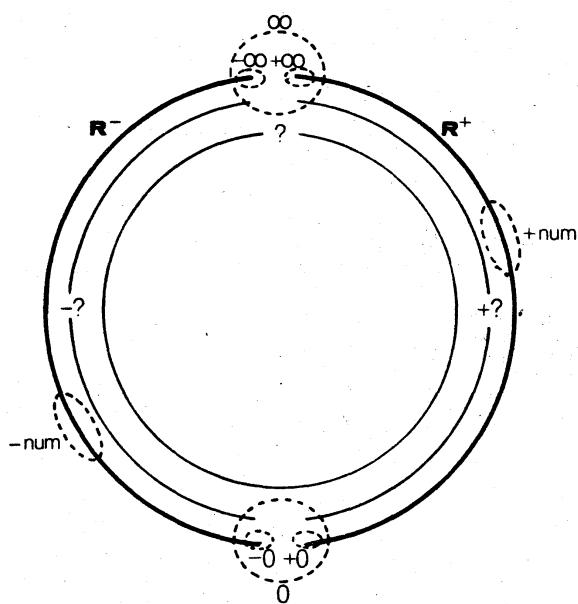


図-2. 四則演算に関する閉じた数の体系の概念図

表-1. 加算の定義

op ²	+num	-num	+∞	-∞	+0	-0	+?	-?	∞	?	0
op ¹	+num	±num	+∞	-∞	+0	-0	+?	-?	∞	?	0
+num	+∞	±0,0	+∞	-∞	+num	+num	+?	?	∞	?	+num
-num	±0,0	-∞	+0	-∞	-num	-num	?	-?	∞	?	-num
+∞	+∞	+∞	+0	?	+∞	+∞	+?	?	?	?	+∞
-∞	-∞	-∞	?	-∞	-∞	-∞	?	-?	?	?	-∞
+0	+num	-num	+∞	-∞	+0	0	+?	?	∞	?	0
-0	+num	-num	+∞	-∞	0	-0	?	-?	∞	?	0
+?	+?	?	+?	?	+?	?	+?	?	?	?	?
-?	?	-num	?	-?	?	-?	?	-?	?	?	?
∞	∞	∞	?	?	∞	∞	?	?	∞	?	∞
?	?	?	?	?	?	?	?	?	?	?	?
0	+num	-num	+∞	-∞	0	0	?	?	∞	?	0

表-2. 減算の定義

\diagdown op ²	+ num	- num	+∞	-∞	+0	-0	+?	-?	∞	?	0
op ¹	+ num	\pm num $\pm 0, 0$	+ num $\pm \infty$	-∞	+∞	+ num + num	?	+?	∞	?	+ num
+ num	- num	\pm num $\pm 0, 0$	+ num $\pm \infty$	-∞	+∞	- num - num	-?	?	∞	?	- num
- num	+ num	\pm num $\pm 0, 0$	+ num $\pm \infty$	-∞	+∞	+ num + num	?	+?	?	?	+ num
+∞	+∞	+∞	?	+∞	+∞	+∞	?	+?	?	?	+∞
-∞	-∞	-∞	-∞	?	-∞	-∞	-?	?	?	?	-∞
+0	- num	+ num	-∞	+∞	0	+0	?	+?	∞	?	0
-0	- num	+ num	-∞	+∞	-0	0	-?	?	∞	?	0
+?	?	+?	?	+?	?	+?	?	+?	?	?	?
-?	-?	?	-?	?	-?	?	-?	?	?	?	?
∞	∞	∞	?	?	∞	∞	?	?	?	?	∞
?	?	?	?	?	?	?	?	?	?	?	?
0	- num	+ num	-∞	+∞	0	0	?	?	∞	?	0

表-3. 乗算の定義

\diagdown op ²	+ num	- num	+∞	-∞	+0	-0	+?	-?	∞	?	0
op ¹	+ num	+ num $\pm 0, \pm \infty, 0$	- num $\pm \infty, 0$	+∞	-∞	+0 -0	+?	-?	∞	?	0
+ num	- num	+ num $\pm \infty, 0$	+ num $\pm 0, \pm \infty$	-∞	+∞	-0 +0	-?	+?	∞	?	0
- num	+ num	- num $\pm \infty, 0$	+ num $\pm 0, \pm \infty$	-∞	+∞	+0 -0	-?	+?	∞	?	0
+∞	+∞	-∞	+∞	-∞	+?	-?	+?	-?	∞	?	?
-∞	-∞	+∞	-∞	+∞	-?	+?	-?	+?	∞	?	?
+0	+0	-0	+?	-?	+0 -0	+0 -0	+?	-?	?	?	0
-0	-0	+0	-?	+?	-0 +0	-0 +0	-?	+?	?	?	0
+?	+?	-?	+?	-?	+? -?	+? -?	+?	-?	?	?	?
-?	-?	+?	-?	+?	-? +?	-? +?	-?	+?	?	?	?
∞	∞	∞	∞	∞	?	?	?	?	∞	?	?
?	?	?	?	?	?	?	?	?	?	?	?
0	0	0	?	?	0	0	?	?	?	?	0

表-4. 除算の定義

\diagdown op ²	+ num	- num	+∞	-∞	+0	-0	+?	-?	∞	?	0
op ¹	+ num	+ num $\pm 0, \pm \infty, 0$	- num $\pm \infty, 0$	+0 -0	-0 +0	+∞ -∞	+?	-?	0	?	?
+ num	- num	+ num $\pm \infty, 0$	+ num $\pm 0, \pm \infty$	+0 -0	-0 +0	+∞ -∞	+?	-?	0	?	?
- num	+ num	- num $\pm \infty, 0$	+ num $\pm 0, \pm \infty$	+0 -0	-0 +0	+∞ -∞	-?	+?	0	?	?
+∞	+∞	-∞	+∞	+?	-?	+∞ -∞	+?	-?	?	?	?
-∞	-∞	+∞	-∞	-?	+?	-∞ +∞	-?	+?	?	?	?
+0	+0	-0	+0	-0	+?	-?	+?	-?	0	?	?
-0	-0	+0	-0	+0	-?	+?	-?	+?	0	?	?
+?	+?	-?	+?	-?	+? -?	+? -?	+?	-?	?	?	?
-?	-?	+?	-?	+?	-? +?	-? +?	-?	+?	?	?	?
∞	∞	∞	∞	?	?	∞	∞	?	?	?	?
?	?	?	?	?	?	?	?	?	?	?	?
0	0	0	0	0	?	?	?	?	0	?	?

5. 表現誤差

ある実数 x に対応する代表点 x^* は、仮数部の最後の桁の次の桁を丸めた数であるとされている。(我々のレベル 0 の表示も同様である。レベル 1 以上の場合は、仮数部および指数部に対して同様な考え方を適用できる。) このとき、"相対誤差"

$$\epsilon_{\text{rep}}(x) = \frac{|x^* - x|}{|x|} \quad (5.1)$$

を x の"表現誤差"と呼ぶ。また、

$$u(x) = \max_y \{\epsilon_{\text{rep}}(y) \mid y \text{ は } x \text{ と同じ代表点 } x^* \text{ を持つ}\} \quad (5.2)$$

を"丸めの単位"と呼ぶ。浮遊法で仮数部が l 衡のとき、

$$u(x) = \frac{1}{2} \beta^{1-l} \quad (5.3)$$

である。(丸めは四捨五入。) なお、非数 x については、 $\epsilon_{\text{rep}}(x)$ は定義されない(あるいは ∞ である)とするのがよりて"ある"。(この意味でも、0 や ± 0 は非数となるのが適当である。)

異なる表現方式の特長を表現誤差、丸めの単位を用いて比較すると興味深い。一語表すならば、人と仮定し比較対象として以下の典型的なものを考える。

<1> IBM型:— 16進、仮数部 56 ビット(丸めは"切捨て"), 指数部 1 ビット("ゲーティング式"), 符号 1 ビット。("倍精度"実数型。)

<2> Kahan型:— 2進、仮数部 52 ビット(先頭ビットを隠すので実質的上は 53 ビット; 丸めは"0捨1入"), 指数部 11 ビット("ゲーティング式"), 符号 1 ビット("倍精度数")。(正規化すると underflow するとき, 34

を導いたための“非正規化数”を考えよ。) [8]

<3> Morris型 :— Morris の原論文[12] の精度を一語長が“64ビット”的場合に改作したもの。2進，“指數部長”を表す部分3ビット（これが表す数を $G (= 0, 1, \dots 7)$ とする），残り61ビットを仮数部，指數部に割当てる。（始めは 0捨1入）。指數部（符号付き絶対値表示）の長さは，

(i) $G+1$ (Morris (i) 型)

(ii) $G+4$ (Morris (ii) 型)

の2通りの解釈が提案されている。

<4> 本論文の方式 :— §3.2 参照。レベル0を中心として考えよ。
(始めは 0捨1入)。

正規化条件としては，<1> × <3> は (2.2) を，<2> × <4> は (2.3) を用いる。

$|\log|x|$ が比較的小さい範囲での $E_{rep}(x)$ を図-3に，広い範囲をもつての $U(x)$ を図-4に示す。

これらの図からもわかるように，本論文の方式は，“あふれ”が起きた“不連続点”がなく，“普通の大きさ”的な数に対しては IBM型, Kahan型より誤差が小さく，数が極端に大きくあるいは小さくなても連続的な誤差が増加する形で対処している。このような点がみて，本方程式各種の表現方式を比較検討する際の一つの基準となりうるであろう。

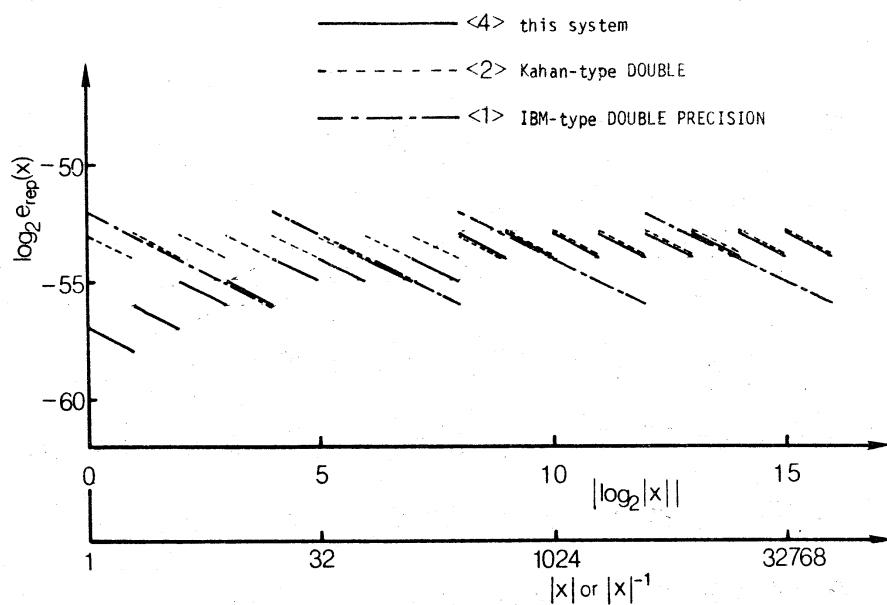


図3. 各種表現方式による表現誤差 $e_{\text{rep}}(x)$ の比較

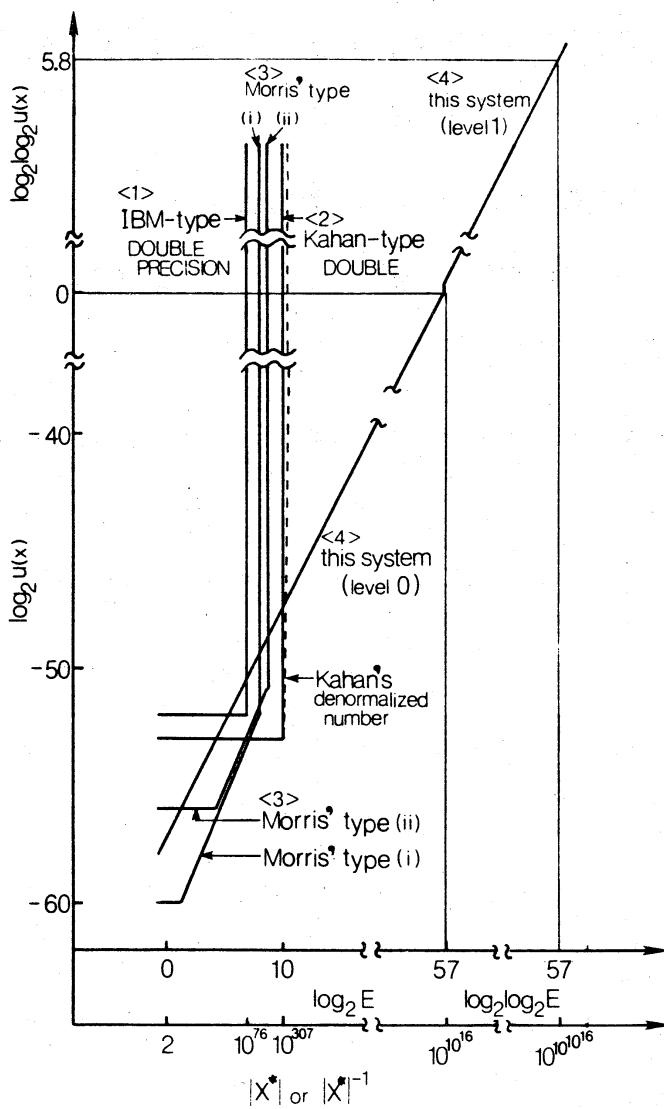


図4. 各種表現方式によるための単位 $u(x)$ の比較

6. 新体系による数値計算例

6.1. 実験プログラム

本論文で提案した方式をもとで述べた形で実現するアロケーム
(サブルーチン群)を東京大学の大型計算機センターの HITAC-8800/
8700 システムの FORTRAN および教育用計算機センターの Melcom-Cosmo
900 の FORTRAN で作成した。(現在下記のものがある)。

- 1° 四則演算用サブルーチン(計約300行),
- 2° 入出力用関数副プログラム(計約200行),
- 3° 型変換(FORTRANのデータと本体系の間の変換を行う)用
関数副プログラム(計約200行),
- 4° 平方根用関数副プログラム(計約60行),
- 5° 補助サブルーチン群(比較, 累乗, 逆数部と指數部の分
離と結合等の処理)(計約300行)。

なお現在の版では非数は"0"のみが特殊をビットパターンとして含まれている。

プログラムは実験用であり, 速度向上の為の技巧を凝らして
いないので, 速度は遅いが(通常の倍精度実数型演算と比較し
て約600~1000倍程度の時間を要する(HITACとの比較)), 二の
点は大幅に改良の余地がある。特に演算回路を全物化した場合
には, IBM型やKahan型の1割増し程度の時間で実現でき
る見込みがある。

6.2. 数値計算例

極端に大きな数、小さな数が出現する典型的な数値計算。
例として代数方程式の Graeffe 法 [13] に対する解を考えよう。

簡単のため、正の零点のみの多項式方程式

$$\begin{aligned} P_1(x) &= x^8 - 11x^7 + 45.35x^6 - 88.55x^5 + 86.752x^4 - 43.274x^3 \\ &\quad + 10.981x^2 - 1.32x + 0.0576 \\ &= (x-0.1)(x-0.2)(x-0.3)(x-0.4)(x-1)(x-2)(x-3)(x-4) \quad (6.1) \end{aligned}$$

おとく

$$\begin{aligned} P_2(x) &= x^4 - 10.43857593020613x^3 + 40.58740567587410x^2 \\ &\quad - 69.60408570545396x + 44.36715614906059 \\ &= (x-2)(x-e)(x-\sqrt{2.4})(x-3) \quad (6.2) \\ &\quad (e = 2.718281828 \dots, \sqrt{2.4} = 2.7202941017 \dots) \end{aligned}$$

を考えよう。

$P(x) = x^n - a_{n-1}x^{n-1} + \dots + (-1)^{n-1}a_1x + (-1)^n a_0$ の零点を d_i ($i=1, \dots, n$)
とするとき、 $d_i^{(2)}$ ($i=1, \dots, n$) を零点とする多項式

$$P^{(2)}(x) = x^n - a_{n-1}^{(2)}x^{n-1} + \dots + (-1)^n a_0^{(2)} \quad (6.3)$$

は簡単な漸化式

$$a_k^{(\omega)} = a_k, \quad a_k^{(\omega+1)} = \sum_{i+j=2k} (-1)^i a_i^{(\omega)} a_j^{(\omega)}, \quad (\omega=0, 1, \dots) \quad (6.4)$$

ω 計算され、 d_i の近似値は

$$d_i \approx \left(a_{i-1}^{(\omega)} / a_i^{(\omega)} \right)^{1/2^{\omega}} \quad (6.5)$$

で計算でき。

$P_1(x)$ に対する反復計算の結果を図-5に、 $P_2(x)$ に対するものを図-6に示す。またこれらをまとめたものを図-7に示す。

図-5にありては $n=7$ くらいですべての零点が十分な精度で得られます。(その後無駄な反復を行なっても精度が悪化しないことに注目すべきです。) IBM型のものでは $n=6$ くらいで破綻をきます。

図-6にありては、近接零点があるため、必要な反復回数が増加し、また最終的に得られる零点の近似値の精度もいくぶん劣る。しかし、本方式では $n=16$ くらいで、10進10桁の精度で零点が得られます。IBM型のものでは、 $n=6$ くらいで破綻をきます(そのときの近接零点の精度は最も悪いものでは僅か2桁), Kahan型のものでは $n=7$ までは大体同じ(そのときの近接零点の精度は、最も悪いものでは2桁)。

7. 今後の課題

本論文では、新しい浮動小数点方式の基本的な着想を提案し、その特長を従来の諸方式と比較考察し、これを実現する試作プログラムによる数値計算例をあげた。カレニの方式へいこは更に検討すべき課題が数多く残されていきますので、これらへいこは逐次検討結果を発表していくつもり。主なものは次の通りです。

- (i) 演算の全物化: 一本來の種の方式は演算を全物化する二つによつて始めてその特長が發揮できます。そのための演算回路の設計試作を行ふこと。理論的には従来方式とほぼ同程度の速度が得

Kahan型の限界

$\nu = 1$
- 3.3177600000000000 EE-3 =A(1)
- 4.7704320000000000 EE-1 =A(2)
1.6598772479999999 EE 1 =A(3)
- 1.9541003280000000 EE 2 =A(4)
8.2947750575999999 EE 2 =A(5)
- 9.027198200000001 EE 2 =A(6)
2.8202729999999999 EE 2 =A(7)
- 3.0300000000000000 EE 1 =A(8)
8.339569428721113 EE-2 =ROOT(1)
1.705584280072372 EE-1 =ROOT(2)
2.896891579541276 EE-1 =ROOT(3)
4.853679799876546 EE-1 =ROOT(4)
9.585743805733726 EE-1 =ROOT(5)
1.7890847510520749 EE0 =ROOT(6)
3.0508739212180358 EE0 =ROOT(7)
5.5045435778091540 EE0 =ROOT(8)

$\nu = 7$
- 2.1581313729824 EE-159 =A(1)
- 2.15813137298248 EE-31 =A(2)
6.34217809318084 EE 58 =A(3)
- 5.3792017006758 EE 125 =A(4)
4.6455692578868 EE 176 =A(5)
- 4.6455692578870 EE 176 =A(6)
1.3652101047498 EE 138 =A(7)
- 1.15792089237327 EE 77 =A(8)
9.9999999999999997 EE-2 =RONT(1)
2.0000000000000006 EE-1 =RONT(2)
2.9999999999999984 EE-1 =RONT(3)
4.0000000000000013 EE-1 =RONT(4)
9.9999999999999996 EE-1 =RONT(5)
2.0000000000000022 EE0 =RONT(6)
2.9999999999999951 EE0 =RONT(7)
4.0000000000000027 EE0 =RONT(8)

$\nu = 5$
2.15535826671273 EE-40 =A(1)
- 2.155358267214587 EE-8 =A(2)
5.01834615819841 EF 14 =A(3)
- 2.70846408510473 EE 31 =A(4)
1.46811384664593 EE 44 =A(5)
- 1.46811384698750 EE 44 =A(6)
3.41822684232871 EE 34 =A(7)
- 1.84485970981938 EF 19 =A(8)
0.9999999999927237 EE-2 =ROOT(1)
1.999999855136427 EE-1 =ROOT(2)
2.999990800367525 EE-1 =ROOT(3)
4.000012555971386 EE-1 =ROOT(4)
9.999999999927293 EE-1 =ROOT(5)
1.9999998551364240 EE0 =ROOT(6)
2.9999908003675362 EE0 =ROOT(7)
4.0000125559713905 EE0 =ROOT(8)

$\nu = 8$
4.6575310230509 EE-318 =A(1)
- 4.65753102305125 EF-62 =A(2)
4.0223222965623 EE 117 =A(3)
- 2.8935810936553 EE 251 =A(4)
2.1581313729823 EE 353 =A(5)
- 2.1581313729825 EE 353 =A(6)
1.8637986301109 EE 276 =A(7)
- 1.3407807929945 EE 154 =A(8)
9.9999999999999997 EE-2 =RONT(1)
2.0000000000000006 EE-1 =RONT(2)
2.9999999999999984 EE-1 =RONT(3)
4.0000000000000013 EE-1 =RONT(4)
9.9999999999999996 EE-1 =RONT(5)
2.0000000000000022 EE0 =RONT(6)
2.9999999999999951 EE0 =RONT(7)
4.0000000000000027 EE0 =RONT(8)

$\nu = 6$
4.64556925788690 EE-80 =A(1)
- 4.64556925788700 EE-16 =A(2)
2.51836814092956 EE 29 =A(3)
- 7.33430419960579 EE 62 =A(4)
2.15535826671271 EF 88 =A(5)
- 2.15535826671276 EE 88 =A(6)
1.16842205763348 EE 69 =A(7)
- 3.40282370354638 EE 38 =A(8)
0.9999999999999997 EE-2 =ROOT(1)
1.9999999999999988 EE-1 =ROOT(2)
2.999999999527234 EE-1 =ROOT(3)
4.000000000630681 EE-1 =ROOT(4)
9.999999999999995 EE-1 =ROOT(5)
1.9999999999999984 EE0 =ROOT(6)
2.99999999995272459 EE0 =ROOT(7)
4.0000000006306709 EE0 =ROOT(8)

$\nu = 30$
2.298526 EE-1330986224 =A(1)
- 2.2985271 EE-257244400 =A(2)
5.4763732 EE 493268927 =A(3)
- 2.670771 EE 1054705705 =A(4)
1.516089 EE 1481990536 =A(5)
- 1.516090 EE 1481990536 =A(6)
3.612177 EE 1158762039 =A(7)
- 1.7616144 EE 646454993 =A(8)
9.9999999999999999 EE-2 =RONT(1)
2.0000000000000006 EE-1 =RONT(2)
2.9999999999999984 EE-1 =RONT(3)
4.0000000000000013 EE-1 =RONT(4)
9.9999999999999994 EE-1 =RONT(5)
2.0000000000000024 EE0 =RONT(6)
2.9999999999999953 EE0 =RONT(7)
4.0000000000000027 EE0 =RONT(8)

5. $P_n(x)$ の零点を求める Graeffe 法

Kahan型の限界

 $V = 1$

- 1.069444544155123	FF 3	=A(1)
- 1.243233216278632	FF 3	=A(2)
2.82936744419149	FF 2	=A(3)
- 2.779905602803071	FF 1	=A(4)
1.2583031670230898	EE0	=ROOT(1)
2.0961947379335457	EE0	=ROOT(2)
3.1908602092232566	EE0	=ROOT(3)
5.2715326138544105	EE0	=ROOT(4)

 $V = 7$

6.6662837510202	FF 210	=A(1)
- 1.0590447225917	FF 172	=A(2)
9.6227697791204	FF 116	=A(3)
- 1.17902661948570	FF 61	=A(4)
1.99999999999999518	EE0	=ROOT(1)
2.7045783330773281	EE0	=ROOT(2)
2.7340770775614731	EE0	=ROOT(3)
3.0000001622446730	EE0	=ROOT(4)

 $V = 5$

5.08125451549211	FF 52	=A(1)
- 1.18320169534957	FF 43	=A(2)
3.02539330106157	FF 29	=A(3)
- 2.01284256209763	FF 15	=A(4)
1.9999931360575824	EE0	=ROOT(1)
2.6592468559773725	EE0	=ROOT(2)
2.7735140870227926	EE0	=ROOT(3)
3.0077660744101009	EE0	=ROOT(4)

 $V = 16$

6.7375701284	FF 107941	=A(1)
- 3.36284975669	FE 88213	=A(2)
4.01365489311	FE 59751	=A(3)
- 4.15479228694	FE 31268	=A(4)
1.99999999999999518	EE0	=ROOT(1)
2.7182818285051764	EE0	=ROOT(2)
2.7202941016100686	EE0	=ROOT(3)
3.000000000000000399	EE0	=ROOT(4)

 $V = 6$

2.5819147451107	FF 105	=A(1)
- 1.39065879601065	FF 86	=A(2)
4.34081732412593	FF 58	=A(3)
- 2.44645651957942	FF 30	=A(4)
1.9999999998191536	EE0	=ROOT(1)
2.6809448172248597	EE0	=ROOT(2)
2.7487913512240691	EE0	=ROOT(3)
3.0001740482911321	EE0	=ROOT(4)

 $V = 30$

1.577772	EF 1768518918	=A(1)
- 3.759240	EF 1445290421	=A(2)
2.5108124	FE 978970272	=A(3)
- 2.0511859	FE 512305046	=A(4)
1.99999999999999518	EE0	=ROOT(1)
2.7182818285051764	EE0	=ROOT(2)
2.7202941016100686	EE0	=ROOT(3)
3.000000000000000399	EE0	=ROOT(4)

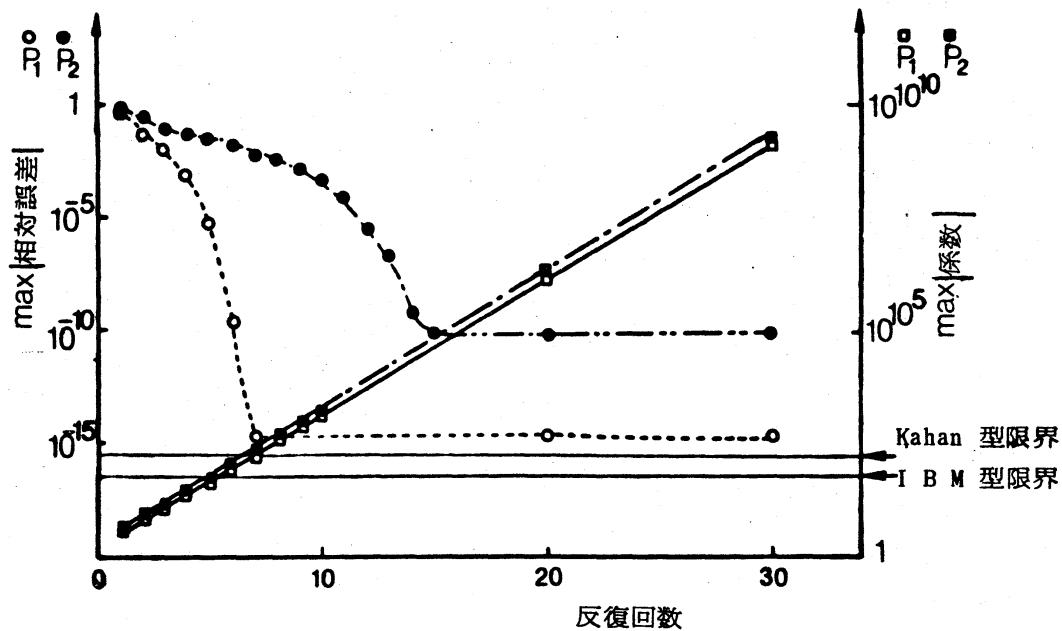
図-6. $P_2(x)$ の零点を求める Graeffe 法

図-7. Graeffe 法による反復過程

られる見込みがある。

- (ii) 新表現方式へ適したため誤差理論の確立：一本論文では数の表現と直接関連した誤差のみを論じたが、「表現誤差がほぼ一定」という従来の誤差理論[13]の仮定の成立しない本方式における、四則その他演算と伴う誤差の拡大、累積に関する理論を確立すると、従来の理論が“非微”の場合を含めてどのようにならざるかを調べることは重要である。
- (iii) 高次レベル、非数の実際的な取り扱い：一非数やレベル1以上の入出力をどうするか、どのようにして実現するか、またどのくらいのレベルまで考えべきか、等々について、理論・実際面からの検討の余地がある。

8. おわりに

本研究に関連しては、非公式研究会などにおいて、電気通信大学教授森口繁一先生、慶應大学教授相馬秀夫先生ほか多くの方々から貴重な御助言を賜り、また研究室の方々からも有用な討論を頂いた。これらにより内容の多くの部分を改善することはできた。以上記して、感謝の意を表わす所次第である。

なお、本研究は文部省科学研究費の援助による部分を含んでいます。

9 參考文献

- [1] Brent, R. P., On the Precision Attainable with Various Floating-Point Number System. IEEE Trans. on Computers, Vol. C-22, No. 6, pp. 601-607(1973).
- [2] Cody, W. J., Jr., Static and Dynamic Numerical Characteristics of Floating-Point Arithmetic. IEEE Trans. on Computers, Vol. C-22, NO. 6, pp. 598-601(1973).
- [3] Edger, A. D., and Lee, S. C., FOCUS:Microcomputer Number System. Comm. ACM, Vol. 22, No. 3, pp. 166-177(1979).
- [4] Hamming, R. W., On the Distribution of Numbers. The Bell System Technical Journal, Vol. 40, No. 8, pp. 1609-1625(1970).
- [5] Hehner, E. C. R., and Horspool, R. N. S., A New Representation of the Rational Arithmetic. SIAM J. on Comput., Vol. 8, No. 2, pp. 124-134(1979).
- [6] 一松信, 新標準浮動小数点体系の提案. 情報処理, Vol. 20, No. 9, pp. 793-797(1979).
- [7] Ida, T., and Goto, E., Overflow Free and Variable Precision Computing in FLATS. Journal of Information Processing, Vol. 1, No. 3, pp. 140-142(1978).
- [8] Kahan, W., and Palmer, J., On a Proposed Floating-Point Standard, ACM SIGNUM Newsletter, Special Issue, pp. 13-21(Oct. 1979).
- [9] Knuth, D. E., The Art of Computer Programming, Vol. 2:Seminumerical Algorithms. Addison-Wesley, Reading, Massachusetts(1969).
- [10] Morris, R., Tapered Floating Point: A New Floating Point Representation. IEEE Trans. on Computers, Vol. C-20, No. 6, pp. 1678-1679(1973).
- [11] Reinsch, C. H., Principle and Preference for Computer Arithmetic. ACM SIGNUM Newsletter, Vol. 14, No. 1, pp. 12-27(1979).
- [12] Swartzlander, E. E., Jr., and Alexopoulos, A. G., The Sign/Logarithm Number System. IEEE Trans. on Computers, Vol. C-24, No. 12, pp. 1238-1242(1975).
- [13] Wilkinson, J. H., Rounding Errors in Algebraic Processes. Prentice-Hall, Englewood-Cliffs (1963).