

誤差評価と不等式

京大 数研 一松 信

0. はじめに

数値解析の中心的課題は、誤差評価であり、それは本質的に不等式にほかならない。しかし誤差評価の立場では、在來の不等式論とは、いくぶん相異なるセンスが必要な場合がある。この話は、そういった類の問題提起にすぎず、まとまつた話ではないが、以前から気にかかっている問題をのべて、これからのお研究者のために何かの参考になることを期待する。

1. 後退誤差解析

数値計算とは、抽象化すれば、与えられたデータ x_1, \dots, x_n から、ある値 $f(x_1, \dots, x_n)$ を求めることである。計算にともなう多くの近似により、えられた値 $\tilde{f}(x_1, \dots, x_n)$ は真の値とは差がある。その差が誤差で、それの上限を求めるのが誤差評価である。しかしこのような形の前進誤差解析は、一般にきめめて難しいが、またはえられた結果 $|a| \leq b$ が非現実的な評価であることが多い。——非現実的とは、実際の $|a|$

と b とか桁数以上も違うことという。

この意味で、Wilkinson らの 後退誤差解析は、コロンビスの印かもしれないが、興味深い考え方である。それはえらかた値 $\tilde{f}(x_1, \dots, x_n)$ は、構動どうけたデータ (x_1^*, \dots, x_n^*) に対する真の値である: $\tilde{f}(x_1, \dots, x_n) = f(x_1^*, \dots, x_n^*)$ とみて、 $|x_e - x_e^*|$ を評価しようというものである。この方法によると、多くの場合、 $|x_e - x_e^*|$ の上限として、使用した桁数の最小単位 u の定数倍(比較的小)という「現実的」を評価がえられる。

その大きな理由は、浮動小数点演算における加減法の誤差評価にある。浮動小数点表示では、相対誤差がほぼ一定とみなされるから、 $a+b$ の演算結果 $f_1(a+b)$ について

$$(1) \quad f_1(a+b) = (a+b)(1+\delta), \quad |\delta| \leq C u, \quad C: \text{定数}$$

が成立する必要があるが、(1)は一般には成立しない(桁落ちを生ずるとき)。(しかし Wilkinson は、たとえ桁落ちを生じたとしても、被演算数が、ある桁以後は 0 が無限に続いた正確な数であるとみなし)。後退誤差解析的評価

$$(2) \quad f_1(a+b) = a(1+\delta_1) + b(1+\delta_2); \quad |\delta_1|, |\delta_2| \leq u$$

は正しいことを証明した。乗除法については、(1)のよう評価が成立するので、これによって後退誤差解析が可能になるのである(実例は [1], [2] に詳しい)。

2. 行列のノルムと消去法の誤差解析

$n \times n$ 行列 A は、 n 次元線型空間 Ω の自分自身への一次変換とみるされる。 Ω にノルム $\|\cdot\|$ があるとき、それから誘導された 行列のノルム

$$(3) \quad \|A\| = \sup_{\mathbf{x} \neq 0} \|A\mathbf{x}\| / \|\mathbf{x}\| = \max \{\|A\mathbf{x}\| ; \|\mathbf{x}\|=1\}$$

が定義され、つきの性質がある。

$$\|A\| \geq 0, \quad \|A\|=0 \Leftrightarrow A=0, \quad \|cA\|=|c|\|A\|$$

$$\|A+B\| \leq \|A\| + \|B\|, \quad \|AB\| \leq \|A\| \|B\|, \quad \|I\|=1.$$

$\|\mathbf{x}\|$ が $\ell_1, \ell_2, \ell_\infty$ ノルムであるとき、 $\|A\|$ は具体的にはつきのようにある: $A = [a_{ij}]$

$$\|A\|_1 = \max_j \left(\sum_{i=1}^n |a_{ij}| \right), \quad \|A\|_\infty = \max_i \left(\sum_{j=1}^n |a_{ij}| \right)$$

$$\|A\|_2 = (A^* \cdot A \text{ の最大固有値})^{1/2}.$$

定義から $\|A\mathbf{x}\| \leq \|A\| \cdot \|\mathbf{x}\|$ であるが、「多くの場合」、この両辺はかなり近いことは重要な注意である。([2], [3] 参照)

さて、連立一次方程式 $A\mathbf{x} = \mathbf{b}$ を消去法で解くことは、係數行列 A を、容易に逆行列が求められる行列の積に分解することと解釈される。たとえば Gauss の消去法は、

$$(4) \quad A = L U, \quad L \text{ は下三角行列}, \quad U \text{ は上三角行列}$$

という分解である。 L の対角要素を 1 とすれば、この分解は（可能ならば）一意的である。Wilkinson は注意深く後退誤差解析を行ない、枢軸の選択を加えた Gauss の消去法によ

ってえられた L, U が, $L \cdot U = A + E$ (E は誤差行列)
としたとき, たとえば

$$\|E\|_\infty \leq n^2 \rho \|A\|_\infty \cdot u$$

を示してある (じつせんには成分ごとのもっと詳しい評価が
えられる). ここに ρ は, 消去の途中に生ずる係数 $a_{ij}^{(k)}$ から

$$(5) \quad \rho = \max_{i,j,k} |a_{ij}^{(k)}| / \|A\|_\infty$$

としてえられる量である. 各 A につれて「後天的」には容易
にえられる. 「先天的」な評価としては, $|a_{ij}| \leq M$ のとき

$$(6) \quad \text{部分選択なら } |a_{ij}^{(k)}| \leq 2^{k-1} M$$

$$(7) \quad \text{完全選択なら } |a_{ij}^{(k)}| < \left(k \cdot 2^1 3^{\frac{1}{2}} 4^{\frac{1}{3}} \cdots k^{\frac{1}{k-1}} \right)^2 \cdot M \\ \sim 1.8 k^{(1/4) \log k} \cdot M$$

がえられる. (6) は = が成立しうるという意味で「最良」で
あるが, (7) は最良ではない. ((7) の最良評価は未解決のよう
に思われる. $|a_{ij}^{(k)}| \leq kM$ という予想もある*)

しかし現実には (6) でつねに等号が成立し, 最終的には
 $\rho \cdot \|A\|_\infty = 2^{n-1} \cdot M$ となることは「めった」にはない.

Wilkinson の「実験」によれば, 「たいていの例」では (6) で
 $\rho \cdot \|A\|_\infty \leq 8 \cdot M$ であるといふ. —ここにつきには—
ようなく, 確率論的評価の問題が生ずる.

(*) 複素係数では「反例」が作られいいが, その例でも $\leq 1.05 \cdot M$ である.

3. 確率的誤差限界の一例

たとえばある行で求めた数 a_1, \dots, a_m の和を求めるとする。個々の数の誤差の上限が u ならば、 $S = a_1 + \dots + a_m$ の丸め誤差の上限は mu で、これは最良の評価である。

しかしすべての丸めが皆一齊に同符号で最大値である、といった「特殊」な事態は、「めった」に生じないと考えるほうが自然である。丸め誤差 $\varepsilon_1, \dots, \varepsilon_m$ はもちろん決定的因素であるが、それらを独立な確率変数であるかのように考えるのは、実用上有用な仮定である。もしも ε_k が平均値 0, 標準偏差 σ_k の正規分布に従うと仮定すれば、 S の誤差 $\varepsilon = \varepsilon_1 + \dots + \varepsilon_m$ は、平均値 0, 標準偏差

$$\sigma = (\sigma_1^2 + \dots + \sigma_m^2)^{1/2}$$

の正規分布をなす。 $|\varepsilon| \geq 3\sigma$ となることは稀（確率 0.3% 以下）だから、 $\sigma_1 = \dots = \sigma_m = u$ なら、事实上 $|\varepsilon| \leq 3\sqrt{m}u$ としてよい。これは $m u$ より、だいぶ小さい。

実際には、 ε_k は $[-u, +u]$ の一様分布とするほうがよい近似であろうが、 m が十分大ならば、その分布は中心極限定理により、正規分布に十分近くなる。正確に計算すると、このとき $|\varepsilon| \leq 2bu$ である確率は（[4] 参照）

$$\frac{1}{m!} \left[\sum_{k=0}^{\leq m/2+2b} (-1)^k \binom{m}{k} \left(2b + \frac{m}{2} - k\right)^m - \sum_{k=0}^{\leq m/2+2b} (-1)^k \binom{m}{k} \left(-2b + \frac{m}{2} - k\right)^m \right]$$

であることが計算される。 m が十分大ならば、实用上はまことに $|\varepsilon| \leq 2\sqrt{m} \mu$ としてよい。

Wilkinson の「実験結果」を裏づける理論として、 $|a_{ij}| \leq 1$ の範囲で、 $\{a_{ij}\}$ の分布を適当に仮定し、 $|a_{ij}^{(k)}| \leq c_k$ である確率を計算してみることが望ましい。そして $P\|A\|_\infty \leq 8$ (右辺の 8 は本質的でなく、10でも7でも大差ないが) である確率がかなり小さい、というような結果が示されれば、大いに有意義である。

ただしここで $\{a_{ij}\}$ の分布をどう仮定するかが問題であろう。すべて独立に一様分布とするのは非現実的である。最初の極端な例から、 $a_{11}=1$ とし、 a_{i1} ($i=2, \dots, n$) を一様分布としてもよからう。それ以外の要素を一様分布としてよいか——よくわからぬ。一様分布より正規分布のほうが計算しやすいかもしれないが、すると特異行列に近いものが生じやすくなるかもしれない。——とにかくやってみる必要があるだろ。計算しやすいように、適当な仮定を付加していってもよいかかもしれない。

4. 近似評価での逆向き不等式

誤差評価におけるには、本来 $a > b$ であるのに、多少修正 (2) $a \leq b + \varepsilon$ とか $a \leq (1+\varepsilon)b$ といつ左形の評価がほ

しいことがよくある。四則演算の誤差評価 ([1], [2], [3]) では、しばしば $a \leq 1.01n\mu$ といった形の式が現われるのか、その一例である。1.01 は 1 より僅かに大きいある定数という意味の量である。

この種の例^{といい}（かつて [5] で、相接近した正の数 $a_1 > a_2 > \dots > a_n > 0$ ($(a_1 - a_n)/a_1 \approx 1/30$ 程度) の相乗平均を下から評価する必要があった。数値的には、それより 大きい 相加平均 A_n も十分であり、^{T=とえば} $0.9A_n$ とでもすればすんだが、これでは論理的でない、一般性もない。Kober の不等式 [6] を利用した：

正数 a_1, \dots, a_n の相加平均、相乗平均を A_n, G_n とすると、

$$(8) \quad \frac{1}{n(n-1)} < \frac{A_n - G_n}{\Delta} < \frac{1}{n}$$

$$\Delta = \sum_{1 \leq i < k \leq n} [(a_i)^{1/2} - (a_k)^{1/2}]^2$$

であるから、 $G_n > A_n - (\Delta/n)$ 。しかし $a_1, \dots, a_n \rightarrow a$ のとき、(8) の中央項 $\rightarrow 2/n^2$ であり、 $G_n > A_n - (c\Delta/n^2)$ が期待される。^{当面} この ^{といい} 例では $\Delta = O(n^6)$ であり、 $G_n > A_n - O(n^4)$ がほしかったので、これでは不十分だった。いつまでも a_n の具体的不等式を使って展開して主要項を評価するほうがよかつた。(もっとも後に準備戦から、 A_n と G_n との逆向不等式に関するより結果を御教示いただいた)。しかしこの種の逆向不等式 $A_n - G_n$ の上からの評価は研究課題にある。

参考文献

- [1] J. H. Wilkinson, Rounding errors in algebraic processes, Prentice-Hall, 1963. (他の版、およびドイツ語訳がある)
- [2] J. H. Wilkinson, The algebraic eigenvalue problem, Oxford Univ. Press, 1965.
- [3] G. E. Forsythe & C. B. Moler, Computer solution of linear algebraic systems, Prentice-Hall, 1967 : 日本語訳, 塔風館, 1969.
- [4] 宇野利左衛門, 数値計算論, 岩波, 1941 (とlt;1= p. 65)
- [5] S. Hitotumatu, On the numerical computation of Bessel functions through continued fraction, Comm. Math. Univ. St. Paul, 16 (1968), 89-113.
- [6] H. Kober, On the arithmetic and geometric means and on Hölder inequality, Proc. Amer. Math. Soc., 9 (1958) 452-459.