

第一讲 科学计算引论

数值计算中的误差



目录

1.1 线性代数基础

1.2 数值计算中的误差

<https://math.ecnu.edu.cn/~jypan/Teaching/SC>

1-3 | 数值计算中的误差

1.3 数值计算中的误差

1.3.1 绝对误差和绝对误差限

1.3.2 相对误差和相对误差限

1.3.3 有效数字

1.3.4 误差估计的基本方法

1.3.5 问题的适定性和算法的稳定性

1.3.6 减小误差危害

误差与误差来源

误差 是人们用来描述数值计算中近似解的精确程度.

- **模型误差**: 从实际问题中抽象出数学模型, 往往是抓住主要因素, 忽略次要因素, 因此, 数学模型与实际之间总会存在一定的误差.
- **数据误差**: 模型中往往包含各种数据或参量, 这些数据一般都是通过测量和实验得到的, 也会存在一定的误差.
- **截断误差**: 也称 **方法误差**, 是指对数学模型进行数值求解时产生的误差.
- **舍入误差**: 由于计算机的机器字长有限, 做算术运算时存在一定的精度限制.

 在本讲中, 我们只考虑截断误差和舍入误差对计算结果的影响.

例 近似计算 $\int_0^1 e^{-x^2} dx$ 的值.

解. 利用 Taylor 展开, 可得

$$\begin{aligned}\int_0^1 e^{-x^2} dx &= \int_0^1 \left(x - x^2 + \frac{x^4}{2!} - \frac{x^6}{3!} + \frac{x^8}{4!} - \cdots \right) dx \\ &= 1 - \frac{1}{3} + \frac{1}{2!} \times \frac{1}{5} - \frac{1}{3!} \times \frac{1}{7} + \frac{1}{4!} \times \frac{1}{9} - \cdots \\ &\triangleq S_4 + R_4,\end{aligned}$$

如果我们以 S_4 作为定积分的近似值, 则 R_4 就是由此而产生的误差, 这种误差就称为 **截断误差**, 它是由我们的近似方法所造成的.

在计算 S_4 的值时, 假定我们保留 5 位有效数字, 则

$$S_4 = 1 - \frac{1}{3} + \frac{1}{10} - \frac{1}{42} \approx 1.0000 - 0.33333 + 0.10000 - 0.023810 \approx 0.7429$$

这就是我们最后得到的近似值. 这里, 在计算 S_4 时所产生的误差就是 **舍入误差**. □

1-3-1

绝对误差和绝对误差限

定义 设 $\tilde{x}$ 是 x 的近似值, 则称

$$\epsilon \triangleq \tilde{x} - x$$

为近似值 $\tilde{x}$ 的 **绝对误差**, 简称 **误差**. 若存在 $\varepsilon > 0$ 使得

$$|\epsilon| = |\tilde{x} - x| \leq \varepsilon,$$

则称 ε 为 **绝对误差限**, 简称 **误差限**.

1-3-1

绝对误差和绝对误差限

定义 设 $\tilde{x}$ 是 x 的近似值, 则称

$$\epsilon \triangleq \tilde{x} - x$$

为近似值 $\tilde{x}$ 的 **绝对误差**, 简称 **误差**. 若存在 $\varepsilon > 0$ 使得

$$|\epsilon| = |\tilde{x} - x| \leq \varepsilon,$$

则称 ε 为 **绝对误差限**, 简称 **误差限**.

 在工程中, 通常用 $x = \tilde{x} \pm \varepsilon$ 表示 $\tilde{x}$ 的误差限为 ε .

关于误差和误差限的几点说明

- 绝对误差不是误差的绝对值, 可能是正的, 也可能是负的;
- 由于精确值通常是不知道的, 因此绝对误差一般也是不可知的;
- 在做误差估计时, 我们所求的通常是误差限;
- 误差限不唯一, 越小越好, 一般是指所能找到的最小上界;
- 近似值的精确程度不能仅仅看绝对误差, 还要看相对误差.

1-3-2

相对误差和相对误差限

定义 设 $\tilde{x}$ 是 x 的近似值, 称

$$\epsilon_r \triangleq \frac{\tilde{x} - x}{x} \quad \text{或} \quad \epsilon_r \triangleq \frac{\tilde{x} - x}{\tilde{x}}$$

为近似值 $\tilde{x}$ 的 **相对误差**. 若存在 $\varepsilon_r > 0$ 使得

$$|\epsilon_r| \leq \varepsilon_r,$$

则称 ε_r 为 **相对误差限**.

1-3-2

相对误差和相对误差限

定义 设 $\tilde{x}$ 是 x 的近似值, 称

$$\epsilon_r \triangleq \frac{\tilde{x} - x}{x} \quad \text{或} \quad \epsilon_r \triangleq \frac{\tilde{x} - x}{\tilde{x}}$$

为近似值 $\tilde{x}$ 的 **相对误差**. 若存在 $\varepsilon_r > 0$ 使得

$$|\epsilon_r| \leq \varepsilon_r,$$

则称 ε_r 为 **相对误差限**.

- 近似值的精确程度通常取决于 **相对误差** 的大小;
- 实际计算中我们所能得到的通常是相对误差限 (所能找到的最小上界);
- 绝对误差有量纲, 但相对误差没有.

1-3-3 | 有效数字

在取一个浮点数的近似值时, 为了就尽可能地精确, 一个基本原则是“四舍五入”, 这样所得到的数字都是有效数字.

例 已知精确值 $\pi = 3.14159265 \dots$, 则

- 近似值 $x_1 = 3.14$ 有 3 位有效数字,
- 近似值 $x_2 = 3.1416$ 有 5 位有效数字,
- 近似值 $x_3 = 3.1415$ 有 4 位有效数字.

从上面的例子中可以看出, 我们在计算有效数字的个数时, 是从最小的 **有效数字位** 开始往前数, 直至第一个非零数字为止. 如果总共有 n 个数字, 那么我们就称其有 n 位有效数字.

有效数字的判断

定理 设 $\tilde{x}$ 是 x 的近似值, 若 $\tilde{x}$ 可表示为

$$\tilde{x} = \pm 0.a_1a_2 \cdots a_n \cdots \times 10^m,$$

其中 a_i 是 0 到 9 中的数字, 且 $a_1 \neq 0$. 若

$$0.5 \times 10^{k-1} < |\tilde{x} - x| \leq 0.5 \times 10^k,$$

则 $\tilde{x}$ 恰好有 $m - k$ 位有效数字.

四舍五入

例 根据四舍五入原则写出下列各数的具有 5 位有效数字的近似值:

187.9325, 0.03785551, 8.000033.

 按四舍五入原则得到的数字都是有效数字; 一个数末尾的 0 不可以随意添加或省略.

有效数字与误差限

实际计算中, 往往只知道误差限, 由此可判断有效数字的最少个数.

推论 设 $\tilde{x}$ 是 x 的近似值, 若 $\tilde{x}$ 可表示为

$$\tilde{x} = \pm 0.a_1a_2 \cdots a_n \cdots \times 10^m,$$

其中 a_i 是 0 到 9 中的数字, 且 $a_1 \neq 0$. 若

$$|\tilde{x} - x| \leq 0.5 \times 10^k,$$

则 $\tilde{x}$ 至少有 $m - k$ 位有效数字.

例 已知精确值 $x = 2.7182818\dots$, 则近似值 $x_1 = 2.7182$ 和 $x_2 = 2.7183$ 分别有几位有效数字? (板书, 4, 5)

解 直接计算可得

$$0.5 \times 10^{-4} < |x_1 - x| = 0.818\dots \times 10^{-4} \leq 0.5 \times 10^{-3},$$

$$0.5 \times 10^{-5} < |x_2 - x| = 0.181\dots \times 10^{-4} \leq 0.5 \times 10^{-4}.$$

又 $x_1 = 0.27182 \times 10^1$ 和 $x_2 = 0.27183 \times 10^1$, 因此, x_1 有 $1 - (-3) = 4$ 位有效数字, x_2 有 $1 - (-4) = 5$ 位有效数字.

有效数字与相对误差

定理 (有效数字与相对误差限) 设 $\tilde{x}$ 是 x 的近似值, 若 $\tilde{x}$ 可表示为

$$\tilde{x} = \pm 0.a_1a_2 \dots a_n \dots \times 10^m,$$

其中 a_i 是 0 到 9 中的数字, 且 $a_1 \neq 0$. 若 $\tilde{x}$ 具有 n 位有效数字, 则其相对误差满足

$$|\epsilon_r| \leq \frac{1}{2a_1} \times 10^{-n+1}.$$

反之, 若 $\tilde{x}$ 的相对误差满足

$$|\epsilon_r| \leq \frac{1}{2(a_1 + 1)} \times 10^{-n+1}.$$

则 $\tilde{x}$ 至少有 n 位有效数字.

有效数字越多, 相对误差越小. 同样, 相对误差越小, 则有效数字越多.

1-3-4 | 误差估计的基本方法

误差估计: 四则运算

设 $\tilde{x}_1$ 和 $\tilde{x}_2$ 的误差限分别为 $\varepsilon(\tilde{x}_1)$ 和 $\varepsilon(\tilde{x}_2)$, 则

$$\varepsilon(\tilde{x}_1 \pm \tilde{x}_2) \leq \varepsilon(\tilde{x}_1) + \varepsilon(\tilde{x}_2),$$

$$\varepsilon(\tilde{x}_1 \tilde{x}_2) \leq |\tilde{x}_2| \varepsilon(\tilde{x}_1) + |\tilde{x}_1| \varepsilon(\tilde{x}_2) + \varepsilon(\tilde{x}_1) \varepsilon(\tilde{x}_2) \lesssim |\tilde{x}_2| \varepsilon(\tilde{x}_1) + |\tilde{x}_1| \varepsilon(\tilde{x}_2),$$

$$\varepsilon\left(\frac{\tilde{x}_1}{\tilde{x}_2}\right) \lesssim \frac{|\tilde{x}_2| \varepsilon(\tilde{x}_1) + |\tilde{x}_1| \varepsilon(\tilde{x}_2)}{|\tilde{x}_2|^2}.$$

误差在计算过程中会累积和传递, 也可能会相消.

1-3-5

问题的适定性和算法的稳定性

数学问题的适定性

定义 如果数学问题满足

- (1) 对任意满足一定条件的输入数据, 存在一个解,
- (2) 对任意满足一定条件的输入数据, 解是唯一的,
- (3) 问题的解关于输入数据是连续的,

则称该数学问题是 **适定的** (well-posed), 否则就称为 **不适定的** (ill-posed).

病态问题与条件数

定义 (病态问题) 如果输入数据的微小扰动会引起输出数据 (即计算结果) 的很大变化 (误差), 则称该数学问题是 **病态** 的, 否则就是 **良态** 的.

举例

例 解线性方程组
$$\begin{cases} x + \alpha y = 1 \\ \alpha x + y = 0 \end{cases}$$

解 易知当 $\alpha = 1$ 时, 方程组无解, 问题是不适定的.

当 $\alpha \neq 1$ 时, 存在唯一解, 解为

$$x = \frac{1}{1 - \alpha^2}, \quad y = \frac{-\alpha}{1 - \alpha^2}.$$

如果 $\alpha \approx 1$, 则 α 的微小误差可能会引起解的很大变化.

- 🔴 比如当 $\alpha = 0.999$ 时, $x \approx 500.25$. 假定输入数据 α 带有 0.0001 的误差, 即实际输入数据为 $\tilde{\alpha} = 0.9991$, 则此时有 $\tilde{x} \approx 555.81$, 解的误差约为 55.56, 是输入数据误差的五十多万倍, 因此该问题的病态的.

注记

- 病态是问题本身固有的性质, 与数值算法无关;
- 对于病态问题, 选择数值算法时需要更加谨慎.

算法的稳定性 I

在算法实现过程中, 若误差能得到有效控制, 则称该算法是 **稳定** 的, 否则为 **不稳定** 的.

例 近似计算

(Demo11_Stablity.m)

$$S_n = \int_0^1 \frac{x^n}{x+5} dx, \quad n = 1, 2, \dots, 8.$$

解 通过观察可知: $S_n + 5S_{n-1} = \int_0^1 \frac{x^n + 5x^{n-1}}{x+5} dx = \int_0^1 x^{n-1} = \frac{1}{n}$, 因此有

$$S_n = \frac{1}{n} - 5S_{n-1}$$

易知 $S_0 = \ln 6 - \ln 5 \approx 0.182$ (保留三位有效数字), 根据递推公式, 可得

$$S_1 = 0.0900, \quad S_2 = 0.0500, \quad S_3 = 0.0833, \quad S_4 = -0.166,$$

$$S_5 = 1.03, \quad S_6 = -4.98, \quad S_7 = 25.0, \quad S_8 = -125.$$

另一方面, 我们有

$$\frac{1}{6(n+1)} = \int_0^1 \frac{x^n}{6} dx \leq \int_0^1 \frac{x^n}{x+5} dx \leq \int_0^1 \frac{x^n}{5} dx = \frac{1}{5(n+1)}.$$

易知 $S_0 = \ln 6 - \ln 5 \approx 0.182$ (保留三位有效数字), 根据递推公式, 可得

$$S_1 = 0.0900, \quad S_2 = 0.0500, \quad S_3 = 0.0833, \quad S_4 = -0.166,$$

$$S_5 = 1.03, \quad S_6 = -4.98, \quad S_7 = 25.0, \quad S_8 = -125.$$

另一方面, 我们有

$$\frac{1}{6(n+1)} = \int_0^1 \frac{x^n}{6} dx \leq \int_0^1 \frac{x^n}{x+5} dx \leq \int_0^1 \frac{x^n}{5} dx = \frac{1}{5(n+1)}.$$

因此, 上面计算的 $S_4, \dots, S_8$ 显然是不对的.

易知 $S_0 = \ln 6 - \ln 5 \approx 0.182$ (保留三位有效数字), 根据递推公式, 可得

$$S_1 = 0.0900, \quad S_2 = 0.0500, \quad S_3 = 0.0833, \quad S_4 = -0.166,$$

$$S_5 = 1.03, \quad S_6 = -4.98, \quad S_7 = 25.0, \quad S_8 = -125.$$

另一方面, 我们有

$$\frac{1}{6(n+1)} = \int_0^1 \frac{x^n}{6} dx \leq \int_0^1 \frac{x^n}{x+5} dx \leq \int_0^1 \frac{x^n}{5} dx = \frac{1}{5(n+1)}.$$

因此, 上面计算的 $S_4, \dots, S_8$ 显然是不对的.

原因是什么呢? 误差!

设 $\tilde{S}_n$ 是 S_n 的近似值, 则

$$\epsilon(\tilde{S}_n) = \tilde{S}_n - S_n = \left(\frac{1}{n} - 5\tilde{S}_{n-1} \right) - \left(\frac{1}{n} - 5S_{n-1} \right) \approx -5(\tilde{S}_{n-1} - S_{n-1}) = -5\epsilon(\tilde{S}_{n-1}).$$

即误差是以 5 倍速度增长, 这说明计算过程是 **不稳定** 的, 因此我们不能使用该算法.

事实上, 递推公式可以改写为

$$S_{n-1} = \frac{1}{5n} - \frac{1}{5}S_n$$

因此, 我们可以先估计 S_8 的值, 然后通过反向递推, 得到其它值.

我们可以根据前面的不等式对 S_8 做简单的估计, 即

$$S_8 \approx \frac{1}{2} \left(\int_0^1 \frac{x^8}{6} dx + \int_0^1 \frac{x^8}{5} dx \right) \approx 0.0204.$$

于是

$$\begin{aligned} S_7 &= 0.0209, & S_6 &= 0.0244, & S_5 &= 0.0285, & S_4 &= 0.0343, \\ S_3 &= 0.0431, & S_2 &= 0.0580, & S_1 &= 0.0884, & S_0 &= 0.182. \end{aligned}$$

通过误差分析可知, 误差是以 $\frac{1}{5}$ 的速度减小, 因此计算过程是稳定的.

几点说明

- ✎ 在数值计算中, 误差不可避免, 算法的稳定性是一个非常重要的性质.
- ✎ 在数值计算中, 不要采用不稳定的算法!
- ▶ 用计算机进行整数之间的加减和乘法运算时, 没有误差. (但可能会产生溢出)

几点说明

- ✎ 在数值计算中, 误差不可避免, 算法的稳定性是一个非常重要的性质.
- ✎ 在数值计算中, 不要采用不稳定的算法!
- ▶ 用计算机进行整数之间的加减和乘法运算时, 没有误差. (但可能会产生溢出)

例 已知正整数 y 不超过 2025927, 且满足 100 整除 $2^y + y$, 试问这样的 y 有多少个?

减小误差危害

(1) 避免相近的数相减

如果两个相近的数相减, 则会损失有效数字. 例如如

$$0.12346 - 0.12345 = 0.00001,$$

两个操作数都有 5 位有效数字, 但计算结果却只有 1 位有效数字.

举例

例 计算 $\sqrt{9.01} - 3$, 计算过程中保留 3 位有效数字.

解. 如果直接计算的话, 可得

$$\sqrt{9.01} = 3.0016662039607 \dots \approx 3.00.$$

所以 $\sqrt{9.01} - 3 \approx 0.00$, 一个有效数字都没有!

但如果换一种计算方法, 如

$$\sqrt{9.01} - 3 = \frac{9.01 - 3^2}{\sqrt{9.01} + 3} \approx \frac{0.01}{3.00 + 3} \approx 0.00167.$$

通过精确计算可知 $\sqrt{9.01} - 3 = 0.0016662039607 \dots$. 因此第二种计算能得到三位有效数字! □

如何避免相近的数相减

通过各种等价公式来计算两个相近的数相减, 是避免有效数字损失的有效手段之一.

下面给出几个常用的等价公式:

$$\sqrt{x + \varepsilon} - \sqrt{x} = \frac{\varepsilon}{\sqrt{x + \varepsilon} + \sqrt{x}}$$

$$\ln(x + \varepsilon) - \ln(x) = \ln\left(1 + \frac{\varepsilon}{x}\right)$$

$$1 - \cos(x) = 2 \sin^2 \frac{x}{2}, \quad |x| \ll 1$$

$$e^x - 1 = x \left(1 + \frac{1}{2}x + \frac{1}{6}x^2 + \cdots\right), \quad |x| \ll 1$$

例 计算 $y = \left(\frac{\sqrt{101} - 10}{\sqrt{101} + 10} \right)^2$.

方法一：分母有理化 $y = \left(\frac{\sqrt{101}-10}{\sqrt{101}+10} \right)^2 = 80801 - 8040\sqrt{101}$;

方法二：分子有理化 $y = \left(\frac{\sqrt{101}-10}{\sqrt{101}+10} \right)^2 = \frac{1}{80801+8040\sqrt{101}}$;

方法三：直接将 $\sqrt{101}$ 的近似值代入计算.

已知 $\sqrt{101} = 10.0498756 \dots$, 分别取近似值 10.04, 10.05, 10.06, 计算结果如下:

$\sqrt{101}$	方法一	方法二	方法三
10.04	79.400	6.1911E-6	3.9840E-6
10.05	-1.0000	6.1880E-6	6.2189E-6
10.06	-81.400	6.1849E-6	8.9462E-6

实际值为 $y = 6.188042227 \dots \times 10^{-6}$.

例 在 MATLAB 中用双精度数计算

(Demo12_Significance.m)

$$E_1 = \frac{1 - \cos(x)}{\sin^2(x)} \quad \text{和} \quad E_2 = \frac{1}{1 + \cos(x)}$$

x	E_1	E_2
1.0000000000	0.649223205204762	0.649223205204762
0.1000000000	0.501252086288577	0.501252086288571
0.0100000000	0.500012500208481	0.500012500208336
0.0010000000	0.500000124992189	0.500000125000021
0.0001000000	0.499999998627931	0.500000001250000
0.0000100000	0.500000041386852	0.500000000012500
0.0000010000	0.500044450291337	0.5000000000000125
0.0000001000	0.499600361081322	0.5000000000000001
0.0000000100	0.0000000000000000	0.5000000000000000

由此可见, 当 x 趋于 0 时, E_1 的计算结果显然是错的, 而 E_2 则能很好地计算出近似值.

例 计算 $y = \ln 2$.

(Demo13_ln.m)

方法一 利用 $f(x) = \ln(1+x)$ 的 Taylor 展开

$$\ln(1+x) = x - \frac{1}{2}x^2 + \frac{1}{3}x^3 - \frac{1}{4}x^4 + \cdots + \frac{(-1)^{n+1}}{n}x^n + \cdots.$$

将 $x = 1$ 代入后计算结果为

n	1	2	3	4	5	10	50	100
S_n	1	0.5	0.833	0.583	0.783	0.646	0.683	0.688
误差	3.1E-1	1.9E-1	1.4E-1	1.1E-1	9.0E-2	4.8E-2	9.9E-3	5.0E-3

计算到第 100 项, 误差仍有 0.05.

方法二 利用 $f(x) = \ln\left(\frac{1+x}{1-x}\right)$ 的 Taylor 展开

$$\ln\left(\frac{1+x}{1-x}\right) = 2\left(x + \frac{1}{3}x^3 + \frac{1}{5}x^5 + \cdots + \frac{1}{2n-1}x^{2n-1} + \cdots\right).$$

将 $x = 1/3$ 代入后计算结果为

n	1	2	3	4	5	10
S_n	0.667	0.691	0.693	0.693	0.693	0.693
$ S_n - \ln 2 $	2.6E-2	1.8E-3	1.4E-4	1.2E-5	1.1E-6	1.0E-11

计算到第 10 项, 误差已经小于 10^{-10} ! 实际值为 $\ln 2 = 0.693147180559945\dots$

(2) 避免数量级相差很大的数相除

可能会产生溢出, 即超出计算机所能表示的数的范围. 特别需要注意的是, 尽量不要用很小的数作为除数, 否则为放大分子的误差.

 如果两个数相除, 一般情况下建议把绝对值小的数作为分子, 这在后面的算法中会经常遇到.

(3) 避免大数吃小数

如 $(10^9 + 10^{-9} - 10^9)/10^{-9}$, 直接计算的话, 结果为 0.

另外, 在对一组数求和时, 建议按照绝对值从小到大求和.

例 计算 $S = 1 + 2 + 3 + \cdots + 100 + 10^{16}$.

(Demo14_Sum.m)

从小到大计算, 结果为

$$S = 1 + 2 + 3 + \cdots + 100 + 10^{16} = 1.00000000000005050 \times 10^{16}.$$

从大到小计算, 结果为

$$S = 10^{16} + 100 + 99 + \cdots + 2 + 1 = 1.00000000000005100 \times 10^{16}.$$

(4) 简化计算

尽量减少运算次数, 从而减少误差的积累.

例 多项式计算. 设多项式

([Demo15_Poly.m](#))

$$p(x) = 5x^5 + 4x^4 + 3x^3 + 2x^2 + 2x + 1.$$

试计算 $p(3)$ 的值.

方法一 直接计算

$$p(3) = 5 \times 3^5 + 4 \times 3^4 + 3 \times 3^3 + 2 \times 3^2 + 2 \times 3 + 1.$$

需要做 15 次乘法和 5 次加法.

方法二 当计算 x^k 时, 由于前面已经计算出 x^{k-1} , 因此只需做一次乘法. 这样整个计算过程可以减少到 9 次乘法和 5 次加法.

方法三 有没有更快的?

秦九韶算法/Horner 算法

 在计算多项式的值时, 我们都是将多项式改写成

$$\begin{aligned} p(x) &= a_n x^n + a_{n-1} x^{n-1} + a_{n-2} x^{n-2} + \cdots + a_1 x + a_0 \\ &= ((\cdots ((a_n x + a_{n-1})x + a_{n-2})x + \cdots)x + a_1)x + a_0. \end{aligned}$$

这里利用了嵌套思想, 只需做 n 次乘法和 n 次加法.

这种计算方法就是著名的 **秦九韶算法** (1247), 五百多年后, 英国数学家 Horner (1819) 重新发现了该公式, 因此西方也称为 **Horner 算法**.

方法三 我们可以将多项式改写为

$$p(x) = (((((5x + 4)x + 3)x + 2)x + 2)x + 1).$$

这样就只需做 5 次乘法和 5 次加法. 显然这是更佳的计算方案.

谢谢
THANK YOU

