

数值计算方法与算法

1 绪论

1. 对任一向量 $X \in \mathbf{R}^n$, 按照一个规则确定一个非负实数与它对应, 记该实数为 $\|X\|$ 。若 $\|X\|$ 满足下面三个性质:

- (1) 任取 $X \in \mathbf{R}^n$, 有 $\|X\| \geq 0$, 当且仅当 $X = 0$ 时取等 (非负性);
- (2) 任取 $X \in \mathbf{R}^n, \alpha \in \mathbf{R}$, 有 $\|\alpha X\| = |\alpha| \|X\|$ (齐次性);
- (3) 任取 $X, Y \in \mathbf{R}^n$, 有 $\|X + Y\| \leq \|X\| + \|Y\|$ (三角不等式);

则称实数 $\|X\|$ 为向量 X 的范数。

2. 向量 $X = (x_1, \dots, x_n)^T$ 的 L_p 范数定义为: $\|X\|_p = (\sum_{i=1}^n |x_i|^p)^{1/p}, 1 \leq p \leq +\infty$ 。经常使用的三种 L_p 范数是 $p = 1, 2, \infty$, 即

- 1 范数 (曼哈顿范数): $\|X\|_1 = \sum_{i=1}^n |x_i|$;
- 2 范数 (欧几里得范数): $\|X\|_2 = \sqrt{\sum_{i=1}^n x_i^2}$;
- ∞ 范数: $\|X\|_\infty = \max_{1 \leq i \leq n} \{|x_i|\}$ 。

3. 若 $R_1(X), R_2(X)$ 是 \mathbf{R}^n 上两种不同的范数定义, 则必存在 $0 < m < M < \infty$, 使 $\forall X \in \mathbf{R}^n$, 均有 $m < \frac{R_1(X)}{R_2(X)} < M$ 。

4. 设 $A \in \mathbf{R}^{n \times n}$, 记方阵 A 的范数为 $\|A\|$, 矩阵范数满足下列性质:

- (1) $\|A\| \geq 0$, 当且仅当 $A = 0$ 时取等 (非负性);
- (2) 任取 $\lambda \in \mathbf{R}$, 有 $\|\lambda A\| = |\lambda| \|A\|$ (齐次性);
- (3) 任取 $A, B \in \mathbf{R}^{n \times n}$, 有 $\|A + B\| \leq \|A\| + \|B\|$ (三角不等式);

设 $\|\cdot\|$ 是 \mathbf{R}^n 上的一个向量范数, 则由 $\|A\| = \sup_{\|X\|=1} \|AX\|, A \in \mathbf{R}^{n \times n}$ 定义的是实

值函数 $\|A\|$ 是一个诱导矩阵范数, 它满足:

- (4) 任取 $A, B \in \mathbf{R}^{n \times n}$, 则 $\|AB\| \leq \|A\| \|B\|$ (相乘性);

(5) $\forall X \in \mathbf{R}^n$, 恒有 $\|AX\| \leq \|A\| \cdot \|X\|$ (相容性);

5. 常用矩阵范数

$$\|A\|_1 = \max_{1 \leq j \leq n} \left\{ \sum_{i=1}^n |a_{ij}| \right\} \quad (\text{列和范数})$$

$$\|A\|_\infty = \max_{1 \leq i \leq n} \left\{ \sum_{j=1}^n |a_{ij}| \right\} \quad (\text{行和范数})$$

$$\|A\|_2 = \sqrt{\rho(A^T A)}, \text{ 谱半径 } \rho(A) = \max_{1 \leq i \leq n} |\lambda_i|$$

$$\|A\|_F = \left(\sum_{i=1}^n \sum_{j=1}^n |a_{ij}|^2 \right)^{\frac{1}{2}} \quad (\text{非诱导范数, 但与 } \|X\|_2 \text{ 相容, } \|I\|_F = n^{\frac{1}{2}})$$

对任一种从属范数有 $\|I\| = 1$, 即单位矩阵的范数是 1。

6. 对任一相容的矩阵范数, $|\lambda| \leq \|A\|$, $\rho(A) \leq \|A\|$, 对任意 $\varepsilon > 0$, 存在一个矩阵相容范数使得 $\|A\| < \rho(A) + \varepsilon$ 。

7. 当 $\lim_{k \rightarrow \infty} A^k = 0$ 时, 称 A 为收敛矩阵。 $\lim_{k \rightarrow \infty} A^k = 0$ 的充分必要条件是 $\rho(A) < 1$ 或存在相容范数 $\|\cdot\|$, 使得 $\|A\| < 1$ 。

8. 若 A 非奇异, 称 $Cond_p(A) = \|A\|_p \|A^{-1}\|_p$ 为 A 的条件数, 其中 $\|\cdot\|_p$ 表示矩阵的某种范数。 $Cond(A) \geq 1$, 当 A 为正交矩阵时, $Cond(A) = 1$ 。

9. 设 $A \in \mathbf{R}^{n \times n}$, $b \in \mathbf{R}^n$, $Ax = b$, A 非奇异, δA 和 δb 是 A 和 b 的扰动, $\|A^{-1}\| \|\delta A\| < 1$, 则 $\frac{\|\delta x\|}{\|x\|} \leq \frac{Cond(A)}{1 - Cond(A) \frac{\|\delta A\|}{\|A\|}} \left(\frac{\|\delta A\|}{\|A\|} + \frac{\|\delta b\|}{\|b\|} \right)$ 。

10. 若存在范数 $\|\cdot\|$, 使得 $\|A\| < 1$, 则 $I - A$ 可逆, 且 $(I - A)^{-1} = \sum A^k$, $\|(I - A)^{-1}\| \leq \frac{1}{1 - \|A\|}$ 。

11. 设 A 非奇异, 则 $\min \left\{ \frac{\|\delta A\|_2}{\|A\|_2} : A + \delta A \text{ 奇异} \right\} = \frac{1}{Cond_2(A)}$ 。

2 非线性方程求根

非线性方程求根, 需要给定初始值或求解范围, 迭代求解。

1. 对分法

2.迭代法

$f(x) = 0 \Rightarrow x = \varphi(x)$, 若 $\lim_{k \rightarrow \infty} x_{k+1} = \lim_{k \rightarrow \infty} \varphi(x_k) = x^*$, 则 $f(x^*) = 0$ 。

若 $\varphi(x)$ 在区间 $[a, b]$ 上连续且可导, $a < \varphi(x) < b$, 存在 $L < 1$, $|\varphi'(x)| \leq L$, 那么存在唯一的点 x^* 使得 $x^* = \varphi(x^*)$ 成立, 且 $x_{k+1} = \varphi(x_k)$ 对任意初值均收敛于 x^* , $|x^* - x_k| \leq \frac{L^k}{1-L} |x_1 - x_0|$ 。

构造迭代格式的要素为: (1) 等价形式 $x = \varphi(x)$ 满足 $|\varphi'(x^*)| < 1$; (2) 初始值在 x^* 的充分小邻域。

3.收敛阶

对于迭代格式 $x_{k+1} = \varphi(x_k)$, 若 $\lim_{k \rightarrow \infty} \frac{|e_{k+1}|}{|e_k|^p} = C > 0$, 则称该迭代格式为 p 阶收敛的, C 称为渐进误差常数。

4.Newton 迭代法

$$x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)}$$

若 x^* 为 $f(x)$ 单根, 则迭代格式在 x^* 附近 2 阶收敛。若 x^* 为 $f(x)$ 的 m 重根, 则迭代格式在 x^* 附近 1 阶收敛。修正为下述格式可 2 阶收敛:

$$x_{k+1} = x_k - m \frac{f(x_k)}{f'(x_k)}$$
$$\mu(x) = \frac{f(x)}{f'(x)}, x_{k+1} = x_k - \frac{\mu(x_k)}{\mu'(x_k)}$$

5.弦截法

$$x_{k+1} = x_k - \frac{f(x_k)(x_k - x_{k-1})}{f(x_k) - f(x_{k-1})}$$

6.非线性方程组的 Newton 方法

$$J(X^{(k)})\Delta X^{(k)} = -F(X^{(k)})$$

$$X^{(k+1)} = X^{(k)} + \Delta X^{(k)}$$

在 X 邻域若 $\rho(X) < 1$ 或 $\|J(X)\|_{\infty} < 1$, 初始值接近解, 则迭代收敛。

3 解线性方程组的迭代法

1. $AX = b \Rightarrow X = MX + b$, 若 $\lim_{k \rightarrow \infty} X^{(k+1)} = \lim_{k \rightarrow \infty} MX^{(k)} + b = X^*$, 则 $AX^* = b$ 。

迭代格式收敛的充要条件是 $\rho(M) < 1$, 一个充分条件是 $\|A\|_p < 1$, 与初值选取无关。

3. Jacobi 迭代

$$X^{(k+1)} = RX^{(k)} + g, R = I - D^{-1}A, g = D^{-1}b$$

若 A 严格对角优, Jacobi 迭代收敛。

4. Gauss-Seidel 迭代

$$X^{(k+1)} = SX^{(k)} + f, S = -(D + L)^{-1}U, f = (D + L)^{-1}b$$

若 A 严格对角优或严格正定, Gauss-Seidel 迭代收敛。

5. 松弛迭代 (SOR)

SOR 收敛的必要条件是 $0 < \omega < 2$ 。若 A 对称正定, 则当 $0 < \omega < 2$ 时, SOR 迭代收敛。

4 解线性方程组的直接法

1. Gauss 消元法、Gauss-Jordan 消元法。Gauss 消元过程顺利进行 $\Leftrightarrow A$ 的各阶主子式不为零

2. Gauss 列主元消元法

3. Doolittle 分解: $A = LU$, L 为单位下三角阵, U 为上三角阵。

4. Crout 分解: $A = LU$, L 为下三角阵, U 为单位上三角阵。

5. 三对角方程组的追赶法

$$\begin{pmatrix} a_1 & b_1 & & & \\ c_2 & \ddots & \ddots & & \\ & \ddots & a_{n-1} & b_{n-1} & \\ & & c_n & a_n & \end{pmatrix} = \begin{pmatrix} u_1 & & & & \\ w_2 & \ddots & & & \\ & \ddots & u_{n-1} & & \\ & & w_n & u_n & \end{pmatrix} \begin{pmatrix} 1 & v_1 & & & \\ & \ddots & \ddots & & \\ & & 1 & v_{n-1} & \\ & & & 1 & \end{pmatrix}$$

6. 对称正定矩阵的 LDL^T分解和 cholesky 分解: $A = LDL^T$, L 单位下三角阵, D 为对角阵。 $A = PP^T$, P 为对角元大于零的下三角阵。

5 计算矩阵的特征值与特征向量

1. 幂法

幂法是计算按模最大特征值及相应特征向量的数值方法, 要求矩阵 A 具有完备的特征向量系。

设 A 有特征值 $|\lambda_1| \geq \dots \geq |\lambda_n|$, 做迭代 $x^{(k+1)} = Ax^{(k)}$ 。

(1) 若 $|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_n|$, 有 $\lambda_1 \approx x^{(k+1)}/x^{(k)}$, $v_1 \approx x^{(k+1)}$, 收敛速度取决于 $|\lambda_2|/|\lambda_1|$ 。

(2) 若 $|\lambda_1| = |\lambda_2| > |\lambda_3| \geq \dots \geq |\lambda_n|$, 有 $\lambda_1^2 \approx x^{(2k+2)}/x^{(2k)}$, $\lambda_2^2 \approx x^{(2k+1)}/x^{(2k-1)}$, $v_1 \approx x^{(k+1)} + \lambda_1 x^{(k)}$, $v_2 \approx x^{(k+1)} + \lambda_2 x^{(k)}$ 。

采用规范运算

$$\begin{cases} y^{(k)} = x^{(k)} / \|x^{(k)}\|_{\infty} \\ x^{(k+1)} = Ay^{(k)} \end{cases}$$

(1) 若 $\{y^{(k)}\}$ 收敛, 则 $\lambda_1 \approx \|x^{(k+1)}\|_{\infty} / \|x^{(k)}\|_{\infty}$, $v_1 \approx y^{(k)}$ 。

(2) 若 $\{y^{(2k)}\}, \{y^{(2k+1)}\}$ 收敛于符号相反的向量, 则 $\lambda_1 \approx -\|x^{(k+1)}\|_{\infty} / \|x^{(k)}\|_{\infty}$, $v_1 \approx y^{(k)}$ 。

(3) 若 $\{y^{(2k)}\}, \{y^{(2k+1)}\}$ 收敛于两个不同的向量, 且不是符号相反, 则 $\lambda_1 \approx \sqrt{x^{(k+1)}/y^{(k-1)}}$, $\lambda_2 = -\lambda_1$, $v_1 \approx x^{(k+1)} + \lambda_1 x^{(k)}$, $v_2 \approx x^{(k+1)} + \lambda_2 x^{(k)}$ 。需要注意, $x^{(k+1)} = Ax^{(k)}$, 即最后一次迭代是非规范的。

2. 反幂法

$$\begin{cases} y^{(k)} = x^{(k)} / \|x^{(k)}\|_{\infty} \\ Ax^{(k+1)} = y^{(k)} \end{cases}$$

若 A 有特征值 $|\lambda_1| \geq \dots \geq |\lambda_{n-1}| > |\lambda_n|$, 则得到值 $\frac{1}{\lambda_n}$ 和 v_n , A 的按模最小特征值越

小，收敛越快。

带原点位移的反幂法：

$$\begin{cases} y^{(k)} = x^{(k)} / \|x^{(k)}\|_{\infty} \\ (A - pI)x^{(k+1)} = y^{(k)} \end{cases}$$

得到特征值 μ ，于是 A 的按模最小特征值 $\lambda_i = p + \frac{1}{\mu}$ 。它可以用来求矩阵 A 最接近于 p 的特征值和特征向量。

3. 实对称矩阵的 Jacobi 方法

$$\begin{cases} A \leftarrow Q^T A Q \\ V \leftarrow V Q \end{cases}$$

4. 若 $v \in \mathbb{R}^n, \|v\| = 1$ ，则矩阵 $H = I - 2vv^T$ 称为 Householder 矩阵，且满足性质：(1) $\det(H) = -1$ ；(2) H 为对称正交矩阵；(3) 若 $x, y \in \mathbb{R}^n$ ，且 $\|x\| = \|y\|$ ，记 $v = \frac{y-x}{\|y-x\|}$ ，则 $Hx = y$ 。

4. QR 分解定理：设 A 列满秩，则能被分解为 $A = QR$ 形式，其中 Q 为酉矩阵， R 为非奇异的上三角阵。

推论：设 A 列满秩，则能被唯一分解为 $A = QR$ 形式，其中 Q 为正交矩阵， R 为非奇异的上三角阵。

取 A 第一列 α_1 ，令 $v_1 = \frac{\alpha_1 - \|\alpha_1\|e_1}{\|\alpha_1 - \|\alpha_1\|e_1\|}$ ，构造 H_1 ，于是 $H_1 A = \begin{pmatrix} \|\alpha_1\| & * \\ 0 & A_1 \end{pmatrix}$ ，继续进行，得到系列 H ，于是 $R = HA, Q = H^T$ 。

5. QR 方法

设 A 有特征值 $|\lambda_1| > \dots > |\lambda_n|$ ，分解 A_k ，并迭代得 A_{k+1} ：

$$\begin{cases} A_k = Q_k R_k \\ A_{k+1} = R_k Q_k \end{cases}$$

当 $k \rightarrow \infty$ 时， $\{A_k\}$ 收敛于上三角矩阵，对角线元素为特征值。

6 插值

1. 设 $\{x_i\}_{i=0}^n$ 为 $n+1$ 个互不相等的节点， $\Phi = \text{span}\{\varphi_0, \dots, \varphi_n\}$ 是 $n+1$ 维线性

空间，则插值函数 $\varphi(x)$ 存在且唯一。

2. 多项式插值的 Lagrange 形式

$$L_n(x) = \sum_{i=0}^n l_i(x) f(x_i), l_i(x) = \prod_{\substack{0 \leq j \leq n \\ j \neq i}} \frac{x - x_j}{x_i - x_j}$$

$$R_n(x) = \frac{f^{(n+1)}(\xi)}{(n+1)!} \prod_{i=0}^n (x - x_i), \xi \in (a, b), f \in C^{n+1}[a, b]$$

$$|R_n(x)| \leq \frac{M}{(n+1)!} \prod_{i=0}^n (x - x_i), |f^{(n+1)}(x)| \leq M, x \in [a, b]$$

性质: $\sum_{0 \leq i \leq n} l_i(x) \equiv 1$

后验误差估计，设 $f^{(n+1)}(x)$ 在插值区间内连续且变化不大， L_n 为去下 x_i 的插值函数， \tilde{L}_n 为去下 x_j 的插值函数，则

$$R_n(x) \approx \frac{x - x_i}{x_i - x_j} (L_n(x) - \tilde{L}_n(x))$$

4. 差商

$$f[x_0, \dots, x_k] = \frac{f[x_1, \dots, x_k] - f[x_0, \dots, x_{k-1}]}{x_k - x_0}$$

k 阶差商 $f[x_0, \dots, x_k]$ 由函数值 $f(x_0), \dots, f(x_k)$ 的线性组合而成， $f[x_0, \dots, x_k] = \sum_{i=0}^k [f(x_i) \prod_{0 \leq j \neq i \leq k} \frac{1}{x_i - x_j}]$ 。

若 $\{i_0, \dots, i_k\}$ 是 $\{1, \dots, k\}$ 的任一排列，则 $f[x_0, \dots, x_k] = f[x_{i_0}, \dots, x_{i_k}]$ ，即差商的值只与节点有关而与节点顺序无关。

若 $f(x)$ 为 m 次多项式，则 $f[x_0, \dots, x_k]$ 为 $m - k$ 次多项式。

若多项式 $p(x)$ 插值于 $\{x_i, f(x_i)\}_{i=0}^n$ ，则 $f[x_0, \dots, x_n]$ 等于 $p(x)$ 最高次项的系数。

设 $f \in C^n[a, b]$ ，存在 $\xi \in (a, b)$ ，使得 $f[x_0, \dots, x_n] = \frac{1}{n!} f^{(n)}(\xi)$ 。

5. 多项式插值的 Newton 形式

(1) 构造差商表

(2) 构造插值多项式

$$N_n(x) = \sum_{i=0}^n f[x_0, \dots, x_i] t_i(x), t_0(x) \equiv 1, t_i(x) = \prod_{k=0}^{i-1} (x - x_k), i = 1, \dots$$

$$N_k(x) = N_{k-1}(x) + f[x_0, \dots, x_k] t_k(x)$$

$$R_n(x) = f[x_0, \dots, x_n, x] \prod_{i=0}^n (x - x_i)$$

6. Hermite 插值

如果不仅要求在插值多项式节点的函数值与被插函数的函数值相等，还要求在节点处插值函数与被插函数的一阶或高阶导数的值也相等，这类插值称为 Hermite 插值。

设 $H_{2n+1}(x) = \sum_{i=0}^n h_i(x) f(x_i) + \sum_{i=0}^n g_i(x) f'(x_i)$ ，其中 $h_i(x_j) = \delta_{ij}, h_i'(x_j) = 0, g_i(x_j) = 0, g_i'(x_j) = \delta_{ij}$ ，可解出 h_i, g_i 。

$$R_n(x) = \frac{f^{(2n+2)}(\xi)}{(2n+2)!} \prod_{i=0}^n (x - x_i)^2, \xi \in (a, b), f \in C^{2n+2}[a, b]$$

定义序列 $z_{2i} = z_{2i+1} = x_i$ ，计算差商表时以 $f'(x_i)$ 代替 $f[z_{2i}, z_{2i+1}]$ ，得到差商型 Hermite 插值多项式：

$$H_{2n+1}(x) = f(z_0) + \sum_{k=1}^{2n+1} \left[f[z_0, \dots, z_k] \prod_{i=0}^{k-1} (x - z_i) \right]$$

7. Runge 现象：插值多项式在插值区间内发生剧烈震荡。

8. 分段线性插值

9. 三次样条插值

三次样条函数：分段三次多项式，整体二阶连续导数。具有局部性，且光滑。

给定 $\{x_i, f(x_i)\}_{i=0}^n$ ，若分段函数 $S(x)$ 满足插值条件、分段表示、二阶导数连续，则称 $S(x)$ 为三次样条插值函数， x_i 为样条结点。

确定 $S(x)$ 需要 $4n$ 个条件，插值条件提供 $n+1$ ，二阶连续提供 $3n-3$ ，边界给出 2 个。

7 最小二乘拟合

给定数据序列 $\{x_i, y_i\}_{i=0}^m$ 和函数空间 $\Phi = \text{span}\{\varphi_1(x), \dots, \varphi_n(x)\}$ ，求解 $\min_{\varphi \in \Phi} \sum_{i=1}^m (\varphi(x_i) - y_i)^2$ 。

记 $Q(a_1, \dots, a_n) = \sum_{i=1}^m (\sum_{j=1}^n a_j \varphi_j(x_i) - y_i)^2$ ，问题写作 $\min_{a_1, \dots, a_n} Q(a_1, \dots, a_n)$ 。

$Q(x) = \|Ax - b\|_2^2$ ，其中 $A_{ij} = \varphi_j(x_i)$, $x_j = a_j$, $b_j = y_j$ ，则 $\min_x Q(x)$ 的条件是 $A^T Ax = A^T b$ 。

对于非线性函数空间，通过变换线性化，利用线性拟合求解。需要注意，变换后的拟合函数不再是平方误差极小意义下的拟合函数。

8 函数逼近

一、最佳平方逼近

1. 在 $L^2_\rho[a, b]$ 中，定义内积 $(f, g) = \int_a^b f(x)g(x)\rho(x)dx$ 。

2. 内积空间中，有限维子空间 M 中有且只有一个最佳逼近元。

3. 若 $M = \text{span}\{\varphi_1(x), \dots, \varphi_n(x)\}$ ， $m^* = \sum_{i=1}^n c_i^* \varphi_i$ ，于是有法方程组 $\sum_{i=1}^n c_i^* (\varphi_i, \varphi_j) = (x, \varphi_j)$ ，记 $G_{ij} = (\varphi_i, \varphi_j)$, $b_j = (x, \varphi_j)$ ，于是写作 $Gc^* = b$ 。若 $\varphi_1(x), \dots, \varphi_n(x)$ 构成正交基，则 G 对角， $m^* = \sum_{i=1}^n \frac{(x, \varphi_i)}{(\varphi_i, \varphi_i)} \varphi_i$ ，称为 x 的广义 Fourier 展开。

4. 记 $\mathbb{P}_n[x]$ 为次数不超过 n 的多项式构成的空间。对于任意 $f \in L^2_\rho[a, b]$ ，存在唯一的 n 次多项式 $p(x) = \sum_{i=0}^n c_i x^i$ 使得 $\|f - p\|$ 取到最小值，即最佳平方逼近多项式。法方程 $\sum_{i=1}^n c_i^* (x^i, x^j) = (f, x^j)$ 。

5. 设 $\rho(x) \equiv 1$ ，区间 $[-1, 1]$ 上 $\mathbb{P}_n[x]$ 的正交基 $\{P_k(x)\}_{k=0}^n$ ，称 $P_k(x)$ 为勒让德多

项式, $P_k(x) = \frac{1}{2^k k!} \frac{d^k}{dx^k} [(x^2 - 1)^k]$ 。

6. 对于任意周期函数 $f \in L^2[0, T)$, 存在唯一的最佳逼近元 $f_n(x) = a_0 + \sum_{k=1}^n (a_k \cos k\omega x + b_k \sin k\omega x)$ 。

7. 离散傅里叶正变换写作 $\mathbf{g} = F_n \mathbf{f}$, $(F_n)_{ij} = \frac{1}{n} \rho^{(i-1)(j-1)}$, $\rho = e^{-i2\pi/n}$, 逆变换写作 $\mathbf{f} = F_n^{-1} \mathbf{g}$, $(F_n^{-1})_{ij} = \rho^{-(i-1)(j-1)}$ 。

二、最佳一致逼近多项式

1. 在函数空间 $C[a, b]$, 定义一致范数 $\|f\|_\infty = \max_{x \in [a, b]} |f(x)|$, 逼近集合 M 取 $n+1$ 维多项式空间 $\mathbb{P}_n[x]$ 。对于任意的 $f \in C[a, b]$, 若存在 $p^* \in \mathbb{P}_n[x]$ 使得 $\|f - p^*\|_\infty = \inf_{p \in \mathbb{P}_n[x]} \|f - p\|_\infty \triangleq d(f, \mathbb{P}_n[x])$, 则称 p^* 为 f 的最佳一致逼近多项式。

2. 考虑误差函数 $e^*(x) = f(x) - p^*(x)$, 定义 $e^*(x)$ 的极值点集, 即 $\mathcal{L}_M = \{x \in [a, b] \mid |e^*(x)| = \|e^*\|_\infty\}$, p^* 是 f 的最佳一致逼近多项式的充要条件是不存在多项式 p 使得 $[f(x) - p^*(x)]p(x) > 0, x \in \mathcal{L}_M$ 。

设 $g \in C[a, b]$, 则称点集 $\{x_i\}_{i=0}^k$ 为 g 的交错点组, 如果 $g(x_i) = (-1)^i \sigma \|g\|_\infty$ 。

设函数 $f \in C[a, b]$ 且 $f \notin \mathbb{P}_n[x]$, 则 p^* 是 f 的 n 次最佳一致逼近多项式的充分必要条件是 $f - p^*$ 在 $[a, b]$ 存在 $n+2$ 个点组成的交错点组。即, 误差函数在交错点取极值, 全区间极值相等且正负交错。

设 p^* 是 f 的 n 次最佳一致逼近多项式, 如果 f 在区间 $[a, b]$ 上有 $n+1$ 阶导数, 且 $f^{(n+1)}$ 在 $[a, b]$ 不变号, 则 $f - p^*$ 的交错点组有且仅有 $n+2$ 个交错点, 且区间 $[a, b]$ 的端点属于交错点组。

3. 切比雪夫多项式 $T_k(x)$ 是区间 $[-1, 1]$ 的多项式空间 $\mathbb{P}_n[x]$ 关于权函数 $\frac{1}{\sqrt{1-x^2}}$ 的一组正交基, 即 $T_k(x) = \cos(k \arccos x)$, $\int_{-1}^1 \frac{T_m(x) T_n(x)}{\sqrt{1-x^2}} dx = \begin{cases} 0, & m \neq n \\ \pi/2, & m = n \neq 0 \\ \pi, & m = n = 0 \end{cases}$, 递

推公式 $\begin{cases} T_{k+1} = 2xT_k - T_{k-1}, & T_k \text{ 有 } k \text{ 个根, 且有 } k+1 \text{ 个极值点.} \\ T_0 = 1, T_1 = x \end{cases}$

4. 求 $\|x^n - p_{n-1}^*\| = \min_{p_{n-1} \in \mathbb{P}_{n-1}[x]} \|x^n - p_{n-1}\|$, 记 $\mathbb{P}_n^1[x]$ 为首系数为 1 的 n 次多项式全体, 前述问题等价于 $\|p_n^* - 0\| = \min_{p_n \in \mathbb{P}_n^1[x]} \|p_n - 0\|$, 称为最小零偏差问题。

对于任意的 $p_n \in \mathbb{P}_n^1[x]$, 有 $\|p_n\| \geq \|\frac{1}{2^{n-1}}T_n(x)\| = \frac{1}{2^{n-1}}$, 当且仅当 $p_n(x) = \frac{1}{2^{n-1}}T_n(x)$ 时等号成立。

设函数 $f(x) \in C^{n+1}[-1, 1]$, 若取 $n+1$ 个互不相同的节点构造 n 次插值多项式 q_n , 则有 $\|f - q_n\| \leq \frac{\|f^{(n+1)}\|}{(n+1)!} \max_x |(x-x_0)\cdots(x-x_n)|$, 寻找节点使插值余项尽可能小的问题等价于寻找 $p_{n+1} \in \mathbb{P}_{n+1}^1[x]$ 使之零偏差最小。当节点取 T_{n+1} 的零点时, 余项最小。其他插值区间可以利用仿射变换。

对于任意 $f(x) \in C[-1, 1]$, 取权函数 $\frac{1}{\sqrt{1-x^2}}$, 按照 $L^2_\rho[-1, 1]$ 内积构造 n 次最佳平方逼近多项式 $S_n(x) = \frac{c_0}{2}T_0 + \sum_{i=1}^n c_i T_i, c_i = \frac{2}{\pi} \langle f, T_i \rangle$ 。如果 $f(x) \in C^1[-1, 1]$, 那么 $S_n(x)$ 一致收敛于 $f(x)$ 。如果 $f(x) \in C^r[-1, 1]$, 那么 $|c_i| \leq \frac{c(f,r)}{i^r}$, 对于足够光滑的函数 f , c_i 迅速趋于零, $f(x) - S_n(x) \approx c_{n+1}T_{n+1}$, $S_n(x)$ 相似于最佳一致逼近多项式。

多项式低次逼近问题, 将多项式写成切比雪夫多项式级数的形式, 取前 m 项, 将之写成幂级数形式。

9 数值微分和数值积分

一、数值微分

1. 导数逼近

- 向前差商

$$f'(x_0) \approx \frac{f(x_0+h) - f(x_0)}{h}$$

$$R(x) = f'(x_0) - \frac{f(x_0+h) - f(x_0)}{h} = -\frac{h}{2}f''(\xi)$$

- 向后差商

$$f'(x_0) \approx \frac{f(x_0) - f(x_0 - h)}{h}$$

$$R(x) = f'(x_0) - \frac{f(x_0) - f(x_0 - h)}{h} = \frac{h}{2} f''(\xi)$$

- 中心差商

$$f'(x_0) \approx \frac{f(x_0 + h) - f(x_0 - h)}{2h}$$

$$R(x) = f'(x_0) - \frac{f(x_0 + h) - f(x_0 - h)}{2h} = -\frac{h^2}{3!} f^{(3)}(\xi)$$

- 理论估计: $h = \sqrt[3]{\frac{3e}{M_3}}$

- 事后估计: 当 $|D(h, x) - D(h/2, x)| < \epsilon$ 时, h 即为适当的步长。

2. 数值微分: 对于给定 $f(x)$ 的函数表, 建立插值函数, 用插值函数的导数近似函数 $f(x)$ 的导数。

$$R(x_j) = \frac{f^{(n+1)}(\xi)}{(n+1)!} \prod_{0 \leq i \neq j \leq n} (x_j - x_i)$$

二、数值积分

1. 代数精度

设 $[a, b]$ 上以 x_i 为积分节点的数值积分公式为 $I_n(f) = \sum_{i=0}^n \alpha_i f(x_i)$, 若 $I_n(f)$ 满足 $I_n(x^i) = I(x^i), i = 0, \dots, k, I_n(x^{k+1}) \neq I(x^{k+1})$, 则称 $I_n(f)$ 具有 k 阶代数精度。

2. 插值型数值积分

利用插值函数代替被积函数进行积分。

$$I_n(f) = \sum_{i=0}^n \alpha_i f(x_i), \alpha_i = \int_a^b l_i(x) dx$$

$$E_n(f) = \int_a^b \frac{f^{(n+1)}(\xi)}{(n+1)!} \omega_n(x) dx$$

n 次插值多项式形式的数值积分公式至少有 n 阶代数精度。

3. Newton-Cotes 积分

取步长 $h = \frac{b-a}{n}$, $x_i = a + ih$, 有 $\alpha_i = (b-a)C_i^{(n)}$, $\sum_{i=0}^n C_i^{(n)} = 1$ 。

取 $n = 1$, 梯形积分, 具有一阶代数精度:

$$T(f) = \frac{b-a}{2}[f(a) + f(b)]$$

$$E_1(f) = -\frac{(b-a)^3}{12}f''(\xi)$$

取 $n = 2$, Simpson 积分, 具有三阶代数精度:

$$S(f) = (b-a)\left[\frac{1}{6}f(a) + \frac{4}{6}f\left(\frac{a+b}{2}\right) + \frac{1}{6}f(b)\right]$$

$$E_1(f) = -\frac{(b-a)^5}{2880}f^{(4)}(\xi)$$

n 为奇数时, $f \in C^{n+1}[a, b]$, $E_n(f) = \frac{f^{(n+1)}(\xi)}{(n+1)!} \int_a^b (x-x_0)\cdots(x-x_n)dx$, 有 n 阶代数精度; n 为偶数时, $f \in C^{n+2}[a, b]$, $E_n(f) = \frac{f^{(n+2)}(\xi)}{(n+2)!} \int_a^b x(x-x_0)\cdots(x-x_n)dx$, 有 $n+1$ 阶代数精度。

若数值积分公式满足 $\lim_{h \rightarrow 0} \frac{R[f]}{h^p} = C < \infty, C \neq 0$, 则称该公式 p 阶收敛。

外推算法, Romberg 积分计算公式: $R_{k,j} = R_{k,j-1} + \frac{R_{k,j-1} - R_{k-1,j-1}}{4^{j-1} - 1} + O(h^{2j})$, 它是 $2^{k-1}n$ 个小区间, 每区间插值次数为 j 的公式。

4. Gauss 积分

设 $I(f)$ 关于积分节点 x_1, \dots, x_n 的数值积分公式为 $I_n(f) = \sum_{i=1}^n a_i f(x_i)$, 则 $I_n(f)$ 的代数精度不超过 $2n - 1$ 阶。

取 n 次正交多项式的 n 个零点为积分节点的数值积分公式具有 $2n-1$ 阶代数精度。

$$G_n(f) = \sum_{i=1}^n a_i f(x_i), a_i = \int_a^b l_i(x)W(x)dx$$

$$E_n(f) = \frac{f^{(2n)}(\xi)}{(2n)!} \int_a^b \omega^2(x)W(x)dx$$

1.常微分方程初值问题

$$\begin{cases} y' = f(x, y), x \in [a, b] \\ y(a) = y_0 \end{cases}$$

若 $f(x, y)$ 在条带连续, 且 $|f(x, y_1) - f(x, y_2)| \leq L|y_1 - y_2|$, 则初值问题解在 $[a, b]$ 上存在且唯一。

2.Euler 公式

对定义域 $[a, b]$ 作等距剖分, 即 $x_i = a + ih, h = \frac{b-a}{n}$ 。

在假设第 i 步计算精确前提下, 考虑截断误差 $T_{i+1} = y(x_{i+1}) - y_{i+1}$, 称为局部截断误差, 如果 $T_{i+1} = O(h^{p+1})$, 则称方法 p 阶相容。整体截断误差需要累计计算。

• 向前差商公式: $y_{i+1} = y_i + hf(x_i, y_i)$, $T_{i+1} = \frac{h^2}{2}y''(\xi) = O(h^2)$, 整体截断误差 $O(h)$, 是1阶方法。

• 向后差商公式: $y_{i+1} = y_i + hf(x_{i+1}, y_{i+1})$, 需要迭代求解。Picard 迭代格式:

$$\begin{cases} y_{i+1}^{(0)} = y_i + hf(x_i, y_i) \\ y_{i+1}^{(k+1)} = y_i + hf(x_{i+1}, y_{i+1}^{(k)}) \end{cases}$$

• 中心差商公式: $y_{i+1} = y_{i-1} + 2hf(x_i, y_i)$, 二阶格式, 数值不稳定。

• 基于数值积分的近似公式, 单边近似对应向前、向后差商, 若取梯形积分近似, 则有 $y_{i+1} = y_i + \frac{h}{2}[f(x_i, y_i) + f(x_{i+1}, y_{i+1})]$, 预估 - 校正公式:

$$\begin{cases} \bar{y}_{i+1} = y_i + hf(x_i, y_i) \\ y_{i+1} = y_i + \frac{h}{2}[f(x_i, y_i) + f(x_{i+1}, \bar{y}_{i+1})] \end{cases}$$

3.Runge-Kutta 方法

$$y_{i+1} = y_i + hy'(x_i) + \dots + \frac{h^k}{k!}y^{(k)}(x_i) + \frac{h^{k+1}}{(k+1)!}y^{(k+1)}(\xi)$$

以 $\sum_{j=1}^k c_j k_j$ 逼近 $y'(x_i) + \dots + \frac{h^{k-1}}{k!} y^{(k)}(x_i)$, 其中 $k_1 = f(x_i, y_i), k_j = f(x_i + a_j h, y_i + h \sum_{l=1}^{j-1} b_{jl} k_l), a_j = \sum_{l=1}^{j-1} b_{jl}$, 它是 k 阶方法。

4. 线性多步法

$$y(x_{i+1}) = y(x_{i-p}) + \int_{x_{i-p}}^{x_{i+1}} y'(x) dx$$

显式格式: 以 x_i, \dots, x_{i-q} 构造插值多项式近似 $y'(x)$; 隐式格式: 以 $x_{i+1}, \dots, x_{i+1-q}$ 构造插值多项式近似 $y'(x)$ 。 p 控制积分区间, q 控制插值节点。

$p = 0$ 称为 Adams 格式。 (p, q) 的隐式格式使用 $(p-1, q)$ 显示预估后进行校正。

5. 常微分方程组的数值解法

一阶常微分方程组写成向量形式:

$$\begin{cases} \frac{dY}{dx} = F(x, Y(x)), x \in [a, b] \\ Y(a) = Y_0 \end{cases}$$

高阶微分方程:

$$\begin{cases} \frac{d^m y}{dx^m} = f(x, y, y', \dots, y^{(m-1)}), x \in [a, b] \\ y^{(m-1)}(a) = \eta_m \end{cases}$$

引入辅助变量 $\begin{cases} y_1 = y \\ \vdots \\ y_m = y^{(m-1)} \end{cases}$, 问题转化为一阶常微分方程组问题。

6. 若一个离散变量的 k 步方法, 在 Lipschitz 条件下, 存在常数 C 和 $h_0 > 0$, 使得以 $(0, h_0]$ 中任意值 h 为步长, 通过任意两组初值得到的离散值的差 (差为各分量差的最大值), 与初值差可比较, 则该方法稳定。

取经典微分方程 $\begin{cases} y' = \lambda y, \operatorname{Re}(\lambda) < 0 \\ y(a) = y_0 \end{cases}$, 将一般数值格式代入, 对于给定的初始误差, 误差方程具有同样的格式。

若对任意的初值, 总存在左半复平面上的一个区域, 当在这个区域时, 差分方程的解趋于 $0 (x \rightarrow \infty)$, 这个区域称为稳定区域, 差分方程称为绝对稳定的。

当绝对稳定区域时左半平面时，称该方法是无条件绝对稳定的。一般隐式比显示好。

11 最优化方法

一、线性规划问题

$$\begin{aligned} \max z &= \sum_{i=1}^n c_i x_i \\ \text{s. t. } &\begin{cases} \sum_{j=1}^n a_{ij} x_j = b_i \geq 0 \\ x_j \geq 0 \end{cases} \end{aligned}$$

设 $A = (a_{ij})_{m \times n}$ 为等式约束的系数矩阵，其中 $m < n, \text{rank}(A) = m$ 。若 $B = (\mathbf{p}_1, \dots, \mathbf{p}_m)$ 是 A 的一个满秩子矩阵，则称 B 是线性规划问题的一组基，每个列向量 \mathbf{p}_j 称为基向量，与之对应的变量 x_j 称为基变量，除基变量外的变量称为非基变量。

若令所有非基变量置零，则 m 个基变量有唯一解 \mathbf{x}_B ，加上取零的非基变量，即 \mathbf{x} ，称为线性规划问题的基解。基解总数不超过 $\binom{n}{m}$ 。

满足非负约束的基解为基可行解，与之对应的基称为可行基。

$c_j \rightarrow$			c_1	...	c_m	...	c_j	...	c_n
\mathbf{c}_B	\mathbf{x}_B	\mathbf{b}	x_1	...	x_m	...	x_j	...	x_n
c_1	x_1	b_1	1	...	0	...	a_{1j}	...	a_{1n}
c_2	x_2	b_2	0	...	0	...	a_{2j}	...	a_{2n}
\vdots	\vdots	\vdots	\vdots		\vdots		\vdots		\vdots
c_m	x_m	b_m	0	...	1	...	a_{mj}	...	a_{mn}
$\sigma_j \rightarrow$			0	...	0	...	$c_j - \sum_{i=1}^m c_i a_{ij}$...	$c_n - \sum_{i=1}^m c_i a_{in}$

(1) 确定初始可行基和初始基可行解，建立单纯形表

(2) 计算各非基变量 x_k 的检验指标 $\sigma_k = c_k - \sum_{i=1}^m c_i a_{ik}$, $k = m + 1, \dots, n$ 。若 $\sigma_k \leq 0$ 对所有 $k = m + 1, \dots, n$ 成立, 则得到了最优解。

(3) 在 $\sigma_k > 0$ 中, 若有某个 σ_j 对应的 x_j 的系数向量 $\mathbf{p}_j \leq 0$, 则有无界解。

(4) 根据 $\max\{\sigma_k\} = \sigma_j$, 确定 x_j 为换入变量, 按公式 $\lambda = \min_i \left\{ \frac{x_i^0}{a_{ij}} \mid a_{ij} > 0 \right\} = \frac{x_l^0}{a_{lj}}$ 确定 x_l 为换出变量。

(5) 以 a_{lj} 为主变量, 对等式约束的增广矩阵进行初等行变换, 将变量 x_j 对应的列向量变换为 $a_{lj} = 1$, 其余为0。将 \mathbf{x}_B 列中的 x_l 换为 x_j , 建立新的单纯形表。

添加人工变量, 总能得到一个子单位矩阵。为使得最优解中人工变量为零, 在目标函数中令人工变量的系数为任意大的负值 $-M$, 称为罚因子, 称为大 M 法。或者在第一阶段令目标函数中其他变量系数为零, 人工变量系数为1, 保持约束求极小化时的解, 若极小值为0, 作为原线性规划问题的初始可行解, 将第一阶段最终形式删除人工列, 更新目标函数系数, 若不为0, 无解。

确定换入换出变量时, 均以下标小者优先。

若求解结果出现所有 $\sigma_k \leq 0$, 但基变量中仍有非零人工变量, 则无解。

二、非线性优化问题

$$\min f(\mathbf{x})$$

1. 下降迭代算法

选定初始点 \mathbf{x}_0 , 令 $k \leftarrow 0$; 确定搜索方向 \mathbf{p}_k , 要求 $\mathbf{p}_k^T \nabla f(\mathbf{x}_k) < 0$; 求步长 λ_k , 产生 $\mathbf{x}_{k+1} = \mathbf{x}_k + \lambda_k \mathbf{p}_k$; 检查是否为极小点或近似极小点。

确定 λ_k 可以取常数(不能保证下降)、取可接受点(任意下降点), 或者使下降最多, 即解决子优化问题 $\min_{\lambda} f(\mathbf{x}_k + \lambda \mathbf{p}_k)$, 称为最优一维搜索或精确一维搜索, 称 λ_k 为最佳步长。

$$\text{若} \begin{cases} \lambda_k = \arg \min_{\lambda} f(\mathbf{x}_k + \lambda \mathbf{p}_k) \\ \mathbf{x}_{k+1} = \mathbf{x}_k + \lambda_k \mathbf{p}_k \end{cases}, \text{ 则有 } \nabla f^T(\mathbf{x}_{k+1}) \mathbf{p}_k = 0$$

设序列 $\{\mathbf{x}_k\}_{k=0}^{\infty}$ 收敛于 \mathbf{x}^* , 若存在常数 $c > 0, \alpha \geq 1$ 及整数 $k_0 > 0$, 使得当 $k > k_0$ 时, 有 $\|\mathbf{x}_{k+1} - \mathbf{x}^*\| \leq c \|\mathbf{x}_k - \mathbf{x}^*\|^\alpha$ 成立, 则称 $\{\mathbf{x}_k\}_{k=0}^{\infty}$ 收敛阶为 α 。当 $\alpha = 2$, 称为二阶收敛, $1 < \alpha < 2$, 称为超线性收敛, $\alpha = 1$, 称为线性收敛。

2. 最速下降法 (至少线性)

$$f(\mathbf{x}_k - \lambda_k \nabla f(\mathbf{x}_k)) = \min_{\lambda \geq 0} f(\mathbf{x}_k - \lambda \nabla f(\mathbf{x}_k))$$

3. 牛顿迭代法 (二阶)

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\nabla^2 f(\mathbf{x}_k)]^{-1} \nabla f(\mathbf{x}_k)$$

4. 带步长因子的牛顿法:

$$f(\mathbf{x}_k - \lambda_k \nabla f(\mathbf{x}_k)) = \min_{\lambda \geq 0} f(\mathbf{x}_k - \lambda [\nabla^2 f(\mathbf{x}_k)]^{-1} \nabla f(\mathbf{x}_k))$$

5. 拟牛顿法:

$$f(\mathbf{x}_k + \lambda_k \mathbf{p}_k) = \min_{\lambda \geq 0} f(\mathbf{x}_k - \lambda H_k \nabla f(\mathbf{x}_k))$$

$$\text{DFP 矫正矩阵: } H_{k+1} = H_k + \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{s}_k^T \mathbf{y}_k} - \frac{H_k \mathbf{y}_k \mathbf{y}_k^T H_k}{\mathbf{y}_k^T H_k \mathbf{y}_k}$$

$$\text{BFGS 校正公式: } H_{k+1} = H_k + \left(1 + \frac{\mathbf{y}_k^T H_k \mathbf{y}_k}{\mathbf{s}_k^T \mathbf{y}_k}\right) \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{s}_k^T \mathbf{y}_k} - \frac{\mathbf{s}_k \mathbf{y}_k^T - H_k \mathbf{y}_k \mathbf{s}_k^T}{\mathbf{s}_k^T \mathbf{y}_k}$$

6. 共轭梯度法

$$f(\mathbf{x}_k + \lambda_k \mathbf{p}_k) = \min_{\lambda \geq 0} f(\mathbf{x}_k + \lambda \mathbf{p}_k)$$

$$\mathbf{p}_k = -\mathbf{g}_k + \beta_{k-1} \mathbf{p}_{k-1}, \beta_{k-1} = \frac{\mathbf{g}_k^T \mathbf{g}_k}{\mathbf{p}_{k-1}^T \mathbf{g}_k}$$