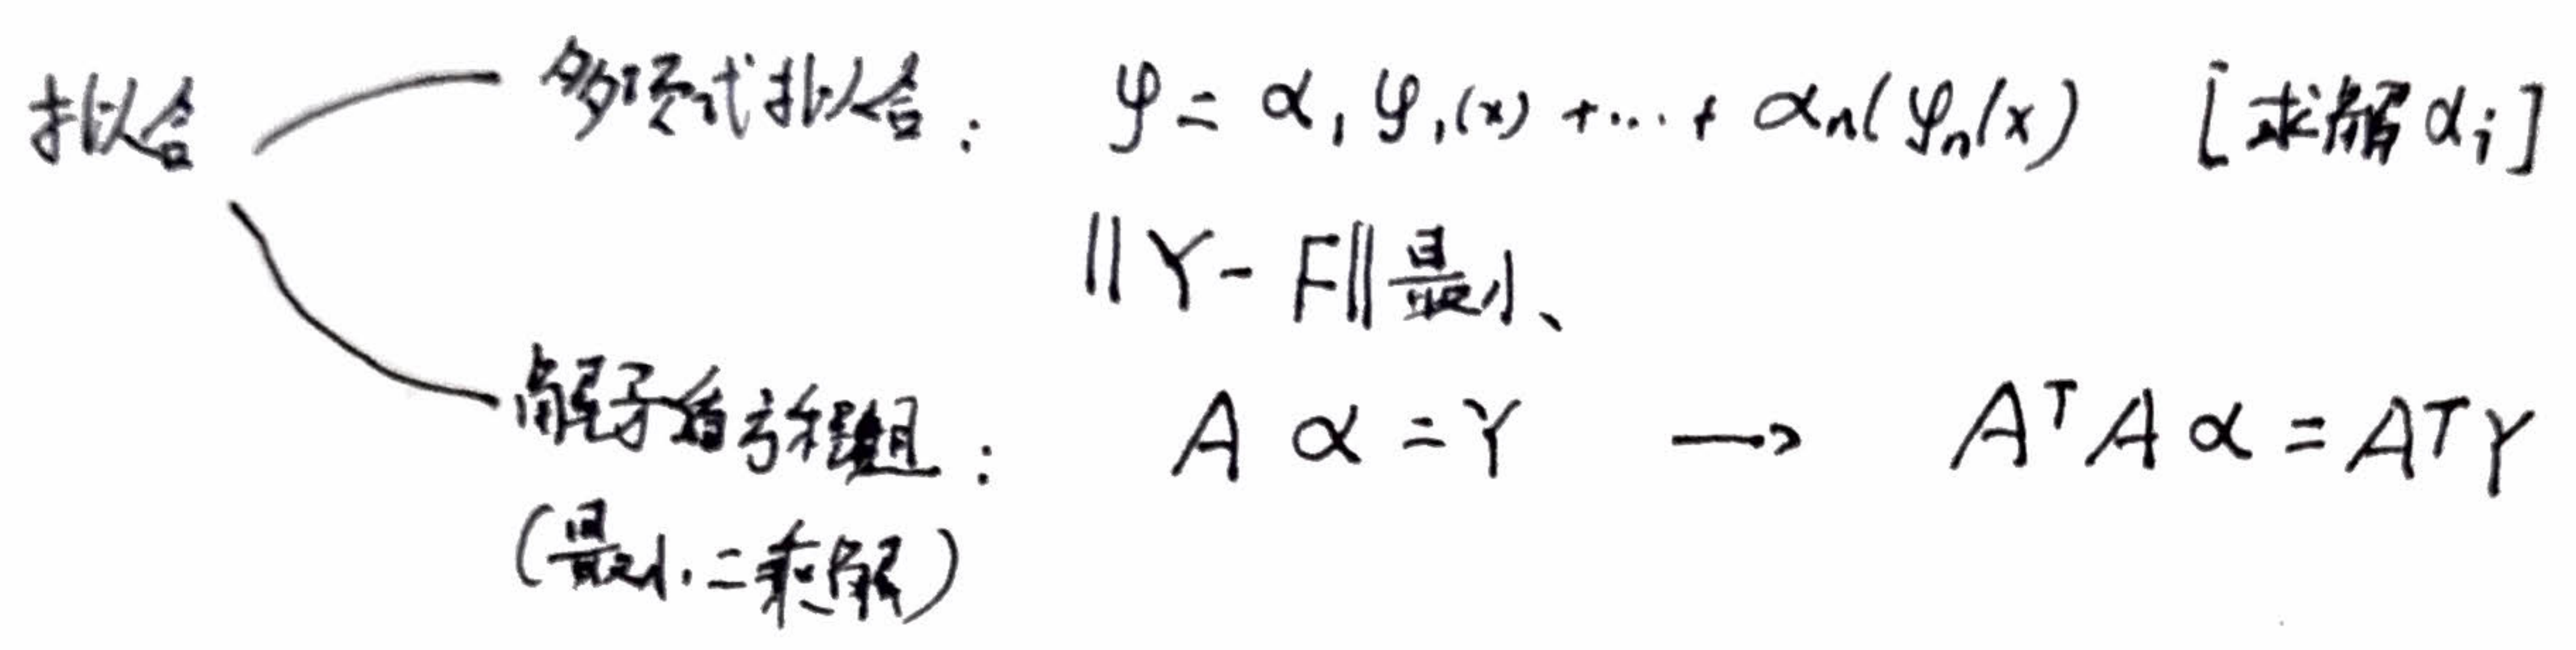
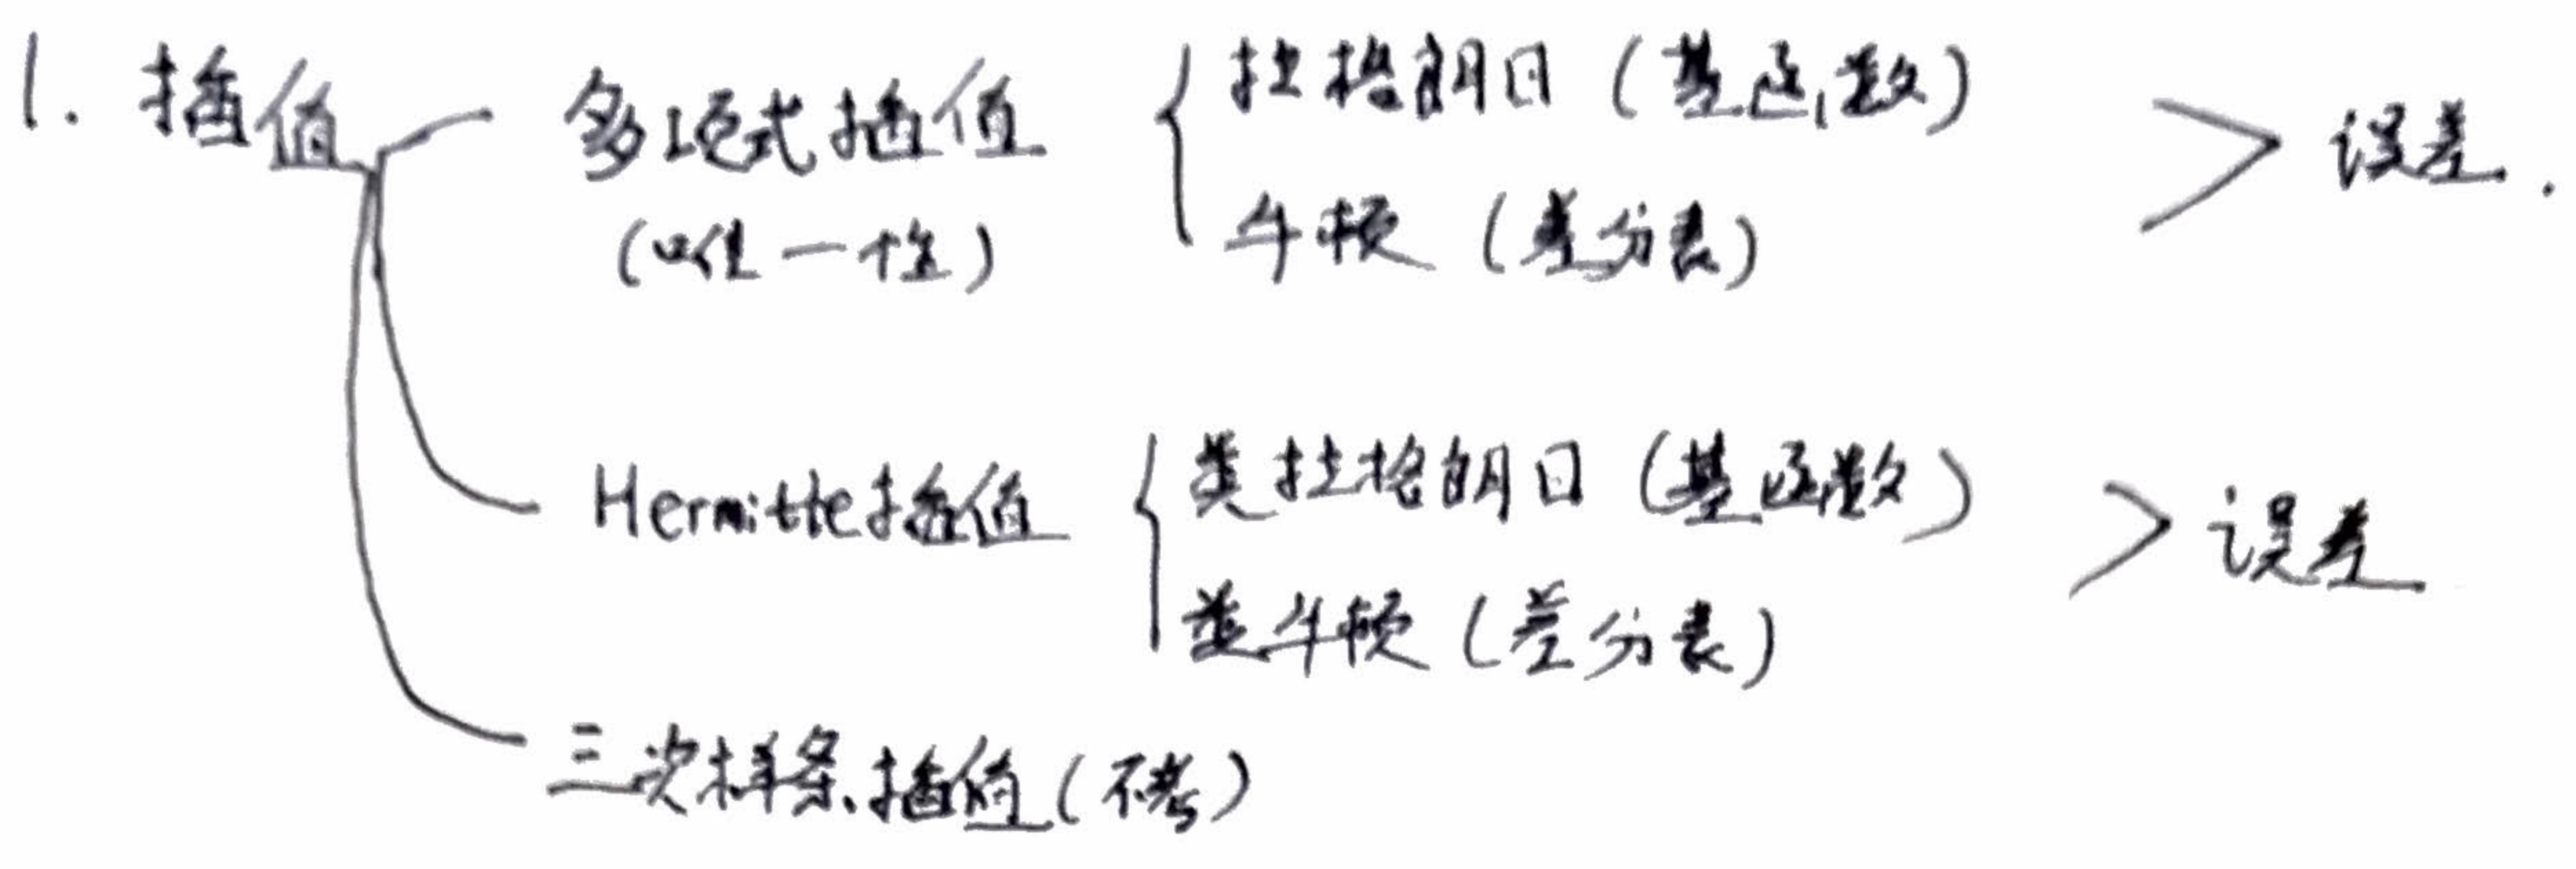
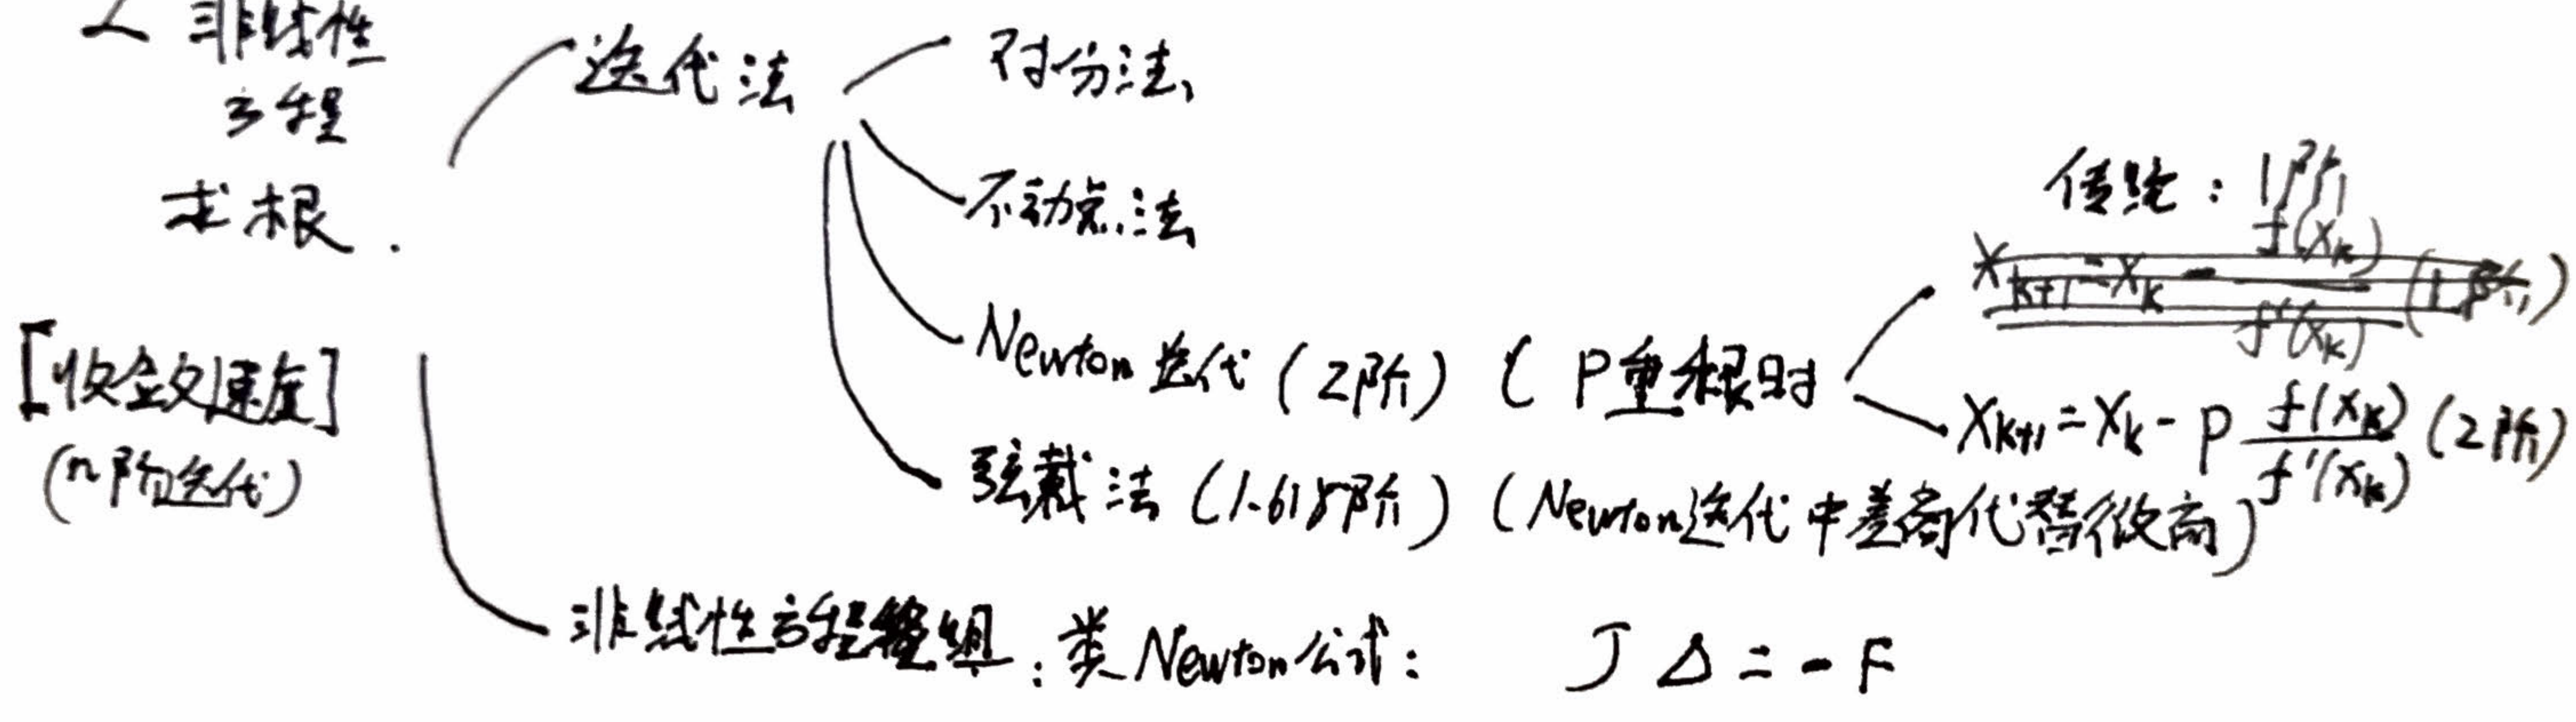


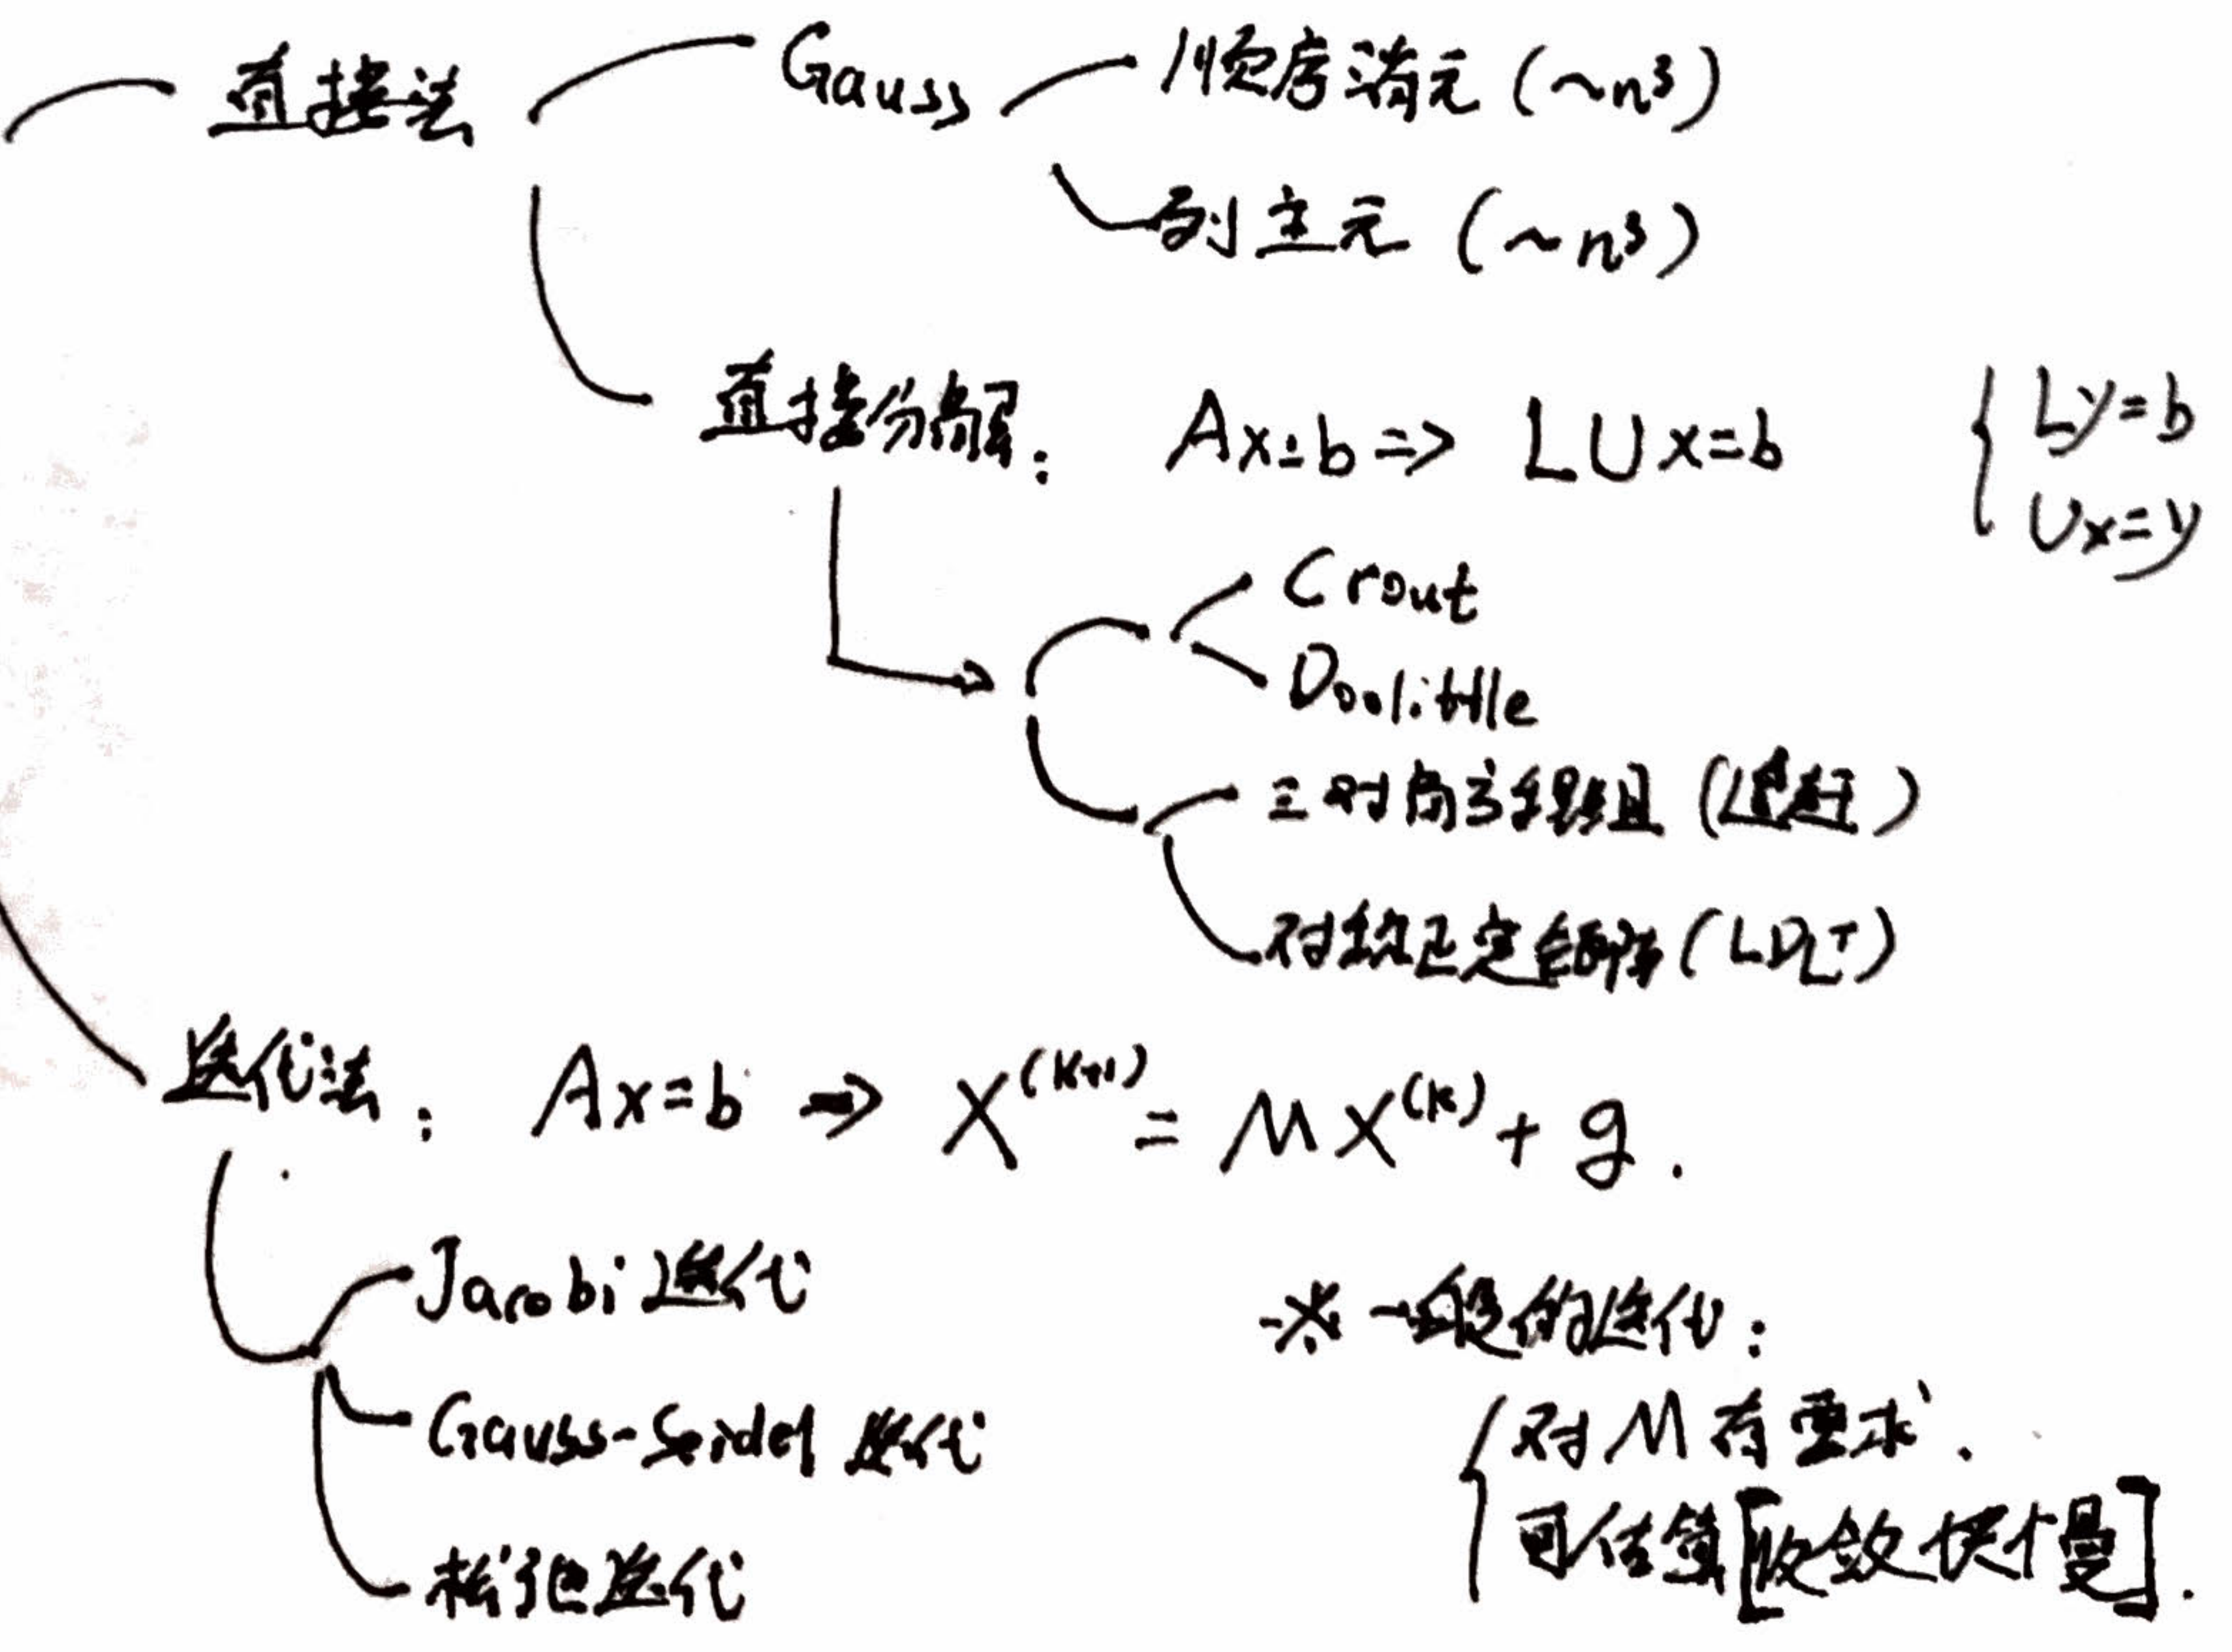
# 计算方法


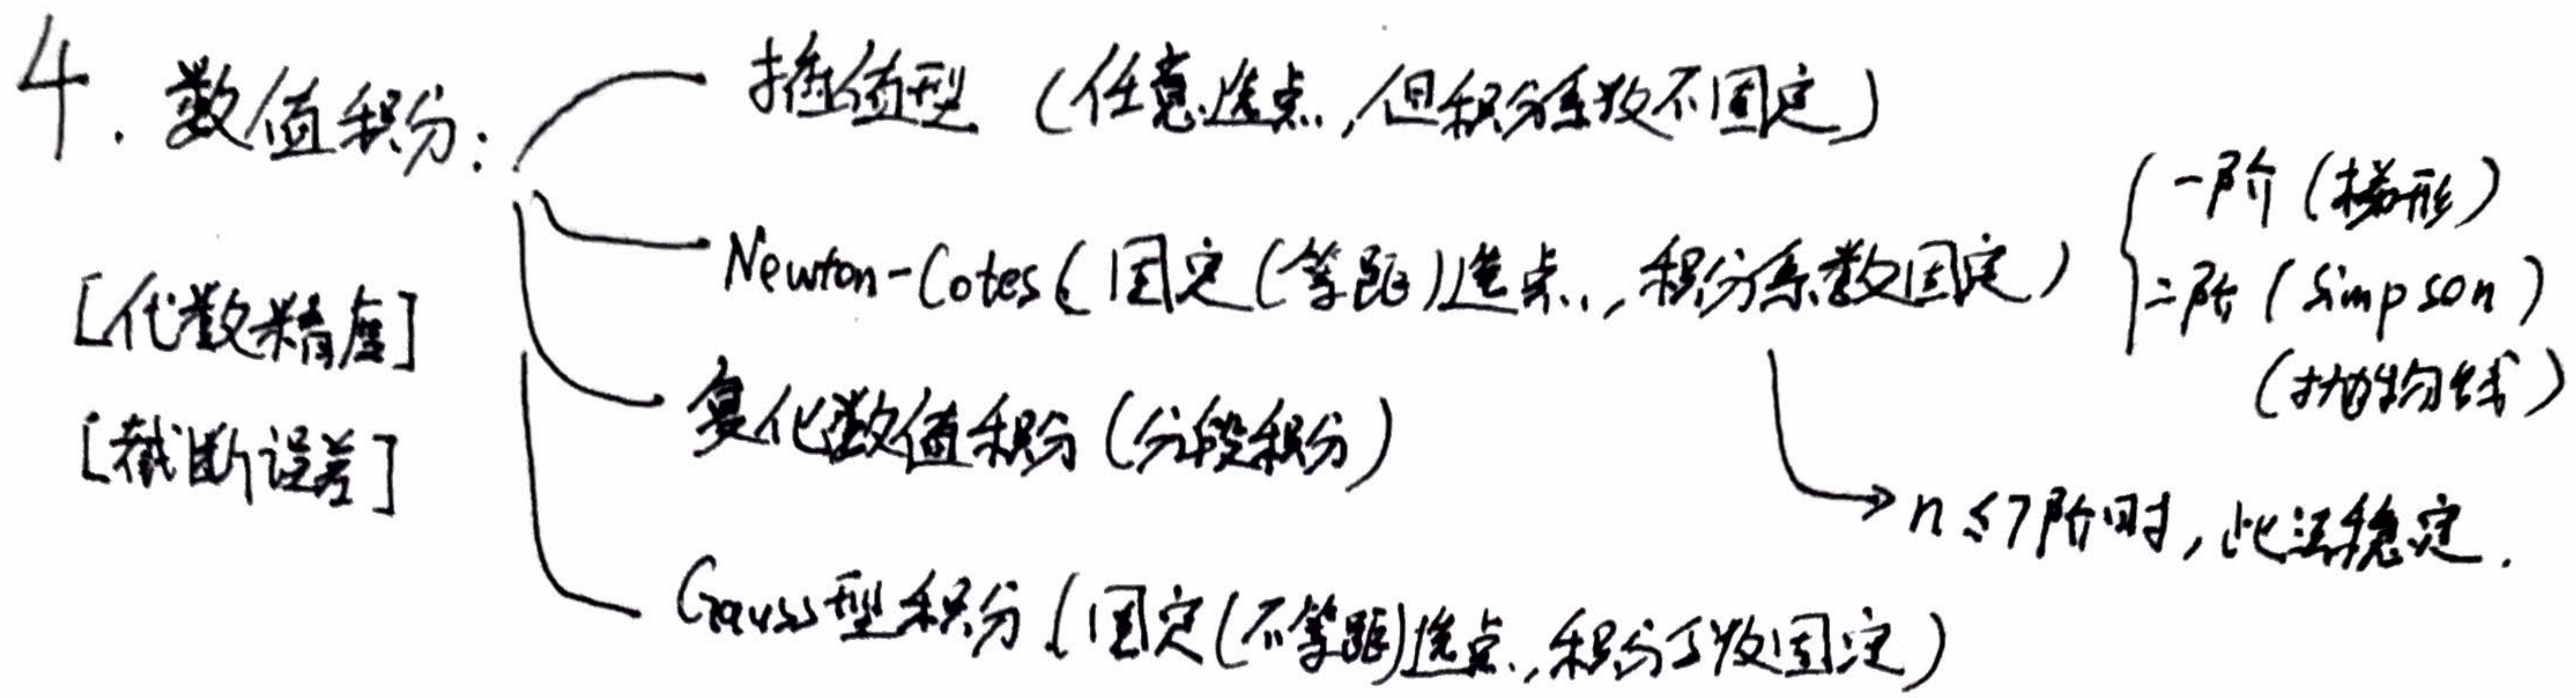


## 2. 非线性方程求根



## 3. 线性方程组求解





5. 常微分方程.

# 基础知识

## 1. 误差

误差  $\begin{cases} \text{绝对} \\ \text{相对} \end{cases}$

产生原因  $\begin{cases} \text{原始误差 (模型误差和数据误差)} \\ \text{截断误差} \\ \text{舍入误差} \end{cases}$

## 2. 有效位数

① 对于未标明误差的数：认为这是经四舍五入得到的，则正常地按位数即可。

② 对于标明误差的数：按定义 例如  $5.12 \pm 0.1$ ：有效位数为 2  
(见第三版 P3)  $5.12 \pm 0.7$ ：有效位数为 1

## 3. 范数

### (1) 向量范数

定义： $\|X\|$   $\begin{cases} \text{非负性: } \|X\| \geq 0 \text{ (当且仅当 } X=0 \text{ 时取等)} \\ \text{齐次性: } \|\alpha X\| = |\alpha| \|X\| \\ \text{三角不等式: } \|X+Y\| \leq \|X\| + \|Y\| \end{cases}$

1-范数:  $\|X\|_1 = \sum |x_i| = |x_1| + \dots + |x_n|$

2-范数:  $\|X\|_2 = \sqrt{\sum |x_i|^2} = \sqrt{x_1^2 + \dots + x_n^2}$

$\infty$ -范数:  $\|X\|_\infty = \sqrt[\infty]{\sum |x_i|^\infty} = \max\{|x_1|, \dots, |x_n|\}$

\*  $1 \leq \frac{\|X\|_1}{\|X\|_\infty} \leq n$        $1 \leq \frac{\|X\|_2}{\|X\|_\infty} \leq \sqrt{n}$

$1 \leq \frac{\|X\|}{\|X\|_\infty} \leq \sqrt{n}$

## (2) 矩阵范数

定义:  $\|A\|$  的性质:

- 非负性  $\|A\| \geq 0$  (且仅当  $A=0$  时取等)
- 齐次性  $\|\lambda A\| = |\lambda| \|A\|$
- 三角不等式  $\|A+B\| \leq \|A\| + \|B\|$

$$\|A\|_1 = \max_{1 \leq j \leq n} \left\{ \sum_{i=1}^n |a_{ij}| \right\} \quad \text{列和取最大}$$

$$\|A\|_2 = \sqrt{\max \{ |\lambda_i| \}} \quad (\lambda_i \text{ 是 } A^T A \text{ 的特征值})$$

$$\|A\|_\infty = \max_{1 \leq i \leq n} \left\{ \sum_{j=1}^n |a_{ij}| \right\} \quad \text{行和取最大}$$

$$(\|A\|_F = \sqrt{\sum a_{ij}^2})$$

(- 列无穷行  
- 找特征值  
- 全是绝对值  
- 全是取最大)

\* 谱半径:  $\rho(A) = \max \{ |\lambda_i| \}$  ( $\|A\|_2 = \sqrt{\rho(A^T A)}$ )

\*  $|\lambda_i| \leq \|A\|$  ( $|\lambda| \|x\| = \|\lambda x\| = \|Ax\| \leq \|A\| \|x\|$ )

\*  $\rho(A) \leq \|A\|$

\*  $\rho(A) < 1 \iff \lim_{k \rightarrow \infty} A^k = 0$

## (3) 条件数:

定义:  $\text{Cond}_p(A) = \|A\|_p \|A^{-1}\|_p \geq \|AA^{-1}\| = 1$

① 由  $ASx = \delta b$  可得:  $\frac{\|\delta x\|}{\|x\|} \leq \text{Cond}(A) \frac{\|\delta b\|}{\|b\|}$

② 由  $(A+SA)(x+\delta x) = b$  可得:

$$\frac{\|\delta x\|}{\|x\|} \leq \frac{\text{Cond}(A) \frac{\|SA\|}{\|A\|}}{1 - \text{Cond}(A) \frac{\|SA\|}{\|A\|}}$$

\* 条件数越大, 表明解对  $A, b$  的敏感性越大, 误差越可能大.

# 插值

## 1. 多项式插值.

① 唯一性: 用待定系数法, 解出的系数唯一.

② 拉格朗日:  $L_n(x) = \sum l_i(x) \cdot f(x_i)$        $l_{ij}(x) = \frac{(x-x_0) \cdots (x-x_n)}{(x_i-x_0) \cdots (x_i-x_n)}$

③ 牛顿法:  $N(x) = \sum t_i(x) f[x_0, \dots, x_i]$   
 $= f(x_0) + (x-x_0) f[x_0, x_1] + (x-x_0)(x-x_1) f[x_0, x_1, x_2] + \dots$

④ 截断误差 (余项)  
 $R(x) = f[x, x_0, \dots, x_n] \cdot \prod (x-x_i)$   
 $= \frac{f^{(n+1)}(\xi)}{(n+1)!} \prod (x-x_i) \quad (\xi \in [x_0, x_n])$

## 2. Hermite 插值:

① 类拉格朗日: 设基函数  $h_i(x), g_i(x)$ , 均为  $N-1$  阶. 且

$h_1(x_1) = 1$	$h_2(x_2) = 0$	$h_1'(x_1) = 0$	$h_1'(x_2) = 0$
$h_2(x_1) = 0$	$h_2(x_2) = 1$	$h_2'(x_1) = 0$	$h_2'(x_2) = 0$
$g_1'(x_1) = 1$	$g_2'(x_2) = 0$	$g_1'(x_1) = 1$	$g_1'(x_2) = 0$
$g_2'(x_1) = 0$	$g_2'(x_2) = 1$	$g_2'(x_1) = 0$	$g_2'(x_2) = 1$

(  $h_1(x_1) = 1$  ;  $h_2(x_2) = 1$  ;  $g_1'(x_1) = 1$  ;  $g_2'(x_2) = 1$  )

② 类牛顿: 差分表.

③ 截断误差:  $R(x) = \frac{f^{(N)}(\xi)}{N!} \prod (x-x_i)$       (  $N$  为待定系数的个数 )  
(  $N-1$  为方程阶数 )

# 拟合

1. 多项式拟合:  $f = \alpha_1 \varphi_1(x) + \alpha_2 \varphi_2(x) + \dots + \alpha_n \varphi_n(x)$ .

$$\Rightarrow \alpha_1 \varphi_1(x_1) + \dots + \alpha_n \varphi_n(x_1) = \varphi(x_1)$$

$$\alpha_1 \varphi_1(x_2) + \dots + \alpha_n \varphi_n(x_2) = \varphi(x_2)$$

$\vdots$

$$\alpha_1 \varphi_1(x_m) + \dots + \alpha_n \varphi_n(x_m) = \varphi(x_m)$$

几个未知数.

$m$  个方程

$m \geq n$ .

$$\Rightarrow A \alpha = Y.$$

$$(m \times n) \quad (n \times 1) \quad (m \times 1)$$

2. 解方程组:

$$A \alpha = Y \quad \text{最小二乘解为: } A^T A \alpha = A^T Y$$

$$(n \times m) \quad (m \times n) \quad (n \times 1) \sim (n \times m) \quad (m \times 1)$$

$$\begin{matrix} \vee & | & \vee \\ (n \times n) & (n \times 1) & (n \times 1) \end{matrix}$$

# 非线性方程求根

\* 收敛速度: 设真实根为  $x^*$

$$\text{误差为 } e_k = |x_k - x^*|$$

$$\text{则若有 } \lim_{k \rightarrow \infty} \frac{|e_{k+1}|}{|e_k|^n} = M$$

则迭代格式收敛的阶为  $n$ . (详细内容见第三版 P6)

## 1. 迭代法:

① 对分法.

② 不动点法:  $x_{k+1} = \varphi(x_k)$

条件: 在  $[a, b]$  上,  $\varphi(a) > a$ ,  $\varphi(x) \leq L < 1$ ,  $\varphi(b) < b$

$$\text{误差: } e_k \leq \frac{L^k}{1-L} |x_1 - x_0|$$

[可证: 若  $\varphi(x^*) = \dots = \varphi^{(p-1)}(x^*) = 0$ ,  $\varphi^{(p)}(x^*) \neq 0$ , 则收敛阶为  $p$ ]

③ Newton法:

$$x_{k+1} = -\frac{f(x_k)}{f'(x_k)} \quad (2\text{阶})$$

↓ 差分代替微分:

弦截法:

$$x_{k+1} = -\frac{f(x_k)(x_k - x_{k-1})}{f(x_k) - f(x_{k-1})} \quad (1.618\text{阶})$$

## 2. 解非线性方程组:

类Newton法:  $J_k \cdot \Delta = -F_k$

$$J = \begin{pmatrix} \partial f / \partial x & \partial f / \partial y & \dots \\ \partial g / \partial x & \partial g / \partial y & \dots \\ \dots & \dots & \dots \end{pmatrix}$$

$n \times n$

$$F = \begin{pmatrix} f(\vec{x}) \\ g(\vec{x}) \\ \dots \end{pmatrix}$$

$n \times 1$

$$\Delta = \begin{pmatrix} x_{k+1} - x_k \\ \dots \end{pmatrix}$$

$n \times 1$

$$(x_{k+1} = x_k - J^{-1}(x_k) F(x_k))$$

# 线性方程组求解 - 1

## 1. 直接法:

① Gauss 消元 (求解的运算量  $\sim n^3$ )

- └ 顺序消元
- └ 列主元

② 直接分解:  $LUx=b$  (在已分解出  $A = \begin{matrix} L & U \end{matrix}$  的前提下, 运算量  $\sim n^2$ )

Doolittle

$$A = \begin{pmatrix} | & & \\ \hline l & & \\ \hline & \ddots & \\ & & 1 \end{pmatrix} \begin{pmatrix} \square & & \\ & \square & \\ & & \square \end{pmatrix} u$$

Cront

$$A = \begin{pmatrix} \square & & \\ & \square & \\ & & \square \end{pmatrix} l \begin{pmatrix} | & & \\ \hline & \square & \\ \hline & & \square \end{pmatrix} u$$

\*

三对角方程组

$$A = \begin{pmatrix} & & & 0 \\ & \diagdown & & \\ & & \diagup & \\ 0 & & & \end{pmatrix} = \begin{pmatrix} & & & 0 \\ & \diagdown & & \\ & & \diagup & \\ 0 & & & \end{pmatrix} \begin{pmatrix} & & & v \\ & & & \\ & & & \\ 0 & & & 1 \end{pmatrix} u$$

(先求出所有  $w$ , 再依次求各个  $u, v, u, v, \dots$ )

对称正定矩阵

$$A = \begin{pmatrix} | & & \\ \hline l & & \\ \hline & \ddots & \\ & & 1 \end{pmatrix} \begin{pmatrix} \square & & \\ & \square & \\ & & \square \end{pmatrix} u$$

对称元素可以照抄

$$= \begin{pmatrix} | & & \\ \hline l & & \\ \hline & \ddots & \\ & & 1 \end{pmatrix} \begin{pmatrix} \square & & \\ & \square & \\ & & \square \end{pmatrix} \begin{pmatrix} | & & \\ \hline & \square & \\ \hline & & \square \end{pmatrix} u$$

$L \quad D \quad L^T$



## 2 迭代法

① 一般格式.

$$A = D + L + U = \begin{pmatrix} \diagdown & & \\ & \triangle & \\ & & \triangle \end{pmatrix} + \begin{pmatrix} \triangle & & \\ & \triangle & \\ & & \triangle \end{pmatrix} + \begin{pmatrix} \triangle & & \\ & \triangle & \\ & & \triangle \end{pmatrix}$$

(P102)

$$Ax = b \Rightarrow (N-P)X = b$$

$$\Rightarrow X = N^{-1}P X + N^{-1}b = \underbrace{M}_{\text{迭代矩阵}} X + g$$

\* 迭代收敛的充要条件:  $\rho(M) < 1$  (充分:  $\|M\| < 1$ )

② 经典迭代: 设  $C = N^{-1}$ , 则  $X = C \begin{pmatrix} C^{-1} - A \\ \end{pmatrix} X + Cb$  (P106)  
 $= (I - CA)X + Cb.$

<1> Jacobi 迭代:	$C = D^{-1}$
<2> Gauss-Seidel	$C = (D+L)^{-1}$
<3> SOR (SOR)	$C = (w^{-1}D + L)^{-1}$

Gauss-Seidel

③ 一些收敛判别的结论:

(\*) (严格) 行对角优: 每一行中, 对角元素 (严格) 大于其它元素之和.  
 (例) (例)

(\*) (严格) 列对角优: 每一列中, 对角元素 (严格) 大于其它元素之和.

<1> 若  $M$  为严格行对角优, 则  $M$  可逆.

<2> 若  $A$  为 严格行对角优, 则 Jacob 迭代收敛.

<3> 若  $A$  为 严格列对角优, 则 G-S 收敛.

<4> 若  $A$  正定, 则 G-S 收敛.

# 数值积分与微分-1

\* 代数精度与截断误差:

- <1> 对于直接选点的积分, 代数精度指: 此积分方法对  $\leq n$  阶的多项式结果准确.
- <2> 对于复化(分段)积分, 截断误差指:  $O(\frac{1}{n^k})$ ,  $n$  为选点数.
- <3> 对于数值微分, 截断误差指:  $O(h^k)$ ,  $h$  为求微分时的点间距.

## 1. 数值积分:

① 插值型积分: 任意选点, 但积分系数不固定.

② Newton-Cotes 积分:

<1> 一阶 (梯形积分) [1阶代数精度]  $I = h(\frac{1}{2}f(a) + \frac{1}{2}f(b))$

<2> 二阶 (Simpson 积分) [3阶代数精度]  $I = h(\frac{1}{6}f(a) + \frac{4}{6}f(\frac{a+b}{2}) + \frac{1}{6}f(b))$

<3>  $n$  阶:  $\left[ \begin{array}{l} n \text{ 为奇: } n \text{ 阶代数精度} \\ n \text{ 为偶: } n-1 \text{ 阶代数精度} \end{array} \right]$  \*  $n \leq 7$  时, Newton-Cotes 积分稳定.

\* 如何计算代数精度:

$$I = \int f(x)dx \approx \underbrace{\int L(x)dx}_{\text{插值公式}} + \underbrace{\int R(x)dx}_{\text{余项公式}}$$

通过算截断误差  $\int R(x)dx$ , 即可得到代数精度.

③ 复化数值积分:

<1> 分段梯形积分  $T_n$ :  $\frac{1}{2} \quad 1 \quad 1 \quad \dots \quad 1 \quad 1 \quad \frac{1}{2}$ , 截断误差  $O(\frac{1}{n^2})$

<2> 分段 Simpson 积分  $S_n$ :  $\frac{1}{6} \quad \frac{4}{6} \quad \frac{2}{6} \quad \dots \quad \frac{2}{6} \quad \frac{4}{6} \quad \frac{1}{6}$ , 截断误差  $O(\frac{1}{n^4})$

<3> Cotes 积分  $C_n$  和 Romberg 积分  $R_n$ :

由于  $I - T_{2n} \approx \frac{1}{4}(I - T_n) \Rightarrow I \approx T_{2n} + \frac{1}{3}(T_{2n} - T_n)$  刚好为  $S_{2n}$

截断误差由  $\frac{1}{(2n)^2}$  降为  $\frac{1}{(2n)^4}$


所以进一步组合,

$$I - S_{2n} \approx \frac{1}{2^4}(I - S_n) \implies C_n$$

$$I - C_n \approx \frac{1}{2^6}(I - C_n) \implies R_n$$

# 数值积分与微分-2

实际计算中:



## ④ Gauss型积分:

对  $I(f) = \int_{-1}^1 f(x) dx$ , 取 Legendre 多项式  $L_n(x)$  的几个零点作为积分节点.

取  $\alpha_j = \int_{-1}^1 \frac{(x-x_1) \dots (x-x_n)}{(x_j-x_1) \dots (x_j-x_n)} dx$  为积分系数.

则代数精度可达  $2n-1$  阶.

## ⑤ 重积分:

梯形:  $\frac{1}{4} \times \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix} \longrightarrow \frac{1}{4} \begin{pmatrix} 1 & 2 & \dots & 2 & 1 \\ 2 & 4 & \dots & 4 & 2 \\ \vdots & \vdots & & \vdots & \vdots \\ \vdots & \vdots & & \vdots & \vdots \\ 2 & 4 & \dots & 4 & 2 \\ 1 & 2 & \dots & 2 & 1 \end{pmatrix} \times \text{某函数}$

Simpson:  $\frac{1}{36} \times \begin{pmatrix} 1 & 4 & 1 \\ 4 & 16 & 4 \\ 1 & 4 & 1 \end{pmatrix} \longrightarrow \frac{1}{36} \begin{pmatrix} 1 & 4 & 2 & \dots & 2 & 4 & 1 \\ 4 & 16 & 8 & \dots & 8 & 16 & 4 \\ 2 & 8 & 4 & \dots & 4 & 8 & 2 \\ \vdots & \vdots & \vdots & & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & & \vdots & \vdots & \vdots \\ 2 & 8 & 4 & \dots & 4 & 8 & 2 \\ 4 & 16 & 8 & \dots & 8 & 16 & 4 \\ 1 & 4 & 2 & \dots & 2 & 4 & 1 \end{pmatrix} \times \text{某函数}.$

## 2. 数值微分:

### ① 依赖于 Taylor 展开:

\* 截断误差: 按照展开式计算即可, 例如, 截断误差为  $O(h^n)$

\* 向前差分: 利用  $f(x_0+h), f(x_0)$  算, 截断误差为  $O(h)$

向后差分: 利用  $f(x_0), f(x_0-h)$  算, 截断误差为  $O(h)$

中心差分: 利用  $f(x_0-h), f(x_0+h)$  算, 截断误差为  $O(h^2)$

### ② 插值型.

# 数值求解常微分方程:

## 1. 基本概念:

① 计算形式: 
$$y_{n+1} = \sum_{i=n-a+1}^n \alpha_i y_i + \sum_{i=n-a+1}^{n+1} \beta_i f_i$$

其中  $f_i = f(x_i, y_i)$ ,  $\alpha_i, \beta_i$  为常数.

②  $\alpha$  为步数, 表示: 为了计算  $y_{n+1}$ , 需要用到前面第  $a$  个  $x_i$  以后的信息,  
即, 从  $x_{n-a+1}$  到  $x_n$ , 共  $a$  步.

③  $\beta_{n+1} = 0$  时,  $y_{n+1}$  由右式直接求出, 称为 "显性"公式.

$\beta_{n+1} \neq 0$  时, 称为 "隐性"公式.

④ 上式可用 Taylor 展开来证明. 等式左右的偏差  $T = O(h^{k+1})$  称为局部截断误差, 称为 阶数.

⑤ 整体截断误差:

设  $|e_n| = |y(x_{n+1}) - y_{n+1}|$

$|T_n| = |R_n|$ ,  $T$  为  $|T_n|$  的上界.

则由 Taylor 展开可以求得  $|e_n|$  的递推式, 最终求得,  $|e_n|$  与  $|e_1|, T$  的关系.

## 2. 示例: Euler 公式.

① 基于数值微商: 向前微商  $y'(x_n) \approx \frac{y(x_{n+1}) - y(x_n)}{h} \Rightarrow y(x_{n+1}) = y(x_n) + hf_n$

向后微商:  $y'(x_n) \approx \frac{y(x_n) - y(x_{n-1}))}{h} \Rightarrow y(x_{n+1}) = y(x_n) + hf_{n+1}$   
\* 隐式:

② 基于数值积分:  $y(x_{n+1}) = y(x_n) + \int_{x_n}^{x_{n+1}} f(x, y(x)) dx$

$\Rightarrow y_{n+1} = y_n + \frac{1}{2}h(f_n + f_{n+1})$

3. 积分方法.

$$\textcircled{1} \quad y(x_{n+1}) = y(x_{n-p}) + \int_{x_{n-p}}^{x_{n+1}} f(x) dx$$

~~步骤~~  
P: 积分范围.

用  ~~$x_n, x_{n-1}$~~

$\{y_n, y_{n-1}, \dots, y_{n-q}\}$  计算积分式.

q: 积分节点.

(节点数 = q + 1)

\* 若用  $\{y_{n+1}, y_n, \dots, y_{n-q+1}\}$ , 则为隐式.

② 具体计算过程, (以显式为例)

设:  ~~$y(x_{n+1}) = y(x_{n-p}) + h [a_0 f_n + a_1 f_{n-1} + \dots + a_p f_{n-p}]$~~

则

在  $\{x_n, x_{n-1}, \dots, x_{n-q}\}$  处, 构造插值公式:

$$L(x) = l_0 f(x_n) + l_1 f(x_{n-1}) + \dots + l_q f(x_{n-q})$$

$$\text{则 } y(x_{n+1}) = y_{n-p} + \int_{x_{n-p}}^{x_{n+1}} L(x) dx$$

$$= y_{n-p} + \left( \int_{x_{n-p}}^{x_{n+1}} l_0 dx \right) \cdot f(x_n) + \dots + \left( \int_{x_{n-p}}^{x_{n+1}} l_q dx \right) f(x_{n-q})$$

\*  $p=0$ , 则称为 Adam 公式.

\* 对于隐式的初值计算, 可用其它方法.

但是为了不影响精度, K阶精度的线性多步法中的总步

运算至少应为  $K-1$  阶.



① ~~Runge-Kutta 3阶~~ // 微分方程 = Runge-Kutta 3阶

② Taylor 展开  $y(x_{n+1}) = y(x_n) + h y'(x_n) + \frac{h^2}{2} y''(x_n) + \dots$

其中  $y(x_n) = y(x_n)$

$y'(x_n) = f(x_n, y(x_n))$

$y''(x_n) = f_x(x_n, y(x_n)) + f_y(x_n, y(x_n)) \cdot f(x_n, y(x_n))$

.....

则可取最高  $p$  阶导数, 误差为  $\frac{h^{(p+1)}}{(p+1)!} y^{(p+1)}(x_n + \theta h) = O(h^{p+1})$

阶数为  $p$ .

② Runge-Kutta 3阶法: 用点值代替偏导数, 其  $p$  阶公式为:

$$\begin{cases}
 y_{n+1} = y_n + \alpha_1 k_1 + \alpha_2 k_2 + \dots + \alpha_p k_p \\
 \alpha_1 = f(x_n, y_n) = F(x_n, h; y_n, h k_1) \\
 \alpha_2 = f(x_n + \beta_{21} h, y_n + \beta_{22} h k_1) = F(x_n, h; y_n, h k_1) \\
 \alpha_3 = f(x_n + \beta_{31} h, y_n + \beta_{32} h k_1 + \beta_{33} h k_2) = F(x_n, h; y_n, h k_1, h k_2) \\
 \dots \\
 \alpha_p = F(x_n, h; y_n, h k_1, \dots, h k_{p-1})
 \end{cases}$$

~~微分方程~~: Runge-Kutta 3阶法

# 矩阵的特征值 & 特征向量

幂法  $A$  ~~按模最大的~~  $\text{Max} |\lambda|$

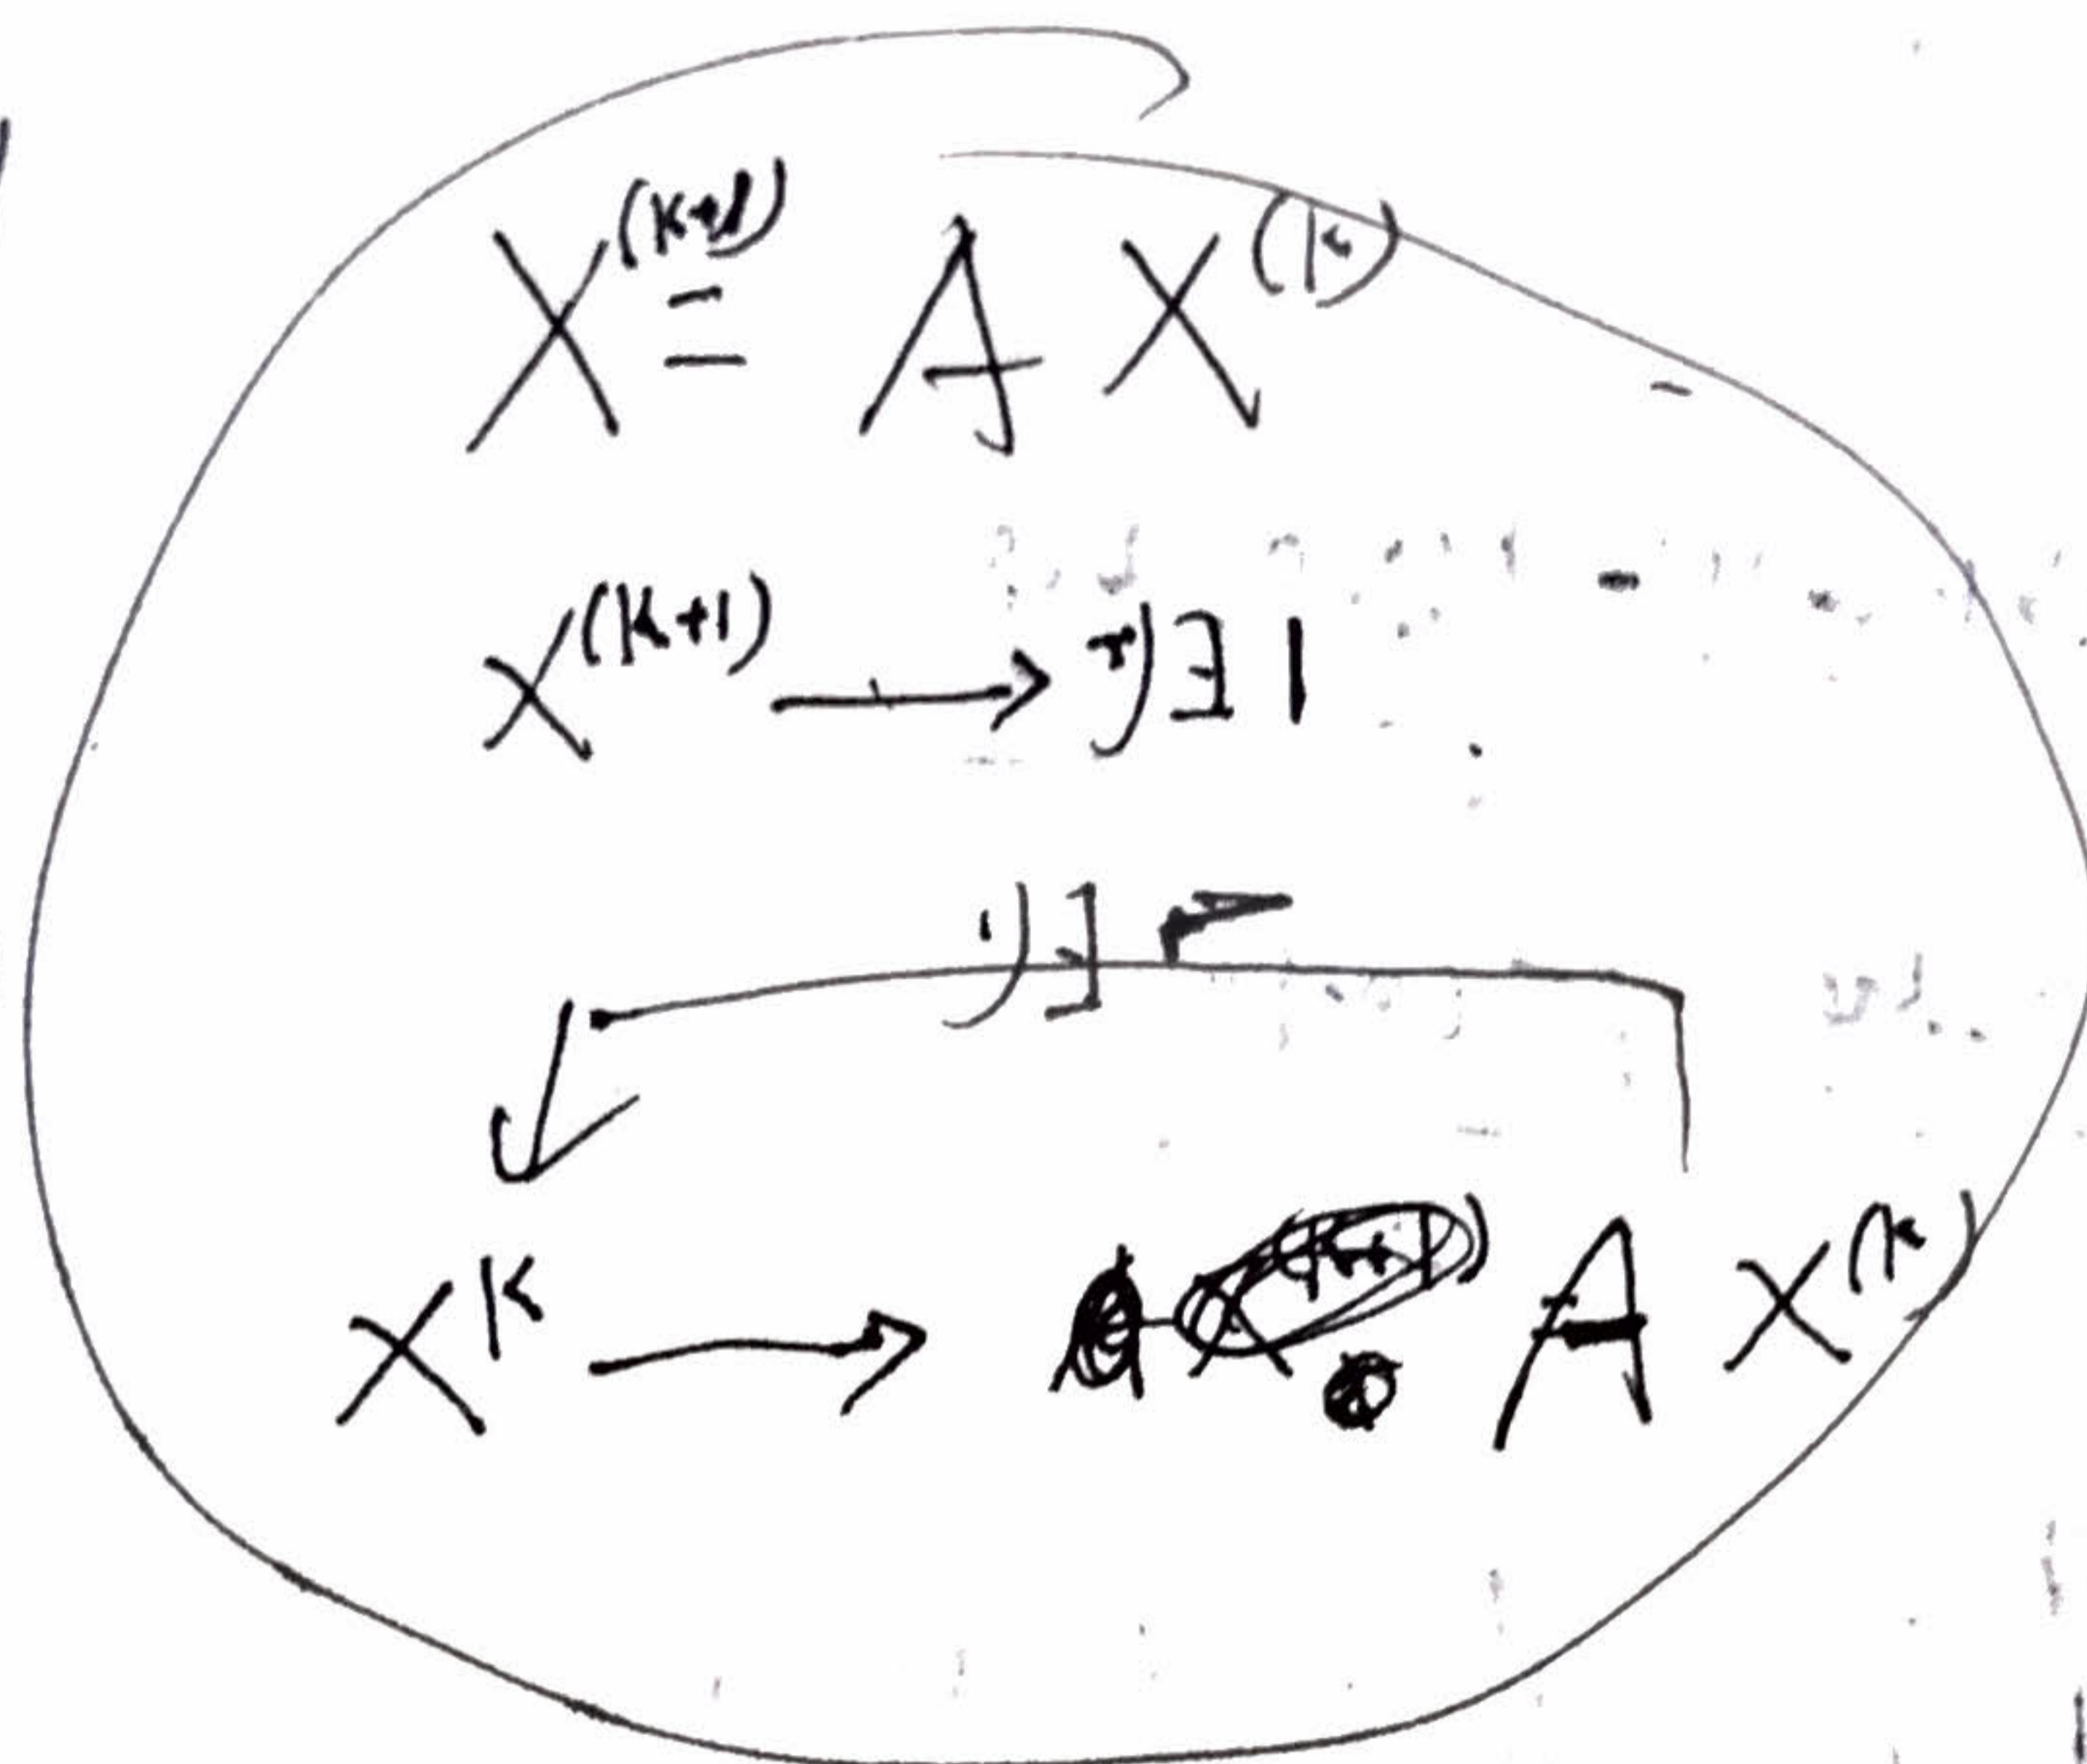
原点位移法  $A - pI$   $\text{Max} |\lambda - p|$

反幂法  $A^{-1}$   $\text{Min} |\lambda|$

原点位移反幂法  $A^{-1} - pI$   $\text{Min} |\lambda - p|$

以幂法为例

① 若  $\text{max} |\lambda|$   
只有 1 个 (实根)



~~若~~

② 若  $\text{max} |\lambda|$  为互为相反数的两实根 (---)