

数值线性代数：求解线性方程组

- 矩阵的三角分解

- LU分解：若 A 的前 $n-1$ 顺序主子式不等于0，则存在唯一的 L 是单位下三角阵， U 是上三角阵，使得 $A = LU$

【证明】存在性由Gauss消元法过程给出，唯一性用数学归纳法计算：

$$\begin{aligned} A &= \begin{pmatrix} A_{n-1} & \mu \\ \nu^T & a_{nn} \end{pmatrix} = \begin{pmatrix} L_{n-1} & 0 \\ \sigma^T & 1 \end{pmatrix} \begin{pmatrix} U_{n-1} & \tau \\ 0 & u_n \end{pmatrix} \\ &= \begin{pmatrix} \tilde{L}_{n-1} & 0 \\ \tilde{\sigma}^T & 1 \end{pmatrix} \begin{pmatrix} \tilde{U}_{n-1} & \tilde{\tau} \\ 0 & \tilde{u}_n \end{pmatrix} \end{aligned}$$

推论：相同的条件，存在唯一的单位上（下）三角阵 L （ U ），对角矩阵 D ，使得 $A = LDU$

- PLU分解：若 $\det A \neq 0$ ，则存在排列阵 P 、单位下三角 L 和上三角 U ，使得 $PA = LU$
- Cholesky分解：若 A 对称正定，则存在对角元为正的下三角阵 L 使得 $A = LL^T$

【证明】正定 \Rightarrow 所有顺序主子式都是正数，特别地都不得零，因此有LDLT分解，再结合正定可知 D 的对角线都是正数，所以 $A = L\sqrt{D}\sqrt{D}L^T = \tilde{L}\tilde{L}^T$ ，其中 \tilde{L} 的对角线元素就是 \sqrt{D} 的对角线元素，为正数

【例题】

设 $A = \begin{pmatrix} 5 & a \\ a & 3 \end{pmatrix}$ ， $a \in \mathbb{R}$ ，要想 A 正定，则 a 的取值范围是？此时做Cholesky分解 $A = LL^T$ ，计算 L 。

【解答】 A 的特征多项式为 $p(\lambda) = (\lambda - 3)(\lambda - 5) - a^2$ ，若要两根都为正，则 $p(0) = 15 - a^2 > 0$ ，且 $p(4) = -1 - a^2 < 0$ 。其中解第一个不等式可得 $|a| < \sqrt{15}$ ，第二个不等式自动满足（也可以用性质：实对称矩阵 A 是正定的，当且仅当 A 的每个顺序主子式都大于零）。因此所求 a 的范围是 $|a| < \sqrt{15}$ 。

对于Cholesky分解，首先根据Gauss消元法可得矩阵分解：

$$A = \begin{pmatrix} 1 & 0 \\ \frac{a}{5} & 1 \end{pmatrix} \begin{pmatrix} 5 & a \\ 0 & 3 - \frac{a^2}{5} \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ \frac{a}{5} & 1 \end{pmatrix} \begin{pmatrix} 5 & 0 \\ 0 & 3 - \frac{a^2}{5} \end{pmatrix} \begin{pmatrix} 1 & \frac{a}{5} \\ 0 & 1 \end{pmatrix},$$

所以

$$L = \begin{pmatrix} 1 & 0 \\ \frac{a}{5} & 1 \end{pmatrix} \begin{pmatrix} \sqrt{5} & 0 \\ 0 & \sqrt{\frac{15-a^2}{5}} \end{pmatrix} = \begin{pmatrix} \sqrt{5} & 0 \\ \frac{a}{\sqrt{5}} & \sqrt{\frac{15-a^2}{5}} \end{pmatrix}.$$

- LDLT分解：设 A 是对称阵，且前 $n-1$ 顺序主子式不得零，则 A 可以唯一分解为 $A = LDL^T$ ，其中 L 是单位下三角阵， D 是对角阵

【证明】对 A 做LDU分解 $A = LDU$ ，根据对称可知 $U = L^T$ ，得证。

- 矩阵的条件数

- 直接求解线性方程组的先验误差估计：

设 $\det A \neq 0$ ， $\mathbf{b} \neq 0$ ， $\|A^{-1}\| \|\delta A\| < 1$ ，则有：

$$\frac{\|\delta \mathbf{x}\|}{\|\mathbf{x}\|} \leq \frac{\|A\| \|A^{-1}\|}{1 - \|A\| \|A^{-1}\| \frac{\|\delta A\|}{\|A\|}} \cdot \left(\frac{\|\delta A\|}{\|A\|} + \frac{\|\delta \mathbf{b}\|}{\|\mathbf{b}\|} \right).$$

【证明】根据题给条件可知 $A + \delta A = A(I + A^{-1}\delta A)$ ，根据 $\|A^{-1}\delta A\| \leq \|A^{-1}\| \|\delta A\| < 1$ 可知 $A + \delta A$ 是可逆矩阵，所以：

$$\delta \mathbf{x} = (A + \delta A)^{-1}[\mathbf{b} + \delta \mathbf{b} - (A + \delta A)\mathbf{x}] = (I + A^{-1}\delta A)^{-1}A^{-1}(\delta \mathbf{b} - \delta A\mathbf{x})$$

所以：

$$\|\delta \mathbf{x}\| \leq \frac{\|A^{-1}\|}{1 - \|A^{-1}\| \|\delta A\|} \cdot [\|\delta \mathbf{b}\| + \|\delta A\| \|\mathbf{x}\|],$$

再根据 $\|\mathbf{b}\| \leq \|A\| \|\mathbf{x}\|$ 可得

- 条件数 $\text{cond} A = \|A\| \|A^{-1}\|$

性质：

- 对于任何范数， $\text{cond}(A) \geq 1$ （显然）
- 对于2-范数， $\text{cond}_2(U) = 1$ （对于酉矩阵）； $\text{cond}_2(UA) = \text{cond}_2(U)$ ； $\text{cond}_2(A^T A) \geq \text{cond}_2(A)$

【证明】

(a) 断言: 设 Q 为 n 阶正交阵, $A \in \mathbb{R}^{n \times n}$, 则 $\|A\|_2 = \|QA\|_2 = \|AQ\|_2$.

【事实上,

$$\|QA\|_2 = \sup_{\|x\|_2=1} \|QAx\|_2 = \sup_{\|x\|_2=1} \sqrt{x^t A^t Q^t Q A x} = \sup_{\|x\|_2=1} \sqrt{x^t A^t A x} = \sup_{\|x\|_2=1} \|Ax\|_2 = \|A\|_2;$$

$$\|AQ\|_2 = \sup_{\|x\|_2=1} \|AQx\|_2 = \sup_{\|Qx\|_2=1} \|AQx\|_2 = \sup_{\|y\|_2=1} \|Ay\|_2 = \|A\|_2 \quad (\text{这里用到正交矩阵不改变向量的2-范数})$$

所以:

$$\text{cond}_2(QA) = \|QA\|_2 \|(QA)^{-1}\|_2 = \|QA\|_2 \|A^{-1}Q^T\|_2 = \|A\|_2 \|A^{-1}\|_2 = \text{cond}_2(A).$$

(这里用到 Q 是正交矩阵 $\Rightarrow Q^T$ 也是正交矩阵)

(b)

断言: 对所有 $n \times n$ 实矩阵 A , $\text{cond}_2(A) \geq 1$, 从而 $[\text{cond}_2(A)]^2 \geq \text{cond}_2(A)$.

【按定义, $\text{cond}_2(A) = \|A\|_2 \|A^{-1}\|_2 \geq \|AA^{-1}\|_2 = \|I_n\|_2 = 1$.】

断言: 对所有 $n \times n$ 实矩阵 A , $\|A^T A\|_2 \geq \|A\|_2^2$, $\|AA^T\|_2 \geq \|A\|_2^2$.

【按定义, $\|Ax\|_2^2 = x^T A^T A x \leq \|x\|_2 \|A^T A x\|_2 \leq \|x\|_2^2 \|A^T A\|_2 \Rightarrow \left(\sup_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2}\right)^2 \leq \|A^T A\|_2$, 即 $\|A\|_2^2 \leq \|A^T A\|_2$. 用 A^T 替换 A 可得 $\|A^T\|_2^2 \leq \|AA^T\|_2$. 由 $A^T A$ 和 AA^T 的特征多项式完全相同, 以及二范数的定义可知 $\|A^T\|_2^2 = \lambda_{\max}(AA^T) = \lambda_{\max}(A^T A) = \|A\|_2^2$, 即 $\|AA^T\|_2 \geq \|A\|_2^2$ 】

我们计算 $\text{cond}_2(A^T A)$:

$$\text{cond}_2(A^T A) = \|A^T A\|_2 \|A^{-1}(A^T)^{-1}\|_2 = \|A^T A\|_2 \|A^{-1}(A^{-1})^T\|_2 \geq \|A\|_2^2 \|A^{-1}\|_2^2 = \text{cond}_2(A)^2 \geq \text{cond}_2(A).$$

■ 对于2-范数, $\text{cond}_2(A) = \frac{\sigma_{\max}(A)}{\sigma_{\min}(A)}$ (最大奇异值和最小奇异值之比)

【证明】注意到 $\|A\|_2 = \sqrt{\lambda_{\max}(A^T A)} = \sigma_{\max}(A)$ 即可

○ 后验误差估计

设 \bar{x} 为 $Ax = b$ 的一个近似解. $r = b - A\bar{x}$ 称为“残差”. 有

$$\frac{1}{\text{cond}(A)} \frac{\|r\|}{\|b\|} \leq \frac{\|x - \bar{x}\|}{\|x\|} \leq \text{cond}(A) \frac{\|r\|}{\|b\|}$$

• 吉洪诺夫正则化方法

○ 根据奇异值分解 $A = VDU^*$, 我们有分解式:

$$Ax = \sum_{j=1}^r \sigma_j(x, u_j) v_j.$$

【证明】注意到 $Au_k = \mu_j v_j, j = 1, \dots, r; Au_j = 0, j = r+1, \dots, n$, 以及 $x = \sum_{j=1}^n (x, u_j) u_j$ (由于标准正交) 即可

○ 广义逆:

$$x = \sum_{j=1}^r \frac{1}{\mu_j} (b, v_j) u_j.$$

正则化方法:

$$x = \sum_{j=1}^r \frac{\mu_j}{\alpha + \mu_j^2} (b, v_j) u_j.$$

(相当于求解 $(\alpha I + A^* A)x_\alpha = A^* b$, $\text{cond}_2(\alpha I + A^* A) = \frac{\mu_1^2 + \alpha}{\mu_n^2 + \alpha}$)

• 线性方程组的迭代求解——线性格式

○ 【命题】 B 是 n 阶复方阵, 则以下等价:

$$B^k \rightarrow 0; \rho(B) < 1; \text{存在一种范数使得 } \|B\| < 1.$$

【证明】① \rightarrow ②: 取特征向量即得 $\lambda^k \rightarrow 0$, 因此 B 的所有特征值模都小于 1;

② \rightarrow ③: 回忆一个事实: 对任何 $\varepsilon > 0$, 存在一种范数 $\|\cdot\|_\varepsilon$ 使得 $\|B\|_\varepsilon \leq \rho(B) + \varepsilon$, 由此立刻得

③ \rightarrow ①: 根据算子范数的性质 $\|B^k\| \leq \|B\|^k$ 立刻得

○ 【定理】 $\lim_k \|B^k\|^{1/k} = \rho(B)$

【证明】对整数 k 做除法公式 $k = qn(k) + r$, 利用凸性证明 $\limsup_k \|B^k\|^{1/k} = \liminf_k \|B^k\|^{1/k}$

○ 简单迭代格式

记号: $A = D - L - U = M - N$, 构造类似于 $\mathbf{x} = M^{-1}N\mathbf{x} + M^{-1}\mathbf{b}$ 的形式

Jacobi: $\mathbf{x}^{(n+1)} = D^{-1}(L + U)\mathbf{x}^{(n)} + D^{-1}\mathbf{b} = (I - D^{-1}A)\mathbf{x}^{(n)} + D^{-1}\mathbf{b}$

G-S: $\mathbf{x}^{(n+1)} = (D - L)^{-1}U\mathbf{x}^{(n)} + (D - L)^{-1}\mathbf{b}$

SOR: $\mathbf{x}^{(n+1)} = (D - \omega L)^{-1}[(1 - \omega)D + \omega U]\mathbf{x}^{(n)} + (D - \omega L)^{-1}\omega\mathbf{b}$

o 简单迭代格式的收敛性

- 若 A 严格对角占优或者不可约弱对角占优, 则Jacobi和G-S收敛

【证明】这里只对严格对角占优证明, 不可约弱对角占优略去:

只需验证 $B = M^{-1}N$ 满足收敛性条件

$B_J = D^{-1}(D - A) = I - D^{-1}A$, 根据对角占优可知 $\|B_J\|_\infty < 1$

$B_{G-S} = (D - L)^{-1}U$, 取特征向量 x , 假设特征值 $|\lambda| > 1$, 则根据对角占优可知 $\lambda(D - L) - U$ 也是严格对角占优, 所以:

$$\det(\lambda I - B_{G-S}) = \det(D - L)^{-1} \det(\lambda(D - L) - U) \neq 0$$

这和 λ 是特征值矛盾, 所以 $\rho(B_{G-S}) < 1$

- 设 A 对称正定, 则Jacobi收敛当且仅当 $2D - A$ 也正定

【证明】根据正定可知对角线均为正, 也就是 D 的元素都是正数, 所以

$$B_J = D^{-1}(D - A) = I - D^{-1}A = \sqrt{D}^{-1}(I - \sqrt{D}^{-1}A\sqrt{D}^{-1})\sqrt{D}$$

$2D - A$ 正定, 说明 $2I - \sqrt{D}^{-1}A\sqrt{D}^{-1}$ 也正定 (合同变换), 所以其特征值落在 $(0, 2)$, 因此

$I - \sqrt{D}^{-1}A\sqrt{D}^{-1}$ 的特征值落在 $(-1, 1)$, 其谱半径 $\rho(I - \sqrt{D}^{-1}A\sqrt{D}^{-1}) < 1$, 所以 B_J 的谱半径

$$\rho(B_J) = \rho(I - \sqrt{D}^{-1}A\sqrt{D}^{-1}) < 1 \text{ (相似变换不改变谱)}$$

- 1) 设 A Hermite 正定, $0 < \omega < 2$, 则SOR方法收敛. 特别地, 只要 A Hermite 正定, 则G-S收敛 ($\omega = 1$ 的情形)

2) 设 A 对角非零, 则SOR收敛 $\Leftrightarrow 0 < \omega < 2$

【对角非零且正定: 则ASOR收敛 $\Leftrightarrow 0 < \omega < 2$ 】

【证明】

1) 设 λ 是 $(D - \omega L)^{-1}[\omega U + (1 - \omega)D]$ 的特征值, x 为特征向量, 则有:

$$(1 - \omega)Dx + \omega Ux = (D - \omega L)x.$$

注意到有如下分解:

$$2(1 - \omega)D + 2\omega U = (2 - \omega)D - \omega A + \omega(U - L),$$

$$2(D - \omega L) = (2 - \omega)D + \omega A + \omega(U - L).$$

于是:

$$\lambda = \frac{x^*(2 - \omega D)x - \omega x^*Ax + \omega x^*(U - L)x}{x^*(2 - \omega D)x + \omega x^*Ax + \omega x^*(U - L)x}.$$

注意到 $U - L$ 是 Hermite 反对称矩阵, 所以 $x^*(U - L)x$ 是纯虚数, 而 A Hermite 正定 $\Rightarrow x^*Ax$ 为正实数且 D 的对角线大于 0 (于是 $x^*(2 - \omega D)x$ 也是正实数), 所以:

$$|\lambda|^2 = \frac{[x^*(2 - \omega D)x - \omega x^*Ax]^2 + |\omega x^*(U - L)x|^2}{[x^*(2 - \omega D)x + \omega x^*Ax]^2 + |\omega x^*(U - L)x|^2}$$

因为:

$$|x^*(2 - \omega D)x - \omega x^*Ax| < x^*(2 - \omega D)x + \omega x^*Ax,$$

所以 $|\lambda|^2 < 1$, 于是 $\rho(B_{SOR}^\omega) < 1$, 这里 $B_{SOR}^\omega = (D - \omega L)^{-1}[\omega U + (1 - \omega)D]$.

2) 设 μ_1, \dots, μ_n 是 B_{SOR}^ω 的特征值, 则:

$$\prod_{i=1}^n \mu_i = \det(D - \omega L)^{-1} \det((1 - \omega)D + \omega U) = \det D^{-1} [(1 - \omega)^n \det D] = (1 - \omega)^n,$$

此因 U 和 L 分别是严格上三角和严格下三角以及 D 对角非零.

所以:

$$|\omega - 1| = \sqrt[n]{\prod_{j=1}^n |\mu_j|} \leq \max_{1 \leq j \leq n} |\mu_j| = \rho(B_{SOR}^\omega) < 1$$

于是有 $\omega \in (0, 2)$.

• 最速下降法和共轭梯度法

- Setting: A 是实对称矩阵, 求解 $Ax = b$
- 原理: $Ax = b$ 的真解 x^* 极小化泛函 $\mathcal{F}[x] = \frac{1}{2}(Ax, x) - (b, x)$
- 最速下降法: 沿着残差方向下降

$$p^{(k)} = -\nabla \mathcal{F}[x^{(k)}] = b - Ax^{(k)} = r^{(k)},$$

一维搜索的最小值

$$\alpha_k = \arg \min \mathcal{F}[x^{(k)} + \alpha_k p^{(k)}] = \frac{(r^{(k)}, p^{(k)})}{(Ap^{(k)}, p^{(k)})}$$

可以证明:

$$\mathcal{F}(x^{(k+1)}) = \mathcal{F}(x^{(k)}) - \frac{1}{2} \frac{(r^{(k)}, r^{(k)})^2}{(Ar^{(k)}, r^{(k)})} \leq \mathcal{F}(x^{(k)})$$

- 共轭梯度法: 不选择 $p^{(k+1)} = r^{(k+1)}$, 而是选择:

$$p^{(k+1)} = r^{(k)} + \beta_k p^{(k)}$$

其中 β_k 的选取使得 $p^{(k+1)}$ 和 $p^{(k)}$ 是 A -共轭的, 也就是:

$$\beta_k = -\frac{(r^{(k+1)}, Ap^{(k)})}{(p^{(k)}, Ap^{(k)})}$$

然后对新的 $p^{(k+1)}$ 同样找一维搜索的最优参数 $\alpha_{k+1} = \arg \min \mathcal{F}[x^{(k+1)} + \alpha_{k+1} p^{(k+1)}]$

• Galerkin原理, Arnoldi算法和GMRES算法

- 试验函数空间 $K_m = \text{Span}(v_i)_{i=1}^m$; 测试函数空间 $L_m = \text{Span}(w_i)_{i=1}^m$
要求解 $Ax = b$ (A 未必是对称正定矩阵), 为此令 $x_0 \in \mathbb{R}^n$ 是任一向量, 求解残差方程:

$$Az = r_0, \quad \text{其中 } z = x - x_0, \quad r_0 = b - Ax_0,$$

如果能较好地求解出 z^* , 则 $x^* = x_0 + z^*$ 就是真解的一个很好的近似

- Galerkin原理: 在子空间 K_m 中找向量 z_m , 使得残差 $r_0 - Az_m$ 和测试函数空间 L_m 中所有向量都是正交的, 也就是:

$$(r_0 - Az_m, w_i) = 0, \quad i = 1, 2, \dots, m$$

因为 $K_m = \text{Span}(v_i)_{i=1}^m$, 所以不妨设 $z_m = Vy_m$, 其中 $V = (v_1, \dots, v_m)$, 于是有:

$$w_i^T AVy_m = w_i^T r_0, \quad i = 1, 2, \dots, m$$

再定义 $W = (w_1, \dots, w_m)$, 则有:

$$W^T AVy_m = W^T r_0 \Rightarrow z_m^* = V_m(W^T AV)^{-1} W^T r_0.$$

这就是 z_m 的一个近似解

- Arnoldi算法: $L_m = K_m = \text{Span}(r_0, Ar_0, \dots, A^{m-1}r_0)$ (Krylov子空间)

Arnoldi过程: 生成 K_m 的标准正交基 $(v_i)_{i=1}^m$ 的过程

取 $v_1 = \frac{r_0}{\|r_0\|_2}$, 我们希望扩充成 K_m 的**标准正交向量组**, 设它们放在一起构成列正交矩阵 $V = (v_1, \dots, v_m)$

我们假定 $V^T AV$ 是上Hessenberg矩阵 H , 逐列计算:

$$Av_1 = h_{11}v_1 + h_{21}v_2$$

做内积可得:

$$\begin{aligned} (v_1, Av_1) &= h_{11}(v_1, v_1) + h_{21}(v_1, v_2) = h_{11} \Rightarrow h_{11} = (v_1, Av_1) \\ &\Rightarrow h_{21}v_2 = Av_1 - h_{11}v_1 \equiv r_1 \Rightarrow h_{21} = \|r_1\|_2. \end{aligned}$$

然后, 写出第二列 $Av_2 = h_{12}v_1 + h_{22}v_2 + h_{32}v_3$, 继续计算下去. 可以证明, 这样产生的正交序列 $\{v_i\}_{i=1}^m$ 就是 $K_m = \text{Span}(r_0, Ar_0, \dots, A^{m-1}r_0)$ 的标准正交基. 可以用矩阵记号写出Arnoldi过程的通式:

$$AV_m = V_m H_m + h_{m+1,m} v_{m+1} e_m^T.$$

恶性中断现象：根据Galerkin原理求解残差方程时：

$$W_m^T AV_m y_m = W_m^T r_0,$$

这里 $W_m^T = V_m^T$, $V_m^T AV_m = H_m$, $V_m^T r_0 = V_m^T \|r_0\| v_1 = \|r_0\| e_1$, 所以近似解就是

$$z_m = V_m H_m^{-1} \|r_0\| e_1.$$

但是并不能保证 H_m 非奇异, 如果 H_m 是奇异矩阵, 则称Arnoldi算法发生了**恶性中断**, 需要更换 x_0 重新求解

- GMRES方法 (广义极小化残差方法) : $K_m = \text{Span}(r_0, \dots, A^{m-1} r_0)$ (仍是Krylov子空间), 而测试函数空间换成 $L_m = AK_m$

【定理】设 A 是可逆矩阵, 设 $V_m = (v_1, \dots, v_m)$ 是 K_m 的标准正交基, $W_m = (w_1, \dots, w_m)$ 是 L_m 的标准正交基, 则按照GMRES方法求解残差方程不会发生恶性中断, 也就是 $B_m = W_m^T AV_m$ 是非奇异矩阵.

【证明】写 $W_m = AV_m G$, 其中 $U_m = (u_1, \dots, u_m)$, $u_i \in K_m$, 所以存在可逆矩阵 $G \in M_m(\mathbb{R})$, 使得 $U_m = V_m G$, 所以 $W_m = AV_m G$, 此时根据Galerkin原理:

$$B_m = W_m^T AV_m = G^T (AV_m)^T (AV_m),$$

根据 A 可逆, V_m 列正交可知 $(AV_m)^T (AV_m)$ 对称正定, 因而可逆, 而 G 也可逆, 所以 B 可逆.

【定理】按照GMRES方法计算出来的近似解 $\tilde{x} = x_0 + \tilde{z}$ 在 $x_0 + K_m$ 中极小化泛函 $R[x] = \|b - Ax\|_2^2$, 也就是:

$$R[\tilde{x}] = \min_{x \in x_0 + K_m} R[x].$$

反过来, 如果 $R[\tilde{x}] = \min_{x \in x_0 + K_m} R[x]$ 成立, 那么 \tilde{x} 一定是GMRES方法计算出来的解.

【证明】

- 任取 $x \in x_0 + K_m$, 都有

$$\|b - Ax\|_2^2 = \|b - A\tilde{x} - A(x - \tilde{x})\|_2^2 = \|b - A\tilde{x}\|_2^2 - 2(b - A\tilde{x}, A(x - \tilde{x})) + \|A(x - \tilde{x})\|_2^2$$

因为 $A(x - \tilde{x}) \in AK_m = L_m$, 所以 $A(x - \tilde{x}) \perp \tilde{z} = b - A\tilde{x}$, 所以:

$$\|b - Ax\|_2^2 = \|b - A\tilde{x}\|_2^2 + \|A(x - \tilde{x})\|_2^2 \geq \|b - A\tilde{x}\|_2^2.$$

所以, $R[\tilde{x}] = \min_{x \in x_0 + K_m} R[x]$

- 假设 \tilde{x} 极小化残差泛函, 只要证明: 任取 $v \in K_m$, 都有 $\tilde{x} - x_0 \perp v$ 即可.

考虑二次函数

$$Q_v(\alpha) = \|b - A(\tilde{x} + \alpha v)\|_2^2$$

展开得:

$$Q_v(\alpha) = \alpha^2 \|Av\|_2^2 - 2\alpha(b - A\tilde{x}, Av) + \|b - A\tilde{x}\|_2^2 = \alpha^2 \|Av\|_2^2 - 2\alpha(b - A\tilde{x}, Av) + R[\tilde{x}].$$

根据假设条件, $Q_v(\alpha) \geq R[\tilde{x}]$, 对任何 $\alpha \in \mathbb{R}$ 成立. 由此可知 $Q_v(\alpha)$ 的极小值点是 $\alpha = 0$, 根据二次函数性质可得:

$$(b - A\tilde{x}, Av) = 0, \quad \forall v \in K_m$$

这恰好就是Galerkin原理, 证明完毕.

【定理】在 \mathbb{R}^m 中极小化 $\|r_0 - Az_m\|$ 等价于在 K_m 中极小化 $\|\|r_0\| e_1 - \tilde{H}_m y_m\|$, 其中 $\tilde{H}_m = \begin{pmatrix} H_m \\ h_{m+1,m} e_m^T \end{pmatrix}$

【证明】对于 K_m , 根据Arnoldi过程可知其标准正交基 $(v_i)_{i=1}^m$ 满足矩阵方程

$$AV_m = V_m H_m + h_{m+1,m} v_{m+1} e_m^T = V_{m+1} \tilde{H}_m,$$

根据Galerkin原理, $Az_m = AV_m y_m = V_{m+1} \tilde{H}_m y_m$, 所以:

$$\|r_0 - Az_m\| = \|v_1 \|r_0\| - V_{m+1} \tilde{H}_m y_m\| = \|V_{m+1} (\|r_0\| e_1 - \tilde{H}_m y_m)\| = \|\|r_0\| e_1 - \tilde{H}_m y_m\|.$$

其中, 最后一个等号是因为 V_{m+1} 是列正交矩阵, 因而是等距矩阵.

数值线性代数：特征值问题

- 特征值的估计：盖氏圆盘定理

A 是 $n \times n$ 复方阵，其盖氏圆盘为：

$$D_i = \{z \in \mathbb{C} : |z - a_{ii}| < \sum_{j \neq i} |a_{ij}|\}, \quad D_i^* = \{z \in \mathbb{C} : |z - a_{ii}| < \sum_{j \neq i} |a_{ji}|\}$$

特征值的估计：

- 每个特征值必然在某个盖氏圆盘中
 - 如果 m 个盖氏圆盘组成一个连通集 S ，且 S 和其他 $n - m$ 个圆盘互不相交，则 S 中恰好有 A 的 m 个特征值
- 特征值的估计：Rayleigh商

变分法：min-max原理

A hermite, 有 n 个实特征值 $\lambda_1 \geq \dots \geq \lambda_n$ ， n 个标准正交的特征向量 x_1, \dots, x_n ，则有：

$$\lambda_1 = \max_{x \neq 0} \frac{(Ax, x)}{(x, x)}, \quad \lambda_n = \min_{x \neq 0} \frac{(Ax, x)}{(x, x)}$$

$$\lambda_i = \min_{x \in \text{Span}(x_1, \dots, x_i)} \frac{(Ax, x)}{(x, x)} = \max_{\dim W = i} \min_{x \in W} \frac{(Ax, x)}{(x, x)}$$

$$\lambda_i = \max_{x \in \text{Span}(x_i, \dots, x_n)} \frac{(Ax, x)}{(x, x)} = \min_{\dim W = n+1-i} \max_{x \in W} \frac{(Ax, x)}{(x, x)}$$

【证明】对于最后一条，我们只需要取 W 的o.n.基 (z_j) ，并取其中的一个向量 $x = \sum_{j=1}^{n+1-i} (x, z_j) z_j$ ，解方程组 $(x, x_k) = 0, k = i + 1, \dots, n$ ，也就是：

$$\sum_{j=1}^{n+1-i} (x, z_j)(z_j, x_k) = 0, \quad \text{for } k = i + 1, \dots, n$$

注意这一共有 $n - i$ 个方程，但是有 $n + 1 - i$ 个系数，因此必然存在一组 $\{(x, z_j)\}$ 使得 $(x, x_k) = 0$ 对 $k = i + 1, \dots, n$ 成立，也就是此时 $x \perp \text{Span}(x_{i+1}, \dots, x_n)$ ，所以此时 $x = \sum_{k=1}^i (x, x_k) x_k = \sum_{k=1}^i (x, x_k) x_k$ ，于是：

$$(Ax, x) = \sum_{k=1}^i \lambda_k |(x, x_k)|^2 \geq \lambda_i (x, x) \Rightarrow \frac{(Ax, x)}{(x, x)} \geq \lambda_i$$

另一方面，取 $W = \text{Span}(x_i, \dots, x_n)$ 可得 $\max_{x \in W} \frac{(Ax, x)}{(x, x)} = \lambda_i$ ，这就证明了结论。

- 幂法、反幂法

- 幂法：求最大特征值

取 $v_0 \neq 0, u_0 = v_0, u_{n+1} = Au_n/m_n$ ，其中 m_n 是 Au_n 的最大模元素（保证 $\|u_n\|_\infty = 1$ 一直成立，防止浮点运算溢出）

判断 $|m_k - m_{k-1}| < \epsilon$ 决定是否停止迭代，此时 $x^{(1)} \approx u_k, \lambda_1 \approx m_k$

- 反幂法：求最小特征值

取 $v_0 \neq 0, u_0 = v_0$ ；求解 $Av_{k+1} = u_k$ 得到 v_{k+1} ，然后 $u_{k+1} = v_{k+1}/m_k$ ，其中 m_k 是 v_{k+1} 最大模元素

- 借助Rayleigh商加速的幂法：求Hermite矩阵最大特征值

和幂法流程相同，不过每一次判断 $|R_k - R_{k-1}| < \epsilon$ 决定是否停止迭代，其中 $R_k = \frac{(Ax_k, x_k)}{(x_k, x_k)}$

- 借助Rayleigh商加速的反幂法：如果已经有了 μ 是 λ_1 的好的近似，则：

$\mu_k = \frac{(Ax_k, x_k)}{(x_k, x_k)}$ ，求解 $(A - \mu_k I)y_{k+1} = x_k$ 得到 y_{k+1} ，归一化得到 x_{k+1}

可以验证，借助Rayleigh商的反幂法至少二次收敛。如果 A 为Hermite阵可达三阶收敛。

- Jacobi法

经典Jacobi法：每一次迭代时扫描出最大非对角元素 $|a_{kl}^{(m)}| = \max_{i \neq j} |a_{ij}^{(m)}|$

依照以下规则确定角度 θ ：

$$\tan 2\theta = \frac{2a_{kl}}{a_{kk} - a_{ll}} \quad (\text{如果 } a_{kk} \neq a_{ll}), \quad \theta = \frac{\pi}{4} \quad (\text{如果 } a_{kk} = a_{ll})$$

然后做变换 $A^{(m+1)} = J(k, l; \theta)A^{(m)}J(k, l; \theta)^T$ ，其中 $J(k, l; \theta)$ 是Givens矩阵，其形状为：

