

# Helmholtz 方程数值解：理论推导与算法实现

周晟煜 刘棋

2025 年 12 月 24 日

## 目录

1	引言	2
2	离散化	2
3	基础求解器实现	2
3.1	幂法 (Power Method)	2
3.2	反迭代法 (Inverse Iteration)	3
4	高级求解器实现	3
4.1	Shift-and-Invert Lanczos 算法	3
4.2	瑞利商迭代 (RQI)	5
5	理论复杂度分析	6
5.1	时间复杂度分析	6
5.1.1	幂法	6
5.1.2	反迭代法	6
5.1.3	Lanczos 算法	6
5.1.4	瑞利商迭代	7
5.2	空间复杂度分析	7
6	数值实验与结果分析	8
6.1	实验 1：正确性验证与物理模态	8
6.2	实验 2：时间复杂度分析	9
6.3	实验 3：RQI 收敛速度测试	9
6.4	实验 4：算法综合对比	9
7	结论	10

# 1 引言

Helmholtz 方程是数学物理中描述波动现象的基本方程，在声学、电磁学、量子力学等领域有广泛应用。本报告研究二维 Helmholtz 特征值问题的数值解法，包括数学推导、有限差分离散化、基础求解器实现（幂法和反迭代法）、高级方法（Lanczos 算法和 Rayleigh 商迭代）以及数值实验分析。

## 2 离散化

考虑二维 Helmholtz 特征值问题：

$$-\Delta u = \lambda u \quad \text{在 } \Omega = [0, 1] \times [0, 1] \quad (1)$$

带有 Dirichlet 边界条件： $u|_{\partial\Omega} = 0$ 。

我们采用均匀网格离散化的方法：取网格间距  $\Delta x = \Delta y = h = \frac{1}{N+1}$ 。内部点数共  $N^2$  个。利用五点差分格式，对拉普拉斯算子进行近似：

$$-\Delta u_{i,j} \approx \frac{4u_{i,j} - u_{i-1,j} - u_{i+1,j} - u_{i,j-1} - u_{i,j+1}}{h^2} \quad (2)$$

令  $U$  为按行优先排列的未知向量，离散化后的特征值问题转化为代数方程：

$$\mathbf{A}\mathbf{u} = \lambda\mathbf{u} \quad (3)$$

其中  $\mathbf{A} \in \mathbb{R}^{N^2 \times N^2}$  是稀疏对称矩阵，具有分块三对角结构：

$$\mathbf{A} = \frac{1}{h^2} (I_N \otimes D_2 + D_2 \otimes I_N) \quad (4)$$

其中  $D_2 = \text{tridiag}(-1, 2, -1)$  是  $N \times N$  的一维拉普拉斯矩阵。

## 3 基础求解器实现

### 3.1 幂法 (Power Method)

幂法用于求解模最大的特征值。收敛速度取决于最大特征值与次大特征值的比值。

```

1 function [lambda, v, iter_log] = power_method_algorithm(A, tol, max_iter)
2     n = size(A, 1);
3     v = randn(n, 1); v = v / norm(v);
4     iter_log = [];
5     for k = 1:max_iter
6         w = A * v;
7         v_new = w / norm(w);
8         lambda = v_new' * A * v_new;

```

```

9      iter_log = [iter_log; lambda];
10     if norm(v_new - v) < tol, break; end
11     v = v_new;
12 end
13 end

```

Listing 1: 幂法

## 3.2 反迭代法 (Inverse Iteration)

反迭代法用于求解最接近给定值  $\mu$  的特征值。利用 LU 分解预处理，其收敛速度通常为线性，但在特征值附近收敛较快。

```

1 function [lambda, v, iter_log] = inverse_iteration(A, mu, tol, max_iter)
2     n = size(A, 1);
3     v = randn(n, 1); v = v / norm(v);
4     [L, U, P, Q] = lu(A - mu * speye(n));
5     iter_log = [];
6     for k = 1:max_iter
7         w = Q * (U \ (L \ (P * v)));
8         v_new = w / norm(w);
9         lambda = v_new' * A * v_new;
10        iter_log = [iter_log; lambda];
11        if norm(v_new - v) < tol, break; end
12        v = v_new;
13    end
14 end

```

Listing 2: 反迭代法

## 4 高级求解器实现

经典的算法倾向于收敛到模最大的特征值。然而，在物理问题中，我们通常关注最小特征值。此外，为了获得极高精度的单个特征值，我们需要更快的局部收敛算法。

### 4.1 Shift-and-Invert Lanczos 算法

Lanczos 算法是一种迭代方法，用于求解大规模稀疏矩阵的特征值问题和线性方程组。该算法由 Cornelius Lanczos 在 1950 年提出，是 Krylov 子空间方法的重要代表。该算法通过构造一个三对角矩阵，将原矩阵的特征值问题转化为更容易求解的形式。

设  $\mathbf{A}$  是  $n$  阶实对称矩阵。Lanczos 方法通过从一个随机选取的初始向量  $\mathbf{b}_0$  开始，构建一个子空间  $S_j = \text{span}(\mathbf{b}_0, \mathbf{b}_1, \dots, \mathbf{b}_j)$ 。在每一步迭代中，新向量  $\mathbf{b}_{j+1}$  的生成过程

可以看作是将  $\mathbf{A}\mathbf{b}_j$  投影到已知子空间  $S_j$  上，然后去除该投影分量，从而得到与之前所有向量正交的新向量。

不同于一般的正交化过程需要与所有之前的向量进行运算，Lanczos 的天才发现在于：对于对称矩阵，每一步迭代只需要通过三项递归式即可保证正交性。

设第  $j$  步得到的向量为  $\mathbf{b}_j$ ，我们构建下一个向量  $\mathbf{b}_{j+1}$  为  $\mathbf{A}\mathbf{b}_j$  与前两项的线性组合：

$$\mathbf{b}_{j+1} = \mathbf{A}\mathbf{b}_j - \alpha_j \mathbf{b}_j - \beta_{j-1} \mathbf{b}_{j-1}$$

其中系数  $\alpha_j$  和  $\beta_{j-1}$  的选取原则是使新向量  $\mathbf{b}_{j+1}$  的模长最小。由此推导出的系数计算公式为：

$$\alpha_j = \frac{(\mathbf{A}\mathbf{b}_j)\mathbf{b}_j}{\mathbf{b}_j^2}, \quad \beta_{j-1} = \frac{(\mathbf{A}\mathbf{b}_j)\mathbf{b}_{j-1}}{\mathbf{b}_{j-1}^2}$$

经过  $n$  步迭代（或在  $m < n$  步提前终止），我们将得到一组双正交向量  $B = [\mathbf{b}_0, \mathbf{b}_1, \dots, \mathbf{b}_{n-1}]$ ，使得原矩阵  $A$  被转化为三对角矩阵  $T$ ：

$$T = (B^*)^T A B = \begin{pmatrix} \alpha_0 & \beta_0 & & \\ \beta_0 & \alpha_1 & \beta_1 & \\ & \beta_1 & \ddots & \ddots \\ & & \ddots & \alpha_{n-1} \end{pmatrix}$$

此时， $T$  的特征值即为原矩阵  $\mathbf{A}$  的特征值近似解。

根据上述推导，我们给出 Lanczos 算法的具体步骤如下：

- 初始化：随机选取初始向量  $\mathbf{b}_0$ 。
- $\mathbf{b}_1 = \mathbf{A}\mathbf{b}_0 - \alpha_0 \mathbf{b}_0$ ，其中  $\alpha_0 = \frac{(\mathbf{A}\mathbf{b}_0)\mathbf{b}_0}{\mathbf{b}_0^2}$
- 对于  $j = 1, 2, \dots$ ，执行以下步骤：
- $\mathbf{b}_{j+1} = \mathbf{A}\mathbf{b}_j - \alpha_j \mathbf{b}_j - \beta_{j-1} \mathbf{b}_{j-1}$
- $\alpha_j = \frac{(\mathbf{A}\mathbf{b}_j)\mathbf{b}_j}{\mathbf{b}_j^2}$ ， $\beta_{j-1} = \frac{\mathbf{b}_j^2}{\mathbf{b}_{j-1}^2}$
- 终止条件：当  $\beta_j = 0$  时，迭代结束，此时达到了最小多项式的秩。

```

1 function [evals, T, B] = lanczos_solver(A, v0, m)
2     n = size(A, 1);
3     B = zeros(n, m); alpha = zeros(m, 1); beta = zeros(m-1, 1);
4     b_curr = v0 / norm(v0); B(:, 1) = b_curr; b_prev = zeros(n, 1);
5     beta_prev = 0;
6     for j = 1:m
7         u = A * b_curr;
```

```

8     alpha(j) = b_curr' * u;
9     r = u - alpha(j) * b_curr - beta_prev * b_prev;
10    if j < m
11        beta_curr = norm(r);
12        if beta_curr < 1e-10, break; end
13        beta(j) = beta_curr;
14        b_next = r / beta_curr;
15        B(:, j+1) = b_next; b_prev = b_curr; b_curr = b_next;
16        beta_prev = beta_curr;
17    end
18 end
19 T = diag(alpha) + diag(beta, 1) + diag(beta, -1);
20 evals = sort(eig(T));
21 end

```

Listing 3: Lanczos

## 4.2 瑞利商迭代 (RQI)

瑞利商迭代 (Rayleigh Quotient Iteration) 是一种寻找单个特征值的高效算法。其核心思想是在反幂法的基础上, 利用当前的瑞利商作为位移。具体步骤如下:

- 计算瑞利商:  $\mu_k = \frac{\mathbf{v}_k^T \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^T \mathbf{v}_k}$
- 求解线性方程组:  $(\mathbf{A} - \mu_k \mathbf{I}) \mathbf{w}_{k+1} = \mathbf{v}_k$
- 归一化:  $\mathbf{v}_{k+1} = \mathbf{w}_{k+1} / \|\mathbf{w}_{k+1}\|$

对于对称矩阵, RQI 具有立方收敛速度, 即误差以  $\epsilon_{k+1} \approx C\epsilon_k^3$  的速度下降。

```

1 function [lambda, v, iter_log] = rqi_solver(A, v0, tol, max_iter)
2     n = size(A, 1);
3     I = speye(n);
4     v = v0 / norm(v0);
5     lambda = v' * A * v;
6     iter_log = [];
7     for k = 1:max_iter
8         iter_log = [iter_log; lambda];
9         residual = norm(A * v - lambda * v);
10        if residual < tol, break; end
11        try
12            w = (A - lambda * I) \ v;
13        catch
14            w = (A - (lambda + 1e-8) * I) \ v;
15        end

```

```

16     v = w / norm(w);
17     lambda = v' * A * v;
18 end
19 end

```

Listing 4: RQI

## 5 理论复杂度分析

### 5.1 时间复杂度分析

#### 5.1.1 幂法

幂法的计算核心在于单步迭代的累积开销与总迭代次数的乘积。在每一次迭代中，主要运算包括稀疏矩阵-向量乘法、向量归一化以及 Rayleigh 商的计算。针对二维 Helmholtz 方程的五点差分格式，离散矩阵  $A \in \mathbb{R}^{n \times n}$ （其中  $n = N^2$ ）每行仅有 5 个非零元素。因此，SpMV 操作仅需  $5N^2$  次浮点运算。加上向量归一化（ $2N^2$ ）、Rayleigh 商计算（利用中间结果仅需  $N^2$ ）以及收敛性检查（ $N^2$ ），单步迭代的总计算量约为  $9N^2$ ，即具有  $O(N^2)$  的线性复杂度。

然而，幂法的总耗时受限于其收敛速度。收敛率由主特征值与次大特征值的比值  $\rho = |\lambda_2/\lambda_1|$  决定。对于 Helmholtz 问题， $\rho$  通常接近于 1（例如  $0.9 \sim 0.98$ ），导致收敛缓慢。为达到预设精度  $\varepsilon$ ，所需迭代次数  $k$  满足  $k \approx O(\log(1/\varepsilon))$ 。综上所述，幂法的总时间复杂度为  $T_{\text{power}}(N) = O(N^2 \log(1/\varepsilon))$ 。

#### 5.1.2 反迭代法

反迭代法通过引入位移  $\mu$  显著加速了收敛，但其代价是将简单的矩阵乘法转变为求解线性方程组  $(A - \mu I)w = v$ 。该算法的整体复杂度取决于线性方程组求解器的选择：

若采用**直接法**（如针对带状矩阵的 LU 分解），由于矩阵带宽为  $N$ ，初始的分解过程需要  $O(N^4)$  的运算量。分解完成后，每次迭代中的前向和回代求解仅需  $O(N^3)$ 。

若采用**迭代法**（如预条件共轭梯度法 PCG），位移后的矩阵  $A - \mu I$  条件数通常较差（ $\kappa \approx O(N^2)$ ），导致 PCG 内部需要  $O(N)$  次迭代才能收敛。因此，反迭代法外部的每一步实际上消耗了  $O(N \cdot N^2) = O(N^3)$  的计算量。

尽管单步成本较高，但反迭代法在  $\mu$  接近特征值时表现出二次收敛特性，通常仅需极少的步数即可收敛。因此，其总复杂度通常由求解线性方程组的开销主导。

#### 5.1.3 Lanczos 算法

在单步迭代中，Lanczos 同样以稀疏矩阵-向量乘法（SpMV）为核心，基础开销与幂法相当（ $O(N^2)$ ）。Lanczos 算法通常仅需较小的子空间维数（ $m \ll N$ ）即可精确逼近

矩阵谱边缘的特征值（基态或高频态）。最后对  $m \times m$  三对角矩阵求解特征值的开销仅为  $O(m^3)$ ，相对于大规模矩阵运算可忽略不计。因此，Lanczos 算法的总时间复杂度约为  $O(mN^2)$ 。它在保持线性复杂度的同时，能比幂法提取更多的谱信息。

#### 5.1.4 瑞利商迭代

瑞利商迭代是反迭代法的变体，其位移量  $\lambda_k$  在每一步都会动态更新。单步开销是 RQI 的主要瓶颈。由于位移  $\lambda_k$  随迭代变化，每一步都必须重新进行矩阵分解。若使用直接法，单步代价高达  $O(N^4)$ （分解）或  $O(N^3)$ （求解）。

然而，RQI 的优势在于其惊人的立方收敛速度。对于实对称矩阵，通常仅需 3 ~ 5 步即可达到机器精度。极少的迭代次数弥补了昂贵的单步开销。因此，RQI 非常适合在 Lanczos 算法提供良好的初始猜测后，用于特征值的高精度计算。

## 5.2 空间复杂度分析

空间复杂度的分析主要考量矩阵存储与求解过程中的辅助空间。

对于矩阵  $A$ ，利用压缩稀疏行（CSR）格式存储仅需  $O(N^2)$  空间，这远优于稠密格式的  $O(N^4)$ ，是处理大规模网格的关键。基础向量存储同样维持在  $O(N^2)$  级别。

- 幂法与 RQI:** 仅需存储当前迭代向量和辅助向量，空间复杂度最低，为  $O(N^2)$ 。但需注意，若 RQI 使用直接求解器，动态 LU 分解产生的填充元可能导致瞬时空间峰值达到  $O(N^3)$ 。
- 反迭代法:** 若使用直接法，LU 分解因子的存储需求为  $O(N^3)$ ，是内存瓶颈所在。
- Lanczos 算法:** 为了在最后一步还原 Ritz 向量（近似特征向量），必须存储整个 Krylov 子空间的基底  $B \in \mathbb{R}^{N^2 \times m}$ 。随着迭代步数  $m$  的增加，其空间需求线性增长。这是 Lanczos 算法相对于幂法的主要内存代价。

表 1: 算法对比 ( $N$  为网格边长，矩阵维数  $n = N^2$ )

算法	单步时间复杂度	收敛速度	总空间复杂度	适用场景
幂法 (稀疏)	$O(N^2)$	线性	$O(N^2)$	获取模最大特征值
幂法 (稠密)	$O(N^4)$	线性	$O(N^4)$	不实用
反迭代 (直接法)	$O(N^3)$	线性	$O(N^3)$	中小规模，求特定特征值
反迭代 (PCG)	$O(N^3)$	线性	$O(N^2)$	超大规模，内存受限时
Lanczos	$O(N^2)$	超线性	$O(mN^2)$	快速获取谱边缘概况
RQI	$O(N^3)$	立方	$O(N^3)$	单特征值高精度计算

## 6 数值实验与结果分析

### 6.1 实验 1：正确性验证与物理模态

我们首先在  $N = 40$  的网格上验证算法的正确性。图 1 展示了通过 Lanczos 算法计算得到的基态和最高频模态。基态呈现出光滑的单峰结构。通过与 MATLAB 内置 `eigs` 函数对比（表 2），绝对误差极小，验证了算法实现的正确性。




图 1: Lanczos 算法计算得到的基态（左）与高频态（右）波形图

表 2: Lanczos 计算值与标准值的对比（采用最近邻匹配）

特征值类型	Lanczos (计算值)	真值 (eigs)	绝对误差
低频/基态部分			
基态 +0	19.729553	19.729553	1.67e-12
基态 +1	49.265992	49.265992	1.27e-12
基态 +2	49.265992	49.265992	1.49e-12
基态 +3	78.802431	78.802431	1.05e-10
基态 +4	98.300761	98.300761	2.66e-08
基态 +5	98.300761	98.300761	2.66e-08
高频/最大部分			
最大-5	13349.699239	13349.699239	4.93e-09
最大-4	13349.699239	13349.699239	5.01e-09
最大-3	13369.197569	13369.197569	2.00e-11
最大-2	13398.734008	13398.734008	1.82e-11
最大-1	13398.734008	13398.734008	7.28e-12
最大-0	13428.270447	13428.270447	6.18e-11



## 6.2 实验 2：时间复杂度分析

我们测试了从  $N = 20$  到  $N = 200$  不同网格规模下 Lanczos 算法的运行时间。结果如图 2 所示。运行时间与  $O(N^2)$  相近，表明算法的线性复杂度非常适合大规模问题。




图 2: 算法运行时间与矩阵自由度的关系

## 6.3 实验 3：RQI 收敛速度测试

图 3 展示了瑞利商迭代的立方收敛特征。

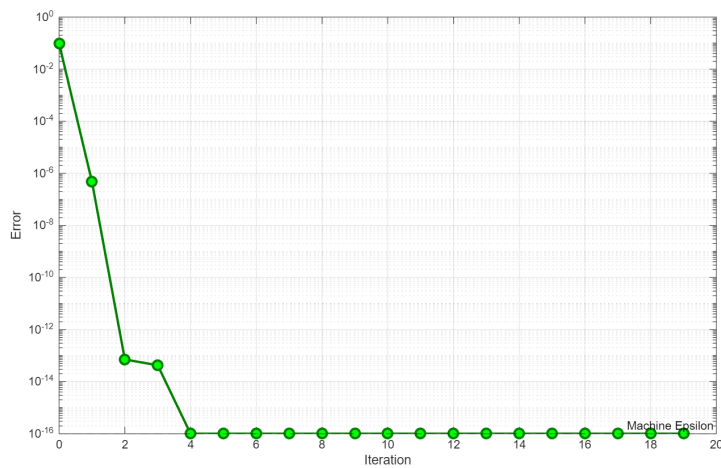


图 3: 瑞利商迭代的立方收敛性

## 6.4 实验 4：算法综合对比

- 求最大特征值：Lanczos 算法的收敛速度显著快于幂法，表现出超线性收敛特征。
- 求特定特征值：RQI 的收敛速度远超反迭代法，后者仅表现为线性收敛。

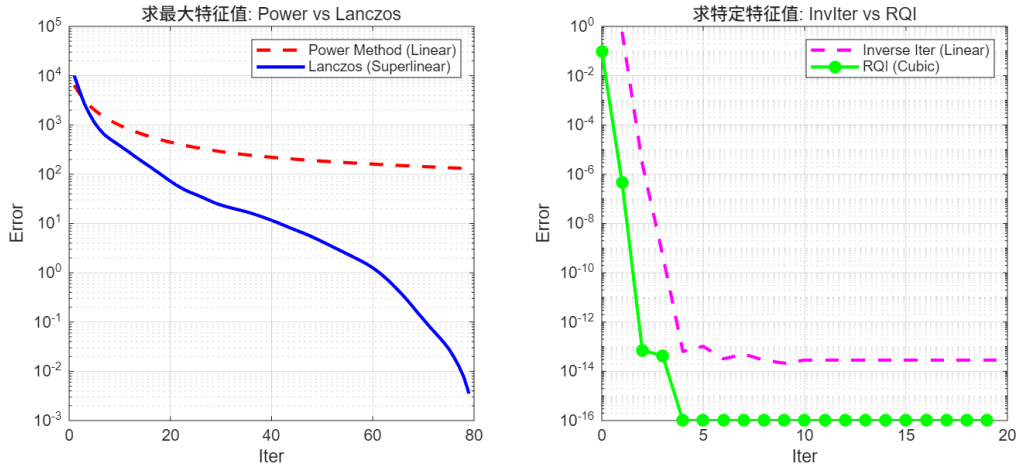


图 4: 对比: (左) 幂法 vs Lanczos; (右) 反迭代 vs RQI

## 7 结论

本项目成功实现并比较了求解二维 Helmholtz 方程特征值问题的多种数值算法。实验结果表明: Lanczos 与 RQI 算法在收敛阶数和计算效率上均优于幂法与反迭代法。实际应用中, 建议使用 Lanczos 快速定位, 再结合 RQI 进行精确计算。