

1 基础算法

1.1 反幂法

设矩阵 A 有按摸最小特征值 λ , 则有:

$$\begin{aligned} \mathbf{A}\mathbf{X} &= \lambda\mathbf{X} \\ \implies \mathbf{A}^{-1}\mathbf{X} &= \frac{1}{\lambda}\mathbf{X} \end{aligned}$$

若记 $\mu = \frac{1}{\lambda}$, 则 μ 为 \mathbf{A}^{-1} 的按摸最大特征值。以此类推, 若要计算矩阵 A 的按摸最小特征值, 只需使用幂法计算其逆矩阵的按摸最大特征值:

$$\begin{cases} \mathbf{Y}^{(k)} = \frac{\mathbf{X}^{(k)}}{\|\mathbf{X}^{(k)}\|_{\infty}} \\ \mathbf{X}^{(k+1)} = \mathbf{A}^{-1}\mathbf{Y}^{(k)} \end{cases}$$

如此规范化迭代计算, 会由于矩阵求逆运算而在实际计算中并不稳定, 因此采用下面的变换:

$$\begin{cases} \mathbf{Y}^{(k)} = \frac{\mathbf{X}^{(k)}}{\|\mathbf{X}^{(k)}\|_{\infty}} \\ \mathbf{A}\mathbf{X}^{(k+1)} = \mathbf{Y}^{(k)} \end{cases}$$

通过求解方程组 $\mathbf{A}\mathbf{X}^{(k+1)} = \mathbf{Y}^{(k)}$ 来代替矩阵求逆并迭代。

1.2 Doolittle 分解

将矩阵 A 分解成下三角矩阵 L 和上三角矩阵 U 的乘积:

$$\begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{pmatrix} = \begin{pmatrix} 1 & 0 & \cdots & 0 \\ l_{21} & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ l_{n1} & l_{n2} & \cdots & 1 \end{pmatrix} \begin{pmatrix} u_{11} & u_{12} & \cdots & u_{1n} \\ 0 & u_{22} & \cdots & u_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & a_{nn} \end{pmatrix}$$

然后分别解方程组:

$$\begin{cases} \mathbf{L}\mathbf{M} = \mathbf{Y}^{(k)} \\ \mathbf{U}\mathbf{X}^{(k+1)} = \mathbf{M} \end{cases}$$

迭代求解。

2 代码实现

2.1 数据结构

```
typedef struct Matrix{
    int Dimension;
    double **OMat;
    double **LMat;
    double **UMat;
}matrix;
```

其中 Dimension 为矩阵维度、 OMat 为矩阵的元素数组、 LMat 为矩阵做 Doolittle 分解后的下三角矩阵 L ， UMat 为矩阵做 Doolittle 分解后的上三角矩阵 U ，如此设计数据结构使得算法具有普适性，能够对不同维度的矩阵做处理。

2.2 Doolittle 分解

```
void Doolittle(matrix Mat){
    for (int k = 0; k < Mat.Dimension; k++){
        Mat.LMat[k][k] = 1; // 对角线上的元素为1
        // 计算 U 矩阵的第 k 行
        for (int j = k; j < Mat.Dimension; j++){
            Mat.UMat[k][j] = Mat.OMat[k][j];
            for (int p = 0; p < k; p++) {
                Mat.UMat[k][j] -= Mat.LMat[k][p] * Mat.UMat[p][j];
            }
        }
        // 计算 L 矩阵的第 k 列
        for (int i = k + 1; i < Mat.Dimension; i++){
            Mat.LMat[i][k] = Mat.OMat[i][k];
            for (int p = 0; p < k; p++) {
                Mat.LMat[i][k] -= Mat.LMat[i][p] * Mat.UMat[p][k];
            }
            Mat.LMat[i][k] /= Mat.UMat[k][k];
        }
    }
}
```

以上算法将对矩阵 Mat 做 Doolittle 分解，以便接下来的求解。

2.3 利用 Doolittle 分解的结果求解方程组

```
void SolveFunction(matrix Mat, double *Bias, double *Solution){
    double *y = (double *)malloc(Mat.Dimension * sizeof(double));
    // 前代法求解 Ly = b
    for (int i = 0; i < Mat.Dimension; ++i) {
        double sum = 0;
        for (int j = 0; j < i; ++j) {
            sum += Mat.LMat[i][j] * y[j];
        }
        y[i] = Bias[i] - sum;
    }
    // 回代法求解 Ux = y
    for (int i = Mat.Dimension - 1; i >= 0; --i) {
        double sum = 0;
        for (int j = i + 1; j < Mat.Dimension; ++j) {
            sum += Mat.UMat[i][j] * Solution[j];
        }
        Solution[i] = (y[i] - sum) / Mat.UMat[i][i];
    }
    // 释放内存
    free(y);
}
```

上面的算法利用 Doolittle 分解的结果求解出 $\mathbf{X}^{(k+1)}$ 以便后续反幂法迭代的计算。

2.4 反幂法迭代

```
double InversePowerMethod(matrix Mat, double *InitialX, double *
    Vector, double epsilon){
    double *XK = (double *)malloc(Mat.Dimension * sizeof(double));
    double *NextXK = (double *)malloc(Mat.Dimension * sizeof(double
        ));
    double Max, Change; int flag = 0;

    for (int i = 0; i < Mat.Dimension; i++){XK[i] = InitialX[i];}
    do {
        Max = 0, Change = 0;
```

```
for (int i = 0; i < Mat.Dimension; i++){Max = (fabs(XK[i])
    > Max) ? fabs(XK[i]) : Max;}
for (int i = 0; i < Mat.Dimension; i++){Vector[i] = XK[i] /
    Max;}
SolveFunction(Mat, Vector, NextXK);
for (int i = 0; i < Mat.Dimension; i++){
    Change = (fabs(NextXK[i] - XK[i]) > Change) ? fabs(
        NextXK[i] - XK[i]) : Change;
}
for (int i = 0; i < Mat.Dimension; i++){XK[i] = NextXK[i];}
}while(Change > epsilon);
double lambda; Max = 0;
for (int i = 0; i < Mat.Dimension; i++){
    Max = (fabs(NextXK[i]) > Max) ? fabs(NextXK[i]) : Max;
}
lambda = 1 / Max; free(XK), free(NextXK);
return lambda;
}
```

3 实验结果

3.1 矩阵 1

| k | $\mathbf{X}^{(k+1)}$ | | | | | $\mathbf{Y}^{(k)}$ | | | | | λ^{-1} |
|-----|----------------------|---------|--------|--------|------|--------------------|------|-----|------|-------|----------------|
| 0 | 630 | -1120 | 630 | -120 | 5 | 1 | 1 | 1 | 1 | 1 | 1120 |
| 1 | 146253 | -297849 | 196175 | -45114 | 2377 | 0.6 | -1 | 0.6 | -0.1 | 0.004 | 297849 |
| 2 | 149113 | -304047 | 200595 | -46245 | 2447 | 0.5 | -1 | 0.7 | -0.2 | 0.008 | 304047 |
| 3 | 149157 | -304142 | 200661 | -46261 | 2447 | 0.5 | -1.0 | 0.7 | -0.2 | 0.01 | 304142 |
| 4 | 149158 | -304143 | 200662 | -46261 | 2448 | 0.5 | -1.0 | 0.7 | -0.2 | 0.01 | 304143 |
| 5 | 149158 | -304143 | 200662 | -46261 | 2448 | 0.5 | -1.0 | 0.7 | -0.2 | 0.01 | 304143 |
| 6 | 149158 | -304143 | 200662 | -46261 | 2448 | 0.5 | -1.0 | 0.7 | -0.2 | 0.01 | 304143 |
| 7 | 149158 | -304143 | 200662 | -46261 | 2448 | 0.5 | -1.0 | 0.7 | -0.2 | 0.01 | 304143 |

表 1: 矩阵 1 的迭代

由于数位较多，因此在此展示社区较多小数部分，计算得出 $\lambda = 0.000003285$ ，按摸最小特征向量 $\mathbf{X} = (0.49042, -1.00000, 0.65976, -0.15210, 0.00805)^T$ 。

3.2 矩阵 2

| k | $\mathbf{X}^{(k+1)}$ | | | | $\mathbf{Y}^{(k)}$ | | | | λ^{-1} |
|-----|----------------------|------|-------|------|--------------------|------|-------|------|----------------|
| 0 | 0.00 | 2.00 | -0.00 | 1.00 | 1.00 | 1.00 | 1.00 | 1.00 | 2.00 |
| 1 | -0.62 | 5.62 | -2.38 | 3.50 | 0.00 | 1.00 | -0.00 | 0.50 | 5.62 |
| 2 | -0.93 | 8.08 | -3.43 | 5.04 | -0.11 | 1.00 | -0.42 | 0.62 | 8.08 |
| 3 | -0.94 | 8.09 | -3.44 | 5.05 | -0.12 | 1.00 | -0.43 | 0.62 | 8.09 |
| 4 | -0.94 | 8.09 | -3.45 | 5.06 | -0.12 | 1.00 | -0.43 | 0.62 | 8.09 |
| 5 | -0.94 | 8.09 | -3.45 | 5.06 | -0.12 | 1.00 | -0.43 | 0.62 | 8.09 |
| 6 | -0.94 | 8.09 | -3.45 | 5.06 | -0.12 | 1.00 | -0.43 | 0.62 | 8.09 |

表 2: 矩阵 2 的迭代

由于数位较多, 因此在此展示社区较多小数部分, 计算得出按摸最小特征值 $\lambda = 0.12355$, 对应的特征向量为 $\mathbf{X} = (-0.11573, 1.00000, -0.42569, 0.62477)^T$ 。

4 结果分析

- 从实验结果来看, 矩阵 \mathbf{A}_1 的按摸最小特征值更接近于 0, 但是迭代次数却比矩阵 \mathbf{A}_2 要多一次, 这并不符合预期。但是通过观察迭代表格, 发现矩阵 1 从第 2 次计算开始就离最终结果比较接近了, 而矩阵 2 要更多一次, 所以可能因为矩阵 1 计算结果的数值更大, 相比矩阵 2 更难达到指定精度, 因此迭代次数更多, 但收敛速度更快;
- 在实验中, 我们尝试估计每次迭代的特征值, 但在计算过程中可能会遇到数值问题。特别是在计算 $\mathbf{X}^{(k+1)}/\mathbf{Y}^{(k)}$ 时, 由于分母中的特征向量可能包含非常小的数值, 这可能导致数值不稳定性。为了解决这个问题, 我们可以采取一些数值稳定性的技巧, 比如在计算中避免除以接近零的数值, 或者采用其他数值稳定的方法来估计特征值。