



计算方法

刘景铖

计算机软件新技术国家重点实验室
南京大学



回顾与补充

上节课: 随机游走 (Random walk), Page Rank


- 记 X_t 为时间 t 随机游走所处的状态, 则转移矩阵 $P_{i,j} = \Pr[X_{t+1} = j | X_t = i]$
- 记 $p_t(i)$ 为时间 t 在状态 i 的概率, 则有 $\overrightarrow{p_{t+1}} = \overrightarrow{p_t} \cdot P$
- 不可约: 强连通
- 周期: $\gcd\{ t \mid (P^t)_{i,i} > 0 \}$, 周期为 1 称为非周期性的

对于有限, 不可约, 非周期的马尔可夫链, 有以下事实:

1. 存在一个稳态分布 $\vec{\pi}$.
2. 随着 $t \rightarrow \infty$, $\overrightarrow{p_t}$ 都会收敛到 $\vec{\pi}$, 无论从什么样的 $\overrightarrow{p_0}$ 开始.
3. 稳态分布是唯一的
4. $\pi(i) = \frac{1}{h_i}$



谱图理论 (Spectral graph theory)



谱分析: 特征值 + 特征向量
+ 相关的线性代数

图论与组合结构:

- 连通性 (Cheeger不等式)
- 图染色
- 聚类(Clustering)
- Mixing of random walks
- Expander graphs (efficient network, superconcentrators)

计算机科学:

- Pagerank
- 稀疏化Sparsification
- 迭代法解线性方程
- 电阻网络
- Expander codes (LDPC, Tanner codes)
- 不可近似性(Dinur's proof of the PCP theorem)
- 去随机化 (Derandomization)



矩阵的幂

回顾已经多次出现的矩阵的幂

- 对于可以对角化的矩阵 A , 收敛只需要特征值的幂是收敛的 (特别地, 谱半径 $\rho(A) = 1$ 也有可能是收敛的)

$$\begin{aligned}x &= \alpha_1 v_1 + \alpha_2 v_2 + \cdots + \alpha_n v_n \\A^k x &= \lambda_1^k \alpha_1 v_1 + \lambda_2^k \alpha_2 v_2 + \cdots + \lambda_n^k \alpha_n v_n\end{aligned}$$

- 但一般来说, 可能需要使用: 谱半径 $\rho(A) < 1$ 当且仅当 $\lim_{k \rightarrow \infty} A^k = 0$
 - 课后练习: 考虑 $\begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix}$ 的特征值? $\begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix}^k = ?$
 - 注意: 随机游走的转移矩阵一定不会是 $\begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix}$, 对应的只会是 $\begin{bmatrix} 1/2 & 1/2 \\ 0 & 1 \end{bmatrix}$
- 随机游走: $\overrightarrow{p_{t+1}} = \overrightarrow{p_t} \cdot P$, 转移矩阵 $P := D^{-1}A$, 及其相似的对角阵 $W = D^{-\frac{1}{2}}AD^{-\frac{1}{2}}$
 - 这节课: 马尔可夫链基本定理在无向图上成立: 对于连通的, 非二分图, 存在唯一的稳态分布, 且会收敛
 - 完整证明可参照Olle Häggström的Finite Markov chains and algorithmic applications



Graph spectrum

考虑图的邻接矩阵，它的代数性质（如特征值与特征向量）能否与图本身的组合性质（连通性，是否二分图）相对应？

图的邻接矩阵的例子：完全图 $A = J - I = \vec{1} \vec{1}^T - I$
 J 的特征值和特征向量是什么？

$$J \vec{1} = n \vec{1}$$



Graph spectrum

考虑图的邻接矩阵，它的代数性质（如特征值与特征向量）能否与图本身的组合性质相对应？

图的邻接矩阵的例子：二分图

- 引理：对于二分图 G ，如果 α 是 $A(G)$ 的一个特征值，且重数为 k ，那么 $-\alpha$ 也是 $A(G)$ 的一个特征值，重数也是 k
- 特征值的重数(multiplicity)
 - 代数重数(algebraic multiplicity)：特征多项式里面，根的重复次数
 - 几何重数(geometric multiplicity)：特征值对应的特征空间的维度
 - 对于可对角化的矩阵（特别地，对于无向图的邻接矩阵，它们是一样的）



Graph spectrum

引理：对于二分图 G ，如果 α 是 $A(G)$ 的一个特征值，且重数为 k ，那么 $-\alpha$ 也是 $A(G)$ 的一个特征值，重数也是 k

证明：把 A 表示为 $U \begin{bmatrix} U & V \\ 0 & B \end{bmatrix} V^T$

假设 $\begin{pmatrix} x \\ y \end{pmatrix}$ 是 A 的一个特征向量，对应特征值为 α ：

$$\begin{pmatrix} By \\ B^T x \end{pmatrix} = \begin{bmatrix} 0 & B \\ B^T & 0 \end{bmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \alpha \begin{pmatrix} x \\ y \end{pmatrix}$$

因此 $B^T x = \alpha y, By = \alpha x$ 。再考虑 $\begin{pmatrix} x \\ -y \end{pmatrix}$

$$A \begin{pmatrix} x \\ -y \end{pmatrix} = \begin{bmatrix} 0 & B \\ B^T & 0 \end{bmatrix} \begin{pmatrix} x \\ -y \end{pmatrix} = \begin{pmatrix} -By \\ B^T x \end{pmatrix} = \begin{pmatrix} -\alpha x \\ \alpha y \end{pmatrix} = -\alpha \begin{pmatrix} x \\ -y \end{pmatrix}$$

因此 $-\alpha$ 也是 A 的特征值

最后，注意到： α 的重数为 $k \Leftrightarrow$ 存在 k 个线性无关的特征向量对应的特征值 α

对每一个分别取反后依然是线性无关的，因此 $-\alpha$ 的重数也为 k



Graph spectrum

事实上，引理的反方向也是对的。

引理：设 $A(G)$ 的特征值为 $\alpha_1 \geq \alpha_2 \geq \dots \geq \alpha_n$, 如果 $\forall i, \alpha_i = -\alpha_{n-i+1}$, 那么 G 一定是二分图

证明：首先证明：对于任意奇数 $k, \sum_i \alpha_i^k = 0$

A 的特征值为 $\alpha_1, \alpha_2, \dots, \alpha_n$ 则 A^k 的特征值为 $\alpha_1^k, \alpha_2^k, \dots, \alpha_n^k$, 因此对于任意奇数 k ,

$$\text{trace}(A^k) = \sum_i \lambda_i^k = 0$$

组合含义： $(A^k)_{i,j} =$ 长度为 k 的从 i 到 j 的行走方案的数目

$$\text{trace}(A^k) = \sum_i (A^k)_{i,i} = 0, \text{ 又因为 } (A^k)_{i,i} \geq 0, \text{ 所以 } (A^k)_{i,i} = 0$$

即，对于任意奇数 k ，长度为 k 的环路不存在。因此，一定是二分图



Largest eigenvalue of adjacency matrix

图的邻接矩阵A的最大特征值 $\alpha_{max} \leq \deg_{max}(G)$

证明：设 v 为对应最大特征值的特征向量，有 $Av = \alpha_1 v$

令 $v_j = \max_i v_i > 0$ ，则 $(Av)_j = (\alpha_1 v)_j$

$$\Rightarrow \alpha_1 v_j = \sum_i A_{j,i} v_i \leq \deg_{max}(G) \cdot v_j$$

$$\Rightarrow \alpha_{max} \leq \deg_{max}(G)$$



Laplacian matrix

给定图 G , 它的拉普拉斯矩阵 $L(G)$ 定义为 $L(G) := D(G) - A(G)$, 其中 $D(G)$ 是对角线上为度数的矩阵

对于 d -正则图, $L(G) = dI - A(G)$, 因此正则图的拉普拉斯矩阵和邻接矩阵的特征空间是一样的。但一般图上并不成立。

可以写出 $L(G) = \sum_{e \in E} L_e$, 其中 L_e 是只有 e 这一条边的图的拉普拉斯矩阵

另外: $x^T L x = \sum_{ij \in E} (x_i - x_j)^2$



Laplacian matrix

给定图 G , 它的拉普拉斯矩阵 $L(G)$ 定义为 $L(G) := D(G) - A(G)$, 其中 $D(G)$ 是对角线上为度数的矩阵

性质: $\vec{1}$ 是 $L(G)$ 的一个特征向量, 对应特征值是0

性质: $L(G) \geq 0$



Connectedness

定理：给定图 G ，它是连通的当且仅当 $L(G)$ 的特征值0的重数为1

证明(\Leftarrow)：先考虑 G 是不连通的情况。此时我们需要证明 $L(G)$ 的特征值0的重数大于1.

$$L(G) = \begin{bmatrix} V_1 & V_2 \\ V_1 & L(G_1) & 0 \\ V_2 & 0 & L(G_2) \end{bmatrix}$$

有2组线性无关的特征向量，对应特征值为0



Connectedness

定理：给定图 G ，它是连通的当且仅当 $L(G)$ 的特征值0的重数为1

证明(\Rightarrow)：接下来考虑 G 是连通的。假设 $Lx = 0$ ，则 $x^T L x = \sum_{ij \in E} (x_i - x_j)^2 = 0$

因此 $(x_i - x_j)^2 = 0, \forall ij \in E$ ，即 $x_i = x_j, \forall ij \in E$

因为 G 是连通的，所以也有 $x_i = x_j, \forall i, j \in V$

因此 $x = c\vec{1}$



Second eigenvalue

把 $L(G)$ 的特征值记为 $0 = \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$

刚刚的定理证明了： G 是非连通的当且仅当 $\lambda_2 = 0$, 或者说 G 是连通的当且仅当 $\lambda_2 > 0$

更一般地（课后练习）：

$\lambda_k = 0$ 当且仅当 G 有至少 k 个连通分量。



Robust connectedness

连通性和二分图在组合上也非常容易刻画，为什么需要特征值？

事实上，可以更加量化特征值的刻画：

- λ_2 非常小，当且仅当 G 非常接近于不连通(i.e. 存在非常稀疏的割).
- λ_k 非常小，当且仅当 G 非常接近于存在 k 个连通分量(i.e. k 个不相交的非常稀疏的分割).
- 对于邻接矩阵的特征值 $\lambda_n \approx -\lambda_1$ 当且仅当 G 中存在接近于二分的分量



Perron-Frobenius定理

设 A 是非负的，不可约且非周期的矩阵（不一定对称）。

1. 最大特征值的重数是1
2. 对应的特征向量中，每个维度都是非零且同号的
3. $|\lambda_i| < \lambda_1$, 对于 $2 \leq i \leq n$.

证明可参见：“Algebraic graph theory” Chapter 8, by Godsil and Royle



Graph conductance

Recall that G is disconnected if and only if $\lambda_2 = 0$.

Cheeger's inequality will show that G is “close” to be disconnected if and only if λ_2 is “small”.

We will first define precisely what it means to be close to be disconnected.

The conductance of a set $S \subseteq V$ is defined as

$$\phi(S) := \frac{|\delta(S)|}{\text{vol}(S)},$$

where $\text{vol}(S) := \sum_{v \in S} \deg(v)$.

When the graph is d -regular, $\phi(S) := \frac{|\delta(S)|}{d|S|}$.

Note: the expansion of a set S is defined as $\frac{|\delta(S)|}{|S|}$; For d -regular graphs, they're basically the same.

The conductance of a graph G is defined as $\phi(G) := \min_{S: \text{vol}(S) \leq m} \phi(S)$.

Note that $0 \leq \phi(G) \leq 1$.



Expander graphs and sparse cuts

A graph G with constant $\phi(G)$ (e.g. $\phi(G) = 0.1$) is called an expander graph.

A set S with small $\phi(S)$ is called a sparse cut.

Both concepts are very useful.

Finding a sparse cut is useful in designing divide-and-conquer algorithms, and have applications in

- image segmentation
- data clustering
- community detection
- VLSI-design
-



Spectral partitioning algorithm

A popular heuristic used in practice.

1. Compute an eigenvector $x \in \mathbb{R}^n$ corresponding to the second smallest eigenvalue of \mathcal{L} .
2. Sort the vertices so that $x_1 \geq x_2 \geq \dots \geq x_n$.

3. Let $S_i := \begin{cases} \{1, \dots, i\} & \text{if } i \leq \frac{n}{2} \\ \{i + 1, \dots, n\} & \text{if } i \geq \frac{n}{2} \end{cases}$

Return $\min_{1 \leq i \leq n} \phi(S_i)$.

This is simple and can be implemented in near-linear time.

It performs very well in practice, especially in image segmentation.



Normalized matrices

To state Cheeger's inequality nicely, we introduce normalized adjacency and Laplacian matrices.

Let $\mathcal{A} = D^{-\frac{1}{2}}AD^{-\frac{1}{2}}$ be the normalized adjacency matrix.

Let $\mathcal{L} = D^{-\frac{1}{2}}LD^{-\frac{1}{2}}$ be the normalized Laplacian matrix.

Note that $\mathcal{L} = I - \mathcal{A}$.

When the graph is d -regular, $\mathcal{A} = \frac{1}{d}A$ and $\mathcal{L} = \frac{1}{d}L$.

Claim. Let $\alpha_1 \geq \dots \geq \alpha_n$ be the eigenvalues of \mathcal{A} , and $\lambda_1 \leq \dots \leq \lambda_n$ be the eigenvalues of \mathcal{L} .

Then, $1 = \alpha_1 \geq \dots \geq \alpha_n \geq -1$, and $0 = \lambda_1 \leq \dots \leq \lambda_n \leq 2$.



Cheeger's inequality

Cheeger's Inequality [Cheeger 70, Alon-Milman 85]

$$\frac{\lambda_2}{2} \leq \phi(G) \leq \sqrt{2\lambda_2}$$

The first inequality is called the easy direction, and the second inequality is called the hard direction. We give some intuition in the case when G is a d -regular graph.

For the easy direction: think of λ_2 as a “relaxation” of the graph conductance problem.

$$\phi(G) \approx \min_{x \perp 1 : x \text{ is binary}} \frac{\sum_{ij \in E} (x_i - x_j)^2}{d \sum_{i \in V} x_i^2} \quad \text{and} \quad \lambda_2 = \min_{x \perp 1} \frac{\sum_{ij \in E} (x_i - x_j)^2}{d \sum_{i \in V} x_i^2}.$$

For the hard direction: given an optimizer x for λ_2 , we want to produce a set S with $\phi(S) \leq \sqrt{2\lambda_2}$. The idea is to use the spectral partitioning algorithm: for a “fractional” x , we try to round it to an integral (binary) solution x . This is known as “rounding”.