

# 最大割问题 (Max-Cut)

秦睿哲

## 一、半正定规划 (Semi-Definite Programming)

首先我们考虑线性规划:

$$\begin{cases} \min \sum_{i=1}^n \alpha_i x_i \\ AX \leq 0 \end{cases} \quad X = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$$

如果是凸优化,则需要满足两个条件: ①目标函数是下凸函数; ②可行域 (Feasible Domain) 是一个凸区域 (Convex Region)

而如果是半正定规划 SDP, 对于  $\{x_{ij} \mid 1 \leq i, j \leq n\}$

目标是得到  $\min \sum_{i,j} \alpha_{ij} x_{ij}$

$$X = \begin{pmatrix} x_{11} & \cdots & x_{1n} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{nn} \end{pmatrix}$$

限制条件与线性规划略有区别。共同点是均为关于  $\{x_{ij}\}$  的线性方程组; 不同的是这里  $X$  必须是一个半正定矩阵。这里半正定矩阵  $X$  可以理解成, 在变量空间  $R^{n^2}$  中, 对于  $\forall y \in R^n$ , 都有  $y^T X y \geq 0$ 。当  $y$  固定的时候, 该不等式定义了  $R^{n^2}$  上的一个经过原点的半空间。 $y$  取不同值的时候, 就形成了无穷个经过原点的半空间的交, 从而形成了一个空间中的圆锥。

## 二、最大割 (Max-Cut)


输入:  $G = (V, E) \rightarrow$  无向有权图,  $\forall v_i, v_j \in V$ , 两点边上的权值为  $\omega(e_{ij}) = \omega_{ij} \geq 0$

输出:  $S \subseteq V$ , s.t.  $\omega(S, V \setminus S) = \sum_{i \in S, j \notin S} \omega_{ij}$  最大

### 问题 (A)

定义割向量  $\{y_1, \dots, y_n\}$ , 其中  $y_i$  的取值为  $y_i = \begin{cases} +1 & i \in S \\ -1 & i \in V \setminus S \end{cases}$

则最大割问题的数学模型等价于优化问题  $\max \sum_{i \in S, j \notin S} \omega_{ij} = \frac{1}{2} \sum_{i < j} \omega_{ij} (1 - y_i y_j)$



$$y_i \in \{\pm 1\} \Rightarrow v_i \in S^n$$

### 问题 (B)

在单位球面上

$$\begin{cases} \max \frac{1}{2} \sum_{i < j} \omega_{ij} (1 - \langle v_i, v_j \rangle) \\ \forall v_i \in S^n \end{cases}$$

可以想象，问题 (B) 把定义域从  $\pm 1$  扩大到单位球面上任何一个点都可以，所以问题 (A) 的解一定是问题 (B) 的解之一，但是问题 (B) 的解不能全是问题 (A) 的解。

$$\text{令 } x_{ij} = \langle v_i, v_j \rangle$$

$$\text{则原问题就变成了 } \begin{cases} \max \frac{1}{2} \sum_{i < j} \omega_{ij} (1 - x_{ij}) \\ \mathbf{X} = \begin{pmatrix} x_{11} & \cdots & x_{1n} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{nn} \end{pmatrix} \text{ 是半正定的} \\ x_{ii} = 1, x_{ij} = x_{ji} \end{cases}$$


$$\forall \mathbf{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}, \mathbf{y}^T \mathbf{X} \mathbf{y} = \|y_1 v_1 + \cdots + y_n v_n\|^2 \geq 0, \text{ 所以 } \mathbf{X} \text{ 一定是半正定的。}$$

### 三、Max-Cut 算法

1、将问题 (A) 转化成问题 (B)，得到  $\{v_1, v_2, \dots, v_n\} \subseteq S^n$


2、在  $S^n$  上随机选取一个向量  $r$ ，令  $H$  为与  $r$  垂直的超平面。选择  $S: \{i \mid \langle v_i, r \rangle \geq 0\}$  以及

$V \setminus S: \{i \mid \langle v_i, r \rangle < 0\}$ ，则  $S, V \setminus S$  为最大割的结果。



注意到，此时  $\omega(S, V \setminus S)$  的期望  $E[\omega(S, V \setminus S)] = \sum_{i < j} \omega_{ij} \Pr[\text{sgn}(\langle v_i, r \rangle) \neq \text{sgn}(\langle v_j, r \rangle)]$

这里的  $\text{sgn}$  函数是符号函数，返回内部参数的正负。



可从图上看到，

$$\begin{aligned} & \Pr[\text{sgn}(\langle v_i, r \rangle) \neq \text{sgn}(\langle v_j, r \rangle)] \\ &= \frac{2 \arccos(\langle v_i, v_j \rangle)}{2\pi} = \frac{2\theta}{2\pi} \\ &= \frac{\arccos(\langle v_i, v_j \rangle)}{\pi} \end{aligned}$$

$$\begin{aligned} & \Rightarrow E[\omega(S, V \setminus S)] \\ &= \frac{1}{\pi} \sum_{i < j} \omega_{ij} \arccos(\langle v_i, v_j \rangle) = \Delta \end{aligned}$$

再考虑最优值 OPT 的一个上界  $U$ ，得到我们结果的近似比  $= \frac{\Delta}{\text{OPT}} \geq \frac{\Delta}{U}$ （越接近 1，结果越好）。由于问题 (B) 是由问题 (A) 放松得到的，即问题 (B) 比问题 (A) 的面更加广泛，也就是说问题 (B) 的最优解一定大于问题 (A) 的最优解。

$$\text{问题 (B) 的目标函数 } U = \frac{1}{2} \sum_{i < j} \omega_{ij} (1 - \langle v_i, v_j \rangle),$$

那么就可以推出我们的近似比  $\geq$

$$\begin{aligned} & \frac{2 \sum_{i < j} \omega_{ij} \arccos(\langle v_i, v_j \rangle)}{\pi \sum_{i < j} \omega_{ij} (1 - \langle v_i, v_j \rangle)} \\ & \geq \frac{2}{\pi} \min \frac{\arccos(\langle v_i, v_j \rangle)}{(1 - \langle v_i, v_j \rangle)} \end{aligned} \quad \text{考虑函数 } f(\theta) = \frac{\theta}{1 - \cos \theta} \text{ 的极值}$$

$$\geq 0.878$$

即，我们的近似比的期望  $\geq 0.878$

参考文献:

Goemans M X. *Improved Approximation Algorithms for Maximum Cut and Satisfiability Problems using Semidefinite Programming*[J]. Journal of the Acm, 1995, 42(6):1115-1145.