



# 计算方法

刘景铨

计算机软件新技术国家重点实验室  
南京大学



# 补充: Von-Neumann Minimax Theorem

## Von-Neumann Minimax Theorem.

$$\max_{x \in \Delta^m} \min_{y \in \Delta^n} x^T A y = \min_{y \in \Delta^n} \max_{x \in \Delta^m} x^T A y$$

证明(cont'd): 把它们都转化为标准形式

$$\begin{aligned} & \max \quad t \\ & t - \sum_{i=1}^m x_i a_{ij} \leq 0 \quad \forall j = 1, \dots, n \\ & \sum_{i=1}^m x_i = 1 \\ & x_i \geq 0 \quad \forall i = 1, \dots, m \end{aligned}$$

×  $y_j$

×  $r$

$$\begin{aligned} & \min \quad r \\ & r - \sum_{j=1}^n a_{ij} y_j \geq 0 \quad \forall i = 1, \dots, m \\ & \sum_{i=1}^n y_i = 1 \\ & y_i \geq 0 \quad \forall i = 1, \dots, n \end{aligned}$$

×  $x_i$

×  $t$

Equality follows directly from strong duality!



# Strong duality theorem


强对偶性：假设 primal 和 dual LP 都存在可行解，则它们的最优解相等

证明方法很多，其中包括分析单纯形算法的

这节课：通过凸优化分析(Farkas lemma)给出证明

参考资料：

Understanding and Using Linear Programming  
By Jiří Matoušek , Bernd Gärtner





# Separation theorem

凸几何的性质: Separation theorem

定义: 一个集合 $S$ , 如果对 $\forall x, y \in S, \forall \alpha \in [0, 1]$ 都有 $\alpha x + (1 - \alpha)y \in S$ , 则称 $S$ 为凸集(convex set)

定义: 如果 $S$ 中的所有的点列的极限点都在 $S$ 中, 则称集合 $S$ 为闭集(closed set)

给定一个闭的凸集 $S \subseteq \mathbb{R}^n$ , 和集合外的点 $v \notin S$ 。  
 $\exists w \in \mathbb{R}^n$  使得 $\langle w, v \rangle > \langle w, x \rangle$  对任意 $x \in S$ 成立



# Separation theorem

给定一个闭的凸集  $S \subseteq \mathbb{R}^n$ ，和集合外的点  $v \notin S$ 。

$\exists w \in \mathbb{R}^n$  使得  $\langle w, v \rangle > \langle w, x \rangle$  对任意  $x \in S$  成立

证明(sketch): 找到唯一的  $x_* \in S$ ，使得与  $v$  最接近

1. 存在性: 由于  $S$  是闭集, 由Weierstrass定理, 可知其最接近  $v$  的点可以在  $S$  中取到
2. 唯一性: 假设有两个点, 考虑它们的中点, 只会与  $v$  更加接近
3.  $x_*$  为最接近的点当且仅当  $\forall x \in S, \langle x - x_*, v - x_* \rangle \leq 0$

考虑  $y := (1 - t)x_* + tx \in S$ , 则

$$\begin{aligned}\|y - v\|_2^2 &= \|x_* - v - t(x_* - x)\|_2^2 \\ &= \|v - x_*\|_2^2 - 2t\langle x - x_*, v - x_* \rangle + t^2\|x - x_*\|_2^2\end{aligned}$$

$$x_* \text{ 为最接近的点} \Leftrightarrow -2t\langle x - x_*, v - x_* \rangle + t^2\|x - x_*\|_2^2 \geq 0, \forall x, t > 0$$

$$\Leftrightarrow \frac{t}{2}\|x - x_*\|_2^2 \geq \langle x - x_*, v - x_* \rangle, \forall x, t > 0$$

$$\Leftrightarrow 0 \geq \langle x - x_*, v - x_* \rangle, \forall x$$

令  $w = v - x_*$ , 由  $\|v - x_*\|_2^2 > 0$  可知  $\langle v, v - x_* \rangle > \langle x_*, v - x_* \rangle$ , 进而  $\langle v, w \rangle > \langle x_*, w \rangle$

另一方面, 前面已经证明  $\forall x \in S, \langle x - x_*, v - x_* \rangle \leq 0$

这意味着  $\langle x, v - x_* \rangle \leq \langle x_*, v - x_* \rangle$ , 即  $\langle x, w \rangle \leq \langle x_*, w \rangle$ , 因此  $\langle v, w \rangle > \langle x_*, w \rangle \geq \langle x, w \rangle, \forall x \in S$



## Farkas Lemma

$Ax = b, x \geq 0$  无解当且仅当存在  $y$  使得  $y^T A \geq 0$  且  $y^T b < 0$

证明: ( $\Leftarrow$ ) 如果这样的  $y$  存在, 显然无解, 否则  $y^T Ax \geq 0$  与  $y^T b < 0$  矛盾

( $\Rightarrow$ ) 考虑  $S = \{Ax: x \geq 0\}$ .  $S$  是闭的凸集. 无解意味着  $b \notin S$ .

由 Separation theorem, 存在  $w \in \mathbb{R}^n$  使得  $\langle w, b \rangle > \langle w, s \rangle$  对任意  $s \in S$  成立. 令  $y = -w$ , 则有  $y^T b < y^T Ax, \forall x \geq 0$

由于  $0 \in S$ , 因此  $y^T b < 0$

另一方面,  $y^T A \geq 0$ , 否则可以找到  $x \geq 0$  使得  $y^T Ax = -\infty$ , 与  $y^T b < y^T Ax$  矛盾



# Strong LP duality

假设 primal 和 dual LP 都存在可行解, 则它们的最优解相等  
证明:

$$\max \langle c, x \rangle$$

$$Ax = b$$

$$x \geq 0.$$

$$\min \langle b, y \rangle$$

$$y^T A \geq c$$

只需要证明, 如果 primal 的 objective 小于  $t$ , 则 dual objective 也小于  $t$

“primal objective 小于  $t$ ” 本身可以表示成 LP

$$\langle c, x \rangle - s = t$$

$$Ax = b$$

$$x \geq 0, s \geq 0$$

$$\begin{bmatrix} A & 0 \\ c^T & -1 \end{bmatrix} \begin{pmatrix} x \\ s \end{pmatrix} = \begin{pmatrix} b \\ t \end{pmatrix}$$
$$x \geq 0, s \geq 0$$

这个  $x$  和  $s$  的方程组有解当且仅当 “primal objective 大于等于  $t$ ”

这个  $x$  和  $s$  的方程组无解当且仅当 “primal objective 小于  $t$ ”



## Strong LP duality

假设primal和dual LP都存在可行解, 则它们的最优解相等

证明(cont'd): 由Farkas lemma

$$\begin{bmatrix} A & 0 \\ c^T & -1 \end{bmatrix} \begin{pmatrix} x \\ s \end{pmatrix} = \begin{pmatrix} b \\ t \end{pmatrix}$$
$$x \geq 0, s \geq 0$$

无解当且仅当存在  $y, z$  使得

$$\begin{pmatrix} y^T & z \end{pmatrix} \begin{bmatrix} A & 0 \\ c^T & -1 \end{bmatrix} \geq 0$$
$$\begin{pmatrix} y^T & z \end{pmatrix} \begin{pmatrix} b \\ t \end{pmatrix} < 0$$

即  $y^T A + zc^T \geq 0, -z \geq 0, y^T b + zt < 0$

考虑  $z = 0$ , 则有  $y^T A \geq 0, y^T b < 0$ , primal not feasible;

考虑  $z \neq 0$ , 则有  $\frac{1}{-z} y^T A \geq c^T, \frac{1}{-z} y^T b < t$ , 因此  $\frac{1}{-z} y^T$  为dual LP中的可行解, 且目标函数值  $< t$ 。





# 课程回顾

核心思想:

- 收敛性: 能合理近似的算法, 至少需要收敛
- 复杂性: 计算复杂性
- 条件性 (鲁棒性)
  - 回顾条件数的定义
- 压缩性
  - SVD
- 正交性
  - 正交多项式
  - 共轭



# 课程回顾

## 课程话题

- 插值与拟合
  - 方程求根：二分法，不动点迭代法，牛顿法
  - 拉格朗日插值：误差分析
  - Chebyshev插值
  - Chebyshev多项式：极值性质
  - 函数空间上的线性代数、不同的范数及比较
  - 最小二乘法：几何推导、微积分推导
  - 正交化过程：Gram-Schmidt
  - 正交系统中的最小二乘法：三角级数、函数逼近
  - 傅里叶变换：多项式的两种表示，正交性与FFT算法
- 特征值与随机游走（线性代数方法）
- 最优化与线性规划



# 课程回顾

## 课程话题

- 插值与拟合
- 特征值与随机游走（线性代数方法）
  - 求解线性方程组——一种特殊的方程求根问题
  - 解决线性方程组的通用方法—高斯消元法：pivoting
  - 矩阵的算子范数：作为线性映射对长度的改变
  - 线性方程组的条件数（比较：根的敏感性）
  - 解决线性方程组的迭代方法：Jacobi, Gauss-Seidel, Richardson, Conjugate-gradient
  - 分析线性迭代方程：谱半径
  - 特征值的min-max刻画（Courant-Fischer）
  - 矩阵的多项式：线性迭代方程, Cayley-Hamilton, 逆矩阵的多项式, 幂迭代
  - 计算特征值与特征向量、Singular value decomposition (SVD)
  - ...
- 最优化与线性规划



# 课程回顾

## 课程话题

- 插值与拟合
- 特征值与随机游走（线性代数方法）
  - 图上的随机游走：概率转移方程（线性迭代），稳态分布（特征向量），mixing time（收敛速度）与spectral gap
  - 马尔可夫链：基本定理、周期性、不可约；Pagerank
  - 图的谱理论：拉普拉斯矩阵，特征值、特征向量与图的连通结构，图上随机游走的谱分析
  - 电阻电路网络：拉普拉斯线性方程组，等效电阻，电势能，等效电阻距离
  - hitting time：拉普拉斯线性方程组，cover time
  - Spectral embedding：使用特征向量进行“嵌入”
- 最优化与线性规划



# 课程回顾

## 课程话题

- 插值与拟合
- 特征值与随机游走（线性代数方法）
- 最优化与线性规划
  - 线性规划的不同形式
  - 整数线性规划与松弛化
  - LP的顶点：整数规划的最优解与松弛化的LP最优解
  - Duality(对偶性)：经济学解释，Min-max定理与对偶性，组合优化，零和博弈，随机算法分析
  - \* 在线决策问题与Multiplicative weight update: LP与minimax定理



# What we did not cover (in detail)

- Expander codes
  - Further reading: Essential coding theory by V. Guruswami, A. Rudra, M. Sudan
- Low rank matrix approximation (via SVD)
  - Compression
  - De-noising
  - Matrix completion
  - Further reading: Algorithmic Aspects of Machine Learning by Ankur Moitra; A simpler approach to matrix completion by Ben Recht
- Generalizations of Cheeger's inequality
  - Further reading: Eigenvalues and polynomials by Lap Chi Lau
- Graph sparsification
  - Further reading:  $Lx=b$  by Nisheeth Vishnoi
- Markov chain Monte Carlo and high dimensional integral
  - Further reading: Techniques in Optimization and Sampling by Yin Tat Lee and Santosh Vempala
  - [The Markov Chain Monte Carlo Revolution by Persi Diaconis](#), and the references therein