



对偶理论 (Duality)

张伯雷

南京邮电大学 计算机学院、通达学院

<https://bolei-zhang.github.io/course/opt.html>

回顾

- 凸集

- 集合中任意两点所组成的线段仍然在该集合中

- 凸函数

- 定义一：如果 $\text{dom}f$ 为凸集，且 $f(\theta x + (1 - \theta)y) \leq \theta f(x) + (1 - \theta)f(y)$ 对所有的 $x, y \in \text{dom}f$, $0 \leq \theta \leq 1$ 成立
- 定义二：对于可微函数 f ，如果 $\text{dom}f$ 为凸集，则 f 为凸函数当且仅当 $f(y) \geq f(x) + \nabla f(x)^T(y - x)$, 对所有的 $x, y \in \text{dom}f$ 成立
- 定义三：对于二阶可微函数 f ，如果 $\text{dom}f$ 为凸集，则 f 为凸函数当且仅当 $\nabla^2 f(x) \geq 0$, 对所有 $x \in \text{dom}f$ 成立

- 凸优化问题

- 标准形式
- 局部最优=全局最优
- 最优条件： $x \in X$ 最优 $\Leftrightarrow \nabla f_0^T(x)(y - x) \geq 0$ for all $y \in X$



目录

- 拉格朗日与共轭函数
- 对偶间隙
- 最优性条件：Slater 条件
- 最优条件的两个解释
 - 几何解释
 - 鞍点解释
- 互补松弛与KKT 条件

一般优化问题

- 优化问题

$$\min f_0(x).$$

$$\text{s.t. } f_i(x) \leq 0, \quad i = 1, \dots, m$$

$$h_i(x) = 0, \quad i = 1, \dots, p$$

- $x \in R^n$
- $D = \bigcap_{i=0}^m \text{dom}f_i \cap \bigcap_{i=1}^p \text{dom}h_i$
- $X = \{x \in D \text{ 且所有约束条件可以满足}\}$
- p^* 为最优值

不一定是凸优化问题!

拉格朗日函数

- 优化问题

$$\begin{aligned}
 & \min \quad f_0(x) \\
 \text{s. t.} \quad & f_i(x) \leq 0, \quad i = 1, \dots, m \\
 & h_i(x) = 0, \quad i = 1, \dots, p
 \end{aligned}$$

- 拉格朗日函数 (Lagrangian function)

- 给该问题中的每一个约束指定一个拉格朗日乘子 λ, ν ，以乘子为加权系数将约束增加到目标函数中
- $L: \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p \rightarrow \mathbb{R}$, 其中定义域为 $D \times \mathbb{R}^m \times \mathbb{R}^p$,

$$L(x, \lambda, \nu) = f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{i=1}^p \nu_i h_i(x)$$



拉格朗日对偶函数

- 拉格朗日对偶函数(Lagrange Function/Dual Function)


$$g(\lambda, v) = \inf_{x \in D} L(x, \lambda, v)$$

$$= \inf_{x \in D} (f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{i=1}^p v_i h_i(x))$$

- $\lambda \in \mathbb{R}^m, v \in \mathbb{R}^p$

对偶函数性质一

- 弱对偶理论：如果 $\lambda \geq 0$, 则 $g(\lambda, v) \leq p^*$




实线：目标函数 f_0

虚线： $f_1 \leq 0$

点虚线：拉格朗日 $f_0 + \lambda f_1: \lambda = 0.1, 0.2, \dots, 1.0$

可行解集：[-0.46, 0.46]



对偶函数性质二

- 性质：对偶函数为凹函数

$$g(\lambda, \nu) = \inf_{x \in \mathcal{D}} L(x, \lambda, \nu) = \inf_{x \in \mathcal{D}} \left(f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{i=1}^p \nu_i h_i(x) \right)$$

- 命题：若 f_1, \dots, f_m 为凸函数，则 $f(x) = \max\{f_1(x), \dots, f_m(x)\}$ 为凸函数
- 命题：若 $f(x, y)$ 对所有 $y \in A$ 为关于 x 的凸函数，则 $f(x) = \sup_{y \in A} f(x, y)$ 为凸函数



例 1

$$\min x^T x$$

$$\text{s. t. } Ax = b$$

$$x \in \mathbb{R}^n, b \in \mathbb{R}^p, A \in \mathbb{R}^{p \times n}$$



例2

$$\begin{aligned} & \min \quad C^T x \\ \text{s. t. } & Ax = b, x \geq 0 \end{aligned}$$



例3

$$\begin{aligned} & \min \quad x^T W x \\ \text{s.t.} \quad & x_i = \pm 1, i = 1, \dots, m \end{aligned}$$

函数的共轭

- 函数共轭：

f^* 是 f 的共轭，若 $f^*(y) = \sup_{x \in \text{dom } f} (y^T x - f(x))$

- 拉格朗日对偶函数(Lagrange Function/Dual Function)

$$g(\lambda, v) = \inf_{x \in D} L(x, \lambda, v)$$

$$= \inf_{x \in D} (f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{i=1}^p v_i h_i(x))$$



例

$$\min f(x)$$

$$\text{s. t. } x = 0$$

- 解

例

$$\begin{aligned} & \min f_0(x) \\ s.t. \quad & Ax \leq b, Cx = d \end{aligned}$$

- 解



对偶理论 (Duality)

张伯雷

南京邮电大学 计算机学院、通达学院

<https://bolei-zhang.github.io/course/opt.html>

目录

- 拉格朗日函数

$$L(x, \lambda, v) = f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{i=1}^p v_i h_i(x)$$

- 对偶函数

$$\begin{aligned} g(\lambda, v) &= \inf_{x \in D} L(x, \lambda, v) \\ &= \inf_{x \in D} (f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{i=1}^p v_i h_i(x)) \end{aligned}$$

- 弱对偶理论：如果 $\lambda \geq 0$ ，则 $g(\lambda, v) \leq p^*$
- 性质：对偶函数为凹函数



对偶问题 (dual problem)

- 原问题 (Primal problem)

$$\begin{aligned} & \min f_0(x). \\ \text{s. t. } & f_i(x) \leq 0, \quad i = 1, \dots, m \\ & h_i(x) = 0, \quad i = 1, \dots, p \end{aligned}$$

- 对偶问题 (Dual problem)

$$\begin{aligned} & \max g(\lambda, v) \\ \text{s. t. } & \lambda \geq 0 \end{aligned}$$

- 通过最大化 $g(\lambda, v)$, 可以不断逼近于 p^* 的下界

$$\max_{\lambda \geq 0, v} g(\lambda, v) = \max_{\lambda \geq 0, v} \inf_{x \in D} L(x, \lambda, v) \leq p^*$$

- 该问题为一个凸优化问题, 最优值为 d^* , 最优解为 (λ^*, v^*)



对偶间隙 (duality gap)

- 对偶问题为凸优化问题
- $p^* - d^*$: 对偶间隙 (duality gap)
- 弱对偶 (weak duality) : $d^* \leq p^*$
 - 对凸优化问题与非凸优化问题都成立
 - 用于找到一个原问题的下界
- 强对偶 (strong duality) : $d^* = p^*$



相对内点集 (relative interior)

定义 5.13 (相对内点集) 给定集合 \mathcal{D} , 记其仿射包为 $\text{affine } \mathcal{D}$ (见定义 2.14). 集合 \mathcal{D} 的**相对内点集** 定义为

$$\text{relint } \mathcal{D} = \{x \in \mathcal{D} \mid \exists r > 0, \text{ 使得 } B(x, r) \cap \text{affine } \mathcal{D} \subseteq \mathcal{D}\}.$$

- $B(x, r)$: 以 x 为中心的球

Slater条件

- 强对偶成立的充分条件

- 对于一个**凸**优化问题

$$\min f_0(x).$$

$$\text{s.t. } f_i(x) \leq 0, \quad i = 1, \dots, m$$

$$Ax = b$$

- Slater条件：对以上的凸优化问题，存在 $x \in \text{relint } D$ ，满足

$$f_i(x) < 0, \quad i = 1, \dots, m, \quad Ax = b$$

- 则称为Slater条件，此时 $d^* = p^*$
- 对大多数凸优化问题，slater条件都成立；对非凸问题，强对偶也可能存在
- 弱Slater条件：若不等式约束为仿射时，只要可行域非空，必有 $d^* = p^*$



例1

- 线性约束的最小二乘问题

$$\begin{aligned} \min \quad & x^T x \\ \text{s. t.} \quad & Ax = b \end{aligned}$$



$$d^* \leq p^*$$

- 几何解释

$$\min f_0(x).$$

$$\text{s.t. } f_i(x) \leq 0, \quad i = 1, \dots, m$$

- $G = \{(f_1(x), f_0(x)) \mid x \in D\}$
- $p^* = \inf\{t \mid (u, t) \in G, u \leq 0\}$
- $g(\lambda) = \inf\{\lambda u + t \mid (u, t) \in G\}$



$$d^* = p^*$$

- 几何解释

$$\begin{aligned} & \min f_0(x) . \\ \text{s.t. } & f_i(x) \leq 0, \quad i = 1, \dots, m \end{aligned}$$

- $G = \{(f_1(x), f_0(x)) \mid x \in D\}$
- $p^* = \inf\{t \mid (u, t) \in G, u \leq 0\}$
- $g(\lambda) = \inf\{\lambda u + t \mid (u, t) \in G\}$


$$d^* = p^*$$

- 鞍点解释

- 极小极大不等式

$$\sup_{\lambda \geq 0} \inf_{x \in D} L(x, \lambda) \leq \inf_{x \in D} \sup_{\lambda \geq 0} L(x, \lambda)$$

$$d^* \leq p^*$$



- 鞍点定理

- 对一般的优化问题

- 拉格朗日函数有鞍点 \Leftrightarrow 该点为原始/对偶问题的最优解，对偶间隙为0

根据对偶间隙求 ϵ 次优解

- 如果 x 是原始问题的可行解， λ, ν 是对偶问题的可行解，则存在

$$f_0(x) - p^* \leq f_0(x) - g(\lambda, \nu)$$

- ϵ -次优解集 (ϵ – suboptimal set)

$$X_\epsilon = \{x | x \in X_f, f_0(x) \leq p^* + \epsilon\}$$

- $\epsilon = f_0(x) - g(\lambda, \nu)$
- 原始问题可行解 x 与对偶问题可行解 λ, ν 对应的对偶间隙

$$p^* \in [g(\lambda, \nu), f_0(x)]$$

$$d^* \in [g(\lambda, \nu), f_0(x)]$$

算法

- 假设一个算法可以产生序列的可行解：

- $\cdot x^{(k)}, (\lambda^{(k)}, \nu^{(k)}), \text{ for } k = 1, 2, \dots$

- 预先设定一个期望的间隙值 ϵ_{abs}

- 不断生成可行解，直至

$$f_0(x^{(k)}) - g(\lambda^{(k)}, \nu^{(k)}) \leq \epsilon_{abs}$$

- 则 $x^{(k)}$ 是 ϵ_{abs} -次优解

互补松弛 (complementary slackness)

- 假设强对偶成立, x^* 为原问题的最优解, λ^*, ν^* 为对偶问题的最优解

$$\begin{aligned}
 f_0(x^*) &= g(\lambda^*, \nu^*) \\
 &= \inf_x \left(f_0(x) + \sum_{i=1}^m \lambda_i^* f_i(x) + \sum_{i=1}^p \nu_i^* h_i(x) \right) \\
 &\leq f_0(x^*) + \sum_{i=1}^m \lambda_i^* f_i(x^*) + \sum_{i=1}^p \nu_i^* h_i(x^*) \\
 &\leq f_0(x^*).
 \end{aligned}$$

- 结论1: x^* 最小化 $L(x, \lambda^*, \nu^*)$.
- 结论2: $\lambda_i^* f_i(x^*) = 0, i = 1, \dots, m$. (互补松弛 complementary slackness)



互补松弛 (complementary slackness)

$$\lambda_i^* f_i(x^*) = 0, \quad i = 1, \dots, m$$

- 如果 $\lambda_i^* > 0$, 则 $f_i(x^*) = 0$
- 如果 $f_i(x^*) < 0$, 则 $\lambda_i^* = 0$

KKT条件（一般可微优化问题）

- 假设 $f_0, f_1, \dots, f_m, h_1, \dots, h_p$ 都是可微的，但不一定为凸函数
- 假设强对偶成立， x^* 为原问题的最优解， λ^*, ν^* 为对偶问题的最优解
- 由于 x^* 最小化 $L(x, \lambda^*, \nu^*)$ ，因此该点的梯度为0

$$\nabla f_0(x^*) + \sum_{i=1}^m \lambda_i^* \nabla f_i(x^*) + \sum_{i=1}^p \nu_i^* \nabla h_i(x^*) = 0.$$

- KKT条件：

$$\begin{aligned}
 f_i(x^*) &\leq 0, & i &= 1, \dots, m \\
 h_i(x^*) &= 0, & i &= 1, \dots, p \\
 \lambda_i^* &\geq 0, & i &= 1, \dots, m \\
 \lambda_i^* f_i(x^*) &= 0, & i &= 1, \dots, m \\
 \nabla f_0(x^*) + \sum_{i=1}^m \lambda_i^* \nabla f_i(x^*) + \sum_{i=1}^p \nu_i^* \nabla h_i(x^*) &= 0,
 \end{aligned}$$

KKT条件（可微凸优化问题）

- 假设 $f_0, f_1, \dots, f_m, h_1, \dots, h_p$ 都是可微的，且该问题为凸优化问题
- KKT条件是强对偶的充分必要条件
- 证明：假设 $(\tilde{x}, \tilde{\lambda}, \tilde{\nu})$ 为满足KKT条件一个可行解

$$\begin{aligned}
 g(\tilde{\lambda}, \tilde{\nu}) &= L(\tilde{x}, \tilde{\lambda}, \tilde{\nu}) \\
 &= f_0(\tilde{x}) + \sum_{i=1}^m \tilde{\lambda}_i f_i(\tilde{x}) + \sum_{i=1}^p \tilde{\nu}_i h_i(\tilde{x}) \\
 &= f_0(\tilde{x}),
 \end{aligned}$$

- 可以得到： $\tilde{x}, (\tilde{\lambda}, \tilde{\nu})$ 满足强对偶，同时为原始与对偶问题的最优解



KKT条件的意义

- 对一般可微的优化问题（不一定为凸）
 - 对偶间隙为 $0 \Rightarrow$ KKT条件成立
- 对可微的凸优化问题
 - 对偶间隙为 $0 \Leftrightarrow$ KKT条件成立
- 意义：
 - 如果一个凸优化问题，存在很多约束条件，则往往难以求解
 - 很多凸优化问题可以通过求解KKT条件来解决



对偶理论 (Duality)

张伯雷

南京邮电大学 计算机学院、通达学院

<https://bolei-zhang.github.io/course/opt.html>



例：等式约束的QP问题


$$\begin{aligned} & \text{minimize} && (1/2)x^T Px + q^T x + r \\ & \text{subject to} && Ax = b, \end{aligned} \quad P \in S_+^n$$

例：最大熵问题


$$\min_x f_0(x) \doteq \sum_{i=1}^n x_i \log x_i \quad : \quad x \geq 0, \quad \mathbf{1}^\top x = 1.$$

例：Water filling 问题

$$\begin{aligned} & \text{minimize} && -\sum_{i=1}^n \log(\alpha_i + x_i) \\ & \text{subject to} && x \succeq 0, \quad \mathbf{1}^T x = 1, \end{aligned}$$



支持向量机 (support vector machine)




SMO算法

- 输入：训练数据集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$
 $x_i \in \mathcal{X} = R^n, y_i \in \mathcal{Y} = \{+1, -1\}, i = 1, 2, \dots, N$ ， 精度 ε
 - 输出：近似解 α
- (1) 取初值 $\alpha^{(0)} = 0$ ，令 $k = 0$
- (2) 选取优化变量 α_1^k, α_2^k ，解析求解两个变量的最优化问题，求得最优解 $\alpha_1^{(k+1)}, \alpha_2^{(k+1)}$ ，更新 α 为 $\alpha^{(k+1)}$ ；
- (3) 若在精度 ε 范围内满足停机条件
- $$\sum_{i=1}^N \alpha_i y_i = 0$$
- $$0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, N$$
- 则转(4);否则令 $k=k+1$,转(2);
- (4) 取 $\hat{\alpha} = \alpha^{(k+1)}$
- $y_i \cdot g(x_i) = \begin{cases} \geq 1, & \{x_i | \alpha_i = 0\} \\ = 1, & \{x_i | 0 < \alpha_i < C\} \\ \leq 1, & \{x_i | \alpha_i = C\} \end{cases}$

$$g(x_i) = \sum_{j=1}^N \alpha_j y_j K(x_j, x_i) + b$$

SVM核方法



作业

1. 求以下问题的KKT条件和对应的最优解：

$$\begin{aligned} \min_{x \in \mathbb{R}^2} \quad & x_1, \\ \text{s.t.} \quad & 16 - (x_1 - 4)^2 - x_2^2 \geq 0, \\ & x_1^2 + (x_2 - 2)^2 - 4 = 0. \end{aligned}$$

2. (1) 以下优化问题是否为凸优化问题，求出最优解；
 (2) 写出该问题的对偶问题，并求出对偶问题的最优解以及对偶间隙

$$\min_{x \in \mathbb{R}, y > 0} \quad e^{-x}, \quad \text{s.t.} \quad \frac{x^2}{y} \leq 0.$$



实验二


- 使用最小二乘对房屋价格（数据集:题目1数据.xlsx）进行拟合，需要对前350行作为拟合，并在351-414行上测试拟合结果，并对测试数据输出评价指标均方误差。
 1. 使用CVXOPT实现最小二乘；
 2. 对优化目标增加L2范数约束；
 3. 对以上情况，分别测试从0.01, 0.1, 1, 10, 100, 1000不同的拉格朗日乘子 λ 的时候，优化的参数在训练数据和测试数据的均方误差，并以拉格朗日乘子 λ 为横坐标（log），均方误差为纵坐标，画出曲线图



作业

- 1: $f(x) = x^{-2}, x \neq 0$, 是否为凸函数, 请说明理由
- 2: 0范数: $\|x\|_0 = x$ 中非零元素的个数 , 是否为范数, 是否为凸函数,
写出证明过程
- 3. 求证: $f(x, y) = x^2/y$ 对所有的 $y > 0$ 都为凸函数
- 4*. 已知 $\forall x, v \in \text{dom } f, g(t) = f(x + tv)$ 是凸函数, 求证f是凸函数

KKT条件的机械学解释



系统的势能：

$$f_0(x_1, x_2) = \frac{1}{2}k_1x_1^2 + \frac{1}{2}k_2(x_2 - x_1)^2 + \frac{1}{2}k_3(l - x_2)^2,$$

系统的均衡点为满足以下约束时的最小势能

$$w/2 - x_1 \leq 0, \quad w + x_1 - x_2 \leq 0, \quad w/2 - l + x_2 \leq 0.$$

KKT条件的机械学解释

- 引入 $\lambda_1, \lambda_2, \lambda_3$ 为拉格朗日乘子，KKT条件为

- 约束条件
- 非负拉格朗日: $\lambda_1, \lambda_2, \lambda_3 \geq 0$
- 互补松弛

$$\lambda_1(w/2 - x_1) = 0, \quad \lambda_2(w - x_2 + x_1) = 0, \quad \lambda_3(w/2 - l + x_2) = 0,$$

- 梯度为0

$$\begin{bmatrix} k_1x_1 - k_2(x_2 - x_1) \\ k_2(x_2 - x_1) - k_3(l - x_2) \end{bmatrix} + \lambda_1 \begin{bmatrix} -1 \\ 0 \end{bmatrix} + \lambda_2 \begin{bmatrix} 1 \\ -1 \end{bmatrix} + \lambda_3 \begin{bmatrix} 0 \\ 1 \end{bmatrix} = 0.$$

