

# 第 5 章：对偶

## (1): Lagrange 对偶

---

授课教师：曹语

课程主页：<https://yucaoyc.github.io/math3806>

# 从无约束到有约束

**背景：**我们已经学习了无约束的凸优化问题，其中的重点是

- 优化问题的最优性条件
- 梯度法和牛顿法

然而工程实际问题往往具有约束：

- 结构设计中，重量、强度、位移都有允许范围；
- 通信与控制中，功率、带宽、稳定性都不能随意违反；
- 生产计划中，资源、需求、预算形成线性或非线性约束。

**下一阶段的目标：**学习如何理解并求解带约束的优化问题。

## 回顾练习

**逐点上确界:** 如果对于任意  $\mathbf{y} \in \mathcal{A}$  , 函数  $g(\mathbf{x}, \mathbf{y})$  关于  $\mathbf{x}$  都是凸的, 则函数  $f(\mathbf{x}) = \sup_{\mathbf{y} \in \mathcal{A}} g(\mathbf{x}, \mathbf{y})$  是关于  $\mathbf{x}$  的凸函数。

**练习:** 判断下面的函数是否是凸/凹的? 并说明为什么?

- $f(\mathbf{x}) = \sup_{\mathbf{y} \in \mathcal{A}} \mathbf{x}^\top \mathbf{y} + h(\mathbf{y})$ , 其中  $h: \mathbb{R}^n \rightarrow \mathbb{R}$
- $f(\mathbf{x}) = \inf_{\mathbf{y} \in \mathcal{A}} \mathbf{x}^\top \mathbf{y} + h(\mathbf{y})$ , 其中  $h: \mathbb{R}^n \rightarrow \mathbb{R}$

## 回顾练习

**逐点上确界：** 如果对于任意  $\mathbf{y} \in \mathcal{A}$ ，函数  $g(\mathbf{x}, \mathbf{y})$  关于  $\mathbf{x}$  都是凸的，则函数  $f(\mathbf{x}) = \sup_{\mathbf{y} \in \mathcal{A}} g(\mathbf{x}, \mathbf{y})$  是关于  $\mathbf{x}$  的凸函数。

**练习：** 判断下面的函数是否是凸/凹的？并说明为什么？

- $f(\mathbf{x}) = \sup_{\mathbf{y} \in \mathcal{A}} \mathbf{x}^\top \mathbf{y} + h(\mathbf{y})$ ，其中  $h : \mathbb{R}^n \rightarrow \mathbb{R}$
- $f(\mathbf{x}) = \inf_{\mathbf{y} \in \mathcal{A}} \mathbf{x}^\top \mathbf{y} + h(\mathbf{y})$ ，其中  $h : \mathbb{R}^n \rightarrow \mathbb{R}$

**答案：** 第一项是仿射函数族的逐点上确界，因此是凸函数；第二项是仿射函数族的逐点下确界，因此是凹函数。

前置背景

Lagrange 对偶函数

Lagrange 对偶问题


总结

我们考虑优化如下问题:

$$\begin{aligned} & \text{minimize} && f_0(\mathbf{x}) \\ & \text{subject to} && h(\mathbf{x}) = 0 \\ & && \mathbf{x} \in \mathbb{R}^2 \end{aligned}$$

右侧的例子为:

$$\begin{aligned} f_0(x_1, x_2) &= x_1^2 + x_2^2 \\ h(x_1, x_2) &= x_1 + x_2 - 1 \end{aligned}$$



## Lagrange 乘子的几何理解

- 如果我们找到了最优点  $\mathbf{x}^*$ ，则在这点附近，沿任意可行方向  $\mathbf{v}$  满足：

$$\nabla f_0(\mathbf{x}^*)^\top \mathbf{v} \geq 0, \quad \mathbf{v} \text{ 可行}$$

对于等式约束，沿切线的正反两个方向通常都可行，因此

$$\nabla f_0(\mathbf{x}^*)^\top \mathbf{v} = 0, \quad \mathbf{v} \text{ 可行}$$

- 对于等式约束，若  $\nabla h(\mathbf{x}^*) \neq \mathbf{0}$ ，可行方向的一阶近似是约束曲线的切线方向，因此

$$\nabla h(\mathbf{x}^*)^\top \mathbf{v} = 0$$

问题：目标函数等高线和约束曲线有什么关系？

因此我们可以看到： $\nabla f_0(\mathbf{x}^*)$  平行于  $\nabla h(\mathbf{x}^*)$ ，即存在  $\nu$  满足

$$\nabla f_0(\mathbf{x}^*) + \nu \nabla h(\mathbf{x}^*) = 0.$$

此处的  $\nu$  被称为 **Lagrange 乘子**

并且我们的问题变成了求解  $(\mathbf{x}^*, \nu)$  来满足

$$\nabla f_0(\mathbf{x}^*) + \nu \nabla h(\mathbf{x}^*) = 0, \quad h(\mathbf{x}^*) = 0$$

这其实就是知名的 **Karush-Kuhn-Tucker (KKT) 条件** 对该特定问题的形式。



Joseph-Louis Lagrange  
(1736 - 1813, 18 世纪  
知名科学家, 图片来自  
wikipedia)

- 这个形式似乎建议我们可以考虑如下的函数

$$L(\mathbf{x}, \nu) = f_0(\mathbf{x}) + \nu h(\mathbf{x})$$

- 如果有多个函数  $h_i(\mathbf{x})$ ,  $i = 1, 2, \dots, p$ , 我们考虑

$$L(\mathbf{x}, \boldsymbol{\nu}) = f_0(\mathbf{x}) + \sum_{i=1}^p \nu_i h_i(\mathbf{x})$$

## 本节课的目标：

- 对于一般的凸优化问题，拓展并建立 Lagrange 对偶函数  
(即上述  $L$  的更一般形式)
- 介绍 Lagrange 对偶问题  
(即关于  $L$ ，先优化  $x$ ，再优化  $\nu$ ；还是顺序倒过来)

前置背景

Lagrange 对偶函数

Lagrange 对偶问题

总结

# Lagrange 函数

考虑标准的优化问题：

$$\begin{aligned} & \text{minimize} && f_0(\mathbf{x}) \\ & \text{subject to} && f_i(\mathbf{x}) \leq 0, \quad i = 1, \dots, m \\ & && h_i(\mathbf{x}) = 0, \quad i = 1, \dots, p \\ & && \mathbf{x} \in \mathcal{D} \end{aligned}$$

其中  $\mathcal{D}$  是变量的定义域，优化变量为  $\mathbf{x} \in \mathcal{D} \subseteq \mathbb{R}^n$ 。

定义该问题的 **Lagrange 函数**  $L : \mathcal{D} \times \mathbb{R}^m \times \mathbb{R}^p \rightarrow \mathbb{R}$  为

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

其中  $\lambda_i, \nu_i$  被称为 **Lagrange 乘子**； $\boldsymbol{\lambda}, \boldsymbol{\nu}$  被称为 **Lagrange 乘子向量**。

# 什么时候是凸优化问题

对于上页的标准形式，如果

- $\mathcal{D}$  是凸集；
- $f_0, f_1, \dots, f_m$  都是凸函数；
- 等式约束  $h_i(\mathbf{x}) = 0$  都是仿射约束，例如  $\mathbf{Ax} = \mathbf{b}$ ；

则该问题称为**凸优化问题**。

- $f_i(\mathbf{x}) \leq 0$  可理解为第  $i$  个工程限制：功率不能超标、库存不能为负等。
- 不等式约束对应的乘子要满足  $\lambda_i \geq 0$ ；等式约束的乘子  $\nu_i$  可正可负。
- $\lambda_i$  可以理解为这个限制的**约束敏感度**：如果该限制稍微放宽，最优值大约会改善多少。 $\nu_i$  也具有类似理解。【具体含义在后面解释】

**Lagrange 对偶函数 (或对偶函数)**  $g : \mathbb{R}^m \times \mathbb{R}^p \rightarrow \mathbb{R} \cup \{-\infty\}$  为

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

- 这里的  $\inf_{\boldsymbol{x} \in \mathcal{D}}$  是只在定义域内取下确界;
- 不等式和等式约束已经被搬进  $L$  中, 不再单独要求  $\boldsymbol{x}$  满足这些约束。

## 对偶函数为什么是凹的

### 定理

无论问题是否是凸的，该函数  $g$  一定是凹函数。

答案：固定  $x$  时， $L(x, \lambda, \nu)$  关于  $(\lambda, \nu)$  是仿射函数； $g$  是这些仿射函数的逐点下确界，所以是凹函数。

## 计算对偶函数的三步

对于一个具体问题，计算  $g(\lambda, \nu)$  通常按如下步骤：

1. 写出  $L = f_0 + \sum_i \lambda_i f_i + \sum_i \nu_i h_i$ ;
2. 把  $\lambda, \nu$  暂时看成常数，对  $x$  求  $\inf L$ ;
3. 如果  $\inf L = -\infty$ ，这组乘子没有给出有效下界；否则得到一个关于乘子的函数  $g$ 。

## 例子 1：一维不等式约束

例子 1: 考虑最简单的一维问题

$$\begin{aligned} & \text{minimize} && x^2 \\ & \text{subject to} && 1 - x \leq 0. \end{aligned}$$

Lagrange 函数为

$$L(x, \lambda) = x^2 + \lambda(1 - x).$$

对  $x$  求下确界:

$$\frac{\partial L}{\partial x} = 2x - \lambda = 0 \quad \Rightarrow \quad x = \frac{\lambda}{2}, \quad g(\lambda) = \lambda - \frac{\lambda^2}{4}.$$

## 例子 2: 二次目标加等式约束

例子 2: 考虑优化问题

$$\begin{aligned} & \text{minimize} && \mathbf{x}^\top \mathbf{x} \\ & \text{subject to} && \mathbf{A}\mathbf{x} = \mathbf{b} \end{aligned}$$

Lagrange 函数为

$$L(\mathbf{x}, \boldsymbol{\nu}) = \mathbf{x}^\top \mathbf{x} + \boldsymbol{\nu}^\top (\mathbf{A}\mathbf{x} - \mathbf{b}).$$

对  $\mathbf{x}$  求最小值:

$$\nabla_{\mathbf{x}} L = 2\mathbf{x} + \mathbf{A}^\top \boldsymbol{\nu} = 0 \quad \Rightarrow \quad \mathbf{x}^* = -\frac{1}{2} \mathbf{A}^\top \boldsymbol{\nu}, \quad g(\boldsymbol{\nu}) = -\frac{1}{4} \boldsymbol{\nu}^\top \mathbf{A} \mathbf{A}^\top \boldsymbol{\nu} - \mathbf{b}^\top \boldsymbol{\nu}.$$

## 例子 3: 线性规划

例子 3: 考虑线性规划问题

$$\begin{aligned} & \text{minimize} && \mathbf{c}^\top \mathbf{x} \\ & \text{subject to} && \mathbf{Ax} = \mathbf{b} \\ & && \mathbf{x} \succeq \mathbf{0} \end{aligned}$$

把  $\mathbf{x} \succeq \mathbf{0}$  写成  $-\mathbf{x} \preceq \mathbf{0}$ , 则

$$L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}) = \mathbf{c}^\top \mathbf{x} + \boldsymbol{\nu}^\top (\mathbf{Ax} - \mathbf{b}) - \boldsymbol{\lambda}^\top \mathbf{x} = (\mathbf{c} + \mathbf{A}^\top \boldsymbol{\nu} - \boldsymbol{\lambda})^\top \mathbf{x} - \mathbf{b}^\top \boldsymbol{\nu}.$$

若  $\mathbf{x}$  前的系数不为  $\mathbf{0}$ , 则  $\inf_{\mathbf{x}} L = -\infty$ ; 否则得到

$$g(\boldsymbol{\lambda}, \boldsymbol{\nu}) = \begin{cases} -\mathbf{b}^\top \boldsymbol{\nu}, & \mathbf{A}^\top \boldsymbol{\nu} - \boldsymbol{\lambda} + \mathbf{c} = \mathbf{0} \\ -\infty & \text{其他情况} \end{cases}$$

前置背景

Lagrange 对偶函数

Lagrange 对偶问题

总结

## 弱对偶性：为什么是下界

### 定理

对于任意的  $\lambda \succeq 0$ ，以及任意的  $\nu$

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

其中  $p^*$  是原问题的最优值。

证明思路：对任意原问题可行点  $\mathbf{x}$ ,

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

因此  $g(\lambda, \nu) = \inf_{\mathbf{z} \in \mathcal{D}} L(\mathbf{z}, \lambda, \nu) \leq L(\mathbf{x}, \lambda, \nu) \leq f_0(\mathbf{x})$ . 对所有可行  $\mathbf{x}$  取下确界，即得到  $g(\lambda, \nu) \leq p^*$ 。

我们称满足  $\lambda \succeq 0$ ,  $g(\lambda, \nu) > -\infty$  的  $(\lambda, \nu)$  是**对偶可行的**。

此时  $g(\lambda, \nu)$  给出了原问题最优值  $p^*$  的一个下界。

# Lagrange 对偶问题

由于

$$g(\boldsymbol{\lambda}, \boldsymbol{\nu}) \leq p^*$$

因此，我们可以考虑最好的下界：

$$\begin{aligned} & \text{maximize} && g(\boldsymbol{\lambda}, \boldsymbol{\nu}) \\ & \text{subject to} && \boldsymbol{\lambda} \succeq \mathbf{0} \end{aligned}$$

该问题被称为**Lagrange 对偶问题**。该问题的最优解  $(\boldsymbol{\lambda}^*, \boldsymbol{\nu}^*)$  被称为**对偶最优解**或**最优 Lagrange 乘子**。对偶问题的最优值记为  $d^*$ ，因此

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

该性质被称为**弱对偶性**。

# 例子 1：一维问题的对偶问题

例子 1：原问题

$$\begin{aligned} & \text{minimize} && x^2 \\ & \text{subject to} && 1 - x \leq 0 \end{aligned}$$

前面已经算得

$$g(\lambda) = \lambda - \frac{\lambda^2}{4}.$$

因此对偶问题是

$$\max_{\lambda \geq 0} \left( \lambda - \frac{\lambda^2}{4} \right).$$

令导数为零：

$$1 - \frac{\lambda}{2} = 0 \quad \Rightarrow \quad \lambda^* = 2, \quad d^* = 1.$$

## 例子 1：为什么最优乘子像约束价格？

将约束稍微放宽为

$$1 - x \leq u \quad \Longleftrightarrow \quad x \geq 1 - u.$$

当  $u \approx 0$  时，新的最优解和最优值为

$$x^*(u) = 1 - u, \quad p^*(u) = (1 - u)^2 \approx 1 - 2u.$$

由于上一页得到  $\lambda^* = 2$ ，该系数  $\lambda^*$  其实就是线性近似部分的系数，

$$p^*(u) \approx p^*(0) - \lambda^* u.$$

所以  $\lambda^* = 2$  的含义是：约束放宽很小的  $u$  个单位时，最优值大约下降  $\lambda^* u$ 。这就是把最优乘子理解为**边际价值**的来源。更严格的说明将在第二部分学完 KKT 条件后再回顾。

## 例子 2：等式约束二次问题的对偶

例子 2：原问题

$$\begin{aligned} & \text{minimize} && \mathbf{x}^\top \mathbf{x} \\ & \text{subject to} && \mathbf{A}\mathbf{x} = \mathbf{b} \end{aligned}$$

的对偶问题是

$$\text{maximize} \quad -\frac{1}{4}\boldsymbol{\nu}^\top \mathbf{A}\mathbf{A}^\top \boldsymbol{\nu} - \mathbf{b}^\top \boldsymbol{\nu}$$

练习：假设  $\mathbf{A}\mathbf{A}^\top$  可逆，最优乘子  $\boldsymbol{\nu}^*$  和对偶最优值  $d^*$  是什么？

## 例子 2：等式约束二次问题的对偶

例子 2：原问题

$$\begin{aligned} & \text{minimize} && \mathbf{x}^\top \mathbf{x} \\ & \text{subject to} && \mathbf{Ax} = \mathbf{b} \end{aligned}$$

的对偶问题是

$$\text{maximize} \quad -\frac{1}{4} \boldsymbol{\nu}^\top \mathbf{AA}^\top \boldsymbol{\nu} - \mathbf{b}^\top \boldsymbol{\nu}$$

**练习：**假设  $\mathbf{AA}^\top$  可逆，最优乘子  $\boldsymbol{\nu}^*$  和对偶最优值  $d^*$  是什么？

**答案：**令  $\mathbf{M} = \mathbf{AA}^\top$ 。由一阶条件  $-\frac{1}{2} \mathbf{M} \boldsymbol{\nu} - \mathbf{b} = \mathbf{0}$  可得

$$\boldsymbol{\nu}^* = -2\mathbf{M}^{-1}\mathbf{b}, \quad d^* = \mathbf{b}^\top \mathbf{M}^{-1}\mathbf{b}.$$

## 例子 3：线性规划的对偶问题

例子 3：原问题为

$$\min \mathbf{c}^\top \mathbf{x} \quad \text{s.t.} \quad \mathbf{Ax} = \mathbf{b}, \quad \mathbf{x} \succeq \mathbf{0}.$$

前面已经算得

$$g(\boldsymbol{\lambda}, \boldsymbol{\nu}) = \begin{cases} -\mathbf{b}^\top \boldsymbol{\nu}, & \mathbf{A}^\top \boldsymbol{\nu} - \boldsymbol{\lambda} + \mathbf{c} = \mathbf{0} \\ -\infty & \text{其他情况} \end{cases}$$

因此对偶问题可写成

$$\begin{aligned} & \text{maximize} && -\mathbf{b}^\top \boldsymbol{\nu} \\ & \text{subject to} && \mathbf{A}^\top \boldsymbol{\nu} - \boldsymbol{\lambda} + \mathbf{c} = \mathbf{0} \\ & && \boldsymbol{\lambda} \succeq \mathbf{0}. \end{aligned}$$

## 例子 3: 消去 $\lambda$

由等式约束

$$A^T \nu - \lambda + c = 0 \quad \Rightarrow \quad \lambda = A^T \nu + c.$$

再结合  $\lambda \succeq 0$ , 得到

$$A^T \nu + c \succeq 0.$$

所以线性规划的对偶问题等价于

$$\begin{array}{ll} \text{maximize} & -b^T \nu \\ \text{subject to} & A^T \nu + c \succeq 0. \end{array}$$

练习：考虑一维优化问题

$$\begin{array}{ll} \text{minimize} & x^2 \\ \text{subject to} & x - 1 \leq 0. \end{array}$$

1. 写出 Lagrange 函数  $L(x, \lambda)$ ;
2. 计算对偶函数  $g(\lambda)$ ;
3. 求最优乘子  $\lambda^*$ ，并从边际价值角度解释为什么它是 0。

练习：考虑一维优化问题

$$\begin{array}{ll} \text{minimize} & x^2 \\ \text{subject to} & x - 1 \leq 0. \end{array}$$

1. 写出 Lagrange 函数  $L(x, \lambda)$ ;
2. 计算对偶函数  $g(\lambda)$ ;
3. 求最优乘子  $\lambda^*$ ，并从边际价值角度解释为什么它是 0。

答案：  $L(x, \lambda) = x^2 + \lambda(x - 1)$ ；  $g(\lambda) = -\lambda - \lambda^2/4$ ； 对偶问题为  $\max_{\lambda \geq 0} -\lambda - \lambda^2/4$ ， 最优解  $\lambda^* = 0$ 。 原问题最优解是  $x^* = 0$ ， 约束  $x^* - 1 < 0$  不紧， 因此它没有边际价值。

差值  $p^* - d^*$  为**最优对偶间隙**；如果

$$d^* = p^*,$$

则我们称之为**强对偶性**。

将在本章第 2 部分学习何时具有强对偶性，以及介绍 KKT 条件。

前置背景

Lagrange 对偶函数

Lagrange 对偶问题

总结

# 总结

- 知道 Lagrange 函数和 Lagrange 对偶函数的定义，并能解释对偶函数为什么是凹函数
- 理解弱对偶性：任意对偶可行点都给出原问题最优值的下界
- 知道 Lagrange 对偶问题的含义，并知道相关的术语名词

## 阅读作业 & 参考资料：

- 课本第 3.3, 5.1, 5.2 章