

第 5 章：对偶

(2)：最优性条件

授课教师：曹语

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

从弱对偶到最优性条件

上一讲我们得到：任意对偶可行点都给出原问题的下界。

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

本节课回答两个进一步的问题：

- 什么时候下界刚好等于最优值？ 这就是强对偶；
- 怎样不用先解对偶问题，也能验证一个点是最优的？ 这就是 KKT 条件。

回顾：原问题与对偶问题

原始问题为

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

其中优化变量为 $\mathbf{x} \in \mathcal{D}$ ，且 \mathcal{D} 为定义域。Lagrange 函数为

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

对偶问题为

$$d^* = \sup_{\boldsymbol{\lambda} \geq \mathbf{0}, \boldsymbol{\nu}} g(\boldsymbol{\lambda}, \boldsymbol{\nu}), \quad g(\boldsymbol{\lambda}, \boldsymbol{\nu}) = \inf_{\mathbf{x} \in \mathcal{D}} L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}).$$

本节目标

学完本节后，希望大家能够：

- 用 Slater 条件判断凸优化问题是否具有强对偶；
- 准确写出 KKT 条件；
- 用 KKT 条件解简单的等式/不等式约束优化问题；
- 解释 Lagrange 乘子为什么可以理解为约束的“边际价格”。

今天的重心是**会判断、会写、会用**，证明细节只保留主线思想。

课前热身：最大熵问题

考虑凸优化问题

$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n x_i \log x_i \\ \text{subject to} & \mathbf{Ax} \preceq \mathbf{b}, \\ & \mathbf{1}^\top \mathbf{x} = 1, \\ \text{domain} & \mathbf{x} \succeq \mathbf{0}. \end{array}$$

这里约定 $0 \log 0 = 0$ 。¹

练习：请写出 Lagrange 函数，并尝试计算对偶函数。

¹非负性在此作为定义域处理，因此计算对偶函数时在 $x_i \geq 0$ 上取下确界，不再配乘子。

热身答案：先写 Lagrange 函数

令 $\lambda \succeq 0$ 对应约束 $Ax \preceq b$ ，令 $\nu \in \mathbb{R}$ 对应 $\mathbf{1}^\top x = 1$ 。

$$\begin{aligned} L(\mathbf{x}, \boldsymbol{\lambda}, \nu) &= \sum_{i=1}^n x_i \log x_i + \boldsymbol{\lambda}^\top (A\mathbf{x} - \mathbf{b}) + \nu(\mathbf{1}^\top \mathbf{x} - 1) \\ &= -\mathbf{b}^\top \boldsymbol{\lambda} - \nu + \sum_{i=1}^n \left[x_i \log x_i + \underbrace{((A^\top \boldsymbol{\lambda})_i + \nu)}_{=: s_i} x_i \right]. \end{aligned}$$

逐个计算可得

$$\inf_{x_i \geq 0} x_i \log x_i + s_i x_i = -e^{-s_i - 1}.$$

热身答案：对偶函数与对偶问题

由上一页得到

$$g(\boldsymbol{\lambda}, \nu) = -\mathbf{b}^\top \boldsymbol{\lambda} - \nu - \sum_{i=1}^n e^{-(\mathbf{A}^\top \boldsymbol{\lambda})_i - \nu - 1}.$$

因此对偶问题为

$$\begin{aligned} & \text{maximize} && -\mathbf{b}^\top \boldsymbol{\lambda} - \nu - \sum_{i=1}^n e^{-(\mathbf{A}^\top \boldsymbol{\lambda})_i - \nu - 1} \\ & \text{subject to} && \boldsymbol{\lambda} \succeq \mathbf{0}, \quad \nu \in \mathbb{R}. \end{aligned}$$

问题：这个对偶问题给出的最优下界什么时候等于原问题最优值？

Slater 条件：强对偶的实用判据

鞍点解释：为什么对偶像一场博弈

KKT 条件：最优点的检查清单

总结

Slater 条件的直观

强对偶通常需要某种“没有卡在边界上的可行性”。Slater 条件说：

对于凸优化问题，只要能找到一个点，使所有**非仿射不等式约束都严格满足**，仿射不等式可仅满足 ≤ 0 ，且满足等式约束，那么通常就有强对偶。

这里“严格满足”的含义是 $f_i(\mathbf{x}) < 0$ ，不是刚好等于 0。

为什么普通内部不够用？

回到最大熵问题中的约束：

$$\mathbf{1}^\top \mathbf{x} = 1, \quad \mathbf{x} \succeq \mathbf{0}.$$

可行点都落在超平面 $\mathbf{1}^\top \mathbf{x} = 1$ 上。因此在整个 \mathbb{R}^n 里，任何可行点附近的小球都会跑出这个超平面。


所以

$$\text{int}\{\mathbf{x} \succeq \mathbf{0}, \mathbf{1}^\top \mathbf{x} = 1\} = \emptyset.$$


但我们仍然认为 $\mathbf{x} \succ \mathbf{0}$ 且 $\mathbf{1}^\top \mathbf{x} = 1$ 是“没有贴在边界上”的概率分布。

问题：应该在什么空间里看“内部”？

相对内点：在自己的平面里是内点



普通内部



若集合本身落在一条直线或一个平面里，普通内部可能为空；相对内部只要求它在**自己的仿射空间**里像内点。也就是说，相对内部不要求在整体 \mathbb{R}^n 里有活动空间，只要求在允许活动的方向里留有余量。

相对内点：正式定义

给定凸集 $C \subseteq \mathbb{R}^n$ ，它的仿射包 $\text{aff } C$ 是包含 C 的最小仿射集合。

$$\text{relint } C = \{\mathbf{x} \in C : \exists r > 0, B(\mathbf{x}, r) \cap \text{aff } C \subseteq C\}.$$

也就是说，只沿着 C 自己所在的仿射空间看， \mathbf{x} 附近的一小块仍然留在 C 里面。

例子：概率单纯形的相对内部是

$$\{\mathbf{x} : \mathbf{x} \succ \mathbf{0}, \mathbf{1}^\top \mathbf{x} = 1\}.$$

Slater 中的“严格”在哪里？

Slater 条件不要求点在整个空间里都能自由移动。

它只要求：

- 仿射结构、定义域造成的低维性是允许的；
- 非仿射不等式约束不能刚好卡在边界上。

因此 Slater 写成

$$\mathbf{x} \in \text{relint } \mathcal{D}, \quad f_i(\mathbf{x}) < 0, \quad \mathbf{Ax} = \mathbf{b}.$$

一句话：在不可避免的平面里，要留有余量；在真正的不等式边界上，不要贴边。

Slater 定理：常用版本

考虑凸优化问题

$$\begin{aligned} & \text{minimize} && f_0(\mathbf{x}) \\ & \text{subject to} && f_i(\mathbf{x}) \leq 0, \quad i = 1, \dots, m, \\ & && \mathbf{Ax} = \mathbf{b}, \end{aligned}$$

其中 f_0, f_i 为凸函数， $\mathbf{Ax} = \mathbf{b}$ 为仿射等式约束，公共定义域记为 \mathcal{D} 。

定理 (Slater 定理)

若存在 $\mathbf{x} \in \text{relint } \mathcal{D}$ 使得

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

且 p^* 有限，则强对偶成立，并且对偶最优值可达到。

Slater 条件的仿射约束版本

如果前 k 个不等式约束 f_1, \dots, f_k 是仿射函数, 那么 Slater 条件可以放宽为:

$$\begin{aligned} f_i(\mathbf{x}) &\leq 0, & i = 1, \dots, k, \\ f_i(\mathbf{x}) &< 0, & i = k + 1, \dots, m, \\ \mathbf{Ax} &= \mathbf{b}, & \mathbf{x} \in \operatorname{relint} \mathcal{D}. \end{aligned}$$

判断 Slater 时, 先问自己:

- 哪些不等式是仿射的?
- 是否存在一个点让所有非仿射不等式都严格小于 0?

简化版的证明见附录。

Slater 判断练习

练习：假设下列问题可行且 p^* 有限。哪些可以直接用 Slater 推出强对偶？

1. 等式约束二次问题

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

2. 线性规划

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

3. 一维问题

$$\min x \quad \text{s.t.} \quad x^2 \leq 0.$$

4. 最大熵问题（第5页）在什么条件下满足 Slater？

Slater 快速判断：答案

1. 可以。只有仿射等式约束，因此 Slater 条件成立。
2. 可以。这里把 $\mathbf{x} \succeq \mathbf{0}$ 写成仿射不等式 $-x_i \leq 0$ ，因此目标、等式和不等式约束都是仿射的，仿射版 Slater 条件成立。
3. 不可以直接用 Slater。唯一可行点是 $x = 0$ ，但 $x^2 < 0$ 不可能成立。这个例子提醒我们：**凸问题不等于自动满足 Slater**；不能用 Slater 也不代表强对偶一定失败。
4. 用仿射版 Slater 时，只需存在 $\mathbf{x} \succ \mathbf{0}$ ，满足 $\mathbf{1}^\top \mathbf{x} = 1$ 且 $\mathbf{Ax} \preceq \mathbf{b}$ ；若不使用仿射放宽版， $\mathbf{Ax} \prec \mathbf{b}$ 是更强的充分条件。

Slater 条件：强对偶的实用判据

鞍点解释：为什么对偶是一场博弈

KKT 条件：最优点的检查清单

总结

原问题与对偶：交换优化顺序

原问题可以写成【证明见附录】

$$\inf_{\mathbf{x} \in \mathcal{D}} \sup_{\boldsymbol{\lambda} \succeq \mathbf{0}, \boldsymbol{\nu}} L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}).$$

对偶问题则是

$$\sup_{\boldsymbol{\lambda} \succeq \mathbf{0}, \boldsymbol{\nu}} \inf_{\mathbf{x} \in \mathcal{D}} L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}).$$

因此，弱对偶本质上是：

$$\sup_z \inf_w F(w, z) \leq \inf_w \sup_z F(w, z)$$

强对偶就是：在足够好的条件下，交换顺序不改变答案。

$$\sup_z \inf_w F(w, z) \leq \inf_w \sup_z F(w, z)$$

令左/右侧的外环优化问题的最优解分别为 z^* 和 w^* ，则可得如下形式：

$$\sup_z \inf_w F(w, z) = \inf_w F(w, z^*) \leq \sup_z F(w^*, z) \leq \inf_w \sup_z F(w, z).$$

若**强对偶性成立**，则

$$\inf_w F(w, z^*) = \sup_z F(w^*, z).$$

由此可知

$$F(w^*, z^*) \geq \inf_w F(w, z^*) = \sup_z F(w^*, z) \geq F(w^*, z^*).$$

由于上下界是一样的，我们可以得到鞍点性质（见下一页）。

如果存在 (w^*, z^*) 满足

$$F(w^*, z) \leq F(w^*, z^*) \leq F(w, z^*), \quad \forall w, z \quad (1)$$

则称 (w^*, z^*) 是鞍点。

直观解释：

- 固定 w^* 时， z^* 让函数尽可能大；
- 固定 z^* 时， w^* 让函数尽可能小；

例子： $F(w, z) = w^2 - z^2$ 在 $(0, 0)$ 处有鞍点。

案例：矩阵对策的混合策略

玩家 1 选择 $k \in \{1, \dots, n\}$, 玩家 2 选择 $l \in \{1, \dots, m\}$ 。玩家 1 向玩家 2 支付 $P_{k,l}$ 。若双方使用随机策略

$$\text{Prob}(k = i) = w_i, \quad \text{Prob}(l = j) = z_j,$$

其中

$$W = \{\mathbf{w} : \mathbf{w} \succeq \mathbf{0}, \mathbf{1}^\top \mathbf{w} = 1\}, \quad Z = \{\mathbf{z} : \mathbf{z} \succeq \mathbf{0}, \mathbf{1}^\top \mathbf{z} = 1\},$$

则期望支付为

$$F(\mathbf{w}, \mathbf{z}) = \mathbf{w}^\top \mathbf{P} \mathbf{z}.$$

矩阵对策与强对偶

- 玩家 1 希望少付钱:

$$p_1^* = \min_{w \in W} \max_{z \in Z} w^\top Pz.$$

- 玩家 2 希望多挣钱:

$$p_2^* = \max_{z \in Z} \min_{w \in W} w^\top Pz.$$

- 一般总有 $p_2^* \leq p_1^*$ 。矩阵零和博弈中，线性规划对偶性给出 $p_1^* = p_2^*$ （证明见课本 5.2.5；不要求）。

在 Lagrange 对偶中， x 和 (λ, ν) 也可以看成两方的博弈。

博弈视角小结

博弈语言

设计者先选 x

检查者选择 (λ, ν)

$\min \max$ 与 $\max \min$ 的差距

鞍点存在

对偶语言

原问题：先找一个满足约束的方案

乘子给违反约束的行为定价

原/对偶最优值之间的间隙

双方都无法单方面改进，原/对偶值相等

强对偶：

$$\inf_{x \in \mathcal{D}} \sup_{\lambda \geq 0, \nu} L = \sup_{\lambda \geq 0, \nu} \inf_{x \in \mathcal{D}} L.$$

下一步：KKT 条件就是鞍点处的“没有单方面改进”的代数形式。

Slater 条件：强对偶的实用判据

鞍点解释：为什么对偶像一场博弈

KKT 条件：最优点的检查清单

总结

为什么需要 KKT?

Slater 告诉我们**什么时候强对偶成立**；KKT 告诉我们**最优点长什么样**。

对于带约束问题，最优点通常不能只看 $\nabla f_0(\mathbf{x}^*) = \mathbf{0}$ 。原因是有些方向不可行，例如约束会挡住下降方向。

KKT 是一组最优解满足的可检查的方程/不等式。

KKT 条件从哪里来：互补松弛

假设强对偶成立，且原问题最优解 \mathbf{x}^* 与对偶最优解 $(\boldsymbol{\lambda}^*, \boldsymbol{\nu}^*)$ 都存在。

由于对偶间隙为 0，有

$$\begin{aligned} f_0(\mathbf{x}^*) &= g(\boldsymbol{\lambda}^*, \boldsymbol{\nu}^*) \\ &\leq L(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\nu}^*) \\ &= f_0(\mathbf{x}^*) + \sum_{i=1}^m \lambda_i^* f_i(\mathbf{x}^*) \leq f_0(\mathbf{x}^*). \end{aligned}$$

所以所有不等号都必须取等号，得到

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

KKT 条件从哪里来：驻点条件

上一页还说明

$$g(\boldsymbol{\lambda}^*, \boldsymbol{\nu}^*) = L(\boldsymbol{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\nu}^*) = \inf_{\boldsymbol{x} \in \mathcal{D}} L(\boldsymbol{x}, \boldsymbol{\lambda}^*, \boldsymbol{\nu}^*).$$

若 L 对 \boldsymbol{x} 可微，且 \boldsymbol{x} 没有额外未写出的边界限制，则一阶必要条件为

$$\nabla_{\boldsymbol{x}} L(\boldsymbol{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\nu}^*) = \mathbf{0}.$$

也就是

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

KKT 条件：检查清单

定理 (KKT 必要条件)

若 f_0, f_i, h_i 可微，没有未显式处理的定义域边界，强对偶成立，且原问题和对偶问题的最优解都达到，则任意一组原/对偶最优解满足：

原始可行： $\mathbf{x}^* \in \mathcal{D}, \quad f_i(\mathbf{x}^*) \leq 0, \quad h_i(\mathbf{x}^*) = 0,$

对偶可行： $\lambda_i^* \geq 0,$

互补松弛： $\lambda_i^* f_i(\mathbf{x}^*) = 0,$

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

这组条件称为 **Karush-Kuhn-Tucker (KKT) 条件**。

互补松弛怎么理解？

对每个不等式约束都有

$$\lambda_i^* f_i(\mathbf{x}^*) = 0, \quad \lambda_i^* \geq 0, \quad f_i(\mathbf{x}^*) \leq 0.$$

因此每个约束只能处在两种状态之一：

- **不紧约束：** $f_i(\mathbf{x}^*) < 0$ ，则必须有 $\lambda_i^* = 0$ ；
- **紧约束：** $f_i(\mathbf{x}^*) = 0$ ，此时 λ_i^* 可以为正。

凸优化中：KKT 也是充分条件

定理 (凸 KKT 充分性)

在与 KKT 必要条件相同的光滑和无额外定义域边界假设下，若 f_0, f_i 为凸函数， h_i 为仿射函数，且 $\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\nu}^*$ 满足 KKT 条件，则 \mathbf{x}^* 是原问题最优解， $(\boldsymbol{\lambda}^*, \boldsymbol{\nu}^*)$ 是对偶最优解，且对偶间隙为 0。

证明要点总结：

- 因为 $\lambda_i^* \geq 0$ 且 f_0, f_i 凸、 h_i 仿射， $L(\mathbf{x}, \boldsymbol{\lambda}^*, \boldsymbol{\nu}^*)$ 关于 \mathbf{x} 是凸函数；
- 驻点条件说明 \mathbf{x}^* 最小化这个 Lagrange 函数；
- 原始可行和互补松弛给出 $L(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\nu}^*) = f_0(\mathbf{x}^*)$ 。

Slater + 凸性: KKT 充要条件

定理 (常用结论)

对于可微凸优化问题, 若等式约束为仿射约束、没有未显式处理的定义域边界、*Slater* 条件满足、 p^* 有限且原问题最优解达到, 则 *KKT* 条件是最优性的充要条件。

也就是说:

- 如果 x^* 最优, 则存在乘子让 *KKT* 成立;
- 如果找到一组变量和乘子满足 *KKT*, 则 x^* 就是全局最优解。

例子 1: 只有等式约束

例子 1: 最小范数解

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

KKT 条件为

$$\mathbf{A}\mathbf{x}^* = \mathbf{b}, \quad 2\mathbf{x}^* + \mathbf{A}^\top \boldsymbol{\nu}^* = \mathbf{0}.$$

可写成线性方程组

$$\begin{bmatrix} 2\mathbf{I} & \mathbf{A}^\top \\ \mathbf{A} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{x}^* \\ \boldsymbol{\nu}^* \end{bmatrix} = \begin{bmatrix} \mathbf{0} \\ \mathbf{b} \end{bmatrix}.$$

例子 2: 一个不等式约束

例子 2: 求解

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

写成 $f_1(x) = x - 1 \leq 0$, Lagrange 函数为

$$L(x, \lambda) = (x - 2)^2 + \lambda(x - 1), \quad \lambda \geq 0.$$

KKT 条件:

$$x^* - 1 \leq 0, \quad \lambda^* \geq 0,$$

$$\lambda^*(x^* - 1) = 0,$$

$$2(x^* - 2) + \lambda^* = 0.$$

由互补松弛：

- 若约束不紧， $x^* < 1$ ，则 $\lambda^* = 0$ 。驻点给出 $x^* = 2$ ，但它不可行，所以排除；
- 因此约束必须紧： $x^* = 1$ 。驻点给出

$$2(1 - 2) + \lambda^* = 0 \quad \Rightarrow \quad \lambda^* = 2.$$

所以最优解为

$$x^* = 1, \quad \lambda^* = 2.$$

例子 3：不紧约束

例子 3：求解

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

无约束最优点 $x = 1$ 已经满足 $0 \leq x \leq 2$ ，所以猜测 $x^* = 1$ 。

KKT 检查：

$$\begin{aligned} f_1(1) &= 1 - 2 = -1 < 0, & f_2(1) &= -1 < 0, \\ \lambda_1^* &= \lambda_2^* = 0, \\ 2(x^* - 1) + \lambda_1^* - \lambda_2^* &= 0. \end{aligned}$$

两个约束都不紧，因此乘子都为 0。

应用 4：乘子的价格含义

为了看一个不等式约束的边际价值，把

$$f_1(x) \leq 0$$

放宽为

$$f_1(x) \leq u.$$

记扰动后问题的最优值为 $p^*(u)$ 。先只看一个不等式约束，Lagrange 函数为

$$L(x, \lambda; u) = f_0(x) + \lambda(f_1(x) - u).$$

单位理解：若 $f_1(x) \leq u$ 表示资源上限或安全裕度，则 λ^* 的单位是“目标值/资源单位”。例如 $\lambda^* = 2$ 表示把约束放宽 1 个单位时，最优成本约下降 2 个单位。

需要的光滑假设：最优解 $x^*(u)$ 、乘子 $\lambda^*(u)$ 以及最优值 $p^*(u)$ 在 $u = 0$ 附近可微，并且活跃约束保持活跃（即约束紧）。

乘子的价格含义：一阶变化

若约束在最优点处保持紧约束，则

$$f_1(x^*(u)) - u = 0,$$

$$p^*(u) = L(x^*(u), \lambda^*(u); u) = f_0(x^*(u)) + \lambda^*(u)(f_1(x^*(u)) - u).$$

对 u 求导，利用驻点条件和紧约束条件，可得

$$\frac{dp^*(u)}{du} = -\lambda^*(u).$$

特别地，在 $u = 0$ 处，

$$\frac{dp^*}{du}(0) = -\lambda^*.$$

解释：如果把约束放宽一个小量 $\Delta u > 0$ ，最优值的一阶变化约为 $-\lambda^* \Delta u$ ；若约束不紧，则 $\lambda^* = 0$ ，通常没有一阶收益。

练习：对问题

$$\begin{aligned} & \text{minimize} && x^2 + y^2 \\ & \text{subject to} && x + y \geq 1 \end{aligned}$$

写出 KKT 条件，并判断哪个约束活跃。

提示：先写成标准形式 $f_1(x, y) = 1 - x - y \leq 0$.

练习：对问题

$$\begin{aligned} & \text{minimize} && x^2 + y^2 \\ & \text{subject to} && x + y \geq 1 \end{aligned}$$

写出 KKT 条件，并判断哪个约束活跃。

提示：先写成标准形式 $f_1(x, y) = 1 - x - y \leq 0$.

答案：约束活跃，最优点为 $(1/2, 1/2)$ ；KKT 乘子为 $\lambda^* = 1$ 。

Slater 条件：强对偶的实用判据

鞍点解释：为什么对偶像一场博弈

KKT 条件：最优点的检查清单

总结

总结：四个核心结论

条件/工具	得到什么
Slater 条件	凸优化中推出强对偶，常还能保证对偶最优解存在
KKT 必要性	强对偶且最优解达到时，最优解必须满足 KKT
凸性 + KKT	满足 KKT 就足以推出全局最优
凸性 + Slater	KKT 成为最优性的充要条件

本节需要掌握：先检查 Slater，再写 KKT。

- 会解释 Slater 条件的含义，并能判断简单问题是否满足；
- 会完整写出 KKT 条件，尤其不要漏掉互补松弛和对偶可行；
- 会用“紧/不紧”两种情况求解简单不等式约束问题；
- 理解乘子作为边际价格的含义，但知道该解释依赖一定光滑性。

阅读作业 & 参考资料：

- 课本第 5.2–5.5 节。

附录：额外证明

附录：Slater 条件证明草图

附录：为什么原问题可写成 min-max?

回顾 Lagrange 函数

$$L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}) = f_0(\mathbf{x}) + \sum_{i=1}^m \lambda_i f_i(\mathbf{x}) + \sum_{i=1}^p \nu_i h_i(\mathbf{x}), \quad \boldsymbol{\lambda} \succeq \mathbf{0}, \boldsymbol{\nu} \in \mathbb{R}^p.$$

固定一个 $\mathbf{x} \in \mathcal{D}$ ，看内层

$$\sup_{\boldsymbol{\lambda} \succeq \mathbf{0}, \boldsymbol{\nu}} L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}).$$

- 若某个不等式约束被违反，即存在 i 使 $f_i(\mathbf{x}) > 0$ ，令 $\lambda_i \rightarrow +\infty$ 且其他乘子固定，则

$$L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}) \rightarrow +\infty.$$

- 若某个等式约束被违反，即存在 j 使 $h_j(\mathbf{x}) \neq 0$ ，令 ν_j 沿着 $h_j(\mathbf{x})$ 同号方向趋于无穷，则

$$\nu_j h_j(\mathbf{x}) \rightarrow +\infty, \quad L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}) \rightarrow +\infty.$$

因此

$$\sup_{\boldsymbol{\lambda} \geq \mathbf{0}, \boldsymbol{\nu}} L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}) = \begin{cases} f_0(\mathbf{x}), & \mathbf{x} \text{ 原始可行,} \\ +\infty, & \mathbf{x} \text{ 原始不可行.} \end{cases}$$

$$\inf_{\mathbf{x} \in \mathcal{D}} \sup_{\boldsymbol{\lambda} \geq \mathbf{0}, \boldsymbol{\nu}} L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}) = \inf_{\mathbf{x} \text{ 原始可行}} f_0(\mathbf{x}) = p^*.$$

凸 KKT 充分性的证明

结论见第31页

对任意可行点 \mathbf{x} ，由 $\lambda_i^* \geq 0$ 和 $f_i(\mathbf{x}) \leq 0$ 可知

$$L(\mathbf{x}, \boldsymbol{\lambda}^*, \boldsymbol{\nu}^*) = f_0(\mathbf{x}) + \sum_i \lambda_i^* f_i(\mathbf{x}) + \sum_i \nu_i^* h_i(\mathbf{x}) \leq f_0(\mathbf{x}).$$

另一方面，由于 \mathbf{x}^* 满足 KKT 条件，因此 \mathbf{x}^* 最小化 $L(\cdot, \boldsymbol{\lambda}^*, \boldsymbol{\nu}^*)$ ，所以

$$f_0(\mathbf{x}^*) = L(\mathbf{x}^*, \boldsymbol{\lambda}^*, \boldsymbol{\nu}^*) \leq L(\mathbf{x}, \boldsymbol{\lambda}^*, \boldsymbol{\nu}^*) \leq f_0(\mathbf{x}).$$

因此 \mathbf{x}^* 优于任意可行点，是全局最优解。

目录


附录：额外证明

附录：Slater 条件证明草图

附录：Slater 证明的几何图像

考虑简化问题：

$$\begin{aligned} p^* &= \text{minimize} && f_0(z) \\ &\text{subject to} && f_1(z) \leq 0. \end{aligned}$$



图中取具体例子 $z = (x, y)$,

$$f_1(z) = x, \quad f_0(z) = (x - 1)^2 + y^2.$$

于是原始图像集合为

$$\mathcal{S} = \{(f_1(z), f_0(z))\} = \{(u, t) \mid t \geq (u - 1)^2\}.$$

右上平移后得到

$$\mathcal{A} = \mathcal{S} + \mathbb{R}_+^2 = \{(u, t) \mid t \geq \phi(u)\},$$

$$\phi(u) = \begin{cases} (u - 1)^2, & u \leq 1, \\ 0, & u \geq 1. \end{cases}$$

可证明这样的集合 \mathcal{A} 是凸集。

附录：Slater 证明草图

由 p^* 的定义, $(0, p^*)$ 是 $\bar{\mathcal{A}}$ 的边界点。由支撑超平面定理, 存在非零向量 (α, β) , 使

$$\alpha u + \beta t \geq \beta p^*, \quad \forall (u, t) \in \bar{\mathcal{A}}.$$

因为 \mathcal{A} 向右上方延伸, 必须有 $\alpha, \beta \geq 0$ 。若 $\beta = 0$, 则上式推出所有 $(u, t) \in \mathcal{A}$ 都有 $u \geq 0$; 但 Slater 点给出 $f_1(\bar{z}) < 0$, 矛盾。所以 $\beta > 0$ 。

令 $\lambda^* = \alpha/\beta \geq 0$ 。对任意 z , 取 $(u, t) = (f_1(z), f_0(z)) \in \mathcal{A}$, 得到

$$f_0(z) + \lambda^* f_1(z) \geq p^*.$$

$$g(\lambda^*) = \inf_{z \in \mathcal{D}} \{f_0(z) + \lambda^* f_1(z)\} \geq p^*.$$

再由弱对偶 $g(\lambda^*) \leq p^*$, 可得 $g(\lambda^*) = p^*$ 。因此强对偶成立, 且 λ^* 就是图中支撑线对应的 Lagrange 乘子。