

第一章：介绍

(3)：最优性条件

授课教师：曹语

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

优化问题

$$\min_{x \in \Omega} f_0(x)$$

我们希望理解如下的问题：

Q1 **存在性**： 是否具有极小值？（能不能找到最低点？）

Q2 **最优性条件**： 若解有极小值，极小值点满足什么性质？（如果在谷底，周围的地势是怎么样的？）

想象我们在大雾的山中寻找最低点，我们怎么知道脚下的点是不是就是最低点呢？

回顾练习

练习: 分别描述 \mathbb{R}^2 中 (画图) $S_p = \{\mathbf{x} \mid \|\mathbf{x}\|_p = 1, \mathbf{x} \in \mathbb{R}^2\}$ ($p = 1, 2, \infty$)

基本概念


极值定理

最优性条件

总结

全局最优解 vs 局部最优解

- **全局最小 (Global Minimum):**
在整个定义域 Ω 内最小。
- **局部最小 (Local Minimum):**
在附近邻域内最小。



定义 (最优点和最优集)

- 假设 $x^* \in \Omega$ 满足 $f_0(x^*) \leq f_0(z), \forall z \in \Omega$, 则我们称该 x^* 为**最优点/全局最优解**
- 所有最优点的集合为**最优集**

练习: 请写出对如下例子的最优集:

- $f_0(x) = \log(x), \Omega = \mathbb{R}_{++} = (0, \infty)$
- $f_0(x) = \log(x), \Omega = (1, \infty)$
- $f_0(x) = \log(x), \Omega = [1, \infty)$

局部最优解

定义 (局部最优解)

若存在 $R > 0$ 使得对于任意的 $z \in \Omega \cap B(\mathbf{x}, R)$, 皆有 $f_0(\mathbf{x}) \leq f_0(\mathbf{z})$, 则我们称 \mathbf{x} 为**局部最优解**。其中 $B(\mathbf{x}, R) = \{z : \|z - \mathbf{x}\|_2 \leq R\}$ 是以 \mathbf{x} 为中心, 半径为 R 的球体。

这里的 R 可以非常非常小。

该 \mathbf{x} 是如下优化问题的最优解:

$$\begin{array}{ll} \text{minimize} & f_0(\mathbf{z}) \\ \text{subject to} & \mathbf{z} \in \Omega \\ & \|\mathbf{z} - \mathbf{x}\|_2 \leq R \end{array}$$

如果 \mathbf{x} 是如上意义下的局部最优解，则存在 $R_p > 0$ 使得它同时是

$$\begin{aligned} & \text{minimize} && f_0(\mathbf{z}) \\ & \text{subject to} && \mathbf{z} \in \Omega \\ & && \|\mathbf{z} - \mathbf{x}\|_p \leq R_p \end{aligned}$$

的最优解（即局部最优解的定义中，选择不同范数并不影响）

提示： $\|\mathbf{x}\|_\infty \leq \|\mathbf{x}\|_p \leq n^{1/p} \|\mathbf{x}\|_\infty$ ，其中 n 是向量的维数。

基本概念

极值定理

最优性条件

总结

开集和闭集：直观理解

定义

- 对于集合 C ，如果对于任意的 $x \in C$ ，都存在 $\epsilon > 0$ 使得 $B(x, \epsilon) \subset C$ ，则称 x 为 C 的**内点**；
- C 的所有内点组成的集合被称为 C 的**内部**，符号为 $\text{int}C$ ；
- 若 $C = \text{int}C$ ，则称 C 为**开集**；(直观：不包含边界)
- 若其补集 $\mathbb{R}^n \setminus C$ 为开集，则称 C 为**闭集**。(直观：包含所有边界)

定理 (闭集的另一个定义)

集合 C 为闭集的一个充要条件是，对于任意一个序列 $\{\mathbf{x}_i\}_{i=1}^{\infty} \subset C$ ，若 $\lim_{i \rightarrow \infty} \|\mathbf{x} - \mathbf{x}_i\| = 0$ ，则 $\mathbf{x} \in C$ 。

直观：“你怎么跑也跑不出去”——极限点也必须在集合内。

例子：请判断如下的集合是否为开集，是否为闭集？

(1) \emptyset

(2) $\{x\}$

(3) $(1, 2)$

(4) $(1, 2]$

(5) $[1, 2] \times [1, 2]$

极值定理

定义 (紧集 Compact set)

若 $C \subset \mathbb{R}^n$, 当 C 是有界的闭集, 它又被称为**紧集**。

定理 (极值定理)

若 C 为紧集, 函数 f 在 C 上为连续函数, 则 f 的值是有界的, 且在 C 中某点能取到极大值/极小值。

这就好比在一个有限的封闭山谷里, 最低点一定存在。极值定理保障了对一类问题的最优解的存在性。

回应了前面提出的 Q1。

基本概念

极值定理

最优性条件

总结

一维函数的回忆


微积分里学过：考虑函数 $f : \mathbb{R} \rightarrow \mathbb{R}$, $x^* \in \mathbb{R}$,

- 必要条件:

- 一阶：若 x^* 是局部极小，则 $f'(x^*) = 0$ (驻点)。
- 二阶：若 x^* 是局部极小，则 $f''(x^*) \geq 0$ (开口向上)。

- 充分条件:

- 若 $f'(x^*) = 0$ 且 $f''(x^*) > 0$ ，则 x^* 是局部极小点。



目标：将这些“斜率为 0”、“开口向上”的概念推广到 n 维空间，即解决 Q2。 14

必要条件的反命题不一定对

我们假设函数 f 是光滑的，即任意阶导数存在且连续：

问题： $f'(x^*) = 0$ 能否推出 x^* 是局部极小点？

问题： $f'(x^*) = 0, f''(x^*) = 0$ ，能否推出 x^* 是局部极小点？

一阶条件：梯度

导数的 n 维推广是**梯度**，记为 ∇f

定义 (梯度)

若 $f \equiv f(x_1, \dots, x_n)$ 偏导存在，则

$$\nabla f := \begin{bmatrix} \partial_{x_1} f \\ \vdots \\ \partial_{x_n} f \end{bmatrix}$$

例子：

- 若 $f(x) = \mathbf{v}^\top \mathbf{x} + b$ ，则 $\nabla f(x) = \mathbf{v}$ ；
- 若 $f(x) = \mathbf{x}^\top \mathbf{A} \mathbf{x}$ ，则 $\nabla f(x) = (\mathbf{A} + \mathbf{A}^\top) \mathbf{x}$ 。

一阶必要条件

定理 (一阶必要条件)

- 假设目标函数 f_0 可微, \mathbf{x}^* 是局部极小点, 则对于任何合适的单位向量 \mathbf{v} , $\mathbf{v}^\top \nabla f_0(\mathbf{x}^*) \geq 0$ (其中合适的 \mathbf{v} 的含义是满足只要 ϵ 足够小, $\mathbf{x}^* + \epsilon \mathbf{v} \in \Omega$)。
- 若任意的单位向量 \mathbf{v} 都是可行的, 则 $\nabla f(\mathbf{x}^*) = \mathbf{0}$; 这样的点我们称为**驻点 (Stationary Point)**。

直观解释:

- 如果在某个方向 \mathbf{v} 上, 方向导数 $\nabla f^T \mathbf{v} < 0$, 说明顺着 \mathbf{v} 走函数值会下降, 那这就不是最低点。
- 如果是内部点, 所有方向都能走, 所以必须各个方向看来都是平的。

证明.

设 \mathbf{x}^* 是局部极小点, 则存在 $R > 0$ 使得对于任意的 $\mathbf{z} \in \Omega \cap B(\mathbf{x}^*, R)$, 皆有 $f_0(\mathbf{x}^*) \leq f_0(\mathbf{z})$ 。对于任意合适的单位向量 \mathbf{v} , 当 ϵ 足够小时, $\mathbf{x}^* + \epsilon\mathbf{v}$ 在局部区域内, 因此函数

$$g(\epsilon) := f_0(\mathbf{x}^* + \epsilon\mathbf{v})$$

应该在 $\epsilon \geq 0$ 的局部区域内, 在 $\epsilon = 0$ 处取得最小值。我们有 $g'(0) \geq 0$, 即

$$g'(0) = \nabla f_0(\mathbf{x}^*)^\top \mathbf{v} \geq 0$$


□

问题： 那么反过来结论是否对呢？

反例：鞍点 (Saddle Point)

对于 $f(x, y) = (x^2 - y^2)/2$, $(0, 0)$ 满足一阶条件 ($\nabla f = 0$), 但不是最优点。

- 沿 x 轴看是极小 (x^2)
- 沿 y 轴看是极大 ($-y^2$)



Hessian 矩阵

定义 (Hessian 矩阵)

二阶导数的 n 维拓展是 Hessian 矩阵, 定义为

$$\nabla^2 f := \begin{bmatrix} \partial_{x_1, x_1} f & \cdots & \partial_{x_1, x_n} f \\ \vdots & \ddots & \vdots \\ \partial_{x_n, x_1} f & \cdots & \partial_{x_n, x_n} f \end{bmatrix}$$

若 f 具有连续二阶导, 则 $\nabla^2 f$ 为对称矩阵。

例子:

- 若 $f(x) = \mathbf{v}^\top \mathbf{x} + b$, 则 $\nabla^2 f(x) = \mathbf{0}_{n \times n}$
- 若 $f(x) = \mathbf{x}^\top \mathbf{A} \mathbf{x}$, 则 $\nabla^2 f(x) = \mathbf{A} + \mathbf{A}^\top$

类似的，若 x^* 是局部最优解，则对于函数

$$g(\epsilon) := f_0(\mathbf{x}^* + \epsilon\mathbf{v}) \quad (1)$$

其开口向上，即 $g''(0) \geq 0$ ，因此

$$g''(0) = \mathbf{v}^\top \nabla^2 f_0(\mathbf{x}^*) \mathbf{v} \geq 0$$

因此，我们得到如下结论：

定理 (二阶必要条件)

假设目标函数 f_0 具有连续的二阶导， \mathbf{x}^* 是局部极小点，则对于任何合适的单位向量 \mathbf{v} ， $\mathbf{v}^\top \nabla^2 f_0(\mathbf{x}^*) \mathbf{v} \geq 0$ （其中合适的 \mathbf{v} 的含义是满足只要 ϵ 足够小， $\mathbf{x}^* + \epsilon\mathbf{v} \in \Omega$ ）。

正定与半正定：矩阵的“符号”

定义

假设矩阵 A 是对称矩阵：

- 若对于任意向量 v ， $v^{\top}Av \geq 0$ ，则称 A 为**半正定**(PSD)， $A \succeq 0$ 。
- 若对于任意非零 v ， $v^{\top}Av > 0$ ，则称为**正定**(PD)， $A \succ 0$ 。

因此，上述定理中的二阶必要条件可以表述为： $\nabla^2 f_0(\mathbf{x}^*) \succeq 0$ ，即 Hessian 矩阵是半正定的。

特征值与正定性

定义 (特征值与特征向量)

- 对于矩阵 A ，如果存在标量 λ 和非零向量 v 使得 $Av = \lambda v$ ，则称 λ 是 A 的**特征值**， v 是对应的**特征向量**。
- 特征值满足如下方程：

$$\det(A - \lambda I) = 0$$

- 特征向量是 $A - \lambda I$ 的零空间中的向量。

定理 (特征值与正定性的关系)

A 为半正定 (正定) 等价于其特征值非负 (全为正)。

证明.

设对称 A 的特征值为 $\lambda_1, \dots, \lambda_n$, 对应的单位特征向量为 $\mathbf{v}_1, \dots, \mathbf{v}_n$, 则 $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ 能够构成 \mathbb{R}^n 的一组基底 (该证明将作为作业)。

- (非负特征值 \rightarrow 半正定) 因此对于任意向量 \mathbf{v} , 存在 $\alpha_1, \dots, \alpha_n$ 使得 $\mathbf{v} = \sum_{i=1}^n \alpha_i \mathbf{v}_i$, 因此

$$\mathbf{v}^\top \mathbf{A} \mathbf{v} = \sum_{i=1}^n \lambda_i \alpha_i^2 \geq 0$$

- (半正定 \rightarrow 非负特征值) 反过来, 设 \mathbf{v} 为 A 的特征向量, λ 为对应的特征值, 则 $\mathbf{v}^\top \mathbf{A} \mathbf{v} = \lambda \|\mathbf{v}\|^2 \geq 0$, 因此 $\lambda \geq 0$ 。

□

练习：判断 $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 2 & 1 \end{bmatrix}$ 是否为半正定矩阵。

二阶充分条件：如何确认是极小值

定理 (二阶充分条件)

假设目标函数 f_0 具有连续的二阶导数，若 \mathbf{x}^* 满足：

1. 一阶条件： $\nabla f(\mathbf{x}^*) = \mathbf{0}$ (驻点)
2. 二阶条件： $\nabla^2 f_0(\mathbf{x}^*) \succ \mathbf{0}$ (*Hessian* 矩阵正定)

则 \mathbf{x}^* 一定是局部极小点。

这相当于一维中的： $f'(x) = 0$ 且 $f''(x) > 0$ 。
正定保证了在所有方向上，函数值都在“向上弯曲”。

练习

练习：请使用面前的定理来说明为什么 $(0, 0)$ 不可能是

$$f(x, y) = (x^2 - y^2)/2$$

的局部极小点。

在上述计算中，我们已经隐式地使用了多元函数的泰勒展开，总结如下：

定理 (多元函数的泰勒展开)

设 f 在 \mathbf{x} 的某个邻域内具有连续的二阶导数，则对于任意 \mathbf{v} 使得当 $\|\mathbf{v}\|$ 足够小时， $\mathbf{x} + \mathbf{v}$ 在该邻域内，且

$$f(\mathbf{x} + \mathbf{v}) = f(\mathbf{x}) + \nabla f(\mathbf{x})^\top \mathbf{v} + \frac{1}{2} \mathbf{v}^\top \nabla^2 f(\mathbf{x}) \mathbf{v} + o(\|\mathbf{v}\|^2).$$

基本概念

极值定理

最优性条件

总结


- 掌握最优点（全局最优解），局部最优解，开/闭集的定义和含义，极值定理，以及 ∇f ，Hessian $\nabla^2 f$ 等概念。
- 掌握最优性条件的 3 个结论，并且能知道基本的证明思路。

阅读作业 & 参考资料：


- 课本 4.1.1 章，以及附录 A.2.1，附录 A.4

■ 第3页:


$$\begin{aligned} S_1 &= \{x \in \mathbb{R}^2 \mid \|x\|_1 = 1\} \\ &= \{x \in \mathbb{R}^2 \mid |x_1| + |x_2| = 1\} \end{aligned}$$



$$\begin{aligned} S_2 &= \{x \in \mathbb{R}^2 \mid \|x\|_2 = 1\} \\ &= \{x \in \mathbb{R}^2 \mid \sqrt{x_1^2 + x_2^2} = 1\} \end{aligned}$$



$$\begin{aligned} S_\infty &= \{x \in \mathbb{R}^2 \mid \|x\|_\infty = 1\} \\ &= \{x \in \mathbb{R}^2 \mid \max\{|x_1|, |x_2|\} = 1\} \end{aligned}$$



参考答案

- 第6页: $\emptyset, \emptyset, \{1\}$
- 第11页: (1) 是开集, 是闭集; (2) 不是开集, 是闭集; (3) 是开集, 不是闭集; (4) 不是开集, 不是闭集; (5) 不是开集, 是闭集
- 第15页: 对 $f(x) = x^3$, 显然 $x = 0$ 满足一阶条件, 但该点不是极小点。
- 第25页: 由于 A 的特征值为 $3, -1$, 因此该矩阵不是半正定。
- 第27页: 假设 $(0, 0)$ 是局部极小点, 则 $\nabla^2 f(0, 0) = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$ 需要是半正定的, 但显然 $\nabla^2 f(0, 0)$ 不是, 因此得到矛盾。