

最优化理论与方法

第一章 最优化基础

上海财经大学应用数学系

December 26, 2008

最优化问题数学模型的一般形式

最优化问题数学模型的一般形式为

$$\begin{cases} \min f(x) \\ \text{s.t. } c_i(x) = 0, i \in E = \{1, 2, \dots, l\} \\ c_i(x) \leq 0, i \in I = \{l + 1, l + 2, \dots, l + m\} \\ x \in R^n. \end{cases} \quad (1.1.1)$$

这里min表示求极小值, s.t.=subject to意思是受限制于..., x 是 n 维向量, 其分量是 x_1, \dots, x_n . 在问题(1.1.1)中称 $f(x)$ 为目标函数(objective function), 称 $c_i(x)$ ($i \in E \cup I$)为约束函数(constraint functions). 若求极大值, 可以将目标函数写成 $\min(-f(x))$, 不等式约束 $c_i(x) \geq 0$ 可以写成 $-c_i(x) \leq 0$.

最优化问题数学模型的一般形式

最优化问题数学模型的一般形式为

$$\begin{cases} \min f(x) \\ \text{s.t. } c_i(x) = 0, i \in E = \{1, 2, \dots, l\} \\ \quad c_i(x) \leq 0, i \in I = \{l + 1, l + 2, \dots, l + m\} \\ \quad x \in R^n. \end{cases} \quad (1.1.1)$$

这里 \min 表示求极小值, $\text{s.t.}=\text{subject to}$ 意思是受限制于 \dots , x 是 n 维向量, 其分量是 x_1, \dots, x_n . 在问题(1.1.1)中称 $f(x)$ 为目标函数(objective function), 称 $c_i(x)(i \in E \cup I)$ 为约束函数(constraint functions). 若求极大值, 可以将目标函数写成 $\min(-f(x))$, 不等式约束 $c_i(x) \geq 0$ 可以写成 $-c_i(x) \leq 0$.

可行域, 可行点

定义 1.1.1

若记集合

$$D = \{x \mid c_i(x) = 0, i \in E; c_i(x) \leq 0, i \in I, x \in R^n\},$$

则称 D 为问题 (1.1.1) 的可行域, 若 $x \in D$, 则称 x 为可行点.

最优化问题(1.1.1)的简单分类

- 1、根据可行域 D 划分: 若 $D = R^n$, 即 x 是自由变量, 则称问题(1.1.1)为**无约束优化问题**; 否则, $D \subset R^n$, 称问题(1.1.1)为**约束优化问题**.
- 2、根据函数的性质划分: 若目标函数和约束函数都是线性的, 则称问题(1.1.1)为**线性规划**; 若目标函数和约束函数中至少有一个是非线性的, 则称问题(1.1.1)为**非线性规划**. 进一步, 若目标函数是二次函数, $c_i(x)(i = 1, \dots, l + m)$ 是线性函数, 则称问题(1.1.1)为**二次规划**.
- 3、根据可行域的性质划分: 若可行域内的点是有限的, 则称(1.1.1)为**离散最优化问题**; 若可行域内含有无穷多个不可数的点, 且可行域内的点可以连续变化, 则称(1.1.1)为**连续最优化问题**. 对于离散优化问题, 若变量均为整数, 则称其为**整数规划问题**; 若部分变量为整数, 而另一部分变量连续变化, 则称其为**混合整数规划问题**.

最优化问题(1.1.1)的简单分类

- 1、根据可行域 D 划分: 若 $D = R^n$, 即 x 是自由变量, 则称问题(1.1.1)为**无约束优化问题**; 否则, $D \subset R^n$, 称问题(1.1.1)为**约束优化问题**.
- 2、根据函数的性质划分: 若目标函数和约束函数都是线性的, 则称问题(1.1.1)为**线性规划**; 若目标函数和约束函数中至少有一个是非线性的, 则称问题(1.1.1)为**非线性规划**. 进一步, 若目标函数是二次函数, $c_i(x)(i = 1, \dots, l + m)$ 是线性函数, 则称问题(1.1.1)为**二次规划**.
- 3、根据可行域的性质划分: 若可行域内的点是有限的, 则称(1.1.1)为**离散最优化问题**; 若可行域内含有无穷多个不可数的点, 且可行域内的点可以连续变化, 则称(1.1.1)为**连续最优化问题**. 对于离散优化问题, 若变量均为整数, 则称其为**整数规划问题**; 若部分变量为整数, 而另一部分变量连续变化, 则称其为**混合整数规划问题**.

最优化问题(1.1.1)的简单分类

- 1、根据可行域 D 划分: 若 $D = R^n$, 即 x 是自由变量, 则称问题(1.1.1)为**无约束优化问题**; 否则, $D \subset R^n$, 称问题(1.1.1)为**约束优化问题**.
- 2、根据函数的性质划分: 若目标函数和约束函数都是线性的, 则称问题(1.1.1)为**线性规划**; 若目标函数和约束函数中至少有一个是非线性的, 则称问题(1.1.1)为**非线性规划**. 进一步, 若目标函数是二次函数, $c_i(x)(i = 1, \dots, l + m)$ 是线性函数, 则称问题(1.1.1)为**二次规划**.
- 3、根据可行域的性质划分: 若可行域内的点是有限的, 则称(1.1.1)为**离散最优化问题**; 若可行域内含有无穷多个不可数的点, 且可行域内的点可以连续变化, 则称(1.1.1)为**连续最优化问题**. 对于离散优化问题, 若变量均为整数, 则称其为**整数规划问题**; 若部分变量为整数, 而另一部分变量连续变化, 则称其为**混合整数规划问题**.

最优化问题(1.1.1)的简单分类

4. 根据函数的向量性质划分: 若目标函数为向量函数时, 则称(1.1.1)为多目标规划问题; 若目标函数为数量函数时, 则称(1.1.1)为单目标规划问题.
 5. 根据规划问题有关信息的确定性划分: 若目标函数或约束函数具有随机性, 也就是问题的表述形式随时间的变化而变化, 具有不确定性, 这样的优化问题称为随机规划; 相应地, 另外一类就是目标函数和可行域都是确定的, 这样的规划问题称为确定性规划问题.
- 本书主要讨论确定性规划问题.

最优化问题(1.1.1)的简单分类

4. 根据函数的向量性质划分: 若目标函数为向量函数时, 则称(1.1.1)为**多目标规划问题**; 若目标函数为数量函数时, 则称(1.1.1)为**单目标规划问题**.
 5. 根据规划问题有关信息的确定性划分: 若目标函数或约束函数具有随机性, 也就是问题的表述形式随时间的变化而变化, 具有不确定性, 这样的优化问题称为**随机规划**; 相应地, 另外一类就是目标函数和可行域都是确定的, 这样的规划问题称为**确定性规划问题**.
- 本书主要讨论确定性规划问题.

最优化问题(1.1.1)的简单分类

4. 根据函数的向量性质划分: 若目标函数为向量函数时, 则称(1.1.1)为**多目标规划问题**; 若目标函数为数量函数时, 则称(1.1.1)为**单目标规划问题**.
 5. 根据规划问题有关信息的确定性划分: 若目标函数或约束函数具有随机性, 也就是问题的表述形式随时间的变化而变化, 具有不确定性, 这样的优化问题称为**随机规划**; 相应地, 另外一类就是目标函数和可行域都是确定的, 这样的规划问题称为**确定性规划问题**.
- 本书主要讨论确定性规划问题.

实例

例题1.1.1 投资问题

假定国家的下一个五年计划内用于发展某种工业的总投资为 b 亿元，可供选择兴建的项目共有 n 个.已知第 j 个项目的投资为 a_j 亿元，可得收益为 c_j 亿元，问应如何进行投资，才能使盈利率（即单位投资可得到的收益）为最高？

解：令决策变量为 x_j ，则 x_j 应满足条件

$$x_j(x_j - 1) = 0.$$

同时 x_j 应满足约束条件 $\sum_{j=1}^n a_j x_j \leq b$. 目标函数是要求盈利率

$$f(x_1, x_2, \dots, x_n) = \frac{\sum_{j=1}^n c_j x_j}{\sum_{j=1}^n a_j x_j}$$

达到最大. 这是一个整数规划问题.

实例

例题1.1.2 厂址选择问题

设有 n 个市场，第 j 个市场位置为 (p_j, q_j) ，它对某种货物的需要量为 $b_j, j = 1, \dots, n$. 现计划建立 m 个仓库，第 i 个仓库的存储容量为 $a_i, i = 1, \dots, m$. 试确定仓库的位置，使各仓库对各市场的运输量与路程乘积之和为最小.

解：设第 i 个仓库的位置为 $(x_i, y_i), i = 1, \dots, m$ ，第 i 个仓库到第 j 个市场的货物供应量为 $z_{ij}, i = 1, \dots, m, j = 1, \dots, n$ ，则第 i 个仓库到第 j 个市场的距离为

$$d_{ij} = \sqrt{(x_i - p_j)^2 + (y_i - q_j)^2}.$$

实例

例题1.1.2 厂址选择问题

目标函数为

$$\sum_{i=1}^m \sum_{j=1}^n z_{ij} d_{ij} = \sum_{i=1}^m \sum_{j=1}^n z_{ij} \sqrt{(x_i - p_j)^2 + (y_i - q_j)^2}$$

约束条件为:

- (1) 每个仓库向各市场提供的货物量之和不能超过它的存储容量;
- (2) 每个市场从各仓库得到的货物量之和应等于它的需要量;
- (3) 运输量不能为负数.

实例

例题1.1.2 厂址选择问题

因此, 问题的数学模型为:

$$\left\{ \begin{array}{l} \min \quad f(x) = \sum_{i=1}^m \sum_{j=1}^n z_{ij} d_{ij} \\ \quad = \sum_{i=1}^m \sum_{j=1}^n z_{ij} \sqrt{(x_i - p_j)^2 + (y_i - q_j)^2} \\ \text{s.t.} \quad \sum_{j=1}^n z_{ij} \leq a_i, i = 1, \dots, m, \\ \quad \sum_{i=1}^m z_{ij} = b_j, j = 1, \dots, n, \\ \quad z_{ij} \geq 0, i = 1, \dots, m, j = 1, \dots, n, \end{array} \right.$$

实例

例题1.1.3 曲线拟合问题

在科学实验、工程设计和管理工作 中，经常会遇到下述问题：通过实验或实测得到 n 组数据 (t_i, y_i) ，它们可视为平面上的 n 个点，期望确定一组参数 $x = (x_1, \dots, x_m)^T$ ，使曲线 $y = \phi(x; t)$ 最佳逼近这 n 个点。通常把这一问题归结为如下的优化问题：

$$\min f(x) = \sum_{i=1}^m [\phi(x, t_i) - y_i]^2$$

设 x^* 为问题的最优解，则 $y = \phi(x^*, t)$ 即为通过最小二乘法对 n 组数据 (t_i, y_i) 的拟合曲线。

实例

例题1.1.4 砂石运输问题

设有 $V(m^3)$ 的砂、石要由甲地运输到乙地，运输前需要先装入一个有底无盖并在底部有滑行器的木箱中，砂、石运到乙地后，从箱中倒出，再继续用空箱装运，不论箱子大小，每装运一箱，需0.1元，箱底和两端的材料费为 $20元/m^2$ ，箱子两侧材料费为 $5元/m^2$ ，箱底的两个滑行器与箱子同长，材料费为 $2.5元/m$ ，问木箱的长、宽、高应各为多少米，才能使运费与箱子的成本费的总和为最小。

解：设木箱的长、宽、高分别为 x_1, x_2, x_3 ，运费与成本费的总和为 w ，则上述问题可归结为如下的优化模型：

$$\begin{cases} \min w(x) = 0.1 * V / (x_1 x_2 x_3) + 20x_1 x_2 + 10x_1 x_3 + 40x_2 x_3 + 5x_1 \\ s.t. \quad x_i > 0, i = 1, 2, 3. \end{cases}$$

实例

例题1.1.4 砂石运输问题

在上述问题中，若要求箱子底与两侧使用废料来做，而废料只有4平方米，其他与上述问题相同，这时问题归结为：

$$\begin{cases} \min w(x) = 0.1 * V / (x_1 x_2 x_3) + 40x_2 x_3 + 5x_1 \\ \text{s.t.} \quad \frac{1}{2}x_1 x_3 + \frac{1}{4}x_1 x_2 \leq 1, \\ \quad \quad x_i > 0, i = 1, 2, 3. \end{cases}$$

一. 线性空间

线性空间定义

设 E 是一个集合,在此集合上定义加法和数乘运算,并且运算是封闭的,这样形式的 E 称为**线性空间**,其中 E 中的元素 x 称为**向量**.

在 n 维线性空间中,记 n 维列向量为

$$x = (x_1, x_2, \dots, x_n)^T$$

其中 T 表示转置.

一. 线性空间

线性空间定义

设 E 是一个集合,在此集合上定义加法和数乘运算,并且运算是封闭的,这样形式的 E 称为**线性空间**,其中 E 中的元素 x 称为**向量**.

在 n 维线性空间中,记 n 维列向量为

$$x = (x_1, x_2, \dots, x_n)^T$$

其中 T 表示转置.

一. 线性空间

向量加法, 数乘定义

若 x, y 是线性空间 E 中的两个向量, 通常的加法定义为

$$x + y = (x_1 + y_1, x_2 + y_2, \cdots, x_n + y_n)^T,$$

若 λ 是一个标量, 通常的数乘定义为:

$$\lambda x = (\lambda x_1, \lambda x_2, \cdots, \lambda x_n)^T$$

一. 线性空间

数乘的性质

$$\lambda(\mu x) = (\lambda\mu)x,$$

$$(\lambda + \mu)x = \lambda x + \mu x,$$

$$\lambda(x + y) = \lambda x + \lambda y.$$

线性组合

设 a_1, a_2, \dots, a_m 为 E 中 m 个向量, 称

$$x = \lambda_1 a_1 + \dots + \lambda_m a_m$$

为 a_1, \dots, a_m 的**线性组合**.

一. 线性空间

线性相关, 线性无关

如果存在 $\lambda_i \neq 0$ (即 λ_i 不全为零), 使得

$$\lambda_1 a_1 + \cdots + \lambda_m a_m = 0,$$

则称 a_1, a_2, \cdots, a_m **线性相关**, 反之则称 a_1, a_2, \cdots, a_m **线性无关**.

也就是说, 若

$$\lambda_1 a_1 + \cdots + \lambda_m a_m = 0,$$

则仅有 $\lambda_i = 0, i = 1, \cdots, m$.

二. *Euclid*空间 (欧氏空间)

所谓欧氏空间,就是在线性空间上定义一个度量。对于n维欧氏空间(记为 R^n),向量 x 与 y 的内积定义为

$$\langle x, y \rangle = \sum_{i=1}^n x_i y_i = x^T y.$$

二. Euclid空间 (欧氏空间)

内积的性质

- 1, $\langle x, x \rangle \geq 0$, 且 $\langle x, x \rangle = 0$ 的充分必要条件是 $x = 0$.
- 2, $\langle x, y \rangle = \langle y, x \rangle$.
- 3, $\langle \lambda x + \mu y, z \rangle = \lambda \langle x, z \rangle + \mu \langle y, z \rangle$.

范数定义

n 维欧氏空间 R^n 上的范数定义为:

$$|x| = \left(\sum_{i=1}^n x_i^2 \right)^{\frac{1}{2}} = (\langle x, x \rangle)^{\frac{1}{2}},$$

即通常意义下的距离, 或称为 l_2 范数.

二. Euclid空间 (欧氏空间)

范数的性质

- 1, $\|x\| \geq 0$, 且 $\|x\| = 0$ 的充分必要条件是 $x = 0$.
- 2, $\|x\| \geq 0$, 且 $\|x\| = 0$ 的充分必要条件是 $x = 0$.
- 3, $\|x + y\| \leq \|x\| + \|y\|$ (三角不等式). 以及 Cauchy-Schwarz 不等式

$$|\langle x, y \rangle| \leq \|x\| \|y\|,$$

且等号成立的充分必要条件是: x 与 y 共线, 即存在 λ , 使得

$$x = \lambda y.$$

将该不等式写成分量形式为:

$$\left| \sum_{i=1}^n x_i y_i \right| \leq \left(\sum_{i=1}^n x_i^2 \right)^{\frac{1}{2}} \left(\sum_{i=1}^n y_i^2 \right)^{\frac{1}{2}}$$

三. 矩阵

矩阵定义

称

$$A = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix}$$

为 $m \times n$ 阶矩阵, 记为 $A = A_{m \times n}$.

三. 矩阵

分块矩阵

对于矩阵A, 可以进行分块, 即

$$A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix},$$

其中 A_{11} 为 $m_1 \times n_1$, A_{12} 为 $m_1 \times n_2$, A_{21} 为 $m_2 \times n_1$, A_{22} 为 $m_2 \times n_2$ 阶矩阵, 且 $m_1 + m_2 = m$, $n_1 + n_2 = n$. 这里特别提到两种特殊的分块矩阵, 按列分块

$$A = [P_1, P_2, \dots, P_n], P_j = \begin{pmatrix} a_{1j} \\ a_{2j} \\ \vdots \\ a_{mj} \end{pmatrix}$$

三. 矩阵

分块矩阵

和按行分块

$$A = \begin{pmatrix} a_1^T \\ a_2^T \\ \vdots \\ a_m^T \end{pmatrix}, a_i^T = (a_{i1}, a_{i2}, \dots, a_{in}).$$

矩阵A的秩记为 $\text{rank}(A)$.若

$$\text{rank}(A) = \min\{m, n\}$$

时, 则称矩阵A是满秩的. 若 $m < n$, 则称为行满秩, 若 $m > n$, 则称为列满秩. 当若 $m = n$ 时, 则矩阵为n阶非奇异方阵.

矩阵非奇异的充分必要条件是: $\det(A) \neq 0$.

三. 矩阵

对称矩阵, 正定矩阵

若 A 为 $n \times n$ 阶矩阵, 若 A 满足

$$A^T = A,$$

则称 A 为**对称矩阵**. 若对于一切 $x \neq 0$, 均有

$$x^T A x > 0,$$

则称 A 为**正定对称矩阵**. 若对一切 x , 均有

$$x^T A x \geq 0,$$

则称 A 为**半正定矩阵**.

多元函数分析

定义1.3.1

设 n 元函数 $f(x)$ 对自变量 $x = (x_1, x_2, \dots, x_n)^T$ 的各分量 x_i 的偏导数 $\frac{\partial f(x)}{\partial x_i}$, $i = 1, \dots, n$ 都存在, 则称函数 $f(x)$ 在 x 处一阶可导, 并称向量:

$$\nabla f(x) = \left(\frac{\partial f(x)}{\partial x_1}, \dots, \frac{\partial f(x)}{\partial x_n} \right)^T$$

为函数 $f(x)$ 在 x 处的一阶倒数或梯度, 记 $g(x) = \nabla f(x)$ ($g(x)$ 为列向量)。

多元函数分析

定义1.3.2

设 n 元函数 $f(x)$ 自变量 $x = (x_1, x_2, \dots, x_n)^T$ 的各分量 x_i 的二阶偏导数 $\frac{\partial^2 f(x)}{\partial x_i \partial x_j}$, $i = 1, \dots, n, j = 1, \dots, n$ 都存在, 则称函数 $f(x)$ 在点 x 处二阶可导, 并称矩阵

$$\nabla^2 f(x) = \begin{bmatrix} \frac{\partial^2 f(x)}{\partial x_1^2} & \frac{\partial^2 f(x)}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f(x)}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f(x)}{\partial x_2 \partial x_1} & \frac{\partial^2 f(x)}{\partial x_2 \partial x_2} & \cdots & \frac{\partial^2 f(x)}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f(x)}{\partial x_n \partial x_1} & \frac{\partial^2 f(x)}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f(x)}{\partial x_n^2} \end{bmatrix}$$

为 $f(x)$ 在 x 处的二阶导数或 Hessian 矩阵.

多元函数分析

记为 $\nabla^2 f(x)$, 即

$$\nabla^2 f(x) = \left(\frac{\partial^2 f(x)}{\partial x_i \partial x_j} \right)_{n \times n}.$$

有时记为 $G(x)$.

若 $f(x)$ 对 x 各变元的所有二阶偏导数都连续, 则

$$\frac{\partial^2 f(x)}{\partial x_i \partial x_j} = \frac{\partial^2 f(x)}{\partial x_j \partial x_i},$$

此时 $\nabla^2 f(x)$ 为对称矩阵。

多元函数分析

例1.3.1

设 $A \in R^{n \times n}$ 为对称矩阵, $b \in R^n, c \in R^1$, 求

(1) 线性函数 $f(x) = b^T x$ 的梯度和Hessian 矩阵,

(2) 二次函数 $f(x) = x^T A x + b^T x + c$ 的梯度和Hessian 矩阵.

解:(1) $f(x) = b^T x = b_1 x_1 + b_2 x_2 + \cdots + b_n x_n$,

所以

$$\frac{\partial f}{\partial x_k} = b_k, \quad k = 1, 2, \cdots, n, \quad (*)$$

因此

$$\nabla f(x) = (b_1, b_2, \cdots, b_n)^T = b.$$

对(*)式再求导数, 得到

$$\frac{\partial^2 f}{\partial x_k \partial x_l} = 0, \quad k, l = 1, 2, \cdots, n,$$

多元函数分析

因此得到 $\nabla^2 f(x) = 0$.

(2) 令 $f'(x) = x^T Ax$, 于是

$$f'(x) = x^T Ax = \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j,$$

因此

$$\begin{aligned} \frac{\partial f'}{\partial x_k} &= \left(\sum_{i=1, i \neq k}^n \left(\sum_{j=1}^n a_{ij} x_i x_j \right) + \sum_{j=1, j \neq k}^n a_{kj} x_k x_j + a_{kk} x_k^2 \right)' \\ &= \sum_{i=1, i \neq k}^n a_{ik} x_i + \sum_{j=1, j \neq k}^n a_{kj} x_j + 2a_{kk} x_k \\ &= \sum_{i=1}^n a_{ik} x_i + \sum_{j=1}^n a_{kj} x_j, \quad k = 1, 2, \dots, n, \end{aligned}$$

和

$$\frac{\partial^2 f'}{\partial x_k \partial x_l} = a_{lk} + a_{kl}, \quad k, l = 1, 2, \dots, n,$$

多元函数分析

所以梯度为

$$\begin{aligned} \nabla f'(x) &= \begin{bmatrix} a_{11} & a_{21} & \cdots & a_{n1} \\ a_{12} & a_{22} & \cdots & a_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ a_{1n} & a_{2n} & \cdots & a_{nn} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} + \\ &\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (**) \\ &= A^T x + Ax \end{aligned}$$

多元函数分析

所以梯度为其Hesse矩阵为

$$\begin{aligned}\nabla^2 f'(x) &= \begin{bmatrix} a_{11} & a_{21} & \cdots & a_{n1} \\ a_{12} & a_{22} & \cdots & a_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ a_{1n} & a_{2n} & \cdots & a_{nn} \end{bmatrix} + \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} \\ &= A^T + A.\end{aligned}$$

(***)

多元函数分析

因为 A 为对称矩阵, 即 $A^T = A$, 则(**)式和(***)式可以写成

$$\nabla f'(x) = 2Ax,$$

$$\nabla^2 f'(x) = 2A.$$

因此

$$\nabla f(x) = 2Ax + b,$$

$$\nabla^2 f(x) = 2A.$$

多元函数分析

定义1.3.3

设向量函数 $F(x) = (f_1(x), f_2(x), \dots, f_m(x))^T$ 的各分量函数 $f_i(x) (i = 1, \dots, m)$ 对自变量 $x = (x_1, \dots, x_n)^T$ 各分量的偏导数

$$\frac{\partial f_i(x)}{\partial x_j}, \quad i = 1, \dots, m, \quad j = 1, \dots, n$$

都存在, 则称 $F(x)$ 在点 x 处一阶可导, 并称矩阵

$$F'(x) = \begin{bmatrix} \frac{\partial f_1(x)}{\partial x_1} & \frac{\partial f_1(x)}{\partial x_2} & \dots & \frac{\partial f_1(x)}{\partial x_n} \\ \frac{\partial f_2(x)}{\partial x_1} & \frac{\partial f_2(x)}{\partial x_2} & \dots & \frac{\partial f_2(x)}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_m(x)}{\partial x_1} & \frac{\partial f_m(x)}{\partial x_2} & \dots & \frac{\partial f_m(x)}{\partial x_n} \end{bmatrix}$$

为向量函数 $F(x)$ 在 x 处的雅可比(Jacobi)矩阵.

多元函数分析

与导数相关的另一个概念是方向导数, n 元函数的方向导数在非线性规划问题的研究中具有非常重要的作用, 下面, 我们借助于一元函数的一阶和二阶导数, 导出 n 元函数的一阶和二阶方向导数. 首先, 根据多元复合函数的求导法则, 导出一元函数

$$\phi(a) = f(x + ad), \quad a \in R^1, x, d \in R^n$$

的一阶、二阶导数.

令

$$u = x + ad = (x_1 + ad_1, x_2 + ad_2 + \cdots, x_n + ad_n)^T = (u_1, \cdots, u_n)^T,$$

多元函数分析

则

$$\begin{aligned}\phi'(a) &= \frac{\partial f(u)}{\partial u_1} \frac{du_1}{da} + \cdots + \frac{\partial f(u)}{\partial u_n} \frac{du_n}{da} \\ &= \frac{\partial f(u)}{\partial u_1} d_1 + \cdots + \frac{\partial f(u)}{\partial u_n} d_n \\ &= \nabla f(u)^T d \\ &= \nabla f(x + ad)^T d,\end{aligned}\tag{1.3.1}$$

多元函数分析

$$\begin{aligned}\phi''(a) &= \left(\frac{\partial^2 f(u)}{\partial u_1^2} d_1 + \frac{\partial^2 f(u)}{\partial u_1 \partial u_2} d_2 + \cdots + \frac{\partial^2 f(u)}{\partial u_1 \partial u_n} d_n \right) d_1 \\ &\quad \left(\frac{\partial^2 f(u)}{\partial u_2 \partial u_1} d_1 + \frac{\partial^2 f(u)}{\partial u_2^2} d_2 + \cdots + \frac{\partial^2 f(u)}{\partial u_2 \partial u_n} d_n \right) d_2 \\ &\quad + \cdots \\ &\quad \left(\frac{\partial^2 f(u)}{\partial u_n \partial u_1} d_1 + \frac{\partial^2 f(u)}{\partial u_n \partial u_2} d_2 + \cdots + \frac{\partial^2 f(u)}{\partial u_n^2} d_n \right) d_n \\ &= (d_1, d_2, \cdots, d_n) \begin{bmatrix} \frac{\partial^2 f(u)}{\partial u_1^2} & \frac{\partial^2 f(u)}{\partial u_1 \partial u_2} & \cdots & \frac{\partial^2 f(u)}{\partial u_1 \partial u_n} \\ \frac{\partial^2 f(u)}{\partial u_2 \partial u_1} & \frac{\partial^2 f(u)}{\partial u_2^2} & \cdots & \frac{\partial^2 f(u)}{\partial u_2 \partial u_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f(u)}{\partial u_n \partial u_1} & \frac{\partial^2 f(u)}{\partial u_n \partial u_2} & \cdots & \frac{\partial^2 f(u)}{\partial u_n^2} \end{bmatrix} \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_n \end{bmatrix} \\ &= d^T \nabla^2 f(x + ad) d.\end{aligned}\tag{1.3.2}$$

多元函数分析

定义1.3.4

对于任意给定的 $d \neq 0$,若极限

$$\lim_{a \rightarrow 0^+} \frac{f(\bar{x} + ad) - f(\bar{x})}{a\|d\|}$$

存在, 则称该极限值为函数 $f(x)$ 在 \bar{x} 处沿方向 d 的**一阶方向导数**, 简称为**方向导数**, 记为 $\frac{\partial}{\partial d} f(\bar{x})$, 即

$$\frac{\partial}{\partial d} f(\bar{x}) = \lim_{a \rightarrow 0^+} \frac{f(\bar{x} + ad) - f(\bar{x})}{a\|d\|} \quad (1.3.3)$$

多元函数分析

如果按上述定义求方向导数的话相当繁琐，下面给出方向导数的另一种表达式。

定理 1.3.1

若函数 $f(x)$ 具有连续的一阶偏导数，则它在 \bar{x} 处沿方向 d 的一阶方向导数为

$$\frac{\partial}{\partial d} f(\bar{x}) = \left\langle \nabla f(\bar{x}), \frac{d}{\|d\|} \right\rangle = \frac{1}{\|d\|} d^T \nabla f(\bar{x}). \quad (1.3.4)$$

多元函数分析

证明: 记 $\bar{x} = (\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n)^T$, $d = (d_1, \dots, d_n)^T$, 考虑单变量函数

$$\phi(a) = f(\bar{x} + ad),$$

由定理条件知 $\phi(a)$ 可微, 由式(1.3.1)可得

$$\phi'(a) = d^T \nabla f(\bar{x} + ad),$$

当 $a = 0$ 时, 有

$$\phi'(0) = d^T \nabla f(\bar{x}). \quad (1.3.5)$$

多元函数分析

另一方面, 由式(1.3.3)(1.3.5)可得:

$$\begin{aligned}\frac{\partial}{\partial d} f(\bar{x}) &= \lim_{a \rightarrow 0^+} \frac{f(\bar{x}+ad) - f(\bar{x})}{a\|d\|} \\ &= \frac{1}{\|d\|} \lim_{a \rightarrow 0^+} \frac{\phi(a) - \phi(0)}{a} \\ &= \frac{1}{\|d\|} \phi'(0) \\ &= \frac{1}{\|d\|} d^T \nabla f(\bar{x})\end{aligned}$$

多元函数分析

方向导数的几何意义

函数 $f(x)$ 在 \bar{x} 处沿 d 方向的变化率. 若 $\frac{\partial f}{\partial d} > 0$, 则沿着方向 d 增加时, 函数值上升, 此时, 也称 d 为上升方向. 若 $\frac{\partial f}{\partial d} < 0$, 则称 d 是下降方向.

多元函数分析

由式(1.3.4)和Cauchy-Schwarz不等式得到

$$\begin{aligned}\frac{\partial}{\partial d} f(\bar{x}) &= \langle \nabla f(\bar{x}), \frac{d}{\|d\|} \rangle \\ &\leq \|\nabla f(\bar{x})\| \left\| \frac{d}{\|d\|} \right\| \\ &= \|\nabla f(\bar{x})\|.\end{aligned}$$

特别当 $d = \nabla f(\bar{x})$ 时,有

$$\begin{aligned}\frac{\partial}{\partial d} f(\bar{x}) &= \langle \nabla f(\bar{x}), \frac{d}{\|d\|} \rangle \\ &= \langle \nabla f(\bar{x}), \frac{\nabla f(\bar{x})}{\|\nabla f(\bar{x})\|} \rangle \\ &= \|\nabla f(\bar{x})\|.\end{aligned}$$

结合上面两式, $d = \nabla f(\bar{x})$ 是在 \bar{x} 处使得方向导数达到最大的方向,称其为**最速上升方向**.

多元函数分析

同理可得 $\frac{\partial}{\partial d} f(\bar{x}) \geq -\|\nabla f(\bar{x})\|$, 当 $d = -\nabla f(\bar{x})$ 时, 有

$$\frac{\partial}{\partial d} f(\bar{x}) = -\|\nabla f(\bar{x})\|,$$

因此称 $d = -\nabla f(\bar{x})$ 为 \bar{x} 处的 **最速下降方向** (direction of steepest descent).

多元函数分析

下面介绍二阶方向导数.

定义1.3.5

对于任意给定的 $d \neq 0$,若极限

$$\lim_{a \rightarrow 0^+} \frac{\frac{\partial}{\partial d} f(\bar{x} + ad) - \frac{\partial}{\partial d} f(\bar{x})}{a \|d\|}$$

存在, 则称该极限值为函数 $f(x)$ 在 \bar{x} 处沿方向 d 的**二阶方向导数**, 记为 $\frac{\partial^2}{\partial d^2} f(\bar{x})$, 即

$$\frac{\partial^2}{\partial d^2} f(\bar{x}) = \lim_{a \rightarrow 0^+} \frac{\frac{\partial}{\partial d} f(\bar{x} + ad) - \frac{\partial}{\partial d} f(\bar{x})}{a \|d\|}.$$

多元函数分析

定理1.3.2

若函数 $f(x)$ 具有连续的二阶偏导数, 则它在 \bar{x} 处沿方向 d 的二阶方向导数为

$$\frac{\partial^2}{\partial d^2} f(\bar{x}) = \frac{1}{\|d\|^2} d^T \nabla^2 f(\bar{x}) d.$$

证明: 考虑单变量函数

$$\phi(a) = f(\bar{x} + ad),$$

由定理条件及式(1.3.2)可得:

$$\phi''(a) = d^T \nabla^2 f(\bar{x} + ad) d.$$

当 $a = 0$ 时, 有

$$\phi''(0) = d^T \nabla^2 f(\bar{x}) d.$$

多元函数分析

另一方面，由定理(1.3.1)的证明过程有：

$$\frac{\partial}{\partial d} f(\bar{x}) = \frac{1}{\|d\|} \phi'(0),$$

$$\frac{\partial}{\partial d} f(\bar{x} + ad) = \frac{1}{\|d\|} \phi'(a),$$

因此有：

$$\begin{aligned} \frac{\partial^2}{\partial d^2} f(\bar{x}) &= \lim_{a \rightarrow 0^+} \frac{\frac{\partial}{\partial d} f(\bar{x} + ad) - \frac{\partial}{\partial d} f(\bar{x})}{\frac{a\|d\|}{\|d\|^2}} \\ &= \frac{1}{\|d\|^2} \lim_{a \rightarrow 0^+} \frac{\phi'(a) - \phi'(0)}{a} \\ &= \frac{1}{\|d\|^2} \phi''(0) \end{aligned}$$

多元函数分析

二阶方向导数的几何意义: 描述函数 $f(x)$ 在 \bar{x} 处沿方向 d 的凹凸性和弯曲的程度.

n 元函数的泰勒展开式在非线性规划的理论分析中起着重要的作用, 关于 n 元函数的泰勒展开式, 成立如下定理.

多元函数分析

定理1.3.3

(1) 设函数 $f(x) : R^n \rightarrow R^1$, 若 $f(x)$ 在点 \bar{x} 的某个邻域 $N(\bar{x})$ 内一阶连续可微, 则存在 $\theta \in (0, 1)$ 使得

$$f(x) = f(\bar{x}) + \nabla f(\bar{x} + \theta(x - \bar{x}))^T (x - \bar{x}), \quad x \in N(\bar{x}).$$

(2) 设函数 $f(x) : R^n \rightarrow R^1$, 若 $f(x)$ 在点 \bar{x} 的某个邻域 $N(\bar{x})$ 内一阶连续可微, 则

$$f(x) = f(\bar{x}) + \nabla f(\bar{x})^T (x - \bar{x}) + o(\|x - \bar{x}\|), \quad x \in N(\bar{x}).$$

多元函数分析

定理1.3.3

(3) 函数 $f(x) : R^n \rightarrow R^1$, 若 $f(x)$ 在点 \bar{x} 的某个邻域 $N(\bar{x})$ 内二阶连续可微, 则存在 $\theta \in (0, 1)$ 使得

$$f(x) = f(\bar{x}) + \nabla f(\bar{x})^T(x - \bar{x}) + \frac{1}{2}(x - \bar{x})^T \nabla^2 f(\bar{x} + \theta(x - \bar{x}))(x - \bar{x}), \quad x \in N(\bar{x}). \quad (1.3.6)$$

(4) 数 $f(x) : R^n \rightarrow R^1$, 若 $f(x)$ 在点 \bar{x} 的某个邻域 $N(\bar{x})$ 内二阶连续可微, 则

$$f(x) = f(\bar{x}) + \nabla f(\bar{x})^T(x - \bar{x}) + \frac{1}{2}(x - \bar{x})^T \nabla^2 f(\bar{x})(x - \bar{x}) + o(\|x - \bar{x}\|^2), \quad x \in N(\bar{x}). \quad (1.3.7)$$

多元函数分析

证明:结论(1)(2)留给读者自证, 下面证明结论(3)和(4).

(3). 当 $x = \bar{x}$ 时, (1.3.6)显然成立, 因此我们仅考虑 $x \neq \bar{x}$ 的情况.
设

$$\phi(a) = f(\bar{x} + ad),$$

其中 $d = x - \bar{x}$, 由一元函数的泰勒公式有:

$$\phi(a) = \phi(0) + \phi'(0)a + \frac{1}{2}\phi''(\theta)a^2,$$

其中 $0 < \theta < a$. 取 $a = 1$, 得

$$\phi(1) = \phi(0) + \phi'(0) + \frac{1}{2}\phi''(\theta), \quad (1.3.8)$$

多元函数分析

证明:结论(1)(2)留给读者自证, 下面证明结论(3)和(4).

(3). 当 $x = \bar{x}$ 时, (1.3.6)显然成立, 因此我们仅考虑 $x \neq \bar{x}$ 的情况. 设

$$\phi(a) = f(\bar{x} + ad),$$

其中 $d = x - \bar{x}$, 由一元函数的泰勒公式有:

$$\phi(a) = \phi(0) + \phi'(0)a + \frac{1}{2}\phi''(\theta)a^2,$$

其中 $0 < \theta < a$. 取 $a = 1$, 得

$$\phi(1) = \phi(0) + \phi'(0) + \frac{1}{2}\phi''(\theta), \quad (1.3.8)$$

多元函数分析

显然 $\phi(1) = f(x)$, $\phi(0) = f(\bar{x})$, 由式(1.3.5)(1.3.2)知

$$\phi'(0) = d^T \nabla f(\bar{x}).$$

$$\phi''(\theta) = d^T \nabla^2 f(\bar{x} + \theta d)d.$$

将以上各式代入(1.3.8)式, 便得(1.3.6).

(4) 设

$$\phi(a) = f(\bar{x} + ad)$$

多元函数分析

其中 $a = \|x - \bar{x}\|$, $d = \frac{x - \bar{x}}{\|x - \bar{x}\|}$, 由一元函数的泰勒公式有:

$$\phi(a) = \phi(0) + \phi'(0)a + \frac{1}{2}\phi''(0)a^2 + o(a^2), \quad (1.3.9)$$

又有:

$$\phi(a) = f(x), \phi(0) = f(\bar{x})$$

$$\phi'(0)a = \nabla f(\bar{x})^T(x - \bar{x}),$$

$$\phi''(0)a^2 = (x - \bar{x})^T \nabla^2 f(\bar{x})^T(x - \bar{x}),$$

将以上各式代进(1.3.9)式, 即得(1.3.7)式.

多元函数分析

在(2)(4)中,若略去高阶无穷小量,则有近似关系式

$$f(x) \approx f(\bar{x}) + \nabla f(\bar{x})^T(x - \bar{x}), \quad (1.3.10)$$

$$f(x) \approx f(\bar{x}) + \nabla f(\bar{x})^T(x - \bar{x}) + \frac{1}{2}(x - \bar{x})^T \nabla^2 f(\bar{x})(x - \bar{x}), \quad x \in N(\bar{x}). \quad (1.3.11)$$

通常把(1.3.10)(1.3.11)的右边分别称为函数 $f(x)$ 在 \bar{x} 处的线性近似(函数)和二次近似(函数).

凸集与凸函数

凸集与凸函数是最优化方法理论分析中较为重要的一部分内容,在本节我们扼要地介绍凸集和凸函数的定义和基本性质.


定义1.4.1

设集合 $D \subset R^n$, 如果对于任意的 $x, y \in D$ 与任意的 $a \in [0, 1]$ 有

$$ax + (1 - a)y \in D,$$

则称集合 D 是凸集.(convex set)

凸集与凸函数

凸集的几何意义是:若两个点属于此集合,则这两点连线上的任意一点均属于此集合(见1.4.1)

凸集与凸函数

定理1.4.1

设 $D_1, D_2 \subset R^n$ 是凸集, $\alpha \in R^1$, 则

- (1) $D_1 \cap D_2 = \{x | x \in D_1, x \in D_2\}$ 是凸集.
- (2) $\alpha D_1 = \{\alpha x | x \in D_1\}$ 是凸集.
- (3) $D_1 + D_2 = \{x + y | x \in D_1, x \in D_2\}$ 是凸集.
- (4) $D_1 - D_2 = \{x - y | x \in D_1, x \in D_2\}$ 是凸集.

这个定理的证明可由凸集的定义直接得出, 留给读者作为练习.

凸集与凸函数

定理1.4.2

D 是凸集的充分必要条件是:对任意的 $m \geq 2$,任给 $x^{(1)}, \dots, x^{(m)} \in D$ 和实数 $\alpha_1, \dots, \alpha_m$, 且 $\alpha_i \geq 0, i = 1, \dots, m, \sum_{i=1}^m \alpha_i = 1$,均有

$$\alpha_1 x^{(1)} + \dots + \alpha_m x^{(m)} \in D$$

证明:当 $m = 2$ 时, 由凸集的定义,命题显然成立.

假设当 $m = k$ 时命题成立, 即当 $x^{(i)} \in D, i = 1, 2, \dots, k, \alpha_i \geq 0, i = 1, 2, \dots, k, \sum_{i=1}^k \alpha_i = 1$, 有 $\sum_{i=1}^k \alpha_i x^{(i)} \in D$.

当 $m = k + 1$ 时, $x^{(i)} \in D, i = 1, 2, \dots, k, k + 1, \alpha_i \geq 0, i = 1, 2, \dots, k, k + 1, \sum_{i=1}^{k+1} \alpha_i = 1$, 有

凸集与凸函数

$$\begin{aligned}\sum_{i=1}^{k+1} \alpha_i x^{(i)} &= \sum_{i=1}^k \alpha_i x^{(i)} + \alpha_{k+1} x^{(k+1)} \\ &= \left(\sum_{j=1}^k \alpha_j \right) \left[\sum_{i=1}^k \frac{\alpha_i}{\sum_{j=1}^k \alpha_j} x^{(i)} \right] + \alpha_{k+1} x^{(k+1)}\end{aligned}\tag{1.4.1}$$

由于 $\sum_{i=1}^k \frac{\alpha_i}{\sum_{j=1}^k \alpha_j} = 1$, 且 $\frac{\alpha_i}{\sum_{j=1}^k \alpha_j} \geq 0$, 由归纳法假设有

$$\sum_{i=1}^k \frac{\alpha_i}{\sum_{j=1}^k \alpha_j} x^{(i)} \in D\tag{1.4.2}$$

注意到 $\sum_{j=1}^k \alpha_j + \alpha_{k+1} = 1$, 由(1.4.1)式和(1.4.2)式及凸集的定义, 得到 $\sum_{i=1}^{k+1} \alpha_i x^{(i)} \in D$.

凸集与凸函数

定义1.4.2

设 D 是非空凸集, f 是定义在 D 上的函数, 如果对任意的 $x^{(1)}, x^{(2)} \in D, \alpha \in (0, 1)$, 均有

$$f(\alpha x^{(1)} + (1 - \alpha)x^{(2)}) \leq \alpha f(x^{(1)}) + (1 - \alpha)f(x^{(2)}),$$

则称 f 为 D 上的凸函数(convex function).


若对任意的 $x^{(1)}, x^{(2)} \in D, \alpha \in (0, 1)$, 均有

$$f(\alpha x^{(1)} + (1 - \alpha)x^{(2)}) < \alpha f(x^{(1)}) + (1 - \alpha)f(x^{(2)}),$$

则称 f 为 D 上的严格凸函数.

凸集与凸函数

若 $-f$ 为凸函数, 则称 f 为凹函数(concave function), 若 $-f$ 为严格凸函数, 则称 f 为严格凹函数.

凸函数的几何意义为: 当 x 为单变量时, 凸函数的任意两点间的曲线段总在弦的下方, 凹函数总在弦的上方(见).

下列函数均为 R^n 上的凸函数: (1) $f(x) = c^T x$; (2) $f(x) = \|x\|$; (3) $f(x) = x^T A x$ (其中 A 是对称正定矩阵).

凸集与凸函数

定义1.4.3

称集合

$$D_\alpha = \{x | f(x) \leq \alpha, x \in D\}$$

为函数 f 的**水平集**(level set).

定理1.4.3

若 D 是非空凸集, f 是定义在 D 上的凸函数, 则对任意的 $\alpha \in R$, 水平集 D_α 是凸集.

凸集与凸函数

定义1.4.3

称集合

$$D_\alpha = \{x | f(x) \leq \alpha, x \in D\}$$

为函数 f 的**水平集**(level set).

定理1.4.3

若 D 是非空凸集, f 是定义在 D 上的凸函数, 则对任意的 $\alpha \in R$, 水平集 D_α 是凸集.

凸集与凸函数

证明: 对于任意的 $x^{(1)}, x^{(2)} \in D_\alpha$, 即 $f(x^{(1)}) \leq a, f(x^{(2)}) \leq \alpha$, 则对于任意的 $\lambda \in (0, 1)$, 有

$$\begin{aligned} f(\lambda x^{(1)} + (1 - \lambda)x^{(2)}) &\leq \lambda f(x^{(1)}) + (1 - \lambda)f(x^{(2)}) \\ &\leq \lambda\alpha + (1 - \lambda)\alpha = \alpha \end{aligned}$$

所以

$$\lambda x^{(1)} + (1 - \lambda)x^{(2)} \in D_\alpha$$

凸集与凸函数

下面给出几个凸函数的判别定理.

定理1.4.4

$f(x)$ 为凸函数的充要条件是对任意的 $x, y \in R^n$, 一元函数 $\varphi(\alpha) = f(x + \alpha y)$ 是关于 α 的凸函数.

证明: 必要性 设 $\lambda_1 \geq 0, \lambda_2 \geq 0$, 且 $\lambda_1 + \lambda_2 = 1$, 由 $\varphi(\alpha)$ 的定义和 $f(x)$ 的凸性有

$$\begin{aligned}\varphi(\lambda_1\alpha_1 + \lambda_2\alpha_2) &= f(x + (\lambda_1\alpha_1 + \lambda_2\alpha_2)y) \\ &= f(\lambda_1x + \lambda_2x + (\lambda_1\alpha_1 + \lambda_2\alpha_2)y) \\ &= f(\lambda_1(x + \alpha_1y) + \lambda_2(x + \alpha_2y)) \\ &\leq \lambda_1f(x + \alpha_1y) + \lambda_2f(x + \alpha_2y) \\ &= \lambda_1\varphi(\alpha_1) + \lambda_2\varphi(\alpha_2)\end{aligned}$$

由函数的定义知 $\varphi(\alpha)$ 是凸函数.

凸集与凸函数

充分性 任取 $x, y \in R^n$, 设 $z^1 = x + \alpha_1 y, z^2 = x + \alpha_2 y$,

$$\begin{aligned} f(\lambda_1 z^1 + \lambda_2 z^2) &= f(\lambda_1(x + \alpha_1 y) + \lambda_2(x + \alpha_2 y)) \\ &= f(x + (\lambda_1 \alpha_1 + \lambda_2 \alpha_2)y) \\ &= \varphi(\lambda_1 \alpha_1 + \lambda_2 \alpha_2) \\ &\leq \lambda_1 \varphi(\alpha_1) + \lambda_2 \varphi(\alpha_2) \\ &= \lambda_1 f(x + \alpha_1 y) + \lambda_2 f(x + \alpha_2 y) \\ &= \lambda_1 f(z^1) + \lambda_2 f(z^2) \end{aligned}$$

故知 $f(x)$ 是凸函数.

凸集与凸函数

定理1.4.5

设 $D \subset R^n$ 是非空开凸集, $f: D \subset R^n \rightarrow R^1$, 且 $f(x)$ 在 D 上一阶连续可微, 则

(1) $f(x)$ 是 D 上的凸函数的充要条件是

$$f(y) \geq f(x) + \nabla f(x)^T(y - x), \quad \forall x, y, \in D. \quad (1.4.3)$$

(2) $f(x)$ 是 D 上的严格凸函数的充要条件是

$$f(y) > f(x) + \nabla f(x)^T(y - x), \quad \forall x, y, \in D, \text{ 且 } x \neq y. \quad (1.4.4)$$

凸集与凸函数

证明: 必要性 设 $f(x)$ 是 D 上的凸函数, 则 $\forall \alpha \in (0, 1)$ 有

$$f(\alpha y + (1 - \alpha)x) \leq \alpha f(y) + (1 - \alpha)f(x),$$

故

$$\frac{f(x + \alpha(y - x)) - f(x)}{\alpha} \leq f(y) - f(x). \quad (1.4.5)$$

由泰勒展开式可知

$$f(x + \alpha(y - x)) - f(x) = \alpha \nabla f(x)^T (y - x) + o(\alpha \|y - x\|),$$

凸集与凸函数

将其代入(1.4.5)式得

$$\nabla f(x)^T(y-x) + \frac{o(\alpha\|y-x\|)}{\alpha} \leq f(y) - f(x).$$

两边关于 $\alpha \rightarrow 0$ 取极限, 有 $\nabla f(x)^T(y-x) \leq f(y) - f(x)$.

充分性 设 $f(y) - f(x) \geq \nabla f(x)^T(y-x), \forall x, y \in D, \forall \alpha \in (0, 1)$.
取 $\bar{x} = \alpha x + (1-\alpha)y$, 由于 D 是凸集, 故 $\bar{x} \in D$. 由(1.4.3)式知,
对 $x, \bar{x} \in D$ 和 $y, \bar{x} \in D$ 分别有

$$f(\bar{x}) + \nabla f(\bar{x})^T(x - \bar{x}) \leq f(x), \quad \forall x \in D, \quad (1.4.6)$$

$$f(\bar{x}) + \nabla f(\bar{x})^T(y - \bar{x}) \leq f(y), \quad \forall y \in D. \quad (1.4.7)$$

凸集与凸函数

对(1.4.6)式乘以 α , (1.4.7)式乘以 $(1 - \alpha)$ 相加得

$$f(\bar{x}) + \nabla f(\bar{x})^T(\alpha x + (1 - \alpha)y - \bar{x}) \leq \alpha f(x) + (1 - \alpha)f(y),$$

注意到 $\bar{x} = \alpha x + (1 - \alpha)y$, 于是得

$$f(\bar{x}) \leq \alpha f(x) + (1 - \alpha)f(y),$$

即

$$f(\alpha x + (1 - \alpha)y) \leq \alpha f(x) + (1 - \alpha)f(y).$$

上式对任意的 $\alpha \in (0, 1)$ 成立, 故由定义1.4.2知 $f(x)$ 是凸集 D 上的凸函数.

类似可证结论(2).

凸集与凸函数

若函数 $f(x)$ 二阶连续可微，则有下面的判别定理.

定理1.4.6

设 $D \subset R^n$ 是非空开凸集， $f: D \subset R^n \rightarrow R^1$ ，且 $f(x)$ 在 D 上二阶连续可微，则 $f(x)$ 是 D 上的凸函数的充要条件是 $f(x)$ 的Hessian矩阵 $\nabla^2 f(x)$ 在 D 上是半正定的.

证明：必要性 任取 $\bar{x} \in D$ ，由 D 是开凸集知， $\forall x \in D$ ，存在 $\delta > 0$ 使当 $\alpha \in (0, \delta)$ 时有 $\bar{x} + \alpha x \in D$ ，由于 $f(x)$ 是 D 上的凸函数，由定理1.4.5的结论(1)有

$$f(\bar{x}) + \alpha \nabla f(\bar{x})^T x \leq f(\bar{x} + \alpha x), \quad \forall x \in D. \quad (1.4.8)$$

凸集与凸函数

又由于 $f(x)$ 二阶连续可微, 按二阶泰勒展开式有

$$f(\bar{x} + \alpha x) = f(\bar{x}) + \alpha \nabla f(\bar{x})^T x + \frac{1}{2} \alpha^2 x^T \nabla^2 f(\bar{x})^T x + o(\|\alpha x\|^2). \quad (1.4.9)$$

将上式代入(1.4.8)得

$$\frac{1}{2} \alpha^2 x^T \nabla^2 f(\bar{x})^T x + o(\|\alpha x\|^2) \geq 0, \quad \forall x \in D.$$

上式两边除以 α^2 , 并令 $\alpha \rightarrow 0$, 使得

$$x^T \nabla^2 f(\bar{x})^T x \geq 0, \quad \forall x \in D, \quad (1.4.10)$$

即 $\nabla^2 f(x)$ 在 D 上是半正定的.

凸集与凸函数

充分性 设 $\nabla^2 f(x)$ 在任意一点 $x \in D$ 半正定, 将 $f(x)$ 在 $\bar{x}(\bar{x} \in D)$ 处泰勒展开

$$f(x) = f(\bar{x}) + \nabla f(\bar{x})^T(x - \bar{x}) + \frac{1}{2}(x - \bar{x})^T \nabla^2 f(\xi)(x - \bar{x}), \quad (1.4.11)$$

其中 $\xi = \bar{x} + \theta(x - \bar{x}) = \theta x + (1 - \theta)\bar{x}(0 < \theta < 1)$. 由于 $\theta \in (0, 1)$, 及 D 是凸集, 因而 $\xi \in D$, 又由条件知 $\nabla^2 f(\xi)$ 半正定, 故有 $(x - \bar{x})^T \nabla^2 f(\xi)(x - \bar{x}) \geq 0$. 由(1.4.11)式可得

$$f(x) - f(\bar{x}) \geq \nabla f(\bar{x})^T(x - \bar{x}).$$

定理1.4.5的结论(1)知 $f(x)$ 是 D 上的凸函数.

凸集与凸函数

定理1.4.7

设 $D \subset R^n$ 是非空开凸集, $f: D \subset R^n \rightarrow R^1$, 且 $f(x)$ 在 D 上二阶连续可微, 如果 $f(x)$ 的 Hessian 矩阵 $\nabla^2 f(x)$ 在 D 上是正定的. 则 $f(x)$ 是 D 上的严格凸函数, 反之如果 $f(x)$ 是严格凸函数, 则 $\nabla^2 f(x)$ 在 D 上是半正定矩阵.

证明: $\forall x, y \in D, x \neq y$, 由 $f(x)$ 在 x 处的泰勒展开式有

$$f(y) = f(x) + \nabla f(x)^T (y - x) + \frac{1}{2} (y - x)^T \nabla^2 f(\xi) (y - x),$$

其中 $\xi = x + \theta(y - x), \theta \in (0, 1)$. 因为 D 是凸集, 故 $\xi \in D$, 由此, 根据 $\nabla^2 f(x)$ 在 D 上的正定性, 可知

$$(y - x)^T \nabla^2 f(\xi) (y - x) > 0.$$

凸集与凸函数

代入泰勒展开式有

$$f(y) - f(x) > \nabla f(x)^T (y - x),$$

根据定理1.4.5的结论(2)知 $f(x)$ 是 D 上的严格凸函数.

又由 $f(x)$ 在 D 上是严格凸函数知 $f(x)$ 在 D 上是必凸函数, 根据定理1.4.6知 $f(x)$ 的Hessian矩阵 $\nabla^2 f(x)$ 在 D 上是半正定矩阵.

凸集与凸函数

注

值得注意的是由 $f(x)$ 在 D 上是严格凸函数不能推出 $\nabla^2 f(x)$ 在 D 上是正定矩阵.例如,一元函数 $f(x) = x^4$ 是严格凸函数, $f''(x) = 12x^2$,但 $f''(0) = 0$,即 $f''(x)$ 在 $x = 0$ 处不是正定的.

凸集分离定理是研究非线性规划最优性条件的理论基础,下面予以介绍.

凸集与凸函数

定义1.4.4

设 D_1, D_2 是两个非空集合, $\alpha \in R^n, \beta \in R^1$, 若有

$$D_1 \subset H^+ = \{x \in R^n | \alpha^T x \geq \beta\},$$

$$D_2 \subset H^- = \{x \in R^n | \alpha^T x \leq \beta\},$$

则称超平面 $H = \{x \in R^n | \alpha^T x = \beta\}$ 分离了集合 D_1 与 D_2 , 进而若有 $D_1 \cup D_2 \not\subset H$, 则称 H 正常分离了 D_1 与 D_2 . 若有

$$D_1 \subset \bar{H}^+ = \{x \in R^n | \alpha^T x > \beta\},$$

$$D_2 \subset \bar{H}^- = \{x \in R^n | \alpha^T x < \beta\},$$

则称 H 严格分离了 D_1 与 D_2 .

凸集与凸函数

定理1.4.8

设 $D \subset R^n$ 是非空闭凸集, $y \in R^n$ 但 $y \notin D$, 则

(1) 存在唯一的一点 $\bar{x} \in D$, 使得 y 到 D 的距离最小. 即有

$$\|\bar{x} - y\| = \inf\{\|x - y\|, x \in D\} > 0.$$

(2) \bar{x} 是 y 到 D 的最小距离点的充要条件是

$$(x - \bar{x})^T (\bar{x} - y) \geq 0, \quad \forall x \in D.$$

凸集与凸函数

证明:(1)设有单位球 $S = \{s \mid \|s\| \leq 1, s \in R^n\}$,取充分大的 $\mu > 0$ 可使

$$D \cap (y + \mu S) \neq \emptyset.$$

注意到 D 是闭集, $y + \mu S$ 是有界闭集, 故 $D \cap (y + \mu S)$ 是非空有界闭集.因此, 连续函数

$$f(x) = \|y - x\|$$

在 $D \cap (y + \mu S)$ 上取到最小值.设这个最小值在点 $\bar{x} \in D \cap (y + \mu S)$ 上达到, 则 \bar{x} 是 y 到 D 的距离最小的点。

凸集与凸函数

现证点 \bar{x} 的唯一性. 设有 $\tilde{x} \in D, \tilde{x} \neq \bar{x}$, 使

$$\|y - \tilde{x}\| = \|y - \bar{x}\| = \gamma,$$

则

$$\left\| y - \frac{\bar{x} + \tilde{x}}{2} \right\| \leq \frac{1}{2} \|y - \bar{x}\| + \frac{1}{2} \|y - \tilde{x}\| = \gamma.$$

由 D 是凸集知 $\frac{\bar{x} + \tilde{x}}{2} \in D$, 及 γ 是最小距离, 故上式等号成立, 从而存在 $\lambda \in R^1$, 必有

$$y - \bar{x} = \lambda(y - \tilde{x}).$$

又由于 $\|y - \bar{x}\| = \|y - \tilde{x}\| = \gamma$, 所以 $|\lambda| = 1$. 若 $\lambda = -1$, 则由 $y - \bar{x} = -y + \tilde{x}$ 知 $y = \frac{\bar{x} + \tilde{x}}{2} \in D$, 这与 $y \notin D$ 矛盾. 因而 $\lambda = 1$, 即有 $\tilde{x} = \bar{x}$, \bar{x} 的唯一性得证.

凸集与凸函数

(2)充分性 对任意的 $x \in D$,有

$$\begin{aligned}\|x - y\|^2 &= \|x - \bar{x} + \bar{x} - y\|^2 \\ &= \|x - \bar{x}\|^2 + \|\bar{x} - y\|^2 + 2(x - \bar{x})^T(\bar{x} - y).\end{aligned}$$

由于 $\|x - \bar{x}\|^2 > 0$ 及 $(x - \bar{x})^T(\bar{x} - y) \geq 0$, 从上式有

$$\|x - y\|^2 > \|\bar{x} - y\|^2, \quad \forall x \in D,$$

即 \bar{x} 为最小距离点.

必要性 由 \bar{x} 是 y 到 D 距离最小的点, 知

$$\|\bar{x} - y\| \leq \|x - y\|, \quad \forall x \in D,$$

或等价地有

$$\|\bar{x} - y\|^2 \leq \|x - y\|^2, \quad \forall x \in D. \quad (1.4.12)$$

由于 $\bar{x} \in D$ 及 D 是凸集, 所以, 对任意的 $\alpha \in (0, 1)$, 有

$$\bar{x} + \alpha(x - \bar{x}) = \alpha x + (1 - \alpha)\bar{x} \in D, \quad \forall x \in D.$$

凸集与凸函数

用上式代替(1.4.12)中的 x , 则得

$$\begin{aligned}\|\bar{x} - y\|^2 &\leq \|y - \bar{x} - \alpha(x - \bar{x})\|^2 \\ &= \|y - \bar{x}\|^2 + \alpha^2\|x - \bar{x}\|^2 - 2\alpha(y - \bar{x})^T(x - \bar{x}).\end{aligned}$$

从上式可得

$$\alpha^2\|x - \bar{x}\|^2 - 2\alpha(y - \bar{x})^T(x - \bar{x}) \geq 0, \quad \forall \alpha \in (0, 1).$$

将上式两端同除以 α , 并令 $\alpha \rightarrow 0$, 便得

$$(x - \bar{x})^T(\bar{x} - y) \geq 0, \quad \forall x \in D.$$

凸集与凸函数

定理1.4.9(点与凸集的分离定理)

设 $D \subset R^n$ 是非空闭凸集, $y \in R^n$ 但 $y \notin D$. 则存在 $\alpha \in R^n$ 但 $\alpha \neq 0, \beta \in R^1$, 使得

$$\alpha^T x \leq \beta < \alpha^T y, \quad \forall x \in D,$$

即存在超平面 $H = \{x | \alpha^T x = \beta, x \in R^n\}$ 严格分离 y 与 D .

凸集与凸函数

证明: 由 D 是闭凸集, $y \notin D$ 及定理1.4.8知, 存在唯一的最小距离点 $\bar{x} \in D$, 使得

$$(x - \bar{x})^T(\bar{x} - y) \geq 0, \quad \forall x \in D$$

成立, 上式也即

$$x^T(y - \bar{x}) \leq \bar{x}^T(y - \bar{x}), \quad \forall x \in D, \quad (1.4.13)$$

而

$$\|y - \bar{x}\|^2 = (y - \bar{x})^T(y - \bar{x}) = y^T(y - \bar{x}) - \bar{x}^T(y - \bar{x}).$$

凸集与凸函数

由(1.4.13)式, 得

$$\|y - \bar{x}\|^2 \leq y^T(y - \bar{x}) - x^T(y - \bar{x}), \quad \forall x \in D.$$

令 $\alpha = y - \bar{x}$, 显然, $\alpha \neq 0$, 则上式成为

$$0 < \|\alpha\|^2 \leq y^T \alpha - x^T \alpha, \quad \forall x \in D,$$

即 $\alpha^T x < \alpha^T y, \forall x \in D$. 令 $\beta = \sup\{\alpha^T x | x \in D\}$, 立即得

$$\alpha^T x \leq \beta < \alpha^T y, \quad \forall x \in D,$$

即超平面 $H = \{x | \alpha^T x = \beta, x \in R^n\}$ 严格分离 y 与 D .