

第 1 章 引 言

1.1 学 科 简 述

最优化理论与算法是一个重要的数学分支,它所研究的问题是讨论在众多的方案中什么样的方案最优以及怎样找出最优方案.这类问题普遍存在.例如,工程设计中怎样选择设计参数,使得设计方案既满足设计要求又能降低成本;资源分配中,怎样分配有限资源,使得分配方案既能满足各方面的基本要求,又能获得好的经济效益;生产计划安排中,选择怎样的计划方案才能提高产值和利润;原料配比问题中,怎样确定各种成分的比例,才能提高质量,降低成本;城建规划中,怎样安排工厂、机关、学校、商店、医院、住户和其他单位的合理布局,才能方便群众,有利于城市各行各业的发展;农田规划中,怎样安排各种农作物的合理布局,才能保持高产稳产,发挥地区优势;军事指挥中,怎样确定最佳作战方案,才能有效地消灭敌人,保存自己,有利于战争的全局;在人类活动的各个领域,诸如此类,不胜枚举.最优化这一数学分支,正是为这些问题的解决,提供理论基础和求解方法,它是一门应用广泛、实用性强的学科.

最优化是个古老的课题.长期以来,人们对最优化问题进行着探讨和研究.早在 17 世纪,英国科学家 Newton 发明微积分的时代,就已提出极值问题,后来又出现 Lagrange 乘数法.1847 年法国数学家 Cauchy 研究了函数值沿什么方向下降最快的问题,提出最速下降法.1939 年前苏联数学家 Л. В. Канторович 提出了解决下料问题和运输问题这两种线性规划问题的求解方法.人们关于最优化问题的研究工作,随着历史的发展不断深入.但是,任何科学的进步,都受到历史条件的限制,直至 20 世纪 30 年代,最优化这个古老课题并未形成独立的有系统的学科.

20 世纪 40 年代以来,由于生产和科学研究突飞猛进地发展,特别是电子计算机日益广泛应用,使最优化问题的研究不仅成为一种迫切需要,而且有了求解的有力工具.因此最优化理论和算法迅速发展起来,形成一个新的学科.至今已出现线性规划、整数规划、非线性规划、几何规划、动态规划、随机规划、网络流等许多分支.最优化理论和算法在实际应用中正在发挥越来越大的作用.

1.2 线性与非线性规划问题

线性与非线性规划有着广泛的实际背景,许多实际问题抽象成数学模型后,可归结为求解这类问题,本书重点介绍线性与非线性规划.下面先来研究几个例题.

例 1.2.1 生产计划问题

设某工厂用 4 种资源生产 3 种产品,每单位第 j 种产品需要第 i 种资源的数量为 a_{ij} ,可获利润为 c_j ,第 i 种资源总消耗量不能超过 b_i ,由于市场限制,第 j 种产品的产量不超过 d_j ,试问如何安排生产才能使总利润最大?

解析 下面分析怎样建立数学模型. 设 3 种产品的产量分别为 x_1, x_2, x_3 , 这是决策变量, 目标函数是总利润 $c_1x_1 + c_2x_2 + c_3x_3$, 约束条件有资源限制 $a_{i1}x_1 + a_{i2}x_2 + a_{i3}x_3 \leq b_i$ ($i=1,2,3,4$), 市场销量限制, $x_j \leq d_j$ ($j=1,2,3$), 及产量非负限制 $x_j \geq 0$ ($j=1,2,3$). 问题概括为, 在一组约束条件下, 确定一个最优生产方案 $\mathbf{x}^* = (x_1^*, x_2^*, x_3^*)$, 使目标函数值最大. 数学模型如下:

$$\begin{aligned} \max \quad & \sum_{j=1}^3 c_j x_j \\ \text{s. t.} \quad & \sum_{j=1}^3 a_{ij} x_j \leq b_i, \quad i = 1, \dots, 4, \\ & x_j \leq d_j, \quad j = 1, 2, 3, \\ & x_j \geq 0, \quad j = 1, 2, 3, \end{aligned}$$

其中 $\max$ 表示 maximize, 读作“极大化”, s. t. 表示 subject to, 读作“约束条件是”.

例 1.2.2 食谱问题

设市场上可买到 n 种不同的食品, 第 j 种食品单位售价为 c_j . 每种食品含有 m 种基本营养成分, 第 j 种食品每一个单位含第 i 种营养成分为 a_{ij} . 又设每人每天对第 i 种营养成分的需要量不少于 b_i . 试确定在保证营养要求条件下的最经济食谱.

解析 建立食谱问题的数学模型. 设每人每天需要各种食品的数量分别为 $x_1, x_2, \dots, x_n$. 我们的目标是使伙食费用最少, 即使 $c_1x_1 + c_2x_2 + \dots + c_nx_n$ 最小. 条件是保证用餐者对各种营养成分的基本需要, 即满足 $a_{i1}x_1 + a_{i2}x_2 + \dots + a_{in}x_n \geq b_i$ ($i=1, 2, \dots, m$). 数学模型是

$$\begin{aligned} \min \quad & \sum_{j=1}^n c_j x_j \\ \text{s. t.} \quad & \sum_{j=1}^n a_{ij} x_j \geq b_i, \quad i = 1, \dots, m, \\ & x_j \geq 0, \quad j = 1, \dots, n, \end{aligned}$$

其中 $\min$ 表示 minimize, 读作“极小化”.

例 1.2.3 结构设计问题

以两个构件组成的对称桁架为例(参见图 1.2.1).

已知桁架的跨度 $2L$, 高度 x_2 的上限 H , 承受负荷 $2P$, 钢管的厚度 T , 材料比重 ρ , 纵向弹性模量 E 及容许应力 σ_y . 试确定钢管的平均直径 x_1 及桁架的高度 x_2 , 使桁架的重量最小.

解析 桁架的重量

$$G = 2\pi\rho T x_1 (L^2 + x_2^2)^{\frac{1}{2}},$$

它是平均直径 x_1 和高度 x_2 的函数. x_1 和 x_2 的选择不是任意的, 必须满足以下几个条件:

(1) 由于空间限制, 要求 x_2 不能超过高度上限 H , 即

$$x_2 \leq H.$$

(2) 钢管上的压应力不能超过材料的容许应力 σ_y . 在负荷 $2P$ 作用下, 钢管承受的压力为

$$F = \frac{P}{\cos\theta} = \frac{P(L^2 + x_2^2)^{\frac{1}{2}}}{x_2},$$

钢管的横截面积

$$S \approx \pi T x_1,$$

由此可知, 钢管上的压应力为

$$\sigma(x_1, x_2) = \frac{P(L^2 + x_2^2)^{\frac{1}{2}}}{\pi T x_1 x_2},$$

因此要求

$$\frac{P(L^2 + x_2^2)^{\frac{1}{2}}}{\pi T x_1 x_2} \leq \sigma_y.$$

(3) 参数的选择还必须保证在负荷 $2P$ 的作用下钢管不发生弯曲, 这就要求压应力不超过临界应力 σ_l . 临界应力可由 Euler 公式算出:

$$\sigma_l = \frac{\pi^2 E (x_1^2 + T^2)}{8(L^2 + x_2^2)},$$

其中 E 是已知的弹性模量. 按此要求应有

$$\frac{P(L^2 + x_2^2)^{\frac{1}{2}}}{\pi T x_1 x_2} \leq \frac{\pi^2 E (x_1^2 + T^2)}{8(L^2 + x_2^2)}.$$

根据以上分析, 桁架的最优设计问题, 就是求重量函数 G 在上述 3 个约束条件下的极小




图 1.2.1

点问题. 它的数学模型是

$$\begin{aligned}
 \min \quad & 2\pi\rho T x_1 (L^2 + x_2^2)^{\frac{1}{2}} \\
 \text{s. t.} \quad & x_2 \leq H, \\
 & \frac{P(L^2 + x_2^2)^{\frac{1}{2}}}{\pi T x_1 x_2} \leq \sigma_y, \\
 & \frac{P(L^2 + x_2^2)^{\frac{1}{2}}}{\pi T x_1 x_2} \leq \frac{\pi^2 E(x_1^2 + T^2)}{8(L^2 + x_2^2)}, \\
 & x_1, x_2 \geq 0.
 \end{aligned}$$

例 1.2.4 选址问题

设有 n 个市场, 第 j 个市场的位置为 (a_j, b_j) , 对某种货物的需要量为 $q_j (j=1, \dots, n)$. 现计划建立 m 个货栈, 第 i 个货栈的容量为 $c_i (i=1, \dots, m)$. 试确定货栈的位置, 使各货栈到各市场的运输量与路程乘积之和最小.

解析 现在来建立数学模型. 设第 i 个货栈的位置为 $(x_i, y_i) (i=1, \dots, m)$. 第 i 个货栈供给第 j 个市场的货物量为 $W_{ij} (i=1, \dots, m; j=1, \dots, n)$. 第 i 个货栈到第 j 个市场的距离为 d_{ij} , 一般定义为

$$d_{ij} = \sqrt{(x_i - a_j)^2 + (y_i - b_j)^2} \quad (1.2.1)$$

或

$$d_{ij} = |x_i - a_j| + |y_i - b_j|, \quad (1.2.2)$$

我们的目标是使运输量与路程乘积之和最小, 如果距离按(1.2.1)式定义, 就是使

$$\sum_{i=1}^m \sum_{j=1}^n W_{ij} \sqrt{(x_i - a_j)^2 + (y_i - b_j)^2}$$

最小. 约束条件是:

- (1) 每个货栈向各市场提供的货物量之和不能超过它的容量;
- (2) 每个市场从各货栈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.

因此, 问题的数学模型如下:

$$\begin{aligned}
 \min \quad & \sum_{i=1}^m \sum_{j=1}^n W_{ij} \sqrt{(x_i - a_j)^2 + (y_i - b_j)^2} \\
 \text{s. t.} \quad & \sum_{j=1}^n W_{ij} \leq c_i, \quad i = 1, \dots, m, \\
 & \sum_{i=1}^m W_{ij} = q_j, \quad j = 1, \dots, n, \\
 & W_{ij} \geq 0, \quad i = 1, \dots, m, j = 1, \dots, n.
 \end{aligned}$$

在上述例 1.2.1 和例 1.2.2 的数学模型中,目标函数和约束函数都是线性的,称之为线性规划问题;而例 1.2.3 和例 1.2.4 的数学模型中含有非线性函数,因此称为非线性规划问题.

在线性规划与非线性规划中,满足约束条件的点称为可行点,全体可行点组成的集合称为可行集或可行域. 如果一个问题可行集是整个空间,那么此问题就称为无约束问题.

下面给出最优解概念.

定义 1.2.1 设 $f(x)$ 为目标函数, S 为可行域, $\bar{x} \in S$, 若对每个 $x \in S$, 成立 $f(x) \geq f(\bar{x})$, 则称 $\bar{x}$ 为 $f(x)$ 在 S 上的全局极小点.

定义 1.2.2 设 $f(x)$ 为目标函数, S 为可行域, 若存在 $\bar{x} \in S$ 的 $\epsilon > 0$ 邻域 $N(\bar{x}, \epsilon) = \{x \mid \|x - \bar{x}\| < \epsilon\}$, 使得对每个 $x \in S \cap N(\bar{x}, \epsilon)$ 成立 $f(x) \geq f(\bar{x})$, 则称 $\bar{x}$ 为 $f(x)$ 在 S 上的一个局部极小点.

对于极大化问题,可类似地定义全局极大点和局部极大点,这里不再叙述.

根据上述定义,全局极小点也是局部极小点,而局部极小点不一定是全局极小点. 但是对于某些特殊情形,如将在后面介绍的凸规划,局部极小点也是全局极小点.

* 1.3 几个数学概念

1.3.1 向量范数和矩阵范数

定义 1.3.1 若实值函数 $\|\cdot\|: \mathbb{R}^n \rightarrow \mathbb{R}$ 满足下列条件:

- (1) $\|x\| \geq 0, \forall x \in \mathbb{R}^n; \|x\| = 0$ 当且仅当 $x = 0$;
- (2) $\|\alpha x\| = |\alpha| \|x\|, \forall \alpha \in \mathbb{R}, x \in \mathbb{R}^n$;
- (3) $\|x + y\| \leq \|x\| + \|y\|, \forall x, y \in \mathbb{R}^n$.

则称 $\|\cdot\|$ 为向量范数. 其中 $\mathbb{R}^n$ 表示 n 维向量空间.

设 $x = (x_1, x_2, \dots, x_n)^T \in \mathbb{R}^n$, 常用的向量范数有 L_1 范数, L_2 范数和 L_∞ 范数, 分别为

$$\|x\|_1 = \sum_{j=1}^n |x_j|,$$

$$\|x\|_2 = \left(\sum_{j=1}^n x_j^2 \right)^{\frac{1}{2}},$$

$$\|x\|_\infty = \max_j |x_j|.$$

一般地, 对于 $1 \leq p < \infty$, L_p 范数为

$$\|x\|_p = \left(\sum_{j=1}^n |x_j|^p \right)^{\frac{1}{p}}.$$

关于范数的等价性,有下列定义.

定义 1.3.2 设 $\|\cdot\|_\alpha$ 和 $\|\cdot\|_\beta$ 是 $\mathbb{R}^n$ 上任意两个范数,如果存在正数 c_1 和 c_2 ,使得对每个 $\mathbf{x} \in \mathbb{R}^n$ 成立 $c_1 \|\mathbf{x}\|_\alpha \leq \|\mathbf{x}\|_\beta \leq c_2 \|\mathbf{x}\|_\alpha$,则称范数 $\|\mathbf{x}\|_\alpha$ 和范数 $\|\mathbf{x}\|_\beta$ 等价.

在 $\mathbb{R}^n$ 中任何两种范数均等价.

这里应指出,上述向量范数中, $\|\mathbf{x}\|_2$ 称为 Euclid 范数,如无特殊指明,后面将用 $\mathbb{R}^n$ 表示 n 维 Euclid 空间.

关于矩阵范数,定义如下.

定义 1.3.3 设 $\mathbf{A}$ 为 $m \times n$ 矩阵, $\|\cdot\|_\alpha$ 是 $\mathbb{R}^m$ 上向量范数, $\|\cdot\|_\beta$ 是 $\mathbb{R}^n$ 上向量范数,定义矩阵范数 $\|\mathbf{A}\| = \max_{\|\mathbf{x}\|_\beta=1} \|\mathbf{Ax}\|_\alpha$.

根据矩阵范数定义,对于单位矩阵 $\mathbf{I}$,总有 $\|\mathbf{I}\| = 1$. 关于矩阵范数有下列结论.

定理 1.3.1 矩阵范数具有下列性质:

- (1) $\|\mathbf{Ax}\|_\alpha \leq \|\mathbf{A}\| \|\mathbf{x}\|_\beta$;
- (2) $\|\lambda \mathbf{A}\| = |\lambda| \|\mathbf{A}\|$;
- (3) $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$;
- (4) $\|\mathbf{AD}\| \leq \|\mathbf{A}\| \|\mathbf{D}\|$.

其中 $\mathbf{A}, \mathbf{B}$ 为 $m \times n$ 矩阵, $\mathbf{D}$ 是 $n \times p$ 矩阵, λ 为实数, $\mathbf{x} \in \mathbb{R}^n$.

设矩阵 $\mathbf{A} = (a_{ij})_{m \times n}$, 下面给出 3 种常用的矩阵范数,分别记作 $\|\mathbf{A}\|_1$, $\|\mathbf{A}\|_2$, $\|\mathbf{A}\|_\infty$:

- (1) $\|\mathbf{A}\|_1 = \max_j \sum_{i=1}^m |a_{ij}|$;
- (2) $\|\mathbf{A}\|_2 = \sqrt{\lambda_{\mathbf{A}^T \mathbf{A}}}$;
- (3) $\|\mathbf{A}\|_\infty = \max_i \sum_{j=1}^n |a_{ij}|$.

其中 $\lambda_{\mathbf{A}^T \mathbf{A}}$ 表示 $\mathbf{A}^T \mathbf{A}$ 的最大特征值. $\|\mathbf{A}\|_2$ 称为 $\mathbf{A}$ 的谱范数.

1.3.2 序列的极限

定义 1.3.4 设 $\{\mathbf{x}^{(k)}\}$ 是 $\mathbb{R}^n$ 中一个向量序列, $\bar{\mathbf{x}} \in \mathbb{R}^n$, 如果对每个任给的 $\epsilon > 0$ 存在正整数 K_ϵ , 使得当 $k > K_\epsilon$ 时就有 $\|\mathbf{x}^{(k)} - \bar{\mathbf{x}}\| < \epsilon$, 则称序列收敛到 $\bar{\mathbf{x}}$, 或称序列以 $\bar{\mathbf{x}}$ 为极限, 记作 $\lim_{k \rightarrow \infty} \mathbf{x}^{(k)} = \bar{\mathbf{x}}$.

按此定义, 序列若存在极限, 则任何子序列有相同的极限, 即序列的极限是惟一的.

定义 1.3.5 设 $\{\mathbf{x}^{(k)}\}$ 是 $\mathbb{R}^n$ 中一个向量序列, 如果存在一个子序列 $\{\mathbf{x}^{(k_j)}\}$, 使 $\lim_{k_j \rightarrow \infty} \mathbf{x}^{(k_j)} = \hat{\mathbf{x}}$, 则称 $\hat{\mathbf{x}}$ 是序列 $\{\mathbf{x}^{(k)}\}$ 的一个聚点.

根据定义易知, 如果无穷序列有界, 即存在正数 M , 使得对所有 k 均有 $\|\mathbf{x}^{(k)}\| \leq M$,

则这个序列必有聚点.

定义 1.3.6 设 $\{\mathbf{x}^{(k)}\}$ 是 $\mathbb{R}^n$ 中一个向量序列, 如果对任意给定的 $\epsilon > 0$, 总存在正整数 K_ϵ , 使得当 $m, l > K_\epsilon$ 时, 就有 $\|\mathbf{x}^{(m)} - \mathbf{x}^{(l)}\| < \epsilon$, 则 $\{\mathbf{x}^{(k)}\}$ 称为 Cauchy 序列.

在 $\mathbb{R}^n$ 中, Cauchy 序列有极限.

定理 1.3.2 设 $\{\mathbf{x}^{(j)}\} \subset \mathbb{R}^n$ 为 Cauchy 序列, 则 $\{\mathbf{x}^{(j)}\}$ 的聚点必为极限点. (证明从略)

后面算法介绍和理论分析中, 还常涉及闭集、开集、紧集等概念. 定义如下: 设 S 为 $\mathbb{R}^n$ 中一个集合, 如果 S 中每个收敛序列的极限均属于 S , 则称 S 为闭集. 如果对每一点 $\hat{\mathbf{x}} \in S$, 存在正数 ϵ , 使得 $\hat{\mathbf{x}}$ 的 ϵ 邻域 $N(\hat{\mathbf{x}}, \epsilon) = \{\mathbf{x} \mid \|\mathbf{x} - \hat{\mathbf{x}}\| < \epsilon\} \subset S$, 则称 S 为开集. 如果 S 是有界闭集, 则称 S 为紧集.

1.3.3 梯度、Hesse 矩阵、Taylor 展开式

设集合 $S \subset \mathbb{R}^n$ 非空, $f(\mathbf{x})$ 为定义在 S 上的实函数. 如果 f 在每一点 $\mathbf{x} \in S$ 连续, 则称 f 在 S 上连续, 记作 $f \in C(S)$. 再设 S 为开集, 如果在每一点 $\mathbf{x} \in S$, 对所有 $j=1, \dots, n$, 偏导数 $\frac{\partial f(\mathbf{x})}{\partial x_j}$ 存在且连续, 则称 f 在开集 S 上连续可微, 记作 $f \in C^1(S)$. 如果在每一点 $\mathbf{x} \in S$, 对所有 $i=1, \dots, n$ 和 $j=1, \dots, n$, 二阶偏导数 $\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j}$ 存在且连续, 则称 f 在开集 S 上二次连续可微, 记作 $f \in C^2(S)$.

函数 f 在 $\mathbf{x}$ 处的梯度为 n 维列向量:

$$\nabla f(\mathbf{x}) = \left[\frac{\partial f(\mathbf{x})}{\partial x_1}, \frac{\partial f(\mathbf{x})}{\partial x_2}, \dots, \frac{\partial f(\mathbf{x})}{\partial x_n} \right]^T. \quad (1.3.1)$$

f 在 $\mathbf{x}$ 处的 Hesse 矩阵为 $n \times n$ 矩阵 $\nabla^2 f(\mathbf{x})$, 第 i 行第 j 列元素为

$$[\nabla^2 f(\mathbf{x})]_{ij} = \frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j}, \quad 1 \leq i, j \leq n. \quad (1.3.2)$$

当 $f(\mathbf{x})$ 为二次函数时, 梯度及 Hesse 矩阵很容易求得. 二次函数可以写成下列形式:

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{b}^T \mathbf{x} + c,$$

其中 $\mathbf{A}$ 是 n 阶对称矩阵, $\mathbf{b}$ 是 n 维列向量, c 是常数. 函数 $f(\mathbf{x})$ 在 $\mathbf{x}$ 处的梯度 $\nabla f(\mathbf{x}) = \mathbf{A} \mathbf{x} + \mathbf{b}$, Hesse 矩阵 $\nabla^2 f(\mathbf{x}) = \mathbf{A}$.

假设在开集 $S \subset \mathbb{R}^n$ 上 $f \in C^1(S)$, 给定点 $\bar{\mathbf{x}} \in S$, 则 f 在点 $\bar{\mathbf{x}}$ 的一阶 Taylor 展开式为

$$f(\mathbf{x}) = f(\bar{\mathbf{x}}) + \nabla f(\bar{\mathbf{x}})^T (\mathbf{x} - \bar{\mathbf{x}}) + o(\|\mathbf{x} - \bar{\mathbf{x}}\|),$$

其中 $o(\|\mathbf{x} - \bar{\mathbf{x}}\|)$ 当 $\|\mathbf{x} - \bar{\mathbf{x}}\| \rightarrow 0$ 时, 关于 $\|\mathbf{x} - \bar{\mathbf{x}}\|$ 是高阶无穷小量.

假设在开集 $S \subset \mathbb{R}^n$ 上 $f \in C^2(S)$, 则 f 在 $\bar{\mathbf{x}} \in S$ 的二阶 Taylor 展开式为

$$f(\mathbf{x}) = f(\bar{\mathbf{x}}) + \nabla f(\bar{\mathbf{x}})^T (\mathbf{x} - \bar{\mathbf{x}}) + \frac{1}{2} (\mathbf{x} - \bar{\mathbf{x}})^T \nabla^2 f(\bar{\mathbf{x}}) (\mathbf{x} - \bar{\mathbf{x}}) + o(\|\mathbf{x} - \bar{\mathbf{x}}\|^2),$$

其中 $o(\|\mathbf{x}-\bar{\mathbf{x}}\|^2)$ 当 $\|\mathbf{x}-\bar{\mathbf{x}}\|^2 \rightarrow 0$ 时, 关于 $\|\mathbf{x}-\bar{\mathbf{x}}\|^2$ 是高阶无穷小量.

1.3.4 Jacobi 矩阵、链式法则和隐函数存在定理

1. Jacobi 矩阵

考虑向量值函数

$$\mathbf{h}(\mathbf{x}) = (h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_m(\mathbf{x}))^T,$$

其中每个分量 $h_i(\mathbf{x})$ 为 n 元实值函数, 假设对所有 i, j 偏导数 $\frac{\partial h_i(\mathbf{x})}{\partial x_j}$ 存在. $\mathbf{h}$ 在点 $\mathbf{x}$ 的 Jacobi 矩阵为

$$\begin{bmatrix} \frac{\partial h_1(\mathbf{x})}{\partial x_1} & \frac{\partial h_1(\mathbf{x})}{\partial x_2} & \dots & \frac{\partial h_1(\mathbf{x})}{\partial x_n} \\ \frac{\partial h_2(\mathbf{x})}{\partial x_1} & \frac{\partial h_2(\mathbf{x})}{\partial x_2} & \dots & \frac{\partial h_2(\mathbf{x})}{\partial x_n} \\ \vdots & \vdots & & \vdots \\ \frac{\partial h_m(\mathbf{x})}{\partial x_1} & \frac{\partial h_m(\mathbf{x})}{\partial x_2} & \dots & \frac{\partial h_m(\mathbf{x})}{\partial x_n} \end{bmatrix}, \quad (1.3.3)$$

这个矩阵称为向量值函数 $\mathbf{h}$ 在 $\mathbf{x}$ 的导数, 记作 $\mathbf{h}'(\mathbf{x})$ 或 $\nabla \mathbf{h}(\mathbf{x})^T$, 其中 $\nabla \mathbf{h}(\mathbf{x}) = (\nabla h_1(\mathbf{x}), \nabla h_2(\mathbf{x}), \dots, \nabla h_m(\mathbf{x}))$.

例 1.3.1 设有向量值函数

$$\mathbf{f}(\mathbf{x}) = \mathbf{f}(x_1, x_2) = \begin{bmatrix} \sin x_1 + \cos x_2 \\ e^{2x_1+x_2} \\ 2x_1^2 + x_1 x_2 \end{bmatrix},$$

则 $\mathbf{f}(\mathbf{x})$ 在任一点 (x_1, x_2) 的 Jacobi 矩阵, 即导数为

$$\mathbf{f}'(\mathbf{x}) = \begin{bmatrix} \cos x_1 & -\sin x_2 \\ 2e^{2x_1+x_2} & e^{2x_1+x_2} \\ 4x_1 + x_2 & x_1 \end{bmatrix}.$$

2. 链式法则

设有复合函数 $\mathbf{h}(\mathbf{x}) = \mathbf{f}(\mathbf{g}(\mathbf{x}))$, 其中向量值函数 $\mathbf{f}(\mathbf{g})$ 和 $\mathbf{g}(\mathbf{x})$ 均可微, $\mathbf{x} \in D^n \subset \mathbb{R}^n$, $\mathbf{g}: D^n \rightarrow D_1^m, \mathbf{f}: D_1^m \rightarrow \mathbb{R}^k$, 其中 $D_1^m \subset D_2^m, \mathbf{h}: D^n \rightarrow \mathbb{R}^k$. 根据复合函数求导数的链式法则, 必有

$$\mathbf{h}'(\mathbf{x}) = \mathbf{f}'(\mathbf{g}(\mathbf{x}))\mathbf{g}'(\mathbf{x}), \quad \mathbf{x} \in D^n, \quad (1.3.4)$$

其中 $\mathbf{f}'$ 和 $\mathbf{g}'$ 分别为 $k \times m$ 和 $m \times n$ 矩阵, $\mathbf{h}'$ 为 $k \times n$ 矩阵. 若记 $\nabla \mathbf{f} = (\nabla f_1, \nabla f_2, \dots, \nabla f_k)$, $\nabla \mathbf{g} = (\nabla g_1, \nabla g_2, \dots, \nabla g_m)$, 由于 $\mathbf{h}' = \nabla \mathbf{h}^T, \mathbf{f}' = \nabla \mathbf{f}^T$ 和 $\mathbf{g}' = \nabla \mathbf{g}^T$, 可将 (1.3.4) 式改写为

$$\nabla \mathbf{h}(\mathbf{x}) = \nabla \mathbf{g}(\mathbf{x}) \nabla f(\mathbf{g}(\mathbf{x})), \quad (1.3.5)$$

式中 $\nabla \mathbf{h}$ 为 $n \times k$ 矩阵, 第 j 列 $\nabla h_j(\mathbf{x})$ 为 $h_j(\mathbf{x})$ 的梯度.

例 1.3.2 设有复合函数 $\mathbf{h}(\mathbf{x}) = \mathbf{f}(\mathbf{u}(\mathbf{x}))$, 其中

$$\mathbf{f}(\mathbf{u}) = \begin{bmatrix} f_1(\mathbf{u}) \\ f_2(\mathbf{u}) \end{bmatrix} = \begin{bmatrix} u_1^2 - u_2 \\ u_1 + u_2^2 \end{bmatrix}, \quad \mathbf{u}(\mathbf{x}) = \begin{bmatrix} u_1(\mathbf{x}) \\ u_2(\mathbf{x}) \end{bmatrix} = \begin{bmatrix} x_1 + x_3 \\ x_2^2 - x_3 \end{bmatrix},$$

试求复合函数 $\mathbf{h}(\mathbf{x}) = \mathbf{f}(\mathbf{u}(\mathbf{x}))$ 的导数.

解 $\mathbf{h}'(\mathbf{x}) = \mathbf{f}'(\mathbf{u}(\mathbf{x}))\mathbf{u}'(\mathbf{x})$

$$= \begin{bmatrix} 2u_1 & -1 \\ 1 & 2u_2 \end{bmatrix} \begin{bmatrix} 1 & 0 & 1 \\ 0 & 2x_2 & -1 \end{bmatrix} = \begin{bmatrix} 2u_1 & -2x_2 & 2u_1 + 1 \\ 1 & 4u_2x_2 & 1 - 2u_2 \end{bmatrix},$$

将 $\mathbf{u}$ 用 $\mathbf{x}$ 表示, 得到

$$\begin{bmatrix} \frac{\partial h_1(\mathbf{x})}{\partial x_1} & \frac{\partial h_1(\mathbf{x})}{\partial x_2} & \frac{\partial h_1(\mathbf{x})}{\partial x_3} \\ \frac{\partial h_2(\mathbf{x})}{\partial x_1} & \frac{\partial h_2(\mathbf{x})}{\partial x_2} & \frac{\partial h_2(\mathbf{x})}{\partial x_3} \end{bmatrix} = \begin{bmatrix} 2(x_1 + x_3) & -2x_2 & 2(x_1 + x_3) + 1 \\ 1 & 4x_2(x_2^2 - x_3) & 1 - 2(x_2^2 - x_3) \end{bmatrix}.$$

3. 隐函数定理

考虑有 m 个方程的 n 元方程组

$$h_i(\mathbf{x}) = 0, \quad i = 1, 2, \dots, m. \quad (1.3.6)$$

问题是, 用这组方程能否确定 m 个变量, 比如 $x_1, x_2, \dots, x_m$ 为另外 $n - m$ 个变量 $x_{m+1}, \dots, x_n$ 的隐函数, 即是否存在满足方程组 (1.3.6) 的函数 $x_i = \phi_i(x_{m+1}, x_{m+2}, \dots, x_n)$ ($i = 1, 2, \dots, m$). 下列隐函数定理回答了这个问题.

定理 1.3.3 设 $\mathbf{x}^{(0)} \in \mathbb{R}^n$ 满足下列条件:

- (1) $h_i(\mathbf{x}^{(0)}) = 0$ ($i = 1, 2, \dots, m$);
- (2) 在 $\mathbf{x}^{(0)}$ 的某个邻域内函数 $h_i \in C^1$ ($i = 1, \dots, m$);
- (3) 方程组关于变元 $x_1, x_2, \dots, x_m$ 的 Jacobi 式

$$\begin{vmatrix} \frac{\partial h_1(\mathbf{x}^{(0)})}{\partial x_1} & \frac{\partial h_1(\mathbf{x}^{(0)})}{\partial x_2} & \dots & \frac{\partial h_1(\mathbf{x}^{(0)})}{\partial x_m} \\ \frac{\partial h_2(\mathbf{x}^{(0)})}{\partial x_1} & \frac{\partial h_2(\mathbf{x}^{(0)})}{\partial x_2} & \dots & \frac{\partial h_2(\mathbf{x}^{(0)})}{\partial x_m} \\ \vdots & \vdots & & \vdots \\ \frac{\partial h_m(\mathbf{x}^{(0)})}{\partial x_1} & \frac{\partial h_m(\mathbf{x}^{(0)})}{\partial x_2} & \dots & \frac{\partial h_m(\mathbf{x}^{(0)})}{\partial x_m} \end{vmatrix} \neq 0.$$

则存在 $\hat{\mathbf{x}}^{(0)} = (x_{m+1}^{(0)}, \dots, x_n^{(0)}) \in \mathbb{R}^{n-m}$ 的一个邻域, 使得对于邻域中的点 $\hat{\mathbf{x}} = (x_{m+1}, \dots, x_n)$ 存在函数 $\phi_i(\hat{\mathbf{x}})$ ($i = 1, \dots, m$), 满足

- (1) $\phi_i \in C^1$ ($i = 1, 2, \dots, m$);

(2) $x_i^{(0)} = \phi_i(\hat{\mathbf{x}}^{(0)})$ ($i=1, 2, \dots, m$);

(3) $h_i(\phi_1(\hat{\mathbf{x}}), \dots, \phi_m(\hat{\mathbf{x}}), \hat{\mathbf{x}}) = 0$ ($i=1, 2, \dots, m$).

1.4 凸集和凸函数

凸集和凸函数是线性规划和非线性规划都要涉及的基本概念. 关于凸集和凸函数的一些定理在最优化问题的理论证明及算法研究中具有重要作用. 本书对凸集和凸函数只作一般性介绍, 要想对这方面的知识有更深入的了解, 可参见文献[1]~[3].

1.4.1 凸集

定义 1.4.1 设 S 为 n 维欧氏空间 $\mathbb{R}^n$ 中一个集合. 若对 S 中任意两点, 联结它们的线段仍属于 S ; 换言之, 对 S 中任意两点 $\mathbf{x}^{(1)}, \mathbf{x}^{(2)}$ 及每个实数 $\lambda \in [0, 1]$, 都有

$$\lambda \mathbf{x}^{(1)} + (1 - \lambda) \mathbf{x}^{(2)} \in S,$$

则称 S 为凸集.

$\lambda \mathbf{x}^{(1)} + (1 - \lambda) \mathbf{x}^{(2)}$ 称为 $\mathbf{x}^{(1)}$ 和 $\mathbf{x}^{(2)}$ 的凸组合. 图 1.4.1 中, (a) 为凸集, (b) 为非凸集.

例 1.4.1 验证集合 $H = \{\mathbf{x} \mid \mathbf{p}^T \mathbf{x} = \alpha\}$ 为凸集, 其中, $\mathbf{p}$ 为 n 维列向量, α 为实数.

解 由于对任意两点 $\mathbf{x}^{(1)}, \mathbf{x}^{(2)} \in H$ 及每个实数 $\lambda \in [0, 1]$ 都有

$$\mathbf{p}^T [\lambda \mathbf{x}^{(1)} + (1 - \lambda) \mathbf{x}^{(2)}] = \alpha,$$

因此

$$\lambda \mathbf{x}^{(1)} + (1 - \lambda) \mathbf{x}^{(2)} \in H.$$

根据定义 1.4.1 知 H 为凸集.

例 1.4.1 中定义的集合 H 称为 $\mathbb{R}^n$ 中的超平面, 故超平面为凸集.

例 1.4.2 验证集合 $H^- = \{\mathbf{x} \mid \mathbf{p}^T \mathbf{x} \leq \alpha\}$ 为凸集.

解 这是因为对任意的 $\mathbf{x}^{(1)}, \mathbf{x}^{(2)} \in H^-$ 及每一个实数 $\lambda \in [0, 1]$, 都有

$$\mathbf{p}^T [\lambda \mathbf{x}^{(1)} + (1 - \lambda) \mathbf{x}^{(2)}] = \lambda \mathbf{p}^T \mathbf{x}^{(1)} + (1 - \lambda) \mathbf{p}^T \mathbf{x}^{(2)} \leq \alpha,$$

所以 $\lambda \mathbf{x}^{(1)} + (1 - \lambda) \mathbf{x}^{(2)} \in H^-$. 根据定义 1.4.1 知 H^- 为凸集.

集合 $H^- = \{\mathbf{x} \mid \mathbf{p}^T \mathbf{x} \leq \alpha\}$ 称为半空间, 故半空间为凸集.

例 1.4.3 验证集合 $L = \{\mathbf{x} \mid \mathbf{x} = \mathbf{x}^{(0)} + \lambda \mathbf{d}, \lambda \geq 0\}$ 为凸集, 其中 $\mathbf{d}$ 是给定的非零向量, $\mathbf{x}^{(0)}$ 是定点.

解 因为对任意两点 $\mathbf{x}^{(1)}, \mathbf{x}^{(2)} \in L$ 及每一个数 $\lambda \in [0, 1]$, 必有 $\mathbf{x}^{(1)} = \mathbf{x}^{(0)} + \lambda_1 \mathbf{d}, \mathbf{x}^{(2)} = \mathbf{x}^{(0)} + \lambda_2 \mathbf{d}$, λ_1 和 λ_2 是两个非负数, 以及




图 1.4.1