






最优化方法

Optimality Methods



课程简介



- 01 课程简介(Introduction)**
- 02 线性规划(Linear Programming)**
- 03 非线性规划(Non-Linear Programming)**
- 04 整数规划(Integer Programming)**
- 05 动态规划(Dynamic Programming)**



PART ONE

课程简介 Introduction

■ 课程大纲

- 引言
- 线性规划的基本性质
- 单纯形方法原理
- 对偶原理及灵敏度分析
- 运输问题
- 线性规划的内点算法
- 最优性条件
- 算法
- 一维搜索
- 使用导数的最优化方法
- 无约束最优化的直接方法
- 可行方向法
- 惩罚函数法
- 二次规划
- 整数规划简介
- 动态规划简介

■ 课程考核(32学时)



■ 平时作业（30%）

- 内容：最优化方法课后作业
 - 独立完成（抄袭扣平时分10）
 - 每人至少完成4次作业（少于4次扣10）
 - 未按题目数量完成（扣1-5）
 - 错误率较高（扣1-5）
- 提交时间：课程章节结束后，下一章节开始前，按班级提交给助教
- 考勤：不定时点名至少5次（每次10分）

■ 期末考试（70%）

- 闭卷考试，课程过程及习题作业中选择
- 百分制，选择+计算
- 考试成绩为卷面成绩，除合分错误，不存在修改的可能

■ 参考书目



1. 陈宝林 《最优化理论与算法(第二版)》清华大学出版社，2005
2. [美]Edwin K.P. Chong Stanislaw H.Zak 著，/孙志强，白圣建，郑永斌，刘伟 (译)/宫二玲(校) 《最优化导论(第四版)》电子工业出版社，2016.
3. 傅英家等主编 《最优化理论与方法》国防工业出版社，2008.
4. 袁亚湘、孙文瑜 著 《最优化理论与方法》科学出版社，1997.

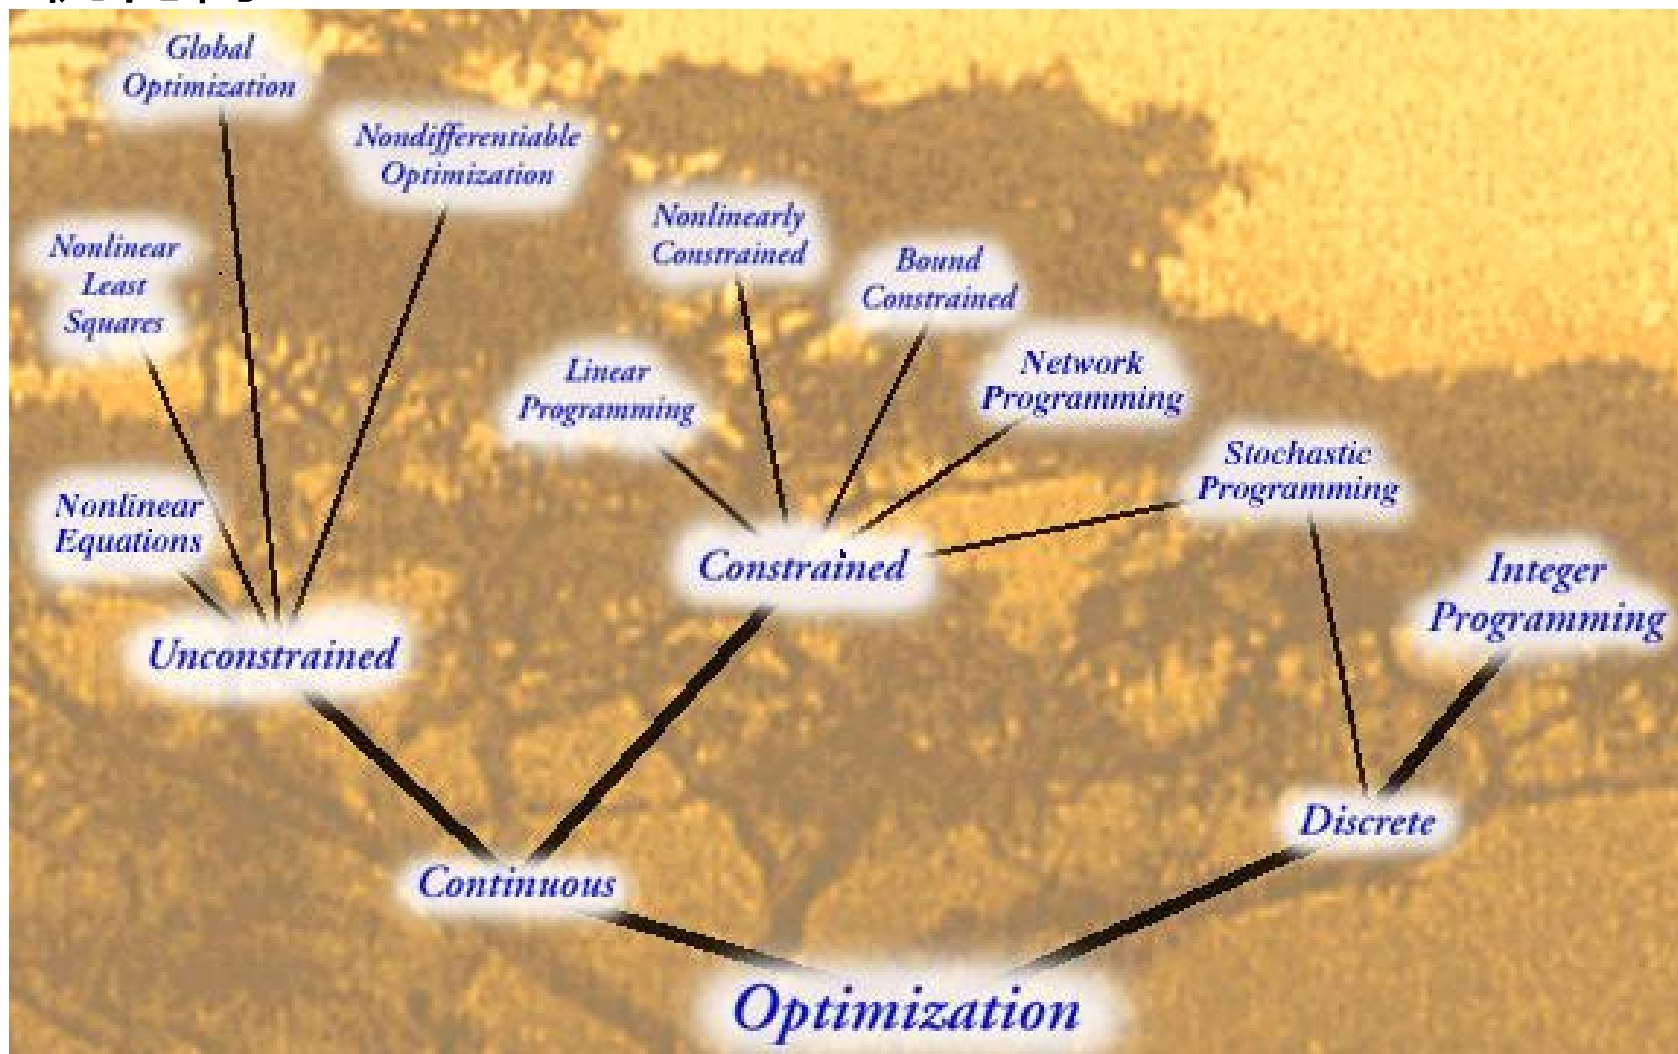
■ 相关/推荐课程

- 运筹学，西安邮电大学，
➤ <https://www.icourse163.org/course/XIYOU-1207132805>
- 最优化理论，南京理工大学，
<https://www.icourse163.org/course/preview/NJUST-1003545092/?tid=1003779153>
- 最优化方法，四川大学，
➤ <https://www.icourse163.org/spoc/course/SCU-1206412801>

■ 学科概述

- 最优化是从所有可能的方案中选择最合理的一种方案，以达到最佳目标的科学
- 达到最佳目标的方案是最优方案，寻找最优方案的方法就是最优化方法(算法)
- 这种方法的数学理论即为最优化理论
- 最优化方法是运筹学方法论之一
- 最优化首先是一种理念，其次才是一种方法

■ 优化树



■ 最优化的发展历程(理论)

- 费马(1638);牛顿(1670)

$$\min_x f(x) \quad x \in \mathbb{R}$$

$$\frac{df(x)}{dx} = 0$$

一元函数

- 欧拉(1755)

$$\min f(x_1, x_2, \dots, x_n)$$

$$\nabla f(x) = 0$$

多元函数

- 拉格朗日(1797)

$$\min f(x_1, x_2, \dots, x_n)$$

$$\text{s.t. } g_k(x_1, x_2, \dots, x_n) = 0 \quad \text{多元约束}$$

$$k = 1, 2, \dots, m$$

- 欧拉, 拉格朗日: 无穷维问题, 变分学
- 柯西: 最早应用最速下降法




■ 最优化的发展历程(计算机)

- 1930年代, 康托诺维奇: 线性规划
- 1940年代, Dantzig: 单纯形方法
冯 诺依曼: 对策论
- 1950年代, Bellman: 动态规划, 最优性原理; KKT条件
- 1960年代, Zoutendijk, Rosen, Carroll等非线性规划算法
Duffin, Zener等几何规划,
Gomory等整数规划,
Dantzig等随机规划
- 1970年代, Cook等复杂性理论, 组合优化迅速发展

■ 最优化应用举例

具有广泛的实用性

- 运输问题，车辆调度，员工安排，空运控制等
- 工程设计，结构设计等
- 资源分配，生产计划等
- 通信：光网络、无线网络、互联网、物联网等
- 制造业：钢铁生产，车间调度等
- 医药生产，化工处理等
- 电子工程，集成电路VLSI 等
- 电子排版（TEX,Latex等）



■ 1.食谱问题

我每天要求一定量的两种维生素， V_c 和 V_b 。
假设这些维生素可以分别从牛奶和鸡蛋中得到。

维生素	奶中含量	蛋中含量	每日需求
$V_c(\text{mg})$	2	4	40
$V_b(\text{mg})$	3	2	50
单价(\$)	3	2.5	

需要确定每天喝奶和吃蛋的量，
目标以便以最低可能的花费购买这些食物，
而**满足**最低限度的维生素需求量。

■ 1.食谱问题

令 x 表示要买的奶的量, y 为要买的蛋的量。食谱问题可以写成如下的数学形式:

$$\text{Min } 3x + 2.5y$$

$$\text{s.t. } 2x + 4y \geq 40$$

$$3x + 2y \geq 50$$

$$x, y \geq 0.$$

极小化目标函数

可行区域

可行解

建立关于何时出现最小费用(或者最大利润)的排序, 或者计划, 早期被标示为**规划**。

求最优安排或计划的问题, 称作**规划问题**。

■ 2.运输问题

设某种物资有 m 个产地 A_1, A_2, \dots, A_m , 各产地的产量是 a_1, a_2, \dots, a_m ; 有 n 个销地 B_1, B_2, \dots, B_n . 各销地的销量是 b_1, b_2, \dots, b_n . 假定从产地 $A_i (i=1, 2, \dots, m)$ 到销地 $B_j (j=1, 2, \dots, n)$ 运输单位物品的运价是 c_{ij} .

问怎样调运这些物品才能使总运费最小?

如果运输问题的总产量等于总销量, 即有

$$\sum_{i=1}^m a_i = \sum_{j=1}^n b_j$$

则称该运输问题为产销平衡问题; 反之, 称产销不平衡问题。

■ 2.运输问题

令 x_{ij} 表示由产地 A_i 运往销地 B_j 的物品数量，则产销平衡问题的数学模型为：

$$\begin{aligned} \min z &= \sum_{i=1}^n \sum_{j=1}^m c_{ij} x_{ij} \\ s.t. &\begin{cases} \sum_{j=1}^m x_{ij} = a_i & i=1,2,\dots,m \\ \sum_{i=1}^n x_{ij} = b_j & j=1,2,\dots,n \\ x_{ij} \geq 0 & i=1,2,\dots,m \\ & j=1,2,\dots,n \end{cases} \end{aligned}$$

■ 基本概念

在上述例子中,

1. 目标函数和约束函数都是线性的, 称之为**线性规划问题**,
2. 模型中含有非线性函数, 称之为**非线性规划问题**.

在线性与非线性规划中,

1. 满足约束条件的点称为**可行点**,
2. 全体可行点组成的集合称为**可行集或可行域**.
3. 如果一个问题的可行域是整个空间, 则称此问题为**无约束问题**.



■ 基本概念

最优化问题可归结成如下数学形式：

$$\min_{x \in R^n} f(x) \quad \text{---目标函数}$$

$$s.t. \quad g_i(x) \geq 0, i \in I$$

$$h_j(x) = 0, j \in E$$



■ 基本概念

定义 1.1 设 $f(x)$ 为目标函数, S 为可行域, $x_0 \in S$,
若对每一个 $x \in S$, 成立 $f(x) \geq f(x_0)$, 则称 x_0 为极小化问题 $\min_{x \in S} f(x)$ 的**最优解(整体最优解)**
(全局极小点)

定义 1.2 设 $f(x)$ 为目标函数, S 为可行域,
若存在 x_0 的 ε 邻域
$$N_\varepsilon(x_0) = \{x \mid \|x - x_0\| < \varepsilon, \varepsilon > 0\}$$

使得对每个 $x \in S \cap N_\varepsilon(x_0)$, 成立 $f(x) > f(x_0)$

则称 x_0 为极小化问题 $\min_{x \in S} f(x)$ 的**局部最优解**
(局部极小点)

■ 基本概念

- 对于极大化问题，可类似定义全局极大点和局部极大点；
- 全局极小点也是局部极小点；
- 局部极小点不一定是全局极小点；
- 某些条件下(如凸规划)，局部极小点也是全局极小点

■ 1.*预备知识

- 线性空间
- 范数
- 集合与序列
- 矩阵的分解与校正
- 函数的可微性与展开

■ 1.1 线性空间

定义 1.3 给定一非空集合 G 以及在 G 上的一种代数运算 $+:G \times G \rightarrow G$ (称为加法),若下述条件成立:

$$(1) \forall a, b, c \in G, \text{有 } a + (b + c) = (a + b) + c$$

$$(2) \exists 0 \in G, \text{使得 } \forall a \in G, \text{有 } a + 0 = 0 + a = a$$

$$(3) \forall a \in G, \exists -a \in G \text{使得 } a + (-a) = (-a) + a = 0$$

则 $\langle G, + \rangle$ 称为一个**群**.若还满足对任意的 $a, b \in G$,有 $a + b = b + a$,
则 $\langle G, + \rangle$ 称为一个**阿贝尔群(交换群)**

■ 1.1 线性空间

定义 1.4 给定一非空集合 V 和一个域 F ,并定义两种运算
加 $+: V \times V \rightarrow V$ 以及**数乘** $\cdot: F \times V \rightarrow V$.

若 $\langle V, + \rangle$ 构成一交换群,且两种运算满足下面性质:

$\forall a, b \in V, \forall \lambda, \mu \in F$ 以及单位元 $1 \in F$,有

$$1 \cdot a = a$$

$$\lambda \cdot (\mu \cdot a) = (\lambda \mu) \cdot a$$

$$(\lambda + \mu) \cdot a = \lambda \cdot a + \mu \cdot a$$

$$\lambda \cdot (a + b) = \lambda \cdot a + \lambda \cdot b$$

则称 V 在域 F 上关于加法和数乘运算构成一**线性空间**,简称 V 为 F 上的线性空间.记为 **$V(F)$** .若 V 的非空子集合 S 关于加法和数乘运算在 F 上也构成一线性空间,则 S 称为 F 上的**线性子空间**.

■ 1.1 线性空间 例子

1, \mathbb{R}^n 是实数域 \mathbb{R} 上的一线性空间.

2, $\mathbb{R}[x]_n$ 是系数在实数域 \mathbb{R} 上次数小于 n 的全体多项式组成的集合, 则 $\mathbb{R}[x]_n$ 关于多项式的加法以及数与多项式的乘法构成一线性空间.

3, $\mathbb{R}^{m \times n}$ 是实数域 \mathbb{R} 上所有 $m \times n$ 矩阵组成的集合, 则其关于矩阵加法和数乘运算构成一线性空间.

■ 1.2 范数

定义 1.5 若函数 $\|\cdot\|: R^n \rightarrow R$ 满足:

- (1) 正定性: $\forall x \in R^n, \|x\| \geq 0, \|x\| = 0 \Leftrightarrow x = 0$;
- (2) 三角不等式: $\forall x, y \in R^n, \|x + y\| \leq \|x\| + \|y\|$;
- (3) 齐次性: $\forall x \in R^n, \forall \alpha \in R, \|\alpha x\| = |\alpha| \|x\|$.

则 $\|\cdot\|$ 称为 R^n 上的 **范数**

例子: $x = (x_1, x_2, \dots, x_n)^T \in R^n$

2-范数 $\|x\|_2 = (\sum_{i=1}^n x_i^2)^{1/2}$; 1-范数 $\|x\|_1 = \sum_{i=1}^n |x_i|$;

∞ -范数 $\|x\|_\infty = \max_i |x_i|$; p -范数 $\|x\|_p = (\sum_{i=1}^n x_i^p)^{1/p}, 1 \leq p < +\infty$;

■ 1.3 集合与序列

$x^0 \in \mathbb{R}^n$ 的 ε -邻域:

$$N_\varepsilon(x^0) = \{x \mid \|x - x^0\| < \varepsilon\}$$

$x^0 \in S \subseteq \mathbb{R}^n$ 称为 S 的**内点**, 若 $\exists \varepsilon > 0$, 使得 $N_\varepsilon(x^0) \subseteq S$.

集合 S 的所有内点的全体称为 S 的**内部**, 记为 $\text{int}(S)$ 或 $\overset{\circ}{S}$.

若集合 $S = \text{int}(S)$, 则 S 称为一个**开集**;

集合 S 的**补集** $S^c = \{x \mid x \notin S, x \in \mathbb{R}^n\}$;

若集合 S 的补集 S^c 是开集, 则称 S 为**闭集**;

集合 S 的**闭包**是指包含它的最小闭集, 记为 $\text{cl}S$ 或 \overline{S}

集合 S 的**边界**定义为集合 $\partial S = \text{cl}S \cap \text{cl}S^c$

■ 1.3 集合与序列

集合 $S \subseteq \mathbb{R}^n$ 称为**有界集**, 若 $\exists M > 0$, 使得 $\forall x \in S, \|x\| \leq M$

\mathbb{R}^n 中的有界闭集也称为**紧集**。

非空集合 $S \subseteq \mathbb{R}^n$, 若存在一实数 $\alpha \in \mathbb{R}$, 使得 $\forall x \in S, x \leq \alpha$ 成立

则 α 称为 S 的一个**上界**, 若存在一实数 $\beta \in \mathbb{R}$, 使得 $\forall x \in S, x \geq \beta$ 成立

则 β 称为 S 的一个**下界**。

S 的**上确界** $\sup(S)$ 是指它的最小上界, 其**下确界** $\inf(S)$ 是指它的最大下界。

给定有界的实数序列 $\{x_k\}$, 对 $\forall n \in \mathbb{N}$, 令

$$\alpha_n = \sup \{x_k \mid k \geq n\}, \beta_n = \inf \{x_k \mid k \geq n\},$$

则序列 $\{\alpha_n\}$ 和 $\{\beta_n\}$, 分别是单调递减和单调递增的

实数序列, 且 $\alpha_n \geq \beta_n$. 从而都有极限, 分别称为

上极限和下极限, 记为

$$\limsup_{k \rightarrow \infty} x_k = \lim_{n \rightarrow \infty} \alpha_n, \liminf_{k \rightarrow \infty} x_k = \lim_{n \rightarrow \infty} \beta_n$$

■ 1.4 矩阵的分解与校正

Th1.4 给定矩阵 $A \in R^{n \times n}$, A 的顺序主子式

$$\begin{pmatrix} a_{11} & \cdots & a_{1k} \\ \vdots & & \vdots \\ a_{k1} & \cdots & a_{kk} \end{pmatrix}$$

都可逆, 则存在唯一的单位下三角矩阵 L (主对角元全为1) 和可逆的上三角矩阵 U , 使得 $A=LU$ (称为 A 的 LU-分解)

Th1.5 若 n 阶矩阵 A 可逆, 则存在一个排列矩阵 P , 单位下三角矩阵 L 和上三角矩阵 U , 使得 $PA=LU$

■ 1.4 矩阵的分解与校正

定理 1.3 设A为对称正定矩阵，则

- (1) 矩阵A可唯一的分解成 $A=LDL^T$, 其中L为单位下三角矩阵, D为对角矩阵
- (2) 存在可逆的下三角矩阵L, 使得 $A=LL^T$. 当L的对角元素为正时, 分解是唯一的。(Cholesky分解)

Th1.7 设 $A \in R^{n \times n}$ 可逆, $B \in R^{m \times m}$, $U, V \in R^{n \times m}$ 若矩阵 $B - V^T A^{-1} U$

是可逆的, 则分块矩阵 $\begin{pmatrix} A & U \\ V^T & B \end{pmatrix}$ 可逆, 且

$$\begin{pmatrix} A & U \\ V^T & B \end{pmatrix}^{-1} = \begin{pmatrix} A^{-1} + A^{-1} U G V^T A^{-1} & -A^{-1} U G \\ -G V^T A^{-1} & G \end{pmatrix}$$

其中 $G = (B - V^T A^{-1} U)^{-1}$.

■ 1.5 函数的可微性与展开

设 $f: R^n \rightarrow R$ 是连续函数, 对于 $x^0 \in R^n$ 和单位向量

$e^i = (\delta_1^i, \delta_2^i, \dots, \delta_n^i)^T, \delta_i^i = 1, \delta_j^i = 0 (i \neq j)$, 一元函数 $f(x^0 + te^i)$

在 $t = 0$ 的导数(若存在的话)称为 f 在点 x^0 关于 x_i 的 **一阶偏导数**.
($i = 1, 2, \dots, n$)

对于任意 $i = 1, 2, \dots, n$, 若 f 在点 x 关于 x_i 的一阶偏导数存在, 则称 $f(x)$ 在 x 点存在一阶偏导数. 此时, $f(x)$ 在 x 点的 **梯度** 定义为

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

对于 $x^0 \in R^n, p \in R^n, p \neq 0$, 函数 f 在点 x^0 关于方向 p 的 **方向导数** 定义为:

$$\frac{\partial f(x^0)}{\partial p} = \lim_{t \rightarrow 0^+} \frac{f(x^0 + tp) - f(x^0)}{t}.$$

■ 1.5 函数的可微性与展开

我们也用 $Df(x^0; p)$ 表示 f 在点 x^0 关于方向 p 的方向导数当 f 的一阶偏导连续时有

$$Df(x^0; p) = \nabla f(x^0)^T p$$

当 $f(x)$ 在 x 点存在二阶偏导时, 函数 f 在点 x 的 **Hesse** 矩阵定义为

$$\nabla^2 f(x) = \begin{pmatrix} \frac{\partial^2 f(x)}{\partial x_1^2} & \cdots & \frac{\partial^2 f(x)}{\partial x_1 x_n} \\ \frac{\partial^2 f(x)}{\partial x_2 x_1} & \cdots & \frac{\partial^2 f(x)}{\partial x_2 x_n} \\ \vdots & & \vdots \\ \frac{\partial^2 f(x)}{\partial x_n x_1} & \cdots & \frac{\partial^2 f(x)}{\partial x_n^2} \end{pmatrix} \quad \left(\text{其中 } \frac{\partial^2 f(x)}{\partial x_i x_j} = \frac{\partial}{\partial x_j} \left(\frac{\partial f(x)}{\partial x_i} \right) \right)$$

■ 1.5 函数的可微性与展开

Th1.9(Taylor) 设 $f: R^n \rightarrow R$ 连续可微, 向量 $p \in R^n$, 则

$$\begin{aligned} f(x+p) &= f(x) + \int_0^1 \nabla f(x+tp)^T p dt = f(x) + \nabla f(x+\xi p)^T p, \xi \in (0,1) \\ &= f(x) + \nabla f(x)^T p + o(\|p\|) \end{aligned}$$

进而, 若 f 二阶连续可微, 则

$$\begin{aligned} \nabla f(x+p) &= \nabla f(x) + \int_0^1 \nabla^2 f(x+tp)^T p dt = \nabla f(x) + \nabla^2 f(x+\xi p)p, \xi \in (0,1) \\ &= \nabla f(x) + \nabla^2 f(x)p + o(\|p\|) \end{aligned}$$

$$\begin{aligned} f(x+p) &= f(x) + \nabla f(x)^T p + \int_0^1 (1-t)p^T \nabla^2 f(x+tp)^T p dt \\ &= f(x) + \nabla f(x)^T p + \frac{1}{2} p^T \nabla^2 f(x+\xi p)p, \xi \in (0,1) \\ &= f(x) + \nabla f(x)^T p + \frac{1}{2} p^T \nabla^2 f(x)p + o(\|p\|^2) \end{aligned}$$

■ 1.5 函数的可微性与展开

对向量值函数 $F = (f_1, f_2, \dots, f_n): R^n \rightarrow R^m$, 若每个分量函数 f_i 是(连续)可微的, 则称函数 F 是(连续)可微的。向量函数 F 在 x 的导数 $F' \in R^{m \times n}$ 是指它在 x 点的 *Jacobi* 矩阵, 记为 $F'(x)$ 或 $J_F(x)$. 为与标量函数梯度对应, 定义 *Jacobi* 矩阵的转置为 F 在 x 点的梯度, 记为

$$\nabla F(x) = J_F(x)^T = (\nabla f_1, \nabla f_2, \dots, \nabla f_n)$$

类似地, 设 $F: R^n \rightarrow R^m$ 连续可微, $\forall x, p \in R^n$, 则

$$F(x + p) = F(x) + \int_0^1 J_F(x + tp)^T p dt$$

■ 1.5 函数的可微性与展开

Df1.12 给定映射 $G: R^n \rightarrow R^m$, 点 $x \in R^n$, 若存在常数 $L > 0$, 使对任意 $y \in R^n$, 下式成立:

$$\|G(x) - G(y)\| \leq L \|x - y\|$$

则称 G 在 x 是 Lipschitz 连续的, L 称为 **Lipschitz 常数**。若上式对 $\forall x, y \in R^n$ 成立, 则称 G 在 R^n 内 **Lipschitz 连续**。

Th1.10 设向量值函数 $F: R^n \rightarrow R^m$ 连续可微, 则对 $\forall u, v, x \in R^n$, 有

$$\|F(u) - F(v) - J_F(x)(u - v)\| \leq \sup_{t \in [0,1]} \|J_F(v + t(u - v)) - J_F(x)\| \|u - v\|$$

进而, 若 Jacobi 矩阵映射 J_F 在 R^n 内是 Lipschitz 连续的, 记 L 为 Lipschitz 常数, 则

$$\|F(u) - F(v) - J_F(x)(u - v)\| \leq L \frac{\|u - x\| + \|v - x\|}{2} \|u - v\|$$

■ 2.*凸集与凸函数




- 凸集与锥
- 凸函数
- 凸规划

■ 2.1 凸集与锥

Df 2.1 设 S 为 n 维欧氏空间 R^n 中的一个集合。若对任意两点 $x^{(1)}, x^{(2)} \in S$ 及每个实数 $\lambda \in [0, 1]$, 有

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

则称 S 为**凸集**。 $\lambda x^{(1)} + (1 - \lambda)x^{(2)}$ 称为 $x^{(1)}$ 和 $x^{(2)}$ 的**凸组合**。



■ 2.1 凸集与锥

例2.1 超平面 $H = \{x \mid p^T x = \alpha\}$ 为凸集，其中 p 为 n 维列向量， α 为实数。此外，下面相对于法向量 p 的半空间都是凸集：


正的闭半空间 $H^+ = \{x \mid p^T x \geq \alpha\}$

负的闭半空间 $H^- = \{x \mid p^T x \leq \alpha\}$

正的开半空间 $\dot{H}^+ = \{x \mid p^T x > \alpha\}$

负的开半空间 $\dot{H}^- = \{x \mid p^T x < \alpha\}$

■ 2.1 凸集与锥



例2.2 集合 $L = \{x \mid x = x^{(0)} + \lambda d, \lambda \geq 0\}$ 为凸集, 其中 d 为给定的非零向量, $x^{(0)}$ 为定点。

集合 $L = \{x \mid x = x^{(0)} + \lambda d, \lambda \geq 0\}$ 称为**射线**, $x^{(0)}$ 为射线的顶点

■ 2.1 凸集与锥

Df 2.2 给定 m 个向量, $x^1, \dots, x^m \in R^n$, 以及满足 $\sum_{i=1}^m \lambda_i = 1$ 的非负实数 $\lambda_i \in R, i = 1, \dots, m$, 称向量 $\lambda_1 x^1 + \dots + \lambda_m x^m$ 为 $\{x^1, \dots, x^m\}$ 的凸组合.

Th 2.1 集合 $S \subseteq R^n$ 是凸集, 当且仅当 S 包含其中任意有限个元素的凸组合, 即对 $\forall m \in R^+ = \{1, 2, \dots\}$, 任意的 $x^1, \dots, x^m \in R^n$, 有 $\lambda_1 x^1 + \dots + \lambda_m x^m \in S$, 其中 $\sum_{i=1}^m \lambda_i = 1, \lambda_i \geq 0 \in R, i = 1, \dots, m$.

■ 2.1 凸集与锥

运用定义不难验证如下命题：

命题2.1 设 S_1 和 S_2 为 \mathbb{R}^n 中两个凸集, β 是实数,则

- 1, $\beta S_1 = \{\beta x \mid x \in S_1\}$ 为凸集。
- 2, $S_1 \cap S_2$ 为凸集
- 3, $S_1 + S_2 = \{x^{(1)} + x^{(2)} \mid x^{(1)} \in S_1, x^{(2)} \in S_2\}$ 为凸集
- 4, $S_1 - S_2 = \{x^{(1)} - x^{(2)} \mid x^{(1)} \in S_1, x^{(2)} \in S_2\}$ 为凸集



■ 2.1 凸集与锥

有限点集 $\{x^0, x^1, \dots, x^m\} \subset R^n$ 的凸包称为**多胞形**。

若 $\{x^0, x^1, \dots, x^m\}$ 仿射无关时，对应的凸包称为 **m 维单纯形**。


向量 x^i 称为该单纯形的**顶点**。

多面体 (polyhedral set) 是有限闭半空间的交. (可表为 $Ax \leq b$).



■ 2.1 凸集与锥

Df 2.4 设有集合 $C \subset R^n$, 若对每一点 $x \in C$, 当 λ 取任何非负数时, 都有 $\lambda x \in C$, 称 C 为 **锥**, 又若 C 为凸集, 则称 C 为 **凸锥**.



例 2.3, 向量集 $\alpha^{(1)}, \alpha^{(2)}, \dots, \alpha^{(k)}$ 的所有非负线性组合构成的集合 $\{\sum_{i=1}^k \lambda_i \alpha^{(i)} \mid \lambda_i \geq 0, i = 1, 2, \dots, k\}$ 为凸锥。

■ 2.1 凸集与锥

由定义可知, 锥关于正的数乘运算封闭, 凸锥关于加法和正的数乘封闭, 一般的, 对于凸集 S , 集合

$$K(S) = \{ \lambda x \mid \lambda > 0, x \in S \}$$

是包含 S 的最小凸锥.

锥 C 称为**尖锥**, 若 $0 \in S$. 尖锥称为**突出**的, 若它不包含一维子空间.

多面集 $\{x \mid Ax \leq 0\}$ 也是凸锥, 称为**多面锥**。



约定: 非空集合 S 生成的凸锥, 是指可以表示成 S 中有限个元素的非负线性组合 (称为凸锥组合) 的所有点所构成的集合, 记为 $\text{cone}S$. 若 S 凸, 则

$$\text{cone}S = K(S) \cup \{0\}$$

■ 2.1 凸集与锥

Df 2.5 非空凸集中的点 \mathbf{x} 称为**极点**, 若 $\mathbf{x} = \lambda \mathbf{x}_1 + (1-\lambda) \mathbf{x}_2$, $\lambda \in (0,1)$, $\mathbf{x}_1, \mathbf{x}_2 \in S$, 则 $\mathbf{x} = \mathbf{x}_1 = \mathbf{x}_2$.

换言之, \mathbf{x} 不能表示成 S 中两个不同点的凸组合.




由上可知, 任何有界凸集中任一点都可表成极点的凸组合.

■ 2.1 凸集与锥

Def 2.6. 设非空凸集 $S \subset \mathbb{R}^n$, \mathbb{R}^n 中向量 $d \neq 0$ 称为 S 的一个**回收方向(方向)**, 若对每一 $x \in S$, $R(x, d) = \{x + \lambda d \mid \lambda \geq 0\} \subset S$. S 的所有方向构成的尖锥称为 S 的**回收锥**, 记为 0^+S


方向 d_1 和 d_2 称为 S 的两个**不同的方向**, 若对任意 $\lambda > 0$, 都有 $d_1 \neq \lambda d_2$; 方向 d 称为 S 的**极方向** extreme direction, 若 $d = \lambda d_1 + (1-\lambda)d_2$, $\lambda \in (0, 1)$, d_1, d_2 是 S 的两个方向, 则有 $d = d_1 = d_2$.

换言之 d 不能表成它的两个不同方向的凸锥组合



■ 2.1 凸集与锥

例2.4 集合 $S = \{(x_1, x_2) \mid x_2 \geq |x_1|\}$
凡是与向量 $(0, 1)^T$ 夹角 $\leq 45^\circ$ 的向量
都是它的方向。 $(1, 1)^T, (-1, 1)^T$ 是其仅
有的两个极方向



例2.5 设 $S = \{x \mid Ax = b, x \geq 0\} \neq \emptyset$, d 是非零向量。
证明, d 是 S 的方向 $\Leftrightarrow d \geq 0$ 且 $Ad = 0$.

Th2.3 若多面体 P 的极点(极方向)存在的话, 则极点
(极方向)的数目一定有限.

■ 2.2 凸集分离定理

Df 2.7, 设 S_1 和 S_2 是 R^n 中两个非空集合, $H = \{x \mid p^T x = \alpha\}$ 为超平面。若对 $\forall x \in S_1$, 有 $p^T x \geq \alpha$, 对于 $\forall x \in S_2$, 有 $p^T x \leq \alpha$ (或情形恰好相反), 则称超平面 H 分离集合 S_1 和 S_2 。若 $S_1 \cup S_2 \not\subset H$, 则称 H 正常分离 S_1 和 S_2 。若 $S_1 \subseteq \dot{H}^+$, $S_2 \subseteq \dot{H}^-$, 则称 H 严格分离 S_1 和 S_2 。若 $S_1 \subseteq H(\varepsilon)^+ = \{x \mid p^T x \geq \alpha + \varepsilon\}, \varepsilon > 0, S_2 \subseteq \dot{H}^-$, 则称 H 强分离 S_1 和 S_2 。

■ 2.2 凸集分离定理

Df2.8, 设 $S(\neq \emptyset) \subset R^n$, $p \in R^n$, $p \neq 0, \bar{x} \in \partial S$

若 $S \subseteq H^+ = \{x \mid p^T(x - \bar{x}) \geq 0\}$ 或者 $S \subseteq H^- = \{x \mid p^T(x - \bar{x}) \leq 0\}$

则称 $H = \{x \mid p^T(x - \bar{x}) = 0\}$ 是 S 在 \bar{x} 处的 **支撑超平面**, 若 $S \not\subset H$,

则称 H 为 S 在 \bar{x} 处的 **正常支撑超平面**。

Df2.9 设 $S \subseteq R^n$ 非空, $y \in R^n$, 则点 y 与集合 S 之间的距离 $dist(y, S)$ 定义为

$$dist(y, S) = \inf_{x \in S} \|y - x\| \quad (2.4)$$

Th2.5 设 S 为 R^n 中的闭凸集, $y \notin S$, 则存在唯一的点 $\bar{x} \in S$,

使得 $\|y - \bar{x}\| = \inf_{x \in S} \|y - x\|$

■ 2.2 凸集分离定理

Th2.6 设 $S \subseteq R^n$ 的非空闭凸集, $y \notin S$, 则点 $\bar{x} \notin S$ 为极小化问题 (2.4) 的最优解当且仅当 $(y - \bar{x})^T (\bar{x} - x) \geq 0$

设 S 为闭凸集, $y \notin S$, $H = \{x \mid p^T x = \alpha\}$ 为超平面。

H 分离点 $y \Rightarrow$ 若 $p^T y > \alpha$, 则 $p^T x \leq \alpha, \forall x \in S$.

令 $p^T y - \alpha = \varepsilon$, 则 y 与 S 分离可表为

$$p^T y \geq \varepsilon + p^T x, \forall x \in S.$$

Th2.7 设 $S (\neq \Phi)$ 为 R^n 中的闭凸集, $y \notin S$, 则存在 $p \neq 0$ 及实数 $\varepsilon > 0$, 使得对点 $x \in S$, 有 $p^T y \geq \varepsilon + p^T x$ 。

■ 2.2 凸集分离定理

Th2.8 设 $S(\neq \Phi)$ 为 R^n 中的凸集, $y \in \partial S$, 则存在 $p \neq 0$, 使得对点 $x \in \text{cl}S$, 有 $p^T y \geq p^T x$ 。

Th2.9. 设 $S_1, S_2(\neq \Phi)$ 为 R^n 中的凸集, $S_1 \cap S_2 = \Phi$, 则存在 $p \neq 0$ 使 $\inf\{p^T x | x \in S_1\} \geq \sup\{p^T x | x \in S_2\}$

(换言之, 存在超平面 H , 使得 $S_1 \subseteq H^+$, $S_2 \subseteq H^-$)。

Th2.10. 设 $S_1, S_2(\neq \Phi) \subseteq R^n$ 中的闭凸集, S_1 有界, $S_1 \cap S_2 = \Phi$, 则存在超平面 H 强分离 S_1 和 S_2 , 即存在 $p \neq 0$, $\varepsilon > 0$ 使

$$\inf\{p^T x | x \in S_1\} \geq \varepsilon + \sup\{p^T x | x \in S_2\}$$

■ 2.3 择一定理

作为凸集分离定理的应用，下面介绍两个择一定理：**Farkas定理**和**Gordan定理**，它们在最优化理论中是很有用的。

定理2.11(*Farkas*定理)

设 A 为 $m \times n$ 矩阵， c 为 n 维向量，则

$Ax \leq 0, c^T x > 0$ 有解的充要条件是， $A^T y = c, y \geq 0$ 无解。

■ 2.3 择一定理

定理2.11' (Farkas置换定理)

设 $A \in R^{m \times n}$, $c \in R^n$, 则 c 为 A 的行向量的凸锥组合,

即 $c \in \text{cone} A \Leftrightarrow$ 对任意满足 $Ax \leq 0$ 的向量 $x \in R^n$, 都有 $c^T x \leq 0$.

推论 (Gale置换定理) 设 A 为 $m \times n$ 矩阵, b 为 m 维向量, 则线性系统 $Ax \leq b$ 有解 \Leftrightarrow 对任意满足 $A^T w = 0, w \geq 0$, 的向量 $w \in R^m$, 都有 $b^T w \geq 0$.

定理2.12(Gordan定理)

设 A 为 $m \times n$ 矩阵, 那么, $Ax < 0$ 有解的充要条件是不存在非零向量 $y \geq 0$, 使 $A^T y = 0$.


■ 2.4 凸函数

Df 2.10 设 $S \subset \mathbb{R}^n$ 是非空凸集, 函数 $f: S \rightarrow \mathbb{R}$, 若对任意 $\mathbf{x}_1, \mathbf{x}_2 \in S$, 和每一 $\lambda \in (0, 1)$ 都有


$$f(\lambda \mathbf{x}_1 + (1-\lambda)\mathbf{x}_2) \leq \lambda f(\mathbf{x}_1) + (1-\lambda)f(\mathbf{x}_2)$$

则称 f 是 S 上的 **凸函数**. 若上面的不等式对于 $\mathbf{x} \neq \mathbf{y}$ 严格成立, 则称 f 是 S 上的 **严格凸函数**.


若 $-f$ 是 S 上的凸函数, 则称 f 是 S 上的 **凹函数**. 若 $-f$ 是 S 上的严格凸函数, 则称 f 是 S 上的 **严格凹函数**.



convex function



concave function



neither convex
nor concave

■ 2.4 凸函数

命题2.3 设 f 是定义在凸集 S 上的凸函数, 则

- (1) 所有凸函数 f 的集合关于凸锥组合运算是封闭的,
即(a)实数 $\lambda \geq 0$, 则 λf 也是定义在 S 上的凸函数(b)
设 f_1 和 f_2 是定义在凸集 S 上的凸函数, 则 $f_1 + f_2$ 也是
定义在 S 上的凸函数
- (2) 函数 f 在开集 $\text{int}S$ 内是连续的.
- (3) 函数 f 的水平集 $L(f, \alpha) = \{x | x \in S, f(x) \leq \alpha\}, \alpha \in \mathbb{R}$
和上镜图 $\text{epi}(f) = \{(x, y) | x \in S, y \in \mathbb{R}, y \geq f(x)\}$ 都是凸集

■ 2.4 凸规划

$$\begin{aligned} & \min \quad f(x) \\ \text{s.t.} \quad & g_i(x) \geq 0, i = 1, 2, \dots, m \\ & h_j(x) = 0, j = 1, 2, \dots, l \end{aligned}$$

$f(x)$ 是凸函数, $g_i(x)$ 是凹函数,
 $h_j(x)$ 是线性函数。可行域

$$S = \left\{ x \left| \begin{array}{l} g_i(x) \geq 0, i = 1, 2, \dots, m \\ h_j(x) = 0, j = 1, 2, \dots, l \end{array} \right. \right\}$$

■ 小结

- 课程简介
- 预备知识
- 凸集和凸函数
- 最优化的应用

■ 作业

- 习题 2、4、9、10、12、14
- 线性规划的应用
<https://haokan.baidu.com/v?vid=3203660548000343532&pd=bjh&fr=bjhauthor&type=video>
- 常见的几个凸函数与凹函数