



深圳北理莫斯科大学

УНИВЕРСИТЕТ МГУ-ППИ В ШЭНЬЧЖЭНЕ

SHENZHEN MSU-BIT UNIVERSITY

Математическое моделирование и
исследование моделей с помощью
математических программ

数学建模及数学软件的使用

Лекция № 7a (优化)

张晔

ye.zhang@smbu.edu.cn

- **最优化问题**: 在数学与计算机科学领域中, 是从所有可行解中查找最优良的解的问题。
- Оптимизация/ Optimization/
Экстремальные задачи
- 根据变量是连续的或离散的, 最优化问题可分为两类:
连续最优化问题 与 **组合优化**。
- 相对于决策问题(Decision problem)、功能性问题(Function problem), 最优化问题是: 从问题的多个解中, 求出最佳解。
- 袁亚湘 院士的ppt

引子：瞎子爬山



瞎子与计算机

瞎子 - - - 知道脚底下情况,
但看不见周围的东西

计算机 - - - 给一个点 x , 可计算:
 $f(x), \partial f(x), \dots$
但对于 x 附近的其他 y ,
不知道 $f(y)$

瞎子爬山 vs 优化方法

瞎子和计算机谁快?

瞎子和计算机谁聪明?

瞎子会如何“看”“瞎子爬山法”呢?

优化方法的特征

- 基于极小 ($\min f(x)$)
- 基于KKT 条件 ($\nabla L(x, \lambda) = 0$)
- 迭代

$$x_{k+1} = U(x_k, \dots, \dots)$$

ККТ条件/Karush-Kuhn-Tucker Conditions

- В теории оптимизации условия Каруша — Куна — Таккера: необходимые условия решения задачи нелинейного программирования. Чтобы решение было оптимальным, должны быть выполнены некоторые условия регулярности. Метод является обобщением метода множителей Лагранжа. В отличие от него, ограничения, накладываемые на переменные, представляют собой не уравнения, а неравенства.

$$\min_x f(x)$$

Subject to:

$$g_i(x) \leq 0, h_j(x) = 0$$

$f(x)$ 是需要最小化的函数, $g_i(x)$ ($i = 1, \dots, m$)是不等式约束, $h_j(x)$ ($j = 1, \dots, l$)是等式约束, m 和 l 分别为不等式约束和等式约束的数量。

必要条件

假设有目标函数, 即是要被最小化的函数 $f: \mathbb{R}^n \rightarrow \mathbb{R}$, 约束函数 $g_i: \mathbb{R}^n \rightarrow \mathbb{R}$ 及 $h_j: \mathbb{R}^n \rightarrow \mathbb{R}$ 。再者, 假设他们都是于 x^* 这点是连续可微的, 如果 x^* 是一局部极小值, 那么将会存在一组所谓乘子的常数 $\lambda \geq 0$, $\mu_i \geq 0$ ($i = 1, \dots, m$) 及 ν_j ($j = 1, \dots, l$) 令到

$$\lambda + \sum_{i=1}^m \mu_i + \sum_{j=1}^l |\nu_j| > 0,$$

$$\lambda \nabla f(x^*) + \sum_{i=1}^m \mu_i \nabla g_i(x^*) + \sum_{j=1}^l \nu_j \nabla h_j(x^*) = 0,$$

$$\mu_i g_i(x^*) = 0 \text{ for all } i = 1, \dots, m.$$

充分条件

假设目标函数 $f: \mathbb{R}^n \rightarrow \mathbb{R}$ 及约束函数 $g_i: \mathbb{R}^n \rightarrow \mathbb{R}$ 皆为凸函数, 而 $h_j: \mathbb{R}^n \rightarrow \mathbb{R}$ 是一仿射函数, 假设有一可行点 x^* , 如果有常数 $\mu_i \geq 0$ ($i = 1, \dots, m$) 及 ν_j ($j = 1, \dots, l$) 令到

$$\nabla f(x^*) + \sum_{i=1}^m \mu_i \nabla g_i(x^*) + \sum_{j=1}^l \nu_j \nabla h_j(x^*) = 0$$

$$\mu_i g_i(x^*) = 0 \text{ for all } i = 1, \dots, m,$$

那么 x^* 这点是一全局极小值。

- **对偶**： Duality / Двойственность
- 优化角度： primal problem/ dual problem
 - **прямая задача / двойственная задача**
- **弱对偶 vs 强对偶**： “ ≤ ” vs “ = ”

- **Min-Max问题 (Bilevel optimization) :**

$$\max_x \min_y f(x, y) \leq \min_y \max_x f(x, y)$$

- “宁做鸡头,不做凤尾”： min = 鸡； max=凤

- 线性问题/二次规划 => **强对偶** => “ = ”： 等价求解比较容易的对偶问题
- 强对偶关系 \Leftrightarrow 满足KKT条件

(Lagrangian) duality

➤ 如何找到问题(1)的最优值的一个最好的下界?

$$\min\{f(\mathbf{x}) : g_i(\mathbf{x}) \leq 0, i = 1, 2, \dots, m\} \quad (1)$$

- 若方程组 $f(\mathbf{x}) < v$
 $g_i(\mathbf{x}) \leq 0, i = 1, 2, \dots, m$ (2) 无解, 则 v 是问题(1)的一个下界。

- 注意到方程组(2)有解可以推出对于任意的 $\lambda \geq 0$, 方程(3)有解

$$f(\mathbf{x}) + \sum_{i=1}^m \lambda_i g_i(\mathbf{x}) < v \quad (3)$$

- 根据逆否命题, 方程组(2)无解的充分条件是存在 $\lambda \geq 0$, 让方程(3)无解。

方程(3)无解的充要条件是 $\min_{\mathbf{x}} f(\mathbf{x}) + \sum_{i=1}^m \lambda_i g_i(\mathbf{x}) \geq v$ (4)

- 因为我们要找最好的下界, 所以这个时候的 v 和 λ 应该取

$$v = \max_{\lambda \geq 0} \min_{\mathbf{x}} f(\mathbf{x}) + \sum_{i=1}^m \lambda_i g_i(\mathbf{x}) \quad (5)$$

- 由此引入了 **dual problem**. 证明逻辑是根据式(5)取 v 和 λ , 则(4)成立, 从而导出(3)无解, 然后可以知道(2)无解, 因此 v 是问题(1)的下界。

迭代 - 计算的基本



千里之行始于足下 - - - 老子

几个经典优化方法

- **黄金分割法**
- **最速下降法**
- **共轭梯度法**
- **牛顿法与拟牛顿法**
- **高斯牛顿法与信赖域方法**
- **单纯形法与内点法**
- **交替方向法**

黄金分割法/Золотое сечение/ Golden ratio

目 录

第一部分 单因素优选法


第一章 黄金分割法和分数法	3
§ 1. 有限点的问题——分数法	4
§ 2. F_n 的解析表达式	6
§ 3. 黄金分割法	9
§ 4. 来回调试法	11
§ 5. 黄金分割法的最优性	14
§ 6. 连分数的知识	16
§ 7. 连分数与来回调试法(一)	19
§ 8. 连分数与来回调试法(二)	27
§ 9. 对分法	31
第二章 抛物线法	33
§ 1. 第一种方法	34
§ 2. 误差估计	38
§ 3. 第二种方法	40
§ 4. C_n 的表达式	42
§ 5. 第三种方法	44
第三章 分批试验及其他	47
§ 1. 试验方案优劣的衡量标准	48
§ 2. 一组特殊的方程组的解法	49
§ 3. 每批作奇数个试验, 如何安排	51
§ 4. 每批作偶数个试验, 如何安排	54
§ 5. 一般情形, 如何安排	56
§ 6. 试验批数不定的情形	58

§ 7. 是否最好的安排	62
§ 8. 依某种要求进行试验	65
§ 9. 重复性试验的分辨问题	67
§ 10. 非单峰的情形如何办	69




第二部分 多因素优选法

第一章 双因素优选法	73
§ 1. 对开法	77
§ 2. 旋升法	80
§ 3. 平行线法	81
§ 4. 两个因素的离散情形	82
§ 5. 翻筋斗法	83
第二章 最陡上升法	88
§ 1. 最陡上升法	88
§ 2. 渐近陡升法	94
§ 3. 二次模拟	96
§ 4. 反向 Schwarz 不等式	98
§ 5. 收敛因子的进一步改进	99
第三章 切块法	103
§ 1. 一个几何不等式(二维)	104
§ 2. s 维锥形的体积与重心	109
§ 3. 对称化	110
§ 4. Brun-Minkowski 不等式	113
§ 5. 拉直	113
§ 6. 说明	114
第四章 二次迴归法评介	116
§ 1. 背景	116
§ 2. 二次迴归	118
§ 3. s 个因素的问题	119
§ 4. 讨论	120

华罗庚 著



优选学



科学出版社



华罗庚 (1910 - 1985)

华罗庚在农村推广优选法



华罗庚在大庆油田讲优选法



华罗庚在矿山推广优选法




华罗庚在工厂、车间



max f(x)

- $[a, b]$ 上的连续函数 $f(x)$ 是单峰的 (只有一个最大值点), 求解 $\max f(x)$
- 任取 $a < c < d < b$, 如果 $f(c) < f(d)$, 则我们只需在 $[c, b]$ 上求 $\max f(x)$

如何选取 c, d ?



最优的 c, d

1) $\max[b-c, d-a]$ 达到最小

$$\rightarrow c \approx d = (a+b)/2 !$$

2) Repeat the procedure ?

$$\text{Once} \rightarrow c=1/3, d=2/3$$

$$\text{Twice} \rightarrow c=2/5, d=3/5?$$

一般的 c, d

$$F_0=1, F_1=1,$$
$$F_{k+1}=F_k + F_{k-1}$$

General case

$$c=F_{k-1}/F_{k+1} \quad d=F_k/F_{k+1}$$

$$\lim_{k \rightarrow \infty} \frac{F_k}{F_{k+1}} = \frac{\sqrt{5}-1}{2} \approx 0.618$$



Fibonacci(1170-1250)

斐波那契数列又因数学家列昂纳多·斐波那契以兔子繁殖为例子而引入，故又称为“兔子数列”。

一般而言，兔子在出生两个月后，就有繁殖能力，一对兔子每个月能生出一对小兔子来。如果所有兔子都不死，那么一年以后可以繁殖多少对兔子？

我们不妨拿新出生的一对小兔子分析一下：


第一个月小兔子没有繁殖能力，所以还是一对

两个月后，生下一对小兔对数共有两对

三个月以后，老兔子又生下一对，因为小兔子还没有繁殖能力，所以一共是三只

依次类推可以列出下表：

经过月数	0	1	2	3	4	5	6	7	8	9			
幼仔对数	1	0	1	1	2	3	5	8	13	21			
成兔对数	0	1	1	2	3	5	8	13	21	34	55	89	144
总体对数	1	1	2	3	5	8	13	21	34	55	89	144	233



幼仔对数=前月成兔对数


成兔对数=前月成兔对数+前月幼仔对数

总体对数=本月成兔对数+本月幼仔对数

可以看出幼仔对数、成兔对数、总体对数都构成了一个数列。这个数列有十分明显的特点，那是：前面相邻两项之和，构成了后一项。

这个数列是意大利中世纪数学家斐波那契在《算盘全书》中提出的，这个级数的通项公式，除了具有 $a(n+2)=a(n)+a(n+1)$ 的性质外，还可以证明通项公式为： $a_n=(1/\sqrt{5}) * \{[(1+\sqrt{5})/2]^n - [(1-\sqrt{5})/2]^n\}$ (n=1,2,3.....)

达·芬奇与黄金分割



- 黄金分割法:
- 给出 $[0, 1]$:
- $X=0.382$
- $Y=0.618$
- 新区间:
- $[0, 0.618]$ or
- $[0.382, 1]$

Leonardo da Vinci (1452-1519)



[article](#) | [discussion](#) | [view source](#) | [history](#)

Leonardo da Vinci

From Wikipedia, the free encyclopedia


"Da Vinci" redirects here. For other uses, see [Da Vinci \(disambiguation\)](#).

For the 17th century Italian composer, see [Leonardo Vinci](#)

Leonardo di ser Piero da Vinci ([ⓘ] pronunciation (help·info), April 15, 1452 – May 2, 1519) was an [Italian polymath](#), [scientist](#), [mathematician](#), [engineer](#), [inventor](#), [anatomist](#), [painter](#), [sculptor](#), [architect](#), [botanist](#), [musician](#) and [writer](#). Leonardo has often been described as the [archetype](#) of the [renaissance man](#), a man whose unquenchable curiosity was equaled only by his powers of invention.^[1] He is widely considered to be one of the greatest [painters](#) of all time and perhaps the most diversely talented person ever to have lived.^[2] [Helen Gardner](#) says "The scope and depth of his interests were without precedent...His mind and personality seem to us superhuman, the man himself mysterious and remote".^[1]



Euclid
(约325BC—265BC)



extreme and mean ratio

最速下降法

$$\min_{x \in \mathbb{R}^n} f(x)$$

$$d_k = -\nabla f(x_k)$$

$$x_{k+1} = x_k + \alpha_k d_k$$

α_k 使 $f(x + \alpha d)$ 达到最小
(精确搜索)

A. Cauchy, Comptes Rendus de
L'Acadmia des Sciences
25(1847) 536-538



Cauchy (1789 – 1859)

最速下降法收敛速度

假定 $f(x)$ 是二次凸函数

$$f(x) = g^T x + x^T H x$$

收敛速度:

$$\frac{f(x_{k+1}) - f(x^*)}{f(x_k) - f(x^*)} \leq \left[\frac{\sigma_1(H) - \sigma_n(H)}{\sigma_1(H) + \sigma_n(H)} \right]^2$$

最好 + 最好 = 最好 ???


- 方向 (最速下降) (best d_k)

$$d^T \nabla f(x_k) \geq d_k^T \nabla f(x_k), \quad \forall d, \|d\| = \|d_k\|$$

- 步长 (精确搜索) (best α_k)

$$f(x_k + \alpha d_k) \geq f(x_k + \alpha_k d_k), \quad \forall \alpha$$

- $x_{k+1} = x_k + \alpha_k d_k$ 是否最好 ????



最速下降法应用于 $f(x,y) = 100x^2 + y^2$

最速下降法的启示

最好方向 + 最好步长 \neq 最好的方法

推论：

班上最好的女生不应该嫁给
班上最好的男生！

Barzilai & Borwein Method

方向


(最速下降 - 最好方向)

步长

(上一次的精确搜索步长)


最好的 d + 上一步最好的 α

→ 最好



J.M. Borwein(1951-

Steepest descent with Barzilai-Borwein Step



BB 方法 应用于 $f(x,y)=100x^2+y^2$

BB方法的启示

最好方向 + 上一次最好步长 = 最好

推论：

班上最好的女生应该嫁给
高年级最好的男生！

共轭梯度法/Conjugate gradient method/

Метод сопряжённых градиентов

- 共轭梯度法是介于最速下降法与牛顿法之间的一个方法，它仅需利用一阶导数信息，但克服了最速下降法收敛慢的缺点，又避免了牛顿法需要存储和计算Hessen矩阵并求逆的缺点。
- 优点：存储量小，具有n步收敛性，稳定性高，而且不需要任何外来参数。

$$\min_{x \in \mathbb{R}^n} f(x)$$

$$x_{k+1} = x_k + \alpha_k d_k$$

- α_k 使 $f(x + \alpha d)$ 达到最小
(精确搜索)
- 如何选取 d_k ?

共轭梯度法

$$d_k = -\nabla f(x_k) + \beta_k d_{k-1}$$

前后两次的方向 d 相互共轭

d_k and d_{k-1} are conjugate!

$$d_k^T \nabla^2 f(x) d_{k-1} = 0$$

- **收敛速度**：N次迭代内收敛，其中N是变量的维度。
- **但是**：在 ill-posed problems 和 机器学习中，它不一定好！

共轭梯度法基本思想

考虑 $f(x) = (1/2) x^T A x - b^T x$

共轭方向 d_1, d_2, \dots, d_n

$$x = \sum_{i=1}^n \alpha_i d_i$$

$$f(x) = \sum_{i=1}^n \left[\frac{1}{2} \alpha_i^2 d_i^T A d_i - \alpha_i b^T d_i \right]$$

一个 n 维问题 转化为 n 个 一维问题

共轭梯度法的实现

$$d_{k+1} = -g_{k+1} + \beta_k d_k$$

著名的 β 选取:

$$\beta_k^{HS} = \frac{(g_{k+1} - g_k)^T g_{k+1}}{d_k^T (g_{k+1} - g_k)}$$

$$\beta_k^{FR} = \frac{\|g_{k+1}\|_2^2}{\|g_k\|_2^2}$$

$$\beta_k^{PRP} = \frac{(g_{k+1} - g_k)^T g_{k+1}}{\|g_k\|_2^2}$$




Hestenes
(1906-1991)




Stiefel
(1909-1978)

牛顿法：切线代替曲线



Newton(1643-1727)



牛顿法求 $f(x)=0$ 的根

牛顿法性质

迭代公式：

$$x_{k+1} = x_k - (\nabla^2 f(x_k))^{-1} \nabla f(x_k)$$

优缺点：

1) 优点：速度快（二次收敛）

$$\|x_{k+1} - x^*\| = O(\|x_k - x^*\|^2)$$

2) 缺点：计算量大（需要计算二阶导数）

拟牛顿法

牛顿:

$$x_{k+1} = x_k - (\nabla^2 f(x_k))^{-1} \nabla f(x_k)$$

拟牛顿:

Quasi-Newton: $x_{k+1} = x_k - (B_k)^{-1} \nabla f(x_k)$

如何选取 B?

如何“拟”牛顿？

拟牛顿方程：

$$B_{k+1} s_k = y_k$$

$$s_k = \alpha_k d_k$$

$$y_k = g_{k+1} - g_k.$$

Davidon(1959), Fletcher and Powell (1963):

$$B_{k+1} = B_k - \frac{B_k s_k y_k^T + y_k s_k^T B_k}{s_k^T y_k} + \left(1 + \frac{s_k^T B_k s_k}{s_k^T y_k}\right) \frac{y_k y_k^T}{s_k^T y_k},$$

$$F(x)=0$$

非线性最小二乘问题

$$\min_{x \in \mathbb{R}^n} \|F(x)\|_2^2$$

$$F(x) = (f_1(x), \dots, f_m(x))^T$$

最小二乘问题

- 超定方程组求解

$$Ax = b, \quad A \in \mathbb{R}^{m \times n}, b \in \mathbb{R}^m, x \in \mathbb{R}^n. \quad m \gg n.$$

- 数值模拟，曲线拟合

$$y_i \approx f(x_i, \beta), \quad i = 1, \dots, m.$$

- 反问题

$$\begin{aligned} h(x, y) &= \int \int k(x - \xi, y - \eta) f(\xi, \eta) d\xi d\eta + e(x, y) \\ &= (k \star f)(x, y) + e(x, y). \end{aligned}$$

高斯 - 牛顿法

$x_{k+1} = x_k + d_k$, 如何求 d_k ?

$$\min \|F(x_k + d)\|_2^2 \implies \min \|F(x_k) + A(x_k)^T d\|_2^2$$

$A(x)$ 是 $F(x)$ 的 JACOBI 阵

$$d_k = -(A(x_k)^T)^+ F(x_k)$$

J. C. F. Gauss
(1777-1855)



I. Newton
(1642-1727)

Levenberg-Marquardt 方法

当 A 坏条件时 高斯 - 牛顿步 很可能不好。

Levenberg (1944), Marquardt(1963) 提出：

$$d_k = -(A(x_k)A(x_k)^T + \lambda_k I)^{-1} A(x_k) F'(x_k)$$

L-M步的最优性

设 d_k 是 Levenberg-Marquardt 步:

$$d_k = -(A(x_k)A(x_k)^T + \lambda_k I)^{-1} A(x_k)F(x_k)$$

则它也是如下问题的解

$$\min_{d \in \mathcal{R}^n} \|F(x_k) + A(x_k)^T d\|_2^2$$

$$s. t. \quad \|d\|_2 \leq \|d_k\|_2$$

信赖域方法

信赖域方法基本思想

- 1) 局部区域
- 2) 逼近模型
- 3) 调节模型和区域

孙悟空的信赖域

- 袁亚湘 院士 团队



交替方向方法/ADMM

Alternating Direction Method of Multipliers

$$\min f(x)$$

$$x=(x_1, \dots, x_n)$$

固定 x_j ($j \neq i$), 对 x_i 进行优化

例子:

Gauss-Seidel 方法 求解 $Ax = b$

- 何炳生教授
- <http://maths.nju.edu.cn/~hebma> (很多资料)

交替方向方法 -- L1 优化

$$\min \|x\|_1$$

$$\text{s.t. } Ax = b$$

罚函数方法:

$$\min \sigma \|x\|_1 + \|Ax - b\|_2^2$$

交替方向方法 -- L1 优化

$$\min \sigma \|x\|_1 + \|Ay - b\|_2^2$$

$$\text{s. t. } y = x$$

对于: $\min \|Ay - b\|_2^2$

可以用梯度法下降;

对于 $\min \|x\|_1$

$$|x_{i+1}| \leq |x_i| - \delta \quad (\text{shrinkage operator})$$

祝福大家

优化自己的一生！

表 11-1

MATLAB 优化工具箱函数列表

类 别	适用问题	公式描述	可用函数
极小值优化	标量最小值优化问题	$\min_x f(x)$ $l < x < u$ (x 是标量)	fminbnd
	无约束最小值优化问题	$\min_x f(x)$	fminunc fminsearch
	线性规划	$\min_x f^T x$ $A \bullet x \leq b$ $Aeq \bullet x = beq$ $l \leq x \leq u$	linprog
	二次规划	$\min_x \frac{1}{2} x^T H x + f^T x$ $A \bullet x \leq b$ $Aeq \bullet x = beq$ $l \leq x \leq u$	quadprog
	约束最小值优化问题	$\min_x f(x)$ $c(x) \leq 0$ $ceq(x) = 0$ $A \bullet x \leq b$ $Aeq \bullet x = beq$ $l \leq x \leq u$	fmincon
	半无限问题	$\min_x f(x)$ $K(x, w) \leq 0$ (对于所有的 w) $c(x) \leq 0$ $ceq(x) = 0$ $A \bullet x \leq b$ $Aeq \bullet x = beq$ $l \leq x \leq u$	fseminf
	0-1 规划	$\min_x f^T x$ $A \bullet x \leq b$ $Aeq \bullet x = beq$ x 为二进制	bintprog

Пример 1

Find values of x that minimize $f(x) = -x_1 * x_2 * x_3$, starting at the point $x = [10;10;10]$, subject to the constraints: $0 \leq x_1 + 2x_2 + 2x_3 \leq 72$.

Write a file that returns a scalar value f of the objective function evaluated at x :

```
function f = myfun(x)
```

```
f = -x(1) * x(2) * x(3);
```

Rewrite the constraints as both less than or equal to a constant,

$$-x_1 - 2x_2 - 2x_3 \leq 0$$

$$x_1 + 2x_2 + 2x_3 \leq 72$$

Since both constraints are linear, formulate them as the matrix inequality $A \cdot x \leq b$, where

$$A = [-1 \ -2 \ -2; \dots$$

$$1 \ 2 \ 2];$$

$$b = [0;72];$$

Supply a starting point and invoke an optimization routine:

```
x0 = [10;10;10]; % Starting guess at the solution
```

```
[x,fval] = fmincon(@myfun,x0,A,b);
```

Пример 2

find values of x that minimize $f(x) = \frac{1}{2}x_1^2 + x_2^2 - x_1x_2 - 2x_1 - 6x_2$, subject to

$$\begin{aligned}x_1 + x_2 &\leq 2 \\ -x_1 + 2x_2 &\leq 2 \\ 2x_1 + x_2 &\leq 3 \\ 0 &\leq x_1, 0 \leq x_2.\end{aligned}$$

In matrix notation this is $f(x) = \frac{1}{2}x^T H x + f^T x$, $H = \begin{bmatrix} 1 & -1 \\ -1 & 2 \end{bmatrix}$, $f = \begin{bmatrix} -2 \\ -6 \end{bmatrix}$, $x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$.

- Enter the coefficient matrices:
H = [1 -1; -1 2];
f = [-2; -6];
A = [1 1; -1 2; 2 1];
b = [2; 2; 3];
lb = zeros(2,1);

- [x,fval] = quadprog(H,f,A,b,[],[],lb,[],[])

课后作业

作业： 给定 $k(x,t)$ 和 $g(t)$, 用最小二乘法求解如下两个问题：

问题1：
$$f(x) + \int_0^1 k(x,t) f(x) dx = g(t)$$

问题2：
$$\int_0^1 k(x,t) f(x) dx = g(t)$$