

# 1 无约束优化 [4]

无约束优化问题可表示为

$$\min_{\mathbf{x}} f(\mathbf{x}), \quad \mathbf{x} = (x_1, \dots, x_n)^T \in \mathbb{R}^n \quad (1.1)$$

$f$  为非线性函数, 则 1.1 称为无约束非线性规划. 实际上是一个多元函数无条件极值问题.

极值问题的解都是全局最优解, 全局最优解只能从局部最优解的比较中得到.

若  $f(\mathbf{x})$  二次可导, 则记一阶导数  $\nabla f(\mathbf{x}) = (f_{x_1}, \dots, f_{x_n})^T$ , 二阶导数记为  $\nabla^2 f = (f_{x_i x_j})_{n \times n}$ , 即 Hessian 矩阵. 多元函数极值条件为:

$$\nabla f(\mathbf{x}) = 0, \text{ 且 } \nabla^2 f(\mathbf{x}) \text{ 正定} \quad (1.2)$$

使用迭代法求极值: 选取初始解  $x_0$ , 对第  $k$  次迭代解, 确定搜索方向  $\mathbf{d}_k \in \mathbb{R}^n$  和步长  $a_k \in \mathbb{R}$  令

$$\mathbf{x}_{k+1} = \mathbf{x}_k + a_k \mathbf{d}_k \quad (1.3)$$

使

$$f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k) \quad (1.4)$$

当  $\mathbf{x}_k$  满足终止条件时终止.

## 1.1 确定搜索方向

### 1.1.1 最速下降法(梯度法)

作泰勒展开:

$$\begin{aligned} f(\mathbf{x}_{k+1}) &= f(\mathbf{x}_k + a_k \mathbf{d}_k) \\ &= f(\mathbf{x}_k) + a_k \nabla f(\mathbf{x}_k)^T \mathbf{d}_k + o(\|a_k \mathbf{d}_k\|^2) \end{aligned} \quad (1.5)$$

取于是取  $\mathbf{d}^k = -\nabla f(\mathbf{x}^k)$  可使目标下降最快, 这种方法就是最速下降法.

### 1.1.2 牛顿法

作二阶展开:

$$\begin{aligned} f(\mathbf{x}_{k+1}) &= f(\mathbf{x}_k + a_k \mathbf{d}_k) \\ &= f(\mathbf{x}_k) + a_k \nabla f(\mathbf{x}_k)^T \mathbf{d}_k + \frac{1}{2} a_k \mathbf{d}_k^T \nabla^2 f(\mathbf{x}_k) \mathbf{d}_k + o(\|a_k \mathbf{d}_k\|^3) \end{aligned} \quad (1.6)$$

若  $\nabla^2 f(\mathbf{x}_k)$  正定, 则余项  $a_k \nabla f(\mathbf{x}_k)^T \mathbf{d}_k + \frac{1}{2} a_k^2 \mathbf{d}_k^T \nabla^2 f(\mathbf{x}_k) \mathbf{d}_k$  为  $\mathbf{d}_k$  二次型, 必可取到最小值.

且在  $\mathbf{d}_k = -a_k (\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$  处取到. 这就是牛顿法.

### 1.1.3 拟牛顿法

$(\nabla^2 f(\mathbf{x}_k))^{-1}$  的不仅计算复杂, 而且会出现病态, 不正定的情况. 为克服这些缺点, 同时保持较快收敛的优点, 构造一个正定矩阵  $G_{k+1}$  近似代替  $(\nabla^2 f(\mathbf{x}_k))^{-1}$ , 或构造  $H_{k+1}$  近似代替  $(\nabla^2 f(\mathbf{x}_k))^{-1}$

记:

$$\Delta \mathbf{x}_k = \mathbf{x}_{k+1} - \mathbf{x}_k \quad (1.7)$$

$$\Delta f_k = \nabla f(\mathbf{x}_{k+1}) - \nabla f(\mathbf{x}_k) \quad (1.8)$$

计算  $G_{k+1}$  有两组迭代公式:

BFGS (Broyden-Fletcher-Goldfarb-Shanno) 公式

$$G_{k+1} = G_k + \frac{\Delta f_k \Delta f_k^T}{\Delta f_k^T \Delta \mathbf{x}_k} - \frac{G_k \Delta \mathbf{x}_k \Delta \mathbf{x}_k^T G_k}{\Delta \mathbf{x}_k^T G_k \Delta \mathbf{x}_k} \quad (1.9)$$

$$H_{k+1} = H_k + \left(1 + \frac{\Delta f_k^T H_k \Delta f_k}{\Delta f_k^T \Delta \mathbf{x}_k}\right) \frac{\Delta \mathbf{x}_k (\Delta \mathbf{x}_k)^T}{\Delta f_k^T \Delta \mathbf{x}_k} - \frac{\Delta \mathbf{x}_k \Delta f_k^T H_k + H_k \Delta f_k \Delta \mathbf{x}_k^T}{\Delta f_k^T \Delta \mathbf{x}_k} \quad (1.10)$$

DFP(Davidon-Fletcher-Powell) 公式

$$G_{k+1} = G_k + \left(1 + \frac{\Delta \mathbf{x}_k^T G_k \Delta \mathbf{x}_k}{\Delta \mathbf{x}_k^T \Delta f_k}\right) \frac{\Delta f_k \Delta f_k^T}{\Delta f_k^T \Delta \mathbf{x}_k} - \frac{\Delta f_k \Delta \mathbf{x}_k^T G_k + G_k \Delta \mathbf{x}_k \Delta f_k^T}{\Delta \mathbf{x}_k^T \Delta f_k} \quad (1.11)$$

$$H_{k+1} = H_k + \frac{\Delta \mathbf{x}_k \Delta \mathbf{x}_k^T}{\Delta f_k^T \Delta \mathbf{x}_k} - \frac{H_k \Delta f_k \Delta f_k^T H_k}{\Delta f_k^T H_k \Delta f_k} \quad (1.12)$$

这两组公式是对偶的, 只要互换  $G_k, H_k$  与  $\Delta f_k, \Delta \mathbf{x}_k$  互换即得.

可证明, 只要  $\Delta f_k^T \Delta \mathbf{x}_k > 0$  取  $H_1 = I$  (单位阵), 这样构造的  $H_k$  正定对称, 迭代过程二阶收敛.

## 1.2 搜索步长的确定

确定搜索方向  $\mathbf{d}_k$  确定, 求步长  $a_k$  实际是一个一维优化问题:

$$\min_{\alpha} f(x_k + \alpha) \quad (1.13)$$

显然其精确解应满足

$$\nabla f(x_k + \alpha \mathbf{d}_k)^T \mathbf{d}_k = 0 \quad (1.14)$$

当  $f$  复杂的时候计算很复杂, 实际计算的时候用插值方法. 如采用二次插值:

$$q(\alpha) = a\alpha^2 + b\alpha + c \quad (1.15)$$

参数  $a, b, c$  可由  $\alpha = 0$  的函数值和导数  $q(0) = f(x_k)$ ,  $q'(0) = \nabla f(x_k)^T \mathbf{d}_k$ , 以及另一点函数值确定, 而  $\alpha$  的最优值取  $\alpha_{min} = -\frac{b}{2a}$  使  $q(\alpha)$  达到最小值.

还可以用三次插值, 或者二次三次混合插值等.

### 1.3 非线性最小二乘拟合

有一组数据  $(t_i, y_i), i = 1, \dots, n$ , 要拟合一个已知函数  $y = f(t, \mathbf{x})$   
 $\mathbf{x} = (x_1, \dots, x_m)^T, m \leq n$ ,  $\mathbf{x}$  为待定系数.

记  $r_i(\mathbf{x}) = y_i - f(t_i, \mathbf{x}), r(\mathbf{x}) = (r_1(\mathbf{x}), \dots, r_n(\mathbf{x}))$   
 最小二乘法即如下优化模型:

$$\min_{\mathbf{x}} R(\mathbf{x}) = r^T(\mathbf{x})r(\mathbf{x}) \quad (1.16)$$

记  $r(\mathbf{x})$  的 Jacobi 矩阵为:

$$J(\mathbf{x}) = \left( \frac{\partial r_i}{\partial x_j} \right)_{n \times m} \quad (1.17)$$

则

$$\nabla R = 2J(\mathbf{x})^T r(\mathbf{x}) \quad (1.18)$$

$$\nabla^2 R = 2J(\mathbf{x})^T J(\mathbf{x}) + 2S \quad (1.19)$$

$$S = \sum_{i=1}^n r_i(\mathbf{x}) \nabla^2 r_i(\mathbf{x}) \quad (1.20)$$

$$\nabla^2 r_i(\mathbf{x}) = \left( \frac{\partial^2 r_i}{\partial x_k \partial x_l} \right)_{n \times n} \quad (1.21)$$

如用牛顿法计算,  $S$  的计算量很大, 因此需要简化. 可忽略  $S$  由此得高斯-牛顿(Guass-Newton) 法. 下降方向  $\mathbf{d}_k$  为:

$$J(\mathbf{x}_k)^T J(\mathbf{x}_k) \mathbf{d}_k = -J(\mathbf{x}_k) r(\mathbf{x}_k) \quad (1.22)$$

高斯-牛顿法中  $J^T J$  总是半正定, 但会出现病态, 改进方法是修正的计算方法:

$$(J(\mathbf{x}_k)^T J(\mathbf{x}_k) + \alpha_k I) \mathbf{d}_k = -J(\mathbf{x}_k) r(\mathbf{x}_k) \quad (1.23)$$

$\alpha_k > 0$  是在每次迭代中修正的参数.  $\alpha$  很小时  $\mathbf{d}_k$  接近高斯-牛顿法,  $\alpha$  很大时, 接近负梯度方向, 迭代方向在牛顿方向和负梯度方向之间. 这个方法的名字叫 LM(Levenberg-Marquardt) 法.

## 2 带约束非线性规划 [4]

带约束线性规划可表示成如下形式:

$$\begin{aligned} \max \quad & z = f(\mathbf{x}), \mathbf{x} \in \mathbb{R}^n \\ \text{s.t.} \quad & h_i(\mathbf{x}), i = 1, 2, \dots, m \\ & g_i(\mathbf{x}) \leq 0, j = 1, 2, \dots, l \end{aligned} \quad (2.1)$$

若只有等式约束  $h_i(\mathbf{x}) = 0$  可用 Lagrange 乘子法化为无约束优化:

$$L(\mathbf{x}, \boldsymbol{\mu}) = f(\mathbf{x}) + \sum_{i=1}^m \mu_i h_i(\mathbf{x}) \quad (2.2)$$

记可行解域为  $G : g_j(\mathbf{x}) \leq 0, j = 1, 2, \dots, l$ , 若最优解不在  $G$  的边界而在其内部取到, 则问题可简化为无约束优化. 下面只考虑最优解在边界取到.

设  $\mathbf{x}$  为可行解, 使

$$g_j(\mathbf{x}) = 0, \quad j \in J_1 \quad (2.3)$$

$$g_j(\mathbf{x}) < 0, \quad j \in J_2 \quad (2.4)$$

$$(2.5)$$

称  $g_j(j \in J_1)$  为起作用约束,  $g_j(j \in J_2)$  为不起作用约束.

对于  $\mathbf{x} \in G$  和一方向  $\mathbf{d}$  若存在实数  $\lambda_0$ , 使  $\mathbf{x} + \lambda\mathbf{d} \in G(0 < \lambda < \lambda_0)$ , 则称  $\mathbf{d}$  为  $\mathbf{x}$  的可行方向.

$\mathbf{x}$  在有效约束上, 即  $g_j(\mathbf{x}) = 0(j \in J_i)$ , 将  $g_j(\mathbf{x} + \lambda\mathbf{d})$  泰勒展开,

$$g_i(\mathbf{x} + \lambda\mathbf{d}) = g_i(\mathbf{x}) + \lambda\nabla g_i(\mathbf{x})^T \mathbf{d} + o(\lambda^2) \quad (2.6)$$

只要

$$\nabla g_i(\mathbf{x})^T \mathbf{d} < 0 \quad (2.7)$$

即  $\mathbf{d}$  即为可行方向.

对于  $\mathbf{x} \in G$  和一方向  $\mathbf{d}$ , 若存在  $\lambda_0$ , 使:

$$f(\mathbf{x} + \lambda\mathbf{d}) < f(\mathbf{x}), \quad (0 < \lambda < \lambda_0) \quad (2.8)$$

只要

$$\nabla f(\mathbf{x})^T \mathbf{d} < 0 \quad (2.9)$$

$\mathbf{d}$  即为下降方向.

显然最优解有必要条件, 即不存在同时为可行方向和最优方向的方向.

即: 若  $\mathbf{x}$  是最优解, 且  $\nabla g_j(\mathbf{x})(j \in J_1)$  线性无关, 则存在  $\lambda_1, \dots, \lambda_l \geq 0$ , 使

$$\nabla f(\mathbf{x}) + \sum_{j=1}^l \lambda_j \nabla g_j(\mathbf{x}) = 0 \quad (2.10)$$

$$\lambda_j g_j(\mathbf{x}) = 0, \quad j = 1, 2, \dots, l \quad (2.11)$$

这个条件称为 Kuhn-Tucker 条件, 满足这个条件的点称为 K-T 点. 最优解只可能在 K-T 点中取到.

## 2.1 二次规划

当目标函数是二次函数, 约束为线性时, 模型 2.1 简化为

$$\begin{aligned} \max \quad & f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T H \mathbf{x} + \mathbf{c}^T \mathbf{x} \\ \text{s.t.} \quad & A \mathbf{x} \leq \mathbf{b} \end{aligned} \quad (2.12)$$

其中  $\mathbf{x}, A, \mathbf{b}$  同线性规划,  $H \in \mathbb{R}^{n \times n}$  为对称阵, 叫做二次规划(Quadratic Programming, 记作 QP). 特别, 当  $H$  正定时, 目标函数是凸函数, 称为凸二次规划.

QP 有良好的性质:

- K-T 条件不仅是最优解的必要条件, 而且是充分条件
- 局部最优解就是全局最优解

## 2.2 逐步二次规划法

非线性规划的解法很多, 有可行方向法, 罚函数发, 梯度投影法等. 下面简述, 逐步二次规划法(Sequential Quadratic Programming)

基本原理是:构造Lagrange 乘子

$$L(\mathbf{x}, \boldsymbol{\mu}, \boldsymbol{\lambda}) = f(\mathbf{x}) + \sum_{i=1}^m \mu_i h_i(\mathbf{x}) + \sum_{j=1}^l \lambda_j g_j(\mathbf{x}) \quad (2.13)$$

用二次函数近似 $L(\mathbf{x}, \boldsymbol{\mu}, \boldsymbol{\lambda})$  后化为QP 问题:

$$\begin{aligned} \max \quad & \frac{1}{2} \mathbf{d}^T G \mathbf{d} + \nabla f(\mathbf{x}_k)^T \mathbf{d} \\ \text{s.t.} \quad & \nabla h_i(\mathbf{x}_k)^T \mathbf{d} + h_i(\mathbf{x}) = 0, \quad i = 1, \dots, m \\ & \nabla g_i(\mathbf{x}_k)^T \mathbf{d} + g_i(\mathbf{x}_k) \leq 0, \quad j = 1, \dots, l \end{aligned} \quad (2.14)$$

其中 $\mathbf{x}_k$  是第 $k$  次迭代的初始点,  $G_k$  是 $L(\mathbf{x}, \boldsymbol{\mu}, \boldsymbol{\lambda})$  的Hesse 矩阵的近似, 可用BFGS 公式.

得到的最优解 $\mathbf{d}_k$  取作第 $k$  次迭代的搜索方向. 步长由线性搜索确定.

## 3 求解非线性规划的软件 [1]

求解非线性规划方法众多, 不像线性规划中基本上单纯形法一统天下, 因此有各种各样的软件和工具包的存在, 这里很不完全的列一些软件, 并介绍下面用到的AMPL 建模系统.

### 3.1 可用的软件库

Omuses/HQP 是一个开源的c++库, 提供各种解法器. OPT++2.1 也是一个c++库, 提供各种解法器.

我测试过以上两个库, 具体的程序比较复杂, 不再详述.

另外COIN-OR [3] ( COmputational INfrastructure for Operations Research - open source for the operations research community - ) 是一个不错的软件收集工程.

### 3.2 AMPL [2]

AMPL ®[2] ( A Modeling Language for Mathematical Programming )

专门为优化问题设计的建模语言. 它是由Bell实验室开发的. GLPK 使用的GNU MathProg Language 就是他的一个子集. AMPL 不仅可以处理线性规划问题, 还能处理非线性规划问题. 他将规划文件.mod 转换成专门的.nl 文件. 然后调用解法器(solver) 求解. AMPL本身不是一个求解程序, 而是一种翻译器.

AMPL软件是付费的, 不过可以使用免费的学生版.

<http://www.ampl.com/NEW/TABLES/amplcm1.zip>

他还包括了学生版的MINOS, CPLEX 等解法器, 学生版的限制主要是问题的规模限制在300个变量以下. 下面的计算都是在学生版中完成的.

### 3.2.1 AMPL/Solver

这里主要讨论开源的解法器, Ipopt, 和TRON. Ipopt 和TRON都可以用c之间调用, 具体方法就不给出了.

### 3.2.2 Neos

<http://neos.mcs.anl.gov/>

NEOS服务. 是在线解决优化问题的服务器, 可以通过email, XML-RPC, 和web提交问题. 目前NEOS的版本是5. NEOS支持各种各样的的优化解法器, 而且可以自动确定很多求解参数. NEOS支持AMPL格式的建模程序. 如果你有优化问题, 规模比较大, 不妨试一下, 很好用.

## 4 习题解答

### 4.1 解下面问题

$$\begin{aligned} \max \quad & f(\mathbf{x}) = 2x_1 - x_2 \\ \text{s.t.} \quad & x_1^2 + x_2^2 \leq 1 \\ & x_2 \geq 0 \end{aligned} \tag{4.1}$$

使用AMPL语言建模, 求解

```
var x{1..2};  
maximize ff: 2 * x[1] - x[2];  
subject to ss: x[1]^2 + x[2]^2 <= 1;  
subject to bb: x[2] >= 0;
```

运行命令

```
G:\mydoc\my text\建模\modeling\05sum\nonlinear>ampl  
ampl: model a2.mod  
ampl: solve;  
MINOS 5.5: optimal solution found.  
9 iterations, objective 2  
Nonlin evals: constrs = 32, Jac = 31.  
ampl: display x;  
x [*] :=  
1 1  
2 0  
;
```

解得最优解在 $x_1 = 1, x_2 = 0$  取得为2.

## 4.2 第二题解

### 4.2.1 题目

根据一个地区国民经济发展需要和电力建设规划, 已知到某一年要求水电总装机容量至少为 $NkW$ , 现拟同时兴建 $n$ 座水电站, 而该地区可能筹集到的资金为 $B$ , 若采用水电站群的“总年利润最大”为准则, 试确定各水电站的最优装机容量. 试建立其数学模型.

### 4.2.2 解

假设电价和可供应电量成负指数关系, 假设发电机组的利润和发电机组容量成负指数关系. 即容量越大, 单位利润越大

具体建模如AMPL程序, 并凑了一组数据试验

```
set P;
param op{P}; #各电站建设支出每千瓦
param bop{P}; #各电站基准建设费用
param bip; #基准价格
param N; #至少装机容量
param B; #可获得的资金
param bue{P}; #最大装机容量
param bbe{P}; #最小装机容量
param bmoq; # 基准维护费用
param mlam; # 单位利润的上升参数
param lam; # 电价的下降参数

var e{P} >=0 ; #装机容量
var ip; # 收入每千瓦
var income; # 年收入
var outcome; # 年维护支出
var bout; # 建设支出
var ea ; #总装机容量
var lucre ; # 收益
var moq{P}; # 每个电站的维护费用

maximize w: lucre;

# 利润等于年收入减去总维护费用
subject to lucreq: lucre - (income - outcome) = 0 ;
# 年支出等于各电站维护费用.
subject to youteq: outcome - sum{i in P} moq[i] * e[i] = 0 ;
# 年收入等于电价乘以装机容量
subject to inm: income - ip * ea = 0;
# 建设支出等于各电站基础建设费用加上装机费用
subject to bouteq: sum{i in P} (op[i] * e[i] + bop[i]) - bout = 0 ;
# 建设支出小于可筹集资金
```

```

subject to allb: bout <= B;
# 总供电量大于N
subject to equic: ea >= N;
# 各电站有可建设容量上下限
subject to beq{i in P}: bbe[i] <= e[i] <= bue[i] ;
# 总供电量为各电站供电量之和
subject to eqa: sum{i in P} e[i] - ea = 0;
# 单位电价和总供电量成负指数关系
subject to eip: bip * lam ^ (ea/N) - ip = 0;
# 单位维护费用随容量上升而下降, 设为负指数关系
subject to moeq{i in P}: bmoq * mlam ^ e[i] - moq[i] = 0;

data;
set P:=1,2,3,4,5;
param op:-
1 1.1
2 1.2
3 1.1
4 1.3
5 1.2;
param bop:-
1 2.2
2 2.0
3 2.5
4 2.3
5 2.2;
param bbe:-
1 100
2 110
3 120
4 150
5 170
;
param bue:-
1 200
2 250
3 270
4 290
5 300
;
param bip:=2.0;
param N:=400;
param B:=2000;
param lam:=0.7;
param mlam:= 0.6;

```

```
param bmoq:= 1.1;
end;
```

求解结果

```
ampl: model tp1.mod
ampl: solve;
MINOS 5.5: optimal solution found.
23 iterations, objective 825.1309982
Nonlin evals: constrs = 62, Jac = 61.
ampl: display e;
e [*] :=
1 200
2 250
3 270
4 231.409
5 170
;
```

## References

- [1] Nonlinear Programming Frequently Asked Questions , <http://www-unix.mcs.anl.gov/otc/Guide/faq/nonlinear-programming-faq.html> , 2000
- [2] AMPL 主页, <http://www.ampl.com> , 2001
- [3] COmputational INfrastructure for Operations Research , <http://www.coin-or.org/>
- [4] 高等教育出版社, 数学实验, 肖铁树等, 1999