

# 最优化理论

## Optimality Theory



- 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)**



## 使用导数的最优化方法

---

### Optimization Method Using Derivative



## ■ 主要内容

- 最速下降法
- 牛顿法
- 共轭梯度法
- 拟牛顿法
- 信赖域法



## ■ 共轭方向与扩张子空间定理

**定义10.3.1** 设 $A$ 是 $n \times n$ 对称矩阵,若 $R^n$  中的两个方向 $d^1$  和 $d^2$ 满足

$$(d^1)^T A d^2 = 0 \quad (10.3.1)$$


则称这两个方向关于 $A$ 共轭,或称它们关于 $A$ 正交.

若 $d^{(1)}, d^{(2)}, \dots, d^{(k)}$ 是 $R^n$ 中 $k$ 个方向, 它们两两关于 $A$ 共轭, 即

$$d^{(i)T} A d^{(j)} = 0, i \neq j, \quad i, j = 1, 2, \dots, k. \quad (10.3.2)$$

则称这组方向是 $A$ 共轭,或称它们为 $A$ 的 $k$ 个共轭方向

## ■ 几何意义



沿着 $d^{(1)}$ 和 $d^{(2)}$ 进行一维搜索，经两次迭代必达到极小点

## 算法1 共轭方向法

步1(初始化), 给定初始点  $x^0 \in R^n$ , 计算  $\nabla f(x^0)$ , 给定一个搜索方向  $d^0 \neq 0$ , 使得  $\nabla f(x^0)^T d^0 < 0$ ; 置  $k = 0$

步2(线搜索), 求解一维极小化问题  $\min_{\alpha \in R} f(x^k + \alpha d^k)$ ;

$x^{k+1} = x^k + \alpha_k d^k$ , 若  $\nabla f(x^{k+1}) = 0$  或  $k = n - 1$ , 停止, 否则转步3

步3(计算共轭方向), 计算一个非零方向  $d^{k+1} \in R^n$ , 使得

$(d^{k+1})^T G d^j = 0 (\forall j = 0, 1, \dots, k)$ ; 置  $k + 1 \rightarrow k$  转步2

**定理10.3.1** 设  $A$  是  $n$  阶对称正定矩阵,  $d^{(1)}, d^{(2)}, \dots, d^{(k)}$  是  $k$  个  $A$  共轭的非零向量, 则这个向量组线性无关.

**定理10.3.2**(扩张子空间定理) 设有函数

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

其中A是n阶对称正定矩阵,  $d^{(1)}, d^{(2)}, \dots, d^{(k)}$ 是A共轭的非零向量. 以任意的  $x^{(1)} \in R^n$  为初始点, 依次沿  $d^{(1)}, d^{(2)}, \dots, d^{(k)}$  进行一维搜索, 得到点列  $x^{(1)}, x^{(2)}, \dots, x^{(k+1)}$ , 则  $x^{(k+1)}$  是函数  $f(x)$  在线性流形  $x^{(1)} + \Gamma_\kappa$  上的唯一极小点. 特别地, 当  $k = n$  时,  $x^{(k+1)}$  是函数  $f(x)$  在  $E^n$  上的唯一极小点. 其中

$$\Gamma_\kappa = \left\{ x \left| x = \sum_{i=1}^k \lambda_i d^{(i)}, \lambda_i \in (-\infty, +\infty) \right. \right\}$$

是  $d^{(1)}, d^{(2)}, \dots, d^{(k)}$  生成的子空间.



## ■ 线性共轭梯度法与二次终止性

上述定理表明,对于二次凸函数,若沿一组共轭方向(非零向量)搜索,经有限步迭代必到达极小点.

- 基本思想:把共轭性与最速下降法相结合, 利用已知点处的梯度构造一组共轭方向, 并沿着这组方向进行搜索, 求出目标函数的极小点



- 注意,初始搜索方向选择最速下降方向十分重要,如果选择别的方向作为初始方向,其余方向均按FR方法构造,则极小化正定二次函数时,这样构造出来的一组方向并不能保证共轭性.

例 考虑下列问题

$$\min x_1^2 + \frac{1}{2}x_2^2 + x_3^2$$

取初始点和初始搜索方向分别为

$$x^{(1)} = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}, d^{(1)} = \begin{pmatrix} -1 \\ -2 \\ 0 \end{pmatrix}$$



- 可以证明,对于正定二次函数,运用FR法时不作矩阵运算就能求出因子 $\beta_i$

**定理10.3.4** 对于正定二次函数,FR法中因子 $\beta_i$ 具有下述表达式

$$\beta_i = \frac{\|g_{i+1}\|^2}{\|g_i\|^2}, \quad (i \geq 1, g_i \neq 0) \quad (10.3.24)$$



- FR法(对二次凸函数)

1,给定初点 $x^{(1)}$ ,置 $k = 1$ .

2,计算 $g_k = \nabla f(x^{(k)})$ .若 $\|g_k\| = 0$ ,停止计算,得点  
 $\bar{x} = x^{(k)}$ ; 否则,进行下一步.

3,构造搜索方向.令

$$d^{(k)} = -g_k + \beta_{k-1}d^{(k-1)}$$

其中,当 $k = 1$ 时, $\beta_{k-1} = 0$ ,

当 $k > 1$ 时按公式(10.3.24)计算 $\beta_{k-1}$ .



4, 令  $x^{(k+1)} = x^{(k)} + \lambda_k d^{(k)}$

其中按公式(10.3.17)计算步长 $\lambda_k$ .

5, 若 $k = n$ , 则停止计算, 得点 $\bar{x} = x^{(k+1)}$

否则, 置 $k := k + 1$ , 转2

## ■ 一般函数的共轭梯度法—非线性共轭梯度法

一般迭代格式

$$\begin{cases} x^{k+1} = x^k + \alpha_k d^k \\ d^{k+1} = -g^{k+1} + \beta_k d^k \end{cases} \quad k=0,1,\dots \quad (10.3.3.1)$$

其中初始方向  $d^0 = -g^0$ , 步长参数  $\alpha_k$  由一维搜索得到,  
 $\beta_k$  的计算公式通常有如下几种:

$$1, \quad \beta_k = \frac{(g^{k+1})^T g^{k+1}}{(g^k)^T g^k} \quad (\text{Fletcher-Reeves(FR)})$$



- 2,  $\beta_k = \frac{\mathbf{g}_{k+1}^T(\mathbf{g}_{k+1} - \mathbf{g}_k)}{\mathbf{g}_k^T \mathbf{g}_k}$  ----PRP(Polak-Ribiere-Polyar)
- 3,  $\beta_k = \frac{\mathbf{g}_{k+1}^T(\mathbf{g}_{k+1} - \mathbf{g}_k)}{(\mathbf{d}^k)^T(\mathbf{g}_{k+1} - \mathbf{g}_k)}$  -----SW(Sorenson-Wolfe)
- 4,  $\beta_k = \frac{(\mathbf{d}^k)^T \nabla^2 f(\mathbf{x}^{k+1}) \mathbf{g}_{k+1}}{(\mathbf{d}^k)^T \nabla^2 f(\mathbf{x}^{k+1}) \mathbf{d}^k}$  ----Daniel
- 5,  $\beta_k = \frac{\mathbf{g}_{k+1}^T \mathbf{g}_{k+1}}{(\mathbf{d}^k)^T \mathbf{g}_k}$  -----Dixon



## FR共轭梯度法

1, 给定初始点  $x^{(1)}$ , 允许误差  $\varepsilon > 0$ . 置

$$y^{(1)} = x^{(1)}, d^{(1)} = -\nabla f(y^{(1)}), k = j = 0.$$

2, 若  $\|\nabla f(y^{(j)})\| < \varepsilon$ , 则停止计算, 否则作一维搜索,

求  $\lambda_j$  满足  $f(y^{(j)} + \lambda_j d^{(j)}) = \min_{\lambda} f(y^{(j)} + \lambda d^{(j)})$

令  $y^{(j+1)} = y^{(j)} + \lambda_j d^{(j)}$



3,如果 $j < n$ ,转步4,否则,转5

4,令  $d^{(j+1)} = -\nabla f(y^{(j+1)}) + \beta_j d^{(j)}$

其中  $\beta_j = \frac{\|\nabla f(y^{(j+1)})\|^2}{\|\nabla f(y^{(j)})\|^2}$

置 $j := j + 1$ ,转步2.

5,令  $x^{(j+1)} = y^{(n+1)}$ ,  $y^{(1)} = x^{(k+1)}$ ,  $d^{(1)} = -\nabla f(y^{(1)})$

置 $j = 1, k := k + 1$ ,转步2.

可以证明,对一般函数,共轭梯度法在一定条件下是收敛的,



FR算法中使用精确线搜索，我们有如下收敛性结果

**定理** 假设函数 $f: R^n \rightarrow R$ 有下界，梯度 $\nabla f(x)$ 是Lipschitz连续的. 在FR共轭梯度法中，步长参数 $\alpha_k$ 是由精确线搜索确定的，并且满足充分下降条件(即Armijo条件). 若 $\forall k \geq 0, g^k \neq 0$ , 则

$$\liminf_{k \rightarrow +\infty} \|g^k\| = 0$$

(Armijo条件:选择步长 $\lambda_k$ 满足

$$f(x^k + \lambda_k d^k) \leq f(x^k) + c_1 \lambda_k \nabla f(x^k)^T d^k \quad )$$



## ■ 拟牛顿条件和算法步骤

### 基本思想：

牛顿法成功的关键在于利用了Hessian矩阵提供的曲率信息，而计算Hessian矩阵工作量大，并且有的目标函数的Hessian矩阵很难计算，甚至不好求出，这就导致**仅利用目标函数一阶导数的方法。**

拟牛顿法就是利用目标函数值 $f$ 和一阶导数 $g$ 的信息，构造出目标函数的曲率近似，而不需要明显形成Hessian矩阵，同时具有收敛速度快的优点。



## ■ 拟牛顿条件和算法步骤

牛顿法的迭代公式为

$$x^{(k+1)} = x^{(k)} + \lambda_k d^{(k)} \quad (10.4.1)$$

其中  $d^{(k)}$  是在  $x^{(k)}$  处的牛顿方向

$$d^{(k)} = -\nabla^2 f(x^{(k)})^{-1} \nabla f(x^{(k)}) \quad (10.4.2)$$

$\lambda_k$  是从  $x^{(k)}$  出发沿牛顿方向搜索的最优步长.

为构造  $\nabla^2 f(x^{(k)})^{-1}$  的近似矩阵  $H_k$ , 先分析  $\nabla^2 f(x^{(k)})^{-1}$  与一阶导数的关系.



## ■ 拟牛顿条件和算法步骤

设在第 $k$ 次迭代后,得点 $x^{(k+1)}$ ,将 $f(x)$ 在点 $x^{(k+1)}$ Taylor展开

$$f(x) \approx f(x^{(k+1)}) + \nabla f(x^{(k+1)})^T (x - x^{(k+1)}) + \frac{1}{2} (x - x^{(k+1)})^T \nabla^2 f(x^{(k+1)}) (x - x^{(k+1)})$$

于是在 $x^{(k+1)}$ 附近

$$g(x) = \nabla f(x) \approx \nabla f(x^{(k+1)}) + \nabla^2 f(x^{(k+1)}) (x - x^{(k+1)}) \quad (10.4.3)$$

令 $x = x^{(k)}$ ,则

$$\nabla f(x^{(k)}) \approx \nabla f(x^{(k+1)}) + \nabla^2 f(x^{(k+1)}) (x^{(k)} - x^{(k+1)})$$



## ■ 拟牛顿条件和算法步骤

记  $p^{(k)} = x^{(k+1)} - x^{(k)}$  (10.4.4)

$$q^{(k)} = \nabla f(x^{(k+1)}) - \nabla f(x^{(k)}) \quad (10.4.5)$$

则

$$q^{(k)} \approx \nabla^2 f(x^{(k+1)}) p^{(k)} \quad (10.4.6)$$

设Hessian矩阵 $\nabla^2 f(x^{(k+1)})$ 可逆, 则

$$p^{(k)} \approx \nabla^2 f(x^{(k+1)})^{-1} q^{(k)} \quad (10.4.7)$$

于是, 计算出 $p^{(k)}$ 和 $q^{(k)}$ , 可根据(10.4.7)估计在 $x^{(k+1)}$ 处的Hessian矩阵的逆. 令 $H_{k+1}$ 取代牛顿法中的Hessian阵的逆 $\nabla^2 f(x^{(k+1)})^{-1}$ , 则 $H_{k+1}$ 满足



## ■ 拟牛顿条件和算法步骤

$$p^{(k)} = H_{k+1} q^{(k)} \quad (10.4.8)$$

(10.4.8)称为拟牛顿条件(方程), 也称为割线方程.  
怎样确定满足这个条件的  $H_{k+1}$ ?



## ■ 对称秩1校正

当  $\nabla^2 f(x^{(k)})^{-1}$  是  $n$  阶对称正定矩阵时, 满足拟牛顿条件的矩阵  $H_{k+1}$  也应是  $n$  阶对称矩阵. 于是, 构造如此的近似矩阵的一般策略是:

$H_1$  取为任意一  $n$  阶对称正定矩阵(如单位阵  $I$ ),

然后通过修正  $H_k$  给出  $H_{k+1}$ .



## ■ 对称秩1校正

$$H_{k+1} = H_k + \Delta H_k \quad (10.4.9)$$

$\Delta H_k$ 称为校正矩阵. 确定 $\Delta H_k$ 的一个方法是令

$$\Delta H_k = \alpha_k Z^{(k)} Z^{(k)T} \quad (10.4.10)$$

$\alpha_k$ 是一常数,  $Z^{(k)}$ 是 $n$ 维列向量.

$Z^{(k)}$ 的选择应使(10.4.8)得到满足, 令

$$p^{(k)} = H_k q^{(k)} + \alpha_k Z^{(k)} Z^{(k)T} q^{(k)} \quad (10.4.11)$$

从而

$$Z^{(k)} = \frac{p^{(k)} - H_k q^{(k)}}{\alpha_k Z^{(k)T} q^{(k)}} \quad (10.4.12)$$



## ■ 对称秩1校正

(10.4.11)等号两端左乘 $q^{(k)T}$ , 整理得

$$q^{(k)T}(p^{(k)} - H_k q^{(k)}) = \alpha_k (Z^{(k)T} q^{(k)})^2 \quad (10.4.13)$$

利用(10.4.10),(10.4.12-13),(10.4.9)可写成

$$H_{k+1} = H_k + \frac{(p^{(k)} - H_k q^{(k)})(p^{(k)} - H_k q^{(k)})^T}{q^{(k)T}(p^{(k)} - H_k q^{(k)})} \quad (10.4.14)$$

---秩1校正公式

利用秩1校正极小化函数 $f(x)$ , 在第 $k$ 次迭代中, 令  
搜索方向

$$d^{(k)} = -H_k \nabla f(x^{(k)}) \quad (10.4.15)$$

## ■ 对称秩1校正

然后沿  $d^{(k)}$  方向搜索, 求步长  $\lambda_k$ , 满足

$$f(x^{(k)} + \lambda_k d^{(k)}) = \min_{\lambda \geq 0} f(x^{(k)} + \lambda d^{(k)})$$

确定后继点

$$x^{(k+1)} = x^{(k)} + \lambda_k d^{(k)} \quad (10.4.16)$$



## ■ 对称秩2校正

### • 1, DFP算法(变尺度法)

定义校正矩阵

$$\Delta H_k = \frac{p^{(k)} p^{(k)T}}{p^{(k)T} q^{(k)}} - \frac{H_k q^{(k)} q^{(k)T} H_k}{q^{(k)T} H_k q^{(k)}} \quad (10.4.17)$$

则

$$H_{k+1} = H_k + \frac{p^{(k)} p^{(k)T}}{p^{(k)T} q^{(k)}} - \frac{H_k q^{(k)} q^{(k)T} H_k}{q^{(k)T} H_k q^{(k)}} \quad (10.4.18)$$

DFP (Davidon-Fletcher-Powell)公式



## ■ 对称秩2校正

- DFP算法

Step1, 给定初始点  $x^{(k)} \in E^n$ , 允许误差  $\varepsilon > 0$ ,

Step2, 置  $H_1 = I_n$ , 计算出在  $x^{(1)}$  处的梯度

$$g_1 = \nabla f(x^{(1)})$$

置  $k = 1$

Step3, 令  $d^{(k)} = -H_k g_k$

Step4, 从  $x^{(k)}$  出发, 沿  $d^{(k)}$  进行一维搜索, 求  $\lambda_k$ , 使

$$f(x^{(k)} + \lambda_k d^{(k)}) = \min_{\lambda \geq 0} f(x^{(k)} + \lambda d^{(k)})$$

令  $x^{(k+1)} = x^{(k)} + \lambda_k d^{(k)}$ ,

## ■ 对称秩2校正

Step5, 检验是否满足收敛准则, 若

$$\|\nabla f(x^{(k+1)})\| \leq \varepsilon,$$

停止, 得  $\bar{x} = x^{(k+1)}$ , 否则, 转 Step6

Step6, 若  $k = n$ , 则令  $x^{(1)} = x^{(k+1)}$ , 转 Step2; 否则, 转 Step7

Step7, 令  $g_{k+1} = \nabla f(x^{(k+1)})$ ,  $p^{(k)} = x^{(k+1)} - x^{(k)}$ ,  $q^{(k)} = g_{k+1} - g_k$

由公式(10.4.18)计算  $H_{k+1}$ , 置  $k \doteq k + 1$ , 转 Step3

## ■ 对称秩2校正

例1 用DFP方法求解下列问题

$$\min 2x_1^2 + x_2^2 - 4x_1 + 2$$

初始点及初始矩阵分别为

$$x^{(1)} = \begin{pmatrix} 2 \\ 1 \end{pmatrix}, H_1 = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

在点  $x = (x_1, x_2)^T$  的梯度

$$g = \begin{pmatrix} 4(x_1 - 1) \\ 2x_2 \end{pmatrix}$$

## ■ 对称秩2校正

第1次迭代

在点 $x^{(1)}$ 处的梯度  $g_1 = \begin{pmatrix} 4 \\ 2 \end{pmatrix}$

令搜索方向

$$d^{(1)} = -H_1 g_1 = \begin{pmatrix} -4 \\ -2 \end{pmatrix}$$

从 $x^{(1)}$ 出发, 沿方向 $d^{(1)}$ 进行一维搜索, 求步长 $\lambda_1$ :

$$\min_{\lambda \geq 0} f(x^{(1)} + \lambda d^{(1)})$$

得到

$$\lambda_1 = \frac{5}{18}$$



## ■ 对称秩2校正

令

$$x^{(2)} = x^{(1)} + \lambda_1 d^{(1)} = \begin{bmatrix} 2 \\ 1 \end{bmatrix} + \frac{5}{18} \begin{bmatrix} -4 \\ -2 \end{bmatrix} = \begin{bmatrix} 8/9 \\ 4/9 \end{bmatrix}$$

$$g_2 = \begin{bmatrix} 4\left(\frac{8}{9} - 1\right) \\ 2\frac{4}{9} \end{bmatrix} = \begin{bmatrix} -4/9 \\ 8/9 \end{bmatrix}$$

## ■ 对称秩2校正

第2次迭代

$$p^{(1)} = \lambda_1 d^{(1)} = \begin{pmatrix} -10/9 \\ -5/9 \end{pmatrix}$$

$$q^{(1)} = g_2 - g_1 = \begin{pmatrix} -40/9 \\ -10/9 \end{pmatrix}$$

计算  $H_2$

$$H_2 = H_1 + \frac{p^{(1)} p^{(1)T}}{p^{(1)T} q^{(1)}} - \frac{H_1 q^{(1)} q^{(1)T} H_1}{q^{(1)T} H_1 q^{(1)}}$$



## ■ 对称秩2校正

$$= \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + \frac{\begin{pmatrix} -10/9 \\ -5/9 \end{pmatrix} \begin{pmatrix} -10/9 & -5/9 \end{pmatrix}}{\begin{pmatrix} -10/9 & -5/9 \end{pmatrix} \begin{pmatrix} -40/9 \\ -10/9 \end{pmatrix}}$$
$$+ \frac{\begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} -40/9 \\ -10/9 \end{pmatrix} \begin{pmatrix} -40/9 & -10/9 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}}{\begin{pmatrix} -40/9 & -10/9 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} -40/9 \\ -10/9 \end{pmatrix}}$$



## ■ 对称秩2校正

$$\begin{aligned}&= \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + \frac{1}{18} \begin{pmatrix} 4 & 2 \\ 2 & 1 \end{pmatrix} - \frac{1}{17} \begin{pmatrix} 16 & 4 \\ 4 & 1 \end{pmatrix} \\&= \frac{1}{306} \begin{pmatrix} 86 & -38 \\ -38 & 305 \end{pmatrix}\end{aligned}$$

令

$$\begin{aligned}d^{(2)} &= -H_2 g_2 = -\frac{1}{306} \begin{pmatrix} 86 & -38 \\ -38 & 305 \end{pmatrix} \begin{pmatrix} -4/9 \\ 8/9 \end{pmatrix} \\&= \frac{12}{51} \begin{pmatrix} 1 \\ -4 \end{pmatrix}\end{aligned}$$



## ■ 对称秩2校正

从 $x^{(2)}$ 出发, 沿方向 $d^{(2)}$ 进行一维搜索, 求步长 $\lambda_2$ :

$$\min_{\lambda \geq 0} f(x^{(2)} + \lambda d^{(2)})$$

得到

$$\lambda_2 = \frac{17}{36}$$

令

$$x^{(3)} = x^{(2)} + \lambda_2 d^{(2)} = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$$



## ■ 对称秩2校正

$$g_3 = \nabla f(x^{(3)}) = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

于是得最优解

$$(x_1, x_2) = (1, 0)$$



## ■ DFP算法的正定性及二次终止性

**定理10.4.1**若 $g_i \neq 0, i = 1, 2, \dots, n$ ,则DFP方法构造的矩阵 $H_i (i = 1, 2, \dots, n)$ 为对称正定矩阵.

**定理10.4.2**设用DFP方法求解下列问题

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

其中A为n阶对称正定矩阵.取初点 $x^{(1)} \in E^n$ ,令 $H_1$ 为n阶对称正定矩阵,则成立:

$$1, \quad p^{(i)T} A p^{(j)} = 0, \quad 1 \leq i < j \leq k \quad (10.4.25)$$

$$2, \quad H_{k+1} A p^{(i)} = p^{(i)}, \quad 1 \leq i \leq k \quad (10.4.26)$$

其中 $p^{(i)} = x^{(i+1)} - x^{(i)} = \lambda_i d^{(i)}$ ,  $\lambda_i \neq 0, k \leq n$ .



- 推论:在Th10.4.2的条件下,必有

$$H_{n+1} = A^{-1}$$

- DFP方法中构造出来的搜索方向是一组A共轭方向
- DFP方法具有二次终止性.
- 若 $f$ 是 $E^n$ 上的二次连续可微实函数,对任意的 $\hat{x} \in E^n$ 存在常数 $m > 0$ ,使得当  $x \in C(\hat{x}) = \{x \mid f(x) \leq f(\hat{x})\}$ ,  
 $y \in E^n$ 时有  $m\|y\|^2 \leq y^T \nabla^2 f(x) y$   
则DFP方法产生的序列 $\{x^{(k)}\}$ 或终止于或收敛于 $f$ 在 $E^n$ 上的唯一极小点.

## ■ BFGS公式及 Broyden簇

若用不含二阶导数的矩阵  $B_{k+1}$  近似 Hessian 矩阵  $\nabla^2 f(x^{(k+1)})$ , 则由(10.4.6)给出另一种形式的拟牛顿条件, 即

$$q^{(k)} = B_{k+1} p^{(k)} \quad (10.4.32)$$

可得修正公式

$$B_{k+1} = B_k + \frac{q^{(k)} q^{(k)T}}{q^{(k)T} p^{(k)}} - \frac{B_k p^{(k)} p^{(k)T} B_k}{p^{(k)T} B_k p^{(k)}} \quad (10.4.33)$$

---关于矩阵B的BFGS修正公式



## ■ BFGS公式及 Broyden簇

设 $B_{k+1}$ 可逆,则由(10.4.32)可知

$$p^{(k)} = B_{k+1}^{-1} q^{(k)}$$

于是 $B_{k+1}^{-1}$ 满足拟牛顿条件(10.4.8),故可令

$$H_{k+1} = B_{k+1}^{-1} \quad (10.4.34)$$

于是,利用Sherman - Morrison公式

可得关于H的BFGS公式:

$$H_{k+1}^{BFGS} = H_k + \left(1 + \frac{q^{(k)T} H_k q^{(k)}}{p^{(k)T} q^{(k)}}\right) \frac{p^{(k)} p^{(k)T}}{p^{(k)T} q^{(k)}} - \frac{p^{(k)} q^{(k)T} H_k + H_k q^{(k)} p^{(k)T}}{p^{(k)T} q^{(k)}} \quad (10.4.35)$$



## ■ BFGS公式及 Broyden簇

上述公式由Broyden,Fletcher,Goldfarb,Shanno(1970)给出.

DFP和BFGS公式都有由 $p^{(k)}$ 和 $H_k q^{(k)}$ 构成的对称秩2校正,故此两公式的加权组合仍具有相同的形式  
定义

$$H_{k+1}^\phi = (1 - \phi) H_{k+1}^{\text{DFP}} + \phi H_{k+1}^{\text{BFGS}} \quad (10.4.36)$$

---Broyden簇



## ■ BFGS公式及 Broyden簇

显示表达式

$$\begin{aligned} H_{k+1}^\phi &= H_k + \frac{p^{(k)} p^{(k)T}}{p^{(k)T} q^{(k)}} - \frac{H_k q^{(k)} q^{(k)T} H_k}{q^{(k)T} H_k q^{(k)}} + \phi v^{(k)} v^{(k)T} \\ &= H_{k+1}^{DFP} + \phi v^{(k)} v^{(k)T} \end{aligned} \quad (10.4.37)$$

其中

$$v^{(k)} = \left( q^{(k)T} H_k q^{(k)} \right)^{1/2} \left( \frac{p^{(k)}}{p^{(k)T} q^{(k)}} - \frac{H_k q^{(k)}}{q^{(k)T} H_k q^{(k)}} \right) \quad (10.4.38)$$



## ■ BFGS公式及 Broyden簇

定理10.4.3 设

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

其中 $A$ 为 $n$ 阶对称正定矩阵. 则对于Broyden方法, 成立:

$$1, \quad p^{(i)T} A p^{(j)} = 0, \quad 1 \leq i < j \leq k$$

$$2, \quad H_{k+1} A p^{(i)} = p^{(i)}, \quad 1 \leq i \leq k$$

## ■ 拟牛顿条件和算法步骤

### 算法 拟牛顿法

1(初始化), 给定初始点  $x^0 \in R^n$ , 正定矩阵  $H_0 \in R^{n \times n}$ ,  $\varepsilon \in (0,1)$ ;

计算  $g^0 = \nabla f(x^0)$ , 置  $k = 0$ .

2(平稳性检验), 若  $\|g^k\| \leq \varepsilon$ , 则停止, 否则,

计算搜索方向  $d^k = -H_k g^k$ ,

3(线搜索), 沿射线  $R(x^k, d^k) = \{x \mid x = x^k + \lambda d^k, \lambda \geq 0\}$  进行线搜索,

求出步长  $\lambda_k$ , 令  $x^{k+1} = x^k + \lambda_k d^k$

4(修正拟牛顿方程), 计算  $g^{k+1} = \nabla f(x^{k+1})$ , 对  $H_k$  校正, 得

$H_{k+1}$  使满足拟牛顿条件, 令  $k \leftarrow k+1$ , 转2



## ■ 算法步骤

- 线搜索方法：每次迭代时产生一搜索方向，在此方向上进行精确或不精确一维搜索，得到下一迭代点。
- 缺点：可能由于步长过大导致算法失败，特别当问题病态时。



## ■ 算法步骤

- 信赖域方法：

在每次迭代时，强制性要求新迭代点与当前迭代点之间的距离不超过某一控制量。实际上是在以当前迭代点为中心的邻域内对一近似于原问题的简单模型求极值。

- 优点：算法稳定性好、收敛性强。



## ■ 算法步骤

- 问题：

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

- 基本思想：给定初始迭代点，确定一个以其为中心的邻域，在此域内优化目标函数的二次逼近式，得到下一迭代点。




## ■ 算法收敛性

- 在一定条件下，信赖域方法具有全局收敛性。
- 设  $f(x)$  是  $R^n$  上的实函数， $x_1$  是给定初始点， $S = \{x \mid f(x) \leq f(x_1)\}$  是有界闭集， $f(x), \nabla f(x)$  和  $\nabla^2 f(x)$  在  $S$  上连续，用信赖域方法求得序列  $\{x_k\}$ ，则

$$\lim_{k \rightarrow \infty} \|\nabla f(x_k)\| = 0$$

## ■ 一元线性回归/单变量线性回归



$$\begin{aligned}
 y_1 &\approx wx_1 + b \\
 y_2 &\approx wx_2 + b \\
 &\dots \\
 y_N &\approx wx_N + b
 \end{aligned}$$

➤ 回归误差:

$$e_n = y_n - (wx_n + b)$$

➤ 均方和误差:

$$\sum_{n=1}^N e_n^2 = \sum_{n=1}^N (y_n - wx_n - b)^2$$

- ✓ 欧式距离
- ✓ 能量...

➤ 最小二乘法

(Least Square Method)

$$(w^*, b^*) = \arg \min_{w, b} \sum_{n=1}^N (y_n - wx_n - b)^2$$

## ■ 多元线性回归 (Multivariate Linear Regression)

$$y_1 \approx x_1 w + b$$

$$y_1 \approx x_{1,1} w_1 + x_{1,2} w_2 + \dots + x_{1,D} w_D + b$$

$$y_2 \approx x_2 w + b$$



$$y_2 \approx x_{2,1} w_1 + x_{2,2} w_2 + \dots + x_{2,D} w_D + b$$


...

一元到多元

...

$$y_N \approx x_N w + b$$

$$y_N \approx x_{N,1} w_1 + x_{N,2} w_2 + \dots + x_{N,D} w_D + b$$



$$\mathbf{w}^* = \arg \min_{\mathbf{w}} \|\mathbf{y} - \mathbf{Xw}\|_2^2$$

多元最小二乘法

$$\mathbf{y} \approx \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} \approx \begin{bmatrix} x_{1,1} & x_{1,2} & \dots & x_{1,D} \\ x_{2,1} & x_{2,2} & \dots & x_{2,D} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N,1} & x_{N,2} & \dots & x_{N,D} \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_D \\ b \end{bmatrix}$$

一般形式



$$\mathbf{y} \approx \mathbf{X} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_D \\ b \end{bmatrix}$$



## ■ 问题求解/优化

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} \|\mathbf{y} - \mathbf{X}\mathbf{w}\|_2^2$$

➤ 闭合解/解析解 (Closed-form Solution/ Analytic Solution):

$$J(\mathbf{w}) = \|\mathbf{y} - \mathbf{X}\mathbf{w}\|_2^2 = (\mathbf{y} - \mathbf{X}\mathbf{w})^T (\mathbf{y} - \mathbf{X}\mathbf{w})$$

$$\frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} = 2\mathbf{X}^T (\mathbf{y} - \mathbf{X}\mathbf{w}) = 2\mathbf{X}^T \mathbf{X}\mathbf{w} - 2\mathbf{X}^T \mathbf{y} = \mathbf{0}$$

$$\mathbf{w}^* = \underline{(\mathbf{X}^T \mathbf{X})^{-1}} \mathbf{X}^T \mathbf{y} \quad \longrightarrow \quad \mathbf{w}^* = (\mathbf{X}^T \mathbf{X} + \lambda \mathbf{I})^{-1} \mathbf{X}^T \mathbf{y}$$

✓ 正则化  
✓ 岭回归

➤ 梯度下降法 (Gradient Descent):

$$\frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} = 2\mathbf{X}^T (\mathbf{y} - \mathbf{X}\mathbf{w}) \quad \Rightarrow \quad \mathbf{w} \leftarrow \mathbf{w} - \eta \frac{\partial J(\mathbf{w})}{\partial \mathbf{w}}$$

<https://www.bilibili.com/video/av41473299?from=search&seid=8346799062692305739>




## ■ 子空间 $X$ 上的正交投影

$$\mathbf{e} = \mathbf{y} - \mathbf{X}\mathbf{w} = \begin{bmatrix} y_1 \\ \vdots \\ y_N \end{bmatrix} - \left( \begin{bmatrix} x_{1,1} \\ \dots \\ x_{N,1} \end{bmatrix} w_1 + \begin{bmatrix} x_{1,2} \\ \dots \\ x_{N,2} \end{bmatrix} w_2 + \dots + \begin{bmatrix} x_{1,D} \\ \dots \\ x_{N,D} \end{bmatrix} w_D \right)$$

$$= \mathbf{y} - (\mathbf{x}_1 w_1 + \mathbf{x}_2 w_2 + \dots + \mathbf{x}_d w_D)$$

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} \|\mathbf{y} - \mathbf{X}\mathbf{w}\|_2^2$$






## ■ 子空间

$$\begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \rightarrow \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix}, \begin{bmatrix} 1 \\ 0 \\ 1 \end{bmatrix}$$

完备正交基


完备基




列秩 (rank)  
子空间  
正交补空间

$$\begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \rightarrow \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix} \rightarrow \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}$$

$$\mathbf{a}_1 x_1 + \mathbf{a}_2 x_2 + \mathbf{a}_3 x_3$$



MIT公开课《线性代数》：  
<https://www.bilibili.com/video/av24368594>





## ■ 高斯噪声假设

$$\mathbf{e} = \mathbf{y} - \mathbf{X}\mathbf{w} \quad \Rightarrow \quad \begin{bmatrix} e_1 \\ \vdots \\ e_N \end{bmatrix} = \begin{bmatrix} y_1 \\ \vdots \\ y_N \end{bmatrix} - \begin{bmatrix} x_{1,1}w_1 + x_{1,2}w_2 + \dots + x_{1,D}w_D \\ \vdots \\ x_{N,1}w_1 + x_{N,2}w_2 + \dots + x_{N,D}w_D \end{bmatrix}$$

### ➤ 零均值等方差高斯噪声假设

$$e_n \sim N(0, \sigma^2) \Rightarrow p(e_n) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{e_n^2}{2\sigma^2}\right)$$

### ➤ 最大似然估计



$$p(e_1, e_2, \dots, e_N) = \prod_{n=1}^N p(e_n) = \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^N \exp\left(-\sum_{n=1}^N e_n^2 / 2\sigma^2\right)$$

### ➤ 概率解释

$$\max_{\mathbf{w}} p(e_1, e_2, \dots, e_N; \mathbf{w}) \Leftrightarrow \min_{\mathbf{w}} \sum_{n=1}^N e_n^2 \Leftrightarrow \min_{\mathbf{w}} \|\mathbf{y} - \mathbf{X}\mathbf{w}\|_2^2$$



## ■ 对异常点(Outliers)鲁棒性差



- 随机取样一致 (Random Sample Consensus, RANSAC)
- 鲁棒回归 (Robust Regression)

## ■ 线性的含义

$$y = wx + b$$

线性?



$$y = w_1x + w_2x^2 + w_3x^3 + b$$

线性?



$$x_1 = x, x_2 = x^2, x_3 = x^3$$

线性?



$$y = w_1x_1 + w_2x_2 + w_3x_3 + b$$


- 线性并不指对输入变量的线性，而是指对参数空间的线性。也就是说对于输入来说，完全可以对先对其进行非线性变换，再进行线性组合。从这个角度来说，线性模型完全具有描述非线性的能力。
- 通用非线性化方法：核学习方法 (Kernel-based Learning Algorithms)

## ■ 广义线性模型 (Generalized Linear Model)

- 对数线性回归 (Log-Linear Regression):

$$y = \exp(wx + b) \quad \log y = wx + b$$

形式上仍是线性回归，实质上已经是求取输入空间到输出空间的非线性函数映射



摘自《机器学习》，清华大学出版社，周志华著，P56图3.1

- 广义线性模型 (Generalized Linear Model):

$$y = g^{-1}(\mathbf{w}^T \mathbf{x}) \quad y' = g(y) = \mathbf{w}^T \mathbf{x}$$

↑  
单调可微函数

## ■ 小结

- 使用导数基本概念
- 最速下降法
- 牛顿法
- 共轭梯度法
- 拟牛顿法
- 信赖域方法



## ■ 作业

- 习题 3、4、5、10、14、17、18、19