

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

■ 算法

算法描述

Step1, 给定初始点 $x^{(k)} \in E^n$, 允许误差 $\varepsilon > 0$, 置 $k = 1$

Step2, 计算搜索方向 $d^{(k)} = -\nabla f(x^{(k)})$


Step3, 若 $\|d^{(k)}\| \leq \varepsilon$, 停止, 否则, 从 $x^{(k)}$ 出发, 沿 $d^{(k)}$ 进行一维搜索,

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

Step4, 令 $x^{(k+1)} = x^{(k)} + \lambda_k d^{(k)}$, 置 $k := k + 1$, 转 Step2

■ 性质1

最速下降法存在锯齿现象





■ 性质2

容易证明,用最速下降法极小化目标函数时,
相邻两个搜索方向是正交的.

令

$$\varphi(\lambda) = f(x^{(k)} + \lambda d^{(k)})$$

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

则

$$\varphi'(\lambda) = \nabla f(x^{(k)} + \lambda_k d^{(k)})^T d^{(k)} = 0$$

$$\Rightarrow -\nabla f(x^{(k+1)})^T \nabla f(x^{(k)}) = 0$$

$\Rightarrow d^{(k+1)} = -\nabla f(x^{(k+1)})$ 与 $d^{(k)} = -\nabla f(x^{(k)})$ 正交



■ 概念

设 $\nabla^2 f(x^{(k)})$ 可逆, 则得牛顿法的迭代公式

$$x^{(k+1)} = x^{(k)} - \nabla^2 f(x^{(k)})^{-1} \nabla f(x^{(k)}) \quad (10.2.2)$$

算法 (Newton法)

Step1, 给定初始点 $x^{(0)}$, 允许误差 $\varepsilon > 0$, 置 $k = 1$;

Step2, 若 $\|\nabla f(x^{(k)})\| \leq \varepsilon$, 停止, 得解 $x^{(k)}$; 否则, 令

$x^{(k+1)} = x^{(k)} - \nabla^2 f(x^{(k)})^{-1} \nabla f(x^{(k)})$, $k := k + 1$, 转2

■ 局部收敛性

定理(局部收敛定理)设函数 $f \in C^2(R^n)$, 它在 x^* 的梯度 $\nabla f(x^*) = 0$, Hesse矩阵 $\nabla^2 f(x^*)$ 正定. 若初始点 x^0 充分靠近 x^* , 并且Hesse矩阵 $G(x) = \nabla^2 f(x)$ 满足Lipschitz条件, 即存在 $L > 0$, 使得 $\forall x, y \in R^n$, 有

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

则对 $\forall k$, 迭代格式(10.2.2)有意义, 且迭代点序列 $\{x^k\}$ 以二阶的收敛速度收敛到 x^* .

- 注意,当初始点远离极小点时,牛顿法可能不收敛

• 阻尼牛顿法

基本思想:增加了沿牛顿方向的一维搜索.

迭代公式为

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

其中 $d^{(k)} = -\nabla^2 f(x^{(k)})^{-1} \nabla f(x^{(k)})$ 为牛顿方向, λ_k 是由一维搜索所得的步长,即满足

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

• 算法(阻尼牛顿法)

Step1, 给定初始点 $x^{(0)}$, 允许误差 $\varepsilon > 0$, 置 $k = 1$;

Step2, 计算 $\nabla f(x^{(k)})$, $\nabla^2 f(x^{(k)})^{-1}$

Step3, 若 $\|\nabla f(x^{(k)})\| \leq \varepsilon$, 停止, 得解 $x^{(k)}$; 否则, 令

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

Step4, 从 $x^{(k)}$ 出发, 沿方向 $d^{(k)}$ 作一维搜索:

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

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

Step5, 置 $k := k + 1$, 转2

■ 存在问题

显然可能存在：

- 1) Hessian 矩阵 $\nabla^2 f(x^{(1)})$ 奇异-不可逆
- 2) 即使非奇异，Hessian 矩阵 $\nabla^2 f(x^{(1)})$ 也可能非正定

牛顿方向不一定是下降方向，算法失效！

■ 修正牛顿法

解决*Hessian*矩阵 $\nabla^2 f(x^{(k)})$ 非正定问题的基本思想

修正 $\nabla^2 f(x^{(k)})$, 构造一个对称正定矩阵 G_k , 在方程(d)

中用 G_k 取代矩阵 $\nabla^2 f(x^{(k)})$:

$$G_k d^{(k)} = -\nabla f(x^{(k)}) \quad (\text{f})$$

$$\Rightarrow d^{(k)} = -G_k^{-1} \nabla f(x^{(k)}) \quad (\text{g})$$

再沿此方向作一维搜索

如何构造 G_k ? 比如, 可令

$$G_k = \nabla^2 f(x^{(k)}) + \varepsilon_k I \quad (\text{h})$$

其中I是单位阵, ε_k 是一个适当的正数.

■ 修正牛顿法

定理(全局收敛定理) 设 $f : R^n \rightarrow R$ 在某开集D上二阶连续可微,且修正牛顿法的初始点 $x^0 \in D$ 使得f的水平集 $S_{f(x^0)} = \{x \in D \mid f(x) \leq f(x^0)\}$ 是紧集. 若矩阵序列满足有界分解特性,则 $\lim_{x \rightarrow \infty} \nabla f(x^k) = 0$.



■ 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

设有二次函数

$$f(x) = \frac{1}{2}(x - \bar{x})^T A(x - \bar{x}) \quad (10.3.3)$$

其中 A 是 $n \times n$ 对称正定矩阵, \bar{x} 是一个定点.

$f(x)$ 的等值面

$$\frac{1}{2}(x - \bar{x})^T A(x - \bar{x}) = c$$

是以 \bar{x} 为中心的椭球面,

由于

$$\nabla f(\bar{x}) = A(\bar{x} - \bar{x}) = 0$$

A 正定, 故 \bar{x} 是 $f(x)$ 的极小值点.



设 $x^{(1)}$ 是在某等值面上一点,此面在点 $x^{(1)}$ 处的法向量

$$\nabla f(x^{(1)}) = A(x^{(1)} - \bar{x})$$

又设 $d^{(1)}$ 是在该等值面在点 $x^{(1)}$ 处的一个切向量.


$$d^{(2)} = \bar{x} - x^{(1)}$$

显然, $d^{(1)}$ 与 $\nabla f(x^{(1)})$ 正交.即 $d^{(1)T} \nabla f(x^{(1)}) = 0$, 于是

$$d^{(1)T} A d^{(2)} = 0$$

即等值面上一点 $x^{(1)}$ 处的切向量与由这点指向极小点的向量关于 A 共轭.

■ 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

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

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.



证明：由于 $f(x)$ 严格凸，要证明 $x^{(k+1)}$ 是函数 $f(x)$ 在线性流形 $x^{(1)} + \Gamma_\kappa$ 上的唯一极小点，只要证在 $x^{(k+1)}$ 点， $\nabla f(x^{(k+1)})$ 与子空间 Γ_κ 正交。

用归纳法证之，为方便，用 g_j 表示函数 $f(x)$ 在 $x^{(j)}$ 处的梯度，即

证明 $g_{k+1} \perp \Gamma_k$ ，对 k 归纳

当 $k = 1$ ，由一维搜索的定义知 $g_2 \perp \Gamma_1$ 。

假设 $k = m < n$ 时 $g_{m+1} \perp \Gamma_m$ ，下证 $g_{m+2} \perp \Gamma_{m+1}$ 。

由二次函数梯度的表达式和点 $x^{(k+1)}$ 的定义, 有

$$\begin{aligned} g_{m+2} &= Ax^{(m+2)} = A(x^{(m+1)} + \lambda_{m+1}d^{(m+1)}) + b \\ &= g_{m+1} + \lambda_{m+1}Ad^{(m+1)} \end{aligned} \quad (10.3.7)$$

利用上式可以将 g_{m+2} 和 $d^{(i)}$ 的内积写成

$$d^{(i)}g_{m+2} = d^{(i)T}g_{m+1} + \lambda_{m+1}d^{(i)T}Ad^{(m+1)} \quad (10.3.8)$$

当 $i=m+1$ 时, 由一维搜索定义, 知

$$d^{(m+1)T}g_{m+2} = 0 \quad (10.3.9)$$

当 $1 \leq i < m+1$ 时, 由归纳假设知

$$d^{(i)T}g_{m+1} = 0 \quad (10.3.10)$$

由于 $d^{(1)}, d^{(2)}, \dots, d^{(m+1)}$ 关于A共轭, 则

$$d^{(i)T}Ad^{(m+1)} = 0 \quad (10.3.11)$$

由10.3.8-11, 知

$$d^{(i)T} g_{m+2} = 0$$

即

$$g_{m+2} \perp \Gamma_{m+1}.$$

根据上述证明, $x^{(k+1)}$ 是 $f(x)$ 在 $x^{(1)} + \Gamma_k$ 上的极小点由于 $f(x)$ 严格凸, 故必为此流形上的唯一极小点.

当 $k = n, d^{(1)}, d^{(2)}, \dots, d^{(n)}$ 是 E^n 的一组基, 此时必有 $g_{n+1} = 0$,
从而 $x^{(n+1)}$ 是函数在 E^n 上的唯一极小点.

推论: 在 Th10.3.2 的条件下, $g_{k+1}^T d^{(j)} = 0, \quad \forall j \leq k$



■ 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

先讨论对于二次凸函数的共轭梯度法, 考虑问题

$$\min f(x) = \frac{1}{2}x^T Ax + b^T x + c \quad (10.3.12)$$

$x \in E^n$, A 对称正定, c 是常数.

求解方法

首先, 任意给定一初始点 $x^{(1)}$, 计算出目标函数在该点的梯度, 若 $\|g_1\|=0$, 则停止计算, 否则, 令

$$d^{(1)} = -\nabla f(x^{(1)}) = -g_1 \quad (10.3.13)$$

沿 $d^{(1)}$ 搜索, 得点 $x^{(2)}$. 计算在 $x^{(2)}$ 处的梯度, 若 $\|g_2\|\neq 0$ 则利用 $-g_2$ 和 $d^{(1)}$ 构造搜索方向 $d^{(2)}$, 再沿 $d^{(2)}$ 搜索.



一般地,若已知点 $x^{(k)}$ 和搜索方向 $d^{(k)}$,则从 $x^{(k)}$ 出发,
沿 $d^{(1)}$ 进行搜索,得

$$x^{(k+1)} = x^{(k)} + \lambda_k d^{(k)} \quad (10.3.14)$$

其中步长 λ_k 满足

$$f(x^{(k)} + \lambda_k d^{(k)}) = \min f(x^{(k)} + \lambda d^{(k)})$$

下求 λ_k 的表达式

记 $\varphi(\lambda) = f(x^{(k)} + \lambda d^{(k)})$

令 $\varphi'(\lambda) = \nabla f(x^{(k+1)})^T d^{(k)} = 0 \quad (10.3.15)$

即 $(Ax^{(k+1)} + b)^T d^{(k)} = 0$

$$\begin{aligned} & \Rightarrow (A(x^{(k)} + \lambda_k d^{(k)}) + b)^T d^{(k)} = 0 \\ & \Rightarrow (g_k + \lambda_k A d^{(k)})^T d^{(k)} = 0 \quad (10.3.16) \end{aligned}$$

$$\Rightarrow \lambda_k = -\frac{g_k^T d^{(k)}}{d^{(k)T} A d^{(k)}} \quad (10.3.17)$$

计算 $f(x)$ 在 $x^{(k+1)}$ 处的梯度, 若 $\|g_{k+1}\|=0$, 则停止计算,
否则, 利用 $-g_{k+1}$ 和 $d^{(k)}$ 构造下一搜索方向 $d^{(k+1)}$, 并使
 $d^{(k+1)}$ 和 $d^{(k)}$ 关于A共轭, 按此设想. 令

$$d^{(k+1)} = -g_{k+1} + \beta_k d^{(k)} \quad (10.3.18)$$



上式两端左乘 $d^{(k)T} A$, 并令

$$\begin{aligned} d^{(k)T} A d^{(k+1)} &= -d^{(k)T} A g_{k+1} + \beta_k d^{(k)T} A d^{(k)} = 0 \\ \Rightarrow \beta_k &= \frac{d^{(k)T} A g_{k+1}}{d^{(k)T} A d^{(k)}} \end{aligned} \quad (10.3.19)$$

再从 $x^{(k+1)}$ 出发, 沿方向 $d^{(k+1)}$ 搜索.

综上分析, 在第一个搜索方向取负梯度的前提下, 重复使用公式3.14, 3.17-3.19就能伴随计算点的增加, 构造出一组搜索方向. (Fletcher-Reeves法)



定理10.3.3 对于正定二次函数(10.3.12),具有精确一维搜索的Fletcher-Reeves法在 $m \leq n$ 次一维搜索后即终止,并且对所有 $i(1 \leq i \leq m)$,下列关系成立:

$$1, d^{(i)T} A d^{(j)} = 0, \quad j = 1, 2, \dots, i - 1$$

$$2, g_i^T g_j = 0, \quad j = 1, 2, \dots, i - 1$$

$$3, g_i^T d^{(i)} = -g_i^T g_i \quad (\text{蕴涵 } d^{(i)} \neq 0)$$

证明: 显然 $m \geq 1$,下用归纳法(对*i*)证之.

当*i* = 1时,由于 $d^{(1)} = -g_1$,从而3)成立,对*i* = 2时,
关系1)和2)成立,从而3)也成立.



设对某个 $i < m$,这些关系均成立,我们证明对于 $i+1$ 也成立.先证2),

$$x^{(i+1)} = x^{(i)} + \lambda_i d^{(i)}$$

由迭代公式两端左乘 A ,再加上 b ,得

$$g_{i+1} = g_i + \lambda_i A d^{(i)} \quad (10.3.20)$$

其中 λ_i 由式(10.3.17)确定,即

$$\lambda_i = -\frac{g_i^T d^{(i)}}{d^{(i)T} A d^{(i)}} = \frac{g_i^T g_i}{d^{(i)T} A d^{(i)}} \neq 0 \quad (10.3.21)$$

考虑到(10.3.20)和(10.3.18),则

$$\begin{aligned} g_{i+1}^T g_j &= \left[g_i + \lambda_i A d^{(i)} \right]^T g_j \\ &= g_i^T g_j + \lambda_i d^{(i)T} A (-d^{(j)} + \beta_{j-1} d^{(j-1)}) \end{aligned} \quad (10.3.22)$$

(注:j=1时上式为 $g_{i+1}^T g_1 = g_i^T g_1 - \lambda_i d^{(i)T} A d^{(1)}$)

当 $j = i$ 时,由归纳假设 $d^{(i)T} A d^{(i-1)} = 0$,根据(10.3.21)

$$\begin{aligned} -\lambda_i d^{(i)T} A d^{(i)} &= -g_i^T g_i \\ \Rightarrow g_{i+1}^T g_i &= 0 \end{aligned}$$



当 $j < i$ 时,根据归纳假设,式(10.3.22)等号右端各项均为0

故
$$g_{i+1}^T g_j = 0$$

再证1),运用(10.3.18)和(10.3.20),则

$$d^{(i+1)T} A d^{(j)} = \left[-g_{i+1} + \beta_i d^{(i)} \right]^T A d^{(j)}$$

$$= -g_{i+1}^T \frac{g_{j+1} - g_j}{\lambda_j} + \beta_i d^{(i)T} A d^{(j)}$$

当 $j = i$ 时,把(10.3.19)代入上式第一个等号的右端,立得

当 $j < i$ 时,由前面已经证明的结论和归纳假设,式中第2个等号右端显然为0,因此

$$d^{(i+1)T} A d^{(j)} = 0$$

最后证3), 易知

$$g_{i+1}^T d^{(i+1)} = g_{i+1}^T \left[-g_{i+1} + \beta_i d^{(i)} \right] = -g_{i+1}^T g_{i+1}$$

综上,对 $i+1$,上述三种关系成立

由上可知, *Fletcher – Reeves* 共轭梯度法所产生的搜索方向 $d^{(1)}, d^{(2)}, \dots, d^{(m)}$ 是 A 共轭的, 根据 Th10.3.2, 经有限步迭代必达极小点.



- 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

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

取初始点和初始搜索方向分别为

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



显然, $d^{(1)}$ 不是目标函数在 $x^{(1)}$ 处的最速下降方向.

下面, 我们用FR法构造两个搜索方向.

从 $x^{(1)}$ 出发, 沿方向 $d^{(1)}$ 进行搜索, 求步长 λ_1 , 使满足:

$$f(x^{(1)} + \lambda_1 d^{(1)}) = \min_{\lambda \geq 0} f(x^{(1)} + \lambda d^{(1)})$$

得 $\lambda_1 = 2/3$

$$\Rightarrow x^{(2)} = x^{(1)} + \lambda_1 d^{(1)} = \begin{pmatrix} 1/3 \\ -1/3 \\ 1 \end{pmatrix}, g_2 = \begin{pmatrix} 2/3 \\ -1/3 \\ 1 \end{pmatrix}$$

$$d^{(2)} = -g_2 + \beta_1 d^{(1)}$$

根据公式(10.3.19),有

$$\beta_1 = \frac{d^{(1)T} A g_2}{d^{(1)T} A d^{(1)}} = \frac{-2/3}{6} = -\frac{1}{9}$$

因此

$$d^{(2)} = -\begin{pmatrix} 2/3 \\ -1/3 \\ 1 \end{pmatrix} - \frac{1}{9} \begin{pmatrix} -1 \\ -2 \\ 0 \end{pmatrix} = \begin{pmatrix} -5/9 \\ 5/9 \\ -1 \end{pmatrix}$$

从 $x^{(2)}$ 出发,沿方向 $d^{(2)}$ 进行搜索,求步长 λ_2 ,使满足:

$$f(x^{(1)} + \lambda_2 d^{(1)}) = \min_{\lambda \geq 0} f(x^{(2)} + \lambda d^{(2)})$$

得 $\lambda_2 = 21/26$

$$\Rightarrow x^{(3)} = x^{(2)} + \lambda_2 d^{(2)} = \begin{pmatrix} -9/78 \\ 9/78 \\ 5/26 \end{pmatrix}, g_3 = \begin{pmatrix} -18/78 \\ 9/78 \\ 5/26 \end{pmatrix}$$

令

$$d^{(3)} = -g_3 + \beta_2 d^{(2)}$$

根据公式(10.3.19),有

$$\beta_2 = \frac{d^{(2)T} A g_3}{d^{(2)T} A d^{(2)}} = \frac{45}{676}$$



因此

$$d^{(3)} = - \begin{pmatrix} -18/78 \\ 9/78 \\ 5/26 \end{pmatrix} + \frac{45}{676} \begin{pmatrix} -5/9 \\ 5/9 \\ -1 \end{pmatrix} = \frac{1}{676} \begin{pmatrix} 131 \\ -53 \\ -175 \end{pmatrix}$$

可以验证, $d^{(1)}$ 与 $d^{(2)}$ 关于 A 共轭, $d^{(3)}$ 与 $d^{(2)}$ 关于 A 共轭, 但 $d^{(1)}$ 与 $d^{(3)}$ 不关于 A 共轭, 于是 $d^{(1)}, d^{(2)}, d^{(3)}$ 不关于 A 共轭.

- 注意, 在 FR 法中, 初始搜索方向必须取最速下降方向



- 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 β_i

定理10.3.4 对于正定二次函数,FR法中因子 β_i 具有下述表达式

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

证明:

$$\beta_i = \frac{d^{(i)T} A g_{i+1}}{d^{(i)T} A d^{(i)}} = \frac{g_{i+1}^T A (x^{(i+1)} - x^{(i)}) / \lambda_i}{d^{(i)T} A (x^{(i+1)} - x^{(i)}) / \lambda_i}$$



$$= \frac{g_{i+1}^T (g_{i+1} - g_i)}{d^{(i)T} (g_{i+1} - g_i)} = \frac{\|g_{i+1}\|^2}{-d^{(i)T} g_i} \quad (10.3.23)$$

根据定理10.3.3, $d^{(i)T} g_i = -\|g_i\|^2$. 因此

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



- 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 β_{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 λ_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



例3.2 用FR法求解下列问题

$$\min \quad f(x) = x_1^2 + 2x_2^2 \quad \text{初点} x^{(1)} = (5, 5)^T$$

目标函数 $f(x)$ 在点 x 处的梯度

$$\nabla f(x) = \begin{bmatrix} 2x_1 \\ 4x_2 \end{bmatrix}$$

第一次迭代，

令

$$d^{(1)} = -g_1 = \begin{bmatrix} -10 \\ -20 \end{bmatrix}$$

从 $x^{(1)}$ 出发, 沿方向 $d^{(1)}$ 进行一维搜索, 求步长 λ_1 :



$$\lambda_1 = -\frac{g_1^T d^{(1)}}{d^{(1)T} A d^{(1)}} = \frac{(-10, -20) \begin{pmatrix} -10 \\ -20 \end{pmatrix}}{(-10, -20) \begin{pmatrix} 2 & 0 \\ 0 & 4 \end{pmatrix} \begin{pmatrix} -10 \\ -20 \end{pmatrix}} = \frac{5}{18}$$

$$x^{(2)} = x^{(1)} + \lambda_1 d^{(1)} = \begin{bmatrix} 5 \\ 5 \end{bmatrix} + \frac{5}{18} \begin{pmatrix} -10 \\ -20 \end{pmatrix} = \begin{pmatrix} 20/9 \\ -5/9 \end{pmatrix}$$

第2次迭代

目标函数在点 $x^{(2)}$ 处的梯度 $g_2 = \begin{pmatrix} 40/9 \\ -20/9 \end{pmatrix}$



构造搜索方向 $d^{(2)}$. 先计算因子 β_1

$$\beta_1 = \frac{\|g_2\|^2}{\|g_1\|^2} = \frac{(40/9)^2 + (-20/9)^2}{10^2 + 20^2} = \frac{4}{81}$$

令

$$d^{(2)} = -g_2 + \beta_1 d^{(1)} = \frac{100}{81} \begin{bmatrix} -4 \\ 1 \end{bmatrix}$$

从 $x^{(2)}$ 出发, 沿方向 $d^{(2)}$ 作一维搜索, 求 λ_2 :

$$\lambda_2 = -\frac{g_2^T d^{(2)}}{d^{(2)T} A d^{(2)}} = \frac{-\frac{20}{9} \cdot \frac{100}{81} (2, -1) \begin{pmatrix} -4 \\ 1 \end{pmatrix}}{\left(\frac{100}{81}\right)^2 (-4, 1) \begin{pmatrix} 2 & 0 \\ 0 & 4 \end{pmatrix} \begin{pmatrix} -4 \\ 1 \end{pmatrix}} = \frac{9}{20}$$

$$x^{(3)} = x^{(2)} + \lambda_2 d^{(2)} = \begin{bmatrix} 20/9 \\ -5/9 \end{bmatrix} + \frac{9}{20} \cdot \frac{100}{81} \begin{pmatrix} -4 \\ 1 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

显然点 $x^{(2)}$ 处目标函数的梯度 $g_2 = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$, 已达极小点 $\begin{pmatrix} 0 \\ 0 \end{pmatrix}$.

■ 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 α_k 由一维搜索得到,
 β_k 的计算公式通常有如下几种:

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



- 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 λ_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 α_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 λ_k 满足

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

■ 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