



第十章 最优化
方法

计算方法

¹ 数学科学学院 中国科学技术大学



§10.4.1 数学模型

第十章 最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索


§10.6 无约束非线性优化

非线性优化问题

如果最优化问题中的目标函数或约束条件中有关于决策变量的非线性函数, 则称它是非线性优化问题或非线性规划问题.


例 如图所示，如何截取 x 使铁皮所围成的容积最大？

$$v = (a - 2x)^2 \cdot x$$



例 10.5


在半径为 R 的圆内有一内接三角形 $\triangle ABC$, 其顶点 A, B, C 可以在圆上移动, 求 $\triangle ABC$ 面积的最大值.





例 10.6

现有一块椭球形的石材，其半轴分别为 $a, b, c > 0$. 若要从中加工出一块长方体的石砖，要求长方体各边平行于椭球的半轴且浪费最少，问该如何设计切割方案？



第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化



§10.4.1 数学模型

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

不失一般性, **非线性优化问题**可写成:

$$\begin{aligned} \min & f(\mathbf{x}), \quad \mathbf{x} \in \mathbb{R}^n \\ \text{s. t.} & \begin{cases} c_i(\mathbf{x}) \geq 0, & i \in \mathcal{I} \\ c_i(\mathbf{x}) = 0, & i \in \mathcal{E}. \end{cases} \end{aligned}$$

其中 $f(\mathbf{x}), c_i(\mathbf{x})$ 是有 n 个自变量的连续实函数, $\mathcal{E}, \mathcal{I}$ 分别是等式约束和不等式约束的有限指标集.



§10.4.1 数学模型

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

如果非线性优化问题中的目标函数和约束条件中的函数均为凸函数, 则称它为**凸优化**问题.

如果目标函数的**自变量为离散变量**, 譬如整数或有限集合中的元素, 则称它为**离散优化**. **整数规划**问题、旅行商问题、图着色问题、最小生成树等都是离散优化问题.



§10.4.2 函数极值

定义 10.9

设函数 $f: D \rightarrow \mathbb{R}$, 其中区域 $D \subset \mathbb{R}^n$. 如果对于 D 的内点 $\mathbf{x}^*$, 存在领域 $U(\mathbf{x}^*) \subset D$, 当 $\mathbf{x} \in U(\mathbf{x}^*)$ 时, 有 $f(\mathbf{x}) \geq f(\mathbf{x}^*)$ ($f(\mathbf{x}) \leq f(\mathbf{x}^*)$), 则称函数 f 在 D 的内点 $\mathbf{x}^*$ 取**局部极小值** (**局部极大值**), 简称**极小值** (**极大值**). 如果对 $\mathbf{x} \in U(\mathbf{x}^*) \setminus \{\mathbf{x}^*\}$ 有严格不等式 $f(\mathbf{x}) > f(\mathbf{x}^*)$ ($f(\mathbf{x}) < f(\mathbf{x}^*)$), 则称函数 f 在 $\mathbf{x}^*$ 取**严格局部极小值** (**严格局部极大值**).

定义 10.10

函数的局部极大值与局部极小值统称为函数的**局部极值**, 简称**极值**, **函数取极值的点**称为**极值点**.



§10.4.2 函数极值

定理 10.4

设函数 $f: D \rightarrow \mathbb{R}$ 在内点 $\mathbf{x}^*$ 取极值且 $Jf(\mathbf{x}^*)$ 存在, 则 $Jf(\mathbf{x}^*) = \mathbf{0}$, 即

$$\frac{\partial f}{\partial x_i}(\mathbf{x}^*) = 0, \quad i = 1, 2, \dots, n.$$

定义 10.11

设函数 $f: D \rightarrow \mathbb{R}$, 在 D 中使得 $Jf(\mathbf{x}) = \mathbf{0}$ 的一切内点称为函数 f 的驻点.



§10.4.2 函数极值

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

显然, **极值点一定是驻点**, 但一般来说**驻点未必是极值点**. 若记

$$Jf(\mathbf{x}) = \left(\frac{\partial f(\mathbf{x})}{\partial x_1}, \dots, \frac{\partial f(\mathbf{x})}{\partial x_n} \right), Hf(\mathbf{x}) = \begin{pmatrix} \frac{\partial^2 f(\mathbf{x})}{\partial x_1^2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_1} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_n^2} \end{pmatrix},$$

分别称 $Jf(\mathbf{x})$ 和 $Hf(\mathbf{x})$ 为函数 f 的 **Jacobian 矩阵** 和 **Hessian 矩阵**.




§10.4.2 函数极值

定理 10.5

设函数 $f(\mathbf{x})$ 在 D 上具有连续的二阶偏导数, 即 $f(\mathbf{x}) \in C^2(D)$.

- (1) (必要性) 若 $f(\mathbf{x})$ 在 $\mathbf{x}^*$ 取局部极小(大)值, 则 $J(\mathbf{x}^*) = \mathbf{0}$ 且 $Hf(\mathbf{x}^*)$ 半正(负)定;
- (2) (充分性) 若 $Jf(\mathbf{x}^*) = \mathbf{0}$ 且 $Hf(\mathbf{x}^*)$ 正(负)定, 则 $f(\mathbf{x})$ 在 $\mathbf{x}^*$ 取得严格局部极小(大)值.

判别函数内部局部极值点的二阶必要条件和充分条件.






§10.4.2 函数极值

定义 10.12

设 $\mathbf{x}^* \in D$, 若对所有 $\mathbf{x} \in D$, 都有 $f(\mathbf{x}) \geq f(\mathbf{x}^*)$ ($f(\mathbf{x}) \leq f(\mathbf{x}^*)$), 则称 $\mathbf{x}^*$ 为 $f(\mathbf{x})$ 在 D 上的全局极小值点 (全局极大值点). 若对所有 $\mathbf{x} \in D \setminus \mathbf{x}^*$, 都有 $f(\mathbf{x}) > f(\mathbf{x}^*)$ ($f(\mathbf{x}) < f(\mathbf{x}^*)$), 则称 $\mathbf{x}^*$ 为 $f(\mathbf{x})$ 在 D 上的全局严格极小值点 (全局严格极大值点)


全局极值点可能在定义域的边界点上取到. 然而, 对于这些边界上的极值点, 并没有实用的判别条件. 因此, 寻找全局极值点是一个相当困难的任务.

幸好, 在许多实际问题中, 局部极值点就己能满足应用的需求, 故非线性优化主要研究寻找局部或极值点.



通过塑造景观 存储记忆

约翰·霍普菲尔德(John Hopfield)发展的联想记忆方法是以一种类似于塑造风景的方式存储信息。当神经网络被训练时，它会为每个保存的图案在虚拟能量景观中创建一个山谷(能谷)。



© Johan Jarnestad/The Royal Swedish Academy of Sciences

2 球只有在滚动到一个被山丘环绕的地方时才会停下。同样的，神经网络也在寻找更低的能量，并找到距离初始位置最近的低能模式。

输入图案



输出图案





§10.4.2 函数极值

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

凸优化问题的极值

对于定义在**凸集上的凸函数** $f(\mathbf{x})$, 可以证明: $f(\mathbf{x})$ 的**局部极值点就是全局极值点**, 且所有极值点构成一个凸集. 进一步, 若 $f(\mathbf{x})$ 是**严格凸函数**, 则 $f(\mathbf{x})$ 的**全局极值点是唯一的**.



§10.4.3 迭代法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

求解非线性优化问题的一个自然的想法是: 1) 令 $\nabla f(\mathbf{x}) = \mathbf{0}$, 求出 $f(\mathbf{x})$ 的所有驻点; 2) 对每一驻点, 利用局部极值的充分条件进行判别, 找出所要的解.

对某些较简单的函数, 这样做是可行的, 但是, 对于一般的 n 元函数, 由条件 $\nabla f(\mathbf{x}) = \mathbf{0}$ 得到的方程通常是一个非线性方程组, 求解非常困难. 当函数 $f(\mathbf{x})$ 不可微分时, 就更不能用上述方法了.

因此, 求解非线性优化问题常使用迭代法.



§10.4.3 迭代法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

迭代法的基本思路是：为求函数 $f(\mathbf{x})$ 的最优解，首先给定一个**初始估计** $\mathbf{x}_0$ ，然后**按某种规则**找出比 $\mathbf{x}_0$ 更好的一个解 $\mathbf{x}_1$ ，即 $f(\mathbf{x}_1) < f(\mathbf{x}_0)$ ，重复上述过程，得到一个解序列 $\{\mathbf{x}_k\}_{k=0}^{\infty}$ 。若这个解序列有极限 $\mathbf{x}^*$ ，即

$$\lim_{k \rightarrow \infty} \|\mathbf{x}_k - \mathbf{x}^*\| = 0,$$

则称它收敛于 $\mathbf{x}^*$ 。

迭代法的关键是：**设计有效的规则**，使得所产生的解序列 $\{\mathbf{x}_k\}_{k=0}^{\infty}$ 收敛于该问题的最优解之一。



§10.4.3 迭代法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题


§10.5 一维搜索

§10.6 无约束非线性优化

若由某种算法所产生的解序列 $\{\mathbf{x}_k\}_{k=0}^{\infty}$ 使目标函数 $f(\mathbf{x}_k)$ 逐步减少, 则称它为 **下降算法**. 现假定已迭代到点 $\mathbf{x}_k$, 若从该点出发沿任何方向移动都不能使目标函数 $f(\mathbf{x})$ 值下降, 则 $\mathbf{x}_k$ 是一个 **局部极小点**, 迭代停止; 否则, 从该点出发至少存在一个方向使目标函数值有所下降, 则可选择使目标函数值下降的某一方向 $\mathbf{p}_k$ 作为搜索方向, 选择一个合适的步长 λ_k , 得到一个新的迭代点

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \lambda_k \mathbf{p}_k,$$

其中称 $\mathbf{p}_k$ 为 **搜索方向**, λ_k 为 **步长** 或 **步长因子**.





§10.4.3 迭代法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

下降迭代算法的计算步骤如下:

1. 选定某一初始点 $\mathbf{x}_0$, 并令 $k \leftarrow 0$;
2. 确定搜索方向 $\mathbf{p}_k$;
3. 从 $\mathbf{x}_k$ 出发, 沿搜索方向 $\mathbf{p}_k$ 求步长 λ_k , 以产生下一个迭代点 $\mathbf{x}_{k+1}$;
4. 检查新点 $\mathbf{x}_{k+1}$ 是否为极小点或近似极小点. 若是, 则算法终止; 否则, 令 $k \leftarrow k + 1$, 重复步骤 2-4.



§10.4.3 迭代法

选取**搜索方向** $\mathbf{p}_k$ 是最关键的一步, 各种算法的主要差别之一在于确定搜索方向的方法不同.

确定步长 λ_k 亦可采用不同的方法. 最简单的一种是令它等于某一常数, 譬如 $\lambda_k = 1$, 这样做计算简便, 但不能保证使目标函数值下降; 第二种称为可接收点算法, 只要能使目标函数值下降, 可任意选择步长 λ_k ; 第三种方法是沿着搜索方向使目标函数值下降最多, 即求解一个子优化问题

$$\min_{\lambda \in \mathbb{R}} f(\mathbf{x}_k + \lambda \mathbf{p}_k),$$

称这一过程为**最优一维搜索**或**精确一维搜索**, 所确定的步长为**最佳步长**.

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化



§10.4.3 迭代法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

最优一维搜索有一个重要的性质：在搜索方向上所得到的**最优点处**，目标函数的梯度和该搜索方向正交。

定理 10.6

设目标函数 $f(\mathbf{x})$ 具有一阶连续偏导数, $\mathbf{x}_{k+1}$ 按如下规则产生:

$$\begin{cases} \lambda_k = \arg \min_{\lambda \in \mathbb{R}} f(\mathbf{x}_k + \lambda \mathbf{p}_k), \\ \mathbf{x}_{k+1} = \mathbf{x}_k + \lambda_k \mathbf{p}_k, \end{cases}$$

则有

$$\nabla f(\mathbf{x}_{k+1})^T \mathbf{p}_k = 0.$$



§10.4.3 迭代法

定义 10.13

设序列 $\{\mathbf{x}_k\}_{k=0}^{\infty}$ 收敛于 $\mathbf{x}^*$, 若存在常数 $c > 0$, $\alpha \geq 1$ 及整数 $k_0 > 0$, 使得当 $k > k_0$ 时, 均有

$$\|\mathbf{x}_{k+1} - \mathbf{x}^*\| \leq c \|\mathbf{x}_k - \mathbf{x}^*\|^\alpha$$

成立, 则称 $\{\mathbf{x}_k\}_{k=0}^{\infty}$ 的**收敛阶**为 α , 或 $\{\mathbf{x}_k\}_{k=0}^{\infty}$ 是 α 阶收敛. 当 $\alpha = 2$ 时, 称为**二阶收敛**; 当 $1 < \alpha < 2$ 时, 称为**超线性收敛**; 当 $\alpha = 1$ 时, 称为**线性收敛**或**一阶收敛**.

通常, 线性收敛速度是比较慢的, **二阶收敛是很快**的, 超线性收敛介于它们之间.

若一个算法具有超线性或更高的收敛速度, 一般就认为它是一个很好的算法了.



§10.4.3 迭代法

算法的收敛准则. 常用的有以下几种:

(1) 依据相邻两次迭代的绝对误差

$$\|\mathbf{x}_{k+1} - \mathbf{x}_k\| < \varepsilon_1, \quad |f(\mathbf{x}_{k+1}) - f(\mathbf{x}_k)| < \varepsilon_2;$$

(2) 依据相邻两次迭代的相对误差

$$\frac{\|\mathbf{x}_{k+1} - \mathbf{x}_k\|}{\|\mathbf{x}_k\|} < \varepsilon_3, \quad \frac{|f(\mathbf{x}_{k+1}) - f(\mathbf{x}_k)|}{|f(\mathbf{x}_k)|} < \varepsilon_4;$$

(3) 依据目标函数梯度的模

$$\|\nabla f(\mathbf{x}_k)\| < \varepsilon_5,$$

其中 $\varepsilon_1, \varepsilon_2, \varepsilon_3, \varepsilon_4, \varepsilon_5$ 为事先设定的精度参数. 此外, 为了防止程序陷入无限循环, 还可设置最大迭代次数 N .



§10.5.1 数学模型

所谓**一维搜索**，又称**线性搜索**，是指单变量函数的最优化，它是多变量函数优化的基础。

在用迭代法求函数的极小值时，经常用到一维搜索，即**沿着某一已知方向求目标函数的极小值点**。另外，如果优化问题中的目标函数的导数或偏导数不存在或难以计算时，也常采用搜索的方法求解。

$$\min_{\lambda \in \mathbb{R}} f(\mathbf{x}_k + \lambda \mathbf{p}_k)$$

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化



§10.5.1 数学模型

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

所谓**一维搜索**, 又称**线性搜索**, 是指单变量函数的最优化, 它是多变量函数优化的基础.

在用迭代法求函数的极小值时, 经常用到一维搜索, 即**沿着某一已知方向求目标函数的极小值点**. 另外, 如果优化问题中的目标函数的导数或偏导数不存在或难以计算时, 也常采用搜索的方法求解.

一维搜索的主要步骤: **首先确定包含问题最优解的搜索区间**; 然后采用某种分割技术或插值方法**缩小这个区间, 进行搜索求解**.



§10.5.1 数学模型

定义 10.14

设 $\varphi: \mathbb{R} \mapsto \mathbb{R}$ 是一个连续函数, $\lambda^* \in [0, +\infty)$, 且有

$$\varphi(\lambda^*) = \min_{\lambda \geq 0} \varphi(\lambda). \quad \min f(\mathbf{x}_k + \lambda \mathbf{p}_k)$$

若存在闭区间 $[a, b] \subset [0, +\infty)$, 使 $\lambda^* \in [a, b]$, 则称 $[a, b]$ 是一维优化问题 $\min_{\lambda \geq 0} \varphi(\lambda)$ 的 **搜索区间**.

第十章最优化
方法

§10.1 线性规划问题

§10.2 线性规划问题的
几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优
化



§10.5.1 数学模型

定义 10.14

设 $\varphi: \mathbb{R} \mapsto \mathbb{R}$ 是一个连续函数, $\lambda^* \in [0, +\infty)$, 且有

$$\varphi(\lambda^*) = \min_{\lambda \geq 0} \varphi(\lambda). \quad \min f(\mathbf{x}_k + \lambda \mathbf{p}_k)$$

若存在闭区间 $[a, b] \subset [0, +\infty)$, 使 $\lambda^* \in [a, b]$, 则称 $[a, b]$ 是一维优化问题 $\min_{\lambda \geq 0} \varphi(\lambda)$ 的**搜索区间**.

确定搜索区间的一种简单方法叫**进退法**, 它的基本思想为: 从定义域内某一点出发, 按一定步长, 试图确定某一区间, 使得函数值呈现“**高 - 低 - 高**”的形状. 一个方向不成功, 就退回来, 再沿相反方向进行搜索.



§10.5.1 数学模型

进退法的计算步骤如下:

1. 设置初始值. $\lambda_0 \in [0, +\infty)$, $h_0 > 0$, 加倍系数 $t > 1$, 常取 $t = 2$, 计算 $\varphi(\lambda_0)$, $k \leftarrow 0$;
2. 比较目标函数值. 令 $\lambda_{k+1} \leftarrow \lambda_k + h_k$, 计算 $\varphi(\lambda_{k+1})$. 若 $\varphi(\lambda_{k+1}) < \varphi(\lambda_k)$, 进入下一步; 否则, 转步骤 4;
3. 更新搜索步长. 令 $h_{k+1} \leftarrow t \times h_k$, $\lambda \leftarrow \lambda_k$, $\lambda_k \leftarrow \lambda_{k+1}$, $k \leftarrow k + 1$, 转步骤 2;
4. 反向搜索. 若 $k = 0$, 转换搜索方向, 令 $h_k \leftarrow (-h_k)$, $\lambda_k \leftarrow \lambda_{k+1}$, 转步骤 2; 否则, 停止迭代, 并令

$$a = \min\{\lambda, \lambda_{k+1}\}, \quad b = \max\{\lambda, \lambda_{k+1}\},$$

输出 $[a, b]$.

第十章最优化
方法

§10.1 线性规划问题

§10.2 线性规划问题的
几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优
化



§10.5.1 数学模型

一维搜索方法主要针对单峰函数在单峰区间上的优化问题.

定义 10.15

设 $\varphi: \mathbb{R} \mapsto \mathbb{R}$ 是一个连续函数, 若存在 $[a, b]$ 及 $\lambda^* \in [a, b]$, 使 $\varphi(\lambda)$ 在 $[a, \lambda^*]$ 上严格递减, 在 $[\lambda^*, b]$ 上严格递增, 则称 $[a, b]$ 是函数 $\varphi(\lambda)$ 的**单峰区间**, $\varphi(\lambda)$ 是区间 $[a, b]$ 上的**单峰函数**.

引理 10.2

设 $\varphi: \mathbb{R} \mapsto \mathbb{R}$ 是一个连续函数, $[a, b]$ 是 $\varphi(\lambda)$ 的单峰区间, $\alpha_1, \alpha_2 \in [a, b]$, 且 $\alpha_1 < \alpha_2$.

- (1) 若 $\varphi(\alpha_1) \leq \varphi(\alpha_2)$, 则 $[a, \alpha_2]$ 是 $\varphi(\lambda)$ 的单峰区间;
- (2) 若 $\varphi(\alpha_1) \geq \varphi(\alpha_2)$, 则 $[\alpha_1, b]$ 是 $\varphi(\lambda)$ 的单峰区间.

第十章最优化
方法

§10.1 线性规划问题

§10.2 线性规划问题的
几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优
化



§10.5.1 数学模型

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

如果 $\varphi(\lambda)$ 是 $[a, b]$ 上的单峰函数, 则可通过比较 $\varphi(\lambda)$ 的函数值, 来缩小搜索区间. 设 $\varphi(\lambda) = f(\mathbf{x}_k + \lambda \mathbf{p}_k)$, $\varphi(\lambda)$ 是搜索区间 $[a, b]$ 上的单峰函数. 记第 k 次迭代所产生的搜索区间为 $[a_k, b_k]$, 取两个试探点 $\alpha_k, \beta_k \in [a_k, b_k]$, 且 $\alpha_k < \beta_k$, 计算 $\varphi(\alpha_k)$ 和 $\varphi(\beta_k)$, 根据引理10.2, 知

- (1) 若 $\varphi(\alpha_k) \leq \varphi(\beta_k)$, 则令 $a_{k+1} \leftarrow a_k, b_{k+1} \leftarrow \beta_k$;
- (2) 若 $\varphi(\alpha_k) > \varphi(\beta_k)$, 则令 $a_{k+1} \leftarrow \alpha_k, b_{k+1} \leftarrow b_k$.

反复执行上述步骤, 搜索区间逐渐变小, 当达到所需的精度时, 算法终止.

问题: 如何确定试探点 α_k, β_k 的位置.




§10.5.4 二分法

$$\varphi(\lambda^*) = \min \varphi(\lambda)$$

二分法: 通过计算函数导数值来缩短搜索区间. 设初始搜索区间为 $[a_0, b_0] = [a, b]$, 第 k 步时的搜索区间为 $[a_k, b_k]$, 满足 $\varphi'(a_k) \leq 0$, $\varphi'(b_k) \geq 0$, 取中点

$$c_k = \frac{a_k + b_k}{2}.$$

若 $\varphi'(c_k) \geq 0$, 则令 $a_{k+1} = a_k$, $b_{k+1} = c_k$; 否则, 令 $a_{k+1} = c_k$, $b_{k+1} = b_k$, 从而得到新的搜索区间 $[a_{k+1}, b_{k+1}]$. 重复上述步骤, 直到搜索区间的长度小于事先设定的精度为止. 容易看出, 二分法每次迭代都将区间缩短一半, 故二分法的收敛速度也是线性的.





§10.5.2 黄金分割法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

要求试探点 α_k, β_k 满足以下条件:

(1) α_k 和 β_k 到搜索区间 $[a_k, b_k]$ 的端点距离相等, 即

$$b_k - \alpha_k = \beta_k - a_k; \quad (4)$$

(2) 每次迭代, 搜索区间长度的缩短率相等, 即

$$b_{k+1} - a_{k+1} = \tau(b_k - a_k). \quad (5)$$



§10.5.2 黄金分割法

将式 (4) 与式 (5) 联立, 可得

$$\alpha_k = a_k + (1 - \tau)(b_k - a_k), \quad (6)$$

$$\beta_k = a_k + \tau(b_k - a_k). \quad (7)$$

现考虑 $\varphi(\alpha_k) \leq \varphi(\beta_k)$ 的情形, 则新的搜索区间为

$[a_{k+1}, b_{k+1}] = [a_k, \beta_k]$. 为进一步缩短搜索区间, 需取新的试探点 $\alpha_{k+1}, \beta_{k+1}$. 由式 (7) 知,

$$\begin{aligned} \beta_{k+1} &= a_{k+1} + \tau(b_{k+1} - a_{k+1}) \\ &= a_k + \tau(\beta_k - a_k) \\ &= a_k + \tau[a_k + \tau(b_k - a_k) - a_k] \\ &= a_k + \tau^2(b_k - a_k). \end{aligned}$$



§10.5.2 黄金分割法

若令 $\tau^2 = 1 - \tau$, 则

$$\beta_{k+1} = a_k + (1 - \tau)(b_k - a_k) = \alpha_k.$$

此时, 新的试探点 β_{k+1} 不需要重新计算, 只要取 α_k 即可. 从而在每次迭代中, 仅需取一个新的试探点即可. 类似地, 考虑 $\varphi(\alpha_k) > \varphi(\beta_k)$ 的情形, 由式 (6) 知, 新的试探点 $\alpha_{k+1} = \beta_k$, 它也不需要重新计算.

由于 $\tau^2 = 1 - \tau$, 且 $\tau > 0$, 解得

$$\tau = \frac{-1 + \sqrt{5}}{2} \approx 0.618.$$

因 0.618 等于**黄金分割率**, 故上述方法常称为**黄金分割法**或**0.618 法**.

第十章最优化
方法

§10.1 线性规划问题

§10.2 线性规划问题的
几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优
化



§10.5.2 黄金分割法

黄金分割法的计算步骤如下:

1. 选取初始数据. 确定初始搜索区间 $[a_0, b_0] = [a, b]$ 和精度要求 $\delta > 0$. 计算初始试探点 α_0, β_0 , 并令 $k \leftarrow 0$;
2. 比较函数值. 若 $\varphi(\alpha_k) \leq \varphi(\beta_k)$, 进入下一步; 否则, 转步骤 4;
3. 若 $\beta_k - a_k \leq \delta$, 则停止计算, 输出 α_k ; 否则, 令 $a_{k+1} \leftarrow a_k$,
 $b_{k+1} \leftarrow \beta_k$, $\beta_{k+1} \leftarrow \alpha_k$, $\varphi(\beta_{k+1}) \leftarrow \varphi(\alpha_k)$,
 $\alpha_{k+1} \leftarrow a_{k+1} + 0.382(b_{k+1} - a_{k+1})$, 计算 $\varphi(\alpha_{k+1})$, 转步骤 5;
4. 若 $k - \alpha_k \leq \delta$, 则停止计算, 输出 β_k ; 否则, 令 $a_{k+1} \leftarrow \alpha_k$,
 $b_{k+1} \leftarrow b_k$, $\alpha_{k+1} \leftarrow \beta_k$, $\varphi(\alpha_{k+1}) \leftarrow \varphi(\beta_k)$,
 $\beta_{k+1} \leftarrow a_{k+1} + 0.618(b_{k+1} - a_{k+1})$, 计算 $\varphi(\beta_{k+1})$, 进入下一步;
5. 令 $k \leftarrow k + 1$, 转步骤 2.

每次迭代后, 搜索区间的缩短率为 τ . 若搜索初始区间为 $[a, b]$, 则经过 n 迭代后, 搜索区间的长度为 $\tau^n(b - a)$, 算法是收敛的, 且收敛速度是线性的.



斐波那契数列 $\{F_k\}$, 即

$$F_0 = F_1 = 1,$$


$$F_{k+1} = F_k + F_{k-1}, \quad k = 1, 2, \cdots .$$



种子的排列



松果上的螺旋线条，顺时针数**8**条；反向再数就变成了**13**条。是不是很神奇？





§10.5.3 斐波那契法

斐波那契法：搜索区间长度的缩短率不是采用黄金分割数，而是采用**斐波那契数列** $\{F_k\}_{k=0}^{\infty}$ ，即

$$\begin{aligned} F_0 &= F_1 = 1, \\ F_{k+1} &= F_k + F_{k-1}, \quad k = 1, 2, \dots \end{aligned}$$

在该方法中，试探点 α_k, β_k 的取法为

$$\begin{aligned} \alpha_k &= a_k + \left(1 - \frac{F_{n-k}}{F_{n-k+1}}\right)(b_k - a_k), \\ \beta_k &= a_k + \frac{F_{n-k}}{F_{n-k+1}}(b_k - a_k). \end{aligned}$$

第十章最优化
方法

§10.1 线性规划问题

§10.2 线性规划问题的
几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优
化



§10.5.3 斐波那契法

每次缩短率满足

$$b_{k+1} - a_{k+1} = \frac{F_{n-k}}{F_{n-k+1}}(b_k - a_k),$$

其中 n 是计算函数值的次数. 若要求经过 n 次迭代后, 所得的区间长度不超过 δ , 即 $b_n - a_n \leq \delta$, 那么

$$\begin{aligned} b_n - a_n &= \frac{F_1}{F_2}(b_{n-1} - a_{n-1}) \\ &= \frac{F_1}{F_2} \cdot \frac{F_2}{F_3} \cdots \frac{F_{n-1}}{F_n}(b_1 - a_1) \\ &= \frac{1}{F_n}(b_1 - a_1). \end{aligned}$$

从而有 $F_n \geq \frac{b_1 - a_1}{\delta}$.

第十章最优化
方法

§10.1 线性规划问题

§10.2 线性规划问题的
几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优
化



§10.5.3 斐波那契法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

斐波那契数列的通项公式

$$F_k = \frac{1}{\sqrt{5}} \left\{ \left(\frac{1 + \sqrt{5}}{2} \right)^{k+1} - \left(\frac{1 - \sqrt{5}}{2} \right)^{k+1} \right\}, \quad k = 0, 1, 2, \dots$$

因此, 对于给定的初始搜索区间 $[a, b]$ 及精度参数 δ , 可先确定 F_n 的下界, 然后利用通项公式求出满足要求的最小 n , 再通过采用与黄金分割法类似的迭代过程, 求出最终的搜索区间.



§10.5.3 斐波那契法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

容易看出

$$\lim_{k \rightarrow \infty} \frac{F_{k-1}}{F_k} = \frac{\sqrt{5} - 1}{2} = \tau,$$

故斐波那契法的区间缩短率与黄金分割法相同, 也是线性收敛的. 可以证明: **斐波那契法**是用分割方法求**一维极小化问题的最优策略**, 而**黄金分割法**是近似最优的. 但由于后者简单易行, 因而得到了广泛的应用.



§10.5.4 二分法

二分法: 通过计算函数导数值来缩短搜索区间. 设初始搜索区间为 $[a_0, b_0] = [a, b]$, 第 k 步时的搜索区间为 $[a_k, b_k]$, 满足 $\varphi'(a_k) \leq 0$, $\varphi'(b_k) \geq 0$, 取中点

$$c_k = \frac{a_k + b_k}{2}.$$

若 $\varphi'(c_k) \geq 0$, 则令 $a_{k+1} = a_k$, $b_{k+1} = c_k$; 否则, 令 $a_{k+1} = c_k$, $b_{k+1} = b_k$, 从而得到新的搜索区间 $[a_{k+1}, b_{k+1}]$. 重复上述步骤, 直到搜索区间的长度小于事先设定的精度为止. 容易看出, 二分法每次迭代都将区间缩短一半, 故二分法的收敛速度也是线性的.

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化



§10.5.4 插值法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

插值法：在搜索区间中**不断用低次**（通常不超过三次）**多项式来近似目标函数**，并逐步用插值多项式的极小点来逼近一维搜索问题

$$\varphi(\lambda^*) = \min_{\lambda \geq 0} \varphi(\lambda)$$

的极小点。当函数具有较好的解析性质时，插值法比直接方法，譬如黄金分割法和斐波那契法等，**效果更好**。



§10.5.4 插值法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

考虑利用一点处的函数值、一阶和二阶导数值来**构造二次插值函数**. 设二次插值多项式为

$$q(x) = ax^2 + bx + c,$$

则 $q(x)$ 在

$$x = -\frac{b}{2a}$$

处取到极小值, 故可作为计算近似极小点的公式.



§10.5.4 插值法

若已知函数在 λ 处的函数值、一阶和二阶导数值, 即 $\varphi(\lambda), \varphi'(\lambda), \varphi''(\lambda)$, 则 $q(x)$ 需满足插值条件

$$q(\lambda) = a\lambda^2 + b\lambda + c = \varphi(\lambda),$$

$$q'(\lambda) = 2a\lambda + b = \varphi'(\lambda),$$

$$q''(\lambda) = 2a = \varphi''(\lambda).$$

解得 $a = \frac{\varphi''(\lambda)}{2}$, $b = \varphi'(\lambda) - \varphi''(\lambda)\lambda$. 从而有迭代计算公式

$$\lambda_{k+1} = \lambda_k - \frac{\varphi'(\lambda_k)}{\varphi''(\lambda_k)}, \quad k = 0, 1, \dots,$$

称为**一点二次插值法**, 或称为**牛顿法**.

可以证明: 当初始值 λ_0 充分靠近 λ^* 时, 由牛顿法产生的迭代序列 $\{\lambda_k\}_{k=1}^{\infty}$ 是收敛的, 且**收敛速度是二阶的**(λ^* 为单根时)



§10.5.4 插值法

牛顿法的优点是速度速度快, 但是需要用到二阶导数值, 计算代价高. 因此, 一个自然的想法是: 用两个点 λ_1, λ_2 处的函数值及其中一个点的导数值 $\varphi'(\lambda_1)$ (或 $\varphi'(\lambda_2)$) 来构造二次插值函数. 通过插值条件并求解, 可得计算公式:

$$\lambda_{k+1} = \lambda_k - \frac{(\lambda_k - \lambda_{k-1})\varphi'(\lambda_k)}{2 \left[\varphi'(\lambda_k) - \frac{\varphi(\lambda_k) - \varphi(\lambda_{k-1})}{\lambda_k - \lambda_{k-1}} \right]}, \quad k = 1, \dots,$$

称为**两点二次插值法**, 其收敛速度的阶为 $(1 + \sqrt{5})/2 \approx 1.618$. 类似地, 还有**三点二次插值法**, **二点三次插值法**等.



§10.5.5 其他方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

一维搜索过程是**非线性优化**方法的基本组成部分, 前述通过求解一维搜索最优化问题的方法, 譬如黄金分割法, 牛顿法等, 统称为**精确一维搜索**, 需要花费很大的计算量. 特别地, 当迭代点远离问题的解时, 精确得求解一个一维子问题通常不是十分有效.

因此, 提出了**非精确一维搜索**, 即选取步长 λ_k 使得目标函数 $f(\mathbf{x})$ 有可接收的**下降量** $f(\mathbf{x}_k) - f(\mathbf{x}_k + \lambda_k \mathbf{p}_k) > \delta$. **非精确一维搜索**包括 Armijo-Goldstein 方法, Wolfe-Powell 方法等.



§10.5.5 其他方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

在非线性优化中, 一个可用来代替一维线搜索的方法是**信赖域方法** (Trust-Region Methods), 其**基本思想**是: 先设定一个可信的步长, 然后利用局部 n 维二次模型寻找最优下降方向和步长. 因步长受到使 Taylor 展开式有效的信赖域限制, 故又称**限步长法**. **信赖域方法具有快速的局部收敛性**, 又有理想的总体收敛性, 是一个很好的方法.



§10.6.1 最速下降法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

不失一般性, **无约束非线性优化**问题可写成

$$\min f(\mathbf{x}), \quad \mathbf{x} \in \mathbb{R}^n \quad (8)$$

其中 $f(\mathbf{x}) : \mathbb{R}^n \mapsto \mathbb{R}$ 是有 n 个自变量的连续函数.

求解无约束最优化问题最简单的方法是**最速下降法**, 它以**负梯度方向**作为极小化算法的下降方向, 故又称为**梯度法**.



§10.6.1 最速下降法

设函数 $f(\mathbf{x})$ 在 $\mathbf{x}_k$ 附件连续可微, 且 $\nabla f(\mathbf{x}_k) \neq 0$. 利用 Taylor 展开式

$$f(\mathbf{x}) = f(\mathbf{x}_k) + (\mathbf{x} - \mathbf{x}_k)^T \nabla f(\mathbf{x}_k) + o(\|\mathbf{x} - \mathbf{x}_k\|)$$

可知, 若记 $\mathbf{x} - \mathbf{x}_k = \lambda \mathbf{p}_k$, $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$ 则满足 $\mathbf{p}_k^T \mathbf{g}_k < 0$ 的方向 $\mathbf{p}_k$ 都是下降方向. 当 λ 的值固定后, 若 $\mathbf{p}_k^T \mathbf{g}_k$ 的值越小, 即 $-\mathbf{p}_k^T \mathbf{g}_k$ 的值越大, 则函数 $f(\mathbf{x})$ 的值下降的越快. 另外, 由 Cauchy-Schwartz 不等式知最优化问题

$$\min_{\mathbf{p}_k \in \mathbb{R}^n} \mathbf{p}_k^T \mathbf{g}_k, \quad \text{subject to } \|\mathbf{p}_k\| = \|\mathbf{g}_k\|,$$

当且仅当 $\mathbf{p}_k = -\mathbf{g}_k$ 时, $\mathbf{p}_k^T \mathbf{g}_k$ 的值最小, 称 $-\mathbf{g}_k$ 为**最速下降方向**.



§10.6.1 最速下降法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

最速下降法的计算步骤如下:

1. 设定初始值 $\mathbf{x}_0 \in \mathbb{R}^n$ 及精度参数 $\varepsilon > 0$, 并令 $k \leftarrow 0$;
2. **计算梯度** $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$, 令 $\mathbf{p}_k = -\mathbf{g}_k$;
3. 若 $\|\mathbf{g}_k\| < \varepsilon$, 则算法终止; 否则, 利用**一维搜索**求步长因子 λ_k , 使得

$$f(\mathbf{x}_k + \lambda_k \mathbf{p}_k) = \min_{\lambda \geq 0} f(\mathbf{x}_k + \lambda \mathbf{p}_k);$$

4. 计算 $\mathbf{x}_{k+1} \leftarrow \mathbf{x}_k + \lambda_k \mathbf{p}_k$, 令 $k \leftarrow k + 1$, 转步骤 2.



§10.6.1 最速下降法

可以证明: 若 $f(\mathbf{x}) \in C^1$, 在最速下降法中采用**精确一维搜索**, 则产生的迭代点序列 $\{\mathbf{x}_k\}_{k=1}^{\infty}$ 的每一个聚点都是驻点. 进一步, 若 $\lim_{k \rightarrow \infty} \mathbf{x}_k = \mathbf{x}^*$ 且 $f(\mathbf{x})$ 在 $\mathbf{x}^*$ 的某一邻域内二次连续可微, 存在 $\varepsilon > 0$ 和 $M > m > 0$, 使得当 $\|\mathbf{x} - \mathbf{x}^*\| < \varepsilon$ 时, 有

$$m\|\mathbf{y}\|^2 \leq \mathbf{y}^T G(\mathbf{x})\mathbf{y} \leq M\|\mathbf{y}\|^2, \quad \forall \mathbf{y} \in \mathbb{R}^n,$$

其中 $G(\mathbf{x}) = \nabla^2 f(\mathbf{x})$, 则**最速下降法至少是线性收敛的**.



§10.6.1 最速下降法


由于最速下降方向是函数的局部性质, 对许多实际问题, 最速下降法并非“**最速下降**”, 而是下降非常缓慢.

数值实验表明, 当目标函数的等值线或面接近于一个圆或球时, 最速下降法下降较快; 而当目标函数的等值线或面接近于一个扁长的椭圆或椭球时, 最速下降法开始几步下降较快, 后来就出现锯齿现象, 下降十分缓慢. 事实上, 因采用一维精确搜索, 由定理10.6知

$$\mathbf{g}_{k+1}^T \mathbf{p}_k = \mathbf{p}_{k+1}^T \mathbf{p}_k = 0,$$

即在相邻的两个迭代点上, 两个搜索方向是相互正交的, 这便是产生锯齿状现象的原因. 当接近极小点时, 步长越小, 前进越慢.

$$f(x) = \frac{1}{2}x^T \begin{pmatrix} 1 & 0.5 \\ 0.5 & 1 \end{pmatrix} x - (1.5 \ 1.5) x, \quad x_0 = (0 \ 0)^T$$





§10.6.2 牛顿法

最速下降法仅用到了函数 $f(\mathbf{x})$ 的一阶局部信息. 若目标函数 $f(\mathbf{x})$ 是二次连续可微的, 则在 $\mathbf{x}_k$ 附件可用 $f(\mathbf{x})$ 的二次 Taylor 展开式

$$q_k(\mathbf{h}) = f(\mathbf{x}_k) + \nabla f(\mathbf{x}_k)^T \mathbf{h} + \frac{1}{2} \mathbf{h}^T \nabla^2 f(\mathbf{x}_k) \mathbf{h}$$

来近似 $f(\mathbf{x})$, 其中 $\mathbf{h} = \mathbf{x} - \mathbf{x}_k$. 若矩阵 $\nabla^2 f(\mathbf{x}_k)$ 正定, 则 n 维二次函数 $q_k(\mathbf{x})$ 在

$$\frac{\partial q_k(\mathbf{h})}{\partial \mathbf{h}} = \mathbf{0} \Leftrightarrow \nabla^2 f(\mathbf{x}_k) \mathbf{h} = -\nabla f(\mathbf{x}_k) \Leftrightarrow \mathbf{h} = -[\nabla^2 f(\mathbf{x}_k)]^{-1} \nabla f(\mathbf{x}_k)$$

处取到极小值. 因此, 可设计迭代格式

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\nabla^2 f(\mathbf{x}_k)]^{-1} \nabla f(\mathbf{x}_k), \quad k = 0, 1, \dots,$$

称为**牛顿迭代法**.



§10.6.2 牛顿法

牛顿迭代法是在椭球范数下的最速下降法. 事实上, 对于局部近似函数 $f(\mathbf{x}_k + \mathbf{h}) \approx f(\mathbf{x}_k) + \mathbf{g}_k^T \mathbf{h}$, 考虑极小化问题

$$\min_{\mathbf{h} \in \mathbb{R}^n} \frac{\mathbf{g}_k^T \mathbf{h}}{\|\mathbf{h}\|}$$

的最优解, 其中 $\|\cdot\|$ 是某种向量范数. 当采用 l_2 范数时, 即 $\|\mathbf{x}\|^2 = \mathbf{x}^T \mathbf{x}$, 可得

$$\mathbf{h} = -\mathbf{g}_k,$$

所得的方法是最速下降法. 当采用椭球范数时, 即 $\|\mathbf{x}\|^2 = \mathbf{x}^T G_k \mathbf{x}$, 可得

$$\mathbf{h} = -G_k^{-1} \mathbf{g}_k,$$

所得的方法是牛顿迭代法.



§10.6.2 牛顿法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

当 $f(\mathbf{x})$ 是正定二次函数时, $q_k(\mathbf{x}) = f(\mathbf{x})$, 故**牛顿迭代法**一步就可达**最优解**. 而对于非二次函数, 牛顿迭代法不能保证经过有限次迭代求得最优解, 但由于目标函数在极小点附件可近似于二次函数, 故当初始点靠近极小点时, 牛顿迭代法的收敛速度一般是快的.

可以证明: 若 $f(\mathbf{x}) \in C^2$, $\mathbf{x}_k$ 充分靠近 $\mathbf{x}^*$, 如果 $\nabla^2 f(\mathbf{x}^*)$ 正定, 且 $G(\mathbf{x}) = \nabla^2 f(\mathbf{x})$ 的每一个元素的函数满足 Lipschitz 条件, 则牛顿迭代法所得的序列 $\{\mathbf{x}_k\}_{k=1}^{\infty}$ 收敛于 $\mathbf{x}^*$, 且具有二阶的收敛速度.



§10.6.2 牛顿法

当初始点远离最优解时, G_k 不一定正定, 牛顿方向不一定是下降方向, 收敛性不能保证, 这说明恒取步长为 1 的牛顿迭代法是不合适的. 因此, 应该引入某种一维搜索来确定步长因子, 这种方法称为**带步长因子的牛顿法**, 计算步骤如下:

1. 设定初始值 $\mathbf{x}_0 \in \mathbb{R}^n$ 及精度参数 $\varepsilon > 0$, 并令 $k \leftarrow 0$;
2. 计算梯度 $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$. 若 $\|\mathbf{g}_k\| < \varepsilon$, 则算法终止; 否则, 进入下一步;
3. 计算矩阵 G_k , 并求解线性方程组 $G_k \mathbf{p} = -\mathbf{g}_k$ 得牛顿方向 $\mathbf{p}_k$;
4. 利用一维搜索求步长因子 λ_k , 使得

$$f(\mathbf{x}_k + \lambda_k \mathbf{p}_k) = \min_{\lambda \geq 0} f(\mathbf{x}_k + \lambda \mathbf{p}_k);$$

5. 计算 $\mathbf{x}_{k+1} \leftarrow \mathbf{x}_k + \lambda_k \mathbf{p}_k$, 令 $k \leftarrow k + 1$, 转步骤 2.



§10.6.3 共轭方向法

共轭方向法：一种介于**最速下降法**与**牛顿法**之间的方法，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，又避免了存储和计算牛顿法所需要的二阶导数信息。

共轭方向法是从研究二次函数的极小化问题产生的，是一种迭代求解大型稀疏正定线性方程组的有效方法，同时它还可以推广到处理非二次函数的极小化问题。

简介

共轭方向法和共轭梯度法

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Hesse矩阵并求逆的缺点，共轭梯度法不仅是解决大型线性方程组最有用的方法之一，也是解大型非线性最优化最有效的算法之一。

(1) 最初是由计算数学家Hestenes和几何学家Stiefel于1952年

为求正定系数矩阵线性方程组而独立提出的。他们合作的著名文章 *Method of conjugate gradients for solving linear systems* 被认为是共轭梯度法的奠基性文章。

(2) 1964年，Fletcher和Reeves将此方法推广到非线性最优化，得到了求解一般函数极小值的共轭梯度法。

(3) 共轭梯度法的收敛性分析的早期工作主要由Fletcher、Powell、Beale等学者给出。

(4) Nocedal、Gilbert、Nazareth、Al-Baali、Storey、Dai、Yuan和Han等学者在收敛性方面得到了不少新成果。



§10.6.3 共轭方向法


定义 10.16

设 G 是 n 阶正定方阵, $\mathbf{p}_1, \mathbf{p}_2$ 是 n 维非零向量, 如果 $\mathbf{p}_1^T G \mathbf{p}_2 = 0$, 则称 $\mathbf{p}_1$ 与 $\mathbf{p}_2$ 是 G -共轭的. 类似地, 设 $\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_n$ 是一组 n 维非零向量, 如果


$$\mathbf{p}_i^T G \mathbf{p}_j = 0, \quad \forall 1 \leq i \neq j \leq n,$$

则称 $\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_n$ 是 G -共轭的.

显然, 如果 $\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_n$ 是 G -共轭的, 则它们是线性无关的. 当 $G = I$ 时, G -共轭性就是通常的正交性.



正交



共轭



§10.6.3 共轭方向法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

一般共轭方向法的计算步骤如下:

1. 设定初始值 $\mathbf{x}_0 \in \mathbb{R}^n$ 及初始方向 $\mathbf{g}_0$, 计算 $\mathbf{p}_0$, 使得

$$\mathbf{p}_0^T \mathbf{g}_0 < 0, \text{ 并令 } k \leftarrow 0;$$

2. 计算 λ_k 和 $\mathbf{x}_{k+1}$, 使得

$$f(\mathbf{x}_k + \lambda_k \mathbf{p}_k) = \min_{\lambda \geq 0} f(\mathbf{x}_k + \lambda \mathbf{p}_k),$$

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \lambda_k \mathbf{p}_k;$$

3. 计算 $\mathbf{p}_{k+1}$, 使得 $\mathbf{p}_{k+1}^T G \mathbf{p}_j = 0$, 其中 $j = 0, 1, 2, \dots, k$;
4. 令 $k \leftarrow k + 1$, 转步骤 2.



§10.6.3 共轭方向法

共轭方向法: 只要执行精确一维搜索, 就具有 n 次终止性.

定理 10.7

(共轭方向基本定理) 设 $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T G \mathbf{x} + \mathbf{b}^T \mathbf{x} + c$ 是正定二次函数, 其中 G 是 n 阶正定方阵, $\mathbf{b}$ 是 n 维向量, c 是常数, 则共轭方向法至多经过 n 步精确线性搜索终止; 且每一个 $\mathbf{x}_{k+1}$ 都是 $f(\mathbf{x})$ 在点 $\mathbf{x}_0$ 和方向 $\mathbf{p}_0, \mathbf{p}_1, \dots, \mathbf{p}_k$ 所张成的线性流形

$\left\{ \mathbf{x} \mid \mathbf{x} = \mathbf{x}_0 + \sum_{j=0}^k \lambda_j \mathbf{p}_j, \quad \forall \lambda_j \in \mathbb{R} \right\}$ 中的极小点.

在精确线性搜索的条件下, 利用 $\mathbf{g}_{k+1} - \mathbf{g}_k = G(\mathbf{x}_{k+1} - \mathbf{x}_k) = \lambda_k G \mathbf{p}_k$ 可知, 共轭方向法的梯度 $\mathbf{g}_{k+1}$ 满足

$$\mathbf{g}_{k+1}^T \mathbf{p}_j = 0, \quad j = 0, 1, \dots, k.$$



§10.6.3 共轭方向法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

若记 $\mathbf{x}^* = \mathbf{x}_0 + \sum_{i=0}^{n-1} y_i^* \mathbf{p}_i$, $\mathbf{x} = \mathbf{x}_0 + \sum_{i=0}^{n-1} y_i \mathbf{p}_i$, 则二次函数 $f(\mathbf{x})$ 可改写成

$$q(\mathbf{y}) = \frac{1}{2}(\mathbf{x} - \mathbf{x}^*)^T G(\mathbf{x} - \mathbf{x}^*) + \tilde{c} = \frac{1}{2}(\mathbf{y} - \mathbf{y}^*)^T S^T G S(\mathbf{y} - \mathbf{y}^*) + \tilde{c},$$

其中 $S = (\mathbf{p}_0, \mathbf{p}_1, \dots, \mathbf{p}_{n-1})$. 利用 G -共轭性条件, 得

$$q(\mathbf{y}) = \frac{1}{2} \sum_{i=0}^{n-1} (y_i - y_i^*)^2 d_{ii},$$

其中 $d_{ii} = \mathbf{p}_i^T G \mathbf{p}_i$.

共轭性意味着存在一个恰当的坐标变换 S , 使得 G 在新的坐标系下是一个对角矩阵 $S^T G S$, 新的变量在二次函数中是相互分离的. 于是, 一个共轭方向法是在新坐标系中的一个交替变量法.



§10.6.3 共轭方向法

共轭梯度法是最著名的共轭方向法, 它使得最速下降方向具有共轭性, 从而提高算法的有效性和可靠性.

由于解正定线性方程组 $A\mathbf{x} = \mathbf{b}$ 等价于极小化一个正定二次函数

$$\min_{\mathbf{x} \in \mathbb{R}^n} \frac{1}{2} \mathbf{x}^T A \mathbf{x} - \mathbf{b}^T \mathbf{x},$$

共轭梯度法首先是作为解线性方程组的方法被提出来的.



§10.6.3 共轭方向法

考虑正定二次函数

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

$f(\mathbf{x})$ 的梯度为 $\nabla f(\mathbf{x}) = G\mathbf{x} + \mathbf{b}$. 共轭梯度法有一个非常特殊的性质: 在构造共轭方向时, $\mathbf{p}_k$ 仅依赖于 $\mathbf{p}_{k-1}$. 这意味着在实现算法时, 可以减少存储量和计算时间, 是一个很好的性质. 另外, 在搜索方向 $\mathbf{p}_k$ 上, 希望函数值是下降的, 故一个自然的选择是

$$\mathbf{p}_k = -\mathbf{g}_k + \beta_{k-1} \mathbf{p}_{k-1},$$

其中 $\mathbf{g}_k = \nabla f(\mathbf{x}_k) = G\mathbf{x}_k + \mathbf{b}$, β_{k-1} 是待定系数.



§10.6.3 共轭方向法

因 $\mathbf{p}_k$ 与 $\mathbf{p}_{k-1}$ 需满足 G -共轭条件, 上式两端左乘以 $\mathbf{p}_{k-1}^T G$, 故有

$$\beta_{k-1} = \frac{\mathbf{g}_k^T G \mathbf{p}_{k-1}}{\mathbf{p}_{k-1}^T G \mathbf{p}_{k-1}}, \quad k = 1, 2, \dots, n-1.$$

对于 $\mathbf{p}_0$, 直接取 $\mathbf{p}_0 = -\mathbf{g}_0$. 可以证明 $\mathbf{p}_0, \mathbf{p}_1, \dots, \mathbf{p}_{n-1}$ 是 G -共轭的, 且每一次迭代所产生的搜索方向 $\mathbf{p}_k$ 和梯度方向 $\mathbf{g}_k$ 都包含于

$$\mathcal{K}(\mathbf{g}_0; k) \triangleq \text{span} \{ \mathbf{g}_0, G\mathbf{g}_0, \dots, G^k \mathbf{g}_0 \},$$

称 $\mathcal{K}(\mathbf{g}_0; k)$ 为 $\mathbf{g}_0$ 的 k 次 Krylov 子空间.



§10.6.3 共轭方向法

定理 10.8

设 $f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T G \mathbf{x} + \mathbf{b}^T \mathbf{x} + c$ 是正定二次函数, 其中 G 是 n 阶正定方阵, $\mathbf{b}$ 是 n 维向量, c 是常数, 则采用精确线性搜索的共轭梯度法经过 $m \leq n$ 步终止, 且对任意的 $k \leq m$ 有

$$\mathbf{g}_k^T \mathbf{g}_i = 0, \quad i = 0, 1, \dots, k-1, \quad (9)$$

$$\mathbf{p}_k^T G \mathbf{p}_i = 0, \quad i = 0, 1, \dots, k-1, \quad (10)$$

$$\mathbf{p}_i^T \mathbf{g}_i = -\mathbf{g}_i^T \mathbf{g}_i, \quad i = 0, 1, \dots, k-1, \quad (11)$$

$$\text{span} \{ \mathbf{g}_0, \mathbf{g}_1, \dots, \mathbf{g}_k \} = \mathcal{K}(\mathbf{g}_0; k), \quad (12)$$

$$\text{span} \{ \mathbf{p}_0, \mathbf{p}_1, \dots, \mathbf{p}_k \} = \mathcal{K}(\mathbf{g}_0; k). \quad (13)$$

注意: $\mathbf{p}_0$ 必须取 $-\mathbf{g}_0$, 否则上述定理是不成立的.



§10.6.3 共轭方向法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

式 (9) 表明梯度向量序列 $\{\mathbf{g}_i\}$ 是相互正交的, 而式 (10) 表明搜索方向序列 $\{\mathbf{p}_i\}$ 才是 G -共轭的. 由式 (11) 知, 共轭梯度法的每一步都是值下降的, 精确一维搜索的步长 λ_k 可写成:

$$\lambda_k = -\frac{\mathbf{p}_k^T \mathbf{g}_k}{\mathbf{p}_k^T G \mathbf{p}_k} = \frac{\mathbf{g}_k^T \mathbf{g}_k}{\mathbf{p}_k^T G \mathbf{p}_k}.$$



§10.6.3 共轭方向法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

利用 $G\mathbf{p}_k = (\mathbf{g}_{k+1} - \mathbf{g}_k)/\lambda_k$ 及式 (9) 和 (11), 可得计算搜索方向的步长 β_k 几个常用公式

$$\begin{aligned}\beta_k &= \frac{\mathbf{g}_{k+1}^T (\mathbf{g}_{k+1} - \mathbf{g}_k)}{\mathbf{p}_k^T (\mathbf{g}_{k+1} - \mathbf{g}_k)} \quad (\text{Crowder-Wolfe 公式}) \\ &= \frac{\mathbf{g}_{k+1}^T \mathbf{g}_{k+1}}{\mathbf{g}_k^T \mathbf{g}_k} \quad (\text{Fletcher-Reeves 公式}) \\ &= \frac{\mathbf{g}_{k+1}^T (\mathbf{g}_{k+1} - \mathbf{g}_k)}{\mathbf{g}_k^T \mathbf{g}_k} \quad (\text{Polak-Ribiere-Polyak 公式}) \\ &= -\frac{\mathbf{g}_{k+1}^T \mathbf{g}_{k+1}}{\mathbf{p}_k^T \mathbf{g}_k} \quad (\text{Dixon 公式}).\end{aligned}$$

共轭梯度法仅比最速下降法稍微复杂一点, 但却具有二次终止性, 所以共轭梯度法是一个很有效的方法.



§10.6.3 共轭方向法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

共轭梯度法可推广至一般的目标函数 $f(\mathbf{x})$, 此时, 步长 λ_k 可通过精确一维搜索或非精确一维搜索得到, 而 β_k 的计算公式保持不变. 但是, 需要注意的是, n 步以后共轭梯度法所产生的搜索方向 $\mathbf{p}_n$ 不再与 $\mathbf{p}_0, \mathbf{p}_1, \dots, \mathbf{p}_{n-1}$ 满足 G -共轭条件, 故需重新取最速下降方向作为搜索方向, 即

$$\mathbf{p}_{cn} = -\mathbf{g}_{cn}, \quad c = 1, 2, \dots,$$

这种方法称为再开始共轭梯度法.



§10.6.3 共轭方向法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

再开始共轭梯度法的计算步骤如下:

1. 设定初始值 $\mathbf{x}_0 \in \mathbb{R}^n$ 及精度参数 $\varepsilon > 0$, 计算

$$\mathbf{g}_0 = \nabla f(\mathbf{x}_0), \text{ 令 } k \leftarrow 0;$$

2. 若 $\|\mathbf{g}_0\| < \varepsilon$, 则算法终止; 否则, 令 $\mathbf{p}_0 \leftarrow -\mathbf{g}_0$;
3. 利用一维搜索求步长因子 λ_k , 使得

$$f(\mathbf{x}_k + \lambda_k \mathbf{p}_k) = \min_{\lambda \geq 0} f(\mathbf{x}_k + \lambda \mathbf{p}_k),$$

令 $\mathbf{x}_{k+1} \leftarrow \mathbf{x}_k + \lambda_k \mathbf{p}_k$, 计算 $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1})$;

4. 若 $\|\mathbf{g}_{k+1}\| < \varepsilon$, 则算法终止; 否则, 进入下一步;
5. 若 $k = n - 1$, 令 $\mathbf{x}_0 \leftarrow \mathbf{x}_{k+1}$, 转步骤 1; 否则, 进入下一步;
6. 计算 $\beta_k = \mathbf{g}_{k+1}^T \mathbf{g}_{k+1} / \mathbf{g}_k^T \mathbf{g}_k$, 令 $\mathbf{p}_{k+1} \leftarrow -\mathbf{g}_{k+1} + \beta_k \mathbf{p}_k$,
 $k \leftarrow k + 1$;
7. 若 $\mathbf{p}_k^T \mathbf{g}_k > 0$, 令 $\mathbf{x}_0 \leftarrow \mathbf{x}_k$, 转步骤 1; 否则, 转步骤 3.



§10.6.3 共轭方向法

当步长因子 λ_k 也可以采用非精确一维搜索时, β_k 的几种计算公式的效果是不同的.

共轭梯度法在一定条件下是收敛的. 可以证明: 若 $f(\mathbf{x})$ 在有界水平集 $L = \{\mathbf{x} \in \mathbb{R}^n \mid f(\mathbf{x}) \leq f(\mathbf{x}_0)\}$ 上连续可微, 则采用 Fletcher-Reeves 公式和精确一维搜索的共轭梯度法产生的序列 $\{\mathbf{x}_k\}$ 至少有一个聚点是驻点, 即

- (1) 当 $\{\mathbf{x}_k\}$ 是有穷点列时, 其最后一个点 $\mathbf{x}^*$ 是 $f(\mathbf{x})$ 的驻点;
- (2) 当 $\{\mathbf{x}_k\}$ 是无穷点列时, 它必有极限点, 且其任一极限点都是 $f(\mathbf{x})$ 的驻点.

采用其他公式和搜索策略也有类似的结论.



§10.6.3 共轭方向法

当 $f(\mathbf{x})$ 是正定二次函数时, 采用精确一维搜索的共轭梯度法至多在 n 次迭代后终止. 而对于一般的非线性函数 $f(\mathbf{x})$, 若将 n 次迭代视为一次大的迭代, 则共轭梯度法应该与牛顿法有类似的收敛速度. 可以证明: 设 $f(\mathbf{x}) \in C^3$, 且存在常数 $m, M > 0$, 使得

$$m\|\mathbf{y}\|^2 \leq \mathbf{y}^T \nabla^2 f(\mathbf{x}) \mathbf{y} \leq M\|\mathbf{y}\|^2, \quad \forall \mathbf{y} \in \mathbb{R}^n, \mathbf{x} \in L,$$

其中 $L = \{\mathbf{x} \in \mathbb{R}^n \mid f(\mathbf{x}) \leq f(\mathbf{x}_0)\}$ 是有界水平集, 则采用 Fletcher-Reeves 公式和精确一维搜索的再开始共轭梯度法产生的序列 $\{\mathbf{x}_k\}$ 是 n 步二阶收敛的, 即存在常数 $c > 0$, 使得

$$\limsup_{k \rightarrow \infty} \frac{\|\mathbf{x}_{kn+n} - \mathbf{x}^*\|}{\|\mathbf{x}_{kn} - \mathbf{x}^*\|^2} \leq c < \infty.$$



§10.6.4 拟牛顿法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

拟牛顿法：利用目标函数 $f(\mathbf{x})$ 及一阶导数 $\nabla f(\mathbf{x})$ 的信息来构造近似的 Hessian 矩阵, 从而实现加快收敛速度的目标.

设 $f(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}$ 是二次连续可微的函数, 则 $f(\mathbf{x})$ 在 $\mathbf{x}_{k+1}$ 附近的二次近似函数为

$$f(\mathbf{x}) \approx f(\mathbf{x}_{k+1}) + \mathbf{g}_{k+1}^T (\mathbf{x} - \mathbf{x}_{k+1}) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_{k+1})^T G_{k+1} (\mathbf{x} - \mathbf{x}_{k+1}),$$

其中 $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1})$, $G_{k+1} = \nabla^2 f(\mathbf{x}_{k+1})$, 从而有

$$\nabla f(\mathbf{x}) \approx \mathbf{g}_{k+1} + G_{k+1} (\mathbf{x} - \mathbf{x}_{k+1}).$$

令 $\mathbf{x} = \mathbf{x}_k$, 记 $\mathbf{s}_k = \mathbf{x}_{k+1} - \mathbf{x}_k$, $\mathbf{y}_k = \mathbf{g}_{k+1} - \mathbf{g}_k$, 则

$$G_{k+1}^{-1} \mathbf{y}_k \approx \mathbf{s}_k.$$

显然, 当 $f(\mathbf{x})$ 是二次函数时, 上述近似关系取等号.



§10.6.4 拟牛顿法

在拟牛顿法中, 要求构造出来的 Hessian 矩阵的逆近似 H_{k+1} 满足这种关系, 即

$$H_{k+1}\mathbf{y}_k = \mathbf{s}_k, \quad (14)$$

称为**拟牛顿条件**或**拟牛顿方程**. 若记 $B_{k+1} = H_{k+1}^{-1}$, 则上述条件也可写为

$$B_{k+1}\mathbf{s}_k = \mathbf{y}_k,$$

是关于 Hessian 矩阵的拟牛顿条件.



§10.6.4 拟牛顿法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

一般拟牛顿法的计算步骤如下:

1. 设定初始值 $\mathbf{x}_0 \in \mathbb{R}^n$ 及精度参数 $\varepsilon > 0$, $H_0 \in \mathbb{R}^{n \times n}$, 并令 $k \leftarrow 0$;
2. 计算梯度 $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$, 若 $\|\mathbf{g}_k\| < \varepsilon$, 则算法终止; 否则, 计算 $\mathbf{p}_k = -H_k \mathbf{g}_k$;
3. 利用一维搜索求步长因子 λ_k , 使得

$$f(\mathbf{x}_k + \lambda_k \mathbf{p}_k) = \min_{\lambda \geq 0} f(\mathbf{x}_k + \lambda \mathbf{p}_k);$$

4. 校正 H_k 产生 H_{k+1} , 使得拟牛顿条件 (14) 成立;
5. 计算 $\mathbf{x}_{k+1} \leftarrow \mathbf{x}_k + \lambda_k \mathbf{p}_k$, 令 $k \leftarrow k + 1$, 转步骤 2.

类似地, 拟牛顿法也可采用近似 Hessian 矩阵 B_k 进行. 在实际应用中, 初始矩阵 H_0 可取单位阵, 此时, 拟牛顿法的第一次迭代等价于一个最速下降迭代.



§10.6.4 拟牛顿法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

拟牛顿法是在椭球范数 $\|\cdot\|_{H_k^{-1}}$ 下的最速下降法, 搜索方向

$$\mathbf{p}_k = -H_k \mathbf{g}_k$$

是 $f(\mathbf{x})$ 从 $\mathbf{x}_k$ 点出发的最速下降方向. 因在每一次迭代中, 度量矩阵 H_k^{-1} 都是变化的, 故方法也称为**变尺度法**.

与牛顿法相比, 拟牛顿法有以下优点:

- (1) 仅需一阶导数信息;
- (2) H_k 保持正定, 使得方法具有下降性质;
- (3) 每次迭代需要 $O(n^2)$ 次乘法运算.



§10.6.4 拟牛顿法

如何校正 H_k 产生 H_{k+1} , 使得拟牛顿条件 (14) 成立, 并保持正定性. 设 H_{k+1} 是 H_k 通过对称秩二校正得到的, 即

$$H_{k+1} = H_k + a\mathbf{u}\mathbf{u}^T + b\mathbf{v}\mathbf{v}^T,$$

其中 $a, b \in \mathbb{R}$, $\mathbf{u}, \mathbf{v} \in \mathbb{R}^{n \times 1}$. 代入拟牛顿条件 (14) 得

$$H_k \mathbf{y}_k + a\mathbf{u}\mathbf{u}^T \mathbf{y}_k + b\mathbf{v}\mathbf{v}^T \mathbf{y}_k = \mathbf{s}_k.$$

显然, 向量 $\mathbf{u}$ 和 $\mathbf{v}$ 不能由上式唯一确定, 但是 $\mathbf{u}$ 和 $\mathbf{v}$ 可取为

$$\mathbf{u} = \mathbf{s}_k, \quad \mathbf{v} = H_k \mathbf{y}_k,$$

这时, 只要 a 和 b 满足 $a\mathbf{u}^T \mathbf{y}_k = 1$, $b\mathbf{v}^T \mathbf{y}_k = -1$, 拟牛顿条件 (14) 就成立了. 解得

$$H_{k+1} = H_k + \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{s}_k^T \mathbf{y}_k} - \frac{H_k \mathbf{y}_k \mathbf{y}_k^T H_k}{\mathbf{y}_k^T H_k \mathbf{y}_k}, \quad (15)$$

称为 **DFP 校正公式**, 是由 Davidon, Fletcher 和 Powell 发展出来的。



§10.6.4 拟牛顿法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

DFP 校正公式具有很多重要的性质:

- (1) 校正保持正定性, 故下降性质成立;
- (2) 每次迭代需要 $3n^2 + O(n)$ 次乘法运算;
- (3) 具有超线性的收敛速度;
- (4) 对于凸函数, 当采用精确一维搜索时, 方法具有总体收敛性.



§10.6.4 拟牛顿法

计算方法

第十章最优化方法

§10.1 线性规划问题

§10.2 线性规划问题的几何意义

§10.3 单纯形法

§10.4 非线性优化问题

§10.5 一维搜索

§10.6 无约束非线性优化

利用 $H_{k+1} \longleftrightarrow B_{k+1}$, $\mathbf{s}_k \longleftrightarrow \mathbf{y}_k$ 之间的对偶关系及矩阵逆的秩一校正公式, 可得

$$H_{k+1} = H_k + \left(1 + \frac{\mathbf{y}_k^T H_k \mathbf{y}_k}{\mathbf{s}_k^T \mathbf{y}_k}\right) \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{s}_k^T \mathbf{y}_k} - \frac{\mathbf{s}_k \mathbf{y}_k^T H_k + H_k \mathbf{y}_k \mathbf{s}_k^T}{\mathbf{s}_k^T \mathbf{y}_k}, \quad (16)$$

称为 **BFGS 校正公式**, 是由 Broyden, Fletcher, Goldfarb 和 Shanno 发展出来的. BFGS 校正公式具备与 DFP 校正公式相同的性质, 并且对于凸函数, 当采用非精确一维搜索时, 仍具有总体收敛性. 在实际应用中, BFGS 校正公式的结果也优于 DFP 校正公式, 是最常用的拟牛顿方法之一.



§10.6.4 拟牛顿法

一般地, 当初始点靠近极小点时, 拟牛顿迭代法在一定条件下是线性收敛的, 很多时候甚至是超线性收敛的.

对于凸函数, 拟牛顿法还有整体收敛性. 可以证明: 当 $f(\mathbf{x})$ 是一致凸的二阶连续可微函数时, 采用精确一维搜索和 DFP 校正公式的拟牛顿法整体收敛; 当 $f(\mathbf{x})$ 是凸的二阶连续可微函数时, 采用非精确一维搜索的 Wolfe-Powell 准则和 BFGS 校正公式的拟牛顿法整体收敛.



§10.6.5 随机梯度下降法

在许多实际应用中, 譬如深度学习, 压缩感知, 低秩矩阵填充等, 优化变量的个数可能会很大, 如几十万甚至更多, 这时即使采用梯度下降法, 每一步迭代所需的计算量也是相当可观的. 因此, 人们提出了**随机梯度下降法**, 基本思想是: 梯度向量可以视为期望, 而期望可以使用小规模样本来近似估计. 设优化的目标函数为 $f(\mathbf{x})$, 优化变量 $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$, 先任取它的一个有 m 个元素的子集 $\{x_{i1}, x_{i2}, \dots, x_{im}\}$, m 远小于 n , 然后计算 $f(\mathbf{x})$ 关于变量 $x_{i1}, x_{i2}, \dots, x_{im}$ 的梯度并乘以一个称为**学习率**的常数 r , 其他变量视为常数, 执行一次梯度下降. 重复以上步骤, 直至算法满足收敛准则.