

# 1.4 线搜索迭代算法概述及收敛性准则

# 1.4.1 线搜索算法的一般框架

**基本思想：**从某个点 $x^0 \in R^n$ 出发，按照某种规则产生一个迭代点序列 $\{x^k\}$ ，直到算法终止。

**算法分类：**

按照迭代点是否可行，分为

- (1) 可行算法 所有迭代点都是可行点
- (2) 不可行算法 迭代点中至少存在一个不可行点

按照目标函数值是否下降分为：

- (1) 单调下降算法  $f(x^{k+1}) \leq f(x^k), \forall k$
- (2) 非单调下降算法 否则

## (一) 线搜索迭代算法的一般框架

步1: 选择一个初始点 $x^0 \in R^n$ , 令 $k := 0$ ;

步2: 判断当前的迭代点 $x^k$ 是否满足终止条件;

步3: 从当前点出发, 选择沿什么方向进行迭代,

(即迭代方向, 不妨记为 $d^k$ )

以及沿该方向走多远 (即迭代步长, 不妨记为 $\lambda_k$ ),

确定下一个迭代点 $x^{k+1} = x^k + \lambda_k d^k$

步4: 令 $k := k + 1$ , 转步2

**注；** 最有用的终止规则： $|f(x^k) - f(x^*)| \leq \varepsilon; \|x^k - x^*\| \leq \varepsilon, (x^* \in S)$

关于步2: 常用的终止准则:

$$(a) \|x^{k+1} - x^k\| < \varepsilon$$

$$(b) |f(x^{k+1}) - f(x^k)| < \varepsilon$$

$$(c) \frac{\|x^{k+1} - x^k\|}{\|x^k\|} < \varepsilon$$

$$(d) \frac{|f(x^{k+1}) - f(x^k)|}{|f(x^k)|} < \varepsilon$$

$$(e) \|\nabla f(x^k)\| \leq \varepsilon$$

## 1.4.2 迭代方向

**定义1.4.1** 在点 $x^k$ 处, 对于向量 $d^k \in R^n \setminus \{0\}$ , 若存在 $\bar{\lambda} > 0$ 使得对任意 $\lambda \in (0, \bar{\lambda})$ 都有 $f(x^k + \lambda d^k) < f(x^k)$ , 则称 $d^k$ 为函数 $f$ 在 $x^k$ 处的一个下降方向。

**命题1.4.1** 假设函数 $f$ 一阶连续可微, 那么 $d^k$ 为 $f$ 在 $x^k$ 处的下降方向当且仅当 $\nabla f(x^k)^T d^k < 0$ .

证明: 由Taylor展式得:

$$f(x^k + \lambda d^k) = f(x^k) + \lambda \nabla f(x^k)^T d^k + o(\lambda \|d^k\|).$$

$$\text{所以 } f(x^k + \lambda d^k) - f(x^k) = \lambda [\nabla f(x^k)^T d^k + o(\|d^k\|)].$$

从而结论成立。

**定义1.4.2** 给定非空集合  $F \subseteq R^n$  和点  $x^k \in F$ . 对于向量  $d^k \in R^n \setminus \{0\}$ .  
若存在  $\bar{\lambda} > 0$  使得对任意  $\lambda \in (0, \bar{\lambda})$  都有  $x^k + \lambda d^k \in F$ , 则称  $d^k$  为  $x^k$  处关于  $F$  的一个可行方向。

**可行下降方向:** 如果  $d^k$  为点  $x^k$  处的可行下降方向, 那么存在  $\lambda_k$  使得  $x^k + \lambda_k d^k \in F$ , 且  $f(x^k + \lambda_k d^k) < f(x^k)$ .

## 1.4.3 迭代步长

### 1. 精确一维线搜索

选取  $\lambda_k = \arg \min_{\lambda > 0} \varphi(\lambda) = \min_{\lambda > 0} f(x^k + \lambda d^k)$ ,

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

## 2. 非精确一维线搜索（近似一维搜索）

### (1) Goldstein型线搜索（1965）

$$\text{选取 } \lambda_k > 0 \text{ 使得: } f(x^k + \lambda_k d^k) - f(x^k) \leq \sigma \lambda_k \nabla f(x^k)^T d^k, \\ f(x^k + \lambda_k d^k) - f(x^k) \geq (1 - \sigma) \lambda_k \nabla f(x^k)^T d^k,$$

其中  $\sigma \in (0, \frac{1}{2})$  .

### (2) Armijo型线搜索（1966）

选取  $\lambda_k := \rho \gamma^{m_k}$  使得  $m_k$  为满足下式的最小非负整数:

$$f(x^k + \rho \gamma^{m_k} d^k) - f(x^k) \leq \sigma \rho \gamma^{m_k} \nabla f(x^k)^T d^k$$

其中  $\rho > 0, \sigma, \gamma \in (0, 1)$  .

### (3) Wolfe型线搜索（Wolfe-Powell型线搜索）

1969 1976

$$\text{选取 } \lambda_k > 0 \text{ 使得: } f(x^k + \lambda_k d^k) - f(x^k) \leq \sigma \lambda_k \nabla f(x^k)^T d^k, \\ \nabla f(x^k + \lambda_k d^k)^T d^k \geq \delta \nabla f(x^k)^T d^k,$$

其中  $\sigma \in (0, \frac{1}{2})$  ,  $\delta \in (\sigma, 1)$  .

### 3. 非单调一维线搜索

#### (1) Grippo-Lampariello-Lucidi非单调线搜索 (1986)

寻找步长 $\lambda_k = \rho\gamma^{h_k}$ 使得 $h_k$ 是满足下式的最小非负整数:

$$f(x^k + \lambda_k d^k) \leq \max_{0 \leq j \leq m_k} f(x^{k-j}) + \delta \lambda_k \nabla f(x^k)^T d^k$$

其中,  $m_k$ 是一个正整数且 $m_k \leq M$  ( $M$ 为某一正整数),

$\lambda_k^0$ 是一个给定的小实数,  $\sigma, \rho \in (0, 1)$ .

注: 当 $f(x^k) = \max_{0 \leq j \leq m_k} f(x^{k-j})$ 时, 即为单调的Armijo型线搜索.

## (2) Zhang-Hager (2004) 非单调线搜索

寻找步长  $\lambda_k > 0$ , 使得:

$$f(x^k + \lambda_k d^k) \leq C_k + \delta \lambda_k \nabla f(x^k)^T d^k$$

$$\nabla f(x^k + \lambda_k d^k)^T d^k \geq \sigma \nabla f(x^k)^T d^k$$

其中,  $0 < \delta < \sigma < 1$ ,  $C_k$  按如下方式选取:

$$C_{k+1} = (\eta_k Q_k C_k + f(x^{k+1})) / Q_{k+1}$$

这里,  $Q_{k+1} = \eta_k Q_k + 1$ ,  $C_0 = f(x^0)$ ,  $Q_0 = 1$ , 且

$$\eta_k \in [\eta_{\min}, \eta_{\max}], 0 \leq \eta_{\min} \leq \eta_{\max} \leq 1$$

注:  $C_k$  是  $f(x^0), f(x^1), \dots, f(x^k)$  的凸组合, 含有第  $k$  步迭代之前所有迭代点函数值的信息;

$\eta_k$  的选取控制着“非单调性”的度, 如果  $\eta_k = 0$ ,  $k \in \{0, 1, 2, \dots\}$ , 则即为单调的 *Wolfe* 搜索。

(3) *Hu – Huang – Lu*(2010)非单调线搜索

寻找步长 $\lambda_k > 0$ 使得： $f(x^k + \lambda_k d^k) \leq C_k + \delta \lambda_k \nabla f(x^k)^T d^k$   
 $\nabla f(x^k + \lambda_k d^k)^T d^k \geq \sigma \nabla f(x^k)^T d^k$

其中, $0 < \delta < \sigma < 1$ ,  $C_k$ 按如下方式选取:

$$C_{k+1} = (\eta_k \sum_{i=1}^{m_k-1} \eta_{k-i} f(x^{k-i}) + f(x^k)) / Q_k \quad \text{且} \quad Q_k = \eta_k \sum_{i=1}^{m_k-1} \eta_{k-i} + 1,$$

其中 $\eta_k \in [\eta_{\min}, \eta_{\max}]$ 且 $0 \leq \eta_{\min} \leq \eta_{\max} \leq 1$ ,  $f(x^k) - C_k \leq \frac{\delta l_k |\nabla f(x^k)^T d^k|}{2}$

这里, 若 $\nabla f$ 是Lipschitz连续的, 则令 $l_k := \frac{(1-\sigma) |\nabla f(x^k)^T d^k|}{L \|d^k\|^2}$ ,

其中 $L$ 为Lipschitz常数; 否则, 令 $l_k := 0$

注1:  $C_k$ 是目前迭代点函数值和之前若干迭代点对应函数值的凸组合, 该方法综合使用了Grippo-Lampariello-Lucidi非单调线搜索和Zhang-Hager非单调线搜索的思想。

注2: 一个特例: 若 $\sum_{i=1}^{m_k-1} \eta_{k-i} f(x^{k-i}) \geq \sum_{i=1}^{m_k-1} \eta_{k-i} f(x^k)$ , 则选择 $\eta_k \in (0, 1]$ ;

否则, 选择 $\eta_k = 0$ 。因此, 每一步或者使用单调线搜索, 或者使用非单调线搜索, 是一种混合线搜索方法。

## 1.4.4 算法收敛性

1. 适定性(well-defined):如果算法的每一步是适定的, 则这个算法是适定的。
2. 算法是收敛的: 如果算法是有限终止的或所产生迭代点列 $\{x^k\}$ 的每个聚点是优化问题的最优解, 则称该算法是收敛的。
3. 全局收敛(globally convergent)、局部收敛(locally convergent):  
如果对于任意的初始点 $x^0$ , 算法是收敛的, 则称该算法是全局收敛的;  
如果只有初始点 $x^0$ 充分靠近最优解时, 算法是收敛的, 则称该算法是局部收敛的。

#### 4 收敛率(rate of convergence)

假设算法产生无穷点列 $\{x^k\}$ ,且算法收敛到最优解 $x^*$ ,不妨设 $\{x^k\}$ 收敛到 $x^*$ , 即 $\lim_{k \rightarrow \infty} \|x^k - x^*\| = 0$

##### (1) 全局 $Q$ -线性收敛:

如果算法初始迭代点的选取无关于最优解的信息, 且存在 $\beta \in (0, 1)$  使得: $\|x^{k+1} - x^*\| \leq \beta \|x^k - x^*\|, \forall k \in \{0, 1, 2, \dots\}$

则称该算法是全局 $Q$ -线性收敛的。

##### (2) 局部 $Q$ -收敛率:

如果存在 $\beta > 0, \zeta \geq 0$ 使得:  $\lim_{k \rightarrow \infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|^\beta} = \zeta$ , 则称该算法

是局部 $Q-\beta$ 阶收敛的。

如果存在 $\beta > 0, \zeta \geq 0$ 使得：
$$\lim_{k \rightarrow \infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|^\beta} = \zeta,$$
 则称该算法

是局部 $Q-\beta$ 阶收敛的。

注：特别的，

若 $\beta=1, \zeta \in (0,1)$ ，则该算法是局部 $Q$ -线性收敛的；

若 $\beta \in (1,2), \zeta > 0$ 或 $\beta=1, \zeta=0$ ，则称该算法是局部 $Q$ -超线性收敛的；

若 $\beta=2, \zeta > 0$ ，则称该算法是局部 $Q$ -二阶收敛的。