

NLP 总结

李宗军

青岛理工大学·理学院

2016 年





- 1 基本概念
- 2 凸规划
- 3 一维搜索问题
- 4 无约束最优化
 - 最速下降算法
 - Newton 法
 - 共轭方向法
- 5 约束最优化



NLP 总结

ljz

基本概念

凸规划

一维搜索问题

无约束最优化

约束最优化

- 1 NLP 模型
- 2 NLP 最优解定义
- 3 迭代算法框架



$\min f(x)$

$$\begin{cases} g(x) & \leq 0 \\ h(x) & = 0 \end{cases}$$

- 1 无约束
- 2 值含有等式约束
- 3 只含有不等式约束
- 4 两种约束都含有
- 5 线性规划是 NLP 的特殊情况



NLP 最优解的定义

- 1 局部最优解
- 2 严格局部最优解
- 3 全局最优解
- 4 严格全局最优解
- 5 说明：
 - 求解 NLP 就是获得全局最优解，但是难度太大
 - 可考虑先获得局部最优解，再在多个局部最优解中挑选最好的
 - 某些特殊的 NLP，例如凸规划，其局部最优解就是全局最优解，从而引出了图规划的研究

NLP 总结

ljz

基本概念

凸规划

一维搜索问题

无约束最优化

约束最优化



- 1 给定初始点 $x^0, k := 0$
- 2 停止计算条件
 - 一般由最优性条件构造，从而引出了各种 NLP 模型的最优性条件
- 3 迭代方向 p^k
 - 不同的产生方式导致了各种不同的算法
 - 必须遵守: 是可行下降方向
 - 下降方向必须满足 $-\nabla f(x^k)^T p^k \geq 0$
 - $p^k = -H\nabla f(x^k)$ 是一种一般的取法，其中 H 是半正定矩阵
 - 当 H 是单位矩阵时，就是最速下降法，当 H 是 f 的 Hessian 矩阵的逆矩阵时，就是 Newton 法,...
- 4 迭代步长: 一维搜索 (精确、非精确)
- 5 $k := k + 1$, 转向 2.



凸规划 I

① 凸集: $\forall \mathbf{x}_1, \mathbf{x}_2 \in S, \forall \lambda \in [0, 1], \lambda \mathbf{x}_1 + (1 - \lambda) \mathbf{x}_2 \in S$

② 凸函数

- 定义: $\forall \mathbf{x}_1, \mathbf{x}_2 \in S, \forall \lambda \in [0, 1], f(\lambda \mathbf{x}_1 + (1 - \lambda) \mathbf{x}_2) \leq \lambda f(\mathbf{x}_1) + (1 - \lambda) f(\mathbf{x}_2)$

- 性质:

- 凸函数的非负数乘仍凸
- 两个凸函数之和仍凸
- 两个凸函数之积不一定仍凸

- 判定

- 凸函数定义
- 判定定理 (梯度/导数, Hesse 矩阵/二阶导数)

③ 凸集与凸函数的关系定理: 凸函数的水平截集仍是凸集

④ 凸规划

NLP 总结

ljz

基本概念

凸规划

一维搜索问题

无约束最优化

约束最优化



- 1 定义： f 是凸函数，可行区域是凸集
- 2 性质：任意局部最优解都是全局最优解
- 3 判定：NLP 中非线性函数都是凸函数



- 1 问题模型及其背景
- 2 精确搜索算法:0.618,Newton
- 3 非精确算法
 - Goldstein:
 - $\varphi(t_k) \leq \varphi(0) + m_1\varphi'(0)t_k$
 - $\varphi(t_k) \geq \varphi(0) + m_2\varphi'(0)t_k$
 - Armijo:
 - $\varphi(t_k) \leq \varphi(0) + m\varphi'(0)t_k$
 - $\varphi(Mt_k) \geq \varphi(0) + m\varphi'(0)Mt_k$



- 1 问题模型
- 2 最优性条件
- 3 算法
 - 最速下降法
 - **Newton 法**
 - 共轭方向法 (共轭梯度法)



无约束最优性条件

NLP 总结

lj

基本概念

凸规划

一维搜索问题

无约束最优化

最速下降算法

Newton 法

共轭方向法

约束最优化

- 1 无约束最优化问题: $\min\{f(x)|x \in R^n\}$
- 2 最优性条件 (四个定理 4.4.1–4.4.4):
 - 下降方向的判定: $\nabla f(x)^T p < 0$
 - 局部最优解的必要条件: $\nabla f(x^*) = 0$
 - 局部最优解的充分条件: $\nabla f(x^*) = 0, \nabla^2 f(x^*)$ 正定
 - 凸规划的最优解的充要条件: $\nabla f(x^*) = 0$



① 算法思想

迭代方向采用 $-\nabla f(x^k)$, 步长采用精确的一维搜索算法。

② 最优性条件: $\nabla f(x^*) = 0$

③ 迭代终止条件: $\|\nabla f(x^k)\| \leq \varepsilon$

④ 初始点: 任意 x^0 都可以



- 1 init: 给定初始点 $x^0, k = 0, \varepsilon > 0$
- 2 若 $\|\nabla f(x^k)\| \leq \varepsilon$, 则输出近似解 x^k , stop; 否则转型下一步
- 3 取 $p^k = -\nabla f(x^k)$, 构造一维搜索问题
 $\min \varphi(t) = f(x^k + tp^k)$, 采用 0.618 法求解之, 得 t_k
- 4 $x^{k+1} = x^k + t_k p^k, k := k + 1$, 转向步骤 2.



- ① 具有全局收敛性
- ② 每次迭代，计算量较小
- ③ 迭代速度较慢
- ④ 改进：用非精确搜索代替精确搜索



1 算法思想

$$\begin{aligned}f(x) &\approx f(x^k) + \nabla f(x^k)^T(x - x^k) + \frac{1}{2}(x - x^k)^T \nabla^2 f(x^k)(x - x^k) \\ &= g(x)\end{aligned}$$

let $\nabla g(x) = 0$, 解得 $x^{k+1} = x^k - \nabla^2 f(x^k)^{-1} \nabla f(x^k)$

2 Newton 法迭代步骤

- 1 **init:** 给定充分靠近最优解的初始点 x^0 , 误差 $\varepsilon > 0$, $k = 0$
- 2 若 $\|\nabla f(x^k)^T\| \leq \varepsilon$, 则输出 x^k , stop
- 3 $x^{k+1} = x^k - [\nabla^2 f(x^k)]^{-1} \nabla f(x^k)$
- 4 $k = k + 1$, 转向步骤 2.



Newton 法特点

NLP 总结

lj

基本概念

凸规划

一维搜索问题

无约束最优化

最速下降算法

Newton 法

共轭方向法

约束最优化

同一维搜索的 Newton 法

- ① 具有局部收敛性
- ② 只有当初始点充分靠近最优解时，才能保证算法的收敛性
 - ① 改进： $x^{k+1} = x^k - t_k [\nabla^2 f(x^k)]^{-1} \nabla f(x^k)$, t_k 采用一维搜索
 - ② 即迭代方向 $p^k = - [\nabla^2 f(x^k)]^{-1} \nabla f(x^k)$
- ③ 具有二阶收敛速度
- ④ 每次迭代步的计算量较大： $[\nabla^2 f(x^k)]^{-1}$



简介:

- 1 计算量介于最速下降法和 **Newton** 法之间
- 2 为二次规划设计的
- 3 调整后, 可适用于非线性规划, 依据是在最优解附近, 非线性函数近似于二次函数
- 4 迭代方向采用共轭方向
- 5 步长采用精确一维搜索



- 1 共轭方向: $p, q \neq 0, p^T A q = 0$, 其中 A 是实对称矩阵。
 - 注: 正交是共轭的特殊情况。
- 2 共轭方向组: 对 p^1, \dots, p^n 中的任何两个不同的向量, 满足 $(p^i)^T A p^j = 0, i \neq j$
- 3 共轭方向组的性质
 - 共轭方向组是线性无关组 (Th4.4.5)



共轭方向法定理

对二次严格凸函数 $\min f(x) = \frac{1}{2}x^T Ax + b^T x$, 其中 A 是 n 阶实对称正定矩阵:

依次沿着任意一组共轭方向: p^1, \dots, p^n , 采用精确一维搜索, 则最多经过 n 轮迭代就可获得整体最优解。

NLP 总结

|zj

基本概念

凸规划

一维搜索问题

无约束最优化

最速下降算法

Newton 法

共轭方向法

约束最优化

迭代步骤



- 1 给定 $x^0, \varepsilon > 0$
- 2 计算 $\nabla f(x^k)$, 若 $\|\nabla f(x^k)\| \leq \varepsilon$, stop, 输出 x^k
- 3 令 $k = 0, p^k = -\nabla f(x^k)$
- 4 采用一维搜索, 求解 $\min \varphi(t) = f(x^k + t p^k)$, 解得 t_k .
- 5 $x^{k+1} = x^k + t_k p^k, k++$
- 6 While $k \leq n$:
 - 1 若 $\nabla f(x^k)$, 若 $\|\nabla f(x^k)\| \leq \varepsilon$, stop, 输出 x^k
 - 2 $\lambda_k = \frac{\|\nabla f(x^k)\|^2}{\|p^k\|^2}, p^{k+1} = -\nabla f(x^k) + \lambda_k p^k$
 - 3 采用一维搜索, 求解 $\min \varphi(t) = f(x^k + t p^{k+1})$, 解得 $t_k, x^{k+1} = x^k + t_k p^{k+1}$
 - 4 $k++$
- 7 转向步骤 2.

NLP 总结

ljz

基本概念

凸规划

一维搜索问题

无约束最优化

最速下降算法

Newton 法

共轭方向法

约束最优化



- 1 约束最优化模型
- 2 最优性条件：K-T 条件
- 3 算法
 - 简约梯度法
 - 罚函数法
 - 内点障碍函数法



K-T 条件 I

NLP 总结

|zj

基本概念

凸规划

一维搜索问题

无约束最优化

约束最优化

$$\nabla f(x) + \sum_{i \in I(x^*)} \lambda_i \nabla g_i(x) + \sum_{j \in J} u_j \nabla h_j(x) = 0, \lambda_i \geq 0, i \in I$$

等价于

$$\begin{aligned} \nabla f(x) + \sum_{i \in I} \lambda_i \nabla g_i(x) + \sum_{j \in J} u_j \nabla h_j(x) &= 0 \\ \lambda_i g_i(x) &= 0, i \in I \\ \lambda_i &\geq 0, i \in I \end{aligned} \quad (1)$$

其中 $\lambda_i g_i(x) = 0$ 称为互补松紧条件。



- 1 K-T 条件是 NLP 最优解的必要条件!
- 2 凸规划的充要条件：定理 4.5.2
- 3 K-T 条件的作用是：把最优化问题，转换为方程组问题，然后运用方程组的求解理论方法来解决。
- 4 注意：K-T 条件适用于 LP 问题（熟练写出 LP 三种模型的 K-T 条件）



简约梯度法

1 考虑的问题

$$\begin{aligned} \min & f(x) \\ \text{st.} & \begin{cases} Ax = b \\ x \geq 0 \end{cases} \end{aligned}$$

2 算法思想

仿照 LP 中的单纯形法，在每一轮迭代的当前点 x^k 处，把 x^k 分为基变量部分和非基变量部分，则 $f(x) = F(x_N)$ ，采用 $F(x_N)$ 的负梯度方向构造可行下降方向 p ，迭代步长采用一维搜索方法。

定理 4.5.3



NLP 总结

lzt

基本概念

凸规划

一维搜索问题

无约束最优化

约束最优化

- 1 若 $p \neq 0$, 则 p 是 $f(x)$ 在 x^k 处的可行下降方向;
- 2 $p = 0$ 的充要条件是 x^k 是 K-T 点。



迭代步骤 I

- ① 算法初始化, 给定初始点 $x^0, \varepsilon > 0, k := 0$
- ② 设 I_B^k 是 x^k 的 m 个最大分量的下标集, 对矩阵 A 进行分解 $A = (B_k, N_k)$
- ③ 计算 $\nabla f(x^k) = (\nabla_B f(x^k), \nabla_N f(x^k))^T$, 然后计算简约梯度 $r_N^k = (B_k^{-1} N_k)^T \nabla_B f(x^k) - \nabla_N f(x^k)$. 记 r_N^k 的第 i 个分量为 r_i^k
- ④ 构造 $p^k = (p_B^k, p_N^k)^T$, 其中

$$p_N^k = (p_i^k) = \begin{cases} r_i^k, & r_i^k \leq 0 \\ x_i^k r_i^k, & r_i^k > 0 \end{cases}, p_B^k = -B_k^{-1} N_k p_N^k. \text{ 若 } \|p^k\| \leq \varepsilon,$$

停止迭代, 输出 x^k .

- ⑤ 采用一维搜索, 求解 $\min \{f(x^k + tp^k) \mid 0 \leq t \leq t_{\max}^k\}$, 得

$$\text{到最优解 } t_k, \text{ 其中 } t_{\max}^k = \begin{cases} +\infty, & p^k \geq 0 \\ \min \left\{ -\frac{x_i^k}{p_i^k} \mid p_i^k < 0 \right\}, & \text{else} \end{cases}$$



NLP 总结

ljz

基本概念

凸规划

一维搜索问题

无约束最优化

约束最优化

⑥ $x^{k+1} = x^k + t_k p^k, k := k + 1$, 转向 2.



- 1 数值实验表明：对于大规模的线性约束的 NLP，简约梯度法是最好的
- 2 对约束最优化而言，迭代方向必须是可行下降方向，此类算法统称为可行下降算法。
- 3 由定理 4.5.3 ($p^k = 0$ 的充要条件是 x^k 是 K-T 点。)，从而迭代终止条件采用简单的 $\|p^k\| \leq \varepsilon$ ，而不是采用复杂的 K-T 条件。
- 4 初始点，可采用 LP 中的两阶段法获得。



1 算法思想

利用问题中的约束，构造适当的带有参数的惩罚函数，然后在转移到原来的目标函数上，以构造增广目标函数，把约束 NLP 问题转化为求解一系列无约束 NLP 问题。

2 序列无约束极小化方法

这种把约束 NLP 的求解转换为一系列无约束优化问题求解的方法，统称为序列无约束极小化方法。

3 增广函数构造

构造增广函数： $F(x) = f(x) + M_k p(x)$



- 1 基本概念
- 2 凸规划
- 3 一维搜索问题
- 4 无约束最优化
 - 最速下降算法
 - **Newton 法**
 - 共轭方向法
- 5 约束最优化



NLP 总结

lzh

基本概念

凸规划

一维搜索问题

无约束最优化

约束最优化

- 1 基本概念
- 2 凸规划
- 3 一维搜索问题
- 4 无约束最优化
 - 最速下降算法
 - **Newton 法**
 - 共轭方向法
- 5 约束最优化