



最优化方法

东南大学

计算机&人工智能学院

宋沫飞

songmf@seu.edu.cn



无约束优化



- 术语和假设
- 梯度下降法
- 最速下降法
- Newton**法
- 自和谐
- 实现

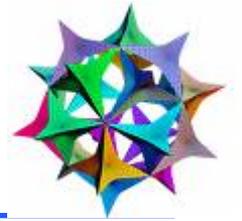


无约束优化





无约束优化



minimize $f(x)$



无约束优化



minimize $f(x)$

- 函数为凸函数，二次连续可微



无约束优化



minimize $f(x)$

- 函数为凸函数，二次连续可微
- 假设最优值 $p^* = \inf_x f(x)$ 存在且为有限值



无约束优化



$$\text{minimize } f(x)$$

- 函数为凸函数，二次连续可微
- 假设最优值 $p^* = \inf_x f(x)$ 存在且为有限值
- 无约束优化方法



无约束优化



$$\text{minimize } f(x)$$

- 函数为凸函数，二次连续可微
- 假设最优值 $p^* = \inf_x f(x)$ 存在且为有限值
- 无约束优化方法
 - 产生点序列 $x^{(k)} \in \text{dom } f, k = 0, 1, \dots$ 其中



无约束优化



$$\text{minimize } f(x)$$

- 函数为凸函数，二次连续可微
- 假设最优值 $p^* = \inf_x f(x)$ 存在且为有限值
- 无约束优化方法
 - 产生点序列 $x^{(k)} \in \text{dom } f, k = 0, 1, \dots$ 其中
$$f(x^{(k)}) \rightarrow p^*$$



无约束优化

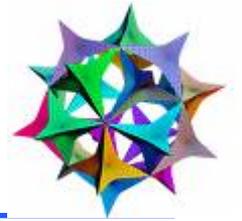


$$\text{minimize } f(x)$$

- 函数为凸函数，二次连续可微
- 假设最优值 $p^* = \inf_x f(x)$ 存在且为有限值
- 无约束优化方法
 - 产生点序列 $x^{(k)} \in \text{dom } f, k = 0, 1, \dots$ 其中
$$f(x^{(k)}) \rightarrow p^*$$
- 通过迭代算法求解满足最优化条件的方程



无约束优化



$$\text{minimize } f(x)$$

- 函数为凸函数，二次连续可微
- 假设最优值 $p^* = \inf_x f(x)$ 存在且为有限值
- 无约束优化方法
 - 产生点序列 $x^{(k)} \in \text{dom } f, k = 0, 1, \dots$ 其中
$$f(x^{(k)}) \rightarrow p^*$$
- 通过迭代算法求解满足最优化条件的方程

$$\nabla f(x^*) = 0$$



初始点和下水平集





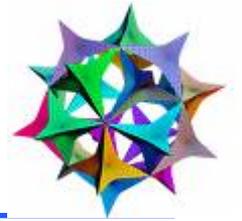
初始点和下水平集



- 本章算法需要一个初始点 $x^{(0)}$ 满足



初始点和下水平集



- 本章算法需要一个初始点 $x^{(0)}$ 满足
 $x^{(0)} \in \mathbf{dom} f$



初始点和下水平集



- 本章算法需要一个初始点 $x^{(0)}$ 满足
$$x^{(0)} \in \mathbf{dom} f$$
- 下水平集 $S = \{x \mid f(x) \leq f(x^{(0)})\}$ 为闭集



初始点和下水平集



- 本章算法需要一个初始点 $x^{(0)}$ 满足
$$x^{(0)} \in \mathbf{dom} f$$
- 下水平集 $S = \{x \mid f(x) \leq f(x^{(0)})\}$ 为闭集
- 条件**2**较难验证，除非所有的下水平集是闭集：



初始点和下水平集



- 本章算法需要一个初始点 $x^{(0)}$ 满足
$$x^{(0)} \in \mathbf{dom} f$$
- 下水平集 $S = \{x \mid f(x) \leq f(x^{(0)})\}$ 为闭集
- 条件**2**较难验证，除非所有的下水平集是闭集：
 - 等价于 $\mathbf{epi} f$ 是闭的



初始点和下水平集



- 本章算法需要一个初始点 $x^{(0)}$ 满足
$$x^{(0)} \in \mathbf{dom} f$$
- 下水平集 $S = \{x \mid f(x) \leq f(x^{(0)})\}$ 为闭集
- 条件**2**较难验证，除非所有的下水平集是闭集：
 - 等价于 $\mathbf{epi} f$ 是闭的
 - 若 $\mathbf{dom} f = \mathbf{R}^n$ ，则为真



初始点和下水平集



- 本章算法需要一个初始点 $x^{(0)}$ 满足
$$x^{(0)} \in \mathbf{dom} f$$
- 下水平集 $S = \{x \mid f(x) \leq f(x^{(0)})\}$ 为闭集
- 条件**2**较难验证，除非所有的下水平集是闭集：
 - 等价于 $\mathbf{epi} f$ 是闭的
 - 若 $\mathbf{dom} f = \mathbf{R}^n$ ，则为真
 - 若 $f(x) \rightarrow \infty$ as $x \rightarrow \mathbf{bd} \mathbf{dom} f$ ，则为真



初始点和下水平集



- 本章算法需要一个初始点 $x^{(0)}$ 满足
$$x^{(0)} \in \mathbf{dom} f$$
- 下水平集 $S = \{x \mid f(x) \leq f(x^{(0)})\}$ 为闭集
- 条件**2**较难验证，除非所有的下水平集是闭集：
 - 等价于 $\mathbf{epi} f$ 是闭的
 - 若 $\mathbf{dom} f = \mathbf{R}^n$ ，则为真
 - 若 $f(x) \rightarrow \infty$ as $x \rightarrow \mathbf{bd} \mathbf{dom} f$ ，则为真
- 不同带有闭的下水平集的可微函数



初始点和下水平集



- 本章算法需要一个初始点 $x^{(0)}$ 满足
$$x^{(0)} \in \mathbf{dom} f$$
- 下水平集 $S = \{x \mid f(x) \leq f(x^{(0)})\}$ 为闭集
- 条件**2**较难验证，除非所有的下水平集是闭集：
 - 等价于 $\mathbf{epi} f$ 是闭的
 - 若 $\mathbf{dom} f = \mathbf{R}^n$ ，则为真
 - 若 $f(x) \rightarrow \infty$ as $x \rightarrow \mathbf{bd} \mathbf{dom} f$ ，则为真
- 不同带有闭的下水平集的可微函数
$$f(x) = \log\left(\sum_{i=1}^m \exp(a_i^T x + b_i)\right), \quad f(x) = -\sum_{i=1}^m \log(b_i - a_i^T x)$$



强凸性及其含义





强凸性及其含义



□ 目标函数在 S 上强凸的，指存在 $m > 0$ ，满足



强凸性及其含义



- 目标函数在 S 上强凸的，指存在 $m > 0$ ，满足
- $$\nabla^2 f(x) \succeq mI \quad \text{for all } x \in S$$



强凸性及其含义



□ 目标函数在 S 上强凸的，指存在 $m > 0$ ，满足

$$\nabla^2 f(x) \succeq mI \quad \text{for all } x \in S$$

□ 对 $x, y \in S$,



强凸性及其含义



□ 目标函数在 S 上强凸的，指存在 $m > 0$ ，满足

$$\nabla^2 f(x) \succeq mI \quad \text{for all } x \in S$$

□ 对 $x, y \in S$,

$$f(y) \geq f(x) + \nabla f(x)^T (y - x) + \frac{m}{2} \|x - y\|_2^2$$



强凸性及其含义



□ 目标函数在 S 上强凸的，指存在 $m > 0$ ，满足

$$\nabla^2 f(x) \succeq mI \quad \text{for all } x \in S$$

□ 对 $x, y \in S$,

$$f(y) \geq f(x) + \nabla f(x)^T (y - x) + \frac{m}{2} \|x - y\|_2^2$$

□ $p^* > -\infty$ ，且对 $x \in S$,



强凸性及其含义



□ 目标函数在 S 上强凸的，指存在 $m > 0$ ，满足

$$\nabla^2 f(x) \succeq mI \quad \text{for all } x \in S$$

□ 对 $x, y \in S$,

$$f(y) \geq f(x) + \nabla f(x)^T (y - x) + \frac{m}{2} \|x - y\|_2^2$$

□ $p^* > -\infty$ ，且对 $x \in S$,

$$f(x) - p^* \leq \frac{1}{2m} \|\nabla f(x)\|_2^2$$



强凸性及其含义



□ 目标函数在 S 上强凸的，指存在 $m > 0$ ，满足

$$\nabla^2 f(x) \succeq mI \quad \text{for all } x \in S$$

□ 对 $x, y \in S$,

$$f(y) \geq f(x) + \nabla f(x)^T (y - x) + \frac{m}{2} \|x - y\|_2^2$$

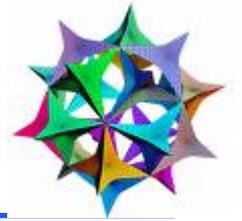
□ $p^* > -\infty$ ，且对 $x \in S$,

$$f(x) - p^* \leq \frac{1}{2m} \|\nabla f(x)\|_2^2$$

□ 作为停止条件十分有用（若 m 已知）



下降方法





下降方法



$$x^{(k+1)} = x^{(k)} + t^{(k)} \Delta x^{(k)} \quad \text{with } f(x^{(k+1)}) < f(x^{(k)})$$



下降方法



$$x^{(k+1)} = x^{(k)} + t^{(k)} \Delta x^{(k)} \quad \text{with } f(x^{(k+1)}) < f(x^{(k)})$$

□ 其他表示方法: $x^+ = x + t\Delta x$, $x := x + t\Delta x$



下降方法



$$x^{(k+1)} = x^{(k)} + t^{(k)} \Delta x^{(k)} \quad \text{with } f(x^{(k+1)}) < f(x^{(k)})$$

- 其他表示方法: $x^+ = x + t\Delta x$, $x := x + t\Delta x$
- Δx 为步径或搜索方向; t 为步长



下降方法



$$x^{(k+1)} = x^{(k)} + t^{(k)} \Delta x^{(k)} \quad \text{with } f(x^{(k+1)}) < f(x^{(k)})$$

- 其他表示方法: $x^+ = x + t\Delta x$, $x := x + t\Delta x$
- Δx 为步径或搜索方向; t 为步长
- 根据凸性, $f(x^+) < f(x)$ 则 $\nabla f(x)^T \Delta x < 0$, Δx 为下降方向



下降方法



$$x^{(k+1)} = x^{(k)} + t^{(k)} \Delta x^{(k)} \quad \text{with } f(x^{(k+1)}) < f(x^{(k)})$$

- 其他表示方法: $x^+ = x + t\Delta x$, $x := x + t\Delta x$
- Δx 为步径或搜索方向; t 为步长
- 根据凸性, $f(x^+) < f(x)$ 则 $\nabla f(x)^T \Delta x < 0$, Δx 为下降方向

算法 9.1 通用下降方法。

给定 初始点 $x \in \text{dom } f$ 。

重复进行

1. 确定下降方向 Δx 。
2. 直线搜索。选择步长 $t > 0$ 。
3. 修改。 $x := x + t\Delta x$ 。

直到 满足停止准则。



直线搜索





直线搜索



□ 精确搜索: $t = \operatorname{argmin}_{t>0} f(x + t\Delta x)$



直线搜索



- 精确搜索: $t = \operatorname{argmin}_{t>0} f(x + t\Delta x)$
- 回溯直线搜索 (参数为 $\alpha \in (0, 1/2)$, $\beta \in (0, 1)$)



直线搜索



- 精确搜索: $t = \operatorname{argmin}_{t>0} f(x + t\Delta x)$
- 回溯直线搜索 (参数为 $\alpha \in (0, 1/2)$, $\beta \in (0, 1)$)
- 从 $t = 1$ 开始, 反复执行 $t := \beta t$ 直到



直线搜索



- 精确搜索: $t = \operatorname{argmin}_{t>0} f(x + t\Delta x)$
- 回溯直线搜索 (参数为 $\alpha \in (0, 1/2)$, $\beta \in (0, 1)$)
- 从 $t = 1$ 开始, 反复执行 $t := \beta t$ 直到
$$f(x + t\Delta x) < f(x) + \alpha t \nabla f(x)^T \Delta x$$



直线搜索



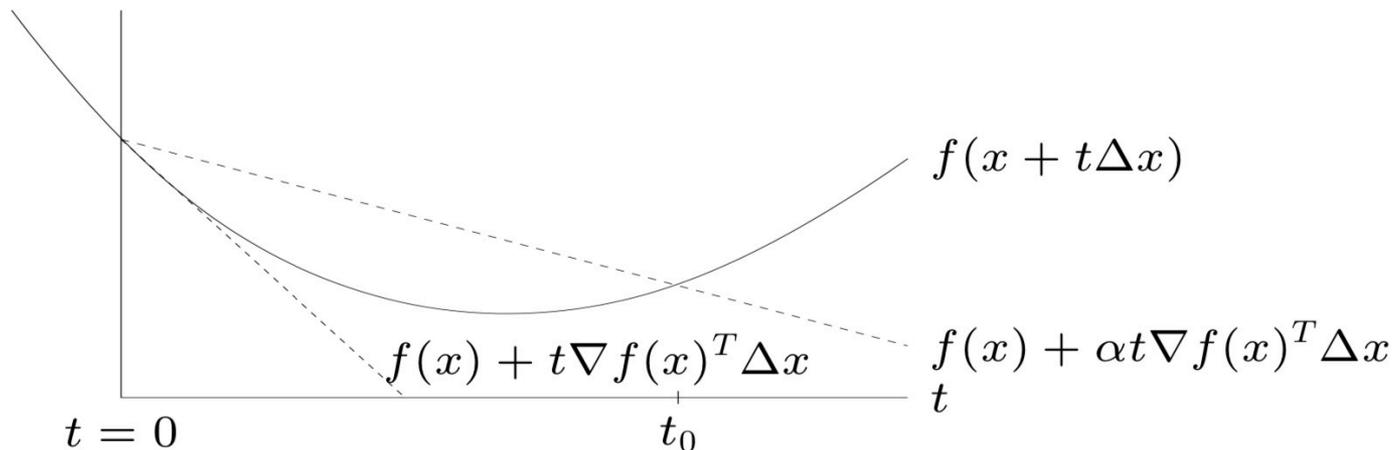
- 精确搜索: $t = \operatorname{argmin}_{t>0} f(x + t\Delta x)$
- 回溯直线搜索 (参数为 $\alpha \in (0, 1/2)$, $\beta \in (0, 1)$)
- 从 $t = 1$ 开始, 反复执行 $t := \beta t$ 直到
$$f(x + t\Delta x) < f(x) + \alpha t \nabla f(x)^T \Delta x$$
- 图例说明: 回溯到 $t \leq t_0$



直线搜索



- 精确搜索: $t = \operatorname{argmin}_{t>0} f(x + t\Delta x)$
- 回溯直线搜索 (参数为 $\alpha \in (0, 1/2)$, $\beta \in (0, 1)$)
- 从 $t = 1$ 开始, 反复执行 $t := \beta t$ 直到
$$f(x + t\Delta x) < f(x) + \alpha t \nabla f(x)^T \Delta x$$
- 图例说明: 回溯到 $t \leq t_0$





梯度下降法





梯度下降法



□ 梯度下降法，其中 $\Delta x = -\nabla f(x)$



梯度下降法



□ 梯度下降法，其中 $\Delta x = -\nabla f(x)$

算法 9.3 梯度下降方法。

给定 初始点 $x \in \text{dom } f$ 。

重复进行

1. $\Delta x := -\nabla f(x)$ 。
2. 直线搜索。通过精确或回溯直线搜索方法确定步长 t 。
3. 修改。 $x := x + t\Delta x$ 。

直到 满足停止准则。



梯度下降法



□ 梯度下降法，其中 $\Delta x = -\nabla f(x)$

算法 9.3 梯度下降方法。

给定 初始点 $x \in \text{dom } f$ 。

重复进行

1. $\Delta x := -\nabla f(x)$ 。
2. 直线搜索。通过精确或回溯直线搜索方法确定步长 t 。
3. 修改。 $x := x + t\Delta x$ 。

直到 满足停止准则。

□ 停止条件：通常形如 $\|\nabla f(x)\|_2 \leq \epsilon$



梯度下降法



□ 梯度下降法，其中 $\Delta x = -\nabla f(x)$

算法 9.3 梯度下降方法。

给定 初始点 $x \in \text{dom } f$ 。

重复进行

1. $\Delta x := -\nabla f(x)$ 。
2. 直线搜索。通过精确或回溯直线搜索方法确定步长 t 。
3. 修改。 $x := x + t\Delta x$ 。

直到 满足停止准则。

□ 停止条件：通常形如 $\|\nabla f(x)\|_2 \leq \epsilon$

□ 收敛结果：对强凸函数 f , $f(x^{(k)}) - p^* \leq c^k (f(x^{(0)}) - p^*)$



梯度下降法



□ 梯度下降法，其中 $\Delta x = -\nabla f(x)$

算法 9.3 梯度下降方法。

给定 初始点 $x \in \text{dom } f$ 。

重复进行

1. $\Delta x := -\nabla f(x)$ 。
2. 直线搜索。通过精确或回溯直线搜索方法确定步长 t 。
3. 修改。 $x := x + t\Delta x$ 。

直到 满足停止准则。

□ 停止条件：通常形如 $\|\nabla f(x)\|_2 \leq \epsilon$

□ 收敛结果：对强凸函数 f , $f(x^{(k)}) - p^* \leq c^k (f(x^{(0)}) - p^*)$

□ $c \in (0, 1)$ 取决于 m , $x^{(0)}$, 直线搜索类型



梯度下降法



□ 梯度下降法，其中 $\Delta x = -\nabla f(x)$

算法 9.3 梯度下降方法。

给定 初始点 $x \in \text{dom } f$ 。

重复进行

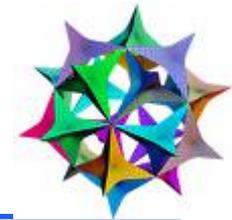
1. $\Delta x := -\nabla f(x)$ 。
2. 直线搜索。通过精确或回溯直线搜索方法确定步长 t 。
3. 修改。 $x := x + t\Delta x$ 。

直到 满足停止准则。

- 停止条件：通常形如 $\|\nabla f(x)\|_2 \leq \epsilon$
- 收敛结果：对强凸函数 f , $f(x^{(k)}) - p^* \leq c^k (f(x^{(0)}) - p^*)$
- $c \in (0, 1)$ 取决于 m , $x^{(0)}$, 直线搜索类型
- 非常简单，但通常较慢；实际中很少使用

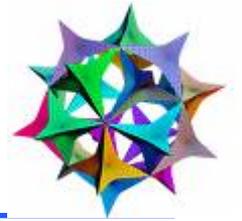


R^2 空间中的二次问题





R^2 空间中的二次问题



$$f(x) = (1/2)(x_1^2 + \gamma x_2^2) \quad (\gamma > 0)$$



R^2 空间中的二次问题



$$f(x) = (1/2)(x_1^2 + \gamma x_2^2) \quad (\gamma > 0)$$

□ 进行精确直线搜索，起始点为 $x^{(0)} = (\gamma, 1)$:



R^2 空间中的二次问题



$$f(x) = (1/2)(x_1^2 + \gamma x_2^2) \quad (\gamma > 0)$$

□ 进行精确直线搜索，起始点为 $x^{(0)} = (\gamma, 1)$:

$$x_1^{(k)} = \gamma \left(\frac{\gamma - 1}{\gamma + 1} \right)^k, \quad x_2^{(k)} = \left(-\frac{\gamma - 1}{\gamma + 1} \right)^k$$



R^2 空间中的二次问题



$$f(x) = (1/2)(x_1^2 + \gamma x_2^2) \quad (\gamma > 0)$$

□ 进行精确直线搜索，起始点为 $x^{(0)} = (\gamma, 1)$:

$$x_1^{(k)} = \gamma \left(\frac{\gamma - 1}{\gamma + 1} \right)^k, \quad x_2^{(k)} = \left(-\frac{\gamma - 1}{\gamma + 1} \right)^k$$

□ 若 $\gamma \gg 1$ or $\gamma \ll 1$ ，速度非常慢



R^2 空间中的二次问题



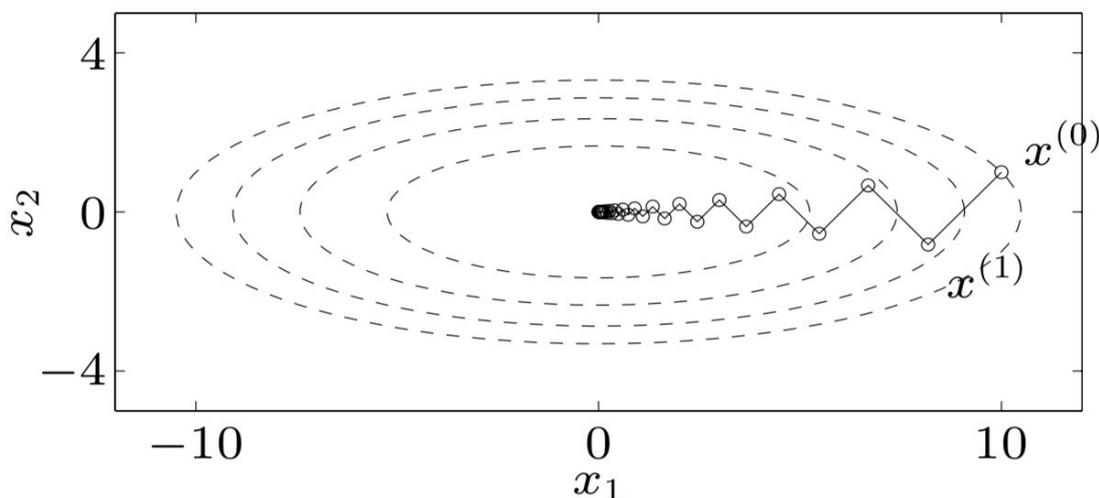
$$f(x) = (1/2)(x_1^2 + \gamma x_2^2) \quad (\gamma > 0)$$

□ 进行精确直线搜索，起始点为 $x^{(0)} = (\gamma, 1)$:

$$x_1^{(k)} = \gamma \left(\frac{\gamma - 1}{\gamma + 1} \right)^k, \quad x_2^{(k)} = \left(-\frac{\gamma - 1}{\gamma + 1} \right)^k$$

□ 若 $\gamma \gg 1$ or $\gamma \ll 1$ ，速度非常慢

□ $\gamma = 10$

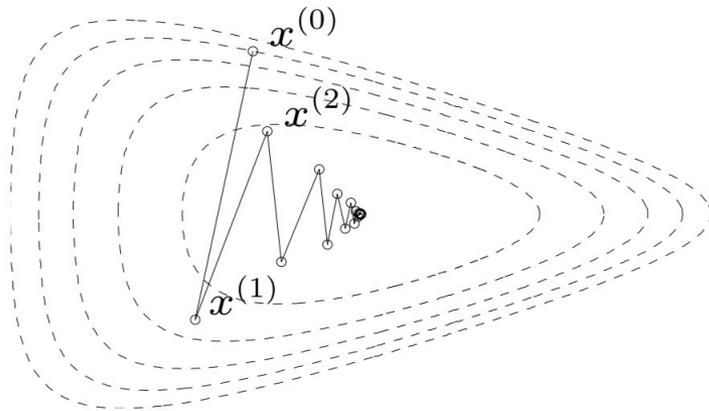




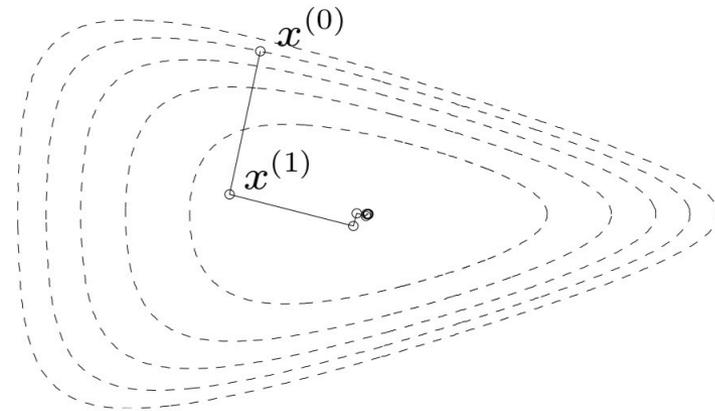
非二次型问题



$$f(x_1, x_2) = e^{x_1+3x_2-0.1} + e^{x_1-3x_2-0.1} + e^{-x_1-0.1}$$



回溯直线搜索



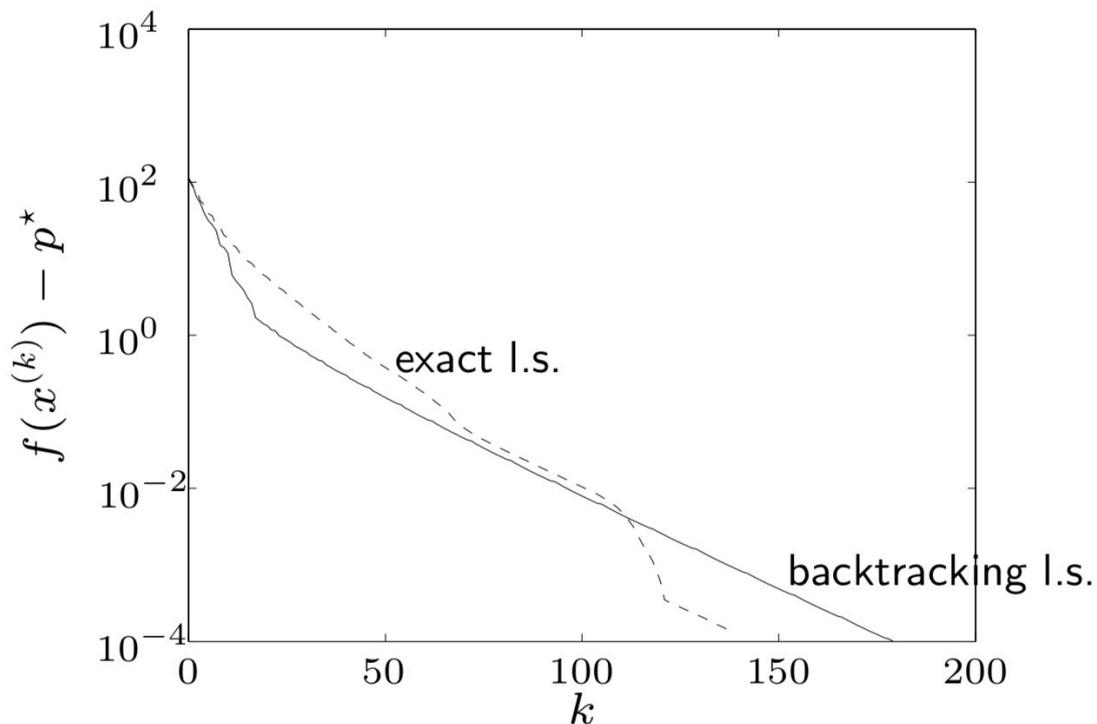
精确直线搜索



R^{100} 空间中的问题



$$f(x) = c^T x - \sum_{i=1}^{500} \log(b_i - a_i^T x)$$



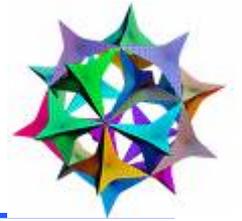


最速下降法





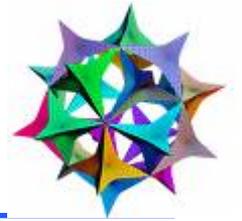
最速下降法



- 规范化的最速下降方向（相对于范数 $\|\cdot\|$ ）：



最速下降法

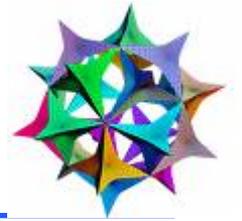


□ 规范化的最速下降方向（相对于范数 $\|\cdot\|$ ）：

$$\Delta x_{\text{nsd}} = \operatorname{argmin}\{\nabla f(x)^T v \mid \|v\| = 1\}$$



最速下降法



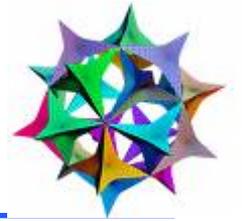
- 规范化的最速下降方向（相对于范数 $\|\cdot\|$ ）：

$$\Delta x_{\text{nsd}} = \operatorname{argmin}\{\nabla f(x)^T v \mid \|v\| = 1\}$$

- 解释：对较小的 v ，有 $f(x+v) \approx f(x) + \nabla f(x)^T v$



最速下降法



- 规范化的最速下降方向（相对于范数 $\|\cdot\|$ ）：

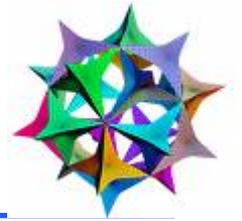
$$\Delta x_{\text{nsd}} = \operatorname{argmin}\{\nabla f(x)^T v \mid \|v\| = 1\}$$

- 解释：对较小的 v ，有 $f(x+v) \approx f(x) + \nabla f(x)^T v$

- 搜索方向 Δx_{nsd} 是具有最大线性下降的单位范数的步径



最速下降法



- 规范化的最速下降方向（相对于范数 $\|\cdot\|$ ）：

$$\Delta x_{\text{nsd}} = \operatorname{argmin}\{\nabla f(x)^T v \mid \|v\| = 1\}$$

- 解释：对较小的 v ，有 $f(x+v) \approx f(x) + \nabla f(x)^T v$
- 搜索方向 Δx_{nsd} 是具有最大线性下降的单位范数的步径
- 非规范化的最速下降方向



最速下降法



- 规范化的最速下降方向（相对于范数 $\|\cdot\|$ ）：

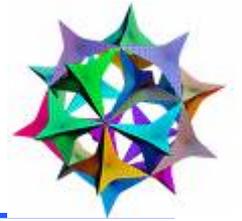
$$\Delta x_{\text{nsd}} = \operatorname{argmin}\{\nabla f(x)^T v \mid \|v\| = 1\}$$

- 解释：对较小的 v ，有 $f(x+v) \approx f(x) + \nabla f(x)^T v$
- 搜索方向 Δx_{nsd} 是具有最大线性下降的单位范数的步径
- 非规范化的最速下降方向

$$\Delta x_{\text{sd}} = \|\nabla f(x)\|_* \Delta x_{\text{nsd}}$$



最速下降法



- 规范化的最速下降方向（相对于范数 $\|\cdot\|$ ）：

$$\Delta x_{\text{nsd}} = \operatorname{argmin}\{\nabla f(x)^T v \mid \|v\| = 1\}$$

- 解释：对较小的 v ，有 $f(x+v) \approx f(x) + \nabla f(x)^T v$

- 搜索方向 Δx_{nsd} 是具有最大线性下降的单位范数的步径

- 非规范化的最速下降方向

$$\Delta x_{\text{sd}} = \|\nabla f(x)\|_* \Delta x_{\text{nsd}}$$

- 满足 $\nabla f(x)^T \Delta x_{\text{sd}} = -\|\nabla f(x)\|_*^2$



最速下降法



- 规范化的最速下降方向（相对于范数 $\|\cdot\|$ ）：

$$\Delta x_{\text{nsd}} = \operatorname{argmin}\{\nabla f(x)^T v \mid \|v\| = 1\}$$

- 解释：对较小的 v ，有 $f(x+v) \approx f(x) + \nabla f(x)^T v$
- 搜索方向 Δx_{nsd} 是具有最大线性下降的单位范数的步径
- 非规范化的最速下降方向

$$\Delta x_{\text{sd}} = \|\nabla f(x)\|_* \Delta x_{\text{nsd}}$$

- 满足 $\nabla f(x)^T \Delta x_{\text{sd}} = -\|\nabla f(x)\|_*^2$
- 最速下降法



最速下降法



- 规范化的最速下降方向（相对于范数 $\|\cdot\|$ ）：

$$\Delta x_{\text{nsd}} = \operatorname{argmin}\{\nabla f(x)^T v \mid \|v\| = 1\}$$

- 解释：对较小的 v ，有 $f(x+v) \approx f(x) + \nabla f(x)^T v$

- 搜索方向 Δx_{nsd} 是具有最大线性下降的单位范数的步径

- 非规范化的最速下降方向

$$\Delta x_{\text{sd}} = \|\nabla f(x)\|_* \Delta x_{\text{nsd}}$$

- 满足 $\nabla f(x)^T \Delta x_{\text{sd}} = -\|\nabla f(x)\|_*^2$

- 最速下降法

- 通用下降法 $\Delta x = \Delta x_{\text{sd}}$



最速下降法



- 规范化的最速下降方向（相对于范数 $\|\cdot\|$ ）：

$$\Delta x_{\text{nsd}} = \operatorname{argmin}\{\nabla f(x)^T v \mid \|v\| = 1\}$$

- 解释：对较小的 v ，有 $f(x+v) \approx f(x) + \nabla f(x)^T v$

- 搜索方向 Δx_{nsd} 是具有最大线性下降的单位范数的步径

- 非规范化的最速下降方向

$$\Delta x_{\text{sd}} = \|\nabla f(x)\|_* \Delta x_{\text{nsd}}$$

- 满足 $\nabla f(x)^T \Delta x_{\text{sd}} = -\|\nabla f(x)\|_*^2$

- 最速下降法

- 通用下降法 $\Delta x = \Delta x_{\text{sd}}$

- 收敛特性和梯度下降一致



例





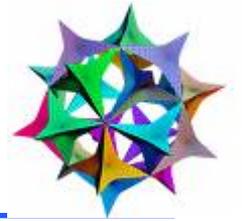
例



□ 欧式范数: $\Delta x_{\text{sd}} = -\nabla f(x)$



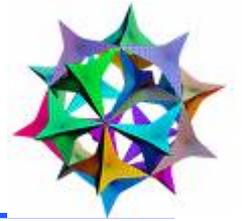
例



- 欧式范数: $\Delta x_{\text{sd}} = -\nabla f(x)$
- 二次范数 $\|x\|_P = (x^T P x)^{1/2}$ ($P \in \mathbf{S}_{++}^n$): $\Delta x_{\text{sd}} = -P^{-1} \nabla f(x)$



例



- 欧式范数: $\Delta x_{\text{sd}} = -\nabla f(x)$
- 二次范数 $\|x\|_P = (x^T P x)^{1/2}$ ($P \in \mathbf{S}_{++}^n$): $\Delta x_{\text{sd}} = -P^{-1} \nabla f(x)$
- ℓ_1 -范数 $\Delta x_{\text{sd}} = -(\partial f(x)/\partial x_i) e_i$, where $|\partial f(x)/\partial x_i| = \|\nabla f(x)\|_\infty$



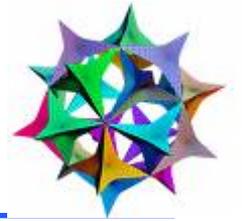
例



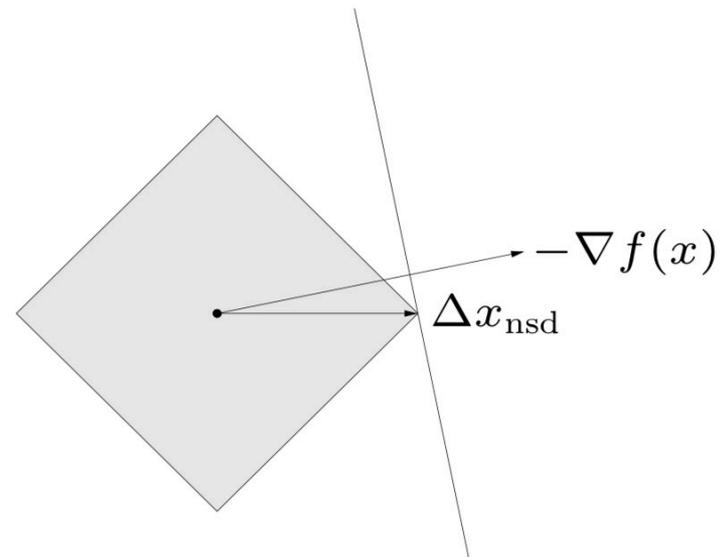
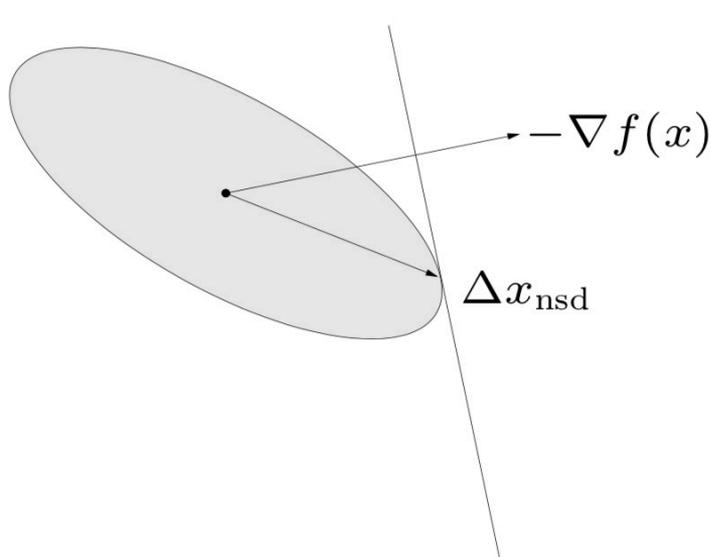
- 欧式范数: $\Delta x_{\text{sd}} = -\nabla f(x)$
- 二次范数 $\|x\|_P = (x^T P x)^{1/2}$ ($P \in \mathbf{S}_{++}^n$): $\Delta x_{\text{sd}} = -P^{-1} \nabla f(x)$
- ℓ_1 -范数 $\Delta x_{\text{sd}} = -(\partial f(x)/\partial x_i) e_i$, where $|\partial f(x)/\partial x_i| = \|\nabla f(x)\|_\infty$
- 关于二次型和 ℓ_1 -范数的单位球和规范化最速下降方向



例

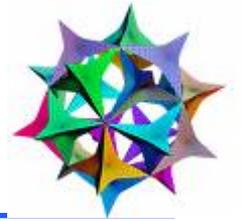


- 欧式范数: $\Delta x_{\text{sd}} = -\nabla f(x)$
- 二次范数 $\|x\|_P = (x^T P x)^{1/2}$ ($P \in \mathbf{S}_{++}^n$): $\Delta x_{\text{sd}} = -P^{-1} \nabla f(x)$
- ℓ_1 -范数 $\Delta x_{\text{sd}} = -(\partial f(x)/\partial x_i) e_i$, where $|\partial f(x)/\partial x_i| = \|\nabla f(x)\|_\infty$
- 关于二次型和 ℓ_1 -范数的单位球和规范化最速下降方向



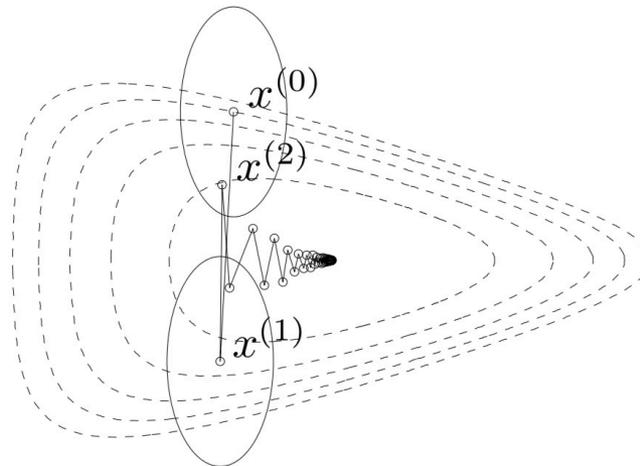
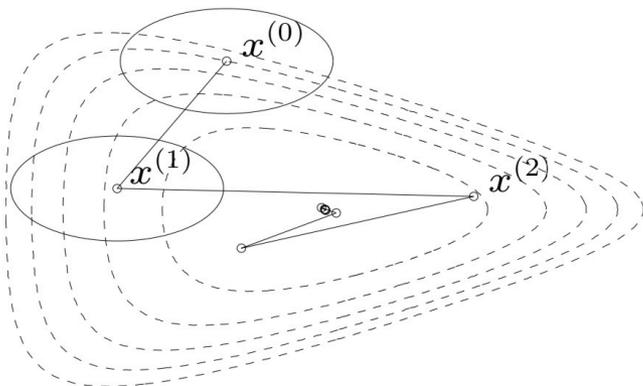


最速下降的范数选择



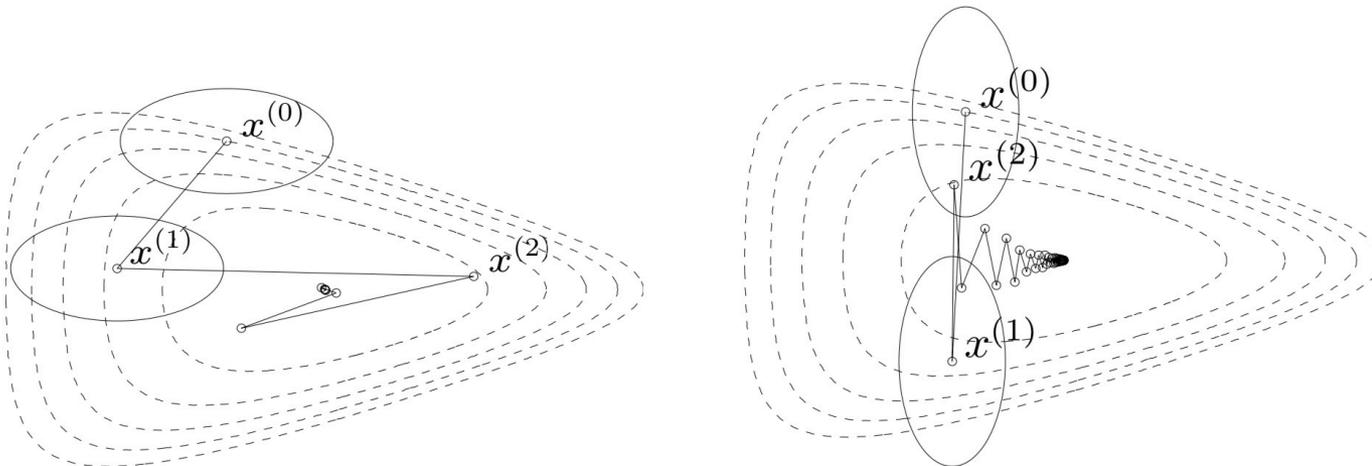


最速下降的范数选择





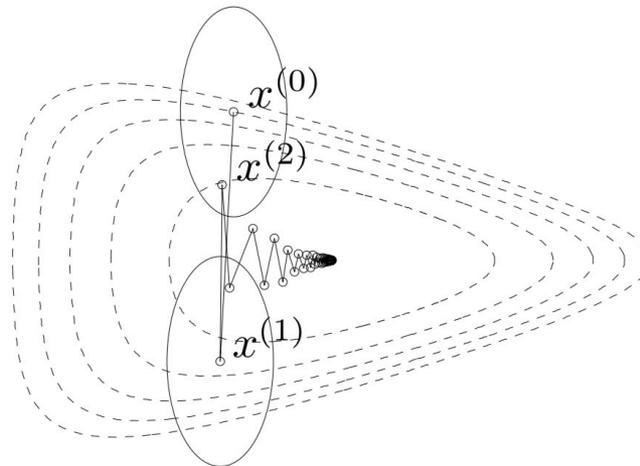
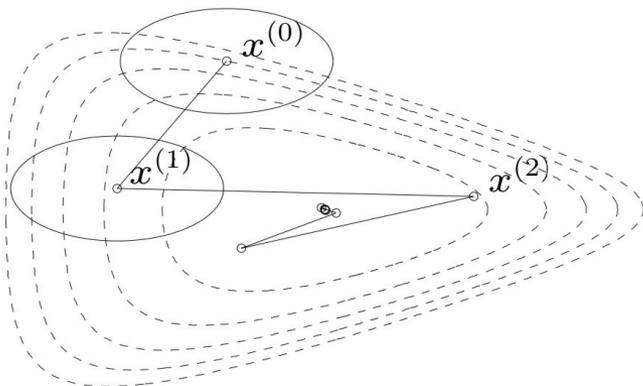
最速下降的范数选择



- 分别使用两个二次范数和回溯直线搜索的最速下降法



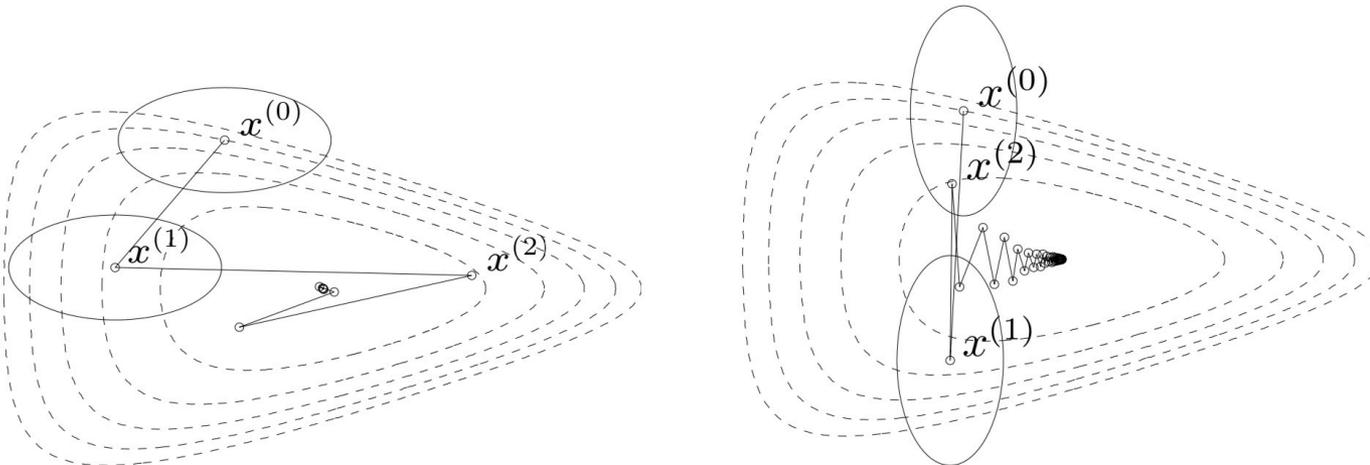
最速下降的范数选择



- 分别使用两个二次范数和回溯直线搜索的最速下降法
- 椭圆 $\{x \mid \|x - x^{(k)}\|_P = 1\}$



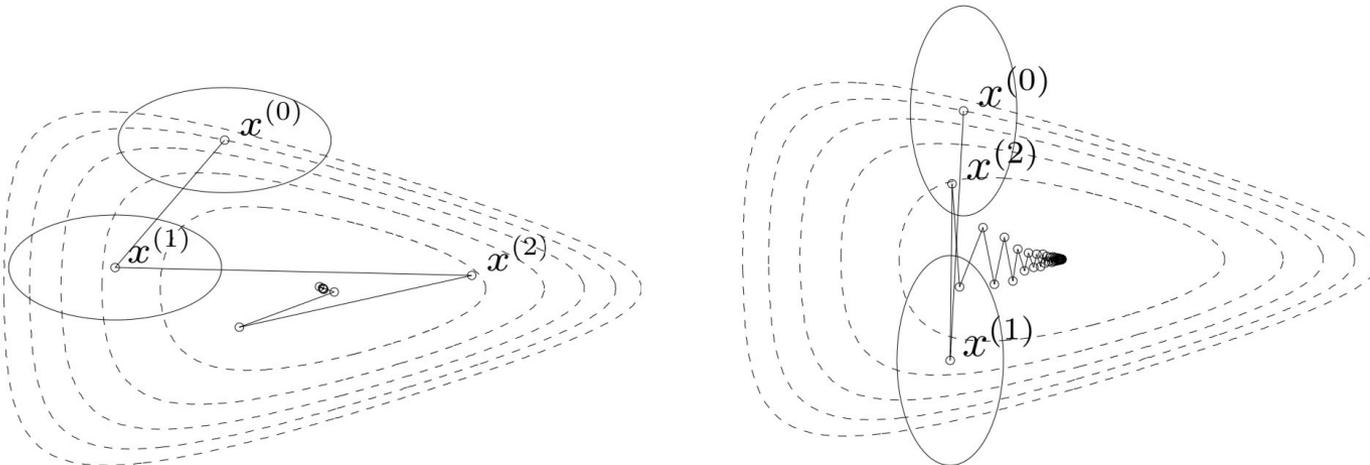
最速下降的范数选择



- 分别使用两个二次范数和回溯直线搜索的最速下降法
- 椭圆 $\{x \mid \|x - x^{(k)}\|_P = 1\}$
- 二次型最速下降的等价解释：修改优化变量 $\bar{x} = P^{1/2}x$ 的梯度下降



最速下降的范数选择



- 分别使用两个二次范数和回溯直线搜索的最速下降法
- 椭圆 $\{x \mid \|x - x^{(k)}\|_P = 1\}$
- 二次型最速下降的等价解释：修改优化变量 $\bar{x} = P^{1/2}x$ 的梯度下降
- 范数选择对收敛速度有很大影响



Newton 步径





Newton 步径



$$\Delta x_{nt} = -\nabla^2 f(x)^{-1} \nabla f(x)$$



Newton步径



$$\Delta x_{\text{nt}} = -\nabla^2 f(x)^{-1} \nabla f(x)$$

□ $x + \Delta x_{\text{nt}}$ 最小化二阶近似



Newton步径



$$\Delta x_{\text{nt}} = -\nabla^2 f(x)^{-1} \nabla f(x)$$

□ $x + \Delta x_{\text{nt}}$ 最小化二阶近似

$$\hat{f}(x + v) = f(x) + \nabla f(x)^T v + \frac{1}{2} v^T \nabla^2 f(x) v$$



Newton步径



$$\Delta x_{\text{nt}} = -\nabla^2 f(x)^{-1} \nabla f(x)$$

□ $x + \Delta x_{\text{nt}}$ 最小化二阶近似

$$\hat{f}(x + v) = f(x) + \nabla f(x)^T v + \frac{1}{2} v^T \nabla^2 f(x) v$$

□ $x + \Delta x_{\text{nt}}$ 求解线性最优条件



Newton步径



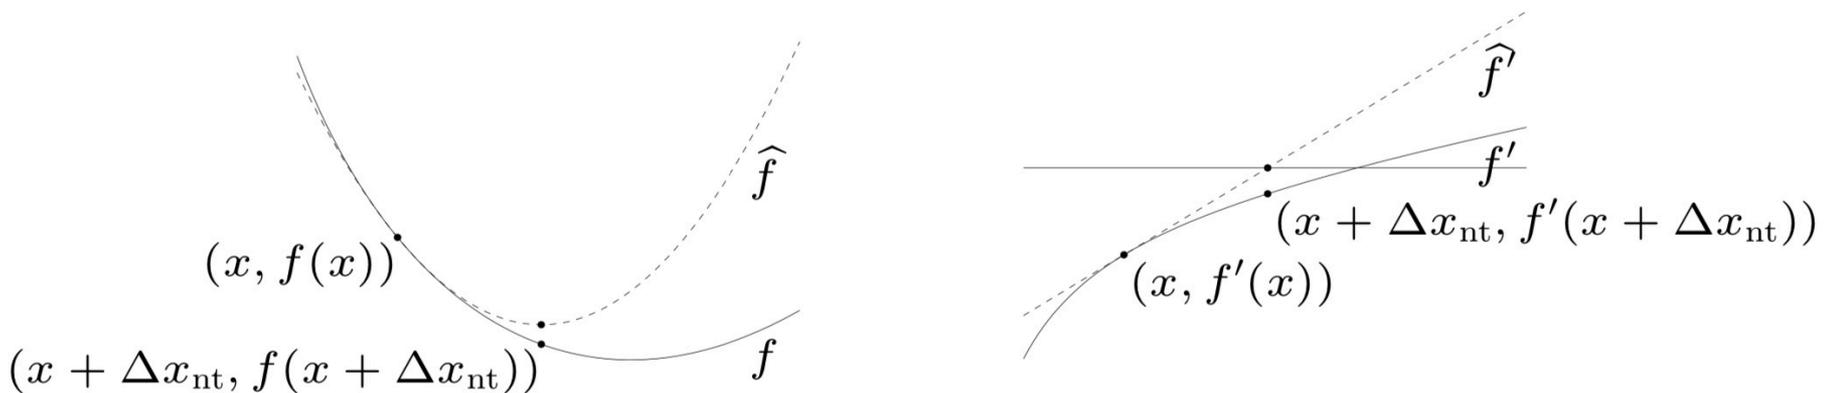
$$\Delta x_{\text{nt}} = -\nabla^2 f(x)^{-1} \nabla f(x)$$

□ $x + \Delta x_{\text{nt}}$ 最小化二阶近似

$$\hat{f}(x+v) = f(x) + \nabla f(x)^T v + \frac{1}{2} v^T \nabla^2 f(x) v$$

□ $x + \Delta x_{\text{nt}}$ 求解线性最优条件

$$\nabla f(x+v) \approx \nabla \hat{f}(x+v) = \nabla f(x) + \nabla^2 f(x) v = 0$$





Newton 步径





Newton步径



□ Δx_{nt} 为局部**Hessian**范数的最速梯度下降方向

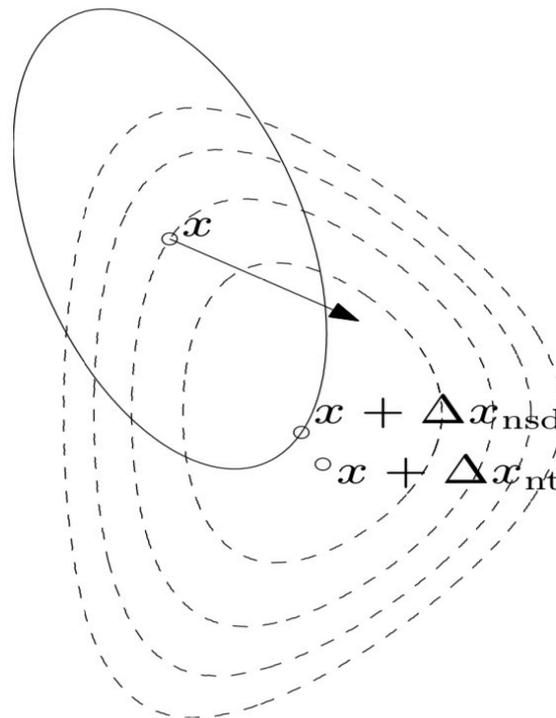


Newton步径



□ Δx_{nt} 为局部**Hessian**范数的最速梯度下降方向

$$\|u\|_{\nabla^2 f(x)} = (u^T \nabla^2 f(x) u)^{1/2}$$





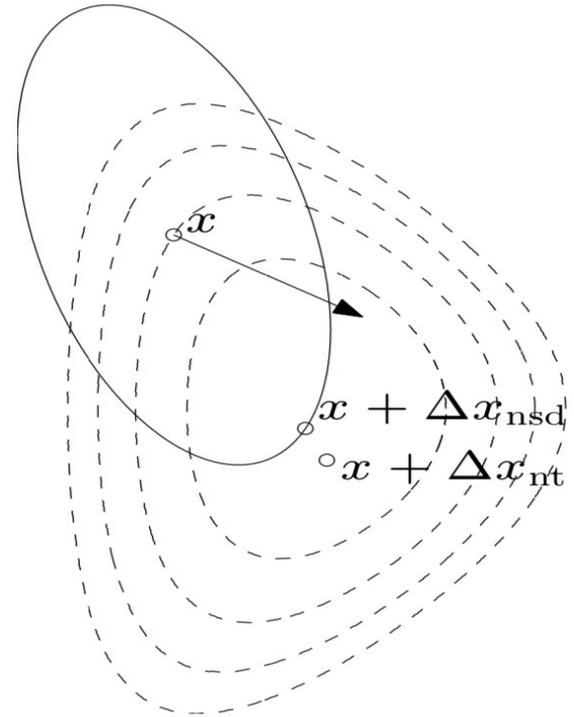
Newton步径



- Δx_{nt} 为局部**Hessian**范数的最速梯度下降方向

$$\|u\|_{\nabla^2 f(x)} = (u^T \nabla^2 f(x) u)^{1/2}$$

- 虚线为函数的等高线





Newton步径

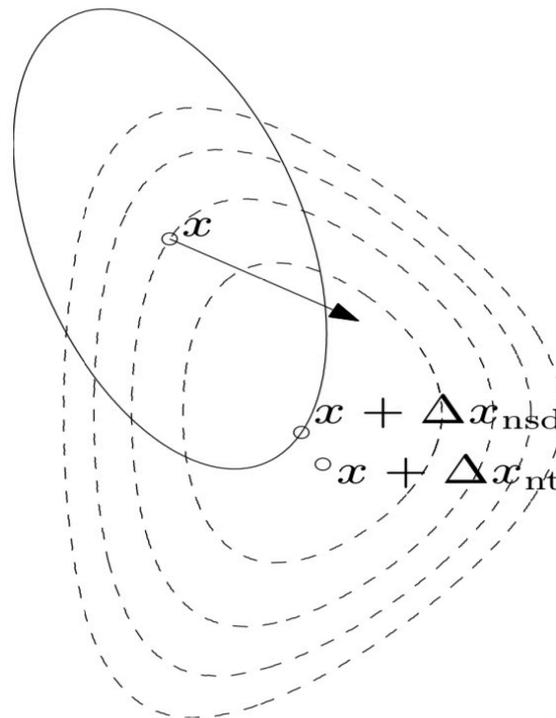


- Δx_{nt} 为局部**Hessian**范数的最速梯度下降方向

$$\|u\|_{\nabla^2 f(x)} = (u^T \nabla^2 f(x) u)^{1/2}$$

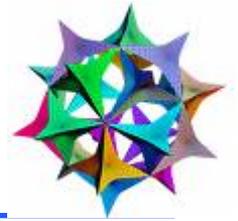
- 虚线为函数的等高线

- 椭圆为 $\{x + v \mid v^T \nabla^2 f(x) v = 1\}$





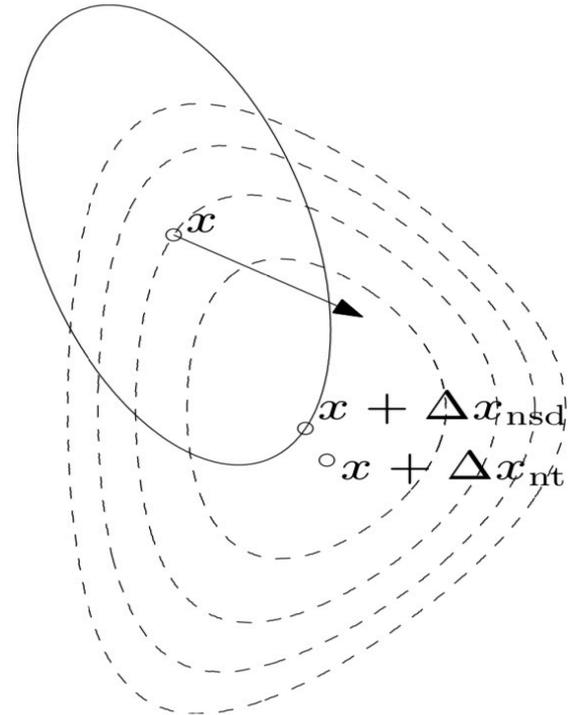
Newton步径



- Δx_{nt} 为局部**Hessian**范数的最速梯度下降方向

$$\|u\|_{\nabla^2 f(x)} = (u^T \nabla^2 f(x) u)^{1/2}$$

- 虚线为函数的等高线
- 椭圆为 $\{x + v \mid v^T \nabla^2 f(x) v = 1\}$
- 箭头表示 $-\nabla f(x)$





Newton減量





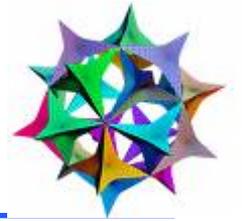
Newton減量



$$\lambda(x) = (\nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x))^{1/2}$$



Newton 减量

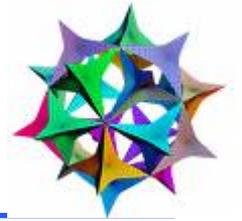


$$\lambda(x) = (\nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x))^{1/2}$$

□ 对 x 和 x^* 接近程度的度量



Newton 减量

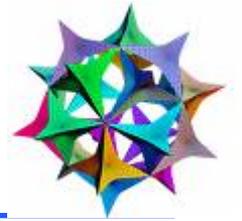


$$\lambda(x) = (\nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x))^{1/2}$$

- 对 x 和 x^* 接近程度的度量
- 性质



Newton 减量



$$\lambda(x) = (\nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x))^{1/2}$$

- 对 x 和 x^* 接近程度的度量
- 性质
 - 给出了 $f(x) - p^*$ 的一个估计，使用二次近似：



Newton 减量



$$\lambda(x) = (\nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x))^{1/2}$$

- 对 x 和 x^* 接近程度的度量
- 性质
 - 给出了 $f(x) - p^*$ 的一个估计，使用二次近似：

$$f(x) - \inf_y \hat{f}(y) = \frac{1}{2} \lambda(x)^2$$



Newton 减量



$$\lambda(x) = (\nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x))^{1/2}$$

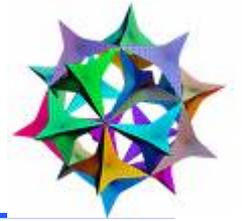
- 对 x 和 x^* 接近程度的度量
- 性质
 - 给出了 $f(x) - p^*$ 的一个估计，使用二次近似：

$$f(x) - \inf_y \hat{f}(y) = \frac{1}{2} \lambda(x)^2$$

- 为 **Newton** 步径的二次范数，具有二次 **Hessian** 形式



Newton 减量



$$\lambda(x) = (\nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x))^{1/2}$$

- 对 x 和 x^* 接近程度的度量
- 性质
 - 给出了 $f(x) - p^*$ 的一个估计，使用二次近似：

$$f(x) - \inf_y \hat{f}(y) = \frac{1}{2} \lambda(x)^2$$

- 为 **Newton** 步径的二次范数，具有二次 **Hessian** 形式
$$\lambda(x) = (\Delta x_{nt}^T \nabla^2 f(x) \Delta x_{nt})^{1/2}$$



Newton 减量



$$\lambda(x) = (\nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x))^{1/2}$$

□ 对 x 和 x^* 接近程度的度量

□ 性质

□ 给出了 $f(x) - p^*$ 的一个估计，使用二次近似：

$$f(x) - \inf_y \hat{f}(y) = \frac{1}{2} \lambda(x)^2$$

□ 为 **Newton** 步径的二次范数，具有二次 **Hessian** 形式

$$\lambda(x) = (\Delta x_{nt}^T \nabla^2 f(x) \Delta x_{nt})^{1/2}$$

□ 仿射不变性（和 $\|\nabla f(x)\|_2$ 不一样）



Newton方法





Newton方法



算法 9.5 Newton 方法。

给定 初始点 $x \in \text{dom } f$, 误差阈值 $\epsilon > 0$ 。

重复进行

1. 计算 Newton 步径和减量。

$$\Delta x_{\text{nt}} := -\nabla^2 f(x)^{-1} \nabla f(x); \quad \lambda^2 := \nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x).$$

2. 停止准则。如果 $\lambda^2/2 \leq \epsilon$, 退出。

3. 直线搜索。通过回溯直线搜索确定步长 t 。

4. 改进。 $x := x + t\Delta x_{\text{nt}}$ 。



Newton方法



算法 9.5 Newton 方法。

给定 初始点 $x \in \text{dom } f$, 误差阈值 $\epsilon > 0$ 。

重复进行

1. 计算 Newton 步径和减量。

$$\Delta x_{\text{nt}} := -\nabla^2 f(x)^{-1} \nabla f(x); \quad \lambda^2 := \nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x)。$$

2. 停止准则。如果 $\lambda^2/2 \leq \epsilon$, 退出。

3. 直线搜索。通过回溯直线搜索确定步长 t 。

4. 改进。 $x := x + t\Delta x_{\text{nt}}$ 。

□ 仿射不变性，表示和坐标的线性变换无关：



Newton方法



算法 9.5 Newton 方法。

给定 初始点 $x \in \text{dom } f$, 误差阈值 $\epsilon > 0$ 。

重复进行

1. 计算 Newton 步径和减量。

$$\Delta x_{\text{nt}} := -\nabla^2 f(x)^{-1} \nabla f(x); \quad \lambda^2 := \nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x)。$$

2. 停止准则。如果 $\lambda^2/2 \leq \epsilon$, 退出。

3. 直线搜索。通过回溯直线搜索确定步长 t 。

4. 改进。 $x := x + t\Delta x_{\text{nt}}$ 。

- 仿射不变性，表示和坐标的线性变换无关：
- **Newton**迭代进行 $\tilde{f}(y) = f(Ty)$



Newton方法



算法 9.5 Newton 方法。

给定 初始点 $x \in \text{dom } f$, 误差阈值 $\epsilon > 0$ 。

重复进行

1. 计算 Newton 步径和减量。

$$\Delta x_{\text{nt}} := -\nabla^2 f(x)^{-1} \nabla f(x); \quad \lambda^2 := \nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x)。$$

2. 停止准则。如果 $\lambda^2/2 \leq \epsilon$, 退出。

3. 直线搜索。通过回溯直线搜索确定步长 t 。

4. 改进。 $x := x + t\Delta x_{\text{nt}}$ 。

□ 仿射不变性，表示和坐标的线性变换无关：

□ **Newton**迭代进行 $\tilde{f}(y) = f(Ty)$

□ 起始点为 $y^{(0)} = T^{-1}x^{(0)}$



Newton方法



算法 9.5 Newton 方法。

给定 初始点 $x \in \text{dom } f$, 误差阈值 $\epsilon > 0$ 。

重复进行

1. 计算 Newton 步径和减量。

$$\Delta x_{\text{nt}} := -\nabla^2 f(x)^{-1} \nabla f(x); \quad \lambda^2 := \nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x)。$$

2. 停止准则。如果 $\lambda^2/2 \leq \epsilon$, 退出。

3. 直线搜索。通过回溯直线搜索确定步长 t 。

4. 改进。 $x := x + t\Delta x_{\text{nt}}$ 。

□ 仿射不变性，表示和坐标的线性变换无关：

□ **Newton**迭代进行 $\tilde{f}(y) = f(Ty)$

□ 起始点为 $y^{(0)} = T^{-1}x^{(0)}$

$$y^{(k)} = T^{-1}x^{(k)}$$



经典收敛分析





经典收敛分析



□ 假设 f 在 S 上具有常数为 m 的强凸性



经典收敛分析



- 假设 f 在 S 上具有常数为 m 的强凸性
 - $\nabla^2 f$ 在 S 上具有以 L 为常数的**Lipschitz**连续性：



经典收敛分析



- 假设 f 在 S 上具有常数为 m 的强凸性
 - $\nabla^2 f$ 在 S 上具有以 L 为常数的**Lipschitz**连续性：
$$\|\nabla^2 f(x) - \nabla^2 f(y)\|_2 \leq L\|x - y\|_2$$



经典收敛分析



- 假设 f 在 S 上具有常数为 m 的强凸性
 - $\nabla^2 f$ 在 S 上具有以 L 为常数的**Lipschitz**连续性：
$$\|\nabla^2 f(x) - \nabla^2 f(y)\|_2 \leq L\|x - y\|_2$$
- L 测量了使用二次函数拟合函数 f 的近似程度



经典收敛分析



- 假设 f 在 S 上具有常数为 m 的强凸性
 - $\nabla^2 f$ 在 S 上具有以 L 为常数的**Lipschitz**连续性：
$$\|\nabla^2 f(x) - \nabla^2 f(y)\|_2 \leq L\|x - y\|_2$$
- L 测量了使用二次函数拟合函数 f 的近似程度
- 框架：存在常数 $\eta \in (0, m^2/L)$, $\gamma > 0$ 满足



经典收敛分析



- 假设 f 在 S 上具有常数为 m 的强凸性
 - $\nabla^2 f$ 在 S 上具有以 L 为常数的**Lipschitz**连续性:

$$\|\nabla^2 f(x) - \nabla^2 f(y)\|_2 \leq L\|x - y\|_2$$

- L 测量了使用二次函数拟合函数 f 的近似程度
- 框架: 存在常数 $\eta \in (0, m^2/L)$, $\gamma > 0$ 满足

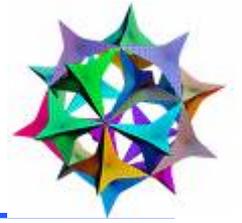
if $\|\nabla f(x)\|_2 \geq \eta$, then $f(x^{(k+1)}) - f(x^{(k)}) \leq -\gamma$

if $\|\nabla f(x)\|_2 < \eta$, then

$$\frac{L}{2m^2} \|\nabla f(x^{(k+1)})\|_2 \leq \left(\frac{L}{2m^2} \|\nabla f(x^{(k)})\|_2 \right)^2$$



阻尼Newton阶段





阻尼Newton阶段



$$(\|\nabla f(x)\|_2 \geq \eta)$$



阻尼Newton阶段



$$(\|\nabla f(x)\|_2 \geq \eta)$$

□ 大多数迭代过程需要回溯步骤



阻尼Newton阶段



$$(\|\nabla f(x)\|_2 \geq \eta)$$

- 大多数迭代过程需要回溯步骤
- 目标函数减少量至少为 γ



阻尼Newton阶段



$$(\|\nabla f(x)\|_2 \geq \eta)$$

- 大多数迭代过程需要回溯步骤
- 目标函数减少量至少为 γ
- 若 $p^* > -\infty$ ，该阶段最多需要的迭代次数是



阻尼Newton阶段



$$(\|\nabla f(x)\|_2 \geq \eta)$$

- 大多数迭代过程需要回溯步骤
- 目标函数减少量至少为 γ
- 若 $p^* > -\infty$ ，该阶段最多需要的迭代次数是
 $(f(x^{(0)}) - p^*)/\gamma$



阻尼Newton阶段



$$(\|\nabla f(x)\|_2 \geq \eta)$$

□ 大多数迭代过程需要回溯步骤

□ 目标函数减少量至少为 γ

□ 若 $p^* > -\infty$ ，该阶段最多需要的迭代次数是

$$(f(x^{(0)}) - p^*)/\gamma$$

□ 二次收敛阶段 ($\|\nabla f(x)\|_2 < \eta$)



阻尼Newton阶段



$$(\|\nabla f(x)\|_2 \geq \eta)$$

□ 大多数迭代过程需要回溯步骤

□ 目标函数减少量至少为 γ

□ 若 $p^* > -\infty$ ，该阶段最多需要的迭代次数是

$$(f(x^{(0)}) - p^*)/\gamma$$

□ 二次收敛阶段 ($\|\nabla f(x)\|_2 < \eta$)

□ 所有迭代使用相同步长 $t = 1$



阻尼Newton阶段



$$(\|\nabla f(x)\|_2 \geq \eta)$$

- 大多数迭代过程需要回溯步骤
- 目标函数减少量至少为 γ
- 若 $p^* > -\infty$ ，该阶段最多需要的迭代次数是

$$(f(x^{(0)}) - p^*)/\gamma$$

- 二次收敛阶段 ($\|\nabla f(x)\|_2 < \eta$)
 - 所有迭代使用相同步长 $t = 1$
- $\|\nabla f(x)\|_2$ 二次收敛到 $\mathbf{0}$ ：若 $\|\nabla f(x^{(k)})\|_2 < \eta$



阻尼Newton阶段



$$(\|\nabla f(x)\|_2 \geq \eta)$$

- 大多数迭代过程需要回溯步骤
- 目标函数减少量至少为 γ
- 若 $p^* > -\infty$ ，该阶段最多需要的迭代次数是

$$(f(x^{(0)}) - p^*)/\gamma$$

- 二次收敛阶段 ($\|\nabla f(x)\|_2 < \eta$)

- 所有迭代使用相同步长 $t = 1$

- $\|\nabla f(x)\|_2$ 二次收敛到 $\mathbf{0}$: 若 $\|\nabla f(x^{(k)})\|_2 < \eta$

$$\frac{L}{2m^2} \|\nabla f(x^l)\|_2 \leq \left(\frac{L}{2m^2} \|\nabla f(x^k)\|_2 \right)^{2^{l-k}} \leq \left(\frac{1}{2} \right)^{2^{l-k}}, \quad l \geq k$$



结论





结论



□ 达到 $f(x) - p^* \leq \epsilon$ 的迭代次数上界为



结论



□ 达到 $f(x) - p^* \leq \epsilon$ 的迭代次数上界为

$$\frac{f(x^{(0)}) - p^*}{\gamma} + \log_2 \log_2(\epsilon_0/\epsilon)$$



结论



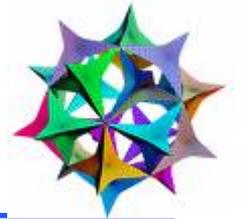
□ 达到 $f(x) - p^* \leq \epsilon$ 的迭代次数上界为

$$\frac{f(x^{(0)}) - p^*}{\gamma} + \log_2 \log_2(\epsilon_0/\epsilon)$$

□ γ, ϵ_0 为常数, 取决于 $m, L, x^{(0)}$



结论



□ 达到 $f(x) - p^* \leq \epsilon$ 的迭代次数上界为

$$\frac{f(x^{(0)}) - p^*}{\gamma} + \log_2 \log_2(\epsilon_0/\epsilon)$$

□ γ, ϵ_0 为常数，取决于 $m, L, x^{(0)}$

□ 第二项较小，实际中基本为常数



结论



- 达到 $f(x) - p^* \leq \epsilon$ 的迭代次数上界为

$$\frac{f(x^{(0)}) - p^*}{\gamma} + \log_2 \log_2(\epsilon_0/\epsilon)$$

- γ, ϵ_0 为常数，取决于 $m, L, x^{(0)}$
- 第二项较小，实际中基本为常数
- 实际上，常数 m, L 通常未知（因此， γ, ϵ_0 也未知）



结论



- 达到 $f(x) - p^* \leq \epsilon$ 的迭代次数上界为

$$\frac{f(x^{(0)}) - p^*}{\gamma} + \log_2 \log_2(\epsilon_0/\epsilon)$$

- γ, ϵ_0 为常数，取决于 $m, L, x^{(0)}$
- 第二项较小，实际中基本为常数
- 实际上，常数 m, L 通常未知（因此， γ, ϵ_0 也未知）
- 为收敛性提供了定性理解（指解释了两个阶段）



例





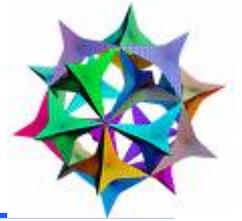
例



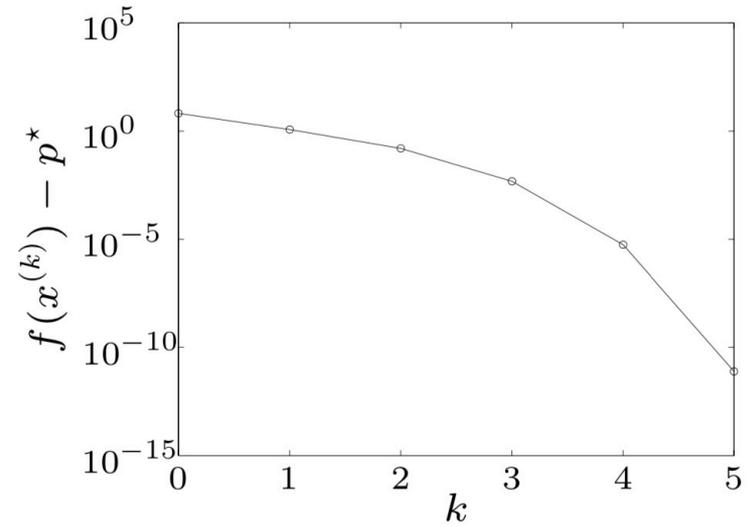
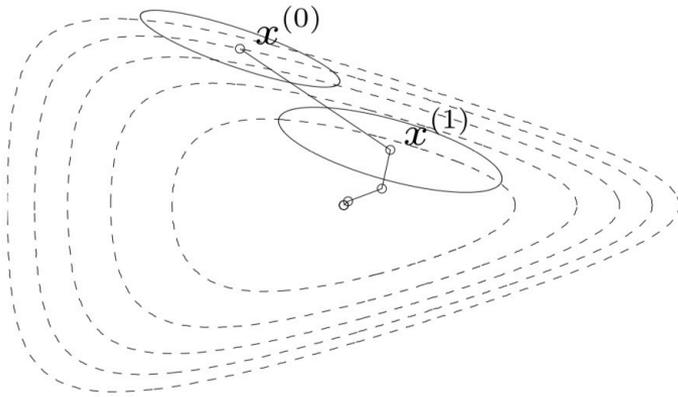
□ R^2 空间中的例子



例

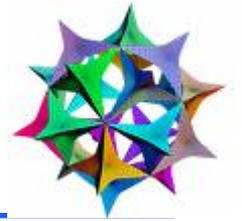


□ R^2 空间中的例子

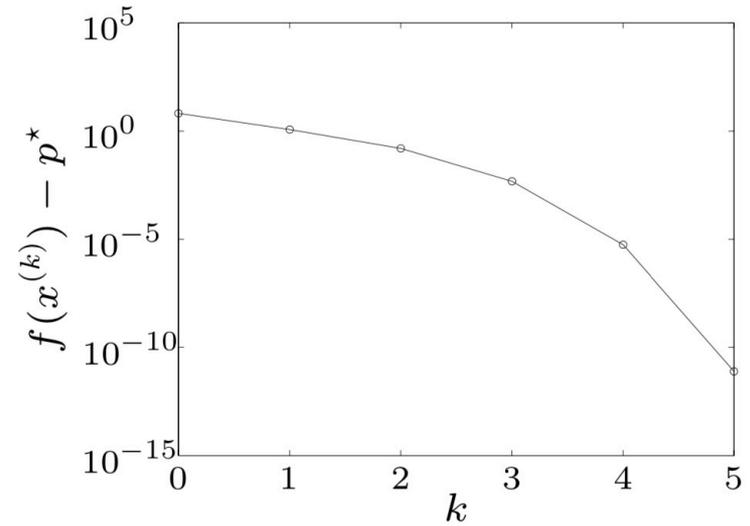
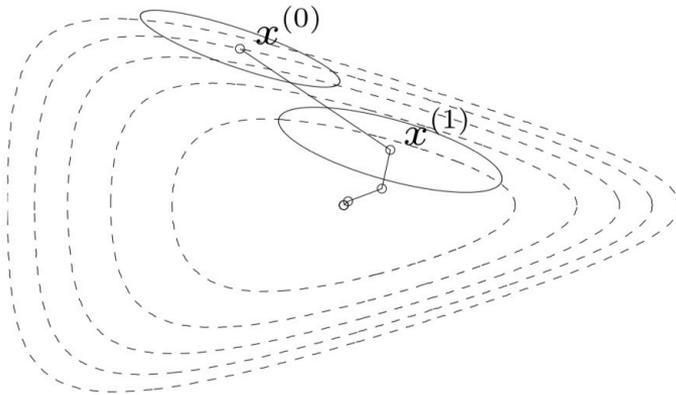




例



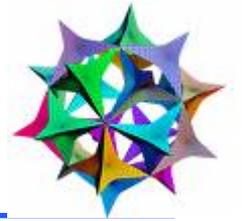
□ R^2 空间中的例子



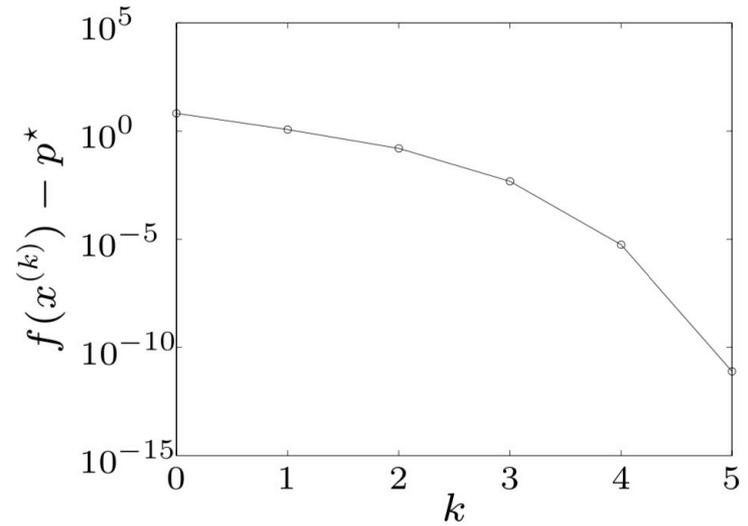
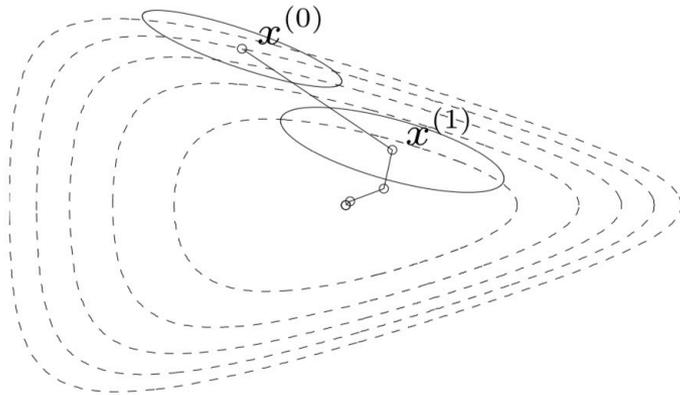
□ 回溯参数 $\alpha = 0.1, \beta = 0.7$



例



□ R^2 空间中的例子

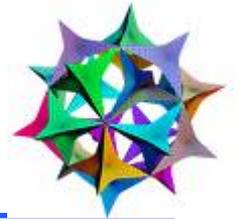


□ 回溯参数 $\alpha = 0.1, \beta = 0.7$

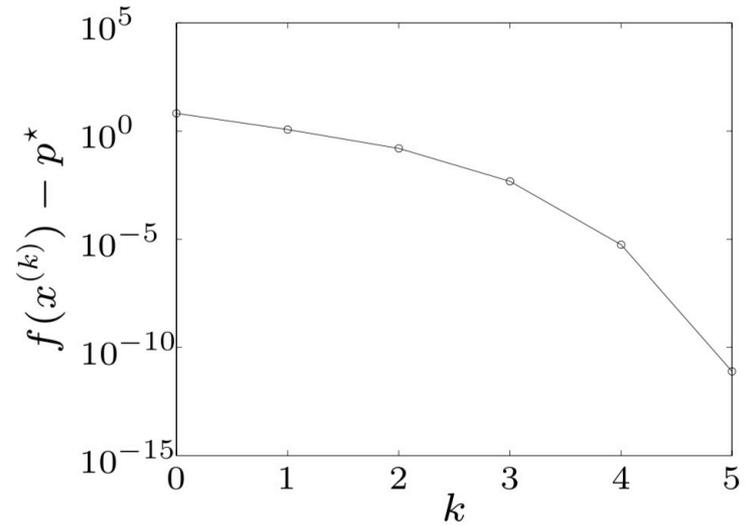
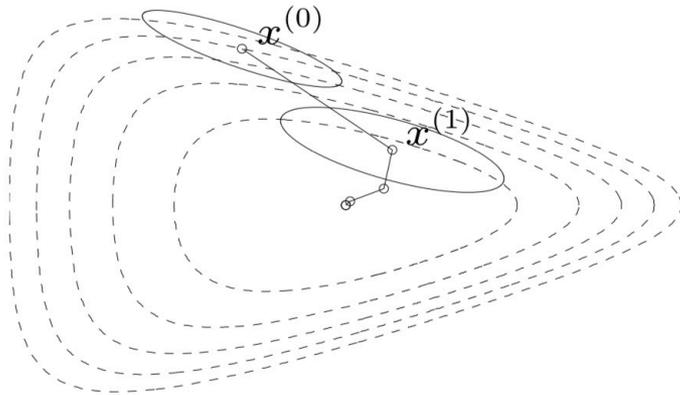
□ 使用**5**步即收敛



例



□ R^2 空间中的例子



- 回溯参数 $\alpha = 0.1, \beta = 0.7$
- 使用**5**步即收敛
- 二次局部收敛



例





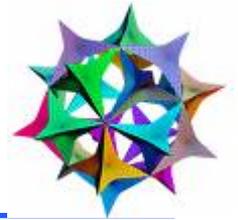
例



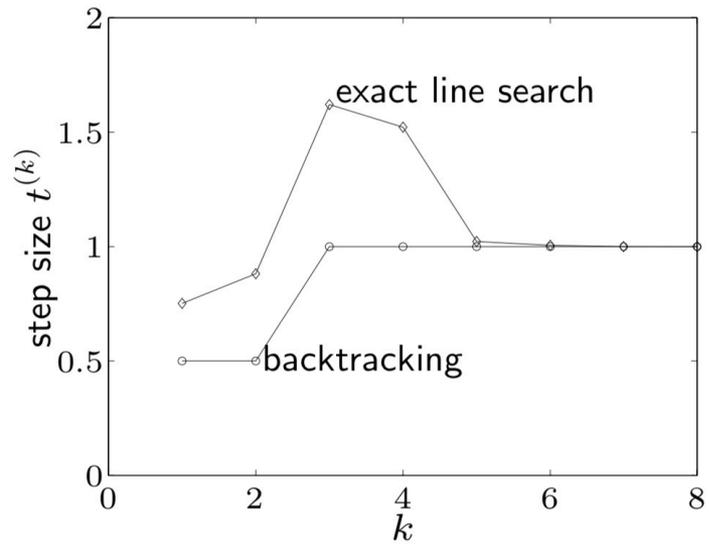
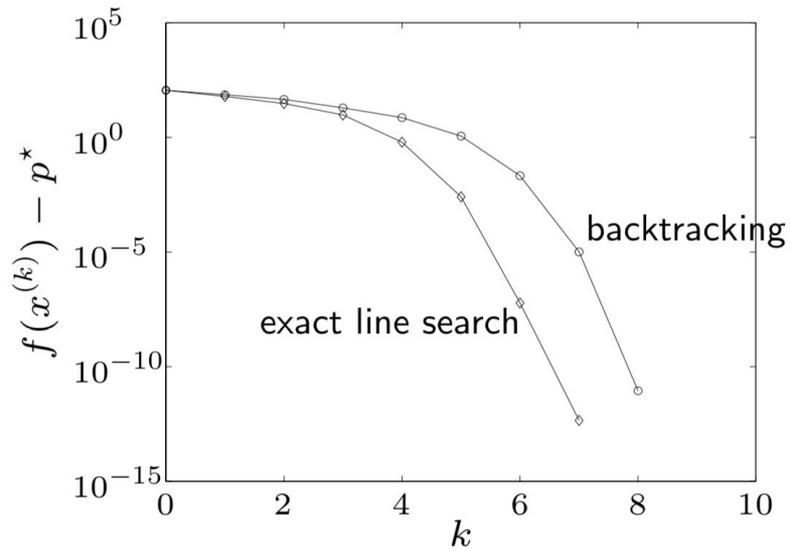
□ R^{100} 空间中的例子



例

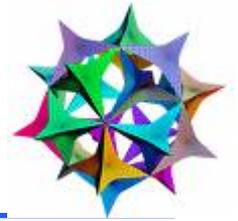


□ R^{100} 空间中的例子

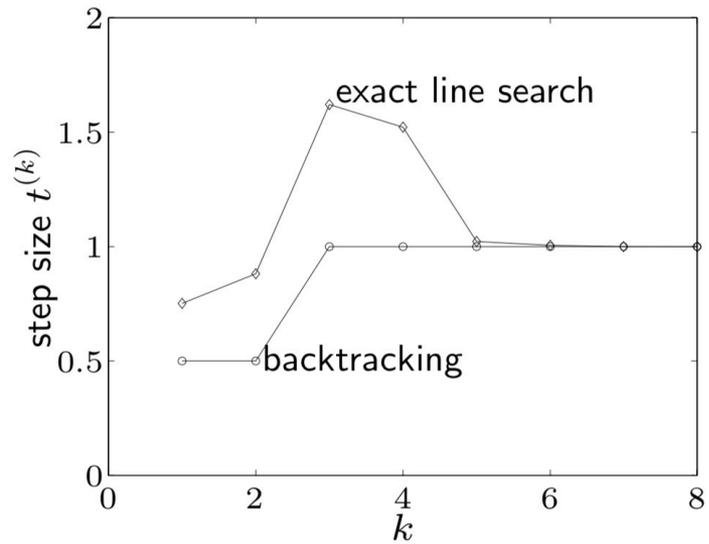
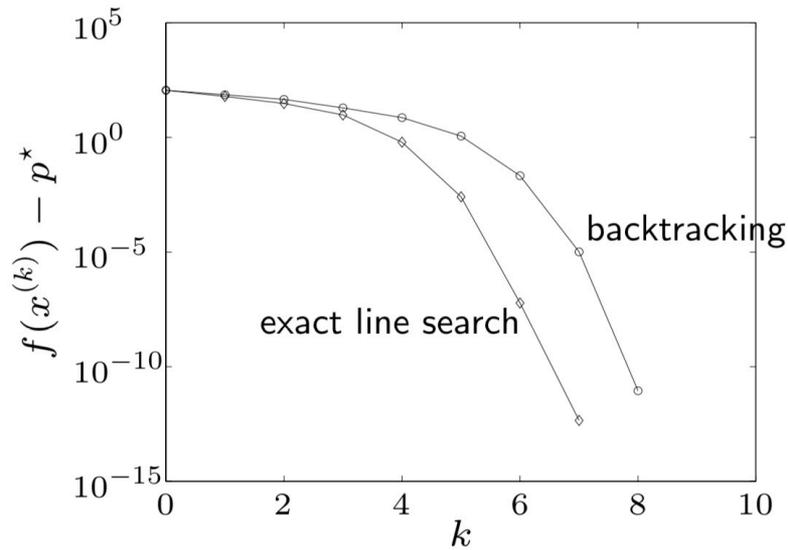




例



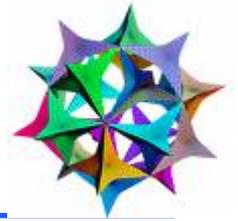
□ R^{100} 空间中的例子



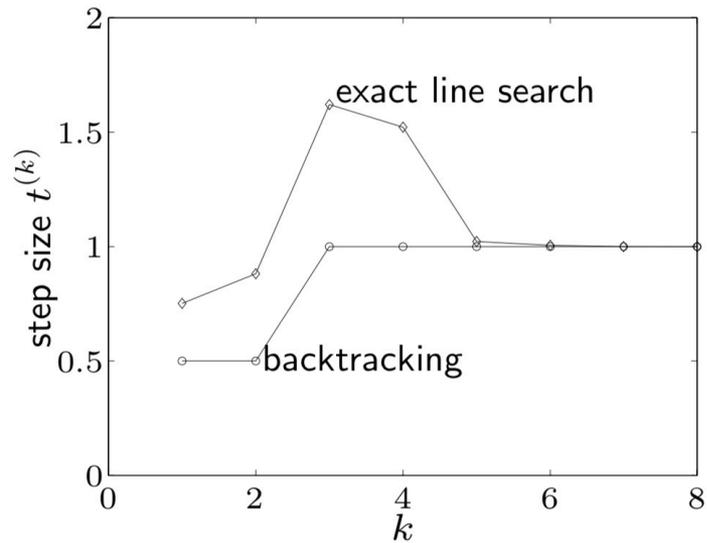
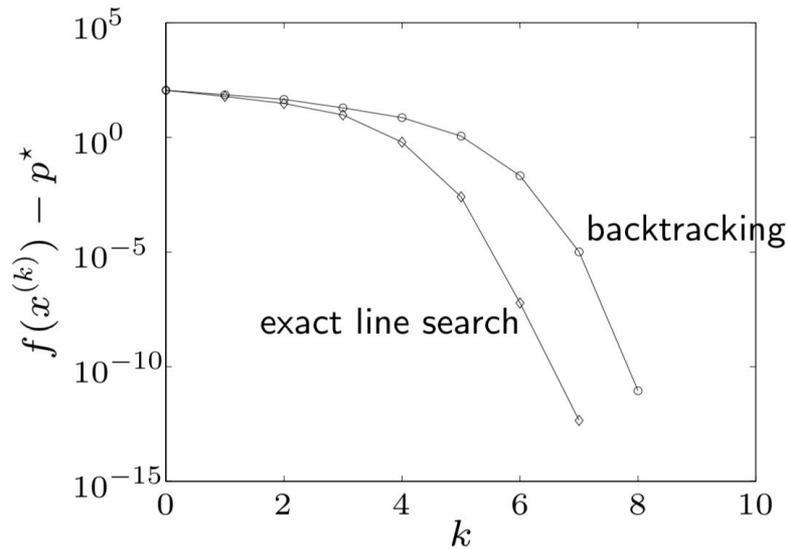
□ 回溯参数 $\alpha = 0.01, \beta = 0.5$



例



□ R^{100} 空间中的例子

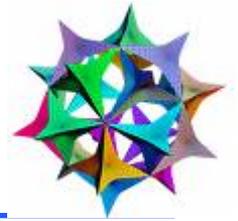


□ 回溯参数 $\alpha = 0.01, \beta = 0.5$

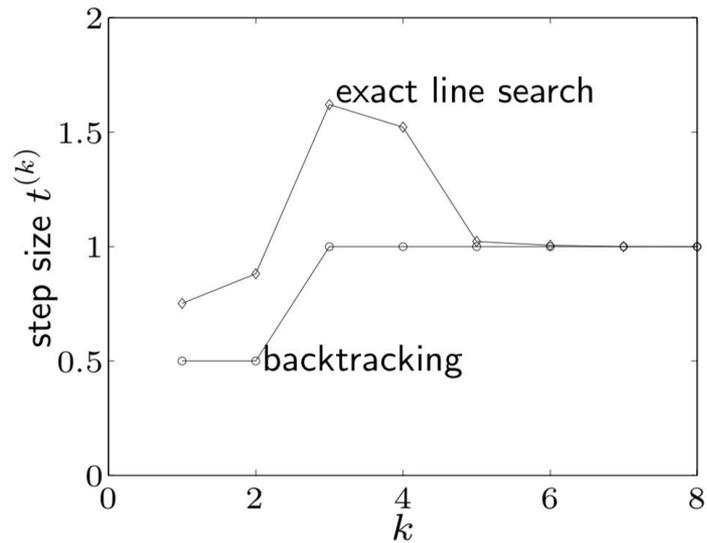
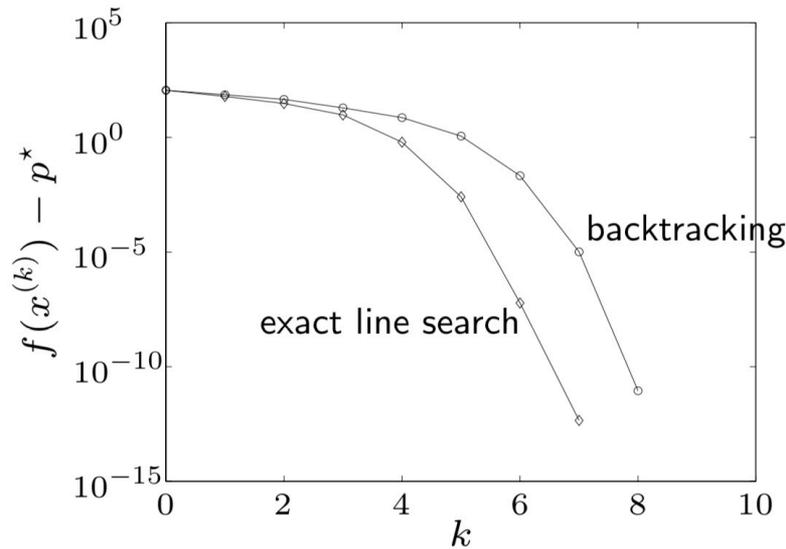
□ 回溯直线搜索和精确搜索基本一样快（且更为简单）



例



□ R^{100} 空间中的例子



- 回溯参数 $\alpha = 0.01, \beta = 0.5$
- 回溯直线搜索和精确搜索基本一样快（且更为简单）
- 清楚的显示了算法的两个阶段

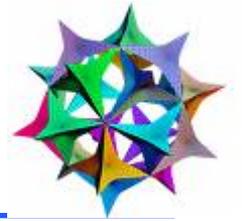


例





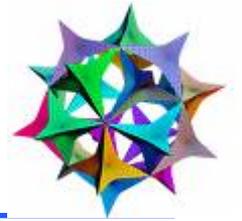
例



□ R^{10000} 空间的例子（带有稀疏的 a_i ）

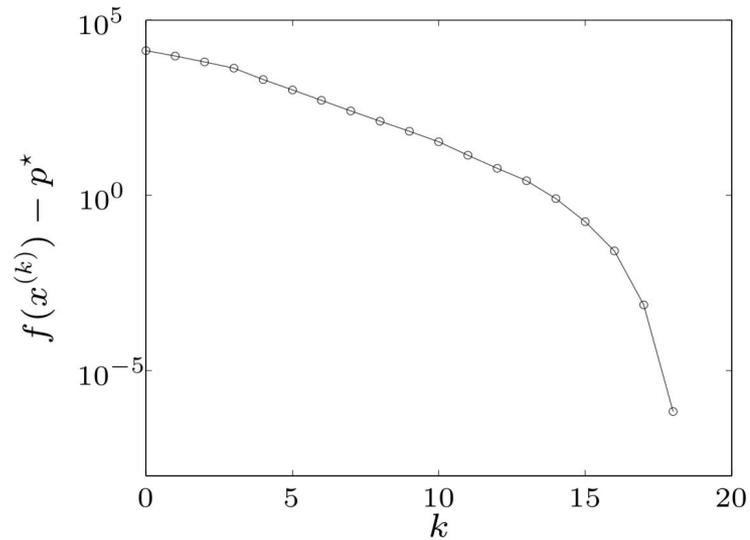


例



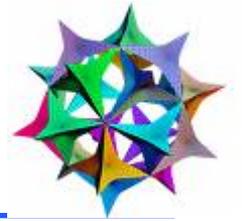
□ R^{10000} 空间的例子（带有稀疏的 a_i ）

$$f(x) = - \sum_{i=1}^{10000} \log(1 - x_i^2) - \sum_{i=1}^{100000} \log(b_i - a_i^T x)$$



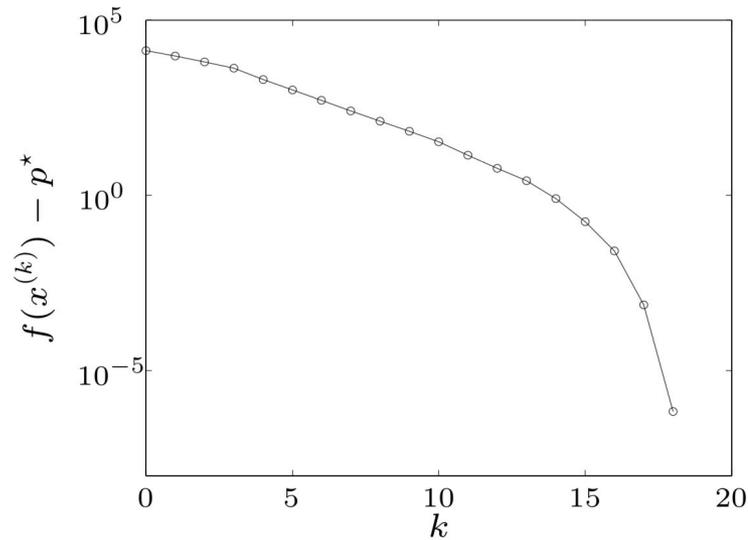


例



□ R^{10000} 空间的例子（带有稀疏的 a_i ）

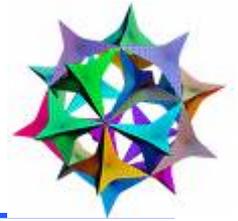
$$f(x) = - \sum_{i=1}^{10000} \log(1 - x_i^2) - \sum_{i=1}^{100000} \log(b_i - a_i^T x)$$



□ 回溯参数 $\alpha = 0.01, \beta = 0.5$

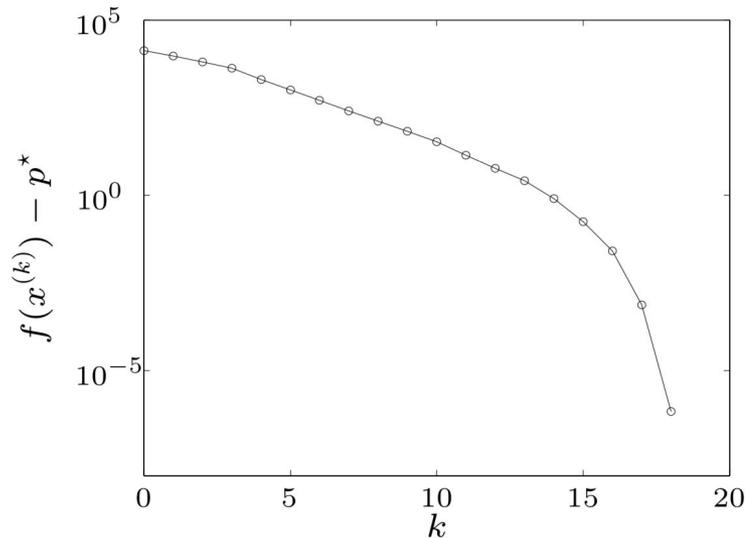


例



□ R^{10000} 空间的例子（带有稀疏的 a_i ）

$$f(x) = - \sum_{i=1}^{10000} \log(1 - x_i^2) - \sum_{i=1}^{100000} \log(b_i - a_i^T x)$$



□ 回溯参数 $\alpha = 0.01, \beta = 0.5$

□ 和较小的例子具有同样的性能

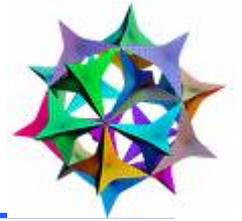


自和谐





自和谐



- 经典收敛性分析的不足



自和谐



- 经典收敛性分析的不足
 - 取决于未知常量 (m, L, \dots)



自和谐



- 经典收敛性分析的不足
 - 取决于未知常量 (m, L, \dots)
 - 界限不具仿射不变性



自和谐



- 经典收敛性分析的不足
 - 取决于未知常量 (m, L, \dots)
 - 界限不具仿射不变性
- 使用自和谐的收敛性分析 (**Nesterov**和**Nemirovski**)



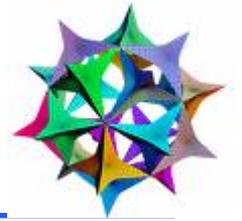
自和谐



- 经典收敛性分析的不足
 - 取决于未知常量 (m, L, \dots)
 - 界限不具仿射不变性
- 使用自和谐的收敛性分析 (**Nesterov**和**Nemirovski**)
 - 不受任何未知常量影响



自和谐



- 经典收敛性分析的不足
 - 取决于未知常量 (m, L, \dots)
 - 界限不具仿射不变性
- 使用自和谐的收敛性分析 (**Nesterov**和**Nemirovski**)
 - 不受任何未知常量影响
 - 给出了具有仿射不变性的边界



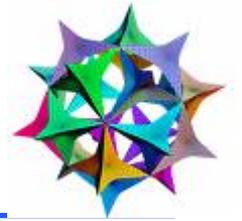
自和谐



- 经典收敛性分析的不足
 - 取决于未知常量 (m, L, \dots)
 - 界限不具仿射不变性
- 使用自和谐的收敛性分析 (**Nesterov**和**Nemirovski**)
 - 不受任何未知常量影响
 - 给出了具有仿射不变性的边界
 - 可用于特殊的凸函数 (自和谐函数)



自和谐



- 经典收敛性分析的不足
 - 取决于未知常量 (m, L, \dots)
 - 界限不具仿射不变性
- 使用自和谐的收敛性分析 (**Nesterov**和**Nemirovski**)
 - 不受任何未知常量影响
 - 给出了具有仿射不变性的边界
 - 可用于特殊的凸函数 (自和谐函数)
 - 可用来分析凸优化的多项式时间内点法

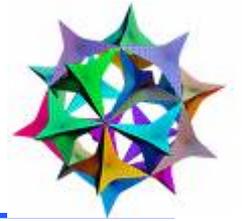


自和谐方程





自和谐方程



□ 定义



自和谐方程



- 定义
- 凸函数 $f : \mathbf{R} \rightarrow \mathbf{R}$ 为自和谐函数



自和谐方程



- 定义
- 凸函数 $f : \mathbf{R} \rightarrow \mathbf{R}$ 为自和谐函数
 - 对所有 $x \in \mathbf{dom} f$, 满足



自和谐方程



- 定义
- 凸函数 $f : \mathbf{R} \rightarrow \mathbf{R}$ 为自和谐函数
 - 对所有 $x \in \mathbf{dom} f$, 满足

$$|f'''(x)| \leq 2f''(x)^{3/2}$$



自和谐方程



- 定义
- 凸函数 $f : \mathbf{R} \rightarrow \mathbf{R}$ 为自和谐函数
 - 对所有 $x \in \mathbf{dom} f$, 满足
$$|f'''(x)| \leq 2f''(x)^{3/2}$$
- 函数 $f : \mathbf{R}^n \rightarrow \mathbf{R}$ 为自和谐函数



自和谐方程



- 定义
- 凸函数 $f : \mathbf{R} \rightarrow \mathbf{R}$ 为自和谐函数
 - 对所有 $x \in \mathbf{dom} f$, 满足
$$|f'''(x)| \leq 2f''(x)^{3/2}$$
- 函数 $f : \mathbf{R}^n \rightarrow \mathbf{R}$ 为自和谐函数
 - 对所有 $x \in \mathbf{dom} f, v \in \mathbf{R}^n$ 满足 $g(t) = f(x + tv)$ 为自和谐函数



自和谐方程





自和谐方程



□ R 空间



自和谐方程



- R 空间
- 线性和二次函数



自和谐方程



- R 空间

- 线性和二次函数

- 负对数函数 $f(x) = -\log x$



自和谐方程



□ R 空间

□ 线性和二次函数

□ 负对数函数 $f(x) = -\log x$

□ 负熵加负对数 $f(x) = x \log x - \log x$



自和谐方程



- R 空间
 - 线性和二次函数
 - 负对数函数 $f(x) = -\log x$
 - 负熵加负对数 $f(x) = x \log x - \log x$
- 仿射不变性:



自和谐方程



□ \mathbf{R} 空间

□ 线性和二次函数

□ 负对数函数 $f(x) = -\log x$

□ 负熵加负对数 $f(x) = x \log x - \log x$

□ 仿射不变性:

□ 若 $f: \mathbf{R} \rightarrow \mathbf{R}$ 为自和谐, 则 $\tilde{f}(y) = f(ay + b)$
为自和谐



自和谐方程



□ \mathbf{R} 空间

□ 线性和二次函数

□ 负对数函数 $f(x) = -\log x$

□ 负熵加负对数 $f(x) = x \log x - \log x$

□ 仿射不变性:

□ 若 $f: \mathbf{R} \rightarrow \mathbf{R}$ 为自和谐, 则 $\tilde{f}(y) = f(ay + b)$
为自和谐

$$\tilde{f}'''(y) = a^3 f'''(ay + b), \quad \tilde{f}''(y) = a^2 f''(ay + b)$$



基于自和谐函数的收敛分析





基于自和谐函数的收敛分析



□ 存在常数 $\eta \in (0, 1/4]$, $\gamma > 0$ 满足:



基于自和谐函数的收敛分析



- 存在常数 $\eta \in (0, 1/4]$, $\gamma > 0$ 满足:
 - 若 $\lambda(x) > \eta$, 有 $f(x^{(k+1)}) - f(x^{(k)}) \leq -\gamma$



基于自和谐函数的收敛分析



- 存在常数 $\eta \in (0, 1/4]$, $\gamma > 0$ 满足:
 - 若 $\lambda(x) > \eta$, 有 $f(x^{(k+1)}) - f(x^{(k)}) \leq -\gamma$
 - 若 $\lambda(x) \leq \eta$, 有 $2\lambda(x^{(k+1)}) \leq \left(2\lambda(x^{(k)})\right)^2$



基于自和谐函数的收敛分析



- 存在常数 $\eta \in (0, 1/4]$, $\gamma > 0$ 满足:
 - 若 $\lambda(x) > \eta$, 有 $f(x^{(k+1)}) - f(x^{(k)}) \leq -\gamma$
 - 若 $\lambda(x) \leq \eta$, 有 $2\lambda(x^{(k+1)}) \leq \left(2\lambda(x^{(k)})\right)^2$
- (η 和 γ 只取决于回溯参数 α, β)



基于自和谐函数的收敛分析



- 存在常数 $\eta \in (0, 1/4]$, $\gamma > 0$ 满足:
 - 若 $\lambda(x) > \eta$, 有 $f(x^{(k+1)}) - f(x^{(k)}) \leq -\gamma$
 - 若 $\lambda(x) \leq \eta$, 有 $2\lambda(x^{(k+1)}) \leq (2\lambda(x^{(k)}))^2$
- (η 和 γ 只取决于回溯参数 α, β)
- 复杂性边界: **Newton**收敛次数上界为



基于自和谐函数的收敛分析



- 存在常数 $\eta \in (0, 1/4]$, $\gamma > 0$ 满足:
 - 若 $\lambda(x) > \eta$, 有 $f(x^{(k+1)}) - f(x^{(k)}) \leq -\gamma$
 - 若 $\lambda(x) \leq \eta$, 有 $2\lambda(x^{(k+1)}) \leq (2\lambda(x^{(k)}))^2$
- (η 和 γ 只取决于回溯参数 α, β)
- 复杂性边界: **Newton**收敛次数上界为

$$\frac{f(x^{(0)}) - p^*}{\gamma} + \log_2 \log_2(1/\epsilon)$$



基于自和谐函数的收敛分析



- 存在常数 $\eta \in (0, 1/4]$, $\gamma > 0$ 满足:
 - 若 $\lambda(x) > \eta$, 有 $f(x^{(k+1)}) - f(x^{(k)}) \leq -\gamma$
 - 若 $\lambda(x) \leq \eta$, 有 $2\lambda(x^{(k+1)}) \leq (2\lambda(x^{(k)}))^2$
- (η 和 γ 只取决于回溯参数 α, β)

- 复杂性边界: **Newton**收敛次数上界为

$$\frac{f(x^{(0)}) - p^*}{\gamma} + \log_2 \log_2(1/\epsilon)$$

- 若 $\alpha = 0.1, \beta = 0.8, \epsilon = 10^{-10}$, 上界估计为



基于自和谐函数的收敛分析



- 存在常数 $\eta \in (0, 1/4]$, $\gamma > 0$ 满足:
 - 若 $\lambda(x) > \eta$, 有 $f(x^{(k+1)}) - f(x^{(k)}) \leq -\gamma$
 - 若 $\lambda(x) \leq \eta$, 有 $2\lambda(x^{(k+1)}) \leq (2\lambda(x^{(k)}))^2$
- (η 和 γ 只取决于回溯参数 α, β)

- 复杂性边界: **Newton**收敛次数上界为

$$\frac{f(x^{(0)}) - p^*}{\gamma} + \log_2 \log_2(1/\epsilon)$$

- 若 $\alpha = 0.1, \beta = 0.8, \epsilon = 10^{-10}$, 上界估计为

$$375(f(x^{(0)}) - p^*) + 6$$



数值例子





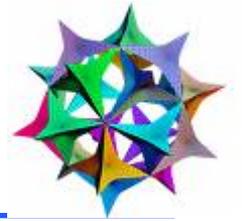
数值例子



- **150**个随机生成的实例



数值例子

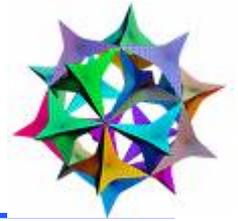


□ **150**个随机生成的实例

$$\text{minimize } f(x) = - \sum_{i=1}^m \log(b_i - a_i^T x)$$



数值例子



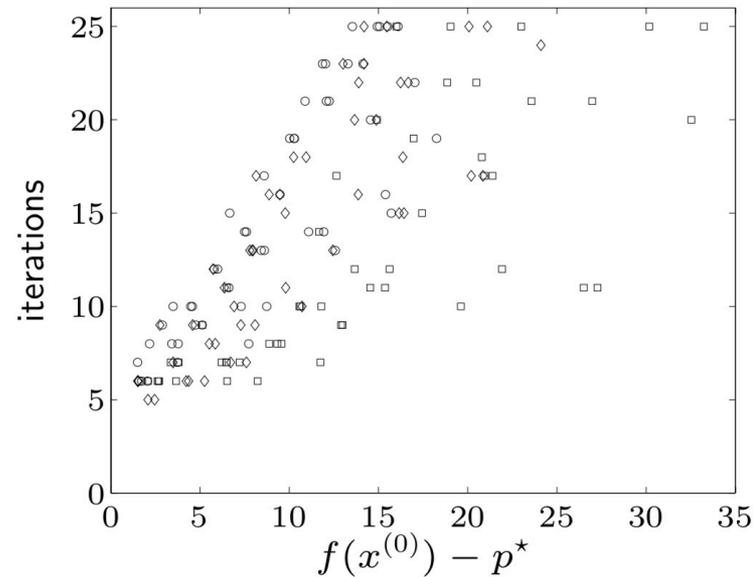
150个随机生成的实例

$$\text{minimize } f(x) = -\sum_{i=1}^m \log(b_i - a_i^T x)$$

○: $m = 100, n = 50$

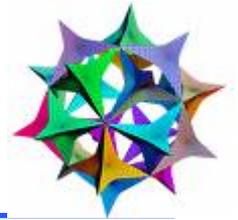
□: $m = 1000, n = 500$

◇: $m = 1000, n = 50$





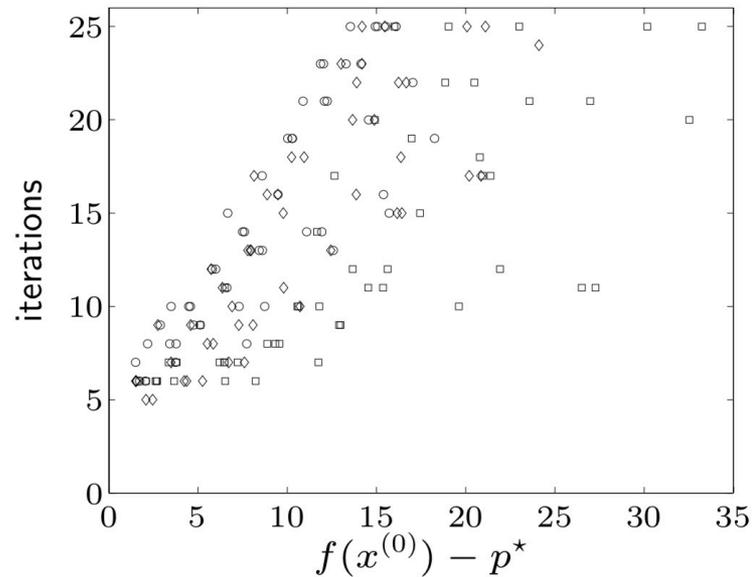
数值例子



150个随机生成的实例

$$\text{minimize } f(x) = -\sum_{i=1}^m \log(b_i - a_i^T x)$$

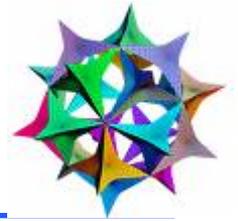
- : $m = 100, n = 50$
- : $m = 1000, n = 500$
- ◇: $m = 1000, n = 50$



收敛次数大大少于 $375(f(x^{(0)}) - p^*) + 6$



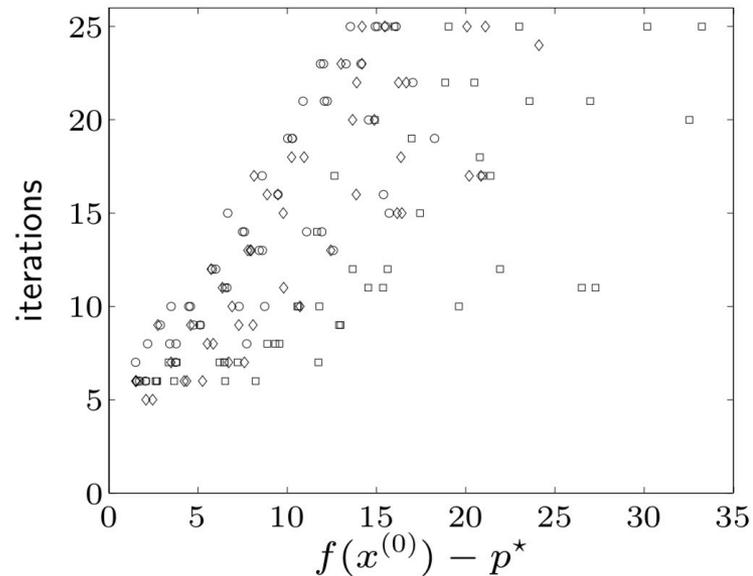
数值例子



150个随机生成的实例

$$\text{minimize } f(x) = -\sum_{i=1}^m \log(b_i - a_i^T x)$$

- : $m = 100, n = 50$
- : $m = 1000, n = 500$
- ◇: $m = 1000, n = 50$



- 收敛次数大大少于 $375(f(x^{(0)}) - p^*) + 6$
- $c(f(x^{(0)}) - p^*) + 6$ 是所需迭代次数的一个不坏的估计 (c 较小)



实现





实现



- 每次迭代的主要代价：估计导数并求解**Newton**系统 $H\Delta x = -g$



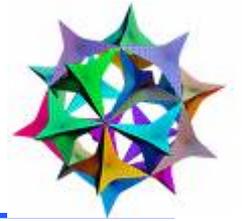
实现



- 每次迭代的主要代价：估计导数并求解**Newton**系统 $H\Delta x = -g$
- 其中, $H = \nabla^2 f(x)$, $g = \nabla f(x)$



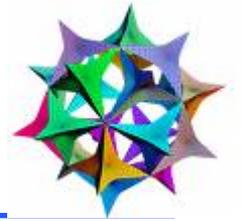
实现



- 每次迭代的主要代价：估计导数并求解**Newton**系统 $H\Delta x = -g$
 - 其中, $H = \nabla^2 f(x)$, $g = \nabla f(x)$
- 通过**Cholesky**因式分解



实现

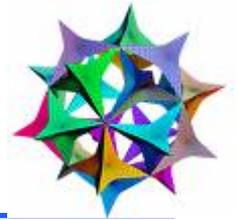


- 每次迭代的主要代价：估计导数并求解**Newton**系统 $H\Delta x = -g$
 - 其中, $H = \nabla^2 f(x)$, $g = \nabla f(x)$
- 通过**Cholesky**因式分解

$$H = LL^T, \quad \Delta x_{\text{nt}} = -L^{-T}L^{-1}g, \quad \lambda(x) = \|L^{-1}g\|_2$$



实现



□ 每次迭代的主要代价：估计导数并求解**Newton**系统 $H\Delta x = -g$

□ 其中, $H = \nabla^2 f(x)$, $g = \nabla f(x)$

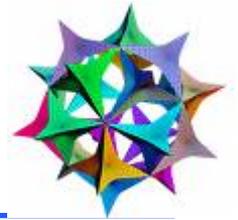
□ 通过**Cholesky**因式分解

$$H = LL^T, \quad \Delta x_{\text{nt}} = -L^{-T}L^{-1}g, \quad \lambda(x) = \|L^{-1}g\|_2$$

□ 对非结构系统需要 $(1/3)n^3$ 次浮点运算



实现



□ 每次迭代的主要代价：估计导数并求解**Newton**系统 $H\Delta x = -g$

□ 其中, $H = \nabla^2 f(x)$, $g = \nabla f(x)$

□ 通过**Cholesky**因式分解

$$H = LL^T, \quad \Delta x_{\text{nt}} = -L^{-T}L^{-1}g, \quad \lambda(x) = \|L^{-1}g\|_2$$

□ 对非结构系统需要 $(1/3)n^3$ 次浮点运算

□ 若 H 为稀疏或带状的, 代价 $\ll (1/3)n^3$