

高级人工智能

Advanced Artificial Intelligence

汤云波

yunbotang@fzu.edu.cn

福州大学计算机与大数据学院

- **先修课程：**

高级语言程序设计、数据结构、算法设计与分析，
高等数学、线性代数、统计学

- **后续课程：**

深度学习，大数据分析与挖掘，毕业设计

- **建议教材**

书名：《计算智能》书号：ISBN 9787115534767 作者：
毕晓君 出版社：人民邮电出版社出版时间：2020-06

- **考核方式**

考核环节	权重 (%)
期末考试	70
点名/平时作业	30

- **课程特点**


理论性、抽象性较强，实用价值高



知识回顾

人工智能的应用

1. 计算机视觉
 2. 自然语言处理
 3. 语音识别
 4. 泛数据挖掘
- 等等



知识回顾

什么是人工智能？

- 人工智能（Artificial Intelligence），是研究、开发用于模拟、延伸和扩展人的智能的理论、方法、技术及应用系统的一门新的技术科学。
- 人工智能是计算机科学的一个分支，研究如何将人的智能转化为机器智能，或者用机器来模拟或实现人的智能。
- 人工智能是包含广泛、极富挑战性的科学
 - 思维基础：人们长期以来探索研制能够进行计算、推理和其它思维活动的智能机器的必然结果
 - 理论基础：信息论、控制论、系统工程论、计算机科学、心理学、神经学、认知科学、数学和哲学等多学科相互渗透的结果
 - 技术基础：电子计算机和电子技术得到广泛应用的结果

知识回顾

人工智能的目标

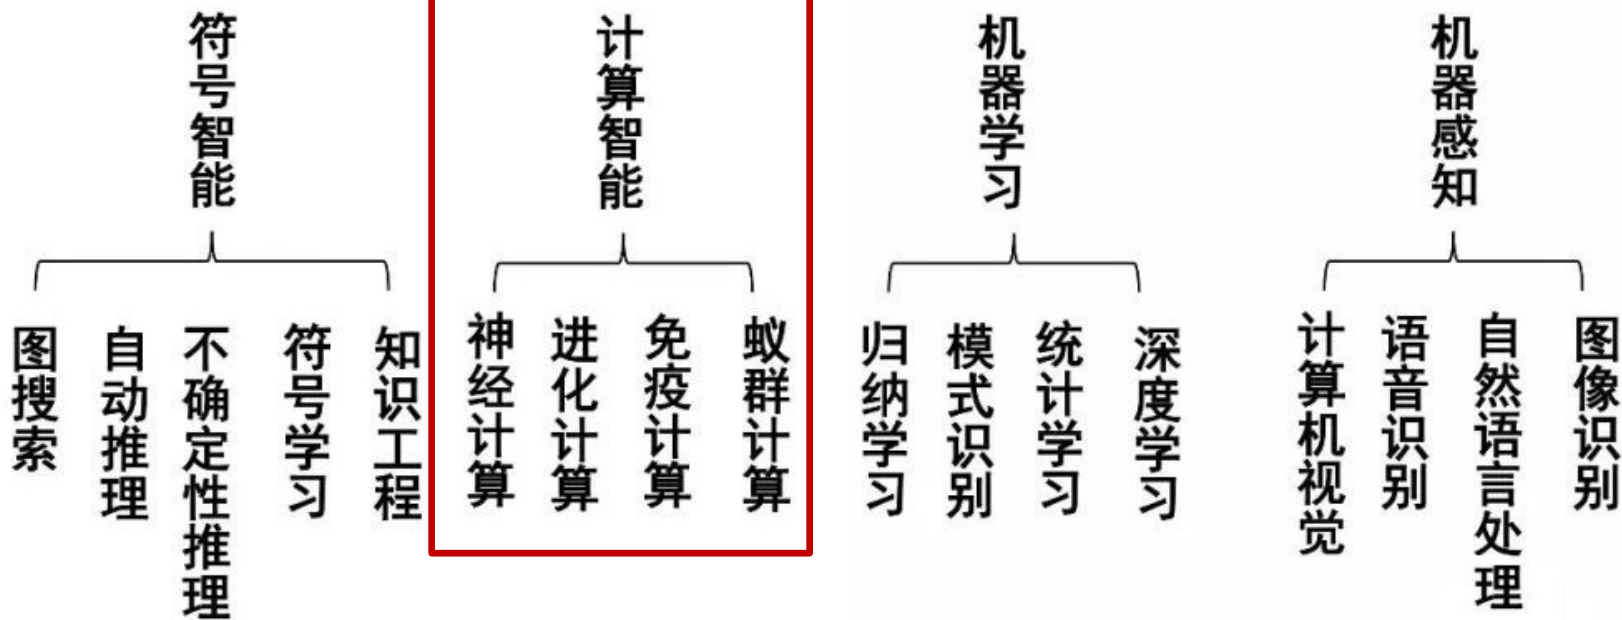
- **近期目标：**研究如何使计算机去做那些靠人的智力才能做的工作
- **最终目标：**探讨智能形成的基本机理，研究利用自动机模拟人的思维过程



知识回顾

人工智能的研究领域

人工智能

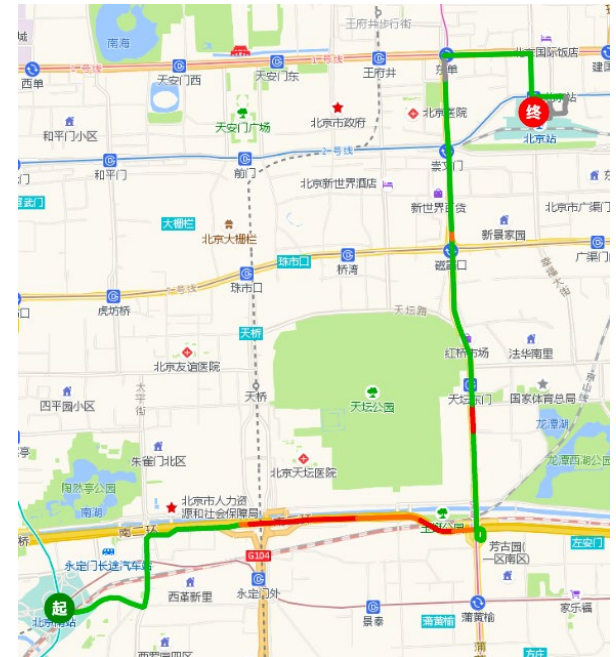
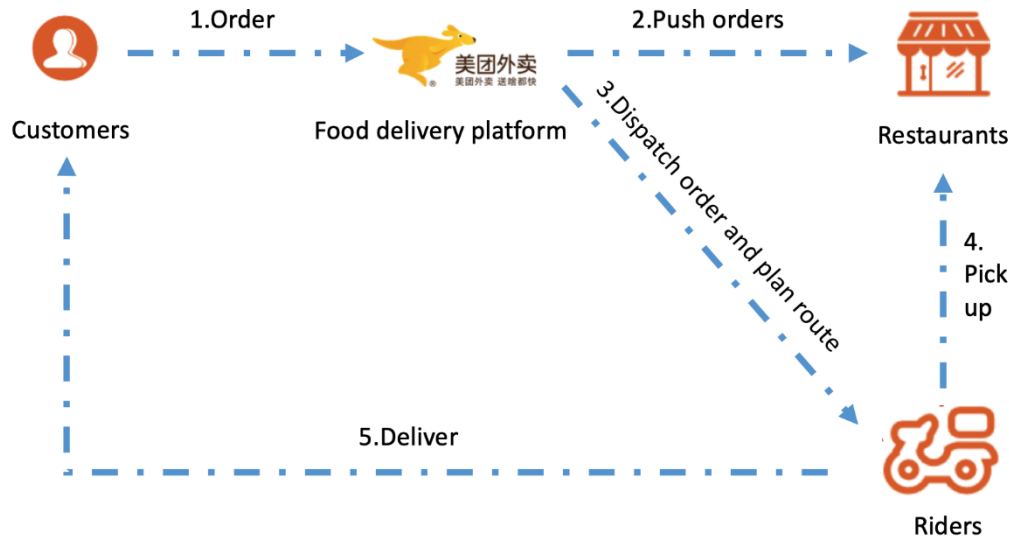


第一章 计算智能方法概述

计算智能概述

- 生物群体的演化、社会集群现象的规律所产生的智能优化算法
- 理论上不如传统优化方法（一阶、二阶梯度）完善,但**全局优化解**获得的可能性较大
- 对目标函数和约束条件**不要求连续性、可微、凸性等**，甚至可以无解析式
- 对数据的不确定性有较强适应性
- 应用于信息处理、调度优化、工程控制、经济管理等等

最优化问题典型案例



最优化问题的数学模型

- 在一定的环境下，根据某种判定条件寻找最佳方案，以获得最大实际价值（最小风险损失）

$$\min_{x \in R^n} F(x) = [f_1(x), f_2(x), \dots, f_h(x)]$$
$$s.t. \begin{cases} g_i(x) \geq 0, i = 1, 2, \dots, m \\ h_j(x) = 0, j = 1, 2, \dots, p \end{cases}$$

- 变量的定义域是离散的，即为离散优化问题；变量的定义域是连续的，即为连续优化问题

最优化问题的分类

- 按目标的数量：单目标和多目标

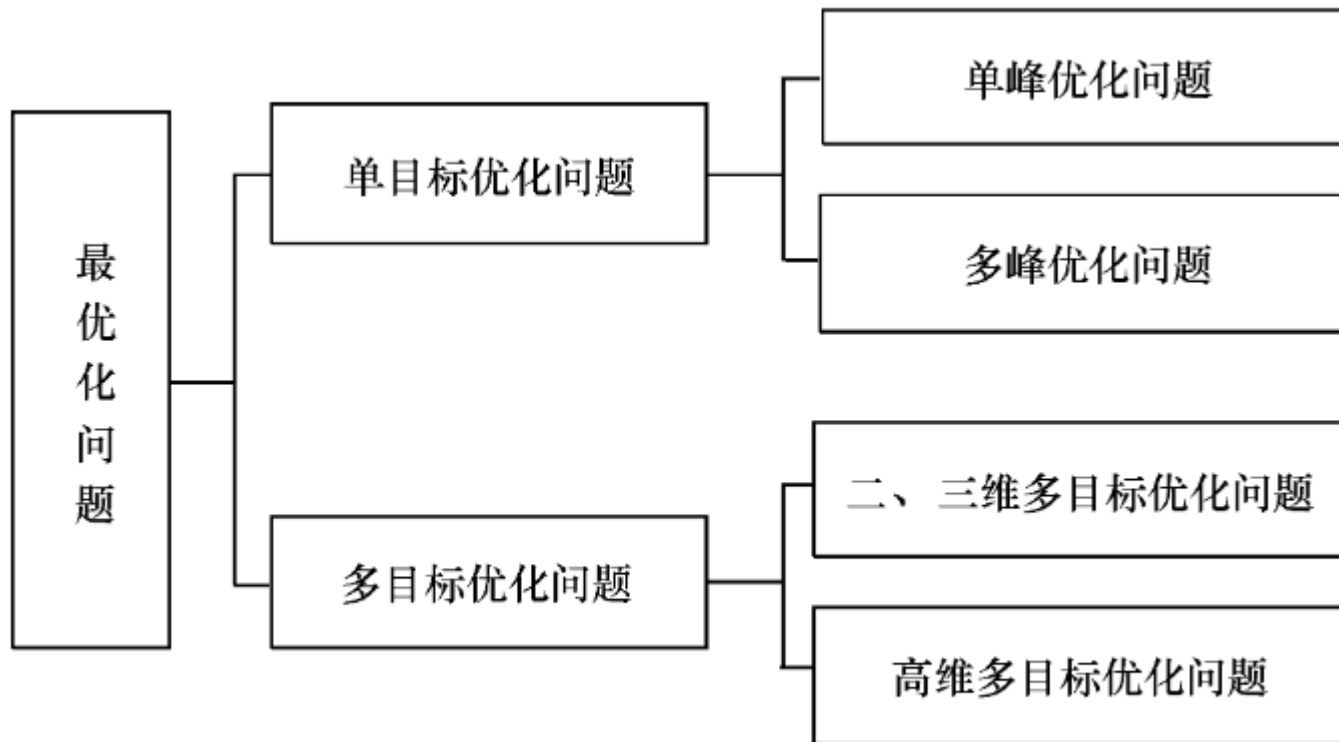


图 1.1 根据目标数量进行的最优化问题分类

最优化问题的分类

- **按变量是否连续：离散变量优化问题和连续变量优化问题**
- **在离散变量优化问题中最常见的是组合优化问题**
- **在连续变量优化问题最常见的是函数优化问题**
- **例：九宫重排，最优排课，旅行推销商，最佳路由等为离散（优化）问题；模式识别（如图像识别、语音识别）和工程结构优化设计等为连续（优化）问题**

最优化问题的分类

- 按目标函数或变量是否受到约束：无约束优化问题和约束优化问题
- 约束条件会使得可行解空间变得不连贯，一般较无约束问题求解难度大

一个图像去噪问题的最优化表达



- 目标 $J(A)=(A$ 的主体与原图尽量接近) $+\alpha\cdot(A$ 尽可能光滑)
 - 求目标的极小值（有时有约束）
-
- 合理的目标形式设计（建模）
 - 求目标极小值的方法（优化）

机器学习与计算智能（最优化）之间的联系

- 建立了许多学习模型模拟人的学习过程，还能完成人难以完成的大数据信息处理工作；但实际上大部分只是样本学习
- 典型：任务（**降维、回归、分类、聚类**等），模型（**主成分分析、k均值聚类、支持向量机、决策树、隐马尔科夫链**等）
- 结构各异，一般都具有大量待定参数。通过学习，模型能实现输入数据输出抽象后的结果（类别、估值等）
- 需要提供大量样本供模型学习，才能逐步调整获得模型最终的参数；
- 模型学习设定的最优化目标函数（以分类问题为例）：
模型的分类错误率尽量小

组合优化问题的局部搜索方法介绍

算法的时间复杂度

- 当组合优化问题的规模较小时，总能通过枚举法获得问题的最优解；但规模较大时，可能产生组合爆炸，难以找到全局最优。
- 一些典型的组合优化问题：TSP问题、背包问题、装箱问题……
- 常见的算法复杂度函数

$O(\log n)$, $O(n)$, $O(n \log n)$, $O(n^2)$,

$O(2^n)$, $O(n^{\log n})$, $O(n!)$, $O(n^n)$

时间复杂性函数比较 (10亿次/秒)


<i>n</i>	10	20	30	40	100
复杂度					
<i>n</i>	10ns	20ns	30ns	40ns	100ns
<i>n</i> log <i>n</i>	10ns	26.0ns	44.3ns	64.1ns	200ns
<i>n</i> ²	100ns	400ns	900ns	1.6μs	10 μ s
<i>2</i> ^{<i>n</i>}	1.0 μ s	1.0ms	1.1s	18.3min	4.0世纪
<i>n</i> !	3.6ms	77.1年	8.4 × 10 ¹³ 世纪	2.6 × 10 ²⁹ 世纪	3.0 × 10 ¹³⁹ 世纪

1ns(纳秒) = 10⁻⁹ s ; 1μs(微秒) = 10⁻⁶ s ; 1ms(毫秒) = 10⁻³ s

TSP问题

Traveling Salesman Problem

从某城市出发遍历所有 n 个城市
一遍且仅一遍再回到出发地，求
最短路径




- 没有通用的求解方法
- NP-hard(Karp,1972)
- 有效的启发式算法 (1973)
- 完全多项式近似方案 (1998)
-

n 个城市,
路线的可能性 $(n-1)!$;
 $O(n!)$;

寻求在可接受的时间内得到满意解的方法

组合爆炸问题—TSP为例



N个城市，路线的可能性 (N-1) !

N=21，小规模问题

(N-1) ! > 10¹⁸

PC, 1亿 (10⁸) 次/秒!

花费 10¹⁰ 秒

1天86400秒 (< 10⁵ 秒)

需要10⁵ 天，约300年!

邻域的概念

- 邻域:一个点附近其它点的集合
- 在距离空间, 邻域就是以某一点为中心的距离域
- 组合优化问题的邻域定义: 设 D 是问题的定义域, 若存在一个映射 N , 使得:

$$N : S \in D \rightarrow N(S) \in 2^D$$

则称 $N(S)$ 为 S 的邻域。



某种序
或关系


2^D : D 的幂集, 所有子集构成

TSP问题的邻域定义示例

- 可能解S：城市序列；邻居S'：交换两城市位置获取
- 例1：简单交换方法

$$S = (x_1, x_2, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_{j-1}, x_j, x_{j+1}, \dots, x_n)$$

$$S' = (x_1, x_2, \dots, x_{i-1}, x_j, x_{i+1}, \dots, x_{j-1}, x_i, x_{j+1}, \dots, x_n)$$




例2：逆序交换方法

邻居 S' ：选取两城市 x_i, x_j ，逆转 x_i, x_j 之间的城市次序

设： $S = (x_1, x_2, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_{j-1}, x_j, x_{j+1}, \dots, x_n)$

则： $S' = (x_1, x_2, \dots, x_{i-1}, x_j, x_{j-1}, x_{j-2}, \dots, x_{i+1}, x_i, x_{j+1}, \dots, x_n)$



局部搜索算法

- **基本思想：在当前点的邻域中搜索，且始终向着离目标最接近的方向搜索。**
- **目标可以是最大值，也可以是最小值。**
- **若无特殊说明，均假定是最小值。**

局部搜索算法 (Local Search)

1) 随机选择一个初始可能解 $x_0 \in D$, $x_b \leftarrow x_0$,

$P = N(x_b)$; 定义指标函数 $f(x)$

2) 若不满足结束条件, 则

Begin

选择 P 的一个子集 P' , x_n 为 P' 中的最优解


如果 $f(x_n) < f(x_b)$, 则 $x_b \leftarrow x_n$, $P \leftarrow N(x_b)$, 转2);

否则 $P = P - P'$, 转2)。

End

3) 输出计算结果, 结束

例：5城市旅行商问题




初始可能解： $x_0 = (a, b, c, d, e)$

指标函数：路径长度， $f(x_b) = f(x_0) = 38$

通过交换两个城市获得邻域

$P = \{(a, c, b, d, e), (a, d, c, b, e), (a, e, c, d, b),$
 $(a, b, d, c, e), (a, b, e, d, c), (a, b, c, e, d)\}$


设每次随机从P中选择一个邻居。



第一次循环

$P = \{(a, c, b, d, e), (a, d, c, b, e), (a, e, c, d, b), (a, b, d, c, e), (a, b, e, d, c), (a, b, c, e, d)\}$

从P中选择一个元素，不妨为 $x_n = (a, c, b, d, e)$,



$$f(x_n) = 42,$$

$$f(x_n) > f(x_b),$$


$$P = P - \{x_n\}$$

$$= \{(a, d, c, b, e), (a, e, c, d, b), (a, b, d, c, e), (a, b, e, d, c), (a, b, c, e, d)\}$$

第二次循环

$P = \{(a, d, c, b, e), (a, e, c, d, b), (a, b, d, c, e),$
 $(a, b, e, d, c), (a, b, c, e, d)\}$

从P中选择一个元素，不妨为 $x_n = (a, d, c, b, e)$,



$f(x_n) = 45,$

$f(x_n) > f(x_b),$

$P = P - \{x_n\}$

$= \{(a, e, c, d, b), (a, b, d, c, e), (a, b, e, d, c),$
 $(a, b, c, e, d)\}$

第三次循环

$P = \{(a, e, c, d, b), (a, b, d, c, e), (a, b, e, d, c),$
 $(a, b, c, e, d)\}$


从P中选择一个元素，不妨为 $x_n = (a, e, c, d, b)$,

$f(x_n) = 44,$

$f(x_n) > f(x_b),$

$P = P - \{x_n\}$

$= \{(a, b, d, c, e), (a, b, e, d, c), (a, b, c, e, d)\}$



第四次循环


$P = \{(a, b, d, c, e), (a, b, e, d, c), (a, b, c, e, d)\}$

从P中选择一个元素，不妨为 $x_n = (a, b, d, c, e)$,

$f(x_n) = 44$,

$f(x_n) > f(x_b)$,

$P = P - \{x_n\} = \{(a, b, e, d, c), (a, b, c, e, d)\}$



第五次循环

$$P = \{(a, b, e, d, c), (a, b, c, e, d)\}$$


从P中选择一个元素，不妨为 $x_n = (a, b, e, d, c)$,

$$f(x_n) = 34,$$

$$f(x_n) < f(x_b),$$

$$x_b = x_n = (a, b, e, d, c),$$

$$P = \{(a, e, b, d, c), (a, d, e, b, c), (a, c, e, d, b), \\ (a, b, d, e, c), (a, b, c, d, e), (a, b, e, c, d)\}$$



第六次循环

$P = \{(a, e, b, d, c), (a, d, e, b, c), (a, c, e, d, b),$
 $(a, b, d, e, c), (a, b, c, d, e), (a, b, e, c, d)\}$

从P中选择一个元素，不妨为 $x_n = (a, e, b, d, c)$,


$$f(x_n) = 44,$$

$$f(x_n) > f(x_b),$$

$$P = P - \{x_n\}$$

$$= \{(a, d, e, b, c), (a, c, e, d, b), (a, b, d, e, c),$$

 $(a, b, c, d, e), (a, b, e, c, d)\}$



第七次循环


$P = \{(a, d, e, b, c), (a, c, e, d, b), (a, b, d, e, c),$
 $(a, b, c, d, e), (a, b, e, c, d)\}$

从P中选择一个元素，不妨为 $x_n = (a, d, e, b, c)$,

$f(x_n) = 39, f(x_n) > f(x_b)$,

$P = P - \{x_n\}$

$= \{(a, c, e, d, b), (a, b, d, e, c), (a, b, c, d, e),$
 $(a, b, e, c, d)\}$



第八次循环

$$P = \{(a, c, e, d, b), (a, b, d, e, c), (a, b, c, d, e), \\ (a, b, e, c, d)\}$$

从P中选择一个元素，不妨为 $x_n = (a, c, e, d, b)$,

$$f(x_n) = 38,$$

$$f(x_n) > f(x_b),$$

$$P = P - \{x_n\}$$

$$= \{(a, b, d, e, c), (a, b, c, d, e), (a, b, e, c, d)\}$$

第九次循环

$$P = \{(a, b, d, e, c), (a, b, c, d, e), (a, b, e, c, d)\}$$

从P中选择一个元素，不妨为 $x_n = (a, b, d, e, c)$,

$$f(x_n) = 38,$$

$$f(x_n) > f(x_b),$$

$$P = P - \{x_n\} = \{(a, b, c, d, e), (a, b, e, c, d)\}$$

第十次循环

$$P = \{(a, b, c, d, e), (a, b, e, c, d)\}$$

从P中选择一个元素，不妨为 $x_n = (a, b, c, d, e)$,

$$f(x_n) = 38,$$

$$f(x_n) > f(x_b),$$

$$P = P - \{x_n\} = \{(a, b, e, c, d)\}$$

第十一次循环

$$P = \{(a, b, e, c, d)\}$$

从P中选择一个元素，不妨为 $x_n = (a, b, e, c, d)$,


$$f(x_n) = 41,$$

$$f(x_n) > f(x_b),$$

$$P = P - \{x_n\} = \emptyset$$

P等于空，算法结束，
得到结果为

$$x_b = (a, b, e, d, c), f(x_b) = 34。$$



局部搜索结果恰好为问题的全局最优解；
一般情况下，未必得到全局最优解。

连续优化问题复习回顾

无约束最优化方法回顾

问题： $\min_{x \in R^n} f(x)$

1) $f \in C^1$, 若 x^* 为 $f(x)$ 的极小点, 则有: $\nabla f(x^*) = \mathbf{0}$ (必要条件)

2) 满足 $\nabla f(x) = \mathbf{0}$ 的点 x , 称为稳定点

稳定点可能是 $\left\{ \begin{array}{l} \text{极大值点} \\ \text{极小值点} \\ \text{两者皆不是} \end{array} \right.$

$$\nabla f(x) = \left(\frac{\partial f(x)}{\partial x_1} \quad \frac{\partial f(x)}{\partial x_2} \quad \dots \quad \frac{\partial f(x)}{\partial x_n} \right)^T$$

3) $f \in C^2, \nabla f(x^*) = \mathbf{0}$, 且 $\nabla^2 f(x^*)$ 是正定的,
 则: x^* 是极小值点 (充分条件)

说明:

$$a) \nabla^2 f(x) = \begin{pmatrix} \frac{\partial^2 f(x)}{\partial x_1^2} & \frac{\partial^2 f(x)}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 f(x)}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f(x)}{\partial x_2 \partial x_1} & \frac{\partial^2 f(x)}{\partial x_2^2} & \dots & \frac{\partial^2 f(x)}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f(x)}{\partial x_n \partial x_1} & \frac{\partial^2 f(x)}{\partial x_n \partial x_2} & \dots & \frac{\partial^2 f(x)}{\partial x_n^2} \end{pmatrix} \text{海色矩阵(Hessian)}$$

b) 一元函数, 充分条件: $f''(x^*) > 0$

$$c) f(x) = \frac{1}{2} x^T A x + b^T x + c, \text{有: } \nabla^2 f(x) = A$$

求解方法概述：

$$1) \text{ 解方程组: } \nabla f(x) = 0 \Leftrightarrow \begin{cases} \frac{\partial f(x)}{\partial x_1} = 0 \\ \vdots \\ \frac{\partial f(x)}{\partial x_n} = 0 \end{cases}$$

$f(x)$ 为二次函数时，线性方程组可解
一般情况下为非线性方程组，难解。常用数值方法近似求解

有时考虑与其用数值方法求解方程组，不如用数值方法直接求极值

2) 迭代法求解的基本步骤:

a) 选择初始点 x_0

b) 确定迭代方向 P_k , 迭代公式: $x_{k+1} = x_k + \lambda_k P_k$

c) 在射线 $x_k + \lambda P_k$ ($\lambda \geq 0$) 上选步长

$$\lambda = \lambda_k \text{ 满足: } f(x_k + \lambda_k P_k) < f(x_k)$$

(保证是下降算法, 也可用一维搜索找到下降最多的 λ 值)

d) 停机条件 (通常): $\|\nabla f(x_{k+1})\| \leq \varepsilon$

3) 一个迭代方法通常要考虑其收敛性：迭代序列中某元素为 x^* 或序列的极限趋向于 x^*

$$\lim_{k \rightarrow \infty} \|x_k - x^*\| = 0$$

4) 算法的收敛速度

$$\lim_{k \rightarrow \infty} \frac{\|x_{k+1} - x^*\|}{\|x_k - x^*\|} = \alpha \begin{cases} \in (0,1), \text{线性收敛} \\ = 0, \text{超线性收敛} \end{cases}$$

$$\lim_{k \rightarrow \infty} \frac{\|x_{k+1} - x^*\|}{\|x_k - x^*\|^2} = \beta \begin{cases} > 0, \text{二次收敛} \\ = 0, \text{超二次收敛} \end{cases}$$

一维搜索方法：

问题： $\min_{-\infty < x < \infty} f(x)$ 思路：先求出稳定点 $f'(x) = 0$

牛顿法：

1) 最早用于方程求根 $\varphi(x) = 0$, $x_{k+1} = x_k - \frac{\varphi(x_k)}{\varphi'(x_k)}$


2) $f(x) \approx f(x_k) + f'(x_k)(x - x_k) + \frac{1}{2} f''(x_k)(x - x_k)^2 \xrightarrow{\text{记为}} \varphi(x)$

$\varphi'(x) = f'(x_k) + f''(x_k)(x - x_k) \xrightarrow{\text{令}} 0$

$$x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k)}$$

性质：

- 1) 收敛速度较快
- 2) 二阶导数存在且需计算
- 3) 初始点应足够靠近极小值点，否则可能不收敛



平分法：

1) 先找到区间 $[a, b]$ 满足： $f'(a)$ 与 $f'(b)$ 异号，区间中有零点
 $f'(x) = 0$ 用平分法搜索

2) $x = \frac{a+b}{2}$, 计算 $f'(x)$

3) $f'(x) \begin{cases} < 0, a \leftarrow x \\ > 0, b \leftarrow x \end{cases}$

- 1) 收敛速度较牛顿法慢
- 2) 计算量较小
- 3) 总能收敛到局部极小点

0.618法:

假设 $f(x)$ 在 $[a, b]$ 中是单峰函数 (另外计算方案), $\alpha = 0.618033988$

1) 求 $x_1 = a + (1 - \alpha)(b - a)$, $x_2 = a + \alpha(b - a)$, $f(x_1) = f_1$, $f(x_2) = f_2$

2) 若 $|b - a| \leq \varepsilon$, 求出近似最优解 $x^* = \frac{a + b}{2}$; 否则转3)

3) $f_1 < f_2 : a \Rightarrow a, x_2 \Rightarrow b, x_1 \Rightarrow x_2, f_1 \Rightarrow f_2$ 转4);

$f_1 > f_2 : x_1 \Rightarrow a, b \Rightarrow b, x_2 \Rightarrow x_1, f_2 \Rightarrow f_1$ 转5);

$f_1 = f_2 : x_1 \Rightarrow a, x_2 \Rightarrow b_1$ 转1);

4) 求 $x_1 = a + (1 - \alpha)(b - a)$, $f(x_1) \Rightarrow f_1$ 转2)

5) 求 $x_2 = a + \alpha(b - a)$, $f(x_2) \Rightarrow f_2$ 转2)

1) 要求函数有较高的解析性质 (单峰)

2) 不用求导, 只需要函数值本身

n维极值的解析方法： 问题： $\min_{x \in R^n} f(x)$

解法： 解析法采用一阶、二阶导数；直接法不用导数只用函数值

梯度法： $f(x) = f(x_k) + (x - x_k)^T \nabla f(x_k) + o(\|x - x_k\|)$

记： $x - x_k = \lambda P, \|P\| = 1, \lambda > 0$;

有： $f(x) = f(x_k) + \lambda P^T \nabla f(x_k) + o(\lambda)$

若： $P^T \nabla f(x_k) < 0, \lambda_k$ 足够小，取： $x_{k+1} = x_k + \lambda_k P$

就有： $f(x_{k+1}) < f(x_k)$

说： P 是点 x_k 的局部下降方向

$$P^T \nabla f(x_k) = \|P\| \cdot \|\nabla f(x_k)\| \cdot \cos \theta \xrightarrow{\min} -\|\nabla f(x_k)\| \quad (\theta = 180^\circ)$$

$f(x)$ 在点 x_k 的梯度方向 $\nabla f(x_k)$ 是函数值局部上升最快的方向；

$-\nabla f(x_k)$ 是函数值局部下降最快的方向。

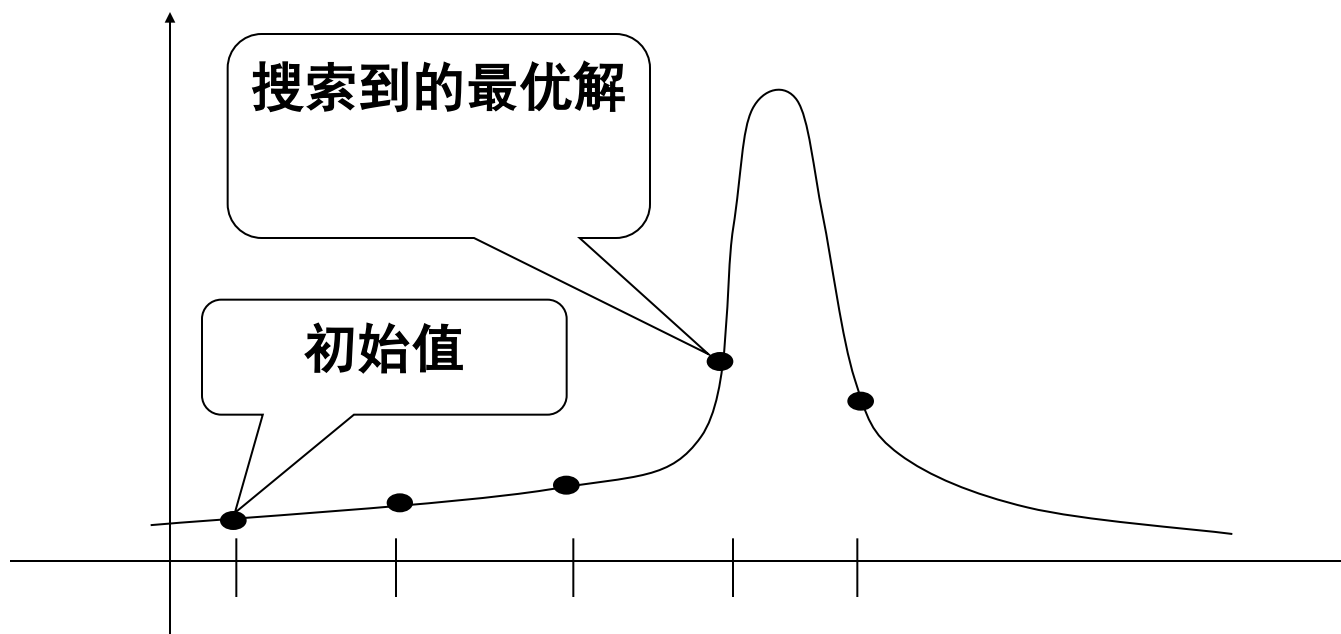
最速下降法： $x_{k+1} = x_k - \lambda_k \nabla f(x_k)$

$$\text{最速下降法: } \mathbf{x}_{k+1} = \mathbf{x}_k - \lambda_k \nabla f(\mathbf{x}_k)$$

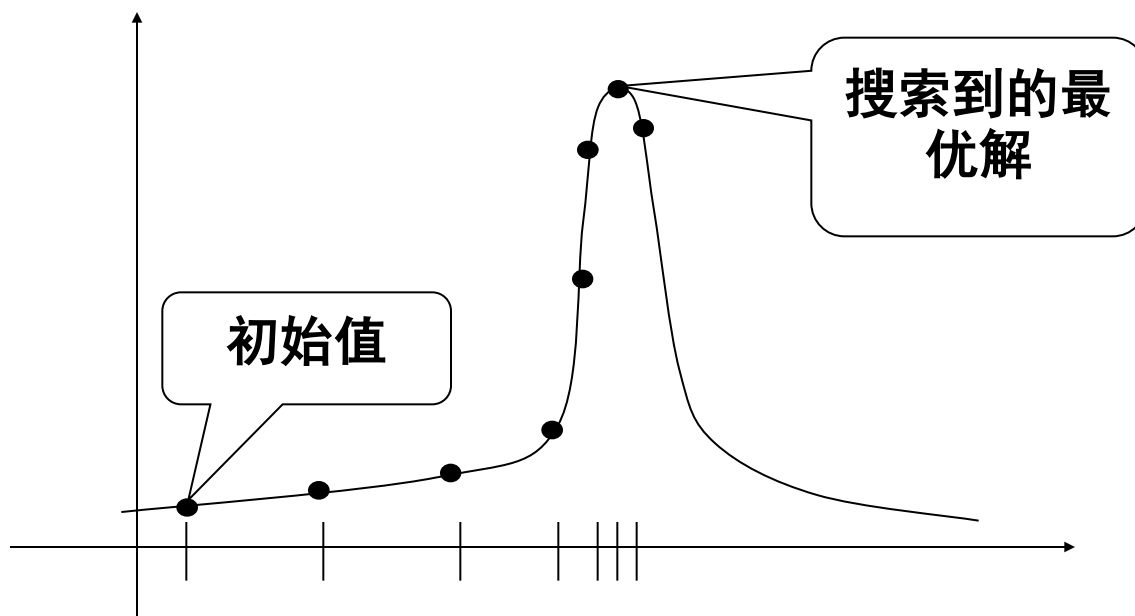
步长 λ_k 的选取问题:

- 1) 定步长: 只能保证一定的精度, 接近极小点时, 步长跨度可能越过极小点;
- 2) 变步长: 按一维搜索方法, 沿方向 $-\nabla f(\mathbf{x}_k)$ 搜索局部极小值点获得 λ_k ;但在接近 \mathbf{x}^* 时, 发生锯齿效应, 造成收敛速度变慢。

- 定步长存在的问题



- 变步长



牛顿法 (n维)

1) *Taylor*展开至二阶:

$$f(x) \approx f(x_k) + (x - x_k)^T \nabla f(x_k) + \frac{1}{2} (x - x_k)^T \nabla^2 f(x_k) (x - x_k)$$

记 $\rightarrow \varphi(x)$

2) $\varphi(x)$ 的极小值点作为 x_{k+1} :

$$\nabla \varphi(x) = \nabla f(x_k) + \nabla^2 f(x_k) (x - x_k) \underline{\underline{= 0}}$$

$$x_{k+1} = x_k - [\nabla^2 f(x_k)]^{-1} \nabla f(x_k)$$

3) 任何二次函数, 用牛顿法, 只需迭代一次就可得到极小点;

但需要计算海色矩阵的逆;

4) 对于非二次函数, 若 $\|x_0 - x^*\| < 1$, 可达二次收敛;

否则不能保证收敛

阻尼牛顿法 (n维)

1) $0 \Rightarrow k$

2) 求: $\nabla f(x_k), [\nabla^2 f(x_k)]^{-1}, P_k = -[\nabla^2 f(x_k)]^{-1} \nabla f(x_k)$

3) 求: $x_{k+1} = x_k + \lambda_k P_k$, 其中 λ_k 满足:

$$f(x_k + \lambda_k P_k) = \min_{\lambda} f(x_k + \lambda P_k)$$

4) 若 $\|x_{k+1} - x_k\| \leq \varepsilon$, 则求出最优解 $x^* = x_{k+1}$; 否则 $k+1 \Rightarrow k$ 转2)

特性:

- 1) 保留了牛顿法的二次收敛特性, 但对初始点的要求不苛刻;
- 2) 仍然要计算 $[\nabla^2 f(x_k)]^{-1}$, 因而要求 $\nabla^2 f(x_k)$ 可逆;
- 3) 即使 $\nabla^2 f(x_k)$ 可逆, 但若是非正定的, 也有可能不收敛。

带约束最优化方法回顾

问题1: $\min_{x \in R^n} f(x)$

$$s.t. \begin{cases} g_i(x) \geq 0, i = 1, 2, \dots, m \\ h_j(x) = 0, j = 1, 2, \dots, p \end{cases}$$

定理(Kuhn - Tucker 最优性必要条件):

设 x^* 为问题1的最优解, 如果在 x^* 处诸起作用约束的梯度向量 $\nabla g_i(x^*), i \in I(x^*)$ 和 $\nabla h_j(x^*) (j = 1, 2, \dots, p)$ 线性无关, 则存在向量 λ^*, μ^* 使下述条件成立:

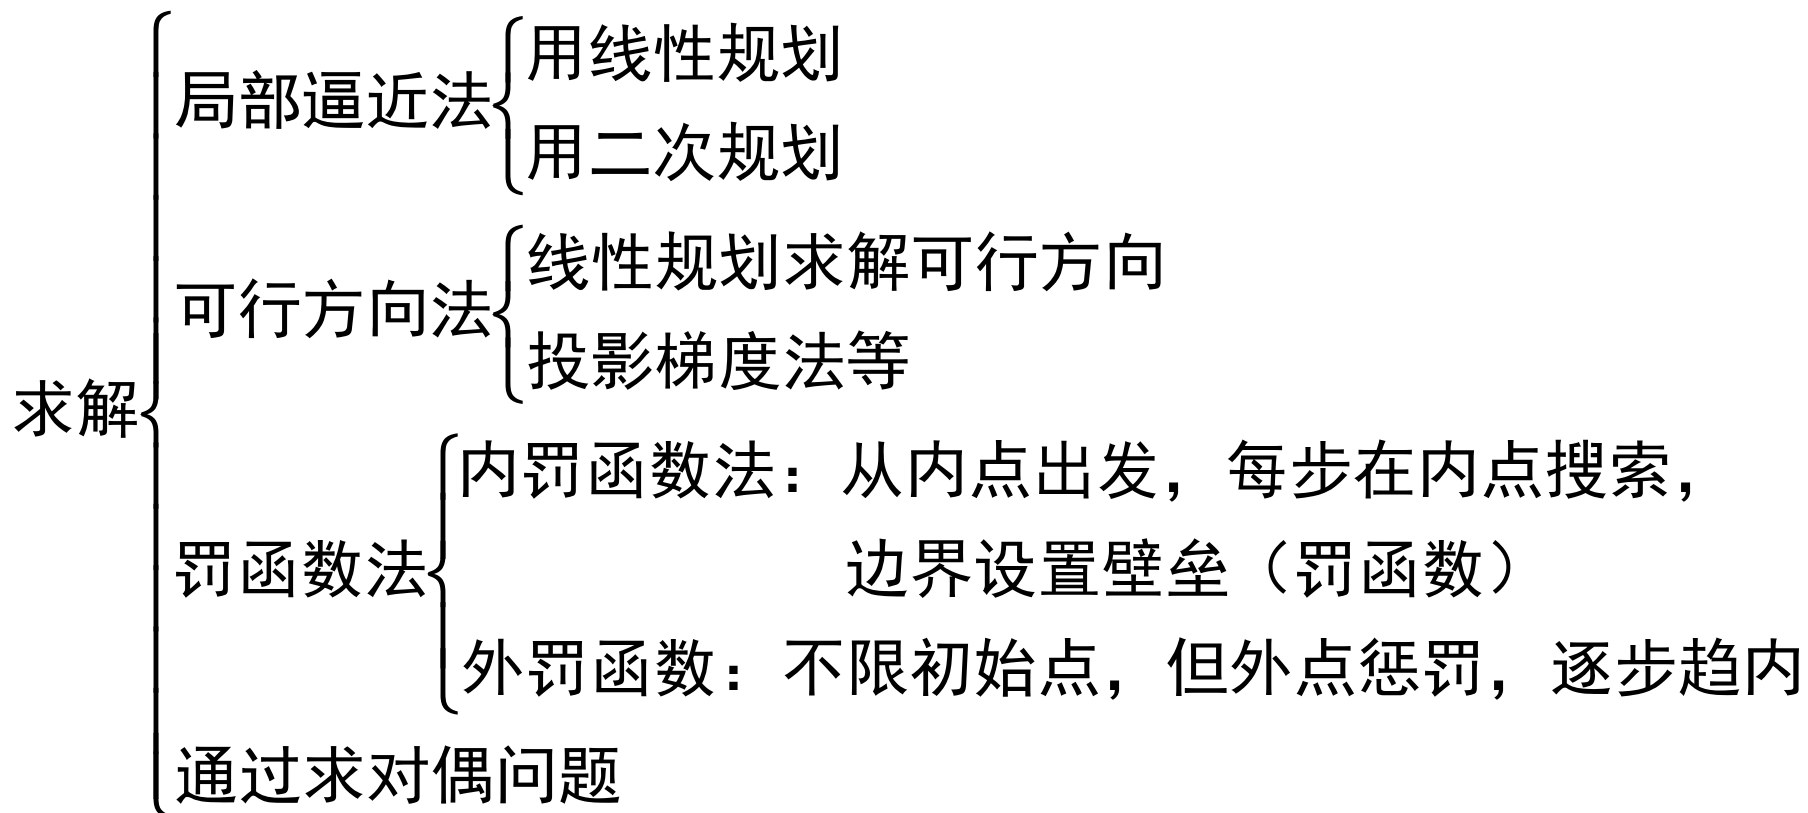
$$\begin{cases} \nabla f(x^*) - \sum_{i=1}^m \lambda_i^* \nabla g_i(x^*) - \sum_{j=1}^p \mu_j^* \nabla h_j(x^*) = 0 \\ \lambda_i^* g_i(x^*) = 0, \lambda_i^* \geq 0, i = 1, 2, \dots, m \end{cases}$$

拉格朗日广义函数与乘子：

$$L(x, \lambda, \mu) = f(x) - \sum_{i=1}^m \lambda_i g_i(x) - \sum_{j=1}^p \mu_j h_j(x)$$

设 x^* 为问题1的最优解，则存在向量 $\lambda^* \geq \mathbf{0}$ 与 μ^* 使 (x^*, λ^*, μ^*) 是 $L(x, \lambda, \mu)$ 的稳定点。 λ^* 与 μ^* 称为原问题的拉格朗日乘子。

对凸规划问题(f 是凸函数， g_i 为凹函数， h_j 为线性函数)， $K-T$ 条件是最优解的充要条件。



外罚函数法：

给定初始点 x_0 ,可以是内点或外点；设误差容许值 $\varepsilon > 0$,
罚因子 $M_0 > 0, c > 1$ 为给定实数；令 $k = 0$

$$1) \text{ 令 } P(x) = \sum_{i=1}^m |\min(0, g_i(x))|^\alpha + \sum_{j=1}^p |h_j(x)|^\beta, \alpha \geq 1, \beta \geq 1 (\text{通常取} 2)$$

$$F_M(x) = f(x) + MP(x) \quad \text{罚函数}$$

2) 求无约束极小问题 $\min_x F_{M_k}(x)$, 得极小值点 x_{k+1}

3) 若 $M_k P(x_{k+1}) < \varepsilon$, 则取 x_{k+1} 为问题 (1) 的最优解, 停机; 否则

$$M_{k+1} \leftarrow cM_k, k \leftarrow k + 1, \text{转} 2)。$$

特性：

1) 对初始点的要求不苛刻；

2) 近似最优解 x_k 可能不是可行解, 实际不可用；

3) M_k 随迭代逐渐增大, 趋于收敛时, 可能增大到引起计算误差。

内罚函数法：

给定初始点 x_0 满足： $g_i(x_0) > 0, i = 1, 2, \dots, m$ ；设误差容许值 $\varepsilon > 0$ ，内罚因子 $r_0 > 0, c > 1$ 为给定实数；令 $k = 0$

1) 令 $B(x) = \sum_{i=1}^m \frac{1}{g_i(x)}$ ； $F_r(x) = f(x) + rB(x)$ 内罚函数

2) 求无约束极小问题 $\min_x F_{r_k}(x)$ ，得极小值点 x_{k+1}

3) 若 $r_k B(x_{k+1}) < \varepsilon$ ，则取 x_{k+1} 为问题（2）的最优解，停机；否则
 $r_{k+1} \leftarrow r_k / c, k \leftarrow k + 1$ ，转2）。

特性：

- 1) 要求初始点必须是内点；
- 2) 只能处理不等式约束；
- 3) 每次迭代点都是可行解，实用有效；
- 4) 随着 r_k 减小，罚函数越来越病态，无约束极小难求。

问题2: $\min_{x \in R^n} f(x)$
 $s.t. g_i(x) \geq 0, i = 1, 2, \dots, m$

乘子法:

$$\text{问题3: } \min_{x \in R^n} f(x), \quad h_j(x) = 0, j = 1, 2, \dots, p$$

给定初始点 x_0 ; 取常数 $c > 0, 0 < \gamma < 1, \alpha > 1$ 和 $\varepsilon > 0$, 给出 μ_1 ,
令 $k = 1$

1) 以 x_{k-1} 为初始点, 求以下函数的无约束极小, 得极小值点 x_k ;

$$M(x, \mu^{(k)}) = f(x) - \sum_{j=1}^p \mu_j^{(k)} h_j(x) + \frac{c}{2} \sum_{j=1}^p (h_j(x))^2$$

2) 若 $\|h(x_k)\| < \varepsilon$, 则以 x_k 为最优解; 否则计算比值 $\|h(x_k)\| / \|h(x_{k-1})\|$,
若该比值 $\geq \gamma$, 则 $\alpha c \Rightarrow c$

3) $\mu_j^{(k+1)} = \mu_j^{(k)} - c h_j(x_k), j = 1, 2, \dots, p; k \leftarrow k + 1$, 转1)。

特性:

- 1) 无约束函数不会发生病态;
- 2) 可以从等式约束推广到不等式约束。

问题1: $\min_{x \in R^n} f(x)$

$$s.t. \begin{cases} g_i(x) \geq 0, i = 1, 2, \dots, m \\ h_j(x) = 0, j = 1, 2, \dots, p \end{cases}$$

乘子法公式如下:

$$M(x, \lambda, \mu) = f(x) + \frac{1}{2c} \sum_{i=1}^m \{[\max(0, \lambda_i^{(k)} - cg_i(x))]^2 - (\lambda_i^{(k)})^2\} \\ - \sum_{j=1}^p \mu_j^{(k)} h_j(x) + \frac{c}{2} \sum_{j=1}^p h_j^2(x)$$

$$\lambda_i^{(k+1)} = \max(0, \lambda_i^{(k)} - cg_i(x_k)), i = 1, 2, \dots, m$$

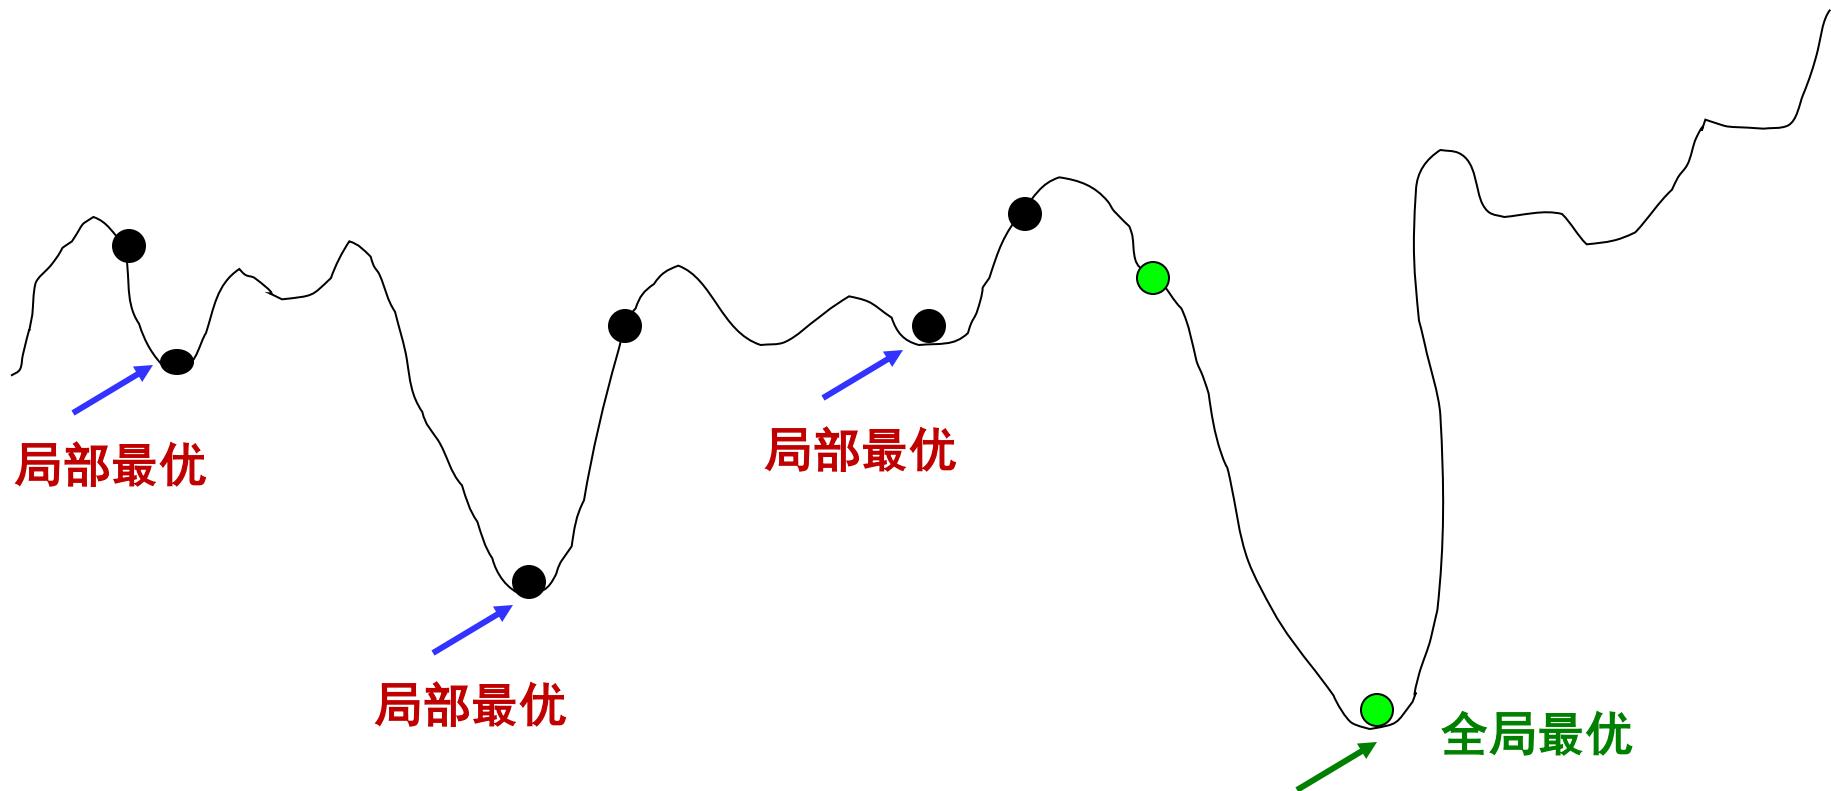
$$\mu_j^{(k+1)} = \mu_j^{(k)} - ch_j(x_k), j = 1, 2, \dots, p$$

传统优化方法的局限性

- 单点方式限制了计算效率的提高
- 易陷入局部最优
- 对目标函数和约束函数的性质有一定的要求，限制了算法的适用范围

局限性之一图示

常导致局部最优，而非全局最优



函数优化


$$f(x) = 10 + \frac{\sin\left(\frac{1}{x}\right)}{(x - 0.16)^2 + 0.1}$$

用于测试的
连续函数极
值求解问题

问题:

在(0,1)内寻找 x_{\max} 使下式成立:


$$f(x_{\max}) \geq f(x), \forall x \in (0,1)$$



Rastrigrin 函数：一个多峰值函数，其局部最优位置随着正弦波动，其全局最优点在 $\mathbf{x}^* = \mathbf{0}$ ，目标函数最优值在 $f(\mathbf{x}^*) = 0$ ，各变量之间独立。


$$f_4(\mathbf{x}) = \sum_{i=1}^n (x_i^2 - 10\cos(2\pi x_i) + 10)$$

多维函数求极值。
有兴趣学习了后续
算法可编程求解




Griewank 函数：一个多峰值函数，变量之间有相互关系，其全局最优点在 $\mathbf{x}^* = \mathbf{0}$ ，目标函数最优值在 $f(\mathbf{x}^*) = 0$ ，各变量之间独立。二维 Griewank 函数如图所示。

$$f_5(\mathbf{x}) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$$



(a) 局部




(b) 全局

Foxhole 函数：一个二维的多峰函数，其全局最优点在 $\mathbf{x}^* = (-32, -32)$ ，目标函数最优值在 $f(\mathbf{x}^*) = 0.998$ 。


$$f_8(\mathbf{x}) = 1 / \left(0.002 + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6} \right)$$

其中

$$[a_{i,j}] = \begin{bmatrix} -32 & -16 & 0 & 16 & 32 & -32 & -16 & 0 & \dots & 0 & 16 & 32 \\ -32 & -32 & -32 & -32 & -32 & -16 & -16 & -16 & \dots & 32 & 32 & 32 \end{bmatrix}$$




$$f_9(\mathbf{x}) = -0.5 + \frac{(\sin \sqrt{x^2 + y^2}) - 0.5}{(1.0 + 0.001(x^2 + y^2))^2}$$




Shaffer's f6 函数三维图


Schwefel 函数：一个多峰函数，局部最优随正弦波动，最优点位于搜索空间的一个角落中， $\mathbf{x}^* = (-420.9687, -420.9687, \dots, -420.9687)$ ， $f(\mathbf{x}^*) = \mathbf{0}$ 。

$$f_6(X) = 418.9829n + \sum_{i=1}^n x_i \sin(\sqrt{|x_i|})$$





现实问题中也存在地形极值问题，虽然未给出解析式



权宜性解决方法一

- 每次不只接受邻域内较优的点，而是依据一定的概率，从邻域内随机选择一个点作为接受点
- 原则是：指标函数优的点，被选中的概率较大，而指标函数差的点，被选中的概率较小。

选择概率的计算

- 目标为求最大值时:

$$P_{\max}(x_i) = \frac{f(x_i)}{\sum_{x_j \in N(x)} f(x_j)}$$

- 目标为求最小值时:

$$\begin{aligned} P_{\min}(x_i) &= \frac{1 - P_{\max}(x_i)}{\sum_{x_j \in N(x)} (1 - P_{\max}(x_j))} = \dots = (\text{略}) \\ &= \frac{1}{|N(x)| - 1} (1 - P_{\max}(x_i)) \end{aligned}$$

局部搜索改进算法1（依概率接受新点）

1) 随机选择一个初始可能解 $x_0 \in D$, $x_b = x_0$,

$$P = N(x_b)$$

2) 如果不满足结束条件, 则

Begin

对于所有的 $x \in P$ 计算指标函数 $f(x)$,

并计算每一个点 x 的概率 $P_{\max}(x_i)$ 或 $P_{\min}(x_i)$

从 P 中依上述概率值选择一个点 x_n ,

$$x_b = x_n, P = N(x_b), \text{ 转2)}$$

End


7) 输出计算结果, 结束

轮盘赌方法



权宜性解决方法二

- 随机生成一些初始点，从每个初始点出发进行搜索，找到各自的最优解。再从这些最优解中选择一个最好的结果作为最终的结果。



局部搜索改进算法2（多个初始点选优）

- 1) $k = 0$
- 2) 随机选择一个初始的可能解 $x_0 \in D$, $x_b = x_0$, $P = N(x_b)$
- 3) 如果不满足结束条件, 则

Begin

选择 P 的一个子集 P' , x_n 为 P' 中的最优解

若 $f(x_n) < f(x_b)$, 则 $x_b = x_n$, $P = N(x_b)$, 转3)

否则 $P = P - P'$, 转3)。

End

- 4) $k = k + 1$
- 5) 如果 k 达到了指定的次数, 则从 k 个结果中选择一个最好的结果输出, 否则转2)
- 6) 输出结果, 结束

局部搜索改进算法3（变步长）

1) 随机选择一个初始可能解 $x_0 \in D$, $x_b = x_0$,
确定一个初始步长后计算 $P = N(x_b)$

2) 如果不满足结束条件, 则

3) Begin

选择 P 的一个子集 P' , x_n 为 P' 中的最优解

如果 $f(x_n) < f(x_b)$, 则 $x_b = x_n$

按照某种策略改变步长, 计算 $P = N(x_b)$,

转2)

否则 $P = P - P'$, 转2)。

End

4) 输出计算结果, 结束

多种方法的集成

- 以上几种解决方法可结合使用，比如第一、第三种方法的结合，就产生了后面介绍的模拟退火方法。

计算智能方法的产生及其特点

- 1943人工神经网络，非线性数学模型的网络建立，全新的迭代逼近求解方法
- 1975遗传算法，模拟大自然生物进化规则
- 寻优与生物进化和社会集群现象极其相似
- 模拟热力学、模拟蚂蚁、模拟人体免疫机制……

计算智能方法的特点

- 隐并行性、协同进化、全局搜索能力强、健壮性佳、适合大规模数据
- 不以达到某个最优条件或理论上的最优解为要旨，更注重计算效率
- 对目标函数和约束条件的性质要求更宽松，无需满足可微、连续、凸性等条件
- 算法的基本思想都是来自于对某种自然规律的模仿，具有人工智能的特点
- 算法以包含多个进化个体的种群为基础，寻优过程就是种群的进化过程
- 算法的理论基础较薄弱，一般不能保证一定收敛到最优解