

系统与amp;控制丛书 C₉

陈杰 辛斌 著

智能优化的探索-开发 权衡理论与方法



科学出版社

013052353

0242. 23

26

系统与amp;控制丛书

智能优化的探索-开发 权衡理论与方法

陈杰 辛斌 著



科学出版社

北京



北航

C1659511

0242. 23

26

013025323

内 容 简 介

智能优化方法是解决复杂优化问题,尤其是复杂系统中产生的各种困难优化问题的有效方法。智能优化方法采用启发方式实现问题的优化求解,具有不依赖于梯度、对优化问题的性质几乎没有要求、适用范围广、适于处理问题的动态变化、易于并行实现等优点。本书介绍了作者在这一研究领域中的最新研究成果,即对智能优化方法的一个本质性的共性问题探索-开发权衡进行的深入研究与分析;介绍了作者针对此问题研究而提出的“最优压缩定理”,并从黑箱优化和灰箱优化两个角度介绍了如何结合具体问题的特点实现智能优化方法的探索-开发权衡,从而实现优化问题的高效求解。

本书可作为信息类以及运筹学等相关专业的科研工作者、工程技术人员、高等院校教师和研究生的参考书或教科书。

图书在版编目(CIP)数据

智能优化的探索-开发权衡理论与方法/陈杰,辛斌著. —北京:科学出版社,2013

(系统与控制丛书)

ISBN 978-7-03-036978-9

I. 智… II. ①陈… ②辛… III. 最优化算法-研究 IV. O242.23

中国版本图书馆 CIP 数据核字(2013)第 044627 号

责任编辑:杨向萍 谷 宾 / 责任校对:张小霞

责任印制:张 倩 / 封面设计:迷底书装

科学出版社出版

北京东黄城根北街 16 号

邮政编码:100717

<http://www.sciencep.com>

骏志印刷厂印刷

科学出版社发行 各地新华书店经销

*

2013 年 6 月第 一 版 开本:B5(720×1000)

2013 年 6 月第一次印刷 印张:13 1/4

字数:265 860

定价:50.00 元

(如有印装质量问题,我社负责调换)

《系统与控制》丛刊编委会

中国科学院数学与系统科学研究院

北京理工大学

中国科学院数学与系统科学研究院

Chinese University of Hong Kong

University of Tokyo

“十一五”国家重点图书出版规划项目

Park Law, University of Texas at Arlington, USA

University of Virginia, USA

Sophia University, Japan

Washington University, USA

Nanyang Technological University, Singapore

Wayne State University, USA

中国科学院数学与系统科学研究院

中国科学院数学与系统科学研究院

清华大学

《系统与amp;控制丛书》编委会

主 编:

郭 雷

中国科学院数学与系统科学研究院

副 主 编:

陈 杰

北京理工大学

编 委:

洪奕光

中国科学院数学与系统科学研究院

黄 捷

Chinese University of Hong Kong

姜钟平

Polytechnic Institute of New York
University, USA

Frank Lewis University of Texas at Arlington, USA

林宗利

University of Virginia, USA

申铁龙

Sophia University, Japan

谈自忠

Washington University, USA

谢立华

Nanyang Technological University, Sin-
gapore

殷 刚

Wayne State University, USA

张纪峰

中国科学院数学与系统科学研究院

周东华

清华大学

编者的话

我们生活在一个科学技术飞速发展的信息时代,诸如宇宙飞船、机器人、因特网、智能机器及汽车制造等高新技术对自动化提出了更高的要求。系统与控制理论也因此面临着更大的挑战。它必须要能够为设计高水平的物理或信息系统提供原理和方法,使得设计出的系统能感知并自动适应快速变化的环境。

为帮助系统控制专业的专家、工程师以及青年学生迎接这些挑战,科学出版社和中国自动化学会控制理论专业委员会合作,设立了《系统与控制丛书》的出版项目。丛书分中、英文两个系列,目的是出版一些具有创新思想的高质量著作,内容既可以是新的研究方向,也可以是至今仍然活跃的传统方向。研究生是本丛书的主要读者群,因此,我们强调内容的可读性和表述的清晰。我们希望丛书能达到这些目的,为此,期盼着大家的支持和奉献!

《系统与控制丛书》编委会

2007年4月1日

前 言

优化问题普遍存在于社会生活与科学工程研究中,产品设计、资源分配、投资管理、生产调度、系统分析与控制中都蕴涵着大量的优化问题。传统优化方法建立在微积分方法的框架上,对问题的性质有较高的要求。随着越来越多的优化问题呈现出高度非线性、多模态、高维度、不确定性甚至动态变化等特征,传统优化方法面临许多新的挑战。而借鉴自然界中的物质和生命的演化规律建立的各种智能优化方法可以较好地处理这些挑战性的问题,而且在实践中得到了大量成功应用。智能优化方法是解决复杂优化问题,尤其是复杂系统中产生的各种困难优化问题的有效方法。智能优化方法采用启发方式实现问题的优化求解,具有不依赖于梯度、对优化问题的性质要求不高、适用范围广、适于处理问题的动态变化、易于并行实现等优点。

从智能优化研究的发展现状来看,智能优化方法种类繁多且层出不穷,不利于从本质上理解智能优化方法的核心与数理本质。因此,对智能优化方法的核心与数理本质进行研究,揭示问题与方法之间的内在联系,建立对智能优化方法的统一性认识,既有利于从种类繁多的算法中抓住智能优化的本质,也可以为从事智能优化研究的学者和使用者提供一种理解智能优化的独特思路。

本书介绍了作者在这一研究领域中的最新研究成果。作者在对智能优化方法的一个本质性的共性问题“探索与开发的权衡”深入研究与分析的基础上,介绍了针对此问题研究而提出的“最优压缩定理”,并从黑箱优化和灰箱优化两个角度介绍了如何结合具体问题的特点实现智能优化方法的探索-开发权衡,从而实现优化问题的高效求解。其中,与黑箱优化有关的内容以有界区域内的无约束连续变量优化问题为对象,介绍了探索-开发互补的变异策略、多样性引导的聚散控制方法和算法的融合策略。灰箱优化部分的内容则以两类典型的具有特定应用背景的组合优化问题为对象,介绍了如何结合问题的具体特点实现搜索空间压缩-探索开发权衡,从而提高问题的求解精度和效率。

本书由5章内容构成。第1章介绍了智能优化的基本概念、研究现状和典型的共性核心问题,以便读者对智能优化形成一个总体认识。第2章重点介绍了作者在智能优化算法的共性核心问题——探索与开发的权衡问题上的研究成果。第3章针对无约束连续变量黑箱优化问题,介绍了三种面向黑箱优化的典型探索-开发权衡方法,包括互补算子的设计、基于种群多样性引导的聚散控制以及不同算法的机制协调方法。第4章和第5章面向实际问题求解,介绍了作战指挥自动化中

涉及的两类典型的组合优化问题的智能优化方法。其中,第4章针对动态武器目标分配问题,第5章针对移动智能体的曲率约束路径规划问题。这两类问题属于灰箱优化问题,都具有特定的问题结构和领域知识,在优化求解方面具有较高的难度,而且都有较强的实时性要求。这两章结合具体问题的求解展示了灰箱优化情形下如何利用领域知识建立有效的探索-开发权衡策略,并通过搜索空间的压缩来降低问题的优化难度,从而实现特定问题的高效求解。

最后,感谢中国自动化学会控制理论专业委员会、《系统与控制丛书》编委会对本书出版的大力支持。感谢国家自然科学基金委员会信息科学部的大力支持,本书相关研究工作得到了国家杰出青年科学基金项目(60925011)、国家自然科学基金重大国际合作研究项目(61120106010)和教育部博士点基金项目(20111101110011)的资助。感谢英国曼彻斯特大学认知与决策科学研究中心的 Yang Jian-Bo 教授和 Xu Dong-Ling 教授给予的帮助和指导。本书的出版还得到了“复杂系统智能控制与决策重点实验室”(国家重点实验室培育基地)的资助,在此表示感谢。

本书是作者近年来在该方面研究成果的系统总结,可作为控制科学与工程、系统科学、管理科学与工程、计算机科学与技术、信息与通信工程等相关学科、专业的教师、学生和研究人员的参考书。由于作者水平有限,书中难免有不妥之处,恳请读者批评指正。

作 者

2013年2月20日

目 录

编者的话

前言

第 1 章 绪论	1
1.1 智能优化	1
1.2 智能优化算法的基本原理	3
1.2.1 遗传算法	3
1.2.2 差分进化算法	4
1.2.3 粒子群优化算法	4
1.2.4 分布估计算法	5
1.2.5 禁忌搜索算法	5
1.3 研究现状	6
1.3.1 智能优化的算法改进研究	6
1.3.2 智能优化算法的理论研究	8
1.3.3 智能优化算法的应用研究	9
1.4 共性核心问题	11
1.4.1 探索与开发的权衡	11
1.4.2 计算代价与求解质量的权衡	13
1.5 本书的主要内容与安排	13
第 2 章 搜索与优化中的探索-开发权衡问题	15
2.1 探索与开发的定义与权衡方式	15
2.2 探索-开发权衡的多阶段随机压缩模型	17
2.2.1 优化难度刻画与最优压缩定理	17
2.2.2 数值分析与比较	27
2.2.3 总结与讨论	35
2.3 问题优化难度分析	37
2.3.1 研究历史与现状	38
2.3.2 欺骗性	39
2.3.3 多模态性	44
2.3.4 多漏斗性	51

2.4 小结	54
第3章 黑箱优化中的探索-开发权衡方法	55
3.1 基于互补变异算子的适应性差分进化算法	55
3.1.1 标准差分进化算法	55
3.1.2 互补变异算子的分配策略	56
3.1.3 数值分析与比较	57
3.2 多样性引导的聚散控制	62
3.2.1 集聚性与弥散性	62
3.2.2 基于种群分布熵的集聚弥散控制	64
3.2.3 基于分布熵的聚散控制算法	67
3.2.4 仿真实验	70
3.3 智能优化算法的机制协调	71
3.3.1 母体算法	72
3.3.2 差分进化与粒子群优化的融合算法	73
3.3.3 融合策略的分类法	75
3.3.4 典型融合策略的实验比较	82
3.4 小结	99
第4章 动态武器目标分配的智能优化	101
4.1 DWTA 模型	101
4.1.1 目标函数	102
4.1.2 约束	103
4.1.3 优化模型	103
4.1.4 DWTA 的测试算例生成	104
4.2 DWTA 快速决策的构造性启发式算法	104
4.2.1 约束处理方法	105
4.2.2 处理流程	105
4.2.3 计算复杂性	107
4.3 DWTA 的搜索算法一:禁忌搜索	107
4.3.1 虚拟排列编码与可行解的生成	107
4.3.2 禁忌搜索算法的操作与步骤	109
4.3.3 算法参数设置	111
4.3.4 DWTA 计算实验	113
4.4 DWTA 的搜索算法二:分布估计算法	116
4.4.1 二进制编码型 EDA	117
4.4.2 虚拟排列编码型 EDA	121

4.4.3 非融合型 EDA 算法的性能比较	128
4.4.4 基于虚拟排列编码和构造性方法的融合型分布估计算法	130
4.5 DWTa 算法的综合比较	134
4.5.1 基本测试	134
4.5.2 算法可扩展性测试	138
4.6 小结	142
第 5 章 移动智能体曲率约束路径规划的智能优化	144
5.1 DTSPN 模型	144
5.2 区域边界双层次采样的模型变换方法	147
5.3 DTSPN 的直接搜索算法一:采用完整编码的遗传算法	149
5.4 DTSPN 的直接搜索算法二:采用完整编码的差分进化算法	150
5.5 基于终端朝向松弛的部分编码差分进化算法	152
5.6 基于终端朝向松弛的融合型差分进化算法	154
5.7 不同 DTSPN 求解算法的实验比较	158
5.7.1 计算实验一:典型 DTSPN 算例	159
5.7.2 计算实验二:一般性对比测试	164
5.8 小结	168
参考文献	169
附录 A 平移向量和旋转矩阵的生成方法	182
附录 B 轮盘赌选择的实现方式	184
附录 C Noon-Bean 变换的 Matlab 代码	185
附录 D 定理 5.1、5.2、5.5、5.6 的证明	188
附录 E 不同情形的边缘路径	196

第 1 章 绪 论

1.1 智能优化

优化是在众多方案中寻找最优方案或满意方案,其在科学研究、工程技术、生产管理等领域中有广泛的应用背景。例如,产品设计中如何选择设计参数,使设计方案既满足设计要求又能降低成本;资源分配中,如何分配有限资源,使分配方案既能满足各方面的基本要求,又能获得好的经济效益。优化这一研究,正是为这些问题的解决,提供理论基础和求解方法,它是一门应用广泛、实用性很强的科学。

智能优化是优化研究的一个重要分支,也是计算智能研究的重要内容之一,它涵盖了采用启发方式求解优化问题的各种算法,如涉及自然机理和生物智能的各种“模拟”型优化算法。在组合优化研究中,这些算法通常又被称为元启发式算法(meta-heuristics,又译作超级启发式算法)。与以牛顿法为代表的传统优化方法相比,这些算法出现的时间相对较晚,而且都具有启发式的问题求解特征,因此通常又被统称作现代启发式优化方法。这些启发式算法具有不依赖于目标函数梯度、不要求目标函数的可微性和连续性、全局优化能力强等优点,并且在解决工程实践中经常遇到的各种复杂优化问题时,具有牛顿法、共轭梯度法等传统优化算法无可比拟的优势。具有代表性的方法包括遗传算法(genetic algorithm,简称 GA)^[1]、蚁群优化算法(简称 ACO)^[2]、粒子群优化算法(particle swarm optimization,简称 PSO)^[3]、免疫算法(简称 IA)^[4]等,这些基本方法源于不同的思想,性能上也各有千秋。

现代优化方法的思想大多来源于自然规律,自然界中存在很多自主优化的现象,挖掘其隐含的规律可以在算法中引进新的机制,对于研究高效的优化方法具有重要意义。以观察和比对思考为主要方式挖掘某种自然现象与优化问题的内在联系,找到它们之间的相似性,促进了各种新思想方法的产生。例如,蚁群优化算法和粒子群优化算法分别对蚂蚁觅食和鸟类飞行的活动行为进行了简单的模拟,从中提取出优化的机制形成了新的思想方法。这种模拟生物群体行为的优化算法还包括细菌算法^[5]、蜂群算法^[6]、鱼群算法^[7]等。免疫算法则模拟了免疫系统识别和消除病原体过程中所具有的学习、记忆和模式识别能力。另一种典型的基于群体演化的优化方法——遗传算法则是对生物进化过程的简单模拟。而模拟退火方法(简称 SA)模拟了一种物理过程,通过对固体金属退火过程中的状态变化规律进行模拟来实现解的迭代更新^[8]。这些受自然规律启发设计而成的优化计算方法在

计算智能领域中又称作自然计算方法(natural computing)(<http://www.springer.com/computer/foundations/journal/11047>),是智能优化研究的一个重要分支。

一些并未借鉴自然规律或模拟自然过程的现代优化方法同样也显现出优异的性能。例如,Glover 提出的禁忌搜索(tabu search,简称 TS)在组合优化问题研究中是一种高效的优化方法^[9],其利用对搜索过程的记忆(memory)来保留所发现的有可能包含在最优解中的解分量,并有效地避免重复搜索。值得一提的是,一些传统优化方法(如分枝定界、动态规划)虽然可以从理论上保证找到最优解,但事实上这些方法都是隐枚举方法,其性能虽然优于穷举法,但计算复杂性非常高。当问题规模不断增大时,这些方法往往会因为无法承受的计算代价而无法在可接受时间内找到最优解(即所谓的“维数灾问题”),因而在实践中通常会采取有限时间截断方式,因而在一般意义上会导致算法的最优性被破坏。从实际应用角度考虑,传统优化方法的适用性往往不如启发式方法,但是传统方法也有其独特的优势,例如,基于梯度搜索的牛顿法等精确方法的局部收敛速度往往比启发式方法快,所获得的局部最优解的精度也较高,而分枝定界法在有效提供目标函数的紧界时可以显著提高搜索效率。

表 1.1 给出了遗传算法、模拟退火算法、粒子群优化算法和蚁群优化算法这四种算法中的核心概念与优化研究中常见术语的对应关系。

表 1.1 四种“模拟”型智能优化算法中的核心概念与优化研究中术语的类比关系

术语	GA	SA	PSO	ACO
解	个体(染色体)	状态	粒子的空间位置	蚂蚁走过的完整路径
目标函数	适应度函数	能量函数	粒子的位置优势	蚂蚁找到的食物量
最优解	适值最高个体	能量最低状态	最佳粒子位置	对应最大食物量的路径
优化	生物种群进化	物质状态的演化	粒子群(鸟群的抽象) 飞行行为的自主优化	蚁群觅食行为的 自主优化
优化原理	通过进化操作 (交叉、变异和选择)进化种群	逐渐降温操作下 实现向最低能量 状态的转移	个体的自我学习 与社会学习	蚂蚁之间的信息素传递 与共享(正反馈机理)

虽然各种优化方法在思想上有所不同,但解的表示和生成方式都是算法设计中最关键的部分。解的表示在遗传算法中又称为编码,适当的表示形式是设计高效算法的重要基础。例如,在包含大量约束的组合优化问题的求解中,理想的表示形式应当有助于设计出高效的算子从而尽可能地生成可行解。解的生成包括初始解的生成和过程解的生成,前者通常采用随机化方式或者采用某种启发式规则、利用问题的有关知识构造初始解,后者则是算法设计的核心部分,体现着算法的

本质。

从信息学的角度讲,优化求解过程相当于一个包含信息获取与利用的采样过程,可以用采样序列 $X_0, \dots, X_{n-1}, X_n, \dots$ 表示一个算法,其中, X_0 表示初始采样点(即初始解), X_n 表示第 n 次采样得到的解,这个序列在搜索空间中构成了搜索的轨迹。所有优化算法都可以用 $X_n = G(X_0, X_1, \dots, X_{n-1})$ 的统一形式来表示,其中, $G(\cdot)$ 表示过程解的生成函数(也称作迭代函数),生成函数利用蕴含在 $X_0, \dots, X_{n-1}$ 中的累积信息来生成新的采样点。不同算法的本质区别体现在 $G(\cdot)$ 的差异上。例如,牛顿法的迭代表达式可以表示为 $X_n = X_{n-1} - \mathbf{H}_{n-1}^{-1} \mathbf{g}_{n-1}$, 其中, $\mathbf{H}_{n-1}^{-1}$ 是 X_{n-1} 对应的 Hessian 阵, $\mathbf{g}_{n-1}$ 是 X_{n-1} 对应的梯度向量。容易看出:牛顿法只利用了与上一次采样有关的信息(包含梯度和曲率)。而对经典遗传算法而言,如果把某时刻的整个群体视为一组采样,那么下一组采样的生成也只与上一组采样有关,这一特性使我们可以采用 Markov 链对遗传算法进行收敛性分析。在经典粒子群优化算法中,生成函数利用的是个体最优信息和邻域最优信息(即当前时刻个体自身发现的最优解和个体所在邻域中所有成员发现的最优解),这两个解都包含在当前的采样序列中。采用何种方式获取信息以及如何利用信息,是区别不同算法的主要依据,也是任何优化算法设计的关键问题。

1.2 智能优化算法的基本原理

本节对后面涉及的五种典型智能优化算法进行简要的介绍,这些算法包括遗传算法、差分进化算法(differential evolution,简称 DE)^[10]、粒子群优化算法、分布估计算法(estimation of distribution algorithm,简称 EDA)^[11] 和禁忌搜索算法。

1.2.1 遗传算法

遗传算法由美国密歇根大学的 Holland 教授于 1975 年提出,是模拟达尔文生物进化论的自然选择和遗传学机理的生物进化过程来搜索最优解的方法。经过数十年的发展,遗传算法已经形成了一个庞大的算法类,其算法变体不胜枚举,应用也不断拓展。

遗传算法的作用对象是种群,种群中的每个个体对应于所要求解问题的一个解。个体在微观层次通常又称作染色体,染色体按一定形式(如二进制位串或符号的排列形式)编码来表示一个解。遗传算法通过对所有个体施加交叉(crossover)、变异(mutation)和选择(selection)等进化操作,使个体和种群的适值不断改进,从而达到趋向最优的目的。交叉操作借鉴了生物进化中两性繁殖的作用方式,从上一代种群中选择两个个体作为产生下一代个体的父代样本,然后对这两个样本的

染色体进行基因对换操作来产生新的个体。变异操作通过对染色体的某些基因位点(gene locus)进行突变来产生新的个体,变异的主要作用在于保持种群的多样性。在种群中多数个体趋同的情况下,交叉操作能够产生的不同于父代的个体的数量非常有限,甚至重复产生相同的解,而变异操作可以较为有效地异化种群中的个体,增加多样性,从而在一定程度上避免算法陷入早熟收敛。选择操作对经过交叉和变异操作产生的子代个体及其父代个体进行比较,通常选择适值较高的个体保留到下一代。交叉、变异和选择操作的循环执行构成了遗传算法的主要流程。

1.2.2 差分进化算法

差分进化算法由 Storn 和 Price 于 1995 年提出,最早用来解决切比雪夫多项式问题^[10]。差分进化算法也是一种基于种群的进化算法,包含变异、交叉和选择操作,按照变异、交叉、选择操作的循环使种群不断进化。差分进化算法的最大特色体现在变异算子的设计上。遗传算法的变异算子作用在单个个体上,而差分进化的变异算子包含多个个体,先从种群中选择一个个体或多个个体的组合形式作为基向量,并选择不同个体的差分来构成差分向量,最后以基向量和差分向量的组合来产生变异向量。变异产生的个体与父代个体进行交叉操作,然后与父代进行竞争,较优者保留到下一代。

Storn 和 Price 提出差分进化算法时借鉴了 Nelder-Mead 单纯形法的一些思想^[10],具体表现在差分变异操作的设计上,这也是差分进化算法中最大的创新所在。大量应用实践和性能测试比较表明:差分进化算法是一种性能非常优异的数值优化算法^[12]。基于差分进化算法设计的一种进化约束优化算法在 2006 年 IEEE 举办的进化计算大会(CEC'06)的实参约束优化比赛中排名第一,一种基于差分进化的 MOEA/D 算法在 2009 年 IEEE 进化计算会议(CEC'09)的多目标优化比赛中排名第一,在 CEC'09 的动态与不确定环境下优化比赛中,差分进化算法同样排名第一。

1.2.3 粒子群优化算法

粒子群优化算法由美国学者 Kennedy 和 Eberhart 于 1995 年提出,模拟了社会性动物的群智能行为,如鸟群和鱼群的集体觅食行为。动物学家对鸟群飞行行为的研究表明:鸟类在飞行过程中对自身位置进行调整时会模仿相邻伙伴的行为。其实,这种社会性学习行为普遍存在于各种动物之中。在粒子群优化算法描述的群智能框架下,学习是一个核心概念,任何个体都处于某个社会结构之中,除了依靠自身的经验进行学习外,还要向所处社会中的优秀个体进行学习。

粒子群优化算法通常采用二阶运动模型,即每个粒子(个体)包含位置和速度

两种属性。位置的变化由速度直接体现。速度的调整包含了三个部分:惯性、自身最优的趋向性(个体经验)和社会最优的趋向性(社会学习)。所谓的社会最优是指当前个体所处邻域中的最优位置,与当前个体相邻的所有邻居个体构成一个邻域。每次迭代过程中产生的速度由以上三部分叠加而成。在迭代过程中,随着自身最优和社会最优的更新,粒子的速度将不断调整。

1.2.4 分布估计算法

分布估计算法的概念最早是由 Mühlenbein 等学者在 1996 年提出的,这类算法在 2000 年之后得到迅速发展,目前已经成为进化计算研究中的一类重要算法^[13]。分布估计算法通过统计学习的手段建立解空间中优秀个体的分布概率模型,依据得到的模型来采样生成新的解并对概率模型进行更新,其总体上采用“采样—建模—采样—建模(或更新模型)……”的循环模式来实现对解空间的采样搜索。这类算法本质上是一种统计学习算法,不采用遗传算法中的交叉、变异等微观操作,而是在“宏观”层次上对多个解构成的种群进行统计分析和概率建模。

根据概率模型的复杂度,分布估计算法可以分为变量无关的分布估计算法、双变量相关的分布估计算法和多变量相关的分布估计算法。变量无关的分布估计算法假设变量之间是不相关的,可以独立地对各维变量分别建模,这类算法的代表如基于种群的增量学习算法(population-based incremental learning,简称 PBIL)^[14]和单变量边际分布算法(univariate marginal distribution algorithm,简称 UMDA)^[15]。双变量相关的分布估计算法则假设变量之间最多两两相关,其代表性算法如 De Bonet 提出的 MIMIC 算法^[16]、Baluja 提出的 COMIT 算法^[17]、Pelikan 等提出的 BMMA 算法^[18]等。多变量相关的分布估计算法采用更复杂的学习算法来构造概率模型,其典型代表如分解式分布算法(factorized distribution algorithm)^[19]和贝叶斯优化算法(Bayesian optimization algorithm)^[20]。其中,贝叶斯优化算法同时对概率模型的结构和参数进行学习,结构学习的目的在于发掘变量之间的相互依赖关系,而参数学习则学习有关变量的条件概率。一般而言,分布估计算法的概率模型越复杂,其适于求解的问题范围越广,因为其考虑了变量之间可能存在的复杂依赖关系,但相应的计算复杂性也越高。在利用分布估计算法求解实际问题时,算法设计者往往需要根据问题特征和问题求解的特定要求在模型的适用性和计算复杂性之间做出权衡。

1.2.5 禁忌搜索算法

禁忌搜索算法是局部邻域搜索算法的推广,由 Glover 于 1986 年提出,主要用于解决组合优化问题,是一种非常高效的邻域搜索算法。它的特点是采用了禁忌

技术,简言之,即禁止重复已执行的操作。禁忌搜索算法采用一个禁忌表(tabu list)来记录已经执行过的解生成操作,并设置相应的禁忌长度,在后续搜索中根据禁忌表中的信息不再或有选择地执行相应的操作,以此避免短期内重复访问相同的解。与前面所述的四种算法不同,禁忌搜索算法不是基于群体演化的优化算法,而是一种基于单解迭代的算法。禁忌搜索是一种典型的利用记忆(memory)机制来提高搜索效率的优化方法。

1.3 研究现状

本节从智能优化的算法改进研究、理论研究和应用研究三个方面对智能优化的研究现况进行简要的介绍。

1.3.1 智能优化的算法改进研究

各种算法自提出以后出现了大量的改进性算法,改进的思想和方法各式各样,另外还有结合具体优化问题专门设计的算法变体。常见的算法改进策略包括设计新的算子、参数的动态调节、拓扑的设计与调节、学习方式的设计与调节、多种群策略、不同算法的融合(hybridization)等。

新算子的设计方式有很多选择,如针对遗传算法,很多学者提出了各种不同的交叉、变异和选择算子^[21],差分进化算法提出后也产生了多种差分变异算子^[10],而差分进化算法的“差分变异”概念本身可以视为对遗传算法中传统变异算子的扩展;新算子也可以通过对不同算法进行融合的方式来构造^[22]。算法的参数调节是算法改进研究中最常见的策略,参数的动态调节可分为适应性调节(adaptive tuning)、自适应性调节(self-adaptive tuning)和非适应性调节(non-adaptive tuning)三种基本类型^[23]。适应性调节根据参数在搜索过程中发挥的作用来调整参数,对目标函数值的改进产生较大贡献的参数或参数组合将在下一步搜索中得到更多的采用,因此适应性调节是一种基于在线搜索状况反馈的调节方式,它的基本特征是在参数的调节与算法在线性能之间直接建立了关联。自适应性调节的基本思想是将参数视为解的一部分,使之同决策变量一起参与进化过程。非适应性调节本质上是一种纯粹基于人工经验设置的调节方式。

拓扑的设计与调节主要针对粒子群优化算法和采用多种群协同搜索的进化算法。Kennedy 在 PSO 研究中借鉴小世界思想提出了种群的“邻域拓扑”(neighborhood topology)概念^[24,25],所谓的邻域拓扑实质上是指种群成员之间的信息联接关系,反映的是种群内的信息互联结构。在原始 PSO 算法中,种群中所有成员互通信息,所有个体在任何时刻都知道其他个体找到的最优位置信息。Kennedy 和 Mendes 的研究表明:拓扑结构对 PSO 的性能有显著影响,全连通拓扑结构的信息