

Dynamic Multi-objective Particle Swarm Optimizer Algorithm and Applications

动态多目标粒子群 优化算法及其应用

潘峰 李位星 高琪 著



动态多目标粒子群 优化算法及其应用

潘 峰 李位星 高 琪 著

 北京理工大学出版社

BEIJING INSTITUTE OF TECHNOLOGY PRESS

版权专有 侵权必究

图书在版编目 (CIP) 数据

动态多目标粒子群优化算法及其应用/潘峰, 李位星, 高琪著. —北京:
北京理工大学出版社, 2014. 7

ISBN 978 - 7 - 5640 - 9090 - 6

I. ①动… II. ①潘… ②李… ③高… III. ①多目标 (数学) - 算法 - 研究
IV. ①O224

中国版本图书馆 CIP 数据核字 (2014) 第 080479 号



出版发行 / 北京理工大学出版社有限责任公司

社 址 / 北京市海淀区中关村南大街 5 号

邮 编 / 100081

电 话 / (010) 68914775 (总编室)

82562903 (教材售后服务热线)

68948351 (其他图书服务热线)

网 址 / <http://www.bitpress.com.cn>

经 销 / 全国各地新华书店

印 刷 / 保定市中画美凯印刷有限公司

开 本 / 710 毫米 × 1000 毫米 1/16

印 张 / 15.75

责任编辑 / 封 雪

字 数 / 256 千字

文案编辑 / 封 雪

版 次 / 2014 年 7 月第 1 版 2014 年 7 月第 1 次印刷

责任校对 / 周瑞红

定 价 / 60.00 元

责任印制 / 王美丽

图书出现印装质量问题, 请拨打售后服务热线, 本社负责调换

前言

大多数实际的优化问题，特别是在设计过程中，需要同时优化多个目标函数，还要面临复杂的动态环境。因此动态多目标优化问题在实际优化设计中是普遍存在的一类复杂优化问题。具体而言，动态多目标优化问题是指目标函数的个数、决策空间、维度等随时间而变化的优化问题，也包含一些约束条件参数等发生改变的多目标优化问题。动态多目标优化有着非常广泛的应用背景，已经成为智能优化研究领域的热点，目前，越来越多的学者开始对其展开深入研究，提出了不少相关理论、各具特色的研究方法以及具体算法。

无人机任务指派问题就是一个典型的包含约束的动态多目标优化问题。面对日趋复杂的现代战场环境，无人机在作战行动中需要执行的战术任务数量规模越来越大，且任务越来越趋于多重性和协同性。因此在求解无人机任务指派问题时，除了需要考虑任务本身的构成要素（如任务兵力、目标分布、任务类型等）的要求之外，还必须考虑多机之间协调一致共同执行任务的约束关系，根据战术任务需求和任务规划的优化指标为各无人机制订出协同的任务规划，使其整体作战效能最优或近似最优。

本书内容取材新颖，覆盖面较广，深入浅出，注重理论与实践相结合。在全面总结国内外关于动态多目标优化问题及其粒子群优化算法发展现状、基础理论及实现技术的基础上，着重介绍了基于粒子群优化计算的动态多目标优化方面的研究成果，主要包括：多目标、动态无约束粒子群优化算法；多种群协同粒子群优化算法求解动态环境优化问题；含有约束的优化问题及其 PSO 求解；动态多目标优化问题研究及其粒子群优化；动态多目标粒子群算法性能评价指标度量方法；动态多目标优化问题测试集；UAV 任务指派问题研究等。

本书可供理工科院校计算机、自动化、信息、管理、控制与系统工程等专业的高年级本科生、研究生和教师、科研工作者阅读，也可供自然科学和工程技术领域相关人员参考。

希望本书起到抛砖引玉的作用。

作 者

目 录

第1章 绪论	1
1.1 引言	1
1.2 粒子群算法简介	2
1.2.1 粒子群算法的研究背景	2
1.2.2 粒子群算法的基本描述	3
1.2.3 粒子群算法的基本应用	5
1.3 动态多目标优化问题及其粒子群算法研究	5
1.3.1 动态多目标优化问题及基本概念	5
1.3.2 多目标优化问题及其 PSO 算法研究	6
1.3.3 动态优化问题及其 PSO 算法研究	7
1.3.4 带约束的优化问题及其 PSO 算法研究	9
1.4 无人机任务指派问题研究	10
1.4.1 无人机任务指派问题研究背景	10
1.4.2 国内外无人机任务指派研究现状	11
1.4.3 国内外求解无人机任务指派方法研究现状	14
1.5 本书的体系结构	17
1.6 本章小结	19
参考文献	19
第2章 多目标优化问题研究及其粒子群优化	27
2.1 多目标优化问题研究	27
2.1.1 多目标优化问题的描述	28
2.1.2 多目标优化问题的研究发展	28
2.1.3 多目标优化问题的实际应用	32

2.2 多目标优化算法的性能度量和测试问题	33
2.2.1 多目标优化算法的性能度量	33
2.2.2 多目标优化算法的测试问题	34
2.3 不同算法在多目标优化中的应用	35
2.3.1 古典的多目标优化方法	36
2.3.2 基于进化算法的多目标优化方法	37
2.3.3 基于人工免疫系统的多目标优化方法	38
2.3.4 基于分布估计的多目标优化方法	41
2.3.5 基于粒子群算法的多目标优化方法	42
2.4 多目标粒子群优化算法	43
2.4.1 基本多目标粒子群优化算法及其流程	44
2.4.2 MOPSO 算法描述	46
2.4.3 数值实验及结果分析	48
2.5 本章小结	55
参考文献	55
第3章 动态环境及动态粒子群优化算法研究	60
3.1 动态优化问题研究	61
3.1.1 动态优化问题的定义及其分类	61
3.1.2 动态环境变化的数学表示	62
3.1.3 动态优化问题的标准测试函数	65
3.1.4 动态优化问题的性能评价	71
3.2 动态优化问题中 PSO 搜索策略	74
3.2.1 针对动态问题的 PSO 改进搜索策略	75
3.2.2 基于种群的搜索策略	76
3.3 环境变化检测方法	78
3.3.1 无环境动态检测方法	79
3.3.2 有环境动态检测操作	79
3.4 动态响应策略	80
3.4.1 主动式策略	81

3.4.2 反应式策略	82
3.4.3 混合式策略	83
3.5 多种群协同 PSO 算法求解动态环境优化问题	83
3.5.1 算法描述	83
3.5.2 仿真实验	85
3.6 本章小结	91
参考文献	92
第 4 章 含有约束的优化问题及其 PSO 求解	96
4.1 约束优化问题研究	96
4.1.1 约束优化问题的模型及基本概念	97
4.1.2 约束优化问题的基准测试函数	97
4.1.3 约束优化问题的性能指标	98
4.1.4 约束优化问题的难点分析	99
4.2 有关约束的处理策略	101
4.2.1 约束惩罚和目标函数法	102
4.2.2 约束与目标的分离策略	104
4.2.3 基于 Pareto 原则的约束处理(多目标处理法)	109
4.2.4 其他约束处理方法	111
4.3 线性约束问题	114
4.4 约束满足问题	115
4.5 本章小结	116
参考文献	117
第 5 章 动态多目标优化问题研究	122
5.1 动态单目标优化问题的研究	122
5.1.1 动态单目标优化问题的定义	122
5.1.2 动态单目标优化算法的研究现状	123
5.2 动态多目标优化问题的描述	124
5.2.1 动态多目标优化问题的定义	124
5.2.2 动态多目标问题的分类	125

5.3 动态多目标算法的研究现状	126
5.3.1 静态多目标算法应用于动态问题	127
5.3.2 新动态多目标算法的提出	129
5.3.3 动态问题静态化	129
5.3.4 动态多目标问题算法设计的通用机制	129
5.3.5 基于预测机制的动态多目标算法	130
5.4 动态多目标优化问题的测试函数	131
5.4.1 DMOPs 测试函数概述	131
5.4.2 FDA 测试函数集	131
5.4.3 其他测试函数集	136
5.5 动态多目标优化算法的性能评价指标	140
5.6 本章小结	143
参考文献	143
第6章 动态多目标粒子群优化算法研究	147
6.1 动态算法中常用的环境变化处理策略	148
6.2 基于 MOPSO 算法的动态多目标算法	149
6.2.1 MOPSO 算法	149
6.2.2 DMOPSO 算法流程	150
6.3 基于 VEPSO 算法的动态多目标算法	151
6.3.1 VEPSO 算法的基本流程	152
6.3.2 DVEPSO 算法	152
6.4 基于 DMOPSO 和 DVEPSO 算法的数值实验及分析	153
6.4.1 实验设计与参数设置	153
6.4.2 测试函数	154
6.4.3 性能评价指标	156
6.4.4 结果分析	156
6.5 基于自变量维数变化的 DMPSO 算法	164
6.5.1 问题描述	164
6.5.2 动态多目标优化粒子群算法(DMPSO)	165

6.5.3 基于自变量维数变化的 DMPSO 算法描述	167
6.5.4 数值实验仿真	169
6.6 本章小结	172
参考文献	173
第 7 章 动态多目标异构无人机指派问题	176
7.1 无人机任务指派问题的研究和发展方向	177
7.1.1 无人机任务指派问题的研究	177
7.1.2 无人机任务指派的发展方向	178
7.2 多 UAV 任务控制体系结构	180
7.2.1 集中式控制体系	180
7.2.2 分布式控制体系	181
7.3 UAV 任务指派问题建模	183
7.3.1 UAV 任务指派问题描述	183
7.3.2 UAV 协同任务类型	184
7.3.3 任务指派计划评价指标	185
7.3.4 无人机协同多任务分配约束条件	186
7.3.5 动态环境定义	188
7.4 常见的任务指派问题数学模型	189
7.4.1 基于市场竞争拍机制的协商模型	189
7.4.2 整数线性规划模型	191
7.4.3 动态网络流模型	191
7.4.4 基于车辆路径问题模型	192
7.4.5 多旅行商问题模型	192
7.5 常见的无人机任务分配算法	193
7.5.1 进化算法求解 UAV 任务指派问题	193
7.5.2 遗传算法求解 UAV 任务指派问题	194
7.5.3 禁忌搜索求解 UAV 任务指派问题	194
7.5.4 粒子群算法求解 UAV 任务指派问题	195
7.6 本章小结	195

参考文献	195
第8章 无人机任务指派问题求解	200
8.1 基于约束条件下的 UAV 任务指派建模	200
8.1.1 UAV 任务指派的约束优化问题模型	200
8.1.2 相关定义	202
8.1.3 任务指派评价指标	204
8.2 无人机任务指派问题中的多目标处理	206
8.2.1 多目标转化为单目标策略	206
8.2.2 基于 Pareto 最优解集的多目标优化处理	206
8.3 约束描述和处理	209
8.3.1 约束定义	209
8.3.2 约束处理	209
8.4 无人机任务指派问题的求解	211
8.4.1 基于 ROV 规则的编码设计	211
8.4.2 基于分离索引策略的适应度函数设计	212
8.4.3 UAV 任务指派的 PSO 优化算法设计	212
8.5 数值实验结果及分析	216
8.5.1 实验设计	217
8.5.2 基于构造解的约束处理实验	217
8.5.3 分离索引策略约束处理	224
8.5.4 动态多目标 UAV 指派问题仿真实验	234
8.6 本章小结	239
参考文献	240

第 章

绪 论

本章作为绪论,主要概述了粒子群优化算法的研究背景并对粒子群优化算法进行了基本描述,且系统全面地介绍了动态多目标粒子群优化算法的基本情况。在此基础上,介绍无人机任务指派问题的研究背景及研究现状,为本书后续章节将动态多目标粒子群优化算法应用于解决无人机任务指派问题做好了铺垫。最后给出了本书的体系结构,并简要介绍了各章的主要内容。



1.1 引言

动态多目标优化问题是目标函数的个数、决策空间、维度等随时间而变化的优化问题,也包含一些约束条件参数等发生改变的多目标优化问题。动态多目标优化问题有非常广泛的应用背景^[1],比如当导弹的打击目标改变时,需要对导弹的飞行轨迹、控制参数、攻角仰角等多个目标进行优化;在航空运营中,受恶劣天气、飞机故障、顾客随机意外等因素影响的航空调度问题,需要考虑旅客滞留时间、运营成本等多个因素而重新优化,这些普遍存在于现实世界的动态多目标优化问题迫切需要有效的方法来提高针对问题的求解能力。动态多目标优化问题已经成为目前智能优化研究领域的热点^[1],越来越多的学者开始展开深入研究,并提出了不少相关理论、各具特色的研究方法以及具体算法^[2-5]。

面对日趋复杂的现代战场环境,无人机在作战行动中需要执行的战术任务数量、规模越来越大,且任务越来越趋于多重性和协同性。无人机任务指派问题是一个典型的包含约束的动态多目标优化问题。首先,现代化战场中往往存在众多的敌方战术目标,并且根据战术用户的需求不同,对应于各战术目标,还可能存在多种类型的任务(如对同一个目标可能需要执行侦察、打击和毁伤评估等任务);其次,由于受无人机自身的任务及载荷能力限制,单架无人机所能执行的任务类型和数量是有限的,许多战术任务往往需要多架无人机协同完成;再者,现代化的战场环境中,不同的战术任务之间由于任务需求的不同,往往存在诸如任务执行顺序和执行时间等较强的约束关系,这些约束使得任务之间存在着时间或者空间上的矛盾。构建满足诸多约束条件的高效率的无人机任务规划系统给未来战场的指挥控制提出了新的挑战。

因此在求解无人机任务指派问题时,除了需要考虑任务本身的构成要素(如任务兵力、目标分布、任务类型等)的要求之外,还必须考虑多机之间协调一致、共同执行任务的约束关系,根据战术任务需求和任务规划的优化指标为各无人机制订出协同的任务规划,使其整体作战效能最优或近似最优。这是提升未来无人机战场适应能力和作战效能的重要途径。本书在全面介绍了动态多目标优化和粒子群优化算法的基础理论、仿真实验的基础上,还着重讨论了动态多目标粒子群优化算法在无人机任务指派问题上的应用。



1.2 粒子群算法简介

1.2.1 粒子群算法的研究背景

群智能正是通过简单智能个体的合作,表现出复杂智能行为的特性,实现群体智慧可以超越最优秀个体智慧的突破。目前,无论是源于何种群体形式,计算智能中基于群智能的理论方法都涉及众多学科的交叉,包括人工智能、计算机科学、社会学、经济学、生态学、组织与管理学以及哲学等学科。随着对其研究的深入,这些研究与其他学科的结合也形成了许多新的研究领域,从整体上推动了相关学科的发展^[6]。尤其是在复杂科学领域,群智能的方法有效地解决了许多复杂系统中难以精确描述的问题,为复杂、困难优

化问题的求解提供了一种通用的技术框架。

Kennedy 和 Eberhart^[7]于 1995 年提出的粒子群优化(Particle Swarm Optimizer, PSO)方法是一种基于群体智能的并行随机优化算法。其思想来源于对鸟群等生物种群觅食行为的研究,设想一群鸟在一个区域内随机搜寻食物,不知道食物的位置信息,鸟群所采取的飞翔和搜索的策略是不断跟随种群中的领头鸟行进。生物社会学家 Wilson 指出:至少从理论上,在搜索食物的过程中群体中的个体成员可以得益于所有其他成员的发现和先前的经历。当食物源不可预测地零星分布时,这种协作带来的优势是决定性的,远大于个体间对食物竞争所带来的劣势,这种群体中个体之间信息的社会共享有助于进化。PSO 算法正是从这种模型中得到启示并用于解决优化问题^[8]。

1.2.2 粒子群算法的基本描述

在 PSO 算法中,每个优化问题的解被看作是搜索空间的一只鸟,即群体中的成员。由于这样的个体被描述为没有重量、没有体积的单位,因此又被称作“粒子”,这样的粒子具有位置、速度和加速状态等属性。所有的粒子都有一个由被优化的函数所决定的适应值,每个粒子还有一个速度决定它们“飞翔”的方向和距离,所有粒子通过追随当前的最优粒子在解空间的可行域(如果有约束条件)中进行搜索。

基本 PSO 算法中,每个粒子(Particle)代表一个可能的解,所有的粒子组成群体(Swarm)。PSO 算法首先初始化为一群随机粒子(随机初始解),然后通过迭代更新其速度和位置。在每一次迭代中,粒子通过跟踪两个“最优值”来更新自己的状态:第一个是粒子个体本身在历史上所找到的最优解,称作个体位置最优值 $pbest$;另一个是整个群体到目前为止找到的最优解,称作群体位置最优值 $gbest$ 。粒子在解空间中根据上述的自身历史信息和群体信息共同决定其“飞翔”的速度和方向,以此来寻找最优解。

假设在 D 维搜索空间中进行问题求解,群体(Swarm)由 m 个粒子组成, $Swarm = \{x_1^{(k)}, x_2^{(k)}, \dots, x_m^{(k)}\}$ 。 k 时刻第 i 个粒子在搜索空间中的位置向量为 $x_i^{(k)} = (x_{i1}^{(k)}, x_{i2}^{(k)}, \dots, x_{iD}^{(k)})$, $i=1, 2, \dots, m$, 这是粒子个体在搜索空间中的位置,也代表问题的一个可能解。与该个体位置向量相对应的是其速度向量 $v_i^{(k)} = (v_{i1}^{(k)}, v_{i2}^{(k)}, \dots, v_{iD}^{(k)})$, 分别描述了该粒子在空间每一维上的运动情况。

注:变量带括号的上标表示迭代周期,如 $x_{id}^{(k+n)}$ 表示第 $k+n$ 个周期;变量不带括号的上标表示幂,如 ω^n 表示 ω 的 n 次方。

PSO 算法的邻域函数在每一个迭代周期根据个体自身位置向量、速度向量、个体历史信息、群体信息和扰动来产生新的位置状态。标准 PSO 算法中,第 i 个粒子在 $k+1$ 时刻的第 d 维邻域函数计算公式如下:

$$\begin{cases} v_{id}^{(k+1)} = \omega \cdot v_{id}^{(k)} + c_1 \cdot r_1 \cdot (p_{id}^{(k)} - x_{id}^{(k)}) + c_2 \cdot r_2 \cdot (p_{gd}^{(k)} - x_{id}^{(k)}) \\ x_{id}^{(k+1)} = x_{id}^{(k)} + v_{id}^{(k+1)} \end{cases} \quad (1.1)$$

在邻域函数产生新的粒子运动速度时,还须满足速度的约束条件:

$$|v_{id}^{(k)}| \leq V_{\max} \quad (1.2)$$

PSO 的选择函数定义为:

$$D(\phi(x_i^{(k)}), p_{id}^{(k)}) = \begin{cases} \phi(x_i^{(k)}) & f(\phi(x_i^{(k)})) \leq f(p_{id}^{(k)}) \\ p_{id}^{(k)} & f(\phi(x_i^{(k)})) > f(p_{id}^{(k)}) \end{cases} \quad (1.3)$$

$$p_{id}^{(k)} \in \{x_{1d}^{(k)}, x_{2d}^{(k)}, \dots, x_{md}^{(k)} \mid f(x_{id}^{(k)})\} = \min\{f(x_{1d}^{(k)}), f(x_{2d}^{(k)}), \dots, f(x_{md}^{(k)})\} \quad (1.4)$$

$$p_{gd}^{(k)} \in \{p_{1d}^{(k)}, p_{2d}^{(k)}, \dots, p_{md}^{(k)} \mid f(p_{id}^{(k)})\} = \min\{f(p_{1d}^{(k)}), f(p_{2d}^{(k)}), \dots, f(p_{md}^{(k)})\} \quad (1.5)$$

以上公式中各参数的含义见表 1.1。

表 1.1 PSO 算法参数

ω	惯量因子	V_{\max}	速度向量限制常数
k	迭代周期	c_1, c_2	加速因子
$x_{id}^{(k)}$	粒子的当前位置	r_1, r_2	在(0,1)之间的随机数
$v_{id}^{(k)}$	粒子运动速度	m	种群粒子数量
$p_{id}^{(k)}$	粒子个体位置最优值	D	搜索空间维数
$p_{gd}^{(k)}$	群体位置最优值	$f(\cdot)$	适应度(目标)函数

根据 PSO 的算法规则,标准 PSO 的算法流程如下所述:

- ① 初始化设置粒子群的规模、惯性因子、加速因子;
- ② 在搜索空间内随机初始化每个粒子的位置,并初始化粒子的速度向量,将每个粒子的个体历史最优位置设置为当前粒子的位置;并按式(1.5)计算群体最优位置;
- ③ 按式(1.1)更新每个粒子的速度,按式(1.2)约束粒子速度;按式(1.1)更新每个粒子的位置,重置超出搜索空间粒子的位置;
- ④ 计算每个粒子位置的目标函数值,并按式(1.4)与式(1.5)更新每个粒子的个体历史最优位置与整个群体的最优位置;

⑤ 若满足停止条件,则停止搜索,输出搜索结果,否则返回③继续搜索。

总的来说,作为一种自然启发(Nature Inspired)的优化算法,PSO 算法具有实现简单、适用性强、寻优快以及易于与其他算法结合等优点。

1.2.3 粒子群算法的基本应用

粒子群优化算法自 1995 年提出以来,由于其简单和明确的实际背景,以及前述的诸多优点,使得很多学者加入到该算法的研究之列。目前粒子群优化算法的研究取得了很多进展,该算法也已经在不同行业中得到应用。

PSO 算法在工程方面的应用有大量的成果,Robinson 等^[9]将其应用于通信工程中的天线设计,李宁等^[10]将其应用于车辆路径规划问题,Bergh 等^[11]应用其提出的协作 PSO 算法训练乘的积单元的神经网络进行模式分类,侯志荣^[12]采用 PSO 算法进行 IIR 的数字低通和带通滤波器的设计,龙云等^[13]采用 PSO 算法进行发电机的参数辨识,夏永明等^[14]将 PSO 算法应用于直线感应电动机的优化设计等,还有自动控制系统中的智能控制器优化设计、系统辨识、路面谱模型计算^[8]等问题。He 等^[15]利用 PSO 算法优化模糊控制系统,设计模糊控制器。粒子群优化算法在电力系统优化中也有着广泛的应用^[16],例如在配电网扩展规划、检修计划、机组组合、负荷经济分配、最优潮流计算与无功优化控制、谐波分析与电容器配置、配电网状态估计、参数辨识、优化设计等方面。

PSO 算法在其他领域同样得到了广泛的应用,高尚等^[17]将 PSO 算法通过一定的改进或变形,已经将其成功用于 TSP 问题的求解;Ting 等^[18]分别通过二进制编码和实数编码混合的 PSO 算法来解决机组组合优化问题,通过二进制编码的 PSO 算法进行机组组合优化,通过实数编码的 PSO 算法进行经济负荷优化分配以及电子商务定价^[19]、约束布局优化^[20]、新产品组合投入^[21]等。



1.3 动态多目标优化问题及其粒子群算法研究

1.3.1 动态多目标优化问题及基本概念

动态多目标优化问题(Dynamic Multi-objective Optimization Problems,DMOPs)不仅有多个目标函数,而且问题还会随着时间或环境动态改

变。近十年来,越来越多的学者开始将注意力集中在 DMOPs 上,也提出了不少相关理论、各具特色的研究方法和算法。比如, Farina 等^[23]提出了最小代价的进化决定算法(Hybridised Minimal Cost Evolutionary Deterministic Algorithm, HMCEDA),这是最早的动态多目标优化算法之一; Koo 等^[24]将多目标梯度算法(MO-EGS)改进为动态多目标梯度算法(DMO-EGS),并进一步采取预测的方法来适应快速变化的环境; Deb 等^[25]在 NSGA-II 的基础上提出了 DNGA-II,这是当今最成功的动态多目标算法之一; Amato 等^[26]提出了极具创新性的 Alife 算法等。

动态多目标优化问题的定义如下。

定义:作为多目标优化问题(Multi-objective Optimization Problem, MOP)的一种自然扩展,一个具有 n 个决策变量, m 个目标函数的 DMOPs 问题可描述为^[2]:

$$\begin{cases} \min f(\mathbf{x}, t) \\ \text{s. t. } g_i(\mathbf{x}, t) \leqslant 0, i = 1, 2, \dots, q; \\ h_j(\mathbf{x}, t) = 0, j = 1, 2, \dots, p; \\ \mathbf{x} \in [x_{\min}, x_{\max}] \end{cases} \quad (1.6)$$

其中, $f(\mathbf{x}, t) = \{f_1(\mathbf{x}, t), f_2(\mathbf{x}, t), \dots, f_n(\mathbf{x}, t)\}$ 是 n 个目标函数构成的目标向量, $g_i(\mathbf{x}, t)$ 、 $h_j(\mathbf{x}, t)$ 是问题可能存在的 q 个不等式约束和 p 个等式约束条件。

动态多目标优化问题是一个涉及多目标、动态、约束的复杂优化问题,以下将从这三个角度具体阐述动态多目标优化问题的研究现状。

1.3.2 多目标优化问题及其 PSO 算法研究

多目标优化问题在实际优化设计中是普遍存在的一类复杂优化问题。它们往往包含一些典型的困难特征,诸如维数高、不连续、非凸、多态,抑或是 NP(非确定多项式)问题等。这些特征对现有的确定性方法提出了挑战,比如贪婪算法、爬山算法、分支定界树/图搜索技术、深度和广度优先搜索算法、最佳优先搜索算法及基于微分的算法等。

目前,多目标粒子群算法的思路主要分为以下几个方面。

(1) 向量法和权重法,如 Parsopoulos 等^[27]提出的适应性权重法和向量评价法,首次将粒子群算法用于多目标优化,但是权重法的权系数选取困难,而向量评价法往往无法给出问题的满意解;