

菌群优化与仿生管理

牛 奔/著

Bacterial Colony Optimization
and Bionic Management



科学出版社

菌群优化与仿生管理

Bacterial Colony Optimization
and Bionic Management

牛 奔 著

科学出版社

北京

内 容 简 介

本书是一本全面、系统研究菌群优化算法、理论、技术和应用的学术专著。一方面，针对传统细菌觅食优化算法(Bacterial Foraging Optimization, BFO)存在的缺点，提出新型菌群优化模型与算法，使之更为有效可靠；另一方面，将提出的新模型、新算法应用于实际问题求解，拓展群体智能优化算法的应用领域。在理论研究方面，对BFO算法的相关核心参数进行分析与探讨，提出了多种基于参数改进的BFO算法及简化BFO算法；为了进一步提升BFO算法的优化性能，提出了一类新型具有群体智能特征的菌群优化(Bacterial Colony Optimization, BCO)算法；在应用研究方面，开展了在投资组合、聚类分析、工程优化等各类管理、经济、工程、科技领域中的应用。此外，通过对菌群优化算法理论与实践相关研究成果的提炼升华，提出了仿生管理学研究框架。

本书可供运筹与管理、人工智能、计算数学、计算机科学、系统科学等专业的师生使用，亦可供从事智能计算研究与应用的各学科研究工作者参考。

图书在版编目(CIP)数据

菌群优化与仿生管理/牛奔著. —北京：科学出版社, 2014.6

ISBN 978-7-03-040584-5

I. ①菌… II. ①牛… III. ①细菌群体-最佳化②细菌体-仿生
IV. ①Q939.1

中国版本图书馆 CIP 数据核字(2014) 第 094512 号

责任编辑：方小丽 / 责任校对：邹慧卿

责任印制：阎 磊 / 封面设计：无极书装

科学出版社出版

北京东黄城根北街 16 号

邮政编码：100071

<http://www.sciencep.com>

北京通州皇家印刷厂 印刷

科学出版社发行 各地新华书店经销

*

2014 年 6 月第 一 版 开本：720 × 1000 B5

2014 年 6 月第一次印刷 印张：14 1/4

字数：287 000

定价：72.00 元

(如有印装质量问题，我社负责调换)

作 者 简 介



牛奔，男，安徽全椒人，工学博士。深圳大学副教授，新西兰惠灵顿维多利亚大学、香港大学访问学者，香港理工大学、中国科学院博士后。长期从事仿生管理理论与实践的研究，至今发表学术论文 100 余篇(SCI、EI 论文 88 篇)，出版专著两部。近年来主持国家自然科学基金、中国博士后基金、广东省自然科学基金等基金项目 7 项，入选 2012 年度国家第二批“香江学者”，广东省“千百十人才”省级培养对象，2013 年度深圳市“高层次人才”，以及 2014 年度深圳市海外高层次人才“孔雀计划”。

前　　言

20世纪90年代,生物学家及计算机专家通过对社会型群居生物行为的观察和研究,提出了群体智能优化算法。与传统智能计算方法相比,该算法没有中心控制的约束,不会因个体的故障而影响群体对目标问题的处理,从而保证了算法具备更强的鲁棒性,为复杂分布式优化问题的求解提供了新思路;不仅如此,它潜在的并行性与分布式特点也确保了算法在实际应用中的即时性与高效性。近年来,群体智能优化算法已在传统NP问题求解及诸多实际应用领域中展现了优异的性能和较好的发展潜力。

然而,目前群体智能优化算法多是启发于高等群居生物(蚂蚁、鸟、蜜蜂、鱼等)行为的模拟,如蚁群算法、粒子群算法、人工蜂群算法、人工鱼群算法等。由于高等生物行为状态较为复杂,很多行为习性难以定性描述,在设计模型时往往需要加入一些假设因素,因此构建出的模型虽然可以反映生物系统的某些特性,但离真实自然生物系统的再现还有一定距离,从而影响了算法对于复杂优化问题的处理效果。因此,建立更加简洁、准确、具有群体智能特征的优化模型,进一步提高群体智能优化算法的性能,便成为了一种迫切的需求。

细菌作为最简单的无核单细胞生物,其行为规则简单、易于描述。同时,细菌群落作为地球上最古老的生物群体之一,其强韧的生命力以及对复杂环境灵活的适应性充分彰显了其生存活动过程中的优化本能。因此,本书拟从一个新的视角,即以低等微生物细菌的行为为启发对象,将细菌的觅食过程视为优化求解过程,探索群体智能的优化本质,开发新型的群体智能优化方法。

本书以作者博士后研究论文为基础,同时结合近年来作者在微生物启发式优化方法方面的研究心得和体会撰写而成。全书共11章:第1章主要介绍了本书开展工作的研究背景与意义及常见的群体智能算法;第2章讨论了BFO算法的基本原理、实现步骤及国内外研究现状;第3章开展了对BFO算法关键参数的研究并提出了四种改进的BFO算法;第4章基于提出的BFO-LDC算法开展了在流动性投资组合优化中的应用;第5章开展了混合BFO算法(BFO+K算法)在数据聚类中的应用研究;第6章将提出的两类改进BFO算法应用于多约束工程优化问题中;第7章开展了基于线性变化趋化步长BFO算法在RFID网络规划中的应用研究;第8章提出了多目标BFO算法,并将其应用于环境经济调度问题中;第9章开展了基于生命周期模型的群体感应机制的研究,提出了LCM-QS的计算模

型；第 10 章在 LCM-QS 模型基础上提出了一类具有群体智能特征的菌群优化算法 (BCO 算法)；第 11 章对全书进行了总结并对仿生管理研究方向进行了展望。

本书的出版得到了国家自然科学基金、中国博士后基金、广东省自然科学基金、香江学者计划等项目的大力支持。具体如下：国家自然科学基金“全面学习与进化细菌觅食优化方法研究(面上项目, 71271140)”；国家自然科学基金“基于群体感应机制的菌群优化方法研究(国际合作交流项目, 71210107016)”；国家自然科学基金“基于菌群生命周期行为的群体智能优化模型与算法研究(青年项目, 71001072)”；中国博士后基金“不确定环境下生产-分销集成规划模型与菌群优化(特别资助, 2012T50584)”；中国博士后基金“基于细菌行为的群体智能系统建模与优化(面上项目, 20100480705)”；香江学者计划项目“Production-Distribution Integrated Planning Models and Bacterial Colony Optimization in an Uncertain Environment(G-YZ24)”；广东省自然科学基金“集成学习细菌觅食优化算法及其在环境经济调度中的应用(面上项目, S2012010008668)”。

在本书的撰写过程中，得到了谭立静、王红、刘衍民、李丽、刘憬在资料收集、校对排版方面的大力支持，同时还要感谢智能管理课题组所有成员，尤其是段琦琦、毕莹、尹凯、黄华丽、谢庭、王沿、王婧文、邢康男、肖寒、范艳、薛冰等研究生给予的帮助。

在撰写本书的过程中，参考了国内外相关研究成果，在书中也做了针对性的标注，笔者对相关专家学者表示衷心感谢；但是，书中的标注可能有所疏漏，在此，希望同行学者批评指正，以便今后改正完善。

目前国内外相关学者已经开始关注细菌觅食优化算法的研究，但到目前为止笔者还没有看到相关的系统性、专业性的书籍出版，本书也是本领域第一本有关细菌行为启发式优化方法的专业书籍。笔者非常希望能够给大家一本既有理论又重实践的好书。但是由于水平有限，书中的缺点、错误以及不足之处在所难免，恳请读者不吝指正。

牛 奔

2014 年 2 月 18 日于深大荔园

目 录

前言

第 1 章 绪论	1
1.1 背景与意义	1
1.2 群体智能与群体智能系统	2
1.3 群体智能算法	3
1.4 本书的篇章结构	27
参考文献	29
第 2 章 BFO 算法基本原理及研究综述	38
2.1 引言	38
2.2 BFO 算法的基本原理	38
2.3 BFO 算法的理论研究综述	42
2.4 BFO 算法的应用研究综述	44
2.5 本章小结	50
参考文献	50
第 3 章 BFO 算法参数分析与算法改进	57
3.1 引言	57
3.2 BFO 算法的参数分析	57
3.3 趋化步长时序变化的 BFO 算法	66
3.4 趋化步长非线性变化的 BFO 算法	80
3.5 简化 BFO 算法	85
3.6 本章小结	90
参考文献	91
第 4 章 基于 BFO 算法的投资组合优化	92
4.1 引言	92
4.2 考虑市场流动性风险的投资组合模型的构建	93
4.3 BFO 算法在流动性风险投资组合优化中的应用	97
4.4 实验结果	99
4.5 本章小结	103
参考文献	104
第 5 章 基于 BFO 算法的聚类分析	107
5.1 引言	107
5.2 数据聚类的含义	108

5.3 K-means 算法	109
5.4 BFO+K 算法	110
5.5 仿真实验与分析	111
5.6 本章小结	116
参考文献	116
第 6 章 基于 BFO 算法的工程优化	118
6.1 引言	118
6.2 基于 BFO 算法的工程优化方案	119
6.3 本章小结	129
参考文献	129
第 7 章 基于 BFO 算法的 RFID 网络规划	132
7.1 引言	132
7.2 RFID 网络规划	133
7.3 实例研究	136
7.4 本章小结	138
参考文献	138
第 8 章 多目标 BFO 算法及其在环境经济调度中的应用	139
8.1 引言	139
8.2 多目标优化问题描述	139
8.3 多目标细菌觅食优化算法	140
8.4 测试实验	145
8.5 基于 MBFO 算法的环境经济调度	152
8.6 本章小结	160
参考文献	160
第 9 章 基于生命周期模型的群体感应仿真	162
9.1 引言	162
9.2 生命周期模型	163
9.3 群体感应系统	165
9.4 LCM-QS 模型	166
9.5 LCM-QS 的实施	169
9.6 仿真实验结果与讨论	171
9.7 本章小结	184
参考文献	180
第 10 章 菌群优化算法	187
10.1 引言	187

10.2 人工菌群行为概述	188
10.3 BCO 算法优化模型与算法	188
10.4 实验与结果	192
10.5 本章小结	200
参考文献	200
第 11 章 研究总结及仿生管理研究展望	201
11.1 研究总结	201
11.2 仿生管理学研究展望	204
11.3 结束语	208
参考文献	208
附录	211
A. BFO 算法 MATLAB 实现	211
B. SiBFO 算法 MATLAB 实现	213
C. 测试函数基本信息	217

1.1.2 意义

1) 在学术意义方面: 本书将目前群体智能优化方法的启发对象从高等生物扩展到微生物, 以在微观生物学中研究较为透彻的大肠杆菌 (*Escherichia Coli*) 行为为启发对象。与传统的高等生物行为启发式优化模型相比, 对菌群优化模型中个体之间、个体与环境之间相互作用演化的过程更容易进行全面、精确的描述。该研究拓展了群体智能的研究范围, 相关研究成果将会进一步充实群体智能优化理论, 促进智能优化、系统科学等相关领域的发展。

2) 在应用价值方面: 本书提出的新型菌群优化方法, 尤其是 BCO 算法, 在性能上表现为更加适合于对动态、多目标、多约束等复杂环境下的问题求解。而传统优化算法在解决该类问题时往往不是十分有效, 如易陷入局部最优、问题依赖性强、计算复杂性高等问题。因此, 本书中初步开展的基于菌群优化理论的现实问题解决方案, 为解决其他管理经济学、工程技术等领域内的动态、多目标强约束等复杂问题提供了借鉴方案, 相关研究成果孕育着巨大的应用潜力。

1.2 群体智能与群体智能系统

群体智能的提出只有短短的 10 年, 可群体智能思想的应用已涉及多个领域,和其他新兴学科一样, 群体智能也并没有一个完整公认的定义。在可查文献中群体智能 (swarm intelligence, SI) 最早出现在 Beni^[6]、Beni 和 Wang^[7] 等对细胞机器人研究的论文中。后来的研究中这一概念被广泛应用于通过社会性昆虫组织或其他的动物群体集体行为刺激而设计算法或分布式问题的求解中。

Bonabeau 等^[8] 认为任何受社会型昆虫或其他生物群体的思想启发去设计算法和对分布式问题的求解都是群体智能的应用。

国外对群体智能的研究多是从 Agent 系统进行研究的, 文献 [9] 认为, 群体智能就是研究受到社会型昆虫或其他生物群体的启发而产生的多智能体系统 (multi-agents system, MAS)。

群体智能与传统人工智能系统的区别从人类认知的角度不难理解, 传统人工智能系统认知来源于生物个体内部系统的认知过程, 而群体智能认知来源于个体与外界环境之间的直接或间接交互^[10]。

群体智能系统 (swarm intelligence system, SIS) 可以看成是多个智能主体松散耦合而成的大型复杂系统。群体智能系统注重的是所有类型的群体的行为, 而不是某一个体行为的变化, 它是个体行为与群体行为的耦合。

传统中心控制系统存在结构复杂、臃肿的缺点, 群体智能系统是一种分布自主式系统 (distributed autonomous system, DAS), 它不存在中心控制, 各单元之间通

过局部交互实现智能行为。系统中每个单元赋予一定的简单功能，但正是由于这些简单的单元个体之间相互协作才可以实现群体的智能。

具体来说，群体智能系统较之传统人工智能系统其优越性主要体现在以下两方面：

1) 柔性。通常情况下系统的健壮性越高越好，但是系统的柔性是不得不考虑的重要因素，只有柔性系统才可以在外界环境的变化中体现出系统的健壮性。群体智能系统的柔性分为好几个类型。如果一个系统具有这些不同类型的柔性，那么它就可以根据环境的变化调节整体系统。例如，多样性，即系统可以有多个方向去演化发展；涌现特性，系统根据环境的变化可以进入全新的下一状态；系统的局部控制，它使得系统通过分布式能力进行决策^[11]。

2) 容错性。在目前研究的群体智能系统中，每个主体本身有能力解决系统面临的任何问题。但是，由于每个主体自身知识的不足以及不同主体所面临的问题之间具有相互依赖性，所以有时并不能单独地解决某个问题，仍需要一个系统中多个主体间的协调合作。而正是这种原因，当系统中某一个主体出现故障时，它所承担的任务可由其他主体承担，整个系统体现了较好的容错性。

1.3 群体智能算法

1.3.1 群体智能算法发展简表

基于群体智能思想，近年来人们提出了多种群体智能优化模型与算法，比较有代表性的是：蚁群算法、粒子群算法、和声搜索算法、人工鱼群算法、细菌趋药性算法、混合蛙跳算法、人工蜂群算法、头脑风暴算法、菌群优化算法等，具体信息见表 1-1。在下面的小节中我们将对相关算法进行详细的介绍。

1.3.2 蚁群算法

1.3.2.1 起源

蚂蚁在觅食时，总能迅速找到离食物源最近的路径，一旦找到这条路径，其他蚂蚁也会知道这些信息，并且从这条最短路径到达食物源。那么为什么蚂蚁能这么快地找到离食物源最近的路径呢？蚂蚁之间又是怎样传递这些信息的呢？研究发现，蚂蚁内部除了有很明确的分工外，还有相互间的信息传递。蚂蚁在觅食之前，并不知道食物的具体位置，只能在某一特定范围内按照一定顺序依次进行搜索。蚂蚁之间通过一种很重要的称为信息素的化学物质来传递信息，同时蚂蚁在觅食时，会在它经过的路径上分泌信息素，而其他蚂蚁也能够感知信息素的存在及其浓度，以此指导自己的运动方向，蚂蚁一般倾向于朝着信息素浓度高的方向移动。假设

表 1-1 群体智能优化算法发展简表

序号	年份	算法名称	提出学者	出处
1	1992	蚁群算法 (ant colony optimization)	Dorigo M 等	Distributed optimization by ant colonies. Proceedings of the first European conference on artificial life, 1991: 134-142.
2	1995	粒子群算法 (particle swarm optimization)	Eberhart R C 等	A new optimizer using particle swarm theory. Micro Machine and Human Science, 1995. MHS'95., Proceedings of the Sixth International Symposium on. IEEE, 1995: 39-43.
3	2001	和声搜索算法 (harmony search)	Zong W G 等	A new heuristic optimization algorithm: harmony search. Simulation, 2001, 76(2): 60-68.
4	2002	人工鱼群算法 (artificial fish swarm algorithm)	李晓磊等	一种基于动物自治体的寻优模式: 鱼群算法. 系统工程理论与实践, 2002,(11):31-38.
5	2002	细菌趋药性算法 (bacteria chemotaxis)	Muller S D 等	Optimization based on bacterial chemotaxis. IEEE Transactions on Evolutionary Computation, 2002, 6(1): 16-29.
6	2003	混合蛙跳算法 (shuffled frog leaping algorithm)	Eusuff M M 等	Optimization of water distribution network design using the shuffled frog leaping algorithm. Journal of Water Resources Planning and Management, 2003,129(3): 210-225.
7	2005	人工蜂群算法 (artificial bee colony algorithm)	Karaboga D	An idea based on honey bee swarm for numerical optimization. Techn. Rep. TR06, Erciyes Univ Press, Erciyes,2005.
8	2011	头脑风暴算法 (brain storm optimization algorithm)	Shi Y H	Brain storm optimization algorithm. Advances in Swarm Intelligence. Springer Berlin Heidelberg, 2011: 303-309.
9	2012	菌群优化算法 (bacterial colony optimization)	Niu B 等	Bacterial colony optimization. Discrete Dynamics in Nature and Society, 2012.

蚂蚁在搜索食物源时,有多条路径可以选择,有的路径长,有的路径短。在经过这些路径时,蚂蚁会分泌信息素,信息素会随着时间挥发,蚂蚁到达食物源的时间越短,在该条路径上的信息素浓度越高,并且经过这条路径的蚂蚁就会越多,相应路径上的信息素浓度也越高,该条路径被其他蚂蚁选择的可能性也就越大。从而,整个蚁群就能够快速地找到到达食物源的最短路径。

基于上述思想,意大利学者 Dorigo 等于 1992 年提出了蚁群 (ant colony opti-

mization, ACO) 算法^[12], 最早用来求解经典的旅行商路径问题, 后期被扩展到各个工程技术领域。

1.3.2.2 算法模型

在该算法中, 将蚂蚁觅食的三维空间抽象成一个平面, 将需要求解的实际问题用数学中的图形来描述, 人工蚂蚁则可以视为具有简单智能的个体, 它们在觅食中会沿着数学图形的边移动, 并根据每条边上的信息素浓度来选择移动方向。将蚁巢定为初始结点, 将食物源定为终结点, 人工蚂蚁通过信息素浓度来决定向下一结点的转移概率, 信息素浓度越高, 转移概率也就越大。蚂蚁之间就是通过这种机制, 从一个结点到下一个结点, 逐步进行下去, 直到找到最优解, 即找到初始结点到终结点的最短距离。其中涉及的主要参数变量表达如下:

从结点 i 到结点 j 的转移概率为

$$P_{ij}^k(t) = \begin{cases} \frac{\tau_{ij}^\alpha(t)\eta_{ij}^\beta(t)}{\sum\limits_{s \in \text{allowed}_k} \tau_{is}^\alpha(t)\eta_{is}^\beta(t)} & (j \in \text{allowed}_k) \\ 0 & \text{other} \end{cases}$$

信息素更新方程

$$\tau_{ij}(t+T) = \rho\tau_{ij}(t) + \sum_{k=1}^m \Delta\tau_{ij}^k$$

其中, $j \in \text{allowed}_k$ 为蚂蚁 k 下一步允许选择的结点; $\eta_{is}^\beta(t)$ 为自启发量; $\eta_{ij}^\beta(t)$ 为能见度量; α, β 为设置的参数, 分别表示蚂蚁在移动过程中所积累的信息素和自启发量在蚂蚁选择路径中所起作用的比重, 也可被称为信息素启发因子和自启发量因子; $\tau(\cdot)$ 为信息素浓度的函数, 在初始时刻, 各条边的信息素浓度都相等, 可设为常数 C ; ρ 为信息素轨迹的持久性; $\Delta\tau_{ij}^k$ 指的是在边 (i, j) 上留下的单位长度轨迹信息素数量, 一般有不同的取法; T 为单位时间。

1.3.2.3 步骤

基本的蚁群算法具体实现步骤如下。

步骤 1: 参数初始化, 设置迭代次数或搜索次数, 将 $\tau_{ij}, \Delta\tau_{ij}$ 初始化; 将 m 只蚂蚁置于 n 个初始结点上。

步骤 2: 将各蚂蚁的初始出发点保存在当前解集中; 对每一个蚂蚁 $k (k = 1, \dots, m)$, 按概率 P 选择移至下一个顶点 j 上, 并更新当前解集。

步骤 3: 计算各蚂蚁的目标函数值 $L^k (k = 1, \dots, m)$; 记录当前最好解。

步骤 4: 按信息素更新方程修改信息素轨迹强度。

步骤5：若搜索次数小于预定迭代次数且无退化行为（即找到的都是相同解），则转步骤2。

步骤6：若满足终止条件，则输出最优解。

图1-1为基本蚁群算法路程图。

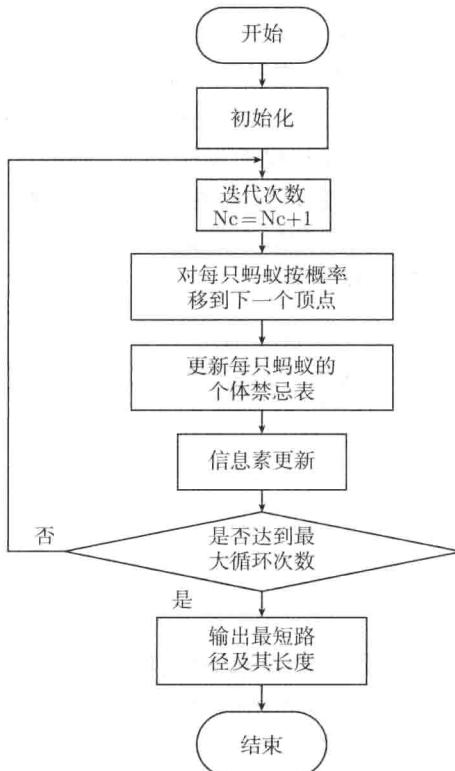


图1-1 蚁群算法路程图

1.3.2.4 简单点评

蚁群算法属于自组织算法，初始蚂蚁寻优线路的选择，对结果不会有太大影响，同时该算法中包含着正反馈机制，随着进化的进行，对系统起到一个自增强的作用，能够有效地获得全局相对较优的解，同时，该算法具有分布并行计算能力，增强了算法运行的可靠性。但是不可忽视的是，一方面，该算法在优化求解时，随着问题规模的增加，搜索时间往往较长；另一方面，蚁群算法的适用范围主要限定在离散问题求解上，对于连续问题求解还需要对算法本身进行改进。针对这些问题，研究人员提出了一系列的改进方法^[13-20]，主要包括与其他算法结合、改进信息素机制等方面。目前，蚁群算法在优化问题求解中取得了一定的研究和应用成

果,由于该算法具有很好的搜索较优解的能力,近几年的应用非常广泛,其中包括路径规划问题^[21–23]、图像选择^[24,25]、组合优化^[26]、调度问题^[27–30]及电力系统优化^[31,32]等许多领域。

1.3.3 粒子群算法

1.3.3.1 起源

粒子群 (particle swarm optimization, PSO) 算法是继蚁群算法之后,另一种著名的群体智能优化算法。它是由美国学者 Kennedy 和 Eberhart 于 1995 年受到鸟群觅食行为的启发而提出的^[33,34]。该算法最初源于对鸟类集群觅食活动的模拟再现,后期发现其包含了丰富的优化思考,逐渐被扩展到优化计算领域。

该算法的基本思想是:假设一群鸟在只有一块食物的区域内随机地搜索食物,它们只知道目前所在位置与食物的距离,而不知道食物的具体准确位置。为了快速地找到食物,不难想出,搜寻目前距离食物最近的鸟的周围区域是最简单有效的可行办法。与优化搜索相对应,搜索空间中的每只鸟表示每个优化问题的解,假设鸟知道目前为止自身所发现的最好位置。我们可以将鸟抽象成一个搜索空间中无质量无体积,只具有位置和速度的“粒子”。所有的粒子都对应着由优化问题的函数值决定的适应值,并且每个具有一定速度的粒子对自身飞行经验具有认知能力。除此之外,每个粒子同样可以认知到目前为止整个群体中所有粒子发现的最好位置,即粒子的同伴经验。基于上述思想,模拟鸟群捕食的过程,实际上就是优化问题求解的过程,食物的最优位置即为所求最优解。

1.3.3.2 算法模型

根据 Kennedy 等学者^[33,34]的研究,该算法执行时,通常是从随机初始化一群粒子开始,粒子位置的好坏是由一个事先设计的适应度函数确定。假设搜索的空间为 D 维,种群中包含 M 个粒子以一定的速度飞行。粒子 i 在 t 时刻的状态属性设置为: $x_i^t = (x_{i1}^t, x_{i2}^t, \dots, x_{iD}^t)^T$, 代表着第 i 个粒子在 D 维搜索空间中的位置,其中 $x_{id}^t \in [L_d, U_d]$, L_d, U_d 分别为搜索空间的上下限。 $v_i^t = (v_{i1}, v_{i2}, \dots, v_{iD})^T$ 表示第 i 个粒子的速度,其中 $v_{id}^t \in [V_{\min,d}, V_{\max,d}]$, V_{\min}, V_{\max} 分别为最小和最大速度。 $p_i^t = (p_{i1}^t, p_{i2}^t, \dots, p_{iD}^t)^T$ 为个体最优位置, $p_g^t = (p_{g1}^t, p_{g2}^t, \dots, p_{gD}^t)^T$ 为全局最优位置,其中 $1 \leq d \leq D, 1 \leq i \leq M$ 。

则在每次迭代过程中,粒子在 $t+1$ 时刻的速度和位置更新公式如下所示:

$$v_{id}^{t+1} = v_{id}^t + c_1 r_1 (p_{id}^t - x_{id}^t) + c_2 r_2 (p_{gd}^t - x_{id}^t) \quad (1-1)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1} \quad (1-2)$$

其中, r_1, r_2 为分布在 $(0,1)$ 区间的随机数; c_1, c_2 为学习因子,通常取值均为 2。

式(1-1)主要由三部分组成：第一部分为粒子先前的速度，可以理解为粒子基于当前自身运动状态的信任，依据自身速度保持的一种惯性运动；第二部分为“认知”行为，表示粒子本身基于个体历史经验的思考，从而影响下一步的行为决策，反映的是向自身历史经验学习的过程。第三部分为“社会”行为，反映了搜索过程中粒子之间的交流，从而实现信息共享与相互合作。在搜索过程中粒子综合考虑自身经历，同时结合其同伴的经验，当同伴经验较好时，它将进行适应性的学习与调整，最终寻求一致认知的过程。

1.3.3.3 步骤

基本的粒子群算法具体实现步骤如下：

步骤1：随机初始化粒子群体的位置和速度。

设定PSO算法中涉及的各类参数：搜索空间的上下限，算法最大迭代次数或收敛精度，粒子速度范围等；记录当前位置为每个粒子的个体最优位置 p_i ，从个体极值中找出全局极值，记录该最优值的粒子序号及其当前位置 P_g 。

步骤2：计算粒子的适应值。

步骤3：将每个粒子的适应值与其个体极值进行比较，若优于该粒子当前的个体极值，则将 p_i 设置为该粒子的位置，且更新个体极值。

步骤4：对每个粒子，将其适应值与全局极值进行比较，若优于当前的全局极值，则将 p_g 设置为该粒子的位置，更新当前全局极值及其粒子索引序号。

步骤5：根据速度和位置更新式(1-1)和式(1-2)，对每一个粒子的状态进行更新。

步骤6：检验是否符合结束条件。若当前迭代次数达到了预先设定的最大次数，或最终结果小于预定收敛精度要求，则停止迭代，输出最优解，否则转到步骤2。

具体流程图如图1-2所示。

1.3.3.4 简单点评

粒子群算法是基于鸟类捕食行为的简化社会模型而提出来的一种智能优化算法。其优势在于该算法的原理简单、易于实现、收敛速度快且没有很多需要调整的参数。近年来该算法备受研究学者的青睐，获得了很大的关注与发展。目前，学者们已提出了多种改进的粒子群算法，并广泛地应用于各类工程技术领域^[35-43]。

粒子群算法主要依赖于个体之间的合作和竞争，不同于遗传算法，粒子本身在搜索过程中没有交叉、变异操作，仅仅通过个体自身的经验和整个群体的最好个体经验来进行行为交互，从而决定自己下一时刻的运动。在这种模式下，整个种群的多样性失去较快，一旦最优粒子陷入局部最优时，很难跳出局部极值的约束，会对

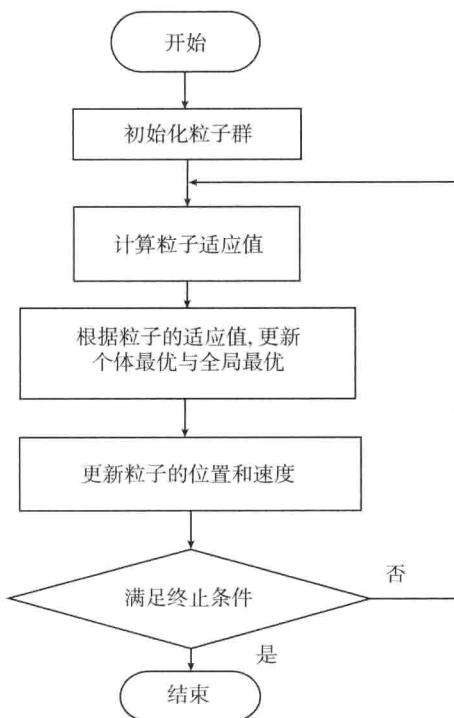


图 1-2 粒子群算法流程图

其他的个体产生信息误导。鉴于该算法易于陷入局部最优，尤其是在解决高维复杂函数优化问题时，往往存在早熟收敛的缺点，学者们从拓扑结构^[43–46]、参数选择^[47–49]、自适应策略^[50,51]、混合策略^[52,53]等方面进行了大量的改进，提出了一系列的改进版本的粒子群算法。

1.3.4 和声搜索算法

1.3.4.1 起源

音乐和声是一种来源于审美观的，令人愉快的美妙的声音组合，音乐演奏就是要寻找一个最好的和声。通常音乐家创作乐曲的时候，会先尝试演奏出多个相似的和声，然后对和声的音符进行替换或者微调产生新的和声，再与已有的和声比较，淘汰美学评价较差的和声而留下较好的和声，音乐家就凭借自己的记忆，通过反复调整乐队中各乐器的音调，直到最终获得一个让自己满意的和声。

基于音乐学家获取满意和声这一个过程，韩国学者 Geem 和 Kim 等^[54] 在 2001 年提出了一种启发式搜索算法，即和声搜索算法 (harmony search, HS)，意在模仿音乐家在谱写音乐时不断调整音调从而产生美妙音乐的过程。