

粒子群算法及其 应用研究

杨英杰 © 著

PARTICLE SWARM OPTIMIZATION
AND ITS APPLICATION

 北京理工大学出版社
BEIJING INSTITUTE OF TECHNOLOGY PRESS

粒子群算法及其 应用研究

杨英杰◎著



 **北京理工大学出版社**
BEIJING INSTITUTE OF TECHNOLOGY PRESS

内 容 提 要

本书的核心是设计求解 MEC 模型的粒子群算法。粒子群算法在很多连续问题上得到成功的应用,而在离散问题上的研究和应用却很少,而本书正是粒子群算法在离散问题上的一个很好的应用。针对 MEC 模型提出一种基于原始粒子群算法的启发式算法,该方法尽管有随机机制,但它对 MEC 模型非常稳定,在大多数情况下都可以找到相当好的最优解。为了提高粒子群算法的收敛速度,在原始粒子群算法中嵌入记忆机制,改进了粒子群算法的性能,进而提出了一种基于改进粒子群算法的启发式算法,提高了单体型重构率。利用给出的两个算法分别对真实数据和模拟数据进行数值计算,结果表明这两个算法对于 MEC 模型是非常有效的。

版权专有 侵权必究

图书在版编目 (CIP) 数据

粒子群算法及其应用研究 / 杨英杰著. —北京: 北京理工大学出版社, 2017. 3
ISBN 978-7-5682-3410-8

I. ①粒… II. ①杨… III. ①电子计算机—算法理论—研究 IV. ①TP301.6

中国版本图书馆CIP数据核字(2016)第285610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)

(010) 82562903 (教材售后服务热线)

(010) 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/北京紫瑞利印刷有限公司

开 本/710毫米×1000毫米 1/16

印 张/12

字 数/241千字

版 次/2017年3月第1版 2017年3月第1次印刷

定 价/58.00

责任编辑/江立

文案编辑/瞿义勇

责任校对/周瑞红

责任印制/边心超

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 Preface

优化是科学研究、工程技术和经济管理等领域的重要研究工具。它所研究的问题是讨论在众多的方案中寻找最优方案。例如，工程设计中如何选择设计参数，使设计方案既能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。优化这一技术，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。近十余年来，粒子群优化算法作为群体智能算法的一个重要分支，得到了众多学者广泛深入的研究，在路径规划等诸多领域都有应用。

许多问题最后都可以归结为优化问题。为了解决各种各样的优化问题，人们提出了许多优化算法，比较著名的有爬山法、遗传算法等。优化问题主要有两个：一是要求寻找全局最小点；二是要求有较高的收敛速度。爬山法精度较高，但是易于陷入局部极小。遗传算法属于进化算法的一种，它通过模仿自然界的选择与遗传的机理来寻找最优解。遗传算法有三个基本算子：选择、交叉和变异。但是遗传算法的编程实现比较复杂，首先需要对问题进行编码，找到最优解之后还需要对问题进行解码。另外，三个算子的实现也有许多参数，如交叉率和变异率，并且这些参数的选择严重影响解的品质，而目前这些参数的选择大部分依靠经验。1995年

Eberhart博士和Kennedy博士提出了一种新的算法，即粒子群优化算法。这种算法以其实现容易、精度高、收敛快等优点引起了学术界的重视，并且在解决实际问题中展示了其优越性。

粒子群优化算法是近年来发展起来的一种新的进化算法，与遗传算法相似，它也是从随机解出发，通过迭代寻找最优解，通过适应度来评价解的品质。但是它比遗传算法规则更为简单，它没有遗传算法的“交叉”和“变异”操作，通过追随当前搜索到的最优值来寻找全局最优。

本书首先介绍各种常见的基本算法，在这些基本算法的对比中显示出粒子群算法的优越性；然后介绍粒子群算法的基本特性，让广大读者先对粒子群算法有一个基本认知；最后讲到粒子群算法的改进策略，读者可以从这部分感受到粒子群算法的优点及缺陷，从而更加深入地了解粒子群算法。

由于笔者学识及时间有限，书中难免存在不足之处，恳请广大读者批评指正。

著者

目 录 Contents

第1章 绪论	1
1.1 群智能	1
1.2 混合蛙跳算法	4
1.3 人工鱼群算法	4
1.4 蚁群算法	6
1.5 粒子群算法	9
第2章 基本粒子群算法	14
2.1 粒子群算法概述	14
2.2 标准粒子群算法	26
2.3 粒子群算法分类	29
2.4 标准粒子群算法的实现	31
2.5 适应度评价函数	43
2.6 连续型原始粒子群算法	48
2.7 离散型粒子群算法	51
2.8 粒子群算法局部版本的实现	51
2.9 混合粒子群算法的实现	66
第3章 粒子群优化算法的改进策略	72
3.1 粒子群初始化	72

3.2	邻域拓扑	72
3.3	混合策略	74
3.4	参数设置	76
3.5	参数理论分析	89
3.6	结论与展望	92
3.7	参考文献	93
3.8	附录	95

第4章 粒子群算法的应用 124

4.1	基于粒子群算法的单体型装配问题	124
4.2	粒子群算法解决函数优化问题	151
4.3	基于粒子群算法求解非线性规划问题的 设计	157
4.4	基于粒子群算法的电力系统环境经济调度 问题	165

第 1 章 绪 论

1.1 群 智 能

1.1.1 群智能概述

群智能(Swarm Intelligence, SI)的概念最早由 Beni, Hackwood 和 Wang 在分子自动机系统中提出。分子自动机中的主体在一维或二维网格空间中与相邻个体相互作用,从而实现自组织。1999 年, Bonabeau, Dorigo 和 Theraulaz 在 *Swarm Intelligence: From Natural to Artificial Systems* 中对群智能进行了详细的论述和分析,给出了群智能的一种非严格定义,即任何一种由昆虫体或其他动物社会行为机制而激发设计出的算法或分布式解决问题的策略均属于群智能。这里,“Swarm”可被描述为一些相互作用相邻个体的集合体,蜂群、蚁群、鸟群都是“Swarm”的典型例子。一只蜜蜂或蚂蚁的行为能力非常有限,它几乎不可能独立存在于自然世界中,而多只蜜蜂或蚂蚁形成的“Swarm”则具有非常强的生存能力,且这种能力不是多个个体之间的能力通过简单叠加获得的。

社会性动物群体所拥有的这种特性能帮助个体很好地适应环境,个体所能获得的信息远比它通过自身感觉器官所取得的多,其根本原因在于个体之间存在信息交互能力。信息的交互过程不仅仅在群体内传播了信息,而且群内个体还能处理信息,并根据所获得的信息(包括环境信息和附近其他个体的信息)改变自身的一些行为模式和规范,使得群体涌现出一些单个个体所不具备的能力和特性,尤其是对环境的适应能力,这种对环境变化所具有的适应能力被认为是一种智能,也就是说动物个体通过聚集成群而涌现出了智能。因此, Bonabeau 将群智能的定义进一步推广为“无智能或简单智能的主体通过任何形式的聚集协同而表现出智能行为的特性”。这里,我们关心的不是个体之间的竞争,而是它们之间的协同。尽管目前群智能理论还不是很成熟,但它已成为有别于传统人工智能中连接主义、行为主义和符号主义的一种新的关于智能的描述方法,并成为人工智能领域的新研究热点。2003 年电气和电子工程师协会(IEEE)举办的第一届国际

群智能研讨会在美国印第安纳州首府召开,以后每年举办一次群智能国际研讨会。

1.1.2 群智能的基本原理和特点

群智能思想的产生主要源于复杂适应系统理论以及人工生命的研究。复杂适应系统(Complex Adaptive System, CAS)理论是在1994年由Holland教授正式提出的。CAS理论中成员称为具有适应性的主体,简称主体。主体的适应性,是指它能够与环境以及其他主体进行交流。在这种交流的过程中“学习”或“积累”经验,并且根据学到的经验改变自身的结构和行为方式。整个系统的演变或进化,包括新层次的产生、分化和多样性的出现,新的、聚合而成的、更大的主体的出现等,都是在这个基础上实现的。CAS理论具有四个基本特点:

(1)主体是主动的、活的实体。具有适应性的主体的概念把个体主动性提高到了系统进化基本动因的位置,从而成为研究与考察宏观行为的出发点。

(2)个体与环境(包括个体之间)之间的相互影响、相互作用是系统演变和进化的主要动力,相互作用是“可记忆”的,它表现为进化过程中每个个体的结构和行为方式的变化,以不同的方式“存储”在个体内部。

(3)这种方法不像其他方法那样把宏观和微观截然分开,而是把它们有机地联系起来。

(4)这种建模方法引进了随机因素的作用,使它具有更强的描述和表达能力。随机因素不仅影响状态,而且影响组织结构和行为方式。具有主动性的个体会接受教训,总结经验,并且以某种方式把“经历”记住,使之“固化”在自己以后的行为方式中。正因为如此,CAS理论提供了模拟生物、生态、经济、社会等复杂系统的巨大潜力。

群智能是一种由无智能或简单智能的个体通过任何形式的聚集协同而表现出的智能行为。它为在没有集中控制且不提供全局模型的前提下寻找复杂的分布式问题求解方案提供了基础。

人工生命(AD)是用来研究具有某些生命基本特征的人工系统。人工生命包括两部分内容:①如何利用计算技术研究生物现象;②如何利用生物技术研究计算问题。

第二部分的内容的研究中,现在已经有了很多源于生物现象的计算技巧,例如,人工神经网络是简化的大脑模型,遗传算法是模拟基因进化的过程,目前这一类计算技术统称为自然计算。群智能属于自然计算中的一类。它模拟另一种生物系统——社会系统,更确切地说,是模拟由简单个体组成的群落与环境以及个体之间的互动行为。

SI是群智能发展的一个重要里程碑,因为此时已有一些群智能理论和方法得到了应用。其中,它反对定义中使用“主体”一词,其理由是“主体”所具有的自治

性和特殊性是许多“Swarm”的个体所不具备的,这将大大限制“Swarm”的定义范围。他们认为暂时无法给出合适的定义,赞同由 Mark Millonas 提出的构建一个 SI 系统所应满足的五条基本原则,具体如下:

(1) Proximity Principle。群内个体具有能执行简单的时间或空间上的评估和计算的能力。

(2) Quality Principle。群内个体对环境(包括群内其他个体)的关键性因素的变化做出响应。

(3) Principle of Diverse Response。群内不同个体对环境中的某一变化所表现出的响应行为具有多样性。

(4) Stability Principle。不是每次环境的变化都会导致整个群体的行为模式的改变。

(5) Adaptability Principle。环境所发生的变化中,若出现群体值得付出代价的改变机遇,群体必须能够改变其行为模式。

以上五条原则成为目前群智能的最基本理论,现有的群智能方法和策略都符合这些原则。

SI 最重要的观点是“Mind is social”,也就是认为人的智能是源于社会性的相互作用,文化和认知是人类社会性不可分割的重要部分,这一观点成为群智能发展的基石。

群智能模拟的是社会系统的变化,其最基本单位是“敏因”(Meme),它是思想文化传播中的基本单位,个体在社会中会根据环境来改变自身的思想,敏因的传播途径是在个体与个体之间,在人类社会,它还可以在人脑与书本之间、人脑与计算机、计算机与计算机之间传播。

群智能研究的更进一步目标是对人类思想变化的社会行为的模拟。人类心理上存在群体性、习惯性、一致性,常常习惯性地遵循一些习俗和规则。无论什么时候,人们思想和行为总是因相互影响而导致近似的结果。人类的社会思想行为并不简单类似于鸟群或鱼群的行为,人类思想的形成过程是一种在高维认知空间的探索历程。两种思想意见在认知空间上聚集到一点上,被称为“一致”或“认同”,而不是鸟群或鱼群系统中的“碰撞”。如果某人认同认知空间某个点,那么就努力靠近它,反之则尽量远离它,这里认知空间中的某个点就是某个人的思想。人类通过这种社会行为达成社会共识,如习俗、道德规范等。

1.1.3 群智能的应用

群智能理论现在已经得到了一些应用,出现了一些基于群智能的算法和策略。不过,仅有蚁群算法(Ant Colony Optimization, ACO)和粒子群优化算法(Particle Swarm Optimizaion, PSO)得到了广泛应用。

1.2 混合蛙跳算法

混合蛙跳算法(Shuffled Frog Leaping Algorithm, SFLA)是2003年由Eusuff和Lansley提出的,是根据模拟青蛙觅食过程中信息共享和交流的特点而产生的群体智能优化算法。SFLA是一种基于种群的亚启发式协同搜索算法,算法的执行过程是模拟自然界的元进化行为。作为一种全新的优化计算方法,SFLA以随机联合体进化算法(Shuffled Complex Evolution, SCE)作为广度搜索的执行框架,结合了基于遗传基因的元进化算法(Memetic Algorithm, MA)及基于群体觅食行为的粒子群算法特点,具有易于理解、概念简单、参数少(具有比PSO更少的算法参数)、计算速度快、全局寻优能力强、易于实现的特点。目前该算法已经不断得到完善和应用,如旅行商问题、0-1背包问题、车辆路径问题、图像分割、网格任务调度等。然而在基本混合蛙跳算法的求解过程中,对于一些复杂的问题依然存在收敛速度较慢、优化精度较低、局部搜索能力差的缺点,而且随着维数的增加,最终影响了算法的效率。因此研究者用不同的方法进行了相应的改进,提出了一种基于PSO的改进混合蛙跳算法,在一定程度上改善了基本混合蛙跳算法的性能;有实验利用邻域正交交叉算子增强个体的多样性,提高了算法的收敛速度。有实验结合差分演化算法提高了SFLA局部搜索的速度,取得了很好的效果。量子粒子群算法(Quantum-behaved Particle Swarm Optimization, QPSO)是根据粒子群的基本收敛性质,受量子物理基本理论的启发,2004年由Sun等人在研究了Clerc等人的关于粒子收敛行为的研究成果后,从量子力学的角度出发提出的一种新的PSO算法模型。QPSO算法是以DELTA势阱为基础,认为粒子具有量子的行为,是对整个PSO算法进行搜索策略的改变,并且进化方程中不需要速度向量,而且进化方程的形式更简单,参数更少,更易于控制。为了解决SFLA算法中的缺陷,研究者利用了SFLA全局搜索能力强及QPSO搜索速度快的优点,局部使用QPSO算法的搜索策略,全局使用SFLA算法的混合能力,对各个簇重新洗牌,加强了局部各簇群中个体的多样性和均匀性。实验证明,改进的SFLA算法,大大提高了算法的优化精度和收敛速度。

1.3 人工鱼群算法

1.3.1 人工鱼群算法概述

人工鱼群算法(Artificial Fish-Swarm Algorithm, AFSA)是由山东大学副教

授李晓磊等在2002年提出的。它源于对鱼群运动行为的研究,是一种新型的智能仿生优化算法。它具有较强的鲁棒性、优良的分布式计算机制以及易于和其他方法结合等优点。目前对该算法的研究、应用已经渗透到多个应用领域,并由解决一维静态优化问题发展到解决多维动态组合优化问题。人工鱼群算法已经成为交叉学科中一门非常活跃的前沿性学科。本节主要对人工鱼群算法进行阐述,引入鱼群模式的概念,然后给出人工鱼的结构,接下来总结人工鱼的寻优原理,并对人工鱼群算法的寻优过程进行仿真,通过四个标准函数选取不同的拥挤度因子进行仿真实验,并证实利用人工鱼群算法进行全局寻优确实是有效的。

1.3.2 人工鱼群算法的特点

动物在进化过程中,经过漫长的优胜劣汰,形成了形形色色的觅食和生存方式,这些方式为人类解决生产和生活中的问题带来了不少启发和灵感。动物不具备复杂逻辑推理能力和综合判断等高级智能,但它们通过个体的简单行为和相互影响,实现了群体的生存和进化。动物行为具有以下几个特点。

(1)适应性。动物通过感觉器官来感知外界环境,并应激性地做出各种反应,从而影响环境,表现出与环境交互的能力。

(2)自治性。在不同的时刻和不同的环境中能够自主地选取某种行为,而无须外界的控制或指导。

(3)盲目性。单个个体的行为是独立的,与总目标之间没有直接关系。

(4)突现性。总目标的完成是在个体行为的运动过程中突现出来的。

(5)并行性。每个个体的行为是并行进行的。

人工鱼群算法是根据鱼类的活动特点提出的一种基于动物行为的自治体寻优模式。20世纪90年代以来,群智能的研究引起了众多学者的极大关注,并出现了蚁群优化、粒子群优化等一些著名的群智能方法。

集群是生物界中常见的一种现象,如昆虫、鸟类、鱼类、微生物乃至人类等。生物的这种特性是在漫长的进化过程中逐渐形成的,对其生存和进化有着重要的影响,同时这些方式也为人类解决问题的思路带来不少启发和鼓舞。因此,近年来有不少科学家对生物行为进行了广泛研究,并逐渐形成了一种基于生物行为的人工智能模式。这种基于生物行为的人工智能模式与经典的人工智能模式是不同的,它不是采取自上而下的设计方法,而是采取自下而上的设计方法:首先设计单个实体的感知、行为机制,然后将一个或一群实体放置于环境中,让它们在与环境的交互作用中解决问题,它是内嵌的、物化的、自治的、突现的。

一个集群通常定义为一群自治体的集合,它们利用相互直接或间接的通信,从而通过全体的活动来解决一些分布式难题。在这里,自治体是指在一个环境中具备自身活动能力的一个实体,其自身力求简单,通常不必具有高级智能。但是,它们的集群活动所表现出来的则是一种高级智能的活动,这种活动被称为集群

智能。

动物自治体通常指自主机器人或动物模拟实体，它主要用来展示动物在复杂多变的环境中能够自主产生自适应的智能行为的一种方式。自治体的行为受到环境影响的同时，每一个自治体又是环境的构成因素。环境的下一个状态是当前状态和自治体活动的函数，自治体的下一个刺激是在环境的当前状态和其自身活动的函数，自治体的合理架构就是能在环境的刺激下做出最好的应激活动。

将动物自治体的概念引入鱼群优化算法中，采用自下而上的设计思路，应用基于行为的人工智能方法，可形成一种新的解决问题的模式。因为是从分析鱼类活动而出发的，所以称为鱼群模式。该模式用于寻优中，形成人工鱼群算法。

在一片水域中，鱼群生存数目最多的地方一般就是该水域中富含营养物质最多的地方，依据这一点来模仿鱼群的觅食、群聚、追尾等行为，从而实现全局寻优，这就是人工鱼群算法的基本思想。

1.3.3 人工鱼群算法的应用

人工鱼(Artificial Fish, AF)是真实鱼的一个虚拟实体，用来进行问题的分析和说明。人工鱼的结构模型和行为描述可以借助面向对象的分析方法，将人工鱼视为封装了自身数据和一系列行为的实体，可以通过感官来接收环境的刺激信息，并通过控制尾鳍来做出相应的应激活动。

1.4 蚁群算法

1.4.1 蚁群算法概述

蚁群算法是一种新型的模拟自然界蚁群行为的进化算法，由意大利学者 Dorigo M 等人于 20 世纪 90 年代初首先提出。该算法采用了分布式并行计算机制，易于与其他优化算法相结合，且具有鲁棒性较强、正反馈等优点，具有无中心控制和分布式个体之间间接通信的特征，被广泛应用于求解复杂的优化问题。

1.4.2 蚁群算法的基本原理

蚂蚁个体之间是通过一种被称为信息素的物质进行信息传递，在运动过程中，能够在路径上留下一定量的信息素，并以此来指导自己的运动方向。蚂蚁倾向于朝信息素浓度高的方向移动。因此由大量蚂蚁组成的蚁群的集体行为就表现出一种正反馈现象：某路径上走过的蚂蚁越多，后者选择该路径的概率就越大。蚂蚁个体之间就是通过这种信息交流来觅食的。

下面以具有代表性的 TSP 问题为例介绍其基本算法。TSP 问题可以描述如下：设 $C = \{c_1, c_2, \dots, c_n\}$ 为 n 个城市的集合， $L = \{l_{ij} \mid c_i, c_j \in C\}$ 是 C 中元素两两连接的集合， $G = (C, L)$ 是一个图，各个城市之间的距离是已知的，TSP 问题的求解目标是从 G 中找出长度最短的 Hamiltonian 回路，也就是寻找一条遍历所有 n 个城市有且仅有一次最后返回到出发城市的最短路径。

设 $b_i(t)$ 表示 t 时刻位于元素 i 的蚂蚁数目， $\tau_{ij}(t)$ 为 t 时刻路径 (i, j) 上的信息量， n 表示 TSP 的规模， m 为蚁群中蚂蚁的数目，则 $m = \sum_{i=1}^n b_i(t)$ ； $\Gamma = \{\tau_{ij}(t) \mid c_i, c_j \in C\}$ 是 t 时刻集合 C 中元素两两连线 l_{ij} 上残留信息量的集合。每只蚂蚁有以下特征。

(1) 根据以城市距离和连接边上信息素的数量为变量的概率函数选择下一个城市。

(2) 完成一次循环后，蚂蚁在其访问过的每条边上留下一定量的信息素。

(3) 规定蚂蚁走合法的路线，在完成一次循环之前，不允许蚂蚁选择已访问过的城市，由禁忌表来控制该过程。设 $tabu_k$ 表示第 k 只蚂蚁的禁忌表，在蚂蚁 k 经过城市 i 后，就将 i 加入到禁忌表 $tabu_k$ 中，表示下次不能选择城市 i 。 $tabu_k(s)$ 表示禁忌表中第 s 个元素。

算法初始时刻，把 m 只蚂蚁随机放到 n 个城市，将每只蚂蚁当前所在的城市加入到其禁忌表中，此时，各条路径上的信息素量相等，并设 $\tau_{ij}(0) = C$ (C 为一个较小常数)。在搜索过程中，蚂蚁 k 根据各条路径上的信息数量及路径的启发式信息来决定转移方向，此种状态转移规则称为随机比例规则。

一些学者对蚁群算法进行了改进，改进主要是从局部搜索策略、蚂蚁内部状态、信息素更新策略及选择策略四方面进行，都取得了较好的效果，如自适应蚁群算法、基于信息素扩散的蚁群算法、多态蚁群算法、基于信息熵的改进蚁群算法、基于网格划分策略的连续域蚁群算法、基于交叉变异操作的连续域蚁群算法等。

蚁群算法还能与其他优化算法相融合，从而相互取长补短，改善算法的性能。目前这方面的研究有蚁群算法与遗传算法、人工神经网络、粒子群算法及人工免疫算法等算法之间的融合。这些融合了的算法在解决某些特定问题时表现出了比较优异的性能，因此，设计新的融合策略，结合其他优化算法，进一步改善蚁群算法的性能是非常有意义的研究方向。

1.4.3 蚁群算法的特点

蚁群算法自 20 世纪 90 年代初问世以来，其理论和应用都取得了很大的进步，从最初求解 TSP 问题开始，逐渐发展为一个优化工具，并成功地应用到科学和工程中的多个领域。蚁群算法具有分布式计算、无中心控制、个体之间异步间接通

信等特点,并且易于与其他优化算法相结合。

同时蚁群算法也存在一些缺点:问题规模大时,其搜索时间长;易出现停滞现象;易陷于局部最优;在数学上缺少严格的理论基础及正确性和可靠性的有效证明。因此,蚁群算法还有很大的尚待解决的问题,其应用也有待进一步挖掘。

蚁群算法仍有以下方面值得深入研究。

(1)目前大部分改进蚁群算法的普适性不强,同时其模型也不能直接应用于实际优化问题。因此,对通用的蚁群算法普适性模型的研究值得深入下去。

(2)同其他几种仿生优化算法相比,蚁群算法没有坚实的数学基础。

(3)蚁群算法与其他算法之间的比较研究还处于起步阶段,与其他算法之间融合机制和策略仍有待进一步探讨。

(4)仿生硬件是并行计算环境下的产物,蚁群算法的硬件实现是仿生硬件研究领域中的一个新分支,还存在许多问题需要解决。

(5)目前蚁群算法的应用领域大多是静态组合优化问题,如何使其应用于动态组合优化问题和连续优化问题也是一个研究方向。

1.4.4 蚁群算法的应用

蚁群算法最初被应用到经典的组合优化问题,随着研究的深入,应用范围扩大到更多的组合优化问题,如在作业调度、网络路由、电力系统、生命科学、空战决策、聚类分析等领域都得到了广泛的应用,体现了蚁群算法的实用性和通用性。以下是蚁群算法应用的一些实例。

(1)网络路由问题。将蚁群算法应用于解决受限路由问题,目前可以解决包括带宽、延时、丢包率和最小花费等约束条件在内的 QoS 组播路由问题,比现有的链路状态路由算法有明显的优越性。

(2)电力系统领域。电力系统的许多优化问题本质上属于组合优化问题。Gomez 等将蚁群算法应用于配电网的规划。王林川等将一种改进蚁群算法应用于配电网故障的定位。王海燕等将蚁群算法应用于电力系统暂态稳定评估特征选择,减少了特征维数,提高了分类正确率。电力系统的这些组合优化问题的有效解决将为电力企业节省大量的资金,因此在电力系统的应用具有很大的实际价值。

(3)航迹规划问题。航迹规划是指在特定的约束条件下,寻找运动体从初始点到目标点满足某种性能指标最优的运动轨迹。在空防技术日益先进、防空体系日益完善的现代战争中,航迹规划是提高飞行器作战效能、实施远程精确打击的有效手段,因此对航迹规划方法的研究将有重要的现实意义。田伟等提出了一种改进蚁群算法用于无人作战飞机的航路寻优过程,提高了无人作战飞机的航路寻优能力。孟祥恒等将蚁群算法应用于无人机航迹规划。曹晋等提出了一种基于蚁群算法的最小代价航迹规划方法,解决了航迹维数解算问题,为飞行器提供了最优航迹规划路径。

总之, 蚁群算法是一种很有前途的算法, 也是一个很值得研究的领域。随着对其研究的不断深入, 其应用将更加广泛, 其理论也将更加成熟。

1.5 粒子群算法

1.5.1 粒子群算法概述

粒子群算法, 也称粒子群优化算法(Particle Swarm Optimization, PSO), 是一种新型的仿生算法, 由 Kennedy 和 Eberhart 于 1995 年提出。该算法是基于群体智能(Swarm Intelligence, SI)的优化算法, 其功能与遗传算法(Genetic Algorithm, GA)非常相似。PSO 因其需要调节的参数少, 具有简单且易于实现的优点, 因此越来越多地被应用于函数优化、神经网络训练、模式分类以及其他领域。但是, 其数学基础不完善, 实现技术不规范, 在适应度函数选取、参数设置、收敛理论等方面还存在许多需要深入研究的问题。本节主要介绍 PSO 算法原理和特点, 并在此基础上提出一种改进的 PSO 算法, 并用测试函数对其进行验证。

1.5.2 粒子群算法的基本原理和特点

1. 粒子群算法简介

粒子群算法是一个非常简单的算法, 且能够有效地优化各种函数。从某种程度上说, 此算法介于遗传算法和进化规划之间。此算法非常依赖于随机的过程, 这也是和进化规划的相识之处, 此算法中朝全局最优和局部最优靠近的调整非常类似于遗传算法中的交叉算子。此算法还用了适应度值的概念, 这是所有进化计算方法所共有的特征。

在粒子群算法中, 每个个体称为一个“粒子”, 其实每个粒子代表着一个潜在的解。例如, 在一个 D 维的目标搜索空间中, 每个粒子可被看成空间内的一个点。设群体由 m 个粒子构成。 m 也被称为群体规模, 过大的 m 会影响算法的运算速度和收敛性。

PSO 算法通常的数学描述为: 设在一个 D 维空间中, 由 m 个粒子组成的种群 $X = (x_1, \dots, x_i, \dots, x_D)$, 其中第 i 个粒子位置为 $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})^T$, 其速度为 $V_i = (v_{i1}, v_{i2}, \dots, v_{id}, \dots, v_{iD})^T$ 。它的个体极值为 $p_i = (p_{i1}, p_{i2}, \dots, p_{iD})^T$, 种群的全局极值为 $p_g = (p_{g1}, p_{g2}, \dots, p_{gD})^T$, 按照追随当前最优例子的原理, 粒子 x_i 将按式(1-1)、式(1-2)改变自己的速度和位置。

$$v_{ij}(t+1) = v_{ij}(t) + c_1 r_1(t)(p_{ij}(t) - x_{ij}(t)) + c_2 r_2(t)(p_{gj}(t) - x_{ij}(t)) \quad (1-1)$$

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

其中, $j=1, 2, \dots, D$; $i=1, 2, \dots, m$; m 为种群规模; t 为当前进化代数; r_1, r_2 为分布于 $[0, 1]$ 之间的随机数; c_1, c_2 为加速常数。从式(1-1)中可知, 每个粒子的速度由三部分组成: 第一部分为粒子先前的速度; 第二部分为“认知”部分, 表示粒子自身的思考; 第三部分为“社会”部分, 表示粒子间的信息共享与相互合作。

2. 粒子群算法的特点

粒子群算法是一种新兴的智能优化技术, 是群体智能中一个新的分支, 它也是对简单社会系统的模拟。该算法本质上是一种随机搜索算法, 并能以较大的概率收敛于全局最优解。实践证明, 粒子群算法适合在动态、多目标优化环境中寻优, 与传统的优化算法相比具有更快的计算速度和更好的全局搜索能力。具体特点如下。

(1) 粒子群优化算法是基于群体智能理论的优化算法, 通过群体中粒子间的合作与竞争产生的群体智能指导优化搜索。与进化算法相比, PSO 是一种更为高效的并行搜索算法。

(2) PSO 与 GA 有很多共同之处, 两者都是随机初始化种群, 使用适应度值来评价个体的优劣程度和进行一定的随机搜索。但 PSO 是根据自己的速度来决定搜索, 没有 GA 的明显的交叉和变异。与进化算法相比, PSO 保留了基于种群的全局搜索策略, 但是其采用的速度一位移模型操作简单, 避免了复杂的遗传操作。

(3) PSO 有良好的机制来有效地平衡搜索过程的多样性和方向性。

(4) GA 中由于染色体共享信息, 故整个种群较均匀地向最优区域移动。在 PSO 中 g_{best} 将信息传递给其他粒子, 是单向的信息流动。多数情况下, 所有的粒子可能更快地收敛于最优解。

(5) PSO 特有的记忆使其可以动态地跟踪当前的搜索情况并调整其搜索策略。

(6) 由于每个粒子在算法结束时仍然保持其个体极值, 因此, 若将 PSO 用于度和决策问题则可以给出多种有意义的选择方案。而基本遗传算法在结束时, 只能得到最后一代个体的信息, 前面迭代的信息没有保留。

(7) 即使同时使用连续变量和离散变量, 对位移和速度同时采用和离散的坐标轴, 在搜索过程中也并不冲突。所以 PSO 可以很自然、很容易地处理混合整数非线性规划问题。

(8) PSO 算法对种群大小不是十分敏感, 即种群数目下降时, 性能下降不是很大。

(9) 在收敛的情况下, 由于所有的粒子都向最优解的方向飞去, 所以粒子趋向同一化(失去了多样性), 使得后期收敛速度明显变慢, 以致算法收敛到一定精度时无法继续优化。因此, 很多学者都致力于提高 PSO 算法的性能。

3. 粒子群算法的原理

粒子群优化算法的基本概念是源于对鸟群捕食行为的模仿研究, 人们从鸟群