



工业和信息化部“十二五”规划专著
“十二五”国家重点图书出版规划项目

辐射传输逆问题的智能优化理论与应用

Intelligent Optimization Theory and Application
in the Inverse Radiative Problem

● 齐宏 阮立明 谈和平 编著



哈爾濱工業大學出版社
HARBIN INSTITUTE OF TECHNOLOGY PRESS

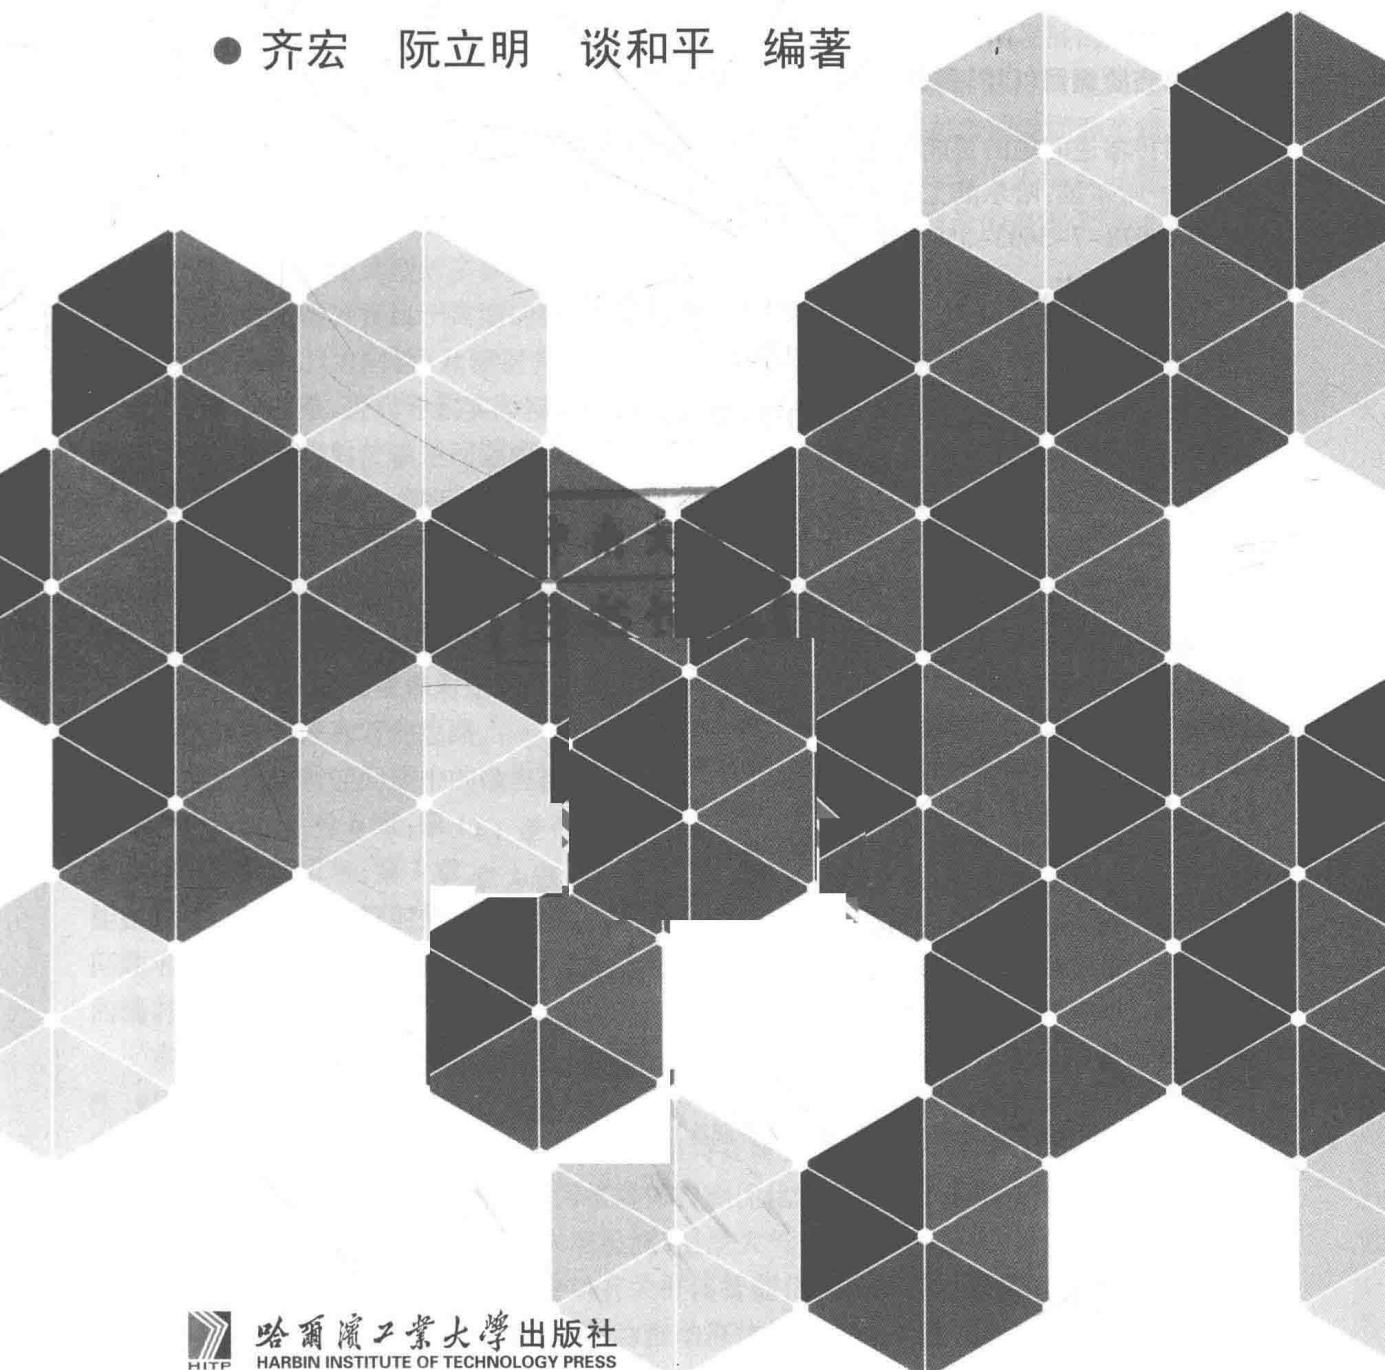


工业和信息化部“十一五”规划教材
“十二五”国家重点图书出版规划项目

辐射传输逆问题的智能优化理论与应用

Intelligent Optimization Theory and Application
in the Inverse Radiative Problem

● 齐宏 阮立明 谈和平 编著



哈爾濱工業大學出版社
HARBIN INSTITUTE OF TECHNOLOGY PRESS

内容提要

本书对微粒群算法、蚁群算法等智能优化方法在辐射传输逆问题中的应用进行了系统性的总结,结合介质辐射传输数值模拟、辐射特性研究、时频域光热信号分析、病态逆问题求解等多学科的理论和知识,阐述了如何将群体智能优化算法运用于辐射传输逆问题的求解。

本书可作为高等学校工程热物理、热能与动力工程、航空航天、生物医学、辐射测量及其相关专业的本科生、研究生的参考书,也可供相关专业的工程技术和科研人员学习参考。

图书在版编目(CIP)数据

辐射传输逆问题的智能优化理论与应用/齐宏,阮立明,谈和平
编著. —哈尔滨:哈尔滨工业大学出版社,2016.3

ISBN 978-7-5603-5507-8

I. ①辐… II. ①齐… ②阮… ③谈… III. ①辐射-
传输-逆问题-研究 IV. ①TL99②0175

中国版本图书馆 CIP 数据核字(2015)第 162116 号

策划编辑 王桂芝

责任编辑 刘 瑶

出版发行 哈尔滨工业大学出版社

社 址 哈尔滨市南岗区复华四道街 10 号 邮编 150006

传 真 0451-86414749

网 址 <http://hitpress.hit.edu.cn>

印 刷 哈尔滨市石桥印务有限公司

开 本 787mm×1092mm 1/16 印张 15 字数 366 千字

版 次 2016 年 3 月第 1 版 2016 年 3 月第 1 次印刷

书 号 ISBN 978-7-5603-5507-8

定 价 48.00 元

(如因印装质量问题影响阅读,我社负责调换)

前　　言

热辐射是能量传递的一种方式,也是信息传输的载体,在航空航天、国防科技、动力、化工、材料、新能源、信息技术、生物技术等工程领域有着广泛应用。例如,高温加热设备中含微粒介质(流体或气体)的辐射传热计算;弹道导弹主动段尾喷焰红外辐射特性;飞机发动机尾喷焰红外辐射强度;弹道导弹再入段可见、红外光辐射特征;军用目标红外热像理论研究;空间光学系统杂散光分析和热分析;可再生新能源光辐射传输分析等。近十年来,辐射逆问题研究已成为红外辐射领域最为活跃的前沿研究方向之一。在近期发展的近红外光学成像领域,其信息重建过程的实质是基于时域或频域光热信号求解辐射传输逆问题。在大气辐射传输领域,气溶胶粒径分布的测量、遥感探测等均属求解辐射传输逆问题范畴。在炉内火焰可视化检测技术领域,基于火焰辐射图像的燃烧检测实质是基于火焰方向辐射传输逆问题的温度场重建。目前,本课题组正在开展的基于光场成像理论的高温发光火焰温度场在线检测技术也是典型的多参数群辐射传输逆问题。

由于辐射传输方程属于典型的积分-微分方程,其控制方程的非线性、辐射界面的复杂性(透明或非透明、方向性)及辐射具有延程性、方向性、光谱性等特点,使得正向求解辐射传输问题十分复杂,进而导致实际辐射传输逆问题求解的复杂性、高度非线性和不稳定性,因此寻找适合于辐射传输逆问题求解的新型优化方法一直是计算辐射学的一个重点研究方向。随着近期计算机技术的高速发展,群体智能优化算法受到了广泛的关注与应用。与传统梯度优化方法相比,智能优化算法具有仿生行为特征和智能性,无需已知优化问题的精确数学模型,无需求解其梯度,不依赖于初始条件,采用启发式概率搜索,能够获得全局最优解或准最优解,尤其适合于复杂辐射逆问题的并行求解。总之,智能优化算法通用性强,且具有全局优化性能,因而在辐射逆问题领域有着广阔的应用前景,可为辐射传输相关的逆问题研究提供新的手段和新的思路。

本书针对辐射逆问题中的微粒群算法、蚁群算法等智能优化算法模型、理论基础和优化应用进行探讨,共分6章:第1章介绍智能优化算法的基本原理和研究现状;第2章为辐射传输理论及数值求解;第3章为辐射传输逆问题求解的群体智能优化理论;第4章为基于智能微粒群优化算法的辐射传输逆问题求解;第5章为基于智能蚁群优化算法的辐射传输逆问题求解;第6章为基于自组织迁移算法、地理学优化算法、果蝇算法及混合智能优化算法的辐射传输逆问题求解。

本书视角独特,对智能优化算法在辐射逆问题中的应用进行系统性的总结,将微粒群算法、蚁群算法、自组织迁移算法、地理学优化算法和果蝇算法等智能优化方法引入辐射传输逆问题领域,结合介质辐射传输数值模拟、辐射特性研究、时频域光热信号分析、病态逆问题求解等多学科的理论和知识,阐述如何将群体智能优化算法运用于辐射传输逆问题的求解,为近红外光学成像、辐射物性测量、火焰检测、卫星大气遥感、海洋探测、导弹红外预警等领域提供理论支撑。本书作者结合自身对有关群体智能优化算法的思考撰写此书,其目的是分享我们在该领域所做的部分研究成果,为推动群体智能优化算法在辐射逆问题领域的发

展尽微薄之力。

本书结合作者多年来在参与性介质辐射逆问题方面的相关研究工作以及国内外同行的研究成果,将辐射传输逆问题的智能优化理论进行归纳总结,结合参与性介质内辐射传输及其逆问题分析、病态问题求解、智能优化算法等方面的理论知识,详细地阐述了基于微粒群算法、蚁群算法及其改进混合算法等智能优化算法的辐射传输逆问题求解理论和技术。本书主题鲜明,结构严谨,内容丰富,对推动我国辐射传输逆问题求解理论的研究具有重要的科学意义和应用价值。

本书由齐宏、阮立明和谈和平共同撰写而成。其中,第1章由齐宏撰写,第2章由谈和平和阮立明撰写,第3章由阮立明撰写,第4~6章由齐宏撰写,全书由齐宏统稿。本书初稿承蒙上海理工大学蔡小舒教授和哈尔滨工业大学戴景民教授审阅,他们对书稿提出了许多宝贵的修改意见,特此感谢。本书的完成得到了哈尔滨工业大学能源学院航空航天热物理所各位同仁的大力支持。

本书研究工作先后得到国家自然科学基金(50806016、51076037、51476043、51576053)、国家自然科学基金创新群体(51121004、51421063)、国家重大科研仪器设备研制专项基金(51327803)、国家安全重大基础研究基金、中国博士后基金(20090460893)、高等学校博士学科点专项科研基金(20122302110046)、黑龙江省自然科学基金(E201235)、黑龙江省博士后启动基金(LBH-Q12111)、哈尔滨市科技创新人才研究专项基金(2013RFXXJ040、2014RFQXJ047)、航天支撑技术基金和中国民航大学天津市民用航空器适航与维修重点实验室开放基金等资助。此外,本研究工作还得到中央高校基本科研业务费专项资金(HIT.BRETI.2010012,5710057215)及哈尔滨工业大学“985工程”本科教学建设项目资助,上述基金项目的支持为作者及其团队创造了宽松的学术氛围和科研环境,在此谨向相关部门表示深深的感谢。

本书内容为几位作者近几年研究成果的总结,作者的多位学生参与了相关科研工作,他们是安巍、王圣刚、王希影、王大林、张彪、贺振宗、乔要宾、牛春洋、任亚涛,同时,撰写过程中还得到孙双成、宫帅、姚禹辰、王雨晴、陈琴、贾腾、黄兴、吕中原、张俊友、文爽、魏林杨、何明键、赵方舟、阮世庭等的协助和支持,在此由衷地表示感谢!

辐射逆问题的智能优化理论是辐射逆问题计算领域中一个正在快速发展的新型分支,其理论与应用方面均存在大量亟待进一步深入研究的问题。由于作者学识水平有限,书中难免有疏漏之处,敬请专家、学者与诸位读者不吝指正。

编 者

2015年12月于哈尔滨工业大学

目 录

第1章 绪论	1
1.1 引言	1
1.2 群体智能优化算法概述	2
1.2.1 群体智能优化算法的特点和分类	2
1.2.2 常见群体智能优化算法简介	5
1.2.3 群体智能优化算法的主要问题和研究方向.....	12
1.3 群体智能优化算法在辐射逆问题求解中的应用.....	13
1.4 本书的结构和内容安排.....	14
参考文献	14
第2章 辐射传输理论及数值求解	18
2.1 引言.....	18
2.2 辐射传输方程.....	19
2.2.1 稳态辐射传输方程.....	19
2.2.2 瞬态辐射传输方程.....	21
2.2.3 频域辐射传输方程.....	24
2.3 热辐射传输数值方法简介.....	26
2.3.1 热流法.....	28
2.3.2 离散坐标法.....	31
2.3.3 有限体积法.....	35
2.3.4 有限单元法.....	42
2.3.5 球谐函数法.....	48
2.3.6 积分方程法.....	51
2.4 辐射能量方程.....	52
2.4.1 辐射-导热耦合换热	54
2.4.2 辐射-相变耦合换热	56
参考文献	60

第3章 辐射传输逆问题求解的群体智能优化理论	65
3.1 辐射传输逆问题的分类	66
3.2 智能优化理论概述	69
3.3 微粒群智能优化算法	70
3.3.1 标准微粒群算法	70
3.3.2 微粒群算法的计算流程	73
3.3.3 微粒群算法的性能评价	73
3.3.4 标准微粒群算法	75
3.3.5 改进的微粒群算法	75
3.4 人工蚁群算法	81
3.4.1 标准离散域蚁群算法	81
3.4.2 基于网格划分的连续域蚁群算法	83
3.4.3 基于概率密度的连续域蚁群算法	86
3.5 混合智能优化算法	87
3.5.1 蚁群-微粒群混合算法	87
3.5.2 单纯形-微粒群混合算法	89
3.5.3 Powell-微粒群混合算法	90
3.5.4 差分进化-微粒群混合算法	92
3.5.5 模拟退火-微粒群混合算法	94
3.6 其他智能优化算法	97
3.6.1 生物地理学优化算法	97
3.6.2 果蝇优化算法	99
3.6.3 自组织迁移优化算法	101
3.7 标准测试函数	103
参考文献	107
第4章 基于智能微粒群优化算法的辐射传输逆问题求解	113
4.1 稳态辐射传输逆问题的微粒群算法求解	113
4.1.1 介质辐射特性的 PSO 算法和 SPSO 算法优化反演	113
4.1.2 介质辐射特性的 MPPSO 算法反演	119
4.2 辐射-导热耦合换热逆问题的微粒群算法求解	125
4.2.1 平板介质热物性及辐射物性参数的 RD-PSO 反演	125
4.2.2 陶瓷类介质内部缺陷重构	126
4.3 瞬态辐射传输逆问题的微粒群算法求解	128

4.3.1 基于时域信号的一维介质的物性参数反演	128
4.3.2 基于时域信号的二维介质的物性参数反演	135
4.3.3 基于时不同时段时域信号的辐射物性反演	136
4.3.4 采用时域峰值信号反演介质内部特性	139
4.3.5 基于频域信号的光学参数重构	143
4.4 粒径分布逆问题的微粒群算法求解	145
4.4.1 粒径分布测量原理	147
4.4.2 粒径分布 MPPSO 反演结果与分析	148
参考文献	150
第5章 基于智能蚁群优化算法的辐射传输逆问题求解	152
5.1 稳态辐射传输逆问题的蚁群算法求解	152
5.1.1 单参数反演	152
5.1.2 多参数反演	154
5.2 瞬态辐射传输逆问题的蚁群算法求解	157
5.2.1 基于时域信号的正问题数值计算	157
5.2.2 基于时域信号的光学厚度和散射反照率的反演	158
5.2.3 反演误差分析	160
5.2.4 基于频域信号的辐射传输逆问题的蚁群算法求解	162
5.3 瞬态辐射-相变耦合换热逆问题的蚁群算法求解	168
5.3.1 瞬态辐射-相变耦合换热正问题	168
5.3.2 衰减系数反演	169
5.3.3 反演误差分析	170
5.4 粒径分布逆问题的蚁群算法求解	171
5.4.1 探测原理	171
5.4.2 球形粒子粒径分布反演	171
5.4.3 椭球形粒子粒径分布反演	181
参考文献	187
第6章 基于混合及其他智能优化算法的辐射传输逆问题求解	190
6.1 采用自组织迁移算法求解辐射传输逆问题	190
6.1.1 逆问题数值模拟计算结果及分析	190
6.1.2 基于时域脉冲信号的生物组织物性反演	196
6.2 采用生物地理学优化算法求解辐射传输逆问题	201
6.2.1 单物性参数的反演结果	202

6.2.2 多物性参数的反演结果	203
6.3 采用果蝇算法求解粒径分布逆问题	205
6.3.1 颗粒粒径分布数值反演结果	205
6.3.2 颗粒粒径分布反演实验研究	211
6.4 采用单纯形-微粒群混合优化算法求解辐射传输逆问题	212
6.4.1 边界温度响应对辐射特性参数的敏感性分析	213
6.4.2 无测量误差条件下的反演结果	216
6.4.3 存在测量误差条件下的反演结果	218
6.5 采用微粒群-蚁群混合优化算法求解辐射传输逆问题	222
6.5.1 单参数反演	223
6.5.2 多参数反演	224
6.6 采用混合差分微粒群算法求解源项分布逆问题	225
参考文献	227
名词索引	230

第1章 絮 论

1.1 引 言

热辐射是能量传递的一种方式,也是信息传递的载体,因此,热辐射传输在国防科技、动力、化工、材料、新能源、信息、生物技术等工程领域有着广泛应用。例如,高温加热设备中含微粒介质的辐射传热计算、弹道导弹主动段尾喷焰红外辐射特性、飞机发动机尾喷焰红外辐射强度、弹道导弹再入段可见及红外光辐射特征、军用目标红外热像理论研究、空间光学系统杂散光分析和热分析、可再生新能源光辐射传输分析等^[1, 2]。近十年来,将辐射传输过程中的光子作为信息载体的辐射逆问题成为红外辐射领域最活跃、最前沿的研究方向之一。

辐射传输逆问题既是当前辐射传输领域发展中的一个前沿研究方向,也是一个典型的交叉研究领域,它的发展与辐射传输、光学、电磁学、计算科学等学科的研究水平息息相关,相辅相成。在近期发展的近红外生物检测技术中,非接触生物光学成像的物理实质是基于时域或频域光热信号的辐射传输逆问题求解。在大气辐射传输领域中,气溶胶粒径分布的测量及遥感探测等均属于辐射传输逆问题范畴。在炉内火焰可视化检测技术中,基于火焰辐射图像的燃烧检测实质是基于方向火焰辐射传输逆问题的温度场和辐射物性场联合信息重建。目前,本课题组正在开展的基于光场成像理论的高温发光火焰温度场在线检测技术也是典型的多参数群辐射传输逆问题求解。

由于辐射传输方程属于典型的积分-微分方程,其控制方程的非线性、辐射界面的复杂性(透明或非透明特性、方向特性等)以及辐射具有延程性、方向性、光谱性等特点,使得求解辐射传输正问题十分复杂,进而导致辐射逆问题的求解更为困难。目前,对于辐射传输逆问题的求解方法大致分为两大类:第一类是基于梯度计算的传统优化方法,其优势在于收敛速度快,反演结果稳定性好,如最速下降法、共轭梯度法、牛顿法、变尺度法及最小二乘法等;第二类是基于概率搜索的智能优化算法,其特点是模型简单、不依赖初值和能够获得全局最优解,如微粒群算法、蚁群算法、遗传算法等。基于梯度计算的传统优化算法具有如下局限性:①传统梯度算法对初值的依赖性大,如果初值设置不合理,优化结果会很差,甚至可能找不到最优解;②传统梯度算法需要对目标函数的导数进行求解,因而将耗费大量计算机内存和计算时间;③对于存在多值性或者多个局部最优解的逆问题模型,传统梯度算法往往容易陷入局部最优而失效^[2]。近期,随着计算机技术的高速发展,具有仿生行为特征和智能性的群体智能优化算法受到广泛关注。自1991年蚁群算法^[3]和1995年微粒群算法^[4]被提出后,对群体智能优化算法的研究迅速展开,被广泛应用于多类实际问题的求解。作为一种启发式算法(Heuristic Algorithm),群体智能优化算法的特点是从某一个随机解出发,按照相应的算法机制,以一定的概率在求解空间中寻找最优解。与传统梯度优化方法相比,智能优化算法无须已知优化问题的精确数学模型,也无须求解目标函数的梯度,采用启发式的概率搜

索,能够获得全局最优解或准最优解,且不依赖于初始条件,尤其适合于复杂逆问题的并行求解。总之,群体智能优化算法通用性强,具有全局优化性能,因而在逆问题领域有着广阔的应用前景,可为辐射传输逆问题的研究提供新的手段和思路。

1.2 群体智能优化算法概述

大自然富有极其多样的、动态的、健壮的、复杂而迷人的现象,这为人类解决复杂问题提供了充足的灵感。随着人们对生命本质的不断了解,社会性动物(如蚁群、蜂群、鸟群、猴群)的自组织行为吸引着越来越多的学者进入人工智能领域,研究这些简单的个体如何通过协作呈现出如此复杂而奇妙的行为,同时通过计算机模拟来探索其中的可循规律,并用于指导和解决一些常规方法无法解决的传统问题及实际应用中出现的新问题,这就产生了一种新型智能计算技术,即所谓的“群智能(Swarm Intelligence)”或“群集智能”。群体是指“一组相互之间可以进行直接通信或者间接通信(通过改变局部环境)的主体,这组主体能够合作进行分布式问题求解”^[5, 6]。

群体智能是一种在自然界生物群体所表现出的智能现象启发下提出的人工智能实现模式,通过模拟自然界生物的群体行为来实现人工智能的一种方法。它是对简单生物群体的智能现象的具体模式研究,这种智能模式需要相当多数目的智能个体来实现对某类问题的求解功能。群体智能利用群体之间的通信、学习、竞争与合作等多种方式,发挥群体优势解决问题,是广义人工智能研究热点和前沿领域。群体智能的概念源于对自然界群居性生物群体的观察,其中,群居性生物包括微生物、植物、昆虫、脊椎动物等。例如,蚂蚁可以协同合作集体搬运食物,建立坚固的蚁穴;大雁可以成群结队地排成“人”字形或“一”字形进行有序的飞翔;蜜蜂可以铸造结构庞大而精致的巢穴等。这种由群体生物表现出的智能现象受到越来越多学者的关注与重视。生物学的研究成果表明,在这些群居生物中虽然每个个体的智能不高,行为简单,也不存在集中的指挥,但由这些单个个体组成的群体,似乎在某种内在规律的作用下,可表现出异常复杂而有序的群体行为,这种从群居性生物中产生出来的集体行为称为群体智能,即是指简单智能的主体通过合作表现出复杂智能行为的特征。任何启发于群居性生物群体的集体行为而设计的算法和分布式问题解决装置都可称为“群体智能”。群体的组织形式、个体智能及其交互形式各不相同,群体智能特征也随着个体智能的提升表现得更为复杂。

1.2.1 群体智能优化算法的特点和分类

基于上述群居性生物群体的集体行为启发抽象演化而成的仿生优化算法,统称为群体智能优化算法。其基本特征可归纳为如下几点。

- (1) 都是一类不确定的算法。其主要步骤都包含随机因素,从而在算法进化过程中,事件发生与否带有很大的不确定性。
- (2) 都是一类概率型的全局优化算法。非确定性算法的优点在于算法能有更多的机会求解全局最优解。
- (3) 都不依赖于优化问题本身的数学性质。在优化过程中都不依赖于优化问题本身的严格数学性质(如连续性、可导性)以及目标函数和约束条件的精确描述。

(4) 都是邻域搜索算法。在局部搜索优化算法的基础上,增加了启发和诱导机制,使算法能有效地跳出局部极值并具有全局寻优能力。

(5) 都具有本质并行性。能够设计成多处理机系统,大大提高算法的执行效率。其表现在两个方面:一是智能计算是内在并行的,即仿生优化算法本身非常适合大规模并行;二是智能计算是内含并行的,这使得智能计算能以较少的计算量获得较大的收益。

(6) 算法都具有灵活性、通用性和突现性的特点。可以按照一定的模式方便地与实际问题相结合,总目标的完成是在多个智能个体行为的运动过程中突现出来的。

(7) 都具有自组织性和进化性。在复杂且不确定的时变环境中,通过自身学习不断提高算法中个体的适应性。

(8) 具有稳健性。群体智能优化算法的稳健性是指在不同条件和环境下算法的适用性和有效性。由于智能优化算法不依赖于优化问题本身的严格数学性质和求解问题本身的结构特征,因此利用智能优化算法求解不同问题时,只需要设计相应的目标评价函数,而基本上无须修改算法的其他部分。

所有群体智能优化算法的结构形式都是相似的。首先,通过初始化产生问题可能解的一个子集,然后在该问题的解空间内,对这个子集施加某种算子操作,从而产生一个新的子集,重复对新子集进行某种算子操作,直到该子集包含最优解或近似最优解^[7]。区分群体智能优化算法之间的不同,主要在于选择施加何种算子操作,即各个算法特有的更新规则,因此群体智能优化算法可以统一到一个框架模式下,如图 1.1 所示。

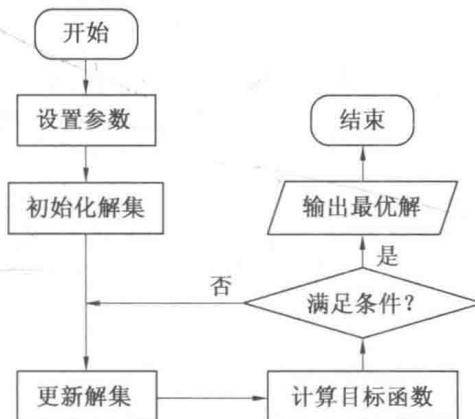


图 1.1 群体智能优化算法统一框架

常见的群体智能优化算法主要包括:蚁群优化算法(Ant Colony Algorithm, ACO)^[8]、微粒群算法(Particle Swarm Optimization, PSO)^[9]、鱼群算法(Artificial Fish Swarm Algorithm, AFSA)^[10]、蛙跳算法(Shuffled Frog Leaping Algorithm, SFLA)^[11]、蜂群算法(Artificial Bee Colony, ABC)^[12]、萤火虫算法(Glowworm Swarm Optimization, GSO)^[13]、猴群算法(Monkey Algorithm, MA)^[14]、蝙蝠算法(Bat Algorithm, BA)^[15]、果蝇算法(Fruit Fly Optimization Algorithm, FFOA)^[16]、布谷鸟搜索算法(Cuckoo Search, CS)^[17]、和声搜索优化算法(Harmony Search Optimizer, HSO)^[18]、细菌觅食优化算法(Bacterial Foraging Optimization Algorithm, BFOA)^[19]、人工免疫系统算法(Artificial Immune System Algorithm, AISA)^[20]和社会情感优化算法(Social Emotional Optimization, SEO)^[21]等,具体分类如图 1.2 所示。这些算法自诞生以来,受到学术界和工程界的广泛关注,当前已经在众多领域得到了成功和有效的应用。

这些领域包括移动机器人路径规划、车间作业调度、电力系统的负荷分配以及最优潮流计算、模式分类、专家系统设计等^[22]。虽然这些启发式群体智能算法的理论基础还有待完备,但是由于其学术思想来自于人类长期对物理、生物、社会等现象仔细的观察和实践以及人类对这些自然规律的深刻理解,是人类逐步向大自然学习、模仿自然现象的运行机制而得到的智慧结晶,因此其科学性和发展潜力是不言而喻的。

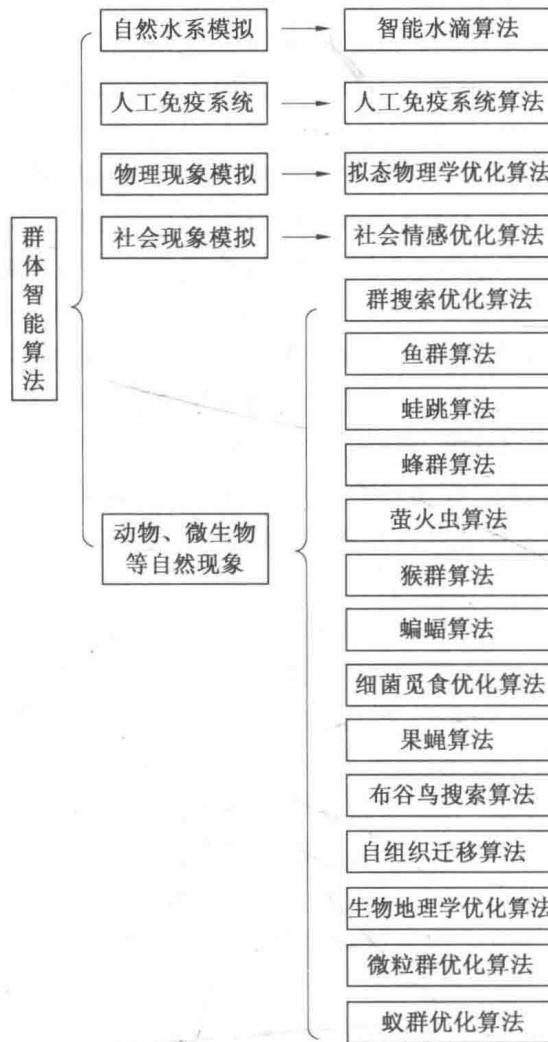


图 1.2 群体智能算法的分类

群体智能算法仅涉及各种基本的数学运算,对计算机性能要求不高,是一种简单且易于实现的算法。该类算法基于概率搜索,只需目标函数的输出值,并不需要相关的梯度信息,这也是与基于梯度求解的优化算法不同的地方。虽然概率搜索算法通常采用较多的评价函数,但与梯度方法及传统的优化算法相比,具有分布式、自组织性、协作性、鲁棒性和实现简单等特点,在没有全局信息的情况下,为寻找复杂问题最优解提供了快速可靠的求解方法,为人工智能、逆问题、认知科学等领域基础理论问题的研究开辟了新的途径。因此,无论从理论研究还是应用研究的角度出发,群体智能理论及其应用研究都具有重要的学术意义和

现实价值,也越来越受到国际智能计算等相关研究领域学者的关注,逐渐成为一个新的重要的研究方向。

1.2.2 常见群体智能优化算法简介

根据群居性昆虫和动物的习性,研究人员设计了不同的搜索路径更新规则,提出了不同的群体智能优化算法,本小节将简略介绍其中常见的群体智能算法。值得一提的是,微粒群优化算法和蚁群算法是目前群体智能研究领域的两种主要算法,前者是对鸟群觅食过程的模拟,而后者主要是对蚂蚁群落食物采集过程的模拟。该两种算法作为群体智能优化算法的典范将在本书的后续章节里做单独介绍。另外,有关智能水滴算法^[23]、人工免疫系统算法^[24],人工蜂群算法^[25]、布谷鸟算法^[26]等的研究,请参阅相关参考文献,这里不再赘述。

1. 群搜索优化算法

群搜索优化算法(Group Search Optimizer, GSO)是基于动物在觅食过程中对食物的扫描机制和PS模型(Producer–Scrounger Model)设计搜寻策略^[27]。在GSO算法中,一个群体由三部分组成,即最佳个体(Producer)、追随者(Scrounger)和随机游荡者(Ranger),其中最佳个体和追随者采取PS模型中的策略,随机游荡者则采取一个为最佳个体,其他成员均为追随者和游荡者的策略。追随者也采用了一个最为简单的追随策略:在每次搜索过程中,所有追随者只简单地去分享最佳个体的搜索成果,同时,假定整个种群中的每个成员在生物特性上没有差别,因此它们之间的角色可以相互转换。

在GSO算法中,第 k 次搜寻最优个体的行为 X_p 表现如下:在三维空间中,使用最大搜索角度 $\theta_{\max} \in \mathbb{R}^{n-1}$ 和最大搜索距离 $l_{\max} \in \mathbb{R}^1$ 来度量一个扫描区域,如图1.3所示。

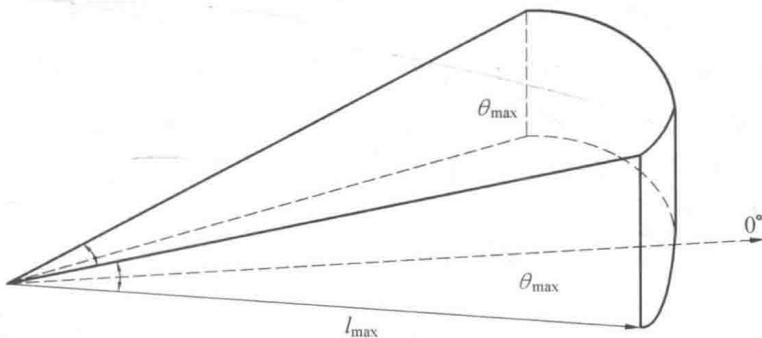


图 1.3 三维空间中的视觉扫描

(1) 最优个体先扫描 0° ,然后再随机扫描区域,并按照下列方式采样:一点在 0° ,一点在 0° 右端,一点在 0° 左端。其具体公式为

$$\begin{cases} X_z = X_p^k + r_1 \cdot l_{\max} \cdot D_p^k(\phi^k) \\ X_r = X_p^k + r_1 \cdot l_{\max} \cdot D_p^k\left(\phi^k + \frac{r_2 \theta_{\max}}{2}\right) \\ X_l = X_p^k + r_1 \cdot l_{\max} \cdot D_p^k\left(\phi^k - \frac{r_2 \theta_{\max}}{2}\right) \end{cases} \quad (1.1)$$

式中, r_1 为均值为0、方差为1的正态分布随机数; r_2 为 $[0, 1]$ 之间均匀分布的随机数。

(2) 如果最优个体找到比当前位置更优的位置,它就移动到那里;否则,就待在原来的

位置,但将移动的搜索角度为

$$\psi^{k+1} = \psi^k + r_2 \alpha_{\max} \quad (1.2)$$

式中, α_{\max} 为设置的最大转向角度。

(3) 如果最佳个体经过 a 次搜索都没有找到比当前位置更优的位置, 则它将返回原来的角度, 即

$$\psi^{k+a} = \psi^k \quad (1.3)$$

式中, a 为一个固定值。而大量追逐者(80%)在搜索空间中不断寻找机会来分享最佳个体寻找的食物, 即

$$X_i^{k+1} = X_i^k + r_3 (X_p^k - X_i^k) \quad (1.4)$$

式中, r_3 为 $[0, 1]$ 之间均匀分布的随机数。

(4) 剩余的被种群驱逐出的个体(20%)离开当前位置。在自然界中, 生物个体的能力往往存在一定差异, 一些能力较弱的个体常常被抛弃, 这些个体往往在环境中随机游荡, 找寻食物和新的居住地。在所选空间中, 对于随机分布的食物源, 采用随机游荡策略寻找食物被认为是最为有效的策略。GSO 算法中随机游荡者采取如下策略: 当第 k 次寻找时, 它随机产生一个角度, 即

$$\psi_i^{k+1} = \psi_i^k + r_2 \alpha_{\max} \quad (1.5)$$

式中, α_{\max} 为可以转动的最大角度。它会随机选择一个距离, 即

$$l_i = \alpha \cdot r_1 l_{\max} \quad (1.6)$$

然后, 它就朝着这个方向移动, 即

$$X_i^{k+1} = l_i D_i^k (\phi^{k+1}) \quad (1.7)$$

最终, 通过不断地群搜索觅食, 有助于获取全局极值, 从而达到寻优的目的。

2. 鱼群算法

鱼群算法是由浙江大学的李晓磊在 2001 年的过程系统工程年会中首次提出的一种仿生型优化算法^[10], 该算法模仿自然界中鱼群的觅食活动, 从鱼群的活动中提取出四种典型的行为, 即聚群行为、尾随行为、觅食行为和随机行为。该算法具有良好的全局搜索能力, 并具有对初值、参数选择不敏感以及鲁棒性强、简单、易实现等优点。该算法的具体操作步骤描述如下。

假设在一个 n 维的目标搜索空间中, 有 N 条组成一个群体的人工鱼, 每条人工鱼的状态可表示为向量 $X_i = (x_1, x_2, \dots, x_n)$, 其中, x_i 为欲寻优的变量; 人工鱼当前所在位置的食物浓度表示为 $F(X_i)$, Visual 表示人工鱼的感知范围, Step 表示人工鱼最大移动步长, N_i 为人工鱼每次觅食的最多尝试次数。

首先设置每条鱼的感知范围 Visual、最大移动步长 Step、最多尝试次数 N_i 和拥挤度因子 δ , 然后初始化鱼群的位置 X_i 和其对应的适应度值 $F(X_i)$, 第 i 条鱼判断感知范围内的伙伴个数 N_i , 若伙伴个数 $N_i > 0$, 则计算出伙伴的中心位置 X_c 及其对应的适应度值 $F(X_c)$, 并且找出伙伴中具有最大适应度值 F_{\max} 的鱼所对应的位置 X_{\max} , 分别执行“聚群”操作和“尾随”操作, 若操作失败, 则执行“觅食”操作; 若操作成功, 则根据两种操作后的结果选择结果更优的操作。若伙伴个数 $N_i = 0$, 则执行“觅食”操作; 若操作失败, 则执行“随机”操作。

“聚群”指每条鱼在游动过程中尽量向邻近伙伴的中心移动并避免过分拥挤的一种寻

优行为。该操作的具体实现为:判断中心位置 X_c 的拥挤度 $F(X_c)/N_i$ 是否大于拥挤度因子 δ ,若 $F(X_c)/N_i < \delta$,则执行“觅食”操作;若 $F(X_c)/N_i \geq \delta$,则按照下式更新当前位置:

$$X_i = X_i + \text{rand}() \cdot \text{Step} \cdot \frac{X_c - X_i}{\|X_c - X_i\|} \quad (1.8)$$

式中, $\text{rand}()$ 为 $[0,1]$ 区间内服从均匀分布的随机数。

“尾随”是指鱼向其可视范围内的最优方向移动的一种行为。该操作的具体实现为:判断中心位置 X_{\max} 的拥挤度 F_{\max}/N_i 是否大于拥挤度因子 δ ,若 $F_{\max}/N_i < \delta$,则执行“觅食”操作;若 $F_{\max}/N_i \geq \delta$,则按照下式更新当前位置:

$$X_i = X_i + \text{rand}() \cdot \text{Step} \cdot \frac{X_{\max} - X_i}{\|X_{\max} - X_i\|} \quad (1.9)$$

“觅食”指鱼循着食物多的方向游动的一种行为。该操作的具体实现为:在感知范围内随机选择一个伙伴,如果不存在伙伴,则直接执行“随机”操作;若存在伙伴,则判断伙伴 j 的适应度值 $F(X_j)$ 是否小于自己的适应度值 $F(X_i)$ 。如果 $F(X_j) < F(X_i)$,则在感知范围内重新找另一个伙伴 k ;如果 N_i 次尝试后均找不到比自己适应度值大的伙伴,则执行“随机”操作;如果找到,则按照下式向伙伴的位置 X_k 前进一步:

$$X_i = X_i + \text{rand}() \cdot \text{Step} \cdot \frac{X_k - X_i}{\|X_k - X_i\|} \quad (1.10)$$

“随机”是指人工鱼会在其视野内随机地移动,当发现食物时,会向食物逐渐增多的方向快速移去。该操作按照下式具体实现:

$$X_i = X_i + \text{rand}() \cdot \text{Step} \cdot e \quad (1.11)$$

式中, e 为搜索空间内的一个随机方向的单位向量。

根据所要解决的问题性质,每条人工鱼对当前所处的环境进行评价,从而选择一种合适的行为来执行。例如,对于求最大值问题,最简单的方法是先模拟执行聚集、尾随等行为,然后评价行动后的值,选择其中的最大值来实际执行,默认的行为方式为“觅食”行为。最终,大量人工鱼会聚集在几个局部极值的周围,这有助于获取全局极值域,而适应度值较优的极值区域周围一般会聚集大量的人工鱼,这有助于获取全局极值,从而达到寻优的目的。

3. 蛙跳算法

蛙跳算法是由美国学者 Eusuff 和 Lansey 于 2003 年模仿青蛙觅食的行为提出的^[28],即生活在湿地中的青蛙,在不同的石头之间跳跃寻找食物较多的地方。该算法采用局部深度搜索和全局信息交换的平衡策略,具有控制参数少、易于实现、概念简单、全局寻优能力强和计算速度快等优点^[29]。算法的具体操作步骤描述如下。

首先设置簇群个数 M 、每个簇群内青蛙的数量 N 以及每次跳跃的最大步长 S_{\max} ,初始化青蛙的位置 X_i 及其对应的适应度值 $F(X_i)$,将青蛙按照适应度值从大到小的顺序依次分配给各个簇群,记录当前蛙群的最优位置 X_g 、每个簇群的最优位置 $X_{b,j}$ 、最差位置 $X_{w,j}$ 以及它们所对应的适应度值 $F(X_g)$ 、 $F(X_{b,j})$ 和 $F(X_{w,j})$,将每个簇群中的最差位置通过下式产生一个新位置 Y :

$$Y = X_{w,j} + V \quad (1.12)$$

$$V = \begin{cases} \text{rand}() \cdot (X_{b,j} - X_{w,j}), & \|X_{b,j} - X_{w,j}\| < S_{\max} \\ S_{\max} \cdot \text{sgn}(X_{b,j} - X_{w,j}), & \|X_{b,j} - X_{w,j}\| \geq S_{\max} \end{cases} \quad (1.13)$$

式中, $\text{sgn}(\cdot)$ 表示符号函数。

若新位置 \mathbf{Y} 所对应的适应度值 $F(\mathbf{Y}) > F(\mathbf{X}_{w,j})$, 则用新位置 \mathbf{Y} 替换原来的最差位置 $\mathbf{X}_{w,j}$; 若 $F(\mathbf{Y}) \leq F(\mathbf{X}_{w,j})$, 则按照式(1.12)来进行更新, 其中 \mathbf{V} 可表示为

$$\mathbf{V} = \begin{cases} \text{rand}(\cdot) \cdot (\mathbf{X}_{g,j} - \mathbf{X}_{w,j}), \|\mathbf{X}_{g,j} - \mathbf{X}_{w,j}\| < S_{\max} \\ S_{\max} \cdot \text{sgn}(\mathbf{X}_{g,j} - \mathbf{X}_{w,j}), \|\mathbf{X}_{g,j} - \mathbf{X}_{w,j}\| \geq S_{\max} \end{cases} \quad (1.14)$$

若新位置 \mathbf{Y} 所对应的适应度值 $F(\mathbf{Y}) > F(\mathbf{X}_{w,j})$, 则用新位置 \mathbf{Y} 替换原来的最差位置 $\mathbf{X}_{w,j}$; 若 $F(\mathbf{Y}) \leq F(\mathbf{X}_{w,j})$, 则在搜索范围内随机产生一个新位置替换原来的最差位置 $\mathbf{X}_{w,j}$, 然后按照适应度值的大小重新排序, 并重新分配簇群, 重复以上步骤直至满足结束条件。

4. 蜂群算法

蜂群算法是由 Karaboga^[12] 在 2005 年模仿蜜蜂采蜜行为而提出的一种优化方法, 通过各工蜂个体的局部寻优行为, 最终在群体中使全局最优值凸显出来, 具有较快的收敛速度。该算法将蜂群按照分工不同分成“引领蜂”“跟随蜂”和“侦察蜂”三类, 其中“引领蜂”在食物源邻域内进行局部搜索, 并用舞蹈告知所有“跟随蜂”食物源的信息, “跟随蜂”根据“引领蜂”提供的信息选择食物源, “侦察蜂”则处理搜索停滞的情况。三种蜜蜂通过分工合作实现了智能寻优, “引领蜂”和“跟随蜂”负责执行开采过程, “侦察蜂”则执行探索过程, 因此蜂群算法结合全局搜索和局部搜索的方法使蜜蜂在食物源的探索和开发两个方面达到了较好的平衡。在蜂群算法中, 蜜蜂对食物源的搜索主要分为三步: ①“引领蜂”发现食物源并记录下花蜜的数量; ②“跟随蜂”依据“引领蜂”所提供的花蜜信息, 确定到哪个食物源采蜜; ③当某个食物源被放弃时, 则生成“侦察蜂”, 寻找新的食物源。蜂群算法在求解优化问题时, 食物源的位置被抽象成解空间中的点, 蜜蜂采蜜(食物源)的过程也就是搜索最优解的过程, 该算法的具体操作步骤描述如下。

首先设置“引领蜂”的个数 SN 、“跟随蜂”的个数 M 、最大停滞次数 $limit$, 然后初始化“引领蜂”的位置 \mathbf{X}_i , 并计算出食物源的大小 $F(\mathbf{X}_i)$, 随机选择一个与之不同的“引领蜂”的位置 \mathbf{X}_j , “引领蜂”根据下式在 \mathbf{X}_i 的邻域内产生一个新位置:

$$\mathbf{Y} = \mathbf{X}_i + \text{rand}(\cdot) \cdot (\mathbf{X}_i - \mathbf{X}_j) \quad (1.15)$$

式中, $\text{rand}(\cdot)$ 表示 $[-1, 1]$ 区间内服从均匀分布的随机数。

计算新位置 \mathbf{Y} 所对应的食物源大小 $F(\mathbf{Y})$, 若 $F(\mathbf{Y}) > F(\mathbf{X}_i)$, 则用 \mathbf{Y} 替换“引领蜂”的当前位置 \mathbf{X}_i ; 若 $F(\mathbf{Y}) \leq F(\mathbf{X}_i)$, 则“引领蜂”保持当前位置 \mathbf{X}_i 不变。然后“跟随蜂”根据“引领蜂”提供的食物源信息, 按照下式计算跟随那个“引领蜂”的概率:

$$P_i = F(\mathbf{X}_i) / \sum_n^{SN} F(\mathbf{X}_n) \quad (1.16)$$

当“跟随蜂”根据概率选择好“引领蜂”后, 在“引领蜂”所在位置上按照公式(1.15)在其邻域内进行一次局部搜索, 计算相应的食物源大小, 当所有 M 只“跟随蜂”完成局部搜索后, 每只“引领蜂”根据在其位置上搜索的“跟随蜂”发现的食物源大小, 选择一个发现最大食物源的“跟随蜂”所对应的位置, 并将其替换为该“引领蜂”的当前位置, 完成一次迭代, 重复以上步骤直至满足收敛条件, 当“引领蜂”在 $limit$ 次迭代中位置均没有更新时, “侦察蜂”会在搜索空间内按照下式随机产生一个位置替换给该“引领蜂”:

$$\mathbf{X}_i = \mathbf{X}_{\min} + \text{rand}(\cdot) \cdot (\mathbf{X}_{\max} - \mathbf{X}_{\min}) \quad (1.17)$$