

群智能理论及应用

彭喜元¹, 彭 宇¹, 戴毓丰²

(1. 哈尔滨工业大学 339 #, 黑龙江哈尔滨 150001; 2. 黑龙江省移动通信公司, 黑龙江哈尔滨 150090)

摘 要: 作为一种新兴演化计算技术, 群智能已成为新的研究热点, 它与人工生命, 特别是进化策略和遗传算法有着极为特殊的联系, 已完成的理论和应用研究证明群智能方法是一种能够有效解决大多数全局优化问题的新方法。更为重要的是, 群智能的潜在并行性和分布式特点为处理大量的以数据库形式存在的数据提供了技术保证。本文介绍了群智能理论的产生和发展过程, 并着力阐述了两种典型算法: 微粒群算法和蚁群算法的基本原理以及研究现状。

关键词: 群智能; 微粒群算法; 蚁群算法; 优化算法

中图分类号: TP18 **文献标识码:** A **文章编号:** 0372-2112 (2003) 12A-1982-07

Swarm Intelligence Theory and Applications

PENG Xi-yuan¹, PENG Yu¹, DAI Yu-feng²

(1. No. 399 #, Harbin Institute of Technology, Harbin, Heilongjiang 150001, China;

2. Heilongjiang Mobile Communication Company, Harbin, Heilongjiang 150090, China)

Abstract: As a novel evolutionary computation technology, swarm intelligence is now becoming a new research hotspot. It has special relationships with artificial life and evolution strategies. All researches of theories and applications related to swarm intelligence proves that it is a kind of effective method to solve most global optimal problems. It is more important that its potential parallel and distributed features provide technical assurance to process data in large database. A survey of origin and development of swarm intelligence are presented. Furthermore, the basic principles and contemporary research status of two typical algorithms: Particle Swarm Optimization and Ant Colony Optimization, are discussed.

Key words: swarm intelligence; particle swarm optimization; ant colony optimization; optimization algorithm

1 引言

与各种各样的自适应随机搜索算法相比, 演化计算技术创造了被称为“种群”的潜在解, 并通过种群间个体的协作与竞争来实现对问题最优解的搜寻^[1], 这类方法往往能够比传统优化方法更快地发现复杂优化问题的最优解。群智能 (Swarm intelligence) 作为一种新兴的演化计算技术已成为越来越多研究者的关注焦点, 它与人工生命, 特别是进化策略以及遗传算法有着极为特殊的联系。群智能中的群体指的是“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 (Agent), 这组主体能够合作进行分布式的问题求解”, 而群智能则是指“无智能的主体通过合作表现出智能行为的特性”。群智能在没有集中控制且不提供全局模型的前提下, 为寻找复杂的分布式问题求解方案提供了基础^[2]。

目前, 群智能理论研究领域有两种主要的算法: 蚁群算法 (Ant colony optimization, ACO) 和微粒群算法 (Particle swarm optimization, PSO)。前者是对蚂蚁群落食物采集过程的模拟, 已成功应用于许多离散优化问题。微粒群算法也是起源于对简单社会系统的模拟, 最初是模拟鸟群觅食的过程, 但后来发现它是一种很好的优化工具。事实上, 群智能方法能够被用于解决大多数优化问题或者能够转化为优化求解的问题。现在其应

用领域已扩展到多目标优化、数据分类、数据聚类、模式识别、电信 QoS 管理、生物系统建模、流程规划、信号处理、机器人控制、决策支持以及仿真和系统辨识等方面^[3], 群智能理论和方法为解决这类应用问题提供了新的途径。

与大多数基于梯度应用优化算法不同, 群智能依靠的是概率搜索算法。虽然概率搜索算法通常要采用较多评价函数, 但与梯度方法及传统的演化算法相比, 其优点还是显著的^[4]: (1) 无集中控制约束, 不会因个别个体的故障影响整个问题的求解, 确保了系统具备更强的鲁棒性; (2) 以非直接的信息交流方式确保了系统的扩展性; (3) 并行分布式算法模型, 可充分利用多处理器; (4) 对问题定义的连续性无特殊要求; (5) 算法实现简单。

群智能方法易于实现, 算法中仅涉及各种基本数学操作, 其数据处理过程对 CPU 和内存的要求也不高。且这种方法只需目标函数的输出值, 而无需其梯度信息。已完成的群智能理论和应用方法研究证明群智能方法是一种能够有效解决大多数全局优化问题的新方法。更重要是, 群智能潜在的并行性和分布式特点为处理大量的以数据库形式存在的数据提供了技术保证。无论是从理论研究还是应用研究的角度分析, 群智能理论及应用研究都是具有重要学术意义和现实价值的。

2 群智能基本原理

群智能理论的基本原理是以生物社会系统(Biology social system)为依托的,也就是由简单个体组成的群落与环境以及个体之间的互动行为.这种生物社会性的模拟系统利用局部信息产生难以估量的群体行为.作为基于迭代的优化方法,群智能理论是一种全新的进化计算方法.

2.1 PSO 原理

微粒群算法和其他演化算法相似,也是根据对环境的适应度将群体中的个体移动到好的区域,因此有人认为它属于演化算法的一种.不同之处在于它不象其它演化算法一样对个体使用演化算子,而是将每个个体看作是 d 维搜索空间中的一个没有体积没有质量的微粒,在搜索空间中以一定的速度飞行,并根据对个体和集体的飞行经验的综合分析来动态调整这个速度.

设群体中第 i 个微粒为 $X_i(x_{i1}, x_{i2}, \dots, x_{id})$, 它经历过的位置为 $P_i(p_{i1}, p_{i2}, \dots, p_{id})$, 其中最佳位置为 $pbest$. 当前组成群体的所有微粒经历过的最佳位置为 $pgbest$. 微粒 i 的速度用 $V_i(v_{i1}, v_{i2}, \dots, v_{id})$ 表示. 对每一次迭代,微粒 i 在 d 维(1~ d) 空间的运动遵循如下方程进行:

$$v_{id}^{k+1} = v_{id}^k + c_1 * \text{Rand}() * (p_{id}^k - x_{id}^k) + c_2 * \text{Rand}() * (pgbest^k - x_{id}^k) \quad (1)$$

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

其中 c_1 为惯性权(Inertia weight), 它使微粒保持运动的惯性,使其有能力探索新的区域. c_1 和 c_2 为加速常数(Acceleration constants), 它们使每个微粒向 $pbest$ 和 $pgbest$ 位置加速运动. $\text{Rand}()$ 为 $[0, 1]$ 范围内变化的随机数. 此外,微粒的速度 V_i 被一最大速度 V_{\max} 所限制. 如果当前对微粒的加速将导致它在某维的速度 V_{id} 超过该维的最大速度 $V_{\max d}$, 则该维的速度被限制为该维的最大速度 $V_{\max d}$. 它决定了微粒在解空间的搜索精度. 如果 V_{\max} 太高,微粒可能会飞过最优解,如果 V_{\max} 太小,微粒陷入局部搜索空间而无法进行全局搜索.

式(1)中的第一部分为微粒先前的速度乘一个权值进行加速,表示微粒对当前自身运动状态的信任,依据自身的速度进行惯性运动;第二部分为“认知”部分,表示微粒本身的思考,即一个得到加强的随机行为在将来的出现几率增大. 这里的行为即“认知”,并假设获得正确的知识是得到加强的,从而实现一个增强学习过程.

第三部分为“社会”部分,表示微粒间的信息共享与相互合作.“社会”部分可以通过 Bandura 的代理概念来理解^[5]. 根据该理论,当观察者观察到某一行为被加强时,将增加它实行该行为的几率,即微粒本身的认知将被其它微粒所模仿.

微粒群算法的这些心理学假设是无争议的:在寻求一致认知过程中,个体往往记住它们的信念,同时考虑同事的信念. 当个体察觉同事信念较好的时候,它将进行适应性地调整.

2.2 ACO 原理

作为与遗传算法同属一类的通用型随机优化方法,蚁群算法不需要任何先验知识,最初只是随机地选择搜索路径,随着对解空间的“了解”,搜索变得有规律,并逐渐逼近直至最终

达到全局最优解. 蚁群算法对搜索空间的“了解”机制主要包括三个方面^[6]:

(1) 蚂蚁的记忆. 一只蚂蚁搜索过的路径在下次搜索时就不会再被选择,由此在蚁群算法中建立 tabu(禁忌)列表来进行模拟;

(2) 蚂蚁利用信息素(pheromone)进行相互通信. 蚂蚁在所选择的路径上会释放一种叫做信息素的物质,当同伴进行路径选择时,会根据路径上的信息素进行选择,这样信息素就成为蚂蚁之间进行通讯的媒介.

(3) 蚂蚁的集群活动. 通过一只蚂蚁的运动很难到达食物源,但整个蚁群进行搜索就完全不同. 当某些路径上通过的蚂蚁越来越多时,在路径上留下的信息素数量也越来越多,导致信息素强度增大,蚂蚁选择该路径的概率随之增加,从而进一步增加该路径的信息素强度,而某些路径上通过的蚂蚁较少时,路径上的信息素就会随时间的推移而蒸发. 因此,模拟这种现象即可利用群体智能建立路径选择机制,使蚁群算法的搜索向最优解推进.

蚁群算法所利用的搜索机制呈现出一种自催化或正反馈的特征,因此,可将蚁群算法模型理解成增强型学习系统. 图 1 说明了蚂蚁群体的路径搜索原理




图 1 蚂蚁觅食过程演示

和机制. 假定障碍物的周围有两条道路可从蚁巢到达食物,即(蚁巢-ABD-食物)和(蚁巢-ACD-食物),路径的长度分别为 4 和 6. 每只蚂蚁在单位时间内移动一个单位长的距离,并在走过的路径上遗留一个单位的信息素. 开始时所有道路上未留有任何信息素,假设在 $t=0$ 时刻,有 20 只蚂蚁从蚁巢出发移动到 A. 它们以相同概率选择左侧或右侧的路径,因此有 10 只蚂蚁走左侧,10 只走右侧. 在 $t=4$ 时刻,第一批找到食物的蚂蚁将返回,在 $t=5$ 时刻,两批蚂蚁将在 D 点相遇,此时 BD 上的信息素数量与 CD 上的相同,因为各有 10 只蚂蚁选择了相应的道路. 从而有 5 只返回的蚂蚁将选择 DB 而另 5 只选择 DC. 在 $t=9$ 时刻,前 5 只蚂蚁又返回 A 并且再次进行往左还是往右的选择. 这时,AB 上的信息素数量是 20 而 AC 上是 15,因此将有较多的蚂蚁选择往左,从而增加了该路径的信息素数量. 随着这种过程的不断进行,两条路径上的信息素数量的差距将越来越大,直到绝大多数蚂蚁都选择了最短的路径,正是由于一条路要比另一条道路短,因此,在相同的时间区间内,短的路线会有更多的机会被选中.

基本的蚁群算法模型由下面三个公式描述:

$$P_{ij}^k = \frac{\tau_{ij}}{\sum_{j \in A} \tau_{ij}} \quad (3)$$

$$\tau_{ij}(n+1) = \rho \tau_{ij}(n) + \sum_{k=1}^m \frac{Q}{L_k} \quad (4)$$

$$\tau_{ij}^k = \frac{Q}{L_k} \quad \text{如果第 } k \text{ 个蚂蚁经过了由 } i \text{ 到 } j \text{ 的路径} \quad (5)$$

式(3)、式(4)和式(5)中: m 为蚂蚁个数; n 为迭代次数; i 为蚂蚁所在位置; j 为蚂蚁可以到达的位置; A 为蚂蚁可以到达位

置的集合; η_{ij} 为启发性信息, 这里为由 i 到 j 的路径的能见度, 即 $1/d_{ij}$; L_k 为目标函数, 这里为两点间欧式距离; η_{ij} 由 i 到 j 的路径的信息素强度; τ_{ij}^k 为蚂蚁 k 由 i 到 j 的路径上留下的信息素数量; ω 为路径权; ω_0 为启发性信息的权; ρ 为路径上信息素数量的蒸发系数; Q 为信息素质量系数; P_{ij}^k 为蚂蚁 k 从位置 i 移动到位置 j 的转移概率。

目前, 除了业已得到公认的遗传算法、模拟退火算法、禁忌搜索算法等计算智能算法外, 新加入这个行列的蚁群算法已开始崭露头角, 为困难的组合优化问题提供了新颖且有竞争力的求解方法。

3 基本理论研究现状

20 世纪 50 年代中期出现了仿生学, 人们从生物进化机理中受到启发, 提出许多用以解决复杂优化问题的新方法, 如遗传算法、进化规划、进化策略等。这些以生物特性为基础演化算法的发展, 及对生物群落行为的发现引导研究人员进一步开展了对生物社会性的研究, 从而出现了基于群智能理论的蚁群算法^[6] (1991, 意大利 M Dorigo, V Maniezzo, A Colomi 等) 和微粒群算法 (1995 James Kenney 和 Russell Eberhart)。虽然二者的研究基础和基本思想是一致的, 但是它们的产生和发展却是相对独立的。以下将对二者的研究现状分别加以介绍。

3.1 微粒群算法研究现状

微粒群算法最早是由美国的 James Kenney 和 Russell Eberhart 在 1995 年提出的^[7]。两位研究者提出的 PSO 基本模型同遗传算法类似, 是一种基于迭代的优化工具。但是在算法实现过程中没有交叉变异操作, 而是以粒子对解空间中最优粒子的追随进行解空间的搜索。同当时的遗传算法相比, PSO 的优点在于流程简单易实现, 算法参数简洁, 无需复杂的调整。因此从出现至今, PSO 被迅速地应用于函数优化、神经网络训练、模糊系统控制、数据聚类以及原有的一些遗传算法应用领域, 作为一种新颖的优化搜索算法, 从其出现至今的八年时间里, 研究者们的绝大部分精力主要集中于对其算法结构和性能的改善方面的研究, 主要包括: 参数设置、粒子多样性、种群结构和算法融合。

PSO 算法与其它计算智能方法的一个显著区别就是所需调整的参数很少, 但是这些关键参数的设置对算法的精度和效率却存在显著影响。文献[8]中针对算法中的种群规模、迭代次数和粒子速度的选择方法进行了详细分析, 利用统计实验方法对约束优化问题的求解论证了这三个参数对算法性能的基本影响, 并给出了具有一定通用性的三种参数选择原则。文献[9]中利用 PSO 解决多目标优化问题时, 分析了种群最优解、本地最优解、个体最优解对算法特性的影响, 并通过对惯性权值加以扰动实现其动态调整以获取更佳的优化结果。

在文献[10]中 YuShi Hui 和 Russell Eberhart 首次提出了惯性权重 的概念, 并对基本算法中的粒子速度更新公式进行了修正, 如式(1)所示, 以获得更佳的全局优化效果。

其后的研究者普遍采用这种方式作为系统粒子速度更新的基本方式, 并在大量的应用问题中充分验证了其合理性, 在这篇文献中, 作者还提出了采用了随时间递减的动态惯性权

值设置方法以提高算法的有效性和可靠性。

在惯性权值修正思想的引导下, 文献[11]提出了自适应设置惯性权值的模糊系统。系统的输入是对 PSO 性能进行评价的变量, 而系统的输出则是调整后的权值增量。该文献中以当前的群体最优解和惯性权值作为输入, 输出设定为新的惯性权值, 并采用归一化的当前最佳性能评优系数来度量 PSO 所获取的最优解的价值。

为了避免算法的过早收敛, 一些研究者提出了通过控制种群多样性提高算法总体性能的方法。Jacques Riget 和 Jakob S Vesterstrom 设计了一种以基本 PSO 为基础的, 通过多样性度量控制种群特征, 从而实现粒子间吸引和互斥平衡以避免算法收敛性早熟的方法^[12]。这种方法在原有算法粒子间位置更新的相互吸引过程之后又引入了一个排斥过程, 也就是吸引的逆过程, 如下公式所示:

$$v_{id}^{k+1} = v_{id}^k - c_1 * \text{Rand}() * (p_{id} - x_{id}^k) - c_2 * \text{Rand}() * (p_{gbest} - x_{id}^k) \quad (6)$$

这种逆过程在一定程度上抑制了吸引过程导致的系统多样性的下降。如果系统多样性下降至某个预定的指标, 则将算法切换到互斥过程以增加粒子的多样性。当互斥过程使这种多样性恢复到预定的水平时, 结束互斥操作继续基本算法运行。其中所需的多样性度量标准定义如下:

$$\text{diversity}(S) = \frac{1}{|S| * |L|} \cdot \sum_{i=1}^{|S|} \sqrt{\sum_{j=1}^N (p_{ij} - p_j)^2} \quad (7)$$

其中, $|S|$ 是种群的规模大小, $|L|$ 是搜索空间的最大的对角线长度, N 是问题的维数, p_{ij} 是第 i 个粒子的第 j 个值, p_j 是所有粒子第 j 个值的平均值。

Morten Lovbjerg 和 Thienno Krink 提出了另一种改善粒子多样性的途径——自组织临界点控制 (Self-Organized Criticality, SOC) 方法^[13]。SOC 粒子与其本粒子的唯一区别就是每个粒子增加了当前临界值属性。每个粒子的临界值 C 初始化为零, 如果两个粒子间的距离小于预定的距离阈值则增加彼此的临界值。当某个粒子的临界值超过系统全局的极限值时, 则需重新分配其在解空间中的位置, 如此便使粒子搜索的多样性得到了有效的增强。

同样是针对算法搜索多样性的问题, Thienno Krink 等提出了一种粒子空间扩展的方法 (SPEPSO) 来解决粒子间的冲突和聚集问题, 并增强粒子突破局部极小值的能力^[14]。这种方法中为每个粒子附加一个最小独立半径 r , 当与其他粒子间的距离小于 r 时, 即认为二者发生“摩擦”, 则采取控制措施使之分离。SPEPSO 还提出了粒子分离方向和速度的确定问题, 并给出了三种基本策略: 随机反弹、真实物理反弹、原始轨迹反弹。另外通过反弹速度因子 (0~1 之间取值) 实现对原速度的改变以防粒子碰撞。文献[15]中 Buthainah Al-Kazzeni 等通过在问题求解过程的不同阶段设置不同的阶段性目标, 驱动粒子靠近或远离其已知的个体最优解或种群最优解, 从而达到增强粒子搜索多样性的目的。这种方法在离散和连续优化问题中都显示出了比基本 PSO 更为优越的性能, 而且其计算效率比基本 PSO 或 GA 更高。

除了上述通过粒子自身特性改善来增强算法搜索多样性

的方法外,许多研究中对于影响算法效能的各种基本条件和环境因素,如:种群拓扑结构和算法融合问题进行了分析。

James Kennedy 和 Rui Mendes 系统地分析了不同的种群拓扑结构时对 PSO 算法效能的影响,如:影响种群结构的节点连接方式、节点聚合问题、节点间最短平均距离,以及拓扑结构与具体优化问题的相关性等问题,以说明构造种群结构的基本原则。这为具体优化问题的 PSO 算法种群结构调整提供了理论基础^[16]。

为了进一步提高 PSO 的基本性能,许多研究者还尝试了将其与其它计算智能方法相融合,以突破其自身局限。在文献^[17]中提出了两种与演化算法相结合的混合型 PSO 优化器。通过在基本的 PSO 中引入繁殖和子种群的概念,增强其收敛性和寻求最优解的能力。在每轮迭代中随机选择一定的粒子作为父代,通过繁殖公式生成具有新的空间坐标和速度的子代粒子,并取代父代以保持种群规模。其实这是一种提高对解空间搜索能力和粒子多样性的数学交叉,可在一定程度上增强系统跳出局部极小的能力。

子种群的概念是在繁殖方法的基础上将整个种群划分为若干个种群,在每个种群内部按照 Kennedy 提出的星型拓扑结构进行构造。而且繁殖过程中增加了子种群间的交叉,进一步扩展了繁殖的多样性。

文献^[18]针对动态系统优化,设计了一种自适应 PSO 算法,通过增加环境检测和响应两种新的算法特征解决了 PSO 对动态系统空间变化的适应性问题。并首次提出了群体的生命周期问题——种群的随机多代初始化,为这种基于演化的算法理论开创了新的研究思想。

本文作者在研究论文中提出了一种将 PSO 与模拟退火算法相结合的 PSOSA 算法,解决了微粒群算法性能分析过程中发现的初始参数依赖性问题和算法搜索能力问题。通过模拟退火算法赋予搜索过程一种时变且最终趋于零的概率突跳性,有效地降低了陷入局部极小的概率,从而获取更佳的近似最优解。而且,模拟退火算法的串行优化结构和微粒群算法的群体并行搜索相结合,拓展了微粒群在解空间中的搜索范围,提高了其优化性能,促进了种群群体多样性的发展。

3.2 蚁群算法研究现状

90 年代 Dorigo 最早提出了蚁群优化算法——蚂蚁系统 (Ant system, AS) 并将其应用于解决计算机算法学中经典的旅行商问题 (TSP)。从蚂蚁系统开始,基本的蚁群算法得到了不断的发展和完善,并在 TSP 以及许多实际优化问题求解中进一步得到了验证^[19,20]。这些 AS 改进版本的一个共同点就是增强了蚂蚁搜索过程中对最优解的探索能力,它们之间的差异仅在于搜索控制策略方面。而且,取得了最佳结果的 ACO 是通过引入局部搜索算法实现的,这实际上是一些结合了标准局部搜索算法的混合型概率搜索算法,有利于提高蚁群各级系统在优化问题中的求解质量。

最初提出的 AS 有三种版本:Ant-density、Ant-quantity 和 Ant-cycle^[21]。在 Ant-density 和 Ant-quantity 中蚂蚁在两个位置节点间每移动一次后即更新信息素,而在 Ant-cycle 中当所有的蚂蚁都完成了自己的行程后才对信息素进行更新,而且每

个蚂蚁所释放的信息素被表达为反映相应行程质量的函数。通过与其他各种通用的启发式算法相比,在不大于 75 城市的 TSP 中,这三种基本算法的求解能力还是比较理想的,但是当问题规模扩展时,AS 的解题能力大幅度下降。因此,其后的 ACO 研究工作主要都集中于 AS 性能的改进方面。较早的一种改进方法是精英策略 (Elitist Strategy)^[22],其思想是在算法开始后即对所有已发现的最好路径给予额外的增强,并将随后与之对应的行程记为 Tgb (全局最优行程),当进行信息素更新时,对这些行程予以加权,同时将经过这些行程的蚂蚁记为“精英”,从而增大较好行程的选择机会。这种改进型算法能够以更快的速度获得更好的解。但是若选择的精英过多则算法会由于较早的收敛于局部次优解而导致搜索的过早停滞。

为了进一步克服 AS 中暴露出的问题,文献^[19,23]中提出了蚁群系统 (Ant colony system, ACS)。该系统的提出是以该文档作者较早提出的 Ant-Q 算法^[24]为基础的。Ant-Q 将蚂蚁算法和一种增强型学习算法 Q-learning 有机的结合了起来。ACS 与 AS 之间存在三方面的主要差异:首先,ACS 采用了更为大胆的行为选择规则;其次,只增强属于全局最优解的路径上的信息素,即:
$$ij(t+1) = (1 - \rho) \cdot ij(t) + \rho \cdot \frac{g_{ij}^b(t)}{L^{gb}(t)} \quad (8)$$
 其中 $\frac{g_{ij}^b(t)}{L^{gb}(t)} = 1/L^{gb}$, $0 < \rho < 1$ 是信息素挥发参数, L^{gb} 是从寻路开始到当前为止全局最优路径长度。另外,还引入了负反馈机制,每当一只蚂蚁由一个节点移动到另一个节点时,该路径上信息素都按照式 (9) 被相应的消除一部分,从而实现一种信息素的局部调整以减小已选择过的路径再次被选择的概率。

$$ij = (1 - \rho) \cdot ij + \rho \cdot 0, \quad 0 < \rho < 1 \quad (9)$$

在对 AS 进行直接完善的方法中,MAX-MIN Ant System 是一个典型代表。该算法修改了 AS 的信息素更新方式,每次迭代之后只有一只蚂蚁能够进行信息素的更新以获取更好的解。为了避免搜索停滞,路径上的信息素浓度被限制在 $[\min, \max]$ 范围内,另外,信息素的初始值被设为其取值上限,这样有助于增加算法初始阶段的搜索能力^[25]。

另一种对 AS 改进的算法是 Rank-based Version AS^[26]。与“精英策略”相似,在此算法中总是更新更好进程上的信息素,选择的标准是其行程长度 ($L^1(t)$, $L^2(t)$, ..., $L^m(t)$) 决定的排序,且每个蚂蚁放置信息素的强度通过式 (10) 中的排序加权处理确定,其中 $\frac{r_{ij}(t)}{L^r} = 1/L^r$, $\frac{g_{ij}^b(t)}{L^{gb}} = 1/L^{gb}$, w 为每次迭代后放置信息素的蚂蚁总数。

$$ij(t+1) = (1 - \rho) \cdot ij(t) + \sum_{r=1}^w (w - r) \cdot \frac{r_{ij}(t)}{L^r} + w \cdot \frac{g_{ij}^b(t)}{L^{gb}} \quad (10)$$

这种算法求解 TSP 的能力与 AS、精英策略 AS、遗传算法和模拟退火算法进行了比较。在大型 TSP 问题中 (最多包含 132 座城市),基于 AS 的算法都显示出了优于 GA 和 SA 的特性。而且在 Rank-based AS 和精英策略 AS 均优于基本 AS 的同时,前者还获得了比精英策略 AS 更好的解。

4 应用研究现状

随着群智能理论和应用算法研究的不断发展,研究者已尝试将其用于各种工程优化问题,并取得了意想不到的收

获. 多种研究表明, 群智能在离散求解空间和连续求解空间中均表现出良好的搜索效果, 并在组合优化问题中表现突出.

文献[27]利用 PSO 实现对卫星无线网络路由的自适应调整, 提高网络容量的有效利用率. 文献[28]中将 PSO 用于 PCHA(剖面波状喇叭天线)的设计优化, 并与 GA 的优化效果进行了比较, 在此基础上又研究了二者混合应用的可行性. 其中所完成的一系列实验证实 PSO 作为一种新型的优化算法具备解决复杂工程优化问题的能力. 文献[29, 30]中利用 PSO 实现了对人工神经网络权值和网络模型结构的优化, 并将研究结果应用于“自然语言词组”的分析方法设计. 文献[31]采用经 PSO 优化的神经网络实现了对人类肢体颤抖现象的分析, 并完成了对正常颤抖和帕金森氏症的诊断功能. 文献[32]中同样采用 PSO 对神经网络进行了优化, 并利用其设计了电力变压器的智能保护机制. 文献[33]利用 PSO 实现了对各种连续和离散控制变量的优化, 从而达到了控制核电机组电流稳定输出电压的目的.

蚁群优化算法并不是旅行商问题的最佳解决方法, 但是它却为解决组合优化问题提供了新思路, 并很快被应用到其他组合优化问题中. 比较典型的应用研究包括: 网络路由优化、数据挖掘以及一些经典的组合优化问题.

蚁群算法在电信路由优化中已取得了一定的应用成果^[34~37]. HP 公司和英国电信公司在 90 年代中后期都开展了这方面的研究, 设计了蚁群路由算法 (Ant colony routing, ACR). 每只蚂蚁就像蚁群优化算法中一样根据它在网络上的经验与性能, 动态更新路由表项. 如果一只蚂蚁因为经过了网络中堵塞的路由而导致了比较大的延迟, 那么就对该表项做较大的增强. 同时根据信息素挥发机制实现系统的信息更新, 从而抛弃过期的路由信息. 这样, 在当前最优路由出现拥堵现象时, ACR 算法就能迅速的搜寻另一条可替代的最优路径, 从而提高网络的均衡性、负荷量和利用率. 目前这方面的应用研究仍在升温, 因为通信网络的分布式信息结构、非稳定随机动态特性以及网络状态的异步演化与 ACO 的算法本质和特性非常相似.

基于群智能聚类算法起源于对蚁群蚁卵的分类研究. Lumer 和 Faieta 将 Deneubourg 提出将蚁巢分类模型应用于数据聚类分析^[38]. 其基本思想是将待聚类数据随机地散布到一个二维平面内, 然后将虚拟蚂蚁分布到这个空间内, 并以随机方式移动, 当一只蚂蚁遇到一个待聚类数据时即将之拾起并继续随机运动, 若运动路径附近的数据与背负的数据相似性高于设置标准则将其放置在该位置, 然后继续移动, 重复上述数据搬运过程. 按照这样的方法可实现对相似数据的聚类^[39].

吴斌等人又在简化分类模型的基础上系统地提出了一种基于群智能的聚类算法^[40, 41], 并将算法成功应用于标准机器学习数据库的聚类分析、客户关系管理 (CRM) 中的客户行为分析以及 Web 搜索文档分类应用中. 与经典的层次聚类算法和 k 均值动态聚类算法相比, 基于群智能的聚类算法具有群智能算法的共同特点, 它利用个体与个体和个体与环境的交互作用, 不必预设聚类中心的数目, 实现自组织聚类过程, 具有健壮性、可视化等特点.

文献中[42]提出了一种利用蚁群算法设计的数据分类规则提取算法. 利用蚂蚁的运动, 根据数据属性的划分通过随机搜索逐步形成相对应规则的前件. 在蚁群算法的搜索方法中定义了适合分类问题的规则构造方法、剪枝方法和信息素更新方法. 该算法采用与 C4.5 相似的熵值度量方法, 并将其与信息素更新结合起来进行以消除熵值度量的局限 (局部启发性度量) 引起的误差. 与典型的分类算法 CN2 相比, 这种方法的准确性与 CN2 相当, 而且发现的规则列表比 CN2 获得规则列表简单.

本文作者在研究过程中, 根据基本蚂蚁聚类算法结构和特性, 针对其中存在的计算效率问题, 利用层次化数据聚类分析方法中的数据凝聚操作, 对蚂蚁聚类算法基本型的效率问题进行了研究和改进, 获得了更优的求解效率和聚类质量.

另外, ACO 还在许多经典组合优化问题中获得了成功的应用, 如二次规划问题 (QAP)、机器人路径规划、作业流程规划、图着色 (Graph coloring) 等问题^[43, 44]. 可以说经过多年的发展, ACO 已成为能够有效解决实际二次规划问题的几种重要算法之一. AS 在作业流程计划 (Job shop scheduling) 问题中的首个应用实例出现在文献[45]中, 该论文说明了 AS 在此领域的应用潜力. 其后的文献[46]利用 MAX-MIN AS 解决 PAQ 取得了比较理想的效果, 并通过实验中的计算数据证明采用该方法处理 PAQ 比较早的 SA 算法更好, 且与禁忌搜索算法性能相当. 文献[47]中利用 ACO 实现了对生产流程和特料管理的综合优化, 并通过与遗传、模拟退火和禁忌搜索算法的比较证明了 ACO 的工程应用价值.

还有许多研究者将 ACO 用于武器攻击目标分配和优化问题^[48]、车辆运行路径规划^[49]、区域性无线电频率自动分配^[50]、Bayesian networks 的训练^[51]和集合覆盖等应用优化问题^[52]. Costa 和 Herz 还提出了一种 AS 在规划问题方面的扩展应用——图着色问题, 并取得了可与其他启发式算法相比的效果.

群智能理论的应用方法研究证明, 虽然相对于各种比较成熟的计算智能方法来说群智能的研究还处于初级阶段, 并存在种种有待深入研究和解决的问题, 但是可以预言群智能的研究代表了以后计算机研究发展的一个重要方向.

5 总结与展望

经过近十年的发展, 群智能理论凭借其简单的算法结构和突出的问题求解能力, 吸引了众多研究者的目光, 并取得了令人瞩目的成果. 大量的研究成果证明社会型生物, 或者说自然系统为人工智能处理系统和算法的设计提供了有益的启发. 人工群智能系统作为其中的一个重要组成部分已显示出潜在的优势: 灵活、稳定、分布式控制和自组织能力. 而且工程问题中日益复杂的信息处理需求, 尤其是动态特性突出的问题, 为群智能的应用研究提供了广阔的空间^[53].

但是, 由于其理论依据来源于对生物群落社会性的模拟, 因此其相关数学分析还比较薄弱, 这就导致了现有研究还存在以下几个主要问题:

(1) 群智能算法的数学理论基础相对薄弱, 缺乏具备普遍意义的理论性分析. 算法中涉及的各种参数设置一直没有确

切的理论依据,通常都是按照经验型方法确定,对具体问题和应用环境的依赖性比较大;

(2) 比较性研究不足,也就是说与各种成熟的优化算法之间的基本特性及性能特点的对比研究还不是十分充分,而且还缺乏用于性能评估的标准测试集;

(3) 同其它的自适应问题处理方法一样,群智能也不具备绝对的可信性.当处理突发事件时,系统的反应可能是不可测的,这在一定程度上增加了其应用风险.

将来的研究工作,应以更高层次的群智能概念为核心将蚁群算法和微粒群算法的研究工作相结合.加强算法特性的分析,进一步明确与算法原理相关的重要定义,如:单个个体的复杂性、学习能力和推理能力等.另外,还应扩展群智能与其它各种先进技术(如:神经网络、模糊逻辑、禁忌搜索和支持向量机等)的融合,以改善其自身或相应技术方法的性能.

参考文献:

- [1] K E Parsopoulos ,M N Vrahatis. Recent approaches to global optimization problems through particle swarm optimization[A]. Nature Computing[C]. Kluwer Academic Publishers ,2002. 1. 235 - 306.
- [2] 郑毅,吴斌. 由鸟群和蚂蚁想到的——基于主体的仿真和群集智能的研究[J]. 微电脑世界, 2001, 1:7 - 13.
- [3] Eberhart R C, Shi Y. Particle swarm optimization: developments, applications and resources[A]. Proc. congress on evolutionary computation [C]. IEEE service center, Piscataway, NJ, Seoul, Korea, 27 - 30 May 2001. 1. 81 - 86.
- [4] Kennedy J, Eberhart R C. Particle swarm optimization[A]. Proc. IEEE Int'l. Conf. on Neural Networks [C]. Piscataway, NJ, WA Australia: IEEE service center, 1995. IV. 1942 - 1948.
- [5] James Kennedy, Russell C Eberhart. Swarm Intelligence[M]. San Francisco: Morgan Kaufmann Publisher, 2001. 165 - 178.
- [6] M Dorigo, V Maniezzo A, Colomi Colomi A, Dorigo M, Maniezzo V. Distributed optimization by ant colonies[A]. Proc 1st European conf Artificial Life [C]. Paris, France: Elsevier, 1991. 134 - 142.
- [7] Kennedy J, Eberhart R C. Particle swarm optimization[A]. Proceedings of the 1995 IEEE International Conference on Neural Networks [C]. Piscataway, NJ, Perth, Australia: IEEE service center, 1995. 1942 - 1948.
- [8] El-Gallad A, El-Hawary M, Sallam A, Kalas A. Enhancing the particle swarm optimizer via proper parameters selection[A]. IEEE CCECE02 Proceedings [C]. Piscataway, NJ, Canadian: IEEE service center, 2002. 2. 792 - 797.
- [9] J E Fieldsend, S Singh. On the selection of gbest, lbest, and pbest individuals, the use of turbulence and the impact of inertia in multi-objective PSO [DB/OL]. <http://citeseer.nj.nec.com/fieldsend02selection.html>.
- [10] Shi Y, Eberhart R C. A modified particle swarm optimizer[A]. Proceedings of the IEEE International Conference on Evolutionary Computation [C]. Piscataway, NJ, Anchorage, AK USA: IEEE service center, 1998. 69 - 73.
- [11] Shi Y, Eberhart R. Fuzzy adaptive particle swarm optimization [A]. Proc. Congress on Evolutionary Computation [C]. Seoul, Korea. Piscataway, NJ: IEEE Service Center, 27 - 30 May 2001. 1. 101 - 106.
- [12] Jacques Riget, Jakob S Vesterstrom. A diversity-guided particle swarm optimization the ARPSO [DB/OL]. <http://citeseer.nj.nec.com/riget02diversityguided.html>.
- [13] Lövbjerg M, Krink T. Extending particle swarms with self-organized criticality[A]. Proceedings of the Fourth Congress on evolutionary computation (CEC-2002) [C]. Honolulu, HI USA, 2002. 2. 1588 - 1593.
- [14] Al-kazemi B, Mohan C K. Multi-phase generalization of the particle swarm optimization algorithm[A]. Proceedings of the 2002 Congress on Evolutionary Computation [C]. Honolulu, HI USA, 12 - 17 May 2002. 1. 489 - 494.
- [15] Krink T, Vesterström J S, Riget J. Particle swarm optimisation with spatial particle extension[A]. Proceedings of the Fourth Congress on Evolutionary Computation (CEC-2002) [C]. Honolulu, HI USA, 2002. 2. 1474 - 1479.
- [16] Kennedy J, Mendes R. Population structure and particle swarm performance[A]. Proceedings of the IEEE Congress on Evolutionary Computation (CEC 2002) [C]. Honolulu, HI USA, 12 - 17 May 2002. 2. 1671 - 1676.
- [17] M Lövbjerg, T K Rasmussen, T Krink. Hybrid particle swarm optimiser with breeding and subpopulations[A]. Proceedings of the Genetic and Evolutionary Computation Conference [C]. San Francisco, California, 2001. 469 - 476.
- [18] Xiaohui Hu, Eberhart R C. Adaptive particle swarm optimization: detection and response to dynamic systems[A]. Proceedings of the 2002 Congress on Evolutionary Computation [C]. Honolulu, HI USA, 2002. 2. 1666 - 1670.
- [19] M Dorigo, L M Gambardella. Ant colony system: a cooperative learning approach to the traveling salesman problem[J]. IEEE Transactions on Evolutionary Computation, 1997, 1(1): 53 - 66.
- [20] T Stutzle, H H Hoos. MAX-MIN Ant system[J]. Journal of Future Generation Computer Systems, 2000, 16: 889 - 914.
- [21] A Colomi, M Dorigo, V Maniezzo. Distributed optimization by ant colonies[A]. In Proceedings of the First European Conference of Artificial Life (ECAL 91) [C]. Elsevier, 1991. 134 - 142.
- [22] M Dorigo, V Maniezzo, A Colomi. The ant system: optimization by a colony of cooperating agents [J]. IEEE Transactions on System, Man and Cybernetics-Part B, 1996, 26(1): 29 - 42.
- [23] L M Gambardella, M Dorigo. Solving symmetric and asymmetric TSPs by ant colonies[A]. Proceedings of the IEEE International Conference on Evolutionary Computation (ICEC 96) [C]. Nagoya Japan, 1996. 622 - 627.
- [24] M Dorigo, L M Gambardella. A study of some properties of Ant-Q[A]. Proceedings of PPSN IV-Fourth International Conference on Parallel Problem Solving From Nature [C]. Springer, Berlin, 1996. 656 - 665.
- [25] T Stutzle, H H Hoos. The MAX-MIN ant system and local search for the traveling salesman problem[A]. In Proceedings of the IEEE International Conference on Evolutionary Computation (ICEC '97) [C]. Indianapolis, USA, 1997. 309 - 314.
- [26] Bernd Bullnheimer, Richard F Hartl, Christine Straub. A new rank based version of the ant system a computational study [DB/OL]. <http://www.wirwien.ac.at/am>.
- [27] Kassabalidis I, El-Sharkawi, M A Marks, R J II Arabshahi, P Gray.

- Adaptive-SDR: Adaptive swarm-based distributed routing[A]. Proceedings of the 2002 International Joint Conference on Neural Networks [C]. Honolulu, HI USA, 2002, 1: 351 - 354.
- [28] Robinson J, Sinton S, Rahmat-Samii. Particle swarm, genetic algorithm, and their hybrids: optimization of a profiled corrugated horn antenna [A]. 2002 IEEE Antennas and Propagation Society International Symposium and URSI National Radio Science Meeting[C]. USA: Sun Auto-mo, TX, 16 - 21 June 2002. 1: 314 - 317.
- [29] Eberhart R C, Kennedy J. A new optimizer using particle swarm theory [A]. Proceedings of the Sixth International Symposium on Micro Machine and Human Science[C]. Nagoya Japan, 4 - 6 Oct. 1995. 39 - 43.
- [30] A Ismail, AP Engelbrecht. Training product units in feedforward neural networks using particle swarm optimization[A]. Proceedings of the International Conference on Artificial Intelligence [C]. Durban, South Africa, 1999. 36 - 40.
- [31] Eberhart R C, Hu X. Human tremor analysis using particle swarm optimization[A]. Proc. Congress on Evolutionary Computation[C]. Washington, DC, USA, 1999. 1927 - 1930.
- [32] El-Gallad A I, El-Hawary, M E Sallam, Kalas. Swarm-intelligently trained neural network for power transformer protection[A]. Canadian Conference on Electrical and Computer Engineering[C]. Toronto, Ont. Canada, 2001. 265 - 269.
- [33] Yoshida H, Kawata K, Fukuyama Y, Nakanishi. A particle swarm optimization for reactive power and voltage control considering voltage stability[A]. Proc. Intl. Conf. on Intelligent System Application to Power Systems[C]. Maui, Hawaii, 1999. 117 - 121.
- [34] G Di Caro, M Dorigo. AntNet: Distributed stigmergetic control for communications networks [J]. Journal of Artificial Intelligence Research (JAIR), 1998, 9: 317 - 365.
- [35] Lianyan Li, Zemin Liu, Zheng Zhou. A new dynamic distributed routing algorithm on telecommunication networks[A]. International Conference on Communication Technology Proceedings [C]. Beijing China, 2000. 1: 849 - 852.
- [36] Gunes M, Sorges U, Bouazizi I. ARA-the ant-colony based routing algorithm for MANETs[A]. Proceedings. International Conference on Parallel Processing Workshops [C]. Vancouver, B. C., Canada, 2002. 79 - 85.
- [37] Di Caro, G Dorigo M. Mobile agents for adaptive routing[A]. Proceedings of the Thirty-First Hawaii International Conference on System Sciences[C]. Kohala Coast, HI USA, 6 - 9 Jan 1998. 7: 74 - 83.
- [38] Lumer E, Faieta B. Diversity and adaptation in populations of clustering ants[A]. Proc. of the 3rd Conf. on Simulation of Adaptive Behavior [C]. MIT Press, 1994. 499 - 508.
- [39] Wu Bin, Zheng Yi, Liu Shaohui, Shi Zhongzhi. CSIM: a document clustering algorithm based on swarm intelligence [A]. Proceedings of the 2002 Congress on Evolutionary Computation[C]. Honolulu, HI USA, 12 - 17 May 2002. 1: 477 - 482.
- [40] Wu bin, Shi Zhongzhi. A clustering algorithm based on swarm intelligence[A]. Proceedings. Beijing 2001 International Conferences on Info-tech and Info-net [C]. Beijing China, 2001. 3: 58 - 66.
- [41] 吴斌, 傅伟鹏, 郑毅, 刘少辉, 史忠植. 一种基于群体智能的 web 文档聚类算法[J]. 计算机研究与发展, 2002, 39(11): 1429 - 1435.
- [42] Parpinelli R S, Lopes H S, Freitas. Data mining with an ant colony optimization algorithm[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(4): 321 - 332.
- [43] Maniezzo V, A Colomi, M Dorigo. The Ant System Applied to the Quadratic Assignment Problem [R]. Tech. Rep. IRIDIA/94-28, Universit   Libre de Bruxelles, Belgium. 1994.
- [44] Talbi E G, Roux O, Fonlupt, C Robillard D. Parallel ant colonies for the quadratic assignment problem [J]. Future Generation Computer Systems, 2001, 17(4): 441 - 449.
- [45] A Colomi, M Dorigo, V Maniezzo, M Trubian. Ant system for job-shop scheduling[J]. Belgian Journal of Operations Research, Statistics and Computer Science, 1994, 34(1): 39 - 53.
- [46] T Stutzle. An ant approach to the flow shop problem[A]. Proceedings of the 6th European Congress on Intelligent Techniques & Soft Computing [C]. Aachen, Germany, 1997. 3: 1560 - 1564.
- [47] McMullen, Patrick R. An ant colony optimization approach to addressing a JIT sequencing problem with multiple objectives[J]. Artificial Intelligence in Engineering, 1998, 15(3): 309 - 317.
- [48] Lee Zne-Jung, Lee Chour-Yuan, Su Shurr-Feng. An immunity-based ant colony optimization algorithm for solving weapon - target assignment problem[J]. Applied Soft Computing Journal, 2002, 2(1): 39 - 47.
- [49] Bullnheimer B, R F Hartl, C Strauss. An improved ant system algorithm for the vehicle routing problem[DB/OL]. The 6th Viennese workshop on Optimal Control, Dynamic Games [C]. Nonlinear Dynamics and Adaptive Systems, <http://citeseer.nj-nec.com/>, 1997 - 05 - 21.
- [50] V Maniezzo, A Carbonaro. An ants heuristic for the frequency assignment problem[A]. Proceedings of MIC '99[C]. 1999. 927 - 935.
- [51] De Campos, Luis M, Fern  ndez-Luna, Juan M, G  n  ez Jos   A Puerta, Jos   M. Ant colony optimization for learning Bayesian networks[J]. International Journal of Approximate Reasoning, 2002, 31(3): 291 - 311.
- [52] De A Silva, R M Ramalho. Ant system for the set covering problem [A]. IEEE International Conference on Systems [C]. Man, and Cybernetics, Tucson, AZ USA, 2001. 5: 3129 - 3133.
- [53] Eric Bonabeau, Marco Dorigo, Guy Theraulaz. Swarm Intelligence: From natural to Artificial Systems[M]. U. K: Oxford University Press, Inc. 1999. 271 - 273.

作者简介:



彭喜元 男, 1961 年生于内蒙古四子王旗, 哈尔滨工业大学自动化测试与控制系教授, 博士生导师, 主要研究方向为自动测试技术和智能故障诊断。



彭宇 男, 1973 年生于西安, 哈尔滨工业大学自动化测试与控制系副教授, 博士, 主要研究领域为计算智能和智能故障诊断理论。