

# 经典种群优化算法研究

段耀武<sup>1</sup>, 王 栋<sup>2</sup>

(1. 北京控制与电子技术研究所, 北京 100045;

2. 中国科学院长春光学精密机械与物理研究所, 吉林 长春 130000)

**摘要** 随着计算机技术和算法理论不断地更新迭代, 优化问题的求解越来越重要。传统的优化算法依靠数学模型和梯度求解, 而种群优化算法作为一种不依赖梯度信息的全局优化算法, 凭借其良好的全局搜索能力和强大的适应性, 为解决复杂优化问题提供了一个新方向。种群优化算法的基本思想是通过模拟自然界中的生物或社会群体行为来寻找问题的最优解。常见的种群优化算法包括粒子群优化算法、遗传算法、蚁群智能算法和差分进化算法等, 这些算法的出现为许多应用领域如工程设计、图像处理和机器学习等提供了新的发展动力。本文对几种经典的种群优化算法进行了探讨, 分析了基本原理、优缺点和应用领域, 总结了当前种群优化算法的主要挑战与未来发展趋势, 以期对相关人员进行借鉴。

**关键词** 种群算法; 优化算法; 算法寻优

**基金项目:** 国家国防科技工业局 2024 年度科研专项资助 (项目编号: KJSP2023020304)。

**中图分类号:** TP3

**文献标志码:** A

**DOI:** 10.3969/j.issn.2097-3365.2025.23.001

## 0 引言

在现代科技迅速发展的背景下, 各类复杂系统的优化问题日益凸显, 如何在高维、非线性、多目标等约束条件下高效地寻找最优解, 成为科研与工程领域的核心问题。传统基于解析建模和梯度信息的优化方法在面对这些复杂问题时, 往往面临着计算效率低、易陷入局部最优等挑战。因此, 研究更具通用性和鲁棒性的优化算法尤为重要。启发式算法尤其是种群优化算法因其模型独立性、全局搜索能力强等优点, 在众多实际应用中崭露头角。

## 1 种群优化算法的基本概念

种群优化算法<sup>[1]</sup>的核心思想源于自然界中物种进化的过程, 研究者通过对生物种群适应环境、竞争与合作等现象的模拟, 构建出高效的优化模型。在这一过程中, 每个个体代表一个可能的解, 而整个种群则共同参与搜索, 通过信息共享和协同进化, 不断地迭代更新解的质量。这种基于群体协作的搜索机制, 使得算法在探索复杂的多维解空间时, 极大地提高了找到最优解的可能性 (见图 1)。

与传统依赖单个个体局部搜索的方法不同, 种群优化算法在每次搜索中充分调动整个群体的信息优势, 通过个体间的互动与竞争, 有效避免了局部最优解的困境。

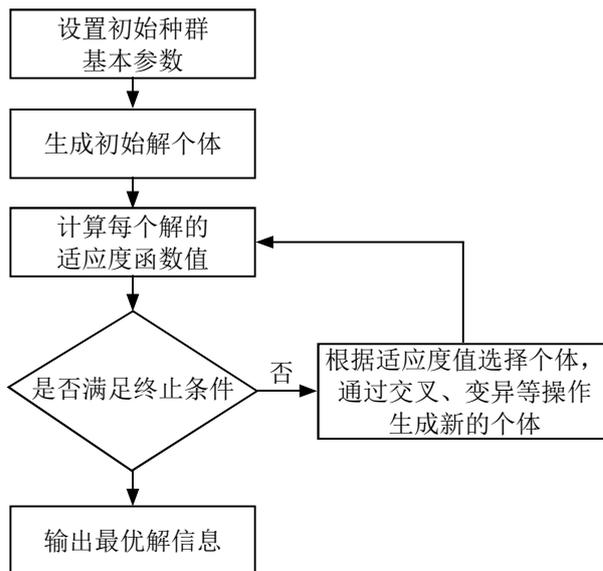


图 1 种群算法求解流程图

图 1 为种群算法的基本逻辑框架。最开始设置种群的基本参数, 然后生成初始解的集合, 其中每个解称为“个体”。通过计算每个解的适应度函数评估每个个体的优劣。最后进行终止条件判断, 终止条件一般为固定的迭代次数或分数指标等。如果满足终止条件就输出最优解信息, 否则根据适应度选择个体, 并通过交叉、变异等操作生成新的个体不断重复上述过程, 直到满足终止条件。

## 2 常见的种群优化算法

### 2.1 粒子群优化算法

粒子群优化算法<sup>[2]</sup>由 Kennedy 和 Eberhart 于 1995 年提出,灵感来源于鸟群的觅食行为。每个个体解被称为“粒子”,粒子通过不断在搜索空间中移动来寻找最优解。它利用公式(1)和(2)来生成新的种群个体,其中  $V$  是粒子在  $t$  时刻的速度,  $W$  是惯性权重通常选择一个较小的值,  $c1$  和  $c2$  是学习因子控制  $pb$  和  $gb$  的学习能力,  $pb$  是粒子的历史最优位置,  $gb$  是整个种群的历史最优位置,  $X$  是粒子在  $t$  时刻的位置,  $V_{t+1}$  是粒子在  $t+1$  时刻的速度。

$$V_{t+1} = W \times V_t + c1 \times (pb - X_t) + c2 \times (gb - X_t) \quad (1)$$

$$X_{t+1} = X_t + V_{t+1} \quad (2)$$

粒子群优化算法的特点主要是无需梯度信息,算法简单,易于实现且具有较强的全局搜索能力,能够避免陷入局部最优。这些特点使得该算法在多个领域广泛应用。

### 2.2 遗传算法

遗传算法由 John Holland 在 1975 年提出,是一种模拟自然选择和遗传机制的优化算法<sup>[3]</sup>。算法通过选择、交叉、变异等操作生成新一代个体,并不断迭代找到最优解。首先,设置参数并生成一个初始种群,并计算每个个体的适应度值。其次,通过选择操作,从种群中选择适应度值较高的个体作为父代进行交叉操作,生成新一代个体。为了增加种群的多样性,算法还会对某些个体进行变异,增加更多的探索范围。新一代种群个体通过选择、交叉和变异产生,并根据适应度保留优秀个体。最后,通过设定的终止条件来输出最优解。

传统优化方法在面对高维度、目标函数不连续或不可导的问题时常常表现不佳,而遗传算法不依赖这些数学性质,因此在许多工程优化、函数拟合和参数寻优等场景中显示出良好的适应性。它通过种群中的个体并行搜索,避免了单点搜索的局限性,能够在庞大且复杂的解空间中有效进行探索,从而提高找到全局最优解的可能性。

另一个显著特点是遗传算法具有较强的全局搜索能力,这得益于其基于种群的搜索策略和交叉、变异等操作带来的多样性保持机制。这种机制使得算法可以在多个区域同时进行搜索,减少陷入局部最优的风险。然而,遗传算法也存在一定的局限性,尤其是在一些特定问题中,容易出现“早期收敛”现象,即种

群在进化过程中过早集中于某个适应度较高的区域,从而失去对其他潜在优质解的探索能力。因此,在实际应用中常需通过调整参数或引入改进机制来提升其搜索效率和收敛效果。

### 2.3 蚁群智能算法

蚁群算法由 Marco Dorigo 于 1992 年提出,模拟蚂蚁寻找食物路径的过程<sup>[4]</sup>。蚂蚁通过信息素的释放和感知在环境中寻找最短路径或最优解。蚁群智能算法的主要应用领域包括旅行商问题、最短路径问题、组合优化问题等。它主要应用公式(3)和公式(4)。其中  $P_{ij}(t)$  是蚂蚁在  $t$  时刻从路径  $i$  到  $j$  的概率,  $\tau_{ij}(t)$  是路径的信息素浓度,  $\eta_{ij}$  是启发式信息,  $\alpha$  和  $\beta$  是控制信息素和启发式信息影响程度参数,  $N_i$  是当前节点  $i$  的邻居节点集,  $\rho$  是信息素挥发因子,  $Q$  是常数,  $L_k$  是蚂蚁  $k$  在路径上的路径长度。

$$P_{ij}(t) = \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}]^\beta}{\sum_{K \in N_i} [\tau_{iK}(t)]^\alpha [\eta_{iK}]^\beta} \quad (3)$$

$$\tau_{ij}(t+1) = (1-\rho) \times \tau_{ij}(t) + \sum_{K \in G} \frac{Q}{L_K} \quad (4)$$

其核心优势在于能够通过模拟蚂蚁释放和感知信息素的行为,把局部搜索与全局搜索结合,从而提高对复杂解空间中的搜索效率,避免陷入局部最优。群体间的协作和正反馈机制使得算法具有较强的自适应性和鲁棒性。然而,蚁群算法也存在一些不足,主要体现在对参数的敏感性较高,特别是在信息素挥发率、更新强度等参数的选择上对最终性能有较大影响,若设置不当可能导致搜索效率下降或收敛不稳定。此外,在处理高维复杂问题时,由于需要维护大量路径和信息素矩阵,算法的计算资源开销和时间复杂度显著上升,影响其在大规模问题中的应用效率。

### 2.4 其他种群优化算法

随着计算机技术的不断进步,研究人员对种群优化算法进行了深入的探索和不断优化,提出了许多先进的新型算法。这些算法借鉴了自然界中生物的觅食、飞翔、迁徙等行为,通过构建模拟生物智能的搜索机制,实现了对复杂优化问题的高效求解。

其中,人工鱼群算法<sup>[5]</sup>通过模拟鱼群的集群行为和觅食策略,使得算法在处理非线性、多峰问题时具有较高的求解精度和较好的鲁棒性。

与此同时,蝙蝠算法<sup>[6]</sup>借鉴蝙蝠利用回声定位捕捉目标的生理特性,通过自适应调整飞行速度与搜索

路径,使算法能够迅速发现全局最优解,特别适用于连续优化问题和多目标优化任务。

此外,鲸鱼优化算法通过模拟鲸鱼捕食时的螺旋式搜索行为,将鲸鱼群体间的协作与竞争机制融入算法设计中,有效增强了全局搜索能力,在处理高维复杂优化问题时表现出优越性能。

这些新兴的优化算法在很多实际应用场景中展示了令人瞩目的表现。与遗传算法和粒子群算法相比,它们在收敛速度和全局搜索能力上具有明显优势。人工鱼群算法能够在搜索过程中平衡探索和开发,使得在局部细节优化与全局趋势把控之间取得良好平衡;蝙蝠算法利用动态自适应机制,对搜索过程中遇到的局部最优陷阱有较强的跳出能力;而鲸鱼优化算法则通过独特的螺旋更新策略和局部精细搜索,有效避免了陷入局部最优解的问题,增强了对复杂问题的求解能力。

### 3 算法的应用实例

种群优化算法作为一类重要的全局优化方法,已在众多领域展现出强大的应用价值,尤其在工程优化、图像处理、机器学习与数据挖掘等方面,取得了显著的成果。其核心优势在于能高效的在高维、复杂的搜索空间内寻找最优解,并且不依赖于问题的解析梯度信息,使其在非线性、多约束优化问题中具有广泛的适用性。

在工程优化领域,种群优化算法已被成功应用于结构优化、机械设计、控制系统设计等问题。例如:在航空航天和汽车制造领域,研究人员利用粒子群优化和遗传算法优化飞行器和车辆的空气动力学结构,以减少阻力并提高燃油效率。对于复杂的控制系统设计,种群优化算法能够帮助优化控制参数,如PID控制器的增益参数调整,以提高系统的稳定性和响应速度,广泛应用于自动化制造和机器人控制领域。

在图像处理方面,种群优化算法被用于图像复原、图像分割、图像匹配等任务,尤其在多模态优化问题中表现出了较强的能力。例如:在医学影像分析中,遗传算法和粒子群优化被用于图像分割,以精确识别病灶区域,提高疾病诊断的准确性。

在机器学习与数据挖掘领域,种群优化算法的作用同样不可忽视。粒子群优化和遗传算法常用于模型训练、特征选择、超参数优化等任务。例如:在深度学习,研究人员利用遗传算法优化神经网络的结构和超参数,以提高模型的泛化能力和收敛速度。

### 4 算法的改进与挑战

尽管种群优化算法在优化问题上展现出了卓越的性能,并在工程、人工智能、图像处理、光学优化等多个领域取得了显著成果,但其仍面临诸多挑战。其中,收敛速率较慢、易陷入局部最优解以及计算复杂度随问题规模增长而急剧上升等问题限制了该算法在实时性强要求的领域使用。为了解决上述问题,研究人员进行了一系列的改进。例如:自适应机制的引入可以根据优化过程中的反馈信息动态调整参数,从而在算法的不同阶段灵活调整探索与开发的平衡,增强其跳出局部最优解的能力。此外,混合算法随着时代的发展逐渐成为研究热点。同时,局部搜索策略的加入也为种群优化算法提供了更精细的搜索能力,通过在解空间内执行局部优化步骤,可以有效提升收敛速度并提高解的质量。

### 5 结束语

种群优化算法作为一种强大的全局优化工具,凭借其无需梯度信息、适应性强等优势,已在众多复杂问题中展现出卓越表现。尽管在收敛速度、局部最优以及计算效率等方面仍存在挑战,但随着算法策略的不断优化和并行计算技术的快速发展,其应用前景愈加广阔。未来,随着多学科技术的融合与智能化程度的提高,种群优化算法有望在更加复杂、动态和高维的优化场景中实现突破,推动各领域技术创新与工程实践的深度发展。

### 参考文献:

- [1] 李雷雷,李盼池,赵娅.一种改进的量子粒子群优化算法[J].计算机与数字工程,2025,53(02):303-307,94.
- [2] 叶倩琳,王万良,王铮.多目标粒子群优化算法及其应用研究综述[J].浙江大学学报(工学版),2024,58(06):1107-1120,1232.
- [3] 孙雨辉,潘大志.基于改进遗传算法的冷链物流配送路径优化[J/OL].西华师范大学学报(自然科学版),1-12 [2025-04-18].<http://kns.cnki.net/kcms/detail/51.1699.N.20250414.1718.002.html>.
- [4] 吴榆俊,叶子青.蚁群算法在微电网容量配置优化中的应用综述[J].电气技术与经济,2022(03):20-22.
- [5] 洪刘.基于人工鱼群优化算法的室内可见光定位技术的研究[D].北京:北京邮电大学,2020.
- [6] 张原宾.基于蝙蝠算法的支持向量机电力变压器故障诊断研究[D].长春:吉林农业大学,2023.