



单种群自适应异构蚁群算法的机器人路径规划

张松灿^{1,2}, 孙力帆¹⁺, 司彦娜¹, 普杰信¹

1. 河南科技大学 信息工程学院, 河南 洛阳 471023

2. 河南科技大学 电气工程学院, 河南 洛阳 471023

+ 通信作者 E-mail: lifan.sun@gmail.com

摘要:针对多种群蚁群算法存在结构复杂、优化速度慢及适应性不足等问题,提出一种单种群自适应异构蚁群算法,并用于机器人路径规划。该算法采用单种群结构,避免多蚁群算法结构复杂的问题;种群内每只蚂蚁都有自己的控制参数,实现蚂蚁的行为异构,增加种群的多样性;在首次迭代时,仅用启发因子构建候选解,提高了初始化种群的质量;根据蚁群优化过程中种群信息熵的变化,自适应确定信息交换周期;所设计的信息交换策略将最优蚂蚁的控制参数传递给最差蚂蚁,增强最优蚂蚁的引导作用;参数突变操作有助于在更大的参数空间探索更优的控制参数,提高算法逃离局部最优的能力。仿真实验与统计检验的结果验证了所提算法的有效性、稳定性和优越性。

关键词:蚁群算法;种群信息熵;移动机器人;路径规划;自适应信息交换周期;状态转移规则;参数突变

文献标志码:A **中图分类号:**TP18

Single-Colony Adaptive Heterogeneous Ant Colony Algorithm for Mobile Robot Path Planning

ZHANG Songcan^{1,2}, SUN Lifan¹⁺, SI Yanna¹, PU Jiexin¹

1. School of Information Engineering, Henan University of Science & Technology, Luoyang, Henan 471023, China

2. School of Electrical Engineering, Henan University of Science & Technology, Luoyang, Henan 471023, China

Abstract: Aiming at the existent problems of complex structure, slow optimization rate and inadequate adaptability of multi-colony ant colony algorithm, a single colony adaptive heterogeneous ant colony algorithm is proposed to solve mobile robot path planning. The proposed algorithm employs a single colony to avoid the problem of complex structure of multi-ant colony algorithm. Each ant in the colony has its own control parameters to realize the heterogeneous behavior and increase the diversity of the population. In the first iteration, only the heuristic factor is used to construct the candidate solution, which improves the quality of the initial population. The information exchange period is adaptively determined based on the change of population information entropy to enhance the adaptability of the algorithm. The information exchange strategy transfers the control parameters of the optimal ant to the worst

基金项目:国家自然科学基金(U1504619);国家“十三五”装备预研领域基金资助项目(61403120207, 61402100203);航空科学基金资助项目(20185142003);河南省高校科技创新人才资助项目(21HASTIT030);河南省高等学校青年骨干教师资助项目(2020GGJS073);中原科技创新领军人才资助项目(194200510012)。

This work was supported by the National Natural Science Foundation of China (U1504619), the National “Thirteen-Five” Equipment Pre-Research Foundation of China (61403120207, 61402100203), the Aeronautical Science Foundation of China (20185142003), the Program of Science and Technology Innovative Talents in Universities of Henan Province (21HASTIT030), the Program of Young Backbone Teachers in Universities of Henan Province (2020GGJS073), and the Program of Leading Talents of Science and Technology Innovation in the Central Plains of China (194200510012).

收稿日期:2021-07-22 **修回日期:**2021-09-29

ant to enhance the guiding role of the optimal ant. Parameter mutation operation is helpful for exploring better algorithm parameters in a larger parameter space and improving the ability to escape from local optimization. The results of simulation experiments and statistical tests verify the effectiveness, stability and superiority of the proposed algorithm.

Key words: colony algorithm; population information entropy; mobile robot; path planning; adaptive information exchange period; state transition rule; parameter mutation

路径规划是移动机器人领域中的研究热点之一,旨在为机器人找到工作空间内的无碰最优或近似最优路径,同时满足一定的优化指标(最短距离、能耗最小等)。目前,解决移动机器人路径规划问题常用的有 Dijkstra Algorithm^[1]、A*算法^[2]、D* Lite^[3]等启发式方法,以及人工神经网络^[4]、遗传算法^[5-6]、模糊逻辑^[7]、粒子群优化算法^[8]等智能算法,每种方法的优点和适应范围有所不同。在诸多规划方法中,蚁群算法模仿真实蚂蚁的寻路方法来得到最优路径,与机器人路径规划要求相似,因而得到广泛应用。

然而常规蚁群算法存在运行效率低、算法停滞和易陷入局部最优等不足,针对这些问题,许多改进算法与改进策略相应提出。王晓燕等^[9]提出初始信息素不均衡分配原则,降低蚁群搜索的盲目性,提高算法的搜索效率。朱佳莹等^[10]利用粒子群算法预搜索路径来优化蚁群算法的初始信息素,加快蚁群算法迭代初期的收敛速度。陈雄等^[11]引入信息素限定措施,并提出了自适应信息素挥发系数的方法来解决蚁群算法中的停滞现象,显著提高了算法的搜索能力。文献[12]提出了一种模型诱导的最大最小蚁群优化算法,改进最大最小蚂蚁系统中的状态转移规则,并利用信息素矩阵的状态作为迭代终止的依据,填补了混合算法选择与理论分析之间的空缺。上述单蚁群改进算法在优化过程中采用相同的状态转移规则构建候选解,难以完全解决蚁群算法自身缺陷,因此,一些学者通过多蚁群合作来获得更好的性能。

Lee^[13]提出了一种异构多蚁群路径规划方法,对转移概率规则、信息素更新规则和异构蚁群进行改进。Sreeja 等^[14]提出分层异构蚁群优化算法,第一层为功能层,第二层是管理层。功能层子蚁群将得到的最优解传递到管理层,管理层生成全局最优解,并将全局最优解传递给各个子蚁群来实现信息交流。张德惠等^[15]将猫群算法中的分工思想引入到蚁群系统中,通过动态分组机制将蚂蚁分为搜索蚂蚁和跟踪蚂蚁两类,不同类型的蚂蚁具有不同的运行机制,并依据算法优化过程自动调整蚂蚁的类型。Zhang 等^[16]结

合动态分组蚁群算法、经典蚁群算法与最大最小蚂蚁系统组成了具有不同行为特征的异构多蚁群优化算法实现算法的性能互补,利用多角色动态协调机制实现信息交换。Gülcü等^[17]提出了一种主从机制的并行协同混合蚁群算法(parallel ant colony optimization and 3-Opt algorithm, PACO-3Opt),将蚁群分为具有主从结构的子群,在子群间共享全局最优信息,通过周期性的子群协作来提高解质量。上述多蚁群算法中,每个蚁群具有自己的特征,通过群间的信息交换能实现优缺点的互补,但是算法结构复杂,无论是采用并行结构、顺序结构还是分层结构,均需要执行多个蚁群的优化操作,消耗了大量的计算资源。此外,多蚁群算法的优化性能与信息交换策略密切相关,如信息交换周期、信息交换内容及信息交换对象等,不合适的交换策略会降低算法的性能。

算法参数对智能算法的优化能力具有重要影响。文献[17]在求解不同规模的旅行商问题时设置了不同的蚁群算法参数,取得了较好的优化结果。万正宜等^[18]设计了一种自适应动态更新信息素挥发因子的策略,当最优解在多次迭代中没有得到增强时,启用自适应更新策略对信息素进行动态更新。Mahi 等^[19]采用粒子群优化蚁群算法参数,但需要耗费大量的计算时间来得到最优参数。这些参数选择方式能提高蚁群的优化能力,但是大多通常都是根据经验而定,需要大量的运算时间,缺乏灵活性与适应能力,也很少在算法优化中同时去探索参数空间与寻找更优的参数组合。

为此,在不增加计算负担的情况下,提出一种基于单种群的自适应异构蚁群算法(adaptive heterogeneous ant colony algorithm based on single-colony, AHACO)。算法的主要改进策略如下:

(1)首次迭代时,仅以启发信息来构建候选解,以提高初始种群的质量。

(2)非首次迭代时,每只蚂蚁使用独立的控制参数构建候选解,呈现出不同的行为特征,增强种群的多样性。

(3)利用种群信息熵衡量算法多样性的变化,并根据种群信息熵的变化,自适应确定信息交换周期,提高算法适应能力,平衡多样性与收敛速度的矛盾。

(4)信息交换策略将最优蚂蚁的控制参数传递给最差蚂蚁,从而发挥最优蚂蚁的引导作用。在信息交换前先对最优蚂蚁的控制参数进行突变,不仅有利于在更大的参数空间探索更优的算法参数,还能增强种群的多样性。

将所提出 AHACO 算法用于移动机器人路径规划问题,仿真结果表明,算法的收敛速度与优化性能均优于传统蚁群算法以及其他对比算法。统计检验进一步证实了 AHACO 算法的优越性。

1 相关研究

1.1 最大最小蚂蚁系统

Stutzle 等在蚂蚁系统基础上提出了最大最小蚂蚁系统(max-min ant system, MMAS)^[20]。作为经典的蚁群算法之一,具有较高的探索能力与寻优能力,在组合优化领域得到广泛使用。相对于蚂蚁系统,最大最小蚂蚁系统算法做了以下改进:(1)仅允许最优蚂蚁进行信息素更新,以加强对最佳搜索历史的利用,最优蚂蚁可以是迭代最优,也可以是全局最优蚂蚁;(2)限定了路径上信息素浓度的上下限,避免最优路径上的信息素过于集中引起的早熟收敛,提高了算法的探索能力;(3)信息素的初始值设定为信息素的上界,有助于算法在更大的问题空间进行探索,增大找到最优解的可能性;(4)引入信息素平滑处理策略,提高算法的寻优能力。

1.1.1 状态转移规则

在最大最小蚂蚁系统中,当蚂蚁 k 从节点 i 向节点 j 转移时,其状态转移概率由路径上的信息素与路径段的启发信息共同决定。用 p_{ij}^k 表示蚂蚁 k 从节点 i 向节点 j 转移的概率,则其计算方法如式(1)所示:

$$p_{ij}^k = \begin{cases} \frac{[\tau_{ij}]^\alpha [\eta_{ij}]^\beta}{\sum_{s \in allowed_k} [\tau_{is}]^\alpha [\eta_{is}]^\beta}, & j \in allowed_k \\ 0, & j \notin allowed_k \end{cases} \quad (1)$$

其中, τ_{ij} 为路径 (i,j) 上的信息素量,表示积累的经验信息, $\eta_{ij} = 1/d_{ij}$ 为从节点 i 转移到节点 j 的启发信息, d_{ij} 表示从节点 i 到节点 j 的距离, $allowed_k$ 为蚂蚁 k 在当前节点的可选节点集, α 和 β 分别表示信息素和启发信息在构建候选解时的相对影响程度,且 β 值越大,状态转移概率越接近于贪心方式。

1.1.2 信息素更新规则

最大最小蚂蚁系统仅允许对最优解进行信息素更新,在信息素更新时,还限定了信息素值的范围,其信息素更新规则如式(2)所示:

$$\tau_{ij}(t+1) = [(1-\rho) * \tau_{ij}(t) + \Delta\tau_{ij}^{best}(t)]_{\tau_{lb}}^{\tau_{ub}} \quad (2)$$

其中, $\Delta\tau_{ij}^{best}(t) = 1/L^{best}(t)$ 表示最优蚂蚁第 t 次迭代时在路径段 (i,j) 释放的信息素增量, $L^{best}(t)$ 是最优路径的适应度值, τ_{ub} 是路径上信息素的上限, τ_{lb} 是信息素的下限,函数 $[x]_{\tau_{lb}}^{\tau_{ub}}$ 用于对因变量进行范围限制,其定义如式(3)所示:

$$[x]_{\tau_{lb}}^{\tau_{ub}} = \begin{cases} ub, & x > ub \\ lb, & x < lb \\ x, & \text{otherwise} \end{cases} \quad (3)$$

其中, ub 是变量 x 的上界, lb 是变量 x 的下界。

1.2 种群信息熵

文献[21]利用种群相似度对种群多样性进行度量,但是种群相似度计算要求个体具有相同的节点数,而蚁群算法用于路径规划时候选解包含的路径节点数不相同,因此需要研究新的种群多样性度量方法。

在信息论中常用熵表示随机变量 X 中每个状态发生的不确定程度,熵越大则越混乱。假设随机变量有 n 个状态 $x_1, x_2, \dots, x_n$, 则它的信息熵计算方法如式(4)所示:

$$H(X) = - \sum_{i=1}^n p(x_i) \ln p(x_i) \quad (4)$$

其中, x_i 表示随机系统的第 i 个状态, $p(x_i)$ 表示状态 x_i 发生的概率。信息熵越大说明每种状态出现的概率相等,意味着系统的多样性就越好。

当用信息熵来描述蚁群算法迭代过程中多样性变化特征时,以候选解适应度值在所有适应度值中出现的比例作为表示该状态发生的概率,其计算方法如式(5)所示:

$$H_Pop(t) = - \sum_{i=1}^N p(x_i) \ln p(x_i) \quad (5)$$

其中, $H_Pop(t)$ 是第 t 迭代时的信息熵; x_i 是第 i 个候选解的适应度值; $p(x_i) \geq 0$ 是适应度值 x_i 在所有适应度值中出现的占比; N 是候选解的个数。

整个种群相对信息熵的计算方法如式(6)所示:

$$HR_pop(t) = \frac{H_pop(t)}{\ln N} \quad (6)$$

1.3 环境模型

栅格法使用固定大小的栅格划分工作区域,使

用简单方便,并且能够标记各种复杂的环境信息,常用于机器人的环境建模。如果障碍物形状不规则,可将其按照栅格大小进行分割处理,占据一个或多个栅格;分割后的障碍物未完全占据一个栅格,也视作一个完整的障碍栅格。图1是一个二维栅格环境示意图,其中白色栅格表示可行栅格,黑色栅格表示障碍栅格。




图1 二维栅格环境示意图

Fig.1 Example of grid-based environment

在访问栅格前,需要对二维环境中的栅格进行标识。常用的标识方法有序号法和直角坐标法,二者本质相同,只是表达方式不同。序号法就是从上至下、从左至右依次对栅格进行编号。以10×10的二维栅格环境为例,各个栅格编号后如图1所示,栅格中的数字对应栅格编号。直角坐标法则根据栅格所在行与列对栅格进行标号。

序号法常用于路径表示,直角坐标法常用于路径代价计算,二者可以进行相互转换,栅格序号到栅格坐标的转换如式(7)所示,栅格坐标到栅格序号的转换如式(8)所示:

$$\begin{cases} row = \text{floor}\left(\frac{idx - 1}{width}\right) + 1 \\ col = \text{mod}(idx - 1, width) + 1 \end{cases} \quad (7)$$

$$idx = (row - 1) * width + col \quad (8)$$

其中, $\text{mod}()$ 表示求模操作; $\text{floor}()$ 表示向下取整操作; idx 表示栅格序号; row 表示栅格所在的行; col 表示栅格所在的列; $width$ 表示栅格地图的宽度,即栅格地图的列数。

2 自适应异构蚁群算法设计

2.1 状态转移规则设计

为了实现个体异构,对最大最小蚂蚁系统的状态转移规则进行修改,每只蚂蚁拥有自己独立的控制参数 α 和 β ,从而实现不同蚂蚁具有不同的行为

特点。修改后的状态转移规则如式(9)所示:

$$p_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^{\alpha(k)} [\eta_{ij}(t)]^{\beta(k)}}{\sum_{s \in allowed_k} [\tau_{is}(t)]^{\alpha(k)} [\eta_{is}(t)]^{\beta(k)}}, j \in allowed_k \\ 0, j \notin allowed_k \end{cases} \quad (9)$$

其中, $\alpha(k)$ 和 $\beta(k)$ 是第 k 只蚂蚁的控制参数,用于管理第 k 只蚂蚁在构建候选解时信息素和启发信息的相对影响程度。 τ_{ij} 为路径 (i,j) 上的信息素量, $\eta_{ij} = 1/d_{ij}$ 为从节点 i 转移到节点 j 的启发信息, d_{ij} 表示从节点 i 到节点 j 的距离, $allowed_k$ 为蚂蚁 k 在当前节点的可选节点集。

显然,由异构蚂蚁组成的群体仍然是单一的蚁群,避免了多蚁群结构复杂、效率低的问题,同时利用异构特征构建多样化的候选解,提高蚁群的探索能力,减少陷入局部最优的概率。

2.2 信息素更新规则设计

自适应异构蚁群算法是对最大最小蚂蚁系统进行改进而提出的,因最大最小蚂蚁系统通过设置信息素阈值,有效地避免了算法早熟,提高了求解质量,因此自适应异构蚁群算法的信息素更新规则与最大最小蚂蚁系统的信息素更新规则相同,更新规则如式(2)所示。

2.3 蚁群初始化

基于种群的智能优化算法中,初始种群的质量对算法的性能具有重要影响。

蚁群算法在构建候选解时,参数 α 和 β 决定了状态转移规则中信息素与启发信息的相对重要性。在初始化路径信息素值时,蚁群算法大多采用均匀初始化方式,因此,在迭代初期,信息素浓度差异不大,难以发挥信息素的引导作用。启发信息可以事先确定,并且在优化过程中保持不变。参数 β 影响着启发信息的相对重要性,较大的 β 能使蚂蚁选择距离更短的节点,构成较优质的候选解。

为了建立优质的初始种群,在算法初期充分发挥启发信息的引导作用,采用较小的 α 值与较大的 β 值。仿真实验时,对于首次迭代,参数 β 取值为10, α 取值为0,即不考虑初始信息素的影响,仅按照启发信息来构建候选解;非首次迭代时,每只蚂蚁使用自己的控制参数构建候选解。

2.4 自适应信息交换周期设计

信息交换的目的是发挥优质解的引导作用,通过调节交换周期可以使算法收敛于全局最优或探索更大的问题空间,对算法的优化性能具有重要影响。

一般来说,自适应信息交流频率比固定信息交换周期的性能要好。

如前所述,种群信息熵能反映种群多样性的信息,当种群多样性较差时,即种群信息熵较小时,要减小交换周期,通过较频繁的信息交换来提高种群的多样性,增强算法的搜索能力;当种群多样性较好时,可以适当地增大交换周期,一方面可以减少通信消耗,另一方面可保持算法优化过程的相对稳定,加速算法收敛。相应的自适应信息交换周期计算方法如式(10)所示:

$$\text{period} = \frac{1}{1 + 4 \times e^{-3.5 \times HR_pop(t)^2}} \times 10 \quad (10)$$

其中, $HR_pop(t)$ 表示第 t 次迭代结束后种群的相对信息熵,计算方法如式(6)所示。

从图2可以看出,信息交换周期随着种群信息熵的变化而变化。当算法处于优化初期,种群中的候选解均匀分布在问题空间中,多样性较好,此时种群信息熵比较大,采用较大的信息交换周期,能够加快算法收敛;随着优化过程的继续,候选解逐渐向最优解聚集,相应的种群信息熵较小,采用较小的信息交换周期实现频繁的信息交换,能够维持较好的种群多样性,增强算法的探索能力。因此所提出自适应信息交换周期设计,有利于在全局寻优和局部寻优能力两方面达到平衡。




图2 信息交换周期曲线

Fig.2 Curve of information exchange period

2.5 信息交换与参数突变设计

信息交换的目的主要是将最优蚂蚁的控制参数传递给最差蚂蚁,从而发挥最优蚂蚁的引导作用。已有的参数选择与优化方法难以满足智能算法的优化需求,也无法在参数空间进一步探索更好的算法参数。

为此,对算法参数进行突变操作,有利于在更大的参数空间寻找更优的参数设置。同时,参数突变

操作使得蚂蚁的行为特征更加不同,有利于保持种群的多样性。为了确保参数突变后依然在当前最优参数附近,仅允许小范围的参数突变。

参数突变完成后,用最优蚂蚁的参数替代种群内最差蚂蚁的参数,如式(11)与式(12)所示:

$$\alpha_{\text{worst}} = \alpha_{\text{best}} + M(0, \sigma) \quad (11)$$

$$\beta_{\text{worst}} = \beta_{\text{best}} + M(0, \sigma) \quad (12)$$

其中, α_{worst} 和 β_{worst} 是最差蚂蚁对应的信息素因子和启发式因子, α_{best} 和 β_{best} 是最优蚂蚁对应的信息素因子和启发式因子。 $M(0, \sigma)$ 表示均值为0、标准差为 σ 的高斯突变函数,为避免算法参数发生大范围突变引起寻优性能下降,设置 $\sigma = 0.05$ 。

由于蚁群算法属于概率型优化算法,每次迭代的最优蚂蚁与最差蚂蚁有可能不相同,为了减少偶然因素引起的偏差,在每个交换周期内对候选解质量进行排序,然后选出最优蚂蚁与最差蚂蚁,之后按照式(11)与式(12)进行参数突变与信息交换。

综上所述,所提的AHACO算法中每只蚂蚁拥有独立的信息素因子和启发因子,呈现出不同的行为特征,因此是一个异构蚁群算法。算法根据种群信息熵的变化自动调整信息交换周期,因此所设计的算法为自适应异构蚁群算法。同时,当需要进行信息交换时,最优蚂蚁的控制参数经过突变后替换最差蚂蚁的参数,即算法参数在优化过程中能够发生变化,具有探索更佳参数的能力。

3 AHACO算法工作流程与分析

3.1 AHACO算法工作流程

将所设计的自适应异构蚁群算法用于移动机器人路径规划,其算法流程如图3所示,具体实施步骤描述如下:

步骤1 加载环境模型,设置规划的起点与终点。

步骤2 初始化算法参数,如蚂蚁个数 m 、最大迭代次数 $maxIter$ 、当前迭代次数 Nc ,信息素挥发系数 ρ 等。初始化首次迭代时的参数 $\alpha = 0$, $\beta = 10$;设置非首次运行时每只蚂蚁的参数 α 、 β 及参数突变时的标准偏差 σ 。

步骤3 判断算法是否为首次迭代,如是,顺序执行,否则跳转到步骤5。

步骤4 初始化蚁群。将蚁群中的蚂蚁放置在路径规划的起点,按照式(1)构建初始可行路径,直到蚂蚁抵达终点或陷入死锁状态。评估所有候选路径的长度,并保存本次所有候选路径的长度信息。然后跳转到步骤6。

步骤5 按照式(9)构建候选路径,直到蚂蚁抵达终点或陷入死锁状态,评估所有候选路径的长度,并保存本次所有候选路径的长度信息。

步骤6 按照式(2)进行信息素全局更新,按照式(3)对信息素进行越界处理。

步骤7 判断是否需要进行信息交换,如果需要,对本次交换周期内蚂蚁的路径质量进行评估,确定出本周期的最优蚂蚁与最差蚂蚁,按式(11)与式(12)对最差蚂蚁的参数进行替换,并按照式(10)计算下一次信息交换周期,否则继续执行程序。

步骤8 重复步骤3到步骤7,直到满足终止条件。

步骤9 输出全局最优路径。




图3 自适应异构蚁群算法流程图

Fig.3 Flowchart of AHACO for path planning

从图3可以看出,AHACO算法与MMAS算法框架基本一致,主要差别在于:(1)AHACO算法将候选解构建过程分为两种情况,如果是首次迭代,按照式(1)构建候选解,否则按照式(9)构建候选解。(2)蚂蚁间的信息交换主要是最优蚂蚁与最差蚂蚁的控制参数交换。此外,为了能在更大的参数空间寻找最优参数,在参数交换前对最优蚂蚁的控制参数进行突变操作。(3)用种群信息熵衡量种群的多样性变化。(4)依据种群信息熵变化自动调整信息交换周期。流程图中的虚线框对应于上述改进。

3.2 AHACO算法复杂度分析

从图3可以看出,AHACO算法框架与经典的最大最小蚂蚁系统一致,但是候选解构建方式分为两种情况:如果是首次迭代,则按照首次迭代的信息素与启发因子来实现蚁群初始化,其算法复杂度为 $O(m \times r \times c)$,其中 m 为总蚂蚁数, r 是栅格地图的高度值, c 是栅格地图的宽度值;如果不是首次迭代,按照式(9)构建候选路径,其算法复杂度为 $O((\maxIter - 1) \times m \times r \times c)$, $\maxIter$ 表示算法最大迭代次数。因此,AHACO算法的总体复杂度为 $O(\maxIter \times m \times r \times c)$,经典MMAS算法复杂度为 $O(\maxIter \times m \times r \times c)$ 。由此可知,本文的AHACO算法并没有增加时间复杂度。

3.3 AHACO算法收敛性分析

关于蚁群算法收敛性的理论研究较少,刘广瑞等^[22]首先分析了移动机器人路径规划蚁群算法的基本原理,指出蚁群算法的优化过程具有马尔科夫性,然后对蚁群算法的收敛性进行深入分析,认为随着迭代过程的进行,蚁群算法以概率1收敛于最短路径。本文算法仅对经典MMAS的蚁群初始化与候选解构建进行改进,并对最优蚂蚁的控制参数进行突变操作替换最差蚂蚁的控制参数,算法框架及优化过程与经典MMAS是相同的,因此有理由相信所提算法能在有限步内以概率1收敛。

4 仿真实验与分析

为了验证AHACO算法的有效性,将其应用于机器人路径规划问题,在二维栅格环境中进行了一系列仿真实验。在二维栅格环境中,标记为“S”的栅格为路径起点,标记为“G”的栅格为目标位置。

由于蚁群算法具有概率优化的特点,为了得到可靠的结果,每个实验均独立运行30次,取均值作为实验结果。采用最优路径长度(用best表示)、平均路径长度(用mean表示)、标准偏差(sd)、首次迭代次数

(用 fbest 表示) 及得到最优路径的比例 (用 rate 表示) 等指标来评估算法的性能。在所有实验中, 用加粗方式突出显示每个评价指标的最优值。

4.1 参数设置

为了评估算法的有效性与优越性, 选择经典的最大最小蚂蚁系统 (MMAS)、蚁群系统 (ant colony system, ACS)、融合猫群算法的动态分组蚁群算法 (dynamic grouping ant colony algorithm combined with cat swarm optimization, CACS)^[15] 和混合粒子群蚁群优化算法 (hybrid particle swarm ACO, PS-ACO)^[23] 进行对比。CACS 算法利用动态分组机制将蚂蚁分为搜索蚂蚁和跟踪蚂蚁, 在某种程度上可认为是异构多蚁群算法。PS-ACO 算法将粒子群算法速度更新规则的个体最优与全局最优概念引入到蚁群算法的信息更新机制, 是典型的混合蚁群算法。

蚁群算法中有许多参数需要提前设置, 如蚂蚁数 m 、全局信息素挥发率 ρ 、局部信息素挥发率 ξ 、信息素启发参数 α 、启发信息参数 β 、最大迭代次数 $maxIter$ 、参数 q_0 。PS-ACO 算法中参数 c_1 与 c_2 均设置为 2, CACS 算法的环境适应度阈值设置为 0.7, 信息素扩散因子参数取值为 0.1。所有算法中蚂蚁数为栅格环境宽度的 2 倍, 最大迭代次数为 200, 其他参数设置如表 1 所示。

表 1 算法参数设置

Table 1 Parameter setting of algorithms

算法	α	β	ρ	ξ	q_0
MMAS	1.1	7	0.200	—	—
ACS	1.1	7	0.200	0.2	0.8
CACS	1.0	4	0.100	0.3	0.8
PS-ACO	1.0	2	0.015	—	—
AHACO	1.1	7	0.200	—	—

4.2 自适应信息交换周期的有效性验证

为了验证自适应信息交换周期的有效性, 分别在两种不同规模的二维栅格环境进行实验, 如图 4 和图 5 所示。其中 map1 与 map2 的大小分别为 (30×30) 和 (50×50), 红色为 AHACO 算法得到的最优路径。为了进一步说明自适应信息交换周期的优势, 还给出了异构蚁群算法采用不同信息交换周期和自适应信息交换周期的实验结果, 如表 2 和表 3 所示。

从表 2 可知, 不同信息交换周期的异构蚁群算法与 AHACO 在 map1 环境下均能得到最优路径, 但异构蚁群算法在信息交换周期为 4 时取得了最快的收敛速度, 而自适应异构蚁群算法需要更多的迭代次




图 4 map1 环境 AHACO 算法得到的最优路径

Fig.4 Optimal path generated by AHACO under grid map1




图 5 map2 环境 AHACO 算法得到的最优路径

Fig.5 Optimal path generated by AHACO under grid map2

表 2 map1 环境不同信息交换周期的实验统计结果

Table 2 Statistical results of different periods for information exchange in map1

信息交换周期	best	mean	std	fbest	rate/%
2	45.698 5	45.891 8	0.356 4	25.13	76.67
4	45.698 5	45.891 8	0.356 4	24.97	76.67
6	45.698 5	45.891 8	0.356 4	27.03	76.60
8	45.698 5	45.891 8	0.356 4	25.50	76.67
10	45.698 5	45.891 8	0.356 4	25.90	76.67
12	45.698 5	45.891 8	0.356 4	25.17	76.67
Adaptive	45.698 5	45.792 8	0.248 6	37.03	86.67

数才能得到最优解。虽然自适应异构蚁群算法在 map1 环境下收敛速度较慢, 但是在平均值与标准偏差两个评价指标上取得最好的表现, 更重要的是自

表3 map2 环境不同信息交换周期的实验统计结果

Table 3 Statistical results of different periods for information exchange in map2

信息交换周期	best	mean	std	fbest	rate/%
2	73.982 8	74.671 7	0.592 2	53.63	33.33
4	73.982 8	74.605 1	0.550 7	54.57	36.67
6	73.982 8	74.605 1	0.550 7	54.03	36.67
8	73.982 8	74.605 1	0.550 7	52.73	36.67
10	73.982 8	74.605 1	0.550 7	54.00	36.67
12	73.982 8	74.605 1	0.550 7	57.70	36.67
Adaptive	73.982 8	74.384 1	0.468 8	51.43	53.33

适应异构蚁群算法取得了最好的成功率,意味着在多次运行时,获得最优解的比例更高。

在更大规模的地图 map2 中,AHACO 算法的优化能力表现更加突出。由表 3 可以看出,异构蚁群算法采用不同信息交换周期与 AHACO 均能得到最优路径,但是 AHACO 在其他所有评价指标上获得最佳值,充分说明了自适应信息交换策略的有效性。

4.3 不同环境下的对比实验

为了验证 AHACO 的优越性及适应能力,选择四种不同规模的栅格环境进行对比实验,如图 6 所示,其中红色为 AHACO 算法得到的最优路径。实验结果如表 4 所示。

从表 4 可以看出,对于四种不同规模的栅格环境,所提出的 AHACO 算法所得到的路径长度均最短,说明算法具有较强的寻优能力。对于 map3 和 map4 两种环境,除 PS-ACO 算法外,其他算法均得到最短路径,但是随着地图规模的变大,得到最优路径的比例也在降低。对于路径长度均值及标准偏差两个评价指标而言,ACS 算法在 map3 和 map4 两个地图中表现较好,但是除 map4 地图外,AHACO 算法表现更为出色。随着地图规模的变大,AHACO 算法的优势更加明显,如 map5 和 map6 地图中,只有自适应异构蚁群算法得到的路径长度最短,对于其他评价指标,AHACO 算法也显示出较大的优势。




图6 不同规模环境下AHACO算法得到的最优路径

Fig.6 Optimal path generated by AHACO in grid maps with different scales

表4 不同环境下路径规划统计结果

Table 4 Statistical results of path planning under different grid maps

Environment	Algorithm	best	mean	std	fbest	rate/%	Environment	Algorithm	best	mean	std	fbest	rate/%
map3	MMAS	29.799 0	29.909 4	0.286 4	14.97	86.67	map5	MMAS	92.526 9	95.153 4	2.267 4	35.93	10.00
	ACS	29.799 0	29.799 0	0	32.57	100.00		ACS	91.698 5	93.848 2	1.094 4	117.10	3.33
	CACS	29.799 0	29.951 8	0.296 9	38.10	76.67		CACS	95.598 0	99.154 4	1.731 9	70.17	3.33
	PS-ACO	30.627 4	32.694 9	1.689 1	16.53	10.00		PS-ACO	95.840 6	100.912 0	3.260 0	40.00	3.33
	AHACO	29.799 0	29.799 0	0	19.20	100.00		AHACO	90.041 6	92.268 9	0.910 3	79.93	6.67
map4	MMAS	58.083 3	58.102 8	0.106 9	44.30	96.67	map6	MMAS	90.468 0	92.562 0	0.813 7	37.10	3.33
	ACS	58.083 3	58.083 3	0	16.40	100.00		ACS	90.124 9	91.820 0	0.848 7	74.63	3.33
	CACS	58.083 3	59.841 4	0.855 9	61.33	6.67		CACS	94.953 3	97.408 5	1.261 2	22.00	6.67
	PS-ACO	59.497 4	63.837 5	2.038 0	19.00	3.33		PS-ACO	93.781 7	99.417 4	3.162 2	90.66	3.33
	AHACO	58.083 3	58.259 0	0.273 0	44.13	70.00		AHACO	89.296 5	91.213 9	0.824 2	66.00	3.33

为了更好地展示 AHACO 算法的优化性能,这里给出不同环境下各种算法的收敛曲线,如图 7 所示。可以看出,AHACO 算法在 4 个地图中均找到最短路径。尽管 MMAS、ACS 及 CACS 算法在 map3 和 map4 两种环境也能找到最优路径,但是这些算法的收敛

速度不尽相同。在 map3 中 MMAS 算法具有较快的收敛速度,ACS 算法在 map4 中具有较快的收敛速度,而 AHACO 在两个地图中的收敛速度仅次于这两个算法。随着地图规模的增大,AHACO 呈现出更加明显的优势,在 map5 和 map6 两个地图中,不仅具有




图7 不同规模环境下的算法收敛曲线

Fig.7 Convergence curves of algorithms in grid maps with different scales

较快的收敛速度,而且最终找到的路径长度优于其他对比算法。PS-ACO算法在4个地图中均未能得到最优路径,从收敛曲线可以看出,PS-ACO算法早早地陷入局部最优。总体而言,本文所提出的改进策略是可行、有效的,不仅增强了算法的优化能力,还能提高算法的收敛速度。

为了进一步分析改进策略对蚁群算法优化性能的影响,图8给出了不同算法在优化过程中种群信息熵变化曲线。如前所述,种群信息熵可以用来衡量算法的多样性,因此信息熵的变化反映了算法优化过程中多样性的变化情况。

从图8的对比曲线可以看出,不同算法具有不同的信息熵变化过程。在整个优化过程中,AHACO算法的信息熵曲线呈现波动状态,种群呈现出较好的多样性,说明算法未出现停滞状态,或者是即使陷入局部最优,但是能顺利摆脱局部最优,算法始终具有较好的探索能力,显著地提高了算法寻优质量。其原因可归结为:(1)AHACO算法中每只蚂蚁都有独

立的控制参数,其个体行为呈现异构特点,能在保持局部寻优的基础上促使蚂蚁探索更大的问题空间,增强算法的全局寻优能力,图7的收敛曲线验证了这一点。(2)参数的突变操作在算法中引入随机性,有利于摆脱局部极值。这两个策略在优化过程中始终存在,增强了种群的多样性。其他算法的信息熵曲线尽管也有波动,但是波动范围没有AHACO算法的范围大,这说明所提出的改进策略能有效改进种群的多样性。从图8可以看出,PS-ACO算法在优化过程中具有较差的多样性,因而其寻优能力较差。

4.4 对比实验的统计检验

为保证结果具有统计意义,对实验结果执行统计检验。常用的检验方法有Wilcoxon符号秩检验与Friedman检验^[24]。Wilcoxon符号秩检验通常用于分析两个算法多次独立运行的结果之间是否存在显著性差异,当计算所得到的 p 值小于设定的显著性水平时,说明两个算法之间存在显著性差异,否则表示差异不明显。Friedman检验是利用秩对多个总体分




图8 不同规模环境下的种群信息熵曲线

Fig.8 Population information entropy curves in grid maps with different scales

布是否存在显著性差异的非参数检验方法。当其计算的 p 值小于给定的显著性水平时,认为各组样本存在显著差异,否则认为各组样本不存在显著性差异。在算法性能比较时,利用 Friedman 检验对多个算法的性能进行比较排名,算法取得的秩均值越小,说明该算法性能就越好。

为了检验 AHACO 算法与对比算法间是否存在显著性差异,将 AHACO 算法分别与其他对比算法进行 Wilcoxon 符号秩检验,30 次独立运行的最优值作为样本数据,显著性水平设置为 0.05,表中的符号“+”“=”和“-”分别表示 AHACO 算法性能优于、相似及弱于对比算法,统计结果如表 5 所示。

表 5 Wilcoxon 符号秩检验结果

Table 5 Results of Wilcoxon sign rank test

地图	AHACO vs. MMAS	AHACO vs. ACS	AHACO vs. CACS	AHACO vs. PS-ACO
map3	4.55E-02 +	1.00E+00 =	1.39E-02 +	1.57E-06 +
map4	1.14E-02 +	2.70E-03 +	1.17E-05 +	1.17E-05 +
map5	6.60E-06 +	3.55E-05 +	1.73E-06 +	1.73E-06 +
map6	3.43E-05 +	3.05E-02 +	1.73E-06 +	1.73E-06 +
+/-/-	4/0/0	3/1/0	4/0/0	4/0/0

从表 5 可以看出,相对于 MMAS、CACS 及 PS-ACO 算法,本文算法在 4 个地图的路径规划中均表现出显著性的差异;对于 ACS 算法,所设计的 AHACO 算法仅在 map3 具有相似的优化性能,在其他 3 个地图中依然具有显著性差异。

为了从总体上验证 AHACO 算法的优越性,依据表 4 中的数据进行 Friedman 检验,显著性水平设置为 0.05,统计结果如表 6 所示。

表 6 Friedman 检验结果

Table 6 Results of Friedman test

p value	AHACO	MMAS	ACS	CACS	PS-ACO
0.006	1.625	2.750	1.625	4.000	5.000

从表 6 可以看出, Friedman 检验得到的 p 值为 0.006,小于设定的显著性水平,因此 AHACO 算法与对比算法之间存在显著性差异。此外,统计结果表明 AHACO 算法得到的平均秩为 1.625,在所有算法中为最小值,表明 AHACO 算法的优化性能最好。

结合 Wilcoxon 符号秩检验与 Friedman 检验的结果可知, AHACO 算法表现出较好的优化性能,从总体上显著优于对比算法。

5 结束语

本文提出了一种单种群自适应异构蚁群算法并应用于移动机器人路径规划问题。算法首次迭代时仅以启发信息来构建候选解,以提高初始蚁群的质量;之后每只蚂蚁使用各自的控制参数构建候选解,增强种群的多样性。根据种群信息熵自动调整信息交换周期,提高算法适应能力。信息交换策略与参数突变机制不仅能发挥最优蚂蚁的引导作用,提高算法的优化能力,而且有助于算法在更大的参数空间探索更优的算法参数。二维环境下移动机器人路径规划仿真实验说明了该算法的有效性与适应能力。统计检验的结果验证了算法的优越性。本文在进行信息交换与参数突变时仅考虑了最优蚂蚁的参数 α 与 β ,未来研究中将考虑最优以及迭代最优蚂蚁的特征用于信息交换。同时,也需要进一步研究其他参数的突变机制与新的信息交换策略。

参考文献:

- [1] PEYER S, RAUTENBACH D, VYGEN J. A generalization of Dijkstra's shortest path algorithm with applications to VLSI routing[J]. Journal of Discrete Algorithms, 2009, 7(4): 377-390.
- [2] GURUJI A K, AGARWAL H, PARSEDIYA D. Time-efficient A* algorithm for robot path planning[J]. Procedia Technology, 2016, 23: 144-149.
- [3] 黄鲁, 周非同. 基于路径优化 D* Lite 算法的移动机器人路径规划[J]. 控制与决策, 2020, 35(4): 877-884.
HUANG L, ZHOU F T. Path planning of moving robot based on path optimization of D* Lite algorithm[J]. Control and Decision, 2020, 35(4): 877-884.
- [4] SINGH M K, PARHI D R. Path optimisation of a mobile robot using an artificial neural network controller[J]. International Journal of Systems Science, 2011, 42(1): 107-120.
- [5] KARAMI A H, HASANZADEH M. An adaptive genetic algorithm for robot motion planning in 2D complex environments[J]. Computers & Electrical Engineering, 2015, 43: 317-329.
- [6] LEE H Y, SHIN H, CHAE J. Path planning for mobile agents using a genetic algorithm with a direction guided factor[J]. Electronics, 2018, 7(10): 212.
- [7] PRADHAN S K, PARHI D R, PANDA A K. Fuzzy logic techniques for navigation of several mobile robots[J]. Applied Soft Computing, 2009, 9(1): 290-304.
- [8] LI G, CHOU W. Path planning for mobile robot using self-adaptive learning particle swarm optimization[J]. Science China Information Sciences, 2018, 61(5): 052204.
- [9] 王晓燕, 杨乐, 张宇, 等. 基于改进势场蚁群算法的机器人

- 路径规划[J]. 控制与决策, 2018, 33(10): 1775-1781.
- WANG X Y, YANG L, ZHANG Y, et al. Robot path planning based on improved ant colony algorithm with potential field heuristic[J]. Control and Decision, 2018, 33(10): 1775-1781.
- [10] 朱佳莹, 高茂庭. 融合粒子群与改进蚁群算法的AUV路径规划算法[J]. 计算机工程与应用, 2021, 57(6): 267-273.
- ZHU J Y, GAO M T. AUV path planning based on particle swarm optimization and improved ant colony optimization[J]. Computer Engineering and Applications, 2021, 57(6): 267-273.
- [11] 陈雄, 袁杨. 一种机器人路径规划的蚁群算法[J]. 系统工程与电子技术, 2008, 30(5): 952-955.
- CHEN X, YUAN Y. Novel ant colony optimization algorithm for robot path planning[J]. Journal of Systems Engineering and Electronics, 2008, 30(5): 952-955.
- [12] BAI J, YANG G K, CHEN Y W, et al. A model induced max-min ant colony optimization for asymmetric traveling salesman problem[J]. Applied Soft Computing, 2013, 13(3): 1365-1375.
- [13] LEE J. Heterogeneous-ants-based path planner for global path planning of mobile robot applications[J]. International Journal of Control, Automation and Systems, 2017, 15(4): 1754-1769.
- [14] SREEJA N, SANKAR A. A hierarchical heterogeneous ant colony optimization based approach for efficient action rule mining[J]. Swarm and Evolutionary Computation, 2016, 29: 1-12.
- [15] 张德惠, 游晓明, 刘升. 融合猫群算法的动态分组蚁群算法[J]. 计算机科学与探索, 2020, 14(5): 880-891.
- ZHANG D H, YOU X M, LIU S. Dynamic grouping ant colony algorithm combined with cat swarm optimization[J]. Journal of Frontiers of Computer Science and Technology, 2020, 14(5): 880-891.
- [16] ZHANG D, YOU X, LIU S, et al. Dynamic multi-role adaptive collaborative ant colony optimization for robot path planning[J]. IEEE Access, 2020, 8: 129958-129974.
- [17] GÜLCÜ Ş, MAHI M, BAYKAN Ö K, et al. A parallel cooperative hybrid method based on ant colony optimization and 3-Opt algorithm for solving traveling salesman problem[J]. Soft Computing, 2018, 22(5): 1669-1685.
- [18] 万正宜, 彭玉旭. 求解旅行商问题的改进型量子蚁群算法[J]. 计算机工程与应用, 2016, 52(22): 59-63.
- WAN Z Y, PENG Y X. Improved quantum ant colony algorithm for traveling salesman problem[J]. Computer Engineering and Applications, 2016, 52(22): 59-63.
- [19] MAHI M, BAYKAN Ö K, KODAZ H. A new hybrid method based on particle swarm optimization, ant colony optimization and 3-opt algorithms for traveling salesman problem[J]. Applied Soft Computing, 2015, 30: 484-490.
- [20] STÜTZLE T, HOOS H H. MAX-MIN ant system[J]. Future Generation Computer Systems, 2000, 16(8): 889-914.
- [21] 张松灿, 普杰信, 司彦娜, 等. 基于种群相似度的自适应改进蚁群算法及应用[J]. 计算机工程与应用, 2021, 57(8): 70-77.
- ZHANG S C, PU J X, SI Y N, et al. Adaptive improved ant colony algorithm based on population similarity and its application[J]. Computer Engineering and Applications, 2021, 57(8): 70-77.
- [22] 刘广瑞, 刘军, 孔令云. 移动机器人路径规划蚁群算法及其收敛性分析[J]. 郑州大学学报(工学版), 2012, 33(2): 24-27.
- LIU G R, LIU J, KONG L Y. Ant colony algorithm of path planning for robot and its convergence analysis[J]. Journal of Zhengzhou University (Engineering Science), 2012, 33(2): 24-27.
- [23] SHUANG B, CHEN J, LI Z. Study on hybrid PS-ACO algorithm[J]. Applied Intelligence, 2011, 34(1): 64-73.
- [24] DERRAC J, GARCÍA S, MOLINA D, et al. A practical tutorial on the use of nonparametric statistical tests as a methodology for comparing evolutionary and swarm intelligence algorithms[J]. Swarm and Evolutionary Computation, 2011, 1(1): 3-18.



张松灿 (1973—), 男, 河南郑州人, 博士研究生, 主要研究方向为群智能算法、移动机器人智能控制。

ZHANG Songcan, born in 1973, Ph.D. candidate. His research interests include swarm intelligence algorithms and intelligent control of mobile robot.



孙力帆 (1982—), 男, 河南洛阳人, 博士, 副教授, 主要研究方向为扩展目标跟踪、信息融合。

SUN Lifan, born in 1982, Ph.D., associate professor. His research interests include extended target tracking and information fusion.



司彦娜 (1990—), 女, 河南郑州人, 博士研究生, 主要研究方向为强化学习、机器人智能控制。

SI Yanna, born in 1990, Ph.D. candidate. Her research interests include reinforcement learning and intelligent control of robot.



普杰信 (1959—), 男, 河南周口人, 博士, 教授, 博士生导师, 主要研究方向为智能信息处理、机器人智能控制。

PU Jiexin, born in 1959, Ph.D., professor, Ph.D. supervisor. His research interests include intelligent information processing and intelligent control of robot.