

基于改进的蚁群算法(ACO)的 混合多目标 AGV 调度

李鹤^{1,2}, 姜德文²

(1. 沈阳工学院 辽宁省数控机床信息物理融合与智能制造重点实验室, 辽宁 抚顺 113122;

2. 沈阳工学院 信息与控制学院, 辽宁 抚顺 113122)

摘要: 蚁群算法是一种通过模拟蚁群的寻路行为对现实问题进行优化的现代智能仿生算法; 对实现 AGV 任务作业调度时, 行驶路径最短的实际应用需求, 研究中将 AGV 的路径优化模型转化为旅行商问题, 分析了多目标 AGV 优化中出现的冲突问题; 实验中, 尝试了一种直接通信机制来进行改进传统算法, 改进后的方法能够更好地维持种群的持久性, 最终对于 AGV 调度规划起到积极的作用, 有效地提高了 AGV 调度系统的效率。

关键词: 车辆调度; 组合优化; ACO 算法; AGV 调度

Research on Hybrid Multi-objective AGV Scheduling Based on Improved Ant Colony Algorithm

Li He^{1,2}, Jiang Dewen²

(1. Liaoning Provincial Key Laboratory of Information Physics Fusion and Intelligent Manufacturing for
Grade CNC Machine, Shenyang Institute of Technology, Fushun 113122, China;

2. College of Information and Control, Shenyang Institute of Technology, Fushun 113122, China)

Abstract: Ant colony algorithm is a modern intelligent bionic algorithm that optimizes real problems by simulating the ant colony's path finding behavior. In order to realize the shortest path requirements of AGV task scheduling, the experiment transforms the path optimization model of AGV into a traveling salesman problem, and analyzes the conflicts in multi-target AGV optimization. To solve the problem, a direct communication mechanism is tried to improve the traditional algorithm. The improved method can better maintain the persistence of the population. Finally, it plays an active role in the AGV scheduling and effectively improves the AGV scheduling system.

Keywords: vehicle scheduling; combinatorial optimization; direct communication mechanism; AGV

0 引言

自动导引车 (automated guided vehicle, AGV)^[1] 属于一种依靠电池进行供电、配置有自动引导系统的新型小型自动化移动机器人, 它能按照预加载的行驶路线自主驱动完成预设的搬运目标。

AGV 多目标优化问题属于典型的性能优化问题, 在实际工作中操作十分困难, 传统方法的一个缺点就是对目标函数具有苛刻的形式要求。针对 AGV 多目标优化问题的痛点和难点, 大量研究学者提出了各自的优化算法, 其中比较经典的有多目标粒子群优化算法^[2], 人工神经网络算法^[3], 协同多目标进化算法^[4]等。在 1992 年, Dorigo 等人通过模拟自然界中蚂蚁集体的寻路本能的行为首次提出了一种基于种群的启发式仿生算法, 即蚁群算法 (ant colony optimization, ACO)。

本文研究了一种改进信息交互机制的蚁群算法来求解多目标调度问题, 对信息素的更新方式进行了优化, 在一定程度上提高了蚂蚁种群的多样性, 实验结果证明, 改进后的方法有效提高了传统蚁群算法的寻优能力。通过对 AGV 路径优化的关键技术进行研究, 可以有效的提高运货效率和节省运送成本。

1 传统蚁群算法求解 AGV 调度问题

1.1 蚁群算法

在真实的蚁群当中, 大量个体所组成的蚁群却展现出相当复杂的群体结构和群体行为。蚁群算法模拟了真实的蚂蚁之间的相互协助寻找食物的过程。在候选的解空间中, 单只蚂蚁需要独立地进行路线搜寻, 生物学家通过众多对比实验探究得到, 蚂蚁个体间通过一种具有一定挥发时间的外激素进行不同个体间的信息交互。

单个蚂蚁在每个搜寻的路径上留存一定浓度信息素, 路径上保留的信息素越多意味着路径的候选概率也越大。随着时间的逐渐推移, 如果信息素的挥发度较大, 则某些长时间没有蚂蚁搜索的路径上的信息素会逐渐消失; 相反, 当挥发度较小时, 已经被搜索过的线路会以较大的概率被

收稿日期: 2018-11-26; 修回日期: 2018-12-19。

基金项目: 沈阳工学院校级基金(5201801)。

作者简介: 李鹤(1981-), 男, 辽宁沈阳人, 硕士, 副教授, 主要从事机器人控制, 机器视觉算法方向的研究。

重新选择, 因此所设定的挥发因子会对算法的最优解产生一定的影响。

通过文献[5-6]中的例子说明蚁群系统的工作原理, 如图 1 所示, 假设 A 是蚂蚁巢穴, E 是食物的位置, 蚁巢与食物之间存在一个障碍物 HC 。

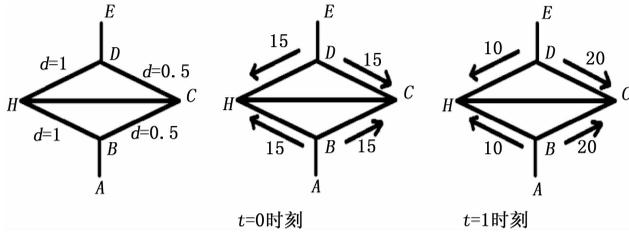


图 1 蚁群系统示意图

由于障碍物的存在, 当 A 从 E 到的时候只能先经过 H 或 C 。现在假设每个时间单位有 30 只蚂蚁初始从 A 端行进到 B 端, 同时有 30 只蚂蚁初始从 E 端行进到 D 端, 单个个体经过后产生单位为 1 的信息素, 同时给定单个个体所留下的信息素存在时间同样为 1。

第一步: 初始状态。由于其余路径各条路径上均无信息素存在, 则位于 B 点和 E 点的蚂蚁会随机选择路径。按照统计学的角度来看, 蚂蚁会以相同的概率选择 BH 、 BC 、 DH 、 DC 四条路径。

第二步: 当经过了一个时间单位后, BCD 上的信息素的累积量是 BHD 上信息素的一倍。当 $t=1$ 时, 会有约为 $2/3$ 的蚂蚁从 B 和 D 到达 C 点, 另外约 $1/3$ 只蚂蚁到达。随信息素的积累, 蚂蚁将会以越来越大的概率选择路径 BCD , 最终后来的所有个体能够确定出整个搜寻过程的最佳路径, 即找到了由起始位置到终点的最优路径 BCD 。因此对于整个过程来说, 蚂蚁个体之间的信息交换是一个正反馈过程。

1.2 针对 AGV 多目标调度的蚁群算法建模

蚁群算法应用于 AGV 多目标调度问题^[7], 可以概括为通过预先给出所有的需求点, 最终 AGV 回到初始位置, 使得付出的运输路径成本最小。假设 AGV 需要到达的装载点的个数为 n , 初始出 m 个个体探索整个调度过程的最优路线。

当时间为 t 时, 第 k 个个体从第 i 号装载点到第 j 号装载点进行转移, 转移概率 P 能够用下式进行表示。

$$P_{ij}^k = \begin{cases} \tau_{ij}^k(t) \cdot \eta_{ij}^k(t) & \sum_j \tau_{ij}^k(t) \cdot \eta_{ij}^k(t) \\ 0 & otherwise \end{cases}$$

上述公式中, 蚂蚁编号 $k=1, 2, \dots, M$, 城市位置 $i, j=1, 2, \dots, N$, 设 $\tau_{ij}^k(t)$ 定为两个城市 i 和 j 之间路径上蚂蚁留存的信息素 $\eta_{ij}^k(t)$, 可以定义为启发信息, 它代表了 t 时刻城市 i 和 j 上残余的信息量, 根据启发信息与距离的关系, 可以简单的表示为 $\eta_{ij}^k(t) = 1/d_{ij}$ (d_{ij} 表示城市 i 和 j 之间的距离), 如果给需要给定某一路径的相对重要程度, 可以用 α 进行表示路径权值, β 表示路径能见度的相对重要性。到 t 时刻, 蚂蚁 k 仍未经过的城市的集合表示为

allowed。

在进行路径探索时, 依据每条路径上信息素的浓度, 目标可以确定下一时刻的方向, 并且当选择了下一方向时, 会在当前路径上留下信息素来标定已经走过当前路线, 由于传统算法中的解容易陷入局部最优值, 因此为了到达表现结果更好的全局最优值, 可以按照下列方式调整信息素的浓度, 从而控制其挥发过程。

$$\tau_{ij}(t+1) = \rho \tau_{ij}(t) + \tau_{ij}(t)$$

$$\Delta \tau_{ij}(t) = \sum_{k=1}^M \Delta \tau_{ij}^k(t)$$

上述公式中, ρ 代表了信息素的挥发系数, ρ 属于 $[0, 1]$, 信息素的挥发使未被选择路径上的浓度进行一定程度的减小, 这个过程便可以减小陷入局部最优的几率, $\Delta \tau_{ij}^k(t)$ 表示了第 k 个个体在搜寻过程中所留下的信息素的量, 因此这个值与单个个体经过的路径总长度有关联。

1.3 求解多目标问题的基本模型

对于多目标优化问题, 考虑到决策变量为可以采用如下算法进行描述^[8]。假设是维欧几里得空间中的非空集合:

$$f(x) = (f_1(x), f_2(x), \dots, f_m(x))^T$$

是 n 维空间中的 m 维向量函数, 并且有:

$$g(x) = (g_1(x), g_2(x), \dots, g_m(x))^T$$

$$h(x) = (h_1(x), h_2(x), \dots, h_m(x))^T$$

分别是 S 上的 p 维和 q 维向量函数, 则在约束条件:

$$g_i(x) \leq 0 \quad (i = 1, 2, 3, \dots, p)$$

$$h_j(x) = 0 \quad (j = 1, 2, 3, \dots, q)$$

下, 以 $f_1(x), f_2(x), \dots, f_m(x)$ 为目标函数的有限 m 维多目标优化问题可以记作:

$$\min/\max f(x) = F(x) = (f_1(x), f_2(x), \dots, f_m(x))^T,$$

$$m = 1, 2, 3, \dots, k$$

s.t. $g_i(x) \leq 0, i = 1, 2, 3, \dots, p; h_j(x) = 0, j = 1, 2, 3, \dots, q$

$f(x)$ 是与目标函数有关的函数, 最终转化为求解 $f(x)$ 的最大值或最小值问题, 根据上式寻找满足条件的矢量解。

AGV 作业调度的本质就是利用多个 AGV 去实现多个任务的合理分配过程, 因此最终目的是为了优化整个调度过程, 寻求完成大量作业的最佳解决方案和先后顺序, 并保证在完成给定作业的前提下, 总的执行路径最短。

2 改进的求解多目标优化问题蚁群算法

2.1 全局最优的寻优方式

多个目标之间往往是相互约束、相互排斥的, 其中某些目标的改善往往会造成另一些目标的恶化, 因此各个目标很难同时达到最优^[9]。而在实际问题当中, 多目标问题的解的优劣往往是相对的, 难以达到所谓的绝对最优, 只能达到相对最优值。求解这类问题往往只能得到一组最优解集, 解集内部无法进一步比较, 这样的解集一般称为 Pareto 最优解。实际求解当中, 要求得到的解集具有较好的均匀性。

为了更好地指导目标进行搜索, 定义一个集合 $A(t)$

来保存整个蚁群经过多次迭代后得到的所有 Pareto 解集。

假设当前集合 $A(t)$ 中有 p 个不可支配的解 x ,

$$x = (x_1, x_2, \dots, x_p)$$

若有:

$$i \in A(t)$$

则个体目前所在的区域不能被群体所支配, 需要适当增大当前个体所释放的信息素的量, 使得其他蚂蚁会更加关注第 i 个个体所在的位置区域; 相反的, 如果第 i 个个体不属于集合 $A(t)$, 那就应当减小信息素的浓度。

当多个蚂蚁同时进入 $A(t)$ 时, 可以利用最新进入 $A(t)$ 的个体与之前集合中所求出的目标函数值之间的最小距离作为第 i 个个体所在的区域, 同时在此区域内释放更多信息素, 实现对单个个体的信息素增量的区分。在上述过程中, 可以用下式进行表示最小距离:

$$\theta(t) = \min \sqrt{\sum_{i=1}^n (f_i(x) - f_i(x_v))^2}$$

因此, 可以重新定义蚁群算法的信息素:

$$\tau_i(t+1) = \begin{cases} \rho\tau_i(t) + \theta(t), & x \in A(t+1) \\ \rho\tau_i(t) & otherwise \end{cases}$$

其中: ρ 为挥发系数。

在解决全局优化的问题时, 一般无法在解空间的分布信息中得到全局的最优解, 因此最好的情况是蚂蚁在解空间中的分布是相对均匀的, 蚁群分布越均匀则越有利于后续的算法在实现中均匀地扫描解空间, 从而得到最优解。一个有效的方法是首先将解空间划分为许多个子区域, 在每个子区域中按照一定比例分配初始蚂蚁, 蚂蚁最初只在当前的子区域中进行搜索, 当局部搜索完成后, 每个蚂蚁按照当前的信息素信息对全局进行移动搜索, 当每次完成循环后, 重新对信息素的浓度进行更新, 最终达到迭代终止条件。

2.2 改进的转移概率和新型学习机制

在多目标优化算法中, 最优解会与每只蚂蚁的信息素留存直接相关, 不同方向的信息素留存量会直接影响到第 i 个个体的下一步移动区域^[10-11], 往往距离短和浓度高的区域会被以更高概率所选择, 此时的移动概率可以表示为:

$$P_{ij}^k =$$

$$\begin{cases} \frac{[\tau(j)]^\alpha \cdot e^{-\beta d_{ij}}}{\sum [\tau(j)]^\alpha \cdot e^{-\beta d_{ij}}} & (d_{ij} < 0 \cap i \neq j) \cup (d_{ij} = 0 \cap i = 1) \\ 0 & otherwise \end{cases}$$

$$d_{ij} = f(x_i) - f(x_j)$$

在上述公式中, α 和 β 作为一项权值, 表明了节点上信息素重视程度和根据两点距离因素得到的启发式信息受重视程度。上述公式表明, 第 i 只蚂蚁尽可能地向更好的领域移动, 如果没有更好的区域进行移动, 蚂蚁则会尽可能地依旧停留在原处, 作为下一次移动的初始位置。

通过以上的分析可以看出, 进行信息素的更新可以在一定程度上增强选择出的最优个体的路径搜索能力, 从而使得蚂蚁可以更快更有效地搜索出最佳的路径。但是, 尽

管最优个体的搜索能力得到了提升, 如果仅仅靠最优个体去寻找最佳路径, 则搜索能力仍然有所局限, 为了进一步加强其他所有普通个体的搜寻能力, 可以采用一定的信息交互机制, 使得除最优个体之外的个体也能实时更新信息素。

这项研究模拟了群体内的不同个体相互利用彼此的触角实现信息的传递和分享的能力, 从只提升单个最优个体路径搜索能力到对整个蚁群路径搜索能力的提高, 将这种特殊的信息交互机制所定义的信息素浓度的更新规则用如下公式表示。

$$\tau(i) = \rho\tau(i) + \eta\tau(j)$$

通过上述公式可以看出, 在每次进行全局最优解的搜索后, 不仅局限于得到最优解的个体, 还会随机选择某一其他个体 i 来实现对信息素的更新。在上式中, η 代表了个体 i 向最优个体 j 学习的能力, 定义为学习因子。 ρ 为挥发的系数, 意味着信息的持久性。当学习因子越高时, 意味着当前个体越可能按照之前的最优解进行移动, 从而使得每个普通个体都从最优个体处得到一定的收益; 而当挥发系数越高时, 则代表信息素会以更快的速度消散, 导致该处所吸引的蚂蚁的能力降低, 因此在实际应用中, 应合理地选择信息交互机制中的参数。

3 实验仿真及结果

3.1 实验描述

实际 AGV 工作过程中, 整个 AGV 调度系统通过中央调度系统配置服务器对 AGV 进行任务分配, AGV 调度系统架构如图 2 所示。在本次实验过程中采用 Matlab 进行仿真和测试。

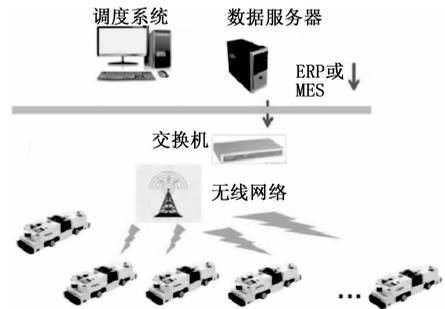


图 2 AGV 调度系统架构图

为了进行验证改进后的算法是否能够尽快收敛到求解多目标优化问题的最优解, 分别设置传统蚁群算法和改进后的蚁群算法进行对比。在连续空间的优化问题中, 可以适当提高蚂蚁的数量。

对于实验中的其他各项参数, 设置 M 为 60, 对于改进后的直接通信方式中, 设置其交叉概率设置为 0.95, 变异概率设置为 0.05, 对于信息素的挥发程度给定参数为 0.2。为了进行公平的对比, 在进行实验仿真时采用相同的群体规模。同时, 对于不同配送点之间的转移概率, 通过轮盘赌的方式进行配送点转移选择, 选择这种方法可以更有效

地通过概率进行优化转移。初始各配送点的坐标如图 3 所示。

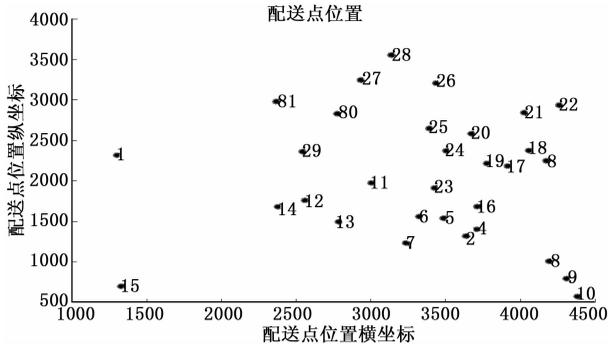


图 3 不同配送点位置坐标

3.2 实验结果

将蚁群算法和改进后的蚁群算法比较，由于算法本身为随机优化算法，因此选择进行多次优化，每次优化迭代设置相同的迭代次数 400 次。得到结果如图 4~5 所示，可以看出随着迭代次数的增加，整个过程中算法具有较快的收敛速度，仅仅在 50 次迭代后，最短距离就已经基本不在变化。

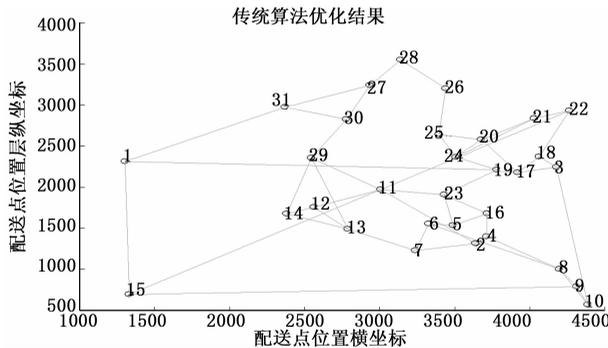


图 4 传统算法最优路径规划

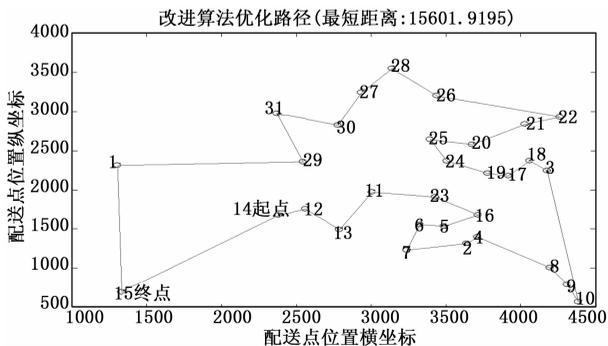


图 5 改进算法最优路径规划

图 4 和图 5 为传统蚁群算法和改进后的蚁群算法分别求解最优路径的结果，从左图中可以直观看出，对于传统算法，进行 AGV 调度时，路径选择更加复杂，产生不稳定的结果，容易陷入局部最优解，导致花费更多的运输成本，降低了整个调度的效率。而从改进后的算法可以看出，此时的规划路径更加清晰，总调度距离明显要优于传统算法。

之后进行各代最短距离和平均距离的对比，如图 6 和图 7 所示。

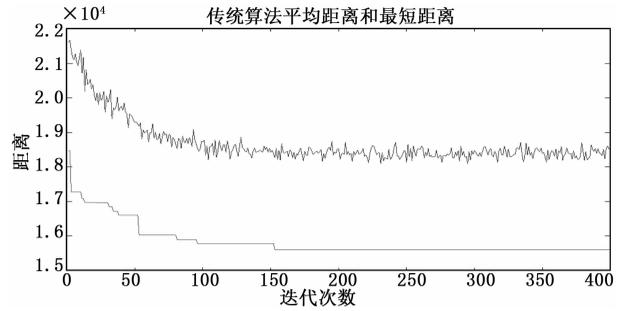


图 6 平均距离随迭代次数的变化对比 (传统算法)

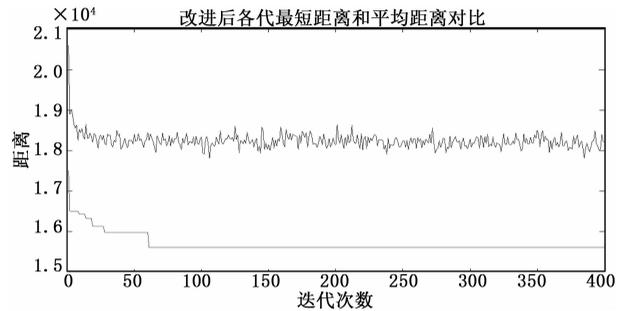


图 7 平均距离随迭代次数的变化对比 (改进算法)

从图中可以看出，传统算法需要 100 次迭代后逐渐趋于稳定值，而改进算法仅需要约 50 代便可收敛，具有较好的收敛速度和收敛精度，在达到最终迭代效果后，可以看出，改进后算法平均距离要小于传统算法，能够有效地提高 AGV 调度的效率，降低运送成本。

4 结论

针对 AGV 调度优化中常出现的陷入局部最优的问题，本文研究了一种采用知识性信息素更新方法和改进转移概率与直接学习机制的蚁群算法。利用 AGV 调度来模拟蚂蚁交流信息的过程，从而实现 AGV 的直接通信学习机制，通过这种方法更新后的信息素可以更好地维持整个群体的多样性，最终实现 AGV 调度优化问题中的最优解。

本文以 AGV 多目标优化调度为模型，对运货车的配送调度问题进行了分析和探讨，建立了简洁的数学模型对复杂的问题进行简化和分析。在实验中，除了对局部最优解进行信息素更新，也利用了其他非最优解间的直接通信学习机制，这种学习机制能够有效提高种群的持久性，从而选择出更优秀的个体，趋近于最优解。通过实际实验对比，设置在相同的参数条件下，改进后的蚁群算法具有更好的性能表现，是一个能更有效地解决车辆调度路径优化问题的算法。

采用直接通信机制的蚁群算法可以有效地解决 AGV 任务作业调度问题，这种方法不仅提高了运货效率，并且节省了运送成本，对 AGV 调度管理有很好的指导意义，本文

(下转第 230 页)