

# 改进蚁群算法的局部信息动态路径规划

赵峰<sup>1</sup>, 杨春曦<sup>1</sup>, 陈飞<sup>1</sup>, 黄凌云<sup>2</sup>, 谈诚<sup>2</sup>

(1. 昆明理工大学 化学工程学院, 昆明 650500; 2. 昆明理工大学 国土资源工程学院, 昆明 650093)

**摘要:** 针对传统蚁群算法收敛速度慢、对动态路径变化适应性低的局限性, 提出了一种基于局部信息获取策略的动态改进型蚁群算法。该算法利用局部信息获取策略, 进行最优局部目标点的获取, 然后调用改进蚁群算法获取局部区域内的最优路径, 再重复循环获取新的最优局部目标点, 直到找到全局目标点; 与此同时, 将提出的改进型蚁群算法应用于动态路径规划中的路径寻优与避障, 仿真结果表明: 提出的算法在具有与传统蚁群算法相当的路径优化效果的同时, 能够有效适应障碍变化、大大提高了路径规划的收敛速度。

**关键词:** 蚁群算法; 局部信息; 局部目标点; 动态路径规划

## Local Information Dynamic Path Planning Based on Improved Ant Colony Algorithm

Zhao Feng<sup>1</sup>, Yang Chunxi<sup>1</sup>, Chen Fei<sup>1</sup>, Huang Lingyun<sup>2</sup>, Tan Cheng<sup>2</sup>

(1. Kunming University of Science and Technology, Faculty of Chemical Engineering, Kunming 650500, China;

2. Kunming University of Science and Technology, Faculty of Land Resource Engineering, Kunming 650093, China)

**Abstract:** Considering the limitation of traditional ant colony algorithm's slowish convergence and bad self-adaptability to dynamic path change, a dynamic improved ant colony algorithm based on local information acquisition strategy is proposed in this paper. Firstly, The local information acquisition strategy is used to obtain the optimal local target point. Then, the improved ant colony algorithm is called to obtain the optimal path in the local region. And the new optimal local target point of the neighbor region is obtained by repeating the loop until the global target point is found. Moreover, the improved ant colony algorithm is applied to the path optimization and obstacle avoidance in dynamic path planning. The simulation results show that the new algorithm proposed not only has considerable path optimization performance compared with the traditional ant colony one, but also has self-adaptive capacity faced with time-vary obstacles and faster convergence speed.

**Keywords:** ant colony algorithm; local information; local target point; dynamic path planning

## 0 引言

路径规划是移动机器人研究领域的一个重要分支<sup>[1-3]</sup>, 它的宗旨就是在有障碍物的路径中, 在能够有效避免障碍物的前提下, 寻找一条从给定起始点到给定终止点的最优的路径。其中最优指标既可以是距离最短, 又可以是时间最短, 还可以是带有权值的二者的结合, 而障碍物可以分为静态障碍物和动态障碍物。因此, 开展对该领域的研究对于科学实验、救援抢险、防爆、排雷等工程实施均具有重要意义<sup>[4]</sup>。由于最优路径问题计算复杂度高, 使得传统算法在面对规模较大、实时性较强的问题时, 搜索效率较差<sup>[5]</sup>。而蚁群算法与其他启发式算法相比, 在求解性能上具有很强的鲁棒性和计算复杂度低等特点。因此, 该算法被广泛应用于解决旅行商<sup>[6-7]</sup>、车间调度<sup>[8-9]</sup>等问题的研究。

## 1 问题描述

由于采用传统蚁群算法 (Traditional Ant Colony Algorithm, T-ACA) 对静态障碍物问题的研究相对成熟, 因此, 人们在使用 T-ACA 进行路径寻优取得了一定效果。但 T-ACA 也存在一定的局限性, 比如 T-ACA 会在机器人出发前设置几十只甚至上百只蚂蚁用来搜索最优路径, 而且在此基础上还要进行迭代几十次甚至上百次, 这样要花费大量的时间和计算资源。在路径寻优完成后, 机器人将沿着搜寻到的一条最优路径行走。如果路径中的障碍情况发生变化, 则原来搜寻到的最优路径就已经过时, 还要再重新进行路径寻优。在这种情况下既没能够避开动态障碍, 也浪费了时间。针对 T-ACA 在此方面的缺陷, 国内外各方面的研究学者进行了相应的动态路径规划方面的探索。

## 2 相关工作

文献 [10] 从 T-ACA 中得到启发, 限制信息素的上下限, 在动态路径规划过程中, 对动态障碍物进行了膨化处理, 通过减小相应的膨化区域, 进一步检测碰撞是否发生最终获取无碰最优路径。文献 [11] 引入人工势场的概念, 为目标点定义吸引势能, 障碍物定义排斥势能, 机器人在势能的引导下可以从起点出发, 避开障碍物, 达到目标点。仿真结果表明, 其算法能够适用于动态路径规划。文献 [12] 借鉴狼群分配原则, 即: 剔除掉最差路径上蚂蚁释放的信息素。仿真结果结果

收稿日期: 2017-01-19; 修回日期: 2017-02-27。

基金项目: 国家自然科学基金 (61364002); 云南省教育厅科学研究基金 (2016YJS020)。

作者简介: 赵峰 (1990-), 男, 河北秦皇岛人, 硕士研究生, 主要从事智能算法方向的研究。

通讯作者: 杨春曦 (1976-), 男, 贵州松桃人, 博士, 教授, 主要从事网络控制系统, 智能控制方向的研究。

表明了该方法的可行性和有效性。

文献 [13] 的核心思想在于如何求得移动障碍物的线性函数, 进而避开移动障碍物。仿真结果表明, 该算法具有高实时性, 而且非常适合在复杂和动态环境实时导航。文献 [14] 针对车辆路径规划问题, 将 A\* 算法与 T-ACA 相结合, 并且在蚂蚁走进“死胡同”到走出死胡同这条局部路径上不释放信息素, 降低了其他蚂蚁走进“死胡同”的概率。仿真结果表明, 改进算法不仅具有很好躲避动态障碍的能力, 而且具有较短的寻优时间。

上述与 T-ACA 算法相关的研究, 虽然取得了一定的效果, 但是都采用了二次规划的思想, 即: 首先进行一次静态规划, 再进行一次动态规划, 虽然在避障效果方面有了大幅提高, 但与此同时, 计算复杂度和寻优时间也成比例的提高, 而且也没有以某个具体的环境背景为参考变量。因此, 本文, 以城市某个区域内交通环境为切入点, 侧重于整个区域内的各个路口的交通实时状态更新与规划, 将交通环境简化为栅格地图的形式, 路口的拥堵状况简化为各个栅格变换状况, 并假设各个路口的交通只会在拥堵和畅通两个状态之间切换, 不需要考虑各种如速度、加速度等运动状态变化状况, 提出了一种改进蚁群算法的局部信息动态路径规划算法 (Local Information Dynamic Path Planning Based on Improved Ant Colony Algorithm, LD-ACA), 该算法采用边走边规划的方式能够充分利用局部信息动态规划行走路径, 具有良好的动态环境适应性和较低的计算复杂度。

### 3 LD-ACA 实施步骤

#### 3.1 基本定义

记  $G$  为机器人在二维平面内的运动区域, 机器人映射实际交通环境中具体某个车辆, 运动区域映射实际的交通规划区域, 区域内的栅格编号如图 1 所示, 在  $G$  中建立直角坐标系, 以  $G$  左下角为坐标零点, 横轴为  $X$  轴, 纵轴为  $Y$  轴。设在相关区域内存在若干个障碍物栅格, 在图 1 中用黑色栅格表示, 实际交通环境中表示为路口拥堵。无障碍物栅格用白色栅格表示, 实际交通环境中表示为路口畅通。其中每个栅格为正方形, 其边长已知。假设机器人能够从起始点经过路径规划最终达到目的地。机器人只在各个栅格内的中心点行走, 关系计算公式如下:

$$X: x_i = a \cdot (\text{mod}(i, MM) - 0.5) \quad (1)$$

$$Y: y_i = a \cdot \left( MM + 0.5 - \text{ceil}\left(\frac{i}{MM}\right) \right) \quad (2)$$

关系式中,  $a$  为每个栅格的边长, 横 (纵) 坐标的最大栅格数值为  $MM$ , 栅格总数为  $e = MM \cdot MM$ , 每个栅格的坐标为  $(x_i, y_i)$ ,  $i$  为每个小正方形的栅格编号,  $\text{mod}$  为求余运算, 而  $\text{ceil}$  为舍余取整运算。其中机器人的起始点和最终目的地已知。

#### 3.2 局部信息动态路径规划

##### 3.2.1 动态障碍变化设置

为验证 LD-ACA 在动态路径变化中相对于 T-ACA 所展现出的优越性, 本节设计了一种动态障碍变化规则, 即: 把全局环境划分成若干个子区域, 并假设机器人在所在位置的子区域行走时, 该子区域的障碍状况是固定不变的, 机器人所在子区域外的信息与机器人本次路径规划无关。划分的子区域数目越多, 则机器人对动态路径障碍适应性越强。

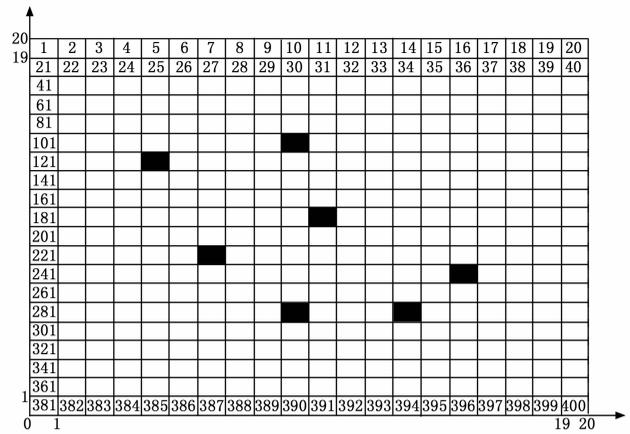


图 1 栅格图

##### 3.2.2 边寻边走策略

鉴于 T-ACA 是选择所有蚂蚁行走路径中的最优路径后, 再沿着最优路径行走, 这样它的时效性就会大打折扣。基于以上原因, 我们设计了边寻边走的策略, 具体策略如图 2 所示: 机器人首先会派出若干只蚂蚁利用局部信息寻找最优局部目标点, 找到最优局部目标点后, 机器人采用被调用蚁群算法 (Called Ant Colony Algorithm, C-ACA), 寻找到达该最优局部目标点的最佳路径并行走, 到达最优局部目标点后判断是否为全局目标点, 若是全局目标点则寻优结束, 若不是全局目标点, 则报告机器人, 继续重复上一步骤, 直到找到全局目标点为止。

##### 3.2.3 最优局部目标点的指标设定

当 LD-ACA 的边寻边走策略实施时, 最优局部目标点的选取方法在很大程度上决定了是否能够寻找到最优路径, 本文以三种最优局部目标点确立原则作对比: 1) 传统的轮盘赌算法 (Traditional Roulette Algorithm, TRA); 2) 改进的轮盘赌算法 (Improve The Roulette Algorithm, ITRA) 3) 最小值选择策略算法 (Minimum Selection Strategy Algorithm, MSSA)。

传统轮盘赌的策略在保证具有最大概率的某节点有最大被选择概率的同时, 其它具有相对较低概率的节点也有可能被选择, 其缺点是收敛速度过慢, 针对此情况, 提出改进轮盘赌算法, 核心思想是进行二次轮盘赌, 具体策略如图 3 所示: 首先确定局部目标点集合  $i, i \in allowed$ ,  $allowed$  为排除已经走过的节点后可以前往的局部目标点的集合, 随后加入  $rand$  作比较, 其中  $rand$  为在 0 到 1 之间的随机数, 服从均匀分布, 筛选出局部目标点  $i$  中被选择概率  $P_i$  大于等于  $rand$  的局部目标点集合  $\bar{i}$ , 最后调入传统轮盘赌算法筛选出最优局部目标点。

第三种方法是借鉴贪婪算法思想, 提出最小值选择策略算法, 核心思想为: 以全局目标点为参考变量, 选取所有可行的局部目标点中距离全局目标点距离值为最小的点为最优局部目标点, 距离计算公式如 (3) 式:

$$Z = \min \sqrt{(x_i - e_x)^2 + (y_i - e_y)^2}, i \in allowed \quad (3)$$

其中:  $allowed$  为排除已经走过的节点后可以前往的局部目标点的集合,  $e_x$  和  $e_y$  分别为全局目标点的横坐标与纵坐标,  $Z$  为局部目标点到全局目标点距离集合的最小值, 以取最小值  $Z$  所在的节点位置为最优局部目标点。

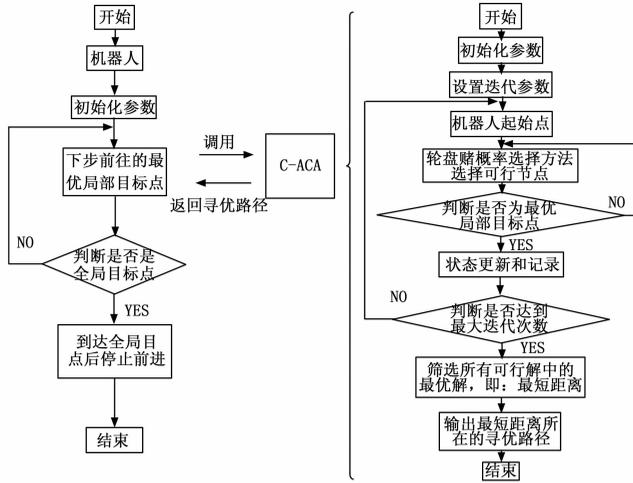


图 2 边寻边走策略流程图

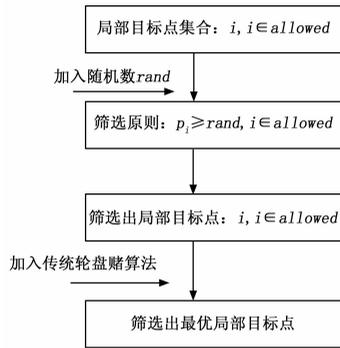


图 3 改进轮盘赌算法流程图

### 3.2.4 C-ACA 基本参数设计

#### 3.2.4.1 初始信息素的分布原则

在 C-ACA 路径寻优过程中，蚂蚁种群在下一步可以前往的节点称为可行节点，可行节点的选取依据主要有两方面：1) 当前节点到可行节点路径上的残留信息素浓度。2) 可行节点的启发式信息。本节取启发式信息  $\eta_{ij} = 1/d_{ij}$ ， $j$  和  $i$  分别为每个小正方形的栅格坐标（节点位置）， $d_{ij}$  为当前节点  $i$  到可行节点  $j$  之间的距离。

#### 3.2.4.2 信息素更新和优化原则

C-ACA 信息素更新策略只发生在从起始点到最优局部目标点走通的道路上，更新规则如式（4）：

$$\tau_{ij}(t) = (1 - R) \cdot \tau_{ij}(t - 1) + \Delta\tau_{ij} \quad (4)$$

$\tau_{ij}(t)$  为所有蚂蚁在当前  $t$  时刻在可以走通路径  $(i, j)$  留下的信息素， $\tau_{ij}(t - 1)$  为所有蚂蚁在  $t - 1$  时刻在可以走通路径  $(i, j)$  留下的信息素， $\Delta\tau_{ij}$  为从  $t - 1$  时刻到  $t$  时刻所有蚂蚁在可以走通路径  $(i, j)$  增加的信息素，计算公式如（5）式：

$$\Delta\tau_{ij}(t) = \begin{cases} \frac{Q}{L_k}, & \text{若蚂蚁 } k \text{ 在本次循环中经过可走通路径 } (i, j) \\ 0, & \text{其它} \end{cases} \quad (5)$$

其中： $L_k$  为第  $k$  只蚂蚁迭代过程中寻找到的可行路径， $Q$  为第  $k$  只蚂蚁在其自身寻优路径上留下的信息素的总和。同时为了避免蚂蚁种群在某条路径上过于扎堆，导致陷入局部最优解的问题，在信息素初步更新完成后，进行信息素的挥发策

略， $R$  为挥发因子。

#### 3.2.4.3 路径选择概率更新规则

由基本的数据可以求得机器人在当前位置节点前往下一个可行节点的公式如（6）式：

$$p_{ij}^k(t) = \begin{cases} \frac{(\tau_{ij}(t))^\alpha \cdot (\eta_{ij}(t))^\beta}{\sum_{j \in allowed_z} (\tau_{ij}(t))^\alpha \cdot (\eta_{ij}(t))^\beta}, & \text{若 } j \in allowed_z \\ 0, & \text{其它} \end{cases} \quad (6)$$

其中： $p_{ij}^k(t)$  为  $t$  时刻位于点  $i$  的蚂蚁  $k$  选择节点  $j$  的概率， $\alpha$  为残留的信息素的权重因子，代表残留信息素的重要程度； $\beta$  为启发式信息素的权重因子，代表启发式信息素的重要程度。 $allowed_z$  为排除已经走过的节点后可以前往的可行节点。

#### 3.2.5 局部可视范围内视野的设置

局部信息的获取方式对于 LD-ACA 的性能有重大影响，搜索范围越小，对动态环境变化适应性越强。当搜索范围逐步增大到全局环境的范围时，该算法就退化成静态路径规划。为分析局部视野与路径优化的关系，本文设计了两种局部信息获取方式：一步范围视野和两步范围视野，即：一步范围视野是机器人从当前位置只走一步所能达到的范围作为所获得的局部信息；两步范围视野是机器人从当前位置走两步所能达到的范围作为所获得的局部信息。

## 4 仿真实验与分析

为了验证 LD-ACA 的特点，本节将 T-ACA 和 LD-ACA 分别应用于路径寻优的问题求解。

以每行（列）栅格数为 20 为例，在本文的 LD-ACA 中，设置了三种不同的障碍环境  $G_1$ 、 $G_2$ 、 $G_3$ ，三种障碍环境会随着机器人的当前位置变化而变化，障碍环境的变化规律如（7）式：

$$G = \begin{cases} G_1, & x_i \in [0, 5] \\ G_2, & x_i \in [5.5, 10.5] \\ G_3, & x_i \in [11, 20] \end{cases} \quad (7)$$

其中： $x_i$  表示机器人运动所处的横坐标。

算法程序采用 MATLAB 进行编程测试，算法的各参数由文献 [15] 得到，初始值设置如表 1 和表 2 所示。

表 1 两种算法的公共参数设置

参数名	参数值
信息素因子权重	1
启发式因子权重	7
信息素蒸发系数	0.3
信息素浓度增强系数	1

表 2 各算法的自有参数设置

算法	参数名称	参数值
T-ACA	算法最大迭代次数	50
	智能蚂蚁数目	50
LD-ACA	算法最大迭代次数	5
	智能蚂蚁数目	5

### 4.1 动态环境的性能比较

为方便比较，本节为两种算法设置了相同的算法参数和环境参数：1) 两种算法的局部信息获取方式为一步范围视野；

2) 每行(列) 栅格数为 20; 图 4 和图 5 中的曲线为 T-ACA 在静态环境下的最优路径曲线, 而图 5 中的 A 曲线为 LD-ACA 在动态环境下的最优路径曲线, 与图 5 中的 B 曲线作对比可知, LD-ACA 具有自适应动态环境变化的能力, 而 T-ACA 一直按照原来寻优的路径行走没有避开动态障碍物, 路径规划失败。为了进一步验证 LD-ACA 对动态环境变化的适应性, 我们再一次改变了环境路况, 如图 6 所示, LD-ACA 依然能成功的规划出可行路径, 表明了 LD-ACA 具有较好的动态环境适应能力。

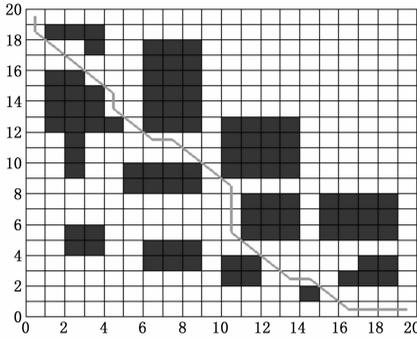


图 4 T-ACA 寻优路径图

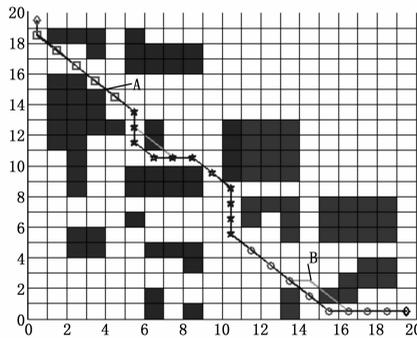


图 5 动态路径规划对比图

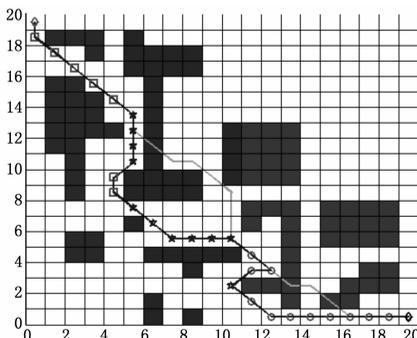


图 6 动态路径规划路径寻优对比图

### 4.2 对动态路径规划的性能优化

#### 4.2.1 三种最优局部目标点选取算法的比较

为验证本文所使用的 MSSA 在最优局部目标点获取方面的优越性, 本文给出了三种最优局部目标点获取算法在不同栅格数目条件下进行 50 次试验得到的平均值。如图 7 所示, 以寻优时间为评判指标, 可知在栅格数目较小情况下, 三者的寻优时间相差不大, 当栅格数目大于 30 时, MSSA 的寻优时间

明显短于其他两种算法; 同理, 以最优路径为指标, 当栅格数目大 20 时, MSSA 找出最优路径短于其他两种算法。

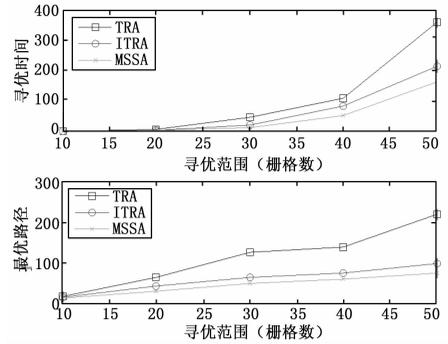


图 7 最优局部目标点选择比较图

#### 4.2.2 局部信息搜索范围变化比较

为了验证局部信息的获取范围对 LD-ACA 的影响, 我们把局部信息的获取范围分别设置为一步范围视野和两步范围视野来对比两种条件下的性能优劣。给定的两种算法的相同条件是: 1) 同等栅格数目; 2) 最优路径相等或相近。评判指标为: 两种算法的寻优时间。图 8 中的上图的前提条件为每行(列) 栅格数目相同, 可知在每行(列) 栅格数目小于等于 20 的情况下, 二者的寻优时间相差无几, 但当每行(列) 栅格数目为 30、40、50 时, 两步范围视野算法寻优时间明显短于一步范围算法; 同理, 图 8 中的下图前提条件为最优路径相等或相近, 可知在最优路径小于等于 33 的情况下, 二者的寻优时间相差无几, 但当最优路径超过 33 时, 两步范围算法寻优时间明显短于一步范围算法。但我们应同时看到在两步范围算法的路径寻优过程中, 放置的蚂蚁数目和迭代次数都是 5, 而一步范围算法放置的蚂蚁数目和迭代次数都是 2, 由此可见, 在局部信息获取方式中, 搜索范围扩大的代价就是增加了计算负担。

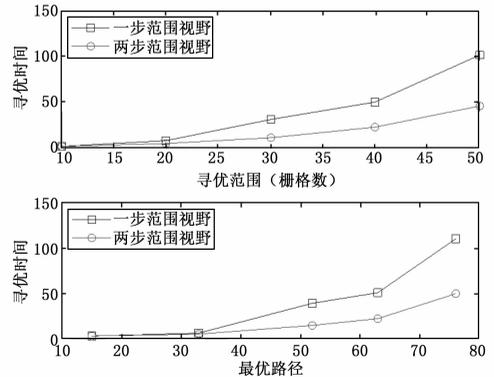


图 8 动态路径规划的性能优化图

### 4.3 静态环境两种算法性能比较

为了验证 T-ACA 和 LD-ACA 在不同栅格数目下的性能差异, 本节给出了两种算法在静态环境情况下的最优路径性能表, 两种算法都在每种栅格数目环境条件下进行了 50 次的仿真实验, 并取平均值。得到如表 3 所示的仿真结果, 由表 3 可知在每行(列) 栅格数小于 30, 即: 栅格数目较少时, 两种算法在最优路径和寻优时间两个路径寻优指标上没有太大差别, 但当每行(列) 的栅格数目大于 30 时, LD-ACA 在仅放置 5 只蚂蚁和进行 5 次迭代的情况下的寻优指标就明显优于

放置 50 只蚂蚁进行 50 次迭代的 T-ACA。

表 3 两种算法性能比较

栅格数	最优路径		寻优时间	
	T-ACA	LD-ACA	T-ACA	LD-ACA
10	13.50	13.31	0.85	0.62
20	32.14	32.14	7.32	6.12
30	50.75	50.63	27.60	23.87
40	74.80	60.43	66.12	52.29
50	123.25	74.57	166.92	117.65

### 5 结束语

针对 T-ACA 在动态环境路径寻优的过程中的局限性, 本文对 T-ACA 进行了相应的改进, 并以实际的区域交通规划背景为切入点, 提出了局部信息动态路径规划的改进蚁群算法, 所提出的 LD-ACA 在保证与 T-ACA 具有相当的优化效果的同时, 能够有效适应障碍变化、大大提高了路径规划的收敛速度。与此同时, 对 LD-ACA 在最优局部目标点选择和局部信息获取两个方面进行了优化, 优化方法在保证蚂蚁种群数目和迭代次数没有大幅增加的前提下, 大幅度地优化了寻优指标。

#### 参考文献:

[1] 赵开新, 魏勇, 王东署. 改进蚁群算法在移动机器人路径规划中的研究 [J]. 计算机测量与控制, 2014, 22 (11): 67-70.  
 [2] 刘营营. 基于模糊神经网络的移动机器人路径规划研究 [D]. 沈阳: 东北大学, 2012.

(上接第 129 页)

[3] 柏 砾, 赵刚要. 基于 MapReduce 与蚁群优化的航路规划算法 [J]. 计算机工程, 2015, 41 (5): 38-44.  
 [4] 赵娟平, 高宪文, 刘金刚, 等. 移动机器人路径规划的参数模糊自适应窗口蚁群优化算法 [J]. 控制与决策, 2011, 26 (7): 1096-1100.  
 [5] 袁亚博, 刘 羿, 吴 斌. 改进蚁群算法求解最优路径问题 [J]. 计算机工程与应用, 2016, 52 (6): 8-12.  
 [6] 基于遗传-模拟退火的蚁群算法求解 TSP 问题 [J]. 计算机测量与控制, 2016, 24 (3): 143-144.  
 [7] 杨学峰. 蚁群算法求解 TSP 问题的研究 [D]. 长春: 吉林大学, 2010.  
 [8] 宋代立, 张 洁. 蚁群算法求解混合流水车间分批调度问题 [J]. 计算机集成制造系统, 2013, 19 (7): 1640-1647.  
 [9] 周 鹏. 求解置换流水车间调度问题的混合蚁群算法 [J]. 计算机工程与应用, 2009, 45 (17): 191-193.  
 [10] 屈 鸿, 黄利伟, 柯 星. 动态环境下基于改进蚁群算法的机器人路径规划研究 [J]. 电子科技大学学报, 2015 (2): 260-265.  
 [11] 王 哲, 孙树栋, 曹飞翔. 动态环境下移动机器人路径规划的改进蚁群算法 [J]. 机械科学与技术, 2013 (1): 42-46.  
 [12] 柳长安, 鄢小虎, 刘春阳, 等. 基于改进蚁群算法的移动机器人动态路径规划方法 [J]. 电子学报, 2011, 39 (5): 1220-1224.  
 [13] Zhu Q, Hu J, Cai W, et al. A new robot navigation algorithm for dynamic unknown environments based on dynamic path re-computation and an improved scout ant algorithm [J]. Applied Soft Computing, 2011, 11 (8): 4667-4676.  
 [14] 葛延峰, 陈 涛, 孔祥勇, 等. 改进蚁群算法在城市汽车导航中的应用 [J]. 控制工程, 2016, 23 (1): 133-137.  
 [15] 叶志伟, 郑肇葆. 蚁群算法中参数  $\alpha$ 、 $\beta$ 、 $\rho$  设置的研究——以 TSP 问题为例 [J]. 武汉大学学报 (信息科学版), 2004, 29 (7): 597-601.

只采用了一种固定的四轮的结构, 没有研究万向轮的位置以及个数对平台的影响。在后续的实验总还需要对这几个方面进行更加全面的研究。

#### 参考文献:

[1] 余志生. 汽车理论 [M]. 北京: 机械工业出版社, 2010.  
 [2] 张忠将. SolidWorks 2014 机械设计完全实例教程 [M]. 北京: 机械工业出版社, 2015.  
 [3] 刘 义. RecurDyn 多体动力学仿真基础应用与提高 [M]. 北京: 电子工业出版社, 2013.  
 [4] 黄朝胜. 轮式车辆垂直障碍通过性研究 [J]. 中国机械工程, 2015 (9).  
 [5] 屠德新, 魏道高, 蒋良生, 等. 基于 ADAMS 的车辆极限越障性能研究 [J]. 湖北汽车工业学院学报, 2010.  
 [6] 程保山. 方向轮定位技术 [J]. 机器人技术与应用, 2009 (5): 35-37.  
 [7] 祝晓才. 轮式移动机器人的运动控制 [D]. 长沙: 国防科学技术大学, 2006.  
 [8] 史恩秀. 轮式移动机器人的运动控制及定位方法研究 [D]. 西安: 西安理工大学, 2006.  
 [9] 王 薇. 轮式移动机器人的运动控制研究 [D]. 北京: 北京邮电大学, 2009.  
 [10] 焦晓娟, 张潜渭, 彭斌彬. RecurDyn 多体系统优化仿真技术 [M]. 北京: 清华大学出版社, 2010.

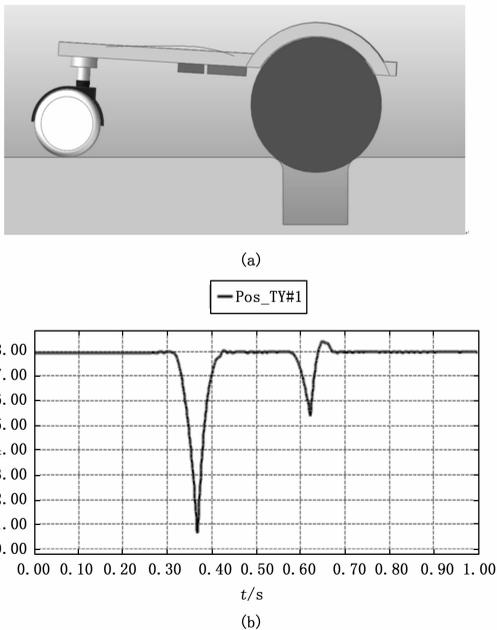


图 7 平台越障的仿真结果

仿真实验过程中考虑到了一部分实验条件, 但是还有一些并没有考虑到, 比如平台在砂土路面的行进情况。另外, 仿真