

文章编号: 1002-0446(2003)06-0531-05

复杂环境中基于人工势场优化算法的最优路径规划*

庄晓东, 孟庆春, 高云, 杨少军, 张继军, 齐勇

(中国海洋大学 计算机科学系 智能技术与系统实验室, 山东 青岛 266071)

摘要: 本文提出一种基于人工势场优化的路径规划方法. 把人工势场的路径规划结果作为先验知识, 对蚁群算法进行初始化, 提高了蚁群算法的优化效率; 另一方面, 机器人的路径也同时得到优化, 克服了人工势场法的局部极小问题. 仿真实验结果表明, 该方法在复杂环境中能有效地实现最优路径规划; 并提供了一种把传统规划方法和统计优化相结合, 提高规划效率的可行思路.

关键词: 人工势场优化; 蚁群算法; 最优路径规划; 复杂环境

中图分类号: FT24 文献标识码: B

OPTIMAL PATH PLANNING IN COMPLEX ENVIRONMENTS BASED ON OPTIMIZATION OF ARTIFICIAL POTENTIAL FIELD

ZHUANG Xiaodong, MENG Qingchun, GAO Yun, YANG Shaojun,

ZHANG Jijun, QI Yong

(Intelligent Technology & System Laboratory, Computer Science Department, Ocean University of China, Qingdao 266071, China)

Abstract: A path planning method based on artificial potential field optimization is proposed. The ant algorithm is initialized by the planning result of the artificial potential field method as the prior knowledge, which improves the algorithm's efficiency. On the other hand, the path obtained by the artificial potential field method is optimized by the ant algorithm, which overcomes the local minima problem in the artificial potential field method. Results of computer simulation experiment indicate that the method can implement optimal path planning in complex environments. In order to improve the planning efficiency a feasible idea of combining traditional planning methods with statistic optimization is also presented.

Keywords: artificial potential field optimization; ant algorithm; optimal path planning; complex environments

1 引言 (Introduction)

路径规划是移动机器人控制中的关键问题, 路径规划算法的性能直接影响移动机器人的工作效率. 实际应用中, 具有多个不规则障碍的复杂环境是常见的情况, 其中的路径规划问题具有高复杂度^[1-3]. 人工势场法是传统算法中较成熟且高效的规划方法, 它通过环境势场模型来规划一条从出发点到目标点的可行路径, 但是没有考察路径是否最优. 人工势场法中不合理的势场方程定义会产生势场的局部极小值, 引起机器人路径的振荡、摆动. 为克服人工势场具有局部极小值的问题, 已有一些改进方法, 比如 Sato 提出的 Laplace 势场法等^[4]; 其基本着眼点是通过数学上合理的定义势场方程, 保证

势场中不存在局部极值, 但也没有考察路径是否最优.

为使机器人路径达到最优, 统计启发式优化算法被应用到路径规划问题中^[5-7]. 其中蚁群算法作为一种高效的优化求解方法, 在路径规划应用中已取得比较成功的实验结果^[5]. 蚁群算法通过解空间中的优化搜索得到最优路径; 随着问题复杂度的增大, 解空间也增大, 使得优化收敛的速度变慢, 影响了路径规划效率.

解的初始化问题在优化求解算法中是普遍存在的, 不合理的初始解将增加求解时间, 甚至使算法陷入局部最优解^[8,9]. 这也是蚁群算法在问题规模增大时效率受到影响的重要因素. 由于在传统算法中, 人

工势场具有环境模型简洁、算法高效的特点,因此本文把人工势场法和蚁群算法相结合,提出一种基于人工势场优化的机器人最优路径规划方法.人工势场作为优化求解的先验知识,对蚁群算法的参数进行初始化,加快了蚁群算法的优化速度;同时优化结果克服了人工势场法的局部极小问题,得到最优路径.计算机仿真实验表明,本文的方法在复杂环境中能高效地求得最优路径,并且和没有先验知识的优化过程相比效率更高.

2 蚁群优化算法简介 (Ant colony optimization)

蚁群优化算法 (Ant Colony Optimization, ACO) 是 Marco Dorigo 等学者提出的一种用于优化求解的算法^[10].在蚁群算法中,问题的解被抽象成在离散状态空间中从起始状态到达目标状态的状态转移序列,即从起始状态到目标状态的路径.一般情况下,问题的最优解对应着状态转移的最短路径.为了求得最优解,蚂蚁从起始状态开始在相邻状态之间转移,直到达到目标状态为止,完成一次解的搜索.路径强度值 (trial intensity) 是蚂蚁进行状态转移的依据;另一方面,每只蚂蚁也会增强所经过的路径上的强度值.蚂蚁群体的优化过程不断循环,最终使最优转移序列上的路径强度达到最大,从而求得最优解.

每只蚂蚁的状态转移是根据状态转移概率随机

$$\Delta \tau_{ij}^k(t, t+1) = \begin{cases} 1/L_k & \text{if the } k\text{-th ant goes from } s_i \text{ to } s_j \text{ at the } t\text{-th loop} \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

其中 $1/L_k$ 是第 k 只蚂蚁经过路径长度的倒数,路径长度越短,路径增强值越大.如果一条路径有越多的蚂蚁经过,该路径的强度值增大得就越快,反过来会吸引更多的蚂蚁沿该路径移动,这是一种正反馈机制,使蚁群算法能够迅速地求得问题的解.

3 基于势场优化算法的机器人路径规划 (Robot path planning based on artificial potential field optimization)

3.1 初始解对蚁群算法性能的影响

复杂环境中的路径规划,是要使机器人从起始点开始,绕过障碍到达目标点.最优路径一般指长度最短的路径.由于蚁群算法是受自然界中蚂蚁路径搜索的启发而产生的,因此和路径规划问题有着自然的联系,并且已经被应用到机器人路径规划中^[5].蚁群算法的求解过程主要有两个阶段:初始解的产生和在此基础上解的优化.对于大的解空间,通过随机搜索得到初始解需要大的运算量,不利于提高算

进行的,从状态 s_i 转移到某个相邻状态 s_j 的状态转移概率 $p_{ij}(t)$ 定义为^[10]

$$p_{ij}(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}]^\beta}{\sum_{s_j \in \text{Allowed}} [\tau_{ij}(t)]^\alpha [\eta_{ij}]^\beta} & \text{if } s_j \in \text{Allowed} \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

其中 $\tau_{ij}(t)$ 是第 t 次搜索时 s_i 和 s_j 之间的路径强度值; α 和 β 是大于零的参数; η_{ij} 是 s_i 和 s_j 之间距离的倒数,是一种启发信息;Allowed 是与 s_i 相邻的,并且当前的蚂蚁未经历的状态集合.

蚂蚁在状态转移过程中,把已经过的状态序列记录在称为 Tabu 列表的数组中,在群体中所有的蚂蚁都完成一次搜索后,对每一个状态 s_i ,路径强度按下式更新^[10]:

$$\tau_{ij}(t+1) = \rho \tau_{ij}(t) + \Delta \tau_{ij}(t, t+1) \quad (2)$$

其中 $\tau_{ij}(t)$ 和 $\tau_{ij}(t+1)$ 分别是 s_i 和相邻状态 s_j 之间在更新前和更新后的路径强度值, ρ 是常数且 $0 < \rho < 1$. $\Delta \tau_{ij}(t, t+1)$ 是路径强度更新值,定义为^[10]

$$\Delta \tau_{ij}(t, t+1) = \sum_{k=1}^m \Delta \tau_{ij}^k(t, t+1) \quad (3)$$

其中 m 是群体中蚂蚁的个数; $\Delta \tau_{ij}^k(t, t+1)$ 是第 t 次搜索时,第 k 只蚂蚁在 s_i 和 s_j 之间的路径上留下的路径增强信息,定义为^[10]

法效率.更重要的是,在大的解空间里,不能够保证随机产生的初始解的质量;由于蚁群算法的正反馈机制,质量不高的初始解可能使算法收敛于次优解.因此,高效地获得较高质量的初始解对提高算法性能很重要.

人工势场法仿照物理学中电场的概念,通过建立以目标点及障碍为场源的虚拟势场,按照势场力的方向高效地规划出可行的避障路径^[11].人工势场法得到的路径可以作为蚁群算法的较高质量的初始解.本文把人工势场作为先验知识融合到蚁群算法中,根据人工势场得到路径强度初始值 $\tau_{ij}(0)$.在这种初始条件下,蚁群算法实际上是对人工势场法得到的机器人路径进行优化,因此可以克服人工势场法的局部极小问题.同时由于有较高质量的初始解,优化效率得到提高.

3.2 基于人工势场的路径强度初始化

由于蚁群算法在离散状态空间中进行最优求解,因此机器人的二维工作平面被离散化,离散化的

位置对应蚁群算法中的离散状态.机器人的运动方向也被离散化成{ Move East, Move West, Move North, Move South, Move Northeast, Move Northwest, Move Southeast, Move Southwest}八个方向.

在没有先验知识的情况下,路径强度的初始值 $\tau_{ij}(0) = 1/N_i$ (其中 N_i 是状态 s_i 相邻状态的个数), 即蚂蚁和相邻的任何一个位置间的路径强度是相等的.本文把人工势场法的路径规划结果作为先验知识,对路径强度值进行初始化,计算过程如下:

(1) 对机器人工作空间中的每一个位置 s_i , 计算 s_i 处的人工势场矢量

$$E(s_i) = A \sum_{k=1}^M \frac{\vec{n}_{ki}}{r_{ki}^2} + B \frac{\vec{n}_{ti}}{r_{ti}^2} \quad (5)$$

其中 A, B 是大于零的常数,用来权衡避障和到达目标两个因素的相对重要性; M 是离散工作平面中障碍点的个数; r_{ki} 是第 k 个障碍点到 s_i 的距离, r_{ti} 是目标点到 s_i 的距离; \vec{n}_{ki} 是从第 k 个障碍点指向 s_i 的单位矢量, \vec{n}_{ti} 是从 s_i 指向目标点的单位矢量.

$E(s_i)$ 的方向就是根据人工势场法得到的在位置 s_i 的机器人运动方向;

(2) 分别计算机器人八个运动方向和 $E(s_i)$ 的夹角 $\theta_i (i=1, 2, \dots, 8)$;

(3) 按照从小到大的顺序,对相应方向的路径强度赋以从大到小的值.这样,与 $E(s_i)$ 夹角越小的运动方向上,路径强度越大.

根据人工势场进行初始化之后,如果从起始点开始按照路径强度最大的方向移动,得到的初始路径就是人工势场法的规划结果.随着优化过程的进行,初始路径上由于势场局部极小问题引起的振荡和摆动会被消除,最终得到最优路径.仿真实验中,对每个位置 s_i , 八个运动方向对应的路径强度按照和势场矢量 $E(s_i)$ 夹角从小到大的顺序,依次被赋值为 $\{0.5, 0.1, 0.1, 0.08, 0.08, 0.06, 0.06, 0.02\}$.

3.3 基于蚁群算法的势场优化和路径规划

经过路径强度值的初始化之后,蚂蚁群体开始从起始点进行路径搜索.蚂蚁在相邻的位置之间移动,每次移动按照(1)式所定义的概率随机决定下一个位置.当蚂蚁到达目标点时就完成一次搜索.群体中所有蚂蚁都完成一次搜索之后,按照(2)式进行路径强度值的更新,完成一次蚂蚁群体的优化.蚂蚁群体的优化过程不断循环,直到所有蚂蚁收敛到同一路径,或者优化次数达到一个预先规定的最大值为止.路径规划的流程图如图 1 所示.

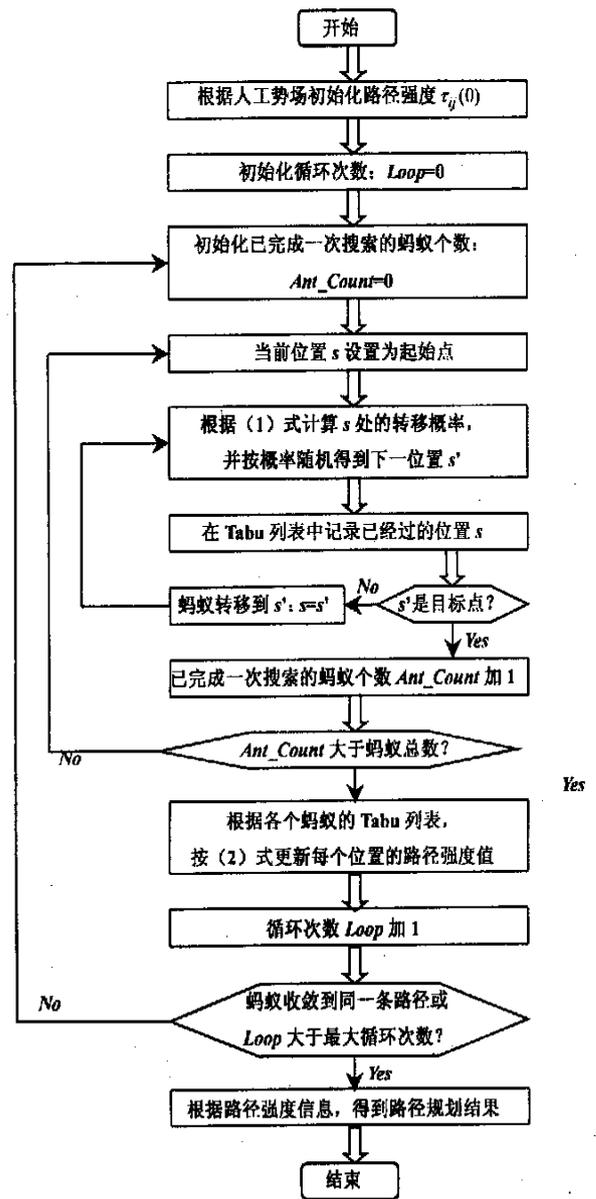


图 1 基于人工势场优化算法的路径规划流程图

Fig.1 The flowchart of the path planning based on the artificial potential field optimization

4 仿真实验结果 (Computer simulation experiment results)

在仿真实验中,机器人的二维工作空间被离散化成 32×32 的网格,其中包含了 7 个具有不规则形状的障碍.实验结果表明:基于蚁群算法的势场优化能够有效地在复杂环境中进行最优路径规划.

4.1 基于蚁群算法的势场优化和人工势场法的实验结果比较

为比较基于蚁群算法的势场优化和人工势场法的路径规划结果,做了多组仿真实验,图 2 和图 3 是

其中一组实验的结果,图中标有“S”的点是机器人的出发点(start point),标有“G”的点是目标点(goal point).图中的箭头表示机器人处于那个位置时的运动方向.图2是采用基于蚁群算法的势场优化方法的规划结果,图3是采用人工势场法的路径规划结果.可以看出图2中的路径优于图3中的路径.图3中圆圈所标出的区域里,机器人的路径由于人工势场的局部极小问题发生摇摆,而在图2中的相应区域里没有这种现象.

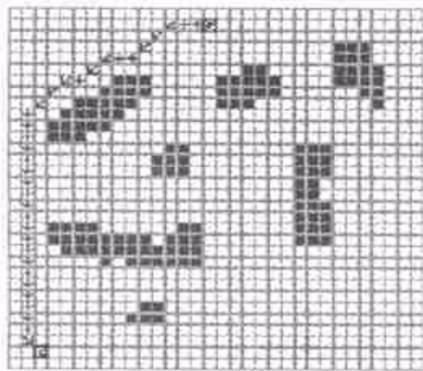


图2 仿真实验中势场优化方法的规划结果

Fig.2 The result of path planning in the simulation experiment based on the artificial potential field optimization with ACO

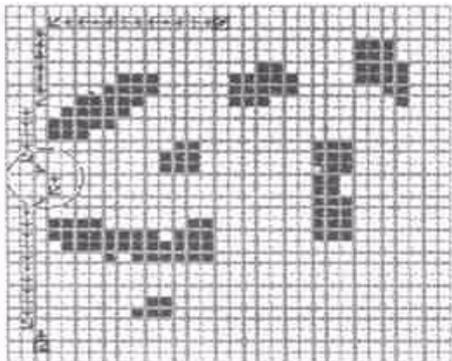


图3 仿真实验中人工势场法的规划结果

Fig.3 The result of path planning in the simulation experiment based on the artificial potential field method

4.2 人工势场作为先验知识对路径优化效率的提高

为考察引入先验知识对提高优化效率的效果,对引入先验知识和没有先验知识的两种蚁群优化算法进行了仿真实验比较.仿真实验环境如图2所示,优化过程中使用22只蚂蚁.在实验中记录以下两个性能评价参数:群体每次优化成功到达目标的蚂蚁数,到达目标所用的平均步数.根据实验数据得到图4至图7.图4至图7表明成功到达目标的蚂蚁数随优化的进行呈增加趋势,而平均步数呈下降趋势.图5中的曲线呈现三个明显不同的区间:[0,300)是初始解的搜索阶段,成功到达目标的蚂蚁很少;[300,

350)是找到初始解后的优化阶段,成功到达目标的蚂蚁数迅速增多;[350,450]是已接近并得到最终解的阶段,成功到达目标的蚂蚁数在22附近摆动.与此不同的是在图4中,由于引入先验知识初始化,不必进行初始解的搜索,缩短了优化时间.

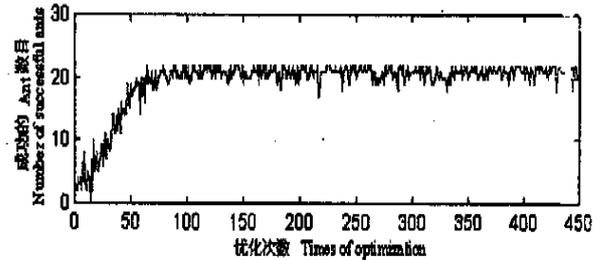


图4 引入先验知识的蚁群算法中,成功到达目标的蚂蚁数目和优化次数的关系

Fig.4 The relationship between the number of successful ants and the times of optimization in ACO with prior knowledge

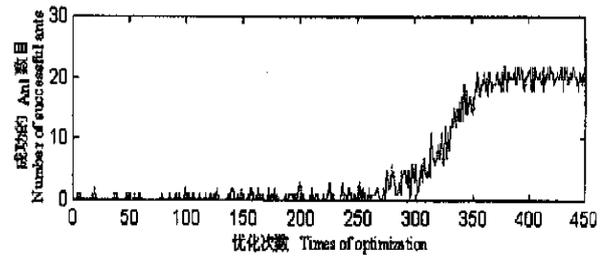


图5 没有先验知识的蚁群算法中,成功到达目标的蚂蚁数目和优化次数的关系

Fig.5 The relationship between the number of successful ants and the times of optimization in ACO without prior knowledge

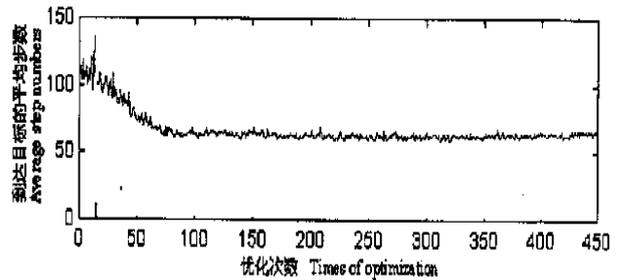


图6 引入先验知识的蚁群算法中,蚂蚁群体到达目标的平均步数和优化次数的关系

Fig.6 The relationship between the average step numbers to reach the goal point and the times of optimization in ACO with prior knowledge

由于优化过程初期出现了成功到达目标的蚂蚁数为0的情况,这时平均步数无法统计,因此在图6和图7中用横坐标上的竖线表示该次优化中成功到达目标的蚂蚁数为0.图7表明:没有先验知识的情

况下,经过 350 次优化才接近最优解;图 6 表明:引入先验知识之后,经过 100 次优化即得到最终解.实验结果表明,在蚁群算法中引入人工势场作为先验知识,提高了路径规划的效率.

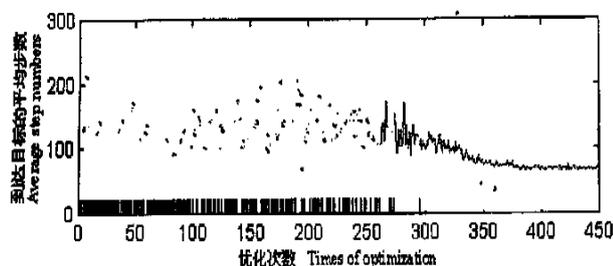


图 7 没有先验知识的蚁群算法中,蚂蚁群体到达目标的平均步数和优化次数的关系

Fig. 7 The relationship between the average step numbers to reach the goal point and the times of optimization in ACO without prior knowledge

5 结论 (Conclusion)

本文提出了一种基于人工势场优化的路径规划方法,根据人工势场来初始化蚁群算法的参数,提高了蚁群算法的优化效率;同时,优化结果克服了人工势场法中局部极小问题引起的路径摆动,并得到最优路径.仿真实验结果表明,该方法能够在复杂环境中有效地进行路径的优化搜索;并且和没有先验知识的优化过程相比,提高了效率.本文提出的方法,提供了一种把传统方法和统计优化求解相结合,提高规划效率的可行思路.

参考文献 (References)

- [1] Philip Kilby, Patrick Prosser, Paul Shaw. Guided local search for the vehicle routing problem[A]. 2nd International Conference on Metaheuristics- MIC97[C].
- [2] Borenstein J, Koren y. The vector field histogram-fast obstacle avoidance for mobile Robots[J]. IEEE Journal of Robotics and Automation, 1991, 7(3): 278 - 288.
- [3] 庄晓东,孟庆春,殷波等. 动态环境中基于模糊概念的机器人路径搜索方法[J]. 机器人, 2001, 23(5): 397 - 399.
- [4] Sato K. Deadlock-free motion planning using the Laplace potential field [J]. Advanced Robotics, 1993, 7(5): 449 - 461.
- [5] 金飞虎,洪炳熔,高庆吉. 基于蚁群算法的自由飞行空间机器人路径规划[J]. 机器人, 2002, 24(6): 526 - 529.
- [6] 吴丽娟,徐心和. 基于遗传算法的足球机器人比赛中障碍回避策略的设计[J]. 机器人, 2001, 23(2): 142 - 145.
- [7] 庄晓东,孟庆春,王汉萍等. 多障碍环境中基于增强式学习的势场优化和机器人路径规划[J]. 青岛海洋大学学报(自然科学版), 2001, 31(6): 937 - 942.
- [8] 唐世浩,朱启疆. 遗传算法中初始种群与交叉、变异率对解的影响及其解决方案[J]. 科技通报, 2001, 17(3): 1 - 7.
- [9] 杨伟,倪黔东,吴军基. BP 神经网络权值初始值与收敛性问题研究[J]. 电力系统及其自动化学报, 2002, 14(1): 20 - 22.
- [10] Dorigo M, Di Caro G, Gambardella L. Ant colony optimization: New Meta-Heuristic[A]. Proceedings of the Congress on Evolutionary Computation[C]. 1999. 1470 - 1477.
- [11] Oussama Khatib. Real-time obstacle avoidance for manipulators and mobile robots[J]. The International Journal of Robotics Research, 1986, 5(1): 90 - 98.

作者简介:

庄晓东 男,博士研究生,研究领域:人工智能.
孟庆春 男,教授,研究领域:智能技术与系统.

(上接第 530 页)

参考文献 (References)

- [1] Zhuang Xiaodong, Meng Qingchun, Wei Tianbin. Robot path planning in dynamic environment based on reinforcement learning[J]. Journal of Harbin Institute of Technology, 2001, 8(3): 253 - 255.
- [2] 王立春,李红兵,陈世福. AODE 中的多 Agent 协商与学习[J]. 模式识别与人工智能, 2001, 14(3): 347 - 351.
- [3] 李实,徐旭明,叶榛,孙增圻. 国际机器人足球比赛及其相关技术[J]. 机器人, 2000, 22(5): 420 - 426.

- [4] Peter Stone. Layered learning in multi-agent systems[D]. Pittsburgh: Carnegie Mellon University: 98.

作者简介:

张淑军 (1980-),女,在读硕士生,研究领域:多智能体技术、计算智能理论与应用.
孟庆春 (1958-),男,教授,博士生导师,研究领域:智能技术与系统、智能机器人、计算智能理论、智能控制等.