

## 基于QPSO算法移动机器人轨迹规划与实验

李仁府<sup>1</sup>, 独孤明哲<sup>1,2</sup>, 胡麟<sup>1</sup>, 汉哲勋<sup>2</sup>

(1. 华中科技大学 航空航天工程系, 武汉 430074; 2. 金策工业综合大学, 平壤 999093)

**摘要:** 针对移动机器人路径规划问题, 提出一种基于QPSO算法的路径规划方法, 并用概率论的方法分析了移动机器人路径规划的收敛性, 阐明了该方法随均匀分布和正态分布的参数关系和收敛区间; 然后根据移动机器人的运动特征提出一种改进的轨迹规划方法. 移动机器人平台的实验结果表明了该方法在移动机器人路径规划中的有效性和可行性.

**关键词:** 移动机器人; 路径规划; 量子行为粒子群优化算法; 轨迹规划

**中图分类号:** TP273

**文献标志码:** A

## Mobile robot trajectory planning based on QPSO algorithm and experiment

LI Ren-fu<sup>1</sup>, DOKGO Myong-chol<sup>1,2</sup>, HU Lin<sup>1</sup>, HAN Chol-hun<sup>2</sup>

(1. Department of Aerospace Engineering, Huazhong University of Science and Technology, Wuhan 430074, China;

2. Kim Chaek University of Technology, Pyongyang 999093, DPRK. Correspondent: LI Ren-fu, E-mail: renfu.li@hust.edu.cn)

**Abstract:** For the problem of mobile robot path planning, a path planning method based on quantum-behaved particle swarm optimization(QPSO) algorithm is proposed. The probability theory is applied to study the relationship with the parameters and convergence of mobile robot path planning, and the convergence interval of the method with uniform distribution and normal distribution is clarified. Considering the movement characteristics of mobile robot, an improved trajectory planning method is proposed. Experimental and calculation results show the effectiveness of the proposed method for mobile robot path planning.

**Key words:** mobile robot; path planning; quantum-behaved particle swarm optimization algorithm; trajectory planning

### 0 引言

移动机器人路径规划是研究如何寻找一条无碰撞的可行路径问题的方法, 广泛应用的路径规划包括人工神经网络、进化计算、模糊逻辑与信息融合、蚁群算法、遗传算法和粒子群优化(PSO)算法等<sup>[1]</sup>. 近年来有关机器人路径规划的理论逐渐在向群体智能优化算法的方向发展, 其中PSO算法是一种新的群体智能优化算法<sup>[2-4]</sup>, 其思想来源于对鸟类群集行为的模拟. 因为该算法本身对目标函数的性质没有依赖, 并且易于实现, 参数相对较少并具有良好的优化性能, 所以吸引了国内外众多学者的关注和研究, 已经成为当前群体智能优化方法研究的一个热点<sup>[5-8]</sup>. 然而, 粒子的运动状态由位置和速度描述, 随着时间的演化, 粒子的运动轨迹是既定的; 同时, 粒子的速度

受到一定限制, 使得粒子的搜索空间是一个有限的并逐渐减小的区域, 不能覆盖整个可行解空间, 并且上限值的设置与粒子的初始位置和最优解的距离有关, 控制参数的选取也需要丰富的经验, 因此PSO算法在某些情况下难以保证全局收敛. 为了提高PSO算法中粒子的随机性和全局搜索性能, Clerc等<sup>[9]</sup>提出了量子行为粒子群优化算法(QPSO), QPSO算法建立于 $\delta$ 势阱模型且具有量子运动的粒子群, 在量子空间中粒子的满足聚集态的性质完全改变0, 它可以在整个可行解空间中进行搜索, 因而QPSO算法的全局搜索性能远远优于标准PSO算法, QPSO算法也以其易于实现、参数较少等特点在多个应用领域得到了关注<sup>[9-11]</sup>. 孙俊等<sup>[10-12]</sup>提出了几种改进的算法和全局收敛性分析, 采用随机分布机构变化法和压缩-扩张因子控制

收稿日期: 2013-10-07; 修回日期: 2014-01-21.

基金项目: 广东省产学研结合项目(2010A090200010).

作者简介: 李仁府(1966-), 男, 教授, 博士生导师, 从事航空航天等研究; 独孤明哲(1977-), 男, 博士生, 从事移动机器人自主导航的研究.

法、混合搜索法等提高 QPSO 算法的全局收敛性和算法精度. 基于群体优化算法的路径规划, 对如何选择收敛可行的粒子数和迭代次数等的基本参数方法的研究<sup>[13-14]</sup>、机器人的运动动力学特征<sup>[15-16]</sup>的考虑, 以及提高收敛性和效率都是值得探索的课题.

本文提出一种基于 QPSO 算法的移动机器人路径规划方法, 且分析了该算法的收敛性与粒子数、迭代次数和粒子维度之间的关系, 通过仿真对不同初始粒子分布给出了收敛区间; 然后根据移动机器人的运动特性提出一种改进的轨迹规划方法; 最后通过轨迹跟踪控制仿真与移动机器人平台实验, 验证了该方法的有效性.

## 1 路径规划建模与参数分析

### 1.1 路径规划建模

在路径规划中每个粒子表示一条可行的路径, 假设共有  $N$  条可行路径, 粒子维度  $D$  表示从出发点到目标点的连线数量. 路径规划过程可看作每个路径分割点到最优角度值的收敛过程, 文献 [10] 已证明了 QPSO 算法的全局收敛性. 此外, 基于 QPSO 算法的移动机器人路径规划过程是马尔可夫链过程, 在路径规划中每个时刻的路径状态与前一时刻的路径状态有关, 与别的状态无关, 路径规划过程可收敛到某一个最优解<sup>[4]</sup>. 基于 QPSO 算法的移动机器人的全局最优路径规划方法基本步骤如下.

**Step 1** 根据机器人的工作环境, 利用栅格法进行环境建模. 采用栅格法描述的环境条件可用极坐标和直角坐标表示, 基于极坐标与直角坐标的关系探测方法如图 1 所示.




图 1 基于极坐标和直角坐标路径探测原理

极坐标的长度为从出发点到目标点的距离, 角度表示探测范围. 本文中栅格粒度大小根据机器人自身的尺寸大小和障碍物的面积大小来确定.

**Step 2** 设置 QPSO 算法的详细参数: 粒子维度  $D$ 、最大迭代次数  $M$ 、粒子数  $N$ 、学习因子  $c_1$  和  $c_2$  以及收缩-扩张系数  $\alpha$ . 粒子群维度由下式确定:

$$D \approx \frac{\text{distance}(\text{path})}{\text{length}_{\text{robot}}}. \quad (1)$$

其中:  $\text{distance}(\text{path})$  为从出发点到目标点的距离,

$\text{length}_{\text{robot}}$  为移动机器人的最大长度,

**Step 3** 设定极坐标的长度、探测最大角度和最小角度. 极坐标的长度由出发点为目标点距离决定. 探测最大角度和最小角度一般取  $0 \sim \pi/2$ , 最大和最小角度范围不能超过搜索范围.

$$\begin{cases} \alpha_{\max} = \alpha_{\text{top}}, \alpha_{\min} = \alpha_{\text{down}}, \rho_L \leq L_{\text{target}}, \\ \alpha_{\max} = \alpha_{\text{top}}, \alpha_{\min} = \alpha_{\text{down}}, \rho_L > L_{\text{target}}. \end{cases} \quad (2)$$

其中:  $\beta = \arccos(L_{\text{target}}/\rho_i)$ ,  $\alpha_{\text{top}}$  和  $\alpha_{\text{down}}$  分别表示探测最大角度和最小角度范围,  $L_{\text{target}}$  为目标在直角坐标目标点位置,  $\rho_L$  为极坐标长度, 且满足

$$\rho_L = \frac{\sqrt{(x_j - x_o)^2 + (y_j - y_o)^2}}{D} j, j = 1, 2, \dots, D. \quad (3)$$

**Step 4** 取粒子种群初始化分布为均匀分布, 并设定粒子的位置范围和速度范围在环境模型的有效区域内, 即满足

$$\alpha_{i,j} = \text{rand} * (\alpha_{\text{top}} - \alpha_{\text{down}}) + \alpha_{\text{down}}. \quad (4)$$

**Step 5** 通过极坐标和直角坐标变换, 获得路径的坐标值  $(x, y)$ , 根据粒子的约束条件来判断粒子是否有效, 无效则重新初始化, 直到保证所有粒子有效为止, 并检查粒子位置和障碍位置.

**Step 6** 根据适应度函数计算每个粒子的适应度值, 将粒子的个体历史最优值和当前粒子适应值进行比较, 如果当前的适应值比历史最优值小, 则用当前的适应值替换个体历史最优值. 适应度函数

$$\text{Fitness}(\text{path}) = f_1 L_D + f_2 L_S, \quad (5)$$

$f_1$  和  $f_2$  分别是路径长度和平滑度函数中的加权系数. 路径长度  $L_D$  满足如下关系:

$$L_D = \sum \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2}, \quad (6)$$

其中  $x_i, y_i, x_{i+1}, y_{i+1}$  分别为路径起点和终点的坐标值. 粒子位置平滑度函数为

$$L_S = \sum \sqrt{\rho_{i+1}^2 + \rho_i^2 - 2\rho_{i+1}\rho_i \cos(\alpha_{i+1} - \alpha_i)}. \quad (7)$$

其中:  $\rho_{i+1}$  和  $\rho_i$  为极坐标长度,  $\alpha_{i+1}$  和  $\alpha_i$  为粒子的角度.

**Step 7** 将粒子历史最优适应值序列中最小的值与当前的全局历史最优值进行比较, 并根据上次迭代取得的  $P_g(t)$  与全局最好位置  $G(t-1)$  的适应度值计算得到粒子群的平均最好位置, 即

$$c_j(t) = \frac{1}{M} \sum_{i=1}^M P_{i,j}(t). \quad (8)$$

**Step 8** 更新种群中粒子的位置信息. 若粒子搜索的位置超过了设定的空间范围, 则选取设定的空间范围作为位置信息. 粒子更新方程为

$$P_{i,j} = \varphi_j(t) \cdot P_{i,j}(t) + [1 - \varphi_j(t)] \cdot G_j(t),$$

$$\varphi_j(t) \sim U(0, 1); \quad (9)$$

$$\varphi_j(t) = \frac{c_1 \cdot \text{rand}_1(t)}{c_1 \cdot \text{rand}_1(t) + c_2 \cdot \text{rand}_2(t)}. \quad (10)$$

粒子的位置进化方程为

$$X_{i,j}(t+1) = P_{i,j}(t) \pm \alpha \cdot |C_j(t) - X_{i,j}(t)| \ln \left[ \frac{1}{u_{i,j}(t)} \right]. \quad (11)$$

**Step 9** 将本次迭代的粒子最优值与之前连续迭代结果进行比较, 如未发生变化则表示变量达到优化值, 退出循环; 否则, 在最大迭代次数内反复计算. 如果达到最大迭代次数, 则采用 Shuman 滤波法进行平滑处理, 对粒子路径进行优化修改, 作为计算结果与最优路径.

## 1.2 路径规划的参数分析

为了便于路径规划的理论分析, 给出 QPSO 算法的数学描述和定义.

**定义 1**(QPSO 算法中粒子的状态和粒子状态空间) 粒子的状态由粒子的位置  $x$ , 粒子群的平均最好位置  $C(t)$  和全局最好位置  $G(t)$  构成, 用  $R = (x, C, G)$  表示. 所有可能的粒子的集合构成状态空间  $\mathbf{R} = \{R = (x, C, G), x, C, G \in A\}$ , 其中  $A$  为可行解集, 简称粒子状态空间.

**定义 2**(QPSO 算法中粒子群的状态和粒子群状态空间) 粒子群状态定义为粒子群中所有  $N$  个粒子的状态的集合, 用  $S = (R_1, R_2, \dots, R_N)$  表示. 所有可能的粒子群状态的集合构成粒子群状态空间  $\mathbf{S} = \{S = (R_1, R_2, \dots, R_N)\}$ ,  $R_i \in R$ ,  $1 \leq i \leq N$ , 简称为粒子群空间.

**定理 1** 基于 QPSO 算法移动机器人的路径规划的收敛性与初始粒子分布有关.

**证明** 基于 QPSO 算法的路径规划中, 粒子群位置变化与每条路径的分割点有关. 根据概率论的乘法定理, 每个路径分割点的收敛概率可表示为

$$P(A_1, A_2, \dots, A_D) = P(A_1)P(A_2|P(A_1)) \cdots P(A_D|A_1 A_2 \cdots A_{D-1}). \quad (12)$$

其中:  $A_1, A_2, \dots, A_D$  为路径分割点的事件,  $P(A_1, A_2, \dots, A_D)$  为一个路径到最优解的概率. 在该算法每个路径分割点的初始分布都是均匀分布, 每个分割点的事件是互相独立的, 所以式 (12) 可简化为

$$P(A_1, A_2, \dots, A_D) = \int_A \prod_{i=1}^D P(A_i) = \int_A P(A_1)^D. \quad (13)$$

由式 (13) 可知, 路径收敛概率中粒子的维度比粒子的最大迭代次数和粒子数具有更重要的作用, 即粒子的维度 (路径分割点数量) 越多, 路径收敛概率越小. 根

据马尔可夫链的定理和 C-K (Chapman-Kolmogorov) 方程, 粒子群的收敛概率在粒子群状态空间中表示为由一步转移概率到  $M$  步转移概率, 一个粒子的转移概率表示为

$$P_i(0) = P\{X_0 = R_i\}, i = 1, 2, \dots, D. \quad (14)$$

$$P_i(m) = P\{X_m = R_i\} = \sum_{t=1}^M P_i \cdot P_{t,i}(m), \quad m = 1, 2, \dots, M. \quad (15)$$

$$P_i(m) = P\{X_m = S_i\} = \sum_{j=1}^N \sum_{t=1}^M P(X(S_{i,j}) = S_{j,t}). \quad (16)$$

其中: 式 (14) 表示一个粒子的一步转移概率, 式 (15) 表示粒子状态空间的  $M$  步转移概率, 式 (16) 表示粒子群状态空间的  $M$  步转移概率,  $R_i$  和  $S_i$  分别表示粒子状态空间和粒子群状态空间. 由于式 (14) 的一步转移概率  $P_i(0)$  是初始分布概率, 而且表示粒子状态空间和粒子群状态空间的  $M$  步转移概率包括一步转移概率  $P_i(0)$ , 由式 (15) 和 (16) 可知粒子的收敛性与初始分布有关, 当初始时刻分布在最优解附近时, 粒子很快收敛到最优解.  $\square$

粒子本身的最优解  $P_g$  与粒子数  $N$  有关, 随着粒子数  $N$  的增加, 粒子的位置快速地接近  $P_g$ , 粒子群的全局最优解  $P_g$  与迭代次数  $M$  有关, 随着迭代次数  $M$  的增加  $P_g$  收敛到最优解, 粒子数  $N$  和迭代次数  $M$  存在一定的限制. 因此, 粒子数  $N$ 、迭代次数  $M$ 、粒子维度  $D$  是重要的收敛控制参数.

为考察各参数对收敛性的影响, 分别采用 3 种粒子群优化算法进行路径规划仿真实验, 即基本粒子群优化算法 (PSO)、量子行为粒子群优化算法 (QPSO) 和变学习因子的粒子群算法 (LnPSO). 仿真环境为  $50 \text{ m} \times 50 \text{ m}$  的无障碍区域, 选取粒子维度 (路径分割数量)  $10 \leq D \leq 50$ , 粒子数  $10 \leq N \leq 100$ , 迭代次数  $50 \leq M \leq 1000$ , 搜索角度为  $[0, \pi/2]$ , 学习因子  $c_1 = 2.1$ ,  $c_2 = 2$ ,  $\alpha = 1.0 \sim 0.5$ . 采用  $c_1$  和  $c_2$  固定、 $\alpha$  动态线性递减策略, 粒子初始分布分为均匀分布和正态分布  $N(45^\circ, 30^\circ)$ . 随着粒子维度  $D$  的变化, 50 次运算后得到的平均最优值和最优解的绝对误差小于  $0.01 \text{ m}$ , 所需要的粒子数  $N$  和迭代次数  $M$  如表 1 和表 2 所示, 表 1 中粒子初始分布为均匀分布, 表 2 中粒子初始分布为正态分布.

由表 1 和表 2 可知, 平均分布时 QPSO 算法的粒子数和迭代次数分别是正态分布时的 2.5 倍和 2.67 倍, 而平均分布时 PSO 算法的粒子数和迭代次数分别是正态分布时的 2.5 倍和 4 倍, 平均分布时 LnPSO 算

表1 平均分布时最小有限粒子数的迭代次数

算法	D = 10		D = 20		D = 30		D = 40		D = 50	
	N	M	N	M	N	M	N	M	N	M
QPSO	10	100	20	500	70	700	200	1000	800	1500
PSO	10	150	20	900	80	1000	500	1500	900	2000
LnPSO	10	100	20	600	60	800	400	1300	800	1800

表2 正态分布  $N(45^\circ, 30^\circ)$  时最小有限粒子数的迭代次数

算法	D = 10		D = 20		D = 30		D = 40		D = 50	
	N	M	N	M	N	M	N	M	N	M
QPSO	10	50	10	300	30	500	200	400	300	600
PSO	10	100	10	550	20	900	200	1000	500	800
LnPSO	10	100	10	300	20	650	200	800	400	700

法的粒子数和迭代次数分别是正态分布时的2倍和2.57倍,因此正态分布时粒子群的初始位置到最优解比均匀分布时近,收敛速度更快,可行的参数大小也相对较小,所以粒子群优化算法的收敛性与初始分布有关.当初始粒子分布选择正态分布时,粒子数和迭代次数更少,因而,计算时间更短.

### 1.3 路径规划仿真

下面对本文提出的QPSO算法和LnPSO算法以及文献中的PSO算法进行仿真比较.仿真中移动机器人的大小为 $0.5\text{ m} \times 0.5\text{ m}$ ,环境大小为 $50\text{ m} \times 50\text{ m}$ 的二维平面区域,出发点坐标为 $(0,0)$ ,目标点坐标设为 $(50,50)$ ,搜索范围为 $[0, \pi/2]$ ,粒子群算法的参数 $c_1 = 2.1$ , $c_2 = 2$ , $\alpha = 1.0 \sim 0.5$ ,采用 $c_1$ 和 $c_2$ 固定、 $\alpha$ 动态线性递减策略,初始分布分别为均匀分布和正态分布 $N(45^\circ, 30^\circ)$ ,粒子的维度为 $D = 50$ .经过50次反复仿真后得到的最优路径长度、标准误差和计算时间的结果如表3和表4所示.

表3 平均分布时仿真结果

计算结果	本文QPSO算法	本文LnPSO算法	经典PSO算法
最短路径/m	74.16	79.06	80.04
标准误差/m	0.15	0.35	0.32
计算时间/min	103.2	104.5	108.43

表4 正态分布时仿真结果

计算结果	本文QPSO算法	本文LnPSO算法	经典PSO算法
最短路径/m	73.98	79.08	81.12
标准误差/m	0.11	0.34	0.33
计算时间/min	20.59	40.5	73.4

由表3和表4可看出:

1) 均匀分布时, QPSO算法得到的路径长度比LnPSO算法短5.1 m, 比经典PSO算法短5.9 m; QPSO算法的计算时间比LnPSO算法少1.3 min, 比经典PSO算法少5.23 min.

2) 正态分布时, QPSO算法得到的路径长度比LnPSO算法短5.1 m, 比经典PSO算法短7.14 m; QPSO

算法的计算时间比LnPSO算法少19.91 min, 比经典PSO算法少52.81 min.

此外, QPSO算法的计算时间在初始分布为正态分布时比均匀分布时更短. 因此, 基于QPSO算法的路径规划收敛性更好, 且初始分布为正态分布时, 该算法的粒子数和迭代次数更少, 计算时间更短.

## 2 运动轨迹规划建模与实验验证

### 2.1 运动轨迹规划建模

在路径规划过程中, 采用移动机器人的最大线速度和旋转角速度, 得到一条最优轨迹; 然后根据轨迹跟踪控制系统特性, 算出新的运动时间和每个轮子的线速度, 并调整机器人的运动轨迹, 得到轨迹规划结果. 图2为移动机器人的运动约束示意图.




图2 在路径上移动机器人运动约束

图2中:  $A_1$ 、 $A_2$ 、 $A_3$  表示粒子之间的距离,  $C_p$  表示移动机器人运动中心,  $V$  和  $\omega$  分别表示移动机器人的最大线速度和旋转角速度. 运动总时间如下:

$$\text{Time}_G = \text{Time}_T + \text{Time}_R. \quad (17)$$

其中:  $\text{Time}_G$  为总运动时间,  $\text{Time}_T$  和  $\text{Time}_R$  为移动和旋转运动时间, 分别满足如下关系:

$$\begin{cases} \text{Time}_T = \sum_{t=1}^{D-1} \frac{\text{Distance}(A_{i+1}, A_i)}{V}, \\ \text{Time}_R = \sum_{t=1}^{D-1} \frac{\text{Angle}(A_{i+1}, A_i)}{\omega}. \end{cases} \quad (18)$$

$\text{Angle}(A_{i+1}, A_i)$  是在惯性坐标系下移动机器人质心的运动角度.

考虑该移动机器人的控制特性再计算可行的路径, 用机器人的控制周期和最大线速度与角速度算出每个控制周期的移动距离与旋转角度, 即

$$\begin{cases} L_{\text{robot}} = V \times T, \\ \theta_{\text{robot}} = \omega \times T. \end{cases} \quad (19)$$

其中:  $L_{\text{robot}}$  和  $\theta_{\text{robot}}$  分别为一个控制周期的移动距离和旋转角度,  $T$  为控制周期.

根据每个粒子之间的距离和旋转角度算出一个控制周期的移动距离和旋转角度, 它们成倍数关系, 更新路径规划的适应度函数, 包括轨迹距离和运动时

间的最优值。

$$\text{Fitness}(\text{orbit}) = f(\text{Fitness}(T_G), \text{Fitness}(L_G)). \quad (20)$$

其中:  $\text{Fitness}(T_G)$  为移动机器人的最优运动时间,  $\text{Fitness}(L_G)$  为考虑控制周期的最优移动距离。

通过更新轨迹优化适应度函数来完成任任务, 由轨迹规划的线速度和角速度决定每个轮子的线速度. 文献 [17-19] 利用 Unicycle 类型移动机器人的运动与控制系统, 用轮式移动机器人的运动方程计算出每个轮子的线速度和轨迹规划. 移动机器人的电机控制一般采用 PWM 控制, 所以还要验证 PWM 控制的可能性, 根据 PWM 控制律来确定可实现轨迹的最优参数。

### 2.2 轨迹规划仿真

在轨迹规划仿真中, 移动机器人的大小为  $0.3 \text{ m} \times 0.4 \text{ m}$ , 环境大小为  $3 \text{ m} \times 3 \text{ m}$  的二维平面区域, 出发点为  $(0, 0)$ , 目标点设为  $(3, 3)$ , 搜索角度为  $[0, \pi/2]$ , 粒子群算法的参数分别为  $c_1 = c_2 = 1.5, \alpha = 1.0 \sim 0.5$ , 采用  $c_1$  和  $c_2$  固定、 $\alpha$  动态线性递减策略, 初始分布取正态分布  $N(45^\circ, 30^\circ), D = 30, N = 30, M = 500$ , 最大线速度和角速度分别为  $v = 0.24 \text{ m/s}, \omega = 0.2 \text{ rad/s}$ , 控制周期为  $0.3 \text{ s}$ , 控制参数为  $k_1 = 1.2, k_2 = 30, k_3 = 0.5, k_4 = 0.001$ , 初始位姿误差为  $(0, 0, 45^\circ)^T, v(0) = 0 \text{ m/s}, \omega(0) = 0 \text{ rad/s}$ . 模拟方案有路径规划和轨迹规划两种, 即考虑了移动机器人 PWM 控制特性的路径规划. 对于每个方案, 都采用 50 次反复计算。

表 5 所示为路径规划与轨迹规划的仿真结果对比, 从中可看出, 路径规划的运动距离和时间比轨迹规划的运动距离和时间略小, 运动距离相差  $0.0258 \text{ m}$ , 运动时间相差  $0.16 \text{ s}$ , 但差别不是很大. 前面已经讨论过, 本文中 QPSO 的路径规划是一个优化的结果, 表 5 中的数据表明本文提出的轨迹规划方法也是一个较为理想的方法。

表 5 路径规划与轨迹规划仿真结果

方案	运动距离/m	运动时间/s	平移时间/s	旋转时间/s
路径规划	4.5676	34.04	19.0316	15.0084
轨迹规划	4.5934	34.2	19.2	15

基于上述两种方案的轨迹跟踪曲线与 QPSO 规划的计算轨迹对比结果如图 3 和表 6 所示. 其中图 3(a) 中的控制轨迹为基于路径规划的轨迹跟踪曲线, 图 3(b) 中的控制轨迹为基于轨迹规划的跟踪曲线. 图示结果表明, 路径规划的控制轨迹和轨迹规划的控制轨迹都接近计算轨迹. 进一步的误差分析结果见表 6. 由表 6 可以看出, 轨迹规划的控制轨迹的平均误差比路径规划的控制轨迹的平均误差小, 位置平均误差小于  $0.064 \text{ m}$ , 姿态角平均误差小于  $1.85^\circ$ , 这些对比分析结果表明, 基于 QPSO 算法的移动机器人轨迹规划控

制比常规路径规划控制算法更可行更有效。

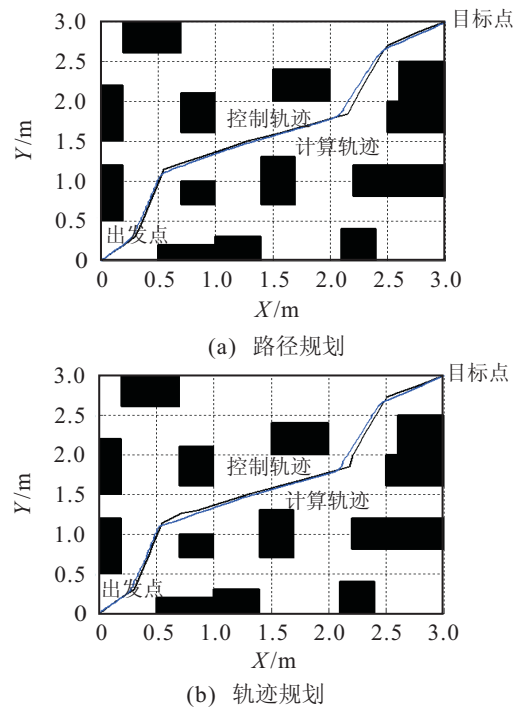


图 3 轨迹跟踪控制仿真结果

表 6 轨迹跟踪控制平均绝对误差值

方案	控制轨迹		
	$\Delta X/\text{m}$	$\Delta Y/\text{m}$	$\Delta \theta/(\circ)$
路径规划	0.098	0.094	3.041
轨迹规划	0.064	0.059	1.850

### 2.3 差速驱动轮式移动机器人平台的实验

为了进一步分析本文提出的轨迹规划方法的有效性, 采用两轮独立三轮差速移动机器人平台进行实验, 三轮差速移动机器人平台机构如图 4 所示. 移动机器人平台的两个主动轮在前、从动轮在后, 机器人质量为  $2.3 \text{ kg}$ , 机器人驱动轮质量为  $0.28 \text{ kg}$ , 机器人质心到驱动轮几何中心距离为  $0.065 \text{ m}$ , 机器人转动惯量为  $0.1 \text{ kg} \cdot \text{m}^2$ , 驱动轮转动惯量为  $0.0021 \text{ kg} \cdot \text{m}^2$ , 驱动轮间距为  $0.3 \text{ m}$ , 驱动轮半径为  $0.068 \text{ m}$ , 电机周转脉冲数为 16, 控制芯片倍频为 2, 编码器脉冲计数周期 (每  $5 \text{ ms}$  计算一次脉冲数) 为  $0.005 \text{ s}$ , 减速器减速比为 131, 机器人通过串口向上位机发送脉冲编码的时间间隔为  $0.3 \text{ s}$ , 采用该平台进行 100 次实验。



图 4 差速驱动移动机器人平台的机构

移动机器人轨迹规划和轨迹跟踪的实验结果如图 5、图 6 和表 7 所示。

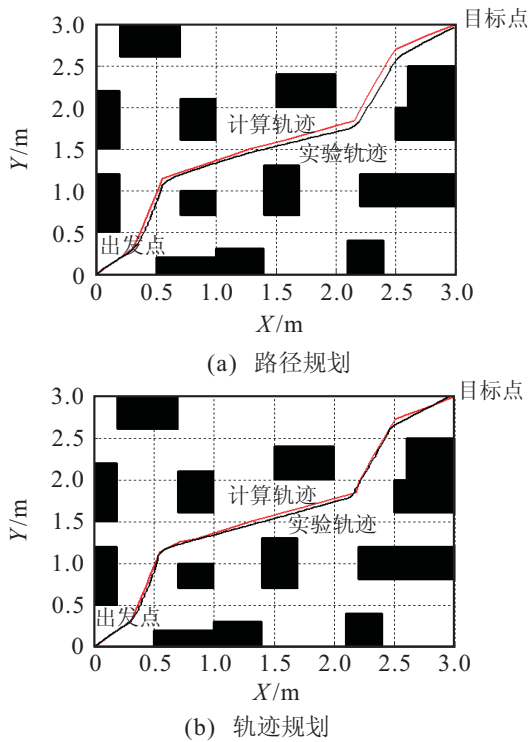


图 5 轨迹实验结果




图 6 实验误差分析结果

表 7 平均绝对误差值对比

方案	控制轨迹仿真			轨迹实验		
	$\Delta X/m$	$\Delta Y/m$	$\Delta \theta/(\circ)$	$\Delta X/m$	$\Delta Y/m$	$\Delta \theta/(\circ)$
路径规划	0.0983	0.0946	3.0419	0.1769	0.1865	3.4934
轨迹规划	0.0641	0.0594	1.8504	0.0848	0.0863	2.2395

从图 5 可以看出, 图 5(a) 中的实验轨迹明显偏离计算轨迹, 而图 5(b) 中采用轨迹控制的实验轨迹更接近

于计算轨迹, 相应的误差分析列于图 6 和表 7 中. 表 7 中数据显示, 轨迹规划方法驱动的机器人实验运动轨迹在 X 方向和 Y 方向平均误差在 0.1 m 以下, 方向角平均误差小于  $2.3^\circ$  (表 7 中第 4 行第 5 列~第 7 列). 将表 7 中第 3 行、第 4 行第 2 列~第 4 列中数值与第 5 列~第 7 列相应数值比较, 进一步发现轨迹规划方法比路径规划的方向误差小 1.57~2.16 倍, 即轨迹规划方法驱动的机器人实验轨迹与规划计算轨迹吻合度高, 因此用考虑机器人运动特征的轨迹规划能够提高轨迹跟踪控制的精度. 实验分析表明, 基于 QPSO 算法移动机器人的轨迹规划高效可行.

### 3 结 论

本文提出了基于量子行为粒子群优化和极坐标变换的移动机器人路径规划方法, 用栅格法对环境进行建模, 并采用马尔科夫链和概率论的方法, 分析了移动机器人路径规划的收敛性和路径规划的重要参数对算法性能的影响. 通过计算仿真给出了 3 种粒子群优化算法中能保证收敛的粒子数和最大迭代次数. 当初始分布为均匀分布和正态分布时, 对比了该方法和经典方法的差别, 验证了该方法的有效性和可行性. 最后, 考虑移动机器人的运动特性带来的影响, 对算法做了改进, 并用差速驱动轮式移动机器人平台进行轨迹跟踪实验, 验证了该方法的有效性和可行性.

### 参考文献(References)

- [1] 朱大奇, 颜明重. 移动机器人路径规划技术综述[J]. 控制与决策, 2010, 25(7): 961-967.  
(Zhu D Q, Yan M Z. Survey on technology of mobile robot path planning[J]. Control and Decision, 2010, 25(7): 961-967.)
- [2] 纪震, 廖惠连, 吴青华. 粒子群算法及应用[M]. 北京: 科学出版社, 2009: 27-78.  
(Ji Z, Liao H L, Wu Q H. Particle swarm optimization and application[M]. Beijing: Science Press, 2009: 27-78.)
- [3] 肖健梅, 李军军, 王锡淮. 梯度微粒群优化算法及其收敛性分析[J]. 控制与决策, 2009, 24(4): 560-564.  
(Xiao J M, Li J J, Wang X H. Convergence analysis of particle swarm optimization and its improved algorithm based on gradient[J]. Control and Decision, 2009, 24(4): 560-564.)
- [4] 任子晖, 王坚, 高岳林. 马尔科夫链的粒子群优化算法全局收敛性分析[J]. 控制理论与应用, 2011, 28(4): 462-466.  
(Ren Z H, Wang J, Gao Y L. The global convergence analysis of particle swarm optimization algorithm based on Markov chain[J]. Control Theory & Applications, 2011, 28(4): 462-466.)

- [5] Ozean E, Mohan C. Analysis of a simple particle swarm optimization system[C]. *Intelligent Engineering Systems Through Artificial Neural Networks*. New York: American Society of Mechanical Engineers, 1998, 8: 253-258.
- [6] Trelea I C. The particle swarm optimization algorithm: Convergence analysis and parameter selection[J]. *Information Processing Letters*, 2003, 85(6): 317-325.
- [7] Rapaic M R, Kanovic Z. Time-varying PSO-convergence analysis, convergence-related parameterization and new parameter adjustment schemes[J]. *Information Processing Letters*, 2009, 109(11): 548-522.
- [8] Yang Shi, Hongcheng Liu, Liang Gao, et al. Cellular particle swarm optimization[J]. *Information Sciences*, 2011, 181(20): 4460-4493.
- [9] 孙俊, 方伟, 吴小俊, 等. 量子行为粒子群优化算法: 原理与其应用[M]. 北京: 清华大学出版社, 2011: 31-68.  
(Sun J, Fang W, Wu X J, et al. Quantum-behaved particle swarm optimization: Principle and application[M]. Beijing: Tsinghua University Press, 2011: 31-68.)
- [10] 方伟, 孙俊, 谢振平, 等. 量子粒子群优化算法的收敛性分析与控制参数研究[J]. *物理学报*, 2010, 59(6): 3686-3694.  
(Fang W, Sun J, Xie Z P, et al. Convergence analysis of quantum-behaved particle swarm optimization algorithm and study on its control parameter[J]. *Acta Physica Sinica*, 2010, 59(6): 3686-3694.)
- [11] Clerc M, Kennedy J. The particle swarm: Explosion, stability, and convergence in a multi-dimensional complex space[J]. *IEEE Trans on Evolutionary Computation*, 2002, 6(1): 58-73.
- [12] Sun J, Wu X J. Convergence analysis and improvements of quantum-behaved particle swarm optimization[J]. *Information Sciences* 2012, 193(6): 81-83.
- [13] 秦元庆, 孙德宝, 李宁, 等. 基于粒子群算法的移动机器人路径规划[J]. *机器人*, 2004, 26(3): 222-225.  
(Qin Y Q, Sun D B, Li N, et al. Path planning for mobile robot based on particle swarm optimization[J]. *Robot*, 2004, 26(3): 222-225.)
- [14] 孙波, 陈卫东, 席裕庚. 基于粒子群优化算法的移动机器人全局路径规划[J]. *控制与决策*, 2005, 20(9): 1052-1060.  
(Sun B, Chen W D, Xi Y G. Particle swarm optimization based global path planning for mobile robots[J]. *Control and Decision*, 2005, 20(9): 1052-1060.)
- [15] 黄麟, 奚茂龙, 孙俊, 改进 QPSO 算法的移动机器人轨迹跟踪控制方法[J]. *计算机工程与应用*, 2012, 48(34): 230-236.  
(Huang L, Xi M L, Sun J. Method of trajectory tracking control for mobile robots with improved QPSO algorithm[J]. *Computer Engineering and Applications*, 2012, 48(34): 230-236.)
- [16] Urmson C, Anhalt J, Clark M. High speed navigation of unrehearsed terrain-red team technology for grand challenge[R]. CMU-RI-TR-04-37, The Robotics Institute, Carnegie Mellon University, 2004.
- [17] 曹其新, 张蕾. 轮式移动机器人[M]. 上海: 上海交通大学出版社, 2012: 159-187.  
(Cao Q X, Zhang L. Wheeled mobile robot[M]. Shanghai: Shanghai Jiaotong University Press, 2012: 159-187.)
- [18] Deng N M, Inoue A, Sekiguchi K, et al. Two-wheeled mobile robot motion control in dynamic environments[J]. *Robotics and Computer-Integrated Manufacturing*, 2010, 26(3): 268-272.
- [19] Takanori Fukao, Hiroshi Nakagawa, Norihiko Adachi. Adaptive tracking control of a nonholonomic mobile robot[J]. *IEEE Trans on Robotics and Automation*, 2000, 16(10): 608-614.

(责任编辑: 孙艺红)