

基于支持向量机和改进蚁群算法的移动机器人路径规划^①

张劲波^{②*} 左 韬^{③***} 胡新宇^{*} 伍一维^{*}

(^{*} 武汉科技大学信息科学与工程学院 武汉 430081)

(^{**} 武汉科技大学冶金自动化与检测技术教育部工程研究中心 武汉 430081)

摘要 针对传统蚁群算法(ACO)收敛速度慢、全局搜索能力不佳、易陷入局部最优、路径不光滑及不安全等缺点,本文提出一种将改进的蚁群算法和非线性支持向量机(SVM)结合的移动机器人路径规划算法。对传统蚁群算法引入两个角度信息,增加算法的朝向性,克服局部最优问题;信息素挥发因子随迭代次数自适应调整,加快全局搜索能力和收敛速度。在此基础上结合高斯径向基核最小二乘支持向量机,采用提出的改进蚁群算法获得支持向量机的惩罚系数和核函数宽度,利用径向基核函数和决策函数在改进蚁群算法的路径转向位置处训练优化,得到平滑及安全的路径。仿真结果表明,提出的算法不但可以有效提高收敛速度和精度,而且使得路径光滑且安全。

关键词 蚁群算法(ACO); 支持向量机(SVM); 路径规划; 移动机器人

0 引言

移动机器人路径规划最早起源于 20 世纪 60 年代,是移动机器人导航至关重要的核心技术^[1],也是当今机器人研究的热门领域之一^[2-3]。其主要功能是在工作空间中找到一条从起点运动到目标点的最优或者次优且能避开所有障碍物的路径^[4]。路径规划在很多高新技术领域都有着非常重要的应用,比如无人机驾驶、服务机器人自主运动、GPS 导航等。

目前,很多研究者对移动机器人的路径规划提出了诸多算法,比如传统的人工势场法^[5]和视图法^[6],基于图形学的栅格图法^[7]和 voronoi 法^[8],基于智能仿生学的遗传算法^[9]和蚁群算法(ant colony algorithm, ACO)^[10-12]等。这些算法在一定程度上有不错的路径规划效果,但是大多存在搜索效率低下、精度不高、路径拐点尖锐且不安全等缺点。对于障碍物单一且非结构化道路^[13](如乡村道路),出

现了基于支持向量机(support vector machine, SVM)的路径规划方法^[14-16],它们有着路径平滑且距离障碍物最远的特点,但是不能对障碍物分布无规则且较为复杂的环境进行路径规划。

针对上述各类算法的缺点,本文将蚁群算法和支持向量机结合,做出以下几点创新。首先对传统蚁群算法进行改进,将当前节点到下一节点的直线与当前节点到终点的直线之间的角度、当前节点到下一节点的直线与下一节点到终点的直线组成的角度加入进启发函数中,增加朝向性,以克服易陷入局部最优问题。其次信息素挥发因子随迭代次数自适应调整,使其前期较小,后期较大,加快全局搜索能力和后期收敛速度。最后结合改进蚁群算法和非线性支持向量机,采用蚁群算法得到的初始路径进行预处理获取两类目标,并利用提出的改进蚁群算法获得支持向量机的最佳惩罚系数和核函数宽度,再利用高斯径向基核最小二乘支持向量机对转向处目标进行训练,在不增加路径长度的前提下,得到平滑

^① 国家自然科学基金(61673304),湖北省技术创新专项重大项目(2019AAA071)和机器人与智能系统研究院开放基金(F201804)资助项目。

^② 男,1995 年生,硕士生;研究方向:机器人;E-mail: 1585519736@qq.com

^③ 通信作者,E-mail: zuomu666@163.com

(收稿日期:2020-03-30)

且安全的路径。

1 改进蚁群算法

1.1 环境建模

本文采用栅格法^[17]来进行环境建模, 将移动机器人的运动空间用大小相同的若干栅格来表示, 建立二维运动环境模型。栅格法前提是已知障碍物和可行域坐标位置, 可分别用黑色和白色栅格代表障碍物和可行空间, 然后对得到的栅格进行标号, 每个栅格中心都对应一个坐标, 从左上方序号依次增加, 第*i*行第*j*列的横纵坐标表达式为

$$\begin{cases} x_i = \text{mod}((i - 1)/N_x) + 0.5 \\ y_i = \text{fix}((i - 1)/N_y) + 0.5 \end{cases} \quad (1)$$

式中 *mod* 表示取余, *fix* 表示取整, *N_x*、*N_y* 表示每行、每列的栅格数目。

机器人在栅格地图中的运动过程是每次从一个栅格的中心到另外一个栅格的中心, 所以其运动方向有 8 种, 栅格地图和机器人运动方向如图 1 所示。

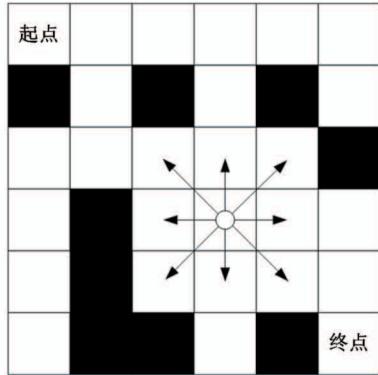


图 1 栅格地图及运动方向

1.2 蚁群算法

蚁群算法是通过模拟蚂蚁寻找食物过程时会释放一种称之为信息素的物质, 路径较短的蚂蚁会释放更多的信息素, 蚂蚁会朝着信息素多的路径上运动, 随着时间的推进, 较短的路径会积累越来越多的信息素, 最终选择该路径的蚂蚁越来越多, 在正反馈的机制下寻找出最优路径。蚁群算法具有适应性强、易与其他算法相结合等特点。传统蚁群算法机器人路径规划步骤如下。

步骤 1 采用栅格法对环境地图进行建模并初

始化算法各类参数。

步骤 2 利用路径转移概率选择下一节点, 记录蚂蚁走过的栅格并加入到禁忌表中, 计算蚂蚁走过的路径长度。

$$P_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}(t)]^\beta}{\sum_{s \in \text{allowS}(k)} [\tau_{is}(t)]^\beta [\eta_{is}(t)]^\beta} & j \in \text{allowS}(k) \\ 0 & \text{其他} \end{cases} \quad (2)$$

其中, *P_{ij}^k(t)* 为路径转移概率, *τ_{ij}(t)* 表示从节点 *i* 到节点 *j* 路径上的信息素浓度, *η_{ij}(t)* 为启发函数, *α* 和 *β* 为启发因子常数, *allowS(k)* 为第 *k* 只蚂蚁下一次能到达的所有节点。

步骤 3 当代所有蚂蚁都到达目标点后, 除去未到达目标点的蚂蚁, 计算所有蚂蚁走过的路径长度。对当代所有蚂蚁进行优劣排序, 在最优的路径上更新其信息素。信息素浓度更新公式为

$$\tau_{ij}(t + 1) = (1 - \rho)\tau_{ij}(t) + \Delta\tau_{ij}(t) \quad (3)$$

式中, *τ_{ij}(t)* 为更新前 *d_{ij}* 上的信息素浓度, *ρ* 为信息素挥发因子常数, 取值范围为 (0, 1), *Δτ_{ij}(t)* 为搜索过程中经过该路径的所有蚂蚁信息素浓度之和, 其公式为

$$\Delta\tau_{ij}(t) = \sum_{k=1}^m \Delta\tau_{ij}^{(k)}(t) \quad (4)$$

式中, *Δτ_{ij}^(k)(t)* 为每只蚂蚁经过该路径留下的信息素浓度

$$\Delta\tau_{ij}^{(k)}(t) = \begin{cases} \frac{Q}{L_d} & \\ 0 & \end{cases} \quad (5)$$

式中, *Q* 为第 *k* 只蚂蚁携带的信息素浓度因子, *L_d* 为第 *k* 只蚂蚁完成路径搜索后走过的路径长度。

步骤 4 重复步骤 2 和步骤 3, 直到蚂蚁迭代次数达到最大, 综合所有迭代次数, 得出全局最优路径。

1.3 启发函数改进

传统蚁群算法的启发函数只与当前节点到下一点的距离有关, 其表达式为

$$\eta_{ij}(t) = 1/d_{ij} \quad (6)$$

式中, *d_{ij}* 为节点 *i* 到节点 *j* 的欧式距离。当 *d_{ij}* 越小时, *η_{ij}(t)* 越大, 说明当前规划效果较好, 但易陷入

局部最优,所以本文改进为对 $f(d_{ij}, \theta_k)$ 函数求解,改进启发函数如下:

$$f(d_{ij}, \theta_k) = \eta_{ij}(t) = \frac{1}{d_{ij} + \theta_1 + \frac{1}{\theta_2}} \quad (7)$$

式中, θ_1 为当前节点到下一节点直线与当前节点到终点直线组成的夹角, θ_2 为当前节点到下一节点的直线与下一节点到终点直线组成的夹角,如图 2 所示。式(7)改进优势的证明如下。

A 为当前节点, B, C, D 为下一可选节点, E 为终点。

证明 1 比较路径 $AC + CE$ 和 $AB + BE$ 、 $\angle CAE$ 和 θ_1 的大小对启发函数的影响。

$\angle ABC$ 和 $\angle EBC$ 始终大于 90° 。

$\therefore AB < AC, BE < CE$

$\therefore AC + CE > AB + BE$

此时 $\theta_1 < \angle CAE, \angle ACE < \theta_2$, 满足 θ_1 越小, θ_2 越大, 则 $d_{ij} + \theta_1 + 1/\theta_2$ 越小, $\eta_{ij}(t)$ 越大, 路径越短, 且估计代价值越小, 不易陷入局部最优。

证明 2 再比较 $AD + DE$ 和 $AB + BE$ 对启发函数的影响, 此时 $\theta_1 = \angle BAE$ 。

$\therefore DB + BE > DE$

$\therefore AD + DE < AD + DB + BE$

$\therefore AD + DE < AB + BE$

所以当 $\theta_1 = \angle BAE$ 时(即 θ_1 不变), θ_2 越大, $d_{ij} + \theta_1 + 1/\theta_2$ 越小, 则 $\eta_{ij}(t)$ 越大, 路径越短, 朝向性越好, 估计代价值越小, 证毕。

1.4 信息素挥发因子改进

传统蚁群算法信息素挥发因子是固定不变的,

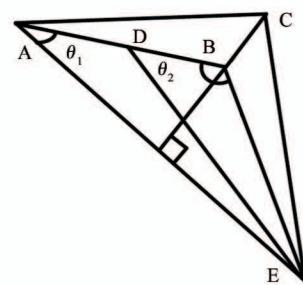


图 2 启发函数证明图

但其过大或过小既会影响算法的收敛速度也会使其陷入局部最优, 所以本文动态调整信息素挥发因子, 本文改进公式如下:

$$\rho(N) = \rho \cdot \left(\frac{N}{M}\right)^\omega, \omega = \frac{M-N}{N} \quad (8)$$

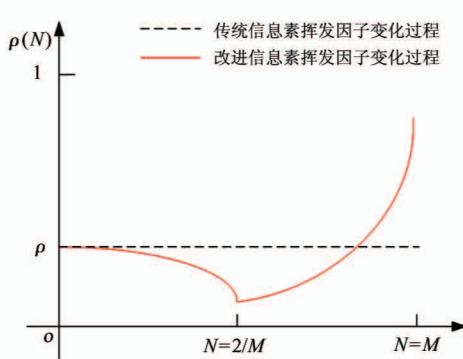
式中, N 为当前迭代次数, M 为总迭代次数, ρ 为初始设置的挥发因子常数。

前半期 $\rho(N)$ 要相对较小, $\frac{M-N}{N} > 1$, 且 $\frac{N}{M} - 1$

直小于 1, 那么 $\frac{N}{M}$ 的正数次幂越小。降低各路径信息素浓度差距, 减小蚁群引导作用, 增加蚂蚁前期的搜索范围, 提高算法精度。

后半期 $\rho(N)$ 相对较大, 后期时 $\frac{N}{M} < 1, \frac{M-N}{N}$

$< 1, \frac{M-N}{N}$ 越来越小, 则 $\frac{N}{M}$ 开根号越来越大, 那么 $\rho(N)$ 越来越大, 加快算法后期收敛速度, 提高算法效率。上述两个阶段效果如图 3 所示。从图 3(a) 中可以看出, 改进后的信息素挥发因子随迭代次数变化前期较小, 后期较大; 从图 3(b) 中可以看出, 改进后信息素挥发因子精度更高, 收敛速度更快。



(a) 信息素挥发因子随迭代次数变化规律

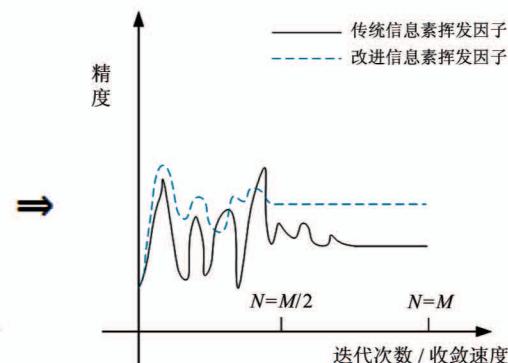


图 3 信息素挥发因子变化规律及效果对比

改进的蚁群算法虽然在一定程度上克服了易陷入局部最优、收敛速度慢等缺点,但是生成的路径拐点尖锐不符合机器人行走要求,且距离障碍物过近导致安全性低的问题。所以本文提出结合高斯径向基核最小二乘支持向量机优化改进蚁群算法拐点处,得到一条平滑且安全的路径,并用改进的蚁群算法取代传统的网格搜索法获取支持向量机的最佳核宽度和惩罚系数,然后用支持向量机进行路径优化,优化后的路径使得机器人运动更加流畅,降低了机器人消耗。

2 基于非线性支持向量机优化改进蚁群算法的路径规划

2.1 高斯径向基核最小二乘支持向量机

支持向量机是一类按监督学习(supervised learning)方式对数据进行二元分类的分类器。最小二乘支持向量机是利用误差平方,构造平方损失函数,将SVM非等式约束用等式约束替换,则二次规划问题转换成线性求解,并引入核函数解决非线性数据分类过程中的空间映射问题。

如图4所示的多维平面上,分布着两类不同的样本点,其中 H 是通过支持向量机训练后得到的最优分类超平面, H_1 和 H_2 是平行且距离 H 最近的两类样本点的标准超平面。通过样本点和类别标记可得训练集 $Q(i, j) = \{x_i, y_i\}$, $i = 1, 2, \dots, n$, $x_i \in R^n$, $y_i = \pm 1$ 。

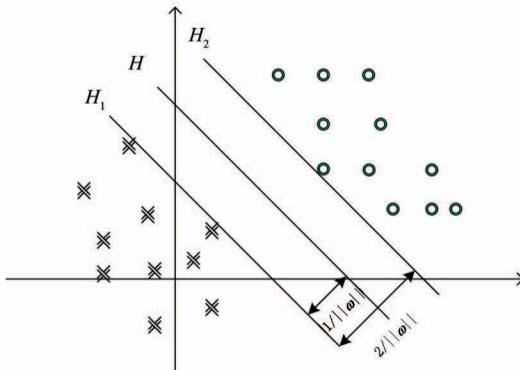


图4 支持向量机分类

x_i 是 n 维空间上的样本点, y_i 是分类标签,其值为 ± 1 。将 x_i 分成两类样本点, H 的表达式为 $\omega \cdot x$

$+ b = 0$, ω 是 H 的法向量,则 H_1 和 H_2 的表达式可为 $\omega \cdot x + b = \pm 1$,然后利用点到面的距离公式可求得标准超平面到最优超平面的距离为 $1/\|\omega\|$,两个标准超平面距离则为 $2/\|\omega\|$ 。为使最优分类超平面距离两类样本点最远,且保证两条标准超平面之间没有样本点,利用最小二乘支持向量机可转换成无约束条件的等式问题,即:

$$\begin{cases} y_i[(\omega_i \cdot x + b)] - 1 + \varepsilon_i = 0; i = 1, 2, \dots, n \\ \min_{\omega, b} \frac{1}{2} \|\omega\|^2 = \min_{\omega, b} \frac{1}{2} \omega^T \omega + \frac{\lambda}{2} \sum_{i=1}^n \varepsilon_i^2 \end{cases} \quad (9)$$

式中, λ 是惩罚系数,用来平衡寻找最优分类超平面和偏差量最小; ε_i 是误差,是优化目标之一。

本文训练的样本点是非线性的,所以需将不能线性可分的低维空间样本点映射到高维空间,然后在高维空间中利用软间隔方法进行逆变换,得到低维空间的最优分类超平面。低维空间与高维空间的映射关系为 $R^n \rightarrow R$, $x \rightarrow \varphi(x)$,可将上式变换为带有拉格朗日乘子的目标函数:

$$L(\omega, b, \alpha) = \frac{1}{2} \omega^T \omega + \frac{\lambda}{2} \sum_{i=1}^n \varepsilon_i^2 - \sum_{i=1}^n \alpha_i \{y_i[(\omega \cdot \varphi(x_i)) + b] - 1 + \varepsilon_i\} \quad (10)$$

按照非线性规划最优解必要条件(Karush-Kuhn-Tucker, KKT),对 $\omega, b, \varepsilon_i, \alpha_i$ 分别求偏导并令其等于0。

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 \\ \frac{\partial L}{\partial b} = 0 \\ \frac{\partial L}{\partial \varepsilon_i} = 0 \\ \frac{\partial L}{\partial \alpha_i} = 0 \end{cases} \Rightarrow \begin{cases} \omega = \sum_{i=1}^n \alpha_i y_i \varphi(x_i) \\ \sum_{i=1}^n \alpha_i y_i = 0 \\ \alpha_i = \lambda \varepsilon_i \\ y_i [\omega^T \varphi(x_i) + b] - 1 + \varepsilon_i = 0 \end{cases} \quad (11)$$

然后将4个等式转换为矩阵方程,消除 ω 和 ε_i :

$$\begin{bmatrix} 0 & Y^T \\ Y & K + \frac{1}{\lambda} \end{bmatrix} \begin{bmatrix} b \\ \alpha_i \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (12)$$

式中 $Y = [y_1, y_2, \dots, y_n]$, $\alpha_i = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$,

$\mathbf{y} = [1, 1, \dots, 1]$, 通过 Mercer 定理(任何半正定对称函数都可以作为核函数)可知, 可用核函数 $K(x_i, x_j)$ 代替 $k = \varphi(x_i)^T \cdot \varphi(x_j)$, 最终得到基于核函数的最小二乘支持向量机决策函数:

$$f(x) = \text{sgn}\left\{\sum_{i=1}^n \alpha_i y_i K(x, x_i) + b\right\} \quad (13)$$

合适的核函数可以更好地求解, 其主要作用是减少低维到高维空间映射时的计算量, 本文采用高斯径向基核函数 (Gaussian radial basis function, GRBF):

$$K(x, x') = \exp\left(-\frac{\|x - x'\|}{2\delta^2}\right) \quad \delta > 0 \quad (14)$$

式中 δ 代表核函数的宽度, 只需要确定合适的 δ 值, 就能以最小的代价发挥核函数的性能。

2.2 改进蚁群算法参数寻优法

通过式(12)和式(14)可知, 合适的惩罚系数 λ 和核函数宽 δ 对数据训练分类有着重要的影响, 本文采用 1.3 节和 1.4 节改进的蚁群算法从参数空间中找到使得 SVM 模型在样本集上性能最优的参数组合, 参数优化算法如图 5 所示。采用不同的 λ 和 δ 时支持向量机分类时的准确率不一样, 所以在应用改进蚁群算法去寻找参数组合空间中的最优组合时, 可以将其视为对分类准确率函数, 即对函数 $Y_{\max} = F(\lambda, \delta)$ 求最大值的情况。初始化各类参数后, 通过 2.1 节得到每一组 λ 和 δ 的分类准确率, 定义准确率越高的信息素浓度越大, 其余蚂蚁会朝着信息素浓度最大的位置移动, 每移动一次会得到一个新的准确率, 继而更新信息素浓度, 在正反馈的机制下从而搜寻出当代最优蚂蚁, 然后再进行全局搜索。具体步骤如下。

步骤 1 初始化蚁群各类参数, 包括蚁群最大迭代次数 M , 蚂蚁数量 m , 信息素初始挥发因子 ρ , λ 和 δ 的上限和下限, 并设置支持向量机训练数据集、训练数据集标签、测试数据集、测试数据集标签。

步骤 2 在 λ 和 δ 上下限间随机对 m 只蚂蚁进行赋值, 组成的坐标 (λ, δ) 作为蚂蚁的位置向量。

步骤 3 对每只蚂蚁所处位置通过非线性支持向量机计算其分类准确率和信息素浓度, 准确率越高信息素浓度越大, 将信息素浓度最大的蚂蚁位置作为其他蚂蚁的目标位置。

步骤 4 以信息素浓度最大的蚂蚁为目标位置, 其他蚂蚁朝着这只蚂蚁的位置移动, 搜寻当前迭代次数最优位置蚂蚁。

步骤 5 判断是否达到最大迭代次数, 若是, 输出分类准确率最大的蚂蚁所对应的 (λ, δ) ; 否则, 迭代次数加 1, 返回步骤 2 到步骤 4, 最后输出所有迭代次数的最优值。

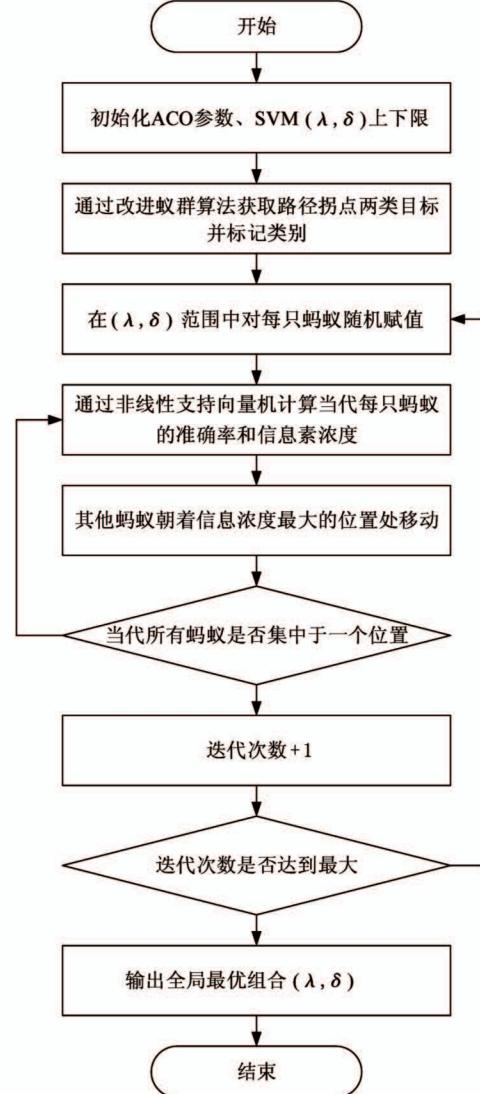


图 5 基于改进蚁群算法的支持向量机参数优化算法

3 实验仿真

本文采用 Matlab2016 进行仿真验证, 首先利用改进的蚁群算法应用于求解旅行商问题 (traveling salesman problem, TSP) 和求解函数最优点来进行验证; 然后将其应用于移动机器人路径规划上, 并与传

统蚁群算法比较;最后运用最小二乘支持向量机优化改进蚁群算法拐点路径。

(1)求解 TSP 问题。参数设置:设置 31 个城市比例坐标点,迭代次数 $M=800$,蚂蚁数量 $m=50$,初始挥发因子 $\rho=0.7$,启发因子 $\alpha=2, \beta=5$ 。将程序运行 20 遍,求其遍历所有坐标点后的最短路径、迭代次数的平均值及所有蚂蚁所有代数的路径长度的平均值,将其与传统蚁群算法对比,得到如表 1 所

示结果。

(2)求解函数最优值问题。参数设置与(1)相同,用改进的蚁群算法(此处用 ImACO 表示)求解表 2 的 3 个测试函数的最小值,运行 20 遍,与遗传算法(genetic algorithm, GA)、粒子群算法(particle swarm optimization, PSO)、传统蚁群算法(ACO)比较其最优值、迭代次数及 20 次平均值,得到如表 3 所示结果。

表 1 改进和传统蚁群算法求解 TSP 问题比较

算法	最短路径	平均迭代次数	路径平均值
传统蚁群算法	322.837	125.6	469.222
改进蚁群算法	280.545	80.2	448.751

表 2 测试函数

测试函数	维度	变量范围	最小值
$F_1(x_i) = 2.15 + x_1 \sin 4\pi x_1 + x_2 \sin 20\pi x_2$	2	$x_1 \in (3, 12)$ $x_2 \in (4, 16)$	-15.5003
$F_2(x_i) = \sum_{i=1}^{10} [(x_i^2 - x_i)^2 - (x_i - 1)^2]$	10	$x_i \in (3, 12)$	0.0000
$F_3(x_i) = \frac{1}{4000}(x_1^3 + x_2^5) - \sum_{i=1}^2 \cos \frac{x_i}{\sqrt{i}} + 1$	2	$x_i \in (3, 12)$	-3.0000

由表 1 结果可以发现,改进蚁群算法在求解 TSP 问题时,求得的最短路径和迭代次数相较于传统蚁群算法有了很大的提升。由表 3 可知,改进蚁群算法在求解 3 个函数最小值时都取得了较高的精度,且其结果在函数 F_1 和 F_3 上达到最优值,在 F_2 上虽然未达到最优值,但是其结果精度优于其他算法;从迭代次数上看,改进蚁群算法相对其他的算法有着更快的收敛速度,图 6 也表明同样的现象。总

体上来说,本文改进后的蚁群算法相对其他算法具有更好的精度和收敛速度。

(3)移动机器人路径规划仿真验证。同样采用 Matlab 编程进行实验仿真验证,地图环境采用栅格地图。参数设置为:迭代次数 300,蚂蚁数量 50,初始挥发因子 0.7,启发因子 $\alpha=2, \beta=5$ 。在简单和复杂栅格地图上分别进行仿真。

表 3 所提算法与其他算法在上述 3 个函数上的测试结果

函数	指标	ImACO	ACO	GA	PSO
F_1	最优值	-15.5003	-15.5003	-15.3003	-15.2760
	迭代次数	35	98	101	475
	20 次平均值	-15.5003	-15.5003	-15.4653	-15.1822
F_2	最优值	1.2547e-04	1.8625e-04	2.4987e-04	4.4485e-04
	迭代次数	137	162	582	768
	20 次平均值	1.3421e-04	2.5237e-04	2.5341e-04	7.7235e-04
F_3	最优值	-3.0000	-3.0000	-2.9999	-2.9998
	迭代次数	8	95	98	12
	20 次平均值	-3.0000	-3.0000	-2.9999	-2.9998

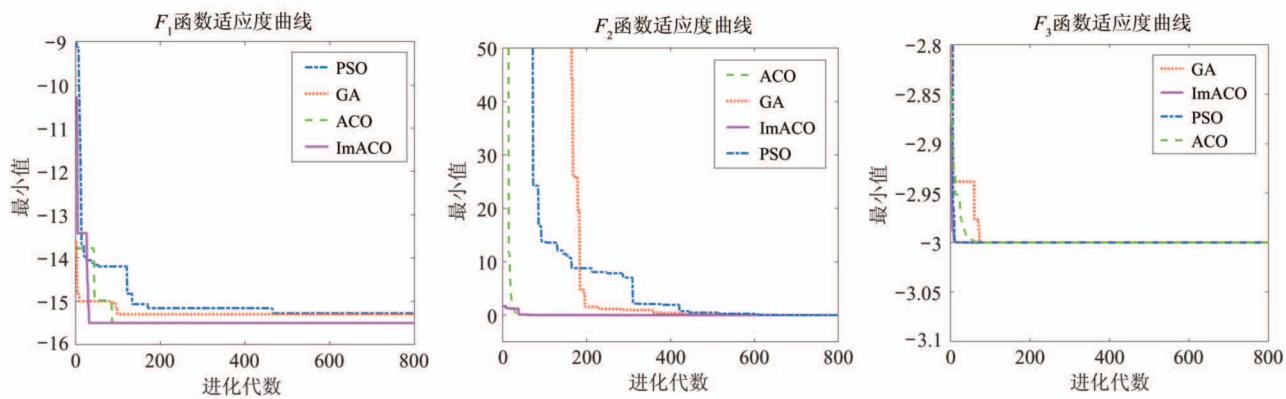


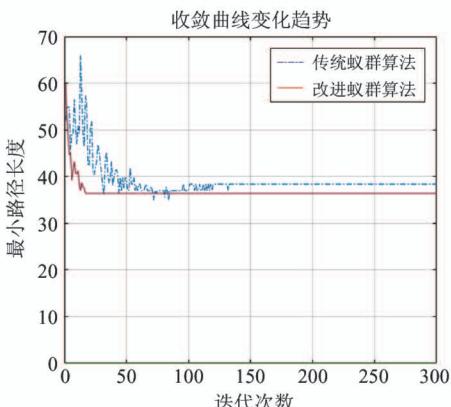
图 6 4 种算法在 3 个函数上的适应度曲线比较

从图 7 和图 8 可以发现, 改进后的蚁群算法在简单和复杂地图上的迭代次数和路径长度都有所减少, 减少了拐点的个数, 缩短了路径长度, 提高了算法的收敛速度, 使算法更高效和更精确。

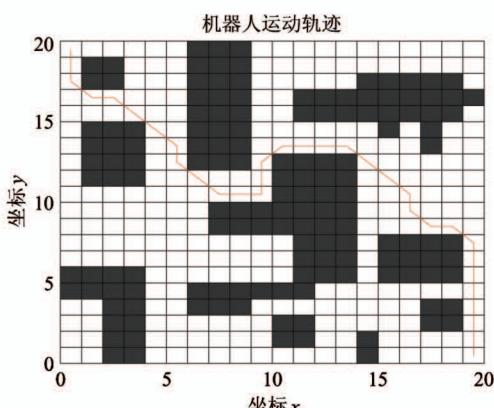
(4) 支持向量机优化改进蚁群算法路径规划验证。改进蚁群算法可以生成一条初始路径, 将路径拐点的两边作为两类目标, 然后用非线性支持向量

机对两类目标进行训练, 进而产生两类目标的最优分类超平面, 将此超平面作为移动机器人的拐点处移动路径。

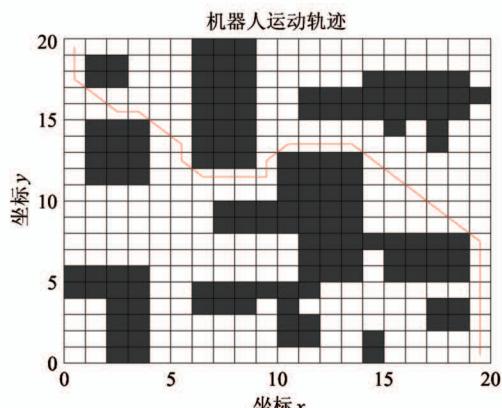
初始路径生成后, 提取路径拐点两边最近障碍物的边缘点坐标, 并对其类别进行标记, 得到两类训练数据, 设置步长 $a = 0.01$, 设置 λ 和 δ 的上下限, 即 $\lambda \in (-2^{12}, 2^{12})$, $\delta \in (-5, 15)$, 并采用 2.2 节



(a) 迭代次数和路径长度比较



(b) 传统蚁群算法路径



(c) 改进蚁群算法路径

图 7 简单栅格地图路径及收敛曲线对比

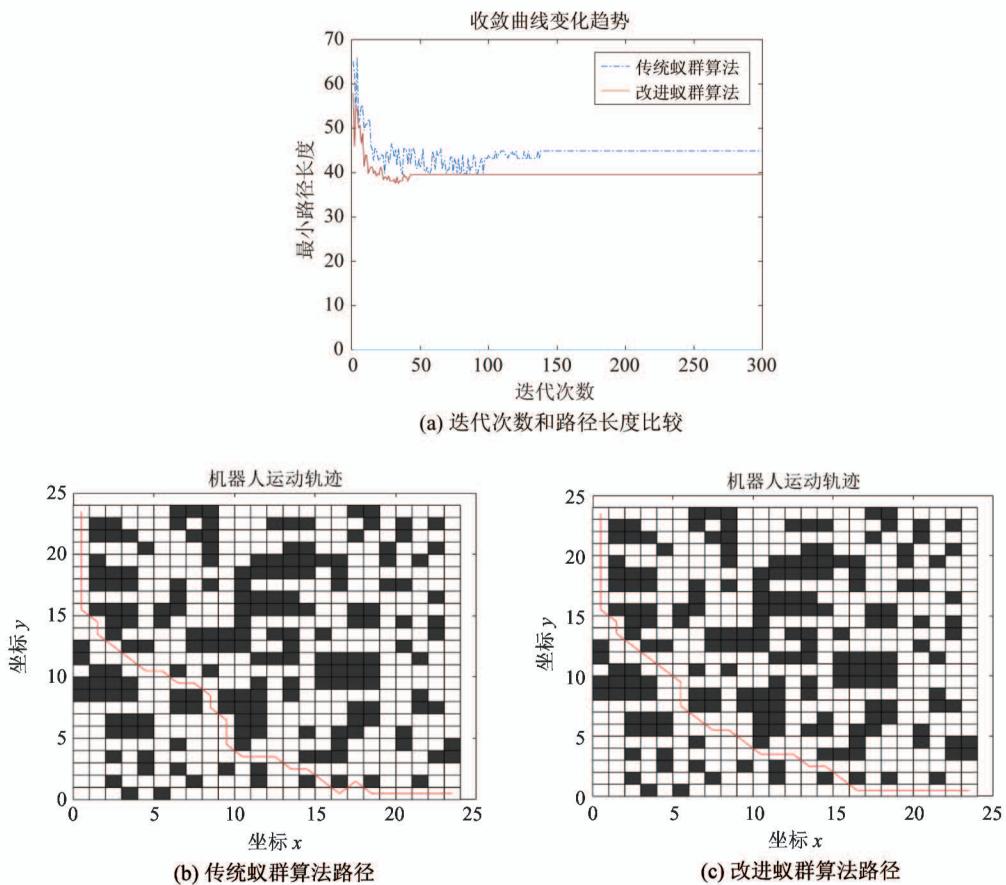


图 8 复杂栅格地图路径及收敛曲线对比

方法搜寻最优组合 (λ, δ) , 得到最优组合 $(\lambda, \delta) = (1024, 7.8492)$, 然后采用高斯径向基核最小二乘支持向量机对拐点目标进行训练得到最优分类超平面, 得到如图 9 所示效果。

图 9 左图是改进蚁群算法得到的一条初始路

径, 其路径长度相对传统蚁群算法有所减少, 但是其拐点尖锐且路径不安全, 机器人行走时损耗较高。右图是通过改进蚁群算法得到高斯径向基核最小二乘支持向量机最佳组合然后训练拐点后的路径, 可以看出其拐点处具有光滑和安全的特点, 在不增加

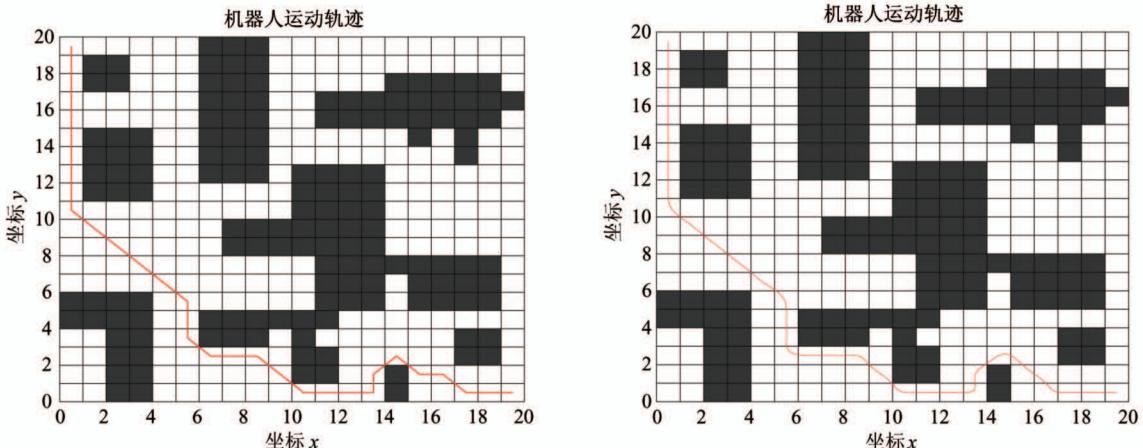


图 9 基于蚁群算法和高斯径向基核最小二乘支持向量机路径规划

路径长度的前提下使得机器人具有更好的行走路径,并且机器人在更好行走的同时不会碰到障碍物,验证了算法的有效性。

4 结 论

本文主要研究了最小二乘支持向量机结合改进的蚁群算法在移动机器人路径规划中的应用,主要做出以下改进。

(1)改进传统蚁群算法的启发函数,引入角度信息,即加入当前节点到下一节点的直线与当前节点到终点的直线之间的角度和当前节点到下一节点的直线与下一节点到终点的直线组成的角度信息,增加朝向性,克服易陷入局部最优问题。

(2)将信息素挥发因子改为随迭代次数自适应调整,使其前期较小,后期较大,加快全局搜索能力和后期收敛速度。

(3)利用改进的蚁群算法寻找支持向量机在当前两类目标中的最优组合,使得支持向量机的训练效果达到最佳。

(4)结合高斯径向基核最小二乘支持向量机优化改进蚁群算法的拐点路径,使得其尖锐的拐点变得平滑且远离障碍物。

对提出的改进蚁群算法首先求解 TSP 问题和 3 个函数的最小值,结果表明该算法具有更高的收敛速度和精度。将其用于机器人路径规划中,在简单和复杂栅格地图上进行验证,结果表明规划出的路径相对传统蚁群算法路径更短、迭代次数更少。最后对提出的 support vector machine 优化改进蚁群算法路径拐点进行验证,仿真结果表明,优化后的路径拐点处具有平滑的效果且远离障碍物,降低了机器人的损耗,并使得路径更加安全。在后续的研究中,将本文算法与 SLAM 和动态环境结合起来,在建图的同时增加障碍物后进行路径规划。

参 考 文 献

- [1] 冯坤,马磊,孙永奎. 基于激光传感器的变电站巡检机器人导航[J]. 传感器与微系统, 2019, 38(2): 118-120, 132
- [2] Wang L P. Automatic control of mobile robot based on au-tonomous navigation algorithm[J]. Springer Japan, 2019, 24(4): 494-498
- [3] Ibrahim D, Erin B, Abiyev R. Navigation of mobile robots in the presence of obstacles[J]. *Advances in Engineering Software*, 2010, 41(10/11): 1179-1186
- [4] 康玉祥,姜春英,秦运海,等. 基于改进 PSO 算法的机器人路径规划及实验[J]. 机器人, 2020, 42(1): 71-78
- [5] Montiel O, Sepúlveda R, Orozco-Rosas U. Optimal path planning generation for mobile robots using parallel evolutionary artificial potential field[J]. *Journal of Intelligent and Robotic Systems*, 2015, 79(2): 237-257
- [6] Mac Thi T, Copot C, Tran D T, et al. Heuristic approaches in robot path planning: a survey[J]. *Robotics and Autonomous Systems*, 2016, 86: 13-28
- [7] 葛伟宽,王保平. 基于栅格图法的移动物流机器人全局路径规划方法[J]. 科技通报, 2019, 35(9): 72-75, 80
- [8] Magid E, Lavrenov R, Afanasyev I. Voronoi-based trajectory optimization for UGV path planning[C]//2017 International Conference on Mechanical, System and Control Engineering, St. Petersburg, Russia, 2017: 383-387
- [9] Tuncer A, Yildirim M. Dynamic path planning of mobile robots with improved genetic algorithm [J]. *Computers and Electrical Engineering*, 2012, 38(6): 1564-1572
- [10] Chen G L, Liu J. Mobile robot path planning using ant colony algorithm and improved potential field method[J]. *Computational Intelligence and Neuroscience*, 2019(6): 1-10
- [11] Yen C T, Cheng M F. A study of fuzzy control with ant colony algorithm used in mobile robot for shortest path planning and obstacle avoidance[J]. *Microsystem Technologies*, 2018, 24(1): 125-135
- [12] 陈劲峰,黄卫华,王肖. 基于改进蚁群算法的移动机器人路径规划[J]. 高技术通讯, 2020, 30(3): 291-297
- [13] 许明,张娟,方志军. 自适应道路模型的非结构化道路检测算法[J]. 传感器与微系统, 2020, 39(1): 132-135
- [14] 诸葛程晨,许劲松,唐振民. 基于支持向量机的局部路径规划算法[J]. 哈尔滨工程大学学报, 2019, 40(2): 323-330
- [15] Konstantinos C, Ioannis K, Antonios G, et al. Thorough robot navigation based on SVM local planning[J]. *Robotics and Autonomous Systems*, 2015, 70: 166-180
- [16] Tong X, Siwei C, Dong W, et al. A novel path planning

method for articulated road roller using support vector machine and longest accessible path with course correction [J]. *IEEE Access*, 2019(7):182784-182795
 [17] Chaari I, Koubaa A, Bennaceur H, et al. Design and

performance analysis of global path planning techniques for autonomous mobile robots in grid environments [J]. *International Journal of Advanced Robotic Systems*, 2017, 14(2): 1-27

Path planning of mobile robot based on support vector machine and improved ant colony algorithm

Zhang Jinbo^{*}, Zuo Tao^{***}, Hu Xinyu^{*}, Wu Yiwei^{*}

(^{*}School of Information Science and Engineering, Wuhan University of Science and Technology, Wuhan 430081)

(^{**}Engineering Research Center for Metallurgical Automation and Measurement Technology of Ministry of Education, Wuhan University of Science and Technology, Wuhan 430081)

Absract

Aiming at the shortcomings of traditional ant colony algorithm(ACO), such as slow convergence speed, poor global search ability, easy to fall into local optimum, unsmooth and unsafe path, a path planning algorithm for mobile robot is proposed, which combines the improved ant colony algorithm and nonlinear support vector machine (SVM). Two angle information is introduced to the traditional ant colony algorithm to increase the direction of the algorithm and overcome the local optimization problem. The pheromone volatility factor is adjusted adaptively with the number of iterations to improve the global search ability and convergence speed. Basis on this, combined with the Gaussian radial basis kernel least squares support vector machine, the improved ant colony algorithm is used to obtain the penalty coefficient and kernel function width of the support vector machine, the radial basis kernel function and decision function are used to train and optimize the improved ant colony algorithm path turning position to obtain a smooth and safe path. Simulation results show that the proposed algorithm can improve the convergence speed and accuracy, and make the path smooth and safe.

Key words: ant colony algorithm (ACO), support vector machine (SVM), path planning, mobile robot