

DOI: 10.19650/j.cnki.cjsi.J1905574

基于BP神经网络机器人实时避障算法*

李卫硕^{1,2}, 孙 剑^{1,2}, 陈 伟^{1,2}

(1. 西安交通大学航空航天学院 机械结构强度与振动国家重点实验室 西安 710049;

2. 西安交通大学 陕西航空航天结构振动控制工程实验室 西安 710049)

摘要:针对二维静态环境下智能机器人避障及路径规划问题,提出了基于BP神经网络的机器人实时避障算法。首先,用多个扇区表示机器人周围的环境,利用激光雷达探测每个扇区内障碍物的距离信息,以每个扇区内障碍物的距离信息为输入,利用BP神经网络计算该扇区被选择为避障方向的得分;然后,利用各扇区中点坐标与当前时刻距障碍物最近扇区中点坐标之间的欧氏距离,计算机器人在当前位姿条件下各扇区被选中作为避障方向的条件概率;最后,将使得得分与条件概率之积最大的扇区作为机器人的避障方向。实验结果表明:所提算法的收敛时间比栅格方法降低了50%以上,机器人的避障轨迹与人工势场方法相比更短,能较好地应用于复杂多障碍物场景。

关键词: 机器人;激光雷达;自主避障;BP神经网络;高斯模型

中图分类号: TH166 TP24 **文献标识码:** A **国家标准学科分类代码:** 510.80

Real-time obstacle avoidance algorithm for robots based on BP neural network

Li Weishuo^{1,2}, Sun Jian^{1,2}, Chen Wei^{1,2}

(1.State Key Laboratory for Strength & Vibration of Mechanical Structures, School of Aerospace, Xi'an Jiaotong University,

Xi'an 710049, China; 2.Shaanxi Engineering Laboratory for Vibration Control of Aerospace

Structures, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract:To address the problem of obstacle avoidance and path planning of intelligent robots in two-dimensional static environment, a real-time obstacle avoidance algorithm based on BP neural network is proposed. Firstly, multiple sectors are used to represent the environment around the robot, and lidar is utilized to detect the distance information of obstacles in each sector. With the distance information of obstacles in each sector, BP neural network is used to calculate the score of the sector selected as obstacle avoidance direction. Then, the Euclidean distance between the mid-point coordinate of each sector and the mid-point coordinate of the closest sector to the obstacle at the current moment is used to calculate the conditional probability. Each sector is selected as the direction of obstacle avoidance under the current pose of the robot. Finally, the sector with the largest product of score and conditional probability is taken as the obstacle avoidance direction of the robot. Experimental results show that the convergence time of the proposed algorithm is 50% less than that of the grid method, and the obstacle avoidance trajectory of the robot is shorter than that of the artificial potential field method. It can be better applied to complex multi-obstacle scenarios.

Keywords: robot; laser radar; autonomous obstacle avoidance; BP neural network; Gaussian model

0 引言

移动机器人的导航与避障技术是目前机器人研究领域的热点问题^[1]。随着人工智能技术的发展,机器人的

应用领域越来越多,其作业的场景也越来越复杂。机器人经常需要在不适合人类前往的复杂且危险的环境下,自主完成侦查、监视、搜救等重要任务,因此开展机器人自主避障技术的研究对于保证机器人顺利完成特定任务,增加其对环境适应性具有十分重要的意义。

机器人自主避障系统主要包括环境信息采集、决策处理、路径规划 3 个部分。现有的路径规划算法主要分两类^[2]:一类是基于已知环境信息的全局路径规划算法,这类算法用于环境信息完全已知的情況^[3],并且可以找到全局最优解,但是需要预先知道环境的准确信息,且当环境发生变化时该方法不能使用,局限性高;另一类是基于机器人当前环境信息的局部路径规划算法,这类算法将对环境的建模与搜索避障融为一体,能对规划结果进行实时反馈和校正,动态性高,但是由于缺乏全局环境信息,规划结果往往不是全局最优,甚至可能找不到正确路径或完整路径。此类算法中目前应用较为广泛是栅格算法^[4],其采用二维笛卡尔矩形栅格表示环境,每个矩形栅格有一个积累值,该值用来表示在此栅格存在障碍物的可信度,同时在在机器人前面开出一个以长度 R 为半径的半圆形假想活动窗口,并将该半圆窗口划分成若干扇形区域,将落在每个扇形区域内各网格对应积累值的和作为确定机器人避障方向的依据,栅格大小的选取直接影响着控制算法的性能^[4]。为了提高机器人对环境感知的分辨率,算法往往选用小的栅格单元,从而导致算法计算量大、实时性和动态性较差。除此之外还有人工势场法(artificial potential field, APF)^[5],该算法的核心思想是将机器人在一个虚拟的人工势场中受到障碍物的斥力以及目标点的吸引力计算成一个合力从而进行路径规划,但其存在在障碍物前路径不够平滑以及在通过狭小通道时出现摆动^[6]等明显不足。此外,随着人工智能技术的兴起,越来越多的智能算法被提出并应用于移动机器人路径规划优化中^[7],以克服传统路径规划算法的局限性^[8-10],如遗传算法^[11]、粒子群算法^[12]、蚁群算法^[13]等。文献[14]将神经网络应用于农业机器人转向控制,同时验证了在路径曲率不超过 35° 情况下算法的可用性;文献[15]所设计的网络模型能在动态环境下产生实时的避障轨迹同时保证生成的轨迹没有遭受局部极小点逃离问题。

1 总体方案

传统避障算法在复杂的应用场景下存在计算量大、轨迹抖动不够平滑等问题。本文提出了一种基于 BP 神经网络的新型机器人实时避障算法,算法流程如图 1 所示。

本文算法利用文献[4]中环境表示的形式将机器人周围环境用扇区的形式表示,并用激光雷达探测各个扇区中障碍物的距离,并利用激光雷达获得数据实现局部路径规划;即在当前位姿和当前观测下找到最优可行扇区作为机器人的避障方向。首先,利用 BP 神经网络根据对应扇区内障碍物的距离信息计算机器人选择该扇区




图 1 基于概率模型避障算法流程

Fig.1 Flowchart of the obstacle avoidance algorithm based on the probability model


作为避障方向的得分 W_i ;之后,根据机器人位姿 X_i 计算此时距离目标点最近的扇区 S_{sb} ,求取其他扇区与扇区 S_{sb} 之间的欧氏距离 L_i^2 ,并假设该距离服从高斯分布,计算机器人在当前位姿下选择某一扇区作为避障方向的概率 $P(S_i | X_i)$,距离 S_{sb} 越近的扇区被选概率越高,从而保证了机器人能快速运动到目标点;最后将扇区得分 W_i 与概率 $P(S_i | X_i)$ 相乘,选择使得乘积取最大值的扇区 S_b 作为当前时刻最优的避障方向。不断迭代上述过程直至机器人运动到目标点。

2 环境表示

本文以安装激光雷达的机器人为主要研究对象,通过激光雷达检测机器人所在 2D 平面中的环境信息,在扫描区域内若有障碍物的存在则打在障碍物上的一系列激光束会生成携带障碍物信息的 2D 点云数据。因此扫描区域内的障碍物转化成一系列数据点云所描述的对象。图 2 所示为雷达扫描到的真实环境信息在雷达坐标系下的点云数据。

图 2(b) 黑色边缘点表示障碍物;箭头起始圆点表示机器人位置;白色区域表示超出扫描范围或空旷区域;箭头表示机器人朝向。

雷达原始数据是使用离散的数据点来描述障碍物,单个数据点由于各种误差的存在不能准确地描述障碍物相关信息,需要将数据点进行聚类处理,因此本文将扫描区域均等的划分成若干的扇形区域,通过扇区划分使得



(a) 真实环境 (b) 真实环境下雷达点云
(a) The real environment (b) Real environment radar point cloud

图 2 机器人周围环境的点云信息

Fig.2 Point cloud information of the robot's surrounding

雷达扫描到的数据点被规律的分配在特定的扇区中,并将每个扇区中所有数据点距离信息的均值作为该扇区内障碍物的距离;同时 will 划分好的扇区赋予特定的标记,扇区划分时扇区划分的数量越多,所规划的路径越灵活,但计算量也会增大,同时每个扇区内数据点的个数会减少从而导致误差增大;综合考虑,本文实验时将机器人周围扫描区域均等的划分成 18 个扇形区域,把机器人周围一定圆形范围作为下一时刻机器人位置的备选迭代区域,同样将该区域划分局部扇形网格图并依次标记为 $S_{18}, S_1, \dots, S_{17}$, 将机器人周围环境划分成如图 3 所示网格形状。




图 3 扫描环境扇区划分

Fig.3 Diagram of the environment sector partition scanning

图 3 中中心点表示 t 时刻机器人位姿 X_t ; 虚线圆表示标记为 $S_i \{i = 1, 2, 3, \dots, 18\}$ 的扇形网格组成的下一时刻机器人位置备选迭代区域(下文称可行扇区 S_i); 外圆实线表示雷达可观测范围; 图中数字表示每个扇区的标记。

机器人为实现实时的自主避障,需在完成数据采集、扇区划分后,根据当前时刻雷达观测值 Z_t 将所有标记好的扇区划分出 $\{best, better, middle, poor, worst\}$ 5 个不同的等级,同时根据扇区的等级赋予该扇区特定的得分 W_i , 等级越高的扇区得分越高,表示在当前雷达观测下该扇区方向被选中的可能性越大。

由于判断某个扇形域 S_i 等级时,判断的结果不仅仅受该扇区内障碍物距离 L_i^1 的影响,同时也受其相邻扇区 $\{S_{i-2}, S_{i-1}, S_{i+1}, S_{i+2}\}$ 内障碍物距离信息 $\{L_{i-2}^1, L_{i-1}^1, L_{i+1}^1, L_{i+2}^1\}$ 的影响。且 $\{L_{i-2}^1, L_{i-1}^1, L_i^1, L_{i+1}^1, L_{i+2}^1\}$ 与该扇区等级之间的对应关系极其复杂、并不能简单地用几个函数来表示,而神经网络具有较强的分类能力,并且可以存储信息,因此能更好地对扇区的等级进行检测。

3 BP 神经网络模型

3.1 网络模型

BP 神经网络进行训练时,首先是将信号正向传递计算实际输出和理想输出的误差,其次利用计算出来的误差反向修正权值和阈值^[16]。本文中 choice 对要判断的扇区 S_i 等级影响较大相邻 5 个扇区内障碍物的距离信息 $\{L_{i-2}^1, L_{i-1}^1, L_i^1, L_{i+1}^1, L_{i+2}^1\}$ 作为输入传递给网络的输入层,经中间层处理,最后输出,这是正向传递过程,当输出的 S_i 等级与期望等级超过设定误差时,误差进行反向传递更新权值和阈值,直到误差达到设定的范围或者达到预设的迭代次数,停止训练。基于上述描述设计 5-10-5 的网络模型,结构如图 4 所示。




图 4 BP 神经网络结构

Fig.4 Diagram of BP neural network structure

本文使用 3 层 BP 神经网络结构。其中网络的输入向量为 $L = (L_{i-2}^1, L_{i-1}^1, L_i^1, L_{i+1}^1, L_{i+2}^1)^T$; 隐含层的输出向量为 $Y = (y_1, y_2, \dots, y_9, y_{10})^T$; 输出层的向量为 $O = (o_1, o_2, o_3, o_4, o_5)^T$ 期望输出为 $D = (d_1, d_2, d_3, d_4, d_5)^T$; 输入层到

隐含层的权值矩阵为 $\omega = \begin{pmatrix} \omega_{11} & \cdots & \omega_{1j} \\ \vdots & \ddots & \vdots \\ \omega_{i1} & \cdots & \omega_{ij} \end{pmatrix}$; 隐含层到输

出层的权值向量为 $V = \begin{pmatrix} v_{11} & \cdots & v_{1k} \\ \vdots & \ddots & \vdots \\ v_{j1} & \cdots & v_{jk} \end{pmatrix}; i = 5, j = 10,$

$k = 5$ 。

该网络输入层的数学关系为:

$$o_k = f_1(net_k) \quad (1)$$

$$net_k = \sum_{j=1}^{10} v_{jk}y_j, \quad k = 1, 2, 3, 4, 5 \quad (2)$$

隐含层数学关系为:

$$y_j = f_2(net_j) \quad (3)$$

$$net_j = \sum_{i=1}^5 w_{ij}L_i^1, \quad j = 1, 2, \dots, 10 \quad (4)$$

在式(1)和(3)中的函数分别为:

$$f_1(x) = kx \quad (5)$$

$$f_2(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

$f_2(x)$ 为单极性 Sigmoid 函数,具有连续性,其一阶导数为:

$$f_2'(x) = f_2(x) [1 - f_2(x)] \quad (7)$$

网络的误差定义为:

$$E = \frac{1}{2} (d - o)^2 = \frac{1}{2} \sum_{k=1}^5 (d_k - o_k)^2 \quad (8)$$

将式(1)、(2)代入式(8),得到隐含层各参数与误差之间的关系为:

$$E = \frac{1}{2} \sum_{k=1}^5 [d_k - f_1(net_k)]^2 = \frac{1}{2} \sum_{k=1}^5 [d_k - f_1(\sum_{j=1}^{10} v_{jk}y_j)]^2 \quad (9)$$

将式(3)、(4)代入式(9),得到输入层各参数与误差之间的关系为:

$$E = \frac{1}{2} \sum_{k=1}^5 \{d_k - f_1[\sum_{j=1}^{10} v_{jk}f_2(\sum_{i=1}^5 w_{ij}L_i^1)]\} \quad (10)$$

由式(10)可以发现:网络输出的误差可以由输入层到隐含层的权值 ω_{ij} 和隐含层到输出层的权值 v_{jk} 的函数表示,权值沿着梯度下降的方向更新。

$$\Delta v_{jk} = -\eta \frac{\partial E}{\partial v_{jk}} = -\eta \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial v_{jk}} \quad (11)$$

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = -\eta \frac{\partial E}{\partial net_j} \frac{\partial net_j}{\partial w_{ij}},$$

$$i = 1, 2, \dots, 5; j = 0, 1, \dots, 10; k = 1, 2, \dots, 5 \quad (12)$$

式中: η 为网络的学习效率。上述公式反映了网络更新过程即误差减小过程。其中:

$$\frac{\partial E}{\partial net_k} = \frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial net_k} \quad (13)$$

$$\frac{\partial E}{\partial net_j} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial net_j} \quad (14)$$

将式(11)、(13)联立求得隐含层到输出层的权值更新表达式为:

$$\Delta v_{jk} = -\eta (d_k - o_k) k y_i \quad (15)$$

将式(12)、(14)联立求得输入层到隐含层的权值更

新表达式为:

$$\Delta w_{ij} = -\eta \left(\sum_{k=1}^5 (d_k - o_k) k v_{jk} \right) y_i (1 - y_i) L_i^1 \quad (16)$$

3.2 训练网络

记录机器人在近 200 组静态场景运动时雷达扫描到的环境信息数据。根据扇区 S_i 所对应的 $\{L_{i-2}^1, L_{i-1}^1, L_i^1, L_{i+1}^1, L_{i+2}^1\}$ 信息,以人的经验为准则,将机器人选择 S_i 为避障方向时,在该方向运动绝对安全、相对安全、比较安全、不安全以及不可行,将扇区分成 5 个等级。在人为标记好的数据集中随机对各等级抽取相同数量的数据作为训练数据,其余作为验证集。不同等级的网络输出结果如表 1 所示。

表 1 扇区等级对照表

Table 1 Comparison of sector level

等级	Best	Better	Middle	Poor	Worst
输出	10000	01000	00100	00010	00001
得分	0.9	0.8	0.65	0.4	0.1

在 MATLAB 中搭建 5-10-5 的 BP 神经网络模型,将标记好的数据利用式(17)进行归一化处理后放入网络进行训练;

$$Y = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (17)$$

训练过程误差曲线如图 5 所示。




图 5 网络训练误差

Fig.5 Error graph of network training

由图 5 可以看出,网络经过有限次迭代后收敛到期望误差,停止训练。将标记好的验证集,输入网络进行检验,经检验网络对扇区等级的估计与人工标定的等级对比准确率为 98%,验证了该方法的可行性。

将扇区按照划分好的等级赋予不同的得分,即划分等级越好的扇区得分越高被选择的概率也就越大,等级越差的扇区被选择的概率越小;等级与扇区得分的对应关系如表 1 所示。

通过上述方法,将当前观测的环境点云信息转化成各

个可行扇区 S_i 选中作为下一步迭代点的得分 W_i 。该值的计算仅仅与当前的观测数据 Z_i 有关,与机器人位姿无关。

4 可行域高斯建模

由网络的结构可知雷达观测值 Z_i 和机器人位姿 X_i 对扇区 S_i 选择的影响作用是独立的。同时仅由 BP 神经网络计算出的最优扇区仅仅能保证机器人避开障碍物,不能保证机器人朝着预设目标前进^[17],例如:当机器人的后方无障碍物时,可能会出现机器人后方扇区得分大于前方扇区得分的情况。为解决这一问题,采用使得式(18)取最大值的扇区作为当前时刻最优的避障方向。

$$\text{Subgoal}(S_b) = \max \{ P(S_i | X_i) W_i \}, i \in [1, 18] \quad (18)$$

式中: $P(S_i | X_i)$ 表示基于位姿 X_i 各扇区被选中的条件概率。该条件概率应保证机器人在避障过程中总是逐步接近目标点,故对位姿 X_i 做如下处理。

由于机器人在二维平面运动,因此机器人位姿 X_i 可由其坐标 (x_i, y_i, θ_i) 表示;其中 (x_i, y_i) 为 t 时刻机器人在全局坐标系下的坐标; θ_i 为偏航。在仅考虑机器人位姿对扇区选择的影响时,扇区 S_i 可根据当前位姿由式(19)计算得到。

$$S_i = f_i(X_i) + w_i, i \in [1, 18] \quad (19)$$

式中: $f_i(X_i)$ 表示由 X_i 到 S_i 映射函数; w_i 为随机变量,表示避障方向选择的不确定性。若不考虑上述不确定性, $f_i(X_i)$ 为机器人在位姿 X_i 条件下距离目标点最近扇区 S_{xb} 的坐标,因此:

$$P(S_i | X_i) \propto L_i^2 = \|S_i - S_{xb}\|, i \in [1, 18] \quad (20)$$

计算各可行扇区 S_i 中点在二维平面中的坐标为:

$$\begin{pmatrix} x_{si} \\ y_{si} \end{pmatrix} = \begin{pmatrix} x_i \\ y_i \end{pmatrix} + d \begin{pmatrix} \cos(\theta_i - \pi i/9) \\ \sin(\theta_i - \pi i/9) \end{pmatrix}, i \in [1, 18] \quad (21)$$

式中: x_{si}, y_{si} 为扇区 S_i 中点在全局坐标系下的坐标,此处 S_i 由 (x_{si}, y_{si}) 表示; d 为单位迭代步长, $\pi/9$ 为相邻扇区夹角; i 为标记的扇区标号;由式(21)可知,在 d 取值较小时 L_i^2 值也较小;为满足 $P(S_i | X_i)$ 与 L_i^2 反比关系同时避免较小值出现在分母引起数值大的波动,因此假设 $P(S_i | X_i)$ 服从均值为 0, 方差为 Γ 的高斯分布。

$$P(S_i | X_i) \propto \exp \left\{ -\frac{1}{2} \|S_{xb} - S_i\|^2 \Gamma \right\}, i \in [1, 18] \quad (22)$$

$$\Gamma = d \sum_{i=1}^{18} \left\| \begin{pmatrix} x_{si} \\ y_{si} \end{pmatrix} - \begin{pmatrix} x_{sxb} \\ y_{sxb} \end{pmatrix} \right\|^2, i \in [1, 18] \quad (23)$$

式中: $\|S_i - S_{xb}\|^2$ 表示二维空间点的欧氏距离,通过上述方法把 S_i 与 S_{xb} 之间的距离 L_i^2 建模成该扇区被选中作

为下一步迭代点的概率;同时保证了机器人在避障过程中逐渐逼近目标点。由各扇区中点坐标与 S_{xb} 中点坐标之间欧氏距离所建高斯模型如图 6 所示。




图 6 高斯模型

Fig.6 Gaussian model

图 6(a) 中小圆点表示目标点,实线箭头表示对该扇区中点与 S_{xb} 扇区中点之间的欧氏距离 $\|S_i - S_{xb}\|^2$,此处应计算所有扇区与 S_{xb} 距离,为避免重复标注,用省略号代替;虚线箭头表示机器人正方向。由图 6(b) 可知与扇区 S_{xb} 距离越近的扇区,被选中的概率越高,距离越远,概率越低。通过记录机器人运动过程中的数据,并将机器人某一面向目标点时刻的位姿 $X_m = (x_m, y_m, \theta_m)$ 作为机器人当前位姿,将机器人周围各扇区对应的距离信息 L_i^2 带入上述高斯模型,归一化处理后得到下一代范围内各扇形可行域被选择的概率如图 7 所示。




图 7 机器人在位姿 X_m 时各扇区由高斯模型计算的条件概率

Fig.7 The conditional probability of each sector calculated by Gaussian model when the robot is in position X_m

仅考虑机器人位姿时,由于此时机器人面向目标点,所以所有扇区中正前方扇区(扇区 18)被选择的概率应最大;正后方(扇区 9)被选择的应该概率应最小,图 7 所示实际结果与理论猜想结果完全相同;改变机器人位姿多次试验,实际结果与理论猜想结果均相同。

在只考虑机器人位姿时,假设机器人周围各扇区 S_i 与 S_{xb} 之间的欧氏距离 L_i^2 服从高斯分布,将上述距离 L_i^2 转化成各扇区 S_i 被选中的条件概率 $P(S_i | X_t)$,并且该概率的计算只与当前机器人位姿信息有关,与当前观测信息无关。

最后将由神经网络计算得到的各扇区得分 W_i 和由高斯模型求得的条件概率 $P(S_i | X_t)$ 相乘,选择使得两者乘积取最大值的扇区作为当前机器人的避障方向,重复上述过程直至机器人运动到目标点。

5 实验验证

实验采用搭载激光雷达的 EAI Robot 对上述方案进行验证,该算法在执行过程中不仅需要实时采集机器人周围环境信息,而且要实时采集机器人位姿信息,因此搭建如图 8 所示的实验平台。




图 8 实验平台
Fig.8 Diagram of experimental platform

为突出上述算法在避障过程的实时性、准确性,实验场地选定在宽 2.1 m 的走廊中;EAI Robot 底盘半径为 0.2 m;实验时采用若干 0.6 m×0.6 m 的正方形挡板作为障碍物搭建如图 9 所示两种不同的实验场景。

图 9(a) 为搭建的单一障碍物场景,在全局坐标系下将机器人初始点坐标设置为(0,0),目标点设置为(6,0);图 9(b)为搭建的 S 型连续多障碍物场景,在全局坐标系下起始点坐标为(0,0),预设目标点坐标为(8,0)。



图 9 实验场景
Fig.9 Experimental scenarios

图 10 所示为单一障碍物场景中,机器人避障时的运动轨迹;通过该轨迹可以发现:上述避障算法能在机器人探测到障碍物的瞬间,就可以实现对障碍物的规避,提高了避障过程安全性;且避障运动轨迹比较光滑,运动过程平稳。




图 10 单一障碍物场景下机器人避障轨迹
Fig.10 Obstacle avoidance trajectory of the robot in the single obstacle scene

为了验证基于 BP 神经网络算法在智能移动体避障路径规划中的性能优势,使用人工势场(APF)算法、基于栅格(GB)算法以及基于 BP 神经网络算法三种不同的方法,在图 9(b)所示的连续多障碍场景下进行避障实验,起始点、终止点、运行速度等条件均相同,不同算法的初始参数如表 2 所示。

Table 2 Initial parameters of different algorithms		
算法	参数名称	参数值
GB 算法	栅格大小	0.1 m×0.1 m
	活动窗口半径	5 m
	活动窗口范围	18×20° = 360°
ADF 算法	引力增益 k_p	2
	斥力距离	1.5 m
	斥力增益 η	5

不同算法的机器人避障轨迹如图 11 所示。




图 11 连续多障碍物场景下不同算法机器人避障轨迹
Fig.11 Obstacle avoidance trajectories of robots with different algorithms in continuous multi-obstacle scenarios

计算不同算法避障轨迹的长度,轨迹长度对比如表 3 所示。同时计算避障过程中机器人实时位置与目标点之间距离的变化,将该算法下机器人其运动至目标点的时间作为评价该算法收敛性的指标,不同算法性如图 12 所示。

表 3 不同算法所规划的路径长度对比
Table 3 Comparison of path length planned by different algorithms

项目	算法			
	理想最优	本文算法	APF 算法	GB 算法
路径长度/m	9.821 6	10.301 12	10.564 1	10.922 0
百分比/%	100	104.88	107.56	111.21




图 12 连续多障碍物场景下不同算法收敛性对比
Fig.12 Comparison of convergence of different algorithms in continuous multi-obstacle scenarios

从图 11 可以看出基于 BP 神经网络的算法相比于其他两种算法所规划的避障轨迹没有异常波动、相对更平滑;由图 12 可知本文算法能够根据当前观测实时对机器人进行控制,保证机器人及时收敛到目标点,其收敛时间比栅格算法减少了 50%;由于机器人在连续多障碍物场景下进行避障时 Y 方向只有小于 2.1 m 的运动范围相比 X 方向运动范围小得多,故图 11 中 S 型避障曲线在图 12 收敛近乎以直线收敛。表 3 中的数据表明,利用本文避障算法实现了对机器人避障方位的选择,同时有效地缩

短了机器人的避障轨迹。
上述实验结果充分说明了本文算法与传统的栅格、人工势场算法相比,具有收敛速度快、所规划的路径短等优点,可以保证机器人在复杂连续多障碍物环境中,以更短的路径、更快的收敛速度解决避障、路径规划问题,有较大的实用价值。

6 结 论

针对二维静态环境下智能移动体避障及路径规划问题,本文提出了基于 BP 神经网络的实时避障算法。采用 BP 神经网络对可行扇区进行选择,解决了扇区选择结果与扇区原始数据之间非线性映射问题,同时解决了避障方向选择时相邻扇区之间数据关联问题,使得选择出的扇区网格更优;将距离目标点最近的扇区坐标点与其他扇区坐标点之间的欧氏距离建模成高斯误差,保证了机器人最终收敛到目标点。实验结果表明,本文算法与传统的方法相比具有计算简单、数据处理快时效性更高、避障路径更平滑等优点。在连续多障碍物实验环境下表现出了很大的优势,能够快速寻得高精度的全局有效最优路径。该算法为复杂静态环境下的机器人避障路径规划问题提供了一种新解决思路。

参考文献

[1] 孙曼晖,杨绍武,易晓东,等.基于 GIS 和 SLAM 的机器人大范围环境自主导航[J].仪器仪表学报,2017,38(3):586-592.
SUN M H, YANG SH W, YI X D, et al. Autonomous navigation of robot in large-scale environments based on GIS and SLAM [J]. Chinese Journal of Scientific Instrument, 2017, 38(3):586-592.
[2] 蒲华燕,丁峰,李小毛,等.基于椭圆碰撞锥的无人艇动态避障方法[J].仪器仪表学报,2017,38(7):1756-1762.
PU H Y, DING F, LI X M, et al. Maritime autonomous obstacle avoidance in a dynamic environment based on collision cone of ellipse [J]. Chinese Journal of Scientific Instrument, 2017, 38(7):1756-1762.
[3] 伍永健,陈跃东,陈孟元.改进 QPSO 和 Morphin 算法下移动机器人混合路径规划[J].电子测量与仪器学报,2017,31(2):295-301.
WU Y J, CHEN Y D, CHEN M Y. Hybrid path planning of mobile robot based on improved QPSO and Morphin algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(2):295-301.
[4] 马兆清,袁曾任.基于栅格算法的移动机器人实时导航和避障[J].机器人,1996,18(6):343-348.
MA ZH Q, YUAN C R. Real-time navigation and obstacle

- avoidance based on grid method for fast mobile robot [J]. Robot, 1996, 18(6): 343-348.
- [5] 陈金鑫, 董蛟, 朱旭芳. 改进人工势场法的移动机器人路径规划[J]. 指挥控制与仿真, 2019, 41(3): 116-121.
- CHEN J X, DONG J, ZHU X F. Robot path planning based on improved artificial potential field method [J]. Command Control & Simulation, 2019, 41(3): 116-121.
- [6] 罗德林, 吴顺祥. 基于势场蚁群算法的机器人路径规划[J]. 系统工程与电子技术, 2010, 32(6): 1277-1280.
- LUO D L, WU S H X. Ant colony optimization with potential field heuristic for robot path planning [J]. Systems Engineering and Electronics, 2010, 32(6): 1277-1280.
- [7] 于振中, 李强, 樊启高. 智能仿生算法在移动机器人路径规划优化中的应用综述[J]. 计算机应用研究, 2019, 26(11): 3210-3220.
- YU Z H, LI Q, FAN Q G, et al. Survey on application of bioinspired intelligent algorithms in path planning optimization of mobile robots [J]. Application Research of Computers, 2019, 26(11): 3210-3220.
- [8] 张菁, 何友, 彭应宁, 等. 基于神经网络和人工势场的协同博弈路径规划[J]. 航空学报, 2019, 40(3): 228-238.
- ZHANG J, HE Y, PENG Y N, et al. Neural network and artificial potential field based cooperative and adversarially path planning [J]. Acta Aeronautica et Astronautica Sinica, 2019, 40(3): 228-238.
- [9] YANS S X, LUO C H M. A neural network approach to complete coverage path planning [J]. IEEE Transactions on Systems Man & Cybernetics Part B, 2004, 34(1): 718-725.
- [10] 朱云国, 周松林. 基于 BP 神经网络的移动机器人路径规划[J]. 煤矿机械, 2007, 28(8): 42-44.
- ZHU Y G, ZHOU S L. Path planning for mobile robot based on BP neural network algorithm [J]. Coal Mine Machinery, 2007, 28(8): 42-44.
- [11] 刘二辉, 姚锡凡, 蓝宏宇, 等. 基于改进遗传算法的自动导引小车动态路径及其实现[J]. 计算机集成制造系统, 2018, 24(6): 1455-1467.
- LIU E R H, YAO X F, LAN H Y, et al. AGV dynamic path planning based on improved genetic algorithm and its implementation [J]. Computer Integrated Manufacturing Systems, 2018, 24(6): 1455-1467.
- [12] 许川佩, 吕莹, 黄喜军, 等. 基于粒子算法的数字微流控芯片在线检测路径优化[J]. 电子测量与仪器学报, 2017, 31(8): 1192-1199.
- XU C H P, LYU Y, HUANG X J, et al. On-line test route optimization of digital microfluidic swarm optimization [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(8): 1192-1199.
- [13] DORIGO M, GAMBARDELLA L M. Ant colony system: A cooperative learning approach to the traveling salesman problem [J]. IEEE Transactions on Evolutionary Computation, 1997, 1(1): 53-66.
- [14] TANG J L, JING X, HE D J, et al. Visual navigation control for agricultural robot using serial BP neural network [J]. Transactions of the Chinese Society of Agricultural Engineering, 2011, 27(2): 194-198.
- [15] GLASIUS R, KOMODA A, GIELEN S, et al. Population coding in a neural net for trajectory formation [J]. Network: Computat Neural Systems, 1994, 5(4): 549-563.
- [16] JUANG C F, YEH Y T. Multiobjective evolution of biped robot gaits using advanced continuous ant colony optimized recurrent neural networks [J]. IEEE Transactions on Cybernetics, 2018, 48(6): 1910-1922.
- [17] JABBARPOUR M R, ZARRABI H, JUNG J J, et al. A green ant-based method for path planning of unmanned ground vehicles [J]. IEEE Access, 2017(5): 1820-1832.

作者简介



李卫硕, 2017 年于深圳大学获得学士学位, 现为西安交通大学硕士研究生, 主要研究方向机器人自主避障算法、SLAM 算法研究。

E-mail: shuozi2@stu.xjtu.edu.cn

Li Wei Shuo received his B. Sc. degree from Shenzhen University in 2017. He is currently a M. Sc. candidate at Xi'an Jiaotong University. His main research interests include autonomous obstacle avoidance algorithm and SLAM algorithm.



孙剑(通信作者), 2007 年于西北工业大学获得博士学位, 2007~2009 年于清华大学精密仪器系从事博士后研究, 现为西安交通大学博士生导师, 主要研究方向为飞行器导航、制导与控制领域的研究工作。

E-mail: sunjian10@mail.xjtu.edu.cn

Sun Jian (Corresponding author) received his Ph. D. degree from Northwest Polytechnic University in 2007. From 2007 to 2009, he was engaged in postdoctoral research in the Department of Precision Instruments at Tsinghua University. He is currently a Ph. D. advisor at Xi'an Jiaotong University. His main research interests include.



陈伟, 现为西安交通大学博士研究生, 主要研究方向为机器人自主导航和激光 SLAM。

E-mail: cw0523@stu.xjtu.edu.cn

Chen Wei is a Ph. D. candidate at Xi'an Jiaotong University. His main research interests include robot autonomous navigation and lidar SLAM.