

基于信息融合模型小车 ANN 避障控制

冯建农 柳 明

吴 捷

(华南理工大学计算机系·广州, 510641) (华南理工大学电力学院·广州, 510641)

摘要: 本文将模糊逻辑、神经网络和传感器融合技术结合起来,用于移动机器人的避障控制研究,利用多个非摄像类的超声波和红外线传感器探测环境信息,采用多传感器融合技术进行传感器信号处理,并且探讨了模糊聚类 and 神经网络系统在机器人系统中的避障控制能力,给出了虚拟环境下的计算机仿真结果。

关键词: 机器人; 避障控制; 模糊聚类; 神经网络; 传感器融合; 导航

1 引 言

移动机器人(这里泛指模型小车)导航研究引起了各方面的广泛关注,并正在从不同侧面开展该课题的研究。目前在移动机器人避障控制研究中,多采用视觉系统探测周围环境,并利用图象信号分析处理技术获得环境信息,引导机器人运动。采用视觉系统导航可以获得较完整的环境信息,但由于图像处理运算量大,需要高性能的信号处理设备,致使这类系统体积大、能耗高、实时性差,难以应用于室外型机器人。近年来,为了克服单纯视觉系统难以在室外型机器人上应用的不足,人们开始研究采用其它非摄像类传感器探测环境信息^[1],有时甚至放弃摄像类视觉系统,直接采用多个廉价传感器,利用多传感器融合技术,通过冗余信息实现对周围环境的探测^[2]。

在基于多传感器融合的导航研究中,模糊逻辑^[3]和神经网络^[4]是采用得比较多的两种方法。这两种方法的共同点在于易于表达某些难以精确描述的规则,但也存在着各自的缺点:模糊逻辑的运算量随规则数量的增加而成几何级数增长,因而在模糊规则较多时难以付诸实施;神经网络系统受学习样本的影响很大,选择代表性强的样本集是一件十分困难的事情,而让样本集覆盖整个样本空间是不现实的,因而样本设计就成为神经网络应用的一个主要问题。由于模糊逻辑和神经网络各自的缺陷,在实际应用中,均未能取得完全满意的结果。

避障控制是导航任务的基本内容之一,本文将模糊逻辑、神经网络和传感器融合技术结合起来,用于移动机器人的避障控制研究,利用多个非摄像类的超声波和红外线传感器探测环境信息,采用多传感器融合技术对传感器信号进行处理,研究了模糊聚类 and 神经网络系统在移动机器人系统中的避障控制能力,给出了虚拟环境下的计算机仿真结果。

2 模型小车的物理模型

我们的移动机器人研究对象是一个带有调速和转向控制的电动小车。速度控制通过调节直流伺服电动机的供电电压完成;方向控制则由一个直流伺服电机组成的随动系统完成,改变该随动系统的给定量,即可实现方向控制。在本文中,仅考虑转向控制,并建立如下移动机器人物理模型:

1) 小车为一个边长 1 米的正方形结构,它在一条印有标志线的道路上行驶,可以任意角度转向。当标志线上无障碍时,沿标志线方向向前移动;当在标志线上或标志线附近探测到障

碍物时,根据探测到的信息,采取一定的避障措施避开障碍物,然后再回到标志线上;

2) 小车装有五组共十五个超声波传感器,分别探测五个不同方向上的障碍距离 D_{-2} — D_2 ,如图 1(a)所示;每一组由三只传感器组成,传感器的有效探测角度为 30° ,按图 1(b)分布.各方向上传感器组的探测方向与中心线的夹角分别为偏左/偏右 22.5° 和偏左/偏右 45° ,各方向均以该方向上的三只传感器的融合值作为检测数据;

3) 标志线探测由二只红外线传感器完成,这两只传感器分别用于检测小车的当前行进方向与标志线方向间的夹角 ang 和小车偏离标志线的距离 d .小车内部设有专用存储器记录这两个数据;

4) 小车每前进 0.1 米就进行一次环境探测,将获得的七个经信息融合的数据 (D_{-2} — D_2 , d , ang) 作为神经网络的输入再次进行信息融合,信息融合的结果(既神经网络的输出)就是小车的转向控制量.

3 数据分类

本文选用有效探测角度为 30° 的超声波传感器,探测距离为 5 米.由于超声波传感器的波束角问题,单只传感器只能获得障碍物的距离信息,而难以得到障碍物的边界信息和准确的方位信息.在避障过程中,仅有距离信息是不足以完成导航工作的,为此我们将图 1(b)所示每一方向上的三只传感器数据,通过传感器融合,获得障碍物的距离及方位信息.我们采用以下融合算法:

1) 根据检测数据,求出三个探测距离 d_1, d_2, d_3 的最小值 $d_{\min}$ 及最大值 $d_{\max}$:


$$d_{\min} = \min(d_1, d_2, d_3), \quad d_{\max} = \max(d_1, d_2, d_3);$$

2) 根据 $d_{\min}$ 和 $d_{\max}$ 的数值求出障碍物的融合距离;


a) $d_{\min} \leq 1.9$ 时,取该方向的融合值 $D_i = d_{\min}$,这种情况对应于图 2(a),此时该方向上必有障碍物存在;

b) $d_{\min} \geq 3.5$ 时,这种情况对应于图 2(b),由于本文在模糊聚类时,将 $D_i \geq 3$ 的距离都归类为 far,所以此时取 $D_i = d_{\min}$;

c) $1.9 < d_{\min} < 3.5$ 时,这种情况对应于图 2(c),此时三只传感器已不足以判断障碍物的分布情况,只能做近似判断;




(a) 传感器探测方向示意图




(b) 各方向传感器配置情况


图 1 传感器安装方法示意图



(a) 障碍物距离小于 1.9



(b) 障碍物距离大于 3.5



(c) 障碍物距离在 1.9 至 3.5 之间

图 2 障碍物位置判断示意图

对于 $d_{\max} - d_{\min} \leq 0.5$, 取 $D_i = d_{\min}$ (如图 2(c) 中障碍 B); 否则取 $D_i = 5$ 即障碍物不在该方向上, 用 5 将其聚类为 far, 如图 2(c) 中障碍 A, C, D 单独存在的情况. 需要指出的是, 若图 2(c) 中的障碍 A 和障碍 D 同时存在时, 融合结果可能会错误地认为障碍物存在于该方向上, 但是当小车前进一段距离后, 重新进行探测时, 错误的结果就能得到纠正, 仿真结果说明了这一点.

3) 根据各组传感器安装的位置, 将求出的融合距离 D_i 减去该方向上的一个常数, 就能得到五个方向上的障碍物距离 $D_{-2} - D_2$.

根据以上方法处理后的距离数据还不能准确表示障碍物的距离, 如果直接将这些数据作为神经网络的输入, 将会造成学习样本的选取困难, 增大网络规模. 为此, 我们采用模糊聚类法将距离划分为五类:

- 样本值 0 表示 $D_i \leq 0.5$;
- 样本值 1 表示 $0.5 < D_i \leq 1$;
- 样本值 2 表示 $1 < D_i \leq 2$;
- 样本值 3 表示 $2 < D_i \leq 3$;
- 样本值 4 表示 $D_i > 3$.

出于同样的理由, 对偏转角度信息 ang 和与标志线的距离信息 d 也加以模糊聚类:

- 样本值 0 表示 $\text{ang} = 0^\circ$;
- 样本值 1 表示 $0^\circ < \text{ang} < 90^\circ$;
- 样本值 -1 表示 $-90^\circ < \text{ang} < 0^\circ$;
- 样本值 2 表示 $90^\circ \leq \text{ang} \leq 180^\circ$;
- 样本值 -2 表示 $-180^\circ \leq \text{ang} \leq -90^\circ$;
- 样本值 0 表示 $-0.1 \leq d \leq 0.1$;
- 样本值 1 表示 $d > 0.1$;
- 样本值 -1 表示 $d < -0.1$.

其中, 与标志线距离 d 取正或负数, 分别表示小车当前位置处于标志线的左侧或右侧. 将神经网络的输出取整, 可得到一个闭区间 $[-2, 2]$ 上的整数, 控制小车左转 45° , 左转 22.5° , 不改变方向, 右转 22.5° 和右转 45° .

4 神经网络学习算法及样本选取

4.1 导航器神经网络模型及学习算法

本文选用一个三层结构的 BP 网络, 如图 3 所示. 输入层为七个探测到的环境数据(融合值); 第一个隐层由 20 个神经元构成, 非线性函数采用双曲正切 S 型函数, 函数形式为 $\text{tansig}(x) = 2/(1 + \exp(-2x)) - 1$; 第二个隐层由 10 个神经元构成, 非线性函数采用对数 S 型函数 $\text{logsig}(x) = 1/(1 + \exp(-x))$; 神经网络的输出层为一个神经元, 该层没有使用非线性活化函数, 直接用其线性和来控制移动小车的转向角度.

本文使用了自适应型的 BP 学习算法, 并采用批




图 3 避障控制 ANN 结构示意图

模式离线进行学习. 为了加快神经网络学习的收敛速度, 避开学习过程中局部极小的振荡, 采取了两个措施: 一是动态调整学习速率, 当本次学习的全局误差比上一次减小时, 学习速率乘一个大于 1 的常数 im , 收敛速度加快, 反之则乘上一小于 1 的常数 dm , 减小学习速率; 二是引入动量常数, 将上一次学习中对权重的修改乘以动量常数 mc 后代入到本次学习对权重的修改中, 使得权重的修改方向具有一定的惯性, 从而能够避免在局部极小附近的振荡. 在两次迭代之间, 如果误差增长较大的话, 则放弃这一次对权的修改, 以避免学习过程由于误差的连续增长而发散. 整个学习过程简述如下:

1) 构造任意初始权重矩阵 $W1_{20 \times 7}, W2_{10 \times 20}, W3_{1 \times 10}$ 及阈值向量 $B1_{20 \times 1}, B2_{10 \times 1}, B3_{1 \times 1}$, 确定学习速率 lr , 动量常数 mc , 学习速率增长常数 im , 递减常数 dm , 误差要求 eg 和误差最大增长率 er 等, 然后给定样本集矩阵 $P_{7 \times N}$, 及目标集向量 $T_{1 \times N}$, N 为学习样本的个数;

2) 将学习样本矩阵作为输入, 按下面公式求各层神经元的输出矩阵 $A1_{20 \times N}, A2_{10 \times N}, A3_{1 \times N}$ 和总误差 SSE . 并按 BP 算法求出权重的微分矩阵 $D1_{20 \times 7}, D2_{10 \times 20}, D3_{1 \times 10}$:

$$A1_{ij} = \text{tansig}(\sum_{k=1}^7 W1_{ik} P_{kj} + B1_i), \quad (i = 1, \dots, 20, j = 1, \dots, N);$$

$$A2_{ij} = \text{logsig}(\sum_{k=1}^{20} W2_{ik} A1_{kj} + B2_i), \quad (i = 1, \dots, 10, j = 1, \dots, N);$$

$$A3_j = \sum_{k=1}^{10} W3_k A2_{kj} + B3, \quad (j = 1, \dots, N);$$

$$SSE = \sum_{k=1}^N (T_k - A3_k)^2;$$

$$D3_j = T_j - A3_j, \quad (j = 1, \dots, N);$$

$$D2_{ij} = A2_{ij}(1 - A2_{ij}) \sum_{k=1}^1 W3_{ki} D3_{kj}, \quad (i = 1, \dots, 10, j = 1, \dots, N);$$

$$D1_{ij} = (1 - A1_{ij}^2) \sum_{k=1}^{10} W2_{ki} D2_{kj}, \quad (i = 1, \dots, 20, j = 1, \dots, N);$$

3) 将动量常数引入对权重及阈值的修改;

$$\text{new-dw}_{ij} = \text{old-dw}_{ij} MC + lr(1 - MC) \sum_{k=1}^N dw_{ik} P_{jk},$$

$$\text{new-db}_{ij} = \text{old-dw}_{ij} MC + lr(1 - MC) \sum_{k=1}^N dw_{ik}.$$

其中 $\text{new-dw}, \text{new-db}$ 为本次学习对权重及阈值的调整; $\text{old-dw}, \text{old-db}$ 为上一次学习时对权重及阈值的修改, 初值为零; MC 的初始值为 mc , 在以后的学习中将根据步骤 4) 的修改确定; dw 和 p 为矩阵变量, 对于 $W1, B1, W2, B2, W3, B3$ 的学习, dw 相应为 $D1, D2, D3$, 而 p 则为 $P, A1, A2$.

4) 将 $\text{new-dw}, \text{new-db}$ 代入, 求出新的权重矩阵和阈值向量和新的总误差 new-SSE , 并与上一次学习的总误差 SSE 比较;

若 $\text{new-SSE} < SSE \times er$, 表明本次权重调整方向不对, 动量项的引入没有效果, 故放弃本次对权重的修改. 在下一次学习中令 $lr = lr * dm, MC = 0$;

若 $\text{new-SSE} < SSE$, 表明本次学习方向正确, 故接受本次对权重的修改. 并在下一次学习时接受动量项, 令 $MC = mc$, 同时加大学习速率, 令 $lr = lr \times im$;

若 $SSE \times er \leq \text{new-SSE} \leq SSE$, 误差有较小的增长, 接受本次对权重的修改, 以便跳出一些较浅的局部极小。在下一次学习时, 减小学习速率 $lr = lr \times dm$, 放弃动量项 $MC = 0$, 以保证学习算法的收敛;

调整学习速率时, 增长的幅度 im 较小, 而衰减幅度 dm 较大, 使得学习速率不会发散;

5) 重复步骤 2) 至 4) 直到 SSE 小于 eg 为止。

在上面的学习过程中, 若经过长时间的迭代后仍然未能达到学习要求, 表明学习陷入较深的局部极小, 故应采用另一组随机权, 从步骤 1) 开始重新学习。这在本文所采用的离线学习方法中是可行的。

4.2 学习样本的选择

在学习样本的选择中, 我们考虑以下情况:

a) 单障碍物情况, 用于代表独立障碍物, 或通过一次转向(向左或向右)就可以避开的障碍, 以及需要通过边界跟踪才能绕过的障碍;

b) 多障碍物随机分布情况, 代表路面同时存在着多个障碍物、需要同时避让多个障碍物和在避障过程中又遇到新障碍物的情况;

c) 障碍物均匀分布情况, 代表障碍物均匀分布于路面的情况。

对于以上各种情况, 我们采取以下避障策略:

1° 在周围环境比较宽松时, 以靠近标志线并试图减小行进方向与标志线方向夹角和距离的优先级为高, 相应降低避障优先级;

2° 在周围环境较局促时, 以避障为主, 此时可不考虑沿标志线行走, 但应记录脱离标志线后的行进方向角 ang 和与标志线的距离 d ;

3° 当所测的五个前进方向都无法通过时, 本着标志线附近障碍较少这一思想, 原地转弯以搜索可以通过的方向。

根据以上三条策略, 我们设计了三个样本学习环境, 并以此作为移动机器人 ANN 导航控制器的学习样本, 如图 4(a)(b)(c) 所示。

5 仿真运行结果

仿真程序是在 Windows 95 环境下用 DELPHI2.0 编写的, 所采用的硬件平台是 PENTIUMPRO/180。我们分别在图 4 的环境中指导机器人做仿真避障训练, 从中选取了 196 个不同的训练样本, 每个样本由七个传感器信号的融合值和一个转向控制量组成, 其中, 在图 4(a) 环境中采集样本 83 个; 在图 4(b) 环境中采集样本 63 个; 在图 4(c) 环境中采集样本 50 个。

将 196 个训练样本分别输入到图 3 网络系统, 采用前面所述算法进行训练, 直至总误差小于




图 4 避障控制 ANN 训练样本环境




图 5 虚拟环境中的仿真运行结果

0.25 为止. 图中, 两边粗实线代表道路边界, 路中间的细直线代表标志线, car 为小车, S 为运动起点, D 为运动终点. 使用训练所得到的权重矩阵指导机器人分别在图 5(a)(b)(c) 所示环境中进行仿真运行, 移动轨迹结果同时示于图 5.

在前方没有障碍或距离障碍较远时, 小车沿标志线行走; 在距离障碍较近时, 则根据神经网络的输出采取避障行动, 最终穿过障碍群, 到达预定目的地 D.

实验结果表明: 本文所采用的传感器融合方法和模糊聚类与神经网络相结合的导航算法, 能够在比较复杂的障碍环境中正确引导机器人避开障碍, 不失为一种移动机器人自主避障导航的可行方案.

参 考 文 献

- 1 Charles, C. Chan and Kai-Tai Song. Ultrasonic sensor data integration and its application to environment perception. *Journal of Robotic Systems*, 1996, 13(10): 663-677
- 2 Daehee Kang and R. C. Luo, H. . Position estimation for mobile robot using sensor fusion. *Proc. IEEE Conf. on Multisensor Fusion and Integration for Intelligent System*, 1994, 10: 647-652
- 3 Bertrand, Beaufriere and Said Zeghloul. A mobile robot navigation method using a fuzzy logic approach. *Robotica*, 1995, 13: 437-448
- 4 艾海舟, 郝放, 刘文举. 基于人工神经网络的移动机器人研究. *机器人*, 1995, 17(1): 32-35

Study on Fuzzy - Classification Based ANN Navigator for Mobile Robot

FENG Jiannong and LIN Ming

(Department of Computer Engineering & Science, South China University of Technology • Guangzhou, 510641, PRC)

WU Jie

(Electric Power College, South China University of Technology • Guangzhou, 510641, PRC)

Abstract: Fuzzy logic, ANN and sensor fusion are integrated to apply to the study on navigator of mobile robot. Fifteen ultrasonic sensors and two infrared sensors are used to acquire information of environment by sensor fusion. The ability of the ANN navigator of fuzzy-classification based is tested, and the result of simulation in virtual environment is given.

Key word: mobile robot; obstacle-avoidance control; fuzzy-category; ANN; sensor fusion; navigation

本文作者简介

- 冯建农 1960 年生. 华南理工大学计算机系副教授. 主要研究方向为机器人智能导航.
柳 明 1970 年生. 华南理工大学计算机系硕士研究生. 研究方向为计算机测控与仿真.
吴 捷 见本刊 1997 年第 3 期第 369 页.