

# 移动机器人测程法定位误差分析与校正

刘 振 陈万米 熊 奇

(上海大学机电工程与自动化学院 上海 200072)

**摘 要:** 里程计的安装误差和凹凸不平或者光滑地面的环境是影响机器人测程法定位精度的主要原因,针对这一问题,首先利用 UMBmark 校核算法定义了系统误差模型;然后基于陀螺仪的测量数据,提出了机器人直线移动时发生非系统误差的辨识算法,利用所给定的控制信号(输入)与里程计数据(输出)建立模糊神经网络模型,校正机器人自定位因为非系统误差而导致的严重位置误差和方向误差。最后采用上海大学自强队机器人平台验证所提出方法的有效性。

**关键词:** 测程法;系统误差;模糊神经网络;自定位

**中图分类号:** TP242      **文献标识码:** A      **国家标准学科分类代码:** 510.8050

## Analysis and correction error of positioning based on odometry in mobile bobot

Liu Zhen Chen Wanmi Xiong Qi

(School of Mechatronic Engineering and Automation, Shanghai University, Shanghai 200072, China)

**Abstract:** The installation error of odometer, accidented and smooth ground environment are the main reason which influence the positioning accuracy of odometry of robot. In order to solve this problem, the system error model was defined by UMBmark check algorithm first; Then an identification algorithm based on the measured data from gyroscope which inside in the robot was put forward, which can identify the non-systematic error that caused by the robots when they move in a straight line. The fuzzy neural network(FNN) model was established by the input of given control and data of odometer, which can correct the serious positioning and direction error that resulted from non-systematic error. The effective of this approach was proved by the strive robot of Shanghai University finally.

**Keywords:** odometry; systematic error; fuzzy neural network(FNN); self-location

## 0 引 言

在自主移动机器人相关技术研究中,定位技术扮演着一种重要的角色,是机器人实现自主移动控制和路径规划的基础。在移动机器人导航中存在着一个基本问题,即“Where am I?”,机器人需要知道它自身的位置,然后才会衍生出“Where am I going”和“How do I get there”这样的问题。

机器人的定位技术分为绝对定位、相对定位和组合定位 3 种。相对定位又称为航迹推算(dead reckoning),主要依靠光电编码器、陀螺仪等机器人内部传感器,给定初始位姿,通过这些内部传感器数据计算得出机器人的移动相对于初始位姿的距离和方向偏差来实现定位的。相对定位包括两种定位方法:惯性导航和测程法(odometry)。惯性导航通常使用加速度计、陀螺仪、电磁罗盘等传感器。测程法是最广泛使用的机器人定位方法(self-contained),通常可

以将它分为狭义和广义两种类型测程法。狭义测程法是通过采集电机编码器上的数据,然后采用一定的数学计算方法来获取机器人在坐标系中的当前位置。广义测程法是在狭义测程法的基础上多采用了一些外界的绝对传感器来估算机器人位置,在本文,测程法指代的是狭义测程法。

在机器人测程法定位中,数据来源为编码器的正交脉冲信号基于车轮旋转角速度转化为相对地面的线性位移这一前提,因而具有一定的局限性,受到不同方面因素的影响而产生误差,其误差可以分为系统误差和非系统误差两类<sup>[1]</sup>:

1) 系统误差:车轮到底盘中心位置的不对称;左右驱动轮直径不等;编码器精度和采样速率;驱动力轴心不重合。

2) 非系统误差:地面高低不平、车轮打滑和机器人移动经过小障碍物。

如果对机器人误差不做相应的校正,随着运动距离的增大,会导致误差的累积增大,特别是方向上的偏差会显著

影响到机器人的定位精度。Borenstein 和 Feng 等人分析确定了测程法主要系统误差并提出了 UMBmark 校核算法,成为了测程法系统误差校核的最常用算法。Maddahi 等人和 Shi 等人分别在不同的机器人运动模型建模中采用了该方法,取得了良好的效果<sup>[2-3]</sup>;Gersdorf 等人<sup>[4]</sup>融合了陀螺仪的数据利用间接卡尔曼滤波融合里程计数据来修正测程法系统误差;Carreira 等人<sup>[5]</sup>利用统计方法,提出融合电磁罗盘、陀螺仪和编码器的多传感器融合算法来校核非系统误差中的方向误差;Myung 等人<sup>[6]</sup>考虑了陀螺仪的漂移偏差,根据角速度差的大小来判断是估计陀螺仪偏差还是利用直接采用该数据;更进一步,夏凌楠等人<sup>[7]</sup>考虑到机器人移动时的垂直方向和侧向的滑动,利用航迹推断法构建 EKF 过程模型。Yang 等人<sup>[8]</sup>计算一类机器人运行轨迹的里程协方差矩阵,建立了非系统误差模型。

本文首先利用 UMBmark 分析测程法中里程计的主要系统误差,然后通过大量数据训练确定了非系统误差参数,针对已定位中已发生的非系统误差,提出了从控制的角度确定控制信号和编码器输出的非线性输入输出模型,建立模糊神经网络模型<sup>[9-10]</sup>来预测机器人正确的位置信息。最后根据该方法设计实验,验证所提出方法的可行性。

## 1 两轮差动式自主移动机器人测程法定位误差分析

### 1.1 测程法基本模型

狭义测程法具有方法简单、低成本和不需要外部传感器信息来实现对机器人位置和方向的估计,能够提供很高的短期定位精度等优点。典型的两轮式差动机器人工作原理<sup>[11]</sup>如图 1 所示。




图 1 差动式两轮移动机器人移动模型

如图 1 所示,假设机器人某一时刻( $t-1$ )的状态为  $X(t-1) = [x_{t-1}, y_{t-1}, \theta_{t-1}]^T$  表示,其中  $(x_{t-1}, y_{t-1})$  为机器人基于一个固定的世界坐标系所对应的位置,  $\theta_{t-1}$  为机器人的角度偏差,在  $t$  时刻从编码器采样获得了机器人左右轮的位移增量  $D_L(t)$  和  $D_R(t)$ ,这里假设机器人的位移路径在短时间(一次采样间隔)为一个近似直线,则可以得出  $t$  时刻机器人的状态增量:

$$\Delta X(t) = \begin{bmatrix} \Delta x_t \\ \Delta y_t \\ \Delta \theta_t \end{bmatrix} = \begin{bmatrix} \Delta D_t \cos \theta_{t-1} \\ \Delta D_t \sin \theta_{t-1} \\ \Delta \theta_t \end{bmatrix} \quad (1)$$

其中  $\Delta D_t$  为机器人在  $t$  时刻的位移增量:

$$\Delta D_t = \frac{D_L(t) + D_R(t)}{2} \quad (2)$$

$$\Delta \theta_t = \frac{D_R(t) - D_L(t)}{B} \quad (3)$$

式中:  $B$  为机器人的轮距。最终可得出机器人在  $t$  时刻的状态为:

$$X(t) = X(t-1) + \Delta X(t) = \begin{bmatrix} x_t \\ y_t \\ \theta_t \end{bmatrix} = \begin{bmatrix} x_{t-1} + \frac{(D_L(t) + D_R(t)) \cos \theta_{t-1}}{2} \\ y_{t-1} + \frac{(D_L(t) + D_R(t)) \sin \theta_{t-1}}{2} \\ \theta_{t-1} + \frac{D_R(t) - D_L(t)}{B} \end{bmatrix} \quad (4)$$

### 1.2 系统误差分析

假定不准确的轮距和不相等的轮子直径是机器人主要的测程法系统误差,为了减少这两种误差,采用 UMBmark 模型,在实验中,两种误差分别定义为  $E_b$  和  $E_d$ :

$$E_b = \frac{B_a}{B_n} \quad (5)$$

$$E_d = \frac{D_R}{D_L} \quad (6)$$

式中:  $B_a$  和  $B_n$  分别为机器人实际轮距和理论轮距,  $D_R$  和  $D_L$  分别为机器人左右轮的实际直径。

为了分隔两种误差,引入如图 2 所示的“双向正方形路径实验”,实验步骤如下:

- 1) 测出机器人的起始位置;
- 2) 根据的数据让机器人顺时针缓慢通过一个  $4 \text{ m} \times 4 \text{ m}$  的正方形路径(走  $4 \text{ m}$  后定点旋转  $90^\circ$ );
- 3) 机器人走到终点后,测出机器人相对于参照物的实际距离;
- 4) 机器人起始和终点位置的差值;
- 5) 重复以上步骤 5 次;得出顺向 5 个差值数据;




图 2 UMBmark 算法系统误差校核模型

6) 逆时针方向重复以上步骤,得出逆向 5 个差值。

如图 2 可知,  $\alpha$  为机器人旋转时候角度方向的误差,  $\beta$  为机器人在一个方向移动时机器人的方向误差。在实验中,认为机器人不正确的轮距只对机器人旋转造成影响,而不相等的轮直径只对机器人的直移造成影响,可以得出式(7)~(10):

$$\alpha = \frac{x_{cw} + x_{ccw}}{-4L} \cdot \frac{180^\circ}{\pi} \text{ 或 } \alpha = \frac{y_{cw} - y_{ccw}}{-4L} \cdot \frac{180^\circ}{\pi} \quad (7)$$

$$\beta = \frac{x_{cw} - x_{ccw}}{-4L} \cdot \frac{180^\circ}{\pi} \text{ 或 } \beta = \frac{y_{cw} + y_{ccw}}{-4L} \cdot \frac{180^\circ}{\pi} \quad (8)$$

$$E_b = \frac{B_a}{B_n} = \frac{90^\circ}{90^\circ - \alpha} \quad (9)$$

式中:  $x_{cw}$  和  $y_{cw}$  为实验中顺时针方向的  $x$  轴和  $y$  轴的偏差均值;  $x_{ccw}$  和  $y_{ccw}$  为实验中逆时针方向的  $x$  轴和  $y$  轴的偏差均值;  $B$  为机器人轮距。

在不相等的轮直径实验中机器人在一条直线上移动,可以认为机器人移动的路径为一条圆弧,其实际轨迹如图 3 所示。




图 3 机器人移动轨迹

$$E_d = \frac{D_R}{D_L} = \frac{\frac{L/2}{\sin(\beta/2)} + \frac{B}{2}}{\frac{L/2}{\sin(\beta/2)} - \frac{B}{2}} \quad (10)$$

其中,  $\frac{L/2}{\sin(\beta/2)}$  为机器人沿一条直线走过的弧线的曲率半径。

### 1.3 机器人非系统误差的辨识方法

非系统误差是由于轮式移动机器人运动过程中的诸多随机因素引起的不确定性误差。而其中方向误差是主要误差源,一个极小的方向误差可能对整个机器人的全局定位造成一个严重的位置误差。而在测程法中,若是机器人移动过程中轮子穿过小的障碍物或者打滑时,都会造成某一个编码器所捕获的数据大于正常移动的数据,从而导致角度测量误差变大。

为了分辨出机器人在某次采样时刻是发生了非系统误差还是正常运行,利用机器人的内部传感器陀螺仪得出的角度数据来校核,定义:

$$\Delta\theta(t) = |\theta_o(t) - \theta_G(t)| \quad (11)$$

式中:  $\theta_o(t)$  为式(3)中  $t$  时刻里程计角度增量,  $\theta_G(t)$  为陀螺仪在  $t$  时刻的角度增量。在理想情况下,由于传感器的采样误差、精度误差等使得  $\Delta\theta(t)$  不为 0。这里认为机器人左右驱动轮发生打滑的可能性相同,所以认为  $\Delta\theta(t)$  服从正态分布。

这里选择以粗糙的平整地面采样获取  $\Delta\theta(t)$  的实际数学期望值  $\mu$ , 实验步骤为:

1) 让机器人先缓慢加速后以同等速率减速直线移动 10 m, 其中里程计和陀螺仪的采样频率要保持一致(以机器人正常运行时的采样频率为准);

2) 计算每一个  $\Delta\theta(t)$  并保存;

3) 重复 1)、2) 实验  $n$  次(这里选择 9 次), 计算:

$$\mu = \frac{\sum_{n=0}^T \Delta\theta(t)}{n \times T} \quad (12)$$

$$P_{\text{refuse}} \{ |\Delta\theta - \mu| \geq k \} = \frac{\alpha}{2} \quad (13)$$

式中:  $T$  为采样次数,  $P_{\text{refuse}} \{ * \}$  为误差偏差过大时的概率, 这里取显著性水平  $\alpha = 0.1$ 。

对所有的采样数据进行统计得出  $k$  的值。

实际情况中,由于路况的复杂性和实际机器人轮子的材料不同,基于不同的实验条件  $\alpha$  的选取也不尽相同,最后得出的模型偏差值  $k$  也不尽相同。

基于以上数据,根据式(3)可以得出:

1) 当  $|\Delta\theta(t) - \mu| \geq k$  且  $\theta_o(t) > \theta_G(t)$  时,

$$\theta_G(t) \approx \frac{D_{R\_Normal}(t) - D_{R\_Normal}(t)}{B} \geq$$

$$\frac{D_{R\_Actual}(t) - D_{L\_Actual}(t)}{B}$$

$$D_{R\_Actual}(t) \geq D_{R\_Normal}(t) \text{ 并且}$$

$$D_{L\_Actual}(t) \geq D_{L\_Normal}(t)$$

其中,  $D_{R\_Normal}(t)$  和  $D_{L\_Normal}(t)$  为理论上基于陀螺仪数据的左右驱动轮位移增量,  $D_{R\_Actual}(t)$  和  $D_{L\_Actual}(t)$  为实际测量出的左右轮位移增量。可得出  $D_{R\_Actual}(t) \leq D_{R\_Normal}(t)$ , 所以可判断是右驱动轮穿过障碍物或者发生滑动,左驱动轮移动状态不定,机器人可能正常移动,也可能经过障碍物或者发生滑动。

2) 当  $|\Delta\theta(t) - \mu| \geq k$  且  $\theta_o(t) < \theta_G(t)$  时,同理可得出左驱动轮穿过障碍物或者发生滑动,右驱动轮移动状态不定。

3) 当  $|\Delta\theta(t) - \mu| < k$  时,由里程计计算出的数据和陀螺仪得出的数据近似相等,可以认为此时机器人没有产生明显的非系统文件。机器人也可能左右两轮出现同样程度的偏差,在这里不做详细的论述。

## 2 基于模糊神经网络的测程法非系统误差校正

在机器人运动控制当中,是根据当前位姿和目标位置

来做出机器人运动决策,具体是通过机器人左右驱动电机给出不同 PWM(脉冲宽度调制)信号使驱动轮产生不同的转速,从而达到控制机器人移动的目的。然而在实际中,由于机器人的机械特性、驱动电机的电学特性等原因,所给出的两路 PWM 值与里程计输出值并不成一个线性关系,为一个非线性系统。

传统的信息处理技术对这样的系统时常无能为力,但有经验的专家却能对这些复杂的对象进行令人满意的处理。于是在以算法为核心的传统信息处理理论的基础上,诞生了集启发式知识获取、处理与应用于一体的新型处理技术——智能信息处理,它有望解决信息量不足的病态问题、用数学模型难以描述的非线性问题、有计算的复杂性与实时性要求的问题等等。模糊神经网络技术是把经验与知识数字化的模糊化处理与把规则、推理变成神经网络映射处理和直接从数据样本中抽取经验规则相结合的<sup>[10,12]</sup>。模糊逻辑和神经网络在许多方面具有关联性和互补性。而且,理论上已经证明:模糊逻辑系统能以任意精度逼近一个非线性函数,神经网络具有映射能力<sup>[13-14]</sup>。

这里采用的是由 TSK 型模糊逻辑系统和 RBF 神经网络组成的多层前馈型网络<sup>[10,15]</sup>。多输入多输出系统可分解为多个多输入单输出系统,可以选取零阶的 TSK 型模糊逻辑规则:

$$\begin{aligned} R^l: & \text{IF } x_1 \text{ is } F_1^l \text{ AND } x_2 \text{ is } F_2^l \cdots x_m \text{ is } F_m^l \\ \text{THEN } & y = h_l, \quad l = 1, 2, \dots, N \end{aligned} \quad (14)$$

其中  $R^l$  表示第  $l$  条模糊规则,  $N$  表示总的模糊规则数,  $xR^M$  表示系统的输入变量,  $yR$  表示系统的单一输出变量,  $F_i^l (l = 1, 2, \dots, N, i = 1, 2, \dots, M)$  表示定义在领域  $[0, 1]$  上的模糊集合,  $h_l$  表示模糊系统的第  $l$  个权值或后件。

整个系统包括 5 层,如图 4 所示,第 1 层为输入层,为直连的各个输入向量,该层节点数为  $N_1 = m$ 。




图 4 模糊神经网络结构

第 2 层由  $N$  条模糊规则组成,每组分别有  $M$  个神经元,每个神经元都表示一个隶属度函数。其输入输出表达式为:

$$O_l^{(2)} = \mu_{F^l}(x(k)) = \exp\left(-\frac{(x(k) - c_{lk})^2}{\delta_l^2}\right) \quad k = 1, \dots, M, l = 1, \dots, N \quad (15)$$

第 3 层由  $N$  个神经元组成,用来计算每条规则的强度。每个神经元与第 2 层的相应组别的所有神经元相连。输入输出可表达为:

$$O_l^{(3)} = \prod_{k=1}^M (\mu_{F^l}(x(k))) = \exp\left(-\sum_{k=1}^M \frac{(x(k) - c_{lk})^2}{\delta_l^2}\right) \quad l = 1, \dots, N \quad (16)$$

第 4 层由 2 个神经元组成。一个神经元与第 3 层神经元通过单位权值相连,另外一个神经元通过权值  $h$  与第 3 层神经元连接,可以表示为:

$$\begin{aligned} O_1^{(4)} &= \sum_{l=1}^N O_l^{(3)} \\ O_2^{(4)} &= \sum_{l=1}^N h_l O_l^{(3)} \end{aligned} \quad (17)$$

第 5 层为整体结构的输出层,与第 4 层 2 个神经元直连,表示如下:

$$y = O^{(5)} = \frac{O_2^{(4)}}{O_1^{(4)}} = \sum_{l=1}^N \phi_l h_l \quad (18)$$

其中,

$$\phi_l = \frac{\exp\left(-\sum_{k=1}^M \frac{(x(k) - c_{lk})^2}{\delta_l^2}\right)}{\sum_{l=1}^N \exp\left(-\sum_{k=1}^M \frac{(x(k) - c_{lk})^2}{\delta_l^2}\right)} \quad l = 1, 2, \dots, N \quad (19)$$

可调节参数为  $w$ ,通过模糊  $C$  均值聚类算法来学习,  $w$  可表示为:

$$w = \begin{bmatrix} c_{11} & \cdots & c_{1M} \\ \vdots & \ddots & \vdots \\ c_{N1} & \cdots & c_{NM} \\ \delta_1 & \cdots & \delta_N \\ h_1 & \cdots & h_N \end{bmatrix}$$

这些可调节参数的学习算法如下:

1) 给定相似性参数  $\beta$ ,将训练数据对  $x(1) = \{x_1(1), x_2(1), \dots, x_M(1)\}$  作为第一个聚类,并设聚类中心  $c_1 = x(1)$ ,此时的聚类个数  $N = 1$ ,属于第一个聚类的数据对数目为  $N_1 = 1$ 。

(2) 对于第  $k$  组训练数据  $x(k) = \{x_1(k), x_2(k), \dots, x_M(k)\}$ ,按照相似性判据计算第  $k$  组训练数据与每一个聚类中心  $c_l (l = 1, 2, \dots, N)$  的相似性,并找到具有最大相似性的聚类  $L$ ,即找到  $x(k)$  属于的聚类(模糊规则)。相似性判据计算如下:

$$S_L = \max_{1 \leq l \leq N} (\sqrt{e^{-x(k) - c_l^2}}) \quad (20)$$

3) 如果  $S_L < \beta$ ,表明第  $k$  组训练数据不属于已有的聚类,则要建立一个新聚类,令  $c_{N+1} = x(k)$ ,并令  $N = N + 1$ ,

$N_N = 1$  ( $N_N$  表示属于第  $N$  个聚类的训练数据对数目);如果  $S_L \geq \beta$ , 表明第  $k$  组训练数据属于第  $L$  个聚类, 则按式 (21) 调节第  $L$  个聚类的参数:

$$c_L = c_L + \lambda(x(k) - c_L)$$
$$\lambda = \frac{\lambda_0}{N_L + 1}, \lambda_0 \in [0, 1]$$
$$N_L = N_L + 1$$

(21)

式中:  $\lambda$  为学习率,  $N_L$  表示聚类  $L$  的数据对数目。

4) 令  $k = k + 1$ , 重复执行步骤 2)~4) 直到所有的训练数据对都被分配到相应的聚类中为止。从而得到聚类个数 (模糊规则) 为  $N$ , 隶属度函数的宽度计算如下:

$$\delta_l = \min_{\substack{j=1,2,\dots,N \\ j \neq l}} \frac{|c_l - c_j|}{\rho}$$

(22)

其中  $\rho$  为交迭参数, 通常取  $1 \leq \rho \leq 2$ 。

(5) 计算模糊规则后件参数  $h_l$ :

$$h_l = \frac{\sum y_l}{n_l}, l = 1, 2, \dots, N$$

(23)

式中:  $n_l$  为第  $l$  个聚类的样本个数,  $\sum y_l$  为其样本值总和, 输出为其平均值。

为了更好的建立两路电机输入和两路编码器输出的模糊神经网络模型, 可以采取以下步骤提高训练准确度:

1) 让机器人由静止状态逐渐加速到机器人速度最大值, 然后逐渐减速直到机器人变为静止状态, 定时采样机器人控制信号和里程计输出数据并记录;

2) 让机器人以一个以采用频率变化的随机角度控制信号 ( $\pm 30^\circ$  内) 驱动机器人移动, 定时采样机器人控制信号和里程计输出数据并记录;

3) 重复步骤 1) 测试 10 次, 以机器人控制器占空比从 50% 缓慢增加到 100% 重复实验多次 (这里取增量 2%, 重复 24 次)。

根据 1.3 节的机器人非系统误差辨识算法判断机器人发生非系统误差时, 就可以根据电机的瞬时输入信号利用所建立的先验模糊神经网络模型, 来预估编码器的输出值, 从而校正了误差。

3 实验结果及分析

本文的实验是基于上海大学自强队自主研发的篮球机器人平台, 如图 5 所示, 采用了两个 TRD-2T1000AF 增量式光电编码器和一个 MPU6050 六轴陀螺仪 (自带滤波算法), 通过串口实时将数据传递给控制器, 控制器来处理这些传感器信息, 从而获取机器人的外界信息, 这里所用的控制器为 STM32F407 开发板。

为了验证 UMBmark 系统校正的有效性, 按照其算法流程执行下去, 即以 30 cm/s 的速度移动机器人经过正向 4 m×4 m 和反向 4 m×4 m 粗糙且平整地面路径分别 5 次, 可计算出相应的  $E_b$  和  $E_d$  值, 以及机器人的位置偏差  $r$ 。假定机器人的初始位置为 (0, 0), 机器人轮距  $B =$




图 5 上海大学篮球机器人

52 cm, 机器人的位置偏差为  $r$ 。  $r = \max(\sqrt{x_{cw}^2 + y_{cw}^2}, \sqrt{x_{ccw}^2 + y_{ccw}^2})$

表 1 UMBmark 校核实验

	顺时针 4 m×4 m 时/cm		逆时针 4 m×4 m 时/cm	
	$x_{cw}$	$y_{cw}$	$x_{ccw}$	$y_{ccw}$
1	22	−25	18	12
2	16	−15	25	17
3	19	−20	16	9
4	13	−11	17	22
5	17	−13	23	18
平均	17.4	−16.8	19.8	15.6

根据式 (7)~式 (10) 得出  $E_b$  和  $E_d$  的值。  
校核模型后重复实验得出数据如表 2 所示。

表 2 校核后实验数据

	顺时针 4 m×4 m 时/cm		逆时针 4 m×4 m 时/cm	
	$x_{cw}$	$y_{cw}$	$x_{ccw}$	$y_{ccw}$
1	−9	7	11	6
2	−7	7	3	4
3	−11	8	8	6
4	−5	2	−1	2
5	−6	−1	4	9
平均	−7.6	4.6	5.0	5.4

$$r_{\text{before}} = \max(\sqrt{17.4^2 + 16.8^2}, \sqrt{19.8^2 + 15.6^2}) =$$
$$25.207\ 1$$
$$r_{\text{after}} = \max(\sqrt{7.6^2 + 4.6^2}, \sqrt{5.0^2 + 5.4^2}) = 8.883\ 7$$

在表 3 中, 可以看到经过 UMBmark 实验方法标定后的机器人参数能够很好地减少机器人运行时的系统误差。  
为了辨识机器人某个采样时间段的位移是否发生了非系统误差, 采用本文提出的机器人非系统误差辨识方法, 控制器将采样到的编码器和陀螺仪数据通过串口发送给 PC, 然后保存并分析, 采样结果如表 4 所示。

表 3 系统误差校正实验结果

	$E_b$	$E_d$	$r$
校正前	1	1	25.207 1
校正后	0.898	0.995	8.883 7

表 4 样本数据

$\Delta\theta$ 区间/(°)	中间值	频数
(-4,-3]	-3.5	36
(-3,-2]	-2.5	213
(-2,-1]	-1.5	701
(-1,-0.5]	-0.75	551
(-0.5,0]	-0.25	1 557
(0,0.5]	0.25	952
(0.5,1]	0.75	688
(1,2]	1.5	436
(2,3]	2.5	176
(3,4]	3.5	28

该表显示了 5 338 个样本数据,所以样本大小  $n=5\,338$ ,根据式(12)、(13)计算,取显著性水平  $\alpha=0.1$ 。在取得的样本中  $\mu=-0.13$ ,拒绝域为  $|\Delta\theta-\mu|\geq 2.2$ 。其正态分布概率密度以及实际分布直方图如图 6 所示,其实际分布能够很好逼近正态分布曲线,因此  $\Delta\theta$  服从正态分布。




图 6  $\Delta\theta$  概率密度及统计直方图

在机器人直线移动的实验室中,以陀螺仪的角度数据为准,可以得到里程计通过式(3)推导的瞬时角度偏差数据如图 7 所示,在 14 s 和 28 s 附近,里程计数据角度偏差数据大于可信值  $2.2^\circ$ ,可以认为机器人发生了非系统误差(实验地面为  $3\text{ m}\times 3\text{ m}$  的地板)。

为了得到关于控制器输入(PWM)和里程计输出的非线性模型,这里用文中所给出的学习方法,建立模糊神经网络模型,选取  $\beta=0.72$ ,对采集到的里程计数据 and 控制器输入数据进行分析然后建模,如图 8~10 所示。

最后,让机器人分别采用不同的算法在一个有小坑的平坦水泥地面上缓慢直线移动 10 m,在同一起点及初始方




图 7 非系统误差辨识




图 8 输入输出曲面




图 9 模型曲面

向重复实验 20 次,实验结果如表 5 所示,采用基于模糊神经网络预估位置增量来校正机器人非系统误差的方法,能很好的抑制机器人运动中产生的非系统误差。

表 5 机器人直线通过特定地面结果

采用方法	机器人实际位置	误差/%
无	(9.154,-1.358)	15.997
UMBmark 校核算法	(9.337,-1.129)	13.093
UMBmark 校核、 FNN 模型校正	(9.765 4,-0.268)	3.561






图 10 模型误差曲面

## 4 结 论

机器人测程法定位中的误差是由非系统误差和系统误差组成,对于系统误差可以通过合理的实验测出因为“不相等的轮直径”、“轮距的不确定”的误差系数;对于非系统误差,文章提出了因“穿过障碍物”、“轮子打滑”而产生误差的辨识方法,通过先验数据建立一个基于模糊神经网络的模型来预估其位置正常值来校正。实验结果表明,该方法能够有效地抑制非系统误差和校正系统误差,且方法简单。

## 参考文献

- [1] KREINAR E J, QUINN R D. Odometry error estimation for a differential drive robot snowplow[C]. 2014 IEEE-ION Position Location and Navigation Symposium (PLANS), 2014: 1122-1129.
- [2] MADDAHI Y, SEPEHRI N, MADDAHI A, et al. Calibration of wheeled mobile robots with differential drive mechanisms: an experimental approach[J]. ROBOTICA, 2012, 30(6):22-26.
- [3] SHI J, LIU J, WANG J. Novel method to calibrate kinematic parameters for mobile robots[J]. Journal of Beijing Institute of Technology, 2015, 24(1):91-96.
- [4] GERSDORF B, FRESE U. A Kalman filter for odometry using a wheel mounted inertial sensor[C]. 10th International Conference on Informatics in Control, Automation and Robotics, 2013: 388-395.
- [5] CARREIRA F, CALADO J M F. Complementary filter design with three frequency bands: Robot attitude estimation[C]. 9th IEEE International Confe-

rence on Autonomous Robot Systems and Competitions (ICARSC), 2015:168-173.

- [6] MYUNG H, LEE H K, CHOI K, et al. Mobile robot localization with gyroscope and constrained kalman filter[J]. International Journal of Control Automation and Systems, 2010, 8(3): 667-676.
- [7] 夏凌楠,张波,王营冠,等. 基于惯性传感器和视觉里程计的机器人定位[J]. 仪器仪表学报, 2013, 34(1): 166-172.
- [8] YANG J D, YANG J H, CAI Z S. An efficient approach to pose tracking based on odometric error modelling for mobile robots[J]. Robotica, 2015, 33(6):1231-1249.
- [9] 董早鹏,刘涛,万磊,等. 基于 Takagi-Sugeno 模糊神经网络的欠驱动无人艇直线航迹跟踪控制[J]. 仪器仪表学报, 2015, 36(4): 863-870.
- [10] 邓娜. 模糊神经网络模型的优化约简及非线性逼近研究[D]. 广州:华南理工大学, 2013.
- [11] JUNG C, MOON C B, JUNG D, et al. Design of test track for accurate calibration of two wheel differential mobile robots[J]. International Journal of Precision Engineering & Manufacturing, 2014, 15(1):53-61.
- [12] QIAO J F, LI W. Identification of fuzzy neural networks by forward recursive input-output clustering and accurate similarity analysis[J]. Applied Soft Computing, 2016(49): 524-543.
- [13] 邵婷婷,张博超,周美丽,等. 基于 RBF 神经网络的测斜仪方位角校正研究[J]. 国外电子测量技术, 2016, 35(2): 77-79.
- [14] 谢苗,刘治翔,毛君. 基于改进型 ANFIS 的矿用空压机故障诊断系统[J]. 电子测量与仪器学报, 2015, 29(4): 500-507.
- [15] LI J, CHIU M S, GE S S. A noniterative neuro-fuzzy based identification method for Hammerstein processes[J]. Journal of Process Control, 2005, 15(7):749-761.

## 作者简介

刘振,上海大学工学硕士,控制理论与控制工程专业,研究方向为自主移动机器人。

E-mail: liuzhenstrive@outlook.com