

基于模糊信息分解与控制规则的移动机器人沿墙导航

方梦琳¹ 唐文兵¹ 黄鸿云² 丁佐华¹

1 浙江理工大学信息学院 杭州 310018

2 浙江理工大学图书馆多媒体大数据中心 杭州 310018

(menglinfang@126.com)

摘要 由于机器人导航任务对实时性要求高,以及机器人自身的非线性导致很难精确建模,而基于规则的控制可解释性好,可以实时响应。因此,文中提出了一种基于模糊信息分解(Fuzzy-based Information Decomposition, FID)与控制规则的机器人沿墙导航方法。在UCI机器人导航数据集上,首先用FID对原始类别不平衡数据集进行过采样,之后训练支持向量机(SVM),然后从SVM中提取控制规则。在提取规则过程中,仅使用支持向量以减少规则数量和提高实时性,使用这些支持向量训练随机森林,然后从中提取控制规则。实验结果表明,在相同数据集上,相较于决策树等6个经典模型,所提方法的平均F1值为0.994,对小类样本的召回率平均提升8.09%。与其他提取规则的模型相比,从SVM中提取规则的方法能平均减少171.33条规则,在测试样本上的平均单个样本决策时间仅为3.145μs。

关键词: 控制规则;类别不平衡;模糊信息分解;支持向量机

中图法分类号 TP242.6

Wall-following Navigation of Mobile Robot Based on Fuzzy-based Information Decomposition and Control Rules

FANG Meng-lin¹, TANG Wen-bing¹, HUANG Hong-yun² and DING Zuo-hua¹

1 School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China

2 Center of Multimedia Big Data of Library, Zhejiang Sci-Tech University, Hangzhou 310018, China

Abstract Due to the high real-time requirements of robot navigation task and the nonlinearity of the robot itself, it is difficult to model accurately, and the rule-based control has good interpretability and real-time response generally. Therefore, a method of robot wall-following navigation based on fuzzy-based information decomposition (FID) and control rules is proposed. In UCI robot navigation data set, the original classimbalanced data set is over-sampled by FID, and then SVM is trained, and control rules are extracted from SVM. In the process of extracting rules, only support vectors are used to reduce the number of rules and improve the real-time performance. These support vectors are used to train the random forest, which is applied to extract control rules. The experimental results show that, on the same data set, the average F1 score of the proposed method is 0.994, and the recall rate of the minority class increases by 8.09% on average, compared with the six classic models such as decision tree. Compared with other rule extraction models, the rule extraction method from SVM can reduce 171.33 rules on average, and the average decision time per sample on the test sample is only 3.145μs.

Keywords Control rules, Class imbalance, Fuzzy-based information decomposition, Support vector machine

1 引言

沿墙导航是一类特殊的运动控制,指机器人在特定方向上沿着墙壁运动,并与物体的壁面保持安全距离^[1]。研究沿墙导航有利于提高机器人在不确定环境下的自适应能力,有益于提升机器人执行复杂任务的能力。

本文在UCI移动机器人沿墙导航数据集(Wall Following Robot Navigation Data, WFRN)上^[2],构建多类别分类器(控制器),即构建一个从传感器感知空间到执行器执行动作空间的非线性映射。WFRN数据集包含4类样本,其中大类样本占的比例为40.41%,而小类样本仅为6.01%,是一个

类别不平衡数据集^[3]。类别不平衡的数据集对训练出的分类器性能有着重要影响,因此,在构造控制器之前,需要对数据集进行“再平衡”处理^[4]。针对数据集层面,现有的处理不平衡数据的方法有欠采样、过采样等。然而常用的过采样方法——随机过采样通过随机复制小类样本来平衡类别分布,这可能会造成过拟合^[5]。本文采用模糊信息分解(Fuzzy-Based Information Decomposition, FID)方法对小类样本进行过采样,FID是一种基于模糊逻辑的数据过采样方法,可被用于处理数据不平衡和缺失值问题^[6]。

WFRN数据集已被用于训练神经网络(Neural Networks, NN)^[7-8]、支持向量机(Support Vector Machine,

基金项目:国家自然科学基金项目(61210004,61170015)

This work was supported by the National Natural Science Foundation of China (61210004,61170015).

通信作者:丁佐华(zouhuading@hotmail.com)

SVM)^[9]来控制机器人沿墙运动。然而,NN 和 SVM 的“黑盒”性质却阻碍了它在机器人导航、自动驾驶和医疗健康等领域的应用,即确定神经网络做出特定决策的原因是一项困难的任务^[10-11]。基于规则(如模糊规则、置信规则等)的控制方法不需要对被控系统进行精确建模,是一种 Model-free 的控制模型,具有实时响应和易于理解等优点^[12],但难点是如何高效地获取控制性能好并且精简的规则库^[13]。

为了解决上述不足,本文使用从 SVM 中提取规则的方法^[10]。首先,在训练集上训练 SVM,并从中提取出真正起决策作用(即决定分类超平面)的支持向量(Support Vectors, SVs)^[10,14]。然后,使用 SVM 对 SVs 的类别标签重新进行标记,得到一个人工数据集,更改标签的目的是确保将来生成的规则能够尽可能地模拟 SVM 的预测。最后,人工数据集被用于训练随机森林(Random Forest, RF),并从中提取控制规则,这是由于 RF 中每棵基决策树天然地包含了决策规则。本文方法通过 SVM 筛选出 SVs 以减少规则的数量,并将随机森林的学习能力和泛化能力与规则的可解释性结合起来。

实验表明,本文实现的基于 FID 和控制规则的移动机器人沿墙导航方法与决策树(C4.5)、k 近邻(KNN)、朴素贝叶斯(NB)、NN、RF 和 SVM 等方法在相同数据集上相比,F1 值平均提高 6.99%,小类样本的召回率平均提升 8.09%。与其他提取规则的模型相比,从 SVM 中提取的规则数量平均减少 171.33 条规则,平均单个样本决策时间减少 0.27μs。

本文第 2 节介绍所提方法的框架与相关数据集;第 3 节介绍了 FID 方法、如何训练 SVM 以及如何从 SVM 中提取规则;第 4 节给出实验结果与分析;第 5 节介绍相关工作;最后总结全文,并指出后续的研究方向。

2 沿墙导航方法框架与数据集

2.1 方法框架

如图 1 所示,本文提出的机器人沿墙导航方法分为 4 个过程,包括:数据集预处理过程、SVM 训练过程、规则提取过程和测试过程。首先对原始数据集中的小类样本使用 FID 进行过采样,即增加该类别的样本数量,并将处理过的数据集划分为训练集和测试集。然后从训练集中训练 SVM,以提取规则。之后筛选出 SVs,并使用 SVM 对 SVs 的类别标签重新进行标记,得到人工数据集。在人工数据集上训练 RF,并从中提取控制规则,所有规则构成一个控制器。在测试过程,将测试集中的每个样本使用控制器对其进行分类。

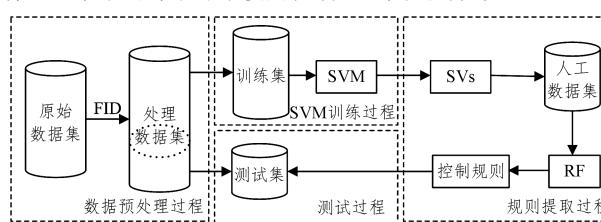


图 1 沿墙导航方法的框架

Fig. 1 Framework of wall-following navigation approach

2.2 数据集介绍

本文使用的 WFRN 数据集记录了布置在 SCITOS G5 机器人上的 24 个超声波传感器(感知范围为 20cm 至 300cm,采样频率为 9Hz)的读数和机器人执行的动作。机器人有 4 个离散的动作:Move-Forward (MF), Slight-Right-Turn

(SRT1), Sharp-Right-Turn (SRT2) 和 Slight-Left-Turn (SLT)。即向前,缓慢右转、急速右转和缓慢左转。

该数据集共包含 3 个子数据集 sensor_readings_2(S2), sensor_readings_4(S4), sensor_readings_24(S24), 分别记录了 24 个超声波中的 2 个、4 个、24 个超声波的读数,每个文件包含 5456 个样本。4 个动作在数据集中的类别分布如表 1 所列。

表 1 动作在数据集中的分布

Table 1 Distribution of actions in dataset

动作	样本数量	所占比例/%
MF	2205	40.01
SRT1	826	15.03
SRT2	2097	38.43
SLT	328	6.01

每个样本包含传感器读数 $X_{ij}, i=1, \dots, 5456, j=1, \dots, n$, 其中 $n=2, 4, 24$ 。机器人动作为 a_i 。 $D=\{(X_i, a_i) | i=1, 2, \dots, 5456\}$ 。sensor_readings_24 的部分数据样本的样例如表 2 所列。

表 2 部分样本数据规格

Table 2 Part specification of sample data

No.	X_1	X_2	$X_3 \sim X_{23}$	X_{24}	Action
1	0.438	0.498	...	0.429	SRT1
73	0.800	0.855	...	0.878	MF
5295	1.839	2.215	...	1.828	SLT
5456	0.950	4.066	...	1.168	SRT2

3 沿墙导航方法

3.1 基于 FID 的数据预处理

现有的分类器大多假设不同类别的训练样本数目是相当的,如果将这样的分类器直接用于类别不平衡数据集,将会驱动分类器产生有利于大类的模型(规则),导致模型对小类识别率很低。

考虑到类别不平衡数据对分类器性能的影响,本文采用 FID 方法处理类别不平衡问题。假设需要生成的小类样本数量为 t ,需要处理的数据集为:

$$D=\{(X_i, a_i) | i=1, 2, \dots, N_{SLT}\}$$

其中, $X_i=(x_{1i}, x_{2i}, \dots, x_{mi})$, $a_i=SLT$ 。

对于 D 的第 j 个特征维度(即某个传感器所有读数) φ_j 有:

$$\varphi_j=(x_{j1}, x_{j2}, \dots, x_{jN_{SLT}}), j=1, \dots, m \quad (1)$$

FID 首先计算 φ_j 的边界值 $x_{\varphi_j}^m$ 和 $x_{\varphi_j}^M$, 即为了生成 t 个小类样本,首先将区间 $I_j=[x_{\varphi_j}^m, x_{\varphi_j}^M]$ 划分为 t 个等距的子区间,即

$$I_j=\bigcup_{s=1}^t I_{js}, \text{ 每个子区间的长度为: } h_j$$

$$h_j=(x_{\varphi_j}^M - x_{\varphi_j}^m)/t \quad (2)$$

因此,子区间 I_{js} 可表示为:

$$I_{js}=[x_{\varphi_j}^m + h_j(s-1), x_{\varphi_j}^m + h_js] \quad (3)$$

其区间中心记为 C_{js} 。

对于每个 x_{jk} ($k=1, \dots, N_{SLT}$),计算 t 个隶属函数。隶属函数采用如下形式:

$$\mu(x_{ji}, c_{js})=\begin{cases} 1-\frac{\|x_{jk}-c_{js}\|}{h_j}, & \text{if } \|x_{jk}-c_{js}\| \leq h_j \\ 0, & \text{其他} \end{cases} \quad (4)$$

其中, $\mu(x_{ji}, c_{js})$ 是 x_{jk} 的第 s 个隶属函数。

基于隶属函数可以生成新的组合数据。数据生成方法如下:

$$G_{js} = \begin{cases} \frac{\sum_{k=1}^{N_{SLT}} x_{jk}}{N_{SLT}}, & \text{if } \sum_{k=1}^{N_{SLT}} \mu(x_{jk}, c_{js}) = 0 \\ \frac{\sum_{k=1}^{N_{SLT}} \mu(x_{jk}, c_{js}) * x_{jk}}{\sum_{k=1}^{N_{SLT}} \mu(x_{jk}, c_{js})}, & \text{其他} \end{cases} \quad (5)$$

上述数据生成方法中如果 x_{jk} 对所有子区间的隶属度均为 0, 则用该维度上所有传感器读数的平均值代替, 否则基于模糊隶属度计算生成的数值。对每个数据集的每个维度逐次执行上述过程, 则可以得到一个处理之后的数据集 D' , 新的数据集可表示为:

$$D' = \{(X_i, a_i) | i=1, 2, \dots, N_{SLT} + t\}, a_i = SLT$$

3.2 训练 SVM

SVM 是建立在 VC 维理论和结构风险最小化原理基础上的机器学习方法, 能较好地解决过拟合、局部极小、维数灾难等问题, 已被广泛应用于分类、回归、决策等方面。SVM 的基本模型是定义在特征空间上的间隔最大的线性分类器, 即寻找一个最优分类超平面将不同类的样本分开, 并且使得分类间隔最大化。标准的 SVM 学习算法问题可以归结为求解一个受约束的凸二次型规划问题, 然后再用拉格朗日乘子法求对偶问题的解, 进而得到原问题的解。对于线性不可分问题, 引入核函数在变换空间中求最优分类面。

本文中的分类问题可表示为:

$$D = \{(X_i, a_i) | i=1, 2, \dots, 5456\}$$

$$a_i \in \{MF, SRT1, SRT2, SLT\}$$

SVM 需要在特征空间中通过间隔最大化或求解凸二次规划问题, 寻找一个能将 D 分类的最优超平面:

$$\omega^T x + b = 0 \quad (6)$$

其决策函数为:

$$f(x) = \text{sign}(\omega^T x + b) \quad (7)$$

即需要求解:

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 \quad (8)$$

$$\text{s. t. } a_i(\omega^T x X_i + b) \geq 1, i=1, 2, \dots, 5456$$

因此, 只需求出 ω 和 b 即可确定分类超平面。用拉格朗日乘子法求对偶问题的解, 进而得到 ω 和 b 。本文使用高斯核函数进行空间映射。

3.3 从 SVM 中提取规则

本文通过如下两个步骤生成规则^[10]:

第 1 步 首先, 根据 SVM 筛选出真正起决策作用的 SVs, 然后使用 SVM 模型对 SVs 的类别标签重新进行标记, 生成一个人工数据集;

第 2 步 使用人工数据集训练 RF 模型, 并在 RF 模型的所有基决策树中提取规则。

4 实验

4.1 数据集的处理

数据集中存在一个使类别失衡的阈值^[15], 即大类样本数量大于小类样本数量的 4 倍时, 数据集中类的比例失衡。在 WFRN 数据集中, 大类样本数量是小类样本数量的 6.723

倍。为了解决该数据集样本的类别不平衡问题, 本文采用 FID 方法使小类样本的数量接近大类样本数量的 25%, 即增加 223 个小类样本。然后, 使用留出法将新的数据集划分成互斥的两个子集, 将 2/3 的数据用于训练, 1/3 的数据用于测试。

4.2 实验结果

为了验证本文方法的有效性, 本文与决策树等 6 个经典模型相比较。表 3 列出了移动机器人导航的 3 个数据集在不同方法之间的性能比较。比较的指标是 F1 值和小类样本的召回率(Recall)。

表 3 同一数据集不同方法的比较

Table 3 Comparison of different methods for same data set

Method	Metric	S2	S4	S24	Average
Our approach	F1	0.997	0.998	0.987	0.994
	Recall	0.990	1.000	0.995	0.995
C4.5	F1	1.000	1.000	0.986	0.995
	Recall	1.000	1.000	0.955	0.985
KNN	F1	0.978	0.958	0.842	0.926
	Recall	0.982	0.927	0.845	0.918
NB	F1	0.911	0.883	0.547	0.780
	Recall	0.864	0.864	0.927	0.885
NN	F1	0.966	0.971	0.910	0.949
	Recall	0.936	0.927	0.864	0.909
RF	F1	0.999	1.000	0.980	0.993
	Recall	0.991	1.000	0.909	0.967
SVM	F1	0.912	0.904	0.887	0.901
	Recall	0.800	0.800	0.864	0.821
Average	F1	0.966	0.959	0.877	0.934
	Recall	0.938	0.931	0.908	0.926

从表 3 中可知, 本文方法、C4.5 和 RF 的 F1 值和小类样本召回率几乎在所有情况下都是最好的。但是, 在 S24 数据集上, 本文方法在 F1 值和小类样本召回率上均优于其他方法。

在 S2 的数据集中, 本文方法的 F1 值为 0.997, 比平均值提升 3.1%; 小类样本召回率为 0.990, 比平均值提升 5.2%。在 S4 的数据集中, 本文方法的 F1 值为 0.998, 比平均值提升 3.9%; 小类样本召回率为 1.000, 比平均值提升 6.9%。在 S24 的数据集中, 本文方法的 F1 值为 0.987, 比平均值提升 11%; 小类样本召回率为 0.995, 比平均值提升 8.7%。由此可知, 随着数据集维数的增大, 本文方法在 S24 数据集中的 F1 值和小类样本召回率的提升效果更明显。

本文所提方法在 3 个数据集上的平均 F1 值为 0.994, 平均小类样本召回率为 0.995。相较于 C4.5, KNN, NB, NN, RF 和 SVM 方法, 本文方法的平均 F1 值基本上最高, 平均小类样本召回率最高。

图 2 展示了两种不同提取规则的方法提取的规则数量, 第一种方法是本文方法, 第二种方法首先将原始 WFRN 数据集划分为训练集和测试集, 在训练集上训练 RF, 并从中提取控制规则。在测试过程中, 将测试集中的每个样本使用控制规则对其进行分类。

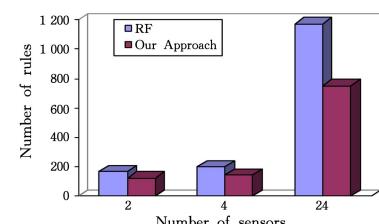


图 2 规则数量的比较

Fig. 2 Comparison of the number of rules

从图 2 中可以看出,本文方法在每个数据集中提取规则的数量比直接使用 RF 在每个数据集中提取规则的数量少。并且随着数据集维数的增大,本文方法提取规则的数量减少得更多。

在 S2 的数据集中,本文方法规则数量减少了 41 条;在 S4 的数据集中,减少了 55 条;在 S24 的数据集中,减少了 418 条。本文方法在 3 个数据集中共提取了 1022 条规则,直接从 RF 中提取规则的方法在 3 个数据集中共提取了 1536 条规则。因此,从 SVM 中提取规则的方法比直接从 RF 中提取规则的方法平均减少了 171.33 条规则。

图 3 给出了本文方法和直接从 RF 中提取规则的方法在不同数据集、相同测试集上 100 次测试时间的平均值。

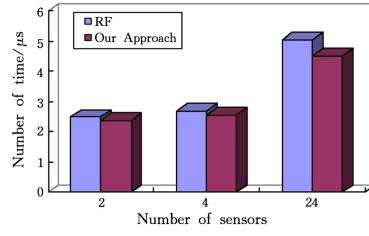


图 3 测试时间的比较

Fig. 3 Comparison of test times

从图 3 可以清楚地看出,本文方法相比于直接从 RF 中提取规则方法,在每个数据集中,100 次测试时间的平均值较短。在 S24 的数据集中,测试时间最多缩短 $0.549 \mu\text{s}$ 。本文方法在测试样本上的平均单个样本决策时间仅为 $3.145 \mu\text{s}$,比直接从 RF 中提取规则方法的单个样本决策时间减少了 $0.27 \mu\text{s}$ 。

综上所述,本文方法的 F1 值和小类样本召回率均较高,规则数量和测试时间均减少,尤其在 S24 的数据集中效果更明显。S2 的数据集很小(只有两个输入传感器读数),S24 的数据文件的维数很大,即 5456×25 ,其中包含了数据集中的目标属性。在现实中,机器人不可能只依靠两个传感器来决定它的下一个方向,而是根据其身体到障碍物的所有距离,以便做出更好的决策。因此,本文方法能更精确、更好地控制移动机器人沿墙导航任务。

5 相关工作

Dash 等在提高机器人自主沿墙导航的精度方面提出了 3 种不同的神经网络方法:在文献[16]中,其提出用梯度下降算法训练神经网络来控制机器人的自主沿墙导航;在文献[7]中,其提出利用重力搜索设置前馈神经网络的最佳权重集,并将其应用于移动机器人的自主沿墙导航;在文献[8]中,其提出了一种利用混合元启发式算法,如:遗传算法和粒子群算法,训练多层人工神经网络来控制移动机器人沿墙导航。神经网络可以通过调整元素之间的连接值来训练神经网络执行特定的功能^[17]。但是,神经网络缺乏可解释性,并且信赖模型参数设置^[18]。Eftekhar 等^[19]计算了使用归一化方法前及 5 种归一化方法中每种归一化方法使用后 SVM 分类的精确度,最后采用数据包络分析对归一化方法进行排序。这些归一化方法具有较低的处理量,而且提高了 SVM 算法的精确度。但是,SVM 由复杂的数学公式所描述,很难被人们理

解^[20]。Barakat 等^[11]指出 SVM 和神经网络均为“黑盒”模型,在解释模型和结果方面存在固有的缺陷,学习模式对人类来说没有透明性和可理解性。Beben 等^[21]提出了一种基于 Erlang 的移动机器人控制系统结构。该方法创建了一个虚拟环境,可以托管一个新颖的、基于 Erlang 的分布式学习库,学习库使用决策树作为监督学习算法,可以集成团队收集的经验,并将学习过程并行化。大多数决策树在设计中不需要调整大量的参数^[22],并且决策树有直观的拓扑结构,其产生的模型容易理解^[23]。但是,决策树是一种单学习器,学习性能比集成学习性能低。

Madí 等^[9]比较了 6 种机器学习分类器(C4.5, NN, SVM, JRipper, NB 和 KNN)对 WFRN 数据集进行分类的效果。其中,KNN 算法训练时间、测试时间和学习速度都最快。但是,上述所有方法都未考虑 WFRN 数据集的类别不平衡问题。

结束语 本文首先用 FID 对原始类别不平衡数据集进行过采样,之后训练 SVM,然后从 SVM 中提取控制规则。实验结果表明,与 C4.5 等 6 个经典模型相比,本文方法的平均 F1 值为 0.994,平均小类样本召回率为 0.995。与直接从 RF 中提取规则方法相比,从 SVM 中提取规则的方法能平均减少 171.33 条规则,单个样本决策时间减少 $0.27 \mu\text{s}$ 。在下一步的工作中,将使用模糊规则或置信规则代替现有控制规则,增强处理不确定性的能力,以进一步提高控制系统的鲁棒性;此外,还将在真实的移动机器人平台上使用本文方法,验证和提高本文方法的实用性。

参 考 文 献

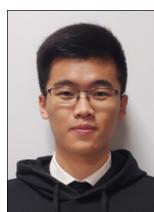
- [1] YERSHOVA A, TOVAR B, GHRISTR, et al. Mapping and Pursuit-Evasion Strategies For a Simple Wall-Following Robot [J]. IEEE Transactions on Robotics, 2011, 27(1): 113-128.
- [2] FREIRE A L, BARRETO G A, VELOSO M, et al. Short-term memory mechanisms in neural network learning of robot navigation tasks: A case study [C] // Robotics Symposium (LARS). Latin American: IEEE, 2009: 1-6.
- [3] AMBROSIO R D, IANNELLO G, SODA P. A One-per-Class reconstruction rule for class imbalance learning [C] // International Conference on Pattern Recognition. IEEE, 2012: 1310-1313.
- [4] ALI A, SHAMSUDDIN S M, RALESCUA L. Classification with class imbalance problem: a review [J]. Int. J. Advance Soft Compu. Appl., 2015, 7(3): 176-204.
- [5] MAHMOOD A M. Class Imbalance Learning in Data Mining-A Survey [J]. International Journal of Communication Technology for Social Networking Services, 2015, 3(2): 17-38.
- [6] LIU S, ZHANG J, XIANGY, et al. Fuzzy-based information decomposition for incomplete and imbalanced data learning [J]. IEEE Transactionson Fuzzy Systems, 2017, 25(6): 1476-1490.
- [7] DASH T, NAYAK T, SWAIN R R. Controlling Wall-following Robot Navigation Based on Gravitational Search and Feed Forward Neural Network [C] // Proceedings of the 2nd International Conference on Perception and Machine Intelligence. New York: ACM, 2015: 196-200.
- [8] DASH T, SWAIN R R, NAYAK T. Automatic Navigation of

- Wall-following Mobile Robot Using a Hybrid Metaheuristic assisted Neural Network[J]. Data Science, 2017;1-17.
- [9] MADI S, BABA-ALI R. Classification Techniques for Wall-Following Robot Navigation: A Comparative Study[C]// International Conference on Advanced Intelligent Systems and Informatics. Springer, Cham, 2018:98-107.
- [10] HAN L, LUO S, YU J, et al. Rule Extraction From Support Vector Machines Using Ensemble Learning Approach: An Application for Diagnosis of Diabetes[J]. IEEE Journal of Biomedical and Health Informatics, 2014, 19(2):728-734.
- [11] BARAKAT N H, BRADLEY A P. Rule Extraction from Support Vector Machines: A Sequential Covering Approach[J]. IEEE Transactions on Knowledge and Data Engineering, 2007, 19(6):729-741.
- [12] SINGH N H, THONGAM K. Fuzzy Logic-genetic Algorithm-neural Network for Mobile Robot Navigation: A Survey[J]. International Research Journal of Engineering and Technology (IRJET), 2017, 4(8):24-45.
- [13] CHOPRA S, MITRA R, KUMAR V. Fuzzy controller: choosing an appropriate and smallest rule set[J]. International Journal of Computational Cognition, 2005, 3(4):73-78.
- [14] BARAKAT N, BRADLEY A P. Rule extraction from support vector machines: a review[J]. Neurocomputing, 2010, 74(1/2/3):178-190.
- [15] SILVA E J R, ZANCHETTIN C. On the existence of a threshold in class imbalance problems[C]// 2015 IEEE International Conference on Systems, Man and Cybernetics. IEEE, 2015: 2714-2719.
- [16] DASH T, SAHU S R, NAYAK T, et al. Neural Network Approach to Control Wall-following Robot Navigation[C]// IEEE International Conference on Advanced Communications, Control and Computing Technologies. Piscataway: IEEE, 2014: 1072-1076.
- [17] SINGH M K, PARHI D R. Intelligent Neuro Controller for Navigation of Mobile Robot[C]// Proceedings of the International Conference on Advances in Computing, Communication and Control. New York: ACM, 2009: 123-128.
- [18] CRAVEN M, SHAVLIK J W. Extracting Tree Structured Representations of Trained Networks[C]// Advances in Neural Information Processing Systems. Colorado: MIT Press, 1996: 24-30.
- [19] EFTEKHARY M, GHOLAMI P, SAFARI S, et al. Rankin Gnormalization Methods for Improving the Accuracy of SVM Algorithm by DEA Method[J]. Modern Applied Science, 2012, 6(10):26-36.
- [20] MARTENS D, BAESENS B, GESTEL T V, et al. Comprehensible Credit Scoring Models Using Rule Extraction from Support Vector Machines[J]. European Journal of Operational Research, 2007, 183(3):1466-1476.
- [21] BEBEN L, SNIEZYNSKI B, TUREK W, et al. Architecture of an Erlang-Based Learning System for Mobile Robot Control [C]// Proceedings of the 5th International Workshop on Evolutionary and Reinforcement Learning for Autonomous Robot Systems. 2012: 45-48.
- [22] GEHRKE J, GANTI V, RAMAKRISHNAN R, et al. BOAT—optimistic Decision Tree Construction[J]. ACM SIGMOD Record, 1999, 28(2):169-180.
- [23] MANWANI N, SASTRY P S. Geometric Decision Tree [J]. IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics), 2011, 42(1):181-192.



FANG Meng-lin, born in 1994, postgraduate. Her current research interests include robot intelligent control and machine learning.

versity of Information Science & Technology (Natural Science Edition), 2019, 11(2):127-137.



SONG Yan, born in 1995, postgraduate. His main research interests include machine learning and so on.



HU Rong-hua, born in 1970, Ph.D, professor, Ph.D supervisor. Her main research interests include robot vision and electro mechanical control.

(上接第 78 页)

- [7] LEONE F, GENTILE C, CIANCIO A L, et al. Simultaneous sEMG Classification of Hand/Wrist Gestures and Forces[J]. Frontiers in Neurorobotics, 2019, 13.
- [8] REN J, LI C, HUANG H, et al. Grasping Force Control of Prosthetic Hand Based on PCA and SVM[C]// International Conference on Life System Modeling and Simulation International Conference on Intelligent Computing for Sustainable Energy and Environment. 2017.
- [9] SRINIVASAN H, GUPTA S, SHENG W, et al. Estimation of hand force from surface Electromyography signals using Artificial Neural Network[C]// Proceedings of the 10th World Congress on Intelligent Control and Automation. IEEE, 2012.
- [10] SONG A G, HU X H, ZHU J H. Research progress on intelligent myoelectric control prosthesis[J]. Journal of Nanjing Uni-