

基于粗糙集和分层支持向量机的 AGV 多分支路径识别

喻俊^{1,2} 楼佩煌^{1,2} 武星^{1,2} 杨旭^{1,2}

(1. 南京航空航天大学机电学院, 南京, 210016;

2. 南京航空航天大学江苏省精密与微细制造技术重点实验室, 南京, 210016)

摘要:双向型视觉导引自动导引车多分支路径识别的关键问题是实时性和鲁棒性。基于智能信息融合的思想, 将粗糙集理论与多类支持向量机方法结合起来, 提出一种基于知识获取实时性和类的相似性的分层多分支路径识别新方法。采用粗糙集知识粒度理论和分层递归约简算法获得最小的决策规则, 有效降低分类识别的复杂性; 提出分类决策安全区域的学习方法, 提高识别的鲁棒性。最后, 仿真实验和多种环境下的运行测试验证了该方法的有效性和可靠性。

关键词:柔性制造系统; 自动导引车; 粗糙集; 支持向量机

中图分类号: TP242.2

文献标志码: A

文章编号: 1005-2615(2013)01-0062-08

Automated Guided Vehicle Cross Path Recognition Based on Rough Set and Hierarchical Support Vector Machine

Yu Jun^{1,2}, Lou Peihuang^{1,2}, Wu Xing^{1,2}, Yang Xu^{1,2}

(1. College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing, 210016, China; 2. Jiangsu Key Laboratory of Precision and Micro-Manufacturing Technology, Nanjing University of Aeronautics & Astronautics, Nanjing, 210016, China)

Abstract: Real-time ability and robustness are the key problems of bi-directional vision-based automated guided vehicle cross path recognition. According to complementary of rough set theory and multi-class support vector machine(SVM), a new cross path hierarchical recognition method is presented based on real-time ability of knowledge and similarity of class. Granularities of knowledge and hierarchical reduction rules of rough set theory are used to obtain the minimum decision rule, which effectively reduce the complexity of the classification. To improve robustness of recognition, learning method of safe area for classification is presented. Finally, simulation and experiments at various environments verify the validity and reliability of the method.

Key words: flexible manufacturing system; automated guided vehicle; rough set; support vector machine

自动导引车(Automated guided vehicle, AGV)是一种广泛应用于柔性制造系统(Flexible manufacturing system, FMS)的物料传送单元^[1]。导引路径按照区间内 AGV 的可运动方向分为单行路径和双向路径, 任务复杂的 AGV 系统需要由

双向路径和多分支路径节点组建基于网络模型的电子地图^[1-2], 再以最短空闲时间、最短路径和最少 AGV 数量^[2]为优化目标实现 AGV 系统的调度。视觉导引 AGV 具有柔性高、成本低和应用广的特点, 国内外研究人员对视觉导引 AGV 做了一些基

基金项目:国家自然科学基金(61105114)资助项目;江苏省高校优势学科建设工程资助项目。

收稿日期: 2012-01-18; **修订日期:** 2012-04-15

通信作者:楼佩煌, 男, 教授, 博士生导师, E-mail: mecphlou@nuaa.edu.cn。

基础研究^[3-5]。现阶段视觉导引 AGV 没能如电磁导引和激光导引 AGV 一样广泛地装备现代化制造工厂,其主要难点在于视觉系统的实时性、鲁棒性。

随着高性能处理器的发展和计算机视觉算法的改进,Zhang 等人^[3]采用的彩色图像处理方法较 Chen^[4]和 Wang 等人^[5]采用的灰度图像处理方法在应对环境光照变化和路面背景复杂方面鲁棒性更强。摄像机前倾安装方式^[3-5]的视觉导引 AGV,只能单向前进,且该方式由于视野较大,视觉测量的精度较低。在多分支路径转弯问题上,Wang^[5]采用的图像顶部单行抽样和验证的方法鲁棒性不高,且这种单向运动 AGV 的路径铺设只能采用单向环形路径^[1]。Zhang^[3]采用提前转弯并对转弯过程场景逐帧模板匹配的方法需要存储大量的场景模板。此外,文献^[3~5]提出的模型和算法都没充分考虑工厂复杂运行环境下,路径局部特征被污损或遮挡时对路径特征提取及方向识别的影响。

双向型 AGV,即不需要反转 180°就能沿导引路径双向运动,具有更高的柔性和效率,适用于任务复杂的 FMS^[1-2]。本文采用区域投影的方法提取路径特征,再由线性判别分析(Linear discriminant analysis, LDA)降低特征维数^[6]。根据知识获取的时间先后和类的等价关系,提出了基于粗糙集(Rough set, RS)约简的层次支持向量机(Support vector machine, SVM)多分类方法,使线性不可分的不确定性问题在建立的分类决策安全区域内线性可分,提高系统多分支路径识别的实时性和鲁棒性。

1 线性判别分析、支持向量机和粗糙集理论

1.1 线性判别分析

在解决机器学习与模式识别问题的方法中,为了提高算法的效率,对提取的高维特征,在分类之前先降维,即把数据样本从高维空间通过线性或非线性映射投影到一个低维空间,从而找出隐藏在多维观测数据中有意义的低维结构^[6]。

LDA 是一种有监督的全局线性降维方法,通过寻找最佳的投影空间,使样本数据映射到低维空间后,各类内样本尽可能紧凑,类间样本尽可能分开,然后在新空间中对样本进行分类,其目标函数为^[6]

$$\max_{\mathbf{W}} \frac{\text{tr}(\mathbf{W}^T \mathbf{S}_b \mathbf{W})}{\text{tr}(\mathbf{W}^T \mathbf{S}_w \mathbf{W})} \quad (1)$$

式中: \mathbf{S}_b 和 \mathbf{S}_w 分别为类间和类内散度矩阵,投影方向矩阵 \mathbf{W} 可以通过广义特征值问题 $\mathbf{S}_b \mathbf{w} = \lambda \mathbf{S}_w \mathbf{w}$ 求得。设输入样本为 \mathbf{X} ,降维后的空间为 \mathbf{Y} ,共有 C 类样本,则 LDA 降维后的空间最多为 $C-1$ 维,有

$$\mathbf{Y} = \mathbf{XW} \quad (2)$$

1.2 基于 SVM 的多类分类方法

1.2.1 SVM 基本原理

SVM 是由 Vapnik 等提出的一种建立在统计学习理论上基于结构风险最小化方法(Structural risk minimization, SRM)的模式识别方法,其具体方法为^[7]:设样本集 \mathbf{S} 为 $\{(x_i, y_i) \mid x_i \in \mathbf{R}^n; y_i \in \{-1, +1\}, i = 1, \dots, I\}$,超平面在 n 维欧几里德空间线性方程为 $\langle \mathbf{w}, \mathbf{x} \rangle + \mathbf{b} = 0$,其中, \mathbf{w} 为权值向量, \mathbf{x} 为 n 维特征向量, $\langle \mathbf{w}, \mathbf{x} \rangle$ 为内积, \mathbf{b} 为偏置向量。欲使得空间中点 x_i 到超平面 L 的距离最大,等价于 $\|\mathbf{w}\|^2$ 最小。于是得到一个在约束条件下的极值问题

$$\begin{cases} \min \frac{1}{2} \|\mathbf{w}\|^2 \\ y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + \mathbf{b}) \geq 1 \quad i = 1, 2, \dots, I \end{cases} \quad (3)$$

引入 Lagrange 乘子 $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_I), \alpha_i \geq 0$,构造约束条件下的 Lagrange 对偶函数,使其值最大的凸二次规划问题的解 α 记为 $\alpha^* = (\alpha_1^*, \dots, \alpha_I^*)^T$ 。最优权值向量 \mathbf{w}^* 和最优偏置 \mathbf{b}^* 分别为

$$\begin{cases} \mathbf{w}^* = \sum_{j=1}^I \alpha_j^* y_j \mathbf{x}_j \\ \mathbf{b}^* = y_i - \sum_{j=1}^I y_j \alpha_j^* (\mathbf{x}_j \cdot \mathbf{x}_i) \end{cases} \quad (4)$$

最优分类函数为

$$f(x) = \text{sgn}\left(\sum_{i \in SV} y_i \alpha_i^* \langle x_i, \mathbf{x} \rangle + \mathbf{b}^*\right) \quad (5)$$

使训练样本可线性分的充要条件为: $\forall \{(x_i, y_i)\}$,

$$y_i (\langle \mathbf{w}^*, \mathbf{x}_i \rangle + \mathbf{b}^* - y_i) \geq 0 \quad i = 1, 2, \dots, I \quad (6)$$

1.2.2 多类 SVM 分类方法

SVM 主要是解决二分类问题,对于 k 类的多分类问题,通过构造多个二分类 SVM 分类器并把它们组合在一起,是解决基于 SVM 的多分类问题的实用方法^[8]。一对一(One versus one, OVO)方法是每两类之间构造一个分类器,用训练样本对每个分类器进行训练,共得到 $k(k-1)/2$ 个分类器,最终获得最多投票的类作为输出结果。其缺点是分类器的数目随类别数的增加而显著增加。一对一剩余(One versus rest, OVR)方法是将每一类与剩

余的其他类看作两类问题,共构造 k 个分类器,最终的测试输出是分类器输出值最大的那一类。其缺点是会产生拒绝分类和重复分类的情况。二叉树(Binary tree, BT)方法是一种层次分类方法^[9],通过 $k-1$ 个二叉树构建分类器,层次分类方法存在上层的分类误差对下层的分类误差形成“误差累积”^[8-10]。

为了降低层次分类方法中,上层分类误差对下层分类误差形成的“误差累积”,一般采用类间相似性,如欧氏距离和类间散度作为分层依据^[10],先将分类间隔最大的分类器放置在顶层,以提高系统的识别率。类 i 与类 j 间的相似性可以通过类间散度 $s_m(i, j)$ 测算

$$s_m(i, j) = \frac{\|\mu_i - \mu_j\|^2}{\|s_i^2\| + \|s_j^2\|} \quad (i < j) \quad (7)$$

式中: $\|\cdot\|$ 为欧氏二范数; s_i^2 和 s_j^2 分别为类 i 和类 j 所有样本数据的方差; μ_i 为每类样本的重心为

$$\mu_i = \frac{1}{n} \sum_{k: y \in \text{class } i} x_k \quad (8)$$

特征相似的两类样本的 $s_m(i, j)$ 小于 1。

1.3 粗糙集理论

粗糙集理论是一种能分析处理不精确、不确定和不可分辨信息与知识的数学工具^[11]。粗糙集理论在机器学习和模式识别领域的应用研究主要集中在属性约简、规则获取和基于粗糙集的智能计算等方面。

一个知识表达系统 $S = \langle U, A, V, f \rangle$, 其中 U 为论域; A 为属性的有限集, $A = C \cup D$, C, D 为两个属性子集, 分别称为条件属性集和决策属性集; $V = \bigcup_{p \in A} V_p$, 为属性值集合, 其中 V_p 为属性 p 的值, $f: U \times A \rightarrow V_p$ 为信息函数, 使得对每个 $x_i \in U, p \in A$, 有 $f(x_i, p) \in V_p$ 。在粗糙集中, 对于属性子集 $R \subseteq A$, 不可分辨关系 $\text{IND}(R)$ 是一个等价关系, 其确定了论域 U 上的一个划分, 不同划分对应 U 上不同子集。

粗糙集理论的知识约简是保持相对分类能力不变的条件下, 约简不必要的属性或属性值, 达到知识简化的目的。决策表的属性约简是指在保持原始决策表条件属性和决策属性之间的依赖关系不发生变化的前提下, 删除冗余的属性。

分层递阶约简算法中, 信息系统的信息熵和决策系统的互信息保持不变, 即分层递阶约简算法不会引起信息系统和决策系统的信息损失。当决策系统中的知识粒度减小时, 知识层次加深, 系统的

互信息单调增加。分层递阶约简方法避免了应用获取方式复杂, 实时性不高的属性。分层递阶规则约简步骤请参见文献[12]。

2 视觉导引 AGV 及多分支路径模型

2.1 双向型视觉导引 AGV 模型

双向型视觉导引 AGV 结构模型如图 1 所示。AGV 的驱动系统由两个独立的驱动轮和前后两个起支撑作用的万向轮组成。这种机构可以通过调节两个驱动轮的速度和转向, 实现前进、后退和任意转弯半径的圆弧运动。摄像机位于 AGV 运动控制中心点 C (两驱动轮轴线的中点) 上方, 且垂直于地面安装, 这种系统结构设计使得 AGV 的视觉和运动都具有了双向特性。摄像机采集的是即时和未来小范围内的路径信息, 相对摄像机前倾的安装方式^[3-5], 视野范围小, 相同图像分辨率下的视觉测量精度高, 但对视频处理算法的实时性要求更高。




图1 双向型视觉导引 AGV 结构模型

设图像分辨率为 $M \times N$, 图像采集频率为 f_c 帧/s, 图像相对地面真实场景的放大倍数为 A_{pix} 像素/mm, 在 AGV 最高速度下地面任意场景点至少出现在 n_{min} 帧连续图像序列中, 则 AGV 理论工作最高速度 v_{max} 为

$$v_{\text{max}} = \frac{Mf_c}{A_{\text{pix}}n_{\text{min}}} \quad (9)$$

A_{pix} 决定了视觉测量的精度, n_{min} 过小会降低 AGV 的鲁棒性, M, N 和 f_c 过大会提高视频处理算法的实时性要求。由式(9)可知实时性、鲁棒性和精度与 AGV 的工作最高速度是相互制约的, 实际设计和应用时, 应满足精度和工作最高速度的条件下提高系统的鲁棒性和算法的实时性。

2.2 多分支路径模型

为充分体现双向型 AGV 的效率和柔性, AGVS 路径拓扑结构模型由双向路径和“L 型”、

“T型”、“十字型”3种路径分支节点组建。AGV由双向路径进入分支路径节点方位的不同,3种分支节点共对应了6类分支路径方向模式,如表1所示。AGV运动到多分支路径处时,运动控制器根据视觉系统识别的分支路径方向类别和系统调度任务,做出AGV运动方向选择决策。

表1 路径分支节点模型分配表

节点模型	L型	T型	十字型
可选择的方向	左 右	左\右 左\前 右\前	左\右\前

AGV沿双向路径运行时,视觉系统测量路径距离偏差和角度偏差即可实现路径跟踪。AGV从双向路径进入局部被污损或遮挡的T型分支路径的连续时间序列视觉采样过程如图2所示。




图2 T型分支路径连续时间序列视觉采样

当分支路径刚进入视野时,视觉系统检测到分支路径,此时前向分支路径并没有进入视野,路径方向特征不完整,暂时不能确定分支路径方向。但视觉系统要在控制中心点运动到分支节点之前确定分支路径方向的类别,使运动控制器能够有足够的时间根据任务需要选择前向分支路径前进或在分支节点停下后原地自转进入转弯分支路径。在此期间,视觉系统还需要测得当前主路径的角度偏差、距离偏差和分支节点的位置,为运动控制器提供路径跟踪参数。

2.3 区域投影和边缘轮廓特征同时提取方法

如上所述,分支路径转弯需要解决的关键问题是连续时间序列图像中的形状识别和基于矢量图的几何测量,解决问题难点在于算法的抗干扰性和实时性。形状识别一般先对目标进行特征提取,再对提取的特征采用模式识别方法进行分类。用于形状识别的特征提取方法有基于区域和基于轮廓两类,针对不同提取目标,可采用全局特征或局部特征^[13]。Thacker等人^[14]从实用性角度指出,傅里叶描述子、链码和曲率估计等基于轮廓的形状描述法对前期图像分割处理结果要求过高,因此并不

实用。Yang等人^[15]对形状特征提取的40余种方法进行了总结,基于区域的面积函数法对局部遮挡、局部变形和噪声具有较强的抗干扰性,并且简单高效,适用于形状简单、规则的场合,而基于矢量图的几何测量一般采用基于轮廓特征的方法。

在分支路径识别应用中,目标较大,并且旋转90°后会改变分支方向的类别。AGV运动过程中采集的路径图像有显著变化,Zhang等人^[3]采用的模板匹配方法存在较大的误判风险。工厂的实际导引路径由于存在随机的局部破损、污染、遮挡和反光等干扰因素,造成基于区域的特征提取存在空洞、残缺和不连通,如图2所示。对这些随机的非理想状况采用图像处理形态学算法很难修复,或者计算代价很高^[15]。综上所述,从原始图像中提取的特征既要有较强的表示能力用于分支路径模式识别,又要有较高的精确性用于几何测量,故采用区域面积行、列向投影和四边界轮廓扫描同时提取法。

本文采用TMS320DM642 DSP采集经解码器TVP5150对PAL制式模拟视频信号解码后的8位BT.601 YCbCr格式彩色图像,Cb、Cr分别为不包含亮度分量的蓝色和红色色度,受光照不均匀的影响较小,利用Cb、Cr分量能够方便地提取蓝色和红色目标。设图像分辨率为 $M \times N$,经滤波和阈值分割后的二值图像为 $f(i,j)$,路径为1,背景为0。对 N 行 M 列二值图像的第 j 行从左向右扫描,第一个和最后一个1分别记为 hl_j 和 hr_j ,1的个数记为 hp_j ,有 $hp_j = \sum_{i=1}^M f(i,j)$ 。对第 i 列从上向下扫描,第一个1和最后一个1分别记为 vt_i 和 vb_i ,1的个数记为 vp_i ,有 $vp_i = \sum_{j=1}^N f(i,j)$ 。则用于矢量图几何测量的四边界轮廓扫描特征点集合分别为

$$\mathbf{H}_l = \{(x,y) \mid x = hl_j, y = j, j = 1, 2, \dots, N\} \quad (10)$$

$$\mathbf{H}_r = \{(x,y) \mid x = hr_j, y = j, j = 1, 2, \dots, N\} \quad (11)$$

$$\mathbf{V}_t = \{(x,y) \mid x = i, y = vt_i, i = 1, 2, \dots, M\} \quad (12)$$

$$\mathbf{V}_b = \{(x,y) \mid x = i, y = vb_i, i = 1, 2, \dots, M\} \quad (13)$$

AGV进入多分支路径状态后,不仅要继续为运动控制器提供当前主路径的角度偏差和距离偏差参数,而且要跟踪分支节点的位置,为AGV转弯提供参考点位置参数。上述问题归结为通过四边界轮廓扫描特征点集合 \mathbf{V}_t 和 \mathbf{V}_b 以及 \mathbf{H}_l 和 \mathbf{H}_r 分别计算出主路径和分支路径的直线方程参数,进

而计算出转弯节点在图像中的坐标。对模型参数进行估计,最小二乘法只适用于测量数据仅有小测量误差情况,而鲁棒方法和基于概率框架下的统计方法适用于测量数据中包含错误数据点的情况。文献[16]对这种情况下的5种直线拟合算法中在计算速度和精度上做了详细比较,本文不再详述。

路径区域特征在行向和列向的投影向量分别记为 \mathbf{H}_p 和 \mathbf{V}_p ,则有

$$\mathbf{H}_p = [hp_1 \ \cdots \ hp_N] \quad (14)$$

$$\mathbf{V}_p = [vp_1 \ \cdots \ vp_M] \quad (15)$$

\mathbf{H}_p 和 \mathbf{V}_p 为路径区域面积的两个线性空间,用于多分支路径模式识别。由于 AGV 具有双向运动特性,DSP 通过与运动控制器的通讯可以获得其当前运动方向。定义其中某一个方向为正向运动,当反向运动时,由图 1 所示 AGV 的结构模型可知,将向量 \mathbf{H}_p 和 \mathbf{V}_p 的所有分量逆序排列,对 7 类路径模式均可获得与正向运动相同的路径特征描述,下文提到的 \mathbf{H}_p 和 \mathbf{V}_p 均为根据 AGV 当前运动方向处理后的特征向量。

3 多分支路径分层识别模型

3.1 类的 SVM 的线性可分性和相似性分析

多分支路径目标检测与方向识别属于摄像机运动下的静止目标运动检测和识别问题。解决上述问题主要有自底向上和自顶向下两种方法^[17]。自底向上的方法源于 Marr 提出的图像理解的 3 个阶段^[16],其优点在于能快速检测并跟踪运动目标,便于工程实现。图像中的路径尺寸较大且有明显的颜色和形状特征,且实时性要求较高,更适合采用自底向上的方法。

自底向上的方法通过图像特征提取、目标检测、目标分类和目标跟踪 4 个步骤完成^[17]。视觉系统需要由路径区域特征在行向和列向的投影向量 \mathbf{H}_p 和 \mathbf{V}_p ,完成由双向路径到分支路径的目标检测和 6 种分支路径方向识别。定义路径方向模式标签号如表 2 所示,共 7 类模式。

多分支路径识别作为 AGV 导引信息,其结果

表 2 路径方向模式类别定义

路径方向模式标签(C)	可选择方向类别
1	前、后
2	左
3	左、前
4	左、右
5	左、右、前
6	右
7	右、前

不能存在歧义,即在样本训练中必须达到 100% 的正确识别率。当在输入空间不能实现线性分离,非线性映射核函数将样本集映射到高维特征空间,但是越简单的模型其泛化能力越强,过于复杂的非线性模型容易导致分类面过拟合。DSP 擅长于卷积运算,若能采用线性分类器实现分类将大大提高分类算法的效率。由于 AGV 图像处理平台是 DSP 为处理器的嵌入式系统,受存储容量的限制,采用离线训练获得 SVM 分类器,再将分类器移植到 DSP 在线测试。离线学习共采集 7 类训练样本各 280 幅,1 960 幅图像。

将 7 类 I 个训练样本的特征向量 \mathbf{H}_p 和 \mathbf{V}_p 首尾相连组成 $M+N$ 维的特征向量 $\mathbf{P}_i^C (i=1,2,\dots,I$ 为样本号, C 为类别号),采用 LDA 得到投影矩阵 \mathbf{W}_p 以及训练样本的投影 \mathbf{X}_{pi}^C 。 \mathbf{X}_{pi}^C 为 6 维的向量,以每两类的 \mathbf{X}_{pi}^C 特征向量作为训练样本代入式(6)可以验证,在 \mathbf{X}_{pi}^C 空间,类 C2 与 C3, C4 与 C5, C6 与 C7 均是线性不可分的,类 C1 与 C2\C3\C4\C5\C6\C7 是线性可分的。

由式(8)计算 7 类样本中每两类之间的相似性度 $s_m(i,j)$,如表 3 所示,类 C2 与 C3, C4 与 C5, C6 与 C7 具有相似性(其中:下划线标注表示类间散度小于 1)。由路径方向模式类别的定义和图 2 所示的连续时间序列图像采样过程的分析可知,分支路径刚进入视野时,分支路径特征暂时不完整,有、无前向分支路径目标是一个不确定性问题。对特征不完整的分类若采用核函数方法映射到高维空间进行分类,反而会降低分类器的泛化能力。

表 3 类间相似度表

$i \setminus j$	2	3	4	5	6	7
1	13.7	15.4	12.0	14.1	12.2	14.8
2		<u>0.3</u>	5.0	5.7	7.1	7.6
3			4.9	4.9	6.1	6.4
4				<u>0.6</u>	15.6	20.1
5					17.9	22.8
6						<u>0.8</u>

为了提高 AGV 系统的实时性,建立两层的分类模型。第一层为初判预警层,即初步判断出是否为多分支路径并发送给运动控制器,使其根据任务及时做出控制输出;第二层为最终分类决策层,随着 AGV 继续运行,有、无前向分支路径特征完整后,再做出最终分类决策。

3.2 基于 SVM 的分层识别方法

采用聚类分类方法的思想,从多个类别中选择

相似的类,将相似类放在粗糙集中看作一个等价类,即类 C2 与 C3,C4 与 C5,C6 与 C7 分别合并成等价类 C23、C45、C67。在分类识别模型的第一层,将类 C1 与 3 个合并类 C23、C45、C67 组成一个 4 类问题,对 $H_{P_i}^C$ 和 $V_{P_i}^C$ ($i=1,2,\dots,I$ 为样本号,C 为类别号)分别采用 LDA 降维,得到训练样本的三维投影 $^1X_{Hi}^C$ 和 $^1X_{Vi}^C$,其前两维如图 3(a,b) 所示。 $^1X_{Hi}^C$ 是线性可分的,采用一对一的 SVM 多分类方法,类 i 与类 j 的分类决策函数为^[9]

$$f(x_{ij}) = \text{sgn}(w_{ij}^* x + b_{ij}^*) \quad 1 \leq i < j \leq 4 \quad (16)$$

w_{ij}^* 和 b_{ij}^* 由式(4)得到,由式(16)获得最多投票的类即为识别目标类。

在模型的第二层,将“无”前向路径的类 C2、C4、C6 合并成类 C246,“有”前向路径的类 C3、C5、C7 合并成类 C357,组成一个 2 类问题。对 $H_{P_i}^C$ 和 $V_{P_i}^C$ 分别采用 LDA 降维,得到训练样本的投影 $^2X_{Hi}^C$ 和 $^2X_{Vi}^C$,其是一维点,均是不可分的,但 $^2X_{Vi}^C$ 的分布较 $^2X_{Hi}^C$ 分散,如图 3(c,d) 所示。

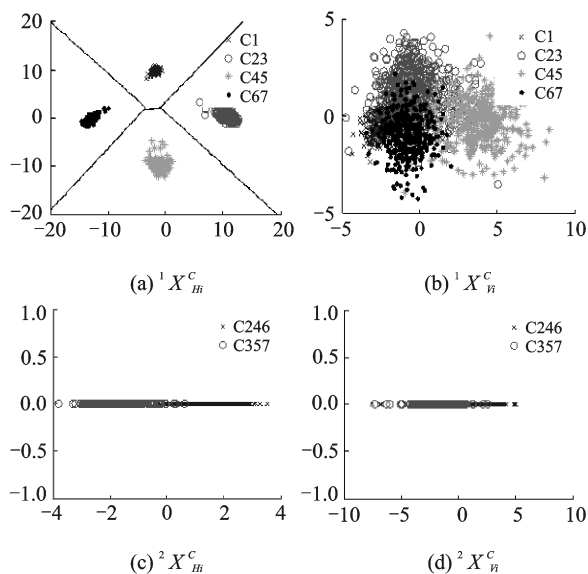


图 3 知识属性分析

3.3 分类决策安全区域

第二层作为最终分类决策层要在主路径方向特征完整后才能做出,需要建立分类决策安全区域模型。设路径分支节点在列向首、尾 Sa 区域内时暂不确定方向分类,在列向中心对称的 $M-2Sa$ 区域内为分类决策安全区域。 Sa 越大,方向识别的可靠性越高,但也会相应地降低实时性。由式(7)可知 $^2X_{Vi}^C$ 的散度较 $^2X_{Hi}^C$ 大,下面由 $^2X_{Vi}^C$ 通过机器学习的方法,找出 Sa 与误判概率和分类间隔的关

系,从而选择合理的 Sa ,步骤如下:

(1)计算 D 个训练样本图片中路径分支节点的列坐标 x_j 到列边界的最短距离,记为 $sa_i = \min(x_j - 1, M - x_j), i = 1, 2, \dots, D$, 令 $Sa = \min(sa_i)$;

(2)从训练样本中剔除 $sa_i < Sa$ 的样本对应的 $V_{P_i}^C$,计算余下样本的 LDA 投影 $^2X_{Vi}^C$;

(3)对余下样本投影值 $V_{P_i}^C$ 采用两类支持向量机分类,计算误判率和分类间隔(两类样本中 $^2X_{Vi}^C$ 的最近点之间距离);

(4)如果 $Sa < M/2$, 令 $Sa = Sa + 1$, 返回步骤(2)。

这是一个从列的两端逐渐削减分支节点靠近列向边界的训练样本直至发现可分区域的回归过程。图 4 为误判率和分类间隔随 Sa 的变化的曲线图,验证了分类决策安全区域模型。理论上误判率为 0 时的 Sa 即可划定分类决策安全区域,但考虑到小样本可能带来的误差,应对其取适当的余量。当 $Sa=108$ 时误判率为 0,对其取 50% 的余量,即当 $Sa=162$ 时,分类间隔为 0.832,对应的 LDA 投影矩阵 W_V 和投影 $^2X_{Vi}^C$ 作为第二层分类的训练结果。




图 4 分类决策安全区域学习

3.4 多类识别规则提取

基于粗糙集约简的分层 SVM 的主要思想是通过粒度划分的方法构建粒度空间,获得一系列信息粒,然后在每个信息粒上进行学习,最后通过聚合信息粒上的知识和规则属性获得最终的 SVM 决策函数。根据粗糙集理论,训练样本作为论域, H_p 和 V_p 作为两个条件属性,7 类分支路径模式作为决策属性。建立 7 种路径目标识别的两层分类递阶决策表^[12],如表 4 所示的,达到了减少冗余数据,压缩数据规模的目的,进而提高支持向量机的分类速度。该学习机制通过数据的粒化将一个线性不可分问题转化为一系列线性可分问题,从而获得多个决策函数,使数据的泛化性能增强。

表4 两层递阶决策表

论域\属性	H_p	d
U11	1	{C1}
U12	2	{C2,C3}
U13	3	{C4,C5}
U14	4	{C6,C7}

论域\属性	V_p	$d1$
U21UU22UU23	1	{C2,C4,C6}
U21UU22UU23	2	{C3,C5,C7}

4 实验及分析

实验验证分为油漆地面和水磨石地面仿真验证和实际运行实验验证。视频分辨率为 $720 \text{ 像素} \times 576 \text{ 像素}$,采集频率为 25 帧/s ,图像相对地面真实场景的放大倍数 $A_{\text{pix}} = 2.0656 \text{ 像素/mm}$,AGV设计最高速度为 $v_{\text{max}} = 1 \text{ m/s}$ 。在AGV最高速度下,地面任意场景点在相邻两帧图像中的距离为 82.6 像素 ,而通过分类决策安全区域学习,获得的决策安全区域距离图像列边界的距离 S_a 为 162 像素 ,视觉系统能够在分支路径进入视野的第2帧内做出分类决策。由式(9)可得,在最高速度下,每个场景点至少出现在 8.7 帧 图像中,即AGV中心运动到转弯节点前至少可以采集 4 幅 图像,具有较高的分类决策安全边际。

图5为AGV在水磨石地面环境中以 0.5 m/s 速度运行的“L型”左转实验仿真,图6为油漆地面环境中以 0.1 m/s 速度运行的“T型”左前转弯分支路径实验仿真。在识别模型的第一层,特征 H_p 降维后的特征点记录如图5(c,d)所示,其只在分支路径刚进入摄像机视野的状态过渡过程中,存在靠近分类面的状况,其他时刻的特征点离分类面均有一定的安全距离。图5(d)和图6(d)说明在分类




图5 “L型”分支路径识别仿真

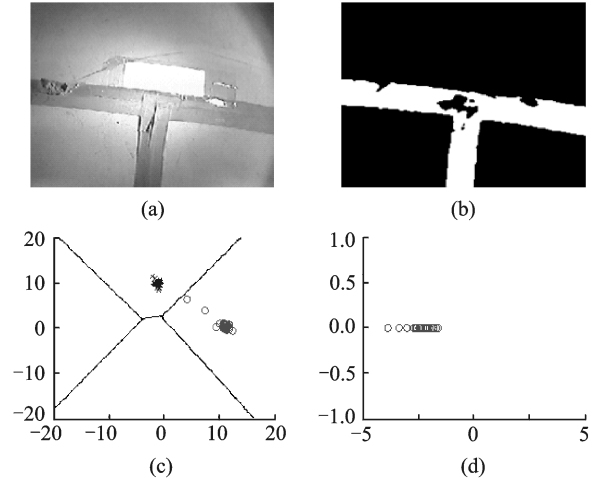


图6 “T型”分支路径识别仿真

决策安全区域的控制下,识别模型第二层没有误判情形,为了提高识别决策的鲁棒性,连续两帧图像识别结果相同时再向控制器发出转弯路径信息。从图6(b)可以看出路径边缘的残缺和内部的孔洞也不会对识别结果造成影响,识别算法的鲁棒性较强。

南京航空航天大学自主开发的NHV-II型双向型视觉导引AGV如图7所示。视频采集和处理采用TMS320DM642 DSP,其内核具有8个32位的独立功能单元,2个乘法器和6个算术逻辑单元,当工作在 600 MB 主频下,每周期能够提供4个16位硬件乘法累加操作,或者8个8位MACs。将训练得到LDA投影矩阵和两层SVM共7分类平面直接用于路径识别计算,则都是线性的乘法累加运算,DSP运算速度较快,加上区域投影和边缘轮廓特征同时提取算法,DSP处理每帧图像的时间小于 0.01 s ,能够满足系统实时性的要求。

在油漆和大理石地面上做多种环境下的不间断时间测试,能够做到连续 8 h 安全运行无误判。



图7 NHV-II型视觉导引AGV

5 结束语

为了解决一种双向型视觉导引 AGV 多分支路径识别的实时性和鲁棒性问题,首先完成图像预处理和路径区域特征的提取,提出了基于粗糙集约简的分层 SVM 识别方法。根据知识获取的确定性和时间的先后,采用粗糙集的分层理论,首先解决确定性问题,提高系统的实时性;通过粗糙集的知识约简和决策规则获取理论,将一个基于多分类 SVM 方法的非线性可分问题转化为两层的线性可分问题,在 SVM 的训练中得到间隔更宽的超平面;对非确定性问题,建立应用模型驱动的分类决策安全区域,并通过回归的机器学习方法计算出分类决策安全区域,提高系统的实时性和鲁棒性。仿真实验和多种环境下的 AGV 实际运行实验验证了算法的有效性和可靠性。

参考文献:

- [1] Herrero-Perez D, Martinez-Barbera H. Modeling distributed transportation systems composed of flexible automated guided vehicles in flexible manufacturing systems[J]. *IEEE Transactions on Industrial Informatics*, 2010, 6(2): 166-180.
- [2] 贺丽娜,楼佩煌,钱晓明,等.基于时间窗的自动导引车无碰撞路径规划[J]. *计算机集成制造系统*, 2010, 16(12):2630-2634.
He Lina, Lou Peihuang, Qian Xiaoming, et al, Conflict-free automated guided vehicles routing based on time window [J]. *Computer Integrated Manufacturing Systems*, 2010, 16(12):2630-2634.
- [3] 张海波,原魁,周庆瑞.基于路径识别的移动机器人视觉导航[J]. *中国图象图形学报*, 2004, 9(7): 853-857.
Zhang Haibo, Yuan Kui, Zhou Qingrui. Visual navigation of a mobile robot based on path recognition [J]. *Journal of Image and Graphics*, 2004, 9(7): 853-857.
- [4] 陈无畏,孙海涛,李碧春,等.基于标识线导航的自动导引车跟踪控制[J]. *机械工程学报*, 2006, 42(8): 164-170.
Chen Wuwei, Sun Haitao, Li Bichun, et al. Tracking control of automatic guided vehicle based on lane marker navigation [J]. *Chinese Journal of Mechanical Engineering*, 2006, 42(8):164-170.
- [5] 王荣本,徐友春,李庆东,等. AGVS 图象识别多分支路径的研究[J]. *中国图象图形学报*, 2000, 8(5): 632-637.
Wang Rongben, Xu Youchun, Li Qingdong, et al. A study on cross road recognizing for vision-based auto-guided vehicle system[J]. *Journal of Image and Graphics*, 2000, 8(5):632-637.
- [6] Ye J, Li Q. A two-stage linear discriminant analysis via QR-decomposition[J]. *Pattern Analysis and Machine Intelligence*, 2005, 27(6): 929-941.
- [7] Burges C J C. A tutorial on support vector machines for pattern recognition[J]. *Data mining and knowledge discovery*, 1998, 2(2): 121-167.
- [8] Hsu C W, Lin C J. A comparison of methods for multiclass support vector machines[J]. *Neural Networks*, 2002, 13(2): 415-425.
- [9] Cheong S, Oh S H, Lee S Y. Support vector machines with binary tree architecture for multi-class classification[J]. *Neural Information Processing-Letters and Reviews*, 2004, 2(3): 47-51.
- [10] Lorena A, de Carvalho A. Minimum spanning trees in hierarchical multiclass support vector machines generation[C]// *Innovations in Applied Artificial Intelligence*. 2005:422-431.
- [11] Thangavel K, Pethalakshmi A. Dimensionality reduction based on rough set theory: A review [J]. *Applied Soft Computing*, 2009, 9(1):1-12.
- [12] 乔斌,李玉榕,蒋静坪.粗糙集理论的分层递阶约简算法及其信息理论基础[J]. *控制理论与应用*, 2004, 21(2):195-199.
Qiao Bing, Li Yurong, Jiang Jingping. Hierarchical reduction approach of rough sets theory and its basis on the information theory [J]. *Control Theory & Applications*, 2004, 21(2):195-199.
- [13] Zhang D, Lu G. Review of shape representation and description techniques [J]. *Pattern Recognition*, 2004, 37(1): 1-19.
- [14] Thacker N A, Clark A F, Barron J L. Performance characterization in computer vision: A guide to best practices[J]. *Computer Vision and Image Understanding*, 2008, 109(3): 305-334.
- [15] Yang M, Kpalma K, Ronsin J. A survey of shape feature extraction techniques[J]. *Pattern Recognition*, 2008(1):43-90.
- [16] Nguyen V, Gchter S, Martinelli A, et al. A comparison of line extraction algorithms using 2D range data for indoor mobile robotics[J]. *Autonomous Robots*, 2007, 23(2): 97-111.
- [17] Yilmaz A, Javed O, Shah M. Object tracking: A survey [J]. *ACM Computing Surveys*, 2006, 38(4): 1-45.