

基于 Boosting 的智能车辆多类障碍物识别

沈志熙, 黄席樾, 杨镇宇, 韦金明
(重庆大学自动化学院, 重庆 400030)

摘要: 提出一种基于 Boosting 集成学习的二叉树支持向量机(BBT-SVM)。根据城区交通环境中各类障碍物的出现概率、模式间的类间差异, 设计适用于智能车辆障碍物识别的 SVM 树型结构。对每个节点 SVM 分类器采用 Boosting 集成学习方法进行改进, 减少差错积累误差, 提高分类精度和泛化能力。实验结果表明, 该方法能有效地对城区交通场景中 6 类常规障碍物模式进行实时在线识别。
关键词: 智能车辆; 障碍物识别; 支持向量机; 集成学习; Boosting 算法

Boosting-based Multi-class Obstacles Recognition of Intelligent Vehicle

SHEN Zhi-xi, HUANG Xi-yue, YANG Zhen-yu, WEI Jin-ming
(College of Automation, Chongqing University, Chongqing 400030)

【Abstract】 A novel Boosting-based Binary Tree-SVM(BBT-SVM) is presented. Based on the distributing probability and pattern diversity of each obstacle in urban traffic scenes, a compatible tree structure of SVM is designed. A Boosting-based ensemble learning approach is applied to reduce the transfer error and it improves the generalization performance of per-node classifier. The improved BBT-SVM can correctly recognize six kinds of normal obstacle patterns in urban traffic scenes. Experimental results show the improved BBT-SVM can efficiently recognize six kinds of normal obstacle patterns in urban traffic scenes.

【Key words】 intelligent vehicle; obstacle recognition; Support Vector Machine(SVM); ensemble learning; Boosting algorithm

障碍物检测与识别是智能车辆研究领域关键问题之一。目前, 城区交通场景中“车辆-非车辆”的车辆检测^[1-2]或“行人-非行人”的行人检测^[3]已有部分成果, 但统一的“车辆-行人-非机动车辆-背景”多类识别系统仍未见报道。因此, 本文提出一种基于 Boosting 集成学习的二叉树支持向量机(Support Vector Machine, SVM)多类分类方法, 该方法应用于城区环境中的智能车辆前向障碍物识别中, 得到了较好效果。

1 支持向量机及其分类原理

在现有的模式分类方法中, 基于统计学习理论的支持向量机在有限样本条件下, 对非线性和高维模式的识别具有更好的分类精度和更强的分类推广能力。对模式识别中的非线性问题, SVM 通过用核函数 $K(x_i, x)$ 代替非线性变换特征空间中的点积, 将输入样本 x 映射到一个高维特征空间, 在这个空间中求广义最优分类面。对于样本集 (x_i, y_i) , $x \in R^d$, $y \in \{+1, -1\}$, SVM 通过解一个不等式约束下的二次函数极值问题, 得到最优分类函数^[4]:

$$f(x) = \text{sgn} \{ \sum \alpha_i^* y_i K(x_i, x) + b^* \} \quad (1)$$

SVM 本质上是一种二值分类器, 将 SVM 从二类分类推广到多类分类的基本思想是把问题划分为多个两分类问题的组合。目前常用的几种包括: 一对多(1ar-SVM)、一对一(1a1-SVM), 决策有向无环图(DDAG-SVM), 二叉树支持向量机(BT-SVM)等。其中, 1ar-SVM 对小样本的分类精度较低; 1a1-SVM 分类速度较慢; DDAG-SVM 分类结果具有很大的不确定性; BT-SVM 则兼有适中的分类精度和最好的分类速度, 是一种很实用的多类分类方法。

2 智能车辆多类障碍物分类器设计

2.1 分类器树型结构设计

本文将前向障碍物定义为 6 种模式: (1)中小型汽车 A; (2)大型客货车 B; (3)摩托车 C; (4)自行车 D; (5)行人 E; (6)属于非障碍物的背景 F。

本文提出的多类分类器树型结构如图 1 所示。

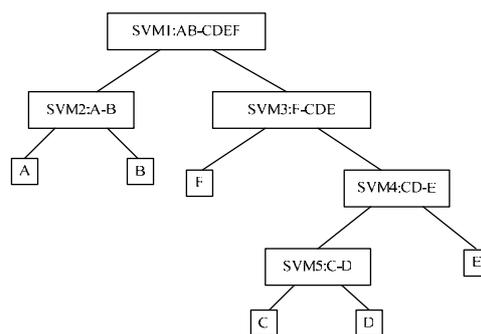


图 1 适合智能车辆障碍物识别的 SVM 树型结构

车辆在道路上通常是跟随前方机动车辆行驶, 因此, 属于机动车辆的模式 A, B 占据最大的出现概率; 城区交通场景

基金项目: 国家自然科学基金资助项目(69674012); 重庆市自然科学基金资助项目(2006BA6016)

作者简介: 沈志熙(1976 -), 男, 博士研究生, 主研方向: 机器视觉, 模式识别与人工智能; 黄席樾, 教授、博士、博士生导师; 杨镇宇, 硕士研究生; 韦金明, 讲师、硕士研究生

收稿日期: 2008-12-05 **E-mail:** shenzxcq@yahoo.com.cn

中,经常出现外形轮廓较为对称的背景模式 F,如护栏、桥梁、建筑物等,因此,模式 F 有着较高的出现概率;而属于非机动车的模式 C、D 以及属于行人的模式 E 有着相对较低的出现概率。此外,从各种模式类间差异来看,模式 A、B(中小型汽车、大型客货车)及模式 C、D(摩托车、自行车)特征相近,类间差异相对较小,应设计独立 SVM 子分类器进行识别以降低误识率。

2.2 基于 Boosting 集成学习的改进算法

树型 SVM 的一个特点是上层节点的分类错误,将被下层分类器传递下去,即差错积累。这是影响树型 SVM 分类精度的重要因素。本文采用集成学习方法提升每个节点分类器的性能,从而有效减少了差错积累误差。

Boosting 算法^[5]是集成学习中最具代表性的方法,其总体思想是:弱分类器的训练依赖于上一次的分类结果,判断出错的样本将以较大的概率出现在新的弱分类器训练子集中,使其后产生的弱分类器更加专注于处理对已有弱分类器来说较为困难的样本区分问题,最终分类器通过每个弱分类器的加权投票集成起来。本文改进算法步骤如下:

Step1 输入样本集 $S = \{x_i, y_i\}, i = 1, 2, \dots, m$, 初始样本权重为 $\omega_i^{(1)} = 1/m$, 弱分类器个数为 T ;

Step2 循环计算(当 $t \leq T$): (1)依据权重大小,从正负样本集中各选择 M 个样本,得到子集 $S^{(t)}$; (2)调用标准 SVM 算法训练 $S^{(t)}$, 得到弱分类器 $svm^{(t)}$, 用 $svm^{(t)}$ 测试 S , 错误率为 $\epsilon^{(t)}$; (3)弱分类器 $svm^{(t)}$ 的权值为: $\beta^{(t)} = 1 - \epsilon^{(t)}$; (4)修改样本权重:支持向量对应的样本权重为 $\omega_i^{(t+1)} = \omega_i^{(t)} + 1$, 错分样本权重为 $\omega_i^{(t+1)} = \omega_i^{(t)} + 2$, 其余样本权重不变; (5)如果选取的训练集与上次相同,退出循环;否则 $t = t + 1$, 继续循环;

Step3 由 $\epsilon^{(t)} < 0.5$ 的多个弱分类器,加权集成该节点分类器的判决函数:

$$f(x) = \text{sgn}\{\sum_{t=1}^T \beta^{(t)} \cdot svm^{(t)}(x)\} \quad (2)$$

3 障碍物检测及分类识别

出于实时性和识别精度的需要,本文将整个识别过程分为 2 个阶段:候选区域假设和假设确认。

3.1 候选区域假设

分析车载视频图像可发现:本文定义的 5 类障碍物模式都具有外形轮廓对称性这一后视视觉特点。因此,本文提出一种基于小波模极大值的候选目标检测算法。首先采用一种投票机制,将二维图像中的轮廓对称性特征映射为一个一维投票向量;然后采用小波模极大值检测算法对投票向量中的奇异点进行检测,这些奇异点就对应于候选区域的对称轴位置;最后,根据各对称轴对应的有投票贡献的左右边缘点对,并结合障碍物的先验特征知识,对障碍物候选区域外接矩形进行框定。

3.2 假设确认

直接由图像数据组成的特征向量维数巨大、类内散布严重,为了更为有效地表征模式类别,本文同时选取了描述形状结构的全局特征和描述内部细节的纹理特征。形状特征由 1 个几何特征(高宽比 R_{hw}), 7 个对平移、旋转和尺度变换不变的 Hu 不变矩特征 $\Phi_1, \Phi_2, \dots, \Phi_7$ 组成;纹理特征采用有很强鲁棒性的 Gabor 特征。本文采用多通道 Gabor 滤波器组,该滤波器在频域中心对称,滤波方向只需考虑半个频率平面,选取 $\theta=0^\circ, 45^\circ, 90^\circ, 135^\circ$, 中心频率 $f=2, 4, 8, 16$, 共 4×4 对 Gabor 滤波器组。按式(3)和式(4)求取滤波后图像 $I'(x, y)$ 的均值 E 和方差 D 作为 Gabor 纹理特征,共有 $4 \times 4 \times 2 = 32$ 个:

$$E = \frac{\sum_{x=1}^N \sum_{y=1}^N I'(x, y)}{N^2} \quad (3)$$

$$D = \sqrt{\sum_{x=1}^N \sum_{y=1}^N [I'(x, y) - E]^2 / N^2} \quad (4)$$

所有特征值串联起来,组成一个包括 40 个属性的特征向量 $F = [R_{hw}, \Phi_1, \Phi_2, \dots, \Phi_7, E_1, E_2, \dots, E_{16}, D_1, D_2, \dots, D_{16}]^T$ 来描述障碍物模式。其中,形状特征从原始样本图像提取, Gabor 特征从 64×64 规格化样本图像提取。5 种类别的障碍物典型样本图像见图 2。



图 2 5 类障碍物模式典型样本图像

分类器训练阶段,按图 1 设计的树型结构,依次训练各节点分类器 $SVM1 \rightarrow SVM2 \rightarrow \dots \rightarrow SVM5$ 。分类器识别阶段,将候选区域特征向量作为输入数据,从上到下逐层判别,如果某个节点分类器计算输出为 +1,表明它属于左子类,继续沿左分支对应的下一层细分;否则,沿着右分支对应的下一层细分;直到确定出最基本的类别。

图 3 为本文算法对城区交通场景中障碍物检测和识别的典型效果图。从左到右分别是原始图像、候选区域检测结果、障碍物分类识别结果,经投票机制映射后的一维对称性投票向量以柱状图形式复合到图像中。结果表明:(1)候选区域检测中虽然存在部分虚检(即背景),但漏检目标很少或基本没有;(2)虚检目标经分类器识别后作为背景模式 F 滤除,而障碍物经分类器识别后被标记并保留。

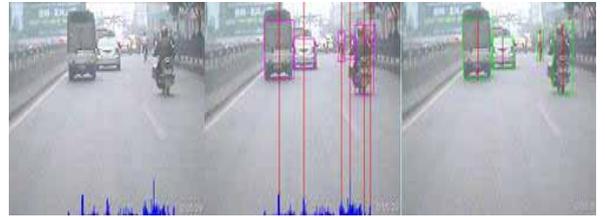


图 3 多类障碍物识别效果

4 实验结果

本文数据来自于重庆大学 CQAC-I 型(普通光型)智能车辆在内市交通干道上的实验录像。采用人工标定的方法,从不同时段、不同场景下的视频帧中,分别选取 6 种障碍物样本(包括背景)共 800 个,其中 1 类~5 类样本各 100 个,其余为背景样本。

由于分类器训练可以离线进行,因此,本文主要针对分类时间和分类精度进行了比较。实验中分别采用了传统分类器最常用的 3 层 BP 网络、测试精度表现较好的 1a1-SVM、测试效率表现较好的 BT-SVM、以及本文提出的 BBT-SVM 方法进行对比验证。二值 SVM 算法在 LIBSVM 工具包基础上修改实现,核函数采用径向基函数(RBF)。实验中 KKT 停止条件容许误差为 0.001, Boosting 中迭代次数取 20。为避免取值范围大的属性比取值范围小的属性更占优势,本文中对样本数据各属性进行归一化预处理,线性调整到 $[-1, 1]$ 。将每种类型的样本均分为 10 组,任取其中 8 组作为训练样本,其余 2 组为测试样本,进行 10 次 Cross-Validation,测试结果由多次测试平均得到,表 1 给出采用不同方法的测试结果。

(下转第 246 页)