

DOI:10.19651/j.cnki.emt.2105772

基于大间隔分布 Pin-SVM 算法的车标分类识别

赵玉田

(烟台汽车工程职业学院 烟台 264000)

摘要: 车标分类是车辆识别的方法之一。车标分类广泛应用于政府大楼、校园、道路等场所的安全防护。本研究的主要目的是利用支持向量机(SVM)分类方法对车标进行识别。针对车标识别问题,设计了一种基于大间隔分布的 Pin-SVM (LMD-Pin-SVM)模型。首先,利用间隔均值和方差定义间隔分布,然后将最优间隔分布引入到 Pin-SVM 模型中,建立 LMD-Pin-SVM 线性模型。此外,利用核技术将线性 LMD-Pin-SVM 模型扩展到非线性情况,并应用于车标识别中。实验结果显示,所提出的模型在泛化性能上优于其他算法。LMD-Pin-SVM 模型可以有效地抑制噪声对分类模型的不利影响,提高不同车标图像的分类正确率。

关键词: 车标;分类;间隔分布;Pin-SVM

中图分类号: TP181 **文献标识码:** A **国家标准学科分类代码:** 520.2040

Vehicle logo classification method based on Pin-SVM with large margin distribution

Zhao Yutian

(Yantai Automobile Engineering Professional College, Yantai 264000, China)

Abstract: Vehicle logo classification is one of the methods of vehicle recognition. Vehicle logo classification is widely used in the safety protection of government buildings, campus, roads and other places. Aiming at the vehicle logo classification, a Pin-SVM based on large margin distribution (LMD-Pin-SVM) is proposed. Firstly, the margin distribution is expressed with margin mean and margin variance. Then introducing the optimal margin distribution into Pin-SVM and the linear LMD-Pin-SVM is built. In addition, the linear LMD-Pin-SVM is extended to the nonlinear case with kernel trick. And the nonlinear LMD-Pin-SVM is applied to vehicle recognition. All experiments show that the proposed method is superior to the state-of-the-art methods in generalization performance. Our LMD-Pin-SVM can effectively suppress the adverse effects of noise on the classification model and improve the classification accuracy of different vehicle logo images.

Keywords: vehicle logo; classification; margin distribution; Pin-SVM

0 引言

车辆识别^[1]是智能交通的重要组成部分。车辆中的有效信息对车辆识别具有重要意义。随着交通系统对车辆识别技术的要求越来越高,车标作为一种重要的车辆信息类型,由于其不应删除、不易更改等特点,为车辆识别提供了重要的方法。目前的车辆识别大多采用特征提取的分类方法,这对于复杂的分类其泛化能力有一定的限制。

目前,可用于车标分类的方法^[2-5]有很多种。如,朱文佳等^[4]提出了一种基于目标优化学习的车标识别方法。与传统特征描述方法相比,它的识别率更高。但是,采用特征提取的分类方法,对于复杂的分类问题而言具有一定的限

制。Butt 等^[5]提出了一种基于卷积神经网络的车标识别方法。相比于传统方法,其识别率较高。但是,如果采用深度学习技术,则需要大量的训练样本。考虑到采集到的车标图像数据集大多是中小规模,深度学习难以胜任。相反,支持向量机(support vector machine, SVM)^[6]是近年来迅速发展起来的一种新的机器学习和分类方法,适用于中小规模数据分类。目前,SVM 在车标识别问题中已经得到了应用。如,薛峰等^[7]结合 SVM 和随机森林的学习方法,实现大规模车标图像的分类,其主要优势是实现增量学习。Dai 等^[8]采用了切比雪夫不变矩阵和 SVM 对车标进行识别,该方法在无噪声环境下具有较好的识别率。

事实上,从互联网和停车场视频录像中获取的车辆图

收稿日期:2021-02-01

像大多是存在噪声的。目前,在车标识别上很少关注噪声对分类模型带来的不利影响。为此,本文提出一种基于大间隔分布的 Pin-SVM 模型 (Pin-SVM with large margin distribution, LMD-Pin-SVM),并应用于车标识别,可以有效地抑制噪声对分类模型的不利影响,提高不同车标图像的分类正确率。

1 结合大间隔分布和 Pin-SVM 的分类方法

1.1 大间隔分布机

标准的 SVM 模型是基于间隔理论的,虽然间隔理论在模式识别中得到了广泛的应用,但有时会导致弱间隔分布,这对泛化能力是不利的。Breiman^[9]对间隔最大化理论提出了质疑,认为间隔理论不是影响泛化性能的关键因素。Huang 等^[10]发现间隔最大化理论仍然有价值,但是间隔分布对于提高分类器的泛化性能更为重要。随后,Gao 等^[11]利用间隔均值和间隔方差对间隔分布进行了描述,并推测间隔分布对泛化性能有重要影响。紧接着,Zhang 等^[12]基于间隔分布理论成果,将其应用到 SVM 上,提出了大间隔分布机 (large margin distribution machine, LDM) 模型。理论和实验结果证明了 LDM 的优越性。

LDM 的思想与标准 SVM 相似,也是寻找一个最优的分类超平面。

$$H: \mathbf{w}^T \mathbf{x} = 0 \quad (1)$$

不同的是,除了最大化最小间隔之外,LDM 还需要最大化间隔均值和最小化间隔方差,这使得 LDM 模型具有更好的泛化能力。LDM 的数学描述如下:

$$\begin{aligned} \min_{\mathbf{w}, \hat{\gamma}, \hat{\gamma}} & \frac{1}{2} \|\mathbf{w}\|^2 - c_1 \bar{\gamma} + c_2 \hat{\gamma} + c_3 e^T \boldsymbol{\xi} \\ \text{s. t. } & y_i \mathbf{w}^T \mathbf{x}_i \geq 1 - \xi_i \\ & \xi_i \geq 0, i = 1, \dots, l \end{aligned} \quad (2)$$

其中, $\|\cdot\|$ 表示 L_2 范数, $\{c_j > 0\}_{j=1}^3$ 是惩罚因子, $\boldsymbol{\xi} = (\xi_1, \dots, \xi_l)^T$ 是松弛向量, $\bar{\gamma}$ 和 $\hat{\gamma}$ 分别代表的是间隔均值和间隔方差,可由下列式子计算得到:

$$\bar{\gamma} = \frac{1}{l} \sum_{i=1}^l y_i \mathbf{w}^T \mathbf{x}_i = \frac{1}{l} \mathbf{y}^T f(\mathbf{X}) \quad (3)$$

$$\begin{aligned} \hat{\gamma} &= \frac{1}{l^2} \sum_{i=1}^l \sum_{i_2=1}^l (y_{i_1} \mathbf{w}^T \mathbf{x}_{i_1} - y_{i_2} \mathbf{w}^T \mathbf{x}_{i_2})^2 = \\ & \frac{2}{l^2} (l f^T(\mathbf{X}) f(\mathbf{X}) - f^T(\mathbf{X}) \mathbf{y} \mathbf{y}^T f(\mathbf{X})) \end{aligned} \quad (4)$$

其中, $f(\mathbf{X}) = \mathbf{X} \mathbf{w}$, $\mathbf{X} = [\mathbf{x}_1^T, \mathbf{x}_2^T, \dots, \mathbf{x}_l^T]^T$ 和 $\mathbf{y} = (y_1, \dots, y_l)^T$ 。

1.2 非线性 Pin-SVM 分类器

为了进一步提高 SVM 的性能,Huang 等^[13]利用弹珠损失函数代替 SVM 中的铰链损失函数,利用分位数距离来度量间隔,提出了一种新的分类模型,称作 Pin-SVM。弹珠损失函数 $L_\tau(\mathbf{x}_i, y_i, f(\mathbf{x}_i))$ 表达式如下:

$$L_\tau(\mathbf{x}_i, y_i, f(\mathbf{x}_i)) = \begin{cases} 1 - y_i f(\mathbf{x}_i), & 1 - y_i f(\mathbf{x}_i) \geq 0 \\ -\tau(1 - y_i f(\mathbf{x}_i)), & 1 - y_i f(\mathbf{x}_i) < 0 \end{cases} \quad (5)$$

Pin-SVM 的原始优化问题为:

$$\begin{aligned} \min_{\mathbf{w}, \hat{\gamma}, \boldsymbol{\xi}} & \frac{1}{2} \|\mathbf{w}\|^2 + c e^T \boldsymbol{\xi} \\ \text{s. t. } & y_i \mathbf{w}^T \mathbf{x}_i \geq 1 - \xi_i \\ & y_i \mathbf{w}^T \mathbf{x}_i \leq 1 + \frac{1}{\tau} \xi_i, i = 1, \dots, l \end{aligned} \quad (6)$$

其中, $\tau > 0$ 是一个可调节参数。Pin-SVM 的主要优点在于对噪声不敏感,特别是位于决策边界附近的特征噪声。同时,Pin-SVM 的计算复杂度与标准 SVM 相似。

1.3 LMD-Pin-SVM

与标准 SVM 一样,Pin-SVM 也只考虑了间隔最大化原则,而忽略了间隔分布对泛化性能带来的影响。因此,受 LDM 的启发,本文在 Pin-SVM 算法的基础上,提出了基于大间隔分布的 Pin-SVM (LMD-Pin-SVM) 算法。LMD-Pin-SVM 的原始优化问题如式(7)所示。同 Pin-SVM 一样,LMD-Pin-SVM 同样可获得两个决策边界, $\mathbf{w}^T \mathbf{x} = +1$ 和 $\mathbf{w}^T \mathbf{x} = -1$,然后通过两条决策边界,确定未知样本的所属类别。

$$\begin{aligned} \min_{\mathbf{w}^k} & \frac{1}{2} \|\mathbf{w}^k\|^2 - \frac{c_1^k}{l} (\mathbf{y}^k)^T \mathbf{X}^k \mathbf{w}^k + c_3^k e^T \boldsymbol{\xi}^k + \\ & \frac{2c_2^k}{l^2} (l (\mathbf{w}^k)^T (\mathbf{X}^k)^T \mathbf{X}^k \mathbf{w}^k - (\mathbf{w}^k)^T (\mathbf{X}^k)^T \mathbf{y}^k (\mathbf{y}^k)^T \mathbf{X}^k \mathbf{w}^k) \\ \text{s. t. } & y_i^k (\mathbf{w}^k)^T \mathbf{x}_i \geq 1 - \xi_i^k \\ & y_i^k (\mathbf{w}^k)^T \mathbf{x}_i \leq 1 + \frac{1}{\tau} \xi_i^k, i = 1, \dots, l \end{aligned} \quad (7)$$

为了获得最优决策边界,需对 LMD-Pin-SVM 的原始优化问题进行推导,获得对应的对偶问题。为了方便求解,首先令:

$$\mathbf{w}^k = (\mathbf{X}^k)^T \boldsymbol{\alpha}^k \quad (8)$$

则有:

$$\mathbf{X}^k \mathbf{w}^k = \mathbf{X}^k (\mathbf{X}^k)^T \boldsymbol{\alpha}^k \quad (9)$$

$$(\mathbf{w}^k)^T \mathbf{w}^k = (\boldsymbol{\alpha}^k)^T \mathbf{X}^k (\mathbf{X}^k)^T \boldsymbol{\alpha}^k \quad (10)$$

接下来,令 $\mathbf{H}^k = \mathbf{X}^k (\mathbf{X}^k)^T$,结合式(9)和(10),原始优化问题式(7)可简化为:

$$\begin{aligned} \min_{\boldsymbol{\alpha}^k} & \frac{1}{2} (\boldsymbol{\alpha}^k)^T \mathbf{Q}^k \boldsymbol{\alpha}^k + (\mathbf{f}^k)^T \boldsymbol{\alpha}^k + c_3 e^T \boldsymbol{\xi}^k \\ \text{s. t. } & y_i^k (\boldsymbol{\alpha}^k)^T \mathbf{H}_i^k \geq 1 - \xi_i^k \\ & y_i^k (\boldsymbol{\alpha}^k)^T \mathbf{H}_i^k \leq 1 + \frac{1}{\tau} \xi_i^k, i = 1, \dots, l \end{aligned} \quad (11)$$

其中, $\mathbf{Q} = \frac{4c_2}{l^2} (l (\mathbf{H}^k)^T \mathbf{H}^k - (\mathbf{H}^k \mathbf{y}^k) (\mathbf{H}^k \mathbf{y}^k)^T) + \mathbf{H}^k$,

$\mathbf{f}^k = -\frac{c_1}{l} \mathbf{H}^k \mathbf{y}^k$, \mathbf{H}_i^k 是矩阵 \mathbf{H}^k 的第 i 列。

接下来,引入拉格朗日乘子 α_i 和 β_i ,构造拉格朗日函数式:

$$L = \frac{1}{2}(\boldsymbol{\alpha}^k)^T \mathbf{Q}^k \boldsymbol{\alpha}^k + (\mathbf{f}^k)^T \boldsymbol{\alpha}^k + c_3 e^T \boldsymbol{\xi}^k -$$

$$\sum_{i=1}^l \beta_i^k (y_i^k (\boldsymbol{\alpha}^k)^T \mathbf{H}_i^k - 1 + \xi_i^k) + \sum_{i=1}^l \lambda_i^k (y_i^k (\boldsymbol{\alpha}^k)^T \mathbf{H}_i^k - 1 - \frac{1}{\tau} \xi_i^k) \quad (12)$$

通过将 $\{\boldsymbol{\alpha}, \boldsymbol{\xi}\}$ 的偏导数设为 0,可以得到:

$$\frac{\partial L}{\partial \boldsymbol{\alpha}^k} = \mathbf{Q}^k \boldsymbol{\alpha}^k + \mathbf{f}^k - \sum_{i=1}^l \beta_i^k y_i^k \mathbf{H}_i^k + \sum_{i=1}^l \lambda_i^k y_i^k \mathbf{H}_i^k \quad (13)$$

$$\frac{\partial L}{\partial \boldsymbol{\xi}^k} = c_3 \mathbf{e} - \boldsymbol{\beta}^k - \frac{1}{\tau} \boldsymbol{\lambda}^k \quad (14)$$

将式(13)和(14)代入到式(12)中,则式(11)的对偶可以转换为:

$$\min_{\boldsymbol{\theta}^k} \frac{1}{2}(\boldsymbol{\theta}^k)^T \mathbf{G}^k \boldsymbol{\theta}^k + \left(\frac{c_1}{l} \mathbf{G}^k \mathbf{e} - \mathbf{e}\right)^T \boldsymbol{\theta}^k \quad (15)$$

$$\text{s. t. } 0\mathbf{e} \leq \boldsymbol{\theta}^k \leq c_3 \tau \mathbf{e}$$

其中, $\boldsymbol{\theta}^k = \boldsymbol{\beta}^k - \boldsymbol{\lambda}^k$, $\mathbf{G}^k = \mathbf{Y}^k \mathbf{H}^k (\mathbf{Q}^k)^{-1} \mathbf{H}^k \mathbf{Y}^k$, $(\mathbf{Q}^k)^{-1}$ 是矩阵 \mathbf{Q}^k 的逆矩阵。

利用 QP 工具箱,可求得对偶问题式(15)的最优解 $\boldsymbol{\theta}^k$,然后根据式(16)获得最优解 $\boldsymbol{\alpha}^k$ 。

$$\boldsymbol{\alpha}^k = (\mathbf{Q}^k)^{-1} \mathbf{H}^k \mathbf{Y}^k \left(\frac{c_1}{l} \mathbf{e} + \boldsymbol{\theta}^k\right) \quad (16)$$

最后,将 $\boldsymbol{\alpha}^k$ 值代入到式(8)中,可以得到 \mathbf{w}^k 的最优解。这样,对于任意标签未知的样本 \mathbf{x}_i ,可通过下列决策函数来确定其所属类别。

$$f(\mathbf{x}_i) = \text{sgn}((\mathbf{w}^k)^T \mathbf{x}_i) \quad (17)$$

2 车标分类

2.1 样本提取算法

在开展本文工作之前,已经从互联网和停车场视频录像中获取了 6 种车标的图像,包括大众、丰田、现代、马自达、日产和宝马,如图 1 所示。




图 1 6 种类型的车标图像

为了完成车标分类识别的任务,需要对车标图像进行预处理、分割和特征提取。首先,将采集的车标图像转换为灰度图像,然后凭借人工经验法剔除不完整的车标图像,最

终获得 1 105 幅可用于训练和测试的车标图像。然后,利用 HOG 特征提取算法^[14],针对车标区域,对车标进行各种特征的描述,最终形成一个 1 105×65 的车标数据集。

2.2 基于 LMD-Pin-SVM 的多类车标分类识别的实现

通过提取出的车标图像样本可以发现,车标分类识别属于多分类问题。众所周知,SVM 模型是二分类模型,为实现多类别的车标分类问题,本文将二叉树方法^[15]应用于 LMD-Pin-SVM 算法中。图 2 所示为实现 K 类车标分类的二叉树模型。

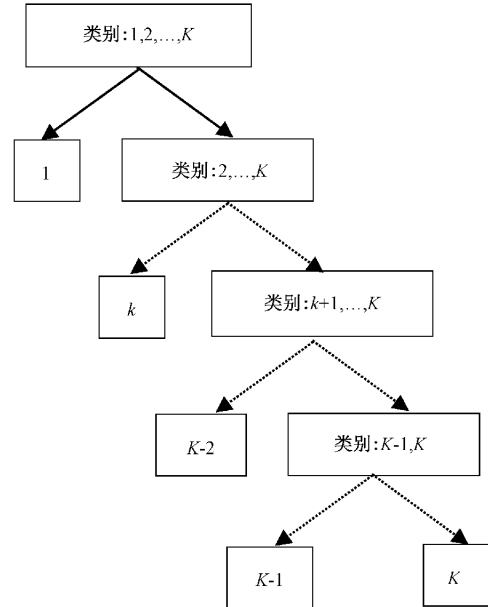


图 2 二叉树模型

基于二叉树的思想,本节设计出多类别车标分类模型。模型分为 3 个部分,分别是预处理部分、训练部分和测试部分。预处理主要是对数据进行处理。首先,所有样本进行归一化处理,将输入样本限制在 $[0, 1]$ 之间,这样可以提高模型的分类精度和收敛速度。然后利用五折交叉验证法,将收集到的 1 105 个车标数据集分成 5 份,其中 4 份用来作为训练样本集,剩余一份作为测试集,并要求保证每一份样本均被视作测试集。训练部分则是利用训练样本集训练出满足解决多类别分类问题的 $(K - 1)$ 个 LMD-Pin-SVM 子模型。测试部分则是利用测试样本集来检测 $(K - 1)$ 个子模型的性能,最后得出结论。

2.3 训练部分

本节以第 k 个子分类模型为例,对其训练过程进行说明。为了获得可靠的分类器参数,使分类器能更加准确的预测未知数据。在训练部分,网格搜索和五折交叉验证方法被雇佣,用来获取模型的最优参数。具体的训练过程如图 3 所示。

2.4 测试部分

在测试阶段,如图 4 所示,LMD-Pin-SVMs 根据训练阶段获得 $(K - 1)$ 个超平面 $H_k: (\mathbf{w}^k)^T \mathbf{x} = 0, k = 1, \dots,$

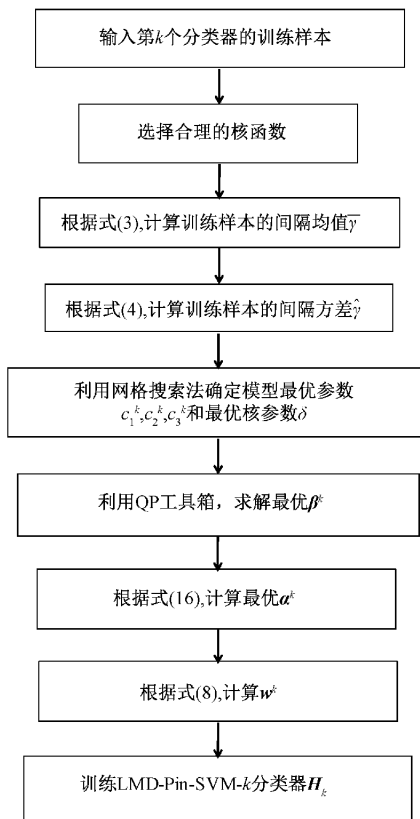


图 3 训练第 k 个分类子模型

$K - 1$, 直接构造出多类分类的决策函数 $f(x_i, H_1, \dots, H_{K-1})$ 。LMD-Pin-SVMs 的决策规则是新样本 x_i 的类别 $y(x_i)$ 归属为距离最近的超平面所对应的类别。需要说明的是, 训练阶段是在离线的时候完成, 而测试阶段需要满足在线的要求。

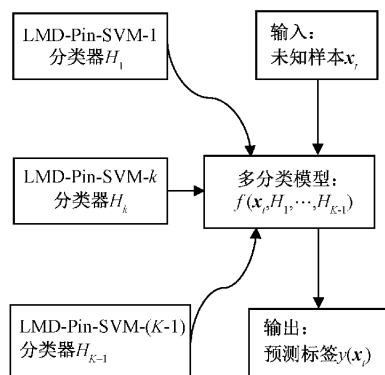


图 4 测试阶段

3 仿真实验与结果分析

3.1 评价指标

为了评价模型的好坏, 模型的准确度被测试。假设我们的兴趣是从其他车标中区分出大众车标, 那么 TP 代表正确分类大众车标的数量, TN 代表正确分类非大众车标

的数量, FP 是非大众车标被错误分类为大众车标的数量, FN 是大众车标被错误分类为非大众车标的数量。使用这些数量, 准确度可通过如下公式来计算。

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (18)$$

3.2 性能对比

在本节, 为了验证 LMD-Pin-SVMs 模型的分类性能, 将 LMD-Pin-SVMs 与 SVMs、LDMs 和 Pin-SVMs 模型进行了对比实验, 分别测试了车标多类别分类的准确度和运行时间。所有模型的最优参数都通过网格法从 $[2^{-7}, 2^7]$ 中进行选择。为实现多分类问题, 所有算法均和二叉树模型相结合。所有的算法被执行在主频 1.8 GHz 的 Intel i7 处理器, 内存为 8 GB RAM 的笔记本电脑。

本实验采用 2.1 节中的车标样本, 且将所有样本归一化到 $[0, 1]$ 之间, 并利用五折交叉验证法将车标样本划分为训练集和测试集, 相关属性如表 1 所示。

表 1 车标样本训练集和测试集

车标	标签	训练样本数量	测试样本数量
大众	1	133	33
丰田	2	184	46
现代	3	128	32
马自达	4	136	34
日产	5	143	36
宝马	6	160	40

由表 1 可知, 共有 6 类车标, 即 $K = 6$ 。则对于每个算法, 均需构造 5 个子模型。为了验证提出模型的抗噪性能, 人为的在车标样本中加入均值为 0, 方差为 0.05 的高斯白噪声^[6]。对于每一类车标数据集, 分别在原始数据集和被噪声破坏的数据集上对 4 个算法进行测试, 实验结果分别记录在表 2 和 3 中。

表 2 原始数据集上的单一类型车标分类精度 %

车标类别	LMD-Pin-SVM ACC	Pin-SVM ACC	LDM ACC	SVM ACC
1	87.20	84.15	85.38	84.32
2	90.57	89.79	88.47	87.69
3	89.95	84.32	85.12	84.55
4	86.41	83.17	84.55	81.47
5	87.59	85.26	84.74	84.69
6	90.32	87.94	88.90	86.55

从表 2 和 3 可以发现, 对于每一类车标而言, LMD-Pin-SVM 的分类精度都要高于其他 3 种算法, 特别是, 当数据集被噪声破坏时。从表 3 可以看出, 当数据集受到噪声破坏时, 4 个算法的精度都呈下降趋势。但可以看出, 本

表 3 噪声数据集上的单一类型车标分类精度 %

车标类别	LMD-Pin-SVM	Pin-SVM	LDM	SVM
	ACC	ACC	ACC	ACC
1	82.15	74.17	75.89	73.57
2	83.22	78.16	76.32	75.17
3	82.73	75.56	72.58	71.33
4	82.13	77.39	75.95	75.96
5	81.22	77.12	75.43	75.09
6	82.15	78.00	75.87	75.43

文提出的 LMD-Pin-SVM 模型和 Pin-SVM 的精度要高于 SVM 和 LDM。这是因为 LMD-Pin-SVM 和 Pin-SVM 都采用了弹珠损失函数,具有抗噪声的特性。此外,可以看出 LMD-Pin-SVM 的精度高于 Pin-SVM,这是因为 LMD-Pin-SVM 考虑了样本的间隔分布,具有更好的泛化性能。

除此之外,4 个算法的总分类精度和执行时间被记录在表 4 中。从表 4 可以看出,针对车标图像分类问题,本文提出的 LMD-Pin-SVM 算法具有更高的识别精度,但是其识别效率较低。原因是为了提高模型的泛化性能,LMD-Pin-SVM 需要花费额外的时间来计算样本的间隔分布,这一结论与 LDM 相同。

表 4 4 个不同分类器的分类结果

分类器	精度/%	精度/%
	时间/s (原始数据)	时间/s (噪声数据)
LMD-Pin-SVMs	89.50±2.27	82.64±1.73
	3.921 7	4.426 7
Pin-SVMs	85.49±2.78	77.73±2.36
	3.473 9	3.929 2
LDMs	87.27±3.14	75.47±1.92
	3.801 5	4.909 7
SVMs	84.75±2.94	74.92±3.12
	3.374 9	3.910 0

4 结 论

在本文中,基于大间隔分布机的思想,将间隔分布应用到 Pin-SVM 算法中,提出一种新的基于大间隔分布的 Pin-SVM 模型(LMD-Pin-SVM),用于汽车标志分类。采用 HOG 特征方法对车标图像进行特征提取,然后对提取的特征进行学习。首先利用间隔方差和间隔均值来定义间隔分布,然后将最优间隔分布引入 Pin-SVM 分类器。此外,将提出的模型与二叉树结构相结合,设计出一种多类别分类模型。然后采用提出的模型对提取的特征进行分类。实验结果表明,本文提出的方法对不同类别的车标图像的识别率高,具有强鲁棒性,具有较高的实用价值。但是,由于

需要计算样本的间隔分布,本文提出的模型需要花费更多的时间。所以,未来工作将关注于如何提高模型的运算效率。

参考文献

- [1] LIN Y, TSAI M, HSU W, et al. Investigating 3-D model and part information for improving content-based vehicle retrieval [J]. IEEE Transactions on Circuits & Systems for Video Technology, 2013, 23(3): 401-413.
- [2] 汪辉,高尚兵,周君,等. 基于 YOLOv3 的多车道车流量统计及车辆跟踪方法[J]. 国外电子测量技术, 2020, 39(2): 47-51.
- [3] 郑少武,李巍华,胡坚耀. 基于激光点云与图像信息融合的交通环境车辆检测[J]. 仪器仪表学报, 2019, 40(12): 146-154.
- [4] 朱文佳,陈宇红,冯瑜瑾,等. 一种基于目标优化学习的车标识别方法[J]. 图学学报, 2019, 40(146): 62-69.
- [5] BUTT M A, KHATTAK A M, SHAFIQUE S, et al. Convolutional neural network based vehicle classification in adverse illuminous conditions for intelligent transportation systems [J]. Complexity, 2021, 2021(1): 1-11.
- [6] LIU L, CHU M, GONG R, et al. An improved nonparallel support vector machine [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020(99): 1-15.
- [7] 薛峰,朱强,林楠. 结合改进的 SVM 和随机森林算法车标分类识别[J]. 计算机工程与设计, 2017, 38(12): 3425-3430.
- [8] DAI S, HUANG H, GAO Z, et al. Vehicle-logo recognition method based on tchebichef moment invariants and SVM [C]. Wri World Congress on Software Engineering, IEEE Computer Society, 2009.
- [9] BREIMAN L. Prediction games and arcing algorithms[J]. Neural Computation, 2014, 11(7): 1493-1517.
- [10] HUANG Y, POWERS B, REYZIN L. Training-time optimization of a budgeted booster[C]. Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence(IJCAI 2015), 2015.
- [11] GAO W, ZHOU Z. On the doubt about margin explanation of boosting [J]. Artificial Intelligence-Amssterdam-Elsevier-, 2013, 203(1): 1-18.
- [12] ZHANG T, ZHOU Z. Large margin distribution machine [C]. In: Proceedings of ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM, 2014, 20: 313-322.
- [13] HUANG X, SHI L, SUYKENS JAK. Support vector

machine classifier with Pinball loss [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(5): 984-997.

[14] 包本刚. 融合多特征的目标检测与跟踪方法[J]. 电子测量与仪器学报, 2019, 33(9): 98-104.

[15] FEI B, LIU J B. Binary tree of SVM: A new fast

multiclass training and classification algorithm [J].

IEEE Trans Neural Networks, 2006, 17(3): 696-704.

作者简介

赵玉田, 副教授, 主要研究方向为新能源汽车轻量化设计。

E-mail: zhaoyutian2010@163.com