

# 一种改进的交通标志图像识别算法

徐 岩, 韦镇余\*

天津大学电子信息工程学院, 天津 300072

**摘要** 交通标志识别(TSR)系统是智能交通系统的重要研究方向。道路交通环境复杂、交通标志数据库规模庞大等因素导致在设计 TSR 系统可行性方案时必须考虑计算复杂度和识别率。提出了一种高效且快速的基于改进主成分分析(PCA)法和极限学习机(ELM)的 TSR 算法,被称为 PCA-HOG。该算法首先提取交通标志数据库中每个交通标志的梯度方向直方图(HOG)特征,利用改进 PCA 算法对提取出的 HOG 特征进行降维处理,之后利用降维后的 HOG 特征进行 ELM 模型训练,利用经过训练的 ELM 模型识别测试图片。实验结果表明,基于 PCA-HOG 和 ELM 模型的交通标志识别算法获得的计算复杂度低,图像识别率可达 97.69%。

**关键词** 图像处理; 交通标志识别; 特征提取; 主成分分析降维; 极限学习机

**中图分类号** TP751.1      **文献标识码** A

**doi:** 10.3788/LOP54.021001

## An Improved Traffic Sign Image Recognition Algorithm

Xu Yan, Wei Zhenyu

*School of Electronic Information Engineering, Tianjin University, Tianjin 300072, China*

**Abstract** The traffic sign recognition (TSR) system is an important research direction in the field of intelligent transport system. Due to traffic complexity, large scale of traffic signs database and other reasons, the feasibility of TSR design must take computational complexity and recognition rate into consideration. An efficient and fast traffic sign algorithm is proposed based on the improved principal component analysis (PCA) and extreme learning machine (ELM), as known as PCA-ELM. Firstly, the histogram of gradient direction (HOG) features for each TSR are extracted from traffic sign database. HOG dimensional features are reduced by the improved PCA algorithm. ELM model training is presented based on the HOG after dimension reduction. Image recognition is tested based on the trained ELM model. Experimental results show that the recognition algorithm based on PCA-HOG and ELM model can get a high recognition rate of 97.69% and perform low in computational complexity.

**Key words** image processing; traffic sign recognition; feature extraction; principal component analysis dimension reduction; extreme learning machine

**OCIS codes** 100.3008; 100.5010; 110.2960; 150.1135

## 1 引言

交通标志识别(TSR)是未来智能交通系统的重要组成部分,也是无人驾驶和驾驶员辅助系统的重要组成部分模块<sup>[1]</sup>。在自然场景下,道路交通环境的复杂性等因素给交通标志的实时自动检测和识别带来了巨大的挑战。因此,高效实时的交通标志识别技术是未来发展的方向和热点<sup>[2]</sup>。

随着人工智能的发展,机器学习算法在现实生活中得到了广泛的应用<sup>[3-4]</sup>。一些先进的机器学习算法同样应用于交通标志识别,如神经网络法<sup>[5-6]</sup>、线性判别分析(LDA)<sup>[7]</sup>、支持向量机<sup>[8]</sup>、子空间分析、集成分类器、慢特征分析、K-D 树和随机森林<sup>[9]</sup>等。文献[10]利用交通标志的局部二值模式特征和 AdaBoost 分类器进行交通标志识别,但该算法只适用于限速类交通标志。文献[11]利用交通标志的颜色特征进行交通标志

**收稿日期:** 2016-09-26; **收到修改稿日期:** 2016-10-19

**基金项目:** 国家自然科学基金(61372145)、天津大学独立创新基金(2015XZC-0005)

**作者简介:** 徐 岩(1977—),女,博士,副教授,主要从事图像处理、人工智能等方面的研究。E-mail: xuyan@tju.edu.cn

\* **通信联系人.** E-mail: weizhenyu@tju.edu.cn

检测,然后利用人工神经网络分类器进行识别,但人工神经网络的参数设置至今没有提出成熟的解决方案。文献[12]提出一种基于随机梯度下降法和卷积神经网络的识别算法,识别率可达99.65%。但是该算法对于模型的训练时间长达50 h,计算复杂度特别高,不能满足实际应用的实时性要求。文献[13]基于交通标志的旋转不变模式特征,将此特征作为人工神经网络的输入进行训练识别,识别率可达98.62%,神经网络训练用时为1800 s,时间复杂度有所降低,但神经网络训练耗时仍然有较大的降低空间。

同时考虑到时间复杂度和识别率,本文提出一种基于改进主成分分析(PCA)法和极限学习机(ELM)模型的交通标志识别算法,被称为PCA-ELM算法。该算法提取交通标志数据库中每一张交通标志的梯度方向直方图(HOG)特征,然后使用改进的PCA方法进行降维,将降维后的HOG特征作为ELM的输入进行特征训练,最终利用训练得到的ELM模型对测试图片进行识别。与现有的识别算法相比,本文提出的PCA-ELM算法只需要设置隐元个数这一个参数,便可以降低时间复杂度。实验结果表明,PCA-ELM算法在降低时间复杂度的同时可以得到较高的识别率。

## 2 算 法

### 2.1 改进的PCA降维理论

由于交通标志提取出的HOG特征维数较高,维数高、特征多会导致训练模型复杂和训练速度过慢,因此找出最能代表原始交通标志的低维数据是分类的关键。在使用ELM模型训练之前,需要引入PCA对提取出的特征进行降维<sup>[14]</sup>。由于提取的HOG特征之间具有较高的相关度,完全可以适当地减去一些信息量少且相关度高的特征,去掉部分冗余信息和噪声等因素不但利于分类识别,而且能够提高识别率。

在降维映射的过程中存在映射误差,因此在对高维特征降维之前,需要首先对特征进行归一化处理,即特征缩放和零均值归一化,得到样本特征矩阵 $\mathbf{A} = [d_{11}, d_{12}, \dots, d_{mn}]^T$ 。然后计算出样本特征的协方差矩阵,进而采用奇异值分解算法计算协方差矩阵的特征值和特征向量,将协方差矩阵的特征向量从大到小正向排序。PCA降维的目的在于根据特征值的贡献率选取其中最重要的前 $k$ 维特征,贡献率是指选取特征值之和与所有特征值之和的比值,即

$$\frac{\sum_{i=1}^k s_{ii}}{\sum_{i=1}^n s_{ii}} \geq T_{\text{th}}, \quad (1)$$

式中 $n$ 为降维前特征维数, $k$ 为降维后特征维数, $T_{\text{th}}$ 为贡献率阈值, $\mathbf{S}$ 为由协方差矩阵的特征值组成的对角矩阵,即

$$\mathbf{S} = \begin{bmatrix} s_{11} & & & & & \\ & s_{22} & & & & \\ & & \ddots & & & \\ & & & & & \\ & & & & s_{mm} & \\ & & & & & \dots & \end{bmatrix}_{n \times n} \quad (2)$$

传统的PCA算法要想取得理想的效果,要求训练样本集必须符合高斯分布。但是天气、光照、运动模糊等问题容易导致原始样本集不符合高斯分布,这种情况下PCA降维将对后续识别产生不良影响。改进方法采用分块PCA理论将原来的标准训练样本矩阵集分解为多个独立的子单元块,即将原来的标准训练矩阵 $\mathbf{A} = [d_{11}, d_{12}, \dots, d_{mn}]^T$ 分为多个子单元块 $\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_k$ ,其中 $\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_k$ 分别为样本里具有相同类别的交通标志的合集。这些子单元块具有相似的形状或颜色等特性,所含的不同因素相对较少,所以其数据分布更符合高斯分布。最终在每个子单元块上进行传统PCA降维,这样得到的特征向量更能够反应出原始数据的属性,有利于提高识别率。

实验中 $T_{\text{th}}$ 设为0.99,即保存样本99%以上的特征,由此降维得到的 $k$ 远小于 $n$ 。降维前特征维数 $n = 1764$ ,降维后特征维数 $k = 441$ ,实验结果表明,降维后不仅提升了交通标志识别率,还在较大程度上降低了时间复杂度。

## 2.2 ELM 算法

ELM 算法是一种基于单隐层前向反馈神经网络(SLFNs)的监督型学习算法<sup>[15]</sup>。学习过程中只需要设置网络的隐层节点个数  $\tilde{N}$  一个参数,其输入层与隐藏层之间的权值向量参数以及隐藏层上的偏置向量参数不需要通过迭代反复调整,ELM 模型可以产生唯一的最优解。ELM 算法具有训练参数少、训练速度快、泛化性能良好等优点<sup>[16]</sup>。

假如输入  $N$  个不同的训练样本  $(\mathbf{x}_i, \mathbf{t}_i), i = 1, 2, \dots, N$ , 其中  $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{im})^T \in \mathbf{R}^m$ ,  $\mathbf{t}_i = (t_{i1}, t_{i2}, \dots, t_{im})^T \in \mathbf{R}^m$ , 则其标准的 SLFNs 模型为

$$\sum_{i=1}^{\tilde{N}} \beta_i g(\mathbf{w}_i \times \mathbf{x}_j + b_i) = o_j, j = 1, 2, \dots, N, \quad (3)$$

式中  $n$  和  $m$  分别为输入和输出层的节点数, sigmoidal 函数  $g(\cdot)$  为激活方程,  $b_i$  为第  $i$  个隐层节点的阈值,  $\mathbf{w}_i = (w_{i1}, w_{i2}, \dots, w_{im})^T$  为第  $i$  个隐层节点和输入节点间的权重向量,  $\beta_i = (\beta_{i1}, \beta_{i2}, \dots, \beta_{im})^T$  为第  $i$  个隐层节点和输出节点间的权重向量,  $\mathbf{w}_i \times \mathbf{x}_j$  表示  $\mathbf{w}_i$  与  $\mathbf{x}_j$  的内积。

选用 sigmoidal 函数作为激活方程, 表达式为

$$g(x) = \frac{1}{1 + \exp(-x)}. \quad (4)$$

SLFNs 模型能够做到零误差的逼近样本, 即

$$\sum_{i=1}^{\tilde{N}} \|o_j - t_j\| = 0, \quad (5)$$

则

$$\sum_{i=1}^{\tilde{N}} \beta_i g(\mathbf{w}_i \times \mathbf{x}_j + b_i) = t_j, j = 1, 2, \dots, N. \quad (6)$$

(6)式可简化为

$$\mathbf{H} \times \boldsymbol{\beta} = \mathbf{T}_e, \quad (7)$$

式中  $\mathbf{H}$  为隐层节点的输出,  $\boldsymbol{\beta}$  为输出权重,  $\mathbf{T}_e$  为期望输出。

$$\mathbf{H}(\mathbf{w}_1, \dots, \mathbf{w}_{\tilde{N}}, b_1, \dots, b_{\tilde{N}}, \mathbf{x}_1, \dots, \mathbf{x}_{\tilde{N}}) = \begin{bmatrix} g(\mathbf{w}_1 \times \mathbf{x}_1 + b_1) & \cdots & g(\mathbf{w}_{\tilde{N}} \times \mathbf{x}_1 + b_{\tilde{N}}) \\ \vdots & & \vdots \\ g(\mathbf{w}_1 \times \mathbf{x}_N + b_1) & \cdots & g(\mathbf{w}_{\tilde{N}} \times \mathbf{x}_N + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}}, \quad (8)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m}, \quad (9)$$

$$\mathbf{T}_e = \begin{bmatrix} \mathbf{T}_{e1}^T \\ \vdots \\ \mathbf{T}_{eN}^T \end{bmatrix}_{N \times m}. \quad (10)$$

为了能够训练单隐层神经网络, 希望  $\tilde{\boldsymbol{\beta}}_i, \tilde{\mathbf{w}}_i$  和  $\tilde{b}_i$  满足

$$\| \mathbf{H}(\tilde{\mathbf{w}}_i, \tilde{b}_i) \tilde{\boldsymbol{\beta}}_i - \mathbf{T}_e \| = \min_{\mathbf{w}, b, \boldsymbol{\beta}} \| \mathbf{H}(\mathbf{w}_i, b_i) \boldsymbol{\beta}_i - \mathbf{T}_e \|, \quad (11)$$

式中  $i = 1, 2, \dots, \tilde{N}$ , (11)式等价于最小化损失函数

$$E = \sum_{j=1}^N \left[ \sum_{i=1}^{\tilde{N}} \beta_i g(\mathbf{w}_i \times \mathbf{x}_j + b_i) - \mathbf{T}_{ej} \right]^2. \quad (12)$$

在 ELM 算法中, 一旦输入权重  $\mathbf{w}_i$  和隐层偏置  $b_i$  被随机确定, 隐层输出矩阵  $\mathbf{H}$  则唯一确定。这样, 训练 SLFNs 可以转化为求解一个线性系统  $\mathbf{H} \times \boldsymbol{\beta} = \mathbf{T}_e$ , 并且输出权重可以确定为

$$\tilde{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T}_e, \quad (13)$$

式中  $\mathbf{H}^+$  是矩阵  $\mathbf{H}$  的广义逆。且可证明求得的解  $\tilde{\boldsymbol{\beta}}$  的范数是最小并且唯一的。

在 ELM 模型中,输出节点的个数应该设置为交通标志训练样本的类别数。假定交通标志共有  $m$  类,且第  $i$  个训练样本  $x_i$  属于第  $k$  类,则输出向量  $o_i$  是一个二进制目标向量,其中第  $k$  个元素为 1,其他的为 0。然后,测试样本的类标可以通过对输出节点的输出向量  $o_i$  取最大值得到,如果  $o_i$  的第  $k$  个元素为最大,则说明测试样本属于第  $k$  类,即

$$o_i = (o_{i1}, o_{i2}, \dots, o_{im})。 \quad (14)$$

对于传统的基于梯度的学习算法(如反向传播算法)可能造成神经网络的过度训练,使其泛化性能变差,因此需要进行交叉验证并且在极小化过程中引入合适的停机准则。文献[17]表明,对于前向反馈性神经网络,权值  $\beta$  的数量级非常重要,权值越小则泛化能力越强,而 ELM 算法中  $\tilde{\beta}$  是最小范数的最小二乘解,因此由(13)式确定的模型具有更好的泛化能力。

### 2.3 基于 PCA 和 ELM 交通标志识别算法

PCA-ELM 算法流程图如图 1 所示,主要利用 HOG-PCA 和 ELM 模型进行交通标志识别。在 ELM 模型训练阶段,首先提取包含 43 类交通标志的训练样本集的特征,将特征保存为文本文件,其中每一行表示一个训练样本的特征,每行的第一个元素是分类识别的期望输出,也就是 43 类交通标志的类标  $[0, 1, 2, \dots, 42]$ ,剩余的是每个样本的 HOG 特征,并且 HOG 特征在训练前要进行预处理使元素归一化到区间  $[-1, 1]$ ;然后使用 PCA 方法对提取出的 HOG 特征进行降维,降维后每个训练样本的 HOG 特征组成特征矩阵  $X$ ,而矩阵  $Y$  代表每个训练样本的期望输出  $[0, 1, 2, \dots, 42]$ , $X$  和  $Y$  组成的特征矩阵  $[Y, X]$  作为 ELM 的输入,经过 ELM 训练后可以得到用于识别的训练模型。在识别阶段,和训练阶段一样,先提取每一张交通标志的 HOG 特征,PCA 降维后的特征与其期望输出组成的特征矩阵  $Z$  作为 ELM 训练好的模型的输入,识别输出向量经过最大值操作后的输出就代表此交通标志的类别。具体步骤如下:

- 1) 提取训练样本集和测试样本集的特征,并保存为文本文件,其中每一行代表一个样本的特征;
- 2) 对提取出的 HOG 特征,设定贡献率阈值大小为 0.99,使用 PCA 方法选取贡献率大于 99% 的主成分,然后在每个样本的头部加上其分类识别期望输出  $[0, 1, 2, \dots, 42]$ ,构成训练、识别的输入  $[Y, X]$  和  $R$ ;
- 3) 对于训练样本集,初始化输入权重  $w_i$  和隐层偏置  $b_i$ ,手动设置隐层节点个数  $\tilde{N}$ ,由(8)式计算出隐层节点的输出矩阵  $H$ ,然后由(13)式计算出输出权重  $\tilde{\beta}$ ;
- 4) 根据步骤 3) 中计算出的  $w_i$  和  $b_i$ ,计算出测试样本集的隐层节点输出矩阵  $H$  和输出权重  $\tilde{\beta}$ ;
- 5) 由(14)式计算出 ELM 输出节点的输出向量  $o_i$ , $o_i$  通过取最大值操作得到每一个测试样本的类标,然后与其期望输出进行比对,可获得测试样本集的分类率。

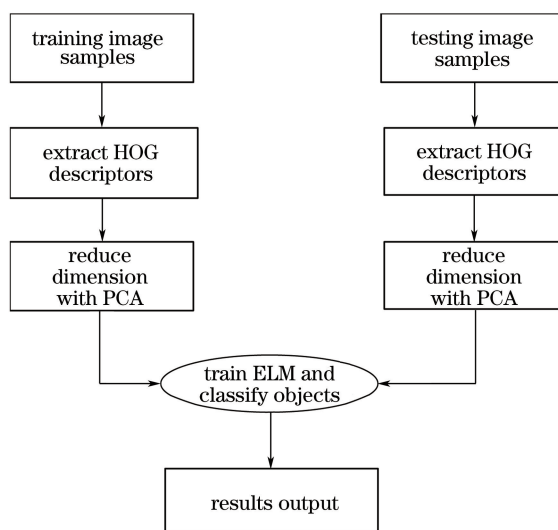


图 1 PCA-ELM 算法流程图

Fig. 1 Flow chart of PCA-ELM algorithm

### 3 实验结果及分析

#### 3.1 实验设置

实验使用 Visual Studio 2013 和 OpenCV 2.4.10 获得 ELM 训练和识别时所用的降维样本特征,然后在 Matlab 2014b 上进行训练和识别。实验所用的计算机 CPU 为 3.6 GHz,内存为 8 GB,硬盘为 7200 r/s。实验使用包含 43 类共 51839 张交通标志的德国交通标志数据库(GTSRB)<sup>[18]</sup>,如图 2 所示。



图 2 GTSRB 交通标志数据库随机数据

Fig. 2 Random data of traffic sign in GTSRB

#### 3.2 ELM、PCA-ELM 算法性能比较

对于 PCA-ELM 算法,隐元个数是影响计算时间和分类识别率的重要参数。如图 3 和 4 所示分别为隐元个数与识别率和计算时间的关系图。由(7)式可知,当  $\tilde{N} = N$  时,SLFNs 模型能够零误差地逼近  $N$  个训练样本。由于训练和测试样本的数目巨大,隐元个数  $\tilde{N}$  应逐渐增大以获得更小的估计误差。由图 3 可知,随着隐元  $\tilde{N}$  个数的递增,分类识别率显著增加,当  $\tilde{N} > 7000$  时识别率增加缓慢,当  $\tilde{N} = 8000$  时甚至有一定程度的下降。由图 4 可知,随着  $\tilde{N}$  的增加,训练时间也大大增加,特别是  $\tilde{N} > 7000$  时训练时间增加显著。综合考虑识别率和计算时间,实验中选取  $\tilde{N} = 7000$ ,对 12630 张测试用交通标志的总识别率能达到 97.69%,总识别时间为 2.016 s,即对于 1 张交通标志来说识别平均耗时 0.16 ms,完全可以满足交通标志的实时识别需求。

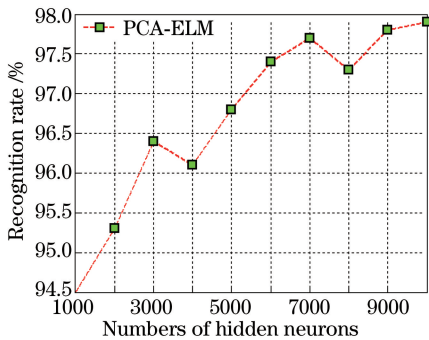


图 3 隐元个数与识别率关系图

Fig. 3 Relationship between recognition rate and number of hidden neurons




图 4 隐元个数与计算时间关系图

Fig. 4 Relationship between computation time and number of hidden neurons

为了验证 PCA 降维的有效性,将直接利用 ELM 算法和 PCA-ELM 算法进行对比实验。如图 5 和 6 所示为 ELM 与 PCA-ELM 计算时间和识别率对比图。由图 5 可知,PCA-ELM 算法比 ELM 算法所用的计算时间略少,这是因为计算复杂度主要是由训练、测试样本集中样本的个数决定的。综上所述,引入 PCA 降维方案,不仅在一定程度上减少了计算复杂度而且可以显著提升识别率。

为了使实验更具针对性,利用 PCA-ELM 算法对 GTSRB 中的速度类、禁令类、危险类等不同类型的交通标志进行分组实验,并将实验结果与文献[19]中表现最优的算法进行比较。比较结果如表 1 所示,表格的最后一行所示数据为 PCA-ELM 算法所得的识别率。由表 1 可知,PCA-ELM 算法的识别率明显高于 ELM 算法,平均提升 2%。

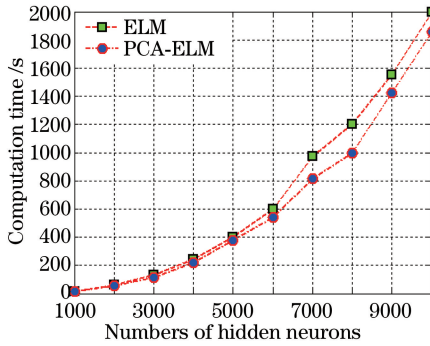


图5 ELM与PCA-ELM计算时间对比图

Fig. 5 Comparison of computation time between ELM and PCA-ELM




图6 ELM与PCA-ELM识别率对比图

Fig. 6 Comparison of recognition rate between ELM and PCA-ELM

表1 各算法对不同类型交通标志的识别率

Table 1 Recognition rate of different traffic signs by each method

Method	Total /%	Derestriction /%	Mandatory /%	Unique /%	Danger /%
Committee of CNNs	99.46	99.72	99.89	99.22	99.07
Human performance	98.84	98.89	99.72	100.0	98.67
Multi-scale CNNs	98.31	94.44	97.18	98.63	98.03
CNN 6HL	97.56	98.33	92.22	99.75	96.42
HOG+LDA+VQ	96.87	99.33	96.72	99.90	95.39
2LDA+5SVM	96.42	99.67	96.94	99.40	94.26
Random forests	96.14	87.50	99.27	98.73	92.08
LDA on HOG 2	95.68	85.53	97.18	98.63	93.73
PCA-ELM	97.69	94.26	99.79	99.85	96.82

从表1可以看出,识别率达到99.46%和98.31%的两种CNNs算法比本文算法识别率高,但是CNNs模型训练过程中需要设置多个动态参数,如下采样层的个数、卷积核函数的个数、下采样的频率等。设置过多的动态参数使得算法往往需要耗费数小时的时间。而PCA-ELM算法的优势在于只需设置隐元个数一个参数,因此可以减少算法的耗时,降低时间复杂度。同时把实验结果与现有的一些算法结果进行比较,比如HLSGD-CNNs<sup>[12]</sup>、MLPs+CNNs<sup>[20]</sup>、HOG+局部二值模式(LBP)+支持向量机(SVM)<sup>[21]</sup>、RIBP+人工神经网络(ANN)<sup>[13]</sup>等,主要以时间复杂度和识别率两个特性来分析和比较各算法的性能。在兼顾识别率和时间复杂度两个特性的前提下,基于PCA-ELM的交通标志识别算法的识别率与其他算法相差不大,但训练耗时却大大减少,比较结果如表2所示,表格的最后一行所示为PCA-ELM算法的识别率和耗时。

表2 各算法的识别率和训练时间

Table 2 Recognition rate and training time by different methods

Method	Recognition rate /%	Time /s
HLSGD-CNNs	99.65	25200
MLPs+CNNs	99.15	86400
HOG+LBP+SVM	98.65	2063
RIBP+ANN	98.62	1800
PCA-ELM	97.69	813

## 4 结 论

提出了一种基于改进PCA和ELM的高效快速交通标志识别算法。该算法对HOG特征进行PCA降维,降维操作在降低时间复杂度的同时,也在一定程度上提升了识别率。上述实验结果表明,基于改进PCA和ELM的交通标志识别算法的识别率可达97.69%,接近人眼的识别率。基于神经网络等识别算法的时间复杂度很高,而PCA-ELM算法可以大大减少的训练时间。该算法在普通配置的电脑上仅仅耗时0.16 ms便

可识别一张交通标志,可以达到实时识别的要求。但是,本文算法对于禁止类交通标志的识别率相对偏低,主要是因为此类交通标志之间具有较大的相似性。今后的工作重点是通过提取交通标志的多种特征更加准确全面地描述交通标志,如分别提取交通标志 LBP 特征和 HOG 特征。LBP 特征主要描述交通标志的内部纹理信息,HOG 特征可以表示交通标志的边缘信息。将目标的多种特征融合,利用融合后的总特征来进行机器学习和目标识别,最终达到提高识别率的目的。

### 参 考 文 献

- [1] Song W J, Fu M Y, Yang Y. An efficient traffic signs recognition method for autonomous vehicle[J]. Robot, 2015, 37(1): 102-111.
- [2] Li Houjie, Qiu Tianshuang, Song Haiyu, *et al.* Separation algorithm of traffic signs based on curvature scale space corner detection[J]. Acta Optica Sinica, 2015, 35(1): 0115002.  
李厚杰, 邱天爽, 宋海玉, 等. 基于曲率尺度空间角点检测的交通标志分离算法[J]. 光学学报, 2015, 35(1): 0115002.
- [3] Zhao Chunhui, You Wei, Qi Bin, *et al.* Real-time anomaly detection algorithm for hyperspectral remote sensing by using recursive polynomial kernel function[J]. Acta Optica Sinica, 2016, 36(2): 0228002.  
赵春晖, 尤伟, 齐滨, 等. 采用多项式递归核的高光谱遥感异常实时检测算法[J]. 光学学报, 2016, 36(2): 0228002.
- [4] Guo Pengyu, Su Ang, Zhang Hongliang, *et al.* Online mixture of random naive bayes tracker combined texture with shape feature[J]. Acta Optica Sinica, 2015, 35(3): 0315002.  
郭鹏宇, 苏昂, 张红良, 等. 结合纹理和形状特征的在线混合随机朴素贝叶斯视觉跟踪器[J]. 光学学报, 2015, 35(3): 0315002.
- [5] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.
- [6] Schmidhuber J. Deep learning in neural networks: An overview[J]. Neural Networks, 2015, 61(4): 85-117.
- [7] Li M, Yuan B. 2D-LDA: A statistical linear discriminant analysis for image matrix[J]. Pattern Recognition Letters, 2005, 26(5): 527-532.
- [8] Cristianini N, Shawe-Taylor J. An introduction to support vector machines and other kernel-based learning methods [M]. New York: Cambridge University Press, 2001: 1-28.
- [9] Zaklouta F, Stanculescu B, Hamdoun O. Traffic sign classification using K-d trees and random forests [C]. Proceedings of 2011 IEEE International Joint Conference on Neural Networks, 2011: 2151-2155.
- [10] Zhang Y K, Hong C Y, Wang C. A real time rectangular speed limit sign recognition system[J]. CAAI Transactions on Intelligent Systems, 2010, 6: 16.
- [11] Fang Zeping, Duan Jianmin, Zheng Banggui. Traffic signs recognition and tracking based on feature color and sncc algorithm[J]. Journal of Transportation Systems Engineering and Information Technology, 2014, 14(1): 47-52.  
房泽平, 段建民, 郑榜贵. 基于特征颜色和 SNCC 的交通标志识别与跟踪[J]. 交通运输系统工程与信息, 2014, 14(1): 47-52.
- [12] Jin J Q, Fu K, Zhang C S. Traffic sign recognition with hinge loss trained convolutional neural networks[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(5): 1991-2000.
- [13] Yin S Y, Peng O Y, Liu L B, *et al.* Fast traffic sign recognition with a rotation invariant binary pattern based feature [J]. Sensors, 2015, 15(1): 2161-2180.
- [14] Shlens J. A tutorial on principal components analysis[J]. Arxiv, 2002, 58(3): 219-226.
- [15] Liu H P, Sun F C, Yu Y L. Multitask extreme learning machine for visual tracking[J]. Cognitive Computation, 2014, 6(3): 391-404.
- [16] Zhu W T, Miao J, Hu J B, *et al.* Vehicle detection in driving simulation using extreme learning machine [J]. Neurocomputing, 2014, 128(5): 160-165.
- [17] Bartlett P L. The sample complexity of pattern classification with neural networks: The size of the weights is more important than the size of the network[J]. IEEE Transactions on Information Theory, 1998, 44(2): 525-536.
- [18] Stallkamp J, Schlipsing M, Salmen J, *et al.* Man vs. computer: Benchmarking machine learning algorithms for traffic

- sign recognition[J]. *Neural Networks*, 2012, 32(2): 323-332.
- [19] Stallkamp J, Schlipsing M, Salmen J, *et al.* The German traffic sign recognition benchmark: A multi-class classification competition[C]. *Proceedings of 2011 IEEE International Joint Conference on Neural Networks*, 2011: 1453-1460.
- [20] Cireşan D, Meier U, Masci J, *et al.* A committee of neural networks for traffic sign classification[C]. *Proceedings of 2011 IEEE International Joint Conference on Neural Networks*, 2011, 42(4): 1918-1921.
- [21] Tang S S, Huang L L. Traffic sign recognition using complementary features[C]. *Proceedings of 2013 IEEE Asian Conference on Pattern Recognition*, 2013: 210-214.