

傅融, 彭森, 逯洋. 基于改进 ResNet 模型的交通标志识别算法[J]. 智能计算机与应用, 2024, 14(5): 221-226. DOI: 10.20169/j.issn.2095-2163.240531

基于改进 ResNet 模型的交通标志识别算法

傅融, 彭森, 逯洋

(吉林师范大学 数学与计算机学院, 吉林 四平 136000)

摘要: 本文提出了一种基于改进残差网络 ResNet50 模型的图像识别方法。通过引入圆形 LBP 算法, 提取图像内部的纹理信息构成纹理图谱; 同时在网络中加入通道注意力机制(Efficient Channel Attention, ECA)提高模型性能, 使得改进后的算法更适合识别交通标志。该方法在 GTSRB 和 BelgiumTS 交通标志数据集上的准确率分别达到 99.7% 和 98.3%, 有效提高了智能系统识别交通标志的准确率和驾驶的安全性。

关键词: 交通标志识别; 通道注意力机制; ResNet 残差网络; 纹理识别

中图分类号: TP391.41

文献标志码: A

文章编号: 2095-2163(2024)05-0221-06

Traffic sign recognition algorithm based on improved ResNet model

FU Rong, PENG Miao, LU Yang

(College of Mathematics and Computer, Jilin Normal University, Siping 136000, Jilin, China)

Abstract: The correct recognition of traffic signs is the key technology of intelligent driving and unmanned driving. This paper proposes an image recognition method based on the modified residual network ResNet50 model. The circular LBP algorithm is introduced to extract the texture information inside the image to form the texture map. The Efficient Channel Attention (ECA) mechanism is added to the network to improve the performance of the model, making the improved algorithm more suitable for recognizing traffic signs. The accuracy rate on the GTSRB and BelgiumTS traffic sign datasets reached 99.7% and 98.3%, respectively, effectively improving the accuracy of recognizing traffic signs and driving safety in the intelligent system.

Key words: traffic sign identification; channel attention mechanism; ResNet residual network; texture recognition

0 引言

在国内经济和科技高速发展的背景下, 汽车工业正在向智能化发展, 自动驾驶成为重要的研究领域。由于驾驶员生理及心理特性, 有可能出现忽视交通标志提示信息的问题, 从而在一定程度上增加了交通事故发生的风险, 因此交通标志的自动识别^[1]就日益受到人们的高度重视。如果辅助驾驶系统能够自动识别相关交通标志, 并将识别结果及时反馈给驾驶者, 则能够有效提高驾驶的安全性, 降低交通事故的发生率。

当前, 该领域的研究均取得了一定的成果。如: 陈龙等学者^[2]提出了将方向梯度直方图(Histogram of Oriented Gradient, HOG)与局部二值模式(Local Binary Patterns, LBP)融合的方法, 实现交通标志的

分类检测, 算法鲁棒性较强, 但存在泛化力弱及检测效率低等问题。唐睢睢^[3]提出了级联融合 HOG、LBP 和 Gabor 滤波器的方法提高了识别准确率, 但其特征维数和时间复杂度过高。马永杰等学者^[4]提出了可用于识别图片不同尺寸特征的卷积神经网络, 但调整参数的过程相对复杂。Zhou 等学者^[5]通过改进 VGG(Visual Geometry Group)卷积神经网络模型加快了模型收敛的速度, 但识别的准确率不高。汪贵平等学者^[6]提出的基于改进 LeNet 卷积神经网络模型的算法, 解决了在交通标志识别中的过度拟合问题, 但网络训练速度过慢。

然而, 如何提高交通标志识别的准确度, 一直是图像识别^[7]领域的重要问题。本文通过引入用于纹理识别的圆形 LBP 算法和高效通道注意力(Efficient Channel Attention, ECA), 提出了一种基于

基金项目: 吉林省创新创业人才基金(2023QN31); 吉林省自然科学基金(YDZJ202301ZYTS157); 吉林省发展和改革委员会创新项目(2021C038-7)。

作者简介: 傅融(1998-), 女, 硕士, 主要研究方向: 交通标志识别; 彭森(1999-), 女, 硕士研究生, 主要研究方向: 纹理识别。

通讯作者: 逯洋(1979-), 女, 博士, 教授, 硕士生导师, 主要研究方向: 机器学习与数值模拟。Email: luyang33@126.com

收稿日期: 2023-12-21

改进 Resnet 网络的交通标志识别方法,并在 GTSRB 和 BelgiumTS 数据集上进行实验,证明了本文算法具有较高的识别准确率。

1 ResNet50 交通标志检测算法

ResNet 网络是 He 等学者^[8]在 2016 年提出的。该网络是由多个卷积层通过层叠的方式组成的残差神经网络。随着神经网络深度的增加,网络模型会出现梯度消失、爆炸、分类精度下降、难以训练、及退化等问题。残差学习思想的提出不仅提高了分类精度,而且加速了 CNN 的训练过程,提升了训练效果,因此本文选择并使用了带有残差结构的 ResNet50 模型,并将其优化后的结构用于交通标志种类的识别研究中。

ResNet 采用一种称作跳跃连接 (Shortcut Connection) 的全新网络连接方式 (见图 1),将输入端与输出端直接相连。研究中, x 为输入, $H(x)$ 为输出, $F(x)$ 为残差映射,可用式 (1) 来表示:

$$H(x) = F(x) + x \quad (1)$$

此结构保留了输入图像的基本原始信息,在不增加计算量的情况下,减少了信息传递损失,有效解决了由于网络深度增加而出现的性能退化问题。




图 1 Shortcut 连接结构

Fig. 1 Shortcut connection structure

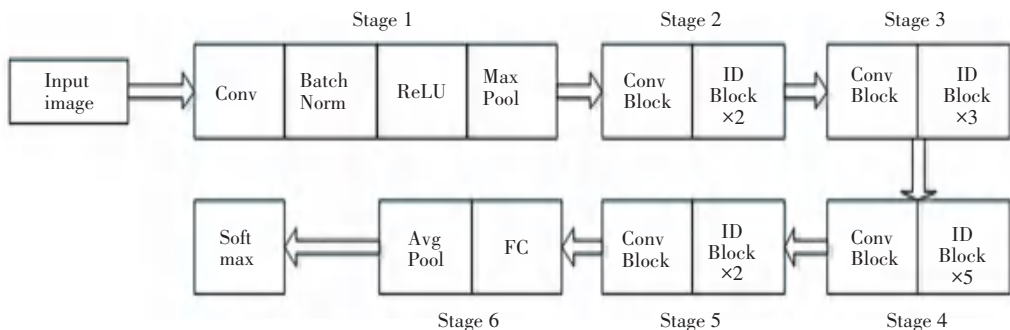


图 3 传统 ResNet50 模型结构

Fig. 3 Traditional ResNet50 model structure

2 基于改进 ResNet 网络的交通标志算法

2.1 LBP 算法

LBP 特征^[9]用于解决多分辨率和旋转情况下

此外,He 等学者^[8]还提出了 Bottle-neck 用来构建更深的网络结构 (见图 2)。该结构由 1 个 3×3 卷积核和 2 个 1×1 的卷积核组成,2 个 1×1 的卷积核分别对特征图进行降维与升维操作,不仅有效减少了计算工作量,而且加快了神经网络的训练速度。ResNet50/101/152 网络均使用 Bottle-neck 结构。




图 2 Bottle-neck 结构

Fig. 2 Bottle-neck structure

传统 ResNet50 网络由 6 个模块构成,分别为输入模块 (stage1)、残差模块 (stage2) ~ (stage5) 以及输出模块 (stage6),传统 ResNet50 模型结构如图 3 所示。其中,输入模块包括卷积层 (CONV)、批归一化层 (Batch Norm)、激活函数 (Relu) 及最大池化层 (MAX POOL),残差模块具有 Conv Block 和 Identity Block 两种形式的残差结构。这里,Conv Block 残差块的输入、输出维度不一致,可改变网络的维度,而 Identity Block 残差块的输入、输出维度一致,残差块的数目分别为 2、3、5、2,每个残差模块由 3 层卷积层构成,卷积核大小分别为 1×1 、 3×3 和 1×1 ;输出模块由平均池化层 (Avg POOL)、全连接层 (FC) 构成,最后通过分类器实现交通标志的分类功能。

图像的纹理分类问题,度量了灰度图像中邻近区域的纹理特征,具有旋转不变、计算简单及对光照具有鲁棒性等众多显著优点。LBP 算法是将灰度图看成一个二维矩阵,通过 3×3 大小的窗口对图像的矩阵

进行整体扫描,窗口中心点位置的灰度值为阈值 (g_c),并将周围邻域的所有像素值与阈值进行比较,比较起点为邻域左上角,按照顺时针方向依次顺序进行比较,如果邻域像素点小于中心像素点的灰度值,那么该像素位置为 0,否则该像素位置为 1。由此方法,最终得到一个二进制编码并将该二进制数转换为对应的十进制数字,转换后得到的数字即为 LBP 值。基本 LBP 算子的获取过程如图 4 所示。LBP 算法的计算公式分别如下:

$$LBP(x_c, y_c) = \sum_{p=0}^{p-1} 2^p S(i_p - i_c) \quad (2)$$

$$S(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3)$$

其中, p 表示领域像素点的个数; i_p 表示领域像素点灰度值; i_c 表示中心像素灰度值; (x_c, y_c) 表示图像的中心像素坐标。




图 4 基本 LBP 算子获取过程

Fig. 4 Basic LBP operator acquisition process

原始的 LBP 算子只覆盖半径固定范围内的区域,无法满足提取不同频率和尺寸纹理的需要。为了实现灰度不变性和旋转不变性的要求, Ojala 等学者^[10]对 LBP 算法进行改进并提出圆形 LBP 算法 (Circular LBP),该算法可以计算任意大小半径的领域,改进后的算子在领域上有着多个等间距的像素点。LBP 算子示例如图 5 所示。图 5 中是为半径为 2、采样点为 4 的 LBP 算子,记作 LBP_4^2 ,算子的半径及采样点可选取任意值。




图 5 圆 LBP 算子示例

Fig. 5 Example of circular LBP operator

(4) 计算:

$$\begin{cases} x_p = x_c + R \cos(\frac{2\pi p}{P}) \\ y_p = y_c - R \sin(\frac{2\pi p}{P}) \end{cases} \quad (4)$$

其中, (x_p, y_p) 表示第 p 个采样点的坐标, (x_c, y_c) 表示邻域的中心坐标。

2.2 注意力机制

近年来,注意力机制作为增强深层神经网络的有效手段,用来提升优化网络性能,其中 SE (Squeeze and Excitation)^[11]作为 2017 年 ImageNet 分类的性能最优,使用压缩通道的方法进行降维,虽然有效降低了模型复杂度,但预测效果欠佳,不利于学习通道间的依赖关系,对提取交通标志的特征造成了较大的干扰。为解决此问题,本文引入高效通道注意力 ECA 机制^[12],该机制是在保持降维不变的情况下学习通道间的依赖关系,能更好地帮助模型重点关注感兴趣的信息,同时抑制无用信息的影响,不仅提高了模型的性能,而且已经广泛应用于目前深度学习的研究中。

ECA 机制模块如图 6 所示。ECA 通道注意力机制首先将 $H \times W \times C$ 的特征图利用全局平均池化功能压缩为 $1 \times 1 \times C$ 的特征图;然后使用大小为 k 的一维卷积,实现通道间的信息交互,并使用 Sigmoid 函数计算各通道的权重;最终将权重与原始输入特征逐元素相乘,即对输入特征图各通道特征进行重新编码,将大的权重分配给重要特征实现增强,将小权重分配给无用特征实现削弱。




图 6 ECA 机制模块图

Fig. 6 ECA mechanism module diagram

2.3 LBP-ResNetECA 网络模型构建

交通标志图片易受到光照强度、角度等诸多条件的影响,使用传统图片格式进行实验会对分类结果造成一定程度的影响。针对于此,本文通过实验将交通标志图像的各像素点都通过圆形 LBP 计算,获得新的交通标志图片,且与原交通标志图像的大小相同,称为 LBP 图谱。本文采用 LBP 图谱作为输入图片,根据 LBP 特征的定义可知,光照变化不会影响到图像的 LBP 值,即 LBP 算法对光照具有鲁棒

通过给定的中心点,各采样点的值可通过式

性,算法效果如图 7 所示。由图 7 可知,LBP 图谱在不同的光照下基本不受任何影响,因此可以很好地应用于交通标志的分类识别中。



(a) 原图



(b) 效果图

图 7 LBP 算法效果图

Fig. 7 Effect diagram of LBP algorithm

因残差神经网络具有完善分类精度下降、梯度消失、模型退化等问题的能力,故本文以 ResNet50 作为基础主干网络,通过引入 LBP 算法对光照强度的干扰有很好的抑制作用,同时在残差中嵌入ECA

通道注意力机制,改进后的残差结构如图 8 所示。将通道注意力模块添加在第三次卷积操作后,用很小的计算代价不仅提升了网络的性能,而且强化了提取特征的能力。改进后的 LBP-ResNetECA 模型结构中的 ECA-ResNet 模块为图 8 改进后的残差块。继而给出改进后的 LBP-ResNetECA 模型结构如图 9 所示。

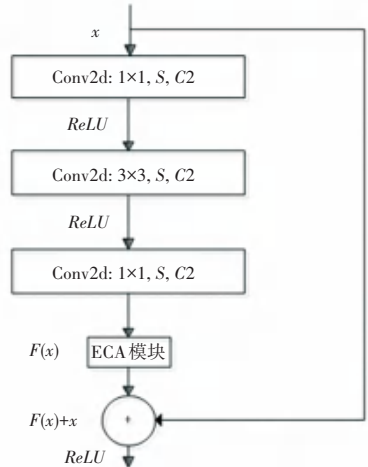


图 8 嵌入通道注意力模块的残差结构

Fig. 8 Residual structure of the embedded channel attention module

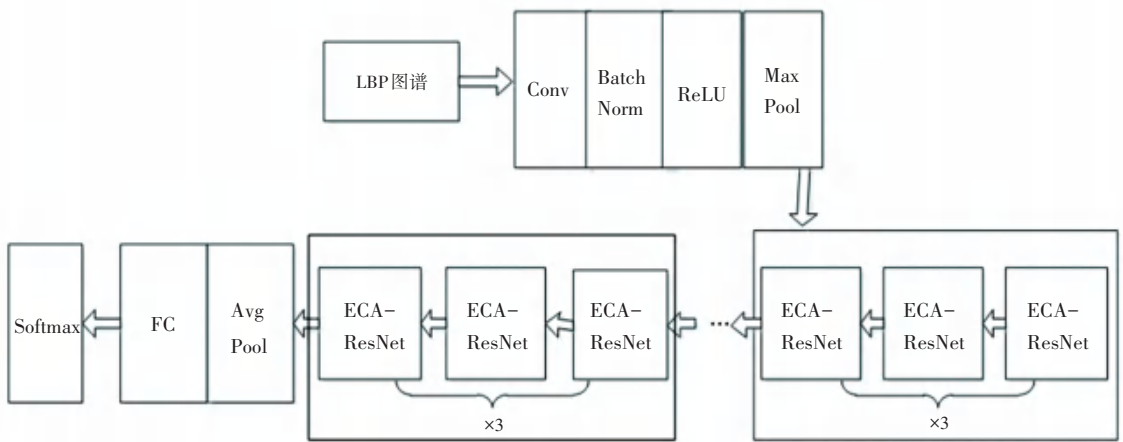


图 9 LBP-ResNetECA 模型

Fig. 9 LBP-ResNetECA model

3 实验

3.1 数据集

本文分别在 GTSRB^[13] 与 BelgiumTS^[14] 两个公开数据集上进行实验。其中,GTSRB 数据集是通过截取车载摄像头在车辆行驶过程中拍摄的视频获得,其中包括 43 类不同类型的交通标志图像,数据样本共 39 209 张图片,分别是:训练集图片 31 368

张,测试集图片 7 841 张,每张图片仅包含一个交通标志且含有 10%左右的边缘区域。BelgiumTS 数据集包括 62 类不同类型的交通标志图像,数据样本共 7 078 张图片,其中训练集图片 5 687 张,测试集图片 1 391 张。图像像素尺寸大小为 15×15 至 250×250 之间,本实验固定图片输入尺寸为 224×224。由于 2 个数据集图片的质量参差不齐,受光照、雨雾、模糊、人为涂抹、遮挡等诸多条件的影响,非常适

合用以校验算法的鲁棒性能和实时性能。不同种类的交通标志实例如图 10 所示。



图 10 不同种类交通标志实例

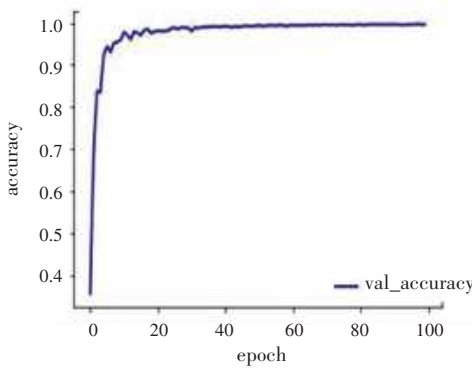
Fig. 10 Examples of different types of traffic signs

3.2 实验结果与分析


网络训练之后,即将改进的模型在实验数据上

进行迭代训练,绘制出在 2 个交通标志数据集训练过程中的准确度曲线如图 11 所示。由于数据集的数量庞大,数据集很难一次性通过网络,所以本文对数据集采用分批处理。经过多次试验,设置 *batch_size* 为 16,即 16 个图像为一组,训练轮次为 100,初始学习率为 0.01 时,训练效果最佳。

在图 11(a)中,模型训练 40 轮次以后趋于平稳;图 11(b)中,模型训练 60 轮次以后趋于平稳,直到第 100 轮次也未发生剧烈波动,证明模型已经收敛到稳定状态。本文算法在 GTSRB 数据集和 BelgiumTS 数据集的准确率分别达到了 99.7%和 98.3%。以上的结果表明,改进后的模型能够获得优异的训练结果。



(a) GTSRB 准确率曲线图



(b) BelgiumTS 准确率曲线图

图 11 数据集模型训练结果图

Fig. 11 Model training results of data set

3.3 对比实验

为了全面评价改进模型对交通标志检测的效果,本文与标准模型进行纵向对比,实验结果见表 1、表 2。

表 1 本文与其他方法在 GTSRB 的结果对比

Table 1 Comparison of results in GTSRB between this paper and other methods

方法	识别准确率/%
BP	81.7
HOGv+CLBP+ELM ^[15]	92.9
LBP ^[16]	93.4
MobileNet ^[17]	94.6
ResNet34 ^[8]	96.2
HOG+Gabor ^[18]	97.7
Single-linkage+CNN ^[19]	98.5
AlexNet+SE ^[20]	99.3
LBP-ResNetECA	99.7

表 2 本文与其他方法在 BelgiumTS 的结果对比

Table 2 Comparison of results in BelgiumTS between this paper and other methods

方法	识别准确率/%
SVM ^[21]	67.8
ELM ^[22]	71.8
BP	83.8
MobileNet ^[17]	94.2
Single-linkage+CNN ^[19]	95.0
ResNet34 ^[8]	96.4
MCF+ELM ^[23]	96.9
AlexNet+SE ^[20]	98.1
LBP-ResNetECA	98.3

通过对比上述方法的实验结果可知,基于 Gabor、SVM 等基础方法的识别准确率较低,然而基于深度 CNN 方法的识别准确率较高,浅层神经网络 BpNet 等虽有不错表现,但面对复杂识别类别时准

准确率较低,对于复杂图案标志的识别效果不好,深层神经网络模型对交通标志数据集有着更加出色的辨认能力。由表1、表2可知,改进后的LBP-ResNetECA模型在GTSRB交通标志数据集上的准确率为99.7%,在BelgiumTS交通数据集的准确率为98.3%,高于实验中作为对照组的图像识别算法,进一步验证了LBP-ResNetECA的有效性。

4 结束语

针对实际场景中的交通标志识别网络模型在达到一定深度时易出现收敛速度慢、梯度消失、识别精度不高等问题。本文在传统ResNet网络基础上引入圆形LBP纹理识别算法和ECA通道注意力机制,提出了LPB-ResNetECA网络算法。在GTSRB及BelgiumTS交通标志数据集的识别准确率分别达到99.7%和98.3%,高于实验中作为对照组的图像识别算法。本文所提模型对智能车辆系统和无人驾驶具有一定的参考意义。

参考文献

- [1] SAADNA Y, BEHLOUL A. An overview of traffic sign detection and classification methods[J]. *International Journal of Multimedia Information Retrieval*, 2017, 6(3): 193-210.
- [2] 陈龙, 潘志敏, 毛庆洲, 等. 利用HOG-LBP自适应融合特征实现禁令交通标志检测[J]. *武汉大学学报(信息科学版)*, 2013, 38(2): 191-194.
- [3] 唐睢睢. 交通标志识别算法研究[D]. 北京: 北京交通大学, 2014.
- [4] 马永杰, 程时升, 马芸婷, 等. 多尺度特征融合与极限学习机结合的交通标志识别[J]. *液晶与显示*, 2020, 35(6): 572-582.
- [5] ZHOU Shuren, LIANG Wenlong, LI Junguo. Improved VGG model for road traffic sign recognition[J]. *Computers, Materials, and Continuum (in English)*, 2018, 57: 11-24.
- [6] 汪贵平, 盛广峰, 黄鹤, 等. 基于改进LeNet-5网络的交通标志识别方法[J]. *科学技术与工程*, 2018, 18(34): 78-84.
- [7] YU F, XUE F W. Study on motion blur image research [J]. *Advanced Materials Research*, 2013, 2526(753): 2976-2979.
- [8] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, USA: IEEE, 2016: 770-778.
- [9] TIMO O, MATTI P, DAVID H. A comparative study of texture measures with classification based on featured distributions[J]. *Pattern Recognition*, 1996, 29(1): 51-59.
- [10] OJALA T, PIET IKAINEN M, MAENPAA T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 24(7): 971-987.
- [11] HU Jie, SHEN Li, ALBANIE S, et al. Squeeze-and-excitation networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(8): 2011-2023.
- [12] WANG Qilong, WU Banggu, ZHU Pengfei, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]//*Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway, USA: IEEE Press, 2020: 1-12.
- [13] STALLKAMP J, SCHLIPSING M, SALMEN J, et al. The German traffic sign recognition benchmark: A multi-class classification competition[C]//*The 2011 International Joint Conference on Neural Networks*. San Jose, USA: IEEE, 2011: 1453-1460.
- [14] MATHIAS M, TIMOFTE R, BENENSON R, et al. Traffic sign recognition - How far are we from the solution? [C]//*International Joint Conference on Neural Networks*. Dallas, USA: IEEE, 2013: 1-8.
- [15] 吴迪, 屈宗顺, 赵葵银, 等. 基于HOGv-CLBP特征融合和ELM的交通标志识别[J]. *光电子·激光*, 2020, 31(6): 621-627.
- [16] BERKAYA S K, GUNDUZ H, OZSEN O, et al. On circular traffic sign detection and recognition[J]. *Expert Systems with Applications*, 2016, 48: 67-75.
- [17] SANDLER M, HOWARD A, ZHU M L, et al. Mobile-NetV2: Inverted residuals and linear bottlenecks[C]//*Proceedings of the 2018 IEEE / CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, USA: IEEE, 2018: 4510-4520.
- [18] 梁敏健, 崔啸宇, 宋青松, 等. 基于HOG-Gabor特征融合与Softmax分类器的交通标志识别方法[J]. *交通运输工程学报*, 2017, 17(3): 151-158.
- [19] 伍锡如, 雪刚刚. 基于图像聚类的交通标志CNN快速识别算法[J]. *智能系统学报*, 2019, 14(4): 670-678.
- [20] 何锐波, 狄岚, 梁久祯. 一种改进的深度学习的路交通标志识别算法[J]. *智能系统学报*, 2020, 15(6): 1121-1130.
- [21] 陈兴, 贾银山. 基于支持向量机的交通标志识别方法研究[J]. *科学技术与工程*, 2011, 11(8): 1751-1754.
- [22] 徐岩, 王权威, 韦镇余. 一种融合加权ELM和AdaBoost的交通标志识别算法[J]. *小型微型计算机系统*, 2017, 38(9): 2028-2032.
- [23] 孙伟, 杜宏吉, 张小瑞, 等. 基于CNN多层特征和ELM的交通标志识别[J]. *电子科技大学学报*, 2018, 47(3): 343-349.