

Traffic Sign Recognition Algorithm Based on Weak Light^{*}

ZHANG Na, LI Zhigang^{*}

(College of Artificial Intelligence, North China University of Science and Technology, Tangshan Hebei 063210, China)

Abstract: Aiming at the problem that traffic signs are difficult to be recognized due to the poor quality of images obtained by automatic driving sensing equipment under weak light environment, a traffic sign recognition method under weak light is proposed. An improved Regnet model is used to identify traffic sign images illumination-enhanced by RetinexNet model. Experimental results show that the proposed recognition method can reach 99.67% of accuracy, 100% of F1 value, 100% of recall rate and 100% of precision on the data set of traffic signs under weak light. Compared with the classical deep learning Resnet101 model, the four evaluation indexes are improved by 1.43%, 1.91%, 1.9% and 1.48% respectively.

Key words: traffic sign recognition; regnet; RetinexNet; ACBlock; SE

EEACC: 6135 **doi:** 10.3969/j.issn.1005-9490.2023.01.018

一种弱光照交通标志识别方法^{*}

张娜, 李志刚^{*}

(华北理工大学人工智能学院, 河北唐山 063210)

摘要: 针对弱光照环境下自动驾驶感知设备获取的图像质量不佳, 从而导致交通标志难以识别的问题, 提出了一种针对弱光照的交通标志识别方法, 即将弱光照交通标志图片经 RetinexNet 模型进行光照增强后, 采用改进 Regnet 模型对光照增强的交通标志图片进行识别。实验结果表明, 在弱光照交通标志数据集上, 所提出的识别方法准确率可达 99.67%, F1 值可达 100%, 召回率可达 100%, 精确度可达 100%。与经典深度学习 Resnet101 模型相比, 四项评价指标分别提高了 1.43%, 1.91%, 1.9% 和 1.48%。

关键词: 交通标志识别; Regnet; RetinexNet; ACBlock; SE

中图分类号: U463.6

文献标识码: A

文章编号: 1005-9490(2023)01-0103-06

受自然天气的影响, 难免会出现阴天雨雪或傍晚等光照较弱的情况, 使得自动驾驶感知设备获取交通标志图像质量不佳, 给交通标志识别带来困难。面对弱光照环境下交通标志识别困难的情况, 进行增强光照任务, 可以达到提高识别准确率的目的。

近些年, 许多研究人员致力于寻找弱光图像增强方案, Guo 等^[1]提出 LIME, 仅利用结构先验估计光照, 并使用反射作为最终增强的结果, 验证了它在增强质量和效率方面优于最新技术。Li 等^[2]提出了基于 Retinex 的联合微光增强和噪声去除方法, 实验结果证明这两种方法在弱光图像增强方面的有效性。廖小兵^[3]提出一种光照不均下图像增强仿真, 此方法提高了光照不均匀图像亮度。尽管上述方法均能增强图像光照, 但依旧限制于模型照明能力与分解反射, 很难找到一组适合各种场景的图像约束

条件。而且, 上述方法大多需要手动调整参数, 费时费力。此外, 弱光图像增强任务也开始采用卷积神经网络进行处理。典型应用有超分辨率^[4]和去除雨水^[5]等任务。Lore 等^[6]提出了一种堆叠稀疏去噪自编码器进行弱光增强降噪方案, 但是, 此方案缺少对弱光照图像本质的考虑。

针对上述问题, 为了减少参数的调整和更好地体现弱光图像的本质, 本文采用 RetinexNet^[7]模型对交通标志图片进行光照增强操作, 该方法不仅在弱光增强中带来不错的视觉质量, 而且为图像分解提供了良好的表征。

对交通标志图片进行光照增强操作, 有利于后续的识别操作。目前, 用于弱光照环境下的交通标志识别相对较少。Khan 等^[8]提出了一种具有照明预处理能力的智能交通标志识别系统。在具有挑战性的韩

项目来源: 国家科技部重点研发专项项目(2017YFE0135700); 河北省工业智能感知重点实验室 唐山市科技计划项目(19150230E)

收稿日期: 2021-12-07

修改日期: 2022-01-07

国交通标志检测数据集上平均精度可达 90.07%，在德国交通标志检测数据集上平均精度为 100%。屈志华等^[9]提出一种改进的基于图像关键点统计变换特征的 Adaboost 集成算法，实验结果显示，对于低光照环境下的交通标志图像，此算法的检测精确率为 94.96%，在复杂光照环境下具有良好的稳健性。Xu 等^[10]提出了一种基于自适应颜色阈值分割和形状对称性假设检验的交通标志检测方法，结果表明在德国交通标志检测基准数据集上准确率超过 94%，证明该方法具有更高的检测精度和时间效率。任条娟等^[11]提出一种基于胶囊神经网络的交通标志识别算法。仿真结果表明，该方法在训练阶段具有较快的训练速度，在识别阶段可有效提高弱光照图片的查全率，提高交通标志的识别率。上述方法虽能解决各种复杂环境下交通标志识别与检测任务，但针对特定弱光照环境下交通标志过暗，识别困难的问题，相关研究相对较少，交通标志识别的准确率还有待提高。

针对上述问题，提出一种弱光照交通标志识别方法，即先用 RetinexNet 模型对交通标志图片进行光照增强任务，然后将光照增强的交通标志图片采用改进 Regnet 模型进行识别。

1 弱光照环境下交通标志识别

1.1 弱光照交通标志识别模型

针对弱光照环境下交通标志识别困难的情况，提出一种弱光照交通标志识别方法。图 1 给出了弱光照交通标志识别模型，此模型一共包含两大部分，第一部分采用 RetinexNet 模型来增强交通标志光照，从而提高交通标志亮度，使得交通标志更容易被看见。第二部分是交通标志识别模型，采用改进 Regnet 模型来训练弱光照交通标志数据集，得到识别模型的 F1 值，召回率，精确度，准确率四项指标，用于评价所提出模型的性能。

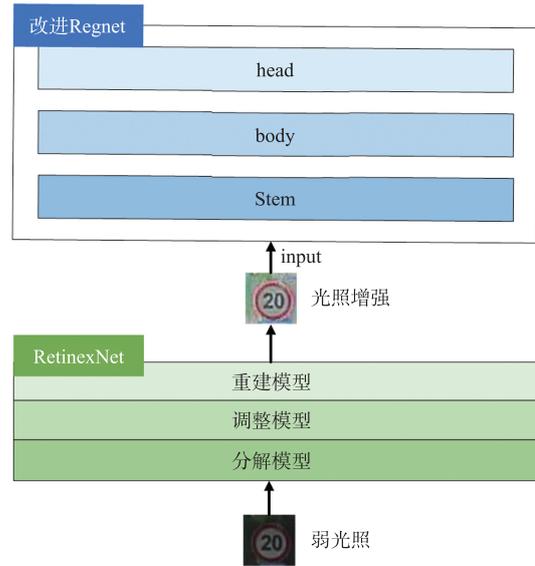


图 1 弱光照交通标志识别模型

1.1.1 RetinexNet 模型

首先对弱光照交通标志图像进行 RetinexNet 增强光照实验。如公式 (1) 所示，Retinex 原理是由反射分量 R 和光照分量 I 相乘得到图像 S ：

$$S = I \times R \tag{1}$$

公式中反射分量 R 是图像本身，光照分量 I 是外界光照对图像的影响，一般通过校正光照分量 I 或者去除光照影响，使图像增强。

图 2 给出了 RetinexNet 增强交通标志光照流程图，可以看出四张不同种类弱光照交通标志图片，经过 RetinexNet 模型的分解模型、调整模型和重建三部分，最终得到其光照增强交通标志图片。下边分别详述 RetinexNet 模型三大组成部分。

第一部分是分解模型。分解光照分量 I 和反射分量 R ，该模型得到低光照图像的光照分量 I_{low} 与反射分量 R_{low} ，正常光照图像的光照分量 I_{normal} 与反射分量 R_{normal} 是通过共享参数和输入正常光照与低光照图像对来实现的。模型的优化通过 I_{low} 、 R_{low} 、 I_{normal} 、

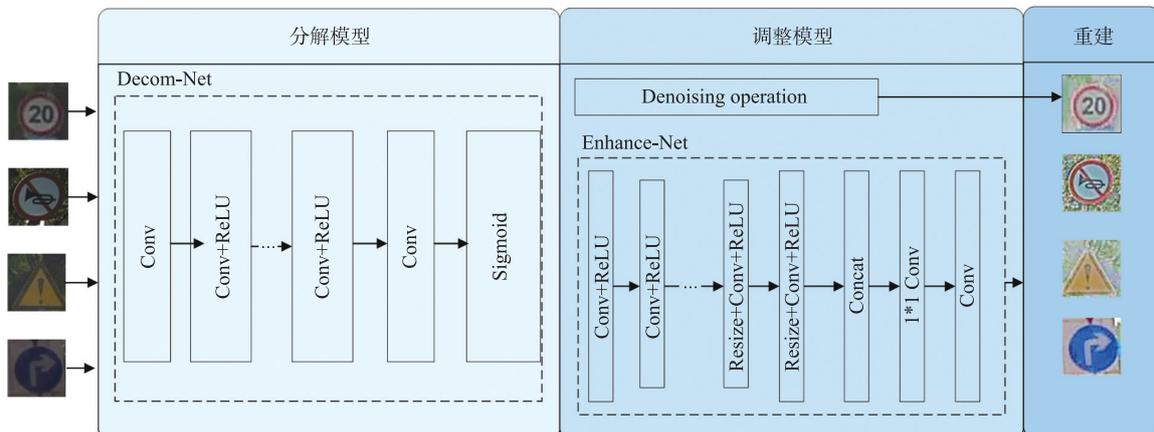


图 2 RetinexNet 增强交通标志光照流程图

R_{normal} 分量之间约束关系来实现, 目标函数是约束关系的关键。分解模型损失函数如式(2)所示:

$$L = L_{recon} + \lambda_{ir} L_{ir} + \lambda_{is} L_{is} \quad (2)$$

式中: L_{recon} 是重建损失, L_{ir} 是反射分量一致性损失, L_{is} 是光照分量平滑损失。

重建损失旨在使模型分解出来的反射分量 R 和光照分量 I 能够尽可能重建出对应的原图。重建损失如式(3)所示:

$$L_{recon} = \sum_{i=low, normal} \sum_{j=low, normal} \lambda_{ij} |R_i \times I_j - S_j|_1 \quad (3)$$

反射分量一致性损失中, 反射分量 R 与光照无关, 因此成对的正常光照和低光照图像的反射分量 R 应一致。反射分量一致性损失如式(4)所示:

$$L_{ir} = \|R_{low} - R_{normal}\|_1 \quad (4)$$

光照分量平滑损失作用是反射分量 R 上平滑区域对应到光照分量 I 上也要平滑。光照分量平滑损失如式(5)所示:

$$L_{is} = \sum_{i=low, normal} \|\nabla I_i \times \exp(-\lambda_g \nabla R_i)\| \quad (5)$$

第二部分是调整模型。调整模型主要是噪声进行抑制反射分量 R 和校正光照分量 I 。对 I_{low} 调整: 由于多尺度连接能够提高自适应调整能力, 因此提出了多尺度 Enhance-Net 光照网络来调节。对 R_{low} 调整: 采用了 BM3D 算法对 R_{low} 中被放大的噪声抑制并引入了光照策略。

第三部分是重建。重建是用调整完的反射分量 R 和光照分量 I 恢复出正常光照图像。由调整后的 R_{low} 和 I_{low} 相乘得到正常光照图像。

1.1.2 改进 Regnet 模型

本文采用改进 Regnet 模型对弱光照环境下的交通标志进行识别, 为了更好地保证实时性且提高识别准确率, 选择了简单而快速的空间设计网络 Regnet^[12]。图 3 给出了改进 Regnet 模型, 可以看出 Regnet 模型由 Stem, Body, Head 三大部分组成, 其中

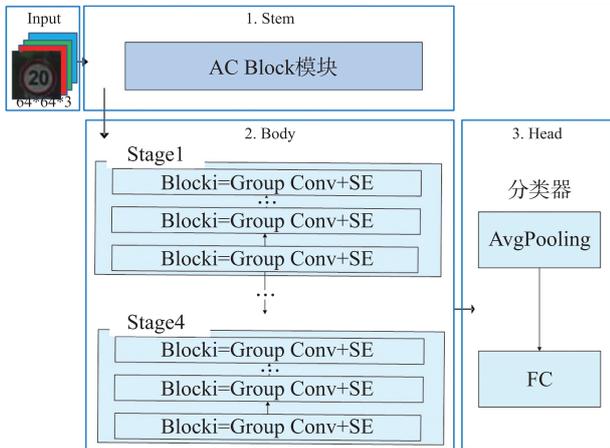


图 3 改进 Regnet 模型

Stem 部分采用 Asymmetric Convolution Net (ACNet)^[13] 中的 ACBlock 模块, Body 部分在组卷积层 (Group Conv) 后加入注意力机制^[14] (SE) 模块。本文通过采用 ACBlock 模块与加入 SE 模块来提高 Regnet 模型的识别准确率, 得到改进 Regnet 模型。

Stem 部分是用来提取交通标志图像特征的, 为了提高交通标志图像特征的提取能力, Stem 部分采用 ACBlock 模块, 图 4 给出了 ACBlock 模块结构图, 可以看出 ACBlock 模块将原来的 3×3 卷积层替换成 $3 \times 1 + 3 \times 3 + 1 \times 3$ 卷积层, 然后将 3 个卷积层的计算结果进行融合得到输出。其中, 3×1 是竖形卷积核, 提高交通标志图像的纵向特征; 1×3 是横形卷积核, 提高交通标志图像的横向特征; 3×3 卷积核, 用来提取交通标志图像的基础特征。

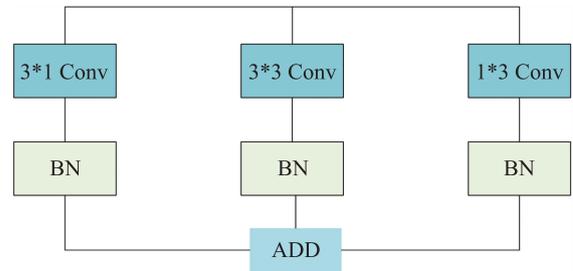


图 4 AC Block 模块

图 3 中 Body 部分由 4 个 Stage 堆叠而成, 每个 Stage 由一系列 Block 堆叠而成, 可以看出 Block 中的每个组卷积层 (Group Conv) 后都加入 SE 模块, 实现从交通标志特征中选择出对图像识别更关键的特征, 抑制其他无用特征的作用。图 5 给出了 SE 模块, 可以看出 SE 模块由一个全局平均池化和两个全连接层组成。其中, 全连接层 1 (FC1) 的激活函数是 ReLU, 全连接层 2 (FC2) 的激活函数是 Sigmoid。

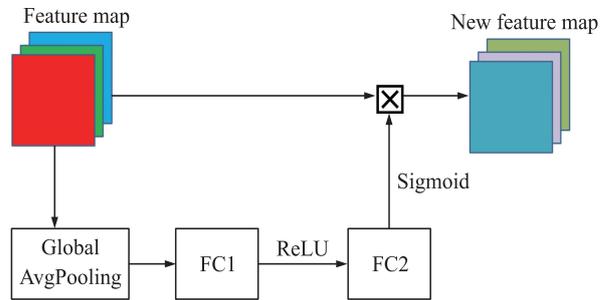


图 5 注意力机制 (Squeeze-and-Excitation, SE) 模块

2 实验

2.1 实验数据

实验数据来自中国交通标志检测数据集^[15] (CSUST Chinese Traffic Sign Detection Benchmark,

CCTSDB),数据集包括禁止标志、警告标志、指示标志三类。

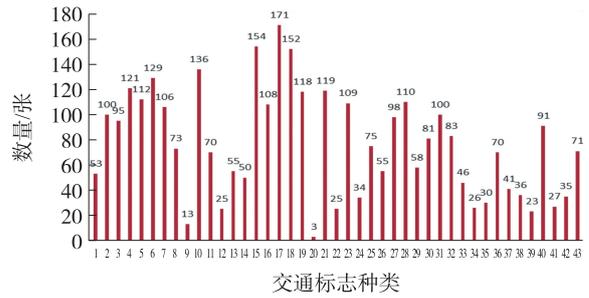
关于弱光照数据集的收集过程进行如下说明,图 6 给出了全景截取交通标志,可以看出根据数据集中所给出的标注框,只截取出全景图的交通标志部分并保存,从而得到一整套交通标志图片。然后,将所有交通标志图片灰度化,设定一张交通标志图片像素值在 0 到 79 范围为偏暗,若偏暗像素所占比例超过整张交通标志图片的 80%,则这张图片被认定为弱光照的交通标志。最后按照种类划分,把认定为弱光照的交通标志保存。图 7 给出了 43 类交通标志,可以看出一共保存了 43 类弱光照交通标志图片。图 8 给出了扩充前后的交通标志数量,从图 8(a)中可以看出交通标志图片数量分布不均衡,这不利于交通标志识别。因此,本实验采用数据增强技术,对交通标志图片数量较少的类别进行翻转、旋转角度和提高对比度的方法,增加弱光照交通标志数据集的数量。图 8(b)给出了扩充后的交通标志图片数据集,可以看出每类数量在 105 到 186 张之间,交通标志图片数量均衡化,有利于后续交通标志识别。本文一共 6 104 张交通标志图片,将交通标志图片按照 7:3 比例划分,训练集为 4 290 张图片,测试集为 1 814 张图片。



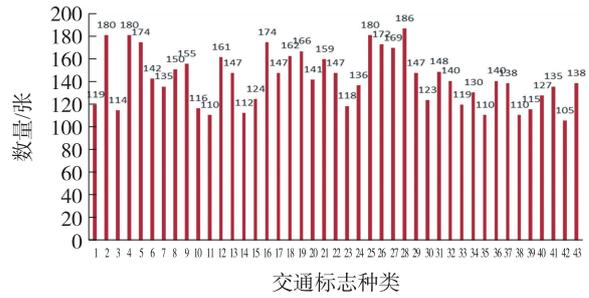
图 6 全景截取交通标志



图 7 43 类交通标志



交通标志种类
(a) 扩充前



交通标志种类
(b) 扩充后

图 8 扩充前、后的交通标志图片数量

2.2 实验平台和评价指标

实验平台为 Win10 操作系统和 Python 实验环境,硬件配置为:GPU 为 NVIDIA GeForce GTX1650,显存大小为 4GB,CPU 为 intel (R) Core (TM) i5-9300H,内存大小为 8GB。

为衡量改进 Regnet 模型在弱光照交通标志数据集上的性能,选用准确率 (Accuracy),精确度 (Precision),召回率 (Recall) 和 F1 值为评价指标。评价指标公式如式(6)~式(9)所示:

$$Accuracy = \frac{TP+TN}{\text{总样本}} \quad (6)$$

$$Precision = \frac{TP}{TP+FP} \quad (7)$$

$$Recall = \frac{TP}{TP+FN} \quad (8)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (9)$$

TP:被预测为正类的正样本,TN:被预测为负类的负样本,FP:被预测为正类的负样本,FN:被预测为负类的正样本。

2.3 实验结果分析

为证明弱光照交通标志方法的有效性,首先用 RetinexNet 模型对交通标志图片进行增强光照实验,然后采用改进 Regnet 模型对增强光照的交通标志图片进行识别。

2.3.1 RetinexNet 增强光照实验

本节用 RetinexNet 模型对交通标志图片进行增

强光照实验, 大致流程为输入弱光照交通标志图片数据集, 用 RetinexNet 模型进行处理, 然后输出光照增强的交通标志图片。图 9(a)、图 9(b) 为弱光照交通标志及其像素概率直方图; 图 10(a)、图 10(b) 为光照增强的交通标志及其像素概率直方图。从图 9(a) 和图 10(a) 可以看出经 RetinexNet 模型增强光照后, 交通标志图片亮度提高, 从图 9(b) 和图 10(b) 的像素概率直方图可以看出经 RetinexNet 模型增强光照后, 交通标志图片 RGB 三原色在 0 到 255 像素值范围内分布更均匀、更广了, 这代表着交通标志图片由暗变亮, 图像亮度的提高使交通标志更容易被看到, 有利于交通标志识别。

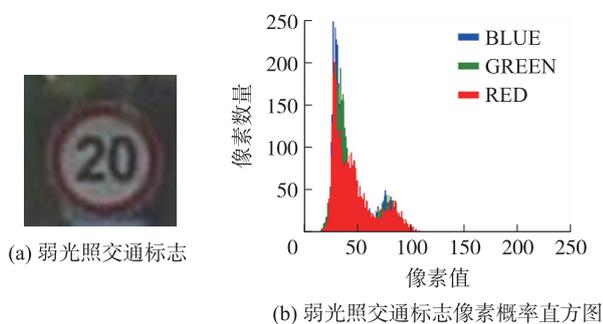


图 9 弱光照交通标志和弱光照交通标志像素概率直方图

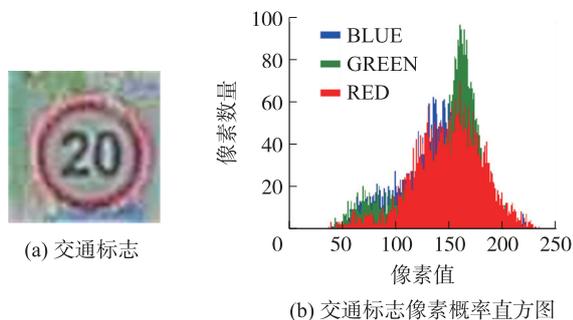


图 10 光照增强的交通标志和交通标志像素概率直方图

2.3.2 改进 Regnet 模型识别实验

本文采用改进 Regnet 模型对上述经过 RetinexNet 增强光照的交通标志图片进行识别。此外, 本文对比 Resnet^[16] 模型, Densenet^[17] 模型, Mobilenet^[18] 模型, 表 1 给出了弱光照交通标志识别结果, 可以看出在经过 RetinexNet 处理的弱光照数据集上, 本文所提出的改进 Regnet 模型相对于 Resnet101, Densenet121 深度学习模型和 MobilenetV2 轻量级神经网络模型, 在四项评价指标上, 效果均更优, 与经典深度学习 Resnet101 模型相比, 四项评价指标分别提升 1.43%、1.91%、1.9% 和 1.48%。因此, 改进 Regnet 模型提高了在弱光照交通标志识别上的准确率, F1 值, 召回率和精度, 对弱光照环境下的交通标志识别具有实际意义。

表 1 弱光照交通标志识别结果

模型	准确率/%	F1 值/%	召回率/%	精度/%
Resnet101	98.24	98.09	98.10	98.52
Densenet121	98.13	95.90	96.75	95.53
MobilenetV2	98.68	98.66	98.67	98.69
改进 Regnet	99.67	100	100	100

为进一步验证弱光照交通标志方法的实用性, 从唐山市真实夜间环境中随机采集四张交通标志全景图片, 然后截取其中的交通标志图像用于识别, 表 2 给出了弱光照交通标志识别情况, 可以看出第一张交通标志图片识别结果属于 30 类, 识别正确; 第二张交通标志图片识别结果属于 1 类, 识别正确; 第三张交通标志图片识别结果属于 24 类, 识别正确。

表 2 弱光照交通标志识别情况

交通标志	所属类别	识别正确与否
	30	正确
	1	正确
	24	正确
	23	错误

第四张交通标志图片识别结果显示为 37 类, 实际应为 23 类, 识别错误, 说明改进 Regnet 模型 F1 值, 召回率及精度尽管可达 100%, 但实际准确率为 99.67%, 实际应用中不可能完全识别正确, 且我国交通标志不止本文采集的 43 类, 因此, 进一步采集弱光照交通标志图片或者采用权威的弱光照数据集进行研究, 来达到实际交通场景应用的目的, 将是本文下一步研究重点工作。

3 结语

对于自动驾驶的安全而言, 弱光照交通标志识别具有重要的研究意义, 针对弱光照环境下交通标志识别困难的问题, 准确性高的弱光照交通标志自动识别模型亟需研究。本文提出一种弱光照交通标志识别方法, 首先将交通标志图片通过 RetinexNet 模型进行光照增强任务, 然后使用改进 Regnet 模型对光照增强的交通标志图片进行识别。和一些经典的深度学习模型相比, 改进 Regnet 模型的识别准确

率, F1 值, 召回率, 精确度均有所提高, 对弱光照交通标志识别有一定的实际应用价值。

参考文献:

- [1] Guo X J, Li Y, Ling H B. LIME: Low-Light Image Enhancement via Illumination Map Estimation [J]. IEEE Transactions on Image Processing, 2017, 26(2): 982-993.
- [2] Li M P, Liu J Y, Yang W H, et al. Joint Denoising and Enhancement for Low-Light Images via Retinex Model [C]//14th International Forum on Digital TV and Wireless Multimedia Communications, Shanghai, China, 2017: 91-99.
- [3] 廖小兵. 光照不均下图像明暗区域关键目标增强仿真 [J]. 计算机仿真, 2018, 35(7): 179-182, 272.
- [4] Yang W H, Xia S F, Liu J Y, et al. Reference Guided Deep Super-Resolution via Manifold Localized External Compensation [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2019, 29(5): 1270-1283.
- [5] Qian R, Tan R T, Yang W, et al. Attentive Generative Adversarial Network for Raindrop Removal from a Single Image [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018: 2482-2491.
- [6] Lore K G, Akintayo A, Sarkar S. LLNet: A Deep Autoencoder Approach to Natural Low-Light Image Enhancement [J]. Pattern Recognition, 2017, 61: 650-662.
- [7] Wei C, Wang W J, Yang W H, et al. Deep Retinex Decomposition for Low-Light Enhancement [C]//BMVC 2018: British Machine Vision Conference, Newcastle, UK, 2018; arXiv: 1808.04560.
- [8] Khan J A, Yeo D, Shin H. New Dark Area Sensitive Tone Mapping for Deep Learning Based Traffic Sign Recognition [J]. Sensors, 2018, 18(11): 3776.
- [9] 屈治华, 邵毅明, 邓天民, 等. 复杂光照条件下的交通标志检测与识别 [J]. 激光与光电子学进展, 2019, 56(23): 140-147.
- [10] Xu X H, Jin J C, Zhang S Q, et al. Smart Data Driven Traffic Sign Detection Method Based on Adaptive Color Threshold and Shape Symmetry [J]. Future Generation Computer Systems, 2018, 94: 381-391.
- [11] 任条娟, 陈鹏, 陈友荣, 等. 基于胶囊神经网络的交通标志识别算法研究 [J]. 汽车技术, 2020(12): 6-11.
- [12] Radosavovic I, Kosaraju R P, Girshick R, et al. Designing Network Design Spaces [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, IEEE, 2020: 10425-10433.
- [13] Ding X, Guo Y, Ding G, et al. ACNet: Strengthening the Kernel Skeletons for Powerful CNN via Asymmetric Convolution Blocks [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, South Korea, 2019: 1911-1920.
- [14] Hu J, Shen L, Albanie S, et al. Squeeze-and-Excitation Networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [15] Zhang J, Huang M, Jin X, et al. A Real-Time Chinese Traffic Sign Detection Algorithm Based on Modified YOLOv2 [J]. Algorithms, 2017, 10(4): 127.
- [16] He K M, Zhang X Y, Ren S Q, et al. Deep Residual Learning for Image Recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 2016: 770-778.
- [17] Huang G, Liu Z, Van Der Maaten L, et al. Densely Connected Convolutional Networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, 2017: 2261-2269.
- [18] Sandler M, Howard A, Zhu M, et al. Mobilenetv2: Inverted Residuals and Linear Bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018: 4510-4520.



张 娜 (1993—), 女, 汉族, 硕士研究生, 主要研究领域为计算机视觉, 交通领域图像识别, zhangna930810@stu.ncst.edu.cn;



李志刚 (1966—), 男, 汉族, 博士, 教授, 硕士研究生导师, 主要研究领域为数据挖掘在智能控制领域的应用。