光电技术及应用

DOI:10.16818/j.issn1001－5868.20240924001

不良光照场景下的交通标志识别算法

党宏社，肖利霞*，张选德
（陕西科技大学 电气与控制工程学院，西安 710021）

摘　要： 交通标志识别技术作为自动驾驶系统的核心组件，在保障行车安全方面具有重要作用。为改善不良光照场景下交通标志的自动识别效果，提出了一种基于改进NanoDet的交通标志识别算法。该算法以NanoDet模型为基础，首先，在主干网络集成SSM模块与CBAM注意力机制，有效提高模型在不良光照场景下的识别精度；其次，构建加权双向特征金字塔网络强化多尺度特征融合；最后，将AGM模块中的标准卷积替换为深度可分离卷积，在保证感受野的同时显著降低模型参数量。基于扩充版CCTSDB数据集的实验表明，该算法在保持138.2帧/s实时处理速度的前提下，识别精度为90.2%，相较基准模型提升4.7个百分点。

关键词： 交通标志识别；不良光照；注意力模块；特征金字塔；深度可分离卷积
中图分类号： TP391.41　**文章编号：** 1001－5868(2025)01－0142－07

Traffic Sign Recognition Algorithm under Adverse Lighting Conditions

DANG Hongshe, XIAO Lixia, ZHANG Xuande
(**School of Electrical and Control Engineering, Shanxi University of Science and Technology, Xi'an 710021, CHN**)

Abstract: Automatic recognition of traffic signs is crucial for vehicle safety in autonomous driving. To improve recognition in poor lighting conditions, an enhanced NanoDet-based traffic sign recognition algorithm is proposed. This algorithm introduces an SSM module and a CBAM attention module into the backbone network of the NanoDet model to boost accuracy under adverse lighting. The weighted bidirectional feature pyramid is used to strengthen the feature extraction. To reduce the number of model parameters and increase the viewshed, deep separable convolution is used to replace the standard convolution in the AGM module. The results on the expanded CCTSDB dataset show a speed of 138.2 frames/s and an accuracy of 90.2%, improving 4.7% compared to standard model.

Key words: traffic sign recognition; poor lighting; attention modules; characteristic pyramids; deep separable convolution

0　引言

交通标志自动识别技术在保障行车安全方面具有重要作用[1]，但由于不良光照的影响，包括曝光、夜间等情况，使得交通标志识别速度与精度无法达到要求。因此，设计出适合在不良光照场景下的交通标志算法对自动驾驶具有重要研究意义[2]。

目前，交通标志识别方法包括传统交通标志识别和基于深度学习交通标志识别方法。Ellahyani等[3]结合了梯度方向直方图（HOG）和色相、饱和度、强度（HSI）等颜色特征，使用支持向量机（SVM）提高识别准确性。吴迪等[4]提出一种名为HOGv-CLBP的有效特征，并通过极限学习机（ELM）获得了良好性能。Zhang等[5]引入级联区域卷积神经网络（R-CNN）来捕捉多尺度特征，解决了

收稿日期：2024－09－24.
基金项目：国家自然科学基金项目（61871206）.
*通信作者：肖利霞

小交通标志的识别问题。郭继峰等[6]将深度可分离卷积(DSConv)应用于YOLOv4-tiny的特征提取网络，减少了模型的计算负荷。Song等[7]基于YOLOv3架构增强了远距离交通标志的检测能力。Guo等[8]在YOLOv5s网络中引入注意力机制，增强了模型的鲁棒性，但同时增加了识别时间。Zhao[9]等通过引入YOLO-MAM双分支模块提高了在恶劣天气下交通标志识别精度。Soans[10]等通过深度估计和文本字符提取合成交通标志牌数据集提高了模型泛化性。显然，现有方法无法同时平衡准确性和速度，不适用于实时交通标志识别，此外，较大的网络模型未能满足驾驶车辆的低计算资源需求。

针对现存交通标志识别算法在不良光照场景下交通标志识别准确度低、识别速度慢的问题，在NanoDet结构基础上进行改进。主干网络中引入SSM模块与CBAM注意力机制来提高模型识别精度，采用加权双向特征金字塔来提高模型的特征聚焦能力，通过轻量化AGM模块来降低计算复杂度，增加可视域。

1　改进的NanoDet算法

1.1　改进的NanoDet网络结构

相较于YOLO等目标检测模型，超轻量级NanoDet模型更小，识别速度快，更易于部署。NanoDet网络结构改进如下：1)将SSM模块与CBAM注意力模块加入到其主干网络中，提高在不良光照场景下的检测能力；2)采用加权双向特征金字塔网络加强特征提取，改善特征提取效果；3)在辅助训练模块AGM采用深度可分离卷积代替标准卷积，降低模型参数量。

改进的NanoDet网络结构如图1所示。主要由4个部分组成：骨干网络BackBone、颈部网络Bi-FPN、检测头Prediction Head和AGM模块四部分组成。轻量化的辅助训练模块AGM将两个Bi-FPN拼接在一起作为输入，当训练完成进行推理时，去除AGM和Aux_fpn，精简网络结构。

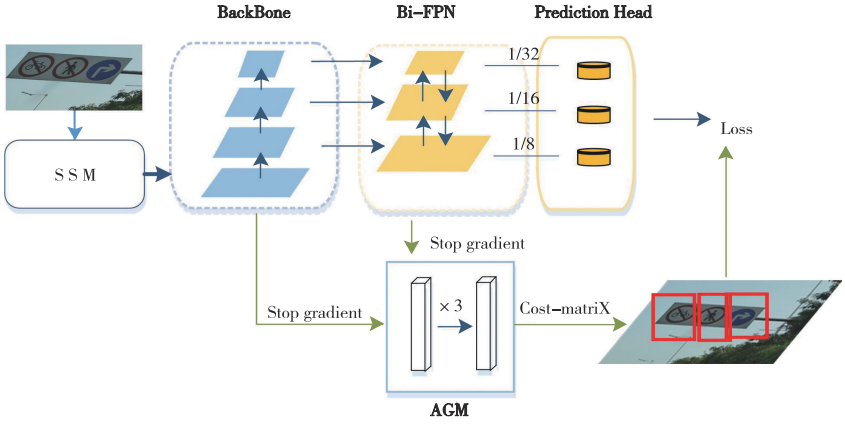

图1　改进后的NanoDet网络结构

1.2　主干网络设计

1.2.1　SSM模块

为提高模型在夜间、曝光等不良光照情况下的识别精度，引入SSM模块处理输入图像。该模块根据标签文件提示，对图像中的多个不同类别交通标志进行分割处理，将分割后的交通标志应用于新的背景图像，以提高模型在不同环境下的识别精度。

如图2所示，SSM模块主要由检测器(Detetor)、掩码-解码器(Encoder-Decoder)组成。图像编码器将输入图像映射至特征空间，从而获得图像的特征嵌入，提示编码器(Prompt Encoder)将输入的标签文件提示映射至特征空间，从而得到提示的特征嵌入，经掩码-解码器对图像编码器和提示编码器进行整合，解码出有效的掩码进行图像分割，最后将分割后图像应用于新的场景而不需要新的训练，有效提高了模型的泛化能力。

1.2.2　CBAM注意力模块

ReLU激活函数[11]虽然计算复杂度较低且网络训练收敛较快，但该函数曲线不平滑，易导致神经元在训练时“坏死”，因此，在ShuffleNet[12]中摒弃ReLU函数。使用曲线更为平滑的Hard-swish函数，相比于ReLU的硬拐点，其能够实现在所有点上都是连续可导的，有助于更稳定的训练过程，函数表达式为：

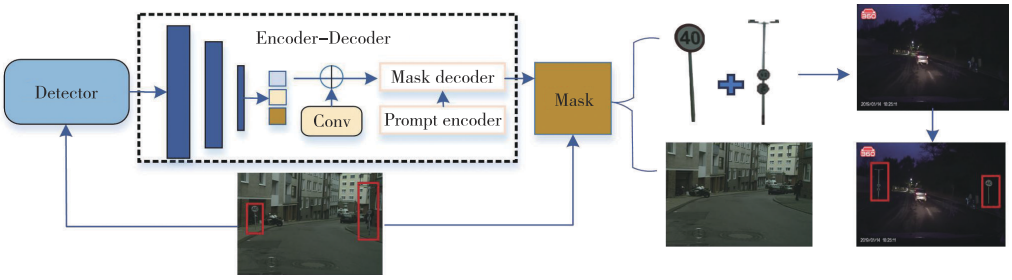

图2 SSM模块

$$f(x)=x\cdot\mathrm{sigmoid}(\beta x) \tag{1}$$

式中，β是可训练参数。

同时针对交通标志模型检测易受背景干扰，准确率低的问题，将CBAM注意力模块[13]引入骨干网络ShuffleNetV2中，分别在Stage2，Stage3，Stage4前添加，提高网络对特征的聚焦能力。CBAM将通道注意力和空间注意力结合在一起，相比只关注通道的SEnet，取得了更好的效果。通道注意力、空间注意力模块的输出公式分别见公式(2)和(3)所示。

$$M_c(F)=\sigma(MLP(\mathrm{AugPool}(F))+MLP(\mathrm{MaxPool}(F))) \tag{2}$$

式中，F是输入特征图，AugPool，MaxPool分别表示全局平均池化和最大池化操作，MLP表示多层感知机，σ表示Sigmoid激活函数。

$$M_s(F)=\sigma(f^{7\times7}([\mathrm{AugPool}(F);\mathrm{MaxPool}(F)])) \tag{3}$$

式中，$f^{7\times7}$表示一个7×7的卷积操作，$[\mathrm{AugPool}(F);\ \mathrm{MaxPool}(F)]$表示将平均池化和最大池化结果沿通道轴拼接起来。

改进的ShuffleNet结构框架如图3所示。首先，输入经过一个包含Conv2d，BatchNorm和Hard-swish的初始卷积层；其次，通过MaxPool2d进行最大池化，降低输入分辨率，其中每个ShuffleNetV2 Block中的激活函数均替换为Hard-swish；然后，添加一个包含Conv2d，BatchNorm和Hard-swish的最终卷积层；最后，通过提取8倍、16倍和32倍下采样的多尺度特征图像，为特征深层次融合做准备。

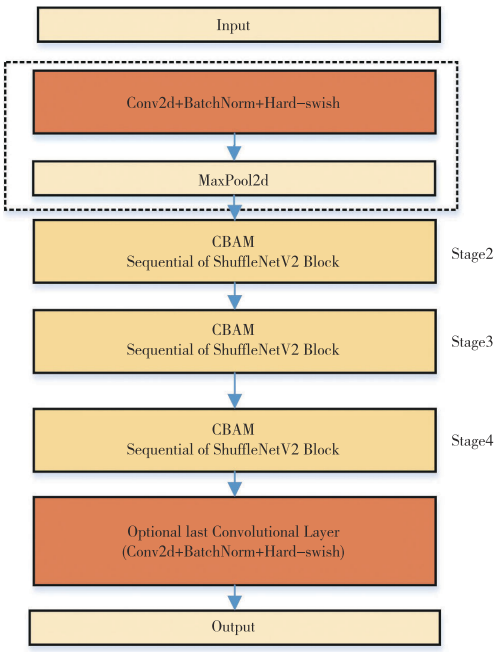

图3 改进后ShuffleNet结构框架

1.3 Bi-FPN双向特征金字塔网络

为保证特征提取的高效性，采用双向特征金字塔网络(Bi-FPN)[14]代替特征金字塔PAN[15]，Bi-FPN可以移除只有一个输入边的节点、添加同一层级的输入输出节点之间的额外边，其结构如图4所示。

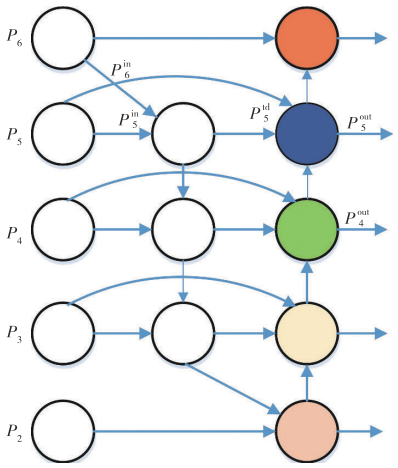

图4 Bi-FPN双向特征金字塔网络

为了提升特征图的表现力，采用一种低计算量的方法，通过顶层至底层和底层至顶层的特征融合策略，实现跨尺度的深层与浅层特征结合。优化网络各层间的特征信息传递，有效避免特征图分辨率变化导致的特征信息损失。同时，在卷积操作后还引入批量归一化和激活函数。输出表达式为：

$$P_5^{td}=Conv\left(\frac{w_1\cdot P_5^{in}+w_2\cdot \mathrm{Resize}(P_6^{in})}{w_1+w_2+\varepsilon}\right) \tag{4}$$

$$P_5^{out}=Conv\left(\frac{w_1'\cdot P_5^{in}+w_2'\cdot P_5^{td}+w_3'\cdot \mathrm{Resize}(P_4^{out})}{w_1'+w_2'+w_3'+\varepsilon}\right) \tag{5}$$

式中，Resize 操作是下采样（或上采样）操作；w 为对应权重，用于区分特征融合过程中不同特征的重要程度。改进后的 Neck 网络能够更好地融合更多位置和细节信息，使网络能更精确地关注目标所在的区域。

1.4　AGM 辅助训练模块

设计轻量级 AGM 辅助训练模块，如图 5 所示。采用深度可分离卷积[16]代替标准卷积，并使用 BN 代替 GN 作为 Normalize 层，在维持参数数量和运算效率的基础上，该方法实现了跨尺度特征图的参数共享，从而减少了训练过程中的参数总量和计算需求。在模型训练前期，其生成的 Cost matrix 作为模型真正 Head 部分的标签分配器的输入，输出在训练初期将会作为 Head 标签分配的参考。并且 AGM 的 Loss 也会进行回传，帮助网络更快地收敛。训练完成后，在进行推理时，去除 AGM 和 Aux_fpn 模块，从而精简网络结构。

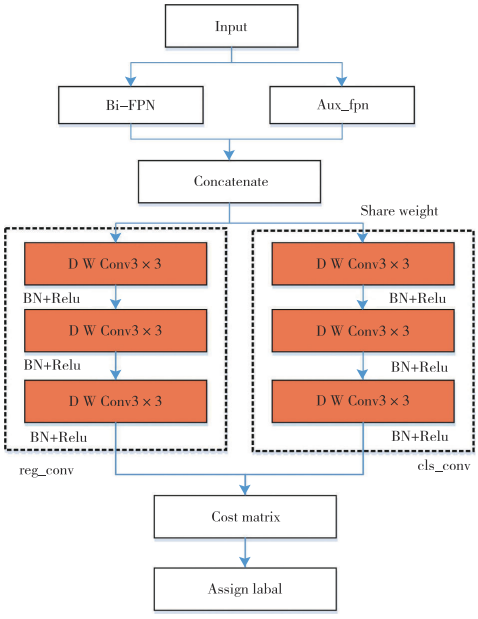

图 5　辅助训练模块

2　仿真实验

2.1　实验环境

实验在 Windows 10 系统条件下进行，GPU 为 RTX 4 090（24 GB），CPU 为 12 vCPU Intel（R）Xeon（R）Platinum 8 352V CPU @ 2.10 GHz，深度学习框架为 PyTorch。

2.2　实验数据集

采用中国交通标志数据集（CSUST Chinese Traffic Sign Detection Benchmark，CCTSDB）[17]。数据集图片来源于不同的城市，覆盖广泛的交通标志类型和场景，总计 17 856 张，包含 3 类交通标志：禁止标志（Prohibitory）、指示标志（Mandatory）、警告标志（Warning）。

为研究因不良光照场景造成识别准确率低的问题，在原有数据集基础上，通过 copy-paste[18]增加样本集，并通过 albumentation 对图像从光照、环境等进行数据增强[19]，从中随机选取 4 000 张禁止标志、3 000 张指示标志、3 000 张警告标志作为训练集，训练集和测试集比例为 8∶2。如图 6 为警告标志依次经过随机尺度抖动、亮度调节、模拟雨天、图像对比度调节以及翻转之后的图像，禁止、指示标志也做相同处理。



图 6　进行数据增强后的图像

2.3　评价指标

通过召回率（Recall）、平均精度均值（mAP）、检测速度（FPS）、平均召回率（AR）指标来评估模型检测结果。如公式（6）～（9）所示，mAP 定义为当交并比（IOU）从 0.5 到 0.95，步长为 0.05 变化时，对 N 个类别的平均精度值（AP）求平均；而 FPS 则衡量了目标检测算法处理图像的速度，反映了检测方法的实时性。

$$Recall=\frac{TP}{TP+FN} \tag{6}$$

$$IOU(A,B)=\left|\frac{A\cap B}{A\cup B}\right| \tag{7}$$

$$AP=\int_0^1 \mathrm{Precision}(Recall)\,\mathrm{d}(Recall) \tag{8}$$

$$mAP=\frac{1}{N}\sum_{C=1}^{N}AP \tag{9}$$

2.4 实验结果与分析

2.4.1 模型训练

使用随机梯度下降算法优化器完成参数更新，采用间隔递减策略调整学习率，初始学习率为0.14，batch size设置为16，共训练150个Epoch。将改进的NanoDet模型在实验数据上进行迭代训练，每一轮评估一次模型参数，训练过程中mAP变化曲线如图7所示。

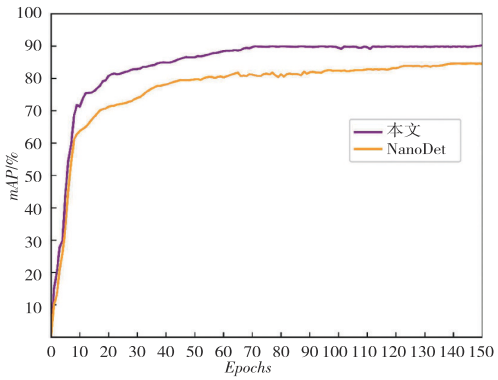

图7 mAP变化曲线

由图7可知，在前15轮次，改进前后的mAP差距并不显著；然而在15轮次之后，改进模型与原模型的mAP差距逐渐增大，随着迭代次数的增加，30次迭代后，mAP开始缓慢增加，并在70次迭代后趋于稳定，略有震荡。在150次迭代后，改进模型与原模型的mAP差距逐渐减小，并最终趋于稳定，但改进模型的mAP始终领先于原模型。

2.4.2 消融实验

为评估改进方法对模型泛化能力的影响，选用扩充的CCTSDB交通标志数据集进行实验，用以上所提的SSM，Hard-swish，CBAM及Bi-FPN模块，验证其对网络模型的影响，结果如表1。

如表1所示，添加SSM模块对网络模型的影响最为显著，大幅提高了识别准确率。其次，在单独替换Bi-FPN时，对网络模型的性能也有小幅度提升，且识别速度基本不受影响。改进后的模型mAP提升4.7%、Recall提升2.5%，性能提升显著。

表1 不同模型的消融实验结果

模型	*mAP*/%	*Recall*/%	*FPS*/(帧·s^{-1})
NanoDet	84.5	90.7	155.0
NanoDet+SSM	86.7	92.4	154.9
NanoDet+Hard-swish	84.9	93.1	153.2
NanoDet+CBAM	84.9	92.2	152.6
NanoDet+Bi-FPN	85.4	91.6	152.2
NanoDet+SSM+Hard-swish	87.9	92.9	150.3
NanoDet+SSM+Hard-swish+CBAM	89.1	93.3	145.2
NanoDet+SSM+Hard-swish+CBAM+Bi-FPN	90.2	93.5	138.2

2.4.3 目标检测算法对比实验

为深入分析改进后模型在交通标志识别任务中的性能，选取相同尺寸YOLOv5s，YOLOv4-Tiny，YOLOv5s和YOLOX-Nano等传统模型作为对照组进行对比分析。实验数据结果如表2所示。

改进后模型虽然平均检测一张图片需要7.06 ms，与改进前相比增加了0.84 ms，但检测精度显著提高，改进后模型mAP比改进前提高4.7%，比同类型的轻量化检测模型YOLOX-Nano高出9.7%。相比于Yolov5s，Yolov4-Tiny等模型，改进后模型在检测速度上具有显著优势，同时检测精度更高。

表2 不同算法试验结果

网络模型	*FPS*/(帧·s^{-1})	权重/MB	*mAP*/%	检测时间/ms
YOLOv5s	28.6	15.0	85.0	13.12
YOLOv3-Tiny	86.7	34.0	65.4	12.41
YOLOv4-Tiny	93.7	23.0	78.4	10.67
YOLOX-Nano	103.0	1.8	80.5	9.45
NanoDet	155.0	4.0	84.5	6.22
本文	138.2	5.1	90.2	7.06

2.4.4 交通标志检测对比实验

交通标志在视觉特征上主要包含颜色、形状和标志内容三个关键属性。如表3所示，对警告标志（注意行人标志、反向弯路标志）、禁止标志（禁止超车标志、禁止载货汽车驶入标志、限制速度标志、限制高度标志）及指示标志（专用车辆标志、靠右侧道

表3 不同交通标志检测对比试验

评价指标	警告标志		禁止标志				指示标志		
									
mAP/%	93.3	91.4	95.3	93.2	97.2	98.2	92.0	94.4	95.6
t/ms	6.8	10.2	6.8	6.5	6.4	6.8	10.4	6.4	6.5

路行驶标志、非机动车行驶标志)进行检测对比。

禁止标志因具有红色圆形的视觉特征且带有标志内容识别精度最高;其次是以蓝色为背景的指示标志;而黄色三角形的警告标志准确度相对较低,这是由于其尺寸较小,导致识别困难。总体而言,颜色鲜明、面积较大且包含标志内容的交通标志更容易被模型准确识别。根据实验结果,各类交通标志mAP均在91%以上,单帧推理速度小于11 ms,达到了实时准确处理的要求。

2.4.5　不同场景检测实验

为评估改进模型对交通标志识别泛化能力的影响,在黄昏、曝光、雨天、夜间环境条件下,利用实际道路拍摄的交通标志数据进行测试,数据涵盖多样的环境变化,能够有效验证模型在现实世界中的表现。如图8所示为改进前后对比图,改进后模型有效解决了昏暗情况下的漏检情况,同时提高了曝光及昏暗环境下的识别准确率,可见改进后的NanoDet网络模型在不良光照环境下展现出了更强的适应性和优越的识别效果。



(a) 黄昏

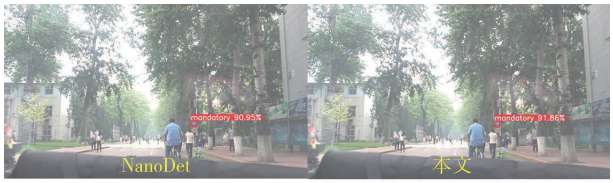

(b) 曝光



(c) 雨天



(d) 夜间

图8　不同场景下的检测效果图

3　结论

为解决不良光照场景下交通标志识别算法效率较低的问题,提出一种基于改进NanoDet的交通标志识别算法。通过在NanoDet模型中引入SSM模块、CBAM注意力机制以及Bi-FPN特征金字塔网络,在保证识别速度的同时提高了算法的识别精度。实验结果表明,改进的NanoDet算法识别精度为90.2%,识别速度为138.2帧/s,能更好适应不同光照环境的影响;此外,该模型的轻量化设计也使其更易于在车辆中部署,为自动驾驶技术的进步提供了支持。

参考文献:

[1] Daus S, Buchwald T, Peuker A U. In-line image analysis of particulate processes with deep learning: Optimizing training data generation via copy-paste augmentation [J]. Powder Technology, 2024, 443(2): 119889.

[2] 曹峻凡, 张向利, 闫　坤, 等. 基于几何透视图像预处理和CNN的全景图像交通标志识别算法[J]. 计算机应用与软件, 2024, 41(7): 171-176.
Cao Junfan, Zhang Xiangli, Yan Kun, et al. Traffic sign recognition algorithm for panoramic image based on geometric perspective image preprocessing and CNN [J]. Computer Applications and Software, 2024, 41(7): 171-176.

[3] Ellahyani A, Ansari M, Jaafari I. Traffic sign detection and recognition based on random forests [J]. Applied Soft Computing, 2016, 46: 805-815.

[4] 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.
Wu Di, Qu Zongshun, Zhao Kuiyin, et al. Traffic sign recognition based on HOGv-CLBP feature fusion and ELM [J]. Optoelectronics·Laser, 2020, 31(6): 621-627.

[5] Zhang J, Xie Z, Sun J, et al. A cascaded R-CNN with multiscale attention and imbalanced samples for traffic sign detection[J]. IEEE Access, 2020, 8: 742-754.

[6] 郭继峰, 孙文博. 一种改进YOLOv4的交通标志识别算法[J]. 小型微型计算机系统, 2021, 13(6): 53-59.
Guo Jifeng, Sun Wenbo. An improved traffic sign recognition algorithm for YOLOv4 [J]. Journal of Chinese Computer Systems, 2021, 13(6): 53-59.

[7] Song S, Li Y, Huang Q, et al. A new real-time detection and tracking method in videos for small target traffic signs [J]. Applied Sciences, 2021, 11(7): 3061.

[8] Guo K, He C, Yang M, et al, A pavement distresses identification method optimized for YOLOv5s [J]. Scientific Reports, 2022. 12(1): 35-42.

[9] Zhao R, Tang H S, Shen J, et al. Enhancing autonomous

driving safety: A robust traffic sign detection and recognition model TSD-YOLO [J]. Signal Processing, 2024, 225: 109619.

[10] Soans R, Fukumizu Y. Custom anchorless object detection model for 3D synthetic traffic sign board dataset with depth estimation and text character extraction[J]. Applied Sciences, 2024, 14(14): 6352.

[11] 刘丛昊, 王 军, 谢 非, 等. 基于改进NanoDet的复杂运动场景多人体检测算法[J]. 南京师大学报(自然科学版), 2024, 47(2): 140-148.
Liu Conghao, Wang Jun, Xie Fei, et al. Multi-human body detection algorithm for complex motion scenes based on improved NanoDet[J]. Journal of Nanjing Normal University (Natural Science Edition), 2024, 47(2): 140-148.

[12] Praharsha H C, Poulose A. CBAM VGG16: An efficient driver distraction classification using CBAM embedded VGG16 architecture[J]. Computers in Biology and Medicine, 2024, 180: 108945.

[13] 党宏社, 党 晨, 张选德. 基于改进YOLOv5s的交通标志识别算法[J]. 实验技术与管理, 2022, 39(9): 97-102.
Dang Hongshe, Dang Chen, Zhang Xuande. Traffic sign recognition algorithm based on improved YOLOv5s [J]. Experimental Technology and Management, 2022, 39(9): 97-102.

[14] Lin Y, Dollar P, Girshick R, et al. Feature pyramid networks for object detection[C]// Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 936-944.

[15] Tan M, Pang R, Le V. EfficientDet: Scalable and efficient object detection [C]// Proceedings of IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 10778 - 10787.

[16] Howard A, Zhu M, Chen B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications [J]. arXiv preprint arXiv: 1704. 04861, 2017.

[17] Haiming T, Jingjing J, Denny J L, et al. Detection of large-droplet macrovesicular steatosis in donor livers based on segment-anything model [J]. Laboratory Investigation: A Journal of Technical Methods and Pathology, 2023, 104(2): 100288.

[18] Zhang L, Xing Z, Wang X. Background instance-based copy-paste data augmentation for object detection[J]. Electronics, 2023, 12(18): 4234.

[19] Runxing Z, Zhiwen W, Wuyuan G, et al. Multi-scene image enhancement based on multi-channel illumination estimation [J]. Expert Systems with Applications, 2023, 226: 120271.

作者简介:

党宏社(1962—),男,陕西省咸阳市人,博士,教授,主要研究方向为数字图像处理、工业过程与控制;

肖利霞(1998—),女,甘肃省定西市人,硕士研究生,主要研究方向为深度学习、图像处理。