

DOI:10.19651/j.cnki.emt.2210944

改进 YOLOX 的弱光线道路交通标志检测^{*}

霍爱清 南思媛 薛静蓉
(西安石油大学电子工程学院 西安 710065)

摘要: 针对弱光线环境下道路交通标志检测精度不高、漏检、错检等情况,提出了一种改进 YOLOX 的融合检测算法。该算法引入轻量级 Mobile Vi T Block 模块,将 CNN 和 Transformer 结合,提高了网络对物体局部和全局特征的学习能力;通过添加自适应特征融合金字塔 ASFF,对有效特征层进行加权融合,加快了网络训练收敛速度;并采用 Focal Loss 替换二元交叉熵损失函数,用以解决因样本少导致分类不准确的问题。实验结果表明,相较于 YOLOX 算法,改进 YOLOX 算法 mAP 值提升了 2.89%,参数量减少了 6.23 M,可视化实验进一步验证了所提算法可以提高检测精度,有效避免因弱光线导致的漏检、错检现象。

关键词: 交通标志检测;Mobile Vi T 网络;自适应空间特征融合;Focal 损失函数;YOLOX 算法

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 520.6040

Improved YOLOX's low-light road traffic sign detection

Huo Aiqing Nan Siyuan Xu Jingrong
(School of Electronic Engineering, Xi'an Shiyou University, Xi'an 710065, China)

Abstract: In view of the low detection accuracy, missed detection, and the wrong detection of road traffic signs in a weak light environment, a detection algorithm based on the improved YOLOX is put forward. Light weight network named Mobile Vi T Block module is adopted, meanwhile CNN is combined with Transformer to raise the network's ability to learn local and global features of objects. By adding the adaptive feature fusion pyramid ASFF, the improved algorithm performs weighted fusion on the effective feature layers in order to accelerate the convergence speed of network training. The binary cross-entropy loss function is replaced by a Focal Loss, so as to solve the problem of inaccurate classification due to the small samples size. As shown by the experimental results, the mAP value of the improved YOLOX algorithm is increased by 2.89% than that of the YOLOX algorithm, and the number of parameters is reduced by 6.23 M. The visualization and other experiments further verify that the improved YOLOX algorithm can effectively avoid the phenomena of missing and wrong detection caused by weak light.

Keywords: traffic sign detection;Mobile Vi T network;ASFF;Focal loss function;YOLOX

0 引言

无人驾驶、辅助驾驶领域对道路交通标志检测技术的要求越来越高,而实际道路交通弱光线环境容易导致检测时出现漏检、错检、检测耗时等问题,严重影响交通标志检测的实时性和准确性。

随着深度学习^[1-3]的快速发展,YOLO(you only look once)系列算法^[4-6]逐渐映入大众的视野。它采用卷积神经网络来直接完成目标类别的判定和边界的预测,真正意义上实现了目标的实时检测,开启了目标检测 One Stage 算法的新纪元。YOLOv3^[7]选用 Darknet-53 作为主干网络,

使用了多标签分类;YOLOv4^[8]输入端采用 Mosaic 增强,主干网络使用 CSPDarknet-53;YOLOv5^[9]使用 Focus 的结构,将宽高信息集中到通道信息。因将目标检测问题转换为回归问题,检测目标的速度很快,因此 YOLO 算法在道路交通标志图像检测与识别逐渐受到学者们的广泛关注^[10-14]。

国内外学者为此也开展了广泛研究^[15-17]。赵坤等^[18]提出了一种自适应图像增强方法,该方法优化了聚类算法和损失函数,将图像增强方法添入了 YOLOv3 模型,但仍存在着处理速度较慢的缺陷。Khan 等^[19]开发了一种智能

收稿日期:2022-08-03

*基金项目:陕西省科技厅一般工业项目(2020GY-152)、陕西省教育厅基金(17JS108)、西安石油大学研究生创新与实践能力培养项目(YCS22113109)资助

交通标志识别系统,针对照明采用预处理方式,但其检测速度较慢。Ciresan 等^[20]采用多柱深度神经网络对交通标志进行检测识别提高识别率,但过程中使用梯度下降法,训练时需对所有参数进行多次调整,训练时间过长,实用性较差。屈治华等^[21]提出了一种 Adaboost 标志检测算法,该算法基于改进图像关键点统计变换(modified census transform,MCT)特征,虽在一定程度上提高了识别精度,但是实时性上仍然存在不足。Xu 等^[22]中提到了一种基于统计假设检验的形状对称检测算法,该方法采用红蓝归一化处理方式,将阈值图像中的高亮部分特征转化为连通域特征向量,从而可以有效的捕捉到交通标志的 ROI(region of interest)。Redmon 等^[23]提出 YOLO 网络,利用回归方法检测目标,并依据卷积网络中提取的特征预测图像边界框坐标,但在小目标检测方面效果欠缺。

为此本文在 YOLOX 算法基础上进行改进,在提高检测精度的同时减少网络参数量,提高实时性,最终通过实验验证了该算法的有效性与可行性。主要工作有:

- 1)引入 Mobile Vi T Block 模块,提高主干网络特征提取能力;
- 2)添加自适应特征融合金字塔(adaptively spatial feature fusion, ASFF),以降低参数量,加快收敛速度;
- 3)使用 Focal 损失函数替代二元交叉熵损失函数,从而改进样本平衡,提高模型检测准确率。

1 改进 YOLOX 算法

1.1 改进 YOLOX 算法的整体构架

YOLOX^[24]是 YOLO 系列的改进版,综合了系列网络

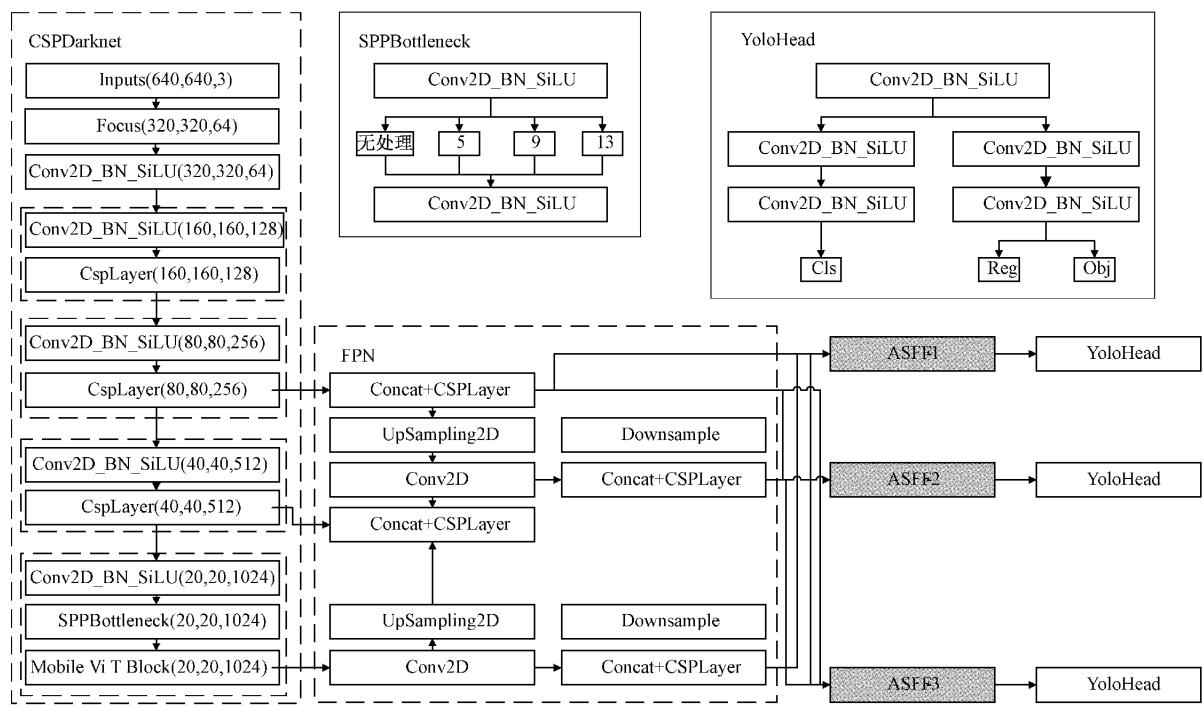


图 1 YOLOX 算法的网络结构

的优点,是创视科技于 2021 年发布的新算法,YOLOX 以 YOLO v3-SPP 为基础,再加入 Anchor-Free 无锚框检测器、Advanced Label Assignment Strategies 先进标签分配策略和端到端(non maximum suppression-Free, NMS-Free)检测器先进的技术构建而得。

虽然 YOLOX 已经具有非常好的检测性能,但是原始 YOLOX 模型在弱光线环境下交通标志检测时依然存在检测速度慢且检测准确率不高的问题。为此着手从以下 3 个方面进行改进:

1) YOLOX 使用的 CSPDarknet 主干特征提取网络具有较强的局部特征学习能力,而全局特征信息学习能力较弱。因此考虑将主干特征提取网络最后一个特征层替换为 Mobile Vi T Block,用以提升网络对局部特征和全局特征的信息感知能力,增强主干网络的特征提取能力。

2) YOLOX 采用的 FPN(feature pyramid networks)对不同的特征层进行特征融合,为了使得特征融合具有充分性以及加强特征效果,在 FPN 特征金字塔之后加入自适应特征融合,这样做的目的使每一层都对 FPN 的 3 个特征层进行加权融合,使正样本和负样本的权重比例不同,保持正负样本的梯度连续稳定,通过参数控制,降低干扰,加快收敛速度。

3) 原始 YOLOX 模型中采用二元交叉熵损失进行置信度预测,二元交叉熵损失存在样本不平衡带来的模型训练问题,会造成样本数少的类别分类难度比较高,因此将二元交叉熵损失替换为 Focal Loss,解决样本少的类别分类准确率不高的问题。

图 1 为改进 YOLOX 算法的网络结构。

由图 1 可知,本文算法中采用 CSPDarknet 网络作为主干特征提取网络,其中包含 CSPnet、Focus 以及 SPP 结构,其最后一个有效特征层采用 Mobile Vi T Block 用以增强主干特征网络局部和全局特征学习和提取能力;加强特征提取网络采用 FPN 和 ASFF 对有效特征进行融合;而预测部分则采用 Anchor-free 检测器和轻量解耦头,提高模型收敛速度。

下面将依次对 3 个主要改进工作进行阐述。

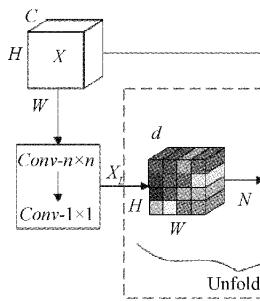


图 2 Mobile Vi T Block 整体结构

Mobile Vi T Block 首先针对给定输入张量 $X \in R^{H \times W \times C}$ (其中 H, W, C 表示分别表示张量的高、宽、通道) 进行 $n \times n$ 卷积学习局部空间信息操作,用 1×1 卷积将输入特征投影到高维空间,得到 $X_L \in R^{H \times W \times d}$ 。为了使 Mobile Vi T 能够学习具有空间归纳偏置的全局表示,首先将得到的张量 X_L 展开为 N 个不重叠的 patch,从而得到张量 $X_U \in R^{P \times N \times d}$ (其中, $P = wh, N = \frac{HW}{P}$ 为 patch 的数量, d 为空间维度, h, w 为 patch 的高和宽,其中 $h \leq nh, w \leq n$),之后跨越 patch 中的每个像素 $p \in \{1, \dots, P\}$,通过 Transformer 来进行建模,得到张量 $X_G \in R^{P \times N \times d}$:

$$X_G(p) = \text{Transformer}(X_U(p)), 1 \leq p \leq P \quad (1)$$

为了防止 patch 之间的位置信息和每个 patch 内像素的空间顺序丢失,折叠 $X_G \in R^{P \times N \times d}$,获得 $X_F \in R^{H \times W \times d}$,之后进行 1×1 卷积,将其投影到低维空间(C 维)得到 $X \in R^{H \times W \times C}$,最后利用 $n \times n$ 卷积对局部和全局特征进行融合得到 $Y \in R^{H \times W \times C}$ 。

如此通过使用 Mobile Vi T Block,可以用较少的参数在输入张量中建模全局和局部信息,进而减少参数量,减轻网络运行负担。

1.3 ASFF

ASFF 可以使网络学习如何对不同尺度特征的冲突信息进行空间滤波,通过对保留的有效信息进行特征融合来提高特征尺度不变性^[26]。

ASFF 的核心思想是通过学习对各尺度特征在融合时的空间权重不断地进行自适应调整。以图 1 中 ASFF-3 为例,其中 x_1, x_2, x_3 分别代表来自 level1, level2, level3 的特征,使用 $x_{ij}^{n \rightarrow l}$ 代表在特征图位置 (i, j) 处从层级 n 调整到

1.2 轻量级 Transformer: Mobile Vi T

Mobile Vi T 网络^[25]引入 Mobile Vi T Block,可以从不同角度学习全局并有效的将局部和全局信息进行编码。Mobile Vi T Block 使用 Transformer 将卷积中的局部建模替换为全局建模,同时具有 CNN 和 Vi T 的性质,可以用更少的参数和简单的训练方式学习更好的表示。Mobile Vi T Block 的结构如图 2 所示。

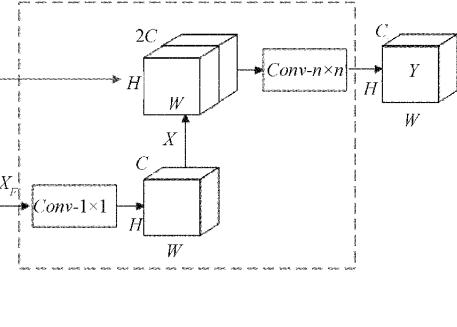


图 2 Mobile Vi T Block 整体结构

层级 1 的特征向量,则相应级别的特征融合如下,由 3 个不同层级的空间重要性权重 $\alpha_{ij}^l, \beta_{ij}^l$ 和 γ_{ij}^l 与特征向量相乘,可以获得融合特征 ASFF-3,空间上尺度融合后输出的特征图 y 为:

$$\mathbf{y}_{ij}^l = \alpha_{ij}^l \cdot \mathbf{x}_{ij}^{1 \rightarrow l} + \beta_{ij}^l \cdot \mathbf{x}_{ij}^{2 \rightarrow l} + \gamma_{ij}^l \cdot \mathbf{x}_{ij}^{3 \rightarrow l} \quad (2)$$

因为 ASFF 其本质就是对所有层进行加权融合,类似于注意力机制,经过降采样和 1×1 卷积压缩通道之后,可以得到 λ_a^l, λ_b^l 和 λ_c^l ,并通过 Softmax (如式(3)求解 α_{ij}^l) 进行归一化,可以得到各权重参数满足 $\alpha_{ij}^l + \beta_{ij}^l + \gamma_{ij}^l = 1$ 和 $\alpha_{ij}^l, \beta_{ij}^l, \gamma_{ij}^l \in [0, 1]$ 的约束条件。

$$\alpha_{ij}^l = \frac{e^{\lambda_a^l}}{e^{\lambda_a^l} + e^{\lambda_b^l} + e^{\lambda_c^l}} \quad (3)$$

故此融合 ASFF 能够使网络更好地学习不同特征尺度之间的空间冲突信息,提高网络训练速度和稳定性,增强特征金字塔特征融合的有效性。

1.4 Focal Loss 函数

Focal Loss 函数^[27]主要用于解决样本数据不均衡而造成的模型性能问题。为了在训练过程中模型可以将重心放置于难分类样本,针对交叉熵函数进行改进,从而降低易分类样本的权重,使得在检测过程中正负样本不平衡问题得到有效改善。

损失函数表达式为:

$$Loss = L(y, \hat{p}) = -y \log(\hat{p}) - (1 - y) \log(1 - \hat{p}) \quad (4)$$

式中: \hat{p} 是预测概率大小, y 是样本标签,在二分类中对应 0, 1。

二分类交叉熵损失函数 L_{ce} 可表示为:

$$L_{ce}(y, \hat{p}) = \begin{cases} -\log(\hat{p}), & y = 1 \\ -\log(1 - \hat{p}), & y = 0 \end{cases} \quad (5)$$

Focal Loss 函数引入 γ , 称作对焦参数 (focusing parameter, $\gamma \geq 0$), 用于调整模型中样本权重, 提高模型对于难分类样本的训练效果, 具体表现形式为:

$$L_{fl} = \begin{cases} -(1 - \hat{p})^\gamma \log(\hat{p}), & y = 1 \\ -\hat{p}^\gamma \log(1 - \hat{p}), & y = 0 \end{cases} \quad (6)$$

令

$$p_t = \begin{cases} \hat{p}, & y = 1 \\ 1 - \hat{p}, & \text{其他} \end{cases}$$

则式(5)、式(6)可改写为:

$$L_{ce} = -\log(p_t) \quad (7)$$

$$L_{fl} = -(1 - p_t)^\gamma \log(p_t) \quad (8)$$

其中, p_t 表示着分类的难易程度, 即标注类别所对应的概率。 p_t 数值越大, 说明分类的置信度越高, 分类越准确。

对比式(7)和(8)可知, Focal Loss 比交叉熵多了一个 $(1 - p_t)^\gamma$ 因式, 所以 Focal Loss 对于分类不准确的样本并不会出现类似交叉熵损失改变的情况, 同时对于分类准确的样本还可以减少其损失。

2 实验结果及分析

2.1 实验环境及数据集

本文的软件开发平台是 Anaconda 平台下的 Pycharm, Python3.7.10, 其运行在 CPU 为 Intel Core i7-10875H, 内存为 16 GB; GPU 为 NVIDIA GeForce RTX 2060; 显存为 6 GB, 且操作系统版本为 Windows10 的 PC 机上。为了加快运算配置了 NVIDIA CUDA10.1 和 Cudnn7.6.0 加速 GPU 运算。

本文使用中国交通标志数据集 (CSUST Chinese Traffic Sign Detection Benchmark, CCTSDB), 以及 500 张自制弱光线场景图片。CCTSDB 数据集中包含不同天气和不同道路的自然场景共 15 734 张交通标志图像, 其中标注的数据分为 3 大类: 指示标志、禁止标志、警告标志。

2.2 消融实验

为了验证本文中 3 种改进方式对于整个改进 YOLOX 算法的性能影响, 设计了 3 组对比试验, 不同改进方式均在相同训练参数情况下进行, 并分别进行对比分析, 实验结果见表 1。其中“×”表示在改进模型中没有使用该模块, “√”表示在改进模型中使用该模块。

对表 1 进行分析可知, 改进 1 在 YOLOX 的基础上添加了 Mobile Vi T 模块, 该模块融合了 CNN 和 Transformer, 提高了主干网络对于全局和局部信息的学习能力, 所以相较于 YOLOX, mAP 提升了 1.34%。

改进 2 在改进 1 的基础上添加了 ASFF 模块, 通过自适应调整各尺度特征的空间融合, 保留有用信息且抑制噪声对网络的影响, FPS 略有下降, 同时 mAP 有所提升。

改进 3 使用 Focal Loss 损失函数对改进 2 进行优化,

表 1 不同模块改进的对比实验结果

方法	Mobile Vi T	ASFF	Focal Loss 损失函数	mAP/%	FPS/帧
YOLOX	×	×	×	85.74	33
改进 1	√	×	×	87.08	31
改进 2	√	√	×	87.47	30
改进 3	√	√	√	88.63	29

调节了正负样本分布不均的问题, 提高了模型的检测准确度, 相较改进 2, mAP 进一步提升了 1.16%。

2.3 目标检测算法对比实验

为了证明改进 YOLOX 算法的有效性, 设计对比实验, 将其与多种主流 YOLO 系列目标检测算法 YOLOv3、YOLOv4、YOLOv4-tiny、mobilenet-YOLOv4、YOLOv5、YOLOX 进行实验性能参数对比, 实验结果如表 2。

表 2 各个检测算法的实验结果

目标检测算法	mAP/%	参数量/M	FPS/帧
YOLOv3	82.80	68.83	17
YOLOv4	84.43	64.36	20
YOLOv4-tiny	81.80	60.56	23
Mobilenet-YOLOv4	58.29	43.60	27
YOLOv5s	80.31	25.39	31
YOLOX	85.74	34.21	33
改进 YOLOX	88.63	27.98	29

由表 2 分析可知, 本文的改进 YOLOX 算法检测精度达 88.63%, 相较于 YOLOv3、YOLOv4、YOLOX 分别提升了 5.83%、4.20%、2.89%, 相较于 YOLOv4-tiny、Mobilenet-YOLOv4、YOLOv5s 这几种轻量级网络分别提升了 6.83%、30.34%、8.32%, 可以看出改进 YOLOX 算法检测准确率优于其他算法。

改进 YOLOX 参数量为 27.98 M, 相较于 YOLOv3、YOLOv4、YOLOX 参数量略有下降, 相较于 YOLOv4-tiny、Mobilenet-YOLOv4 这两种轻量级网络, 参数量分别下降了 32.58 M、15.62 M。

从总体数据来看, 改进 YOLOX 算法以很小的帧率为代价, 大幅减小参数量, 显著提高检测准确率, 因此相较于其他算法, 改进 YOLOX 算法具有一定的优势。

2.4 改进 YOLOX 算法可视化对比实验

弱光线下道路交通标志检测与识别时, 改进 YOLOX 算法与 YOLOX 算法的可视化对比结果如图 3 所示。

从图 3(a)、(b) 对比可知, 相较于 YOLOX 算法, 改进 YOLOX 算法对交通标志检测的分类置信度和检测性能都得到了明显提高, 检测的准确率和精度都有大幅度上升, 且从后两组对比图中可以得到改进 YOLOX 算法针对漏检、错检现象也有了一定改善, 从而验证了本文中所提出



(a) YOLOX 算法 (b) 改进 YOLOX 算法

图 3 YOLOX 算法改进前后可视化结果对比

的改进 YOLOX 算法对于弱光线下道路交通标志检测的实用性和可行性。

3 结 论

本文在 YOLOX 算法基础上提出了一种改进 YOLOX 的融合算法, 所提算法实现了对弱光线下道路交通标志的有效检测, 提高了道路交通标志的检测精度。

提出了改进 YOLOX 检测算法, 引入 Mobile ViT Block 模块, 在 CNN 中融入 Transformer, 提高主干网络对于局部和全局信息的学习能力; 添加自适应特征融合金字塔 ASFF, 通过控制学习权重参数将不同层的特征融合到一起, 调节正负样本的权重比例, 影响特征金字塔的有效

性, 提高网络训练速度和稳定性; 并使用 Focal Loss 解决了因样本少导致类别分类准确率不高的问题。

对改进 YOLOX 检测算法依次进行了消融实验、不同检测算法对比实验以及可视化实验。分析实验结果可知, 改进 YOLOX 算法相比于原 YOLOX 算法检测精度提高了 2.89%, 参数量减少了 6.23 M。可视化实验进一步验证了改进算法对弱光线下道路交通标志检测的有效性。

参考文献

- [1] 童英, 杨会成. 基于改进卷积神经网络的实时交通标志检测方法 [J]. 激光与光电子学进展, 2019, 56(7): 123-129.
- [2] 刘占文, 赵祥模, 李强, 等. 基于图模型与卷积神经

- 网络的交通标志识别方法[J]. 交通运输工程学报, 2016, 16(5): 122-131.
- [3] ARCOS-GARCÍA Á, ÁLVAREZ-GARCÍA J A, SORIA-MORILLO L M. Deep neural network for traffic sign recognition systems: An analysis of spatial transformers and stochastic optimisation methods[J]. Neural Networks, 2018, 99(3): 158-165.
- [4] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]. Conference on Computer Vision and Pattern Recognition, Honolulu, USA, 2017: 6517-6525, DOI: 10.1109/CVPR.2017.690.
- [5] 冯明驰, 高小倩, 汪静姝, 等. 基于立体视觉与激光雷达的车辆目标外形位置融合算法研究[J]. 仪器仪表学报, 2021, 42(10): 210-220.
- [6] REDMON J, FARHADI A. YOLOv3: An Incremental Improvement[C]. Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 1-4, DOI: 10.48550/arXiv.1804.02767.
- [7] XU L, DONG Q, LIAO Y, et al. CLUENER2020: fine-grained named entity recognition dataset and benchmark for Chinese [J]. ArXiv Preprint, 2020, ArXiv: 2001.04351.
- [8] PINHEIRO P O, COLLOBERT R. Weakly Supervised Semantic Segmentation with Convolutional Networks[J]. ArXiv Preprint, 2021, ArXiv:1411.6228.
- [9] LEE-THORP J, AINSLIE J, ECKSTEIN I, et al. FNet: Mixing tokens with Fourier transforms [J]. ArXiv Preprint, 2021, ArXiv: 2105.03824.
- [10] CABALLO A R, ALICE C J. YOLO-based tricycle detection from traffic video[C]. ICIGP 2020: 2020 3rd International Conference on Image and Graphics Processing, 2020: 12-16, DOI: 10.1145/3383812.3383828.
- [11] WANG S, TANG W. Object detection in specific traffic scenes using YOLOv2 [J]. ArXiv Preprint, 2019, ArXiv: 1905.04740.
- [12] 吕禾丰, 陆华才. 基于 YOLOv5 算法的交通标志识别技术研究[J]. 电子测量与仪器学报, 2021, 35(10): 137-144.
- [13] ZHANG J M, HUANG M T, JIN X K, et al. A real-time Chinese traffic sign detection algorithm based on modified YOLOv2[J]. Algorithms, 2017, 10(4): 127.
- [14] 王文胜, 李继旺, 吴波, 张歌博. 基于 YOLOv5 交通标志识别的智能车设计[J]. 国外电子测量技术, 2021, 40(10):158-164.
- [15] MANOCHA P, KUMAR A, KHAN J A, et al. Korean Traffic Sign Detection Using Deep Learning[C]. ISOCC; Daegu, Korea: Nov, 2018, DOI: 10.1109/ISOCC.2018.8649887.
- [16] WALI S, ABDULLAH M, HANNAN M, et al. Vision-Based Traffic Sign Detection and Recognition Systems: Current Trends and Challenges [J]. Sensors, 2019, 19(9): 2093.
- [17] ZHOU K, ZHAN Y, FU D. Learning Region-Based Attention Network for Traffic Sign Recognition[J]. Sensors, 2021, 21(3): 686.
- [18] 赵坤, 刘立, 孟宇, 等. 弱光照条件下交通标志检测与识别[J]. 工程科学学报, 2020, 42(8): 1074-1084.
- [19] 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.
- [20] CIRESAN D, MEIER U, MASCI J, et al. Multi-column deep neural network for traffic sign classification[J]. Neural Networks, 2012, 32: 333-338, DOI: 10.1016/j.neunet.2012.02.023.
- [21] 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.
- [22] 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, 2019, 94 (5): 381-391.
- [23] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [24] ZHENG G, SONGTAO L, FENG W, et al. YOLOX: Exceeding YOLO Series in 2021 [J]. Computer Vision and Pattern Recognition, ArXiv Preprint ArXiv: 107.08430, 2021.
- [25] SACHIN M, MOHAMMAD R. MobileViT: Light-weight, General-purpose, and Mobile-friendly Vision Transformer [J]. Computer Vision and Pattern Recognition, ArXiv Preprint ArXiv:2110.02178, 2022.
- [26] SONGTAO L, DI H, YUNHONG W. Learning Spatial Fusion for Single-Shot Object Detection [J]. Computer Vision and Pattern Recognition, ArXiv Preprint ArXiv: 1911.09516, 2019.
- [27] TSUNG-YI L, PRIYA G, ROSS G, et al. Focal Loss for Dense Object Detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2020, 42(2): 318-327.

作者简介

霍爱清,教授,主要研究方向为定向钻井控制、深度学习与图像处理。

E-mail: aqhuo@xsyu.edu.cn

南思媛(通信作者),硕士研究生,主要研究方向为深度学习与图像处理。

E-mail: 993898475@qq.com

胥静蓉,硕士研究生,主要研究方向为深度学习与图像处理。

E-mail: 2867255600@qq.com