

一种结合上下文感知模块的高压微雾灰尘检测方法

陈 洋¹, 张晓光^{1,3,4}, 陆凡凡², 束正华², 徐文强⁵, 王 涵², 徐新志²

1. 上海智质科技有限公司, 上海 201801
2. 安徽智质工程技术有限公司, 安徽 芜湖 241000
3. 中国科学技术大学 计算机科学与技术学院, 合肥 230026
4. 长三角信息智能创新研究院, 安徽 芜湖 241000
5. 巢湖海螺水泥有限公司, 安徽 巢湖 238000

摘 要:目的 针对堆场下料口灰尘大, 喷雾系统无法快速精准定位除尘等问题, 提出一种结合上下文感知模块的检测方法以实现现场粉尘的有效检测, 辅助高压喷雾系统快速除尘。方法 首先模型的主干网络为轻量级网络 EfficientNetB0, 在实现高效特征提取的同时可以大大减少网络的模型参数量, 提升部署阶段应用效率; 其次利用 CoT(Contextual Transformer) 模块充分探索相邻层级之间的上下文信息, 以一种结合静态与动态信息的方式提升自注意力学习, 增强网络特征提取能力, 进而提升输出特征的表达能力; 最后在 3 个输出层之间进行通道调整与融合之后输入自适应空间特征融合(Adaptively Spatial Feature Fusion, ASFF) 网络, 进一步融合各通道之间的信息特征, 有助于特征细节信息的学习。结果 整个网络的模型大小为 20.42 MB, 有利于模型的嵌入使用, 均值平均精度(mean Average Precision, mAP) 为 95.98%。结论 提出的结合上下文感知模块的检测方法应用于堆场下料口灰尘检测不仅降低了计算量且在精确度方面有一定优势, 满足检测要求。

关键词:缺陷检测; CoT; 非对称卷积; 自适应特征融合

中图分类号: X831; TP391.4 文献标识码: A doi: 10.16055/j.issn.1672-058X.2025.0004.015

A High-pressure Micro-mist Dust Detection Method Incorporating a Context-aware Module

CHEN Yang¹, ZHANG Xiaoguang^{1,3,4}, LU Fanfan², SHU Zhenghua², XU Wenqiang⁵, WANG Han², XU Xinzhi²

1. Shanghai Zhizhi Technology Co., Ltd., Shanghai 201801, China
2. Anhui Zhizhi Engineering Technology Co., Ltd., Anhui Wuhu 241000, China
3. School of Computer Science and Technology, University of Science and Technology of China, Hefei 230026, China
4. Yangtze River Delta Information Intelligence Innovation Research Institute, Anhui Wuhu 241000, China
5. Chaohu Conch Cement Co., Ltd., Anhui Chaohu 238000, China

Abstract: Objective To address issues such as excessive dust at the material unloading point in the yard and the inability of spray systems to quickly and accurately locate and remove the dust, this paper proposed a detection method integrating a context-aware module to effectively detect on-site dust and assist the high-pressure spray system in rapid and precise dust removal. **Methods** The backbone network of the model was a lightweight network, EfficientNetB0, which significantly reduced model parameters while achieving efficient feature extraction and improving deployment efficiency. Additionally,

收稿日期: 2023-11-07 修回日期: 2024-02-26 文章编号: 1672-058X(2025)04-0116-06

基金项目: 国网辽宁省电力有限公司科技项目(2023YF-21)。

作者简介: 陈洋(1986—), 男, 安徽芜湖人, 从事图像识别、设备管理及故障诊断研究。

通信作者: 陆凡凡(1997—), 女, 安徽合肥人, 硕士研究生, 从事图像识别研究。Email: lff666abc@126.com。

引用格式: 陈洋, 张晓光, 陆凡凡, 等. 一种结合上下文感知模块的高压微雾灰尘检测方法[J]. 重庆工商大学学报(自然科学版), 2025, 42(4): 116-121.

CHEN Yang, ZHANG Xiaoguang, LU Fanfan, et al. A high-pressure micro-mist dust detection method incorporating a context-aware module[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 42(4): 116-121.

the CoT (Contextual Transformer) module was used to explore contextual information between adjacent layers, enhancing self-attention learning with a combination of static and dynamic information to improve feature extraction and expression. Finally, after channel adjustment and fusion between three output layers, the input was passed to the Adaptive Spatial Feature Fusion (ASFF) network for further integration of information features across channels, so as to facilitate the learning of feature details. **Results** The total model size of this method is 20.42MB, facilitating model embedding usage, and the mean Average Precision (mAP) is 95.98%. **Conclusion** The proposed context-aware module integrated detection method reduces computational load and has a certain advantage in accuracy for detecting dust at the material unloading point in the yard, meeting detection requirements effectively.

Keywords: defect detection; CoT; asymmetric convolution; adaptive feature fusion

1 引言

工业生产会产生大量灰尘,严重危害现场工作人员的健康,因此及时准确定位灰尘位置并使用喷雾系统清除有着重要意义。灰尘识别与定位一般采用人眼观察的方法,该方法识别速度慢,易受工人经验和现场恶劣生产环境的影响^[1],因此智能化识别灰尘显得尤为重要。文献[2]提出一种同态滤波与Canny算法相结合的目标识别方法,并取得了较好的识别效果。传统的目标检测算法对烟雾灰尘的识别还存在一定问题,文献[3]将相位偏折术和图像处理相结合进行目标识别,提高了识别准确率。近年来,计算机视觉在工业领域的应用越来越广泛,在很多行业已经取得了较好的经济效益^[4]。文献[5]基于Faster-RCNN模型进行改进,得到了识别效果更好的目标识别算法,该算法模型属于Two-stage检测算法。Two-stage检测算法还包括SPP-Net^[6]、R-CNN和Faster R-CNN^[7]等,Two-stage检测算法分为两个阶段,第一阶段先由算法模型生成一系列候选区作为样本,第二阶段通过卷积神经网络进行样本分类。文献[8]基于自注意力机制与SSD(Single Shot MultiBox Detector)图像目标检测算法设计了新的目标检测算法,该算法模型属于One-stage检测算法。One-stage检测算法还包括YOLO^[9-10]系列算法模型、CenterNet无锚框算法等,这类检测算法直接回归物体类别和对应类别的概率,检测速率有很大的提升。CenterNet^[11]是典型的无锚框目标检测算法模型,该算法模型省略掉设置初始锚框的过程,以被测物体的中心点确定目标框的位置和大小,使用更加方便^[12]。

为了保证检测的精确性,本文借鉴YOLO系列的锚框策略并做出相应的改进。针对YOLO系列检测算法中系统模型参数过多,不易嵌入的问题,本文提出以EfficientNetB0为主干网络的非对称卷积网络。利用非对称卷积(Asymmetric Convolution Block Network, ACNet)块加强特征提取并减少检测模型的参数量。同

时使用CoT模块结合静态与动态上下文信息的注意力机制模块解决准确率下降的问题。利用通道特征融合网络ASFF融合各项特征,使网络具备自适应地学习各尺度特征权重的能力。实验结果表明:本文模型在大大降低参数量的情况下依旧取得了较好的精确度,有着较强的工业应用价值^[13-14]。

2 模型与算法设计

所提出的基于EfficientNetB0的深度卷积神经网络如图1所示。主干网络通过多个MBConv模块对输入图片进行下采样特征提取,最终得到 13×13 、 26×26 、 52×52 3种尺寸的特征图。为缓解主干网络压缩采样过程中的信息衰减问题,在最后一层采样结束之后进行卷积运算。共计3个内置CoT模块卷积块,卷积核大小分别为 1×1 、 3×3 、 1×1 ,该层可以加强上下文特征信息间的动态与静态特征信息。模型中引入ASFF自适应空间特征融合网络以解决烟雾灰尘不易识别的问题。将最低层级通过上采样得到与上一层级大小相同的特征图;之后进行连接与卷积操作,在卷积过程中,引入非对称卷积,特征在融合时保护特征核心信息;最后各个层级之间通过ASFF学习不同特征图的融合权重。本文模型共有3层,分别为ASSF1、ASSF2和ASSF3,为方便描述在后续内容中分别使用 A_1 、 A_2 、 A_3 表示。其中 A_1 学习P3、P4、P5 3个层级特征的权重系数,融合各个层级之间的特征,进行加权学习, A_2 、 A_3 以此类推,最终实现3个不同尺度特征图的预测。在进行预测之前,图片会被划分为 $S \times S$ 个网格,每个网格上面都会预先设定3个锚框,模型使用Kmeans++聚类的方式对数据集的分布进行统计,最终3个层级设定大小不同的9个锚框,分别为(23,20)、(25,37)、(28,27)、(32,32)、(33,45)、(39,36)、(44,43)、(51,54)、(70,65),最后通过输出锚框位置的4个偏移量来调整目标框的位置,通过非极大抑制(NMS)方法选出误差最小的目标框作为最后的输出框,并带有目标的类别与概率。




图 1 本文算法模型

Fig. 1 The model of this paper

2.1 EfficientNetB0 主干网络

EfficientNet^[15]网络结合了网络的宽度、深度、分辨率 3 个要素,通过复合因子 ϕ 制约三者之间的缩放比例,实现网络的高效快速性。通过调整缩放比例,共有 8 种模型 (EfficientNetB0—EfficientNetB7)^[16]。本文选取基线模型 EfficientNetB0,在网络整体参数量最小的情况下完成特征提取。EfficientNetB0 的网络结构如表 1 所示,总共由 8 层卷积层组成,卷积核大小为 3×3 与 5×5 两种。MBConv 是引入压缩与激发网络 (Squeeze-and-Excitation Network, SENet) 的一系列残差网络的堆叠。输入图片大小为 $416 \times 416 \times 3$ 时,通过网络特征提取压缩,最终输出 $52 \times 52 \times 40$ 、 $26 \times 26 \times 112$ 、 $13 \times 13 \times 320$ 3 种尺度的特征图^[17]。

表 1 EfficientNetB0 网络结构

Table 1 Structure of efficientNetB0 network

Stage	Operate	Size	Layers
1	Conv 3×3	$208 \times 208 \times 32$	$\times 1$
2	MBConv1, $K3 \times 3$	$208 \times 208 \times 16$	$\times 1$
3	MBConv6, $K3 \times 3$	$104 \times 104 \times 24$	$\times 2$
4	MBConv6, $K5 \times 5$	$52 \times 52 \times 40$	$\times 2$
5	MBConv6, $K3 \times 3$	$26 \times 26 \times 80$	$\times 3$
6	MBConv6, $K5 \times 5$	$26 \times 26 \times 112$	$\times 3$
7	MBConv6, $K5 \times 5$	$13 \times 13 \times 192$	$\times 4$
8	MBConv6, $K3 \times 3$	$13 \times 13 \times 320$	$\times 1$

MBConv 结构如图 2 所示,其中 $K3 \times 3$ 表示卷积核大小为 3×3 , $K5 \times 5$ 表示卷积核大小为 5×5 。对输入图片先进行 1×1 卷积升维操作,具体的升维大小由倍率因子决定,如 MBConv6 表示进行 1×1 卷积时将通道数扩充为 6 倍,MBConv1 表示维度不变,不需要执行卷积操作。之后进行 $K \times K$ 的逐通道深度卷积 (DepthwiseConv2D),同时为了解决不同通道重要性不同带来的特征损失问题,在模型中引入通道注意力机制 (Squeeze and Excitation, SE) 模块,将学习到的各个通道之间的权重与原特征图对应通道进行相乘操作,得到各个通道不同的重要性参数,使模型着重学习权重值高的通道信息,忽略权重值较小的通道信息,提高模型的精确度。最后进行 1×1 卷积降维操作,还原图

片通道数,以便与原输入图片进行残差连接,解决训练过程中网络能力退化的问题。




图 2 MBConv 结构图

Fig. 2 Structure of MBConv

2.2 CoT 上下文感知模块

在经过主干网络特征提取后,为了更好地保留上下文信息,在模型中引入 CoT^[18] 模块,其结构特征如图 3 所示。与传统注意力机制相比,CoT 模块对于输入 X , keys, queries 以及 values 分别定义为 $K = X$, $Q = X$, $V = XW_v$, W_v 为 values 的一个权重关系矩阵。使用 $K \times K$ 组卷积提取上下文信息作为整个输入的静态上下文特征,随后与 Q 进行 Concat 连接,再经过两次 1×1 卷积操作,计算出 Q 与 K 之间的相似性,得到相应的相关矩阵 A ,之后与 V 进行特征增强,最终生成增强特征 $K^2 = A * V$,称为整个输入的动态上下文特征。最后将静态上下文特征与动态上下文特征通过注意力机制进行 Fusion 融合作为最终的 CoT 模块输出。

将 CoT 模块放到卷积块 Conv3 中代替标准卷积,在不改变特征图大小的情况下可以减少特征提取过程中的信息丢失,有效挖掘上下文特征信息。




图 3 CoT 模块结构图

Fig. 3 Structure of CoT module

2.3 ASFF 自适应特征融合

进行多尺度特征融合时,采用自适应特征融合^[19]方法,自适应地学习各尺度特征图融合的空间权重,结构如图4所示。经过自上而下的特征融合后,出现3个有效特征层,分别为 Level1、level2 和 level3,之后分别计算每个层级的特征融合。例如在 Y_1 中,进行式(1)的计算,其中 $X^{1 \rightarrow 1}$ 表示来自 level1 的特征图, $X^{2 \rightarrow 1}$ 表示来自 level2 的特征图经过下采样变成与 level1 大小与通道数都相同的特征图, $X^{3 \rightarrow 1}$ 表示来自 level3 的特征图经过下采样变成与 level1 大小与通道数都相同的特征图, α^1 、 β^1 、 γ^1 则表示各个层级特征在 level1 上的权重参数。 Y_2 、 Y_3 中的计算同理如式(2)、式(3),最终会得到不同层级之间的特征融合。对于权重参数 α 、 β 和 γ ,则是通过特征变换后的 level1—level3 的特征图经过 1×1 的卷积得到,并且参数 α 、 β 和 γ 经过连接之后通过 Softmax 操作使得它们的范围都在 $[0,1]$,并且和为 1。

$$Y_1 = X^{1 \rightarrow 1} \otimes \alpha^1 + X^{2 \rightarrow 1} \otimes \beta^1 + X^{3 \rightarrow 1} \otimes \gamma^1 \quad (1)$$

$$Y_2 = X^{1 \rightarrow 2} \otimes \alpha^2 + X^{2 \rightarrow 2} \otimes \beta^2 + X^{3 \rightarrow 2} \otimes \gamma^2 \quad (2)$$

$$Y_3 = X^{1 \rightarrow 3} \otimes \alpha^3 + X^{2 \rightarrow 3} \otimes \beta^3 + X^{3 \rightarrow 3} \otimes \gamma^3 \quad (3)$$

最终,通过学习自适应调整各尺度特征在融合时的空间权重,得到自适应融合效果,使网络的特征连接更加充分有效。




图4 ASFF 结构图

Fig. 4 Structure of ASFF

3 仿真实验及结果分析

3.1 实验数据与环境

实验数据是某生产堆场实时监控视频。物料从运输机下落至料堆时,会产生大量灰尘。采集现场实时监控视频,采用截断的方式获取所需数据集,数据集共有 1 007 张原始图片,经过旋转、镜像、垂直平移等操作,将图片扩充到 3 768 张,选取 2 637 张图片作为训练集,1 131 张图片作为测试集,使用 Labelimg 进行人工标注。

本实验基于 Anaconda 的 Pytorch 深度学习框架实现,版本为 Anaconda 4.9.2 和 Pytorch1.4.0。硬件配置为 Inter(R) Core(TM) i9-10850K CPU @ 3060,32.0GB 内存。实验迭代次数(epoch)为 100 次,学习率设为 0.001。

3.2 消融实验

为了对比各模块对模型的影响程度,设计了消融实验进行说明,以平均精度均值(mean Average

Precision, mAP) 与网络参数量的大小作为模型优异性的判别指标。实验结果如图 5 所示。




图5 模型训练损失值

Fig. 5 Model training loss

据表 2 可知,本模型的平均精度均值最高,网络参数量也小于添加 PANet 的网络,与不添加 CoT 模块的网络参数量只相差 0.27 MB,网络的综合性能优异。

表2 消融实验结果

Table 2 Ablation test results

网络结构	mAP/%	网络参数量/MB
EfficientNet+ASFF	96.42	20.42
EfficientNet+ASFF+PANet	93.01	22.18
EfficientNet+ASFF+CoT	94.48	20.15

3.3 结果分析

精确度(Precision),即预测为正例的样本中预测正确的比例,如式(4)所示,计算结果用 P 表示。召回率(Average Recall)表示正确识别的图片占该类总数的百分比,计算如(5)所示,计算结果用 R 表示。平均精度(Average Precision)计算公式如(6)所示,计算结果用 A 表示。将 1 131 张图片放入训练好的网络中进行测试,本文所提模型的平均精度均值达到了 95.98%,与其他目标检测常用方法比较有一定的优势。

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \times 100\% \quad (4)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \times 100\% \quad (5)$$

$$A = \int P dR \quad (6)$$

式(4)—式(6)中, N_{TP} 为正样本中被正确分类为正样本的个数, N_{FP} 为负样本被错误分类为正样本的个数, N_{FN} 为正样本被错误的分类为负样本的个数。

为了更进一步说明本文算法的优势,记录训练过程中模型损失值,如图 5 所示。并且采用更详细的评价指标来定量分析本文算法与其他常用算法的表现,实验结果如表 3 所示。

表 3 实验结果

Table 3 Experiment results

模型	A/%	P/%	R/%	网络参数量/MB
Faster-RCNN	85.19	76.02	89.42	141
YOLOv4	94.76	97.41	88.70	224
YOLOv4-Tiny	91.98	89.64	88.44	22.58
CenterNet	69.65	79.26	47.73	14.57
本文方法	97.05	96.07	88.74	20.42

与 Two-stage 的 Fater-RCNN 方法比较,本文方法模型大小相对减少 6 倍左右,并且检测精度提升 11.16%,效率提升明显;与无锚框的 CenterNet 方法比较,精确度提升将近 2 倍,无锚框的检测算法在小物体的检测上不具优势;与 YOLOv4 和 YOLOv4-Tiny 模型相比,本模型参数量相对较少,并且使用 CoT、ACNet、ASFF 等模块,使模型在少量参数的情况下也可以保证较高的检测精度,检测精度达 97.05%。如图 6 所示,可以更直观地看出本文提出模型的平均准确率优于其他模型,并且模型的参数量较少,在工业应用中有一定的优势。




图 6 模型对比图

Fig. 6 Model comparison chart

实验效果如图 7 所示。本模型可以精准地检测出堆场下料时产生灰尘的位置,在进行高压微物除尘时可以给喷头提供精确的位置信息,有效节约水资源,避免大范围开启除尘系统。



(a) 识别视角 1



(b) 识别视角 2

图 7 实验效果图

Fig. 7 Experimental effect chart

为了验证模型迁移的有效性,使用训练模型对车库下料口进行灰尘检测,结果如图 8 所示。结果表明:在不同的下料场景下,本文模型可以检测出灰尘的位置,但也可以看出检测置信度有所下降,表明后期可以增加更多类型带有灰尘的图像参与训练,增强模型的泛化性与鲁棒性。



(a) 识别效果 1



(b) 识别效果 2

图 8 模型迁移识别效果图

Fig. 8 Model migration effect diagram

4 结论

针对灰尘微物难以检测定位的问题,提出一种高效网络模型,使用 EfficientNetB0 作为主干网络,在实现高效特征提取的前提下控制网络参数的大小;其次引入 CoT 模块,提取丰富的上下文特征信息;最后引入自适应特征融合 ASFF 模块,使得不同层级之间的特征信息更充分融合,网络性能更加高效。实验结果表明:本文提出算法的平均精度均值达到 95.98%,模型参数量

只有 20.42 MB,实现了轻量高效的检测。但网络在迁移的过程中,检测置信度还有待提升,检测速度随着不同场景的迁移需要改进,为后续的研究提供了方向。

参考文献(References):

- [1] 张涛,刘玉婷,杨亚宁,等. 基于机器视觉的表面缺陷检测研究综述[J]. 科学技术与工程, 2020, 20(35): 14366–14376.
ZHANG Tao, LIU Yu-ting, YANG Ya-ning, et al. A review of surface defect detection based on machine vision[J]. Science, Technology and Engineering, 2020, 20(35): 14366–14376.
- [2] 朱志勋,赵磊,李恒,等. 基于改进的同态滤波与 Canny 算法的磁瓦表面缺陷检测算法研究[J]. 激光与光电子学进展, 2022, 59(18): 103–110.
ZHU Zhi-xun, ZHAO Lei, LI Heng, et al. Research on surface defect detection algorithm of magnetic tile based on improved homomorphic filtering and Canny algorithm[J]. Advances in Lasers and Optoelectronics, 2022, 59(18): 103–110.
- [3] 成先明,王婷婷,史柏迪,等. 基于相位偏折术和图像处理的表面缺陷检测[J]. 计算机测量与控制, 2021, 29(5): 64–69.
CHENG Xian-ming, WANG Ting-ting, SHI Bai-di, et al. Surface defect detection based on phase deflection technique and image processing[J]. Computerized Measurement and Control, 2021, 29(5): 64–69.
- [4] 黄健,张钢. 深度卷积神经网络的目标检测算法综述[J]. 计算机工程与应用, 2020, 56(17): 12–23.
HUANG Jian, ZHANG Gang. A review of target detection algorithms for deep convolutional neural networks[J]. Computer Engineering and Applications, 2020, 56(17): 12–23.
- [5] 吕本远,嵇真福,韩永赛,等. 基于 Faster 区域卷积神经网络的目标检测[J]. 激光与光电子学进展, 2021, 58(22): 257–265.
LYU Ben-yuan, GAO Zhen-fu, HAN Yong-sai, et al. Object detection based on faster R-CNN[J]. Advances in Lasers and Optoelectronics, 2021, 58(22): 257–265.
- [6] HONG M, LI S, YANG Y, et al. SSPNet: Scale selection pyramid network for tiny person detection from UAV images[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19(10): 1–5.
- [7] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137–1149.
- [8] 储岳中,黄勇,张学锋,等. 基于自注意力的 SSD 图像目标检测算法[J]. 华中科技大学学报(自然科学版), 2020, 48(9): 70–75.
CHU Yue-zhong, HUANG Yong, ZHANG Xue-feng, et al. SSD image target detection algorithm based on Self-attention. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2020, 48(9): 70–75.
- [9] LI X, PAN J D, XIE F P, et al. Fast and accurate green pepper detection in complex backgrounds via an improved YOLOv4-tiny model[J]. Computers and Electronics in Agriculture, 2021, 191(23): 68–75.
- [10] 张帅帅. 基于 YOLOv5 的安全帽检测方法研究[J]. 重庆工商大学学报(自然科学版), 2025, 42(1): 42–47.
ZHANG Shuai-shuai. Research on safety helmet detection method based on YOLOv5[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 42(1): 42–47.
- [11] PENGX F, YANG X W. Liver tumor detection based on objects as points[J]. Physics in Medicine and Biology, 2021, 66(23): 31–42.
- [12] DONG Z, LI G, LIAO Y, et al. CentripetalNet: Pursuing high-quality keypoint pairs for object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 10519–10528.
- [13] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]//European Conference on Computer Vision. Cham: Springer International Publishing, 2020: 213–229.
- [14] ZHANG H, JIANG L, LI C. CS-ResNet: Cost-sensitive residual convolutional neural network for PCB cosmetic defect detection[J]. Expert Systems with Applications, 2021, 185(15): 57–64.
- [15] TAN M, LE Q V. EfficientNet: Rethinking model scaling for convolutional neural networks[C]//International Conference on Machine Learning. PMLR, 2019: 6105–6114.
- [16] TAN M, PANG R, LE Q V. Efficient-Det: Scalable and efficient object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 10781–10790.
- [17] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 4510–4520.
- [18] LI Y, YAO T, PAN Y W, et al. Contextual transformer networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(2): 1489–1500.
- [19] QIAO Y L, GUO Y Y, HE D J. Cattle body detection based on YOLOv5-ASFF for precision livestock farming[J]. Computers and Electronics in Agriculture, 2023, 204(24): 24–33.

责任编辑:李翠薇