

# 基于 YOLOv5m 的电机换向器缺陷检测

许云涛,焦培刚\*,刘家齐

山东交通学院工程机械学院,山东 济南 250357

**摘要:**为降低电机换向器缺陷的检测成本,提高检测效率,满足实际工程中对检测精度和检测速度的均衡要求,以 YOLOv5m 模型为基础提出优化改进的表面缺陷检测算法,将采集的数据集经 Mosica 数据增强,提高模型的鲁棒性;在其他层中采用双向特征金字塔网络(bidirectional feature pyramid network, BiFPN)层代替路径聚合网络(path aggregation network, PANet)层,引入双向连接和跨层特征融合机制,同时增加 Criss-Cross 注意力机制,更好地捕捉输入序列中的相关信息,增强网络在不同尺度下的反馈,并通过消融试验验证。结果表明:相较于传统 YOLOv5m 模型,优化改进后 YOLOv5m 模型的总体平均检测精度增大 17%,准确率增大 28.3%,召回率增大 8.2%。在保证检测精度的同时,缩短缺陷检测时间,较好地满足缺陷检测工程中对检测精度与检测速度的均衡需求。

**关键词:**电机换向器;表面缺陷;YOLOv5m;注意力机制;特征融合

**中图分类号:**U463.6

**文献标志码:**A

**文章编号:**1672-0032(2024)02-0010-09

**引用格式:**许云涛,焦培刚,刘家齐.基于 YOLOv5m 的电机换向器缺陷检测[J].山东交通学院学报,2024,32(2):10-18.

XU Yuntao, JIAO Peigang, LIU Jiaqi. Motor commutator defect detection based on YOLOv5m[J]. Journal of Shandong Jiaotong University, 2024, 32(2): 10-18.

## 0 引言

电机换向器是交流换向器和直流换向器电动机电枢上的重要部件,对电机的性能和质量有较大影响。电机换向器的制作工艺复杂,顶端和底端表面由金属、塑料和云母等多种材料构成,表面缺陷分布广、形式多样、特征复杂,难以制定统一的量化检测标准,采用传统视觉方法检测缺陷时难免出现漏检、误检现象<sup>[1-2]</sup>。

检测电机换向器表面缺陷的方法主要有视觉检测、涡流检测、激光三维扫描和红外线扫描等方法。视觉检测主要通过摄像头拍摄电机换向器表面图像,采用图像处理技术进行缺陷识别和分类;涡流检测是通过电磁感应原理检测电机换向器表面的缺陷,检测速度快,无需接触,不易受表面涂层和颜色干扰。随着机器学习和机器视觉的不断发展,目前多采用自动化方法检测金属材料表面的缺陷。

罗立浩等<sup>[3-4]</sup>开发基于频域分析和分数域分析的在线视觉检测系统,有效排除金属表面氧化层的干扰,并通过自适应滤波器增强缺陷区域,针对柱面缺陷分类问题,综合多种特征,采用随机森林分类,检测准确率明显提高。Jung 等<sup>[5]</sup>训练深度卷积神经网络实时检测纹理表面缺陷,准确性和鲁棒性较高。Gu 等<sup>[6]</sup>采用语义分割的经典 U-Net 网络训练道路数据集,并在嵌入式设备 Jetson AGX Xavier 部署道路分割

收稿日期:2023-04-21

基金项目:山东省重点研发计划项目(2019GNC106032)

第一作者简介:许云涛(1997—),男,山东德州人,硕士研究生,主要研究方向为机器视觉及深度学习,E-mail:514390480@qq.com。

\*通信作者简介:焦培刚(1974—),男,山东聊城人,教授,工学博士,硕士研究生导师,主要研究方向为虚拟现实和光滑粒子流体动力学,E-mail:jiaopeigang@163.com。

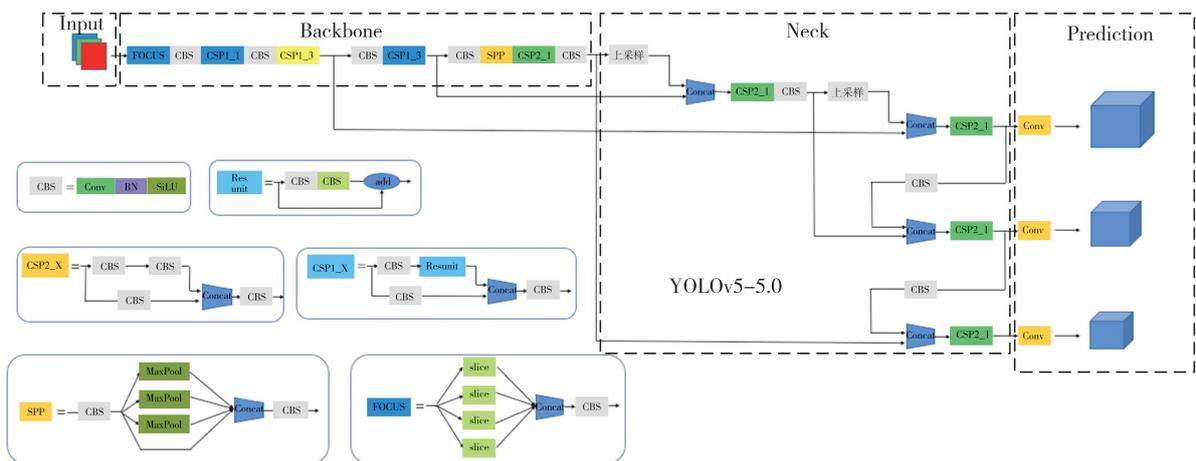
模型,但刷新频率指标效果不理想,在算力有限的边缘设备上难度较高。Nguyen 等<sup>[7]</sup>提出 2 级卷积神经网络,第 1 级结构用于消除噪声并缩小图像中的裂缝区域,第 2 级用于裂缝特征学习,在网络参数较小时检测裂缝。徐晓峰<sup>[8]</sup>采用最小核值相似区 (small univalue segment assimilating nucleus, SUSAN) 算法进行自适应阈值检测,偏差不超过 5  $\mu\text{m}$ ,检测速度明显提高。李树遥<sup>[9]</sup>提出多缺陷在线检测算法,可涵盖换向器各区域多种缺陷。电机换向器缺陷的检测精度提高,但检测成本较高,检测速率较慢。

本文提出优化改进后的 YOLOv5m 算法,融入双向特征金字塔网络 (bidirectional feature pyramid network, BiFPN) 层,从输入图像中提取特征细节,提高检测的准确性,同时增加 Criss-Cross 注意力机制,引入更多的上下文信息,提高网络的特征提取能力,减少网络对特定场景的依赖,提高网络的泛化能力和换向器缺陷检测准确率和检测速度。

# 1 YOLOv5 检测算法

## 1.1 YOLOv5 网络结构

YOLOv5 主要由主干网络 (Backbone)、其他层 (Neck)、输入端 (Input) 及预测头 (Prediction) 部分组成,网络结构如图 1 所示。



注: CBS 为连续卷积、批归一化和激活函数的组合; Conv 为卷积层,可提取输入数据的特征; SPP 为空间金字塔池化,是将输入的特征图转换为预定义的固定值输出方法; Concat 为拼接操作,将来自不同层的特征图按某维度 (通常是通道维度) 拼接; Slice 是指从大的数据结构中抽取出部分数据; CSP 为跨阶段部分网络,可减少计算量并保证准确性; Focus 为特殊层,旨在减少计算成本,保持模型性能; Resunit 为残差单元。

图 1 YOLOv5 网络结构图

YOLOv5 是高效的卷积神经网络结构,以跨阶段部分网络 (cross stage partial network, CSPNet) 为主干网络,提高模型的检测速度和准确率,其他层采用空间金字塔池化 (spatial pyramid pooling, SPP) 和路径聚合网络 (path aggregation network, PAN) 结构,捕捉不同尺度的特征并帮助网络学习全局特征。在预测头部分, YOLOv5 采用 YOLOv3 和 YOLOv4 的结构,包含多个卷积层和池化层,输出预测结果。YOLOv5 采用 anchor-based 的方法作为预测方式,对预测结果进行后处理,可得到目标的类别、位置和置信度信息。

## 1.2 YOLOv5 算法改进

### 1.2.1 BiFPN 特征融合方法

BiFPN 用于目标检测任务的网络结构,旨在提高特征金字塔网络 (feature pyramid network, FPN) 的性能。FPN 通常用于解决目标检测任务中不同尺度特征信息的融合问题,特征自下而上传递,低层特征与高层特征融合。在此基础上,在 BiFPN 中引入反向连接,允许高层特征影响低层特征,实现更全面的信息交换<sup>[10-11]</sup>。BiFPN 引入双向连接和更多的特征融合机制,提高特征的表征能力,原理结构如图 2 所示。

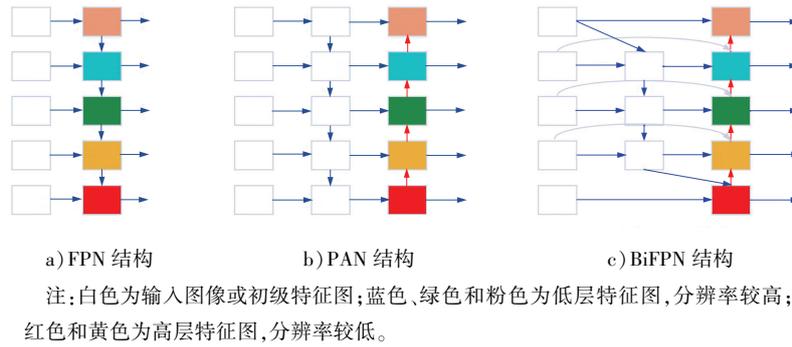
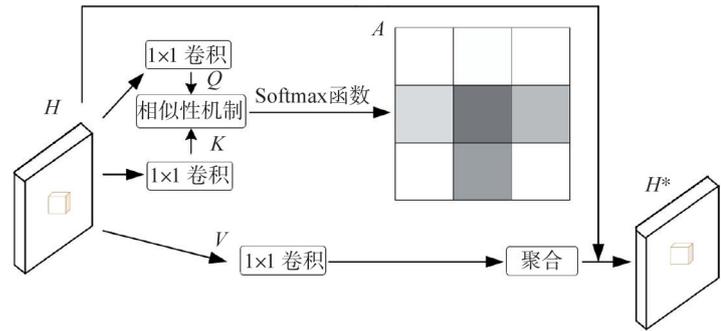


图2 BiFPN 原理结构图

在 YOLOv5m 中, BiFPN 确保从输入图像中提取细节丰富的特征, 上下文信息充足, 提高检测的准确性, 增强网络在不同尺度上的特征表示。BiFPN 嵌入主干特征提取网络, 在不同层级上融合特征, 有助于提高模型对大、小目标的检测能力, 并提高模型的鲁棒性和准确性<sup>[12]</sup>。同时, BiFPN 可去除噪声和假阳性, 在复杂场景下检测目标, 提高模型在工业领域的实用性。因引入更多的融合机制和双向连接, BiFPN 的计算复杂度相对较高, 可能增大模型的训练和推理成本。BiFPN 涉及多个融合机制和参数, 需仔细调整参数, 获得最佳检测性能<sup>[13-14]</sup>。

### 1.2.2 Criss-Cross 注意力机制

Criss-Cross 网络采用轻量级计算和内存表示局部特征, 进行全图像依赖性建模, 引入 1 个交叉注意模块, 结构如图 3 所示。Criss-Cross 是神经网络中的注意力机制, 可处理序列数据, 在水平和垂直 2 个方向上交叉计算注意力权重, 捕捉输入序列中的相关信息, 计算左向和右向的卷积注意力分数, 通过 Softmax 函数 (Softmax 是将输入的实数序列转化为概率分布, 确保结果都在  $[0, 1]$  内, 概率分布总和为 1) 处理得到左向和右向的卷积注意力权重, 通过加权平均合并得到最终的注意力权重矩阵。通过此矩阵, 模型可在处理输入图像时更有效聚焦关键特征, 提高检测准确率。



$H$ —输入的隐藏状态或特征映射;  $H^*$ —输出的隐藏状态或特征映射;  
 $A$ —注意力权重矩阵, 由模型学习确定输入的哪些部分应该被给予更多关注;  
 $Q$ —查询(query);  $K$ —键(key);  $V$ —值(value);  
 $Q, K, V$ —注意力机制中的 3 个基本组件。

图3 Criss-Cross 网络结构图

在 Criss-Cross 注意力机制的工作流程中, 计算从左到右和从右到左的注意力分数, 即左向和右向注意力, 量化位置间的关联程度, 位置  $i$  到位置  $j$  的左向注意力分数矩阵<sup>[15]</sup>

$$L_{ij} = X_{ij}^T,$$

式中:  $X_{ij}$  为输入特征映射矩阵。

位置  $j$  到位置  $i$  的右向注意力分数矩阵  $R_{ij} = X_{ij}^T$ 。

对左向和右向注意力分数矩阵进行 Softmax 函数<sup>[16]</sup>处理得到双向注意力权重, 双向注意力权重反映每个位置相对于其他位置的重要性程度, 位置  $i$  对位置  $j$  的左向注意力权重矩阵

$$L_{\text{softmax}, ij} = \text{expln } L_{ij} / \text{expln } \sum_{k=1}^N L_{ij},$$

式中:  $k$  为对输入向量中的元素进行求和时的迭代变量, 从 1 开始迭代到  $N$ 。

位置  $j$  对位置  $i$  的右向注意力权重矩阵

$$\mathbf{R}_{\text{softmax},ij} = \exp \ln \mathbf{R}_{ij} / \exp \ln \sum_{K=1}^N \mathbf{R}_{ij},$$

通常采用加权平均的方法,将左向注意力权重和右向注意力权重合并得到最终的注意力权重矩阵。超参数  $\alpha$  控制左向注意力权重和右向注意力权重,  $\alpha \in [0, 1]$ , 根据任务和数据调整  $\alpha$  获得最佳检测性能,注意力权重矩阵公式为:

$$\mathbf{A}_{ij} = \alpha \mathbf{L}_{\text{softmax},ij} + (1-\alpha) \mathbf{R}_{\text{softmax},ij} \circ$$

在 Criss-Cross 注意力机制中,通过 2 个全连接层分别计算输入序列在水平和垂直方向上的注意力权重,将这 2 个注意力权重相乘得到最终的注意力权重,能有效捕捉图像中远距离像素间的依赖关系,帮助模型获取更广阔的全局上下文信息,有助于提升任务性能<sup>[16]</sup>。

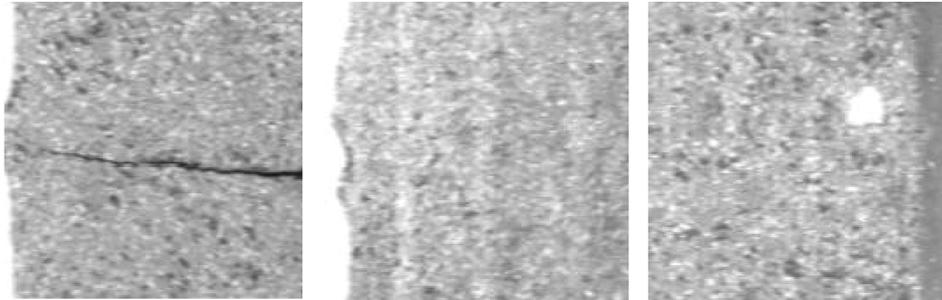
YOLOv5 结合 Criss-Cross 注意力机制可在原有基础上提高检测精度,且对图形处理器 (graphic processing unit, GPU) 内存友好、计算高效, Criss-Cross 模块可增强 YOLOv5 网络模型在不同尺度下的反馈,引入更多的上下文信息,提高网络的特征提取能力和泛化能力<sup>[17-19]</sup>,减少网络对特定场景的依赖。

## 2 试验结果与分析

基于 Windows11 操作系统,采用软件 AMD Ryzen 7 6800H with Radeon Graphics 进行训练和测试,采用 Python 3.11 为深度学习语言,Pytorch 1.7.1 为深度学习框架,以 PyCharm 为开发环境,采用 Cuda 10.1 和 Cudnn 7.6.5 编程。

### 2.1 试验数据集

采用海康 MV-CE050-31GM 工业相机拍摄距相机 0.2 m 的电机换向器元件 3 种常见的表面缺陷,包括划痕 (scratch)、破损 (damaged) 及凹陷 (sunken),如图 4 所示。



a) 划痕

b) 破损

c) 凹陷

图 4 电机换向器元件 3 种表面缺陷图片

共采集原始图片 300 张,保存为 jpg 格式,每种缺陷有 100 张图片,通过 YOLOv5 中的剪切、旋转、缩放等功能增强数据,采用 Mosaic 增强方法将图片增至每种缺陷有 800 张,即将 4 张图片随机裁剪、缩放后排列拼接成 1 张图片,丰富数据集,增加小样本目标,提升网络的训练速度<sup>[20-22]</sup>。进行归一化操作时,一次计算 4 张图片的数据,降低模型对内存的占用空间。

### 2.2 测评标准

试验结果的评价指标包括准确率  $p$ 、召回率  $r$  (衡量模型监测正类的能力)、平均检测精度均值 (mean average precision, mAP)。mAP 基于准确率、召回率、平均检测精度 (average precision, AP) 3 个标准<sup>[23-25]</sup>。

准确率

$$p = N_{\text{TP}} / (N_{\text{TP}} + N_{\text{FP}}) \times 100\%,$$

式中:  $N_{\text{TP}}$  为真正例,  $N_{\text{FP}}$  为假正例。

召回率

$$r = N_{TP} / (N_{TP} + N_{FN}) \times 100\%$$

式中  $N_{FN}$  为被预测为负类的正样本。

第  $i$  类缺陷的平均检测精度  $\overline{X_{AP_i}} = \int_0^1 p(r) dr$ , 平均检测精度均值

$$\overline{X_{mAP}} = \frac{1}{c} \sum_{i=1}^c \overline{X_{AP_i}}$$

式中  $c$  为缺陷类别数。

### 2.3 训练方法

在模型训练过程中, 下载图像识别数据集 MS COCO(微软提供的 Common Objects in Context)后, 通过深度学习框架 darknet 转换为 YOLOv5 数据集, 转换后将图像及标注按一定比例分为训练集、验证集和测试集。一般情况下, 训练集占总数据集的 70%~80%, 验证集占 10%~15%, 测试集占 10%~15%。

采用 YOLOv5m 及权重文件 yolo5m.pt 作为 YOLOv5m 模型的初始权重, 采用小批量随机梯度下降法训练模型, 单次传给程序用来训练的样本数 BatchSize 为 31, 网络的初始学习率为 0.02, 动量参数为 0.916, 权重衰减系数为 0.0006。

在 YOLO 系列算法中, YOLOv5s 模型较小, 检测速度较快, 但检测精度相对较低; YOLOv5m 模型适中, 检测速度较快, 检测精度相对较高; YOLOv5l 模型较大, 检测速度较慢, 但检测精度更高; YOLOv5x 模型最大, 检测速度最慢, 但检测精度最高<sup>[26]</sup>。采用 YOLOv5m、YOLOv5s、YOLOv5l、YOLOv5x 模型训练、测试电机换向器缺陷检测数据集, 结果如表 1 所示。

由表 1 可知: 不同 YOLOv5 模型的数据集特征单一且复杂度较低, 大部分为单标签, 适用于工厂和轻量化的缺陷检测需求; YOLOv5x 模型较大, 参数较多, 浮点运算数最大, 占用 GPU 内存较多, 但可保证较高的平均检测精度和召回率; YOLOv5m 模型的浮点运算数比 YOLOv5l 模型少, 检测速度不占优势, 但能保证在平均检测精度略逊色于 YOLOv5l 模型的同时, 占用较少 GPU 内存; YOLOv5m 模型的平均检测精度和检测速度比 YOLOv5s 高。综合考虑后选择 YOLOv5m 模型为本文的基线, 评估新模型的改进程度。

### 2.4 结果分析

为验证本文设计的有效性, 设置消融试验, 在 YOLOv5m 模型中加入 BiFPN 特征融合方法和 Criss-Cross 注意力机制, 检测电机换向器不同缺陷的平均检测精度均值, 如表 2 所示。模型 1 为增加 BiFPN 层的 YOLOv5m 模型, 模型 2 为加入 Criss-Cross 注意力模块的 YOLOv5m 模型, 模型 3 为加入 BiFPN 和 Criss-Cross 的 YOLOv5m 模型。由表 2 可知: 模型 1~3 对 3 种表面缺陷的检测平均检测精度均值比 YOLOv5m 模型大, 验证了改进算法的有效性。选择模型 3 为改进优化后模型, 检测电机换向器

表 1 不同 YOLOv5 模型检测电机换向器缺陷的结果

模型	$p$	$r$	平均检测精度	参数量	浮点运算数
YOLOv5m	0.634	0.810	0.770	21.2	49.0
YOLOv5s	0.778	0.711	0.754	7.2	16.5
YOLOv5l	0.625	0.727	0.778	46.5	109.1
YOLOv5x	0.745	0.837	0.816	86.7	205.7

注: ①参数量涉及模型大小和复杂性, 通常以参数的总数衡量, 是指构成深度学习模型的所有权重和偏差的总和。② $p$ 、 $r$  等参数在训练中被学习, 以便模型能准确预测或分类。

表 2 YOLOv5m 加入不同模块的消融试验结果

模型	BiFPN 特征融合方法	Criss-Cross 注意力机制	$\overline{X_{mAP}}$		
			划痕	破损	凹陷
YOLOv5m	×	×	0.810	0.764	0.820
模型 1	√	×	0.845	0.866	0.887
模型 2	×	√	0.852	0.859	0.875
模型 3	√	√	0.929	0.925	0.966

注: √表示加入相应模块, ×表示未加入相应模块。



## 2.5 对比试验

对改进优化的 YOLOv5m 模型完成训练后,可观察到  $p$ 、 $r$  与置信度间的关系如图 8 所示。由图 8a)可知:置信度越高, $p$  越高。由图 8b)可知:所有类别曲线与  $x$ 、 $y$  轴围成的区域占据了图片大部分的面积,说明整体优化的效果较好。

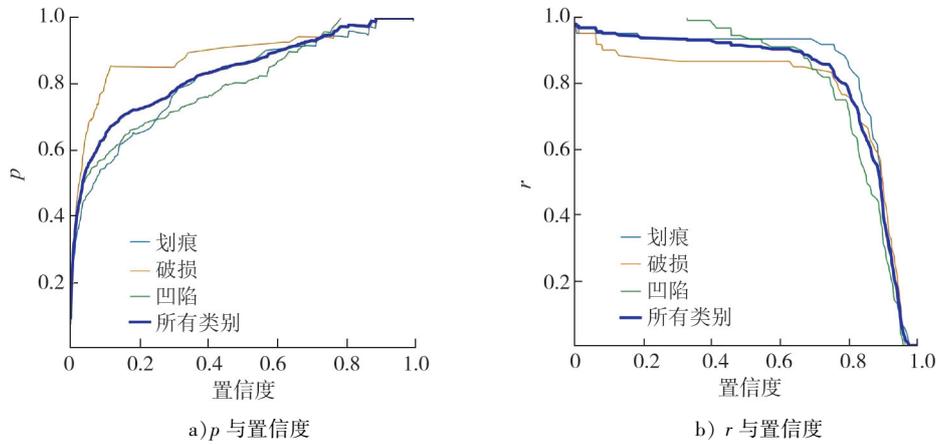


图 8 改进优化后的 YOLOv5m 模型的  $p$ 、 $r$  与置信度的关系曲线

不同模型消融试验的结果如表 3 所示,其中参数量和浮点运算数(又称为浮点计算次数)包含乘法和加法,只与模型有关,可用来衡量深度学习模型的复杂度。

表 3 不同模型消融试验的结果对比

模型	$p$	$r$	平均检测精度	参数量	浮点运算数
YOLOv5s	0.778	0.711	0.754	7.2	16.5
YOLOv5l	0.625	0.727	0.778	46.5	109.1
YOLOv5x	0.745	0.837	0.816	86.7	205.7
YOLOv5m	0.634	0.810	0.770	21.2	49.0
改进优化的 YOLOv5m	0.917	0.892	0.940	30.2	45.2

由表 3 可知:改进优化的 YOLOv5m 模型的平均检测精度为 94.0%,比传统 YOLOv5m 模型增大 17.0%;准确率增大 28.3%,召回率增大 8.2%。因模型内容增加,改进优化的 YOLOv5m 模型进行帧处理时间比传统 YOLOv5m 略长,检测速度略慢,但满足工业生产需求。

通过消融试验证明改进后的 YOLOv5m 模型均能提高原有模型在电机换向器检测缺陷的检测效果,改进后的网络可提高检测精度。

## 3 结论

1)综合考虑电机换向器缺陷检测现状及优化问题,提出融合 BiFPN 及 Criss-Cross 方法的 YOLOv5m 算法,采用 Mosaic 数据增强方法对数据集进行预处理,融入 BiFPN 层,并引入 Criss-Cross 注意力机制,实现多尺度特征融合,减少网络对特定场景的依赖,提高网络的泛化能力。

2)相较于传统 YOLOv5m 模型,改进优化的 YOLOv5m 模型的总体平均检测精度增大 17.0%,准确率增大 28.3%,召回率增大 8.2%。

此方法同样适用于其他工业应用场景,特别是对存在多尺度特征缺陷及背景较复杂的目标缺陷检测领域。同时,需研究如何进一步提高检测速度,更好地满足工业生产需求。

## 参考文献:

- [1] 崔译文,占丰,张宇峰,等.基于机器视觉的电子元器件检测系统设计[J].计算机测量与控制,2020,28(11):21-26.
- [2] 李少波,杨静,王铮,等.缺陷检测技术的发展与应用研究综述[J].自动化学报,2020,46(11):2319-2336.
- [3] 罗立浩,郑日荣,何小敏,等.基于机器视觉的电机换向器质量在线检测系统开发[J].计算机测量与控制,2016,24(7):56-61.
- [4] 罗立浩.电机换向器外观质量在线视觉检测系统[D].广州:广东工业大学,2016.
- [5] JUNG S Y, TSAI Y H, CHIU W Y, et al. Defect detection on randomly textured surfaces by convolutional neural networks [C]//2018 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM). Washington: IEEE, 2018.
- [6] GU N W, FADILLAH M F, PRAKASA E, et al. Road segmentation with U-Net architecture using Jetson AGX Xavier for autonomous vehicle[C]//Proceedings of 2022 16th International Conference on Telecommunication Systems, Services, and Applications. Washington:IEEE, 2022:1-5.
- [7] NGUYEN N H T, PERRY S, BONE D, et al. Two-stage convolutional neural network for road crack detection and segmentation[J]. Expert Systems with Applications,2021,186:115718. 1-115718. 13.
- [8] 徐晓峰.基于改进 SUSAN 算法的电机换向器孔径参数检测[J].仪表技术与传感器,2012(10):50-52.
- [9] 李树遥.换向器视觉检测的分数域分析与缺陷分类方法[D].广州:广东工业大学,2019.
- [10] SMITH S M, BRADY J M. SUSAN:a new approach to low level image processing[J]. International Journal of Computer Vision, 1997, 23(1):45-78.
- [11] TAN M, PANG R, LE Q V. EfficientDet:scalable and efficient object detection[C]//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Washington:IEEE, 2020.
- [12] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. [S. l.]:Institute of Electrical and Electronics Engineers, 2017:936-944.
- [13] CHEN J, MAI H S, LUO L B, et al. Effective feature fusion network in BIFPN for small object detection [C]//Proceedings of 2021 IEEE International Conference on Image Processing (ICIP). Washington:IEEE, 2021:699-703.
- [14] 李英群,李亚菲,裴雷,等.基于YOLOv5-ECA-BiFPN的学术期刊文献图表识别与提取方法研究[J].数据分析与知识发现,2023,7(11):158-171.
- [15] HUANG Z L, WANG X G, HUANG L C, et al. CCNet:criss-cross attention for semantic segmentation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul, Korea:Institute of Electrical and Electronic Engineers,2019:603-612.
- [16] LIU W, WEN Y, YU Z, et al. Large-margin softmax loss for convolutional neural networks[C]//Proceedings of the 33rd International Conference on Machine Learning. New York:JMLR, Workshop and Conference Proceedings, 2016: 1612. 02295v4.
- [17] YAN C, PAN W G, XU C, et al. Gaze estimation via strip pooling and multi-criss-cross attention networks[J]. Applied Sciences,2013,13(10):13105901.
- [18] HUANG L, ZHANG C, ZHANG H. Self-adaptive training:beyond empirical risk minimization[J]. Advances in Neural Information Processing Systems,2020(3):19365-19376.
- [19] ZHANG L, CHENG Y D. A densely connected criss-cross attention network for document-level relation extraction[EB/OL]. (2022-03-26)[2023-04-10]. <https://arxiv.org/abs/2203.13953>.
- [20] CUBUK E D, ZOPH B, MANE D, et al. AutoAugment:learning augmentation strategies from data[C]//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York:IEEE, 2019:113-123.
- [21] ZHANG H Y, CISSE M, DAUPHIN Y N, et al. Mixup:beyond empirical risk minimization[C]//Proceedings of ICLR 2018. [S. l.]:OpenReview. net, 2018.
- [22] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: optimal speed and accuracy of object detection [EB/OL]. (2020-09-13)[2023-04-10]. <https://arxiv.org/abs/2004.10934>.
- [23] 庞宁雅,杜安钰.基于YOLOV5s-Attention的表面缺陷检测的应用研究[J].现代电子技术,2023,46(3):39-46.
- [24] 施恺杰,王颖,王嘉璐,等.基于深度学习的电子换向器表面缺陷检测[J].网络安全技术与应用,2021(6):113-115.

- [25] WU Z L,ZHANG D,SHAO Y H,et al. Using YOLOv5 for garbage classification[C]//Proceedings of the 4th International Conference on Pattern Recognition and Artificial Intelligence. New York:IEEE,2021:35-38.
- [26] 周贤勇,祝俊辉,王圆,等.基于改进 YOLOv7 的 PCB 裸板缺陷检测[J].无线电工程,53(12):1-13.

## Motor commutator defect detection based on YOLOv5m

*XU Yuntao, JIAO Peigang<sup>\*</sup>, LIU Jiaqi*

*School of Construction Machinery, Shandong Jiaotong University, Jinan 250357, China*

**Abstract:** To reduce the detection cost of motor commutator defects, and improve detection efficiency, and meet the balanced requirements of detection accuracy and speed in practical engineering, an optimized and improved surface defect detection algorithm based on the YOLOv5m model is proposed. The collected data is enhanced through Mosica data augmentation to enhance the robustness of model. In other layers, the bidirectional feature pyramid network (BiFPN) layer is used instead of the path aggregation network (PANet) layer, introducing bidirectional connections and cross-layer feature fusion mechanisms, and adding a Criss-Cross attention mechanism to better capture relevant information in the input sequence, and enhance network feedback at different scales, and verified through ablation experiments. The results show that compared to the traditional YOLOv5m model, the average precision (AP), accuracy, and recall of the optimized and improved YOLOv5m model increases by 17%, 28.3%, and 8.2%, respectively. While ensuring detection accuracy, the detection time for defects is shortened, better meeting the balanced requirements of detection accuracy and speed in defect detection engineering.

**Keywords:** motor commutator; surface defect; YOLOv5m; attention mechanism; feature fusion

(责任编辑:王惠)

(上接第9页)

model of the two-wheel balanced wheelchair is established based on the Euler-Lagrange equation, and the motion relationship is established through the differential geometric model. The Pure Pursuit algorithm is used to plan the target motion state of the system, and model predictive control (MPC) and linear quadratic optimal control (LQR) are used to balance and track the motion state of the two-wheel balanced wheelchair. The simulation system for the control of the two-wheel balanced wheelchair is built through software Simulink to verify the trajectory tracking effect and tracking stability of the two-wheel balanced wheelchair system when LQR and MPC controllers are used. The simulation results show that the dynamic response speed of the MPC controller is faster than that of the LQR controller, and the MPC controller can quickly restore the stable state of the vehicle body when acting on the vehicle body; when tracking the trajectory, the MPC controller has better stable control of the vehicle body inclination angle and speed at the starting and ending positions than the LQR controller.

**Keywords:** two-wheel balanced wheelchair; LQR controller; MPC controller; trajectory tracking

(责任编辑:赵玉真)