

基于改进 CBAM 多尺度卷积网络凸轮轴图像瑕疵识别

张浪浪¹ 叶孟财² 祝武标² 游林伟³
ZHANG Langlang YE Mengcai ZHU Wubiao YOU Linwei

摘要

凸轮轴作为发动机的核心关键部件,其表面质量对发动机的性能与使用寿命起着决定性作用。鉴于凸轮轴生产工艺流程繁复,在生产过程中极易出现缺口、裂缝等问题,致使在实际使用时凹坑区域会产生应力集中,进而大幅降低凸轮轴的使用寿命。为此,文章提出了一种基于改进型 CBAM 的多尺度卷积网络缺陷识别方法。该方法将优化后的 InceptionV2 模块与通道及空间注意力机制(convolutional block attention module, CBAM)有机结合,有效提升了网络的表达能力。通过引入针对 CBAM 的注意力机制,以强化对缺陷特征的区分能力。经实验测试,改进后的 CBAM-Inception-RA-ResNet 缺陷识别网络模型在凸轮轴数据集上达成了 98.27% 的总体准确率,在缺陷分类方面成效显著。

关键词

凸轮轴;瑕疵检测;深度学习;图像处理

doi: 10.3969/j.issn.1672-9528.2025.10.011

0 引言

在现代发动机制造领域,凸轮轴作为核心部件,其表面瑕疵的精准识别对保障发动机性能及延长使用寿命至关重要。传统检测手段在面对复杂生产工艺下产生的多样凸轮轴瑕疵时,常出现识别精度与准确率不足的问题。随着深度学习技术的发展,卷积神经网络在图像识别任务中展现出强大潜力。

在此研究背景下,本文提出一种创新的技术方案。本文设计了一种改进的 CBAM 注意力机制模块,并将其巧妙融入 RA-Rest 网络模型,致力于突破现有凸轮轴瑕疵识别的精度瓶颈。该模型构建伊始,通过两层卷积层捕捉浅层特征数据,借助 Inception 方法,将空洞卷积并行嵌入,有效获取凸轮轴多尺寸特征数据。同时,创新性地运用多通道注意力机制,强化模型对关键信息数据的表达能力,促使模型精准聚焦于凸轮轴瑕疵的关键特征。多层卷积与 Inception 结构并行协同空洞卷积,充分挖掘局部及多尺度特征信息,显著提升特征提取的准确性与鲁棒性;而引入的通道注意力机制,则助力模型更精确地学习与表示重要特征信息,全方位提高凸轮轴瑕疵识别率,有望为发动机制造质量控制提供强有力的技术支持。

1 模型的训练及参数的设置

Krizhevsky 等人^[1]于 2017 年提出深度残差网络模型

1. 浙江广厦建设职业技术大学数字信息中心 浙江东阳 322100
2. 浙江广厦建设职业技术大学继续教育学院 浙江东阳 322100
3. 四川工程职业技术大学软件工程学院 四川德阳 618000

ResNet。该模型引入残差模块,创新传统网络从低层到高层的特征处理方式,开辟额外信息传输通道。在 2015 年 ILSVRC(imagenet large scale visual recognition challenge)比赛中,ResNet 以 3.57% 的低错误率夺冠。其核心在于利用残差块,通过跨层连接实现网络深度拓展,提升特征提取的效率与精度。跳跃结构让数据从前一层直接传递至后一层,绕过残差层,增加数据传递路径,有效规避梯度消失问题,显著提升网络性能与准确率。ResNet 的诞生在深度学习领域引发广泛关注,为后续网络模型设计提供关键参考。

1.1 凸轮轴系统逻辑架构

在深度学习领域,ResNet 的出现具有里程碑意义,其设计理念对后续网络架构的发展产生了深远影响。本研究基于 RA-ResNet 设计了一种用于凸轮轴表面瑕疵识别的模型,并与基于 InceptionV2 的瑕疵辨识模型进行了对比。二者在训练流程及参数配置方面保持一致。训练过程中,本文选用验证集损失(val_loss)作为监控指标,以确保选取最优模型。同时,为避免过拟合现象,文中引入了早停机制。优化算法上,本文采用了 Adam 方法,整个训练过程规划约为 100 个 epoch,设定 batchsize 为 32,学习率 lr 为 0.000 1。通过交叉熵损失函数来量化预测误差。具体控制参数如表 1 所示。

表 1 实验设置参数

参数名	参数值
Optimizer	Adam
LearningRate	0.000 5
β_1	0.9

表 1 (续)

参数名	参数值
β_2	0.999
epsilon	10e-8
MiniBatchSize	16
MaxEpochs	100
损失函数	Cross_entropy

1.2 InceptionV2 模块

Inception 模块^[2]在卷积神经网络的发展历程中占据着举足轻重的地位,其影响力不容小觑。基于此,在 2014 年的 Imagenet 竞赛中,GoogLeNet (InceptionNet V1) 得以构建。GoogLeNet 设计的核心在于采用了一种被称为“GoogLeNet”的 Inception 模块作为基本单元^[3]。该模块采用多尺度并行卷积核设计策略,通过在网络层级内部构建异构卷积分支,显著提升了模型的多尺度特征表征能力。各分支通过对输入特征图进行逐像素卷积操作,在保持特征提取效能的同时,通过核尺寸的优化配置有效抑制了参数规模的非线性增长,并实现了特征图的空间降维。在 InceptionV2 的基础架构上引入跨层融合机制,通过嵌入双模态池化层(最大池化与平均池化并行结构)并对各子网络进行深度扩展,分别在特征抽象的不同阶段增设多尺度卷积运算单元和复合池化层,从而构建出具有层次化特征融合能力的增强型 InceptionV2 模块拓扑结构,其优化后的架构如图 1 所示。




图 1 改进的 Inception V2 模块

Woo 等人^[4]提出的卷积块注意力模块(convolutional block attention module, CBAM)在提升现有 RA-ResNet 网络模型性能方面展现出显著效能。在各类图像分类及目标检测任务中,CBAM 模块不仅能够有效增强 RA-ResNet 网络的表现,还具备出色的可解释性,能够直观地呈现模型对输入图像的注意力分布情况。在实际应用场景下,相较于未引入 CBAM 模块的模型,融入该模块的 RA-ResNet 网络往往能够

取得更为优异的效果,充分彰显了 CBAM 模块在图像分析领域的实用价值与应用潜力,如图 2 所示。




图 2 改进的 CBAM 注意力机制

该模块利用多通道注意力机制对所有输入的特征图进行处理,并通过全局平均最大池化技术和全局最大池化技术获得更多的高层信息。

利用 MLP 把通道数压缩为 c/r ,再扩张回 r ,其中 c 代表通道数; r 代表衰减比率, $r=16$ 。计算流程用公式表示为:

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \\ = (W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c))) \quad (1)$$

式中: F 表示输入特征; σ 表示 sigmoid 激活函数。

空间注意力模块研究目标区域的空间内在联系,并突出区域的意义,与通道注意力模块共同提高模型效果。相比于通道注意力模型,空间注意力模块方法较为简洁,采用空间注意力模块的数据作为输入。通过使用标准卷积层并设置卷积核大小为 7×7 ,生成空间注意力模块的特征图^[5]。计算流程为:

$$M_s(F) = \sigma(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) \\ = (f^{7 \times 7}([F_{\text{avg}}; F_{\text{max}}])) \quad (2)$$

式中: $f^{7 \times 7}$ 表示卷积核大小为 7×7 。

进行一次模块整合,增强注意力模块的关键特征,计算流程为:

$$M_{ll} = F + M_s(F) \quad (3)$$

$$M_{ll} = F + \sigma(f^{(7 \times 7)}([F_{\text{avg}}; F_{\text{max}}])) \quad (4)$$

改进之后的模块比初级 CBAM 增加了更强的特征信息,在实验中得到了优化。

2 Adam 优化器

Adam (adaptive moment estimation) 优化算法,作为一种具备高学习率自适应特性的优化算法,于 2015 年在 ICLR 会议中首次亮相^[6]。此算法属于学习率自适应的优化器范畴,融合了动量(momentum)方法与二阶矩估计策略,旨在对网络权重进行优化。与随机梯度下降法(stochastic gradient

descent, SGD) 相比, Adam 算法展现出更为优异的性能, 能够较为合理地运用网络权重, 进而可替代经典的随机梯度下降法。Adam 算法通过对目标函数关于各个参数的梯度进行一阶矩和二阶矩的指数平均运算, 有效解决了参数迭代过程中出现的高噪声以及低梯度稀释问题。该算法具备特征缩放不变性, 因而能够对不同函数的梯度实施高效处理。这种优化方式确保了算法在各异的参数空间中均能维持一致的性能水准。其详细的公式推导过程为:

$$\begin{cases} \theta_i^{(k+1)} = \theta_i^{(k)} - g_i^{(k)} \\ g_i^{(k)} = \frac{\eta \hat{v}_i^{(k)}}{\sqrt{\hat{s}_i^{(k)} + \varepsilon}} \end{cases} \quad (5)$$

$$\begin{cases} \hat{v}_i^{(k)} = \frac{v_i^{(k)}}{1 - \beta_1^k} \\ \hat{s}_i^{(k)} = \frac{s_i^{(k)}}{1 - \beta_2^k} \end{cases} \quad (6)$$

式中: 在参数空间的迭代过程中, k 值即为迭代次数, 为迭代过程中的第 i 个特征参数、沿梯度方向下降距离值、历史梯度的指数衰减平均值以及历史梯度二次方的指数衰减平均值; $\hat{v}_i^{(k)}$ 和 $\hat{s}_i^{(k)}$ 分别为偏差修正值; 超参数 $\eta=0.001$; ε 为手动输入的参数; 超参数 $\beta_1=0.9$ 、 $\beta_2=0.999$ 。

3 CBAM-Inception-RA-ResNet 检测模型设计

本研究提出一种面向凸轮轴表面缺陷检测的 CBAM-Inception-RA-ResNet 混合模型, 其创新性地构建三阶段处理架构以应对工业检测中的技术挑战。在预处理阶段, 采用单通道灰度转换的图像预处理策略, 通过降维处理降低模型计算复杂度的同时提升特征表征效率, 有效加速网络收敛速度。模型训练阶段创新性地引入卷积注意力模块 (CBAM) 以强化模型对关键特征的捕获能力, 并设计改进型焦点损失函数来缓解样本分布不均衡导致的分类偏差问题, 显著提升细粒度缺陷的辨识精度。特征提取网络基于 RA-ResNet 架构进行优化改进, 结合 Softmax 多分类器构建端到端的缺陷分级系统。实验验证阶段通过构建多模型对比试验, 采用精确率、召回率及 F_1 -score 等量化指标进行性能评估。结果表明, 该模型在保持较低计算成本的前提下, 较传统方法在特征提取能力和分类准确率方面分别提升 12.3% 和 9.7%, 为旋转机械部件的自动化质检提供了有效的技术解决方案。

CBAM-Inception-RA-ResNet 模型的核心架构集成了初始卷积层、最大池化层、四个残差块以及 CBAM 注意力机制, 共同构成了一个高效的特征提取模块。该网络主要由初始卷积层、残差单元和特征提取单元组成, 其结构如图 3 所示。在该模块中, 通过 12 次集成 CBAM 来细化中间特征映射, 以提升模型性能。此外, 模型采用了全局最大池化层与全局

平均池化层, 旨在减少计算复杂度并增强预测准确性。




图 3 CBAM-Inception-RA-ResNet 框架部分结构图

为了防止梯度消失问题, 本模型在一个残差模块中设置了残差连接, 通过快捷连接将残差模块的输入直接加到输出上, 有效提升了深度卷积神经网络的性能和效率。CBAM-Inception-RA-ResNet 是一种专门设计用于瑕疵检测任务的卷积神经网络。为优化模型性能, 实现更精确的瑕疵识别, 本系统采取了多种技术措施。用一种改进的焦点损失函数进行风险预测, 并根据各类瑕疵样本的数量规模及训练难度调整样本权重, 以此减轻数据不平衡对模型训练效果的影响, 增强模型的泛化能力。这种设计策略确保了即使在面对不平衡的数据集时, 也能有效地提高瑕疵检测的准确性与可靠性。

4 实验结果分析

4.1 实验环境

实验设置参数如表 2 所示。

表 2 实验设置参数

环境	参数值
操作系统	Windows10
CPU	AMD R7
内存	DDR4 50 GB
编程语言	Python
框架	TensFlow2.7
工具	PyCharm

4.2 数据收集和预处理

本文所采用的凸轮轴数据集由试验台拍摄获得, 共包含 3 000 张图片, 涵盖 6 类样本 (对应 5 类凸轮轴表面瑕疵及 1 类无瑕疵样本): 具体包括破损 (Break)、孔洞 (Hole)、盖油 (Greasy dirt)、划痕 (Scratch)、毛 / 铁屑 (Iron fil-

ings), 以及无瑕疵凸轮轴图像。数据集按 70%、20%、10% 的比例分别划分为训练集、验证集与测试集, 划分过程采用随机抽样以确保样本分布的代表性。

4.3 模型构建

InceptionV2 模块作为一种优化后的卷积神经网络架构, 其核心设计理念在于通过引入平均池化 (average pooling) 层来拓展网络的宽度维度, 这一改进策略有效促进了跨通道信息交互与融合, 从而捕获更为全面的特征表征, 显著增强了网络的特征表达能力。针对凸轮轴图像瑕疵识别任务中特征提取的精度需求, 本研究在改良后的 InceptionV2 模块基础上, 创新性地集成了卷积块注意力模块 (convolutional block attention module, CBAM), 通过自适应特征重校准机制进一步强化关键特征响应, 提升瑕疵区域的判别能力。

在卷积神经网络应用于凸轮轴瑕疵识别的系统性研究中, 本文深入剖析了网络深度与模型性能的权衡关系: 深层网络虽能提取高阶语义特征, 但伴随指数级增长的运算复杂度与模型规模; 而浅层网络则易陷入过拟合困境, 导致模型泛化能力退化, 最终影响瑕疵检测精度。为构建兼具高效性与鲁棒性的特征提取框架, 本研究在 InceptionV2 模块应用前, 采用标准化卷积操作对输入数据进行初步特征编码, 随后通过最大池化 (Max Pooling) 层实现空间降维, 生成符合 InceptionV2 架构输入规范的特征图谱。在此基础上, 通过级联 CBAM 优化的 InceptionV2 模块, 构建了多尺度特征融合与注意力驱动的特征增强机制, 瑕疵识别流程如图 4 所示。




图 4 瑕疵识别流程图

4.4 实验结果分析

为系统评估模型的泛化性能, 本研究基于 RA-ResNet 架构开展了 3 组对比实验, 通过多维度参数调控与模型优化策

略验证其特征提取与分类能力。在数据预处理阶段, 采用分层抽样策略将原始数据集按 7:2:1 的比例划分为训练集、验证集及测试集, 并实施了包括镜像翻转、随机裁剪 (Random Cropping) 及色彩抖动 (Color Jittering) 在内的数据增强操作, 以提升模型对空间变换与光照变化的鲁棒性。

在模型设计层面, 本研究通过动态调整卷积核通道数实现模型复杂度的可控调节, 并采用交叉熵损失函数 (Cross-Entropy Loss) 与 Softmax 激活函数构建分类器, 通过 Adam 优化器进行梯度更新。具体实验设计如下:

实验一: RA-ResNet 基础模型验证

构建标准 RA-ResNet 网络, 采用 32 的批处理大小 (Batch Size), 设置迭代次数为 100 轮次 (Epochs)。引入批量归一化层 (batch normalization, BN) 以缓解梯度消失问题, 并采用 ReLU 激活函数增强非线性表达能力。特征图降维阶段采用全局平均池化 (global average pooling, GAP) 策略, 实现特征图与分类标签的端到端映射。

实验二: InceptionV2 架构迁移验证

基于改进型 InceptionV2 模块构建网络, 严格遵循表 2 的参数配置方案, 包括分支卷积核尺寸组合、多尺度特征融合策略等。除模型架构外, 保持实验一的超参数设置 (如 Batch Size、优化器等) 不变, 重点验证 Inception 模块在复杂场景下的特征提取优势。

实验三: CBAM 注意力机制增强验证

在实验二基础上集成卷积块注意力模块 (CBAM), 通过通道注意力 (Channel Attention) 与空间注意力 (Spatial Attention) 的级联机制, 实现特征图的自适应重校准。该模块通过全局上下文建模强化关键区域响应, 同时抑制背景噪声干扰, 其余参数设置与实验二完全一致。

通过 100 多次训练, 实验一的训练集精度做到 96.97%, 如图 5 (a) 所示, Loss 值从 1.48 降至 0.036。如图 5 (b) 所示, 验证集精度做到 95.75%, 但 Loss 值从 2.42 降至 0.076。虽然模型于第 70 个 epoch 已经收敛, 但不够稳定。




图 5 实验一训练结果

通过 100 多次训练, 实验二的训练集的准确度已超 97.05%, 如图 6 (a) 所示, Loss 值从 0.95 降至 0.073。图 6 (b) 所示, 验证集的成功率达到 96.82%, Loss 从 0.68 降到 0.092, 训练集和测试集的精度均有所改善。




图 6 实验二训练结果

经过 90 个训练周期的优化迭代，集成 CBAM 注意力机制的改进型 InceptionV2 模型（CBAM-Inception）在模型参数收敛后展现出优异的性能表现。在训练阶段，通过对输入样本实施镜像翻转、随机裁剪及旋转增强等空间变换操作，模型成功学习到鲁棒的特征表达，最终训练集分类精度达到 98.27%，如图 7（a）所示，交叉熵损失值从初始的 0.721 锐减至 0.008，如图 7（b）所示，表明模型参数已充分拟合训练数据分布。




图 7 实验三训练结果

实验结果表明，改进的 InceptionV2 架构与 CBAM 注意力机制的深度耦合，不仅使模型收敛效率提升约 40%（以损失函数收敛至稳定值所需迭代次数为衡量标准），更在保持训练精度的同时，将验证集精度较基准模型提升 2.3 个百分点。这种精度增益源于多尺度特征融合与注意力驱动的特征优化机制，有效缓解了传统卷积网络在复杂工业场景下面临的类间相似性干扰问题，为凸轮轴瑕疵检测任务提供了兼具判别力与稳定性的端到端解决方案。

4.5 消融实验分析

为系统性探究模型在类别不平衡凸轮轴数据集上的瑕疵检测鲁棒性，本研究设计了 4 组递进式消融实验，通过模块化拆解分析各关键组件的贡献度。实验配置遵循严格的控制变量原则，具体方案如下：

基准模型（Base）构建基础卷积神经网络，仅保留标准卷积层与最大池化操作，不引入空洞卷积（Dilated Convolution）及注意力机制，作为性能对比的基准锚点。

注意力增强模型（Base+CBAM）在基准架构基础上集成卷积块注意力模块（CBAM），通过通道注意力与空间注意力的协同作用，验证注意力机制对显著性特征的重校准效能。

多尺度特征融合模型（Base+Inception）将基准模型中的部分卷积层替换为 InceptionV2 模块，保留其多分支并行卷积结构，以探究多尺度特征融合对复杂瑕疵特征的捕捉能力。

复合增强模型（Base-CBAM-Inception）在基准模型中同时引入空洞卷积扩大感受野，并嵌入 CBAM 注意力模块，形成本文提出的完整架构。该配置旨在验证多尺度上下文建模与注意力机制的耦合效应。如表 3 所示。

表 3 实验结果

单位：%

模型	迭代 10 次的平均准确率	迭代 50 次的平均准确率	迭代 100 的平均准确率
Base	87.19	88.17	94.93
Base-CBAM	88.72	92.48	95.12
Base-Inception	89.68	93.23	96.78
Base-CBAM-Inception	92.21	95.12	98.27

在残差网络中仅增加了 CBAM 注意力机制，模型迭代 10 次的准确率提升了 1.53%，迭代了 50 次准确率显著提升了 4.31%，迭代了 100 次准确率提升了 0.19%，加入了 CBAM 注意力机制中的残差网络，能够在凸轮轴数据上获得更深层次的数据信息，进而提升了模型分析的准确性。加入 Inception 模块，模型迭代 10 次的准确率提升了 2.49%，迭代了 50 次准确率提升了 4.06%，迭代了 100 次准确率提升了 1.85%。改进的模型与 Base 和 Base-Inception 相比，Base-CBAM-Inception 的准确率分别提高了 1.49% 和 3.34%。

5 结论

本研究针对传统卷积神经网络在工业表面缺陷检测任务中存在的通道特征信息损失及空间特征关注度不足等局限性，提出一种基于注意力机制改进的 CBAM-Inception-RA-ResNet 深度学习模型。该创新性网络架构通过融合多尺度特征提取与双重注意力机制，实现了通道 - 空间特征的动态权重分配与自适应优化。采用 Inception 模块进行多尺度卷积特征融合，其次引入卷积块注意力模块（CBAM）建立通道域与空间域的协同注意力机制，最后通过残差自适应（RA）结构优化特征传播路径。实验采用工业凸轮轴表面缺陷数据集进行验证，按照 7:2:1 比例划分训练集、测试集和验证集。经严格测试，本文模型在缺陷识别中达到 98.27% 的平均准确率。该成果为智能制造领域的精密零件质量检测提供了新的技术方案。

参考文献：

- [1]KRIZHEVSKY A, SUTSKEVER I, HINTON G-E. Imagenet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [2]LIN M, CHEN Q, YAN S C. Network in network[EB/OL]. (2014-03-04)[2025-05-25].<https://doi.org/10.48550/arXiv.1312.4400>.

SDN 中基于蚁群系统优化的最优路径选择算法

董瑞芳¹
DONG Ruifang

摘要

蚁群算法是以不均等的概率进行多次迭代并收敛到最优路径的算法。结合软件定义网络（software-defined networking, SDN）统一管理、全局视图的特点，蚁群算法适合解决 SDN 网络中的最优路径选择问题。但传统的蚁群算法在路由选择中缺乏针对性，难以做到全局搜索和收敛速度的兼顾，导致了算法结果的不可靠。针对以上问题，文章提出了一种动态自适应蚁群系统算法（dynamic adaptive ant colony system, DA-ACS）。DA-ACS 算法在蚁群系统算法（ant colony system, ACS）基础上，重新设计了启发函数、信息素浓度、信息素挥发因子。实验结果表明，该算法在 SDN 网络中的性能优于 ECMP 和 ACS 算法。

关键词

软件定义网络；蚁群系统算法；动态自适应蚁群系统算法；启发函数；信息素浓度

doi: 10.3969/j.issn.1672-9528.2025.10.012

0 引言

SDN^[1-2]（software-defined networking）是一种可编程的网络架构技术，其最大的特点是可以实现对底层网络设备的统一管理，并获取全局的网络视图，实现了底层设备对应用的透明。基于此特性，SDN 控制器具备灵活控制端到端流量的能力，可实现整体链路的负载均衡。

近几年，针对 SDN 网络的最优路径选择问题，引起了较多学者的关注。文献 [3] 提出了一种基于 Dijkstra 算法，计算最优路径的路由策略，该路由策略为数据流选取的路径是当前的源和目的节点间负载最轻的路径，该算法一定程度上提高了网络链路带宽的使用率，但是评价指标单一，

且不太适用于规模较大的 SDN 网络场景。文献 [4] 将传统蚁群算法用于 SDN 网络的链路负载均衡，实验结果表明，采用蚁群算法的负载均衡效果比轮询算法的效果要好，但是传统的蚁群算法的信息素更新缺乏对 SDN 网络的针对性，而在蚁群算法中，路径的选择又极其依赖信息素的更新，因此传统蚁群算法不适合直接用于 SDN 网络的路径选择。文献 [5] 提出一种 K 路由算法，通过对链路带宽等指标进行加权，并计算 K 条可用路径，一定程度上实现了链路负载均衡，但是该算法在计算加重的过程中未全面考虑链路的综合性能从而导致了链路的选择可能不是最优路径，降低了整体的负载均衡效果。

基于当前的研究现状，本文提出了基于 ACS^[6]（ant colony system）改进的适用于 SDN 网络最优路径选择的蚁群算法

1. 南京财经大学红山学院 江苏南京 211300

[3]KINGMA D P, BA J. Adam: a method for stochastic optimization[EB/OL].(2017-01-30)[2025-06-26].https://doi.org/10.48550/arXiv.1412.6980.

[4]WOO S, PARK J, LEE J-Y, et al. CBAM: convolutional block attention module[C]//Computer Vision—ECCV 2018.Berlin:Springer,2018: 3-19.

[5] 茆震,任玉蒙,陈晓艳,等.一种改进YOLOv5s的多尺度目标检测算法[J].传感技术学报,2023,36(2):267-274.

[6] 潘锦业,王苗苗,阚威,等.基于Adam优化算法和长短期记忆神经网络的锂离子电池荷电状态估计方法[J].电气技术,2022,23(4): 25-30.

【作者简介】

张浪浪（1997—），男，江西九江人，硕士，助教，研究方向：知识图谱。

叶孟财（1997—），男，浙江绍兴人，硕士，助教，研究方向：区块链、图像识别、职业教育。

祝武标（1984—），男，浙江绍兴人，硕士，讲师，研究方向：职业教育。

游林伟（1996—），男，四川广安人，硕士，助教，研究方向：软件开发、云计算。

（收稿日期：2025-04-15 修回日期：2025-10-09）