

[缺陷检测]

基于轻量级卷积神经网络的输电线路绝缘子缺陷检测

文/张妍 赵柏然 袁雨桐 贺伟章
国网青海省电力公司西宁供电公司

输电线路绝缘子在电力系统中的作用至关重要。在过去几年中，随着人工智能技术的不断进步，基于无人机的智能巡检技术在电力设备检测领域受到了广泛关注。特别是针对绝缘子缺陷的检测，由于其对实时性和计算资源的要求较高，成为了研究的热点之一。为了解决这一挑战，研究人员提出了两种基于YOLOv5算法的轻量化改进方案。

在电力传输网络中，绝缘子是确保空中高压线路操作安全与可靠的基石，承担着托举导电电缆、隔绝电气通路以防漏电的核心职能。这些设施长期直面自然环境的挑战，从烈日暴晒到严寒侵袭，再到风雨雷电的洗礼，其物理状态难免受损，诸如内在裂纹扩展或外在破损等问题频发^[1]。绝缘子的意外失效不仅会触发局部甚至广泛的停电事故，还可能诱发电网系统的连锁故障，严重影响社会运作与居民生活质量。鉴于此，实施定期且高效的绝缘子健康监测与维护策略显得尤为重要，这是保障电力供应链坚韧性、满足日益增长电力需求的关键措施。通过采用先进的检测技术和智能化巡检手段，能够在问题初期即发现潜在隐患，及时采取修复或更换措施，从而有效避免大规模电力中断事件的发生，确保电力系统的持续稳定运行。这些方法在促进电力高效传输到电网中发挥了不可或缺的作用^[2]。

经典YOLOv5S网络

图1呈现了YOLOv5S模型的网络布局，该布局由四个主要部分构成：输入端、特征提取层（称为“脊柱”）、特征整合层（称为“喉咙”）以及最终的检测输出层（称为“皇冠”）。

YOLOv5S模型在输入阶段采用了Mosaic数据增强技术，通过结合多张图片来增加训练样本的多样性和鲁棒性。此外，该模型还使用了自适应计算和自适应图像缩放技术，以减少工作负载并提高模型的效率。在主干网络中，YOLOv5S采用了CSPDarknet-53架构进行特征提取。这种架构有效地减少模型的计算负担和存储需求，同时增强特征表示的鲁棒性。通过空间金字塔池化模块（SPPF），模型能够整合不同尺度的特征图，从而提取多尺度的目标信息^[3]。颈部网络是YOLOv5S模型的核心组件之一，它无缝集成特征金字塔网络（FPN）和路径聚合网络（PAN）。通过上采样和下采样操作，颈部网络能够融合不同尺度的特征图，从而实现有效融合。这种方法增强模型的特征表达能力，使得特征图可以汇集成一个信息更丰富的特征图。在预测头网络中，YOLOv5S使用了CIoU（完全交并比）作为其损失函数来进行边界框回归预测。CIoU考虑了边界框之间的重叠面积和中心点距离，能够更准确地衡量边界框的质量。此外，该模型还集成了NMS算法来细化预测框，以提高检测的准确性。最终，YOLOv5S通过三个不同尺度上的卷积操作生成预测框的位置、类别概率和置信度。这些预测结果经过后处理后，可以得到最终




图1 经典YOLOv5s网络结构图

的目标检测结果。

轻量级改进计划

1. YOLOv5-MobileNetV3网络

在YOLOv5模型的Backbone架构中，创新性地融合了轻量级卷积神经网络MobileNetV3的核心bneck模块，由此孕育出了全新的YOLOv5 MobileNetV3变体。图2详细揭示了这一bneck结构的奥秘，它作为MobileNetV3的精髓所在，首先对输入的特征图施以 1×1 卷积操作，旨在提升其维度，随后通过 3×3 深度卷积深入挖掘特征信息，并巧妙融入了SE（Squeeze-and-Excitation）模块以增强特征表达。在SE模块内部，特征矩阵的 C 个通道被精心处理：首先进行池化操作，将每

个通道压缩成包含 C 个元素的一维向量，接着这 C 个元素经由两个精心设计的全连接层，最终输出一个向量。该向量精准地反映了特征矩阵中每个通道的重要程度，并据此为每个通道分配相应的权重。这些权重随后被应用于特征矩阵，借助SE注意力机制的魔力，生成了一张富含关注点的新特征图。值得一提的是，SE瓶颈的尺寸被巧妙地调整为扩展层通道数的 $1/4$ ，这一改动在不增加额外时间开销的前提下，显著提升了模型的准确性。最后一步，采用了 1×1 卷积来优雅地降低特征图的维度，并在此过程中运用线性激活函数，确保了信息的线性传递，避免了低维空间中非线性操作可能带来的信息损失。此外，还引入了残差反转结构，这一设计使得网络能够在内部自如地扩展至更高维度的特征空间，从而更加高效地捕获和提炼信息，极大地提升了特征提取的能力。图3展示YOLOv5-MobileNetV3网络结构示意图。




图2 MobileNetV3 bneck结构

MobileNetV3通过采用创新的h-swish激活函数，针对移动设备常见的计算能力限制问题提供了解决方案。传统swish激活函数因其计算密集型特性，在资源受限的移动设备上运行时面临挑战。h-swish通过引入h-sigmoid函数取代原有的sigmoid部分，大幅降低了计算复杂度，从而加快了模型的推理速度并减轻了对硬件资源的负担。这种改进使得MobileNetV3更加适合于在移动设备上部署，同时保持了模型的性能和效率。原始的激活函数swish计算公式为

$$\text{switch}(x) = x \text{sigmoid}(x) \quad (1)$$

优化后的h-swish计算公式为

$$\begin{cases} h\text{-switch}(x) = xh - \text{sigmoid}(x) \\ h\text{-sigmoid}(x) = \frac{\text{ReLU}6(x+3)}{6} \\ \text{ReLU}6(x+3) = \min(\max(0, x+3), 6) \end{cases} \quad (2)$$




图3 展示YOLOv5-MobileNetV3网络结构的示意图




图4 YOLOv5-GhostNet网络结构图

2. YOLOv5-GhostNet网络

YOLOv5模型的网络架构中融入了GhostNet的核心创新——Ghost模块，这一举措标志着轻量级卷积神经网络技术的前沿探索。Ghost模块以其独特的设计哲学，旨在通过生成“幽灵”特征图来高效利用计算资源，从而在保持模型性能的同时显著降低运算开销。这种集成不仅优化了YOLOv5的架构，还增强其在复杂场景下的检测能力，特别是在对实时性和资源效率有严格要求的应用场景中展现出卓越优势。

传统的YOLOv5卷积被Ghost模块取代，Ghost瓶颈结构替代了瓶颈结构，从而形成了YOLOv5 GhostNet模型。图4展示了网络架构。

Ghost模块通过一种创新的策略，实现了特征图的高效轻量化处理，其核心在于利用低成本的线性运算来剔除冗余信息。具体过程如图5所展示。首先，模块采用标准卷积操作生成一个基础特征图；随后，该特征图被分为两路，一路直接通过恒等映射保持其原始状态，而另一路则经历一系列成本较低的线性变换。最终，这两路特征图合并，共同构成了Ghost模块的输出。这一机制不仅保留了关键特征，还大幅减少了计算资源的消耗。




图5 Ghost模块架构

与传统的卷积操作相比较，Ghost模块能够大幅降低计算量。其证明过程如下：

如果令输入特征图的尺寸由垂直方向的 a 、水平方向的 b 、以及通道数 c 来表示。而生成的特征图则拥有高度 h 、宽度 g 和通道 n 的维度。卷积核的维度为 $k \times k$ ，线性操作后的维度变为 $p \times p$ 。初始特征图包含 m 个通道，而生成的幻影特征图具有 s 个通道。在这种情况下， $m=n \div s$ 是准确的。

传统的卷积操作为

$$f_1 = n \times h \times w \times c \times k \times k \quad (3)$$

Ghost模块的计算量为

$$f_2 = m \times h \times w \times c \times k \times k + m \times (s-1) \times h \times w \times m \times p \times p \quad (4)$$

操作压缩比为

$$r = \frac{f_1}{f_2} = \frac{c \times k \times k}{\frac{1}{s} \times c \times k \times k + \frac{s-1}{s} \times p \times p} \approx \frac{1}{\frac{1}{s} \times c + \frac{s-1}{s}} = \frac{c \times s}{c + s - 1} \approx \frac{c \times s}{c} = s \quad (5)$$

式中， $k \times k$ 的大小接近于 $p \times p$ ； s 远小于 c 。

由此可见，使用Ghost模块进行卷积操作可以达到轻量化的要求。

实验及结果分析

1. 绝缘子数据集

在目前的研究中，学者们使用了中国电力线路绝缘子数据集（CPLID），这是一个由中国国家电网公司提供的公开数据集。为了优化模型在检测绝缘子状态的任务中的表现，对数据集进行了细致的构建和增强。原始数据集包含600张展示无缺陷绝缘子的航拍图像和248张展示带有复合故障的绝缘子的图像。为了提升模型对于各种可能情况的适应性和泛化能力，采纳了一系列数据增强技术。这些技术包括对图像进行位移、旋转、镜像翻转，以及调整图像的亮度和对比度。还引入了噪声和Cutout方法来进一步增加数据的多样性，特别是将带缺陷的绝缘子图像从248张扩展到2 480张，以丰富故障模式的表现。

此外，对数据集进行了精心的划分，明确区分了用于训练的数据和用于验证的数据。这一策略不仅有助于在模型训练过程中监控其性能，还使得能够对数据集中的类别分布和标签准确性进行详尽的分析。通过这种方式，可以确保每个类别都得到充分的代表，同时评估模型在不同类别上的表现，从而为模型的最终部署提供了坚实的基础。这种划分对数据分布和分类标签进行分析，见表1。通过这种方式分割数据，模型能够更好地进行泛化并有效执行。

表1 数据分布和分类标签

	训练集	验证集	总数	标注
正常绝缘体	467	133	600	绝缘体
缺陷绝缘体	1 949	551	2 500	绝缘体，缺陷
总计	2 395	605	3 000	绝缘体，缺陷

实验参数见表2。

表2 实验参数设置

超参数	数值	超参数	数值
周期	200	动量	0.945
批量大小	20	权重衰减	0.000 5
学习率	0.01		

在本文档中，平均准确度均值（mAP）用来评估用于检测输电线路绝缘子缺陷的模型的效果。较高的 P_{mA} 值与更好的模型性能相关联。计算公式为

$$P_{mA} = \frac{\sum_{i=1}^n P_{A,i}}{n} \tag{6}$$

2. 实验结果与分析

在本研究中，首先利用标准的YOLOv5s模型对绝缘子缺陷检测进行了初步实验。随后，为了探索更高效的检测方法，引入了两种轻量级网络结构：YOLOv5-MobileNetV3和YOLOv5-GhostNet。这两种改进的网络与原始的YOLOv5s在相同的绝缘子数据集上进行了训练和验证，以比较它们的性能差异。

损失函数作为评估模型预测准确度的关键指标，其值的大小直接反映了模型预测结果与实际标注之间的偏差程度。

结束语

在这项研究中，传统的YOLOv5模型与轻量级卷积神经网络MobileNetV3和GhostNet相结合，以应对无人机在线巡逻中高实时性需求和计算资源受限的挑战。研究结果显示，两种增强策略均达到了预期标准。具体而言，YOLOv5 MobileNetV3在模型轻量化方面表现更为突出，大幅减小了模型体积和计算需求，使其更适合资源受限的环境。而YOLOv5 GhostNet则在保持较高检测准确度的同时，实现了一定程度的优化，减少了模型的复杂性和计算负荷。EA

（收稿日期：2024-11-17）

参考文献

[1] 周旺，于微波，杨宏韬．基于轻量级卷积神经网络的零件位姿识别算法[J]．传感器与微系统 2024(6)：153-156+160．
[2] 陈攀，王绍东．基于轻量级卷积神经网络的多视觉特征图像分割研究[J]．现代电子技术， 2024(15)：60-64．
[3] 谢峰．基于卷积神经网络的轻量级图像超分辨率重建算法研究[D]．桂林：桂林理工大学， 2024．