

基于深度学习的输电线路视觉检测方法研究进展

李春栋 李爽

国网江西省电力有限公司九江供电分公司

摘要: 电力系统快速发展, 输电线路安全稳定运行至关重要。传统输电线路检测方法受限于效率准确性, 深度学习技术为这一领域带来新突破。本文综述基于深度学习输电线路视觉检测方法最新研究进展, 重点介绍目标检测、语义分割、异常识别等关键技术及其在输电线路检测应用。讨论当前面临挑战和未来发展趋势, 为相关领域研究者和实践者提供有价值参考启示。

关键词: 深度学习; 输电线路; 视觉检测; 目标检测

【DOI】 10.12252/j.issn.2096-627X.2022.12.106

输电线路作为电力系统重要组成部分, 安全运行状态可有效保障电能稳定供应。由于输电线路分布广泛、环境复杂, 传统检测方法效率低下, 易受环境因素影响。近年来, 深度学习技术迅猛发展为计算机视觉领域带来革命性变革, 为输电线路视觉检测提供新解决方案。基于深度学习视觉检测方法, 能自动从图像中提取特征, 实现高效准确输电线路部件识别监测。本文系统梳理基于深度学习输电线路视觉检测方法最新研究进展, 为相关领域研究实践提供有益参考借鉴。

一、基于深度学习的输电线路视觉检测优化算法与正则化技术

(一) 优化算法

优化算法在深度学习中用于调整模型权重参数, 最小化训练过程损失函数。对输电线路视觉检测任务, 常见优化算法包括随机梯度下降、带动量SGD、AdaGrad、RMSProp和Adam等。其中, 随机梯度下降是最基础优化算法, 在每次迭代中随机选取一小批样本计算梯度, 据此更新模型参数。计算效率高, 但收敛速度较慢, 容易陷入局部最优。为加速SGD收敛并减少训练过程震荡, 引入动量项累积之前梯度信息, 使更新方向平滑, 有助于跳出局部最优。

AdaGrad是自适应学习率算法, 根据每个参数历史梯度调整学习率。对于经常更新参数, AdaGrad逐渐减小其学习率。对于很少更新参数, 则会保持较大学习率, 有助于处理稀疏数据和不平衡特征问题。RMSProp是AdaGrad改进版本, 引入衰减因子控制历史梯度累积速度, 避免AdaGrad中学习率过早下降问题。

(二) 正则化技术

正则化技术用于防止模型在训练过程中出现过拟合现象, 提高模型泛化能力。在输电线路视觉检测中, 常见正则化技术包括L1正则化、L2正则化、Dropout和批标准化等。L1正则化和L2正则化通过在损失函数中添加权重参数惩罚项, 约束模型复杂度。L1正则化倾向于

产生稀疏权重矩阵, L2正则化则使权重参数趋向于零但非零值, 有助于减少模型参数数量, 降低过拟合风险。Dropout是一种简单有效正则化方法, 在训练过程中随机丢弃一部分神经元, 减少模型参数数量和神经元之间共适应性。防止模型对训练数据中噪声或特定特依赖, 提高模型泛化能力。批标准化对每一批输入数据进行标准化处理, 减去均值并除以标准差, 使网络在训练过程中更稳定。

二、输电线路视觉检测的应用场景

(一) 关键部件检测

在深度学习技术方面, 关键部件检测采用目标检测算法。在图像中准确识别并定位出目标物体位置类别, 在输电线路视觉检测中, 常用目标检测算法包括Faster R-CNN、YOLO等。例如, Faster R-CNN基于区域提案目标检测算法, 通过卷积神经网络提取图像特征, 利用区域提案网络生成可能包含目标候选区域。对候选区域进行分类和边界框回归, 得到最终目标检测结果, 在输电线路图像关键部件检测中表现出较高准确性。YOLO是基于回归目标检测算法, 将目标检测任务转化为回归问题, 直接在输出层预测目标物体边界框和类别概率。YOLO具有较快检测速度, 适用于实时性要求较高场景。在输电线路视觉检测中, YOLO用于实时监测线路状态, 及时发现异常情况。可以结合Faster R-CNN和YOLO优点, 设计出准确快速目标检测算法。

为验证算法有效性, 需要在标注好数据集上进行实验评估。评估指标通常包括准确率、召回率、F1分数等, 对比不同算法在相同数据集表现, 选择出最适合输电线路视觉检测任务算法模型。通过可视化工具将检测结果展示, 以便直观评估模型性能。

(二) 线路走廊分割与障碍物识别

在输电线路视觉检测中, 线路走廊清晰分割和障碍物准确识别至关重要。输电线路周围一定空间范围, 解决对线路造成威胁物体。深度学习技术为线路走廊分割

和障碍物识别提供高效准确方法。例如收集并标注大量输电线路走廊图像数据。数据涵盖不同环境下线路走廊图像,包括城市、乡村、山区等不同场景。标注过程中,需要专业人员对图像线路走廊和障碍物进行准确标注,形成可用于训练标准数据集。为提高模型泛化能力,对数据进行增强处理,如旋转、缩放、翻转等。语义分割算法能将图像中每个像素点分类为不同语义类别,实现线路走廊清晰分割。常用语义分割算法包括U-Net、SegNet等,算法通过卷积神经网络提取图像特征,利用上采样和跳跃连接等技术恢复图像分辨率。在线路走廊分割任务中,将线路走廊和背景分别标记为不同类别,通过训练语义分割模型来实现自动分割。对障碍物识别任务,采用目标检测或实例分割算法。目标检测算法在图像中准确识别并定位出障碍物位置类别,实例分割算法则能将每个障碍物实例分割,提供精细信息。常用目标检测算法包括Faster R-CNN、YOLO等,实例分割算法包括Mask R-CNN等。算法通过卷积神经网络提取图像特征,利用区域提案、分类、边界框回归等技术实现障碍物识别定位。在线路走廊障碍物识别中,根据障碍物类型和特点选择合适算法进行训练推理^[1]。利用注意力机制增强模型对关键信息关注,采用多尺度特征融合提高模型对不同大小障碍物识别能力。在标注好数据集上进行实验评估,评估指标包括像素准确率、均方误差、交并比等^[2]。对比不同算法在相同数据集表现,选择出最适合线路走廊分割和障碍物识别任务算法模型。通过可视化工具将分割识别结果展示,以便直观评估模型性能。

三、基于深度学习的输电线路视觉检测方法

(一) 目标检测方法

1. 基于区域提案的目标检测方法

基于区域提案目标检测方法是—类经典目标检测算法,代表性算法包括R-CNN、Fast R-CNN和Faster R-CNN等。通过区域提案算法生成—系列包含目标候选区域,对每个候选区域进行特征提取分类,最终得到目标物体位置信息。在Faster R-CNN中,区域提案网络引入,用于生成高质量候选区域^[3]。RPN通过共享卷积层特征,在特征图上滑动小窗口,对每个窗口位置进行回归分类,生成—系列候选区域。

2. 基于回归的目标检测方法

基于回归的目标检测代表性算法包括YOLO和SSD,这类方法将目标检测任务转化为回归问题,直接在输出层预测目标物体边界框,无须生成候选区域。YOLO算法将图像划分为一个 $S \times S$ 网格,每个网格负责预测 B 个边界框及其置信度,以及 C 个类别概率。在训练过程中,

最小化边界框坐标和类别概率预测误差优化模型参数。YOLO算法具有较快检测速度,适用于实时性要求较高场景。采用简单网格划分方式,对小目标和密集目标检测效果不佳。为提高对小目标和密集目标检测性能,SSD算法引入多尺度特征融合思想。SSD在不同尺度特征图预测,每个尺度特征图负责检测不同大小目标物体。通过结合多个尺度特征信息,SSD能准确识别定位目标物体^[4]。

3. 基于锚框的目标检测方法

基于锚框的目标检测方法在特征图上预设—系列大小和比例不同锚框,将目标检测任务转化为对锚框分类和边界框回归问题。在Faster R-CNN中,RPN生成候选区域时采用锚框思想。RPN在特征图上滑动小窗口时,每个窗口位置都对应—系列预设锚框。通过对锚框进行分类和边界框回归,RPN能生成高质量候选区域供后续分类器使用。与YOLO相比,YOLOv3在特征图上使用更大尺度锚框检测大目标物体,通过多尺度特征融合提高对小目标检测性能^[5]。YOLOv3引入残差连接和批量归—化等技术。优化模型结构并提高训练效率。

(二) 语义分割方法

1. 基于全卷积网络(FCN)的语义分割

FCN是语义分割领域里程碑式工作,将CNN应用于像素级预测任务。传统CNN在卷积层之后会接上全连接层,用于图像级别分类。而FCN去掉全连接层,全部使用卷积层,输出任意大小特征图。FCN采用上采样(或反卷积)操作,将特征图分辨率恢复到与输入图像相同大小。为融合不同层次特征信息,FCN引入跳跃连接,将浅层高分辨率特征与深层低分辨率特征融合。训练FCN模型,使其学习到线路走廊和背景之间语义差异,实现对线路走廊自动分割。U-Net是—种经典语义分割网络结构,采用编码器—解码器架构。编码器部分负责提取图像特征,解码器部分负责将特征图恢复到原始图像分辨率,进行像素级分类。U-Net在解码器部分采用更多跳跃连接,融合编码器中不同层次特征信息。采用数据增强和加权损失函数等技术手段,提高模型分割性能。在输电线路视觉检测中,U-Net用于绝缘子缺陷检测任务。训练U-Net模型,使其学习到绝缘子正常区域和缺陷区域之间语义差异,实现对绝缘子缺陷自动分割。在语义分割任务中,引入注意力机制帮助模型更好捕捉目标物体边界。

例如,自注意力机制通过计算特征图中任意两个位置之间相关性,捕捉全局上下文信息。通道注意力机制计算不同通道之间权重,强调重要特征通道。在输电线路视觉检测中,引入注意力机制语义分割方法提高对线

路走廊和障碍物等目标物体分割精度。使模型关注目标物体边界细节信息，减少误分割和漏分割情况，提高检测准确性。浅层网络提取特征包含更多细节信息，深层网络提取特征包含更多语义信息。多尺度特征融合方法包括金字塔池化、空洞卷积和注意力机制等。捕捉不同尺度上下文信息，将其融合到一起提高分割精度。

（三）异常识别方法

统计模型假设正常数据服从某种统计分布，异常数据则偏离这种分布。常见统计模型包括高斯分布、泊松分布等，计算数据点与分布之间偏差程度，如马氏距离、Z分数等，判断数据点是否为异常点。在输电线路视觉检测中，基于统计模型异常识别方法用于监测线路走廊内树木生长、建筑物变化等。对历史数据建模，预测出正常情况下数据分布范围，及时发现与预期不符异常变化。机器学习算法从大量数据中自动学习出正常行为模式，据此识别出异常行为。构建分类回归模型，利用该模型对新数据进行预测分类，识别出异常点。在输电线路视觉检测中，构建深层神经网络模拟人脑认知过程。与传统机器学习算法相比，深度学习具有更强特征提取能力。常见深度学习算法包括卷积神经网络CNN、循环神经网络RNN、自编码器Autoencoder等。CNN适用于处理图像数据，RNN适用于处理序列数据，而Autoencoder则适用于无监督学习场景下异常检测。

（四）多模态融合方法

1. 多模态融合方法的基本原理

多模态融合方法核心思想利用不同类型传感器获得对应信息，将信息进行集成融合，获得准确信息特征。这种方法能最大限度利用各种信息，减弱单一传感器存在模态不足。融合过程涉及多阶段，包括数据预处理、特征提取、模态对齐、决策融合等。

2. 多模态融合方法的应用领域

多模态融合感知技术帮助智能家居系统理解用户需求，提供智能化服务。例如，结合语音识别、人体检测、温度传感器等多种传感器，实现智能照明、智能空调等功能。从多个传感器获取信息，如相机、雷达、激光雷达等，将信息融合，获得准确周围环境信息。

3. 多模态融合方法的技术挑战与发展趋势

尽管多模态融合方法在许多领域取得显著成果，但仍面临技术挑战，如数据对齐、模态间互补性与冗余性处理、计算复杂度等。未来，深度学习、强化学习等技术发展，多模态融合方法有望在更多领域实现突破，为我国居民生活带来便利。

四、实验与分析

（一）实验设置

构建包含多样化场景和复杂背景大规模数据集，涵盖正常情况输电线路图像，以及包含各种潜在缺陷和异常的图像。采用多种深度学习模型，如卷积神经网络、目标检测算法，适应不同检测任务。在实验过程中，将数据集分为训练集、验证集和测试集，确保模型泛化能力。

（二）实验结果

在目标检测任务中，模型能准确识别输电线路及其相关部件位置类别，实现较高准确率。在语义分割任务中，精确分割出输电线路走廊区域，为后续安全分析提供有力支持。在异常识别任务中，检测出输电线路潜在缺陷异常，如绝缘子破损、线路松弛等。与其他传统方法对比，验证所提出方法优越性。

（三）结果分析

对实验结果深入分析，发现深度学习模型在输电线路视觉检测任务中表现出强大特征提取分类能力。与传统图像处理方法相比，深度学习模型能自动学习图像深层特征，更好适应复杂场景和变化光照条件。注意到在实验过程中存在挑战限制，例如对于某些罕见缺陷类型，模型无法获得足够训练样本，导致检测性能下降。

五、结语

综上所述，基于深度学习的输电线路视觉检测方法在输电线路视觉检测领域应用广泛。通过深度学习算法，自动提取图像深层特征，实现对输电线路及其相关部件精准识别检测。分析近年来基于深度学习输电线路视觉检测方法研究进展，涵盖目标检测、语义分割、异常识别等多个关键任务，详细讨论各种方法技术原理、应用场景及优缺点。随着算法不断优化和计算能力持续增强，深度学习在输电线路视觉检测应用将更深入广泛，为提升电力系统安全提供有力保障。

参考文献

- [1] 马海霞, 李中兴, 陈斯炯. 基于倾斜摄影的输电线路三维建模应用研究[J]. 电子设计工程, 2022, 30(9): 171-174, 179.
- [2] 林志军, 刘宝军, 关俊峰, 等. 基于影像特征分析的架空输电线路三维实景建模[J]. 电子器件, 2022, 45(1): 172-177.
- [3] 尚军利, 袁文政, 王宇博, 等. 基于5G的输电线路在线监测网络建模方法研究[J]. 电子技术应用, 2022, 48(3): 18-21.
- [4] 唐浩龙, 樊艳, 冯千秀, 等. 500kV同塔双回输电线路感应电压和感应电流建模分析[J]. 四川电力技术, 2022, 45(3): 41-45, 79.
- [5] 郑小英. 高压输电线路中无人机电力巡检技术的应用[J]. 自动化应用, 2022(12): 112-114.