

基于改进型 Faster R-CNN 的变电站设备缺陷检测

康 曦^{1,2} 邓琛韬² 伍 毅¹ 葛 林² 朱东松² 王 军¹

KANG Xi DENG Chentao WU Yi GE Lin ZHU Dongsong WANG Jun

摘 要

为了保障变电站设备的稳定运行,准确检测变电站设备缺陷,提出一种基于改进型 Faster R-CNN 的设备缺陷检测方法。通过引入哈希辅助分支,抑制背景区域干扰,提高了检测精度,同时避免了非目标区域

的无效计算,可以有效提高检测效率。实验表明,引入深度哈希辅助分支后,与原 Faster R-CNN 模型对比,在非目标区域上的计算时间从 0.082 2 s/张提高到 0.044 3 s/张,检测结果的 mAP 从 76.43% 提高到 81.24%,在保持较高检测速度的同时可以有效地提高检测精度,验证了模型的可靠性与高效性。

关键词

Faster R-CNN; 缺陷检测; 哈希辅助分支

doi: 10.3969/j.issn.1672-9528.2024.11.020

0 引言

变电站是电网不可或缺的一环,在运行过程中,其金属设备可能会出现放电痕迹、坏点损伤、漆泡损伤等问题。为保障电力系统的稳定运行,对无人值守变电站设备进行实时检测^[1]已然成为一项重要的任务。传统基于机器学习的设备表面缺陷损伤检测方法,如图像分割方法^[2]、特征提取

方法^[3]、光谱算法^[4]采集图像受环境因素影响较大,且变电站设备的缺陷具有连续扩展性,所以需要泛化性能更强的深度学习模型用于设备表面缺陷损伤检测。为了有效提高检测准确率和检测速度,本文提出一种基于改进型 Faster R-CNN 的金属缺陷检测方法。样本采用 NEU-DET 数据集,将无目标背景图像块与有目标图像块分开,统计加入深度哈希辅助分支前后的平均测试时间与检测准确率。实验结果表明,加入深度哈希辅助网络模型不仅能大幅度缩短模型检测时间,还可以提高检测精度。

1. 江西理工大学机电工程学院 江西赣州 341000
2. 国网江西省电力有限公司赣州供电分公司 江西赣州 341000

- [9] 胡楠. 基于 FPGA 的随钻数据压缩系统设计 [D]. 荆 州: 长 江大学, 2021.
- [10] 刘谱光,魏子令,黄成龙,等. 一种基于 FPGA 加速的高性能数据解压方法 [J]. 计算机学报, 2023, 46 (12): 2687-2704.
- [11] 陈晓杰,李斌,周清雷. RTL 级可扩展高性能数据压缩方法实现 [J]. 电子学报, 2022, 50 (7): 1548-1557.
- [12] 王飞,李钊,尹晓华,等. 高速数据压缩及加密硬件加速电路研究 [J]. 计算机与数字工程, 2020, 48 (1): 212-216+246.
- [13] 张成哲,张迎春,曹中清,等. 基于 FPGA 的波形数据压缩算法设计与实现 [J]. 自动化与仪器仪表, 2022(12): 1-5.
- [14] 梁捷,蒋雯倩,李金瑾. 基于动态字典和差分编码的计量数据压缩研究 [J]. 信息技术, 2020, 44 (10): 116-120.
- [15] ANTONOV A, BESEDIN D, F-ILIPPOV A. Research of the efficien-cy of high-level synthesis tool for FP-GA based

hardware implementation of some basic algorithms for the big d-ata analysis and management tasks[C]//2020 26th Conference of Open Inno-vations Association (FRUCT). Piscataway: IEEE, 2020:1-7.

- [16] YAN D, WANG W X, ZUO L, et al. A novel scheme for real-time max/Min-set-selection sorters on FPGA[J]. IEEE transactions on circuits and systems,ii.express briefs, 2021, 68(7): 2665-2669.

【作者简介】

解佩淼(2002—),男,陕西汉中,本科,研究方向:集成电路设计。

张霞(1983—),女,内蒙古牙克石人,博士,副教授,研究方向:集成电路设计。

(收稿日期:2024-07-30)

1 基于改进型 Faster R-CNN 设备缺陷检测

1.1 深度哈希辅助网络模型设计

针对变电站金属设备缺陷图像中大部分区域为无目标存在背景区域的问题,对 Fast R-CNN 进行改进,提出一种基于改进型 Faster R-CNN 的设备缺陷检测模型。在双阶段目标检测模型中构建哈希辅助分支,以快速判别输入子图像是否为潜在目标区域。该分支由自注意力层、空间金字塔池化层组成,这样的结构可保留局部细节信息,同时抑制背景区域干扰,使其能够对是否存在目标做准确判断,从而使检测模型保持较高精度。得益于哈希辅助分支结构简单及二值计算的高效性,其判别过程引入的额外计算可忽略,并且该分支可以避免检测模型在非目标区域上的大量无效计算,节省了检测时间。深度哈希辅助网络整体结构如图 1 所示,该网络由哈希辅助分支及 Faster R-CNN 检测分支两部分组成,其中两个输出分支共享一个基础网络提取特征,基础网络由 ResNet101 中前 4 个残差组块构建而成^[5]。




图 1 深度哈希辅助分支网络整体结构图

1.2 网络结构设计

1.2.1 深度残差模块

深度残差网络 (deep residual network, ResNet) 能够在层数加深以提高特征提取能力的同时,不会出现其他网络在层数过深时出现的过拟合现象^[6]。本文使用 ResNet 作为基础网络 (Backbone)^[7] 提取图像的特征,通过该结构单元使得网络在层数冗余时,冗余网络层学到的映射趋近于恒等映射^[8]。

1.2.2 哈希辅助模块

哈希辅助分支由卷积层、自注意力层 (self attention module, SAM)^[9]、空间金字塔池化层 (SPP)^[10] 与哈希编码层^[11] 组成。其中, SAM 之前为 3×3 的卷积层,通道数为 512,该层与 RPN 中的卷积层共享参数。深度哈希辅助分支与目标检测分支^[12] 共享基础网络和 RPN 提取的特征,因此

这样的参数共享机制^[13] 可使得深度哈希辅助分支的输入特征中包含更多的目标位置与类别信息。

1.3 网络结构函数

基于 CNN 的深度哈希辅助网络可将特征提取与量化编码两个步骤整合成端到端的过程:由损失函数指导网络生成语义哈希特征^[14],在训练结束后对该特征进行量化编码得到哈希二值序列。哈希二值序列生成及网络测试过程如图 2 所示,对训练集 Strain 所有图像进行减均值操作^[15],输入至训练好的检测模型中,由深度哈希辅助分支得到 Strain 中每张子图像对应的哈希特征向量 feat,而后用量化方式对 feat 进行量化,将量化后的结果保存至本地,得到对应的哈希二值序列库;对测试集 Stest 所有图像减均值后,依次输入至训练好的检测模型。对于每张子图像 S_j ,由深度哈希辅助分支及量化过程得到对应的二值序列,比较 B_j 与 Btrain 中所有二值序列的汉明距离,取距离前 k 的二值序列所对应的标注集,将标注集中占多数的标注作为 S_j 的类别。若 $L_j=1$,则进行后续的 RPN 候选区域提取与 Fast-RCNN 分类和回归,若 $L_j=0$,则结束;对于所有 $L_j=1$ 的子图像 S_j 的检测结果做 NMS 或者 Soft-NMS 得到最终检测结果 P_j ,统计单张图像块预测所需时间 t ;对原属于同一张宽幅图像的所有子图像及其检测结果进行合并,对合并时有结果重叠的相邻检测框进行 NMS 操作;最后得到所有测试图像的检测结果。




图 2 基于哈希辅助网络的目标检测测试流程图

哈希辅助分支通过对标签语义的学习来对二值编码^[16] 进行线性分类,并且最大程度地保存其结构,同时借助非线性性的哈希方程及引入离散约束的目标方程,能够使原始样本空间的相似关系得到最大程度的保存。

2 实验结果与分析

2.1 实验环境

本文实验设备采用 64 位 Win10 系统计算机,显卡

为 RTX2060, CPU 为 Intel CORE i7。实验平台为 Google Colaboratory 云平台, 运行环境为 PyTorch 1.4.0, CUDA 版本为 10.1。输入大小设置为 300 pixel×300 pixel, Batch_size 设置为 16, 初始学习率与动量分别设为 0.001 和 0.9, gamma 与 weight_decay 权重衰减以及 Max_epoch 分别设为 0.1、0.000 5、500, 学习率分别在迭代次数达到 5000、15 000、20 000、25 000、35 000 次时进行调整, 在达到 Max_epoch 时训练终止。

实验采用 NEU-DET 数据集, 该数据集是为东北大学公开发布的设备表面缺陷数据库, 其中收集了 6 种变电站金属设备的典型缺陷, 所有的缺陷都有 300 张图像。本文选取其中三类典型缺陷, 分别为擦花、坏点和漆泡, 按 8:1:1 的比例划分为训练集、验证集及测试集。

2.2 实验结果分析

2.2.1 哈希辅助分支有效性验证

哈希辅助分支的作用是判别输入子图像块中是否无目标存在的背景区域, 并将其快速滤去以节省整体的检测时间的同时保持精度不变。将 NEU-DET 数据集测试集中的无目标背景图像块与有目标图像块分开, 并分别统计基准模型 Faster R-CNN (表 1 中为 Baseline) 与加入深度哈希辅助分支后在有 / 无目标测试集上的平均测试时间, 单位为秒每张 (s/ 张), 并统计两个模型在每个数据集上整体测试集的检测准确率 (mAP), 结果如表 1 所示。

表 1 HANet 分支对 NEU-DET 中有 / 无目标图像的检测结果对比

分支	mAP	有目标 (s/ 张)	无目标 (s/ 张)
Baseline	76.43%	0.082 3	0.082 2
+HANET	81.24%	0.084 0	0.044 3

由表 1 可知, 深度哈希辅助分支的引入使得检测模型在数据集上的无目标背景区域的时间上减少了 46.10%, 该结果表明了深度哈希辅助分支的有效性, 且验证了深度哈希辅助分支能够快速过滤无目标背景区域, 节省检测时间的作用。从深度哈希辅助分支原理上的分析可知, 对于无目标背景区域, 深度哈希辅助分支的引入使得检测模型在检测无目标背景图像时, 节省了候选区域提取部分和对每个候选区域的后续运算, 从而带来了大幅度的速度提升。

深度哈希辅助分支的引入使不同输出端之间的参数共享机制, 加强了所提取特征的语义表征能力, 提升了整体检测精度, 使得检测模型在精度上从 76.43% 提升至 81.24%。

同时, 变换哈希辅助网络模型的不同 layer 和输入图片的高度来进行进一步的检测, 训练结果如图 3 ~ 图 5 所示, 其中图 3 ~ 图 5 分别是擦花、漆泡、坏点损伤图片的 recall

曲线, 其中 hXXX 中 XXX 是指输入图片的 height, mt 代表哈希辅助网络的开启。




图 3 擦花痕迹的 recall 曲线




图 4 漆泡损伤的 recall 曲线




图 5 坏点损伤的 recall 曲线

根据图 3 ~ 图 5, 哈希辅助网络相较于 RPN 生成网络具有更好的性能和健壮性, 随着图片 height 的变化, recall 曲线变化较小, 表明哈希辅助网络可以改善图片尺寸对于生成精度的影响并能够针对每一层对于与其比例匹配的对象具有最高的精度, 同时对于不同损伤的图片大小性能不会出现较大的波动。

2.3 模糊控制器的输出

2.3.1 对比实验

将本文所提出的目标检测模型与现有模型对内含物(In)以及点蚀表面(PS)两种缺陷检测精度对比, 采用的也是 NEU-Det 数据集。参与比较的模型包括 Faster R-CNN、SSD 与 YOLOv3, 其中 Faster R-CNN 为双阶段目标检测模型,

其参数设置与深度哈希辅助网络相同。相较于 VGG16 与 ResNet101，该类基础模型具有更多的参数。SSD 与 YOLOv3 为单阶段目标检测模型，实验中使用 SSD 和 YOLOv3 的默认参数设置，结果如表 2 所示。

表 2 目标检测模型在 NEU-Det 的实验结果与时间对比

检测模型	Back bone	类别		mAP/%
		In/%	PS/%	
Faster R-CNN	VGG16	63.21	95.46	79.33
SSD512	ResNet101	63.40	95.70	79.55
YOLOv3	Dark net19	56.22	89.33	72.78
Ours	ResNet101	69.23	96.00	82.62

由表 2 可知，相较于基准模型（以 ResNet101 为基础网络的 Faster R-CNN），本文提出的深度哈希辅助网络对内含物（In）的检测准确率高达 69.23%，对点蚀表面（PS）的检测准确率高达 96.00%，均高于 SSD512 模型、Faster R-CNN 模型以及 YOLOv3 模型的对应缺陷类别检测准确率。结果表明，本文所提出的模型在这两种缺陷上检测能力都有较大提升，且 mAP 值 82.62% 远高于其他模型，说明了该辅助网络对于检测性能具有提升作用。

3 总结

本文提出了一种基于改进型 Faster R-CNN 的变电站设备缺陷检测的方法，通过在 Faster R-CNN 中的 RPN 构建深度哈希辅助分支，既能有效抑制背景区域干扰，提高检测精度，又能通过该分支对输入子图像是否为潜在目标区域做快速判别，避免了检测模型在背景区域上的大量无效计算，节省了检测时间。通过对比实验，本文提出的改进模型在检测精度和检测效率方面均有所提升，验证了模型的可靠性与高效性。

参考文献：

[1] 肖发龙, 吴岳忠, 沈雪豪, 等. 基于深度学习和知识图谱的变电站设备故障智能诊断 [J]. 电力建设, 2022, 43(3): 66-74.

[2] 刘永学, 李满春, 毛亮. 基于边缘的多光谱遥感图像分割方法 [J]. 遥感学报, 2006(3): 350-356.

[3] 施杰, 伍星, 刘韬. 基于 MPDE-EEMD 及自适应共振解调的轴承故障特征提取方法 [J]. 电子测量与仪器学报, 2020, 34(9): 47-54.

[4] LI M, WAN S H, DENG Z M, et al. Fabric defect detection based on saliency histogram features[J]. Computational intelligence, 2019, 35(3): 517-534.

[5] JARRETT K, KAVUKCUOGLU K, RANZATO M, et al. What is the best multi-stage architecture for object recognition?[C]//

International Conference on Computer Vision (ICCV'09). New York: Curran Associates, Inc, 2009: 2184-2191.

[6] SHAFIQ M, GU Z Q. Deep residual learning for image recognition: a survey[J]. Applied sciences, 2022, 12(18): 8972.

[7] MATHIEU M, COUPRIE C, LECUN Y. Deep multi-scale video prediction beyond mean square error[DB/OL]. (2016-02-16) [2024-05-21]. <https://arxiv.org/pdf/1511.05440>.

[8] 苏雪苗. 基于深度学习的图像目标检测关键技术研究 [D]. 天津: 天津工业大学, 2020.

[9] MUSTAQEEM, KWON S. Att-Net: enhanced emotion recognition system using lightweight self-attention module[J]. Applied soft computing, 2021, 102: 107101.

[10] 于春和, 杨子奇. 基于 YOLOv4 的钢材表面缺陷检测 [J]. 电脑与信息技术, 2023, 31(5): 29-33.

[11] 马宾, 王一利, 徐健, 等. 基于双向生成对抗网络的感知哈希图像内容取证算法 [J]. 计算机学报, 2023, 46(12): 2551-2572.

[12] 王喆. 基于深度哈希学习的高分辨遥感图像目标检测技术研究 [D]. 西安: 西安电子科技大学, 2019.

[13] 彭腾飞. 基于卷积神经网络的极光图像检索研究 [D]. 南京: 南京邮电大学, 2021.

[14] 赵鑫. 大规模行人检索方法研究 [D]. 北京: 清华大学, 2019.

[15] 杨璨. 基于深度学习的交通目标检测方法的研究 [D]. 南昌: 华东交通大学, 2021.

[16] LI H, ZHAO T, LI N, et al. Feature matching of multi-view 3D models based on hash binary encoding[J]. Neural network world, 2017, 27(1): 95-105.

【作者简介】

康曦（1995—），女，江西赣州人，本科，工程师，研究方向：电力系统运行与控制、深度学习。

邓琛韬（1996—），男，江西吉安人，硕士，研究方向：深度学习、电能质量。

伍毅（2000—），男，安徽芜湖人，硕士研究生，研究方向：图像处理。

葛林（1992—），男，江西于都人，硕士，工程师，研究方向：电力系统运行与控制。

朱东松（1981—），男，陕西渭南人，本科，副高级工程师，研究方向：电力系统运行与控制。

王军（1979—），通信作者（email: mkfriend@126.com），男，辽宁本溪人，硕士，副教授，研究方向：智能控制。

（收稿日期：2024-07-23）