

基于网络蒸馏模型的供电接触网支撑装置零部件快速定位方法

喻文彬

(中铁建电气化局集团第四工程有限公司,410116,长沙//高级工程师)

摘要 为确保供电接触网支撑装置具备良好的工作状态,避免支撑装置失效可能造成的严重弓网故障,进而影响列车运行安全,提出一种新型的、适用于小型化嵌入式设备进行部署应用的、基于网络蒸馏技术的深度学习接触网支撑装置快速定位识别模型。网络蒸馏模型是基于双深度学习网络进行指导性学习的,其利用高精度深度学习模型YOLOv5x、YOLOv5l、YOLOv5m作为蒸馏算法中的教师模型,然后利用网络蒸馏技术对复杂模型的特征提取能力进行迁移,以教师模型的类别概率作为软目标并将其用于训练学生模型,从而将知识从复杂模型(教师模型)转移到更高效的小型化模型(学生模型)。研究结果表明,利用网络蒸馏技术可以获得精度高、速度快、模型小、易于部署的接触网支撑装置定位模型。

关键词 轨道交通; 供电接触网; 网络蒸馏模型; 零部件定位

中图分类号 U225.4

DOI:10.16037/j.1007-869x.2023.05.021

Quick Positioning Method of Catenary Support Device Components Based on Network Distillation Model

YU Wenbin

Abstract To ensure that catenary support device is in good working condition and avoid serious pantograph-catenary faults caused by support device failure, which may further undermine railway operation safety, a new deep learning catenary support device quick positioning and recognition model is proposed, that is based on network distillation technology and can be deployed on embedded devices. The network distillation model achieves guided learning through dual deep learning networks. It takes the high-precision deep learning models YOLOv5x, YOLOv5l and YOLOv5m as teacher models in the distillation algorithm, and then the network distillation technology is used to migrate the feature extraction capability of complex model, the category probabilities of teacher model are used as soft targets for the training student model, so that the knowledge is

transferred from the complex model (teacher model) to an efficient miniaturized model (student model). Research results show that the network distillation technology can obtain an accurate, fast, small, and easy-to-deploy model for positioning catenary support device.

Key words rail transit; power supply catenary; network distillation model; component positioning

Author's address The 4th Engineering Co., Ltd. of China Railway Construciton Electrification Bureau Group Co., Ltd., 410116, Changsha, China

在轨道交通牵引供电系统中,接触网是其关键组成部分之一。接触网具有分布范围广、工作环境恶劣及振动频繁剧烈等特点,接触网零部件长期受冲击振动和极端环境的影响容易造成脱落或损坏,严重时甚至会影响列车的运行安全。接触网支撑装置是确保接触网结构稳定性及保证接触网运行安全的关键组成部分,其包含数目庞大、尺寸各异的零部件,因此有必要对接触网支撑装置的各类零部件进行检测。

随着计算机图像处理技术与深度学习技术的发展,针对接触网的非接触式检测成为了弓网检测领域的研究热点之一,弓网监测的最终目的就是实现对接触网零部件缺陷的识别和预警。零部件缺陷识别的首要步骤就是对不同零部件进行高效、精确的分类定位。文献[1]基于 Faster R-CNN(基于区域的快速卷积神经网络)模型对接触网图像中的绝缘子进行定位。文献[2]提出一种 PVANET++网络模型对接触网开口销进行局部定位缺陷判断。文献[3]基于 SSD(单步多框预测检测器)和 YOLO 模型构建了一个级联网络,实现了对接触网悬臂接头的定位。文献[4]基于 Faster R-CNN、YOLOv2 和 SSD 模型,对主要的 12 类接触网零部件进行分类定位。文献[5]提出一种基于 Faster R-CNN 与

SSD 的级联模型,对主要的接触网零部件进行定位。文献[6]通过在 Faster R-CNN 中嵌入一个小尺寸零部件定位网络,提高了接触网零部件的定位精度。以上研究虽然实现了对接触网零部件的自动化检测,但在实际应用与部署上存在着一定问题,主要包括:①接触网专用检测车中设备安装空间有限,对智能化图像检测分析系统的设备尺寸、性能和功率有一定限制;②传统卷积神经网络中包含海量参数,对设备的计算存储空间要求较高;③接触网检测对实时性有较高的要求,传统卷积神经网络的海量参数对设备的计算性能提出了更高的要求。

为解决上述标准化模型文件过大、无法在嵌入式设备上进行部署的问题,本文以深度学习模型蒸馏技术为基础,将复杂大模型 YOLOv5x、YOLOv5l、YOLOv5m 作为教师模型,对简单小模型 YOLOv5s 进行参数蒸馏,最终获得了接触网支撑装置零部件低资源消耗、高精度实时定位的模型,通过蒸馏前后模型的精度和检测速度在 12 类接触网关键零部件进行定位性能对比试验,证明了本文所提方法的有效性。本文研究可为接触网检测设备小型化和轻量化提供参考。

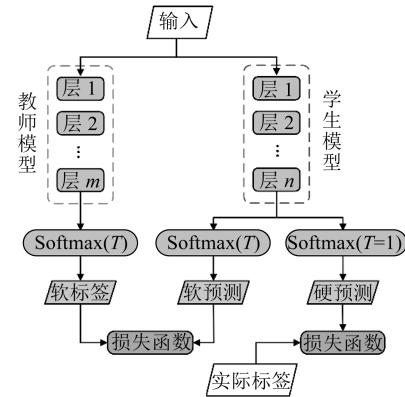
1 基于 YOLO 模型的网络蒸馏原理

1.1 网络蒸馏原理

在深度神经网络实践中,一般复杂大模型容易从图像数据中提取出更多的特征信息。在复杂大模型训练完毕后,可采用蒸馏技术对复杂模型的特征提取能力进行迁移,从而将知识从复杂的模型(教师模型)转移到更高效的小型化模型(学生模型)中。将教师模型的泛化能力迁移到学生模型的常用方法是将教师模型的类别概率作为软目标并用于训练学生模型。若软目标具有高熵值,在训练每一个样本时,软目标能够提供比硬目标(学生模型的真值)更多的信息,且其训练每一个样本时的梯度差异更小。因此,与教师模型相比,学生模型的训练数据要少得多,其使用学习率也更高。网络蒸馏技术可在保留学生模型低资源消耗的基础上引入教师模型的高精度特征提取能力,从而使得小参数模型具备与复杂模型类似的检测能力。

教师模型为一个大型或集成模型,在训练后可以获取其转移组。在相同蒸馏指标条件下,对学生模型和教师模型进行训练。当 $T=1$ 时,对学生模型

的硬目标进行训练,总优化目标是软目标和硬目标的加权和。网络蒸馏原理示意图如图 1 所示。



注: m 为教师网络层数; n 为学生网络层数;
Softmax(\cdot) 为归一化函数; T 为上一网络
层未归一化前的输出值。

图 1 网络蒸馏原理示意图

Fig. 1 Diagram of network distillation principle

1.2 基于网络蒸馏技术的 Yolo 模型优化

与 R-CNN 系列网络不同, YOLO 模型是一个阶段架构模型。YOLO 模型网络架构最后一层的输出包括模型检测接触网零部件目标的边界框坐标和模型检测接触网零部件对象的分类概率。最后一层输出中,包括 N 个检测边界框,其输出为 $N(K+5)$ (K 为检测零部件类别数量;5 表示检测边界框坐标 4 个值与对象类别分类标号 1 个值的组合)。目标函数可以分为回归损失函数 f_{bb} 、对象损失函数 f_{obj} 和分类损失函数 f_{cl} 。目标函数 L_{Yolo} 可以表示为:

$$L_{Yolo} = f_{obj}(o_{igt}, \hat{o}_i) + f_{cl}(p_{igt}, \hat{p}_i) + f_{bb}(b_{igt}, \hat{b}_i) \quad (1)$$

式中:

$\hat{o}_i, \hat{p}_i, \hat{b}_i$ ——分别为学生模型的对象类别分类标号、分类概率和边界框坐标;

$o_{igt}, p_{igt}, b_{igt}$ ——分别为人工标注的对象类别分类标号、分类概率和边界框坐标的真值。

目前,网络蒸馏方法一般通过教师模型的最后一个卷积层输出将知识转移到学生模型。但由于 YOLO 模型是一种单阶段检测方法,其预测结果主要为一组包含大量无效背景候选区域的输出。若采用标准网络蒸馏方法会将 YOLO 教师模型的无效背景候选框信息一起转移给学生模型,这样会影响学生模型的训练效果。为避免教师模型无效背景候选区域的干扰,可将网络蒸馏损失目标函数转化为对象缩放函数,使得学生模型仅在教师模型预测分类概率值很高时,才会学习其边界框坐标和分

类概率。最终的损失函数 L_{final} 由回归损失修正函数 f_{bbco} 、对象损失修正函数 f_{objco} 和分类损失修正函数 f_{clco} 组成, 可以表示为:

$$f_{\text{objco}}(o_{\text{igt}}, \hat{o}_i, o_{\text{IT}}) = f_{\text{obj}}(o_{\text{igt}}, \hat{o}_i) + \lambda_{\text{D}} f_{\text{obj}}(o_{\text{IT}}, \hat{o}_i) \quad (2)$$

$$f_{\text{clco}}(p_{\text{igt}}, \hat{p}_i, p_{\text{IT}}, o_{\text{IT}}) = f_{\text{cl}}(p_{\text{igt}}, \hat{p}_i) + o_{\text{IT}} \lambda_{\text{D}} f_{\text{cl}}(p_{\text{IT}}, \hat{p}_i) \quad (3)$$

$$f_{\text{bbco}}(b_{\text{igt}}, \hat{b}_i, b_{\text{IT}}, o_{\text{IT}}) = f_{\text{bb}}(b_{\text{igt}}, \hat{b}_i) + o_{\text{IT}} \lambda_{\text{D}} f_{\text{bb}}(b_{\text{IT}}, \hat{b}_i) \quad (4)$$

$$L_{\text{final}} = f_{\text{bbco}}(b_{\text{igt}}, \hat{b}_i, b_{\text{IT}}, o_{\text{IT}}) + f_{\text{clco}}(p_{\text{igt}}, \hat{p}_i, p_{\text{IT}}, o_{\text{IT}}) + f_{\text{objco}}(o_{\text{igt}}, \hat{o}_i, o_{\text{IT}}) \quad (5)$$

式中:

$f_{\text{obj}}(o_{\text{igt}}, \hat{o}_i)$ —— 检测损失;

$\lambda_{\text{D}} f_{\text{obj}}(o_{\text{IT}}, \hat{o}_i)$ —— 蒸馏损失;

$o_{\text{IT}}, p_{\text{IT}}, b_{\text{IT}}$ —— 分别为教师模型的对象类别分类标号、分类概率和边界框坐标;

λ_{D} —— 两个损失函数的平衡参数, 默认取为 1。

2 网络训练过程及零部件定位试验

为验证网络蒸馏模型的可行性与有效性, 采用 YOLOv5 模型进行蒸馏试验, 并基于该模型对接触网支撑装置 10 类零部件进行定位检测。

2.1 网络训练过程

以武广高速铁路沿线 1 000 km 为例, 将检测车采集到的接触网图像作为试验数据集。数据集中共有 2 947 张图像, 包含 21 453 个不同尺寸的各类零部件。随机选取数据集中 70% 的图像作为训练集, 剩余的 30% 图像作为测试集, 为了防止过拟合, 从训练样本中抽取 30% 图像作为验证集。本文所用到的所有网络模型均在该数据集上进行训练和测试。数据集中各零部件的数量如表 1 所示。接触网支撑部件示意图如图 2 所示, 接触网检测车示意图如图 3 所示。

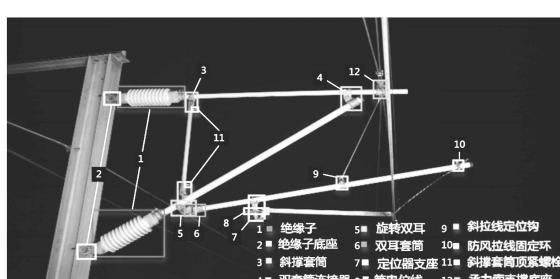


图 2 接触网支撑部件示意图

Fig. 2 Diagram of catenary support device components

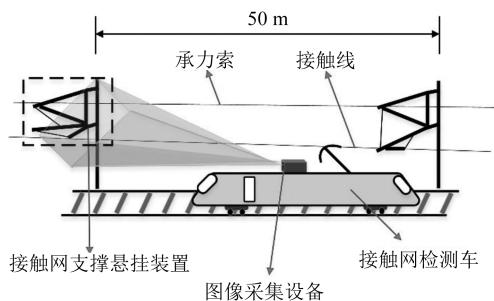


图 3 接触网检测车示意图

Fig. 3 Diagram of catenary inspection vehicle

表 1 数据集中的各零部件数量

Tab. 1 Number of each component in the dataset

名称	数量	名称	数量
绝缘子/个	2 012	旋转双耳/个	1 319
绝缘子底座/个	2 027	承力索支持底座/个	1 704
双耳套筒/个	1 411	定位器支座/个	1 517
斜撑套筒/个	2 710	防风拉线定位环/个	1 122
斜撑套筒顶紧螺栓/只	2 508	双套筒连接器/个	1 567
斜拉线定位钩/只	1 412	等电位线/根	812

试验环境为:深度学习开源框架 Pytorch、Ubuntu 18.04 操作系统、11 GB 显存的 GTX 2080 Ti 图形处理单元。采用 YOLOv5x、YOLOv5l、YOLOv5m 模型作为教师模型, 采用 YOLOv5s 模型作为学生模型。试验中, 每批次训练图像数量为 16 个, 输入图像大小为 640 像素×640 像素, 最大训练迭代次数为 300, 其他规格参数均沿用 YOLOv5 模型的原始配置。将 YOLOv5s 模型的试验结果作为对照组。

2.2 定位试验结果及分析

经过 300 次迭代计算后, 各网络损失函数基本不再下降, 故结束训练, 并用这 3 个网络蒸馏模型对测试集图像进行测试。试验结果评价以 mAP(各类别平均检测精度)和 FPS(每秒处理图像帧数)2 个指标来评估每个网络蒸馏模型的定位性能。

各网络模型检测零部件的 mAP 如表 2 所示, 各网络模型整体性能如表 3 所示。由表 2 和表 3 可知:① Distill-x-s 蒸馏模型的 mAP 最高, 达到了 0.75, 与 YOLOv5m 蒸馏模型的检测精度相当; Distill-l-s 蒸馏模型的 mAP 在 YOLOv5s 蒸馏模型的基础上有一定的提升, 达到了 0.736; Distill-m-s 蒸馏模型的 mAP 最低, 仅为 0.729, 与对照组 YOLOv5s 蒸馏模型基本相同。试验结果表明, 随着教师模型规模的扩大, 学生模型所能蒸馏学习的信息越多, 定位效果越好。② 3 种蒸馏模型的模型文件大小与对照组 YOLOv5s 蒸馏模型接近, 约为 14.0

MB; 相比于 YOLOv5l 蒸馏模型(模型文件大小为 95.5 MB),蒸馏后的 YOLOv5s 模型整体参数规模大大减小,符合实际部署的轻量化实时检测要求。
③在计算性能方面,3 种蒸馏模型的 FPS 与对照组

YOLOv5s 蒸馏模型基本一致,Distill-l-s 蒸馏模型的 FPS 最高,达到了 324 帧/s。相比于 YOLOv5l 蒸馏模型(FPS 为 158 帧/s),其计算速度提高了一倍。

表 2 不同零部件下各网络模型的 mAP

Tab. 2 mAP of each network model with different components

零部件	不同模型的 mAP					
	Distill-x-s	Distill-l-s	Distill-m-s	YOLOv5s	YOLOv5m	YOLOv5l
绝缘子	0.881	0.877	0.853	0.858	0.882	0.924
绝缘子底座	0.749	0.736	0.732	0.722	0.737	0.825
双耳套筒	0.773	0.769	0.765	0.777	0.784	0.864
斜撑套筒	0.845	0.822	0.802	0.802	0.822	0.864
斜撑套筒螺钉	0.679	0.652	0.642	0.638	0.667	0.695
斜拉线定位钩	0.681	0.673	0.672	0.676	0.689	0.732
旋转双耳	0.784	0.767	0.764	0.767	0.809	0.831
承力索座	0.747	0.736	0.732	0.722	0.765	0.791
定位器支座	0.839	0.825	0.821	0.813	0.819	0.867
防风拉线固定环	0.634	0.621	0.621	0.612	0.625	0.667
双套管连接器	0.855	0.842	0.812	0.809	0.826	0.865
等电位线	0.536	0.515	0.529	0.534	0.604	0.679

注: Distill-x-s、Distill-l-s、Distill-m-s 分别表示以 Yolov5x、Yolov5l、Yolov5m 作为教师模型训练获得的 YOLOv5s 学生模型。

表 3 各网络模型整体性能

Tab. 3 Overall performance of each network model

检测模型	mAP	FPS/(帧/s)	模型文件大小/MB
Distill-x-s	0.750	323	14.1
Distill-l-s	0.736	324	13.9
Distill-m-s	0.729	323	13.8
YOLOv5s	0.728	322	13.4
YOLOv5m	0.752	212	41.8
YOLOv5l	0.800	158	95.5

根据试验结果绘制 3 个蒸馏模型的 PR(精准率-召回率)曲线如图 4 所示。将 3 种蒸馏模型的分类性能可视化,Distill-x-s 蒸馏模型接触网图像检测结果截图如图 5 所示。由图 4 和图 5 可知,利用蒸馏技术对接触网零部件定位模型进行轻量化操作可以在保证识别精度的基础上,实现资源占用少、计

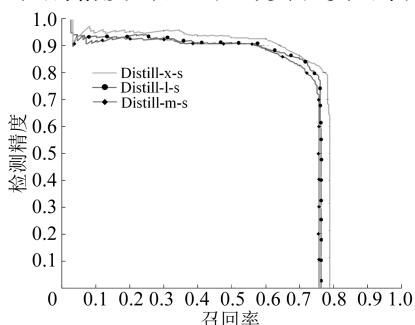
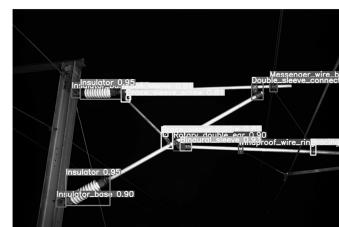


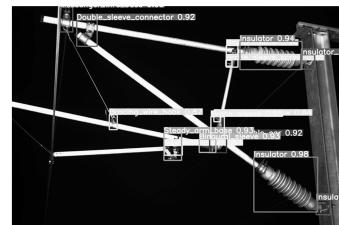
图 4 3 个蒸馏模型的 PR 曲线

Fig. 4 PR curves of 3 distillation models

算速度快的目标。网络蒸馏后的模型可以更好地在基于嵌入式检测设备的智能检测系统上进行部署,能够对接触网支撑装置零部件进行快速有效的定位分析。



a) 模型检测结果示例 1



b) 模型检测结果示例 2

图 5 Distill-x-s 蒸馏模型接触网图像检测结果截图

Fig. 5 Screenshot of catenary image detection results of Distill-x-s distillation model

3 结语

针对传统卷积神经网络模型在供电接触网零部件定位检测中精度高但模型参数规模大和简单

(下转第 118 页)

沉降量先减小然后增大;测点 J23 出现先增大后减小的情况,而测点 J24 出现下沉情况,且其最大沉降量为 1.3 mm,大于靠近围护结构的桥梁桩体,这与数值模拟结果中的桥梁桩基差异沉降规律一致。

人工挖孔桩施工过程中位于基坑东侧桥墩的测点 J22 和地面测点 D133 的最大沉降量分别为 1.3 mm 和 7.1 mm,西侧桥墩的测点 J20 和地面测点 D115 的最大沉降量分别为 1.3 mm 和 7.3 mm。由此可见,采用人工挖孔桩的施工控制措施可以有效避免高架桥和地面的变形。

5 结语

本文研究了基坑下穿高架桥梁且近临既有建(构)筑物结构的施工影响,主要获得以下结论:

1) 在基坑非同步分仓开挖后,坑底上隆区域也呈现出分区域隆起极值的特性,但北端放坡段由于地层不完全揭露,其表现为沉降特性。

2) 在基坑南北端土体开挖完成后,其沉降量大小排序为北端放坡段沉降量>中间段沉降量>南端沉降量>北端沉降量。在基坑开挖完成后,其沉降量大小排序为中间段沉降量>南端沉降量>北端沉降量>北端放坡段沉降量。

3) 基坑下穿桥梁施工会导致梁板出现翘曲变形,由南北端开挖后的两端高、中间低变为开挖完成后的东边沉、西边隆形态。

(上接第 112 页)

小型化网络模型参数规模小、检测速度快但定位精度低的问题,本文提出一种利用网络模型蒸馏技术实现复杂网络模型训练小型化网络模型的方法,提高小型化网络模型的检测精度,以实现轻量化检测设备上的模型高效部署。试验结果表明,在保留接触网零部件定位精度的前提下,所提模型蒸馏方法能够大幅提高接触网零部件的定位计算性能,同时有效减少模型文件大小。本文研究对丰富智能化接触网检测设备的设计制造具有一定的应用参考价值。

参考文献

- [1] KANG G, GAO S, YU L, et al. Deep architecture for high-speed railway insulator surface defect detection: denoising autoencoder with multitask learning[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(8): 2679.
- [2] ZHONG J, LIU Z, HAN Z, et al. A CNN-based defect inspection method for catenary split pins in high-speed railway [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(8): 2849.

4) 有限元数值模拟参数取值偏保守,导致其计算结果较监测数据略大,但整体变化趋势与地下工程实际监测值一致。

参考文献

- [1] 孟繁增. 基坑开挖引起邻近高铁桥墩隆起变形实例分析[J]. 铁道标准设计, 2020, 64(4): 98.
- [2] MENG Fanzeng. Case study on foundation-pit-excavation-induced uplift deformation of adjacent high-speed railway bridge piers[J]. Railway Standard Design, 2020, 64(4): 98.
- [3] 陈祉阳, 王文柱. 地铁车站明挖基坑下穿互通立交桥基础的施工关键技术及变形影响分析[J]. 建筑结构, 2021, 51(增刊1): 1952.
- [4] CHEN Zhiyang, WANG Wenzhu. Key construction technology and deformation influence analysis of subway station open cut foundation pit underpass interchange foundation [J]. Building Structure, 2021, 51(S1): 1952.
- [5] 李文胜. 岩溶地区大直径人工挖孔桩下溶洞处理[J]. 建筑结构, 2018, 48(增刊2): 782.
- [6] LI Wensheng. Treatment of Karst cavity below large diameter hand-excavated piles in Karst area [J]. Building Structure, 2018, 48(S2): 782.
- [7] 李文胜. 岩溶地区大直径人工挖孔桩下溶洞处理[J]. 建筑结构, 2018, 48(增刊2): 782.
- [8] LI Wensheng. Treatment of Karst cavity below large diameter hand-excavated piles in Karst area [J]. Building Structure, 2018, 48(S2): 782.

(收稿日期:2020-09-06)

- [9] CHEN J, LIU Z, WANG H, et al. Automatic defect detection of fasteners on the catenary support device using deep convolutional neural network[J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(2): 257.
- [10] LIU Z, ZHONG J, LYU Y, et al. Location and fault detection of catenary support components based on deep learning[C]//2018 IEEE International Instrumentation and Measurement Technology Conference (I2MTC). Houston, TX: IEEE, 2018: 1.
- [11] LIU Z, LIU K, ZHONG J, et al. A high-precision positioning approach for catenary support components with multiscale difference[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(3): 700.
- [12] LIU W, LIU Z, NÚÑEZ A, et al. Unified deep learning architecture for the detection of all catenary support components[J]. IEEE Access, 2020, 8: 17049.

(收稿日期:2022-06-22)