



主办: 中国科学院空天信息创新研究院  
中国图象图形学学会  
北京应用物理与计算数学研究所

# 中国图象图形学报

2021  
11  
VOL.26

ISSN1006-8961  
CN11-3758/TB





第26卷第11期（总第307期）  
2021年11月16日

中国精品科技期刊  
中国国际影响力优秀学术期刊  
中国科技核心期刊  
中文核心期刊

## 版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

## Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

**主管单位** 中国科学院  
**主办单位** 中国科学院空天信息创新研究院  
中国图象图形学学会  
北京应用物理与计算数学研究所

**主 编** 吴一戎  
**编辑出版** 《中国图象图形学报》编辑出版委员会  
**通信地址** 北京市海淀区北四环西路19号  
**邮 编** 100190  
**电子信箱** jig@aircas.ac.cn  
**电 话** 010-58887035  
**网 址** www.cjig.cn

**广告发布登记号** 京朝工商广登字20170218号  
**总 发 行** 北京报刊发行局  
**订 购** 全国各地邮局  
**海外发行** 中国国际图书贸易集团有限公司  
(邮政信箱: 北京399信箱 邮编: 100048)  
**印刷装订** 北京科信印刷有限公司

## Journal of Image and Graphics

Title inscription: Song Jian | Monthly, Started in 1996


**Superintended by** Chinese Academy of Sciences  
**Sponsored by** Aerospace Information Research Institute, CAS  
China Society of Image and Graphics  
Institute of Applied Physics and Computational Mathematics

**Editor-in-Chief** Wu Yirong  
**Editor, Publisher** Editorial and Publishing Board of Journal of Image and Graphics  
**Address** No. 19, North 4<sup>th</sup> Ring Road West, Haidian District, Beijing, P. R. China  
**Zip code** 100190  
**E-mail** jig@aircas.ac.cn  
**Telephone** 010-58887035  
**Website** www.cjig.cn


**Distributed by** Beijing Bureau for Distribution of Newspapers and Journals  
**Domestic** All Local Post Offices in China  
**Overseas** China International Book Trading Corporation  
(P.O.Box 399, Beijing 100048, P.R.China)  
**Printed by** Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB  
ISSN 1006-8961  
CODEN ZTTXFZ

国外发行代号 M1406  
国内邮发代号 82-831  
国内定价 60.00元



面向改进尺度缩放网络的绝缘子识别(第2561页)



混合增强视觉认知架构及其关键技术进展(第2619页)



激光点云的稀疏体素金字塔邻域构建与分类(第2703页)

编者按 ..... I

## 电力视觉前沿技术

输电线路部件视觉缺陷检测综述

赵振兵, 蒋志钢, 李延旭, 威银城, 翟永杰, 赵文清, 张珂 ..... 2545

面向改进尺度缩放网络的绝缘子识别

赵文清, 张海明, 徐敏夫 ..... 2561

最优知识传递宽残差网络输电线路螺栓缺陷图像分类

威银城, 金超熊, 赵振兵, 丁洁涛, 吕斌 ..... 2571

可变形NTS-Net的螺栓属性多标签分类

张珂, 何颖宣, 赵凯, 冯晓晗, 赵振兵, 马占宇 ..... 2582

嵌入双注意力机制的Faster R-CNN航拍输电线路螺栓缺陷检测

威银城, 武学良, 赵振兵, 史博强, 聂礼强 ..... 2594

轻量化航拍图像电力线语义分割

许刚, 李果 ..... 2605

## 综述

混合增强视觉认知架构及其关键技术进展

王培元, 关欣 ..... 2619

深度学习人脸特征点自动定位综述

徐亚丽, 赵俊莉, 吕智涵, 张志梅, 李劲华, 潘振宽 ..... 2630

## 图像处理和编码

多尺度特征复用混合注意力网络的图像重建

卢正浩, 刘丛 ..... 2645

## 图像分析和识别

自监督深度离散哈希图像检索

万方, 强浩鹏, 雷光波 ..... 2659

L-UNet: 轻量化云遮挡道路提取网络

许苗, 李元祥, 钟娟娟, 左宗成, 熊伟 ..... 2670

基于多尺度特征多对抗网络的雾天图像识别

陈硕, 钟汇才, 李勇周, 王师峰, 杨建刚 ..... 2680

## 图像理解和计算机视觉

结合动态图卷积和空间注意力的点云分类与分割

宋巍, 蔡万源, 何盛琪, 李文俊 ..... 2691

激光点云的稀疏体素金字塔邻域构建与分类

陶帅兵, 梁冲, 蒋腾平, 杨玉娇, 王永君 ..... 2703

## 计算机图形学

单幅植物叶片图像的3维重建

任非儿, 刘通, 杨龙 ..... 2713

## 医学图像处理

深度学习多部位病灶检测与分割

黎生丹, 柏正尧 ..... 2723

## 遥感图像处理

对抗学习遥感图像场景识别


李彤, 张钧萍 ..... 2732

融合特征的卫星视频车辆单目标跟踪


韩鸣飞, 李盛阳, 万雪, 轩诗宇, 赵子飞, 谭洪, 张万峰 ..... 2741

# CONTENTS

## JOURNAL OF IMAGE AND GRAPHICS



Insulator recognition based on an improved scale-transferrable network(P2561)



Hybrid enhanced visual cognition framework and its key technologies(P2619)



Sparse voxel pyramid neighborhood construction and classification of LiDAR point cloud(P2703)

### Frontier Technology of Power Computer Vision

Overview of visual defect detection of transmission line components

Zhao Zhenbing, Jiang Zhigang, Li Yanxu, Qi Yincheng, Zhai Yongjie, Zhao Wenqing, Zhang Ke ..... 2545

Insulator recognition based on an improved scale-transferrable network

Zhao Wenqing, Zhang Haiming, Xu Minfu ..... 2561

Image classification method of transmission line bolt defects using the optimal knowledge transfer wide residual network

Qi Yincheng, Jin Chaoxiong, Zhao Zhenbing, Ding Jietao, Lyu Bin ..... 2571

Multi-label classification method of bolt attributes based on deformable NTS-Net

Zhang Ke, He Yingxuan, Zhao Kai, Feng Xiaohan, Zhao Zhenbing, Ma Zhanyu ..... 2582

Bolt defect detection for aerial transmission lines using Faster R-CNN with an embedded dual attention mechanism

Qi Yincheng, Wu Xueliang, Zhao Zhenbing, Shi Boqiang, Nie Liqiang ..... 2594

Research on lightweight neural network of aerial powerline image segmentation

Xu Gang, Li Guo ..... 2605

### Review

Hybrid enhanced visual cognition framework and its key technologies

Wang Peiyuan, Guan Xin ..... 2619

Automatic facial feature points location based on deep learning: a review

Xu Yali, Zhao Junli, Lyu Zhihan, Zhang Zhimei, Li Jinhua, Pan Zhenkuan ..... 2630

### Image Processing and Coding

Multiscale feature reuse mixed attention network for image reconstruction

Lu Zhenghao, Liu Cong ..... 2645

### Image Analysis and Recognition

Self-supervised deep discrete hashing for image retrieval

Wan Fang, Qiang Haopeng, Lei Guangbo ..... 2659

L-UNet: lightweight network for road extraction in cloud occlusion scene

Xu Miao, Li Yuanxiang, Zhong Juanjuan, Zuo Zongcheng, Xiong Wei ..... 2670

Haze image recognition based on multi-scale feature and multi-adversarial networks

Chen Shuo, Zhong Huicai, Li Yongzhou, Wang Shizheng, Yang Jiangang ..... 2680

### Image Understanding and Computer Vision

Dynamic graph convolution with spatial attention for point cloud classification and segmentation

Song Wei, Cai Wanyuan, He Shengqi, Li Wenjun ..... 2691

Sparse voxel pyramid neighborhood construction and classification of LiDAR point cloud

Tao Shuaibing, Liang Chong, Jiang Tengping, Yang Yujiao, Wang Yongjun ..... 2703

### Computer Graphics

3D reconstruction of a single plant leaf image

Ren Feier, Liu Tong, Yang Long ..... 2713

### Medical Image Processing

Multiorgan lesion detection and segmentation based on deep learning

Li Shengdan, Bai Zhengyao ..... 2723

### Remote Sensing Image Processing

Remote sensing image scene recognition based on adversarial learning

Li Tong, Zhang Junping ..... 2732

Integrating multiple features for tracking vehicles in satellite videos

Han Mingfei, Li Shengyang, Wan Xue, Xuan Shiyu, Zhao Zifei, Tan Hong, Zhang Wanfeng ..... 2741

中图法分类号: TN911.73 文献标识码: A 文章编号: 1006-8961(2021)11-2571-11

论文引用格式: Qi Y C, Jin C X, Zhao Z B, Ding J T and Lyu B. 2021. Image classification method of transmission line bolt defects using the optimal knowledge transfer wide residual network. Journal of Image and Graphics, 26(11): 2571-2581 [DOI:10.11834/jig.200839]

# 最优知识传递宽残差网络输电线路螺栓缺陷图像分类

戚银城<sup>1,2</sup>, 金超熊<sup>1</sup>, 赵振兵<sup>1,2\*</sup>, 丁洁涛<sup>1</sup>, 吕斌<sup>3</sup>

1. 华北电力大学电气与电子工程学院, 保定 071003; 2. 华北电力大学河北省电力物联网技术重点实验室, 保定 071003;
3. 国网浙江杭州萧山区供电有限公司, 杭州 310000

**摘要:** **目的** 输电线路螺栓图像具有分辨率低和视觉信息较差的特点, 针对螺栓缺陷图像分类时教师网络(大模型)参数量大、学生网络(小模型)分类精度低的问题, 提出了一种最优知识传递宽残差网络输电线路螺栓缺陷图像分类方法, 来弥补使用大小模型进行分类任务的局限性。**方法** 首先改变大模型宽度, 即拓宽网络特征表达维度来增加向小模型传递的螺栓缺陷知识和简化小模型结构至3个残差块; 然后为了选出传递螺栓缺陷知识性能最优的大模型, 提出知识偏差的概念来可视化大模型向小模型螺栓缺陷知识传递的程度, 综合分析不同宽度大模型利用知识蒸馏算法与注意力转移算法分别指导小模型训练后的分类准确率, 并用知识偏差来确定最优知识传递模型; 最后将最优知识传递模型利用知识蒸馏算法与注意力转移算法相结合指导小模型训练, 尽可能提升小模型的螺栓缺陷分类性能。**结果** 在自建螺栓缺陷图像分类数据集上进行了验证, 结果表明宽度为5的大模型向小模型传递螺栓缺陷知识性能最优, 使小模型的螺栓缺陷分类准确率提高了5.56%, 小模型与最优大模型分类准确率只差2.17%, 知识偏差为0.28, 且小模型的参数量仅为大模型参数量的0.56%。**结论** 本文提出的最优知识传递宽残差网络输电线路螺栓缺陷图像分类方法, 弥补了大小模型螺栓缺陷图像分类的局限性, 实现了精度与资源消耗的平衡。**关键词:** 螺栓缺陷分类; 最优知识传递; 知识偏差; 知识蒸馏; 注意力转移

## Image classification method of transmission line bolt defects using the optimal knowledge transfer wide residual network

Qi Yincheng<sup>1,2</sup>, Jin Chaoxiong<sup>1</sup>, Zhao Zhenbing<sup>1,2\*</sup>, Ding Jietao<sup>1</sup>, Lyu Bin<sup>3</sup>

1. School of Electrical and Electronic Engineering, North China Electric Power University, Baoding 071003, China;
2. Hebei Key Laboratory of Power Internet of Things Technology, North China Electric Power University, Baoding 071003, China;
3. State Grid Zhejiang Hangzhou Xiaoshan Power Supply CO., LTD., Hangzhou 310000, China

**Abstract: Objective** Bolts play a key role in fixing and connecting various metal parts in transmission lines. Defects seriously affect the power transmission of transmission lines. The imaging background of an inspection image is complicated, the imaging distance and angle are variable, and the bolts occupy a small proportion in the inspection image. Thus, bolt defect images of transmission lines have low resolution and scarce visual information, and they usually require a large model

收稿日期: 2020-12-29; 修回日期: 2021-04-13; 预印本日期: 2021-04-20

\* 通信作者: 赵振兵 zhaozhenbing@ncepu.edu.cn

**基金项目:** 国家自然科学基金项目(61871182, 61773160); 北京市自然科学基金项目(4192055); 河北省自然科学基金项目(F2020502009); 中央高校基本科研业务费专项资金资助(2018MS095, 2020YJ006); 模式识别国家重点实验室开放课题基金项目(201900051)

**Supported by:** National Natural Science Foundation of China (61871182, 61773160); Beijing Municipal Natural Science Foundation (4192055); Natural Science Foundation of Hebei Province, China (F2020502009); Fundamental Research Funds for the Central Universities (2018MS095, 2020YJ006); Open Project Program of the National Laboratory of Pattern Recognition(NLPR) (201900051)

with high complexity and excellent performance to classify bolt defects and ensure accuracy. A large model has a complex structure and numerous parameters, and deploying it on a large scale is difficult due to a large amount of computing resources needed in data analysis. A small model has a simple structure and few parameters, but it cannot completely guarantee the accuracy of bolt defect classification. This study proposes an image classification method of transmission line bolt defects based on the optimal knowledge transfer network to compensate for the limitations of bolt defect classification using large and small models. **Method** The width of the large model is changed, that is, the dimension of network feature expression is broadened, to fully mine the target information in the bolt image, thereby increasing the bolt defect knowledge of the transferability of the large model to the small model. To reduce the parameters of the small model considerably and improve its operation and maintenance capabilities, the structure of the small model is simplified to a 10-layer residual network with three residual blocks. The number of convolution kernels of each residual block is 16, 32, and 64. Therefore, the small model still has obvious features that focus on the low gradient of the bolt image in the low layer, the high difference area in the middle layer, and the overall characteristics of the bolt image in the high layer. Then, the large models of different widths use the attention transfer algorithm and the knowledge distillation algorithm to guide the training of the small models, and the accuracy of the small models under different widths after the training is calculated. Afterward, the concept of knowledge deviation is proposed to measure the degree of bolt defect knowledge transfer of large models and select the large model with the best performance in transferring bolt defect knowledge. The performance of the large and small models is mapped on a number line in the form of accuracy. The calculation process of knowledge deviation proceeds as follows. First, the difference in bolt defect classification accuracy between the large model with a known width and the small model being instructed is calculated. Second, the difference in bolt defect classification accuracy between the large model and the small model that is not being instructed is computed. Lastly, the ratio of the two differences before and after the calculation is adopted as the knowledge deviation. The smaller the knowledge deviation is, the greater the degree of bolt defect knowledge transfer is from the large model to the small model. The optimal knowledge transfer model is determined according to the knowledge deviation of different widths and the bolt defect classification accuracy of the small models under different guidance methods. The optimal knowledge transfer model combines the attention algorithm and the knowledge distillation algorithm to guide in small model training and maximize the bolt defect classification performance of the small model. **Result** The self-built bolt defect image classification data set verifies the effectiveness of this method in improving the accuracy of bolt classification of the simplified small model. The data set is constructed by clipping and optimizing the transmission line inspection image. The bolt defect image classification data set contains a total of 6 420 images, including 3 136 normal bolts, 2 820 bolts with missing pins, and 464 bolts with missing nuts, which belong to three categories. Experimental results show that the large model with a width of 5 has the best performance in transferring bolt defect knowledge to the small model, and it increases the bolt defect classification accuracy of the small model by 5.56%. The difference in the accuracy of bolt defect classification between the small model and the optimal knowledge transfer model is only 2.17%. The knowledge deviation is 0.28, and the parameter of the small model is only 0.56% of the parameter of the large model. **Conclusion** The proposed bolt defect classification method based on the optimal knowledge transfer network greatly alleviates the problems of large model parameters and low classification accuracy of small models caused by bolt image characteristics. Balance is achieved between the classification accuracy of the bolt defect image and resource consumption. The method meets the requirements of actual field operation and maintenance, such as the work requirements of embedded equipment (e.g., online monitoring in transmission lines) and reduces the resource consumption of transmission line patrol data analysis. **Key words:** bolt defect classification; optimal knowledge transfer; knowledge deviation; knowledge distillation; attention transfer

## 0 引言

输电线路是电能高效传输的重要通道(江秀臣

等,2019)。螺栓是输电线路中广泛存在的重要紧固件,其长期受自然环境、外部机械负荷张力和电力系统内部电力负荷影响(赵振兵等,2019),使螺栓易产生螺母松动、缺失、脱销等缺陷,进而严重威胁

电能平稳传输。因此,及时将输电线路中螺栓表面状态分类,对保障输电线路电能传输具有重大意义。

直升机、无人机巡检现已成为输电线路日常巡检的主要手段之一(全卫国等,2010;彭向阳等,2015),巡检图像背景复杂、成像距离与角度多变以及螺栓目标微小,导致螺栓图像具有分辨率较低、视觉信息不充分等特点。为了充分挖掘螺栓图像中的特征信息,王凯等人(2019)利用深度学习 RetinaNet 算法提取正常与缺陷螺栓特征,然后融合底层特征与顶层特征,实现螺栓缺陷识别。薛阳等人(2020)将深度残差网络 ResNet-50 作为 Faster CNN (faster region convolutional neural network) 螺栓图像特征提取网络,提高螺栓缺陷识别精度。针对螺栓尺寸小的特点,顾超越等人(2020)利用 ResNet-101 提取的多尺度特征建立特征金字塔,再以 K-means 算法优化初始锚框,完成螺栓缺陷识别。李雪峰等人(2020)利用残差网络变体 SCNet (self-calibrated convolutions net) 提取特征,然后设计 PinFPN (pin feature pyramid networks),增强识别 Faster RCNN 螺栓等小目标的能力。多种算法的结合使用增加了模型复杂度,提升了图像识别准确率(赵永强等,2020)。但复杂的模型引入了大量参数(戴铂等,2016),在分析海量数据时耗费大量计算资源和时间,降低了任务效率,难以使模型进行大规模部署。因此,Hinton 等人(2015)首次提出了知识蒸馏概念,将复杂度高、性能好的模型称为教师网络(大模型);结构简单、性能较差的模型称为学生网络(小模型)。通过计算两个网络输出的软目标的距离,实现教师网络向学生网络的知识迁移,从而提升学生网络推理性能。为了提高学生网络的性能,Romero 等人(2015)将多个教师网络的软目标进行加权组合、随机选择和样本扩充,再分别指导学生网络学习。Park 等人(2019)提出了关系型蒸馏学习方法,将多个教师网络的输出组成结构单元指导学生网络学习教师网络的结构信息。Heo 等人(2019)利用对抗攻击策略将基准样本转为目标样本,然后通过目标样本指导学生网络训练。耿增民等人(2020)将二值化注意力机制与知识蒸馏相融合来提升学生网络性能。为了提升更纤细的学生网络性能,Fukuda 等人(2017)提出计算教师网络与学生网络特征图距离,实现性能迁移。Cho 和 Hariharan (2019)提出提前终止蒸馏法来解决教师网络与学

生网络的能力匹配问题。Wan 等人(2020)利用学生网络模仿教师网络自注意力模块,实现纤细学生网络的性能提升。Chung 等人(2020)从特征图空间相关性角度出发,提出使用对抗训练的方法在线相互学习特征图的分布。Ye 等人(2020)在教师网络与学生网络标签空间不同的情况下进行样本间的关系蒸馏,提高了学生网络的样本鉴别能力。

在直升机、无人机巡检图像的边缘计算以及输电线路的在线监测等嵌入式设备中都需要参数量小且性能良好的模型支撑;在输电线路监测站多任务并行分析大量数据时,也需要降低资源消耗来保证实时性监测。知识蒸馏技术能够较大程度地提升小模型的性能,其目的为保证小模型足够小的条件下,大模型指导小模型训练后的小模型性能尽可能逼近大模型。本文针对输电线路螺栓图像的特点,提出了最优知识传递宽残差网络输电线路螺栓缺陷图像分类方法,大幅度降低了网络参数量,提升了小模型的性能,实现了螺栓缺陷图像分类精度与资源消耗的平衡。

## 1 研究方法

知识蒸馏的本质是知识迁移,其网络由教师网络和学生网络两部分组成。教师网络具有螺栓缺陷图像分类精度高、参数量大和资源消耗大的特点;而学生网络结构简单,参数量小,能够实现大规模部署,但螺栓缺陷图像的分类精度较低。因此,提高学生网络分类精度和充分简化学生网络结构都是十分必要的。

针对螺栓图像分辨率较低和视觉信息较差的特性导致教师网络参数量大、学生网络精度低的问题,提出了一种最优知识传递宽残差网络输电线路螺栓缺陷图像分类方法,其中主要贡献有:

1) 改变教师网络宽度即拓宽卷积通道维度,来提高教师网络对螺栓图像的特征表达能力,达到增加向学生网络传递螺栓缺陷知识的目的;同时将学生网络简化至含有 3 个残差块的 10 层残差网络,以大幅度降低学生网络参数量。

2) 为了确定最优知识传递网络,提出了知识偏差的概念来衡量教师网络与学生网络的差异性,将不同宽度的教师网络与学生网络性能以准确率的形式在数轴上进行映射,通过计算已知宽度的教师网

络与被指导学生网络的精度差和教师网络与无指导学生网络的精度差的比值来可视化教师网络向学生网络的螺栓缺陷知识传递程度。知识偏差越小,知识传递程度越大,反之越小。最后综合分析知识偏差和不同算法下学生网络的精度提升程度,确定最优知识传递网络。

3) 为了最大程度提升学生网络螺栓缺陷分类性能,将最优知识传递的教师网络采用隐藏层注意力转移(attention transfer, AT)算法和输出层知识蒸馏(knowledge distillation, KD)算法相结合指导学生网络训练后,得到螺栓缺陷分类精度最佳的学生网络。

依据自建螺栓缺陷图像分类数据集对所提方法有效性进行了验证。教师—学生网络螺栓缺陷分类流程如图1所示,其中教师网络选用深度为40的宽残差网络(Zagoruyko和Komodakis, 2016),学生网络简化为只有3个残差块的残差网络, $K$ 为宽残差网络即教师网络的宽度。




图1 教师—学生网络螺栓缺陷图像分类流程

Fig. 1 Flow of bolt defect image classification in teacher-student network

## 1.1 螺栓知识转移方式

### 1.1.1 输出层知识蒸馏

知识蒸馏算法主要原理是通过教师网络输出的

软标签与学生网络输出的软标签一起辅助学生网络对硬标签训练,完成教师网络的知识迁移。完整原理如图2所示,其过程是首先训练教师网络,然后利用训练完成的教师网络指导学生网络训练,最后利用训练完成的学生网络进行分类; $T$ 是网络 Softmax 层引入的温度系数,用于生成软标签。




图2 知识蒸馏原理

Fig. 2 Schematic diagram of knowledge distillation

通常神经网络输出的硬标签只有标注数据时的0和1,忽略了除正确类别下的其他隐藏信息;而教师网络输出的软标签用0和1之间的数据来标注图像,这样软标签不仅有类别信息,同时也具有不同类别间的关系信息。软标签即在网络的 Softmax 层引入温度系数  $T$  得到软化的概率分布,计算公式为

$$S_i = \frac{\exp(z_i/T)}{\sum_j \exp(z_j/T)} \quad (1)$$

式中,  $z_j$  为前一级第  $j$  个神经元的输出值;  $j \in \mathbf{N}^+$ ;  $S_i$  表示第  $i$  个神经元输出值的指数与所有神经元输出值指数和的比值;温度系数  $T$  取值越大,概率分布越平缓;  $T$  值减小,容易放大错误分类概率,本文在计算软标签时  $T$  取4。

知识蒸馏算法整个训练过程的损失函数为

$$L_{KD} = aL_1(P_t, P_s) + (1-a)L_2(Q_s, y_{true}) \quad (2)$$

式中,  $a$  为两部分损失函数的权重系数,为了充分学习教师网络性能,通常设为0.9;  $L_1$  为教师网络输出的软标签  $P_t$  和学生网络输出的软标签  $P_s$  的 KL 散度(Kullback-Leibler divergence)损失函数(Hershey和Olsen, 2007);  $L_2$  为计算学生网络输出的硬标签  $Q_s$  与真实标签  $y_{true}$  距离的交叉熵损失函数(Li和Lee, 1993)。

### 1.1.2 隐藏层注意力转移

注意力的本质是一个空间映射,即把对输出空间决策影响大的输入空间进行编码。在网络中一个隐藏神经元输出的激活函数值的绝对值越大,表明

这个神经元越重要,越值得对其进行注意力生成(Zagoruyko 和 Komodakis, 2017)。

注意力图的生成方式是将激活函数输出的张量  $\mathbf{A}$  在卷积通道维度压平,得到张量  $\mathbf{A}$  中各元素在卷积核通道维度的绝对值统计量,即

$$F: \mathbf{R}^{CHW} \rightarrow \mathbf{R}^{HW} \quad (3)$$

$$F(\mathbf{A}) = \sum_{i=1}^C |\mathbf{A}_i|^U \quad (4)$$

式中,  $\mathbf{R}$  为空间中  $C$  个特征平面的集合;  $F$  是 3 维到 2 维向量的变换;  $F(\mathbf{A})$  是以  $\mathbf{A}$  为变量的  $F$  函数;  $C$  为卷积通道数;  $H$  和  $W$  为特征平面的尺寸;  $\mathbf{A}_i$  为张量  $\mathbf{A}$  中第  $i$  维的特征平面,张量  $\mathbf{A} \in \mathbf{R}$ ;  $U$  为正整数,本文  $U$  取 1。

在网络隐藏层中不同位置注意力图的关注点不同,低层网络关注螺栓缺陷的低梯度点;中层网络关注螺栓缺陷高差异的区域,即激活函数输出大的区域;高层网络关注整体螺栓缺陷。为了使学生网络充分学习教师网络的螺栓缺陷特征表达能力,本文在网络隐藏层低、中、高 3 个位置分别进行注意力转移,如图 3 所示。




图 3 教师—学生网络注意力转移示意图

Fig. 3 Diagram of attention transfer in teacher-student network

教师网络在网络隐藏层向学生网络进行注意力转移,其隐藏层的损失函数为

$$L_{AT} = \frac{\beta}{2} \sum_j \left\| \frac{\mathbf{W}_S^j}{\|\mathbf{W}_S^j\|} - \frac{\mathbf{W}_T^j}{\|\mathbf{W}_T^j\|} \right\|_P \quad (5)$$

式中,  $\beta$  为权重,常取 1 000;  $P$  取 2 表示 2 范数;  $\mathbf{W}_S^j$  和  $\mathbf{W}_T^j$  分别表示第  $j$  组的学生网络和教师网络的注意力图的矢量化形式,  $\mathbf{W}_S^j$  和  $\mathbf{W}_T^j$  的计算公式为

$$\mathbf{W}_S^j = \text{vec}(F(\mathbf{A}_S^j)) \quad (6)$$

$$\mathbf{W}_T^j = \text{vec}(F(\mathbf{A}_T^j)) \quad (7)$$

式中,  $\text{vec}$  表示向量化操作;  $\mathbf{A}_S^j$  和  $\mathbf{A}_T^j$  分别表示第  $j$  组的学生网络和教师网络的 3 维张量。

教师网络通过注意力转移机制指导学生网络训练螺栓缺陷图像分类数据集的损失函数为

$$L_3 = L_2(Q_s, y_{\text{true}}) + L_{AT} \quad (8)$$

综上所述,本文最优知识传递网络采用注意力转移算法与知识蒸馏算法相结合指导学生网络训练,其损失函数为

$$L = L_{AT} + L_{KD} \quad (9)$$

## 1.2 教师—学生网络优化

### 1.2.1 拓宽教师网络

巡检图像成像背景复杂,距离与角度多变,使螺栓缺陷图像数据集内部分螺栓图像具有如阴影、遮挡等视觉信息不充分的特点;另外,螺栓图像在巡检图像中占比小,使螺栓图像普遍具有分辨率低的特点;因此,螺栓缺陷图像分类数据集中存在大量阴影、模糊和遮挡等困难样本,大大增加了螺栓缺陷图像分类任务的难度,数据集中困难样本如图 4 所示。



(a) 阴影脱销螺栓 (b) 被遮挡正常螺栓 (c) 模糊螺母缺失螺栓

图 4 螺栓缺陷图像分类数据集中的困难样本

Fig. 4 Difficult samples in bolt defect image classification dataset ((a) shaded bolts with missing pin; (b) occluded normal bolts; (c) blurred bolts with missing nut)

针对螺栓图像分辨率低和视觉信息较差的特点,通过改变教师网络宽度即拓宽螺栓图像的特征表达维度来充分提取螺栓图像中的特征信息,从而增加教师网络向学生网络的可传递性螺栓缺陷知识,提高学生网络分类精度。本文教师网络中的残差块如图 5 所示。




图 5 残差块

Fig. 5 Residual block ((a) conventional residual block; (b) widened residual block)

图5中  $\text{Conv}[3 \times 3]$  表示卷积核的大小为  $3 \times 3$ ; 为了方便说明, 引入了宽度系数  $K$ , 表示教师网络的宽度;  $N$  为每层卷积核的基础数量;  $X_L$  为当前残差块的输入,  $X_{L+1}$  为当前残差块的输出。在网络中每一卷积层的卷积核数量为

$$M = N \times K, N \in [16, 32, 64] \quad (10)$$

式中,  $N$  取 16、32 和 64 分别表示网络低层、中层和高层卷积核的基础数量,  $M$  表示每一层卷积核的数量; 因此, 网络低、中、高层卷积核数量不同, 关注的螺栓缺陷图像特征信息不同。

将网络宽度加宽后, 每一卷积层的卷积核依然采用并联方式, 能够充分挖掘螺栓图像中的特征信息。但可以预见, 网络宽度与分类效果并不是正比关系, 不能无限增大宽度。这是因为在螺栓图像中存在着除螺栓信息外的其他冗余信息, 过于增大网络宽度, 会导致螺栓图像特征与其他信息过分提取而加大网络的错误学习概率, 影响最终的学生网络分类结果。

### 1.2.2 简化学生网络结构

为了大幅度降低学生网络参数, 将学生网络简化至含有 3 个残差块的 10 层残差网络, 且学生网络没有进行拓宽。为了确保学生网络在隐藏层充分拟合教师网络的特征表达能力, 学生网络 (ResNet-10-1) 在网络低、中、高层分别保留 16、32、64 的卷积核数量, 学生网络结构如图 6 所示。




图6 学生网络结构

Fig. 6 Diagram of student network structure

学生网络为基本的残差网络, 选择 3 个不同卷积核数量残差块的目的是降低参数量的同时, 使整个学生网络仍具备较为明显的低、中、高层网络特性来充分学习教师网络的螺栓缺陷知识。

因此, 教师—学生网络优化的逻辑流程为:

- 1) 输入螺栓图像;
- 2) 增大教师网络宽度;
- 3) 增加卷积通道数, 即拓宽螺栓图像的特征表达维度;
- 4) 教师网络充分提取螺栓缺陷图像中的特征


信息;

- 5) 增加教师网络可传递性螺栓缺陷知识;
- 6) 最优教师网络指导简化后的学生网络训练;
- 7) 提高简化后学生网络螺栓缺陷图像分类精度。

## 2 实验与结果

### 2.1 实验准备

目前没有公共的输电线路螺栓缺陷图像分类数据集, 在实验室课题组长期努力下, 根据 PASCAL VOC (pattern analysis, statistical modeling and computational learning visual object classes) 数据格式对巡检图像进行标注, 标注依据为《架空输电线路设备缺陷影像标注规范(试行)》。通过对标注后的巡检图像依据标注框进行剪裁构建实验所需的螺栓缺陷图像分类数据集, 数据集中的各个类别标准螺栓图像样本如图 7 所示。



(a) 正常螺栓 (b) 脱销螺栓 (c) 螺母缺失螺栓

图7 各个类别标准螺栓图像样本

Fig. 7 Sample image of each type of standard bolt

- ((a) normal bolts; (b) bolts with missing pin;  
(c) bolts with missing nut)

自建螺栓缺陷图像分类数据集共有 6 420 幅图像, 其中正常螺栓 3 136 幅, 脱销螺栓 2 820 幅, 螺母缺失螺栓 464 幅, 共 3 类。数据集分为训练集和测试集, 且训练集与测试集比例为 4 : 1。

教师网络是在 ImageNet 进行了预训练的 ResNet-40-K, 学生网络采用只含有 3 个残差块的 ResNet-10-1; 使用 GPU 版 Pytorch 进行训练; 初始学习率设为 0.1, batch-size 为 64, epoch 为 100; 采用随机梯度下降法进行优化; 采用水平翻转和随机方向旋转进行数据集扩充(马崇昇等, 2021)。实验过程主要步骤为:

- 1) 利用螺栓缺陷分类图像数据集训练不同宽度的教师网络, 并统计准确率;

2)利用已训练完成的不同宽度的教师网络指导学生网络训练螺栓缺陷图像分类数据集,并统计准确率。

步骤2)中为了保证实验的严谨性,在统计不同宽度教师网络准确率后,将不同宽度的教师网络分别采用隐藏层注意力转移、输出层知识蒸馏和注意力转移与知识蒸馏相结合3种方式指导学生网络训练;将分类准确率、参数量和提出的知识偏差作为评价指标,来确定最优传递知识网络;最后将最优宽度教师网络通过隐藏层注意力转移与输出层知识蒸馏相结合指导学生网络训练后的分类准确率作为学生网络的最佳结果。

## 2.2 结果与分析

为了验证改变教师网络宽度以提高教师网络所包含的螺栓缺陷知识,利用自建螺栓缺陷图像分类数据集分别对学生网络 and 不同宽度的教师网络进行了实验研究,其结果如表1所示。本文所有实验结果均取测试集分类准确率收敛后前10名的均值。

表1 不同参数量网络的分类准确率  
Table 1 Classification accuracy of network with different parameters

| 残差网络        | 分类准确率/%      | 参数量        | 字节数/MB |
|-------------|--------------|------------|--------|
| ResNet-10-1 | 83.26        | 78 330     | 0.30   |
| ResNet-40-1 | 89.14        | 566 650    | 2.16   |
| ResNet-40-2 | 89.71        | 2 248 954  | 8.58   |
| ResNet-40-3 | 90.11        | 5 046 650  | 19.25  |
| ResNet-40-4 | 90.47        | 8 959 994  | 34.17  |
| ResNet-40-5 | <b>90.99</b> | 13 988 986 | 53.36  |
| ResNet-40-6 | 90.63        | 20 133 626 | 76.80  |
| ResNet-40-7 | 90.71        | 27 393 914 | 104.50 |
| ResNet-40-8 | 89.89        | 35 769 850 | 136.45 |

注:加粗字体为最优结果。

从表1可得,通过增大卷积通道维度,使网络螺栓缺陷图像的特征表达能力增强,提高了螺栓缺陷图像的分类准确率。宽度为5的教师网络(ResNet-40-5)的分类效果最理想,比没有加宽的教师网络(ResNet-40-1),螺栓缺陷图像的分类准确率提高了1.85%。随着网络宽度增大至5,螺栓缺陷图像的分类准确率逐渐提升,但宽度进一步增大时,螺栓缺陷图像的分类准确率开始呈下降趋势。这是因为螺

栓图像对比度、分辨率较低以及螺栓图像中除了螺栓目标外,还具有其他影响螺栓判别的冗余信息,随着教师网络的卷积特征通道数增加对其过分表达,影响了螺栓缺陷分类精度的提高。

由于不同宽度教师网络的螺栓缺陷分类性能相差较小,仅根据其分类准确率并不能确定螺栓知识传递最优的教师网络。因此,为了选取最优教师网络来提高学生网络的螺栓缺陷分类精度,将宽度1~8的教师网络分别指导学生网络训练。同时为了确保选取最优教师网络的实验严谨性,教师网络分别采用在隐藏层注意力转移算法和输出层知识蒸馏算法两种指导方式进行了实验验证,其结果如表2所示。

表2 指导训练后的学生网络分类准确率  
Table 2 Classification accuracy of the student network after being instructed to train

| 教师网络        | 学生网络螺栓缺陷图像分类准确率/% |              |
|-------------|-------------------|--------------|
|             | 注意力转移             | 知识蒸馏         |
| ResNet-40-1 | 85.06             | 84.15        |
| ResNet-40-2 | 85.35             | 84.75        |
| ResNet-40-3 | 85.36             | 85.31        |
| ResNet-40-4 | 85.55             | 85.64        |
| ResNet-40-5 | <b>87.51</b>      | <b>86.23</b> |
| ResNet-40-6 | 86.48             | <b>85.85</b> |
| ResNet-40-7 | <b>87.53</b>      | 85.06        |
| ResNet-40-8 | 85.96             | 85.33        |

注:加粗字体为每列前2名的最优结果。

从表2分析可得,拓宽螺栓缺陷图像的特征表达维度即增加教师网络的螺栓缺陷知识后,教师网络采用的两种方式指导学生网络训练,均提高了学生网络的分类精度,且随着教师网络卷积通道数的增加,学生网络的分类精度与教师网络分类精度变化趋势相仿。同时,宽度5,6,7的教师网络对比宽度1的教师网络指导的学生网络训练,使得学生网络的准确率有了明显提升,验证了增加螺栓缺陷图像的特征表达通道数对提升学生网络螺栓缺陷分类精度的有效性。

目前,知识蒸馏领域的主要评价指标为参数量和分类准确率。参数量是度量模型的大小,学生网络分类准确率的提升是度量知识传递方法优劣的关键,而仅从学生网络的分类准确率变化判断知识传

递程度会造成性能优秀的教师网络知识传递不充分等问题。

为了选出最优知识传递网络,最大程度提高学生网络的螺栓缺陷分类性能,本文提出了知识偏差的概念来度量教师网络与学生网络的差异性,进而可视化教师网络向学生网络螺栓缺陷知识传递的程度,避免仅依据网络分类准确率而误判最优教师网络的问题。将教师网络与学生网络分类准确率映射在数轴上,如图8所示。




图8 映射教师—学生网络的螺栓缺陷图像分类准确率

Fig. 8 Mapping of bolt defect classification accuracy in teacher-student networks

图8中,  $T_w$  是宽度为  $w$  的教师网络螺栓缺陷分类准确率;  $AS_w$  是学生网络经宽度为  $w$  的教师网络指导训练后的螺栓缺陷分类准确率;  $BS$  是学生网络单独训练后的螺栓缺陷分类准确率;  $\Delta TBS$  是  $T_w$  与  $BS$  的差;  $\Delta TAS$  是  $T_w$  与  $AS_w$  的差。知识偏差的计算公式为

$$TS_w = \frac{T_w - AS_w}{T_w - BS} = \frac{\Delta TAS}{\Delta TBS}, AS_w \in (BS, T_w) \quad (11)$$

式中,  $TS_w$  是教师网络宽为  $w$  时指导学生网络训练后的知识偏差,  $w \in \mathbf{N}^+$ , 本文  $w$  最大值为8; 根据  $AS_w$  的取值可得  $TS_w$  的值域, 即

$$\lim_{AS_w \rightarrow BS} TS_w = 1 \quad (12)$$

$$\lim_{AS_w \rightarrow T_w} TS_w = 0 \quad (13)$$

由式(12)(13)得,  $TS_w \in (0, 1)$ 。故当  $TS_w = 1$  时,  $\Delta TAS = \Delta TBS$  表示教师网络螺栓缺陷知识没有传递; 当  $TS_w = 0$  时,  $\Delta TAS = 0$ , 表示教师网络螺栓缺陷知识完全传递并覆盖了学生网络性能。

通过式(11)一式(13)分析了本文定义的知识偏差的合理性。知识偏差越小, 表明教师网络向学生网络传递的螺栓缺陷知识程度越大; 反之越小。综合分析不同指导方式下的  $AS_w$  和  $TS_w$ , 其结果如图9所示。

图9中,  $BS-AT$  和  $BS-KD$  分别为学生网络单独训练后的螺栓缺陷分类准确率;  $AS-AT$  和  $AS-KD$  分




图9 不同指导方式的结果曲线

Fig. 9 The result curves of different guidance methods

((a) attention transfer algorithm;

(b) knowledge distillation algorithm)

别为教师网络通过隐藏层注意力转移算法和输出层知识蒸馏算法指导学生网络训练后的学生网络螺栓缺陷分类准确率;  $TS-AT$  和  $TS-KD$  分别是注意力转移算法的知识偏差和知识蒸馏算法的知识偏差。

在注意力转移算法中分析  $AS-AT$  曲线可得, 最大的两个值是  $AS_5$  和  $AS_7$ , 表明宽度为5和7的教师网络对学生网络的性能提升最为显著, 分别提高了学生网络4.25%和4.26%的精度, 且  $TS-AT$  曲线中最小的两个值为  $TS_5$  和  $TS_7$  分别是0.45和0.43; 在输出层知识蒸馏算法中分析  $AS-KD$  曲线可得, 最大的两个值是  $AS_5$  和  $AS_6$ , 分别提高了学生网络2.97%和2.59%的精度, 且  $TS-KD$  曲线中最小的两个值为  $TS_5$  和  $TS_6$  分别是0.61和0.64。因此, 综合分析  $AS_w$  和  $TS_w$  可知, 宽度为5的教师网络(Resnet-40-5)是最优知识传递网络。

从以上分析可得, ResNet-40-5 作为最优知识传递网络能够最大化地向学生网络(ResNet-10-1)传递螺栓缺陷知识, 进而最大程度地提高学生网络的螺栓缺陷分类性能。因此, 本文教师网络(ResNet-40-5)采用隐藏层注意力转移与输出层知识蒸馏相

结合的方式指导学生网络(ResNet-10-1)训练后,学生网络的螺栓缺陷分类准确率为最佳结果,学生网络的损失函数曲线如图10所示。




图10 最佳学生网络的损失函数曲线

Fig. 10 The loss function curves of the best of student network

图10中,train\_loss是训练集损失函数曲线,test\_loss是测试集损失函数曲线。在epoch大约为83时,训练集与测试集均平稳收敛,没有出现过拟合或欠拟合现象,验证了利用自建螺栓缺陷图像分类数据集所得结果的科学性,其结果如表3所示。

表3 最佳教师网络与学生网络的分类准确率

Table 3 The classification accuracy of best teacher network and student network

| 残差网络                     | 分类准确率/%      | 参数量        | 字节数/MB |
|--------------------------|--------------|------------|--------|
| ResNet-10-1              | 83.26        | 78 330     | 0.30   |
| ResNet-10-1<br>(AT + KD) | <b>88.82</b> | 78 330     | 0.30   |
| ResNet-40-5              | 90.99        | 13 988 986 | 136.45 |

注:加粗字体为本文学生网络分类最优结果。

从表3可得,教师网络采用隐藏层注意力转移与输出层知识蒸馏相结合的方式指导学生网络训练后,使学生网络准确率提高了5.56%,与教师网络准确率仅差2.17%,知识偏差为0.28,而学生网络的参数量仅为教师网络的0.56%。

从实验结果可知,针对输电线路螺栓图像的特性,提出的螺栓缺陷图像分类方法提升了学生网络的分类性能,但螺栓缺陷图像分类任务仍较为困难,主要有以下几点原因:

1)螺栓缺陷图像分类数据集中总的样本较少,且样本不平衡是造成分类精度普遍较低的主要原因。

2)螺栓缺陷图像分类数据集中存在着类内差异性较大问题,如螺母缺失螺栓图像中存在着带销螺母缺失和脱销螺母缺失两种,如图11所示。



图11 带销螺母缺失螺栓和脱销螺母缺失螺栓

Fig. 11 Missing bolt with pin nut and missing bolt with unthreaded nut

3)螺栓缺陷数据集中除了存在困难样本外,还存在着部分类别间容易混淆样本,如图12所示。



图12 螺母缺失螺栓和正常螺栓

Fig. 12 Nut missing bolt and normal bolt

因此,提高螺栓缺陷图像分类数据集的样本数量、质量和增强网络对螺栓图像类间差异性的关注性是解决螺栓图像分类任务难的重要手段。

为了进一步验证研究方法的有效性,在CIFAR-10(Canadian Institute for Advanced Research)数据集进行了基于最优知识传递网络的图像分类方法的实验探究,如表4所示。

表4 教师—学生网络的分类准确率和知识偏差

Table 4 The classification accuracy and knowledge deviation of teacher-student networks

| 残差网络        | 分类准确率/%      | AT + KD/%    | 知识偏差        |
|-------------|--------------|--------------|-------------|
| ResNet-10-1 | 87.68        | —            | —           |
| ResNet-40-1 | 93.58        | 87.90        | 0.96        |
| ResNet-40-2 | 94.78        | 88.01        | 0.95        |
| ResNet-40-3 | 95.20        | 88.32        | 0.91        |
| ResNet-40-4 | 95.51        | 88.54        | 0.89        |
| ResNet-40-5 | 95.78        | 88.65        | 0.88        |
| ResNet-40-6 | 95.75        | <b>89.09</b> | <b>0.83</b> |
| ResNet-40-7 | <b>95.90</b> | 88.26        | 0.93        |
| ResNet-40-8 | 95.89        | 88.78        | 0.87        |

注:加粗字体为每列最优结果,“—”表示原文中未给出实验结果。

从表4可得,通过对教师网络加宽后,宽为7的教师网络的准确率为95.90%,比宽为1的教师网络准确率提高了2.32%;宽为7的教师网络准确率最高,但并不是CIFAR-10数据集的最优知识传递网络,根据本文方法确定了宽为6的教师网络为最优知识传递网络。表4实验结果验证了依据本文方法选定宽为6的教师网络作为最优知识传递网络指导学生网络训练的有效性,最佳学生网络分类准确率为89.09%,提高了1.41%,知识偏差为0.83,是所有教师—学生网络中的最小值。

学生网络是ResNet-10-1时,在自建螺栓缺陷图像分类数据集中最优知识传递网络是ResNet-40-5;在CIFAR-10数据集中最优知识传递网络是ResNet-40-6,均验证了方法的有效性。因此,本文提出的基于最优知识传递网络的螺栓缺陷图像分类方法能够充分提高学生网络的螺栓缺陷图像分类性能,实现了资源消耗与精度的平衡。

### 3 结 论

利用自建螺栓缺陷数据集验证了本文提出的基于最优知识传递网络的螺栓缺陷图像分类方法,该方法能够极大程度缓解因螺栓图像特性导致的教师网络参数量大、学生网络精度低的问题。

1)通过拓宽教师网络的宽度来增加螺栓图像的特征表达通道数,使教师网络的分类精度最高达90.99%,提升了1.85%;同时将学生网络简化至含有3个残差块,参数量仅有78 330个。

2)提出了知识偏差的概念来可视化不同宽度教师网络向学生网络传递螺栓缺陷知识的程度;综合分析知识偏差和学生网络被不同宽度教师网络利用不同指导方式训练后的螺栓缺陷图像分类精度,确定了宽度为5即ResNet-40-5是最优知识传递网络。

3)将最优知识传递网络利用注意力转移算法与知识蒸馏算法相结合的方式指导学生网络训练,使学生网络螺栓缺陷分类精度提高了5.56%,知识偏差为0.28,学生网络参数量仅是最优知识传递网络的0.56%。

本文模型可以针对其他模型在巡检图像中检测到的螺栓目标,进行2阶段的螺栓缺陷图像分类,降低资源消耗。在后续研究中,将利用知识蒸馏技术实现整幅巡检图像中螺栓缺陷的检测。

### 参考文献 (References)

- Cho J H and Hariharan B. 2019. On the efficacy of knowledge distillation//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South): IEEE: 4794-4802 [DOI: 10.1109/ICCV.2019.00489]
- Chung I, Park S, Kim J and Kwak N. 2020. Feature-map-level online adversarial knowledge distillation [EB/OL]. [2021-02-01]. <https://arxiv.org/pdf/2002.01775.pdf>
- Dai B, Hou Z Q, Yu W S, Hu D and Fan S Y. 2016. Robust visual tracking via fast deep learning. Journal of Image and Graphics, 21(12): 1662-1670 (戴铂, 侯志强, 余旺盛, 胡丹, 范舜奕. 2016. 快速深度学习的鲁棒视觉跟踪. 中国图象图形学报, 21(12): 1662-1670) [DOI: 10.11834/jig.20161211]
- Fukuda T, Suzuki M, Kurata G, Thomas S, Cui J and Ramabhadran B. 2017. Efficient knowledge distillation from an ensemble of teachers//Proceedings of Interspeech 2017. Stockholm, Sweden: Interspeech: 3697-3701 [DOI: 10.21437/Interspeech.2017-614]
- Geng Z M, Yu M Q, Liu X B and Lyu C. 2020. Combining attention mechanism and knowledge distillation for Siamese network compression. Journal of Image and Graphics, 25(12): 2563-2577 (耿增民, 余梦巧, 刘峡壁, 吕超. 2020. 融合注意力机制与知识蒸馏的孪生网络压缩. 中国图象图形学报, 25(12): 2563-2577) [DOI: 10.11834/jig.200051]
- Gu C Y, Li Z, Shi J T, Zhao H H, Jiang Y and Jiang X C. 2020. Detection for pin defects of overhead lines by UAV patrol image based on improved Faster-RCNN. High Voltage Engineering, 46(9): 3089-3096 (顾超越, 李喆, 史晋涛, 赵航航, 江一, 江秀臣. 2020. 基于改进 Faster-RCNN 的无人机巡检架空线路销钉缺陷检测. 高电压技术, 46(9): 3089-3096) [DOI: 10.13336/j.1003-6520.hve.20190748]
- Heo B, Lee M, Yun S and Choi J Y. 2019. Knowledge distillation with adversarial samples supporting decision boundary [EB/OL]. [2021-02-01]. <https://arxiv.org/pdf/1805.05532.pdf>
- Hershey J R and Olsen P A. 2007. Approximating the Kullback Leibler divergence between Gaussian mixture models//Proceedings of 2007 IEEE International Conference on Acoustics, Speech, and Signal Processing-ICASSP'07. Honolulu, USA: IEEE: IV-317-IV-320 [DOI: 10.1109/ICASSP.2007.366913]
- Hinton G, Vinyals O and Dean J. 2015. Distilling the knowledge in a neural network [EB/OL]. [2021-02-01]. <https://arxiv.org/pdf/1503.02531.pdf>
- Jiang X C, Liu Y D, Fu X F, Xu P, Wang S J and Sheng G H. 2019. Construction ideas and development trends of transmission and distribution equipment of the ubiquitous power internet of things. High Voltage Engineering, 45(5): 1345-1351 (江秀臣, 刘亚东, 傅晓飞, 徐鹏, 王劭菁, 盛戈俾. 2019. 输配电设备泛在电力物联网建设思路与发展趋势. 高电压技术, 45(5): 1345-1351) [DOI:

- 10.13336/j.1003-6520.hve.20190505001]
- Li C H and Lee C K. 1993. Minimum cross entropy thresholding. *Pattern recognition*, 26(4): 617-625 [DOI: 10.1016/0031-3203(93)90115-D]
- Li X F, Liu H Y, Liu G H and Su H S. 2020. Transmission line pin defect detection based on deep learning [J/OL]. *Power System Technology*, [2020-11-04]. <https://doi.org/10.13335/j.1000-3673.pst.2020.1028> (李雪峰, 刘海莹, 刘高华, 苏寒松. 2020. 基于深度学习的输电线路销钉缺陷检测[J/OL]. *电网技术*, [2020-11-04]. <https://doi.org/10.13335/j.1000-3673.pst.2020.1028>) [DOI: 10.13335/j.1000-3673.pst.2020.1028]
- Ma D A, Tang P, Zhao L J and Zhang Z. 2021. Review of data augmentation for image in deep learning. *Journal of Image and Graphics*, 26(3): 487-502 (马崇昇, 唐婷, 赵理君, 张正. 2021. 深度学习图像数据增广方法研究综述. *中国图象图形学报*, 26(3): 487-502) [DOI: 10.11834/jig.200089]
- Park W, Kim D, Lu Y and Cho M. 2019. Relational knowledge distillation//*Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Long Beach, USA: IEEE: 3962-3971 [DOI: 10.1109/CVPR.2019.00409]
- Peng X Y, Chen C, Rao Z Q, Yang B S, Mai X M and Wang K. 2015. Safety inspection and intelligent diagnosis of transmission line based on unmanned helicopter of multi sensor data acquisition. *High Voltage Engineering*, 41(1): 159-166 (彭向阳, 陈驰, 饶章权, 杨必胜, 麦晓明, 王珂. 2015. 基于无人机多传感器数据采集的电力线路安全巡检及智能诊断. *高电压技术*, 41(1): 159-166) [DOI: 10.13336/j.1003-6520.hve.2015.01.022]
- Romero A, Ballas N, Kahou S E, Chassang A, Gatta C and Bengio Y. 2015. Fitnets: hints for thin deep nets [EB/OL]. [2021-02-01]. <https://arxiv.org/pdf/1412.6550.pdf>
- Tong W G, Yuan J S and Li B S. 2010. Application of image processing in patrol inspection of overhead transmission line by helicopter. *Power System Technology*, 34(12): 204-208 (仝卫国, 苑津莎, 李宝树. 2010. 图像处理技术在直升机巡检输电线路中的应用综述. *电网技术*, 34(12): 204-208) [DOI: 10.13335/j.1000-3673.pst.2010.12.032]
- Wang K, Wang J, Liu G, Zhou W Q and Chen J. 2019. Defect detection of pins based on RetinaNet and class balanced sampling methods. *Jiangsu Electrical Engineering*, 38(4): 80-85 (王凯, 王健, 刘刚, 周文青, 陈佳. 2019. 基于 RetinaNet 和类别平衡采样方法的销钉缺陷检测. *电力工程技术*, 38(4): 80-85) [DOI: 10.12158/j.2096-3203.2019.04.012]
- Wang W H, Wei F R, Dong L, Bao H B, Yang N and Zhou M. 2020. MiniLM: deep self-attention distillation for task-agnostic compression of pre-trained transformers [EB/OL]. [2021-02-01]. <https://arxiv.org/pdf/2002.10957v2.pdf>
- Xue Y, Wu H D, Zhang N, Yu Z C, Ye X K and Hua X. 2020. Detection of insulation piercing connectors and bolts on the transmission line using improved faster R-CNN. *Laser and Optoelectronics Progress*, 57(8): #081008 (薛阳, 吴海东, 张宁, 俞志程, 叶晓康, 华茜. 2020. 基于改进 Faster R-CNN 输电线路穿刺线夹及螺栓的检测. *激光与光电子学进展*, 57(8): #081008) [DOI: 10.3788/LOP57.081008]
- Ye H J, Lu S and Zhan D C. 2020. Distilling cross-task knowledge via relationship matching//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Seattle, USA: IEEE: 12393-12402 [DOI: 10.1109/CVPR42600.2020.01241]
- Zagoruyko S and Komodakis N. 2017. Paying more attention to attention: improving the performance of convolutional neural networks via attention transfer [EB/OL]. [2021-02-01] <https://arxiv.org/pdf/1612.03928.pdf>
- Zagoruyko S and Komodakis N. 2016. Wide residual networks//*Proceedings of the British Machine Vision Conference (BMVC)*. Bristol, UK: BMVA Press: 87.1-87.12 [DOI: 10.5244/C.30.87]
- Zhao Y Q, Rao Y, Dong S P and Zhang J Y. 2020. Survey on deep learning object detection. *Journal of Image and Graphics*, 25(4): 629-654 (赵永强, 饶元, 董世鹏, 张君毅. 2020. 深度学习目标检测方法综述. *中国图象图形学报*, 25(4): 629-654) [DOI: 10.11834/jig.190307]
- Zhao Z B, Qi H Y and Nie L Q. 2019. Research overview on visual detection of transmission lines based on deep learning. *Guangdong Electric Power*, 32(9): 11-23 (赵振兵, 齐鸿雨, 聂礼强. 2019. 基于深度学习的输电线路视觉检测研究综述. *广东电力*, 32(9): 11-23) [DOI: 10.3969/j.issn.1007-290X.2019.009.002]

## 作者简介



戚银城, 1968 年生, 男, 教授, 硕士生导师, 主要研究方向为电力信息分析与智能处理。  
E-mail: qiyech@ncepu.edu.cn



赵振兵, 通信作者, 男, 教授, 博士生导师, 主要研究方向为电力视觉检测。  
E-mail: zhaozhenbing@ncepu.edu.cn

金超熊, 男, 硕士研究生, 主要研究方向为知识蒸馏及电网智能巡检技术。E-mail: King11031@163.com

丁洁涛, 男, 硕士研究生, 主要研究方向为弱监督及电网智能巡检技术。E-mail: jietaoding@163.com

吕斌, 男, 高级工程师, 从事电力信息与通信方面的运维与管理工作。E-mail: lvbin\_csdl@163.com