

基于联邦学习的输电塔螺母销钉缺失检测^①



宋永康¹, 张俊岭², 公凡奎², 安云云³, 王冶⁴

¹(中国石油大学(华东) 计算机科学与技术学院, 青岛 266580)

²(山东鲁软数字科技有限公司, 济南 250001)

³(国网山东省电力公司 青岛市黄岛区供电公司, 青岛 266500)

⁴(解放军 9144 部队, 青岛 266102)

通信作者: 宋永康, E-mail: songyokn@s.upc.edu.cn

摘要: 输电塔上的螺母是连接两个或多个输电塔部件之间的媒介, 销钉是确保螺母不脱落的重要保障. 销钉缺失会使各部件之间的连接处存在安全隐患. 本文将联邦学习与目标检测算法结合起来, 在保证各地区数据不互通的情况下, 上传局部模型, 经过中心节点生成融合模型, 采用 Faster RCNN 检测算法对螺母进行检测, 同时用分类网络对螺母进行分类, 最终得出销钉是否缺失. 实验结果表明, 联邦学习融合后的模型比各局部模型在检测任务的 mAP 上提升 3%–6%, 在分类任务的准确率上提升 2%–3%.

关键词: 联邦学习; 深度学习; 目标检测; 输电塔; 销钉

引用格式: 宋永康, 张俊岭, 公凡奎, 安云云, 王冶. 基于联邦学习的输电塔螺母销钉缺失检测. 计算机系统应用, 2022, 31(5): 331-337. <http://www.c-s-a.org.cn/1003-3254/8479.html>

Detection of Pin Missing from Nuts of Transmission Tower Based on Federated Learning

SONG Yong-Kang¹, ZHANG Jun-Ling², GONG Fan-Kui², AN Yun-Yun³, WANG Ye⁴

¹(College of Computer Science and Technology, China University of Petroleum, Qingdao 266580, China)

²(Shandong Luneng Software Technology Co. Ltd., Jinan 250001, China)

³(Qingdao Huangdao District Power Supply Company, State Grid Shandong Electric Power Company, Qingdao 266500, China)

⁴(No. 9144 Troops of PLA, Qingdao 266102, China)

Abstract: The nut on the transmission tower is the medium connecting two or more transmission tower components, and the pin is an important guarantee to ensure that the nut does not fall off. The lack of pins will lead to potential safety hazards at the joints between various components. This study combines the federated learning and target detection algorithm to upload the local model and generate the fusion model through the central node without any data exchange among regions. The detection algorithm Faster RCNN and the classification network are used to detect and classify nuts, respectively. The experimental results show that compared with local models, the fusion model based on federated learning improves the mAP of detection tasks by 3%–6% and the accuracy of classification tasks by 2%–3%.

Key words: federated learning; deep learning; target detection; transmission tower; pin

电力系统对于国家安全有重要的意义, 而输电塔作为承载电力运输线路的载体, 输电铁塔是输电线路中最重要的基础设施之一, 起到支持高压或超高压架空输电线路中导线和避雷线的作用, 在整个电力系统

中有着不可替代的作用^[1]. 由于输电塔组成复杂, 存在许多类似于螺母的小部件, 传统的依靠人工巡检的巡检方式存在很大的弊端. 这种方式需要巡检人员近距离查看输电塔各部位, 并且由于人眼具有疲劳性的特

① 基金项目: 国家自然科学基金 (62072469); 国家重点研发计划 (2018YFE0116700); 山东省自然科学基金 (ZR2019MF049); 西海岸人工智能技术创新中心建设专项 (2019-1-5, 2019-1-6); 上海可信工业控制平台开放项目 (TICPSH202003015-ZC).

收稿时间: 2021-07-27; 修改时间: 2021-08-20, 2021-09-10; 采用时间: 2021-09-18; csa 在线出版时间: 2022-04-11

点,这种方式是不安全且效率不高的^[2]。由于输电塔一般建设在野外等人迹较少的地方,并且各个地区对于输电塔的巡检图像数据比较少,由于图像数据标注价值高,并且涉及到地区数据隐私问题,因此各地区不愿意分享本地数据。

在大多数情况下,数据是以孤岛的形式存在的,由于隐私安全、手续复杂等问题,即使是在同一个公司的不同部门之间,实现数据整合也面临着重重阻力,在现实中将分散在各地的数据进行整合几乎是不可能的,或者说耗费巨大。同时,数据隐私保护已经成为全世界关注的趋势,给人工智能技术发展带来巨大挑战。

传统数据处理方法是各方收集数据后,再汇集到一起进行处理、清洗并建模。但随着对隐私安全问题的重视,各项保护数据安全的法律法规也逐渐完善,如果数据离开收集方就可能会危害数据隐私从而出现隐私安全问题。

联邦学习是一种加密的分布式机器学习技术,参与的各方可以在不上传底层数据的前提下共建模型。它可以实现各个地方、各个企业的私有数据不出本地,而通过加密机制下的参数交换方式,使各个机构在不交换数据的情况下进行协作,从而提升机器学习的效果。

为了有效地解决巡检效率不高和数据隐私的问题,本文采用联邦学习与深度学习相结合的方法,利用深度学习处理无人机巡检图像^[3,4]来进行输电塔螺母销钉缺失检测,用联邦学习来保证数据隐私的问题,参与训练的各方不需要将私有数据上传到一处进行整合处理,用私有的数据各自训练,从而在保证数据隐私的情况下获得一个高质量的融合模型^[5],不仅有效的提高了数据质量,也极大地数据节约了整合成本。

1 引言

1.1 联邦学习

目前,数据安全问题已经成为热议的话题,自从 Facebook 数据泄露之后,重视数据隐私和安全已经成为了世界性的趋势。为了解决数据隐私和数据孤岛的问题,联邦学习变得越来越重要^[6]。2017年,谷歌首次引入了联邦学习系统,在数据保留在本地的情况下,多个参与者共同训练,该系统允许用户形成一个联合体训练得到一个集中模型,而用户数据则安全地存储在本本地,这就解决了数据隐私问题^[7]。香港科技大学杨强教授和微众银行(WeBank)进一步提出了联邦迁移学

习(federated transfer learning, FTL)^[8], FTL 将 FL 的概念加以推广,在不损害用户隐私的情况下进行知识共享,以实现在任何数据分布、任何实体上均可以进行协同建模、以学习全局模型。Konečný 等人通过修改神经网络和卷积神经网络,结合联邦学习在 MNIST 数据集上取得了优异的效果^[9]。Zhu 等人利用简单的卷积神经网络训练隐私场景的文字识别,利用 4 个卷积层和 2 个全连接层来训练,经过梯度计算和参数更新更新最终的联邦学习,最后联邦学习表现出优于基线模型的成绩^[10]。Zhang 等人将联邦学习与分类相结合,将多个分类算法融入到联邦学习,在检测 COVID-19 肺部医学数据方面取得了十分好的效果^[11]。

1.2 图像分类

作为计算机视觉领域的基础任务,图像分类是目标检测、语义分割的重要支撑,其目标是将不同的图像划分到不同的类别,并实现最小的分类误差^[12]。

传统的图像分类研究中,多数为基于图像特征的分类^[13],即根据不同类别图像的差异,利用图像处理算法提取经过定性或定量表达的特征,之后对这些特征进行数学方面的统计分析或使用分类器输出分类结果。传统的分类算法在特征提取方面,主要包括纹理、颜色、形状等底层视觉特征,尺度不变特征变换^[14]、局部二值模式^[15]、方向梯度直方图^[16]等局部不变性特征,这些人工设计特征缺乏良好的泛化性能,且依赖于设计者的先验知识和对分类任务的认知理解。目前,海量、高维的数据也使得人工设计特征的难度呈指数级增加。

深度学习^[17]相较于传统的图像分类方法,不需要对目标图像进行人工特征描述和提取,而是通过神经网络自主地从训练样本中学习特征,提取出更高维、抽象的特征,并且这些特征与分类器关系紧密,很好地解决了人工提取特征和分类器选择的难题。

1.3 目标检测

自从 Hinton 团队利用 AlexNet^[18]在 ImageNet^[19]取得成功之后, CNN 成为计算机视觉方向的重要工具。Girshick 等人首先将 CNN 应用于目标检测中,在区域候选的生成算法中,提出了选择性搜索(selective search)^[20]等经典算法,继而出现了 RCNN 的一系列变形: SPP Net^[21]、Fast RCNN^[22]、Faster RCNN^[23]。Fast RCNN 以及 Faster RCNN 的出现加快了 RCNN 用作目标检测的效率,同时 Faster RCNN 也是第一个能够端到端训练,并且速度近乎达到实时的检测器。2017年 Ren 等人^[23]

提出了 RPN, 生成多尺度区域, 结合 Faster RCNN 实现了当时最先进的结果. 目前 Faster RCNN 算法性能仍然十分出色, 目标检测虽然已经取得了相当大的成功, 但是仍然离不开大量数据的支持, 特别是大量已标注好的数据. 然而现实场景中数据往往存在数量少、标注难、数据涉及隐私的问题, 达不到实际需求. 数据十分珍贵.

2 基于联邦学习的螺母销钉缺失检测算法

本文提出的基于联邦学习的螺母销钉缺失检测算法的整体框架如图 1 所示, 各节点利用本地用于检测的训练数据训练基于 Faster RCNN 的目标检测模型, 每训练完成一轮, 会将训练好的本地模型上传到中心节点融合, 中心节点在收到所有的局部模型后进行模型融合处理, 形成新的融合模型再下发到各训练节点, 各训练节点收到融合模型后, 在融合模型的基础上继续下一轮的迭代训练. 最后中心节点得到一个基于 Faster RCNN 的融合模型. 再利用本地用于分类的训练数据训练基于 GoogLeNet^[24] 的分类模型, 上传中心节点进行融合, 最后中心节点得到一个基于 GoogLeNet 的融合模型. 将图像输入到 ResNet50^[25] 中, 生成特征图, 同时 RPN 结构会按照预设的比例生成 anchor 作为初始检测框, 在 RPN 层后链接一层全连接层来区分前景和背景并且对候选框进行修正. RPN 将生成的 anchor 投影到特征图上得到对应的特征矩阵, 将每个特征矩阵通过 ROI pooling 层缩放到统一的 7×7 大小展平, 最后通过全连接层预测检测结果, 将结果输入到分类融合模型中获得最终螺母分类结果.

2.1 联邦学习模型融合策略

在训练过程中, 不同机器的数据大小, 机器效能, 训练速度会有差异, 有的节点训练速度比较快, 有的节点训练速度比较慢. 目前普遍的方法有同步通信和异步通信, 在同步通信的方式中, 中心节点需要收到所有训练节点上传的模型后, 才能进行融合推动下一轮训练, 导致整个进程受集群里最慢的节点的影响. 在异步通信中, 每个节点完成本地训练之后就把局部模型推送到全局模型上去, 并继续本地的训练过程, 而不去等待其他的节点. 在本文中各节点本地数据设置的总数差距不是很大, 因此在本文中采用的是同步通信方式, 中心节点收到所有训练节点上传的本地模型经过融合后下发各训练节点继续下一轮训练. 在融合过程中, 采

用模型参数加权平均的方式进行模型参数融合, 就是将不同局部模型进行参数平均. 这种方式的训练过程如图 2 所示.

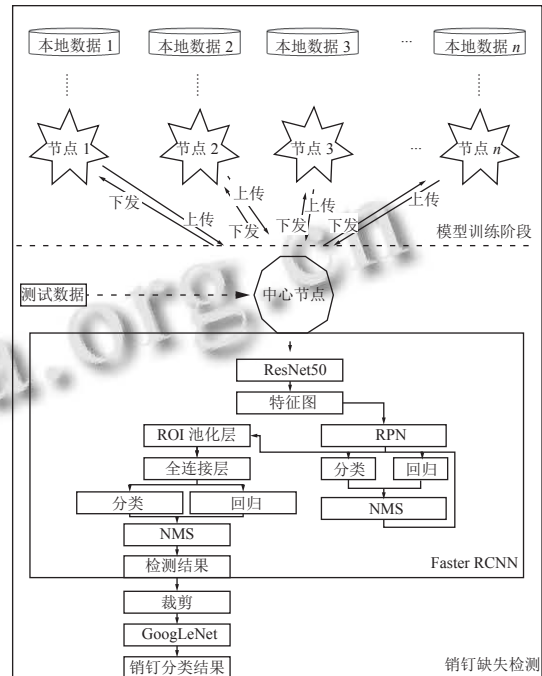


图 1 整体架构图




图 2 平均融合过程

2.2 特征提取网络设计

如图 3 所示, 本文采用 ResNet50 作为特征提取网络, 相对于原始的 VGG16 网络, ResNet50 用更多的网络层数来挖掘更深层的特征, 采用残差连接使得深度模型的训练比较容易, 克服由于网络深度加深而产生的学习效率变低与准确率无法有效提升的问题其中残差块如图 4 所示, 在残差网络单元中包含了跨层连接, 图中的曲线可以将输入直接跨层传递, 进行了同等映射, 之后与经过卷积操作的结果相加. 假设输入图像为 x , 输出为 $H(x)$, 中间经过卷积之后的输出为 $F(x)$ 的非线性函数, 那最终的输出为 $H(x) = F(x) + x$, 网络也就转

化为求残差函数 $F(x)=H(x)-x$, 这样残差函数要比 $F(x)=H(x)$ 更加容易优化. ResNet 包含 49 个卷积层和一个全连接层, 首先对输入数据进行卷积、正则化、激活函数和最大池化的计算, 之后包含 4 个残差块, 最后通过全连接层进行分类任务. 网络的输入为 $224 \times 224 \times 3$, 经过卷积计算, 输出为 $7 \times 7 \times 2048$, 池化层会将其转化成一个特征向量, 最后分类器会对这个特征向量进行计算并输出类别概率.




图3 ResNet50 网络结构




图4 残差块计算流程

2.3 RPN 候选区域大小及比例的设计

RPN 的目标是代替 selective search 实现候选框的提取, 而网络不可能自动生成任意大小的候选框, 因此 anchor 的主要意义就在于根据特征图在原图片上划分出很多大小、宽高比不相同的矩形框, RPN 会对这些框进行分类和回归, 经过微调后选取一些包含前景的类别框以及包含背景的负类别框, 送入之后的网络结构参与训练. 在原始的 RPN 网络中每个点的 anchor 存在 3 种规模以及 3 种比例, 因此原始 RPN 每个点会生成 9 个 anchor, 本实验中通过分析原始数据可以看出, 数据中的螺母面积占图像比例及其小, 不到百分之一, 并且拍摄角度有正面和侧面, 因此本实验中将 scale 设置为 4、8、16、32, anchor 的长宽比例设置为: 1:1, 1:2, 2:1, 即每个点拥有 12 个 anchor.

2.4 损失函数设计

Faster RCNN 包括两个损失: RPN 网络损失和 RCNN 网络损失, 每个损失又包括分类损失和回归损失, 所以需要定义一个多任务损失函数, 包括 Softmax classification loss 和 bounding box regression loss. 分类损失使用的是交叉熵, 回归损失使用的是 smooth L1 loss. 损失函数如式 (1) 定义:

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (1)$$

其中, i 为 anchor 的索引, p_i 为第 i 个 anchor 预测为目标概率, p_i^* 为 ground truth, $p_i^*=1$ 表示第 i 个候选框与 ground truth 之间的 $IoU>0.7$, 包含目标, 为正样本, $p_i^*=0$ 表示第 i 个候选框与 ground truth 之间的 $IoU<0.3$, 不包含目标, 为负样本, IoU 在 0.3 到 0.7 之间的 anchors 则忽略. $t_i = \{t_x, t_y, t_w, t_h\}$ 表示 bounding box 的 4 个参数, RPN 通过这 4 个参数对候选框进行修正. t_i^* 是与 positive anchor 对应的 ground truth 的 4 个坐标参数, λ 是回归 loss 的权重. N_{reg} 为 anchor 的数量. $L_{cls}(\cdot)$ 是交叉熵函数, 表达式为式 (2):

$$L_{cls}(p_i, p_i^*) = -\log[p_i^* p_i + (1 - p_i^*)(1 - p_i)] \quad (2)$$

$L_{reg}(\cdot)$ 为修正参数的损失函数, 表达式为式 (3):

$$L_{reg}(t_i, t_i^*) = \sum_{i \in \{x, y, w, h\}} smooth_{L1}(t_i - t_i^*) \quad (3)$$

其中, $smooth_{L1}(\cdot)$ 为式 (4) 所示:

$$smooth_{L1}(x) = \begin{cases} 0.5x^2, & |x| < 1 \\ |x| - 0.5, & |x| \geq 1 \end{cases} \quad (4)$$

t_x, t_y, t_w, t_h 计算如式 (5)–(8) 所示:

$$t_x = (x - x_a) / w_a \quad (5)$$

$$t_y = (y - y_a) / h_a \quad (6)$$

$$t_w = \log(w / w_a) \quad (7)$$

$$t_h = \log(h / h_a) \quad (8)$$

其中, x, y, w, h 是预测框中心的坐标和宽高, x_a, y_a, w_a, h_a 是 anchor 中心点的坐标和宽高.

$t_x^*, t_y^*, t_w^*, t_h^*$ 是真实标注框中心的坐标和宽高, 计算公式如式 (9)–(12) 所示:

$$t_x^* = (x^* - x_a) / w_a \quad (9)$$

$$t_y^* = (y^* - y_a) / h_a \quad (10)$$

$$t_w^* = \log(w^* / w_a) \quad (11)$$

$$t_h^* = \log(h^*/h_a) \quad (12)$$

3 实验分析

实验将各节点数据按 9:1 的比例进行划分, 将节点数据的 1/10 加入到整体测试集中用于模型评估, 剩下的部分作为节点训练集. 各节点使用本地区无人机采集到的数据进行训练, 每一轮训练完成后将本地模型参数发送给中心节点, 中心节点采用加权平均的融合策略, 将收到的模型融合后下发到各训练节点, 训练节点收到融合模型后继续在融合模型的基础上进行下一轮训练.

3.1 实验环境

本次实验采用 4 个训练节点和 1 个中心节点的配置. 环境配置如表 1 所示.

表 1 训练节点环境配置

节点	显卡类型	内存大小 (GB)
节点1	RTX3080	10
节点2	GTX1080	8
节点3	RTX3080	10
节点4	RTX3090	24
中心节点	RTX3090	24

3.2 实验数据

实验数据如图 5 所示, 分别在多个地方利用无人机拍摄输电塔数据, 经筛选共得到有效数据 1 236 张.



图 5 实验数据

每个节点经过裁剪得后本地螺母分类数据, 分为两类: 螺母有销钉和螺母无销钉. 数据如图 6 所示.

3.3 数据预处理

训练集规模对模型性能有明显的影响, 训练集数量越多, 训练出来的模型性能就越好. 因此本文通过图像缩放、图像旋转以及添加噪声来对数据集进行扩充. 从而提升模型的鲁棒性. 经过扩充后的各节点数据集如表 2 所示.

经过预处理后的图像如图 7 所示. 图 7(a) 为无人

机拍摄得到的原始数据与预处理后的数据, 图 7(b) 为裁剪后螺母原始数据与预处理后的数据. 其中第一行为原始数据, 第二行为预处理后数据, 使用的预处理技术有缩放操作、图像反转、高斯模糊.



图 6 螺母分类数据

表 2 预处理后各节点数据量

节点	检测数据量	扩充后	分类数据量	扩充后
节点1	250	1 250	450	2 250
节点2	223	1 115	422	2 110
节点3	186	930	398	1 990
节点4	477	2 385	502	2 510
中心节点	100	200	150	300



(a) 无人机数据



(b) 螺母数据

图 7 数据预处理结果

3.4 实验步骤

本实验首先通过检测任务对螺母进行检测, 将结果输入到分类网络中进行分类任务, 最终判断螺母上销钉是否存在. 根据实验的要求对各节点的本地训练集进行了人工标注和处理, 然后把训练集进行有限次的迭代训练, 在本文中将迭代次数设置为 20, 每迭代一次上传至中心节点进行模型融合后再下发至训练节点

进行下一轮迭代.最后在中心节点使用测试集在融合模型上进行测试,分析融合训练出的模型与各节点本地模型的性能对比.各节点使用相同的超参数设置,其中 $batchsize$ 为 16, $epoch$ 为 20, 初始学习率为 0.01, 学习率调整策略选择等间隔调整学习率的方法, 学习率衰减的 γ 值为 0.1.

3.5 实验结果与分析

在本实验中,我们对检测任务采用 mAP 指标进行评估 mAP 为各类别准确率和召回率曲线下的面积的平均值,在分类任务上采用准确率进行评估.

各节点局部模型与中心融合模型在迭代 20 次后的准确率曲线如图 8 所示:每个节点用各自的训练集进行训练,这些训练集各不相同,训练完成一轮后会上传到中心节点进行模型融合,因此融合后的模型是各训练节点模型参数的集合,所以融合模型具有比较不错的泛化性,在训练曲线中可以看出在训练 20 轮的过程中,在第 13 轮训练模型的准确率基本达到平稳.

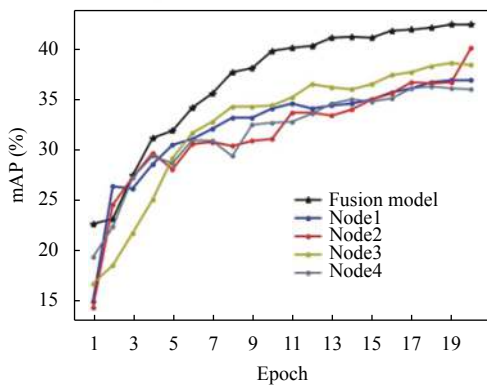


图 8 融合模型与局部模型检测性能对比

可以看出经过中心节点融合后的模型兼容性更好,因此对于测试集来说具有更高的 mAP . 由于没有对各节点进行数据非独立同分布划分,因此各节点数据集分布情况还是存在一定的相似性.

图 9 为各节点在训练过程中的损失收敛曲线.

分类任务的局部模型与融合模型在迭代 20 次后的准确率曲线如图 10 所示.

通过曲线可以看出融合模型相对于各节点局部模型准确率存在提升,约在 2%~4% 之间,由于本地数据与中心节点的数据比较相似,因此在准确率上的提升不明显.

融合模型与本地局部模型的准确率与召回率如表 3 所示.

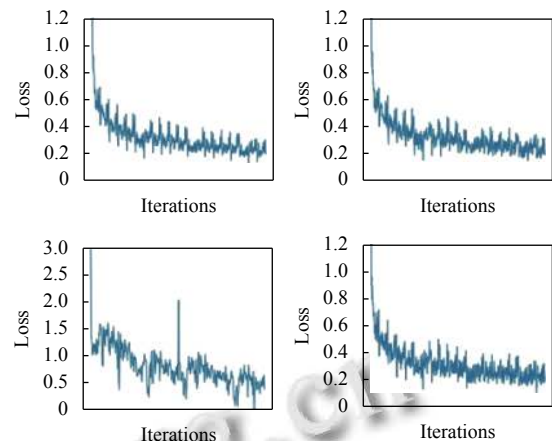


图 9 各节点损失函数收敛曲线




图 10 融合模型与局部模型分类性能对比

表 3 中心节点与训练节点模型准确率与召回率

节点	Precision	Recall
节点1	0.791	0.829
节点2	0.786	0.812
节点3	0.759	0.792
节点4	0.801	0.834
中心节点	0.824	0.851

4 结论与展望

本文将联邦学习与目标检测和图像分类任务相结合,在保证数据隐私的情况下进行同步训练,根据螺母销钉形状特点,重新设计 Faster RCNN 中 $anchor$ 比例,最后经过有限次的迭代训练与融合得到最优的融合模型.实验结果表明,融合模型相对于局部模型在检测和分类任务上均存在一定程度的提升,融合模型具有更好的兼容性,说明将联邦学习用于目标检测和分类任务是可行的,可以有效的解决数据隐私情况下的联合训练,得到一个兼容性更好,性能更高的模型.

在本文中,数据的相似性比较大,没有对本地数据进行非独立同分布设计,导致分类任务最后的提升效果不明显,因此在后续工作中会对数据进行非独立同分布设计,使各节点数据差异性较大,这样最后融合模型效果会比较明显,同时由于各节点数据较少,解下来会对数据进行扩充,通过数据增强的方式扩充实验数据。

参考文献

- 1 宋璇坤, 韩柳, 鞠黄培, 等. 中国智能电网技术发展实践综述. 电力建设, 2016, 37(7): 1-11. [doi: 10.3969/j.issn.1000-7229.2016.07.001]
- 2 彭向阳, 陈驰, 饶章权, 等. 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, 2015, 41(1): 159-166.
- 3 付昱玮, 李字明, 姜洪. 无人机巡线的发展和应研究. 黑龙江科技信息, 2014, (3): 25-27.
- 4 王万国, 张晶晶, 韩军, 等. 基于无人机图像的输电线路断股与异物缺陷检测方法. 计算机应用, 2015, 35(8): 2404-2408. [doi: 10.11772/j.issn.1001-9081.2015.08.2404]
- 5 杨强. AI 与数据隐私保护: 联邦学习的破解之道. 信息安全研究, 2019, 5(11): 961-965. [doi: 10.3969/j.issn.2096-1057.2019.11.003]
- 6 王健宗, 孔令炜, 黄章成, 等. 联邦学习算法综述. 大数据, 2020, 6(6): 64-82.
- 7 McMahan B, Moore E, Ramage D, *et al.* Communication-efficient learning of deep networks from decentralized data. Proceedings of the 20th International Conference on Artificial Intelligence and Statistics. Fort Lauderdale: PMLR, 2017. 1273-1282.
- 8 Liu Y, Kang Y, Xing CP, *et al.* Secure federated transfer learning. arxiv: 1812.03337, 2018.
- 9 Konečný J, McMahan HB, Yu FX, *et al.* Federated learning: Strategies for improving communication efficiency. arXiv: 1610.05492, 2016.
- 10 Zhu XH, Wang JZ, Hong ZH, *et al.* Federated learning of unsegmented Chinese text recognition model. Proceedings of the 2019 IEEE 31st International Conference on Tools with Artificial Intelligence. Portland: IEEE, 2019. 1341-1345.
- 11 Zhang WS, Zhou T, Lu QH, *et al.* Dynamic fusion based federated learning for COVID-19 detection. arXiv: 2009.10401, 2020.
- 12 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述. 计算机学报, 2017, 40(6): 1229-1251. [doi: 10.11897/SP.J.1016.2017.01229]
- 13 黄凯奇, 任伟强, 谭铁牛. 图像物体分类与检测算法综述. 计算机学报, 2014, 37(6): 1225-1240.
- 14 曾接贤, 余永龙. 双边滤波与暗通道结合的图像保边去雾算法. 中国图象图形学报, 2017, 22(2): 147-153. [doi: 10.11834/jig.20170201]
- 15 Ye HM, Yan SL, Huang PL. 2D Otsu image segmentation based on cellular genetic algorithm. Proceedings of the 2017 IEEE 9th International Conference on Communication Software and Networks. Guangzhou: IEEE, 2017. 1313-1316.
- 16 Cha YJ, You K, Choi W. Vision-based detection of loosened bolts using the Hough transform and support vector machines. Automation in Construction, 2016, 71: 181-188. [doi: 10.1016/j.autcon.2016.06.008]
- 17 张军阳, 王慧丽, 郭阳, 等. 深度学习相关研究综述. 计算机应用研究, 2018, 35(7): 1921-1928, 1936. [doi: 10.3969/j.issn.1001-3695.2018.07.001]
- 18 Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. Proceedings of the 26th Annual Conference on Neural Information Processing Systems 2012. Lake Tahoe: NIPS, 2012. 1106-1114.
- 19 Deng J, Dong W, Socher R, *et al.* ImageNet: A large-scale hierarchical image database. Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami: IEEE, 2009. 248-255.
- 20 Girshick RB, Donahue J, Darrell T, Malik J. Rich feature hierarchies for accurate object detection and semantic segmentation. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Columbus: IEEE, 2014. 580-587.
- 21 Purkait P, Zhao C, Zach C. SPP-Net: Deep absolute pose regression with synthetic views. arXiv: 1712.03452, 2017.
- 22 Qian RQ, Liu QY, Yue Y, *et al.* Road surface traffic sign detection with hybrid region proposal and fast R-CNN. Proceedings of the 2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery. Changsha: IEEE, 2016. 555-559.
- 23 Ren S, He K, Girshick R, *et al.* Faster R-CNN: Towards real-time object detection with region proposal networks. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- 24 Szegedy C, Liu W, Jia YQ, *et al.* Going deeper with convolutions. Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE, 2015. 1-9.
- 25 He KM, Zhang XY, Ren SQ, *et al.* Deep residual learning for image recognition. Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016. 770-778.