

基于双视卷积神经网络的输电线路自动巡检

戴永东¹, 王茂飞¹, 唐达熨¹, 尼 啦², 毛 锋¹, 仲 坚¹, 倪 莎³

(1. 国网泰州供电公司, 江苏 泰州 225300; 2. 国网拉萨供电公司城区供电服务中心, 西藏 拉萨 850000;
3. 众芯汉创(北京)科技有限公司, 北京 100089)

摘 要:卷积神经网络算法被广泛应用于输电线路自动巡检领域,但传统卷积神经网络电力缺陷识别模型的泛化能力较差。为此,提出一种融合双角度图像信息的卷积神经网络检测算法(CVR-RCNN),其利用2个视角可见光图像识别输电线路的常见缺陷。经实验测试,CVR-RCNN模型具有良好的鲁棒性,受试者工作特性(ROC)曲线下面积(AUC)值高达0.927,缺陷检测准确度较传统算法有显著提高。因此,CVR-RCNN能明显改善电力缺陷检测效果,可为无人机自动巡检输电线路提高准确稳定的算法架构。

关 键 词:无人机巡检;输电线路缺陷;深度学习;卷积神经网络

DOI:10.19781/j.issn.1673-9140.2021.05.025 中图分类号:TM712 文章编号:1673-9140(2021)05-0201-10

Research on automatic inspection of transmission line based on cross-view convolution neural network

DAI Yongdong¹, WANG Maofei¹, TANG Daa¹, NI La², MAO Feng¹, ZHONG Jian¹, NI Sha³

(1. Taizhou Electric Power Company of State Grid, Taizhou 225300, China; 2. Urban Power Supply Service Center of State Grid Lhasa Power Supply Company, Lhasa 850000, China; 3. Allcorehattrass (Beijing) Technology Co., Ltd., Beijing 100089, China)

Abstract: The convolutional neural network algorithm is widely applied in the automatic inspection of transmission lines. However, the generalization ability of traditional convolutional neural network power defect-recognition model is not ideal. Under the background, this paper proposes a cross-view relation region convolutional neural network (CVR-RCNN) detection algorithm that integrates dual-angle image information, which utilizes two-view visible light images to identify typical defects in transmission lines. The testing shows that the CVR-RCNN model has good robustness. The area under curve (AUC) value of the receiver operating characteristic (ROC) curve is as high as 0.927, and the defect detection accuracy is significantly improved compared with traditional algorithms. Therefore, CVR-RCNN can significantly improve power defect detection and improve the accuracy and stability of the algorithm architecture for the automatic inspection of transmission lines by UAVs.

Key words: Unmanned aerial vehicle inspection; transmission line defects; deep learning; convolutional neural networks

随着全球能源短缺问题日趋严重,现阶段正处于能源转型变革的关键时期,世界各国均面临着前所未有的机遇和挑战。美国经济学家 Jeremy Rifkin 在《第3次工业革命》中首次提出能源互联概念,并迅速受到国内外学者的广泛关注。以能源互联网为核心的第3次工业革命将会给经济发展模式和人类生活方式带来巨大影响,2020年中国全球能源互联网研究院指出,能源互联网以电力能源为基础,其建设必将为电网技术和作业模式带来巨大的变革^[1]。能源互联网促进了全球电力电网产业的蓬勃发展,同时也给输电线路巡检作业带来了诸多挑战。传统人工输电线路巡检难度大、环境差、效率低,而且在恶劣环境和复杂地形条件下作业时,难以保障巡检人员的人身安全^[2]。因此,利用现代人工智能新技术解决传统电力系统中存在的问题已成为国内外研究的热点^[3-9]。

国外研发无人巡线检测技术,主要集中在以下几个领域:自动图像采集、续航方向以及避障巡航等,同时针对检查机器人装置展开对应的分析与实验。在高压输电线路图像数据的处理方面,目前国内研究较少,对问题线路的图像识别还在使用 Hog 特征+SVM 算法^[10]、DPM 算法等传统方法。国外多对高压输电线路的绝缘子、防震锤、垫片和悬挂夹等组件进行相关目标识别研究与分析,对架空高压输电线路导线的破损以及异物的研究相对较少。由此能够预测无人检测技术会由设备硬件的检测分析过渡至数据后处理分析层面,其中图像数据后处理是其关键的检测技术。文献^[11]基于多传感器数据融合技术开发出一套无人机电力线路安全性巡检系统,检测内容包括安全距离、设备过热和异常放电。系统可同步采集高精度三维激光点云、高分辨率空拍图像、红/紫外视频等多模态数据并对其进行独立或融合分析,最终实现对不同输电线路缺陷或潜在隐患的准确分类;文献^[12]应用深度学习算法和图像处理技术实现了多种恶劣复杂环境下电力设备的风险预警,其预测精度较高,为智能评估输电线路中存在的风险和缺陷提供理论和实践基础。

初期的输电线路缺陷自动巡检研究主要集中于图像处理技术和传统机器学习。首先利用灰度增

强、边缘检测和区域分割等图像后处理方法确定出感兴趣区域;然后提取输电线路感兴趣区的图像特征,包括统计特征、纹理特征和形态特征等;最后应用统计机器学习方法构建关于输电线路缺陷的分类模型。此种缺陷巡检方式结构简单、容易实现、计算量小,但算法模型泛化能力弱易受环境影响。近年来,随着深度学习算法的兴起和应用,基于深度学习的输电线路缺陷自动巡检方法成为热点研究^[13-17]。人工神经网络是深度学习的核心算法,深度神经网络由多个隐含层构成,可一次性训练大量数据,并自动筛选出模型有用特征,实践证明此算法训练出的模型准确度高且泛化能力强。该文在传统卷积神经网络的基础上,引入一种融合双角度图像信息的卷积神经网络检测算法(cross-view relation region convolutional neural network, CVR-RCNN)^[18],与传统方法相比,可利用2个方位的图像信息,准确高效地检出输电线路的常见缺陷并进行分类,为电力设施无人机自动巡检提供科学的理论依据和实践证明。

1 基于深度卷积神经网络的输电线路缺陷检测方法研究

通用航空技术在电力设施巡检领域的快速兴起,尤其是无人机巡检设备的逐步完善,使广覆盖、高效率、低成本的输电线路缺陷自动检测的实现成为可能。该文提出的基于深度卷积神经网络的输电线路缺陷检测系统框架如图1所示,系统主要由无人机巡检设备、地面工作站、图像预处理和卷积神经网络缺陷检测模块组成,无人机操作人员将输电线路图像实时传送至地面工作站,图像预处理后输入卷积神经网络模型,通过计算后系统会自动输出存在缺陷的线路图像。

在该文提出的输电线路缺陷检测系统中,深度学习算法设计是其核心部分。常用深度学习算法包含卷积神经网络、自动编码器和深信度网络等,其中卷积神经网络在目标检测研究中应用最为成功,它由输入、卷积、池化、全连接和输出5个层所组成,以反向传播算法(误差逆传播算法)为基础迭代更新网络参数,简单的反向传播网络如图2所示。

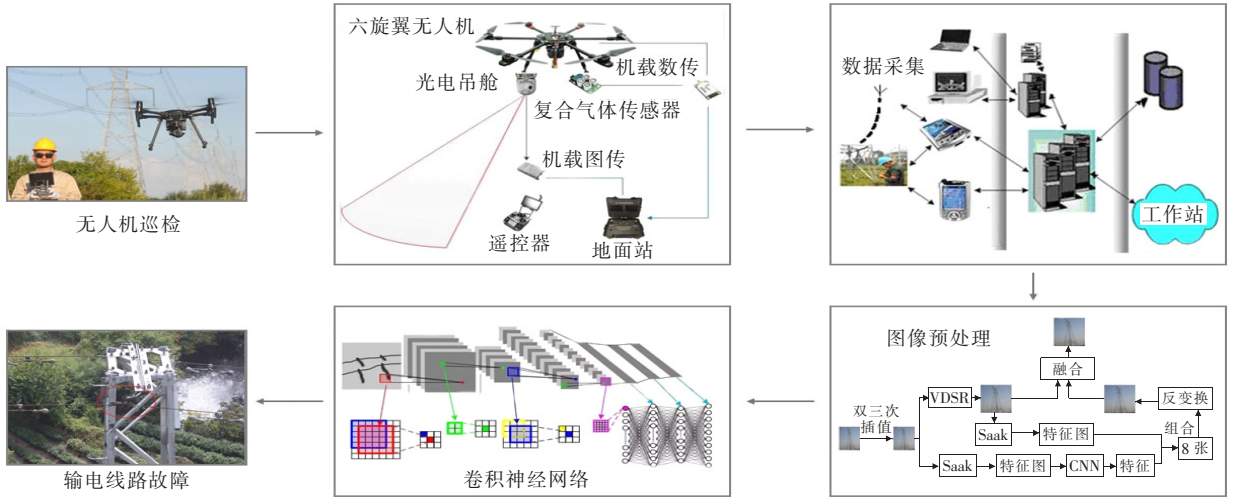


图 1 输电线路缺陷检测系统框架

Figure 1 Frame diagram of transmission line defect detection system




图 2 反向传播算法

Figure 2 Schematic diagram of back propagation algorithm

设在反向传播算法过程中训练集样本为

$$U = \{(x_1, y_1), (x_2, y_2), \dots, (x_k, y_k)\} \quad (1)$$

若输入特征向量包含有 d 个属性,输出向量为 l 维,则记 $x_i \in R^d, y_i \in R^l, d, q, l$ 分别为输入层、隐藏层和输出层的神经元数量。另外,输入层神经元 i 和隐藏层神经元 h 的连接权重记为 v_{ih} ,同理隐藏层神经元 h 和输出层神经元 j 的连接权重记为 ω_{hj} ,隐藏层神经元 h 的输出记为 b_h 。反向传播算法如下。

- 1) 输入训练样本,设置学习率。
- 2) 参数初始化到 $(0, 1)$ 范围内。
- 3) $(x_k, y_k) \in U$ 做如下操作。在当前参数下计算输出值为

$$\hat{y}_k = f(\beta - \theta) \quad (2)$$

利用链式求导法则计算输出层梯度项和隐藏层梯度项为

$$g_j = \frac{\partial E_k}{\partial \hat{y}_j^k} \cdot \frac{\partial \hat{y}_j^k}{\partial \beta_j} \quad (3)$$

$$e_h = \frac{\partial E_k}{\partial b_h} \cdot \frac{\partial b_h}{\partial \alpha_h} \quad (4)$$

其中, $E_k = \frac{1}{2} \sum_{j=1}^l (\hat{y}_j^k - y_j^k)^2$

更新权值为

$$\begin{cases} \Delta \omega_{hj} = -\eta g_j b_h \\ \Delta v_{ih} = -\eta e_h x_i \end{cases} \quad (5)$$

式中 η 为学习率; v_{ih} 和 γ_h 为隐藏层的权值。偏置为

$$\begin{cases} \Delta \theta_j = \eta g_j \\ \gamma_h = \eta e_h \end{cases} \quad (6)$$

式中 v_{ih} 和 γ_h 为隐藏层偏置。

4) 重复步骤 3 直到网络参数收敛。

5) 最后输出训练后的卷积神经网络模型。

训练后卷积神经网络模型的测试性能主要取决于深度网络的架构和训练集样本质量。该文设计的卷积神经网络模型通过主流的深度学习训练框架 TensorFlow 完成数据处理和模型训练的集成和优化,实现端到端的训练生态链。此外,由于研究初期输电线路缺陷样本数量有限,为达到深度神经网络模型训练时所需的样本数量级,从而获得更具泛化能力的神经网络模型,该研究对输电线路图像进行旋转、移位、镜像、倾斜等变换以充分扩展训练样本量。

2 基于双视卷积神经网络的输电线路缺陷分类方法研究

常见输电线路的典型缺陷包括线路断裂、开关

跳闸、设备腐化等多种类型,输电线路自动检测系统抓拍到疑似点后仍然很难判定其缺陷类型,传统人工智能图像分类模型仅利用某一个角度的图像信息,导致模型无法准确判别输电线路缺陷种类。为此该论文创新性地提出一种双视图关系区域卷积神经网络(cross-view relation region convolutional neural network, CVR-RCNN),用于输电线路典型缺陷的自动分类。CVR-RCNN 算法通过 2 个环节进行缺陷分类,以充分增强分类模型的鲁棒性,CVR-RCNN 整体框架中包含 2 个 Faster R-CNN,从 2 个不同无人机视角图像中分别对输电线路同一位置的缺陷进行分类。该文提出的双视角卷积神经网络算法与单一视角算法相比能获取更全面的缺陷信息,CVR-RCNN 融合双视角输电线路图像的相互关系,可准确判别线路缺陷的类型。为实现 2 个视角的图像信息得到充分融合和优势互补,在 CVR-RCNN 网络分类环节处设计了一个双视图关系模块(cross-view relation block, CVR),以对 2 个视图所抓拍缺陷之间的关系进行建模。

2.1 双视图关系区域卷积神经网络

CVR-RCNN 算法设计结构如图 3 所示,输电线路缺陷分类模型构建如下步骤,①输入 2 个视角的输电线路图像;②输电线路图像分别送入卷积网络层,卷积网络层将计算提取图像的特征生成特征图,特征图被区域提取网络(region proposal networks, RPN)及分类网络所共享,区域提取网络 RPN 则根据特征图预测得到候选感兴趣区域(region of interest, ROI),并将筛选后的 ROI 特征图

池化为标准尺寸;③ CVR-RCNN 算法最后一步是分类和位置回归网络,其功能是实现候选 ROI 的分类和位置回归分析,该算法的分类结果以激活函数 Softmax 的形式输出,当分类输出结果为背景时选 ROI 中无输电线路缺陷,反之当分类输出结果为非背景时选 ROI 中有输电线路缺陷。在执行步骤 3 时,2 路缺陷分类模块全连接层的输出均被关联到 CVR, CVR 对这 2 个视图里 ROI 间的关系进行建模,输出某一视图里每个候选 ROI 相对另一视图全部候选 ROI 的关系特征值,以此使分类模型能够融合 2 个角度输电线路缺陷的图像信息。

Faster R-CNN 是 CVR-RCNN 架构的核心算法,通过 2 路 FasterR-CNN 各自对输电线路进行缺陷分类。CVR-RCNN 框架前置部分的 RPN 网络和 ROIpooling 网络彼此独立,不进行信息间的融合。而 CVR-RCNN 框架后置分类网络将 2 路 FasterR-CNN 全连接层的输出连接在一起,通过 CVR 对来自双角度图像的候选 ROI 关系进行建模,由此实现输电线路缺陷判别时双角度图像的信息交融和优势互补。其中, CVR 输入信息是同一位置不同角度输电线路候选 ROI 的图像和几何特征, CVR 输出信息是某一角度图像每个 ROI 与另一角度图像全部 ROI 的对应关系值,此关系值融合 CVR-RCNN 缺陷分类框架的图像特征,以增强双路网络的缺陷分类性能,是 CVR 提高 CVR-RCNN 算法准确度的理论基础。该文在设计 CVR 模块时引入了 Relation Networks 关系模块^[19]中可简单插入其它分类模型的功能,因此在训练 CVR-RCNN 分类模




图 3 CVR-RCNN 缺陷分类算法架构

Figure 3 CVR-RCNN defect classification algorithm architecture

型时不需额外的监督数据,减少了训练模型时样本的人工标记任务。为更全面地融合来自双角度图像的输电线路缺陷信息,CVR-RCNN 架构中可插入多个 CVR 模块。

2.2 双视图关系模块的原理与思路

CVR 模块的设计思路如图 4 所示,其功能是建立 CVR-RCNN 架构中双角度的图像关系,目标是使双角度的图像信息实现充分融合和优势互补,以提高 CVR-RCNN 分类模型的准确度和鲁棒性。

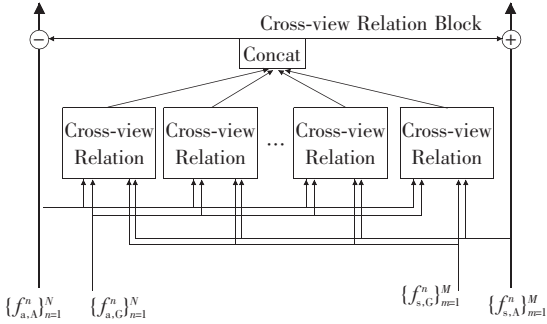


图 4 双视图关系模块设计思路

Figure 4 Design idea of cross-view relation module

假设来自无人机的双角度输电线路图像分别记为 I_a 和 I_s ,即 I_a 和 I_s 是 CVR-RCNN 算法 2 路缺陷分类分支的输入信号。每个角度图像由 RPN 选择出输电线路缺陷候选 ROI 后经 ROI Pooling 操作,输出的图像特征记为 f_A ,几何特征记为 f_G 。图像特征 f_A 为 CVR-RCNN 分类网络全连接层的特征向量,几何特征 f_G 为输电线路缺陷 ROI 几何位置的编码特征四元组 (x, y, w, h) ,其中 (x, y) 对应 ROI 处于整体图像的左上角坐标, (w, h) 为 ROI 的高和宽。由候选 ROI 的 f_A 和 f_G 特征,CVR 可建立出双视图关系特征,记为 f_R 。

若在输电线路图像 I_a 中共分类出 N 个候选缺陷 $\{(f_{a,A}^n, f_{a,G}^n)\}_{n=1}^N$,在输电线路图像 I_s 中共分类出 M 个候选缺陷 $\{(f_{s,A}^m, f_{s,G}^m)\}_{m=1}^M$,那么加权 I_s 全部候选缺陷的关系值可计算出 I_a 第 n 个候选缺陷的关系特征,即

$$f_{a,R}^n = \sum_{m=1}^M \omega^{mn} \cdot (W_V \cdot f_{s,A}^m) \quad (7)$$

式中 ω^{mn} 为图像 I_a 第 n 个候选输电线路缺陷与图像 I_s 第 m 个候选输电线路缺陷的关系值; W_V 为

$f_{s,A}^m$ 的简写线性变换矩阵,其作用是对图像 I_s 第 m 个候选输电线路缺陷的图像特征进行空间变换。由于双视图关系建模需同时考虑 ROI 的图像特征和几何特征,为此使用 Softmax 函数归一化图像 I_a 第 n 个候选输电线路缺陷和图像 I_s 第 m 个候选输电线路缺陷的关系值总和,实现图像特征和几何特征的关系融合。 ω^{mn} 的计算形式为

$$\omega^{mn} = \frac{\tau_{a,G}^{mn} \times \exp(\tau_{a,A}^{mn})}{\sum_k \tau_{a,G}^{kn} \times \exp(\tau_{a,A}^{kn})} \quad (8)$$

式中 $\tau_{a,G}^{mn}$ 为候选 ROI 几何特征关系值; $\tau_{a,A}^{mn}$ 为候选 ROI 图像特征关系值,几何特征关系值 $\tau_{a,G}^{mn}$ 由 ReLU 函数所得,图像特征关系值由放缩点积操作所得,其计算形式分别为

$$\tau_{a,A}^{mn} = \frac{\text{dot}(W_K \times f_{a,A}^n, W_Q \times f_{s,A}^m)}{\sqrt{d}} \quad (9)$$

$$\tau_{a,G}^{mn} = \text{ReLU}(W_G \times (f_{a,G}^n, f_{s,G}^m)) \quad (10)$$

式(9)、(11)中 W_K 、 W_Q 均为线性变换矩阵,表示双视图 ROI 的图像特征线性变换,通过变化后新图像特征空间更有利于双视图 ROI 的关系建模,变换后的空间维度记为 d ,由于卷积神经网络参数过大易出现梯度爆炸现象,而向量 X 、 Y 的相似度则是通过 cosine 函数的点积操作 $\text{dot}(X, Y)$ 来衡量,会引起网络训练参数过大,因此 $\tau_{a,A}^{mn}$ 在计算时将点积操作除以 \sqrt{d} 来降低卷积神经网络训练难度; W_G 为线性变换矩阵,表示双视图 ROI 编码后几何特征的线性变换,通过变化后新几何特征空间更有利于双视图 ROI 的关系建模。根据文献[20],该文对双候选缺陷 ROI 进行如下几何特征编码。

1)为消除几何特征和绝对空间位置的关系且保持几何特征的平移缩放不变性,编码双视图候选缺陷 ROI 的几何特征为四维相对几何特征。图像 I_a 第 n 个候选输电线路缺陷的几何特征编码为

$$f_{a,G}^n = (x_a^n, y_a^n, w_a^n, h_a^n) \quad (11)$$

图像 I_s 第 m 个候选输电线路缺陷的几何特征编码为

$$f_{s,G}^m = (x_s^m, y_s^m, w_s^m, h_s^m) \quad (12)$$

编码完成后的四元组为

$$\mathbf{E}_{nc_a^{mn}} = \left(\log \frac{|x_a^n - x_s^n|}{\omega_s^m}, \log \frac{|y_a^n - y_s^n|}{h_s^m}, \log \frac{\omega_a^n}{\omega_s^m}, \log \frac{h_a^n}{h_s^m} \right) \quad (13)$$

2) 通过 Vaswani 位置编码^[20]提升几何特征编码表示能力,其做法是利用频率相异的 sine 和 cosine 函数映射低维编码空间到高维编码空间,将高维编码空间的维度记为 d_{model} ,因此几何特征空间由 4 维上升到 $4 \times d_{\text{model}}$ 维。向量 $\mathbf{E}_{nc_a^{mn}}$ 第 Pos 维的低维空间编码后高维空间中第 $2i$ 维,其偶数维用 sine 函数计算,即

$$\mathbf{E}_{a,p}^{(Pos,2i)} = \sin \left(\frac{\mathbf{E}_{nc_a^{mn}} [Pos]}{1\ 000^{2i/d_{\text{model}}}} \right) \quad (14)$$

式中 Pos 为向量 $\mathbf{E}_{nc_a^{mn}}$ 的第 Pos 维索引; $\mathbf{E}_{nc_a^{mn}} [Pos]$ 为其索引值; i 为映射后高维空间的第 i 维。 $\mathbf{E}_{nc_a^{mn}}$ 第 Pos 维的低维空间编码后高维空间中第 $2i$ 维,其奇数维用 cosine 函数计算,即

$$\mathbf{E}_{a,p}^{(Pos,2i+1)} = \cos \left(\frac{\mathbf{E}_{nc_a^{mn}} [Pos]}{1\ 000^{2i/d_{\text{model}}}} \right) \quad (15)$$

由上述公式 CVR 模块可计算出表示 I_a 第 n 个候选缺陷和 I_s 全部候选缺陷关系的特征 $f_{a,R}^n$,同样可计算出表示 I_s 第 m 个候选缺陷和 I_a 全部候选缺陷关系的特征 $f_{s,R}^m$ 。 $f_{a,R}^n$ 和 $f_{s,R}^m$ 两特征通过元素加和方法叠加到 CVR-RCNN 网络上,实现 CVR-RCNN 网络 2 路分支中候选输电线路缺陷图像信息的互融,提高模型分类输电线路缺陷的性能。具体表示为

$$f_{a,A}^n = f_{a,R}^n + f_{a,A}^n \quad (16)$$

$$f_{s,A}^m = f_{s,R}^m + f_{s,A}^m \quad (17)$$

最后为进一步提高 CVR-RCNN 网络的鲁棒性,扩展 CVR 模块计算候选缺陷 ROI 关系值时所适应的特征空间维度,采用多头结构同步计算出 N_r 个关系值,将其叠加起来后和 CVR-RCNN 网络按元素加和,即

$$f_{a,A}^n = f_{a,A}^n + C_{\text{oncat}} [f_{a,R}^{n,1}, f_{a,R}^{n,2}, \dots, f_{a,R}^{n,N_r}]$$

$$f_{s,A}^m = f_{s,A}^m + C_{\text{oncat}} [f_{s,R}^{m,1}, f_{s,R}^{m,2}, \dots, f_{s,R}^{m,N_r}] \quad (18)$$

式中 $C_{\text{oncat}} [*]$ 为关系特征的叠加操作,此操作与元素加和不同。元素加和时张量维度保持不变,

而 $C_{\text{oncat}} [*]$ 操作实际是张量的合并,会改变张量维度。

3 深度卷积神经网络输电线路缺陷识别模型的效果评估

3.1 深度卷积神经网络缺陷检测模型的效果评估

无人机选用大疆 M300 RTK、精灵 4RTK 开展巡检作业,无人机巡检系统的具体参数如表 1 所示。为保证输入网络的双视角图像对应于同一目标,2 架无人机同时同地沿待巡检设备两侧起飞、同步飞行,由同一系统控制曝光,2 相机拍摄视角互相垂直。根据拍摄时刻标记图像,以确保输入网络的双视角图像对应于同一目标,如图 5 所示。

表 1 无人机巡检系统参数

Table 1 UAV inspection system parameters

| 主要参数 | 参数值 |
|--------|---|
| 镜头兼容性 | M4/3 卡口 |
| 传感器尺寸 | 1/1.7" CMOS |
| 有效像素 | 约 2 000 万像素 |
| 外形尺寸 | 150×114×151 mm |
| 重量 | 约 680 g |
| 其它性能 | 参数值 |
| 相机参数 | 广角:1/2.3" CMOS,有效像素 1 200 万 变焦:混合光学变焦 23x 最大变焦:200x |
| 图像分辨率 | 变焦:5 184×3 888 广角:4 056×3 040 |
| 曝光模式 | 程序自动曝光,手动曝光,快门优先曝光,光圈优先曝光 |
| 测光模式 | 中央偏重点测光,点测光(点测光区域可选 12×8) |
| 电子快门速度 | 1—1/8 000 s |
| 白平衡 | 自动(AWB),晴天,阴天,白炽灯, 日光灯,手动白平衡(2 000~10 000 K) |
| ISO 范围 | 100~25 600(视频) 100~25 600(照片) |
| 抗闪烁 | 自动,50 Hz,60 Hz |
| 角度抖动量 | ±0.01° |
| 安装方式 | 可拆式 |
| 可控转动范围 | 俯仰: +40°~ -130°; 平移: ±320°; 横滚: ±20° |
| 结构设计范围 | 俯仰: +50°~ -140°; 平移: ±330°, 横滚: +90°~ -50° |
| 最大控制转速 | 俯仰: 180°/s; 平移: 270°/s; 横滚: 180°/s |




图 5 2 架无人机同步巡检

Figure 5 Synchronous inspection for two UAVs

每个卷积神经网络共有 3 层卷积层,第 1 层包含 28 个卷积核,卷积核的尺寸为 21×21 ,以间隔为 1 的方式进行滑窗,采用 ReLU 激活函数;第 2 层包含 32 个卷积核,卷积核的尺寸为 11×11 ,以间隔为 1 的方式进行滑窗,采用 ReLU 激活函数;第 3 层包含 56 个卷积核,卷积核的尺寸为 7×7 ,以间隔为 1 的方式进行滑窗,采用 ReLU 激活函数。有 3 层池化层,采用间隔为 2 的方式进行最大值池化,最后一层池化层和 211 个神经元进行全连接,最后和一层 10 个的神经元进行全连接,输出概率识别矩阵。当卷积神经网络在开始训练前,每层权值参数采用方差为 0.01、均值为 0 的小数值高斯随机方式进行初始化。实验共计使用了 5 000 个案例训练深度卷积神经网络缺陷检测模型,其中包含输电线路缺陷样本 2 048 例。另外 3 000 个样本用于测试缺陷检测模型的效果,其中包含输电线路缺陷样本 1 254 例。训练过程每个 Epoch 对应的损失及预测准确度如图 6 所示,当迭代 20 个 Epochs 之后基本保持稳定。




图 6 损失与准确度变化曲线

Figure 6 Loss and accuracy variation curve

该文通过精确度 (Precision)、灵敏度 (sensitivity, S_N)、 F_1 值以及假阳与真阳比 (F_{PI} 值) 4 项指标对检测模型的效果进行了评估。精确度为模型检测正确的比例,即

$$P_{\text{recision}} = \frac{T_P}{T_P + F_P} \quad (19)$$

式中 T_P 为真实缺陷样本中模型检测为缺陷样本的比例; F_P 为非缺陷样本中模型检测为缺陷样本的比例。

灵敏度为真正缺陷样例中检测正确的比例,即

$$S_N = T_{PR} = \frac{T_P}{T_P + F_N} \quad (20)$$

式中 F_N 为缺陷样本中模型检测为非缺陷样本的比例。

衡量精确度和灵敏度的关系为

$$F_1 = \frac{2 \times P_{\text{recision}} \times S_N}{P_{\text{recision}} + S_N} \quad (21)$$

模型检测出假阳个数和真阳个数的比例为

$$F_{PI} = \frac{F_P}{T_P} \quad (22)$$

F_{PI} 值越小,表示所检测出来的输电线路缺陷假阳率越低。在深度卷积神经网络缺陷检测模型测试实验中,所用 3 000 个测试样本的评估结果如图 7 所示。




图 7 卷积神经网络缺陷检测模型测试结果

Figure 7 Test results of defect detection model based on convolution neural network

3.2 双视卷积神经网络缺陷分类模型的效果评估

实验共计使用 2 048 个缺陷案例训练双视卷积神经网络缺陷分类模型,其中包含线路断裂缺陷 623 例、开关跳闸 518 例、设备腐化 773 例、其他缺

陷 134 例。另外 1254 缺陷样本用于测试缺陷分类模型的效果,其中断裂缺陷 262 例、开关跳闸 481 例、设备腐化 274 例、其它缺陷 237 例。输电线路缺陷判别是一个多分类问题,该文采用 one-vs-rest 的策略构建多分类模型,其做法是训练模型时依次把某类缺陷归为一类样本,其余缺陷归为另一类样本,从而使 4 种类型的输电线路缺陷共构建出 4 个二分类模型,即多分类模型的实质是 4 个二分类模型的组合。

该文选用受试者工作特性(receiver operating characteristic, ROC)曲线的面积(region under curve, AUC)值作为二分类模型的评价指标。受试者工作特性曲线的横坐标为假阳性率,也即 $1 - \text{特异性}$;受试者工作特性曲线的纵坐标为真阳性率,也即灵敏度。坐标值越靠近坐标系的左上角表明分类模型的灵敏度和特异性越高。因此受试者工作特性曲线的面积 AUC 值可综合评估分类模型,AUC 越大表明模型分类效果越好。为评估双视卷积神经网络模型对 4 种缺陷的综合分类能力,引入了加权平均,即

$$\bar{A}_{UC} = \frac{\sum_{i=1}^4 N_i A_{UC-i}}{\sum_{i=1}^4 N_i} \quad (23)$$

式中 N_i 为缺陷种类 i 的样本个数; A_{UC-i} 为模型分类该种缺陷的 AUC 值。该实验中双视卷积神经网络缺陷分类模型的测试集 $\bar{A}_{UC} = 0.914$ 。根据交叉验证实验,双视卷积神经网络、传统单视卷积神经网络(single vision-convolutional neural network, SV-CNN)、随机森林(random forest, RF)、支持向量机(support vector machine, SVM)和罗杰斯特回归(logistic regression, LR)模型的 \bar{A}_{UC} 如图 8 所示。由图 8 可知,CVR-ECNN 算法与 SV-CNN 算法相比 \bar{A}_{UC} 有显著提高,这表明双视角图像包含互补的输电线路故障信息,利用双视卷积神经网络可提高输电线路故障的检出率。

为减轻模型的过拟合,测试样本采用留一交叉验证法评估模型性能,即模型验证时每次循环仅留下 1 个样本做测试集,其余样本做训练集。交叉验证可在有限数据中获取尽可能多的样本信息,预测模型对新数据的表现,评估模型的泛化能力。




图 8 输电线路缺陷检测模型测试的 ROC 曲线
Figure 8 ROC curves of transmission line defect detection model test

为进一步验证双视卷积神经网络模型的显著优势,2 种算法间 \bar{A}_{UC} 的比较采用统计学 bootstrap 策略,测试样本和模型输出值均进行 N 次自举重采样,计算每个模型对应的 N 个 AUC 值,用统计学配对 T 检验算法定量评估 2 组 AUC 值的差异,若假设检验 P 值小于 0.05 则表明两模型的分分类效果具有显著统计学差异。该文所用模型的输电线路缺陷分类效果比较如表 3 所示。

3 组输电线路销钉缺失图例如图 9 所示,红框内为缺陷位置,数字代表分类模型判断为此类缺陷的输出概率。

表 3 模型分类效果的统计检验 P 值

Table 3 Statistical test P value of model classification effect

| 算法 | CVR-RCNN | SV-CNN | RF | SVM | LR |
|----------|----------|---------|---------|---------|----|
| CVR-RCNN | — | — | — | — | — |
| SV-CNN | 0.008 ↑ | — | — | — | — |
| RF | 0.041 ↑ | 0.033 ↑ | — | — | — |
| SVM | 0.022 ↑ | 0.045 ↑ | 0.061 ↓ | — | — |
| LR | 0.018 ↑ | 0.001 | 0.041 ↑ | 0.026 ↑ | — |

注: ↑ 指表格横向所列算法优于纵向所列算法; ↓ 指表格横向所列算法差于纵向所列算法。




图 9 双视角图像故障图像示例

Figure 9 Example of fault image for cross-view image

4 结语

面对全球能源互联背景下繁重的输电线路巡检任务,该文提出的深度卷积神经网络算法是输电线路缺陷自动巡检的有效手段,经实验证明其缺陷检测模型具有很好的准确性和鲁棒性。此系统最大优点是可综合分析输电线路故障的两面特征,实现了双侧图像中故障信息的优势互补。另外,当一侧图像未出现或出现不明显故障点时,CVR-RCNN 算法仍可通过对侧图像进行故障识别。在仅需单次飞行以缩短巡检时间、增加巡检效率的前提下,此巡检模式极大地提高了故障检出率。总之,在无人机输电线路自动巡检系统中载入基于深度卷积神经网络的缺陷分析平台,可提高无人机巡检作业的效率 and 精度,在一定程度上减少了输电线路巡检作业的工作量,有助于早日实现复杂环境下电力设施巡检的全程自动化。

参考文献:

- [1] 张化冰. 能源互联网支撑能源转型—访国家电网全球能源互联网研究院院长、中国工程院院士汤广福[J]. 电力设备管理, 2020, 5(2): 25-28.
ZHANG Huabing. Energy internet supports energy transformation—an interview with Tang Guangfu, President of State Grid global energy Internet Research Institute and academician of Chinese Academy of engineering [J]. Power Equipment Management, 2020, 5(2): 25-28.
- [2] 郑武略, 张富春, 焦炯, 等. 多旋翼无人机在输电线路巡

- 检中的应用[J]. 中国电机(技术版), 2016, 7(4): 70-73.
ZHENG Wuliu, ZHANG Fuchun, JIAO Jiong, et al. Application of multi rotor UAV in transmission line inspection[J]. China Electric Power (Technical Edition), 2016, 7(4): 70-73.
- [3] 李经野, 宋坤宇. 基于雷击故障辨识的 110 kV 输电线路故障巡检策略[J]. 电力科学与技术学报, 2019, 34(2): 175-181.
LI Jingye, SONG Kunyu. Fault patrol strategy for 110 kV transmission line based on the lightning fault identification[J]. Journal of Electric Power Science and Technology, 2019, 34(2): 175-181.
- [4] Patricia L, Jon M, Guillermo M, et al. Low cost photonic sensor for in-line oil quality monitoring: methodological development process towards uncertainty mitigation[J]. Sensors, 2018, 18(7): 1-37.
- [5] Ye X, Wu G, Fei F, et al. Overhead ground wire detection by fusion global and local features and supervised learning method for a cable inspection robot[J]. Sensor Review, 2018, 38(3): 376-386.
- [6] Wu Y, Zhao G, Hu J, et al. Overhead transmission line parameter reconstruction for UAV inspection based on tunneling magnetoresistive sensors and inverse models [J]. IEEE Transactions on Power Delivery, 2019, 34(3): 819-827.
- [7] Fan F, Wu G P, Wang M, et al. Robot delay-tolerant sensor network for overhead transmission line monitoring[J]. Applied Sciences, 2018, 8(6): 847-875.
- [8] 杨可军, 杨建旭, 陈思宝, 等. 基于深度可分离卷积及 SVD 输电线路缺陷检测[J]. 智慧电力, 2020, 48(10): 64-69+77.

- YANG Kejun, YANG Jianxu, CHEN Sibao, et al. Methods of defect detection in transmission line based on depthwise separable convolution and SVD[J]. Smart Power, 2020, 48(10): 64-69+77.
- [9] 赖秋频, 杨军, 谭本东, 等. 基于 YOLOv2 网络的绝缘子自动识别与缺陷诊断模型[J]. 中国电力, 2019, 52(7): 31-39.
- LAI Qiupin, YANG Jun, TAN Bendong, et al. An automatic recognition and defect diagnosis model of transmission line insulator based on YOLOv2 network[J]. Electric Power, 2019, 52(7): 31-39.
- [10] 朱梓倩, 刘蓉, 付瑜, 等. 基于振动云图 HOG 和 SVM 的变压器绕组松动故障诊断方法[J]. 高压电器, 2019, 55(11): 227-231+238.
- ZHU Ziqian, LIU Rong, FU Yu, et al. Diagnostic method for transformer winding looseness based on HOG of vibration cloud picture and SVM[J]. High Voltage Apparatus, 2019, 55(11): 227-231+238.
- [11] 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[J]. 高电压技术, 2015, 41(1): 159-166.
- PENG Xiangyang, CHEN Chi, RAO Zhangquan, et al. Power line safety inspection and intelligent diagnosis based on UAV multi-sensor data acquisition[J]. High voltage technology, 2015, 41(1): 159-166.
- [12] Chen L Q, Tang H C, Xiao X H, et al. Research on risk warning and recognition of transmission line based on deep learning[J]. Power Systems and Big Data, 2018, 21(12): 1-5.
- [13] 杨知, 欧文浩, 费香泽, 等. 基于高分辨率 SAR 影像和深度学习的输电杆塔智能识别研究[J]. 电测与仪表, 2019, 57(4): 71-77.
- YANG Zhi, OWen Hao, Fei xiangze, et al. Intelligent identification of transmission towers based on high resolution SAR images and deep learning[J]. Electrical measurement and instrumentation, 2019, 57(4): 71-77.
- [14] 邵宝珠, 李胜辉, 白雪, 等. 非负约束自动编码器在电缆早期故障识别中的应用[J]. 电力系统保护与控制, 2019, 47(2): 16-23.
- SHAO Baozhu, LI Shenghui, BAI Xue, et al. Application of nonnegative constraint autoencoder in cable incipient fault identification[J]. Power System Protection and Control, 2019, 47(2): 16-23.
- [15] 杨启洪, 秦川, 刘杰荣, 等. 基于对比歧化和深度置信网络的配电网故障类型识别[J]. 电网与清洁能源, 2019, 35(2): 52-57.
- YANG Qihong, QIN Chuan, LIU Jierong, et al. Fault identification of distribution network based on contrast disproportionate algorithm and deep belief network[J]. Power System and Clean Energy, 2019, 35(2): 52-57.
- [16] 汪颖, 孙建风, 肖先勇, 等. 基于优化卷积神经网络的电缆早期故障分类识别[J]. 电力系统保护与控制, 2020, 48(7): 10-18.
- WANG Ying, SUN Jianfeng, XIAO Xianyong, et al. Cable incipient fault classification and identification based on optimized convolution neural network[J]. Power System Protection and Control, 2020, 48(7): 10-18.
- [17] 罗步升, 林志超, 何小龙. 基于拓扑解析与深度学习融合的低压集抄系统故障诊断方法[J]. 电测与仪表, 2019, 56(20): 145-152.
- LUO Busheng, LIN Zhichao, HE Xiaolong. Fault diagnosis method for low-voltage centralized meter reading system based on topology analysis and deep learning[J]. Electrical Measurement & Instrumentation, 2019, 56(20): 145-152.
- [18] Ma J, Liang S, Li X, et al. Cross-view relation networks for mammogram mass detection[C]//2020 25th International Conference on Pattern Recognition (ICPR), Milan, Italy: IEEE, 2020.
- [19] HU H, Gu J Y, Zhang Z, et al. Relation networks for object detection[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA: IEEE, 2018.
- [20] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//The 31st Annual Conference on Neural Information Processing Systems, Long Beach, USA, 2017.