

DOI: 10.13382/j.jemi.B2104280

基于 GAF-CNN 的弓网电弧识别方法研究^{*}

李 斌 阎君宇

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘 要:由于高速铁路接触网会产生弓网电弧对弓网系统有危害,为了减少弓网损害。提出一种电流时间序列编码技术,即格拉姆角求和/差分场(GASF / GADF)。由于不同受流状态的电流信号不同,其时间序列编码形成的图像也不同,这使得计算机视觉技术可以用于时间序列分类,用来识别弓网电弧。共进行了 5 组不同条件下的弓网受流实验,测量得到不同条件下弓网系统中的电流数据,并将弓网实验得到的电流数据的状态分为正常受流状态和电弧受流状态。通过构建神经网络,提取电弧电流信号,以格拉姆角场(GAF)图像的形式直观展示了卷积神经网络(CNN)对弓网电弧数据的抽象特征提取情况。实验结果表明,该方法可在不同条件下准确识别弓网电弧避免视频图像背景变化的问题为弓网电弧故障识别提供一种思路。

关键词: 滑动电接触;图像编码;格拉姆角场;卷积神经网络

中图分类号: TM501 **文献标识码:** A **国家标准学科分类代码:** 470.4027

Research on recognition method of pantograph arc based on GAF-CNN

Li Bin Yan Junyu

(Faulty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: Since the catenary of high-speed railway will produce pantograph arc, it is harmful to pantograph system, in order to reduce pantograph damage. A current time series coding technology, namely, the Gram angle summation/differential field (GASF/GADF) is proposed. Because the current signals of different current receiving states are different, the images formed by their time series coding are also different, which makes computer vision technology can be used for time series classification to identify pantograph arcs. A total of five groups of pantograph receiving experiments were carried out under different conditions to measure the current data in pantograph system under different conditions, and the current data obtained from pantograph experiments were divided into normal receiving state and arc receiving state. By constructing a neural network and extracting the arc current signal, it visually demonstrates the abstract feature extraction of the CNN from the arch-net arc data in the form of a Gram angle field (GAF) image. The experimental results show that the method in this paper can accurately identify pantograph and network arcs under different conditions, avoiding the problem of video image background changes, and provides an idea for pantograph and network arc fault identification.

Keywords: sliding electrical contact; image coding; Gram angle field; convolutional neural network

0 引 言

随着国民经济的快速发展高速电气化铁路的建设发展进程的也在不断推进。弓网关系对列车的运行效率和从业人员的安全有着直接影响。电弓与悬链线间电弧放电过度频繁,导致机车的运行受到极大干扰,也一定程度

的影响到列车运行稳定性,以及面临更大的安全风险。弓网电弧是无法预测的,而且也难以避免,因而对弓网电弧的有效、快速识别,对调控弓网电弧^[1]、提升受流效率有着深刻意义。韩伟峰等^[2]基于磁流体动力学建立弓网电弧模型,通过流体力学软件计算了静态弓网电弧的温度分布特征。Mariscotti 等^[3]研究了弓网电弧的电磁辐射的时频域特性并给出功率谱和频率含量。其他学者研

究了电弧的实时检测和诊断,在图像处理技术越加先进的有力支撑下,许多研究人员将精力投入到受电弓弧的非接触式图像检测上。Karakose 等^[4]提出了一种通过受电弓和悬链线接触点的实际视频捕获和图像处理来分析电弧故障的方法。将阈值方法应用于由 SDRAM 和检测到的电弧构成的图像矩阵。张婷等^[5]按照半周期截取电流时间序列,进行归一化处理,将灰度矩阵变换生成二维图像;通过神经网络进行故障电弧检测。郭凤仪等^[6]采用局部二值模式(LBP)描述图像矩阵的局部纹理特征,通过最大相关系数的数据库匹配准则检测电弧。Aydin 等^[7]检测受电弓和悬链接触线之间的接触点,通过边缘检测算法确定接触线的位置来检测电弧。Huang 等^[8]提出了一种基于多类型视频的受电弓电弧检测的融合方法。在可见光图像中,使用卷积神经网络(CNN)对电弧进行检测,以及识别特征,并应用阈值方法识别红外图像中的电弧。

上面提到的方法都适用于干扰因素相对较少的图像,至于更复杂的图像,它们通常在提取无关区域的同时丢弃有价值的特征。为了避免以上不足,可采用基于回路电流电压信号特征^[9-10]的检测方法。本文采用一种新的2D图像编码手段,即格拉姆角场(GAF)时间序列编码方式,分别将弓网系统正常受流和故障受流电流信号转换成不同的图像,结合卷积神经网络对其进行学习和识别,达到较高的识别精度。

1 实验装置

本实验采用自主研发的受电弓的电磁噪声实验系统^[11]进行实验。该系统由消声室、受电弓产生器和受电弓检测系统组成。具体实物如图1所示。




图1 滑动电接触磨损实验机实物图

Fig.1 Physical image of sliding electrical contact abrasion test machine

由转盘、滑台和滑板组成弓网电弧发生装置,接触线嵌入转盘。滑板水平移动同时转盘旋转,改进受电弓设备的离线控制模块来模拟受电弓电弧放电。该模块可

以设置参数,调整设备的压力,滑动速度和接触电流,以模拟列车的运行状态,并生成正常电流接收和故障电流接收的两种状态。受电弓电弧检测系统可实现对回路电流、接触电压、旋转速度、横向移动速度、接触温度和电弧图像的自动采集、存储和信号分析功能。将测量数据通过采集卡传输到上位计算机后,通过 LabVIEW 软件对电气和机械参数进行实时监控和记录。接触网导线为横截面 120 mm² 的纯铜材料,滑板为浸铜碳滑板。表1为20℃时浸铜碳板和纯铜接触线的物理参数。

表1 滑板和接触导线物理参数

Table 1 Slide and contact wire physical parameters

参数	浸铜碳滑板	接触网导线
密度/($\times 10^3 \text{ kg} \cdot \text{m}^{-3}$)	3.4	8.9
电阻率/($\mu\Omega \cdot \text{m}$)	12.32	0.017 5
热导 λ /($\text{W} \cdot \text{m}^{-1} \cdot \text{K}^{-1}$)	15	380
比热/($\text{J} \cdot \text{kg}^{-1} \cdot \text{K}^{-1}$)	660.2	380

2 实验现象及理论分析

2.1 实验方案

在表1给出的实验条件下,以5组弓网系统为样本,进行受流特性实验。实验设定负载采用功率电阻负载,滑台以0.25 m/s作往复运动,每组运行时间为5 min。以10 kHz的频率,数据采集卡进行采样,实时采集各项实验数据,如接触压力、接触电压等。实验条件如表2所示。

表2 实验条件

Table 2 Experimental Conditions

组别	接触压力/N	滑动速度/($\text{km} \cdot \text{h}^{-1}$)	接触电流/A
1	70	30	50
2	70	50	50
3	70	110	50
4	30	110	50
5	70	110	150

经以上5组实验,获得了5组受电弓在不同条件下的电流数据,在第1组实验条件下获得的原始电流波形如图2所示。因正常电流信号波形存在着高频噪声,为使得电流信号采样更加的真实,以及确保分析更加准确,对获得的原始电流波形数据,作滤波去噪^[12]处理。选取第5组的实验条件下的回路电流信号进行滤波,通过python-opencv设计二阶巴特沃斯低通滤波器,消除了采集的原始电流波形数据上的高频噪声。进行去噪处理后,获得的电流波形如图3所示,其中图3(a)为去噪后的电压波形,图3(b)为电流波形,图3(c)为脉冲。进行实验时,将电流实验中的电流数据波形分为两种状态:电弧受流状态、正常受流状态。当产生故障电弧时,回路电

流中的电流波形将失真,并且该电流波形将处于短的零休止状态。在图 3 中第 2 行“平肩”的部分是带有受电弓故障的电弧,而具有受电弓弧形的部分可以通过此功能与电流波形区分开。




图 2 原始弓网电流波形

Fig. 2 Original pantograph catenary current waveform




图 3 高频去噪后的受电弓电流波形

Fig. 3 Current waveform of pantograph after high frequency denoising

2.2 时间序列编码

本文首先介绍将时间序列编码为图像的框架。GAF 图像^[13-15],其中用极坐标系而不是典型的笛卡尔直角坐标系来表示时间序列。转换缩放的时间序列为极坐标系后,通过考虑每个点之间的三角和来识别不同时间间隔内的时间相关性,GAF 定义如下:

$$\mathbf{G} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cdots & \cos(\phi_2 + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} = \begin{bmatrix} \tilde{\mathbf{X}}' \cdot \tilde{\mathbf{X}} - \sqrt{\mathbf{I} - \tilde{\mathbf{X}}'^2} \cdot \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2} \end{bmatrix} \quad (1)$$

即单位行向量 $[1, 1, \dots, 1]$ 。转换为极坐标系后,将每个时间步的时间序列作为一维度量空间,通过定义内积 $\langle x, y \rangle$ 来表示。 $\mathbf{G}$ 是一个 Gramian 矩阵。

$$\begin{bmatrix} \langle \tilde{x}_1, \tilde{x}_1 \rangle & \cdots & \langle \tilde{x}_1, \tilde{x}_n \rangle \\ \langle \tilde{x}_2, \tilde{x}_1 \rangle & \cdots & \langle \tilde{x}_2, \tilde{x}_n \rangle \\ \vdots & \ddots & \vdots \\ \langle \tilde{x}_n, \tilde{x}_1 \rangle & \cdots & \langle \tilde{x}_n, \tilde{x}_n \rangle \end{bmatrix} \quad (2)$$

在 Gramian 矩阵中,每个元素实际上都是角度求和的余弦。

$$\tilde{x}_{i-1} = \frac{(x_i - \max(\mathbf{X}) + (x_i - \min(\mathbf{X})))}{\max(\mathbf{X}) - \min(\mathbf{X})} \quad (3)$$

$$\text{or } \tilde{x}_0 = \frac{x_i - \min(\mathbf{X})}{\max(\mathbf{X}) - \min(\mathbf{X})}$$

因此,可以通过以下公式将值编码为角余弦,将时间戳编码为半径,来表示重新定标的时间序列 $\mathbf{X}$ 的极坐标。

$$\begin{cases} \phi = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{\mathbf{X}} \\ r = \frac{t_i}{N}, t_i \in N \end{cases} \quad (4)$$

此种基于极坐标的表达形式,是一种对时间序列加以认识的方法。随着时间的增加,对应值会在跨度圆上的不同角点之间弯曲,通过上述变换可将原始时间序列转换为特征图,由于特征图像蕴含时间序列相关信息,因此也可利用特征图对时间序列进行重构,GAF 分为格拉姆求和角场 (GASF) 和格拉姆差分角场 (GADF) 两种图像,由不同的方程生成,GASF 和 GADF 定义如下:

$$\begin{aligned} \text{GASF} &= [\cos(\phi_i + \phi_j)] = \\ \tilde{\mathbf{X}}' \cdot \tilde{\mathbf{X}} - \sqrt{\mathbf{I} - \tilde{\mathbf{X}}'^2} \cdot \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2} \\ \text{GADF} &= [\sin(\phi_i - \phi_j)] = \\ \sqrt{\mathbf{I} - \tilde{\mathbf{X}}'^2} \cdot \tilde{\mathbf{X}} - \tilde{\mathbf{X}}' \cdot \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2} \end{aligned} \quad (5)$$

式中: $\mathbf{I}$ 为单位行向量 $[1, 1, \dots, 1]$; $\tilde{\mathbf{X}}'$ 为 $\tilde{\mathbf{X}}$ 的转置向量,从上面的方程式注意到,GAF 为新构建的运算,而该形式对应于常规内积的惩罚形式。GAF 有几个优点。首先,它提供了一种保留时间依赖性的方法,因为时间随着位置从左上角移动到右下角而增加。能够从深度神经网络学习的高级功能中近似重建时间序列。由于 1 D-CNN 分类效果不佳,为了充分利用目前深度学习在计算机视觉上的优势,选择 GAF 将一维的时间序列转换成二维的图片信号以便于利用卷积神经网络对图像进行分类。对采集的电流信号进行 GAF 图像编码,具体如图 4 所示。在时域波形中存在两个较为明显的波峰,在波形初始振幅较大,当出现第 1 个波峰时在 GADF 与 GASF 特征图呈现出交叉特征,而峰值较大的部分呈现的特征更为明显。因此,在二维图像中,可以通过 GADF 与 GASF 中相应位置的颜色、点、线等不同特征对电流信号进行完整映射。




图4 Gramian 角场编码图的示意图

Fig. 4 Schematic diagram of Gramian angle field coding diagram

3 利用 CNN 识别弓网电弧

作为前馈的分层神经网络,用 CNN 识别图片的主要步骤为卷积层进行卷积计算提取特征,池化层也叫采样层,可减少冗余特征,全连接层汇总各部分特征,充当分类器来进行数据特征的分类。

在卷积层中,对卷积核输入图像进行设定,并做卷积计算,利用 relu 激活函数进行图像的纹理特征提取。卷积核当做一个滤波器,拿二维卷积而言,卷积的操作只是在整个图像上过滤出于卷积核相似或相同的位置,卷积层提取抽象程度更高的特征会增加节点矩阵的深度,计算公式为:

$$x_{kl}^{out} = f(\sum_{i \in M_{kl}} x_i^{in} \times w_{ki} + b_{kl}) \quad (6)$$

在卷积层之间,一般会加入池化层,如此能够缩小矩阵尺寸,从而使得全连接层的参数更小。换句话说,进行池化的主要目的是为了降维。池化,仅以滤波器的尺寸为考量对象;对映射区域内的像素点,取最大值,或者是均值;本文采用最大值池化,在前向过程中,对区域池化后的值,选用最大值;在后向过程中,经前向过程,梯度的最大值反向传播,其他位置具有为 0 的梯度,优点是可实现对图像的纹理结构与边缘的学习。

$$x_m^{out} = \max(x_m^{in} \otimes \sigma_m) \quad (7)$$

在卷积神经网络中,全连接层发挥着“分类器”的作用。卷积层、池化层等作用于特征提取与选择;全连接层,是把学习的特征映射到标记空间,也就是整合各项特征,方便交给最后的分类器。

将 CNN 卷积神经网络和胶囊网络分别提取的特征融合,一方面能够保留电弧电流信号的全局特征,另一方面通过提取胶囊形式的节点特征,利用路由机制在图像中捕获重要的位置和方向信息,而对于不同方向的图片, CNN 模型很容易辨认不明。由于胶囊网络需要较少的训练数据并提供等变映射能够较好地保存对象的位置和姿态信息,在保证时间序列与时间相关性的前提下采用胶囊网络进行特征提取,可较好地保存弓网电弧电流信号的时序信息,路由树还映射目标的部分的层次结构,但

也意味着会保留低频噪声。CNN 由于池化层可能损失一部分特征信息,同时也过滤了低频噪声,保留了重要的突出特征。因此,通过结合卷积神经网络与胶囊网络各自的优点进行卷积特征融合,本文的网络结构如图 5 所示。




图5 网络结构框图

Fig. 5 Network structure block diagram

本文分路 1 采用“卷积-卷积-最大池化-卷积-最大池化-卷积-全连接层”结构的模型,分路 2 由胶囊网络的初级胶囊层和高级胶囊层组成,高级胶囊层的大小为 5×16 ,对应不同时间序列的类别数及相应的不同状态。通过卷积特征融合的方式把两个分路的深层特征相结合,后经过全连接层和 Softmax 层输出最终分类结果。

使用 RMSProp 优化算法训练 CNN。按元素平方,对截止时间 t 步所有小批量随机梯度 gt 进行指数加权移动平均,随时间动态调整,计算量小,不需要手动调整学习速率。依照实验结果,选取正常受流,电弧受流样本各 100 000 组,其中各 80 000 组样本作为训练集,剩下 20 000 组样本数据作为测试样本。利用 GAF 编码方式在时间序列上映射的唯一性,对电流信号进行编码,产生特征明显的故障特征图,之后再结合 CNN 对两种故障特征图进行分类,正常状态和故障状态的时域对比如图 6 所示,对应特征图如图 7、8 所示。




图6 正常状态和故障状态的时域对比

Fig. 6 Time domain comparison diagram of normal state and fault state

由图 6~8 可知,正常受流时电流为正弦波,由于波峰波谷的存在个别区域颜色明显区别于其他区域,而发生故障电弧时电流很小,整体颜色较为统一。与相应的电流波形相对应,正常受流和发生故障电弧时的 GAF 图像有显著区别,利用 CNN 网络来进行受流状态识别。GAF-CNN 故障诊断方法如下:1)对所采集的电流信号按




图 7 正常受流时的 GAF 图
Fig. 7 GAF diagram of normal current collection




图 8 发生故障电弧时的 GAF 图
Fig. 8 GAF diagram of fault arc

照 GADF 或 GASF 编码方式转换为 2D 图像,并划分训练集与测试集;2) 将 GASF 和 GADF 图像分别输入搭建好的模型并进行参数调优^[15],运用 RMSProp 自适应提取图片特征中的相关信息,获取故障电弧和正常受流的信息;3) 运用 Softmax 分类器,识别故障电弧,流程如图 9 所示。

4 神经网络参数及结构优化

为了探究网络参数、不同网络层以及不同诊断方法对故障诊断模型的影响,设置一系列不同的参数值来研究模型的最优组合。模型运行的软件环境为 pycharm,用 1.13 版本 tensorflow-cpu 构建 CNN 网络,生成的图片用来训练和测试 CNN 网络。硬件环境为 AMD R5 处理器。文中神经网络使用 relu 激活函数,图片尺寸为 28×28, 28×28=784,选取 784 个数据形成一个训练样本。其中 epochs=20, batch-size=40, 选取第一组实验工况进行训练,准确率 acc=1.00。




图 9 弓网电弧识别整体流程
Fig. 9 Overall flow of pantograph arc recognition

5 实验结果与分析

5.1 GAF-CNN 算法识别结果

通过格拉姆角场方法将电流信号转化为二维图像后,以融合卷积神经网络为工具,实现自动分类,对模型的有效性,在测试集上进行验证。在模型中,损失函数非常重要,能够对模型的好坏进行预估。损失值越小,模型越好。

图 10、11 所示为在第 1 组试验工况下的准确率和损失率曲线。5 组不同条件的识别精度如表 3 所示,可以看出,在受电弓实验中,如果滑动速度、接触压力等发生变动,识别精度会受到影响。而且,从识别结果来看, GASF 图像识别效果优于 GADF 图像,5 组实验工况下测试准确率都在 96% 以上,可见 GAF 时间序列编码方法具有较好的识别效果。




图 10 准确率变化曲线
Fig. 10 Accuracy curve




图 11 损失率变化曲线
Fig. 11 Loss curve

表 3 不同实验条件下弓网电弧的识别结果

Table 3 Recognition results of pantograph arc under different experimental conditions

组别	接触压力/N	滑动速度/(km·h ⁻¹)	接触电流/A	识别电弧与正常受流的准确率
1	70	30	50	100.0% (4 000/4 000)
2	70	50	50	99.58% (3 983/4 000)
3	70	110	50	98.73% (3 949/4 000)
4	30	110	50	98.30% (3 932/4 000)
5	70	110	100	99.25% (3 970/4 000)

5.2 优化算法比较

为了反映出此方法具有的先进性,基于传统方式将每一帧的图片转化为灰度特征图,并以神经网络为借助,提取特征,以及实现对故障的分类^[16-18]。该方法将电弧图片进行灰度化二值化后,弓网电弧生成 1 000 张特征图,仍旧以 1 : 4 的比例,划分测试集与训练集。将灰度特征图输入同等规模的神经网络进行训练后发现各组工况下准确率最高为 96.4%。由于拍摄背景变化大,对识别造成干扰,且由于图片分辨率很高,数据量大,实时检测故障电弧对硬件要求很高,而 GAF 图像具有分辨率较低,计算量较少,图片特征更显著等优点。试验机电弧图像如图 12 所示。



图 12 实验机电弧图像

Fig. 12 Arc image of testing machinery

增加 BP 网络、支持向量机 (SVM) 进行对比试验。从试验数据中选择故障样本和正常样本各 500 组,以 4 : 1 的比例将数据划分为训练集和测试集,分别输入 BP 神经网络以及支持向量机分类器进行训练。支持向量机模型类似于一个 3 层前馈神经网络,其核函数采用的是 Gauss 核函数 RBF,然后利用灰狼优化算法进行训练和识别求得最优的 c 和 g 。以第 1 组的样本数据为例,可以得出优化结果为 $c = 0.143\ 59$, $g = 2.297\ 4$ 。其准确率为 94.5%。BP 神经网络的结构分为输入层、隐藏层和输出层,其神经网络拓扑结构为 $5 \times 8 \times 4$,通过模型训练可以得到其准确率为 88.3%。相较于支持向量机及 BP 神经网络这类浅层网络,本文的算法准确率更高,验证了 GAF-CNN 算法可以很好的运用于电弧故障检测,识别率如图 13 所示。




图 13 不同诊断方法识别率

Fig. 13 Recognition rate of different diagnostic methods

GAF 编码方式在与本文改进的 CNN 网络相结合达到的识别率为 91.2% 以上,而 BP 网络与 SVM 所取得的分类精度不足 90%。神经网络是故障识别领域中非常重要的部分。但是,由于每种优化算法的优化重点不同,在故障识别的实际应用中识别结果也不尽相同,视频图像检测法^[19-20]的应用,获得的检测精度较大程度受拍摄背景环境、天气状况的限制,因而对特殊情况需加以考虑,譬如:隧道、大雾天气等。而且受视频图像具有较大的数据量影响,往往无法实现预期的实时性。

5.3 时效性分析

为了验证本文方法的时效性,统计不同算法的训练时间和识别时间,各方法训练时间如图 14 所示。

由图可知,SVM 和 BP 的训练时间最短,由于方法简单,输入维度较低,收敛较快。CNN 的时间最长,主要是由于其图片较复杂,图像数量过多,需灰度化后用于训练和识别,导致耗费时间过长。GAF-CNN 的训练时间虽然长于传统方法,但短于 CNN 识别灰度图像,在分类准确率上表现更出色。从整体上看,传统分类器的训练时间虽然明显少于采用二维化方法的分类器,但训练神经网络所需的时间,占用的只是弓网电弧识别系统投入使用前




图 14 不同诊断方法训练时间

Fig. 14 Training time of different diagnostic methods

的一部分时间,缩短测试集的识别故障时间更为重要,提升故障电弧识别准确率的优先度高于缩短训练时间。另外,对于实际的弓网系统,时延是使用者较关注的一个方面,即从故障电弧发生到电流信号被处理器接收、处理到神经网络识别故障这一过程的时间间隔,因此,本文使用训练好的模型统计故障电弧产生的电流信号从输入到识别过程的时间,得到各方法的识别时间,如图 15 所示。




图 15 不同诊断方法识别时间

Fig. 15 Identification time of different diagnostic methods

GAF-CNN 的总时延也处于较低水平,可保证在窗口时间内完成,分类准确率均最优,可以给使用者带来较好的体验。

6 结 论

根据本文的弓网电弧实验结果,实验中的电流分为正常受流状态和故障受流状态。提出了一种 GAF-CNN 模型用于弓网故障电弧的识别,将弓网电流波形的 GASF 和 GADF 图片作为故障特征,然后利用 RMSProp 优化算法进行弓网故障电弧的识别。弓网电弧的识别准确率会受到接触压力、滑动速度和接触电流等的环境条件的影

响。相较于传统分类器和视频图像检测法,利用 GAF-CNN 模型的准确率更高,时效性满足要求,对原信号特征的表达能力更好,总体的识别效果较好。综上所述,在 5 次测试中,正常受流识别率 100%,电弧受流识别率 98% 以上,识别效果较好。

参考文献

- [1] 韩志伟,刘志刚,张桂南,等. 非接触式弓网图像检测技术研究综述[J]. 铁道学报,2013,35(6):40-47.
HAN ZH W, LIU ZH G, ZHANG G N, et al. A review of research on non-contact pantograph image detection technology[J]. Journal of the China Railway Society, 2013, 35(6): 40-47.
- [2] 韩伟锋,高国强,刘贤沛,等. 弓网电弧磁流体动力学模型[J]. 铁道学报,2015,37(5):21-26.
HAN W F, GAO G Q, LIU X R, et al. Magnetohydrodynamic model of pantograph arc [J]. Journal of the China Railway Society, 2015, 37(5): 21-26.
- [3] MARISCOTTI A, MARRESE A, PASQUINO N. Time and frequency characterization of radiated disturbance in telecommunication bands due to pantograph arcing[C]. 2012 IEEE International Instrumentation and Measurement Technology Conference Proceedings, 2012: 2178-2182.
- [4] KARAKOSE M, AKIN E. Deep learning based Arc detection in pantograph-catenary systems [C]. 2017 10th International Conference on Electrical and Electronics Engineering, 2017: 904-908.
- [5] 张婷,王海洪,张认成,等. 基于自归一化神经网络的电弧故障检测方法[J]. 仪器仪表学报,2021,42(3): 141-149.
ZHANG T, WANG H Q, ZHANG R CH, et al. Arc fault detection method based on self-normalized neural network[J]. Chinese Journal of Scientific Instrument, 2021, 42(3): 141-149.
- [6] 郭凤仪,高洪鑫,唐爱霞,等. 局部二值模式直方图匹配的串联故障电弧检测及选线[J]. 电工技术学报, 2020,35(8): 1653-1661.
GUO F Y, GAO H X, TANG AI X, et al. Series fault arc detection and line selection based on local binary mode histogram matching[J]. Transactions of the Chinese Society of Electrical Engineering, 2020, 35 (8): 1653-1661.
- [7] AYDIN I, KARAKOSE M, AKIN E. Anomaly detection using a modified kernel-based tracking in the pantograph-catenary system [J]. Expert Systems with Applications, 2015,42 (2): 938-948.
- [8] HUANG S Y, ZHANG Z M, HOU X. Arc detection and

- recognition in pantograph-catenary system based on convolutional neural network[J]. Information Sciences, 2019, 501:363-376.
- [9] 王智勇,郭凤仪,冯晓丽,等. 基于电流信号特征的弓网电弧识别方法[J]. 电工技术学报,2018,33(1):83-91.
WANG ZH Y, GUO F Y, FENG L X, et al. Recognition method of pantograph arc based on current signal characteristics [J]. Transactions of China Electrotechnical Society, 2018, 33(1):83-91.
- [10] 于晓英,苏宏升. 基于 PMT 电压一次积分值的城轨弓网电弧检测系统[J]. 铁道学报,2019,41(9):51-58.
YU X Y, SU H SH. An urban rail bow network arc detection system based on the first integral value of PMT voltage[J]. Journal of the China Railway Society, 2019, 41(9):51-58.
- [11] 郭凤仪,张艳立,王智勇,等. 弓网电弧实验系统与辐射噪声实验研究[J]. 电工电能新技术, 2015, 34(12):49-53.
GUO F Y, ZHANG Y L, WANG ZH Y, et al. Design of pantograph arc experiment system and study on radiated noise [J]. Advanced Technology of Electrical Engineering and Energy, 2015, 34(12):49-53.
- [12] 王红宇,游敏娟,李琪,等. 一种中值滤波图像去噪的改进算法[J]. 中国科技信息,2019(1):84-85.
WANG H Y, YOU M J, LI Q, et al. An improved algorithm for median filtered image denoising[J]. China Science and Technology Information, 2019, (1):84-85.
- [13] 郑少武,李巍华,胡坚耀. 基于激光点云与图像信息融合的交通环境车辆检测[J]. 仪器仪表学报,2019,40(12):143-151.
ZHENG SH W, LI W H, HU J Y. Vehicle detection in traffic environment based on laser point cloud and image information fusion [J]. Chinese Journal of Scientific Instrument, 2019, 40(12):143-151.
- [14] WANG Z, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks [C]. Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence, 2015.
- [15] ZHENG Y, LIU Q, CHEN E, et al. 2014. Time series classification using multi-channels deep convolutional neural networks[C]. Web-Age Information Management, Springer, 2014: 298-310.
- [16] ENILBERGE M, CHEVALLIER L, PÉREZ P, et al. Finding beans in burgers: Deep semantic-visual embedding with localization[C]. CVPR, 2018.
- [17] BARMADA S, RAUGI M, TUCCI M, et al. Arc detection in pantograph-catenary systems by the use of support vector machines-based classification [J]. IET Electrical Systems in Transportation, 2013, 4(2):45-52.
- [18] ZHENG H, CHENG G, LI Y, et al. A new fault diagnosis method for planetary gear based on image feature extraction and bag-of-words model [J]. Journal of the International Measurement Confederation, 2019, 145:1-13.
- [19] 郭凤仪,周奇,王智勇,等. 波动压力载荷下弓网电弧动态特性研究[J]. 电子测量与仪器学报, 2019, 33(11):178-184.
GUO F Y, ZHOU Q, WANG ZH Y, et al. Research on the dynamic characteristics of pantograph arc under fluctuating pressure load [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(11):178-184.
- [20] BARADEL F, WOLF C, MILLE J. Glimpse clouds: Human activity recognition from unstructured feature points[C]. CVPR, 2018.

作者简介



李斌, 分别于 2006 年和 2012 年于辽宁工程技术大学获得硕士学位和博士学位。现为辽宁工程技术大学副教授, 主要研究方向为电接触理论及应用、智能电器与智能电网技术。

E-mail: 25992816@qq.com

Li Bin received his M. Sc. degree in 2006 and his doctorate in 2012 from Liaoning Technical University. Now he is an associate professor in Liaoning Technical University. His main research interests include electrical contact theory and application, intelligent appliances and smart grid technology.



阎君宇, 2019 年于辽宁工程技术大学获得学士学位。现为辽宁工程技术大学硕士研究生, 主要研究方向为电接触理论及应用、智能电器与智能电网技术。

E-mail: 2278978392@qq.com

Yan Junyu received his B. Sc. degree from Liaoning Technical University in 2019 and is currently a M. Sc. candidate at Liaoning Technical University. His main research interests include electrical contact theory and applications, smart appliances and smart grid technology.