

改进黑翅鸢算法的 1D-2D-GAF-PCNN-GRU-MSA 弓网电弧检测应用^{*}

李斌 舒嘉辉 严灵潇 田浩

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘要:针对高速列车运行时高速气流场对受电弓碳滑板与接触网之间的接触压力和电弧状态影响。通过计算得出更符合实际状态下的接触压力和电弧状态模型,建立了考虑高速气流场影响的弓网电弧实验模型。提出了改进黑翅鸢算法(IBKA)的1D-2D-GAF-PCNN-GRU-MSA故障检测模型。应用格拉姆角场(GAF)将一维接触电压信号时序图象化转换为二维图像并通过双通道卷积神经网络(PCNN)进行特征识别。另将一维时序信号通过门控循环单元(GRU)捕捉时序信号特征。将一维时序信号特征与二维图像特征进行特征融合,弥补各自局限性。针对模型中的难以确定的学习率、门控循环单元网络层神经元个数等参数,融入改进黑翅鸢算法(IBKA)对参数寻优使模型更加合理。最后,融合多头自注意力机制提高模型准确率。将提出的模型与其他3种模型分别对3组不同实验条件的弓网电弧模型进行检测,验证提出的模型具有较强的鲁棒性和较高的准确性。

关键词:高速气流场;改进黑翅鸢算法;特征融合;格拉姆角场;故障检测

中图分类号: TM501.2; TN06 文献标识码: A 国家标准学科分类代码: 470.40

1D-2D-GAF-PCNN-GRU-MSA pantograph arc detection application based on improved black-winged kite algorithm

Li Bin Shu Jiahui Yan Lingxiao Tian Hao

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

Abstract: The influence of high-speed airflow field on the contact pressure and arc state between the pantograph carbon slide plate and the catenary during the operation of high-speed train was analyzed. By calculating the contact pressure and arc state models that are more in line with the actual state, an experimental model of pantograph arc considering the influence of high-speed airflow field is established. In this paper, a 1D-2D-GASF-PCNN-GRU-MSA fault detection model based on the improved black-winged kite algorithm (IBKA) was proposed. The gram-angle field (GAF) was used to convert the one-dimensional contact voltage signal into a two-dimensional image, and the feature recognition was carried out by the parallelizing convolutional neural network (PCNN). In addition, the one-dimensional timing signal is captured by the gated recurrent unit (GRU). The features of the one-dimensional time-series signal and the two-dimensional image are fused to make up for their respective limitations. In view of the parameters in the model, such as the learning rate that is difficult to determine, the number of neurons in the network layer of the gated recurrent unit, and the improved black-winged kite algorithm is integrated to optimize the parameters to make the model more reasonable. Finally, the multi-head self-attention mechanism was fused to improve the accuracy of the model. The proposed model and other three models were tested on three sets of pantograph-net arc models with different experimental conditions, and it was verified that the proposed model had strong robustness and high accuracy.

Keywords: high-velocity airflow field; improved black-winged kite algorithm; feature fusion; gram-angle field; fault diagnosis

0 引言

随着电气化设备的快速发展,国家交通强国政策^[1]

的大力推进,进入21世纪,我国高速铁路事业飞快发展。到2023年底,我国高铁营业里程已达到4.5万千米,位居世界第一。然而,由于弓网电弧问题的存在,已经严重影响我国高速铁路事业的进一步发展。弓网

电弧的产生会对电网受流质量产生一定影响，并且在燃弧时会对碳滑板有很大的烧蚀最用，减少碳滑板的使用寿命，严重时会发生火灾。因此，对弓网电弧的精准识别十分重要。

目前，国内外许多学者对弓网电弧检测做了深入研究。例如，李斌等^[2]通过利用 D-score 评估准则对电流进行特征筛选，最后利用海鸥算法优化支持向量机进行电弧识别。郭凤仪等^[3]提出了将变分模态分解与三阶谱融合的直流电弧识别方法。时光等^[4]通过对弓网系统接触电阻研究，提出了一种融合先进知识的改进食肉算法优化径向基神经网络检测模型。Huang 等^[5]通过利用卷积神经网络对弓网电弧图像进行识别的检测方法。张蓬鹤等^[6]提出了通过广义 S 变换进行时频特征提取，利用二维卷积神经网络进行识别的方法。赵怀军等^[7]提出利用模糊逻辑器对电流进行特征融合的方法判别电弧的产生。鲍光海等^[8]通过对电弧重燃和熄灭时的磁通量分析，并计算峭度值的方式识别是否有电弧产生。

可见，上面提到的方法分别为两种，一种是对通过利用神经网络对电弧图像集进行模型训练实现对电弧的识别。另一种是对电弧的电压信号和电流信号进行特征筛选判断电弧的产生。然而，上述方法仅适用于干扰少，比较理想化的图像，而且在对电流或电压信号进行特征筛选的过程种也都遗忘了一些特征。

针对上述方法的不足，提出了一种改进黑翅膀算法（improved black-winged kite algorithm, IBKA）的 1D-2D-GAF-PCNN-GRU-MSA 的电弧故障检测模型。由于门控循环单元（gate recurrent unit, GRU）在处理时间序列数据时具有参数少，容易训练和优化的优点。因此，采用门控循环单元对一维时序电压信号进行特征提取。然而，由于门控循环单元结构简单，抗干扰性差，处理复杂信号时难以挖掘数据集的复杂特征。针对门控循环单元的不足，另设计一条支路。通过格拉姆角场（gram-angle field, GAF）将一维电压信号时序图像化为二维图像，设计了双通道卷积神经网络最大保留图像特征。利用双通道卷积神经网络（parallelizing convolutional neural network, PCNN）对复杂图像识别处理能力强，抗干扰性好的特点，弥补了门控循环单元的不足。而门控循环单元又可以有效缓解双通道卷积神经网络梯度消失的问题。因此，将一维信号与二维图像特征融合，可以有效弥补了各自的不足。最后利用 IBKA 对模型中的参数以及学习率进行优化，并融合多头注意力机制提高算法准确性。

1 格拉姆角场

格拉姆角场^[9]可以把一维时间序列信号转化成二维图像，它可以最大程度的保留原始信号的特征，并且不会

将特征丢失。格拉姆角场的理论基础是将笛卡尔坐标系统中的一维数据转换到极坐标系下，然后根据它特有的内积定义方式，利用三角函数和与差等方法，得到表征时间相关性的信息，从左上到右下平铺到图像中，从而生成 GASF 和 GADF 两类图像。

定义时间序列 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ ，这里的 N 表示时间点的总数； i 为时间点， $i \in [1, n]$ 。将 X 进行 GAF 交换流程如下所示：

将每组样本的时间序列信号 $X = \{x_1, x_2, \dots, x_n\}$ 采用归一化处理方式缩放至区间 $[-1, 1]$ ，如式(1)所示。

$$\tilde{x}_i = \frac{(x_i - \min(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (1)$$

式(2)表示格拉姆矩阵。不同向量之间的内积可以表现出向量相关性，而向量间夹角表现了同向量间的相关程度。

$$\mathbf{G} = \mathbf{X}^T \mathbf{X} = \begin{bmatrix} \langle x_1, x_1 \rangle & \cdots & \langle x_1, x_n \rangle \\ \langle x_2, x_1 \rangle & \cdots & \langle x_2, x_n \rangle \\ \vdots & & \vdots \\ \langle x_n, x_1 \rangle & \cdots & \langle x_n, x_n \rangle \end{bmatrix} \quad (2)$$

其中， G 是格拉姆矩阵； $\langle \cdot, \cdot \rangle$ 为内积运算。

由于一维时序数据并不是向量，所以需要对时间序列进行极坐标变换，将时序电流数据转化为向量，如式(3)所示。

$$\begin{cases} \phi = \arccos(\tilde{x}_i), & -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{\mathbf{X}} \\ r = \frac{t_i}{N}, & t_i = 1, 2, \dots, N \end{cases} \quad (3)$$

其中， t_i 为时间戳； N 表示正则化极坐标生成空间的常数系数； ϕ 表示相角； r 表示极坐标的半径； \tilde{x} 为标准化缩放后的 X 。

若采用格拉姆矩阵来定义内积，很难区分输出数据的高斯噪声，所以格拉姆角场为了消除高斯白噪声的影响，定义了两种特有的带有惩罚项的内积形式，其公式如式(4)和(5)所示。

$$\langle x_i, x_j \rangle = \cos(\phi_i + \phi_j) \quad (4)$$

$$\langle x_i, x_j \rangle = \sin(\phi_i - \phi_j) \quad (5)$$

根据上述两种不同内积定义形式，可以得到两种不同的格拉姆角场：GASF (gramian angular summation fields) 与 GADF (gramian angular difference fields)。如式(6)和(7)所示。

$$\mathbf{G}_{\text{GASF}} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cdots & \cos(\phi_2 + \phi_n) \\ \vdots & & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (6)$$

$$\mathbf{G}_{\text{GADF}} = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \sin(\phi_2 - \phi_1) & \cdots & \sin(\phi_2 - \phi_n) \\ \vdots & & \vdots \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{bmatrix} \quad (7)$$

对于在时域上距离较近的电流数据, GAF 变换具有抑制信号扰动的能力。发生差模干扰时有: $\Delta\phi_i =$

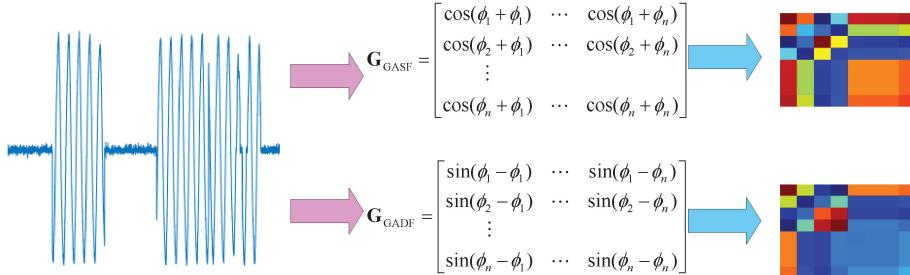


图 1 二维图像转换过程

Fig. 1 2D image conversion process

2 双通道卷积神经网络

为了使图像特征损失降低到最小, 搭建双通道卷积神经网络(PCNN), 用于将 GAF 生成的二维图像特征全

$-\Delta\phi_i$; 发生共模干扰时有: $\Delta\phi_i = \Delta\phi_i$, 将上述两种不同干扰分别代入式(8)与式(9), 可以自动地去除干扰量。GAF 生成二维图像过程如图 1 所示。

$$\langle x_i, x_j \rangle = \cos[(\phi_i + \Delta\phi_i) + (\phi_j + \Delta\phi_j)] \quad (8)$$

$$\langle x_i, x_j \rangle = \sin[(\phi_i + \Delta\phi_i) - (\phi_j + \Delta\phi_j)] \quad (9)$$

部提取。双通道卷积神经网络能够避免单通道卷积神经网络^[10](convolutional neural networks, CNN)对 GAF 生成的二维图像进行舍去的问题, 克服了单通道神经网络特征提取不完全的缺点。其结构如图 2 所示。

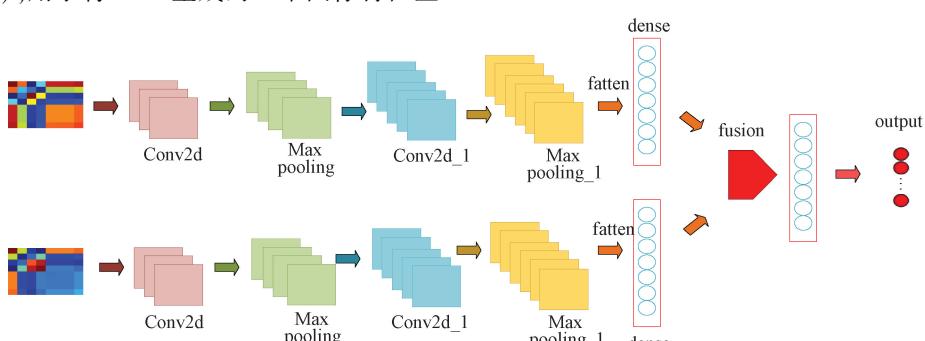


图 2 双通道卷积神经网络

Fig. 2 Parallelizing convolutional neural network

首先, 分别将 GASF 和 GADF 图像同时双通道卷积神经网络中, 两条双通道卷积神经网络在经过双层卷积池化后各输出一组一维向量; 然后, 将所输出两组一维向量进行拼接融合; 通过全连接层后, 最终将融合特征输入到 Softmax 层中, 输出最终的概率。

利用双通道卷积神经网络学习不同的图像权重值, 双支路高维特征互补, 使得深层空间特征得到显著增强

3 门控循环单元

门控循环单元^[11](GRU)旨在解决长期记忆和反向传播中的梯度等问题。GRU 背后的原理与长短期记忆

网络(long short term memory, LSTM)非常相似, 即用门控机制控制输入、记忆等信息在当前时间步做出预测, 其结构如图 3 所示。

重置门 r_t 公式如式(10)所示。

$$r_t = \sigma(W_r x_t + U_r k_{t-1} + b_r) \quad (10)$$

由当前位置输入 x_t 和上一位置隐层的输出 k_{t-1} 经线性变化相加后再接 sigmoid 组成。由于 sigmoid 的存在, 其输出值为 0~1 之间, 用于选择有多少信息留下。

更新门 z_t 公式如式(11)所示。

$$z_t = \sigma(W_z x_t + U_z k_{t-1} + b_z) \quad (11)$$

其中, k'_t 为更新后的值, 由重置门 r_t , 上一位输出 k_{t-1} 和这一位置输出 x_t 共同决定。如式(12)所示。

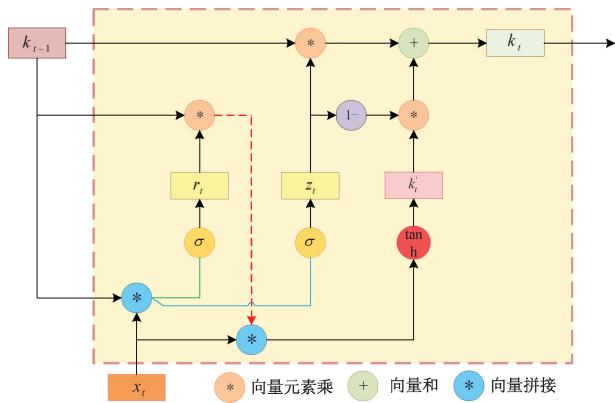


图 3 门控循环单元结构

Fig. 3 Gated recirculating unit structure

$$k'_t = \tanh(W_c x_t, U(r_t \cdot k_t)) \quad (12)$$

其中, k_t 为当前位置最终输出, 由更新后的值 k'_t 、更新门 z_t , 上一位置输入 k_{t-1} 共同决定, 如式(13)所示。

$$k_t = z_t \cdot k_{t-1} + (1 - z_t) k'_t \quad (13)$$

GRU 对于时间序列中有效信息的挖掘更具优势, 在面对大规模训练样本的情况下, 能够在减少预测时间的同时保证预测效果不受明显影响^[12]。

4 超参数优化

由于模型中具有难以确定的学习率、GRU 层神经元个数等参数, 为了提高模型故障识别的精度^[13]引入改进黑翅鸥算法 (IBKA) 对超参数进行优化。黑翅鸥优化算法^[14] (black-winged kite algorithm, BKA) 是一种受自然启发的群智能优化算法, 其灵感来源于黑翅鸥这种动物的生存策略。

4.1 传统黑翅鸥算法

与大多数优化算法一样, 均匀地分配每只黑翅鸥的位置, 种群初始化如式(14)所示。

$$P_i = BK_{lb} + rand(BK_{ub} - BK_{lb}) \quad (14)$$

其中, $i \in 1, 2, \dots, N$, BK_{lb} 和 BK_{ub} 分别是第 j 维黑翅鸥的下界和上界, $rand$ 为 $[0, 1]$ 之间的随机数。

黑翅鸥攻击行为的数学模型如式(15)所示。

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + n \times (2r - 1) \times y_t^{i,j}, & \text{其他} \\ y_t^{i,j} + n(1 + \sin(r) \times y_t^{i,j}), & g < r \end{cases} \quad (15)$$

$$n = 0.05 \times e^{-2 \times (\frac{t}{T})} \quad (16)$$

其中, $y_t^{i,j}$ 和 $y_{t+1}^{i,j}$ 分别表示第 i 只黑翅鸥在第 j 维和 $t+1$ 次迭代步骤中的位置; r 为 $0 \sim 1$ 之间的随机数, g 为 0.9 的常数; T 是迭代的总次数, t 是到目前为止已经完成的迭代次数。

黑翅鸥迁徙行为的数学模型如式(17) :

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + C(0,1) \times (L_t^j - h \times y_t^{i,j}), & \text{其他} \\ y_t^{i,j} + C(0,1) \times (y_t^{i,j} - L_t^j), & F_i < F_n \end{cases} \quad (17)$$

$$h = 2\sin(r + \frac{\pi}{2}) \quad (18)$$

其中, L_t^j 表示到目前为止第 t 次迭代的第 j 维黑翅鸥的领先得分者。 F_i 表示任一黑翅鸥在第 t 次迭代中获得的第 j 维当前位置; F_n 表示第 t 次迭代中任意黑翅鸥在第 j 维随机位置的适应度值; $C(0,1)$ 代表柯西突变。

4.2 改进黑翅鸥算法

为了使 BKA 算法前期具有更好的全局搜索能力, 引入 Levy 飞行策略和自由度参数的 t 分布对黑翅鸥位置进行改进, 使得算法在迭代前期具有较好的全局开发能力, 在迭代后期增加跳出局部最优的可能。改进如式(19)所示。

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + \beta \oplus Levy(\lambda), & g < r \\ y_t^{i,j} + t(iter) \times y_t^{i,j}, & \text{其他} \end{cases} \quad (19)$$

其中, β 为控制步长参数, 表达式如式(20)所示。

$$\beta = 0.01(y_t^{i,j} - y_{best}^{i,j}) \quad (20)$$

其中, $y_{best}^{i,j}$ 为当前最优解。

为了更好控制 Levy 飞行和 t 分布的转换提高算法的收敛速度, 采用动态选择概率对概率 g 进行改进, 以此来调节自适应 t 分布变异和 Levy 飞行的使用。

改进后的动态概率如式(21)所示。

$$g' = \omega_1 - \omega_2 \times (T - \frac{t}{T}) \quad (21)$$

其中, ω_1 决定了动态选择概率的上限, ω_2 决定了动态选择概率的变化幅度。 $\omega_1 = 0.5, \omega_2 = 0.1$ 时调节最优。图 4 为 IBKA 算法流程。

5 多头自注意力机制

注意力机制 (attention mechanism, AM) 是机器学习中一种广泛应用于各种不同类型任务的数据处理方法。可以有选择地聚焦于与任务相关度更高的特征, 抑制无用特征的影响, 从而提高模型的性能。

对于给定 q 和 X , 选择第 i 个输入信息的概率如式(22)所示。

$$\alpha_i = p(z = i | X, q) = \text{softmax}(s(x_i, q)) = \frac{e^{s(x_i, q)}}{\sum_{j=1}^N e^{s(x_j, q)}} \quad (22)$$

其中, X 为输入信息, 如式(23)所示。

$$X = [x_1, x_2, \dots, x_N] \quad (23)$$

维度为 N , z 为要索引的位置, q 为查询矩阵, $s(x_i, q)$ 为注意力评分函数。表达式如式(24)所示。

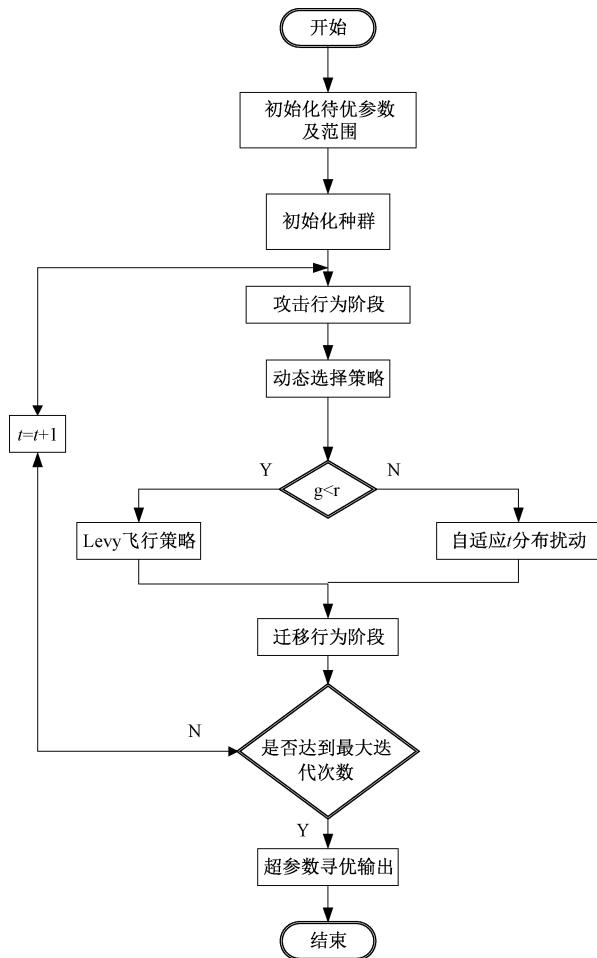


Fig. 4 Flow chart of the improved black-winged kite algorithm

$$s(x_i, q) = \frac{x_i^T q}{\sqrt{d}} \quad (24)$$

D 为输入信息的维度。多头注意力机制^[15] (multi-headed self-attention, MSA) 可以看作从一组查询 Q 和一组键值矩阵 $K-V$ 到输出的映射, 如图 5 所示。

表达式如式(25)所示。

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (25)$$

其中, d_k 是 Q 和 K 的维度, MSA 是由多个自注意力机制结构组成的, 用于同时处理同一特征信息, 其输出为多个自注意力的拼接, 如图 5 所示。这种结构可以更好地捕捉不同特征之间的依赖关系, 并进一步提高模型的表现, 其表达式如式(26)和(27)所示。

$$H_i = \text{Attention}(QW_Q^i, KW_K^i, VW_V^i) \quad (26)$$

$$\text{MSA}(Q, K, V) = \text{concat}(H_1, H_2, \dots, H_m)W_0 \quad (27)$$

其中, m 为注意力头的个数, V 的维度为 d_V , 注意力权值矩阵 $W_0 \in \mathbf{R}^{nd_v \times dim}$, $W_V^i \in \mathbf{R}^{d_v \times dim}$, $W_Q^i, W_K^i \in \mathbf{R}^{d_k \times dim}$ 。

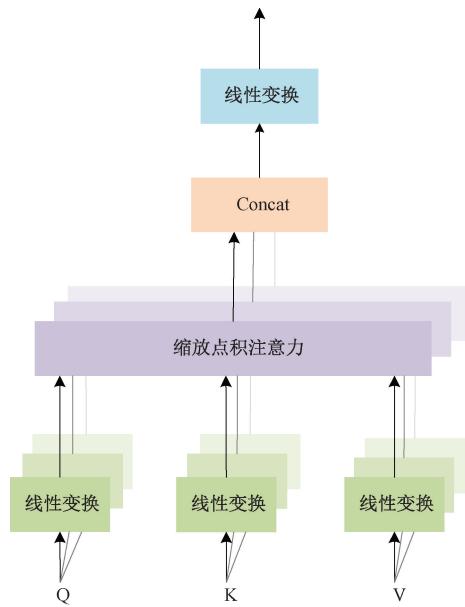


图 5 多头自注意力结构

Fig. 5 Multi-head attention structure

6 故障检测模型总设计

将原始故障信号利用 GAF 实现时序图象化, 生成两组二维图像, 并设计双通道卷积神经网络对两组图像进行空间特征学习, 避免特征丢失的问题。其次, 将故障信号利用 GRU 捕捉一维时序信号的动态变化。将 GRU 和 PCNN 结合, 可以同时考虑时序特征和空间特征。将一维时序信号和二维图像融合, 弥补各自的局限性。针对模型的学习率, 卷积核大小, GRU 神经元个数, 融合改进黑翅鸢算法 (IBKA) 进行寻优, 优化模型建构。最后, 融合 MSA, 将特征进行重点强化, 提高故障识别准确率。总体设计如图 6 所示。

7 弓网电弧实验模拟

在模拟实验中, 通常认为碳滑板与接触网接触压力为定值。在实际过程中, 空气流速的产生对受电弓碳滑板会产生空气抬升力^[16], 使得碳滑板与接触网之间的接触压力随空气流动以及列车运行速度的改变而变化, 进而使得碳滑板与接触网之间的摩擦力随之变化。由空气动力学原理可知, 受电弓与接触网之间的空气动力主要分为空气压差力 F 以及空气摩擦力 f 。表达式如式(28)和(29)所示。

$$F = \rho CLv_\infty^2 (X_0 \sin^2 \theta_\infty + Y_0 \sin \theta_\infty \cos \theta_\infty) \quad (28)$$

$$f = 2\pi \rho LV_\infty^2 (X_0 \sin^2 \theta_\infty + Y_0 \sin \theta_\infty \cos \theta_\infty) \quad (29)$$

所以, 高速气流情况下, 接触网空气抬升力近似计算

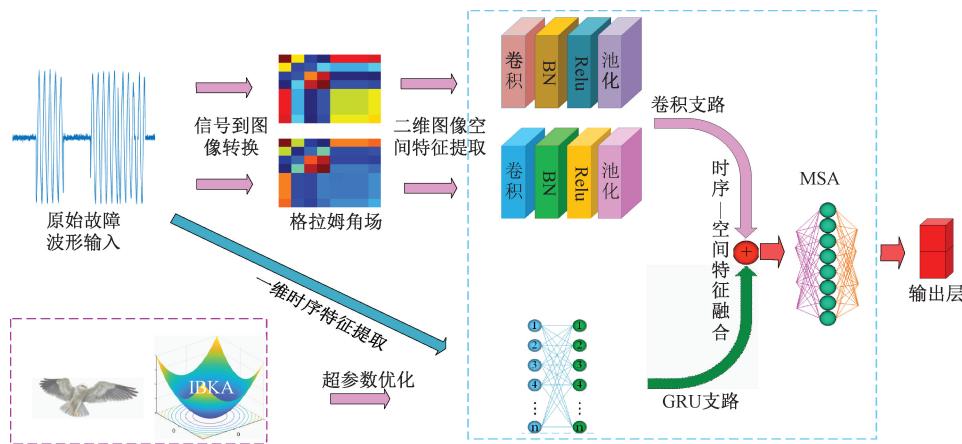


图 6 改进黑翅鸢算法的 1D-2D-GAF-PCNN-GRU-MSA 故障检测模型

Fig. 6 Improved black-winged kite algorithm and 1D-2D-GAF-PCNN-GRU-MSA fault detection model

为式(30)所示。

$$P_c = F + f \quad (30)$$

其中, ρ 为空气密度, X_0 为滑板的宽度, Y_0 为滑板厚度, L 为滑板的长度。 θ_∞ 空气来流的弓角。 v_∞ 为空气流速。

其中, C 为空气动力系数, ρ 为空气密度, 取 $C=0.7$, $\rho=1.29 \text{ kg/m}^3$, $\theta_\infty=\pm 10^\circ$ 。当 V_∞ 为 100 m/s 时, 代入计算得接触压力大约为 4 N。

同时, 由于高速气流影响, 电弧并不是垂直于碳滑板, 而是倾斜状态。图 7 为高速气流下产生电弧示意图。

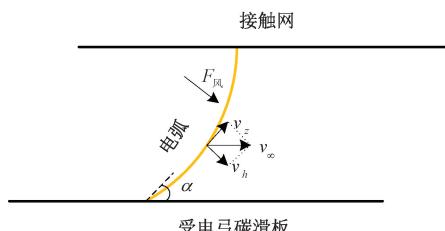


图 7 高速气流场对电弧影响

Fig. 7 Effect of high-velocity airflow field on arc

图 7 中橙色斜柱为电弧, $F_\text{风}$ 是弓网电弧受到的力。从图 7 中可以看出, 列车运行过程中 α 是空气流速 v_∞ 的函数, 如式(31)所示。

$$\begin{cases} v_z = v_\infty \cos\alpha \\ v_h = v_\infty \sin\alpha \\ \alpha = f(v_x) \end{cases} \quad (31)$$

随着气流速度越来越快, 电弧被拉长越多, 此时电弧散热面积增加, 也更容易熄灭^[17]。

根据以上理论进行实验模拟设计, 研究高速气流影响下弓网电弧的特性变化。因此需要采用适合的方案模拟真实情况下的高速气流。在实际运行情况下, 气流对

电弧主要是横向吹弧作用, 因此在实验中, 设备产生的高速气流需要横向作用于弧柱。弓网电弧实验模拟如图 8 所示。



图 8 弓网电弧实验模拟

Fig. 8 Experimental simulation of pantograph arc

为降低其他因素对弓网电弧的干扰, 使用单因素法改变实验条件采集数据。由于弓网系统电流有效值为 141.4 A, 因此实验过程中不改变电流大小, 只对气流速度和接触压力作改变, 得到不同条件下的弓网电弧数据, 其一是不同条件下的数据便于分析弓网电弧特性, 其二是不同实验条件下的弓网电弧数据用于电弧识别, 能够

避免偶然性问题,使结论更有说服力^[18]。设置每组采样 3 min,采样频率为 10 kHz,试验方案如表 1 所示。

表 1 实验参数设置

Table 1 Experimental parameter settings

参数	数值
回路电流/A	141.4
滑板往复速度/(m·s ⁻¹)	0.2
接触压力/N	40/60
电压等级/V	AC 36
碳滑板-接触线相对速度/(km·h ⁻¹)	100
暴风机气流速度/(km·h ⁻¹)	89.3/135.8

以 40 N、89.3 km/h 实验组为例,实验模拟结果如图 9 所示。

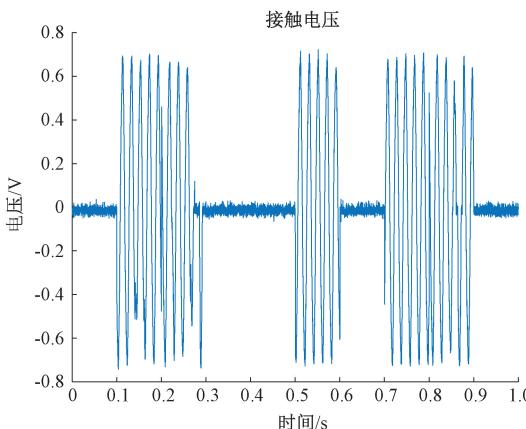


图 9 接触电压波形

Fig. 9 Contact voltage waveform

当不产生电弧时,由于碳滑板和接触网紧密接触,因此接触电压几乎为 0 V,然而当产生电弧时,由于接触网与碳滑板之间存在间隙,因此接触电压不再为 0 V,可以从图 9 中看出在 0.1 s 到 0.3 s,0.5 s 到 0.6 s,以及 0.7 s 到 0.9 s 时间段为燃弧期间。

8 模型验证

8.1 数据预处理

将采集到的一维故障电弧数据经过 GAF 转化为二维特征图^[19-21]。以 40 N、89.3 km/h 实验组为例,数据划分如表 2 所示。

表 2 数据划分

Table 2 Data segmentation

状态	类别	训练集	测试集
正常接触	1	80	20
燃弧	2	80	20

从图 10 可以看出,当迭代次数为 25 次时,训练集准

确率就已经达到 100%,损失值基本为 0。

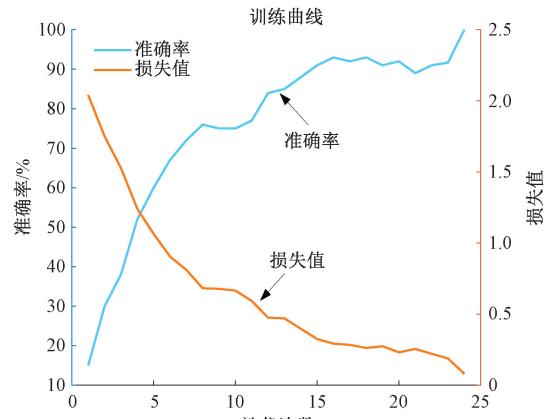


图 10 训练曲线

Fig. 10 Training curve

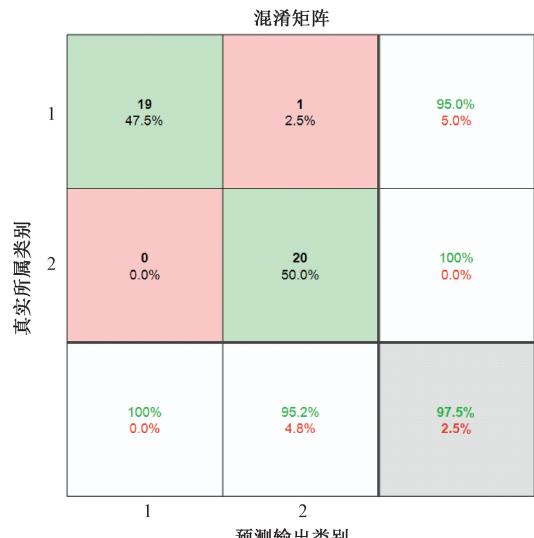


图 11 混淆矩阵

Fig. 11 Confusion matrix

混淆矩阵结果如图 11 所示,从图可以看出所提模型电弧识别准确率达到 97.5%,对电弧故障有很好的识别作用。模型有较强鲁棒性时能够容忍一定程度的错误或噪声,而不会导致系统崩溃或产生严重错误的结果,这种容错性对于处理现实世界中的不完美数据至关重要^[22]。列车在运行过程中环境复杂,弓网之间条件也时刻在变化,尤其是气流速度和接触压力,因此使用不同实验条件下的电压数据检验模型鲁棒性非常必要。训练模型时使用数据实验条件为接触压力 40 N 气流速度为 89.3 km/h。为了对比,使用训练好的模型识别 40 N、135.8 km/h,60 N、135.8 km/h,并标记为实验一,实验二,实验三。3 组实验在测试集上的 t-SNE 分类可视化^[23]如图 12 所示。

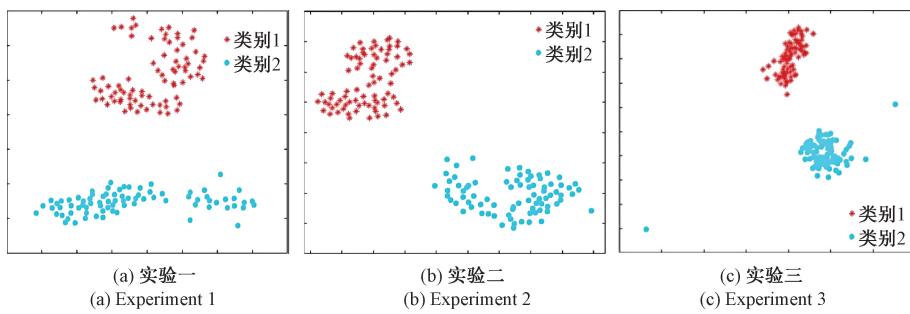


图 12 t-SNE 分类可视化
Fig. 12 t-SNE classification visualization

从图 12(a)和图 12(c)可看出实验一和实验三分类效果明显,从图 12(b)可以看出仅实验二数据的分类没有形成较为紧凑的簇。从整体上看,提出的弓网电弧故障检测模型能够较好的对不同实验条件下的故障数据和正常数据进行分类,具有较强的鲁棒性。

8.2 与其他模型对比

为验证所提方法的性能,在相同环境和数据集情况下,将所提模型与 ResNet 模型、1D-CNN 模型、1D-CNN-Attention 进行对比。数据划分如表 3 所示。

表 3 实验数据划分

Table 3 Experimental data division

实验	状态	类别	训练集	测试集
实验一	正常	1	80	20
	燃弧	2	80	20
实验二	正常	3	80	20
	燃弧	4	80	20
实验三	正常	5	80	20
	燃弧	6	80	20

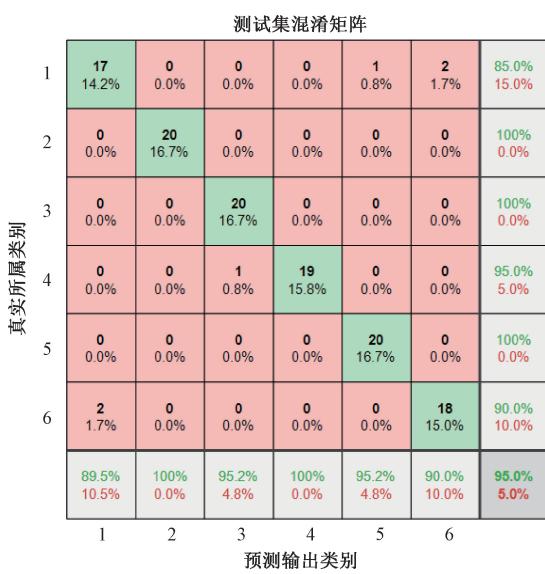


图 13 1D-CNN 模型

Fig. 13 1D-CNN model

		测试集混淆矩阵						
		1	2	3	4	5	6	
真实所属类别	1	19 15.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.8%	95.0% 5.0%
	2	0 0.0%	20 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	20 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	1 0.8%	19 15.8%	0 0.0%	0 0.0%	95.0% 5.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	19 15.8%	1 0.8%	95.0% 5.0%
	6	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	19 15.8%	95.0% 5.0%
		95.0% 5.0%	100% 0.0%	95.2% 4.8%	100% 0.0%	100% 0.0%	90.5% 9.5%	96.7% 3.3%
		1	2	3	4	5	6	

测试集混淆矩阵

图 14 ResNet 模型

Fig. 14 ResNet model

从混淆矩阵图 13~16 和准确率柱状图 17 来看,1D-CNN 模型的准确率最低,准确度为 95%,ResNet 模型的准确率为 96.67%,1D-CNN-Attention 模型准确率为 97.5%,所提模型准确率为 99.17%,基本实现对故障类别的准确识别。

9 结论

为了更加符合铁路列车在实际运行时弓网电弧状态,考虑了高速气流对电弧的影响。利用空气动力学原理,计算出了高速气流与接触压力之间的关系。通过实验模拟发现,当产生弓网电弧故障时接触电压不在为 0 V。根据这一特性,提出了改进黑翅膀算法(IBKA)的 1D-2D-GAF-PCNN-GRU-MSA 弓网电弧故障检测模型。该方法可直接对原始一维电压时序信号进行检测,避免了降噪和降维过程造成特征的损失。同时,将一维时序信号特征和二维图像特征进行融合,克服了在单一维度

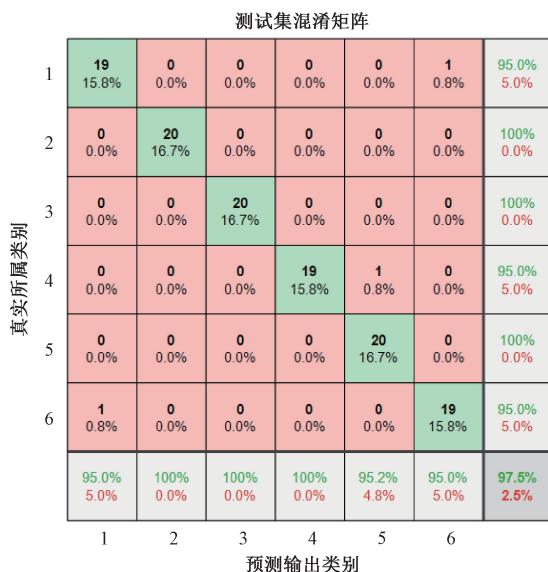


图 15 1D-CNN-Attention 模型

Fig. 15 1D-CNN-Attention model

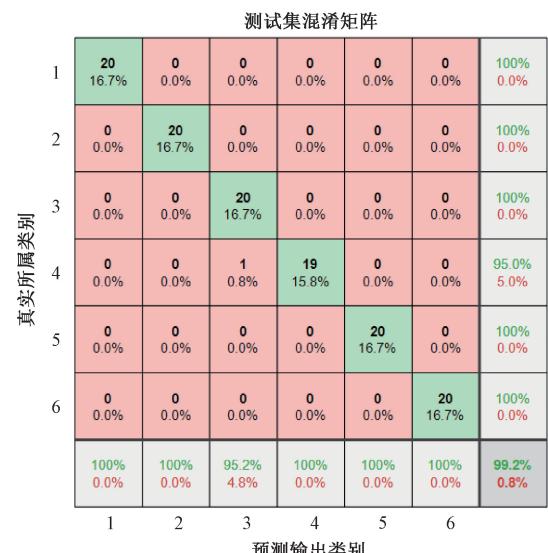


图 16 所提模型

Fig. 16 The proposed model

情况下模型对不同数据检测时发生准确率下降的问题，提高模型的鲁棒性。然后，针对模型难以确定的学习率，卷积核大小，GRU 神经元个数，利用 IBKA 算法进行超参数优化，优化模型架构。结合多头自注意力机制有效把握提取特征的贡献程度，提高模型准确性。最后，与其他 3 种模型进行弓网电弧故障检测，发现所提方法具有更高的准确性和较好的鲁棒性。

参考文献

[1] 陈水生, 谢仪. 新型举国体制助推科技创新的实现机制: 基于中国高铁发展的分析 [J]. 人文杂志, 2024, (8): 87-96.

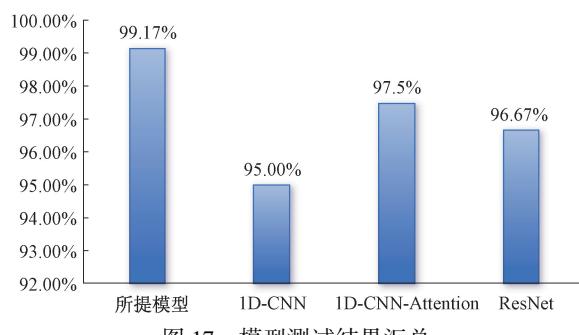


图 17 模型测试结果汇总

Fig. 17 Summary of model test results

CHEN SH SH, XIE Y. The realization mechanism of the new national system to promote scientific and technological innovation: an analysis based on the development of China's high-speed rail [J]. Journal of Humanities, 2024, (8):87-96.

[2] 李斌, 娄璟, 杜典松. 基于 SOA-SVM 的弓网电弧识别方法 [J]. 电子测量与仪器学报, 2022, 36(10):83-91.

LI B, LOU J, DU D S. Pantograph-catenary arc recognition method based on SOA-SVM [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10):83-91.

[3] 郭凤仪, 黄捷康, 侯星雨. 直流弓网电弧的识别方法研究 [J]. 电子测量与仪器学报, 2019, 33(7):122-128.

GUO F Y, HUANG J K, HOU X Y. Research on the identification method of DC bowing network arc [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(7):122-128.

[4] 时光, 陈翼喆, 李莹, 等. 基于先验知识的弓网接触电阻预测模型精度提升方法研究 [J]. 电工技术学报, 2024, 39(14):4535-4546.

SHI G, CHEN Y J, LI Y, et al. Research on accuracy improvement method of pantograph-net contact resistance prediction model based on prior knowledge [J]. Transactions of China Electrotechnical Society, 2024, 39(14):4535-4546.

[5] HUANG SH Z, ZHAI Y CH, ZHANG M M, et al. Arc detection and recognition in pantograph-catenary system based on convolutional neural network [J]. Information Sciences, 2019, 501: 363-376.

[6] 张蓬鹤, 秦译为, 宋如楠, 等. 广义 S 变换下串联故障电弧的时频分析及识别研究 [J]. 电网技术, 2024, 48(7):2995-3003.

ZHANG P H, QIN Y W, SONG R N, et al. Time-frequency analysis and identification of series fault arcs under generalized S-transform [J]. Power Grid Technology, 2024, 48(7):2995-3003.

[7] 赵怀军, 秦海燕, 刘凯, 等. 基于相关理论及零体特征

- 融合的串联故障电弧检测方法 [J]. 仪器仪表学报, 2020, 41 (4): 218-228.
- ZHAO H J, QIN H Y, LIU K, et al. Series fault arc detection method based on correlation theory and zero-rest feature fusion [J]. Chinese Journal of Scientific Instrument, 2020, 41(4):218-228.
- [8] 鲍光海,江润. 基于磁通不对称分布的串联电弧故障检测研究[J]. 仪器仪表学报,2019,40(3):54-61.
- BAO G H, JIANG R. Research on series arc fault detection based on magnetic flux asymmetric distribution[J]. Chinese Journal of Scientific Instrument, 2019, 40(3):54-61.
- [9] 李斌,阎君宇. 基于 GAF-CNN 的弓网电弧识别方法研究[J]. 电子测量与仪器学报, 2022(1):188-195.
- LI B, YAN J Y. Research on pantograph arc identification method based on GAF-CNN[J]. Journal of Electronic Measurement and Instrumentation, 2022 (1): 188-195.
- [10] 全航,杨燕,江永全. 检测脑电癫痫的多头自注意力机制神经网络 [J]. 计算机科学与探索, 2023, 17 (2) : 442-452.
- TONG H, YANG Y, JIANG Y Q. Neural network of multi-head self-attention mechanism for detecting EEG epilepsy [J]. Computer Science and Exploration, 2023, 17(2):442-452.
- [11] 赵紫昱,陈渊睿,陈霆威,等. 基于时空图注意力网络的区域负荷超短期预测 [J]. 电力系统自动化, 2024, 48(12):147-155.
- ZHAO Z Y, CHEN Y R, CHEN T W, et al. Ultra-short-term prediction of regional load based on spatiotemporal graph attention network [J]. Power System Automation, 2024, 48(12):147-155.
- [12] 张莞,张泰瑀,贾民平,等. 多传感器融合和 MHA-LSTM 的电机轴承剩余寿命预测 [J]. 仪器仪表学报, 2024, 45(3):84-93.
- ZHANG Y, ZHANG T Y, JIA M P, et al. Prediction of remaining life of motor bearings based on multi-sensor fusion and MHA-LSTM[J]. Chinese Journal of Scientific Instrument, 2024, 45(3):84-93.
- [13] 谭增强,牛拥军,李元昊,等. 基于麻雀算法和深度极限学习机的 NO_x 预测研究 [J]. 中国电机工程学报, 2022, 42 (S1):187-192.
- TAN Z Q, NIU Y J, LI Y H, et al. Research on NO_x prediction based on Sparrow algorithm and deep extreme learning machine [J]. Proceedings of the CSEE, 2022, 42(S1):187-192.
- [14] WANG J, WANG W CH, HU X X, et al. Black-winged kite algorithm: a nature-inspired meta-heuristic for solving benchmark functions and engineering problems [J]. Artificial Intelligence Review, 2024,57(4): 1-53.
- [15] 李黄曼,张勇,张瑶. 基于 ISSA 优化 SVM 的变压器故障诊断研究 [J]. 电子测量与仪器学报, 2021, 35 (3) : 123-129.
- LI H M, ZHANG Y, ZHANG Y. Research on transformer fault diagnosis based on ISSA optimization SVM [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35 (3) :123-129.
- [16] 白鑫,孙丽霞,王友彪,等. 风载作用下高速列车曲线通过性能研究 [J]. 中国铁道科学, 2024, 45 (2) : 146-154.
- BAI X, SUN L X, WANG Y B, et al. Study on curve passing performance of high-speed train under wind load[J]. China Railway Science, 2024, 45(2):146-154.
- [17] 王彦快,米根锁,孔得盛,等. 基于 MDS 和改进 SSA-SVM 的高速铁路道岔故障诊断方法研究 [J]. 铁道学报, 2024, 46(1):81-90.
- WANG Y K, MI G S, KONG D SH, et al. Research on fault diagnosis method of high-speed railway turnout based on MDS and improved SSA-SVM[J]. Journal of the China Railway Society, 2024, 46(1):81-90.
- [18] ZHANG CH N, WANG F, WANG ZH F, et al. Analysis of stator winding inter-turn short circuit fault of PMSM for electric vehicle based on finite element simulation [C]. 2014 IEEE Conference and Expo Transportation Electrification Asia-Pacific (ITEC Asia-Pacific), Beijing, 2014;1-6.
- [19] ZENG H, CHEN X W, DENG F M. Simulation Analysis of Pantograph Catenary Arc Motion Characteristics During High-speed Train Running [C]. 2022 IEEE 5th International Electrical and Energy Conference (CIEEC), Nanjing, China, 2022:858-862.
- [20] YANG Z F, XU P, WEI W F, et al. Influence of the crosswind on the pantograph arcing dynamics. IEEE Transactions on Plasma Science. 2020, 48 (8) : 2822-2830.
- [21] SHIH K J, HSIEH M F, B. CHEN J, et al. Machine learning for inter-turn short-circuit fault diagnosis in permanent magnet synchronous motors [J]. IEEE Transactions on Magnetics, 2022,58(8): 1-7.
- [22] 李斌,郭自强,高鹏. 改进北方苍鹰算法在光伏阵列中应用研究 [J]. 电子测量与仪器学报, 2023, 37 (07) : 131-139.
- LI B, GUO Z Q, GAO P. Application of improved northern goshawk optimization algorithm in photovoltaic array [J]. Journal of Electronic Measurement and Instrumentation, 2023,5(7): 131-139.
- [23] 王一鹏,陈学振,李连玉. 基于小波包混合特征和支持向量机的机床主轴轴承故障诊断研究 [J]. 电子测量与仪器学报, 2021, 35 (2) :59-64.

WANG Y P, CHEN X ZH, Li L Y. Research on fault diagnosis of spindle bearing of machine tool based on wavelet packet hybrid feature and support vector machine[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2):59-64.

作者简介



李斌, 分别在 2003 年、2006 年和 2012 年于辽宁工程技术大学获得学士学位、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 B. Sc. degree in 2003, M. Sc. degree in 2006, and Ph. D. degree in 2012 from Liaoning Technical University, respectively. 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.

舒嘉辉(通信作者), 2023 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: 1043069285@qq.com



Shu Jiahui (Corresponding author) received his B. Sc. degree from Liaoning Technical University in 2023. Now he is a M. Sc. candidate in Liaoning Technical University. His main research interests include electrical contact theory and application, intelligent appliances and smart grid technology.



严灵潇, 2023 年于沈阳工业大学获得学士学位。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: 1932528609@qq.com

Yan Lingxiao received his B. Sc. degree from Shenyang University of Technology in 2023. Now he is a M. Sc. candidate in Liaoning Technical University. His main research interests include electrical contact theory and application, intelligent appliances and smart grid technology.



田浩, 现为辽宁工程技术大学博士研究生, 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: 15714282369@163.com

Tian Hao now is a Ph. D. candidate at Liaoning Technical University. His main research interests include electrical contact theory and application, smart electrical appliances and smart grid technology.