

基于马尔可夫转移场与改进梦境优化算法的 弓网电弧故障检测研究*

李 斌^{1,2} 郑睦译²

(1. 辽宁工程技术大学鄂尔多斯研究院 鄂尔多斯 017000; 2. 辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘 要:弓网电弧故障严重威胁列车安全运行,精准识别此类故障对保障铁路供电系统可靠性至关重要。针对传统方法在复杂工况下识别精度低,且难以兼顾时序与空间特征提取的问题,设计了一种基于马尔可夫转移场(MTF)与改进梦境优化算法的弓网电弧故障检测方法。首先通过鲁棒经验模态分解对原始电流信号去噪,4种工况下去噪信号信噪比均超36 dB、相关系数大于0.985,最大程度保留故障瞬态特征;利用MTF将一维时序信号映射为二维特征矩阵,构建DarkNet19与门控循环单元双支路架构,分别提取深层视觉特征与时序动态特征,实现多模态信息互补;引入改进梦境优化算法对学习率、GRU神经元个数等关键参数自适应寻优,同时优化多头自注意力机制,通过L1稀疏正则化与冗余度自适应动态缩放因子抑制冗余信息;结合迁移学习突破故障样本稀缺限制。实验结果表明,该模型在4种不同工况下故障检测准确率达99.58%,精确率与召回率均超99.5%,较SVM、1D-CNN、ResNet等6种对比模型准确率提升3.75%~6.67%;抗噪声干扰实验中,去噪后检测准确率较含噪信号提升6.71%,展现出更强的鲁棒性,为弓网电弧故障精准诊断提供了有效技术方案。

关键词:马尔可夫转移场;DarkNet19;改进梦境优化算法;迁移学习;平滑开发变异

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

Research on pantograph-catenary arc fault detection based on Markov transition field and improved dream optimization algorithm

Li Bin^{1,2} Zheng Mui²

(1. Ordos Research Institute of Liaoning Technical University, Erdos 017000, China; 2. Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: Pantograph-catenary pantograph-catenary arc faults pose a serious threat to the safe operation of trains, and the accurate identification of such faults is crucial for ensuring the reliability of railway power supply systems. Aiming at the problems that traditional methods have low recognition accuracy under complex working conditions and are difficult to balance the extraction of temporal and spatial features, this paper designs a pantograph-catenary arc fault detection method based on the Markov transition field (MTF) and an improved dream optimization algorithm. First, the original current signal is denoised by robust empirical mode decomposition. The signal-to-noise ratio of the denoised signals under four working conditions is all above 36 dB, and the correlation coefficient is greater than 0.985, which preserves the fault transient characteristics to the greatest extent. Then, the one-dimensional time-series signal is mapped into a two-dimensional feature matrix using MTF, and a dual-branch architecture combining DarkNet19 and Gated Recurrent Unit is constructed to extract deep visual features and temporal dynamic features respectively, realizing multi-modal information complementarity. Furthermore, the improved dream optimization algorithm is introduced to adaptively optimize key parameters such as learning rate and the number of GRU neurons. Meanwhile, the multi-head self-attention mechanism is optimized, and redundant information is suppressed by L1 sparse regularization and an adaptive dynamic scaling factor for redundancy. In addition, transfer learning is integrated to break through the limitation of scarce fault samples. Experimental results show that the proposed model achieves a fault detection accuracy of 99.58% under four different working conditions, with precision and recall both exceeding 99.5%. Compared

收稿日期: 2025-07-29 Received Date: 2025-07-29

* 基金项目: 辽宁工程技术大学鄂尔多斯研究院校地科技合作培育项目(YJY-XD-2023-005)、国家自然科学基金资助项目(51674136)、2024年辽宁省教育厅基本科研项目的(LJ232410147055)资助

with six comparative models including SVM, 1D-CNN and ResNet, the accuracy is improved by 3.75% ~ 6.67%. In the anti-noise interference experiment, the detection accuracy of the denoised signal is 6.71% higher than that of the noisy signal. It exhibits stronger robustness and provides an effective technical solution for the accurate diagnosis of pantograph-catenary arc faults.

Keywords: Markov transition field; DarkNet19; improved dream optimization algorithm; transfer learning; smooth development mutation

0 引言

随着电气化铁路的快速发展,弓网系统作为电能传输的核心部件,其稳定性和可靠性直接关系到列车的安全运行。然而,随着列车运行速度的提升,弓网接触不良导致的电弧现象日益频繁,严重时可能引发供电中断、设备烧损甚至火灾等事故^[1-2]。弓网电弧不仅会损坏接触线和受电弓材料,还会对列车电力驱动系统的可靠运行造成干扰,并带来电磁兼容性问题^[3]。因此,开发高效的弓网电弧故障检测方法,对保障电气化铁路的安全运营具有重要意义。

近年来,国内外学者在弓网电弧的检测与建模方面开展了大量研究。Liu等^[4]提出了一种考虑弓网动态分离过程的扩展黑箱模型,通过引入动态分离轨迹改进了电弧电压和功率耗散的计算精度,但模型对实时数据的适应性不足。Gao等^[5]针对三相变频器负载回路中的串联电弧故障,提出了一种基于实时训练和故障检测残差的检测方法,通过优化极限学习机(ELM)提升了模型在未知工况下的检测性能,但该方法未涉及电弧的时序特征提取。李斌等^[6]提出基于改进黑翅鸢算法(IBKA)的1D-2D-GAF-PCNN-GRU-MSA模型,通过格拉姆角场(GAF)将一维电压信号转换为二维图像,结合双通道CNN与时序GRU特征提取,并引入IBKA优化学习率与网络结构参数。Huang等^[7]利用卷积神经网络(convolutional neural network, CNN)对弓网电弧图像进行分类,实现了电弧的检测与等级识别,未解决动态电弧的时序故障检测问题。此外,高洪鑫等^[8]结合核极限学习机(KELM)和非负矩阵分解(NMF),提出了一种抗噪性强的电弧检测方法,但其特征提取过程依赖于人工设计的阈值,泛化能力有限。高华章等^[9]引入通道注意力机制优化CNN模型,显著提升了模型对关键特征的敏感度,在矿用电机车场景中准确率高达99.73%。上述方法中存在人工设计特征难度大且不全,难以捕捉弓网电弧复杂动态特征和弓网电弧故障数据存在正常样本远多于故障样本的情况,传统方法易受此影响导致过拟合,对稀有故障模式学习能力不足的问题。

因此,本文提出MTF-IDOA-DarkNet-GRU-MSA迁移学习的弓网电弧故障检测方法。该方法通过MTF将一维电流信号转换为二维特征矩阵;引入DarkNet19深度

网络提取矩阵中的视觉特征;通过GRU对电弧电流时序信号进行建模,捕捉故障前后的信号变化趋势,实现视觉特征与时序特征的互补融合;设计改进梦境优化算法,对MTF-DarkNet-GRU中的学习率、GRU层神经元个数等关键超参数进行自适应寻优;通过MSA强化电弧故障关键特征的权重分配,减少冗余信息干扰;采用迁移学习策略,将通用数据集预训练的DarkNet模型参数迁移至弓网场景,解决故障样本稀缺问题,从而实现对弓网电弧故障的准确诊断。

1 基于MTF-DarkNet-GRU-MSA的故障检测理论

1.1 MTF的基本概念

MTF^[10]是一种将一维时间序列信号映射为二维概率矩阵的分析方法,其核心在于利用马尔可夫过程的无后效性,捕捉弓网电弧信号中状态转移的动态特征。

马尔可夫转移概率矩阵:

$$W = \begin{bmatrix} w_{11}P(x_t \in q_1 | x_t \in q_1) & \cdots & w_{1n}P(x_t \in q_1 | x_t \in q_Q) \\ w_{21}P(x_t \in q_2 | x_t \in q_1) & \cdots & w_{2n}P(x_t \in q_2 | x_t \in q_Q) \\ \vdots & \ddots & \vdots \\ w_{n1}P(x_t \in q_Q | x_t \in q_1) & \cdots & w_{nn}P(x_t \in q_Q | x_t \in q_Q) \end{bmatrix} \quad (1)$$

式中: w_{ij} 为分位数 q_i 与分位数 q_j 紧邻的概率。

马尔可夫转移场矩阵:

$$M = \begin{bmatrix} m_{ij} | x_1 \in q_i, x_1 \in q_j & \cdots & m_{ij} | x_1 \in q_i, x_N \in q_j \\ m_{ij} | x_2 \in q_i, x_1 \in q_j & \cdots & m_{ij} | x_2 \in q_i, x_N \in q_j \\ \vdots & \ddots & \vdots \\ m_{ij} | x_N \in q_i, x_1 \in q_j & \cdots & m_{ij} | x_N \in q_i, x_N \in q_j \end{bmatrix} \quad (2)$$

式中: m_{ij} 为分位数 q_i 转移到分位数 q_j 的概率; i 和 j 表示位置索引。

1.2 DarkNet19原理与核心优势

DarkNet19^[11]是DarkNet框架下专为高效特征提取设计的卷积神经网络,设计初衷是为了在保证计算效率的同时,提升模型对图像特征的提取能力,以满足复杂视觉任务的需求。具体结构如图1所示。




图1 Darknet19 网络结构

Fig. 1 Structure of the Darknet19 network

1) DarkNet19 与迁移学习的结合及应用

迁移学习^[12]是一种将从一个任务或领域学到的知识应用到另一个相关任务或领域的机器学习方法,能够有效解决数据稀缺、模型训练耗时等问题。在弓网电弧故障识别研究中,将 DarkNet19 与迁移学习相结合,可显著提升模型的性能和实用性。具体方法框架如图 2 所示。




图2 迁移学习的策略

Fig. 2 Strategies for transfer learning

DarkNet19 与迁移学习的结合主要通过预训练模型的迁移实现。通常,先在大规模通用图像数据集上对 DarkNet19 进行预训练。将预训练好的 DarkNet19 模型迁移到弓网电弧故障识别任务时,采用微调的方式进行模型适配。冻结 DarkNet19 中底层的卷积层参数,这些层主要学习通用的低级特征,在弓网图像中同样具有重要价值。解冻高层的卷积层和全连接层,利用有限的弓网电弧故障图像数据对这些层的参数进行调整。高层网络更关注特定任务的特征学习,通过微调可以使模型逐渐适应弓网电弧的独特特征。

1.3 门控循环单元

门控循环单元 (gated recurrent unit, GRU)^[13] 是循环神经网络 (RNN) 的重要变体,GRU 通过引入门控机制动态调节信息的流动与保留,能够自适应地选择记忆或遗忘历史信息,尤其适用于处理具有时间序列特性的数据。其结构如图 3 所示。




图3 GRU 结构

Fig. 3 GRU structure diagram

GRU 的核心结构包含两个关键门控单元:更新门 (update gate) 和重置门 (reset gate),通过这两个门控的协同作用实现对信息的筛选与传递。

设输入序列为 x_t (t 为时间步),隐藏状态为 h_t ,则各部分的计算公式如下:

重置门 r_t : 用于控制历史隐藏状态 h_{t-1} 对当前候选隐藏状态的影响程度,其值范围为 $[0, 1]$,计算公式为:

$$r_t = \sigma(W_r \times [h_{t-1}, x_t]) \quad (3)$$

式中: W_r 为重置门的权重矩阵; $[h_{t-1}, x_t]$ 表示为将 h_{t-1} 与 x_t 进行拼接; σ 为 softmax 激活函数。当 $r_t \approx 0$ 时,重置门关闭,历史信息被遗忘;当 $r_t \approx 1$ 时,重置门开启,历史信息被保留。

更新门 z_t : 决定当前隐藏状态 h_t 中保留历史隐藏状态 h_{t-1} 和融入当前输入信息的比例,同样取值于 $[-1, 1]$,

1], 公式为:

$$z_t = \sigma(W_z \times [h_{t-1}, x_t]) \quad (4)$$

式中: W_z 为更新门的权重矩阵。 z_t 的值越大, 表明当前隐藏状态更多地保留历史信息; 反之, 则更多地融入当前输入信息。

候选隐藏状态 $\tilde{h}_t$: 基于重置门筛选后的历史信息和当前输入计算得到, 体现当前时刻的新信息, 计算公式为:

$$\tilde{h}_t = \tanh(W_h \times [r_t \odot h_{t-1}, x_t]) \quad (5)$$

式中: W_h 为候选隐藏状态的权重矩阵; $\odot$ 表示元素级乘法; $\tanh$ 为激活函数, 将输出值限制在 $[-1, 1]$ 范围内。

最终隐藏状态 h_t : 由更新门调节历史隐藏状态与候选隐藏状态的融合比例, 公式为:

$$h_t = (1 - z_t) \odot \tilde{h}_t + z_t \odot h_{t-1} \quad (6)$$

式(6)表明, h_t 与 h_{t-1} 的加权组合, 权重由更新门 z_t 动态控制。

1.4 多头自注意力机制

多头自注意力机制 (multi-head self-attention, MSA)^[14] 是基于自注意力机制发展而来的关键模块。

在具体的计算过程中, 首先需要对输入序列进行线性变换。假设输入序列为 $X \in \mathbb{R}^{n \times d_{\text{model}}}$, 其中 n 为序列长度, d_{model} 为输入特征维度。通过 3 个可学习的权重矩阵 $W_Q \in \mathbb{R}^{d_{\text{model}} \times d_k}$ 、 $W_K \in \mathbb{R}^{d_{\text{model}} \times d_k}$ 、 $W_V \in \mathbb{R}^{d_{\text{model}} \times d_v}$, 分别将输入序列映射为查询矩阵 $Q = XW_Q$ 、键矩阵 $K = XW_K$ 和值矩阵 $V = XW_V$, 其中 d_k 为查询和键的维度, d_v 为值的维度。结构如图 4 所示。




图 4 多头自注意力机制

Fig. 4 Multi-head self-attention mechanism structure

为实现多头并行处理, 将 Q 、 K 、 V 分别分割成 h 个头部, 每个头部对应的子矩阵为 $Q_i \in \mathbb{R}^{n \times d_k/h}$ 、 $K_i \in \mathbb{R}^{n \times d_k/h}$ 、 $V_i \in \mathbb{R}^{n \times d_v/h}$ ($i = 1, 2, \dots, h$)。每个注意力头独立计算自注意力, 其计算公式如下:

$$\text{head}_i = \text{Attention}(Q_i, K_i, V_i) \quad (7)$$

$$\text{Attention}(Q_i, K_i, V_i) = \text{softmax}\left(\frac{Q_i K_i^T}{\sqrt{d_k/h}}\right) V_i \quad (8)$$

其中, $\sqrt{d_k/h}$ 是缩放因子, 用于避免因 d_k/h 数值过大导致的 softmax 函数梯度消失问题, 确保注意力权重的计算更加稳定。

在每个头部完成自注意力计算后, 将所有头部的输出进行拼接, 得到 $\text{concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h) \in \mathbb{R}^{n \times d_v}$ 。最后, 通过一个可学习的权重矩阵 $W_O \in \mathbb{R}^{d_v \times d_{\text{model}}}$ 进行线性变换, 得到 MSA 的最终输出:

$$\text{MSA}(X) = \text{concat}(\text{head}_1, \dots, \text{head}_h) W_O \quad (9)$$

2 超参数优化

2.1 梦境优化算法

梦境优化算法 (dream optimization algorithm, DOA)^[15] 是一种受人类梦境行为启发的元启发式优化算法, 其核心思想源于快速眼动睡眠阶段的记忆保留、遗忘和逻辑自组织特性。

(1) 算法流程与关键步骤

DOA 的优化过程分为探索阶段 (初始迭代) 和开发阶段 (后期迭代), 具体步骤如下:

(1) 初始种群生成

在搜索空间内随机生成初始种群 $X = \{x_1, x_2, \dots, x_N\}$, 其中 x_1 表示第 1 个个体, N 为种群大小。每个个体的位置通过公式 $x_i = X_l + \text{rand} \times (X_u - X_l)$ 生成, 其中 X_l 和 X_u 分别为搜索空间的上下边界。

(2) 探索阶段 ($t \leq T_d$)

分组与记忆策略, 将种群分为 5 组, 每组个体在迭代前将位置重置为该组历史最优解 X_{best} 。

遗忘与补充策略, 每组随机选择 k_q 个维度 (遗忘维度), 通过以下公式更新位置:

$$x_{i,j}^{t+1} = \begin{cases} x_{\text{global},j}^t + \text{rand} \times (x_{u,j} - x_{l,j}) \times \left(1 - \frac{t}{T_{\text{max}}}\right) \\ x_{i,j}^t \end{cases} \quad (10)$$

式中: t 为当前迭代次数; T_d 为探索阶段截止的迭代次数; T_{max} 为最大迭代次数。若 j 属于遗忘维度否则 $x_{i,j}^{t+1} = x_{i,j}^t$ 。

梦境共享策略,以概率 u 随机选择其他个体的位置信息进行更新,增强跳出局部最优的能力。

(3) 开发阶段 ($T_d < t \leq T_{\max}$)

全局记忆引导:所有个体共享全局最优解 X_{global} ,并随机选择 k_r 个维度进行更新:

$$x_{i,j}^{t+1} = \begin{cases} x_{\text{global},j}^t + \text{rand} \times (x_{u,j} - x_{l,j}) \times \left(1 - \frac{t}{T_{\max}}\right) \\ x_{i,j}^t \end{cases} \quad (11)$$

该阶段通过减少遗忘维度数量 k_r ,逐步聚焦于局部优化。若 j 属于遗忘维度否则 $x_{i,j}^{t+1} = x_{i,j}^t$ 。

2.2 斑马优化算法

斑马优化算法(zebra optimization algorithm, ZOA)^[16]的核心机制源于斑马种群在自然环境中的双阶段生存策略:觅食阶段的群体协作搜索与防御阶段的捕食者应对策略。鉴于改进后的 DOA 引入了觅食策略,本节将聚焦该算法的觅食阶段展开详细分析,阐明其核心机制与实现逻辑。

觅食阶段:在第一阶段种群成员的更新是基于模拟斑马觅食时的行为。斑马种群中存在“先锋斑马”,其通过吞食高秆、低营养的草类,为群体开辟适合其他个体的觅食区域。该行为对应算法中最优解引导全局搜索的机制,通过种群中适应度最优的个体引导其他个体向优质解区域聚集。觅食阶段的个体位置更新遵循以下规则:

$$X_{i,j}^{P1} = x_{i,j} + r \times (PZ_j - I \times x_{i,j}) \quad (12)$$

$$X_i = \begin{cases} X_i^{P1}, & F_i^{P1} < F_i \\ X_i, & \text{其他} \end{cases} \quad (13)$$

式中: $x_{i,j}$ 表示第 i 个个体在第 j 维的特征值; X_i 为更新后的个体位置; PZ_j 为当前种群中的“先锋斑马”在第 j 维的位置; r 为 $[0,1]$ 的随机数; I 为 $[1,2]$ 的随机系数,用于增强搜索随机性; F_i 为目标函数值,仅当新位置的适应度更优时接受更新。

该阶段通过先锋斑马的引导作用,使种群向当前最优区域聚集,实现局部开发能力。参数 I 和 r 协同控制收敛速度: I 越大,个体向先锋斑马的移动步长越大,收敛加速; r 的随机性则避免个体过度依赖当前最优解,维持一定的搜索多样性。

2.3 改进梦境优化算法

在弓网系统中,电弧故障检测面临着数据复杂、故障特征难以准确捕捉等问题。传统的 DOA 算法在处理此类复杂问题时,可能存在收敛速度慢、易陷入局部最优等不足。为了更有效地应用于弓网电弧故障预测,对 DOA 算法提出以下改进思路。

1) Hammersley 序列

传统 DOA 算法采用随机方式生成初始种群,个体分布可能不均匀,影响算法搜索效率。为解决此问题,引入低差异序列生成初始种群。Hammersley 序列是一种低差

异序列^[17],结合了确定性与均匀分布特性。它通过将 $n(n \in \{0,1,\dots,N-1\}, N$ 为种群大小) 进行 b 进制分解,公式为:

$$n = \sum_{i=0}^{m-1} a_i b^i \quad (14)$$


其中, $a_i \in \{0,1,\dots,b-1\}$ 然后利用 n 和 $\frac{n}{N}$ 构建序列点。

在生成初始种群时,对于种群中的第 i 个个体,第 j 维的数值计算如下:

$$x_{i,j} = x_{l,j} + \frac{i}{N} \times (x_{u,j} - x_{l,j}) \quad (15)$$


式中: $x_{l,j}$ 和 $x_{u,j}$ 分别是第 j 维搜索空间的下界和上界; $\frac{i}{N}$

为 Hammersley 序列在该维度生成的数值。如图 5 所示,相较于随机数, Hammersley 序列生成的个体在搜索空间中分布更为均匀,能显著增加种群多样性,避免初始种群集中在局部区域,为算法后续对弓网电弧故障特征的搜索提供更优起点,提升算法初始阶段对解空间的覆盖效率。



(a) Hammersley序列初始化

(a) Hammersley sequence initialization



(b) 随机初始化

(b) Random initialization

图5 随机数分布

Fig. 5 Random number distribution

引入 Hammersley 序列后,初始种群在搜索空间内的分布更加均匀且具有规律性,避免了因随机初始化导致的种群聚集现象。这种均匀分布特性使得算法在迭代初期就能更全面地覆盖弓网电弧故障特征所在区域,快速捕捉到潜在的故障模式,减少无效搜索步骤。

2) 融入 ZOA 的觅食策略

在传统 DOA 算法中,探索阶段盲目的随机扰动可能导致无效搜索尤其是在远离最优解的区域,较弱的扰动难以跳出局部最优陷阱,因此引入 ZOA 的觅食策略。通过模拟斑马群体在自然界中的觅食行为^[18]。将 IDOA 中的当前最优个体类比为 ZOA 中的领导者斑马,其余个体视为追随者斑马。引入了全局最优引导,减少了搜索的盲目性,使扰动更具有方向性。在觅食过程中,斑马群会根据领导者斑马发现食物资源的分布情况,采用不同的策略进行搜索,并同时更新所有个体的维度向最优解范围靠近。

对于领导者斑马(最优个体),在进行位置更新时,保留 IDOA 中基于动态调整遗忘维度和故障特征引导的更新方式,同时使用 ZOA 领导者位置更新公式替代原本的随机扰动操作,增加对全局搜索空间的探索力度。具体公式为:

$$X_{i,j}^{Pl} = x_{i,j} + r \times (PZ_j - I \times x_{i,j}) \quad (16)$$

式中: $x_{i,j}$ 为个体值; r 为 $[0,1]$ 之间随机数; I 为 $[1,2]$ 之间随机数; PZ_j 为先锋马的位置。

斑马觅食策略通过模拟自然的智能搜索行为,为 DOA 提供了一种高效的探索机制。该策略不仅保持了算法探索能力,还显著提升了搜索效率和收敛质量,尤其适用于高维复杂优化问题。

3) 平滑开发变异

平滑开发变异又称平滑探索系统(smooth exploration system, SES)通过三大机制实现高效探索:无序维度采样、随机交叉和顺序变异^[19]。将其融入 DOA 时,需建立分层融合框架:首先通过无序维度采样确定变异维度集合,再通过随机交叉与顺序变异的双策略生成新个体,最终通过动态参数调节实现探索与开发的平衡。

无序维度采样基于采样理论动态调整参与进化的维度数量,公式为:

$$Rate_{sample} = ceil\left(\max\left(\frac{t}{\max Iter}, \varepsilon_1\right) \times \dim\right) \quad (17)$$

该机制通过控制维度更新数量,避免种群过度聚集,维持搜索空间稀疏性。具体过程是按迭代次数 t 动态计算采样率,确定每次迭代需变异的维度数;采用无放回随机采样选择维度,避免重复选择导致的多样性下降;未选中维度保持不变,减少无效搜索开销。

随机交叉以随机个体为支点扩展搜索范围,新位置

生成公式为:

$$\vec{X}_{new}(t+1) = \vec{X}_{r1} - (\vec{X}_{r3} - \vec{X}_{r2}) \quad (18)$$

式中: $\vec{X}_{r1}$ 、 $\vec{X}_{r2}$ 、 $\vec{X}_{r3}$ 为随机选取的个体,通过向量差运算突破局部最优限制。

顺序变异利用相邻个体的算术平均平滑探索中间区域,公式为:

$$\vec{X}_i(t+1) = \frac{\vec{X}_i(t) + \vec{X}_{i-1}(t)}{2} \quad (19)$$

当 $i = 1$ 种群最后一个个体,确保搜索的连贯性。图 6 为 IDOA 总流程。




图 6 改进梦境优化算法流程

Fig. 6 Flow of the improved dream optimization algorithm

2.4 DOA 算法分析

1) 算法收敛性分析

为了验证 IDOA 算法的优越性,利用基准测试函数对 IDOA、DOA、AOO、SGA、WMA、DE 算法进行对比,结果如图 7 所示。

从图 7 可以看出, IDOA 在准确率上相较于其他优化算法有着显著的提升。函数 F1 和 F2 可评估算法在简单、无多极值场景下的寻优精度与收敛速度,函数 F8 和




图7 函数收敛曲线对比

Fig. 7 Comparison diagram of function convergence

F12 存在多个局部最优值,能检验算法避免陷入局部最优、全局搜索与局部开发的平衡能力。IDOA 通过引入 Hammersley 序列初始化、斑马觅食策略和平滑开发变异,有效平衡了全局搜索和局部搜索能力,避免了算法陷入局部最优解,在复杂的弓网电弧故障特征空间中能够更精准地找到模型的最优参数组合,显著提升了模型的故障检测性能。

2) 算法性能分析

本文通过最优值、标准差和平均值来分析算法的寻优性能。由表 1 可以看出,从单峰测试函数 F1、F2 和多峰测试函数 F8、F12 可以看出,与其他 5 种算法相比, IDOA 算法寻优的能力更强。表明了将 ZOA 中的觅食策略结合进 DOA 中,提高了 DOA 的寻优能力,加入了 Hammersley 序列和平滑开发变异帮助算法能够寻找到全局最优值通过对 IDOA 的评估,算法不仅有较强适应能力,相较于其他对比算法,更不容易陷入局部最优,很好的协调了全局搜索和局部最优的能力。具有更好的收敛速度、收敛精度以及局部极值逃逸能力。

3 基于 IDOA 优化 MTF-DarkNet-GRU-MSA 故障检测模型

3.1 模型检测流程

利用 MTF 将一维时序信号转换为二维特征矩阵,通过刻画信号状态转移的概率分布,在保留时序动态特性的同时,将抽象的电流波动转化为可视化的空间特征。构建双支路特征提取结构:将 MTF 生成的二维特征矩阵输入 DarkNet19 深度网络,通过 19 层卷积与池化操作的交替堆叠,提取电弧故障的深层视觉特征,利用其稀疏连接与权值共享特性减少冗余信息,强化关键特征的响应;同样以 MTF 生成的二维特征矩阵为输入,经扁平化处理,输入 GRU。通过重置门与更新门动态调节,捕捉二维特征矩阵中隐含的时序依赖关系,弥补 DarkNet 对时序动态特征捕捉不足的缺陷。将 DarkNet19 输出的高维空间特征与 GRU 生成的时序特征进行拼接融合,通过特征维度对齐与权重分配,实现空间、时序特征的互补增

强,既保留电弧的形态细节,又兼顾其动态演化规律。针对模型中 DarkNet19 的学习率、GRU 层神经元个数、特征融合权重、正则化系数等,引入 IDOA 进行自适应寻优。同时,引入迁移学习策略:将 DarkNet19 在通用图像数据集上预训练的参数作为初始权重,冻结底层通用特征提

取层,仅微调高层与弓网场景相关的特征层,利用少量标注故障样本实现模型适配,缓解弓网电弧故障样本稀缺的问题,提升模型泛化能力。最后,MSA 对融合特征进行强化,实现对弓网电弧故障的精准检测。总设计如图 8 所示。

表 1 优化算法性能对比

Table 1 Performance comparison of optimization algorithms

函数	指标	IDOA	DOA	AOO	SGA	WMA	DE
F1	最优值	$7.68\ 39\times10^{-100}$	0.048 7	$1.448\ 9\times10^{-5}$	$1.767\ 0\times10^{-6}$	$1.941\ 7\times10^{-10}$	$2.990\ 0\times10^{-4}$
	标准差	$2.119\ 4\times10^{-70}$	0.010 8	$3.476\ 5\times10^{-4}$	0.002 2	$2.524\ 5\times10^{-7}$	$2.022\ 0\times10^{-4}$
	平均值	$9.478\ 6\times10^{-71}$	0.062 6	$3.736\ 8\times10^{-4}$	0.001 2	$2.089\ 8\times10^{-7}$	$5.539\ 2\times10^{-4}$
	最优值	$6.341\ 6\times10^{-52}$	0.065 7	0.002 9	0.007 4	0.005 4	0.001 6
F2	标准差	$1.936\ 7\times10^{-42}$	0.020 4	0.005 2	0.040 9	0.866 2	$5.691\ 4\times10^{-4}$
	平均值	$1.115\ 4\times10^{-42}$	0.094 3	0.007 3	0.035 2	0.404 3	0.002 2
	最优值	$-1.256\ 9\times10^4$	$-1.197\ 7\times10^4$	$-8.142\ 8\times10^3$	$-9.525\ 8\times10^3$	$-9.332\ 0\times10^3$	$-1.065\ 2\times10^4$
F8	标准差	$1.946\ 1\times10^3$	105.890 0	889.192 7	$1.001\ 5\times10^3$	$1.931\ 7\times10^3$	463.302 2
	平均值	$-1.114\ 8\times10^4$	$-1.190\ 6\times10^4$	$-7.014\ 5\times10^3$	$-7.940\ 3\times10^3$	$-6.846\ 3\times10^3$	$-9.906\ 5\times10^3$
	最优值	$4.675\ 9\times10^{-10}$	$9.164\ 7\times10^{-5}$	$1.183\ 9\times10^{-4}$	0.129 5	$1.041\ 0\times10^{-4}$	$1.883\ 3\times10^{-5}$
F12	标准差	$6.111\ 4\times10^{-10}$	$3.408\ 8\times10^{-5}$	$8.240\ 2\times10^{-5}$	0.292 6	6.074 7	$1.884\ 3\times10^{-5}$
	平均值	$1.201\ 5\times10^{-9}$	$1.132\ 9\times10^{-4}$	$2.367\ 3\times10^{-4}$	0.322 0	3.151 2	$4.213\ 5\times10^{-5}$




图 8 MTF-IDOA-DarkNet-GRU-MSA 故障检测模型

Fig. 8 MTF-IDOA-DarkNet-GRU-MSA fault detection model

3.2 特征融合

在多模态特征融合过程中,DarkNet19 视觉支路与 GRU 时序支路的协同设计实现了优势互补:GRU 时序建模擅长捕捉弓网电流信号的动态演变特征,能精准刻画故障发生前后的信号趋势变化,但难以表征信号中隐含的全局空间分布模式;DarkNet19 视觉提取虽能有效挖掘 MTF 二维矩阵中的纹理、形态等空间特征,全面呈现电弧的局部瞬态特性,但对时序维度上的动态关联捕捉不足。正是由于这两种表征方式各具特点又存在互补性,本文通过 DarkNet19-GRU 的多模态融合架构,既能利用 GRU 捕捉时序动态,又能通过 DarkNet19 从空间角度刻画信

号特征。

多模态融合虽能挖掘弓网电弧多维度特征,但易引发特征冗余与冲突,增加模型复杂度并影响诊断精度。为此,本文优化 MSA,通过稀疏注意力权重约束抑制冗余特征,结合动态缩放因子平衡跨模态表征贡献,实现高效特征融合。

为强制注意力权重向核心特征集中,压缩冗余特征的权重分配空间,在 MSA 的损失函数中引入 L1 稀疏正则化项,通过惩罚非零权重的总和,引导模型聚焦关键信息^[20]。其数学表达式如下:

$$Loss_{MAS} = Loss_{base} + \lambda \times \sum_{i,j} |Attention_{i,j}| \quad (20)$$

式中: $Loss_{base}$ 为基础损失函数,采用交叉熵损失,用于衡量模型预测结果与真实故障标签的差异,保障模型的基础分类能力; λ 为正则化系数,由 IDOA 自适应寻优确定,实现基础损失与稀疏约束的动态平衡,避免过度约束导致核心特征丢失; $\sum_{i,j} |Attention_{i,j}|$ 为所有注意力权重的 L1 范数,通过对权重绝对值求和施加惩罚,鼓励模型仅对少量核心故障特征分配高权重,对冗余特征分配趋近于 0 的权重,实现权重分布的稀疏化。

提出基于冗余度自适应动态缩放因子调整策略^[21],使缩放因子与当前特征的冗余强度正相关,通过放大有效特征与冗余特征的权重差异,确保在不同工况下均能稳定抑制冗余。其数学表达式为:

$$\sqrt{d'_k} = \sqrt{d_k} \times (1 + \gamma \times R)$$

(21)

式中: $\sqrt{d_k}$ 为传统 MSA 的固定缩放因子,保障基础权重计算的稳定性; γ 为调节系数,由 IDOA 进行寻优,用于控制冗余度对缩放因子的影响幅度,避免过度调整; R 为冗余度指标,定义为当前输入特征的方差与标准纯故障特征方差的比值,即 $R = \frac{Var(F_{total})}{Var(F_{fault})}$, F_{total} 为当前输入的融合特征, F_{fault} 为实验室标准无噪环境下采集的纯电弧故障特征, R 值越大表明当前特征中冗余干扰越多。

稀疏注意力权重约束通过 L1 正则化实现权重分布的稀疏化,从源头压制冗余特征的干扰,强化核心特征的决策优先级;动态缩放因子调整通过冗余度感知的自适应机制,使 MSA 适配不同工况的冗余差异,保障跨工况下的稳定性能。两大策略协同作用,改善了冗余特征诱导的过拟合问题。

3.3 IDOA 的模型适配

IDOA 作为 MTF-IDOA-DarkNet-GRU-MSA 模型的核心参数优化引擎,针对弓网电弧故障检测中样本稀缺、工况复杂、多模态特征耦合的核心痛点,通过三大关键改进实现场景化创新支撑:引入 Hammersley 低差异序列生成均匀初始种群,避免随机初始化导致的搜索盲区,提升样本稀缺条件下的参数搜索效率;融入 ZOA 的觅食策略,以全局最优解为引导减少搜索盲目性,同时嵌入平滑开发变异机制,通过无序维度采样动态调整迭代维度数量、随机交叉扩展搜索范围、顺序变异平滑探索中间区域,实现全局探索与局部开发的精准平衡,避免种群过度聚集陷入局部最优;同步优化学习率、特征融合权重、正则化系数等多维度参数,适配多模态特征融合的动态需求,且通过高效寻优机制提升模型训练收敛速度与稳定性,抑制噪声干扰导致的伪特征学习,最终成为模型突破传统方法局限、实现高检测准确率的关键驱动力。

4 实验方案及分析

4.1 实验装置

实验装置采用模块化设计,构建弓网电弧模拟系统。机械传动模块由嵌有 120 mm² 纯铜接触线的转盘与水平滑台组成,通过转盘旋转与滑台往复运动实现“Z”字形摩擦轨迹,模拟列车运行时的弓网动态接触。驱动控制模块包含音圈电机与步进电机组合的压力调节系统,以及自耦调压器配合大电流发生器的负荷模拟装置,可精确调控接触压力、滑动速度及接触电流等工况参数。信号采集系统采用 LHB-Y4 型霍尔电流互感器与数据采集卡,结合 LabVIEW 软件实现回路电流、接触电压等电参数的 10 kHz 高频采样与实时监控。环境控制模块通过消声室与电波暗室构建抗干扰实验空间,确保 4 组不同工况下的弓网受流实验数据可靠性,为弓网电弧特征分析提供标准化实验平台。如图 9 所示。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 2 为 20 ℃ 时浸铜碳板和纯铜接触线的物理参数。表 3 为浸铜碳滑板化学成分。




图 9 实验装置
Fig. 9 Experimental setup

表 2 实验条件滑板和接触导线物理参数

Table 2 Slide and contact wire physical parameters		
参数	浸铜碳滑板	接触网导线
密度/(×10 ³ kg·m ⁻³)	3.4	8.9
电阻率/(μΩ·m)	12.32	0.017 5
热导 λ/(W·m ⁻¹ ·K ⁻¹)	15	380
比热/(J·kg ⁻¹ ·K ⁻¹)	660.2	380
硬度(HRD)	56.7	96.2

表 3 为浸铜碳滑板化学成分

Table 3 Chemical composition of copper-impregnated carbon sliding plates

化学成分	碳(C)	铜(Cu)	铅(Pb)	铁(Fe)	其他
含量/%	86.24	3.0	7.1	1.46	2.2

通过调节接触压力、滑动速度及接触电流,模拟不同工况,共设计 4 组实验条件如表 4 所示。每组实验持续运行 10 min,采样频率为 10 kHz,最终采集正常受流与电弧受流状态下的电流信号各 10 万组。

表 4 实验条件

Table 4 Experimental conditions

工况	接触压力/N	滑动速度/(km·h ⁻¹)	接触电流/A
1	70	30	85
2	70	50	85
3	70	50	110
4	100	50	85

4.2 去噪处理

通过上述 4 组实验,得到了 4 组不同工况的弓网电流波形,如图 10 所示。

由上述波形可知。产生电弧故障时,弓网电流波形会发生短暂的零休止现象。在采集弓网运行过程中包含电弧故障及正常状态的原始电信号,这些信号受电磁干扰、环境噪声等影响,存在大量噪声,需进行滤波处理。

本文采用鲁棒经验模态分解 (robust empirical mode decomposition, REMD) 算法对预处理后的信号进行分解^[22-24]。

为量化去噪效果,引入信号处理领域常用的 4 项核心评价指标:信噪比 (signal-to-noise ratio, SNR)、均方根误差 (root mean square error, RMSE)、峰值信噪比 (peak signal-to-noise ratio, PSNR) 和相关系数 (correlation coefficient, CC),各指标定义及物理意义如下:

$$SNR = 10\lg\left(\frac{\sum_{i=1}^N x^2(i)}{\sum_{i=1}^N [x(i) - \hat{x}(i)]^2}\right) \tag{22}$$

式中: $x(i)$ 为去噪后信号; $\hat{x}(i)$ 为噪声分量; N 为信号长度。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N [x_{ture}(i) - x(i)]^2} \tag{23}$$

其中, x_{ture} 为理想真实信号,通过实验室标准无噪环境下采集的弓网电流信号近似替代。

$$PSNR = 10\lg\left(\frac{x_{peak}^2}{RMSE^2}\right) \tag{24}$$

其中, x_{peak}^2 为信号峰值。

CC 描述去噪后信号与理想真实信号的线性相关程度,取值范围为 $[-1, 1]$,越接近 1 表示去噪信号对真实信号的还原度越高,故障特征保留越完整。




图 10 4 种工况下的弓网电流

Fig. 10 Pantograph-catenary current under four working conditions

基于上述指标,对 4 种工况下的去噪效果进行量化评估,结果如表 5 所示。4 种工况下去噪信号的 SNR 均超过 36 dB,PSNR 高于 42 dB,CC 均大于 0.985, RMSE 均低于 0.022,表明 REMD 小波软阈值去噪方法能有效剥离电磁干扰和环境噪声,同时最大程度保留弓网电弧的瞬态故障特征,为后续特征转换和模型训练提供了高质量的输入数据。

表 5 不同工况下信号去噪评价指标

Table 5 Signal denoising evaluation metrics under different operating conditions				
工况	SNR/dB	RMSE	PSNR/dB	CC
1	38.12	0.018 7	43.26	0.989 3
2	37.56	0.019 5	42.89	0.987 6
3	36.89	0.021 3	42.15	0.985 4
4	39.31	0.017 2	44.03	0.991 2

REMD 依据信号自身时间尺度特征,自适应将原始信号分解为一系列本征模态函数和残差信号,以图 11 工况 1 的分解结构为例。IMF1~IMF8 及残差呈现各异波动。IMF1、IMF2 频率高,噪声占比大,表现为剧烈高频震荡;IMF3~IMF5 频率适中,含部分故障暂态特征;IMF6~IMF8 及残差频率低,反映信号趋势与稳定成分。使用小波软阈值法对高频分量进行去噪。通过线性叠加将去噪后的高频 IMF、原始中低频 IMF 和残差重新组合,还原出兼具故障特征与信号趋势的纯净信号。




图 11 REMD 分解结果

Fig. 11 REMD decomposition results

将重构的纯净信号与故障信号进行对比如图 12 所示。图 12(a)原始信号因噪声呈现明显毛刺、波形畸变;图 12(b)去噪信号波形平滑,还原电弧信号真实形态,证明故障特征得以保留。从噪声分量上可以看出,分离出的噪声呈现随机无规律波动,与原始信号的高频干扰一致,验证噪声被有效剥离。而且残差幅值小且围绕 0 值振荡,说明去噪后信号失真度低,故障特征损失少与表 5 的评价指标结果相互印证。为后续模型的弓网电弧故障检测,提供了高质量的输入数据,保障故障检测模型的精度与鲁棒性。




图 12 信号去噪效果对比

Fig. 12 Comparison of signal denoising effects

信号去噪质量是决定弓网电弧故障检测精度与鲁棒性的核心前提,其通过影响故障检测全流程的关键环节,直接作用于最终检测效果。

噪声会导致 MTF 状态转移概率计算失真,故障特征被噪声淹没;本文中高 SNR、低 RMSE 的去噪信号,保障 MTF 精准刻画电弧故障的时序依赖关系,生成的二维特征矩阵能清晰呈现故障状态转换轨迹。DarkNet19 对噪

声敏感,GRU 需平滑的时序输入,而去噪信号的高相关系数,使网络聚焦于电弧故障的形态与时序变化特征,避免噪声引发的过拟合或特征误判。4 种工况下去噪指标的稳 定表现,确保跨工况故障特征的一致性,提升模型在复杂场景下的鲁棒性。

5 MTF-IDOA-DarkNet-GRU-MSA 模型验证

5.1 数据预处理

在进行弓网电弧故障检测前,利用 MTF 对弓网电流时序信号进行特征转换,将一维信号映射为二维特征矩阵^[25],以保留数据的时间依赖关系和周期性特征。为验证 MTF-IDOA-DarkNet-GRU-MSA 模型的高效性以去噪后工况 2 中的实验组为例,进行数据划分如表 6 所示。

表 6 数据划分
Table 6 Data division

状态	类别	训练集	测试集
正常电流	1	70	30
燃弧电流	2	70	30

图 13 和 14 分别为模型训练阶段故障检测准确率与误差随迭代次数的演化规律,均采用极坐标量化:极角 0°~360°对应迭代次数。准确率曲线从极心区域起始,随极角增大呈螺旋式向外扩展并趋近极坐标边界,尤其在极角 90°~270°区间快速攀升,体现 IDOA 驱动下,DarkNet-GRU-MSA 迁移学习框架通过迭代更新权重,对电弧故障的判别能力持续增强,最终趋于稳定收敛;误差曲线则从极心外侧起始,随极角增大呈螺旋式向内收缩并趋近极心,与准确率曲线的变化趋势相呼应,共同验证了模型在训练过程中性能的持续优化,为后续泛化性能评估奠定基础。




图 13 准确率迭代变化曲线
Fig. 13 Accuracy iteration curve




图 14 误差迭代变化曲线
Fig. 14 Error iteration curve

混淆矩阵如图 15 所示,直观呈现了模型对弓网电弧故障识别的效果。检测精确率超过 99%,充分验证模型对弓网电弧故障及正常状态的精准识别能力,误识别样本的低占比,说明模型在复杂工况下仍具备高可靠性,为实际铁路弓网系统故障监测提供了有力技术支撑。如图 16 所示,测试集故障检测结果对比进一步量化模型性能,准确率为 99.167%。真实值与 MTF-IDOA-DarkNet-GRU-MSA 故障检测值的拟合情况显示,绝大多数样本故障检测结果与真实值完全重合,仅极个别样本存在细微偏差。




图 15 去噪后的混淆矩阵
Fig. 15 Confusion matrix after denoising

5.2 噪声干扰对比

为进一步验证信号去噪对最终故障检测结果的影响,将未进行去噪处理的工况 2 中的数据组,以相同的数




图 16 测试集预测结果

Fig. 16 Prediction results of the test set

据划分通过混淆矩阵判断其精确识别能力。

如图 17 所示,经对比实验证实,原始含噪信号输入模型时,最终检测准确率仅 92.87%、误判率 7.13%;经高质量去噪后如图 15 所示,无效噪声被剥离、故障特征被保留,最终检测准确率超过 99%、误判率低于 1%,充分说明去噪通过减少特征失真、抑制噪声干扰,直接转化为最终故障检测的精准度提升。




图 17 未去噪声的混淆矩阵

Fig. 17 Confusion matrix without noise reduction

5.3 消融实验分析

为验证 MTF-IDOA-DarkNet-GRU-MSA 模型中各核心组件的独立贡献及必要性,进一步明确组件间的协同作用机制。设计 6 组消融实验,通过逐步去除模型中的不同组件,比较不同情况下的预测结果。表 7 是消融实验的结果。

通过消融对比实验的结果可以看出,MTF-IDOA-DarkNet-GRU-MSA 融合模型的预测精度明显优于其他单

一模型或部分去除某一模块的模型。移除 MTF 后模型综合性能降幅最为显著,因为弓网电流一维时序信号的动态依赖关系无法通过直接输入转化为可被深度网络捕捉的空间特征,导致 DarkNet19 缺乏有效视觉特征输入,GRU 的时序建模也失去可靠数据支撑,凸显了 MTF“时序-空间”特征映射对复杂电弧信号表征的核心作用。移除 IDOA 后准确率降至 97.15%,表明传统固定参数设置易使模型陷入局部最优,而 IDOA 对学习率、GRU 神经元个数等关键参数的自适应寻优,是保障特征提取与时序建模协同效率的重要前提。DarkNet19 与 GRU 的移除分别导致准确率降至 95.42%和 96.83%,证明了双支路特征提取的互补优势;DarkNet19 挖掘的电弧形态、纹理等高级语义特征,与 GRU 捕捉的故障前后信号动态趋势形成有效互补,单一特征模态难以实现复杂故障模式的精准识别。移除 MSA 后准确率为 98.33%,模型对噪声干扰的抑制能力减弱,部分微弱故障特征被冗余信息掩盖。

表 7 消融实验性能对比

Table 7 Performance comparison of ablation experiments				
故障诊断模型	准确率/%	精确率/%	召回率/%	F1 分数
移除 MTF	94.18	93.70	94.00	93.85
移除 IDOA	97.15	97.03	97.21	97.12
移除 DarkNet19	95.42	95.25	95.55	95.40
移除 GRU	96.83	96.71	96.69	96.70
移除 MSA	98.33	98.36	98.30	98.33
本文模型	99.58	99.62	99.55	99.58

综上,消融实验结果表明,MTF、IDOA、DarkNet19、GRU、MSA 各组件分别在特征转换、参数优化、视觉提取、时序建模、关键特征强化环节发挥独特作用,且组件间形成的“特征转换-双模态提取-参数优化-关键特征强化”闭环协同机制,是模型突破传统方法局限、实现 99.58%高检测准确率的核心原因,也验证了所提融合模型架构设计的科学性与合理性。

5.4 模型对比

为进一步凸显本文所提故障诊断模型的性能优越性,实验分别选取 3 组单模态消融变体模型与另外 3 组常见模型 SVM、1D-CNN、ResNet 在相同环境和数据集下进行对比分析,表 8 为数据集划分。

表 8 实验数据划分

Table 8 Experimental data division				
实验	状态	类别	训练集	测试集
实验一	正常	1	70	30
	燃弧	2	70	30
实验二	正常	3	70	30
	燃弧	4	70	30
实验三	正常	5	70	30
	燃弧	6	70	30
实验四	正常	7	70	30
	燃弧	8	70	30

为更直观地展示模型性能差异,绘制了各个模型的混淆矩阵如图 18 所示,并整理出准确率双环图如图 19 所示。直观对比了本文 MTF-IDOA-DarkNet-GRU-MSA 模

型与 6 种对比模型的故障检测准确率。本文模型准确率达 99.583%,显著高于其他模型,表现最优。SVM 准确率最低,难以适配电弧信号的非线性时序特性;1D-CNN、




图 18 各模型测试结果

Fig. 18 Test results of each model




图 19 模型测试结果
Fig. 19 Model test results

ResNet 受限于单模态特征,无法充分挖掘时序、空间融合信息,性能提升有限。3 种消融变体准确率均低于完整模型;MTF-IDOA-DarkNet-GRU 验证了 MSA 的冗余抑制作用;MTF-IDOA-GRU-MSA、IDOA-DarkNet-GRU-MSA 凸显了 DarkNet19 视觉提取与 MTF 时序、空间转换的核心价值。

6 结 论

本文针对弓网电弧故障检测难题,提出了基于 MTF-IDOA-DarkNet-GRU-MSA 迁移学习的融合检测模型,经系统研究与实验验证表明,该模型采用 REMD 对原始弓网电流信号进行去噪处理,通过自适应分解与小波软阈值去噪策略,有效剥离电磁干扰与环境噪声,4 种工况下去噪信号的 SNR 均超 36 dB、CC 大于 0.985,在最大程度保留电弧瞬态故障特征的同时,为后续特征转换与模型训练提供了高质量输入,显著降低了噪声对故障检测的负面影响。通过 MTF 将弓网电流一维时序信号转化为二维特征矩阵,构建“时序-空间”特征映射,为深度模型提供适配输入;DarkNet19 与 GRU 双支路协同提取视觉与时序特征,弥补单一模型对多模态信息捕捉的不足;IDOA 精准优化关键参数,提升模型收敛效率与特征拟合能力;迁移学习通过 DarkNet19 通用预训练突破弓网故障样本稀缺限制,快速适配任务场景;MSA 动态强化故障关键特征,抑制噪声干扰,最终形成“转换-提取-优化-迁移-识别”的完整闭环,有效解决了复杂工况下弓网电弧故障识别难题。最后,与其他 6 种模型进行弓网电弧故障检测,该方法的故障检测准确率达到 99.58%,较单模态消融变体模型与另

外 3 组常见模型有着显著提升,在抗噪声干扰方面也表现出显著优势。

参考文献

[1] 李兴文,张照资,杨皓文,等. 低压直流电弧检测与分断技术研究综述[J]. 电器与能效管理技术,2024(8): 1-10.
LI X W, ZHANG ZH Z, YANG H W, et al. A review of research on low-voltage DC arc detection and analysis technology [J]. Electrical Appliances & Energy Efficiency Management Technology, 2024(8): 1-10.
[2] 陈忠华,李兵红,陈明阳,等. 弓网滑动电接触电磁热力耦合效应研究进展[J]. 电工技术学报, 2023, 38(10): 2777-2793.
CHEN ZH H, LI B H, CHEN M Y, et al. Research progress on electromagnetic-thermal-mechanical coupling effect of pantograph-catenary sliding electrical contact[J]. Transactions of China Electrotechnical Society, 2023, 38(10): 2777-2793.
[3] 张昱航,魏志恒,周于翔,等. 城市轨道交通弓网燃弧研究进展与展望[J]. 城市轨道交通研究, 2025, 28(3): 25-28, 34.
ZHANG Y H, WEI ZH H, ZHOU Y X, et al. Research progress and prospect of pantograph-catenary arcing in urban rail transit[J]. Urban Mass Transit, 2025, 28(3): 25-28, 34.
[4] LIU Z, ZHOU H, HUANG K, et al. Extended black-box model of pantograph-catenary detachment ARC considering pantograph-catenary dynamics in electrified railway[J]. IEEE Transactions on Industry Applications, 2019, 55(1): 776-785.

- [5] GAO H, WANG K, WANG Z, et al. Detection method of series arc fault in three-phase frequency converter load circuit under unknown working conditions [J]. IEEE Transactions on Power Electronics, 2024, 39 (7): 8743-8755.
- [6] 李斌,舒嘉辉,严灵潇,等.改进黑翅鸢算法的1D-2D-GAF-PCNN-GRU-MSA 弓网电弧检测应用[J]. 电子测量与仪器学报,2024,38(10):201-211.
LI B, SHU J H, YAN L X, et al. Application of 1D-2D-GAF-PCNN-GRU-MSA for pantograph-catenary arc detection based on improved black-winged kite algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(10):201-211.
- [7] HUANG S, CHEN W, SUN B, et al. Arc detection and recognition in the pantograph-catenary system based on multi-information fusion [J]. Transportation Research Record,2020,2674(10):229-240.
- [8] 高洪鑫,王坤远,王智勇,等.三相变频器回路串联故障电弧检测方法研究[J]. 电子测量与仪器学报, 2025,39(1):203-215.
GAO H X, WANG K Y, WANG ZH Y, et al. Research on series fault arc detection method for three-phase inverter circuit[J]. Journal of Electronic Measurement and Instrumentation,2025,39(1):203-215.
- [9] 高华章,郭凤仪,赵奇,等.基于CNN和通道注意力机制的矿用电动机弓网电弧检测方法[J/OL]. 温州大学学报(自然科学版),1-11[2026-04-22]. <https://doi.org/10.20108/j.wzun.202402004>.
GAO H ZH, GUO F Y, ZHAO Q, et al. A pantograph-catenary arc detection method for mine locomotives based on cnn and channel attention mechanism[J/OL]. Journal of Wenzhou University (Natural Sciences), 1-11 [2026-04-22]. <https://doi.org/10.20108/j.wzun.202402004>.
- [10] 钱倍奇,陈谦,李宗源,等.基于马尔可夫转换场与多头注意力机制的电能质量扰动分类方法[J]. 电网技术,2024,48(2):721-733.
QIAN B Q, CHEN Q, LI Z Y, et al. A power quality disturbance classification method based on markov transition field and multi-head attention mechanism[J]. Power System Technology,2024,48(2):721-733.
- [11] 张龙至.面向低亮度抓取目标的机器人视觉定位方法研究[D]. 哈尔滨:哈尔滨工业大学,2022.
ZHANG L ZH. Research on robot visual positioning method for low-light grasping targets[D]. Harbin:Harbin Institute of Technology, 2022.
- [12] 蒋尚俊,易辉,李红涛,等.基于迁移学习与 ResNet 的太阳电池缺陷检测方法[J]. 太阳能学报,2023, 44(7):116-121.
- JIANG SH J, YI H, LI H T, et al. A solar cell defect detection method based on transfer learning and ResNet[J]. Acta Energiæ Solaris Sinica,2023,44(7):116-121.
- [13] 范竞敏,贺广林,王新刚,等.基于 VMD-TCN-GRU-AM 的超短期风电预测[J]. 太阳能学报,2025,46(6): 538-547.
FAN J M, HE G L, WANG X G, et al. Ultra-Short-Term wind power prediction based on VMD-TCN-GRU-AM[J]. Acta Energiæ Solaris Sinica, 2025,46(6): 538-547.
- [14] 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-Optimized SVM[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(3):123-129.
- [15] LANG Y, GAO Y. Dream optimization algorithm (DOA): A novel metaheuristic optimization algorithm inspired by human dreams and its applications to real-world engineering problems [J]. Computer Methods in Applied Mechanics and Engineering, 2025, 436: 117718-117718.
- [16] 冉谊,毛若华,司仪涵,等.斑马优化算法的收敛性分析[J]. 重庆师范大学学报(自然科学版),2025, 42(2):29-37.
RAN Y, MAO R H, SI Y H, et al. Convergence analysis of zebra optimization algorithm [J]. Journal of Chongqing Normal University (Natural Science Edition), 2025,42(2):29-37.
- [17] 李梓源,于剑桥,李佳讯.基于 H-BSO 算法的导弹敏捷转弯弹道优化[J]. 战术导弹技术,2023(3):32-41.
LI Z Y, YU J Q, LI J X. Trajectory optimization for missile agile turning based on H-BSO algorithm [J]. Tactical Missile Technology, 2023(3):32-41.
- [18] 刘艳冬,刘滢,卢兰萍,等.基于 ZOA-CNN-GRU 模型的煤层底板突水等级预测[J]. 中国煤炭,2024, 50(6):44-51.
LIU Y D, LIU Y, LU L P, et al. Prediction of coal seam floor water inrush grade based on ZOA-CNN-GRU Model[J]. China Coal,2024,50(6):44-51.
- [19] WU L, CHEN E Q, GUO Q, et al. Smooth exploration system: A novel ease-of-use and specialized module for improving exploration of whale optimization algorithm[J]. Knowledge-Based Systems,2023,272:110580.
- [20] ZHANG J, ZHAO Y, LI H , et al. Attention with sparsity regularization for neural machine translation and summarization[J]. IEEE/ACM Transactions on Audio,

2019,27(3):507-518.

[21] DING S, WANG Q, GUO L, et al. Wavelet and adaptive coordinate attention guided fine-grained residual network for image denoising[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2024, 34 (7): 6156-6166.

[22] 姚丹,孙敏,李睿敏,等. 改进的经验模态分解方法和解析能量算子在电机轴承故障诊断中的应用[J]. 计算机测量与控制,2024,32(8):72-77,85.
YAO D, SUN M, LI R M, et al. Application of improved empirical mode decomposition method and analytic energy operator in motor bearing fault diagnosis[J]. Computer Measurement & Control,2024,32(8):72-77,85.

[23] 陈蕤峰,王贺,李岩,等. 组合两步分解和 ARIMA-LSTM 的短期风速预测研究[J]. 太阳能学报,2024, 45(2):164-171.
CHEN H F, WANG H, LI Y, et al. Research on short-term wind speed prediction combining two-step decomposition and ARIMA-LSTM [J]. Acta Energiæ Solaris Sinica,2024,45(2):164-171.

[24] 乔松博,孙瑜,胡海,等. 基于 REMD-CNN-Transformer-LSTM 组合模型的碳排放交易价格预测[J]. 西安理工大学学报,2025,41(2):186-196.
QIAO S B, SUN Y, HU H, et al. Carbon emission trading price prediction based on REMD-CNN-Transformer-LSTM combined model[J]. Journal of Xi'an University of Technology,2025,41(2):186-196.

[25] 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), 2022:858-862.

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.



郑睦译(通信作者),2024 年于郑州工商学院获得学士学位。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: 13803308068@163.com

Zheng Mui (Corresponding author) received his B. Sc. degree from Zhengzhou Technology and Business University in 2024. Now he is a M. Sc. candidate at Liaoning Technical University. His main research interests include electrical contact theory and applications, as well as intelligent electrical apparatus and smart grid technology.