

DOI:10.19650/j.cnki.cjsi.12615088

基于多策略融合的电缆接头故障诊断方法*

李 斌, 蒋 鑫

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘 要:交联聚乙烯(XLPE)电缆的设计使用寿命通常为30~40年,部分较早城市化地区的电缆寿命逐步逼近极限,故障频发,严重影响电力系统的可靠性。电缆接头是电缆线路的薄弱环节,其故障约占故障总量的31%。针对上述特点,提出了一种基于改进杜鹃鲶鱼优化算法(ICCOA)的多策略融合(AKF-MTF-GADF-ViT-BiLSTM)电缆接头故障诊断模型。模型首先使用自适应卡尔曼滤波(AKF)对原始数据进行降噪、还原处理,有效抑制了采集现场的环境扰动和传感器抖动产生的非线性干扰;再利用时序马尔可夫转换场(MTF)和差分格拉姆角场(GADF)捕捉数据的动静态融合特征;结合双路视觉Transformer(ViT)提取特征多维度关联信息;最后输入双向长短期记忆网络(BiLSTM)学习空间特征与时序依赖关系,最终得到模型故障诊断结果。引入改进杜鹃鲶鱼算法整定ViT-BiLSTM模型的前馈网络隐藏单元数、注意力头数量、衰减因子等参数,解决原始模型收敛速度慢、过拟合等问题。所提模型结合实验平台实测数据与SolidWorks Simulation仿真数据开展多故障诊断验证,综合诊断准确率达95.1%,较无滤波的消融模型提升24.8%,较两个单模特征提取的消融模型分别提升31.9%和17.0%,较1D-CNN-BiLSTM、CNN-LSTM、VGAF-CLT这3类行业主流模型最高提升10.9%,解决了单一模型普适性不足、难以精准识别多类型电缆故障的行业技术难题。

关键词: 电缆接头;故障诊断;改进杜鹃鲶鱼优化;ViT-BiLSTM 模型

中图分类号: TM246.5 TH89 **文献标识码:** A **国家标准学科分类代码:** 520.30

Multi-strategy fusion-based fault diagnosis method for cable joints

Li Bin, Jiang Xin

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

Abstract: The designed service life of cross-linked polyethylene (XLPE) cables is typically 30~40 years. The service life of cables in some early urbanized areas is gradually approaching this limit, leading to frequent faults that seriously impair the reliability of power systems. Cable joints are the weak link in cable lines, and their faults account for approximately 31% of all cable faults. In response to the above characteristics, this paper proposes a multi-strategy fusion cable joint fault diagnosis model (AKF-MTF-GADF-ViT-BiLSTM) based on the improved cuckoo-catfish optimization algorithm (ICCOA). First, the model uses adaptive Kalman filtering (AKF) to perform denoising and restoration processing on the original data, which effectively suppresses the nonlinear interference caused by environmental disturbances at the acquisition site and sensor jitter. Then, Markov transition field (MTF) and gramian angular difference field (GADF) are utilized to capture the dynamic and static fusion features of the data. A dual-path Vision Transformer (ViT) is adopted to extract the multi-dimensional correlation information of the features. Finally, the processed features are input into a bidirectional long short-term memory network (BiLSTM) to learn the spatial features and temporal dependencies, yielding the final fault diagnosis results. In this article, ICCOA is introduced to tune parameters such as the number of feedforward network hidden units, the number of attention heads, and the decay factor of the ViT-BiLSTM model. This optimization addresses the problems of slow convergence and overfitting of the original model. The proposed model is verified for multi-fault diagnosis using measured data from an experimental platform and simulation data from SolidWorks Simulation. The overall diagnostic accuracy reaches 95.1%, which is 24.8% higher than that of the ablation model without filtering, 31.9% and 17.0% higher than those of the two ablation models with single-mode feature

收稿日期:2026-03-30 Received Date: 2026-03-30

* 基金项目:2024 年辽宁省教育厅基本科研项目(LJ232410147055)资助

extraction respectively, and up to 10.9% higher than the three mainstream industry models of 1D-CNN-BiLSTM, CNN-LSTM, and VGAF-CLT. These results demonstrate that the proposed method effectively overcomes the limited generalizability of single models and improves the accurate identification of multiple cable joint fault types.

Keywords: cable Joint; fault diagnosis; improved cuckoo catfish optimization; ViT-BiLSTM model

0 引言

随着我国城市化进程加快,电力电缆因其隐蔽简洁、安全稳定,正逐步取代传统架空电力线,成为城市电能输送的骨干。我国电力电缆行业的产值位列全球首位,在国内制造业中排名第二^[1]。截至2023年底,我国电缆的敷设里程已超过 2.5×10^6 km,其中交联聚乙烯(cross-linked polyethylene, XLPE)电缆已经占据所有绝缘电力电缆中98%以上,相比于传统的聚氯乙烯, XLPE 电缆不仅绝缘性能更优越、耐高温能力更强,还具备更出色的机械强度,且安装维护也更便捷^[2]。一般 XLPE 电力电缆的设计使用寿命在30~40年,上世纪90年代前后敷设的电缆正逐步进入故障高发期^[3]。电缆故障直接威胁电网的可靠性,还可能引发大规模的停电事故和设备损毁,对社会经济运行产生严重的影响。因此检测全面、通用性强的电缆故障诊断方法是预防电缆故障、保障电力系统安全稳定运行的必然选择。

传统的电缆故障诊断技术大多集中在局放电压、绝缘电阻、电缆切片、电树枝以及建立等价热路模型等方面^[4-5]。以上方法存在依赖高精度传感器、检测针对性不强、数据解析难度大、故障后需被动排查等缺陷。近年来,电缆故障诊断技术更聚焦将海量采集数据进行特征提取,强化数据特征后,经神经网络模型学习诊断电缆故障。如Naji等^[6]提出的基于量子行为未来搜索算法的人工神经网络模型(quantum-behaved future search algorithm with artificial neural network, QFSA-ANN),在仿真中高效定位电缆故障点; Momtasseem等^[7]提出利用加速度传感器的振动信号,结合长短期记忆的卷积神经网络模型(convolutional neural network-long short-term memory, CNN-LSTM)识别电缆早期故障; Lin等^[8]使用长短期记忆的图神经网络模型(graph neural network-long short-term memory, GNN-LSTM)识别泄漏电流特征图谱,进行电缆护套缺陷诊断;孙抗等^[9]提出深度卷积的对抗神经网络(convolutional neural network-deep convolutional generative adversarial network, CNN-DCGAN)的电缆局部模式识别方法,将局放时域信号特征提取为灰度图像,使用DCGAN优化样本并用CNN识别电缆放电,成功提高了电缆局放模式识别率; Wang等^[10]使用一维卷积的双向长短期记忆神经网络(1-dimensional convolutional neural network-bidirectional long short-term memory, 1D-

CNN-BiLSTM)模型在仿真环境下高效识别电缆多种短路;陈新岗等^[11]提出集成增强K最近邻(K-nearest neighbors, KNN)算法识别拉曼光谱诊断电缆老化状态;李练兵等^[12]提出的变分模态分解格拉姆角场和混合卷积时序网络算法(variational mode decomposition gram angle field-convolutional LSTM Transformer, VGAF-CLT),利用VGAF二维化历史故障数据并导入CLT完成电缆故障识别。这些方法可以很好的辨别同一类故障。但普适性不足,难以通过单一模型精准识别多类电缆状态,如:老化等性能性故障、短路等中断性故障以及正常状态。

针对上述方法存在的局限性,本文提出基于改进杜鹃鲶鱼算法优化的多策略融合故障诊断模型,对电缆接头进行高效故障诊断。接头处是电缆整体的薄弱环节,故障集中。据全国XLPE电力电缆运行故障数量的统计分析表明,电缆接头故障约占电缆运行故障总数的31%,且多发生于夏季^[13-14]。接头易发生外部机械损伤、高温热老化、绝缘层熔解损坏,损坏进一步导致绝缘层龟裂、缺损、漏电、短路以及绝缘电压下降^[15-17]。同时电缆接头处接触电阻远大于电缆本体,老化速度大于电缆本体可以提前反映电缆故障的演变过程。通过检测接头运行状态可以很好地反映电缆整体运行状态。本文模型可有效诊断三大类运行状态:导致电力传输中断的中断性故障状态、暂不影响系统运行的性能性故障状态,以及正常运行状态。上述类别可细分为7个具体运行状态,分别为电缆接头断路、短路、漏电、热老化、破损、检测设备安装异常以及运行正常。

模型首先通过自适应卡尔曼滤波(adaptive Kalman filter, AKF)对原始数据进行预处理,有效过滤传感器噪声;随后采用时序马尔可夫转换场(Markov transition field, MTF)和差分格拉姆角场(gramian angular difference field, GADF)对滤波时序数据进行多角度的融合二维特征提取,充分挖掘特征深层关联信息;所获二维化特征输入注意力机制的视觉循环神经网络(vision Transformer-bidirectional long short-term memory, ViT-BiLSTM),实现对电缆接头的运行状态的诊断。为了高效确定模型的前馈网络隐藏单元数、初始学习率以及注意力头数量等参数,创新使用由模拟退火搜索、莱维飞行控制以及精英个体引导重生策略改进的杜鹃鲶鱼优化算法整定相关参数。同时所提模型还与无滤波模型MTF-GADF-ViT-BiLSTM、单特征提取的消融模型MTF-ViT-BiLSTM、GADF-ViT-BiLSTM以及其他行业优秀模型1D-CNN-BiLSTM、CNN-LSTM、VGAF-CLT进行性能对比,结果显

示本文模型对模型的故障诊断率达 95.1%,高于其他模型,测试函数验证和对实验数据分析的结果均证实,该模型具有更优秀的诊断能力。

1 电缆接头故障实验

本文搭建了一套实验型故障模拟数据采集平台,同时利用该平台获取的故障数据,建立并校准 Solidworks Simulation 热力学仿真模型,扩充更多不易模拟的数据,保证数据的完整性。

1.1 故障特征选取

电缆发生中断性故障前有着较长时间的性能性故障。性能性故障以电缆接头老化和破损为主。老化主要表现为电缆接头的异常发热,稳态温度较高且升温速度加快。破损以表皮龟裂、缺损以及内部气隙为主。破损绝缘层比正常状态薄,在散热性能上表现更优异,导致局部温度降低。但当出现严重破损或者老化严重时会出现一定程度的温度升高,同时伴随着少量漏电^[5,18]。所以性能性故障检测围绕稳态温度、升温速度以及少量漏电电流展开。中断性故障发生的瞬间,会产生异常的大电流、漏电值,电缆上下游的空开或漏电保护器会直接切断电路造成电压电流振荡。中断性故障诊断以接头处电压、电流和漏电的变化为主。最特殊的故障是检测设备安装异常,安装异常时检测数据会出现长时间的电流正常、电压值反复振荡或长时间归零的情况,但系统保持正常运行,该故障以电压电流配合检查为主。

综上所述,需要诊断电缆断路、短路、漏电、热老化、破损、检测设备安装异常及正常运行 7 种状态时,选取电缆接头处的稳态表面温度、升温速度、漏电电流和电压、电流变化为主要故障特征参数。

1.2 实验平台设计

本文针对电缆接头的故障模拟平台如图 1 所示。




图 1 电缆接头故障模拟平台示意图

Fig. 1 Diagram of the cable joint fault simulation platform

该平台通过控制无线遥控空开和故障模拟电路模拟系统断路、短路和漏电的中断性故障;使用不同程度老

化、破损的电缆样品模拟性能性故障;调整阻性负载模拟不同电流下的工作状态。平台交流源选取定制的 TDGC2 交流自耦变压器,电缆选取荣缆的 XLPE2.5 mm² 电缆,其物理性能参数如表 1。

表 1 XLPE 电缆物理参数

Table 1 Physical parameters of XLPE cables

规格	导体绞合外	最大导体电阻	参考允许载流
2.5 mm ²	2.06 mm	7.6 mΩ	25 A

使用该电缆制备电缆样本。数据采集使用自制的电缆接头数据采集设备,设备如图 2 所示。




图 2 数据采集设备示意图

Fig. 2 Diagram of data acquisition equipment

该设备负责采集电缆接头的电压、电流、漏电大小、电缆表面运行温度、升温速度以及运行环境温湿度等参数,并通过蓝牙串口或 Wi-Fi 同步网络时间后上传至上位机。

数据采集设备使用福禄克 17BMAX、人民电气 RE-Y5013HE 和 MIJIALYWSD03 对电压、电流、红外温度以及温湿度传感器进行校准,设备红外传感器采集的原始温度差数据如图 3 所示。




图 3 原始温度差数据

Fig. 3 Original temperature difference data

图 3 中红外传感器数据受空气对流系数、传感器精度和机械振动等因素干扰较大,存在大量的非线性波动,原始数据波动明显。需对原始数据进行滤波处理,才能更好地还原接头处的真实状态。

1.3 仿真模型搭建

为了得到更丰富的电缆接头数据,模拟更多极端条件数据。建立 Solidworks Simulation 热力学模型扩充样本数据集。经过对电缆等比例建模,反复调整模型材料的导热系数、阻抗,以及环境的对流系数等参数,得到以下较为可靠的热力学模型,原始数据、滤波数据和仿真温度误差较小。如图 4 所示,左侧为电缆接头稳态温度分布图,右侧为接头表面升温曲线。稳态即接头发热与散热达到平衡的稳定状态,暂态则是表面未达到热平衡的瞬时状态。




图 4 电缆接头稳态温度分布和升温曲线图

Fig. 4 Steady-state temperature distribution and temperature rise curve of the cable joint

在仿真模型中,通过改变铜芯的发热水平模拟不同电流条件;改变电缆外皮的形状模拟不同类型和程度的破损;改变导体电阻和绝缘材料导热率模拟电缆材料的老化。部分不同运行状态仿真稳态结果如图 5 所示。





图 5 不同运行状态仿真稳态结果

Fig. 5 Steady-state results graphs of different operation status simulations

图 5(a) 依次加深龟裂程度;图 5(b) 依次加大局部缺失范围;图 5(c) 依次扩大内部气隙。如图 5(a) ~ (c) 依次变化所示,电缆表皮破损越严重,表皮散热性能越好,表皮温度将伴随一定程度的降低,但当表皮出现明显的露铜时,露铜区域局部温度将明显高于其他部位。图 5(d) 依次为正常运行、老化运行、短路和断路状态。老化状态运行时升温速度和稳态温度高于正常状态,且明显低于短路的大电流状态。系统断路时,电缆表面温度将逐渐恢复至环境温度值,且电流归零。

2 多策略融合诊断模型

2.1 数据特征提取

原始采集数据受到环境限制,数据中存在大量的非线性干扰。如何精准地过滤掉干扰,并高效区分数据特征,是诊断故障的核心。本文采用自适应卡尔曼算法对采集数据进行降噪还原处理;再使用时间序列马尔可夫转换场和差分格拉姆角场进行融合一维时序特征提取,多角度识别故障特征。

1) 自适应卡尔曼滤波

卡尔曼滤波通过采集数据最小化估计误差的协方差实现对系统状态的最优估计^[19]。自适应卡尔曼滤波能够实时修正测量噪声和预测噪声,结合滑动窗口内新息序列的统计特性实时更新噪声参数,提升滤波器的鲁棒性和准确性。滤波算法分为预测和更新两个部分。

预测阶段使用预测方程推演数据,并用协方差对预测结果进行评价如式(1)所示。

$$\begin{cases} \bar{\mathbf{x}}_k = \mathbf{F} \times \bar{\mathbf{x}}_{k-1} + \mathbf{B} \times \mathbf{u}_k \\ \bar{\mathbf{p}}_k = \mathbf{F} \times \bar{\mathbf{p}}_{k-1} \times \mathbf{F}^T + \mathbf{Q}_k \end{cases} \quad (1)$$

式中: $\bar{\mathbf{x}}_k$ 为当前的预测值; $\mathbf{F}$ 为状态转移矩阵; $\bar{\mathbf{x}}_{k-1}$ 为一个时刻的最优估计值; $\mathbf{B}$ 为控制矩阵; $\mathbf{u}_k$ 为输入量。 $\bar{\mathbf{p}}_k$ 为当前时刻预测值的协方差矩阵; $\bar{\mathbf{p}}_{k-1}$ 为上一时刻的最优估计协方差矩阵。

自适应优化后的过程噪声协方差修正预测方程,如式(2)所示。

$$\mathbf{Q}_k = \frac{1}{N} \sum_{i=k-N+1}^k \Delta \mathbf{x}_i \Delta \mathbf{x}_i^T + \mathbf{P}_k - \mathbf{F} \mathbf{P}_{k-1} \mathbf{F}^T \quad (2)$$

式中: $\mathbf{Q}_k$ 为预测噪声的协方差矩阵; $\Delta \mathbf{x}_i = \mathbf{x}_i - \mathbf{F} \mathbf{x}_{i-1}$ 为状态残差。

更新阶段包含卡尔曼增益计算、状态方程和协方差更新如式(3)所示,自适应的测量噪声协方差修正公式如式(4)所示。

$$\begin{cases} \mathbf{K}_k = \frac{\bar{\mathbf{p}}_k \times \mathbf{H}^T}{\mathbf{H} \times \bar{\mathbf{p}}_k \times \mathbf{H}^T + \mathbf{R}_k} \\ \hat{\mathbf{x}}_k = \bar{\mathbf{x}}_k + \mathbf{K}_k \times (\mathbf{Z}_k - \mathbf{H} \times \bar{\mathbf{x}}_k) \\ \bar{\mathbf{P}}_k = (1 - \mathbf{K}_k \times \mathbf{H}) \times \bar{\mathbf{P}}_k \end{cases} \quad (3)$$

$$\mathbf{R}_k = \frac{1}{N} \sum_{i=k-N+1}^k \mathbf{v}_i \mathbf{v}_i^T - \mathbf{H} \bar{\mathbf{P}}_k \mathbf{H}^T \quad (4)$$

式中: $\mathbf{K}_k$ 为当前卡尔曼增益; $\mathbf{H}$ 为测量矩阵; $\hat{\mathbf{x}}_k$ 为当前时刻的最优估计值; $\mathbf{Z}_k$ 当前时刻的测量值; $\bar{\mathbf{P}}_k$ 为当前时刻最优估计值的协方差矩阵; $\mathbf{R}_k$ 为测量噪声协方差; $\mathbf{v}_i = \mathbf{z}_i - \mathbf{H} \bar{\mathbf{x}}_i$ 为新息序列, N 为滑动窗口大小。

经自适应卡尔曼滤波处理后的温度数据效果如图6所示,表面温度变化相较于图3线性规律更强,更符合实际物理过程。对采集数据滤波后也有助于提升传感器的抗干扰能力,特征的区分度和模型的准确率。





图6 自适应卡尔曼滤波温度差数据

Fig. 6 Adaptive Kalman filtering temperature difference data

经自适应卡尔曼滤波处理后的电缆接头电能数据如图7所示。



(a) 电压数据
(a) Voltage data




图7 电缆接头电能数据堆叠图

Fig. 7 Stacked chart of power data for cable joints

如图7(a)所示,电压上升阶段原始数据存在明显非线性震荡,滤波后数据明显震荡消失,曲线更为平滑。图7(b)为短路模拟电路并入后,骨干电流迅速增大,空开随即切断系统,滤波数据可以快速响应数据变化,滞后性较小。图7(c)为漏电数据,由于测量数据较小,漏电数据在0点附近波动明显。当漏电模拟电路并入实验平台后,漏电流明显增大,滤波后数据在保留数据故障特征的同时,有效抑制了数据抖动并减小了传感器误差。综上经AKF滤波后,数据平滑,细节保留完整,还具有良好的信号跟随性。同时下文的消融实验也验证了滤波的必要性。

2) 时间序列马尔可夫转场

马尔可夫转换场是一种顺序表达状态转移矩阵,该矩阵保留了完整的离散化时域动态信息^[20],数据图像内容依据转移概率进行编码变换^[21]。但传统的马尔可夫转换场往往会忽略大量时域序列的时序信息,导致数据的时间特征的丢失。本文通过时间序列马尔可夫转换场进行特征变换解决时序信息丢失问题^[22]。

先对时域信号 x 划分为 T 个离散的分位单元 m , $x_j = m_T, j = 1, 2, \dots, T$ 。离散化后,统计数据相邻时步的状态转移频次如式(5)所示,状态转移频次相关性按照时序衰减如式(6)所示。

$$\mathbf{M} = \begin{pmatrix} m_{11} & \cdots & m_{1T} \\ \vdots & \ddots & \vdots \\ m_{T1} & \cdots & m_{TT} \end{pmatrix} \quad (5)$$

式中: $\mathbf{M}$ 为马尔可夫转移矩阵。

$$\begin{cases} m_{ij} = P \times w(|i - j|) \\ w(d) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{d^2}{2\sigma^2}} \end{cases} \quad (6)$$

式中: m 为样本分位箱转移的频率; $w(d)$ 为高斯核函数; d 为衰减系数; σ 控制衰减速度系数。

使用时间序列马尔可夫转换场转换故障数据, 特征提取结果如图 8 所示。




图 8 时间序列马尔可夫转换场特征提取结果

Fig. 8 Feature extraction results of the Markov transition field of the time series

图 8 单图为不同运行状态稳态的特征图像, 不同运行状态的特征图像有着明显区别; 图 8 右下侧为同样一样老化故障不同时序的暂态特征图像, 随着状态逐渐稳定特征图像区分度明显下降。可见只使用时间序列马可夫转场特征提取数据特征不能很好地区分电缆故障。




图 9 差分格拉姆角场特征提取结果

Fig. 9 Feature extraction results of differential Gram corner field

4) 融合特征提取

GADF 着重保留原始信号的绝对数值信息, 并利用这些信息刻画故障的严重程度。当数据分布不平衡时, 其生成的图像能更清晰地反映这种数据差异。在记录数据的原始数值信息时, GADF 更偏向数据的静态与瞬时性。MTF 与 GADF 有着明显不同, 它忽略数据幅值, 更关注数据的转移概率。MTF 对信号的变化极其敏感, 这种特征转换方式的核心在于捕捉数据的变化性, 能动态地描述着数据的变化。两种二维化的特性和组合特征对比

3) 差分格拉姆角场

差分格拉姆角场是将一维时间序列映射到二维极坐标空间中的特征提取方法^[23]。该方法可以全方位地捕捉到信号的局部和全局特征, 增强图像特征的几何可区分度, 同时也抑制高斯噪声。

GADF 首先对原始时间序列数据进行归一化处理如式(7)所示。

$$\mathbf{x} = \frac{2x_i - \max(\mathbf{x}) - \min(\mathbf{x})}{\max(\mathbf{x}) - \min(\mathbf{x})} \quad (7)$$

再将归一化后的序列通过式映射到笛卡儿坐标系中, 生成角度序列如式(8)所示, 并且使用差分内积消除高斯噪声如式(9)所示, 形成特征图像:

$$\begin{cases} \sigma = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1 \\ r_i = \frac{t_i}{N}, t_i \in N \end{cases} \quad (8)$$

式中: n 为时间戳; N 为序列长度。

$$\begin{aligned} \mathbf{GADF} &= [\cos(\sigma_1 - \sigma_2)] = \\ &= \begin{pmatrix} \cos(\sigma_1 - \sigma_1) & \cdots & \cos(\sigma_1 - \sigma_n) \\ \vdots & \ddots & \vdots \\ \cos(\sigma_n - \sigma_1) & \cdots & \cos(\sigma_1 - \sigma_n) \end{pmatrix} \end{aligned} \quad (9)$$

使用上述差分格拉姆角场对故障特征进行二维化重构, 可以得到如图 9 的特征提取结果。图 9 右侧是老化电缆暂态特征提取结果, 图 9 中可以清晰的辨别出同一故障的不同的运行阶段的不同特征图形, 弥补了时间序列的马尔可夫转换场的特征提取缺陷。

如表 2 所示。

综合来看, MTF 与 GDAF 的组合特性能够同时覆盖故障信号的幅值、趋势, 以及静态、动态特征。因此, 选取这两种方式进行融合特征提取, 是考虑角度更全面、结果更稳定的做法。同时, 在下文消融模型对比中也可印证了二者融合后的诊断能力最为突出。

2.2 ViT-BiLSTM 模型

为了更好地对提取出来的融合特征进行关联性解读和状态分类, 本文使用 ViT-BiLSTM 网络模型进行特征分

表 2 3 种二维变化对比

Table 2 Comparison of three two-dimensional transformation methods

二维变化	变化核心	变化优势	适用场景
GDAF	保留绝对数值和时间依赖性	保留原始数值信息	信息多的静态特征
MTF	捕捉状态转移概率	对噪声鲁棒性高、强调状态变化	噪声较多的动态采集场景
MTF-GDAF	融合时间依赖的绝对数值保留与状态转移概率捕捉	保留原始数值信息并强化状态变化	复杂多噪声的动态时序数据场景

析、故障诊断。ViT-BiLSTM 是一种融合了视觉 Transformer^[24]和双向长短期记忆网络^[25-26]的深度学习模型。该模型使用视觉神经网络提取 MTF-GADF 空间中的数据特征和关联信息;再利用 BiLSTM 学习时序数据的前后向依赖关系,最终实现对电缆接头 7 类运行状态的诊断。

ViT 首先将特征图像重构为 N 个 $H \times W \times C$ 的一维向量,再将该向量输入 Transformer 进行特征解读。多头注意力 (multi-head self-attention, MSA) 解读不同特征子图像的关联如式 (10) 所示,前馈 (feedforward neural network, FNN) 读取更高维度的特征表达如式 (11) 所示,整体编码过程如式 (12) 所示。

$$\begin{cases} [Q_i, K_i, V_i] = QKVGen(X') = \\ X'W^{QKV} + b^{QKV}x \\ Attn_i = \text{Softmax}\left(\frac{Q_n K_n^T}{\sqrt{d_n}}\right) V_n \\ MSA(X') = \text{pro}(Attn_1, \dots, Attn_h) = \\ Attn W^p + b^p \end{cases} \quad (10)$$

$$FFN(Y') = \text{GELU}(Y'W^{FC_1} + b^{FC_1})W^{FC_2} + b^{FC_2} \quad (11)$$

$$\begin{cases} Y_i = MSA(\text{LN}(X_{i-1})) + X_{i-1} \\ X_{i-1} = FFN(\text{LN}(Y_i)) + Y_i \end{cases} \quad (12)$$

式中: $n = 1, 2, \dots, n$ 表示注意力机制的多头数; $i = 1, 2, \dots$ 为编码器索引序号; $QKVGen$ 为 pro 层投影的 X' 到 Q 、 K 、 V 矩阵结果; Y' 为输入特征。

BiLSTM 是一种循环神经网络的扩展模型。有着双向时间序列捕捉结构。相对于传统 LSTM 可以有效地捕捉运行状态内前后时间序列关系^[25],有效的提升电缆接头运行状态的诊断。

时间序列前向和后向的传播如式 (13) 所示,最终输出结果如式 (14) 所示。

$$\begin{cases} \vec{h}_t = \text{LSTM_forward}(\text{output}, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = \text{LSTM_back}(\text{output}, \overleftarrow{h}_{t+1}) \end{cases} \quad (13)$$

式中: $\vec{h}_t$ 为前向时间 t 的隐藏状态; LSTM_forward 为前向传播函数; $\overleftarrow{h}_t$ 为后向时间 t 的隐藏状态; LSTM_back 为后向传播函数。

$$\text{BiLSTM_output}_i = [\vec{h}_i; \overleftarrow{h}_i] \quad (14)$$

3 改进杜鹃鲶鱼优化模型算法

为了更好地整定模型的前馈网络隐藏单元数、初始学习率以及注意力头数量等参数,同时提升模型的收敛速度、提高诊断模型的识别精度。本文使用改进了的杜鹃鲶鱼优化算法 (improved cuckoo catfish optimizer algorithm, ICCOA) 对模型参数进行优化。原始杜鹃鲶鱼优化算法是一种元启发式算法,其灵感来源于杜鹃鲶鱼在自然界中对慈鲷鱼的捕食行为,在文献[27]中详细介绍了该算法,主要包含 3 种典型行为:包围搜索与压缩空间策略、混沌捕食策略和死亡与寄生机制。

本文 ICCOA 算法旨在解决原始元启发算法存在的普遍问题,包括:在复杂优化问题中普遍存在的全局搜索不全、收敛速度慢,以及在高维空间中陷入局部最优解等问题。为了解决以上问题,本文引入模拟退火搜索策略^[28]、莱维飞行控制^[29]策略和精英个体引导重生策略提升算法的鲁棒性、收敛速度,以及求解精度。

3.1 模拟退火搜索策略

引入模拟退火搜索策略可以提升算法的搜索范围,并提升收敛速度。该策略在算法搜索阶段自动调整搜索行为,控制种群个体全局或局部搜索。

策略使用 Metropolis 准则控制种群的全局探索与局部开发^[28],如式 (15) 所示。利用种群温度衰减机制控制种群,在高温时注重全局探索,扩大种群的搜索范围;低温时候注重局部开发,快速收敛。

$$\begin{aligned} P_m &= \begin{cases} 1, & \Delta E < 0 \\ e^{\frac{-\Delta E}{C_m(I_t)}}, & \Delta E \geq 0 \end{cases} \\ C_m(I_t) &= \alpha C_m(I_{t-1}) \\ \Delta E &= F_0 - F(I_t) \end{aligned} \quad (15)$$

式中: P_m 为接受结果的概率; $\Delta E = F_0 - F(I_t)$ 为目标函数值 F_0 和 $F(I_t)$ 新解的差值; $C_m(I_t) = \alpha C_m(I_{t-1})$ 为退火系数,使用退火参数 α 控制退火速度。

通过控制种群的行为温度实现优化,迭代初期种群全域搜索,随着迭代的推进,温度下降且逐步逼近目标值,算法认可当前解的概率迅速升高,进而实现局部快速收敛。

3.2 莱维飞行控制策略

使用上述模拟退火搜索策略,虽然可以提升搜索范围、加快收敛速度,但是难以解决复杂多峰场景下的局部最优解问题。ICCOA 融合莱维飞行策略有效解决了结果早熟,陷入局部最优解陷阱问题,进一步提升了算法的全局搜索能力^[29],飞行尺度参数和飞行步长方程如式(16)和(17)所示。

$$\delta = \left(\frac{\Gamma(1 + \beta) \sin\left(\frac{\pi\beta}{2}\right)}{2^{\frac{\beta-1}{2}} \beta \Gamma\left(\frac{1+\beta}{2}\right)} \right)^{\frac{1}{\beta}} \tag{16}$$

$$\begin{cases} L = \eta \frac{u}{|v|^{\frac{1}{\delta}}} \\ \eta = 0.05 \times (1 - 0.8\tau) \\ \tau = \frac{I_t}{I_{\text{Max}}} \end{cases} \tag{17}$$

式中: δ 为尺度参数由伽马函数算出; L 为莱维飞行步长; u, v 为正态分布的随机数且 $u \sim N(0, \delta^2)$, $v \sim N(0, 1)$; I_{Max} 为最大迭代次数; β 为莱维参数。

该策略利用莱维飞行长距离跳跃能力,跳出当前的局部最优解,提升算法的全局搜索能力。

3.3 精英个体引导重生策略

在原算法中,个体死亡后采用随机重生方式,易导致搜索过程重复、算法收敛轮次延长。为了提升寻优速度,重生位置引入精英个体引导重生机制,在目前最优解 $\mathbf{x}_{\text{best}}$ 的引导下,重生个体围绕次优解周边搜索目标如

式(18)所示。随着迭代次数,动态衰减重生的范围,且按照历史最优标准差调整重生个体的探索范围,维持种群多样性如式(19)所示。

$$\begin{cases} \mathbf{x}_{\text{new}}(I_t) = \mathbf{L}_b + r_1(\mathbf{U}_b - \mathbf{L}_b)T, \\ 0 < \tau < 0.3 \\ \mathbf{x}_{\text{new}}(I_t) = \mathbf{x}_{\text{best}}(I_t) + r_2(\mathbf{U}_b - \mathbf{L}_b)T, \\ 0.3 < \tau < 0.8 \\ \mathbf{x}_{\text{new}}(I_t) = \mathbf{x}_{\text{best}}(I_t) + r_3(\mathbf{U}_b - \mathbf{L}_b)\sigma, \\ 0.8 < \tau < 1 \end{cases} \tag{18}$$

$$T = \left(1 - \sin\left(\frac{\pi I_t}{2I_{\text{Max}}}\right) \right)^{\frac{2I_t}{I_{\text{Max}}}} \tag{19}$$

$$\sigma = \sqrt{\frac{1}{m-1} \sum_{i=1}^m (\mathbf{X}_i - \mathbf{x}_{\text{best}})^2}$$

式中: $\mathbf{x}_{\text{new}}(I_t)$ 为第 I_t 次重生的新位置; $\mathbf{U}_b$ 和 $\mathbf{L}_b$ 为空间的上边界和下边界; $\mathbf{x}_{\text{best}}(I_t)$ 为当前最优解; T 为活性参数随着迭代非线性衰减; $\mathbf{X}_i$ 为种群历史最优解; m 为种群历史最优解数量; r_1, r_2, r_3 为 3 个阶段搜索半径的放缩系数; σ 反映种群的松散度。

3.4 改进杜鹃鲶鱼优化算法

上述对原始杜鹃鲶鱼优化算法的改进策略让种群搜索范围更加广泛,对目标的遍历更加全面。当陷入局部最优解时可以及时脱出,重生时共享优质的目标位置信息提升了收敛速度。改进后的杜鹃鲶鱼优化算法的流程图如图 10 所示。




图 10 改进杜鹃鲶鱼优化算法流程

Fig. 10 Flowchart of the improved cuckoo catfish optimization algorithm

迭代初期,高温模拟退火实现全局搜索;迭代中期,引导个体在精英个体周围搜索,莱维飞行控制策略跳出当前最优解继续寻找新的优秀结果;迭代后期,结合历史最优解和目前优解的误差进行低温精准搜索。该策略通过 3 个阶段的种群引导,提升了算法的寻优速度,减少了收敛轮次。

3.5 ICCOA 性能测试

为了验证 ICCOA 性能的寻优精度与收敛速度,选用 CEC2020 数据测试集测试函数对算法进行测试,同时与原算法杜鹃鲶鱼优化算法 (cuckoo catfish optimization algorithm, CCOA)、白鲸优化算法 (beluga whale optimization, BWO)、协同群优化算法 (synergistic swarm optimization algorithm, SSOA)、哈里斯鹰算法 (harris hawks optimization, HHO)、鲸鱼优化算法 (whale optimization algorithm, WOA)、常春藤算法 (ivy algorithm, IVY) 进行性能对比。将各个优化算法的最大迭代次数设定为 250 次,种群维度设置为 50,自由维度设置为 15,得出优化算法收敛曲线如图 11 所示。




图 11 F1 收敛曲线
Fig. 11 F1 convergence curve

图 11~16 为 F1~F6 的收敛曲线。测试中,改进杜鹃鲶鱼优化算法均展现出稳定的快速收敛的特性。结合所有收敛曲线图和表 3 结果可知:ICCOA 在收敛速度上大幅度领先原始 CCOA 算法,且收敛结果都要优于其他常见的优化算法。该算法改进很成功,且有一定的复杂问题优化能力,适合本文电缆接头故障诊断问题使用。




图 12 F2 收敛曲线
Fig. 12 F2 convergence curve




图 13 F3 收敛曲线
Fig. 13 F3 convergence curve




图 14 F4 收敛曲线
Fig. 14 F4 convergence curve




图 15 F5 收敛曲线
Fig. 15 F5 convergence curve




图 16 F6 收敛曲线
Fig. 16 F6 convergence curve

表 3 不同算法寻优对比

Table 3 Comparison of optimization performance among different algorithms

函数	指标	ICCOA	CCOA	BWO	SSOA	HHO	WOA	IVY
F1	最优解	100. 51	197. 17	$5. 12 \times 10^6$	$2. 89 \times 10^8$	$2. 20 \times 10^4$	$4. 52 \times 10^4$	$6. 89 \times 10^7$
	平均值	126. 72	399. 98	$5. 98 \times 10^6$	$3. 19 \times 10^8$	$9. 54 \times 10^4$	$4. 52 \times 10^4$	$8. 92 \times 10^7$
	标准差	42. 00	223. 04	$2. 27 \times 10^6$	$5. 47 \times 10^7$	$4. 59 \times 10^4$	0. 29	$1. 36 \times 10^7$
F2	最优解	$1. 82 \times 10^3$	$2. 92 \times 10^3$	$4. 19 \times 10^3$	$5. 28 \times 10^3$	$2. 49 \times 10^3$	$3. 50 \times 10^3$	$2. 50 \times 10^3$
	平均值	$2. 67 \times 10^3$	$3. 30 \times 10^3$	$4. 40 \times 10^3$	$5. 28 \times 10^3$	$2. 72 \times 10^3$	$3. 55 \times 10^3$	$2. 51 \times 10^3$
	标准差	351. 02	549. 37	184. 61	9. 79	$2. 39 \times 10^2$	94. 64	42. 27
F3	最优解	734. 11	751. 16	944. 26	933. 90	930. 12	907. 87	797. 27
	平均值	793. 91	848. 38	949. 14	953. 57	941. 92	918. 44	835. 74
	标准差	109. 53	200. 64	37. 29	87. 94	197. 31	170. 08	142. 34
F4	最优解	$1. 94 \times 10^3$	$2. 75 \times 10^3$	$8. 31 \times 10^5$	$24. 30 \times 10^6$	$1. 98 \times 10^4$	$2. 22 \times 10^5$	$3. 24 \times 10^6$
	平均值	$1. 96 \times 10^3$	$3. 10 \times 10^3$	$9. 40 \times 10^5$	$24. 40 \times 10^6$	$6. 46 \times 10^4$	$3. 65 \times 10^5$	$3. 28 \times 10^6$
	标准差	97. 99	$6. 90 \times 10^2$	$2. 10 \times 10^5$	$1. 08 \times 10^4$	$3. 16 \times 10^4$	$2. 17 \times 10^5$	$1. 69 \times 10^4$
F5	最优解	$2. 44 \times 10^4$	$5. 28 \times 10^5$	$2. 32 \times 10^7$	$3. 33 \times 10^7$	$2. 03 \times 10^6$	$4. 87 \times 10^7$	$1. 74 \times 10^8$
	平均值	$2. 47 \times 10^4$	$5. 66 \times 10^5$	$3. 42 \times 10^7$	$3. 33 \times 10^7$	$2. 48 \times 10^6$	$4. 92 \times 10^7$	$1. 90 \times 10^8$
	标准差	329. 32	$1. 07 \times 10^5$	$2. 12 \times 10^7$	0. 00	$1. 74 \times 10^5$	$3. 39 \times 10^5$	$1. 23 \times 10^7$
F6	最优解	$1. 98 \times 10^3$	$2. 31 \times 10^3$	$3. 24 \times 10^3$	$2. 86 \times 10^3$	$2. 20 \times 10^3$	$2. 56 \times 10^3$	$3. 23 \times 10^3$
	平均值	$2. 00 \times 10^3$	$2. 36 \times 10^3$	$3. 31 \times 10^3$	$2. 90 \times 10^3$	$2. 26 \times 10^3$	$2. 74 \times 10^3$	$3. 43 \times 10^3$
	标准差	37. 90	$7. 76 \times 10^2$	$2. 03 \times 10^2$	60. 42	76. 38	178. 38	77. 36

表 4 数据划分

Table 4 Data segmentation

运行状态	标签	训练集	测试集
断路	K1	260	65
短路	K2	520	130
漏电	K3	260	65
热老化	K4	1 300	325
破损	K5	1 300	325
安装异常	K6	780	195
正常	K7	520	130

4 电缆接头故障诊断模型

4.1 ICCOA 优化的 AKF-MTF-GADF-ViT-BiLSTM 故障诊断模型

基于前文提到的 ICCOA 优化算法、AKF 滤波、MTF、GADF 特征提取方法,以及 ViT-BiLSTM 网络模型构建本文基于 ICCOA 优化的多策略融合(AKF-MTF-GADF-ViT-BiLSTM)电缆接头故障诊断模型。电缆接头故障诊断模型完整流程图如图 17 所示。

4.2 数据集划分

采集训练数据时,针对部分不同程度的故障及难以区分的故障类型,适当扩充数据采集量,便于后期模型训练;对采集所得数据进行整理,从各类故障数据中按 8 : 2 的比例随机抽取样本,划分为训练集与测试集,具体划分情况如表 4 所示。

4.3 优化算法对比

为验证本文改进优化算法对模型性能的提升效果,在固定 AKF-MTF-GADF-ViT-BiLSTM 模型结构的前提下分别与采用 CCOA、BWO、SSOA、HHO、WOA 和未优化参

数的模型进行准确率对比。所有模型均在 NVIDIA GeForce RTX 3050 Laptop GPU 硬件平台上完成训练,不同优化算法下的模型故障诊断准确率如图 18 所示。

基于 ICCOA 算法得到的本文模型最优组合参数如表 5 所示。

优化后的模型较其他算法和没有优化的模型准确率提升了 4. 9% ~ 25. 0%,充分验证了改进杜鹃鲶鱼优化算法可以有效提升模型的故障识别能力。




图 17 基于 ICCOA 优化的 AKF-ViT-BiLSTM 的电缆接头故障诊断模型流程图

Fig. 17 Flowchart of the cable joint fault diagnosis model based on ICCOA optimization of AKF-ViT-BiLST




图 18 不同优化算法模型故障诊断准确率

Fig. 18 Accuracy rates of fault diagnosis for different optimization algorithm models

表 5 模型最优组合参数

Table 5 Optimal combination parameters of the model

参数	搜索区间	最优参数
前馈网络隐藏单元	[32,8 192]	1024
注意力头数量	[2,32]	32
初始学习率	[10 ⁻⁵ ,10 ⁻¹]	2×10 ⁻⁴
衰减因子	[0.8,0.99]	0.93
丢弃率	[0,0.5]	0.2
BiLSTM 隐藏单元	[16,512]	32

4. 4 消融实验和模型性能分析

为更加体现本文提出的故障诊断模型的性能优势,本文模型 AKF-MTF-GADF-ViT-BiLSTM 与无滤波的 MTF-GADF-ViT-BiLSTM、单模特征提取的 AKF-MTF-ViT-BiLSTM 和 AKF-GADF-ViT-BiLSTM 消融模型,以及其他 3 组行业主流模型 1D-CNN-BiLSTM^[10]、CNN-LSTM^[7]、VGAF-CLT^[12] 进行性能对比。为确保评估条件的一致性,试验在相同数据集上并且使用相同的优化算法。本文模型的诊断结果如图 19 所示,对比模型诊断结果如图 20~25 所示。

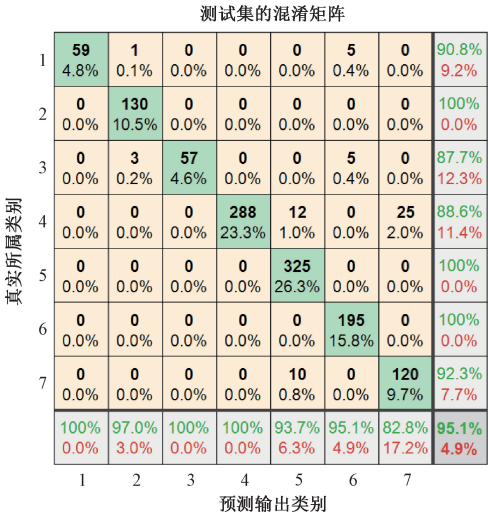


图 19 本文模型诊断结果

Fig. 19 Diagnostic results of model in this article

真实所属类别	1	64 5.2%	1 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	98.5% 1.5%
	2	0 0.0%	130 10.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	0 0.0%	65 5.3%	0 0.0%	0 0.0%	0.0% 100%
	4	0 0.0%	0 0.0%	0 0.0%	154 12.5%	171 13.8%	0 0.0%	47.4% 52.6%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	325 26.3%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	195 15.8%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	84 6.8%	46 3.7%	0 0.0%	0.0% 100%
		100% 0.0%	99.2% 0.8%	NaN% NaN%	64.7% 35.3%	53.5% 46.5%	100% 0.0%	NaN% 29.7%
		预测输出类别						

图 20 MTF-GADF-ViT-BiLSTM 模型诊断结果
Fig. 20 Diagnostic results of the MTF-GADF-ViT-BiLSTM model

真实所属类别	1	63 5.1%	1 0.1%	0 0.0%	0 0.0%	1 0.1%	0 0.0%	96.9% 3.1%
	2	0 0.0%	130 10.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	1 0.1%	0 0.0%	64 5.2%	0 0.0%	0 0.0%	0 0.0%	98.5% 1.5%
	4	0 0.0%	0 0.0%	0 0.0%	245 19.8%	15 1.2%	0 0.0%	65 5.3%
	5	0 0.0%	0 0.0%	0 0.0%	26 2.1%	299 24.2%	0 0.0%	0 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	195 15.8%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	14 1.1%	6 0.5%	0 0.0%	110 8.9%
		98.4% 1.6%	99.2% 0.8%	100% 0.0%	86.0% 14.0%	93.1% 6.9%	100% 0.0%	62.9% 37.1%
		预测输出类别						

图 23 1D-CNN-BiLSTM 模型诊断结果
Fig. 23 Diagnostic results of the 1D-CNN-BiLSTM model

真实所属类别	1	65 5.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	130 10.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	65 5.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	325 26.3%	0 0.0%	0 0.0%	0.0% 100%
	5	0 0.0%	0 0.0%	0 0.0%	325 26.3%	0 0.0%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	195 15.8%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	130 10.5%	0 0.0%	0 0.0%	0.0% 100%
		100% 0.0%	100% 0.0%	100% 0.0%	NaN% NaN%	41.7% 58.3%	100% 0.0%	NaN% 36.8%
		预测输出类别						

图 21 AKF-MTF-ViT-BiLSTM 模型诊断结果
Fig. 21 Diagnostic results of the AKF-MTF-ViT-BiLSTM model

真实所属类别	1	65 5.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	130 10.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	65 5.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	320 25.9%	5 0.4%	0 0.0%	0 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	44 3.6%	281 22.8%	0 0.0%	0 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	195 15.8%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	128 10.4%	2 0.2%	0 0.0%	0 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	65.0% 35.0%	97.6% 2.4%	100% 0.0%	NaN% NaN%
		预测输出类别						

图 24 CNN-LSTM 模型诊断结果
Fig. 24 Diagnostic results of the CNN-LSTM model

真实所属类别	1	63 5.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.2%	96.9% 3.1%
	2	2 0.2%	115 9.3%	1 0.1%	6 0.5%	2 0.2%	4 0.3%	88.5% 11.5%
	3	0 0.0%	0 0.0%	0 0.0%	0 0.0%	65 5.3%	0 0.0%	0.0% 100%
	4	0 0.0%	0 0.0%	0 0.0%	309 25.0%	7 0.6%	0 0.0%	95.1% 4.9%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	283 22.9%	0 0.0%	42 3.4%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	195 15.8%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	116 9.4%	14 1.1%	0 0.0%	0 0.0%
		96.9% 3.1%	100% 0.0%	0.0% NaN%	71.7% 28.3%	76.3% 23.7%	97.0% 3.0%	0.0% 78.1%
		预测输出类别						

图 22 AKF-GADF-ViT-BiLSTM 模型诊断结果
Fig. 22 Diagnostic results of the AKF-GADF-ViT-BiLSTM model

真实所属类别	1	63 5.1%	1 0.1%	0 0.0%	0 0.0%	0 0.0%	1 0.1%	96.9% 3.1%
	2	0 0.0%	130 10.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	0 0.0%	26 2.1%	39 3.2%	0 0.0%	0 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	309 25.0%	16 1.3%	0 0.0%	0 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	325 26.3%	0 0.0%	0 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	195 15.8%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	106 8.6%	6 0.5%	0 0.0%	18 1.5%
		100% 0.0%	99.2% 0.8%	NaN% NaN%	70.1% 29.9%	84.2% 15.8%	99.5% 0.5%	100% 0.0%
		预测输出类别						

图 25 VGAF-CLT 模型诊断结果
Fig. 25 Diagnostic results of the VGAF-CLT model

图 19~25 中,矩阵内部单元格上方为样本数量,下方为该样本占测试集总量的比例。矩阵外部右侧为样本召回率,底部为预测类别准确率。图 20 为无滤波消融模型诊断结果,该模型对漏电、老化、破损及正常样本的区分度较低。结合上文图 6、7 展现出来的优势及图 20 结果可知,经滤波处理后,模型对数据特征的识别能力和抗干扰能力得到了一定程度的提升。图 21 和 22 是只使用一种特征变换消融模型的诊断结果,这两个模型对数据特征的提取不全面,导致故障诊断率均低于 80%。本文模型分别对比消融模型 MTF-GADF-ViT-BiLSTM、AKF-MTF-ViT-BiLSTM、AKF-GADF-ViT-BiLSTM 高出 24.8%、31.9%、17.0%,且和其他当前主流模型相比也具有优势,分别比 1D-CNN-BiLSTM、CNN-LSTM、VGAF-CLT 高出 5.5%、9.6%、10.9%。结合图 19 本文模型诊断结果和图 26 准确率对比图所示,本文故障诊断模型优势明显,模型对电缆接头故障诊断率达 95.1%,明显高于其他模型,可以胜任电缆接头故障诊断任务。




图 26 模型准确率对比

Fig. 26 Model accuracy comparison chart

5 结 论

本文针对当前主流故障诊断模型普适性不足,难以使用单一模型精确诊断多类型的电缆故障问题。本文创新性地提出了一种基于 ICCOA 优化的多策略融合(AKF-MTF-GADF-ViT-BiLSTM)电缆接头故障诊断模型,实现了对电缆断路、短路、漏电、热老化、破损、检测设备异常以及运行正常 7 类状态的精确检测。

该模型首先对采集数据进行自适应卡尔曼滤波(AKF)处理,还原电缆接头真实的运行数据;随后采用时序马尔可夫转换场(MTF)和差分格拉姆角变换(GADF)融合的特征提取方法,以“动静结合”的方式完整保留并强化故障数据相关特征;融合特征图像输入经改进杜鹃鲶鱼算法(ICCOA)优化的双路 ViT-BiLSTM 模型,完成对特征深度解析和故障识别。

最后使用同样测试数据集和优化方法,对消融模型 MTF-GADF-ViT-BiLSTM、AKF-MTF-ViT-BiLSTM、AKF-GADF-ViT-BiLSTM 和其他行业主流(SOTA)模型 1D-

CNN-BiLSTM、CNN-LSTM、VGAF-CLT 进行性能对比,本文使用模型识别准确率最高,故障诊断率达 95.1%。解决了单一模型普适性不足、难以精准识别多类型电缆故障的行业技术难题。

但本方案仍存在些许不足,对识别错误的样本进行分析,模型误判主要集中在正常运行状态与轻微老化、轻微破损状态上。该现象可能源于实验平台对电缆接头数据采集角度不够丰富,部分细微特征未被传感器精准捕捉。同时模型对数据处理及特征提取不够全面,导致未能充分展现出这 3 个状态下的特征差异,最终难以精确诊断。为进一步提升模型故障识别能力,后续将从 4 个主要方面开展优化提升:拓展特征采集维度,引入时域反射曲线、X 射线衍射特征峰等电缆固有属性检测手段;选用分辨率更高、抗干扰能力更强的传感器,强化传感器对细微参数变化的捕捉能力与抑制环境噪声的抗干扰能力;采用更先进的改进策略,提升模型特征提取能力,同时结合其他角度的特征提取方法全方位刻画数据特征;扩大样本集规模,重点区分正常状态、轻微老化、轻微破损等相似状态样本,加大模型的训练量,提升诊断能力。

参考文献

- [1] 李盛涛,王诗航,杨柳青,等. 高压电缆交联聚乙烯绝缘的关键性能与基础问题[J]. 中国电机工程学报, 2022, 42(11): 4247-4255.
LI SH T, WANG SH H, YANG L Q, et al. Important properties and fundamental issues of the crosslinked polyethylene insulating materials used in high-voltage cable[J]. Proceedings of the CSEE, 2022, 42(11): 4247-4255.
- [2] 周韞捷,李海,范玉军,等. 高压 XLPE 电缆缓冲层烧蚀故障原因与检测关键技术[J]. 电线电缆, 2023(1): 26-29.
ZHOU Y J, LI H, FAN Y J, et al. Analysis ablation failure causes on buffer layer of high voltage XLPE cable and key detection technologies[J]. Wire & Cable, 2023(1): 26-29.
- [3] 朱梦瑶,李欢,张瑞祥. 热老化对 XLPE 电缆本体中典型缺陷所引发的电场畸变的影响[J]. 中国电机工程学报, 2024, 44(22): 9076-9087.
ZHU M Y, LI H, ZHANG R X. Influence of thermal aging on electric field distortion caused by typical defects in XLPE cable[J]. Proceedings of the CSEE, 2024, 44(22): 9076-9087.
- [4] 谢安生,郑晓泉,李盛涛,等. XLPE 电缆绝缘中的电树枝结构及其生长特性[J]. 高电压技术, 2007(6): 168-173.
XIE AN SH, ZHENG X Q, LI SH T, et al. Structures and propagation characteristics of electrical trees in XLPE

- cable insulation[J]. High Voltage Technology, 2007(6): 168-173.
- [5] 刘英, 曹晓珑. 电力电缆在线测温及载流量监测的研究进展与应用[J]. 电网与水力发电进展, 2007, 23(5): 11-14.
- LIU Y, CAO X L. Research progress and application of online temperature measurement and current-carrying capacity monitoring of power cables[J]. Power System and Clean Energy, 2007, 23(5): 11-14.
- [6] NAJI H A, FAYADH R A, MUTLAG A H. A novel quantum-behaved future search algorithm for the detection and location of faults in underground power cables using ANN[J]. Iraqi Journal for Electrical and Electronic Engineering, 2024, 20(1): 226-244.
- [7] MOUTASSEM Z, BOUNAIM D, LI G. A physics-enhanced CNN-LSTM predictive condition monitoring method for underground power cable infrastructure[J]. Algorithms, 2025, 18(10): 600.
- [8] LIN M S, WEI H K, DUAN X K, et al. Cable outer sheath defect identification using multi-scale leakage current features and graph neural networks[J]. Energies, 2025, 18(21): 5687.
- [9] 孙抗, 轩旭阳, 刘鹏辉, 等. 小样本下基于 CNN-DCGAN 的电缆局部放电模式识别方法[J]. 电子科技, 2022, 35(7): 7-13.
- SUN K, XUAN X Y, LIU P H, et al. Cable partial discharge pattern recognition method based on CNN-DCGAN under small sample conditions[J]. Electronic Science and Technology, 2022, 35(7): 7-13.
- [10] WANG Q Y, CAO D, ZHANG SH Y, et al. The cable fault diagnosis for XLPE cable based on 1dnnns-bilstm network[J]. Journal of Control Science and Engineering, 2023, 2023(1): 1068078.
- [11] 陈新岗, 范益杰, 马志鹏, 等. 基于集成增强 KNN 的油纸绝缘原始拉曼光谱老化状态判别[J]. 激光与光电子学进展, 2023, 60(21): 338-344.
- CHEN X G, FAN Y J, MA ZH P, et al. Discrimination of aging state of oil-paper insulation based on original raman spectroscopy using ensemble enhanced KNN[J]. Laser & Optoelectronics Progress, 2023, 60(21): 338-344.
- [12] 李练兵, 代亮亮, 高国强, 等. 基于 VGAF 与混合时序网络的电缆故障诊断方法[J]. 华中科技大学学报(自然科学版), 2025, 53(7): 16-23.
- LI L B, DAI L L, GAO G Q, et al. Cable fault diagnosis method based on VGAF and hybrid time-series network[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2025, 53(7): 16-23.
- [13] BRAGATTO T, CERRETTI A, D'ORAZIO L, et al. Thermal effects of ground faults on MV joints and cables[J]. Energies, 2019, 12(18): 3496.
- [14] 方彬, 冶海平. 关于 XLPE 电力电缆选型及附件部分故障处理方法的初步探讨[J]. 科技创新与应用, 2013(6): 156.
- FANG B, YE H P. Preliminary discussion on selection of XLPE power cables and fault handling methods for cable accessories[J]. Technology Innovation and Application, 2013(6): 156.
- [15] 李岩, 甄冠成, 宋浩源, 等. 绝缘层温度对 XLPE 局部放电的影响特性[J]. 电力科学与技术学报, 2024, 39(6): 260-268.
- LI Y, ZHEN G CH, SONG H Y, et al. Influence characteristics of insulation layer temperature on partial discharge of XLPE[J]. Journal of Electric Power Science and Technology, 2024, 39(6): 260-268.
- [16] 吕鸿, 马佳炜, 杨贤, 等. 热老化对 220 kV 硅橡胶电缆接头绝缘材料介电性能的影响[J]. 绝缘材料, 2019, 52(2): 47-51.
- LYU H, MA J W, YANG X, et al. Influence of thermal ageing on dielectric properties of insulating materials in 220 kV silicone rubber cable joint[J]. Insulating Materials, 2019, 52(2): 47-51.
- [17] 卫世超, 孟晓凯, 芦竹茂. 电缆中间接头温度场仿真分析[J]. 科技创新与应用, 2023, 13(35): 15-18.
- WEI SH CH, MENG X K, LU ZH M. Simulation analysis of temperature field at cable intermediate joints[J]. Technology Innovation and Application, 2023, 13(35): 15-18.
- [18] 单威威, 王健. 电线电缆绝缘材料燃烧及热老化研究进展[J]. 塑料, 2020, 49(3): 151-155.
- SHAN W W, WANG J. Research progress on combustion and thermal aging of wire and cable insulation materials[J]. Plastics, 2020, 49(3): 151-155.
- [19] 贺刘辉, 连增增, 赵辰瑞, 等. 融合卡尔曼滤波和时序卷积网络的 UWB 定位算法[J/OL]. 测绘地理信息, 1-5[2026-02-01].
- HE L H, LIAN Z Z, ZHAO CH R, et al. A UWB localization algorithm incorporating Kalman filtering and temporal convolutional networks[J/OL]. Journal of Geomatics, 1-5[2026-02-01].
- [20] 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. Power quality disturbances classification based on Markov transition

- field and Multi-head Attention[J]. Power System Technology, 2024, 48(2): 721-733.
- [21] 罗溢, 李开成, 肖贤贵, 等. 基于马尔可夫转移场和深度残差网络的电能质量复合扰动多标签分类[J]. 中国电机工程学报, 2024, 44(7): 2519-2531.
LUO Y, LI K CH, XIAO X G, et al. Multi-label classification of power quality composite disturbances based on Markov transfer field and resnet [J]. Proceedings of the CSEE, 2024, 44(7): 2519-2531.
- [22] WANG ZH G, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks[C]. AAAI Conference on Artificial Intelligence, 2015: 40-46.
- [23] 谢胜灵, 荆晓远, 杜杰宾, 等. 基于格拉姆角场与并行滑动卷积注意力网络的轴承故障诊断方法[J]. 信息技术与信息化, 2025(5): 187-191.
XIE SH L, JING X Y, DU J B, et al. Bearing fault diagnosis method based on gram angular field and parallel sliding convolutional attention network [J]. Information Technology and Informationization, 2025(5): 187-191.
- [24] 王琦, 张涛, 徐超炜, 等. 多尺度注意力融合与视觉Transformer方法优化的电阻抗层析成像深度学习方法[J]. 仪器仪表学报, 2024, 45(7): 52-63.
WANG Q, ZHANG T, XU CH W, et al. Optimized learning method for electrical impedance tomography with multi-scale attention fusion and vision transformer [J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 52-63.
- [25] 王雨虹, 王志中, 付华, 等. 多策略改进麻雀算法与BiLSTM的变压器故障诊断研究[J]. 仪器仪表学报, 2022, 43(3): 87-97.
WANG Y H, WANG ZH ZH, FU H, et al. Research on transformer fault diagnosis based on the improved multi-strategy sparrow algorithm and BiLSTM [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 87-97.
- [26] 杨蕊璟, 黄以锋, 周伟, 等. 基于GWO-BiLSTM的电磁继电器寿命预测[J]. 电子测量与仪器学报, 2025, 39(7): 159-170.
YANG R J, HUANG Y F, ZHOU W, et al. Life prediction of electromagnetic relays based on GWO-BiLSTM [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(7): 159-170.
- [27] WANG T L, GU SH W, LIU R J, et al. Cuckoo catfish optimizer: A new meta-heuristic optimization algorithm[J]. Artificial Intelligence Review, 2025, 58(10): 326.
- [28] 陈杰, 庄百亮, 杨保华, 等. NSGA-SA:模拟退火增强型多目标优化算法及其热处理应用[J]. 软件导刊, 2025, 24(9): 87-98.
CHEN J, ZHUANG B L, YANG B H, et al. NSGA-SA: Simulated annealing enhanced multi-objective optimization algorithm and its application in heat treatment [J]. Software Guide, 2025, 24(9): 87-98.
- [29] 邓佳欣, 张达敏, 何庆, 等. 结合莱维飞行和布朗运动的金鹰算法[J]. 系统仿真学报, 2023, 35(6): 1290-1307.
DENG J X, ZHANG D M, HE Q, et al. Golden eagle algorithm combining levy flight and brownian motion[J]. Journal of System Simulation, 2023, 35(6): 1290-1307.

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., M. Sc., and Ph. D. degrees all from Liaoning Technical University in 2003, 2006 and 2012, respectively. He is currently an associate professor at Liaoning Technical University. His main research interests include electrical contact theory and application, intelligent appliances and smart grid technology.



蒋鑫(通信作者), 2025 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: 1835434073@qq.com

Jiang Xin (Corresponding author) received his B. Sc. degree from Liaoning Technical University in 2025. He is currently a master candidate at Liaoning Technical University. His main research interests include electrical contact theory and appliances and smart grid technology.