



DOI:10.12404/j.issn.1671-1815.2404712

引用格式:刘岱,李晨辉.基于 Inception-BiLSTM 的航空电缆电弧故障检测[J].科学技术与工程,2025,25(14):6100-6108.

Liu Dai, Li Chenhui. Aviation cable arc fault detection based on Inception-BiLSTM[J]. Science Technology and Engineering, 2025, 25(14): 6100-6108.

基于 Inception-BiLSTM 的航空电缆电弧故障检测

刘岱¹, 李晨辉²

(1. 中国民航大学工程技术训练中心, 天津 300300; 2. 中国民航大学电子信息与自动化学院, 天津 300300)

摘要 针对航空电缆电弧故障引起的微小电流变化难以识别的问题,提出了一种基于 Inception 模块和双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)的交流串联电弧故障诊断方法。首先通过计算自相关系数的离散平方和(discrete sum of squares of the autocorrelation coefficient)、信息熵(Shannon entropy)以及小波能量熵(wavelet energy entropy)提取原始电流数据的特征,将特征合并形成新的特征矩阵,对原始数据实现特征增强。之后 Inception-BiLSTM 网络利用特征矩阵进行学习,最后完成对电弧故障的诊断。为了验证模型在实际环境中的诊断性能,在充分考虑实际情况下,基于航空电缆电弧模拟实验平台进行了振动试验、应力实验以及潮湿电缆实验,并将实验数据整合作为检测样本。实验结果表明,本文方法对于识别电弧故障有着较高的准确度,可以达到 99.69%。

关键词 Inception 模块; 双向长短期记忆网络; 航空电缆电弧故障; 特征提取

中图分类号 V271.1;

文献标志码 A

Aviation Cable Arc Fault Detection Based on Inception-BiLSTM

LIU Dai¹, LI Chen-hui²

(1. Engineer Techniques Training Center, Civil Aviation University of China, Tianjin 300300, China;

2. College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China)

[Abstract] A method for diagnosing AC series arc faults based on the Inception module and BiLSTM (bidirectional long short-term memory) was proposed to address the challenge of identifying small current changes caused by arc faults in aviation cables. First, features of the raw current data were extracted by calculating the discrete sum of squares of the autocorrelation coefficient, Shannon entropy, and wavelet energy entropy. These features are then combined to form a new feature matrix, enhancing the original data's feature representation. Subsequently, the Inception-BiLSTM network learns from the feature matrix and ultimately completes the arc fault diagnosis. To validate the diagnostic performance of the model in practical environments, a series of experiments were conducted, including vibration tests, stress tests, and wet cable tests, based on an aviation cable arc fault simulation platform, with the experimental data being integrated as detection samples. The experimental results show that the proposed method achieves a high accuracy rate of 99.69% in identifying arc faults.

[Keywords] inception module; BiLSTM; aviation cable arc fault; features extraction

随着飞机机龄的增加,电气系统线缆长期负载或过载工作,易导致线缆绝缘老化或故障,出现局部放电或电弧放电^[1]。飞机中线缆故障引发的故障电弧通常伴随着高温与强闪光现象,当电弧接触到线缆的绝缘层或护套时,使得线缆局部电阻和能量增加,造成机舱电气火灾,给飞机安全运行造成极大的隐患。

到目前为止,中外学者对电弧故障检测问题展开了一系列的研究。从应用层面进行分析,电弧故障检测方法大致分为两类:一种是基于物理现象的

方法,这种方法通常涉及电弧产生的声、光、电等^[2]。对光伏直流系统中的电弧电磁辐射脉冲信号进行分析,发现其波形幅值与电弧电流的变化率近似成正比关系,通过实验验证其有效频率范围为 210 ~ 800 MHz。文献[3]提出了另一种利用光谱分析进行弧闪故障检测的新方法。研究表明,通过分析电弧事故期间铜导体和铝导体的光谱,能够提高弧闪故障检测操作的准确性和可靠性。

另一种则是在电弧故障发生的情况下,分析电流和电压的时域、频域和时频域的特征变化。当发

收稿日期:2024-06-24; 修订日期:2025-02-25

基金项目:中央高校基本科研业务中国民航大学专项基金(3122018D009)

第一作者:刘岱(1981—),男,汉族,天津人,硕士,讲师。研究方向:航空器维修及适航审定技术。E-mail:dliu@cauc.edu.cn。

投稿网址:www.stae.com.cn

生电弧故障时,线路的电压电流波形会产生畸变,出现波形不对称、幅值变化,并伴随着高频噪声信号产生等情况。基于耦合信号高频脉冲分量的方法被用于识别住宅建筑中的交流串联电弧故障,文献[4-5]在此方法的基础上,提出短观察窗奇异值分解法和重构算法。

近年来,随着人工智能技术的发展,机器学习和深度学习等技术因其对复杂信号的优异处理能力也逐渐被引入电弧检测研究中。文献[6]通过对故障电弧的时域分析,引用归一化卷积神经网络,优化了传统神经网络在电弧故障识别上的不足,提高了一定的检测精度,但仍有不小提升空间。文献[7]利用电弧电流的高频特性以及全连接神经网络,设计了精细化区分不同负载对应的电弧故障的方法,减低了计算成本。文献[8]利用改进的经验模态分解方法分析电弧电流,并通过 Boruta 和 LightGBM(light gradient boosting machine)算法来降低特征维数,利用决策树完成了对电弧故障的分类和检测。文献[9]设计了一种基于卷积神经网络的光弧检测模型,通过调整卷积网络的结构平衡了计算时间和精度,可以利用原始电流数据对电弧故障进行较高准确率检测。文献[10]提出一种基于麻雀优化算法(sparrow search algorithm, SSA)优化支持向量机(support vector machine, SVM)的航空电弧故障检测方法,从信号无序度角度提取能量熵、模糊熵与近似熵构造特征向量,利用构造的特征向量完成了对航空电弧的故障诊断。文献[11]则提出基于一维卷积神经网络(convolutional neural network, CNN)和 D-S(dempster-shafer)证据理论的故障检测方法,该方法使用 1DCNN 对并联电容器电流和电压信号进行电弧识别,并将基于单个传感数据的识别结果作为证据,运用 D-S 理论计算信度分配最终利用决策规则判断是否发生串联电弧故障。

综上所述,现提出一种 inception-BiLSTM 模型,对含有电弧故障的航空电缆电流检测数据进行故障诊断。利用自相关系数的离散平方和、小波能量熵以及信息熵三种特征对原始电流进行特征增强,利用 Inception-BiLSTM 网络捕捉特征数据中的时空信息,实现航空电缆电弧故障的诊断。

1 航空电缆电弧故障实验

航空电缆作为民航飞机系统中的重要组成部分,负责传输电力、信号和数据等。由于其应用环境的恶劣和复杂,传统的点接触实验很难模拟电弧出现的真实环境,在考虑了电弧出现的各种原因,

包括机械损伤、环境因素和电气等原因^[12]。在相同的电源电压和负载类型下,本次实验基于航空电缆电弧模拟实验平台进行试验,最终选择了振动试验、应力实验以及潮湿电缆实验。具体电路设计如下。振动实验电路如图 1 所示,振动装置不断振动接线端子使得线路处在间接性接触的情况。应力实验电路如图 2 所示,其中利用金属块来对电缆进行挤压。潮湿电缆实验的电路如图 3 所示,实验电缆部分被切除部分外部胶皮,由滴水装置向电缆裸露处滴水。

该实验基于电弧故障断路器标准 UL1699 和航空标准 SAE AS5692A^[13] 搭建,具体的模拟环境如下。

(1) 试验台和振动控制装置一起振动,来模拟电缆的间接性接触,模拟连接器松动。

(2) 切割实验利用金属块挤压电缆模拟电缆被外部坚硬物体挤压的情况。

(3) 潮湿电缆实验以一定的速度向裸漏的电缆处滴加水滴来模拟电缆因温度变化而凝结水滴的情况。

(4) 电源选择 115 V/400 Hz 的驱动电压和电源电压模拟飞机的电源电压。

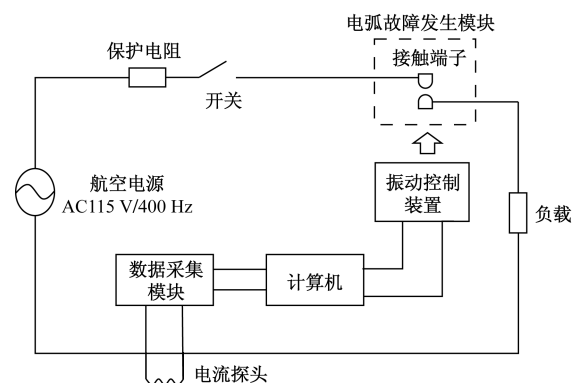


图 1 振动试验电路

Fig. 1 Vibration test circuit




图 2 应力实验电路

Fig. 2 Stress test circuit

(5)负载选用线性负载和非线性负载模拟飞机电缆连接的电器设备,其中线性负载选择灯泡,非线性负载使用电机。

最终采用电流探头采集电弧故障试验电流,每次试验截取30个周期电流,包括正常电流和故障电流,每周期6250个采样点,最终总和采集到的三种场景下的电流数据。如图4所示是采集到的部分电流数据。

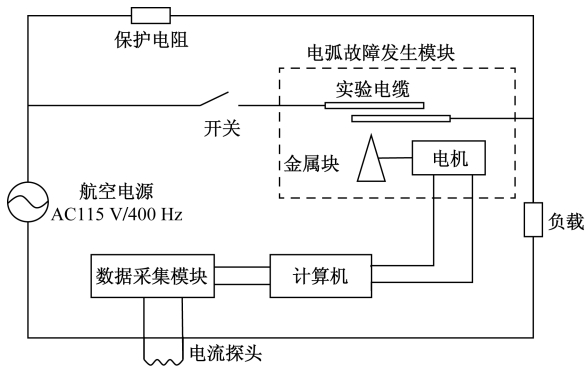


图3 潮湿电缆实验电路

Fig. 3 Wet cable test circuit




图4 部分采样电流

Fig. 4 Partial sampling current

以三种电弧故障的电流数据的总和作为训练样本,以此来保证模型的泛化性。确保模型在面对不同种类的电流数据时仍可以精确的检测出故障的电流。

2 三维特征提取

由于航空电缆电弧故障所引起的电流变化微小,需要大规模的电流数据进行检测。而直接利用原始信号进行检测会导致较高的计算成本的同时花费更多的时间。因此,本文研究从三个维度对原始电流信号进行特征提取。其中,利用自相关系数的离散平方和来描述信号在时域的特征,以香农熵

来描述信号的混乱程度,最后以小波能量熵来描述信号的时频域特征。并将获取的特征值进行合并形成新的输入信号,从三个维度对原始电流信号进行特征从而提高模型的检测效率和泛化性^[14]。

2.1 自相关系数的离散平方和

相关性是信号之间的统计关系,而自相关性可以表示信号与其自身的滞后版本在连续时间间隔内的相似程度。当信号具有周期性时,自相关系数为1。对于非周期随机信号,其自相关系数为0。自相关系数的计算式为

$$R_e(\tau) = \frac{\text{cov}(X_t, X_{t+\tau})}{\sigma_{X_t} \sigma_{X_{t+\tau}}} \quad (1)$$

$$\text{cov}(X_t, X_{t+\tau}) = E[(X_t - \mu_{X_t})(X_{t+\tau} - \mu_{X_{t+\tau}})] \quad (2)$$

式中: R_e 为自相关系数; X_t 为 t 时间内的电弧电流信号; τ 为时间间隔; E 为数学期望; μ 和 σ 分别为 X 的期望值和标准差。

由 $\mu_X = E(X)$ 和 $\sigma_X^2 = E(X^2) - E^2(X)$ 可以推出式(3)和式(4)。

$$R_e(\tau) = \frac{E(X_t X_{t+\tau}) - E(X_t)E(X_{t+\tau})}{\sqrt{E(X_t^2) - E^2(X_t)} \sqrt{E(X_{t+\tau}^2) - E^2(X_{t+\tau})}} \quad (3)$$

$$D = \sum_{t=1}^n R_e(\tau)^2 \quad (4)$$

式中: D 为自相关系数的离散平方和。

与现有的故障检测方法中常用的快速傅里叶变化相比^[15],自相关算法具有较低的时间复杂度,此外自相关算法可以区分粉红噪声和白噪声,通过计算 D 来更准确地区分正常电流和故障电流。由于航空电缆电流为交流电,其电流具有周期性,故障电流的变化在周期内可能微小但显著。通过对电流信号进行周期划分,可以将每个周期内的电流变化单独提取出来,有助于分析周期内的细微变化。而自相关系数能够捕捉到周期内电流的特征变化。对于故障电流,由于其在周期内的变化与正常电流不同,自相关函数将会显示出明显的差异。而通过对自相关函数进行平方求和,可以增强周期内电流变化的特征,使得故障特征更加显著。以此来有效地区分正常电流和故障电流。

2.2 香农熵

由于航空电缆电弧故障发生时,电流信号的复杂度和不确定性通常会显著增加。而使用香农熵作为特征,则可以充分利用其度量信号复杂度和不确定性的特性^[16]。其具体定义式为

$$S(X) = - \sum_{i=1}^n p(x_i) \log_2 p(x_i) \quad (5)$$

式(5)中: $S(X)$ 为随机变量 X 的熵; $p(x_i)$ 为随机变

量 X 取值为 x_i 的概率。

2.3 小波能量熵

小波变换通过将信号分解成不同频率的分量来分析信号的时频特性。与传统的傅里叶变换不同,小波变换不仅能够提供频率信息,还能够提供时间信息。而小波能量熵则结合了小波变换的多分辨率分析能力和熵在度量信号复杂度方面的优势,对于分析电流信号的局部特征和整体特征有着极佳的效果^[17]。其具体定义如下。

假设有一组小波系数 $c_{j,k}$, 其中 j 表示尺度, k 表示时间或空间坐标。

首先计算小波系数的能量 $E_{j,k}$ 。

$$E_{j,k} = |c_{j,k}|^2 \quad (6)$$

将小波系数的能量作为概率分布, 计算每个尺度下 j 的能量分布概率 $p_{j,k}$ 。

$$p_{j,k} = \frac{E_{j,k}}{\sum_{k=1}^N E_{j,k}} \quad (7)$$

式(7)中: N 为系数个数。基于式(6)和式(7)所得使用信息熵的计算公式, 计算小波能量熵 W 。

$$W = - \sum_{j=1}^M \sum_{k=1}^N p_{j,k} \log_2 p_{j,k} \quad (8)$$

其中: M 为分解的子带总数。

3 Inception-BiLSTM 网络

3.1 Inception 模块

传统的 CNN 网络在面对大规模的数据时为了更好地学习特征会增加网络的深度, 但是其反向传播过程可能会随着层数的变化而出现梯度爆炸或梯度消失的问题, 所以在处理航空电缆电流的大规模数据时选择 Inception 网络^[18]。

Inception 网络本质上是多个不同卷积核大小的卷积层进行并行运算, 将并行运算的结果在通道维度上合并成新的特征图, 相比于传统 CNN 的简单堆叠, 该结构可有效解决 CNN 在计算大规模数据时易过拟合以及计算量大容易导致梯度爆炸或梯度消失的问题, 并且从多个尺度学习数据, 可以更好地挖掘出数据的特征^[19]。相关的计算公式如下。

CNN 的特征提取过程即卷积过程具体过程为

$$a_j^k = f \left(\sum_{i \in M_j^k} a_i^{k-1} W_{ij}^k + b_j^k \right) \quad (9)$$

式(9)中: a_j^k 为 j 特征图神经网络第 k 个卷积层对应的输出; f 为激活函数; b_j^k 为偏置。

Inception 网络结构相当于将不同尺度的卷积层输出拼接, 其表达式为

$$A_{\text{concatenate}} = \text{concatenate} \left[\sum_{k=1}^n a_j^k, \text{Maxpool}(j) \right] \quad (10)$$

式(10)中: concatenate 为通道拼接函数。

本文所使用的 Inception 结构如图 5 所示。

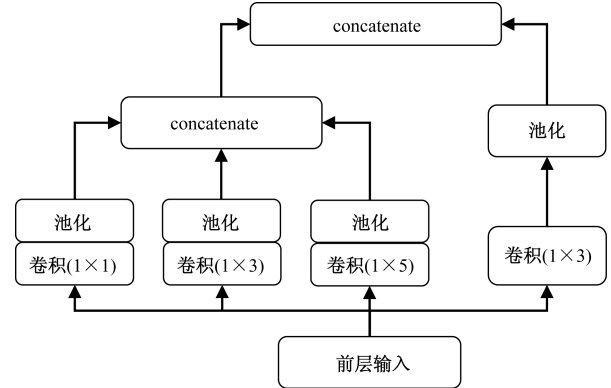


图 5 Inception 结构

Fig. 5 Inception structure

3.2 BiLSTM 工作原理及结构

双向长短期记忆网络是 LSTM 网络的一种变体^[20], 它是由前向 LSTM 和后向 LSTM 组合而成。相比于 LSTM 网络, 增强了网络的表示能力, 使其能够更好地发现输入序列的特征和结构。BiLSTM 网络结构如图 6 所示。




图 6 BiLSTM 结构

Fig. 6 BiLSTM structure

在图 6 中的 BiLSTM 网络的计算过程为

$$\begin{cases} \vec{h} = \text{LSTM}(x_t, \vec{h}_{t-1}) \\ \overleftarrow{h} = \text{LSTM}(x_t, \overleftarrow{h}_{t-1}) \\ y_t = \sigma(\mathbf{W}_y [\vec{h}, \overleftarrow{h}]) + b_y \end{cases} \quad (11)$$

式(11)中: LSTM 单元为传统 LSTM 网络计算过程; \vec{h} 为时刻前向隐藏层状态; \overleftarrow{h} 为后向隐藏层状态; y_t 为当前时间步的输出; σ 为 Sigmoid 激活函数; \mathbf{W}_y 、 b_y 分别为权重矩阵和偏置项。

BiLSTM 网络结构首先利用前向的 LSTM 层, 以正向顺序逐步读取输入序列的信息, 并根据每个时

间步以及前一个时间步的隐藏状态来更新当前时间步的隐藏状态。同时利用反向的 LSTM 层以逆向的顺序处理输入序列,从最后一个时间步开始,依次向前处理序列。最后将每个时间步的正向和逆向的隐藏状态整理连接起来形成一个综合的表示,以捕获两个方向信息的隐藏特征^[21]。

综合 Inception 模块多尺度卷积的空间特征挖掘能力以及 BiLSTM 网络的时间特征发掘能力。Inception-BiLSTM 诊断网络可以更好地捕捉输入数据的时空特征从而提高诊断的准确度以及诊断效率。Inception-BiLSTM 诊断网络的具体结构如图 7 所示。

网络中共使用了 4 种不同尺度的卷积层,其中三种用于组成 Inception 模块,一种用于提取 Inception 模块输出特征图的特征,同时对输入数据进行批归一化来提高网络的泛化能力减少过拟合的风险^[22]。具体参数由表 1 给出,其中卷积层 1×1 表示卷积核的大小。

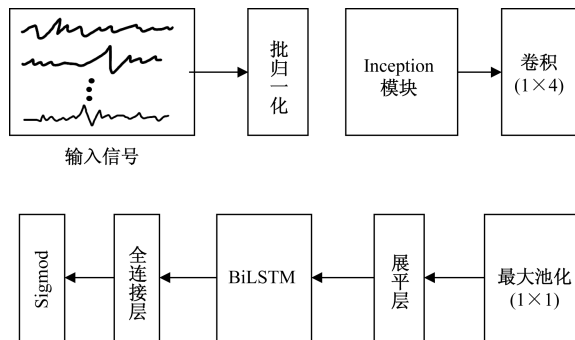


图 7 Inception-BiLSTM 诊断网络

Fig. 7 Inception-BiLSTM diagnostics network

表 1 Inception-BiLSTM 网络参数

Table 1 Inception-BiLSTM network parameters

网络机构	参数	网络机构	参数
卷积层 1	1×1	BiLSTM	128
卷积层 2	1×3	全连接层 1	64
卷积层 3	1×5	全连接层 2	32
卷积层 4	1×4	全连接层 3	16
池化层	1×1		

4 航空电缆电弧故障诊断模型

基于三维特征提取和 Inception-BiLSTM 的航空电缆电弧故障诊断模型如图 8 所示。

具体原理为:首先对输入信号进行测试集和训练集的划分,计算选择的三种特征值并合并成新的特征矩阵输入 Inception 网络。该网络会进行特征的多尺度提取和特征融合,之后将特征图输入 BiLSTM 网络进行训练最后利用 Sigmoid 函数进行故障样本和正常样本的区分。

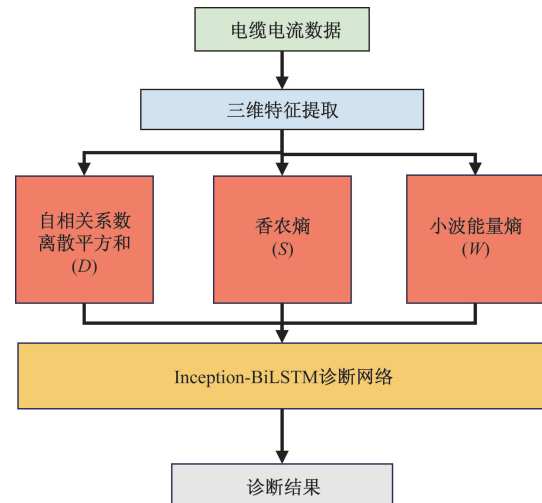


图 8 电弧故障诊断模型

Fig. 8 Arc fault diagnosis model

5 实验验证

5.1 数据预处理

将获得的原始电流数据进行特征提取。利用式(4)计算电流原始数据每一个时间序列样本的自相关系数的离散平方和。同时,为了解决数据之间的差异以及加快网络收敛,同时保证能最大限度保留原始数据的特征,对处理后的数据采用数据归一化的方式来去除量纲,处理后的结果如图 9 所示。

通过式(5)计算计算电流原始数据每一个时间序列样本的香农熵。同样进行归一化以去除量纲,加快网络的计算速度。具体结果如图 10 所示。

通过式(8)计算计算电流原始数据每一个时间序列样本的小波能量熵。同样进行归一化以去除量纲。具体结果如图 11 所示。




图 9 自相关系数的离散平方和散点图

Fig. 9 Scatter plot of discrete sum of squares of the autocorrelation coefficients




图 10 香农熵特征散点图
Fig. 10 Scatter plot of Shannon entropy




图 11 小波能量熵特征散点图
Fig. 11 Scatter plot of wavelet energy entropy

从图 9 ~ 图 11 中可以看出,三种特征值在三个维度上,对原始电流数据中正常样本和故障样本进行了不同程度的区分。

5.2 实验结果分析

本文研究基于 Tensorflow 框架建立组合网络模型,设置的超参数包括学习率为 $l_r = 0.001$,迭代次数为 $W = 250$,使用 Adam 优化函数。此外,为了更好地分析电弧检测模型效果,需选择更有表达力的评估指标。故障检测问题本质上为一个二分类问题,选用交叉熵作为网络的损失函数来观测模型的预测准确度。评价指标选用准确度来对整个模型的性能进行评估。

为了确保模型能够更高的泛化性,避免过拟合,并提高模型的稳定性,将原始样本的顺序打乱,并划分为训练集以及测试集,训练集占原始数据的 80%,测试集则为剩余的 20%。模型训练的流程如图 12 所示。

基于 Inception-BiLSTM 电弧故障诊断模型的训练曲线如图 13 所示,训练后的模型在测试集上进行检验所得的混淆矩阵如图 14 所示。

5.3 消融试验

为了进一步说明 Inception-BiLSTM 网络的性能,在相同的训练参数、网络结构参数和训练数据的设置下,对 CNN 网络、CNN-LSTM 网络,CNN-BiLSTM,和 CNN-LSTM-BiLSTM 网络进行训练。图 15 所示为不同网络训练过程中准确率的变化曲线。

从图 15 中可以看出,Inception-BiLSTM 网络的训

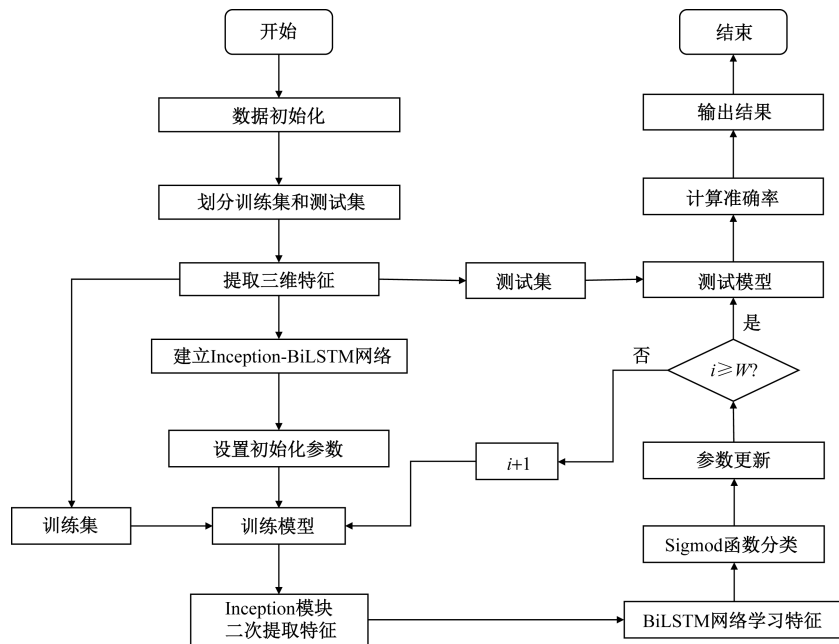


图 12 电弧故障诊断模型流程图
Fig. 12 Arc fault diagnosis model flow chart




图 13 训练集准确率和损失
Fig. 13 Accuracy and loss of training set




图 14 预测结果的混淆矩阵
Fig. 14 Confusion matrix of predicted results

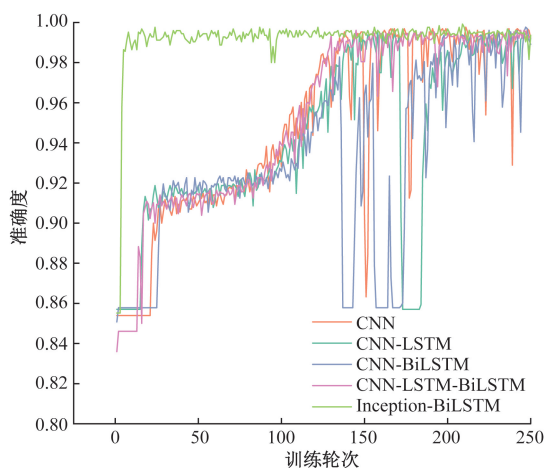


图 15 不同模型的训练曲线
Fig. 15 Training curves for different models

练效率显著优于其他模型,在第 15 轮训练后即达到较高的分类精度。同时,其训练曲线的波动幅度也显著低于其他 4 种模型,进一步证明了该模型在诊

断效率和精度方面的优势。此外,表 2 中记录了训练后的 5 种模型在测试集上的最终预测性能。

由表 2 中的数据可知,BiLSTM 网络的引入显著提高了模型的性能。结合特征提取能力更强的 Inception 模块后,基于 Inception-BiLSTM 的模型在特征提取能力和时序特征捕捉能力方面,相比于单独的 CNN 和简单的堆叠模型有了显著提升。因此,综合来看,基于 Inception-BiLSTM 架构的故障诊断模型的性能优于其他模型。

此外,为了验证本文提出的三种特征值对模型性能的提升,采用不同的训练集和测试集比例,比较了将原始数据集直接用于模型训练和使用三种特征值合并的特征矩阵进行训练所得到的模型在验证集上的诊断结果。具体结果如表 3 所示。

从表 3 中的数据可以看出,通过提取原始电流数据中的三维特征值作为 Inception-BiLSTM 网络的输入,相较于直接使用原始电流数据,能够获得更高的准确率和更快的训练速度,对诊断模型性能有显著提升。此外,随着训练集和测试集比例的变化,直接利用原始数据进行训练的模型准确率波动较大,最高可达 0.990 1,最低可至 0.847 5,表明单独使用网络结构对数据的依赖程度较大,想要获得较好的诊断性能必须选择合适的数据比例,这也导致其故障诊断性能不稳定。而利用所提出的三种特征进行预处理后所获得的输入数据能够帮助提升和稳定模型的训练效果,面对不同比例的训练样本,其最终在测试集上均表现出极高的诊断准确率,且所需训练时间更短。

表 2 不同模型的预测结果

检测模型	模型损失	准确率
CNN	0.256 2	0.917 2
CNN-LSTM	0.270 3	0.908 1
CNN-LSTM-BiLSTM	0.014 1	0.994 6
CNN-BiLSTM	0.038 9	0.990 6
Inception-BiLSTM	0.014 8	0.996 9

表 3 不同数据下模型的诊断结果

训练集: 测试集	检测时间/ms		模型损失		准确率	
	特征数据	原始数据	特征数据	原始数据	特征数据	原始数据
5:5	4	12	0.011 5	0.427 2	0.995 0	0.847 5
6:4	4	12	0.010 7	0.069 8	0.996 9	0.990 1
7:3	4	12	0.014 6	0.061 5	0.995 8	0.989 6
8:2	4	13	0.014 8	0.190 3	0.997 2	0.987 5
9:1	5	13	0.053 0	0.356 8	0.995 7	0.887 5

综合来看,本文中提出的三种特征值不仅在降低了输入信号维度的同时保留了正常电流样本和故障样本之间的关键特征,还进一步提升了模型的鲁棒性和泛化能力。

5.4 对比试验

针对电弧故障诊断问题,深度学习方法因其卓越的特征提取能力而受到广泛关注。然而,传统机器学习方法在某些应用场景中依然展现出良好的性能。在本文中,选取了两种常见的传统机器学习算法构建故障诊断模型,并与本文模型进行对比实验。以测试集上的检测结果为依据,综合记录召回率、准确率和检测时间三个指标,以更全面地评估所提模型的有效性,具体结果如表4所示。

表4 不同诊断模型的性能结果

Table 4 Performance results of different diagnosis models

诊断模型	准确率	召回率	检测时间/ms
本文模型	0.996 9	0.978 6	5
PCA-SVM(PSO)	0.938 0	0.938 0	2 135
特征提取+随机森林 ^[23]	0.982 9	0.982 9	390

表4中其他两种诊断模型包括PCA-SVM(PSO)模型和与参考文献[23]的随机森林模型。PCA-SVM模型首先利用PCA算法对数据进行降维,随后通过SVM进行分类,其中SVM由粒子群算法(particle swarm optimization, PSO)算法进行超参数的优化。尽管该模型通过降维降低了检测时间,并利用智能优化算法提升了SVM的性能,但在处理大规模数据时,其能力明显不及本文所采用的诊断模型。

而参考文献[23]中提出的基于随机森林的故障诊断模型则是提取了包括标注差、平均电流、最大电流等在内的12类特征值,随后采用随机森林算法进行故障识别。尽管该模型在诊断准确率和召回率上有较大的提升,但其特征提取过程需要人工干预,大量特征的提取显著增加了特征选择和数据处理的时间成本。相比之下,本文模型仅使用三类特征,特征维度更为精简。此外,实验结果表明,本文模型的检测时间也明显优于该模型,也证明了本文模型特征的选取和网络的搭建都有助于减少诊断的时间成本。

综上所述,本文模型在综合评估准确性与效率方面,相较于传统机器学习算法,展现出了更卓越的性能。

6 结论

针对航空电缆电弧故障中微小电流变化无法有效识别的问题,提出了一种基于三维特征提取和

Inception-BiLSTM网络的故障诊断模型。该模型有效利用大规模电缆电流数据学习电弧故障的电流特征,实现了高效的电弧故障诊断。通过研究得出以下结论。

(1)本文提出的三种特征值能够有效利用大规模电流数据区分故障样本和正常样本。将这三种特征值合并为新的特征矩阵后,相比于直接使用原始电流数据进行训练,模型的训练速度提升了8 ms,准确率提升了5.5%。

(2)模型具有较好的可扩展性。由于Inception结构具备多尺度特征提取能力,在面对更大规模数据时,可以通过扩展模型的宽度或深度来适应不同的输入数据,展现出较高的适用性。

(3)本文模型在测试集上的最终诊断准确率可达到99.69%,相比于CNN、CNN-LSTM、CNN-BiLSTM以及CNN-LSTM-BiLSTM等简单堆叠模型,故障诊断准确率有显著提升。这表明,相较于单纯的CNN网络,本文模型不仅具有较强的特征提取能力,还兼顾了BiLSTM网络在处理时间序列数据方面的优势。

参 考 文 献

- [1] 刘苏德,王子昕,靖子洋,等. 航空线缆电弧故障引发电气火灾研究综述[J]. 电气工程学报, 2023, 18(3): 18-34.
Liu Sude, Wang Zixin, Jing Ziyang, et al. Review of research on electrical fires caused by arc faults in aviation cables[J]. Journal of Electrical Engineering, 2023, 18(3): 18-34.
- [2] 王尧,张彦风,牛峰,等. 光伏直流电弧电磁辐射特性分析与量方法[J]. 电工技术学报, 2019, 34(14): 2913-2921.
Wang Yao, Zhang Yanfeng, Niu Feng, et al. Analysis and measurement methods of electromagnetic radiation characteristics of photovoltaic DC arc[J]. Transactions of China Electrotechnical Society, 2019, 34(14): 2913-2921.
- [3] Zhao L, Zhou Y, Chen K L, et al. High-speed arcing fault detection: using the light spectrum[J]. IEEE Industry Applications Magazine, 2022, 26(3): 29-36.
- [4] Jiang R, Bao G, Hong Q, et al. A coupling method for identifying arc faults based on short-observation-window SVDR[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.
- [5] Jiang R, Zheng Y. Series arc fault detection using regular signals and time-series reconstruction[J]. IEEE Transactions on Industrial Electronics, 2023, 70(2): 2026-2036.
- [6] 张婷,王海淇,张认成,等. 基于自归一化神经网络的电弧故障检测方法[J]. 仪器仪表学报, 2021, 42(3): 141-149.
Zhang Ting, Wang Haiqi, Zhang Rencheng, et al. Arc fault detection method based on self-normalizing neural network[J]. Chinese Journal of Scientific Instrument, 2021, 42(3): 141-149.
- [7] Wang Y, Zhang F, Zhang X, et al. Series AC arc fault detection method based on hybrid time and frequency analysis and fully connected neural network[J]. IEEE Transactions on Industrial Infor-

- tics, 2019, 15(12): 6210-6219.
- [8] Meng Y, Yang Q, Chen S L, et al. Multi-branch AC arc fault detection based on ICEEMDAN and LightGBM algorithm[J]. *Electrical Power System*, 2023, 220: 109286.
- [9] Wang Y, Hou L, Paul K C, et al. ArcNet: series AC arc fault detection based on raw current and convolutional neural network[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(1): 77-86.
- [10] 戴洪德, 张志亮, 崔伟成, 等. 基于 SSA-SVM 的航空电弧故障检测[J]. *科学技术与工程*, 2024, 24(13): 5626-5633.
Dai Hongde, Zhang Zhiliang, Cui Weicheng, et al. Arc fault detection in aviation based on SSA-SVM[J]. *Science Technology and Engineering*, 2024, 24(13): 5626-5633.
- [11] 李岩, 刘鑫月, 乔俊杰, 等. 基于 1DCNN 和 D-S 多信息融合的光伏系统直流母线串联电弧故障检测[J]. *电工电能新技术*, 2024, 43(5): 58-67.
Li Yan, Liu Xinyue, Qiao Junjie, et al. Detection of series arc faults in dc bus of photovoltaic systems based on 1DCNN and D-S multi-information fusion[J]. *Advanced Technology of Electrical Engineering and Energy*, 2024, 43(5): 58-67.
- [12] Liu X, Huang D, Jing T, et al. Detection of AC arc faults of aviation cables based on H-I-W three-dimensional features and CNN-LSTM neural network [J]. *IEEE Access*, 2022, 10: 106958-106971.
- [13] Riba J R, Moreno-Eguilaz M, Ortega J A. Arc fault protections for aeronautic applications: a review identifying the effects, detection methods, current progress, limitations, future challenges, and research needs [J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-14.
- [14] 火久元, 李昕, 常琛, 等. 基于多尺度特征融合的滚动轴承寿命预测[J]. *北京航空航天大学学报*, 2025. DOI: 10.13700/j.bh.1001-5965.2024.0161.
Huo Jiuyuan, Li Xin, Chang Chen, et al. Rolling bearing life prediction based on multi-scale feature fusion[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2025. DOI: 10.13700/j.bh.1001-5965.2024.0161.
- [15] Miao W, Wang Z, Wang F, et al. Multicharacteristics arc model and autocorrelation-algorithm based arc fault detector for DC microgrid[J]. *IEEE Transactions on Industrial Electronics*, 2023, 70(5): 4875-4886.
- [16] Wang Y, Zhang F, Zhang X, et al. Series AC arc fault detection method based on hybrid time and frequency analysis and fully connected neural network[J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(12): 6210-6219.
- [17] Liu C, Wang F, Zhuo F, et al. Fault diagnosis of HVDC transmission system using wavelet energy entropy and the wavelet neural network [C]//22nd European Conference on Power Electronics and Applications (EPE'20 ECCE Europe). New York: IEEE, 2020: 1-8.
- [18] Ronald M, Poulou A, Han D S. iSPLInception: an inception-ResNet deep learning architecture for human activity recognition [J]. *IEEE Access*, 2021, 9: 68985-69001.
- [19] Mim T R, Amatullah M, Afreen S, et al. GRU-INC: an inception-attention based approach using GRU for human activity recognition[J]. *Expert Systems with Applications*, 2023, 216. DOI: 10.1016/j.eswa.2022.119419.
- [20] 孟宏宇, 张建良, 蔡兆龙, 等. 基于 CNN-BiLSTM-Attention 的直流微电网故障诊断研究[J/OL]. [2025-02-25]. *中国电机工程学报*. <http://kns.cnki.net/kcms/detail/11.2107.TM.20231213.1111.002.html>.
Meng Hongyu, Zhang Jianliang, Cai Zhaolong, et al. Fault diagnosis of DC microgrid based on CNN-BiLSTM-attention[J/OL]. [2025-02-25]. *Proceedings of the Chinese Society for Electrical Engineering*. <http://kns.cnki.net/kcms/detail/11.2107.TM.20231213.1111.002.html>.
- [21] 张印文, 王琳霖, 薛文科, 等. ConvNeXt 网络及 Stacked BiLSTM-Self-Attention 在轴承剩余寿命预测中的应用[J]. *机电工程*, 2024, 41(11): 1977-1985, 1994.
Zhang Yinwen, Wang Linlin, Xue Wenke, et al. Application of ConvNeXt network and stacked BiLSTM-Self-Attention in remaining life prediction of bearings[J]. *Mechanical and Electrical Engineering*, 2024, 41(11): 1977-1985, 1994.
- [22] Chahal H, Toner H, Rahkovsky I. Small data's big AI potential [J]. *Center for Security and Emerging Technology*, 2021, 11: 1-8.
- [23] Emrani A, Pourhomayoun M. Applying machine learning techniques to recognize arc in vehicle 48 electrical systems [C]//IEEE 18th Workshop on Control and Modeling for Power Electronics (COMPEL). New York: IEEE, 2017: 1-4.