

DOI:10.19651/j.cnki.emt.2519267

基于多域融合及 BO-Transformer-BiGRU 的 配电网过电压识别*

李运¹ 徐涛¹ 贾雅君² 江俊杰²

(1. 内蒙古工业大学电力学院 呼和浩特 010000; 2. 上海交通大学电子信息与电气工程学院 上海 200240)

摘要: 针对配电网内部过电压类型识别方法中特征提取与模式识别困难的问题,本文提出一种基于多域融合特征提取和贝叶斯优化(BO)Transformer-BiGRU 相结合的配电网内部过电压识别方法。首先通过多域融合特征提取,将 10 kV 母线中性点过电压信号进行时频、频域、及时频域特征提取,构建具有表征能力的十维特征向量,接着将不同类型过电压的多组 10 维向量输入贝叶斯优化 Transformer-BiGRU 的网络分类器,实现对 5 类典型内部过电压类型识别。为验证方法有效,利用 PSCAD 仿真数据及物理实验平台故障波形,将本文所提算法使用 MATLAB 进行训练和测试,并将测试结果与其他方法进行对比。结果表明,本文所提算法识别准确率高达 99.11%,相较于其他算法具有更强的特征提取能力和更高的识别准确率。

关键词: 10 kV 配电网;内部过电压;类型识别;ICEEMDAN;Transformer-BiGRU

中图分类号: TM771;TN876.3 **文献标识码:** A **国家标准学科分类代码:** 470.40

Overvoltage identification of distribution network based on multi domain fusion and BO-Transformer-BiGRU

Li Yun¹ Xu Tao¹ Jia Yajun² Jiang Junjie²

(1. School of Electric Power, Inner Mongolia University of Technology, Hohhot 010000, China;

2. School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: In response to the difficulty of feature extraction and pattern recognition in the identification of internal overvoltage types in distribution networks, this paper proposes a distribution network internal overvoltage identification method based on multi domain fusion feature extraction and Bayesian optimization Transformer BiGRU. Firstly, through multi domain fusion feature extraction, the 10 kV bus neutral point overvoltage signal is subjected to time-frequency, frequency domain, and time-frequency domain feature extraction to construct a ten dimensional feature vector with representational ability. Then, multiple sets of ten dimensional vectors of different types of overvoltage are input into the Bayesian optimization Transformer BiGRU network classifier to achieve recognition of five typical internal overvoltage types. To verify the effectiveness of the method, PSCAD simulation data and physical experimental platform fault waveforms were used to train and test the algorithm proposed in the paper using MATLAB, and the test results were compared with other methods. The results show that the recognition accuracy of the algorithm proposed in the article is as high as 99.11%, which has stronger feature extraction ability and higher recognition accuracy compared to other algorithms.

Keywords: 10 kV distribution network; internal overvoltage; type identification; ICEEMDAN; Transformer-BiGRU

0 引言

研究表明,在配电网中,80%以上的故障都属于单相接

地故障。这类故障不仅频繁发生,更常常诱发弧光接地和铁磁谐振,这两种过电压往往持续时间长、破坏力强^[1]。严重时可能造成继电保护误动、电气设备损毁,甚至产生火灾风

收稿日期:2025-07-03

* 基金项目:国家电网公司冀北电科院科技项目(SGJBDK00PWJS2400014)、内蒙古自治区自然科学基金(2023LHMS05049)、自治区直属高校基本科研业务费项目(JY20240014)资助

险与停电事故,威胁电力系统安全^[1]。因此,配电网过电压的在线监测与精准辨识,成为监测系统绝缘强度裕度、避免保护装置误动作及供电连续性中断的关键基础,对维护电网安全运行至关重要^[2]。

现有过电压类型辨识方法通常包含两个核心阶段:特征提取与模式识别^[2]。

特征提取方法包括时域分析^[3]、频域分析^[3]、短时傅里叶变化^[4]、小波分析^[5]以及近年来较流行的变分模态分解^[6](variational mode decomposition, VMD),自适应噪声的完全集合经验模态分解^[7](complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)、改进的自适应噪声完备集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)^[8]等。文献[4]通过短时傅里叶变换将过电压时域波形转化为二维的时频图,通过局部特征提取和设置阈值,实现对铁磁谐振过电压的快速识别。文献[5]通过时域、频域及小波变换分析过电压信号特征,但小波分解对复杂暂态信号区分能力不足的问题。文献[6]利用变分模态分解算法对低频振荡信号进行降噪处理;其次通过卷积神经网络对降噪后的低频振荡信号的阶数进行识别。但 VMD 分解参数设置复杂工作量大;CEEMDAN 分解在模式混叠的抑制、计算效率和噪声控制方面较差,并且分解结果的纯净性和鲁棒性较低;ICEEMDAN 分解通过引入高斯白噪声,解决了传统分解方法模态混叠及残余噪声问题^[7-8]。

模式识别阶段,分类器选择尤为关键,目前主流分类器主要包括支持向量机^[9](support vector machine, SVM)、聚类分类^[10]和 CNN^[11](convolutional neural network)。其中,文献[9]提出的 SVM 适合小样本、高维数据任务,擅长处理线性不可分问题;文献[10]提出的聚类分类对初始中心敏感且需预设类别数。文献[11]中改进 CNN 的计算复杂度较高,且对噪声敏感。神经网络是通过多层非线性变换,Transformer^[12]和 BiGRU^[13]作为神经网络变体,虽然 Transformer 和 BiGRU 在时序分类中表现优异,但单独使用时仍存在不足;Transformer 对局部时序模式捕捉有限, BiGRU 难以建模长程依赖^[14];而 Transformer-BiGRU 又存在耗时较长的缺点^[14]。

本文通过提取时域特征,频域特征,以及 ICEEMDAN 分解结合奇异值分解提取的时频域特征,构建具有综合表征能力的十维特征向量;解决了传统单一特征表征能力不足的问题,并通过贝叶斯优化(Bayesian optimization, BO)的 Transformer-BiGRU 分类器,其中贝叶斯优化的自适应参数搜索从而协同发挥 Transformer-BiGRU 的优势,实现了对 5 类典型配网内部过电压的准确分类。之后,利用 PSCAD 电磁仿真与真实故障录波数据进行对比实验,验证该方法在 5 类典型过电压场景中的平均识别准确率。

1 过电压多域融合特征值提取方法

过电压多域融合特征值提取方法通过系统性地联合时域、频域和时频域 3 个维度的特征信息,构建具有更强表征能力和更高判别性的综合特征向量。该方法的核心在于采用多维度的特征提取与融合过程:在时域维度捕捉信号的瞬态特性和波形畸变特征;在频域维度分析信号的频谱分布特性;在时频域维度通过信号分解表征信号的时变频率特性。多域融合特征对于波形特征相似的过电压类型,如弧光接地与基频谐振,具有更好的识别效果。

1.1 时域特征

为了准确反映信号在异常扰动下的时域特征,提取对冲击类事件的识别能力。文章选取 4 个无量纲特征量作为时域特征提取,包括^[3]:峰值因子 C ,表示信号振动的剧烈程度;冲击因子 I ,反映信号波形与其绝对平均值的距离;峭度因子 K ,表示信号波形曲线顶端的尖峭或平坦程度;裕度因子 M ,用于衡量信号尖锐程度,对异常冲击事件敏感。

$$C = \frac{U_p}{U_{rms}} \quad (1)$$

$$I = \frac{U_p}{|U|} \quad (2)$$

$$K = \frac{1}{N} \sum_{i=1}^N u_i^4 \quad (3)$$

$$M = \frac{U_p}{\left(\frac{1}{N} \sum_{i=1}^N \sqrt{|u_i|}\right)^2} \quad (4)$$

其中, U_p 为电压峰值, U_{rms} 为电压有效值, u_i 为电压信号数据, N 为采样数据点数。

1.2 频域特征

选取归一化重心频率 NSC 与归一化频率偏差 NFD 两个无量纲特征量作为频域特征提取参量。

$$NSC = \frac{f_c - f_{min}}{f_{max} - f_{min}} \quad (5)$$

$$f_c = \frac{\sum f_i \cdot P(f_i)}{\sum P(f_i)} \quad (6)$$

$$NFD = \sqrt{\frac{\sum (f_i - f_c)^2 \cdot P(f_i)}{\sum P(f_i)}} \times \frac{1}{f_{max} - f_{min}} \quad (7)$$

式中: f_c 为重心频率, $P(f_i)$ 表示 f_i 对应的功率谱密度, NSC 用来描述信号能量的中心位置,用于区分不同频率特性的信号,越大说明频率越高; NFD 用来描述频谱集中或分散的程度,越大说明信号频率越分散,范围均在 $[0,1]$ 。

1.3 时频域特征

选取 ICEEMDAN 作为时频域特征提取方法,其流程为:

改进的自适应噪声完全集合经验模态分(ICEEMDAN),

其是在经验模态分解(EMD)基础上改进而来的分解方法,有效解决了EMD和EEMD中的模态混叠问题及残余噪声问题。分解步骤为^[8]:

1)在原始信号 X 中加入高斯白噪声,构造待分解信号:

$$x^i = x + \beta_0 E_1(\tau^i) \quad (8)$$

式中: x^i 是加入噪声后的信号; β_0 是噪声系数; τ^i 是噪声,均值和方差分别为 0 和 1。

2)使用 EMD 对加噪信号进行分解,取其局部均值的平均值,得到第 1 个模态分量。

$$IMF_1 = x - \langle M(x^i) \rangle \quad (9)$$

式中: $M(x^i)$ 表示输入信号的局部均值, $\langle \cdot \rangle$ 表示计算的平均值。

3)计算残差信号 $r_1 = x - IMF_1$ 对其降噪,得到后续模态分量。

$$IMF_2 = r_1 - \langle M[r_1 + \beta_1 E_2(\tau^i)] \rangle \quad (10)$$

式中: r_1 表示第 1 阶残差信号, β_1 表示第 2 次噪声加入的系数, $E_2(\tau^i)$ 表示第 2 次噪声分量。

4)重复上述步骤,直至残差信号满足终止条件,最终得到全部 IMF 分量。

1.4 多域融合特征值方法及数据预处理流程

选取过电压发生前后 5 个工频周期(前 1 后 4)的三相电压信号作为研究对象,采样频率为 100 kHz。以一组配电网中性点过电压数据进行说明,将配电网中性点电压进行时域特征提取,频域特征提取,将提取出的特征依次排列构成一个 1 行 6 列的相量。提取其时频域特征时,对其进行 ICEEMDAN 分解,计算每个本征模态函数(intrinsic mode function,IMF)分量与原图像的相关性系数 $r^{[15]}$,选取相关性系数较大的前四个分量,组成一个 4 行 n 列的特征矩阵,并进行奇异值分解^[16],得到一个 4 行 n 列的对角阵,将对角阵上的元素依序排列成行,构成一个 1 行 4 列的奇异值特征值相量,将两相量首位相接组成一个 1 行 10 列的特征相量。最终构成包含 n 行 10 列特征的数据集,具体多域融合^[17]特征值数据预处理流程图如图 1 所示。

2 贝叶斯优化 Transformer-BiGRU 模式识别模型

贝叶斯优化的 Transformer-BiGRU^[14]混合模型,结合了 Transformer 的长序列特征提取能力和 BiGRU 的时序建模优势,通过贝叶斯优化算法自动调整网络结构和超参数。Transformer 模块处理全局特征关系,BiGRU 模块分析局部时序特征,两者协同工作提升分类性能。该方法在过电压识别任务中表现出较好的准确性和泛化能力。

2.1 贝叶斯优化算法

贝叶斯优化^[18]通过高斯过程建立目标函数的代理模型,利用采集函数动态选择采样点。该方法以最少评估次数实现黑盒函数优化,适用于超参数调优等场景,流程如图 2 所示。

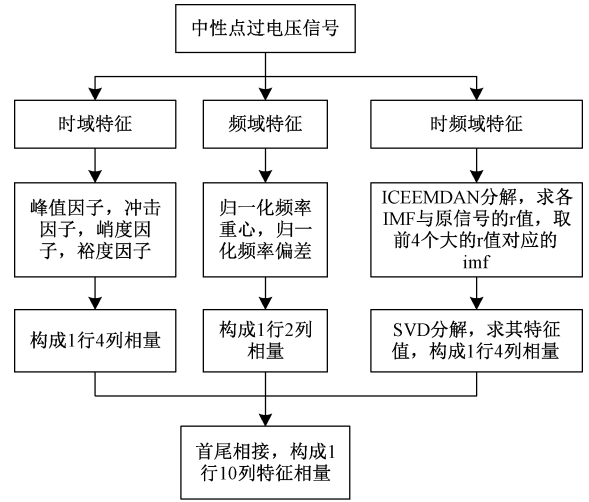


图 1 数据预处理流程图

Fig. 1 Data preprocessing flow chart

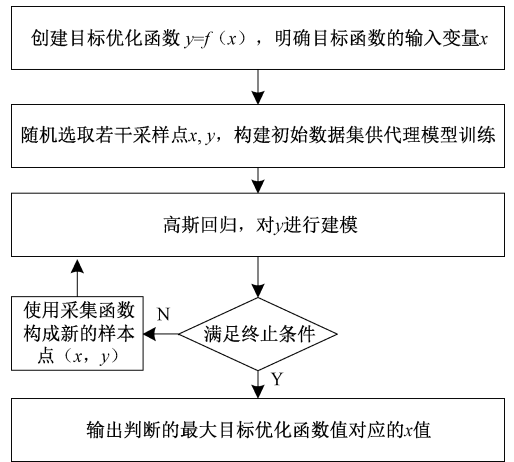


图 2 贝叶斯优化流程图

Fig. 2 Bayesian optimization flowchart

2.2 Transformer

在计算机视觉和自然语言处理等领域,Transformer 编码器架构在多种任务中表现优异,较传统网络具有显著优势。标准 Transformer 包含编码器和解码器,对于非生成类任务,仅需编码器即可高效提取特征,其架构如图 3 所示。

2.3 BiGRU

BiGRU 将 GRU 的计算过程应用于输入数据的两个方向(正向和反向),提升了其对上下文信息的建模能力。GRU 的结构示意图如图 4 所示。

GRU 模型的计算过程为:首先,根据前一时刻的隐藏状态 h_{t-1} 与当前输入 x_t ,计算重置门 r_t 与更新门 z_t 。随后结合 r_t 与当前输入 x_t ,推导出当前的临时隐藏状态 \tilde{h}_t 。最后最后利用 z_t 与 \tilde{h}_t 来计算最终的隐藏状态 h_t 。公式如式(11)~(14)所示。

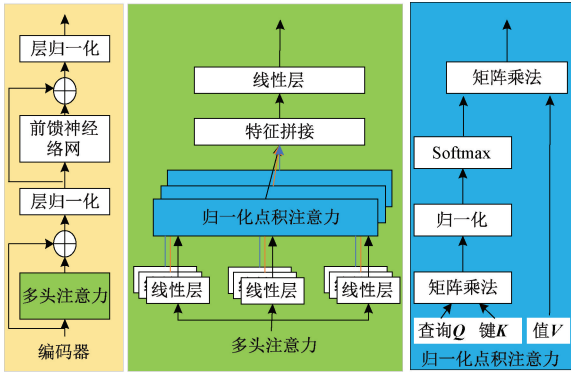


图 3 Transformer 架构

Fig. 3 Transformer architecture

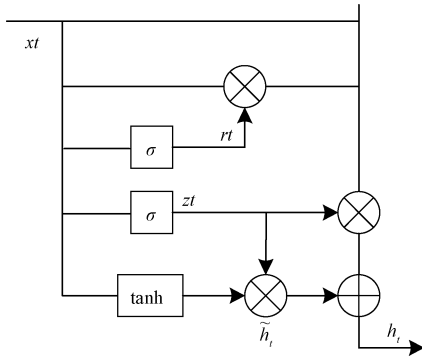


图 4 GRU 结构示意图

Fig. 4 GRU structure diagram

$$z_t = \sigma(\mathbf{W}_z \cdot [h_{t-1}, x_t] + \mathbf{b}_z) \quad (11)$$

$$r_t = \sigma(\mathbf{W}_r \cdot [h_{t-1}, x_t] + \mathbf{b}_r) \quad (12)$$

$$\tilde{h}_t = \tanh(\mathbf{W}_h \cdot [r_t \times h_{t-1}, x_t] + \mathbf{b}_h) \quad (13)$$

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \quad (14)$$

其中, \mathbf{W} 和 \mathbf{b} 为不同输入 x 上的权重矩阵, σ 是 sigmoid 激活函数, \tanh 是双曲正切激活函数^[19]。

2.4 贝叶斯优化 Transformer-BiGRU 辨识流程

本文提出贝叶斯优化 Transformer-BiGRU 模型采用迭代优化的闭环流程,如图 5 所示。该流程通过 15 次^[20]循环迭代实现超参数自动优化与模型训练的协同:每次迭代中,首先使用当前超参数配置训练 Transformer-BiGRU 模型,其中 Transformer 层提取全局特征,双向 GRU 捕获局部时序特征,输出分类错误率;然后将错误率反馈至贝叶斯优化模块,基于高斯过程代理模型和 EI 采集函数生成下一组改进的超参数(包括隐藏单元数、学习率和 L2 正则化系数)。经过 15 次的训练-评估-更新循环后,系统选择最优超参数组合进行最终模型训练,实现时序数据分类。

2.5 评价指标

为了全面评估此模型的性能,文章采用以下评价指标:准确率 $R_{accuracy}$ 、精确率 $R_{precision}$ 、召回率 R_{recall} 、曲线下面积 AUC、损失函数 F_{Loss} 。

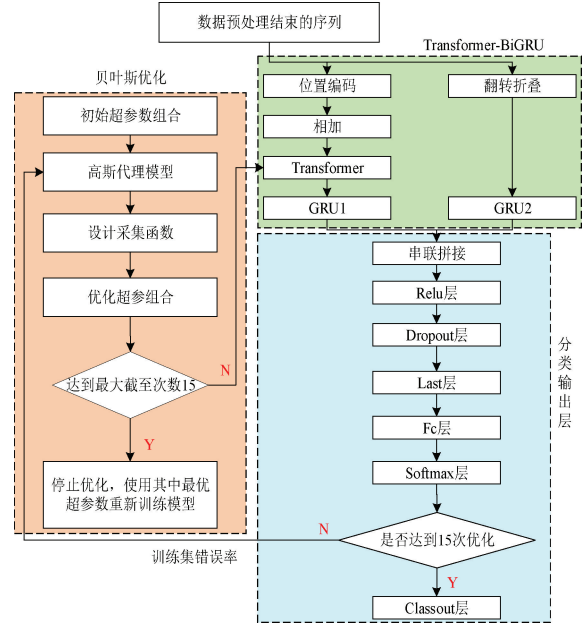


图 5 贝叶斯优化 Transformer-BiGRU 流程图

Fig. 5 Bayesian optimization Transformer-BiGRU flowchart

$$R_{accuracy} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}} \quad (15)$$

$$R_{precision} = \frac{N_{TP}}{N_{FP} + N_{TP}} \quad (16)$$

$$R_{recall} = \frac{N_{TP}}{N_{FP} + N_{FN}} \quad (17)$$

$$F1 = 2 \times \frac{R_{precision} \times R_{recall}}{R_{precision} + R_{recall}} \quad (18)$$

$$FPR = \frac{N_{FP}}{N_{FP} + N_{TN}} \quad (19)$$

$$TPR = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (20)$$

$$AUC = \int_0^1 TPR(FPR) dFPR \quad (21)$$

$$F_{Loss} = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C y_{ij} \log(\hat{y}_{ij}) \quad (22)$$

其中,真正例 N_{TP} 表示正确预测为正类的样本数,假正例 N_{FP} 表示错误预测为正类的样本数,假负例 N_{FN} 表示错误预测为负类的样本数,真正例 N_{TN} 表示正确预测为负类的样本数^[21], N 为样本数量, C 为类别数量, y_{ij} 为样本 i 的真实标签, \hat{y}_{ij} 为样本的模型预测概率。

3 仿真与分析

3.1 仿真模型

本研究通过 PSCAD/EMTDC 电磁暂态仿真软件构建了 10 kV 变电站仿真模型。该模型的主接线设计及基础参数来源于上海某实际变电站。系统结构如图 6 所示,该仿真系统能够有效模拟配电网内部过电压。线路参数由表 1 所示,变压器励磁感抗为 X_m ,线路容抗参数为 X_{c0} ,当线路发

生故障时,变压器发生饱和,变压器励磁感抗减小,根据 Peterson H. A 理论,阻抗参数 $X_{c0}/X_m=0.01\sim 0.07$ 时系统产生分频谐振; $X_{c0}/X_m=0.07\sim 0.55$ 时,系统产生基频谐振; $X_{c0}/X_m=0.55\sim 2.8$ 时系统产生高频谐振。实验共构建 5 类过电压样本集,每类 300 组数据共 1 500 组,详细生成条件如表 2 所示。

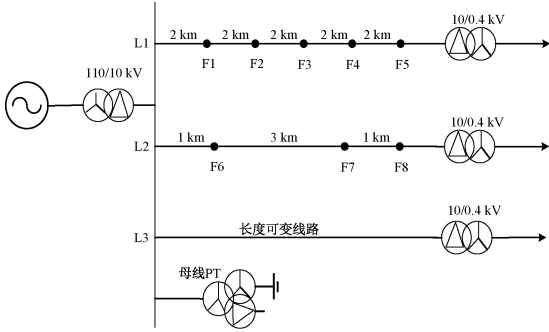


图 6 10 kV 配电网仿真系统结构图

Fig. 6 Structure diagram of 10 kV distribution network simulation system

表 1 线路参数

Table 1 Line parameters

参数类型	R/($\Omega\cdot\text{km}^{-1}$)	L/(mH $\cdot\text{km}^{-1}$)	C/(nF $\cdot\text{km}^{-1}$)
正序	0.17	1.20	10.4
零序	0.23	5.47	7.4

3.2 信号特征的抗混叠效果分析

1) CEEMDAN 与 ICEEMDAN 分解效果对比

以分频铁磁谐振为例,选取其做 ICEEMDAN 与 CEEMDAN 分解,噪声标准差均为 0.1,其分解图以及频谱分析图如图 7~10 所示。在图 7 中,信号被分解为 10 个不同频率的 IMF。在图 9 中,信号被分解为 7 个不同频率的 IMF。且 CEEMDAN 分解的相邻 IMF 频率重叠较明显。ICEEMDAN 的相邻 IMF 频率间隔更大,频域分离度显著优于 CEEMDAN,有效抑制了混叠效应。

2) 提取特征的抗混叠效果对比

选取这 5 类过电压的中性点电压作为特征提取信号,

表 2 过电压样本产生条件

Table 2 Conditions for overvoltage sample generation

过电压类型	过电压相别	过电压位置/线路长度	故障电阻/ Ω	故障相角	样本数
单相接地	A、B、C	F1~F8	1~20	$30^\circ, 90^\circ, 150^\circ, 210^\circ, 270^\circ, 330^\circ$	300
弧光接地	A、B、C	F1~F8	1~20	$30^\circ, 90^\circ, 150^\circ, 210^\circ, 270^\circ, 330^\circ$	300
分频铁磁谐振	A、B、C	9~14 km	1~10	$30^\circ, 90^\circ, 150^\circ, 210^\circ$	300
基频铁磁谐振	A、B、C	5~8 km	1~10	$30^\circ, 90^\circ, 150^\circ, 210^\circ$	300
高频铁磁谐振	A、B、C	0.25~1 km	1~10	$30^\circ, 90^\circ, 150^\circ, 210^\circ$	300




图 7 CEEMDAN 分解图

Fig. 7 CEEMDAN decomposition diagram




图 8 CEEMDAN 分解频谱图

Fig. 8 CEEMDAN decomposition spectrum diagram

随机选择每类过电压的 10 组数据,进行时域,频域,时频域分析,基于篇幅限制,展示了峰值因子,归一化频率偏




图 9 ICEEMDAN 分解图

Fig. 9 ICEEMDAN decomposition diagram




图 10 ICEEMDAN 分解频谱图

Fig. 10 ICEEMDAN decomposition spectrum diagram

差,以及与原信号相关系数最大的 IMF 分量奇异值分解的相关幅值,分别如图 11~13 所示。

整体来看,这些时域、频域和时频域指标展现出每类过电压信号的独特特征,能够减少信号重叠,确保了信号的精确识别和抗干扰能力。

3.3 贝叶斯优化的 Transformer-BiGRU 实验结果

1) 网络参数设置

贝叶斯优化的 Transformer-BiGRU 网络参数如表 3 所示,经过寻优以后,得到 GRU 隐藏层节点数为 54,初始学习率为 0.001 938 9,L2 正则化系数为 0.001 882 4,最小目标函数值为 0.066 673,总训练时间为 1 843.56 s,目标函数计算时间为 1 785.30 s。




图 11 峰值指标

Fig. 11 Peak indicator




图 12 归一化频率偏差

Fig. 12 Normalized frequency deviation




图 13 与原信号相关系数最大的 IMF 奇异值分解

Fig. 13 Singular value decomposition of IMF with the highest correlation coefficient with the original signal

2) 分类结果

图 14 展示了以目标函数最小值为优化目标的贝叶斯优化过程。第 3 次函数评估之后,目标函数值迅速下降,从约 0.8 降至接近 0,此时贝叶斯优化能够快速找到一个较优解。随着优化的进行,第 4 次函数评估后,目标函数

表 3 网络参数

Table 3 Network parameters

参数名称	值或范围	说明
训练集比例	0.7	数据集中,70%用作训练
隐藏层节点数	[10,60]	GRU 隐藏层节点范围,优化得出
初始学习率	$[1 \times 10^{-3}, 1]$	学习率范围,优化得出
L2 正则化系数	$[1 \times 10^{-10}, 1 \times 10^{-2}]$	L2 范围,优化得出
最大训练轮数	200	模型训练的最大迭代次数
小批量样本数	256	每次训练的小批量样本数
Dropout 比例	0.01	随机丢弃神经元的比例
多头注意力头数	4	自注意力机制中的头数
最大编码长度	512	Transformer 的位置嵌入长度
梯度裁剪阈值	10	避免梯度爆炸




图 14 贝叶斯优化过程中目标函数值收敛曲线


Fig. 14 Convergence curve of objective function values in Bayesian optimization process and network parameters

值逐渐趋于稳定,并在后续优化中保持在接近 0 的水平。此外,观测值与估计值高度一致,进一步验证了贝叶斯优化对目标函数估计的准确性。


图 15 展示了模型在训练集上的准确率和损失函数变化曲线。在训练初期,模型准确率迅速提升,损失值显著下降,表明模型能够快速学习训练数据中的特征^[22]。在迭代次数超过 300 次后,准确率趋于稳定并接近 100%,损失值也逐渐收敛至接近 0,说明模型已充分拟合训练数据,训练过程收敛性良好。

图 16 和 17 分别展示了模型在训练集和测试集上的混淆矩阵结果。训练集分类准确率达到 99.33%,测试集分类准确率为 99.11%,两者非常接近,大多数类别的分类完全正确,但类别 2 即弧光接地部分样本被错误分类为类别 1 即单相接地部分,其中训练集 7 个,测试集 4 个。这一分类偏差与类别 2 的特性或样本分布相关。

图 18 展示了模型在测试集上的 ROC 曲线,AUC 值达到 0.994 44,表明模型整体分类性能极为优异。ROC 曲线紧贴左上角,显示模型在保持高真正类率(TPR)的同



(a) 准确率曲线
(a) Accuracy curve



(b) 损失函数曲线
(b) Loss function curve

图 15 训练集准确率和损失值随迭代次数的变化
Fig. 15 The accuracy and loss value of the training set vary with the number of iterations

时,能够有效控制假正类率(FPR)。

3.4 不同方法的效果对比

为了对所提方法的性能进行评估,将样本划分为训练集和测试集,比例为 1 200:300。分类器的最大训练次数为 5 000 次。

特征值提取中 T 代表时域,F 代表频域,TF 代表时频域。分类器包括 LSTM^[23],RNN^[23],Transformer,BiGRU,Transformer-BiGRU,BO-TB(贝叶斯优化的 Transformer-BiGRU)。在加入 -10 dB 白噪声后的测试结果展示在图 19 和 20 中。通过从训练时间和分类准确率两个方面对比不同模型的性能,可以得出一些结论。




图 16 训练集混淆矩阵

Fig. 16 Training set confusion matrix




图 17 测试集混淆矩阵

Fig. 17 Test set confusion matrix




图 18 测试集 ROC 曲线及 AUC 结果

Fig. 18 ROC curve and AUC results of the test set

首先,在训练时间方面,传统的 RNN 和 LSTM 模型在处理复杂特征组合(如 T+F+TF)时,训练耗时明显增加,

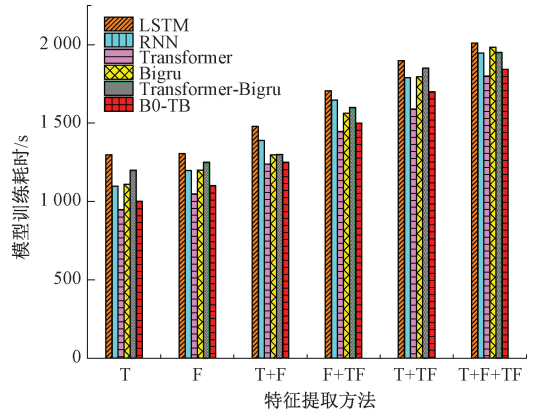


图 19 特征提取方法对模型训练耗时的影响

Fig. 19 The impact of feature extraction methods on model training time

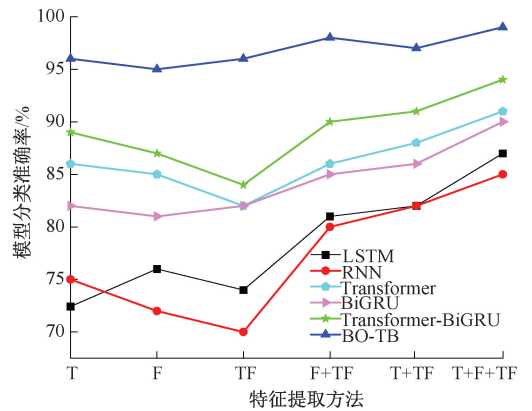


图 20 特征提取方法对模型分类性能的影响

Fig. 20 The impact of feature extraction methods on model classification performance

主要受限于梯度消失,它们需要更多的计算资源来完成训练。相比之下,BO-TB 和 Transformer-BiGRU 模型凭借高效的结构设计和超参数优化,在相同条件下训练时间更短,收敛更快。

其次,在分类准确率方面,BO-TB 和 Transformer-BiGRU 在所有特征提取方法下都表现出了最高的分类准确率。BO-TB 通过其优化的结构和高效的计算方法,在保证较低训练时间的同时,也能够实现高准确率的分类表现。而 Transformer-BiGRU 次之。传统的 RNN 和 LSTM 模型因其抗噪能力不足,在复杂特征下分类准确率大幅降低。

综合来看,BO-TB 模型在训练效率和分类准确率之间达到了最佳的平衡,尤其适用于处理复杂特征的大规模分类任务,表现出了极大的潜力。Transformer-BiGRU 作为次优选择,传统的 RNN 和 LSTM 模型在现代复杂任务中其性能明显不足。

4 配电网物理实验平台验证

为验证该方法的实际可行性,采用配电网物理实验平台^[24-25]进行实际验证,结构包含 7 条线路,包括电缆、架空以及缆线混合线路。通过在线路末端设置可编程故障点,利用电力电子开关模拟不同接地阻抗。该实验平台用来仿真单相接地故障,模拟的配网结构如图 21 所示,实物如图 22,实验系统参数如文献[25]。

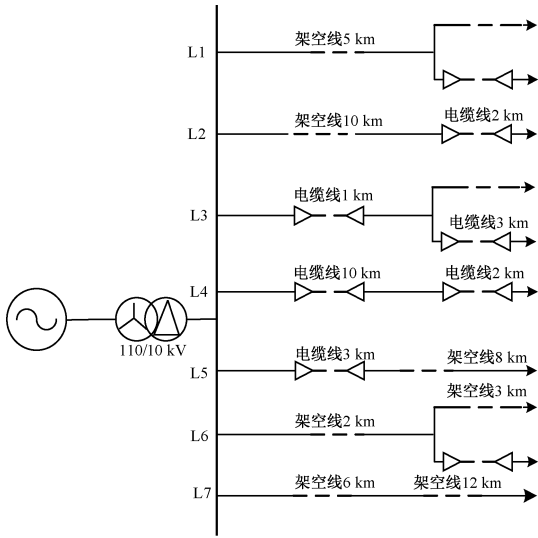


图 21 物理仿真结构网络

Fig. 21 Physical simulation structure network



图 22 物理仿真系统实物

Fig. 22 Physical simulation system physical object

以 10 kHz 采样率采集保护装置端电压波形。实验测试结果如表 4 所示,结果表明:基于贝叶斯优化的 Transformer-BiGRU 模型对 110 组接地过电压样本的识别准确率达 100%,验证了其在跨模型应用中的有效性。

表 4 不同算法在物理实验平台的测试结果

Table 4 Experimental results of different algorithms in physical simulation system

算法	-10 dB 噪声下的 准确率/%	处理耗时/ s
RNN	72.5	28.6
LSTM	78.3	24.2
Transformer	85.7	19.4
BiGRU	88.6	17.8
Transformer-BiGRU	92.4	16.3
BO-TB	100	14.1

5 结 论

提出了一种基于贝叶斯优化 Transformer-BiGRU 的配电网内部过电压识别方法。结合时域、频域和 ICEEMDAN 时频域特征提取,并利用奇异值分解优化特征,成功实现了 5 种过电压类型的识别。

贝叶斯优化的 Transformer-BiGRU 模型通过自动优化超参数,高效提取时序数据的全局和局部特征,实现了 99.33% 的训练集准确率和 99.11% 的测试集准确率。与其他分类方法相比,该模型在过电压识别中表现出更强的学习能力和分类性能,物理仿真平台验证进一步显示,对 110 组实际过电压样本的识别准确率达 100%。

本文方法在配电网实时监测和预警系统中的应用前景广阔,可为电力系统的安全稳定运行提供有力支持。

参考文献

[1] 余佳文. 基于 MultiRocket 的配电网基频铁磁谐振过电压和弧光接地过电压识别方法[D]. 南昌:南昌大学,2024.
YU J W. Identification method of fundamental frequency ferromagnetic resonance overvoltage and arc grounding overvoltage in distribution network based on MultiRocket[D]. Nanchang:Nanchang University, 2024.

[2] 徐浩,刘利强,吕超. 基于迁移学习的配电网内部过电压识别方法[J]. 中国电力,2021,54(8):52-59.
XU H, LIU L Q, LYU CH. Internal overvoltage identification method for distribution network based on transfer learning [J]. China Electric Power, 2021, 54(8): 52-59.

[3] 郑开心. 基于时频域特征量融合的配电网基频铁磁谐振过电压和弧光接地过电压识别方法[D]. 南昌:南昌大学,2023.
ZHENG K X. Identification method of fundamental frequency ferromagnetic resonance overvoltage and arc grounding overvoltage in distribution network based on time-frequency domain feature fusion[D]. Nanchang:

- Nanchang University, 2023.
- [4] 张乐乐, 王海云, 王维庆. 基于 CEEMDAN 和 HT 的谐波检测新方法[J]. 电测与仪表, 2023, 60(6): 147-152.
ZHANG L L, WANG H Y, WANG W Q. A new method for harmonic detection based on CEEMDAN and HT[J]. Electrical Measurement and Instrumentation, 2023, 60(6): 147-152.
- [5] 杨川. 基于双树复小波变换的配电网内部过电压类型识别研究[D]. 福州: 福州大学, 2018.
YANG CH. Research on identification of internal overvoltage types in distribution networks based on double tree complex wavelet transform [D]. Fuzhou: Fuzhou University, 2018.
- [6] 王珍意, 朱欣春, 胡斌, 等. 基于深度学习和 VMD 算法的电力系统低频振荡模式辨识[J]. 电工电能新技术, 2025, 44(5): 56-65.
WANG ZH Y, ZHU X CH, HU B, et al. Identification of low-frequency oscillation modes in power systems based on deep learning and VMD algorithm [J]. New Technologies in Electrical Engineering, 2025, 44(5): 56-65.
- [7] 梁晓龙, 李金刚, 徐平平, 等. 基于 CEEMDAN-CNN-LSTM 的供热异常数据检测与清洗[J]. 电子测量技术, 2024, 47(11): 20-27.
LIANG X L, LI J G, XU P P, et al. Detection and cleaning of abnormal heating data based on CEEMDAN-CNN-LSTM[J]. Electronic Measurement Technology, 2024, 47(11): 20-27.
- [8] 白隆, 俞斌, 高峰, 等. 基于 ICEEMDAN 和 TCN-AM-BiGRU 的短期光伏功率预测[J]. 电子测量技术, 2024, 47(9): 61-69.
BAI L, YU B, GAO F, et al. Short term photovoltaic power prediction based on ICEEMDAN and TCN-AM-BiGRU [J]. Electronic Measurement Technology, 2024, 47(9): 61-69.
- [9] 杨旭, 张涛, 李玉梅, 等. ISSA 优化 SVM 的电机滚动轴承故障诊断[J]. 电子测量技术, 2023, 46(15): 186-192.
YANG X, ZHANG T, LI Y M, et al. ISSA optimized SVM for motor rolling bearing fault diagnosis[J]. Electronic Measurement Technology, 2023, 46(15): 186-192.
- [10] 未争超, 乔强, 郎俊杰, 等. 基于深度学习与聚类的开集个体识别技术[J]. 电子测量技术, 2025, 48(5): 111-117.
WEI ZH CH, QIAO Q, LANG J J, et al. Open set individual recognition technology based on deep learning and clustering[J]. Electronic Measurement Technology, 2025, 48(5): 111-117.
- [11] 刘丽丽, 谢梦, 王艳, 等. 基于聚类的 AW-CNN-LSTM 光伏功率预测方法[J]. 电子测量技术, 2025, 48(18): 92-99.
LIU L L, XIE M, WANG Y, et al. A clustering-based AW-CNN-LSTM method for photovoltaic power forecasting[J]. Electronic Measurement Technology, 2025, 48(18): 92-99.
- [12] 孟衡, 张涛, 王金, 等. 基于多尺度时空图卷积网络与 Transformer 融合的多节点短期电力负荷预测方法[J]. 电网技术, 2024, 48(10): 4297-4311.
MENG H, ZHANG T, WANG J, et al. Multi node short-term power load forecasting method based on multi-scale spatiotemporal graph convolutional network and Transformer fusion [J]. Grid Technology, 2024, 48(10): 4297-4311.
- [13] 孙柳萌, 杨永杰, 张宁涛. L1 正则化和 BiGRU 模型的轴承状态预测研究[J]. 电子测量技术, 2024, 47(4): 58-65.
SUN L M, YANG Y J, ZHANG N T. Research on bearing state prediction using L1 regularization and BiGRU model[J]. Electronic Measurement Technology, 2024, 47(4): 58-65.
- [14] 蒲晓云, 杨靖, 杨兴, 等. 基于分解技术的 IZOA-Transformer-BiGRU 短期风电功率预测[J]. 电子测量技术, 2025, 48(2): 39-48.
PU X Y, YANG J, YANG X, et al. Short term wind power prediction of IZOA-Transformer-BiGRU based on decomposition technology [J]. Electronic Measurement Technology, 2025, 48(2): 39-48.
- [15] 李杰, 赵海波, 李宗杰, 等. 基于 Pearson 系数与多元线性拟合的 330 MW 汽轮机高压汽缸轴向膨胀定量监测方法[J]. 汽轮机技术, 2024, 66(4): 299-302.
LI J, ZHAO H B, LI Z J, et al. Quantitative monitoring method for axial expansion of high-pressure cylinder of 330 MW steam turbine based on Pearson coefficient and multivariate linear fitting[J]. Turbine Technology, 2024, 66(4): 299-302.
- [16] 孙传铭, 魏隆, 张梦楠, 等. 自适应奇异值分解局放信号降噪方法[J]. 电工电能新技术, 2021, 40(5): 34-41.
SUN CH M, WEI L, ZHANG M N, et al. Adaptive singular value decomposition for partial discharge signal denoising[J]. New Technologies in Electrical Engineering and Energy, 2021, 40(5): 34-41.
- [17] 肖健, 党选举. 多域特征融合的脑电信号肢体运动特征提取与动作识别[J]. 电子测量技术, 2024, 47(18): 23-30.
XIAO J, DANG X J. Multi domain feature fusion for

- EEG signal limb motion feature extraction and action recognition[J]. *Electronic Measurement Technology*, 2024, 47(18): 23-30.
- [18] 吴江平,刘若晨,孙见忠,等. 基于 BO 优化 SVM 轴承故障的静电信号识别方法[J]. *电子测量技术*, 2024, 47(18):15-22.
- WU J P, LIU R CH, SUN J ZH, et al. Static signal recognition method for SVM bearing faults based on BO optimization [J]. *Electronic Measurement Technology*, 2024, 47(18): 15-22.
- [19] 程航,段燕北,魏欣. iKcr-RG: 基于 ResNet 和 BiGRU 的双分支策略预测非组蛋白质赖氨酸酰化位点[J]. *中国生物化学与分子生物学报*, 2025, 41(2): 305-314.
- CHENG H, DUAN Y B, WEI X. iKcr-RG: Prediction of non histone lysine acylation sites based on ResNet and BiGRU dual branch strategy [J]. *Chinese Journal of Biochemistry and Molecular Biology*, 2025, 41(2): 305-314.
- [20] SHAHRIARI B, SWERSKY K, WANG Z Y, et al. Taking the human out of the loop: A review of Bayesian optimization[J]. *Proceedings of the IEEE*, 2015, 104(1):148-175.
- [21] 刘健洵. 基于改进图正则化的堆叠自编码器及其在故障诊断方面的应用[D]. 北京:北京化工大学, 2023.
- LIU J X. Stacked autoencoder based on improved graph regularization and its application in fault diagnosis[D]. Beijing: Beijing University of Chemical Technology, 2023.
- [22] 晏婷,何朝良,全骞,等. 基于双编码 U-Net 及离散小波变换的 CBCT 图像散射校正[J]. *光学学报*, 2025, 45(9):107-121.
- YAN T, HE CH L, TONG Q, et al. CBCT image scattering correction based on dual encoding U-Net and discrete wavelet transform [J]. *Acta Optica Sinica*, 2025, 45(9): 107-121.
- [23] 朱晓红,杨伟荣,张蓉,等. 基于 RNN-LSTM 神经网络的小电流接地故障选线方法[J]. *高压电器*, 2023, 59(7):213-220.
- ZHU X H, YANG W R, ZHANG R, et al. Line selection method for small current grounding faults based on RNN-LSTM neural network [J]. *High Voltage Apparatus*, 2023, 59(7): 213-220.
- [24] 许晔,郭谋发,陈彬,等. 配电网单相接地电弧建模及仿真分析研究[J]. *电力系统保护与控制*, 2015, 43(7): 57-64.
- XU Y, GUO M F, CHEN B, et al. Research on modeling and simulation analysis of single phase grounding arc in distribution network [J]. *Power System Protection and Control*, 2015, 43(7): 57-64.
- [25] GUO M F, YANG N CH, YOU L X. Wavelet-transform based early detection method for short-circuit faults in power distribution networks [J]. *International Journal of Electrical Power and Energy Systems*, 2018, 99:706-721.

作者简介

李运, 硕士研究生, 主要研究方向为配电网内部过电压识别与抑制。

E-mail: 2733312076@qq.com

徐涛, 硕士, 副教授, 硕士生导师, 主要研究方向为电力系统稳定与控制。

E-mail: xutao_569@163.com

贾雅君(通信作者), 博士, 高级工程师, 主要研究方向为配网自动化及设备状态监测。

E-mail: jiayajun@sjtu.edu.cn