

基于 TNN-BL 模型的低压配电网断零与缺相故障检测方法研究

林师远*, 黄雄, 吴天杰, 罗杰, 陈锐忠, 林少佳
(海南电网有限责任公司琼海供电局, 海南琼海 571442)

Research on Detection Method for Open-Neutral and Open-Phase Faults in Low-Voltage Distribution Networks Based on TNN-BL Model

LIN Shiyuan*, HUANG Xiong, WU Tianjie, LUO Jie, CHEN Ruizhong, LIN Shaojia
(Qionghai Power Supply Bureau of Hainan Power Grid Co., Ltd., Qionghai 571442, China)

Abstract: The potential safety risks and economic losses caused by open-neutral and open-phase faults in low-voltage distribution networks have been longstanding challenges for power grid companies. With the popularization of intelligent detection equipment in power grids, fault detection can now be performed using voltage and sequence current data collected by smart meters on the low-voltage side. This paper first established a hybrid model, TNN-BL, based on transformer neural network (TNN) and bi-directional long short-term memory (Bi-LSTM). Secondly, by selecting appropriate loss functions and regularization functions, the model was refined to further improve its detection performance. Finally, the model performance was validated using a dataset from the China Southern Power Grid. Experimental results showed that the proposed method had a more effective feature extraction capability, higher detection accuracy and stronger robustness compared to other fault detection methods.

Key words: low-voltage distribution network; open-neutral and open-phase; fault detection; transformer; Bi-LSTM

摘要: 低压配电网中因断零与缺相故障对电网公司造成的安全隐患和经济损失一直是电网公司迫切解决的难题,随着智能化检测设备在电网中普及,可利用智能电表采集的低压侧负载电压和各序电流数据开展故障检测。首先,建立基于 Transformer 神经网络(TNN)和双向长短期记忆(Bi-LSTM)的混合模型 TNN-BL;其次,通过选择合适的损失函数和正则化函数完善模型以进一步提高模型检测性能;最后,采用南网数据集对模型性能进行试验

验证。试验结果表明,该方法拥有更有效的特征提取能力,相比于其他故障检测方法具有更高的检测准确度和更强的鲁棒性。

关键词: 低压配电网; 断零与缺相; 故障检测; transformer; Bi-LSTM

0 引言

低压配电网线路由于受电压等级低、用户分散性强及智能设备应用率低等因素限制,导致当线路发生故障时检修效率低下^[1-3],作为电网中与末端用电设备连接的关键一环,380/220 V 低压配电网因线路众多且设备杂糅繁多等特点决定了其易受外部因素及设备自身影响发生断零或缺相故障^[4-5]。断零与缺相故障不仅对电网绝缘设备及末端用电设备产生巨大安全风险,且故障处会出现大电流情况危及电网正常运行,甚至可能出现火灾等安全事故,造成巨大的经济损失,严重危及公共安全^[6-7]。因此,研究可准确检测并精准判断故障类型的方法对电网安全和用户高质量用电具有巨大意义。

针对断零与缺相故障检测,至今已有众多研究者进行了大量研究工作^[8-9]。传统检测方法主要利用交流接触器、负荷监测模块等保护装置检测和保护^[10-12],但此类方法效率低且耗时费力。随着电力系统智能化程度逐渐提高,基于新型电力的高级量测体系(Advanced Metering Infrastructure, AMI)在电网广泛使用^[13],利用 AMI 的智能电表获取电网中各类海量数据得以实

基金项目:海南电网科技项目(070400KK52220001)

Hainan Power Grid Technology Project (070400KK52220001)

现。目前,基于数据的机器学习方法已逐渐应用于断零与缺相故障检测^[14-15],在故障检测领域主要分为两类,其一适用于无标签数据集的无监督学习方法^[16],另一类适用于含有标签数据集的有监督学习方法^[17]。

基于无监督学习方法中,文献[18]采用基于聚类方法对故障进行检测,但该方法由于无先验知识,模型学习过程较为复杂且学习效果不够理想。基于有监督学习方法中,文献[19]采用支持向量机(Support Vector Machine, SVM)方法对故障进行检测,但由于 SVM 为单一分类器,对数据的学习不够全面导致检测效果欠佳;文献[20]采用集成学习算法的梯度提升决策树(Gradient Boosting Decision Tree, GBDT)方法对故障进行检测,效果得到了提升,但该方法超参数难以调节。针对断零与缺相故障的时序特征,文献[21]采用擅长处理时序数据的长短期记忆网络(Long Short-Term Memory, LSTM)方法进行故障检测,但该方法由于参数众多,易出现过拟合现象。由于以上几种有监督学习方法均需要人工特征提取过程,模型较为复杂,为此采用深度学习自动提取数据的特征。文献[22]采用卷积神经网络(Convolutional Neural Network, CNN)、文献[23]采用循环神经网络(Recurrent Neural Network, RNN)分别对故障检测和定位,且目前大多数深度学习模型均采用 CNN 和 RNN 或二者变体,但基于 CNN 的模型难以捕获时间序列数据的全局特征,而基于 RNN 的模型无法并行计算,且易产生长程依赖问题。此外,这两类模型都无法计算提取特征之间的相对关系,导致对原始输入数据高度依赖。

为此,本文针对上述方法的局限性,提出一种基于 Transformer 神经网络(Transformer Neural Network, TNN)和双向长短期记忆(Bi-directional LSTM, Bi-LSTM)网络^[24]混合模型 TNN-BL 的断零与缺相故障检测方法,TNN-BL 适用处理时间序列数据,通过计算不同时间段电气量数据间注意力系数获取高维序列中的长程特征^[25]。与 CNN 相比,所提出的模型具有更强的全局特征提取能力,与 RNN 相比表现出更高效的并行计算能力。在混合模型 TNN-BL 中通过并行增加 Bi-LSTM 层,用于提取周期性时序特征,以此增强故

障特征敏感度,提高检测准确度。此外,该方法通过计算不同特征间的相对关系,使其在分类预测时不再过度依赖原始输入数据。本文将采集的南方电网某地区某台区低压负载电压和各序电流数据作为数据集,建立基于 TNN-BL 模型的断零与缺相故障检测方法,在此基础上进行模型训练和测试,最后通过数据集对本文所提方法的有效性和准确性进行验证和分析。

1 断零与缺相故障机理分析

当前,我国 380/220 V 低压配电网主要以中性点直接接地的 TT 系统作为系统运行方式,图 1 所示为低压配电网 TT 接线示意图。从变压器一侧中性点引出中性线 N 和保护线 PE,TT 系统零线仅在变压器侧接地,低压配电网零线不作重复接地,而低压线路电气设备外漏可导电部分经外敷接地极接地。




图 1 低压配电网 TT 接线示意图

Fig. 1 Schematic diagram of TT wiring in a low-voltage distribution network

1.1 断零故障

通常情况下,380/220 V 低压配电系统在三相平衡负载正常运作时,零线处不产生电流,而因用户单相负载的随机性,三相负载端会出现不平衡现象,此时零线会产生电流。如图 2 所示为三相四线制低压配电系统等效电路图,若零线在断线处出现断裂,此时系统电源侧,线电压和相电压均未发生变化,负载端均能正常运行。一般情况下,采用中性点电压偏移作为判断断零故障的依据。

图 2 中,在 A 相并联阻抗 Z_K 对负载不平衡情况进行分析,通过节点电压法可推导出电源端中性点 N 与负载端中性点 N' 间的偏移电压,为

$$\dot{U}_{NN'} = \frac{\dot{U}_A / (Z_A // Z_K) + \dot{U}_B / Z_B + \dot{U}_C / Z_C}{1 / (Z_A // Z_K) + 1 / Z_B + 1 / Z_C + 1 / Z_N} \quad (1)$$




图 2 三相四线制低压配电系统等效电路图

Fig.2 Equivalent circuit diagram of a three-phase four-wire low-voltage distribution system

式中: \dot{U}_A 、 \dot{U}_B 、 \dot{U}_C 分别为 A、B、C 相电源; Z_A 、 Z_B 、 Z_C 分别为 A、B、C 相负载; Z_N 为中性线负载。

设 $Z_A = Z_B = Z_C = Z_m$, 当 $Z_N = 0$, 由式(1)可得, $U_{NN'} = 0$, 此时系统无中性点电压偏移; 当 $Z_N = \infty$, 此时零线断裂, 若 $Z_m \neq 0$, 则:

$$\dot{U}_{NN'} = \frac{\dot{U}_A \times Z_m}{Z_m + 3Z_K} \quad (2)$$

由式(2)可知, 中性点偏移电压由负载不平衡程度决定。当 380/220 V 低压配电系统零线出现断裂时, 在系统电源侧, 线电压和相电压均未发生变化, 断零点处之前的负载端均能正常工作, 而中性点电压偏移特征表现在断零点后的负载端, 因此考虑 A、B、C 相负载电压 U_{A0} 、 U_{B0} 、 U_{C0} 的电气量作为断零故障的判断依据。

1.2 缺相故障

如图 3 所示, 当 380/220 V 低压配电系统发生 A 相单相故障时, 此时流过该相的电流等于 0, 设断点处两端分别为 G 和 G', 且在两点间产生纵向电压 E_A 。




图 3 单相断线故障等效电路图

Fig.3 Equivalent circuit diagram of single-phase open-circuit fault

本文采用对称分量法对故障进行分析^[4], 如图(4)所示为 A 相单相故障复合序网图。根据边界条件 $\dot{I}_A = \dot{I}_{A1} + \dot{I}_{A2} + \dot{I}_{A0} = 0$, 当系统处于三相平衡状态, 线路仅存在正序电流, 其大小等于相电流 \dot{I}_p 。由叠加定理可知, 故障后各电气量由故障前

负荷状态与故障附加分量叠加组成, 即 A 相单相断线故障后各序电流为

$$\begin{cases} \dot{I}_{A1} = \dot{I}_p + \dot{I}'_{A1} \\ \dot{I}_{A2} = \dot{I}'_{A2} \\ \dot{I}_{A0} = \dot{I}'_{A0} \end{cases} \quad (3)$$

进一步得:

$$\begin{cases} \dot{I}'_{A1} = \frac{1/Z_{1\Sigma}}{1/Z_{1\Sigma} + 1/Z_{2\Sigma} + 1/Z_{0\Sigma}} \cdot \dot{I}_p \\ \dot{I}'_{A2} = \frac{1/Z_{2\Sigma}}{1/Z_{1\Sigma} + 1/Z_{2\Sigma} + 1/Z_{0\Sigma}} \cdot \dot{I}_p \\ \dot{I}'_{A0} = \frac{1/Z_{0\Sigma}}{1/Z_{1\Sigma} + 1/Z_{2\Sigma} + 1/Z_{0\Sigma}} \cdot \dot{I}_p \end{cases} \quad (4)$$

将式(4)代入式(3)得到:

$$\begin{cases} \dot{I}'_{A1} = \frac{Z_{1\Sigma}/Z_{2\Sigma} + Z_{1\Sigma}/Z_{0\Sigma}}{1/Z_{1\Sigma} + 1/Z_{2\Sigma} + 1/Z_{0\Sigma}} \cdot \dot{I}_p \\ \dot{I}_{A2} = \dot{I}'_{A2} = \frac{1/Z_{2\Sigma}}{1/Z_{1\Sigma} + 1/Z_{2\Sigma} + 1/Z_{0\Sigma}} \cdot \dot{I}_p \\ \dot{I}_{A0} = \dot{I}'_{A0} = \frac{1/Z_{0\Sigma}}{1/Z_{1\Sigma} + 1/Z_{2\Sigma} + 1/Z_{0\Sigma}} \cdot \dot{I}_p \end{cases} \quad (5)$$

由式(5)可知, A 相发生断线故障后, 各序电流分量与线路负荷电流正相关。此外, 从电网实际运行结果可知, 还存在相线断线伴随接地的复杂故障, 其分析过程与仅发生相线故障类似。

同时, 380/220 V 低压配电系统存在多相断线情况, 其中包括两相断线故障(如 A 相、B 相断线)、三相断线故障。此外, 同时存在多相故障伴随接地的复杂故障, 以上故障均可采用对称分量法与复合序网进行故障分析。

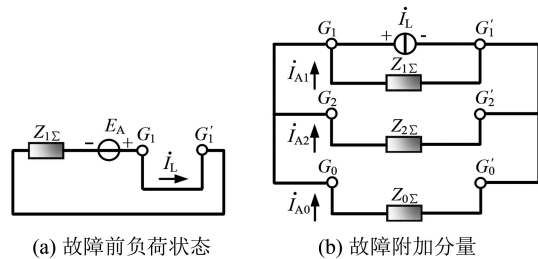


图 4 单相断线复合序网图

Fig.4 Composite sequence network diagram of single-phase open circuit

2 基于 TNN-BL 的故障检测模型

为实现低压配电网断零与缺相故障的准确

检测, 本文采用 TNN-BL 模型对故障进行检测, 如图 5 所示为模型框架图。输入数据由各相负载电压及各序电流分量组成, 将数据输入至由 L 层 Transformer 模块组成的特征提取器中进行特征提取, 以此获得特征向量。而在 Encoder 阶段, 模型通过并行增加 Bi-LSTM 层与原始正则化输出相加至后一个正则化层中,

用于提取周期性时序特征, 以此增强故障特征敏感度。Bi-LSTM 作为一种更有效、灵活性更好且鲁棒性更强的 LSTM 方法, 可有效地获取低压配电网断零与缺相故障的时间序列数据上下文信息。通过获得特征向量, 分类器根据提取的特征属于各故障类别的概率, 输出分类结果, 从而实现故障检测。

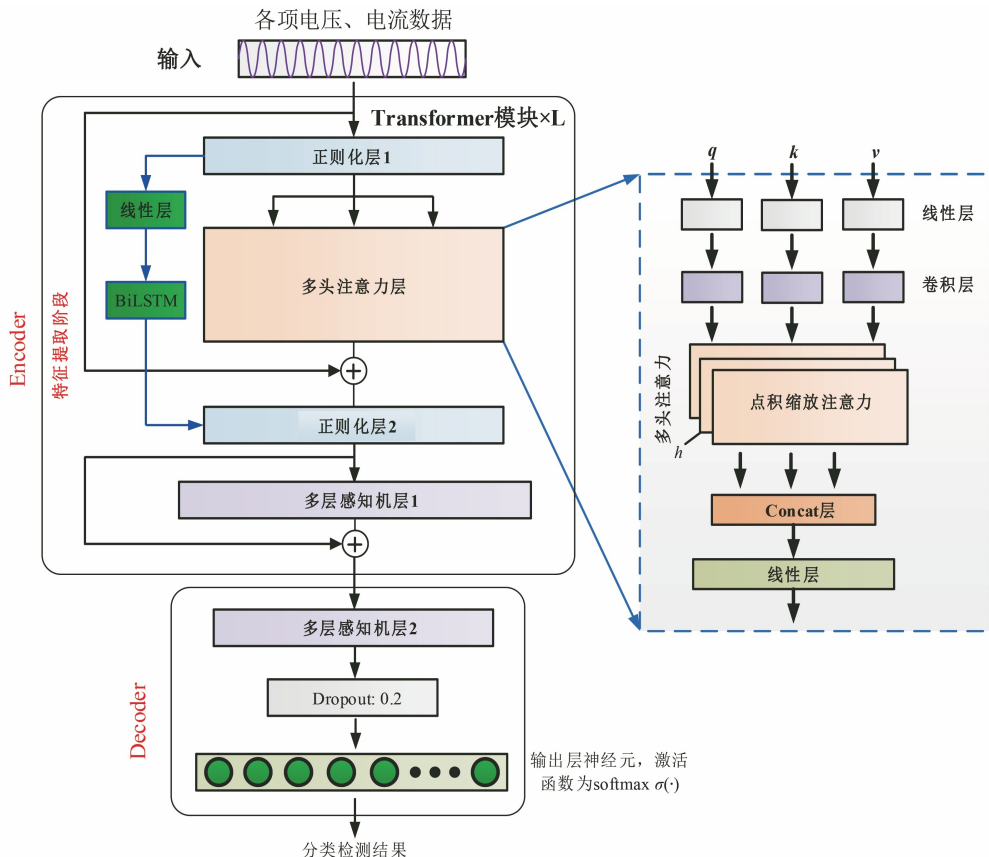


图 5 基于 TNN-BL 模型的故障检测模型
 Fig. 5 Fault detection based on TNN-BL model

如图 5 所示, 输入数据经数个自注意力层处理后的编码向量即为模型提取的特征向量, 与其他深度学习自动提取数据特征仅输出负载序列的特定片段不同的是, 该向量包含所有输入序列的信息, 模型根据自适应权重对不同的输入特征进行赋权。多头注意力层的计算过程为

(1) 首先将输入编码向量 V_i 乘以三个不同的变换矩阵, 得到 q_i, k_i 和 v_i , 其中 q, k 和 v 分别指查询向量、键值向量和值向量。

(2) 其次, 计算当前查询向量与所有键值向量的相似度, 并将结果输入至 softmax 层以此获得一组新的权重。

(3) 最后将(2)中得到的这组权重与对应的乘积相加, 通过自注意力层得到当前输入 V_i 对应的输出 O_i , 该方法称为点积缩放注意力, 可表示为

$$f_{\text{attn}}(q, k, v) = f_{\text{softmax}}\left(\frac{qk^T}{\sqrt{d_e}}\right)v \quad (6)$$

式中: $f_{\text{attn}}(\cdot)$ 为自注意力层输出; k^T 为 k 的转置; $f_{\text{softmax}}(\cdot)$ 为 softmax 函数; d_e 为编码向量维度。

为使模型能同时获取各位置不同子空间的信息, 算法采用多头注意力代替单注意力函数, 其结构如图 5 所示。首先, q, k 和 v 通过线性投影 h 次, 同时并行执行注意力功能, 再将输出值连接并

再次线性投影以此获得最终计算值,多头注意力的计算过程可表示为

$$f_{\text{multihead}}(\mathbf{q}, \mathbf{k}, \mathbf{v}) = f_{\text{conc}}(f_{\text{attn}}^{i=1 \dots h}(f_{\text{conv}q}^i(\mathbf{q}\mathbf{W}_q^i), f_{\text{conv}k}^i(\mathbf{k}\mathbf{W}_k^i), f_{\text{conv}v}^i(\mathbf{v}\mathbf{W}_v^i)))\mathbf{W}^o \quad (7)$$

式中: $f_{\text{attn}}^{i=1 \dots h}$ 表示执行 h 次的注意力函数 f_{conv} 表示线性层权重和第 i 次卷积操作。

位于线性层后的卷积层用于降低 \mathbf{k} 和 \mathbf{v} 的维度,从而降低计算复杂度及减少注意力的计算参数量,在保证 \mathbf{q} 维度不变的同时提取的特征维度不降低。

为获取电气量数据中更为抽象和高级的特征表达,采用多层感知机组成的前馈网络子层。在模型每一个子层中均采用正则化层并添加残差连接,与批量(batch)正则化类似,正则化层可保证特征数据分布的稳定性,从而加快模型训练的收敛速度;残差连接旨在解决随着网络加深而出现的梯度扩散和权值矩阵退化问题,TNN-BL 模型流程可表示为

$$\begin{aligned} \mathbf{I}' &= f_{\text{LN}}(\mathbf{I} + f_{\text{multihead}}(\mathbf{I})) \\ f_{\text{block}}(\mathbf{I}) &= f_{\text{LN}}(\mathbf{I}' + f_{\text{MLP}}(\mathbf{I}')) \end{aligned} \quad (8)$$

式中: $f_{\text{LN}}(\cdot)$ 为正则化层操作; $f_{\text{block}}(\cdot)$ 为 Transformer 模型的输出。

如图 5 所示的 TNN-BL 模型中特征提取模块由 L 个 Transformer 模块组成,其输出 $\mathbf{F}_o \in \mathbb{R}^{1 \times d_e}$ 为提取的特征向量,由多层感知机组成的分类器根据特征图 \mathbf{F}_o 对每一个输入样本进行分类预测,即将多层感知机得到的数据输入至全连接层中,并采用 softmax 激活函数得到每种故障类型的概率输出,概率最大的类别即为模型预测的故障类型,由此即可实现多类别故障检测。

3 试验与分析

为验证本文所提方法的有效性和准确性,所有试验均在 i7-8750HQ CPU、16 GB RAM 和 NVIDIA GeForce GTX 1060Ti GPU 的 PC 上进行,采用 PyTorch 深度学习框架构建 TNN 模型。通过采样频率为 1 kHz 的测量模块,采集南方电网某地区某双绕组额定电压为 10/0.38 kV 台区下 Y/Y 降压变压器的负载电压 (U_{A0} 、 U_{B0} 、 U_{C0}) 和各序电流 (I_{A1} 、 I_{A2} 、 I_{A0} ; I_{B1} 、 I_{B2} 、 I_{B0} ; I_{C1} 、 I_{C2} 、 I_{C0}), 采

集时间为 2 h,并将采集到的数据按照 6:2:2 的比例分为训练集、验证集和测试集。采集到的数据集基本信息如表 1 所示。

表 1 数据集基本信息

Tab. 1 Basic information of the dataset

采样频率/kHz	数据大小	时间段
1	1×7 200 000×12	2024.3.15 8:00-10:00

随机选择某时间点 t ,观察 $t+1$ 600 s 内负载电压 A、B、C 各相电压变化情况,各相电压随时间变化如图 6 所示。由图 6 可知,在 $t+350$ s 至 $t+400$ s 间零线断开,所有相电压降为 0,此时发生断零故障;在 $t+1 000$ s 至 $t+1 050$ s 间 C 相缺相, C 相电压降为 0,此时发生缺 C 相故障。




图 6 各相电压幅值变化图

Fig. 6 Voltage magnitude variation chart

3.1 评价指标

故障检测本质上是分类任务,可用混淆矩阵表 2 的分类结果与实际值进行比较,从而直观地表示各类别的分类状态。

表 2 故障检测中的混淆矩阵

Tab. 2 Confusion matrix in fault detection

类别	预测为正类别	预测为负类别
实际为正类别	TP	FN
实际为负类别	FP	TN

根据表 2 所示的混淆矩阵,对于某类别而言,可将故障按真实标签与预测标签分为真阳性 (True Positive, TP)、假阳性 (False Positive, FP)、真阴性 (True Negative, TN) 与假阴性 (False Negative, FN),可得到结果的评价指标,包括准确率 (ACC)、查全率 Recall、精度 (PRE) 和 F1 分数 (F1-Score, F1),如式 (9)~式 (12) 所示:

$$\text{ACC} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (9)$$

$$\text{PRE} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (10)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (11)$$

$$\text{F1} = \frac{2\text{PRE} \cdot \text{Recall}}{\text{PRE} + \text{Recall}} \quad (12)$$

此外,受试者工作特征(Receiver Operating Characteristic, ROC)曲线描述了假正率(False Positive Rate, FPR)和真正率(True Positive Rate, TPR)变化时的相对关系,适用于在数据集不平衡时评估分类器的整体性能,曲线下面积(Area Under Curve, AUC)越大,模型性能越好。

3.2 模型超参数分析

Transformer 个数 L 、多头注意力头数 h 以及编码向量维度 d_e 共同决定了 TNN-BL 模型的复杂度,3 个参数的值越大,模型检测能力越强,但同时训练模型越困难,模型甚至会出现过度拟合。3 个超参数网格搜索的范围及选择结果如表 3 所示。

表 3 模型超参数选择

超参数	范围	最优值
L	4, 5, 6, 7	6
h	4, 6, 8	6
d_e	32, 64	32

TNN-BL 模型选择 Adam 优化器对模型权重进行更新,模型设置搜索正则化系数、dropout 概率和学习率的最优值分别为 0.001、0.2 和 0.002,模型各超参数设置如表 3 所示,模型训练过程的损失和 ACC 如图 7 所示,可看出训练过程平稳。此外训练集和验证集的损失和 ACC 都很接近,进一步验证模型不会出现欠拟合或过拟合问题。




图 7 不同 Epochs 下 ACC 与模型损失图
Fig. 7 ACC and model loss diagram under different Epochs

3.3 本文所提方法试验与分析

本文将采集的样本数据集按 3:1:1 的比例划

分为训练集、测试集以及验证集,利用所提方法进行训练,各窃电类型检测的混淆矩阵如图 8 所示。

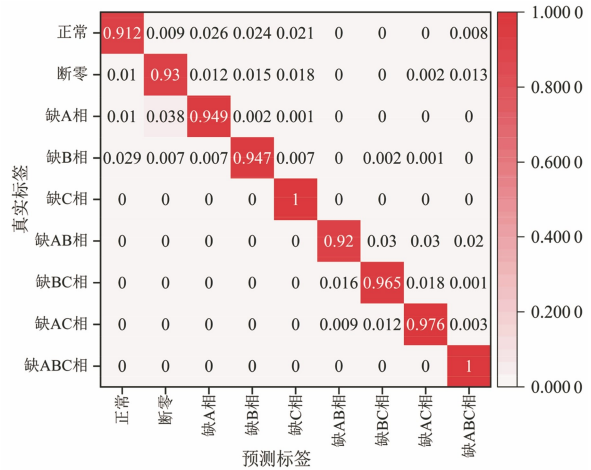


图 8 各故障类型检测混淆矩阵

Fig. 8 Confusion matrix for detection of each fault type

由图 8 可知,本文提出的方法可准确识别 91.2% 的正常情况,对缺 AB 相、缺 B 相和断零的故障识别准确率相对较低,对其他故障类型的识别准确率均在 95% 以上。由图 8 左上角可知,有 2% 的缺 A 相故障被误识别为缺 B 相故障,缺 AB 相故障有 0.03 的概率被识别为缺 BC 相故障和缺 AC 相故障,由于同为单相或两相故障的电气量存在相似性,导致本文所提方法对两者易产生误判,而缺 ABC 三相故障类型因电气特征的特殊性较易被检测。综上所述,无论针对电气特征差别较为显著用户样本还是难以分类样本,本文提出多类别故障检测方法均具有较高准确率。

各故障类型检测的 ROC 曲线如图 9 所示,对于缺 ABC 相故障、缺 C 相故障、缺 BC 相故障以及缺 AC 相故障, AUC 值均在 0.96 以上,本文所提方法具有较高的检测准确度,对于其他故障类




图 9 各故障类型检测 ROC 曲线

Fig. 9 ROC curve for detection of each fault type

型本文检测的 AUC 值仍能达到 0.91 以上。可见,对于各类别故障,本文提出方法均能达到较高的检测准确度。

3.4 与现有方法比较与分析

为进一步验证本文提出的 TNN-BL 模型故障检测方法的有效性,分别采用 SVM^[19]、GBDT^[20]、CNN^[12]、LSTM^[21]和 Transformer^[22]五种基于机器学习的检测方法进行比较试验,各算法参数如表 4 所示。

表 4 各方法参数设置

Tab. 4 Parameter settings of each method

方法	参数
SVM	核函数为径向基函数,惩罚系数 $C = 15$
GBDT	$l = 0.1$,最大迭代次数 $n = 100$
CNN	卷积核为 3×3 ,学习率为 1×10^{-5}
LSTM	神经元个数 32,学习率为 0.1,树的数目为 300
Transformer	$L=6, h=6, d_e=32$

不同算法的评价结果如表 5 所示。由表 5 可知,本文所提方法的各项检测指标均为各检测算法中最高。其 ACC 值为 0.963 2,远高于采用单一分类器 SVM 的 ACC 值 0.863 2 及采用集成学习分类方法 GBDT 的 ACC 值 0.881 3;深度学习方法中 CNN 的 ACC 值 0.903 3 仅次于本文所提方法;LSTM 擅长处理采集到的时序数据,其 ACC 值为 0.901 2,与本文所提方法 TNN-BL 较为接近。本文所提方法在 Transformer 模型上进行融合,在融合前 Transformer 模型各项检测指标均好于其他 4 种方法,而本文所提 TNN-BL 模型在 Transformer 模型上检测性能均有一定幅度的提升。

表 5 不同方法的试验结果

Tab. 5 Experimental results of different methods

方法	ACC	PRE	Recall	F1
SVM	0.863 2	0.870 6	0.861 2	0.820 1
GBDT	0.881 3	0.816 5	0.825 7	0.815 1
CNN	0.903 3	0.921 5	0.901 6	0.914 4
LSTM	0.901 2	0.910 1	0.899 6	0.901 6
Transformer	0.946 6	0.956 8	0.901 5	0.976 9
TNN-BL	0.963 2	0.976 5	0.910 3	0.988 2

为了进一步验证本文提出的低压配电网断零与缺相故障检测方法的有效性,当训练集、测试集及验证集的比例为 3:1:1 时,采用 ROC 曲线将上述 5 种方法与本文所提方法的试验结果进行可视化描述,试验结果如图 10 所示。

在 ROC 空间坐标中,理想的 ROC 曲线应该

尽可能地靠近左上角,表明检测效果越好。由图 10 可知,本文所提方法更靠近左上角,其 AUC 值更大,本文提出的基于 TNN-BL 模型故障检测方法 AUC 表现优于其他方法,该方法特别适合处理时间序列,其通过计算不同时间段电气量数据之间的注意力系数捕获高维负载序列中长时间段特征。与 CNN 相比,所提出的模型具有更强的全局特征提取能力;与 LSTM 相比,具有更高效的并行计算能力,同时可计算不同特征之间的相对关系,使其在分类预测时不再过度依赖原始输入数据,具有较强的鲁棒性。




图 10 各检测方法 ROC 曲线

Fig. 10 ROC curve of each detection method

模型的训练时间是判别模型复杂度和故障检测效率的重要依据。本文在训练数据相同的情况下,考虑不同模型的训练时间,如图 11 所示为各模型的训练时间。




图 11 各模型的训练时间

Fig. 11 Training time of each model

由图 11 可知,本文 TNN-BL 模型的训练时间为 76.912 s,略高于 Transformer、LSTM 和 CNN 的训练时间 73.125 s、69.948 s 和 67.752 s;模型训练时间较少的是 GBDT 的 53.623 s 和 SVM 的 48.169 s。结合图 10 的 ROC 曲线来看,SVM、GBDT、LSTM 的 AUC 值较低,Transformer 和 TNN-BL 的 AUC 值远高于其他 4 个模型。考虑到 TNN-BL 是 Transformer 的改进方法,模型的检测

精度更高,训练时间仅多 3 s,因此本文所提方法的有效性更好。

为全面评估不同检测方法在各故障类别的整体表现,本文采用雷达图更直观地分析各检测方法的综合表现。各方法对应各故障类型 AUC 值如图 12 所示,从图中可看出,本文提出方法和其他深度学习或机器学习方法均能检测出各种类型故障。相比于其他方法,本文所提方法检测缺 C 相故障和缺 ABC 相故障时的性能远优于其他现有方法。

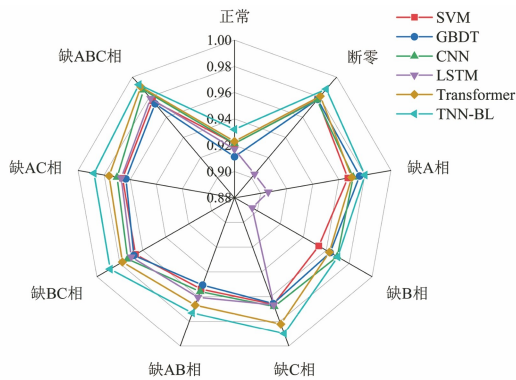


图 12 各方法对应各故障类型 AUC 值

Fig. 12 AUC values for each fault type across various methods

为评估本文训练 TNN-BL 模型的泛化性能,本文利用前述平台不同采集时间段的数据进行验证,采样频率同样设置为 1 kHz,采集时间段为 2024.7.10 13:00–15:00(共 2 h),数据大小为 $1 \times 7\,200\,000 \times 12$ 。当训练集、测试集及验证集的比例为 3:1:1 时,采用 ROC 曲线将各模型与 TNN-BL 模型试验结果进行可视化描述,试验结果如图 13 所示。从图中可看出,本文提出的基于 TNN-BL 模型故障检测方法 AUC 值为 0.960 3,优于其他方法,仅次于 TNN-BL 模型的 Transformer,其 AUC 值为 0.933 9。因此,通过不同数据集的验证结果可知,本文提出的 TNN-BL 模型具有良好的泛化性能。

为进一步验证模型的鲁棒性,本文进行敏感性试验,分析了不同样本量对模型性能的影响。本文采用原始训练集中 10%、20%、40%、60% 和 80% 的样本训练模型,分析不同训练样本量对模型性能的影响,图 14 为模型在不同训练样本量下 ACC 和 AUC 值的变化情况。

由图 14 可知,当原始数据训练样本比例降低




图 13 各模型的 ROC 曲线

Fig. 13 ROC curves of each model




图 14 不同训练数据比例下模型的性能

Fig. 14 Model performance under different training data ratios

时,本文所提出模型的性能略有下降。当训练样本的比例高于 60% 时,模型的性能几乎保持不变,且在比例为 80% 时性能相对较好,该模型的其他评估指标显示出类似趋势。当训练数据比例下降至 10% 时,AUC 值下降了 3.35%。结果表明,当达到一定数量的训练样本时,即为原始数据集的 60%,模型性能已达到最优值。

4 结语

本文提出了基于 Transformer 神经网络和 Bi-LSTM 混合模型 TNN-BL 的低压配电网断零与缺相故障检测方法,实现了实际电网情况下各类型断零与缺相故障的准确检测。试验结果表明:该模型具有强大的特征提取能力,可有效提取低压侧负载电压和各序电流数据局部特征和全局特征,且模型具有较强的泛化能力,可避免出现过拟合现象,与现有的深度学习模型、集成学习模型和单一分类器模型的检测方法相比,本文所提方法的检测精度更高、鲁棒性更强,表现出良好的泛化性能,可为当前智能电网及早发现断零与缺相故障、解决故障问题提供准确有效的检测手段,为保证电网可靠安全运行、保证用户用电质量提供了

有效支撑。

参考文献

- [1] 霍建彬, 李巍, 周歧林, 等. 基于零序导纳的消弧线圈接地系统馈线单相断线故障保护方法[J]. 南方电网技术, 2023, 17(5): 117-124.
- HUO J B, LI W, ZHOU Q L, et al. Feeder single-phase disconnection fault protection method of arc suppression coil grounding system based on zero sequence admittance [J]. Southern Power System Technology, 2023, 17(5): 117-124.
- [2] 李浩, 张禄亮. 基于改进 VMD 和特征分布系数的配电网高阻接地故障检测方法[J]. 南方电网技术, 2022, 16(12): 109-117.
- LI H, ZHANG L L. High impedance grounding fault detection method for distribution network based on improved VMD and characteristic distribution coefficient [J]. Southern Power System Technology, 2022, 16(12): 109-117.
- [3] HAMATWI E, IMORU O, KANIME M, et al. Comparative analysis of high impedance fault detection techniques on distribution networks [J]. IEEE Access, 2023, 11: 25817-25834.
- [4] 韩笑, 夏寅宇, 丁煜飞, 等. 基于暂态零序电流的含光伏电源配电网单相故障定位方法[J]. 电机与控制应用, 2022, 49(9): 81-87.
- HAN X, XIA Y Y, DING Y F, et al. Single-phase fault location method of photovoltaic power distribution network based on transient zero-sequence current [J]. Electric Machines & Control Application, 2022, 49(9): 81-87.
- [5] LAI T, SNIDER L, LO E, et al. High-impedance fault detection using discrete wavelet transform and frequency range and RMS conversion [J]. IEEE Transactions on Power Delivery, 2005, 20(10): 397-407.
- [6] 刘科研, 叶学顺, 李昭, 等. 基于多分辨率小波变换的配电网高阻接地故障检测方法[J]. 高电压技术, 2023, 49(10): 4247-4256.
- LIU K Y, YE X S, LI Z, et al. Detection method of high impedance fault in distribution network based on multi-resolution wavelet transform[J]. High Voltage Engineering, 2023, 49(10): 4247-4256.
- [7] 康奇豹, 丛伟, 盛亚如, 等. 配电线路单相断线故障保护方法[J]. 电力系统保护与控制, 2019, 47(8): 127-136.
- KANG Q B, CONG W, SHENG Y R, et al. Protection methods of single-phase broken-line fault for distribution line [J]. Power System Protection and Control, 2019, 47(8): 127-136.
- [8] 饶鸿江, 何永泰, 彭洁, 等. 基于 FEEMD-NTEO 的风电场送出线路故障定位[J]. 电机与控制应用, 2024, 51(1): 106-116.
- RAO H J, HE Y T, PENG J, et al. Fault location of wind farm transmission line based on FEEMD-NTEO [J]. Electric Machines & Control Application, 2024, 51(1): 106-116.
- [9] 刘红文, 曾祥君, 柴晨超, 等. 配电网柔性接地装置注入非工频小信号的接地故障检测与区段定位方法[J]. 南方电网技术, 2022, 16(6): 44-53.
- LIU H W, ZENG X J, CHAI C C, et al. Grounding fault detection and section location method of injecting non power frequency small signal into flexible grounding device of distribution network [J]. Southern Power System Technology, 2022, 16(6): 44-53.
- [10] 尤毅, 刘东, 李亮, 等. 基于负荷监测仪的 10 kV 架空线单相断线不接地故障区域判定[J]. 电力系统保护与控制, 2012, 40(19): 144-149.
- YOU Y, LIU D, LI L, et al. Detection method based on load monitoring for 10 kV overhead line single-phase ungrounded open fault area [J]. Power System Protection and Control, 2012, 40(19): 144-149.
- [11] 李福志, 郑卫宾, 张文海, 等. 基于回路直流电阻测量的输电线路单相接地故障离线故障定位[J]. 中国电力, 2021, 54(2): 140-146.
- LI F Z, ZHENG W B, ZHANG W H, et al. Fault path direct-current resistance based off-line single-phase-to-ground fault location [J]. Electric Power, 2021, 54(2): 140-146.
- [12] 刘丰, 曾祥君, 谢李为, 等. 基于相电压差值极性的配电网单相接地故障检测方法[J]. 电力系统保护与控制, 2023, 51(15): 155-165.
- LIU F, ZENG X J, XIE L W, et al. Single-phase grounding fault detection method for a distribution network based on phase voltage difference polarity value [J]. Power System Protection and Control, 2023, 51(15): 155-165.
- [13] 董科成, 徐懂理, 潘准, 等. 高级量测体系 AMI 的应用研究[J]. 黑龙江电力, 2023, 45(2): 143-146.
- DONG K C, XU D L, PAN Z, et al. Application

- research on advanced metering infrastructure [J]. Heilongjiang Electric Power, 2023, 45(2): 143-146.
- [14] NGUYEN B, VU T, NGUYEN T, et al. Spatial-temporal recurrent graph neural networks for fault diagnostics in power distribution systems [J]. IEEE Access, 2023, 11: 46039-46050.
- [15] 许允之, 杨佳彬, 方磊. 基于人工神经网络的永磁同步电机供电不平衡及缺相故障诊断[J]. 大电机技术, 2016, (4): 1-5+9.
- XU Y Z, YANG J B, FANG L. Failure diagnosis of unbalanced supply and phase loss in PMSM using ANN-based protection scheme [J]. Large Electric Machine and Hydraulic Turbine, 2016, (4): 1-5+9.
- [16] 王东, 朱永利. 基于模糊 C 均值聚类和改进相关向量机的变压器故障诊断[J]. 电测与仪表, 2019, 56(12): 14-19.
- WANG D, ZHU Y L. Fault diagnosis of transformer based on fuzzy C means clustering and improved relevance vector machine [J]. Electrical Measurement & Instrumentation, 2019, 56(12): 14-19.
- [17] 姜媛媛, 张书婷. 基于改进的 VMD 和 CNN 神经网络的光伏逆变器软故障诊断方法研究[J]. 电测与仪表, 2021, 58(2): 158-163.
- JIANG Y Y, ZHANG S T. Research on soft fault diagnosis method of PV inverter based on improved VMD and CNN neural network [J]. Electrical Measurement & Instrumentation, 2021, 58(2): 158-163.
- [18] DANG J, YAN Y J, JIA R, et al. Fast single-phase fault location method based on community graph depth-first traversal for distribution network [J]. CSEE Journal of Power and Energy Systems, 2023, 9(2): 612-622.
- [19] GAO W, HEN W F, YANG G J, et al. Fault type identification for distribution network based on singular value decomposition and multi-level support vector machine [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(2): 62-71.
- [20] YUAN J W, FENG G, CHEN M, et al. Faulted line detection using sampled data and GBDT for non-solidly earthed system [C] // 2020 IEEE Power & Energy Society General Meeting, Montreal, QC, 2020.
- [21] 李临凤, 饶丹, 樊瑞, 等. 基于双向 LSTM 和注意力机制的输电线路故障判别方法[J]. 广东电力, 2022, 35(11): 91-98.
- LI L F, RAO D, FAN R, et al. Fault discrimination method based on Bi-LSTM-attention for transmission lines [J]. Guangdong Electric Power, 2022, 35(11): 91-98.
- [22] 陈仕龙, 吴涛, 王朋林, 等. 基于深度学习的特高压三端混合直流输电线路波形特征故障区域判别方法[J]. 电力系统及其自动化学报, 2024, 36(1): 24-36.
- CHEN S L, WU T, WANG P L, et al. Fault zone identification method for three-terminal hybrid UHVDC transmission lines based on deep learning and waveform characteristics [J]. Proceedings of the CSU-EPSA, 2024, 36(1): 24-36.
- [23] MNYANGHWALO D, KUNDAELI H, KALINGA E, et al. Faults detection and classification in electrical secondary distribution network using recurrent neural network [C] // 2020 6th IEEE International Energy Conference, Gammarth, Tunisia, 2020.
- [24] 王兰馨, 王卫亚, 程鑫. 结合 Bi-LSTM-CNN 的语音文本双模态情感识别模型[J]. 计算机工程与应用, 2022, 58(4): 192-197.
- WANG L X, WANG W Y, CHENG X. Bimodal emotion recognition model for speech-text based on Bi-LSTM-CNN [J]. Computer Engineering and Applications, 2022, 58(4): 192-197.
- [25] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017.

收稿日期:2024-05-16

收到修改稿日期:2024-07-15

作者简介:

林师远(1992-),男,硕士,工程师,研究方向为人工智能在电力系统中的应用, zhokuisf@126.com;

* 通信作者:林师远(1992-),男,硕士,工程师,研究方向为人工智能在电力系统中的应用, zhokuisf@126.com。

Research on Detection Method for Open-Neutral and Open-Phase Faults in Low-voltage Distribution Networks Based on TNN-BL Model

LIN Shiyuan^{*}, HUANG Xiong, WU Tianjie, LUO Jie, CHEN Ruizhong, LIN Shaojia
(Qionghai Power Supply Bureau of Hainan Power Grid Co., Ltd., Qionghai 571442, China)

Key words: low-voltage distribution network; open-neutral and open-phase; fault detection; transformer; Bi-LSTM

In the 380/220 V low-voltage distribution network, open-phase and open-neutral faults pose significant safety risks to grid insulation equipment and terminal electrical devices. These faults can lead to high currents that threaten the normal operation of the power grid, resulting in substantial economic losses. Addressing this problem has long been a priority for power grid companies. Traditional detection methods using AC contactors, load monitoring modules and other devices are inefficient and time-consuming. With the popularization of intelligent detection equipment in the power grid, load voltage on the low-voltage side and sequence current data collected by smart meters can now be utilized for fault detection.

This paper proposed a detection method for open-neutral and open-phase faults based on hybrid transformer neural network (TNN) and bi-directional long short-term memory (Bi-LSTM) model, called TNN-BL. TNN-BL was well-suited for processing time-series data. By calculating the attention coefficient between different time periods, the model captured long-range features in high-dimensional sequences. The proposed model demonstrated

stronger global feature extraction capability than convolutional neural network, and more efficient parallel computing capability than recurrent neural network. In hybrid TNN-BL model, a Bi-LSTM layer was added in parallel to extract periodic temporal features, enhancing the model's sensitivity to fault features and improving detection accuracy. In addition, by calculating the relative relationship between different features, the method reduced reliance on original input data in classification prediction.

In this paper, the collected low-voltage load voltage and sequence current data from a substation in a specific region of the China Southern Power Grid were used as datasets to develop an open-neutral and open-phase fault detection method based on the TNN-BL model. On this basis, the model was then trained and tested. Finally, the model performance was validated experimentally using real data from the China Southern Power Grid. Experimental results showed that the proposed method had superior feature extraction capability, higher detection accuracy and stronger robustness compared to other fault detection methods.