

刘宝良,张明,高庆忠,等.基于CNN-LSTM混合模型的风电场集电线路接地故障定位[J].辽宁工程技术大学学报(自然科学版),2025,44(3):358-364.DOI:10.11956/j.issn.1008-0562.20240346
LIU Baoliang,ZHANG Ming,GAO Qingzhong,et al.Grounding fault location of wind farm collector line based on CNN-LSTM hybrid model[J].Journal of Liaoning Technical University(Natural Science),2025,44(3):358-364.DOI:10.11956/j.issn.1008-0562.20240346

基于CNN-LSTM混合模型的风电场集电线路接地故障定位

刘宝良¹,张明¹,高庆忠²,张晨³,宋阳¹,程施霖⁴,吴尚润⁴

(1.沈阳工程学院电力学院,辽宁沈阳110136;2.沈阳工程学院新能源学院,辽宁沈阳110136;3.沈阳工程学院能源与动力学院,辽宁沈阳110136;4.华能新能源股份有限公司辽宁分公司,辽宁沈阳110002)

摘要:基于风电场复杂运行环境和多分支混合集电线路的单相接地故障定位需求,提出一种基于卷积神经网络(convolutional neural network, CNN)和长短期记忆网络(long short term memory networks, LSTM)混合模型(CNN-LSTM)的单相接地故障定位策略。采集故障时零序电流,构建风电场单相接地故障数据集,将CNN-LSTM混合模型改进为适合故障测距的预测模型,将该模型应用于在线故障定位。研究表明:与CNN和反向传播神经网络(backpropagation neural network, BP)相比,CNN-LSTM混合模型方法定位准确率更高,在不同故障距离和故障电阻情况下均可使用。研究结论为风电场集电线路接地故障定位提供参考。

关键词:故障定位;卷积神经网络;风电场;集电线路;零序电流;长短期记忆网络

中图分类号:TM773

文献标志码:A

文章编号:1008-0562(2025)03-0358-07

Grounding fault location of wind farm collector line based on CNN-LSTM hybrid model

LIU Baoliang¹,ZHANG Ming¹,GAO Qingzhong²,ZHANG Chen³,SONG Yang¹,
CHENG Shilin⁴,WU Shangrun⁴

(1. School of Electric power, Shenyang Institute of Engineering, Shenyang 110136, China;

2. School of Renewable Energy, Shenyang Institute of Engineering, Shenyang 110136, China;

3. School of Energy and Power, Shenyang Institute of Engineering, Shenyang 110136, China;

4. Liaoning Branch, Huaneng New Energy Company Limited, Shenyang 110002, China)

Abstract: Based on the complex operating environment of wind farms and the single-phase grounding fault location requirements of multi-branch hybrid collector lines, a single-phase grounding fault location strategy based on convolutional neural network (CNN) and long short term memory networks (LSTM) hybrid model (CNN-LSTM) is proposed. The zero-sequence current is collected when the fault occurs, and the single-phase grounding fault data set of the wind farm is constructed. The CNN-LSTM hybrid model is improved into a prediction model suitable for fault location, and the model is applied to online fault location. The results show that compared with CNN and backpropagation neural network (BP), the CNN-LSTM hybrid model method has higher positioning accuracy and can be used in different fault distances and fault resistances. The research conclusions provide a reference for the grounding fault location of wind farm collector lines.

Keywords: fault location; convolutional neural network; wind farms; collector line; zero-sequence current; long short term memory networks

收稿日期:2024-10-17 修回日期:2024-11-09 接受日期:2024-11-23 责任编辑:张雯

基金项目:辽宁省教育厅高校基本科研项目(LJ212411632027)

作者简介:刘宝良(1976-),男,辽宁大连人,硕士,副教授,主要从事新型电力系统、新型储能技术方面的研究。E-mail: wuyutiange@sina.com

0 引言

风电场集电线路是连接风力发电机组和电网的关键环节, 其运行状态的稳定性和可靠性对整个风电场的发电效率和安全运行至关重要。由于风电场通常位于地理环境复杂、气候条件多变的地区, 集电线路易受多种因素的影响, 如极端天气、机械磨损、人为破坏等, 从而导致故障发生。在风电场集电线路故障中单相接地短路故障约占80%^[1], 具有高发性和隐蔽性, 成为影响风电场安全稳定运行的主要因素之一。

在风机集电线路的故障定位方面, 文献[2]和文献[3]利用零序电流近似计算出风电机组输出的电流, 基于测量值与线路参数之间的对应关系计算出故障位置, 该方法未充分结合实际集电线路的结构, 可能得到较多的疑似故障点, 无法确定真正的故障位置。文献[4]和文献[5]根据不同故障位置处的电气量, 通过计算值与实际值的差异确定故障位置, 计算工作量大, 且需要实时计算理论值, 很难应用于工程实践。目前, 结合小波包变换、高精度采样的GPS技术和行波法广泛应用于集电线路故障定位中, 但多分支混合线路故障行波会受影响, 降低了故障定位的精准度。

大数据技术和智能算法为风电场集电线路故障测距提供了有效的方法。文献[6]提出区段阻抗匹配测距算法, 通过逐段判断计算结果是否位于当前区段, 决定是否终止计算。此方法计算量较大, 无法进行快速定位。文献[7]利用LSTM神经网络建立故障定位器, 利用归一化后的风电场集电线路故障数据进行故障距离预测。此方法使用单一模型, 故障信息挖掘不充分, 易受故障条件的影响, 一般只适用于故障区段定位。文献[8]利用行波法收集故障信息, CNN提取各次波头频率分布特征, 挖掘故障支路信息, LSTM提取典型波头时间关联特征, 挖掘故障距离信息, 最终实现配电网故障定位, 但行波信号严重混叠, 难以在实际工程中应用。文献[9]利用1D卷积神经网络(1D-CNN)和波形级联来克服特征提取和分类器选择的困难, 实现高阻单相接地故障情况下的故障测距, 但在故障样本稀缺情况下, 无法对已有样本进行重复利用, 不适合风电场集电线路故障定位^[10-11]。

针对风电场故障样本稀缺, 传统的神经网络模

型无法得到充分训练从而限制了其实际应用问题, 本文提出基于CNN-LSTM混合模型的风电场集电线路智能故障测距方法。利用零序电流法对35 kV母线侧的测量值进行处理, 并提取和收集故障特征。采用CNN-LSTM混合模型对采集到的线路故障数据进行训练, 实现集电线路故障区段的定位。以故障时零序电流幅值为数据样本, 搭建CNN模型、BP模型、CNN-LSTM混合模型, 从准确性和快速性角度对比分析3种网络模型在风电场集电线路故障定位中的效果。

1 风电场集电线路故障特征

1.1 风电场结构

目前, 国内风力发电以大规模风电场集中并网为主, 常采用集电线路将电能汇聚于风电场低压母线。以内蒙古某风电场的集电线路为例, 其拓扑结构见图1。每个风电机组通过升压变压器连接至35 kV的并网母线, 经电缆线路汇集到架空线, 主升压变压器的低压侧采用“Δ”连接方式。风电场集电线路为电缆与架空线路的混合连接, 为维持母线电压稳定需要安装“Z”型接地变压器^[12]。

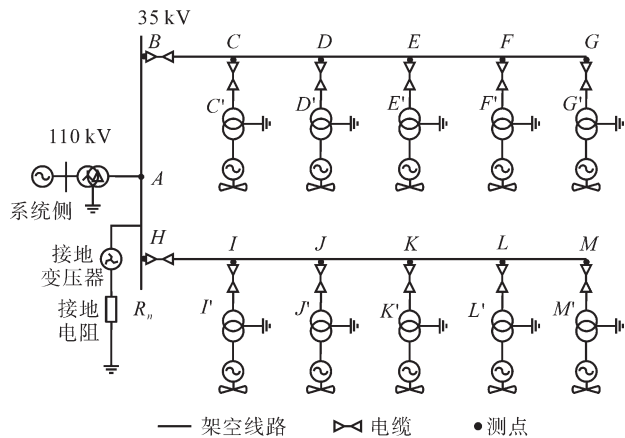


图1 风电场拓扑结构

Fig.1 wind farm topology

1.2 故障特性

当图1中线路C-D发生单相接地故障时, 故障电流流向见图2。

由图2可知

$$\begin{cases} i_{ga1} + i_{ga2} + i_{Z_a} + i_{la1} = i_{fa} \\ i_{gb1} + i_{gb2} + i_{Z_b} + i_{lb1} = i_{fb} \\ i_{gc1} + i_{gc2} + i_{Z_c} + i_{lc1} = i_{fc} \end{cases} \quad (1)$$

发生单相接地故障时, 接地变压器的三相电流 $i_{Z_a a} + i_{Z_b b} + i_{Z_c c} = i_{Z_0 0}$, 且二次侧电流和为 0。由于风电场电流影响较小, 可以忽略不计。对式 (1) 进行简化可得

$$i_{Z_0 0} + i_{g01} + i_{g02} = i_{f0}, \quad (2)$$

式中: $i_{Z_0 0}$ 为故障时接地变压器高压侧的零序电流, kA; i_{g01} 、 i_{g02} 分别为故障点左右风机的零序电流, kA; i_{f0} 为故障时故障端的零序电流^[13], kA。

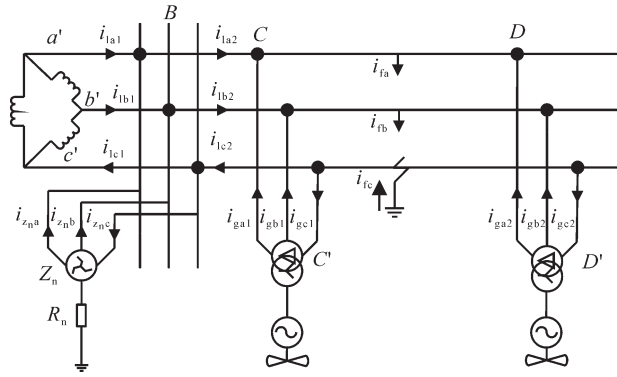


图 2 单相接地故障时电流流向

Fig.2 current flow when a single-phase ground fault occurs

根据式 (2) 简化图 2, 得到故障系统零序网络, 见图 3。图 3 中, B、C、D 为集电线路的测点, f 为线路故障点^[14-15]。 u_{f0} 为零序电压, kV; i_{f0} 为零序电流, kA; x_0 为线路单位距离零序阻抗, Ω ; l_1 、 l_2 为故障距离, km; X_T 为接地变压器的零序阻抗, Ω ; R_n 为接地电阻, Ω ; Z_f 故障阻抗, Ω 。




图 3 单相接地故障系统的零序网络

Fig.3 zero sequence network for a single-phase ground fault system

该风电场系统的零序电流为

$$i_{f0} = \frac{u_{f0}}{3R_n + Z_f + j[X_T + x_0(l_1 + l_2)]} \quad (3)$$

由式 (3) 可得母线距离故障点的距离为

$$l_1 + l_2 = \frac{j(3R_n + Z_f - \frac{u_{f0}}{i_{f0}}) - X_T}{x_0} \quad (4)$$

2 基于混合模型的故障定位方法

风电场集电线路接地故障精确定位基于“先确定故障支路, 再确定故障距离”的思路, 先通

过零序电流法收集故障线路数据, 然后采用卷积神经网络与长短期记忆网络相结合的方式训练出适合风电场故障定位的神经网络模型。

2.1 CNN-LSTM 混合神经网络模型

CNN-LSTM 模型结构见图 4。该神经网络共有 7 层结构, 包含 2 个卷积层 (Conv1D、Conv2D)、2 个最大池化层 (Maxpooling1D、Maxpooling2D)、1 个 Dropout 层、1 个 LSTM 层、1 个全连接层。可根据待解决问题的复杂程度, 在 LSTM 模型中的隐含层数和各层的神经元确定个数。LSTM 中各变量的计算式如下。

$$\begin{pmatrix} f_t \\ i_t \\ g_t \\ o_t \end{pmatrix} = \sigma \left(\begin{pmatrix} W_{f1} & W_{f2} \\ W_{i1} & W_{i2} \\ W_{g1} & W_{g2} \\ W_{o1} & W_{o2} \end{pmatrix} \cdot \begin{pmatrix} x_t \\ h_{t-1} \end{pmatrix} + \begin{pmatrix} b_f \\ b_i \\ b_g \\ b_o \end{pmatrix} \right), \quad (5)$$

$$c_t = f_t c_{t-1} + i_t \tanh(g_t), \quad (6)$$

$$h_t = o_t \tanh(c_t), \quad (7)$$

式 (5) ~ 式 (7) 中: f_t 为遗忘门的输出函数; i_t 为输入门的输出函数; g_t 为候选记忆细胞函数; o_t 为输出门的输出函数; W_{f1} 、 W_{f2} 为 f_t 的权重矩阵; W_{i1} 、 W_{i2} 为 i_t 的权重矩阵; W_{g1} 、 W_{g2} 为 g_t 的权重矩阵; W_{o1} 、 W_{o2} 为 o_t 的权重矩阵; b_f 、 b_i 、 b_g 、 b_o 分别为 f_t 、 i_t 、 g_t 、 o_t 的偏置向量; c_t 、 c_{t-1} 分别为此时此刻和上一时刻的记忆细胞单元; h_t 、 h_{t-1} 分别为此时此刻和上一时刻的隐藏状态; x_t 为当前时刻的输入; $\sigma(\cdot)$ 为激活函数; $\tanh(\cdot)$ 为双曲正切激活函数。

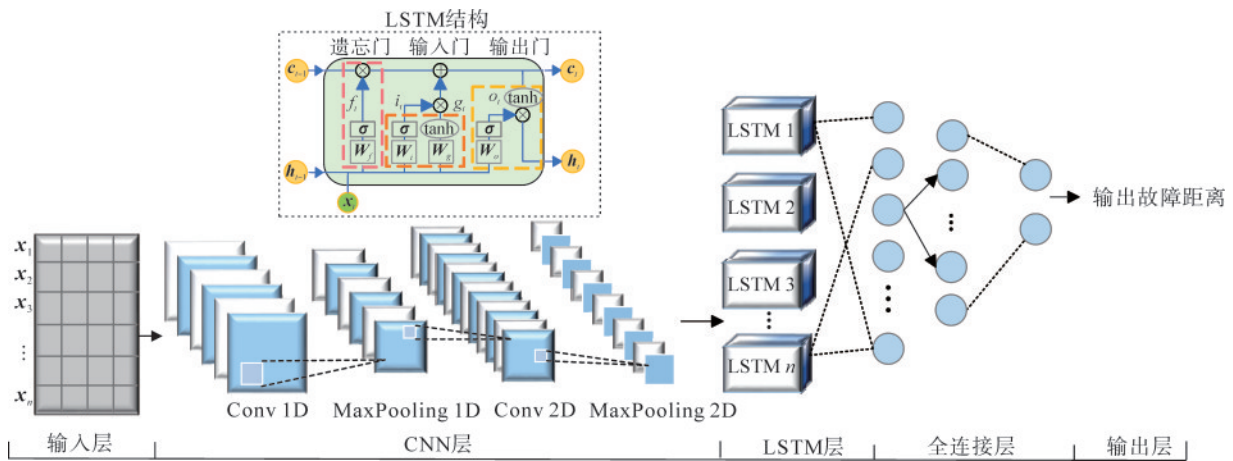


图4 CNN-LSTM混合神经网络模型

Fig.4 CNN-LSTM hybrid neural network model

图4中,模型的输入是序列长度为 n 、维度为 m 的零序电流数据矩阵。针对故障距离的判定,混合模型利用全连接层的权重和偏置项参数将特征向量 p_i 映射至故障点位置向量 y_f ,表达式为

$$y_f = p_i^T W_a + b_a, \quad (8)$$

式中: W_a 为网络的权重矩阵, b_a 为偏置向量。

CNN-LSTM混合模型的参数设置见表1。为提高训练精度,引入Dropout层对LSTM网络结构进行优化,解决网络训练过程的过拟合问题,使用自适应学习率的Adam算法加快参数寻优的速度。

表1 CNN-LSTM混合神经网络模型参数

Tab.1 parameters of CNN-LSTM hybrid network model

模型结构	模型层级	参数
CNN层	卷积层1	64个5×5的卷积核
	池化层1	内核大小为3×3
	卷积层2	128个5×5的卷积核
	池化层2	内核大小为3×3
Dropout层	Dropout层	丢弃率为0.2
LSTM层	隐藏层	神经元个数为64
全连接层	输出层	一维向量

CNN-LSTM混合模型中可将CNN部分看作一个特殊的数据预处理结构。卷积层提取集电线路零序电流特征,捕获故障特征。最大池化层通过对局部特征进行下采样来减少参数的数量和计算量,进一步提高故障定位模型的训练效率。LSTM层可以对局部特征进行整合,从而提取更高级别

的特征表示。最后,全连接层将这些特征表示映射到一个单一的输出,输出故障定位的结果^[6]。

2.2 神经网络故障定位的训练

基于CNN-LSTM的风电场集电线路接地故障定位过程包括数据预处理阶段、训练阶段、验证阶段和测试阶段,具体步骤如下。

步骤1 数据预处理阶段。对线路零序电流数据归一化处理后,按照8:1:1的比例划分为训练集、验证集、测试集。

步骤2 训练阶段。通过数据信息进行迭代权重更新,不断优化卷积内核中的参数、权重以及LSTM层的参数,直至模型收敛,最终完成训练。

步骤3 验证阶段。在多次运行后选取在验证集损失函数值最小的CNN-LSTM混合模型,用于下一阶段。

步骤4 测试阶段。通过均方根误差(RMSE)、均方误差(MSE)、平均绝对百分比误差(MAPE)以及决定系数 R^2 参数,对模型的故障定位效果进行评价。输出定位结果,并进行反归一化处理。

3 实验验证

以某地的风电场为例,该风电场的电压等级为35 kV,变压器采用星形-三角形连接方式,有1条馈线,每条馈线有2条分支,部署分布式监测终端,实时采集和监测集电线路状态,包括各类电

压、电流等关键数据。

3.1 故障发生时电流和电压的特性

发生单相接地故障时，正序和负序电流无法

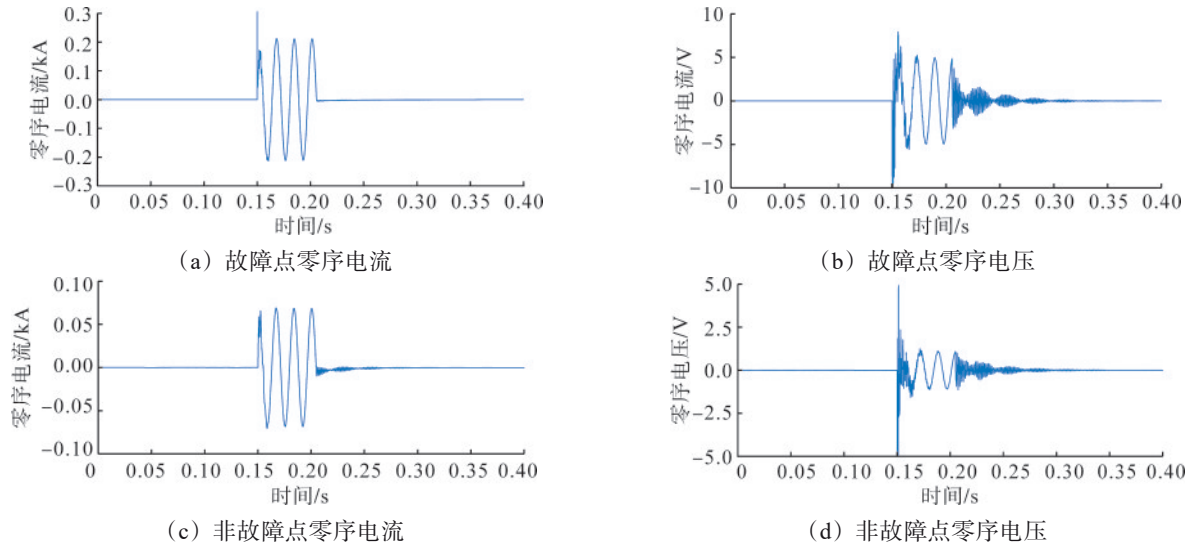


图5 故障支路零序电压、电流波形

Fig.5 waveform of zero sequence voltage and current of fault branch

由图5可知，当发生单相接地故障时，故障点处的零序电流比同一支路非故障处的零序电流更大，可以利用零序电流对风电场集电线路进行故障点定

准确检测到接地故障，零序电流仅在接地故障中产生。发生单相接地故障时故障支路的零序电压与电流波形见图5。

位。非故障支路的零序电压、电流波形见图6。对比图5和图6可知，发生单相接地故障处的零序电流最大，越远离故障点的零序电流越小。




图6 非故障支路零序电压、电流波形

Fig.6 waveform of zero sequence voltage and current of non-fault branch

当C相发生单相接地短路故障时，故障点三相电流、电压波形见图7。由图7可知，故障相电流

幅值突增、故障相电压幅值锐减；非故障相电流、电压幅值受故障的影响较小。

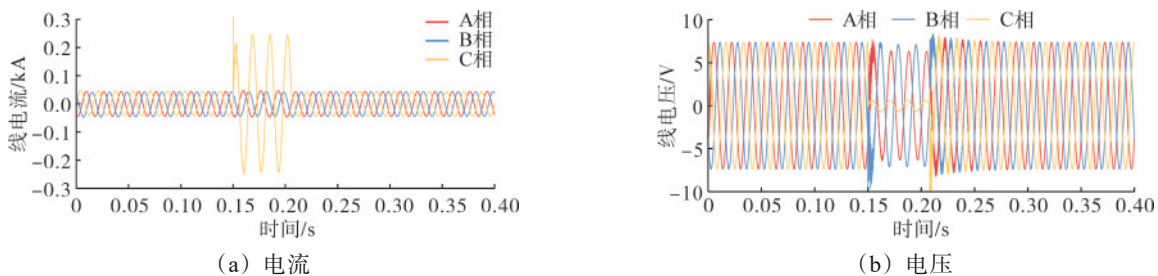


图7 故障点三相电流、电压波形

Fig.7 fault point three-phase current and voltage waveform

3.2 不同情况下故障测距

以风电场集电线路中占比较高的架空线路的单相接地故障为例, 将风电场接地变压器的零序电抗、线路单位距离的零序阻抗、接地阻抗以及测得的零序电流、零序电压值代入式(4), 计算结果见表2。由表2可知, 不同的故障发生位置, 测距的绝对误差都非常小, 说明故障定位准确度较高。

表2 故障发生在不同位置的测距结果

Tab.2 fault occurred at different locations of the ranging results

故障距离/km		绝对误差/km
实际值	计算值	
0.1	0.103	0.003
0.5	0.490	-0.010
1.0	0.982	-0.018
2.0	2.034	0.034
5.0	4.924	-0.076
7.0	7.119	0.119
10.0	9.847	-0.153

在相同故障位置、不同故障电阻的情况下,

表4 不同模型的定位准确率对比

Tab.4 comparison of positioning accuracy rates of different models

故障电阻/ Ω	CNN-LSTM		CNN		BP	
	准确率/%	收敛代数	准确率/%	收敛代数	准确率/%	收敛代数
0.01	98.80	6	97.23	11	93.42	15
0.10	97.58	12	96.05	25	90.53	32
1.00	97.53	19	95.97	39	88.33	50
10.00	97.43	27	94.45	52	85.62	66
100.00	96.65	32	93.23	67	81.56	86

由表4可知, 在接地电阻值较小的情况下, 3种神经网络模型均具有较高的准确率和较快的收敛速度。随着接地电阻值的增加, CNN-LSTM模型的定位准确率虽有所下降, 但准确率仍高于对比模型。当接地电阻为100 Ω 时, 3个模型的损失函数收敛情况见图8。由表4和图8可知, CNN、LSTM模型的收敛速度最快。




图8 损失函数

Fig.8 loss function

零序电流法计算结果见表3。由表3可知, 在故障电阻较低时相对误差较小, 接地电阻最大为100 Ω 时, 故障距离相对误差为1.92%, 绝对误差为96 m。

表3 同一故障点不同故障电阻的测距结果

Tab.3 ranging results of different fault resistors at the same fault point

接地电阻/ Ω	故障距离/km		绝对误差/km	相对误差/%
	实际值	计算值		
0.01	5	4.998 4	0.001 6	0.032
0.10	5	4.997 2	0.002 8	0.056
1.00	5	4.996 5	0.003 5	0.070
10.00	5	4.987 0	0.013 0	0.260
100.00	5	4.904 0	0.096 0	1.920

3.3 不同模型的故障测距效果对比

为验证CNN-LSTM模型在风电场集电线路单相接地故障测距中的性能, 与CNN模型和BP模型做对比分析, 计算不同接地电阻工况下的测距精度。选用8 192组样本数据(接地电阻为0.01 Ω 、0.1 Ω 、1 Ω 、10 Ω 、100 Ω), 按照8 : 1 : 1的比例划分训练样本(6 554组)、验证样本(820组)以及测试样本(818组)。定位结果见表4。

3.4 消融实验

为了进一步分析各模块在故障定位中的效果, 设计消融实验, 将CNN模型、LSTM模型作为对比模型。在接地电阻分别为0.1 Ω 、10 Ω 的数据集上计算故障定位误差, 结果见表5。在低阻(0.1 Ω) 情况下, 与CNN模型和LSTM模型相比, CNN-LSTM模型的RMSE分别降低19.3%、12.5%, MSE分别降低39.8%、29.2%, MAPE分别降低56.3%、52.4%。在高阻(10 Ω) 情况下, 与CNN模型和LSTM模型相比, CNN-LSTM模型的REMS分别降低26.1%、18.4%, MSE分别降低45.4%、33.4%, MAPE分别降低61%、57.7%。可见CNN-LSTM模型能够更好地从数据中提取故障特征。

表5 消融实验结果

Tab.5 ablation experimental results

模型	0.1 Ω			10 Ω		
	RMSE	MSE	MAPE/%	RMSE	MSE	MAPE/%
CNN	0.347 3	0.120 6	6.025	0.390 8	0.152 7	7.520
LSTM	0.320 2	0.102 4	5.524	0.354 0	0.125 3	6.924
CNN-LSTM	0.280 2	0.072 5	2.631	0.288 8	0.083 4	2.931

4 结论

(1) 本文提出了一种基于CNN-LSTM混合模型的风电场集电线路单相接地故障定位方法,并利用某风电场的8 192组故障数据进行实验验证。实验结果表明,该方法可以有效满足风电场复杂环境下的集电线路故障测距需求。

(2) CNN-LSTM模型在0.01 Ω 接地电阻下定位准确率达98.80%,表明该方法对微弱故障工况具有较好的适应能力,联合CNN的局部特征提取与LSTM的时序依赖解析能力,有效提升了故障特征的提取效果。

参考文献(References):

- [1] 彭华,朱永利.基于apFFT频谱校正和XGBoost的风电场集电线路单相接地故障测距[J].电工技术学报,2020,35(23):4931-4939.
PENG Hua,ZHU Yongli.Single phase grounding fault location for power lines of wind farm based on apFFT spectrum correction and XGBoost algorithm[J]. Transactions of China Electrotechnical Society,2020,35(23):4931-4939.
- [2] 潘文庆.风电场零序保护及其场内单相接地故障测距技术研究[D].济南:山东大学,2018:1-43.
- [3] 王宾,任莹.中性点经小电阻接地风电场集电线路单相接地故障测距研究[J].中国电机工程学报,2021,41(6):2136-2144.
WANG Bin,REN Xuan.Single-line-to-ground fault location in wind farm collection line with neutral point grounding with resistor[J]. Proceedings of the CSEE,2021,41(6):2136-2144.
- [4] 张科.大型风电场输电线路短路故障测距方法研究[D].北京:华北电力大学,2019:20-23.
- [5] 李永丽,辛双乔,李涛,等.基于多端信息的风电场集电线路单相接地故障定位算法[J].电力工程技术,2022,41(5):2-11.
LI Yongli,XIN Shuangqiao,LI Tao,et al. Single phase grounding fault location algorithm of wind farm collector lines based on multi-terminal information[J]. Electric Power Engineering Technology, 2022,41(5):2-11.
- [6] 翟羽佳,张凯,朱永利,等.基于分段阻抗匹配的风电场集电线路单相接地故障测距方法[J].智慧电力,2020,48(12):26-32.
ZHAI Yujia,ZHANG Kai,ZHU Yongli,et al. Single-line-to-ground fault location method for wind farm collection line based on segmented impedance matching [J]. Smart Power, 2020, 48(12): 26-32.
- [7] 彭华,王文超,朱永利,等.基于LSTM神经网络的风电场集电线路单相接地智能测距[J].电力系统保护与控制,2021,49(16):60-66.
PENG Hua,WANG Wenchao,ZHU Yongli,et al. An intelligent single-phase grounding fault location for a wind farm collection line based on an LSTM neural network[J].Power System Protection and Control,2021,49(16):60-66.
- [8] 邓丰,史鸿飞,冯思旭,等.CNN-LSTM全景故障特征挖掘的配电网单端定位方法[J].中国电机工程学报,2023,43(增刊):114-126.
DENG Feng,SHI Hongfei,FENG Sixu,et al. Single-ended traveling wave location method for distribution network based on CNN-LSTM panoramic fault feature mining[J].Proceedings of the CSEE, 2019,43(Suppl.):114-126.
- [9] GUO M F,GAO J H,SHAO X,et al. Location of single-line-to-ground fault using 1-D convolutional neural network and waveform concatenation in resonant grounding distribution systems[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 3501009.
- [10] 陈胜,刘鹏飞,王平,等.基于LSTM人工神经网络的电力系统负荷预测方法[J].沈阳工业大学学报,2024,46(1):66-71.
CHEN Sheng,LIU Pengfei,WANG Ping,et al. Load forecasting method of power system based on LSTM artificial neural network [J]. Journal of Shenyang University of Technology, 2024, 46(1): 66-71.
- [11] XIN S Q,LI Y L,LI T,et al. Single phase ground fault locating method of multi-branch wind farm collector lines[C]//2021 IEEE 2nd China International Youth Conference on Electrical Engineering. December 15-17,2021.Chengdu, China. IEEE,2021: 1-5.
- [12] SU X X,WEI H. A fault-line selection method for small-current grounded system based on deep transfer learning[J].Energies,2022, 15(9):3467.
- [13] TEIMOURZADEH H,MORADZADEH A,SHOARAN M,et al. High impedance single-phase faults diagnosis in transmission lines via deep reinforcement learning of transfer functions[J].IEEE Access,2021,9:15796-15809.
- [14] 郑艳艳,朱永利,刘童童,等.基于零序电流的风电场单相接地故障区段定位[J].系统仿真学报,2019,31(7):1408-1415.
ZHENG Yanyan,ZHU Yongli,LIU Tongtong,et al. Single-phase grounding fault location in wind farm based on zero-sequence current[J].Journal of System Simulation,2019,31(7):1408-1415.
- [15] 黄海燕.风电场集电线路单相接地故障特性分析与保护研究[D].昆明:昆明理工大学,2019:1-57.
- [16] 炊婉冰,吕学斌.利用ARIMA-SSA-LSTM组合模型的碳排放交易价格预测[J].西安科技大学学报,2023,43(5):1025-1034.
CUAN Wanbing,LYU Xuebin. Carbon emissions trading price prediction based on ARIMA-SSA-LSTM combination model[J]. Journal of Xi'an University of Science and Technology,2023,43(5): 1025-1034.