

DOI: 10.19783/j.cnki.pspc.201457

基于 LSTM 神经网络的风电场集电线路单相接地智能测距

彭华¹, 王文超², 朱永利¹, 高卉¹, 李瑞青³

(1. 华北电力大学电气与电子工程学院, 河北 保定 071003; 2. 内蒙古华电玫瑰营风力发电有限公司, 内蒙古 呼和浩特 010000; 3. 国网山东省电力公司日照供电公司, 山东 日照 276800)

摘要:为解决风电场多分支、混合短线路中难以查找故障点的问题,提出一种基于长短期记忆(LSTM)神经网络的风电场集电线路单相接地智能故障测距方法。首先,读取集电线路首端测量装置的电气量信息。其次,采用全相位快速傅里叶变换(apFFT)相位差校正法构建了风电场单相接地短路时的故障特征集合。然后,归一化风电场集电线路的故障数据,并训练深度学习 LSTM 神经网络以建立单端故障测距的预测模型。最后,通过 LSTM 神经网络故障定位器开展准确的故障定位。PSCAD/EMTDC 实验结果表明,所提方法的预测精度高于反向传播神经网络和极限学习机方法,且在不同的故障距离和过渡电阻情况下均可行,适用于风电场集电线路的故障测距。

关键词:风电场;集电线路;深度学习;长短期记忆神经网络;单端故障测距

An intelligent single-phase grounding fault location for a wind farm collection line based on an LSTM neural network

PENG Hua¹, WANG Wenchao², ZHU Yongli¹, GAO Hui¹, LI Ruiqing³

(1. School of Electrical and Electronic Engineering, North China Electric Power University, Baoding 071003, China;
2. Inner Mongolia Huadian Meiguiping Wind Power Generation Co., Ltd., Hohhot 010000, China;
3. Rizhao Power Supply Company, State Grid Shandong Electric Power Company, Rizhao 276800, China)

Abstract: It is difficult to determine the fault points in multi branch and hybrid short lines of a wind farm. Thus an intelligent single-phase grounding fault location method based on a Long Short Term Memory (LSTM) neural network is proposed. First, the electrical information of the measuring device at the head of collection line is read. An all-phase Fast Fourier Transform (apFFT) phase difference correction method is used to build the fault feature set when a single-phase grounding fault occurs in a wind farm. Then, the fault data of wind farm collecting lines are normalized, and the deep learning LSTM neural network is trained to establish the prediction model of a single terminal fault location. Finally, precise fault location is carried out through the LSTM neural network fault locator. PSCAD/EMTDC experimental results show that the prediction accuracy of the proposed method is higher than that of a back propagation neural network or an extreme learning machine algorithm. It is feasible to use it for different fault instances and transition resistances, and suitable for fault location of wind farm collecting lines.

This work is supported by the National Natural Science Foundation of China (No. 51677072).

Key words: wind farm; collection line; deep learning; long short term memory neural network; single-terminal fault location

0 引言

随着全球能源危机与环境污染的日益加剧,风电作为一种清洁的新能源发电技术而得到迅猛发展。风电场地处环境恶劣的荒山草原,极易发生短路故障。大规模风电场集电线路^[1]属于典型的多端

电源供电系统,导致常规测距方法不再适用于其特殊的电力网络结构,因不能及时故障定位造成大批机组弃风窝电,这已成为制约风力发电技术应用的主要瓶颈。因此,线路故障后快速、准确的定位,可以及时修复线路和快速恢复风电送出,有利于空气环境的改善,且社会效益显著。

风电场集电线路具有多分支、混合且短的特点,目前尚缺乏有效的故障分析和定位手段。现有测距

基金项目:国家自然科学基金项目资助(51677072)

方法按计算故障距离原理的不同可分为行波法、故障分析法和人工智能算法^[2]。行波法^[3-9]虽然测距精度高,但在风电场内存有大量的分支线和混合线,而且线路较短,受行波采样率的影响,导致波头识别和波速确定困难,此外,行波色散效应使波头发生畸变,引起到达时刻的标定误差。文献[9]采用等效思想对配电网的线路结构归一化处理以解决电缆和架空线混合线路中行波波速明显不同的问题,但需在每个分支线的末端安装同步测量装置,使算法实现成本高。故障分析法^[10-14]的测距准确度受过渡电阻和系统参数变化影响较大,需迭代求解方程,计算量较大,容易出现伪根。文献[14]提出将节点高频电压方程与贝叶斯压缩感知理论相结合的思路实现直流配网的故障定位,但需系统设备的采样率较高,同时对最小测点数目和安装位置分布有一定的要求。

数字驱动的智慧风电场建设开启了风电人工智能时代,不同智能算法^[15-19]的研究将成为解决目前风电场集电线路故障测距困难的有效手段。文献[18]提出矩阵算法和智能优化算法相结合的配电网高容错性故障区段定位思路,利用两种算法的优点并取长补短,在整体上提高了定位辐射式配电网故障区段的性能。文献[19]采用电压和电流传感器检测光伏阵列电压和电流故障特征值,通过训练高斯过程回归器实现了光伏系统的故障定位,性能明显优于反向传播神经网络。

本文针对风电场的网架结构特点,提出一种基于长短期记忆(Long Short Term Memory, LSTM)神经网络的风电场集电线路单相接地智能故障测距方法。采用全相位快速傅里叶变换(all-phase Fast Fourier Transform, apFFT)相位差频谱校正处理 35 kV 母线侧的单端测点数据,构建故障特征集合。通过深度学习 LSTM 神经网络建立故障定位器,并对新输入的归一化风电场集电线路故障数据开展故障距离预测。与传统反向传播神经网络和极限学习机算法相比,实验结果证明了本文方案的有效性。

1 apFFT 相位差频谱校正

apFFT 相位差频谱校正法^[20]充分结合了汉宁窗 FFT 算法与汉宁卷积窗 apFFT 算法的优点,利用两者的优势互补特性来实现风电场集电线路发生单相接地短路时故障信号的准确分析。

若考虑故障信号的时移 n_x ,则汉宁窗 FFT 与汉宁卷积窗 apFFT 主谱线上的相角分别为

$$\varphi_x(k^*) = \varphi_0 - n_x \omega^* - \tau(k^* \Delta\omega - \omega^*) \quad (1)$$

$$\varphi_y(k^*) = \varphi_0 - n_x \omega^* \quad (2)$$

式中: φ_0 为初相位; ω^* 为角频率; τ 为群延时; k^* 为主谱线对应的位置; $\Delta\omega$ 为频率分辨率。在此基础上,可获取两种谱分析的主谱线相角差。

$$\Delta\varphi = \varphi_x(k^*) - \varphi_y(k^*) = \tau(\omega^* - k^* \Delta\omega) = \tau d\omega \quad (3)$$

式中, $d\omega$ 为频偏值。经相位补偿的角频率估计为

$$\hat{\omega}_0 = \frac{\Delta\varphi}{\tau} + k^* \Delta\omega \quad (4)$$

风电场集电线路中故障信号的幅值校正计算式为

$$\hat{A}_0 = \frac{|X(k^*)|^2}{|Y(k^*)|} \quad (5)$$

式中: $|X(k^*)|$ 为汉宁窗 FFT 分析的幅值; $|Y(k^*)|$ 为汉宁卷积窗 apFFT 分析的幅值。故障信号的基波相位则通过汉宁卷积窗 apFFT 算法直接获取。

2 基于 LSTM 神经网络的风电场故障测距

2.1 LSTM 神经网络

深度学习 LSTM 神经网络^[21-24]是由循环神经网络(Recurrent Neural Network, RNN)改进的一种特殊变体,能够充分利用历史信息,避免产生长期依赖的情况,并且有效解决了深度学习 RNN 在实际应用中存在梯度消失和梯度爆炸的问题。其中,深度学习 LSTM 神经网络隐含层内部的拓扑结构如图 1 所示。

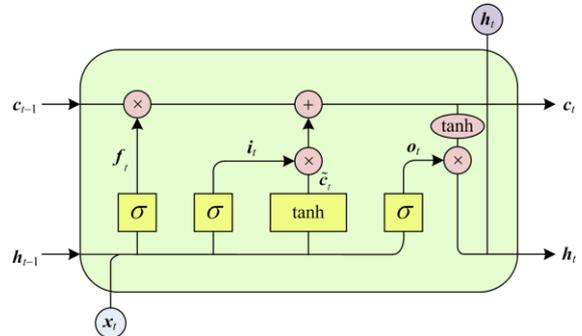


图 1 LSTM 隐含层内记忆模块拓扑结构

Fig. 1 Internal memory module topology of LSTM hidden layer

由图 1 可知,同深度学习 RNN 相比, LSTM 神经网络也是由输入层、隐含层、输出层构成,但其隐含层不再是普通神经元,而是被替换为含门控机制的独特记忆模块。

LSTM 记忆单元是记忆模块的核心组件,其读取和修改是通过遗忘门、输入门和输出门的控制来实现。

遗忘门可决定记忆单元需要保留的历史信息，其计算式为

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (6)$$

式中： σ 为sigmoid激活函数； W_f 为遗忘门的权重矩阵； h_{t-1} 为 $t-1$ 时刻的输出； x_t 为 t 时刻的输入； b_f 为遗忘门的偏置。

输入门由tanh函数生成新候选向量 \tilde{c}_t ，同时用sigmoid函数确定需要加入细胞状态的新信息。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (7)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (8)$$

式中： W_i 、 W_c 分别为输入门和候选向量的权重矩阵； b_i 、 b_c 分别为输入门和候选向量的偏置。

LSTM记忆模块在读取当前风电场集电线路发生单相接地短路时的故障输入数据 x_t 后，需要完成细胞状态信息从 c_{t-1} 到 c_t 的更新，用遗忘门来选择希望删除的信息，而输入门则被用于选择需要更新的信息。

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (9)$$

输出门的功能为选择性输出细胞状态保存的信息，由tanh函数将细胞状态的内容处理为 $[-1,1]$ ，并用sigmoid函数确定需要输出的内容部分。

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (10)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (11)$$

式中， W_o 、 b_o 分别表示输出门的权重矩阵及其偏置。

2.2 LSTM神经网络的训练方法

目前，深度学习LSTM神经网络的主流训练算法有两种：随时间反向传播算法和实时循环学习算法。由于随时间反向传播算法概念清晰，且运算效率更高，故本文采用该方法训练LSTM神经网络预测模型。

随时间反向传播算法的具体应用思路如下：首先，将深度学习LSTM神经网络按照时间的顺序展开成一个前馈网络；然后，应用误差反向传播算法来计算相关的梯度，并对展开之后的前馈网络进行训练。其中，LSTM神经网络的时序展开图如图2所示。

2.3 风电场故障LSTM神经网络预测模型设计

2.3.1 风电场故障信号特征提取

风电场系统中因测点测量的波形数据是高维时序的，故有必要对大规模原始数据提取故障特征量。本文测量装置安装在集电线路的首端，对风电场集电线路单相接地短路时测点检测的波形数据，采用apFFT相位差频谱校正法提取三相及零序电压、电流的基波相量作为故障特征量，如表1所示。

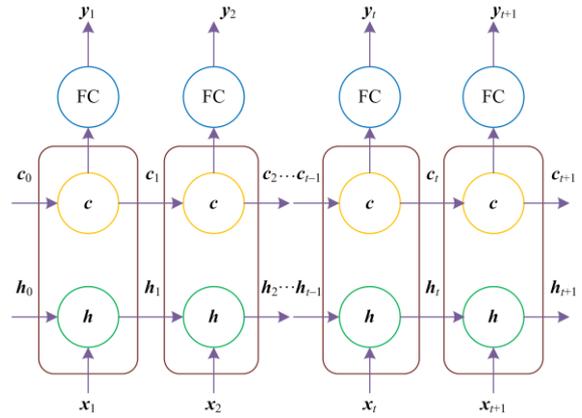


图2 LSTM神经网络时序展开图

Fig. 2 Sequence structure of LSTM neural network

表1 风电场集电线路故障信号特征

Table 1 Features of fault signals of wind farm collection line

特征	特征描述	特征	特征描述
F_1	A相电压有效值	F_9	A相电压相位
F_2	B相电压有效值	F_{10}	B相电压相位
F_3	C相电压有效值	F_{11}	C相电压相位
F_4	零序电压有效值	F_{12}	零序电压相位
F_5	A相电流有效值	F_{13}	A相电流相位
F_6	B相电流有效值	F_{14}	B相电流相位
F_7	C相电流有效值	F_{15}	C相电流相位
F_8	零序电流有效值	F_{16}	零序电流相位

2.3.2 故障数据归一化

考虑到风电场故障不同特征变量间的量纲不同，数值差别较大，以及LSTM神经网络预测模型中激活函数的特性，同时为平等地处理不同特征变量对故障距离的影响，采用最小、最大值标准化将其归一化至 $[0,1]$ 区间。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (12)$$

式中： x 为风电场故障样本数据的实际值； x_{\min} 、 x_{\max} 分别为特征变量对应列的最小值和最大值。

2.3.3 LSTM神经网络预测超参数选择

超参数的选择对于深度学习预测模型性能的提升具有关键的作用，因此，本文还需要根据不同的应用场景对LSTM神经网络开展相应的调参工作，以达到风电场集电线路中故障距离预测的精度水平。

在进行风电场集电线路故障距离预测时，采用控制变量法对影响LSTM神经网络精度较大的网络层数、神经元节点数等参数进行大量统计调优，部分结果如表2所示。

表 2 LSTM 神经网络不同超参数下的结果

Table 2 Results of LSTM neural network under different hyper-parameters

LSTM 网络层数	第一层神经元节点数	第二层神经元节点数	训练轮数	批尺寸	平均预测故障距离
1	128	—	250	60	339.99
1	256	—	250	60	257.77
2	128	16	250	60	666.53
2	256	16	250	60	660.54

本文通过调参工程, 最终确定的最优超参数如下: LSTM 神经网络隐含层为 1 层, 神经元节点数为 256, 训练轮数为 250, 批尺寸大小为 60。选取平均绝对误差作为损失函数, 且根据损失函数采用自适应矩估计 Adam 优化算法对 LSTM 神经网络的权重系数进行更新学习。此外, 引入随机失活机制以防止模型出现过拟合, 最后设置图 2 中的全连接层(Fully Connected Layer, FCL), 用于输出风电场集电线路单相接地短路下预测的故障距离结果。

3 算例仿真验证

为验证本文方案应用于风电场故障测距的有效性和准确性, 以带有双馈异步风力发电机的两条集电线路为例, 采用电磁暂态 PSCAD/EMTDC 软件进行单相接地故障建模仿真, 110 kV/35 kV 风电场系统如图 3 所示。其中, 风电场 35 kV 汇集系统的消弧措施为“接地变压器与电阻柜的组合”, 中性点接地方式为大电流接地, 集电线路中电缆的型号为 YJLV23-26/35kV-3×240, 长度均为 100 m, 架空线的型号为 LGJ240, 相邻风电机组间架空线的长度均为 2 000 m, 采样频率为 1 600 Hz, 此外, 由于风电机组的仿真时长原因, 在集电线路上总共接入 12 台单机额定功率为 2 MW 的风电机组, 测点安装在 35 kV 集电线路的首端。

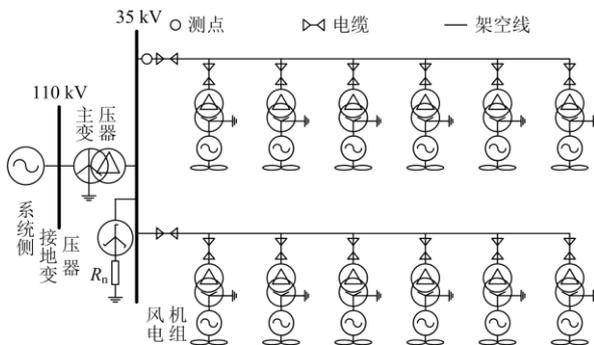


图 3 风电场集电线路电气模型

Fig. 3 Electrical model of wind farm collection line

故障样本集是建立 LSTM 神经网络的关键, 但在建立故障样本集前应先识别接地出线来简化计算复杂度。由文献[1]可知, 根据风电场集电线路 35 kV 母线出口侧的零序电流可判断出单相接地故障发生在哪条集电线路上。

假设故障发生在风电场中的第一条集电线路, 且考虑风电场系统的仿真时长问题, 本文训练样本集的构建方式为: 沿集电线路每隔 200 m 处设置一个单相接地故障点, 并在每个单相接地故障点设置不同的故障条件, 即每个故障点的过渡电阻选取 0 Ω 、30 Ω 、50 Ω 、70 Ω 、100 Ω , 总共 5 种情况的阻值来生成训练故障样本集, 以完成 LSTM 神经网络故障定位器的设计。

3.1 LSTM 神经网络故障距离预测准确性的验证

本文选取两组不同的测试故障样本集用于验证深度学习 LSTM 神经网络在风电场集电线路故障距离预测中的准确性。

对于测试故障样本集 1: 发生 A 相接地故障时的过渡电阻相同, 均为 100 Ω , 故障点位置到图 3 中单端测点的长度分别为 650 m、4 650 m、8 650 m、9 450 m。由此, 风电场集电线路测试故障样本集 1 的 LSTM 神经网络距离预测结果如表 3 所示。

表 3 测试故障样本集 1 的 LSTM 神经网络距离预测结果

Table 3 Distance prediction results of LSTM neural network of test fault sample set 1

故障距离/m	过渡电阻/ Ω	距离预测结果/m	距离预测误差/m
650	100	738.53	88.53
4 650	100	4 716.69	66.69
8 650	100	8 129.10	-520.90
9 450	100	9 663.52	213.52

由表 3 可知, 在过渡电阻为 100 Ω 的不同故障距离条件下, 本文 LSTM 神经网络均具有较小的距离预测误差, 证明了基于 LSTM 神经网络的故障测距思路基本不受故障距离的影响, 依然能够准确地预测故障距离。

对于测试故障样本集 2: 改变过渡电阻值的大小, 使不同次 A 相接地故障时过渡电阻的取值存在差异性, 且随机选取故障点的位置。由此, 风电场集电线路测试故障样本集 2 的 LSTM 神经网络距离预测结果如表 4 所示。

由表 4 可知, 当过渡电阻和故障距离发生改变时, LSTM 神经网络依然可有效进行风电场集电线路故障距离预测, 证明了基于 LSTM 神经网络的故障测距思路基本不受过渡电阻、故障距离的影响, 能够保证风电场集电线路在不同故障条件下的测距应用。

表 4 测试故障样本集 2 的 LSTM 神经网络距离预测结果

Table 4 Distance prediction results of LSTM neural network of test fault sample set 2

过渡电阻/ Ω	故障距离/m	距离预测结果/m	距离预测误差/m
0	4 700	4 583.06	-116.94
30	2 650	3 200.24	550.24
45	5 700	5 745.17	45.17
45	7 250	7 081.26	-168.74
45	9 350	9 830.17	480.17
50	9 500	9 654.94	154.94
65	7 250	7 139.81	-110.19
70	6 450	6 834.61	384.61
80	9 350	9 246.01	-103.99
85	5 700	5 095.81	-604.19

3.2 神经网络智能算法之间的比较验证

为进一步验证深度学习 LSTM 神经网络在风电场集电线路故障测距中的距离预测能力, 本文还比较了 LSTM 神经网络、反向传播(Back Propagation, BP)神经网络和极限学习机(Extreme Learning Machine, ELM)三种不同神经网络模型之间的预测结果。

建立 LSTM 神经网络、BP 神经网络和 ELM 故障预测模型。其中, BP 神经网络的结构参数: 隐含层神经元数为 20, 激活函数为 logsig , 学习训练函数为 trainbfg 。ELM 故障预测模型的结构参数: 隐含层神经元数为 20, 激活函数为 sig 。

三种故障预测模型的整体平均绝对误差如图 4 所示。此外, 不同神经网络智能算法模型的故障距离实际值、预测值及距离预测误差的详细结果如表 5 所示。

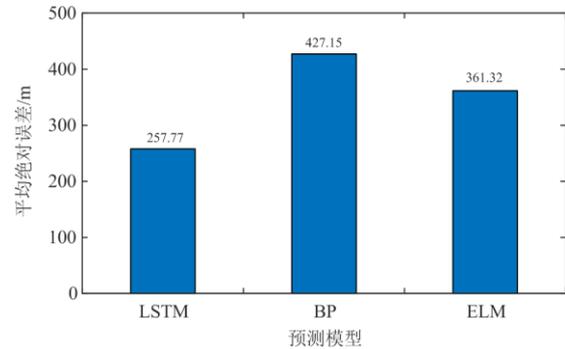


图 4 不同神经网络预测模型整体平均绝对误差

Fig. 4 Mean absolute errors under different neural network prediction models

表 5 风电场集电线路不同神经网络预测模型详细结果比较

Table 5 Detailed comparison results under different neural network prediction models of wind farm collection line

故障距离/m	过渡电阻/ Ω	LSTM 神经网络		BP 神经网络		ELM	
		距离预测结果/m	距离预测误差/m	距离预测结果/m	距离预测误差/m	距离预测结果/m	距离预测误差/m
650	100	738.53	88.53	1 578.05	928.05	1 438.89	788.89
4 650	100	4 716.69	66.69	4 719.34	69.34	4 645.40	-4.60
8 650	100	8 129.10	-520.90	9 021.55	371.55	8 328.07	-321.93
9 450	100	9 663.52	213.52	10 070.19	620.19	10 011.57	561.57
4 700	0	4 583.06	-116.94	4 133.66	-566.34	5 021.21	321.21
2 650	30	3 200.24	550.24	1 767.36	-882.64	2 390.21	-259.79
5 700	45	5 745.17	45.17	5 551.92	-148.08	5 995.78	295.78
7 250	45	7 081.26	-168.74	7 560.20	310.20	6 979.77	-270.23
9 350	45	9 830.17	480.17	9 268.93	-81.07	9 945.53	595.53
9 500	50	9 654.94	154.94	9 753.65	253.65	9 893.98	393.98
7 250	65	7 139.81	-110.19	6 441.20	-808.80	7 333.96	83.96
6 450	70	6 834.61	384.61	6 467.39	17.39	7 064.03	614.03
9 350	80	9 246.01	-103.99	10 075.23	725.23	9 313.21	-36.79
5 700	85	5 095.81	-604.19	5 502.42	-197.58	5 189.79	-510.21

由图 4 和表 5 可知, 本文 LSTM 神经网络与 BP 神经网络、ELM 故障预测模型相比较, 其故障距离预测值与故障距离真实值之间的误差最小, 具有更优的预测精度, 平均绝对误差分别降低了 169.38 m

和 103.55 m。综上比较分析, 证明了基于深度学习 LSTM 神经网络的智能算法在故障距离预测中具有一定的优势, 更适于风电场集电线路的故障测距。

4 结论

本文为解决风电场多分支、混合短线路中难以查找故障点的问题, 提出一种基于深度学习 LSTM 神经网络的风电场集电线路单相接地智能故障测距方法, 具有如下结论:

(1) 利用风电场集电线路的首端测点信息, 避免了同步测量带来的误差, 故障测距简单, 成本低, 易于实现。

(2) 选择随时间反向传播算法对 LSTM 神经网络进行训练, 并引入了随机失活机制, 能够有效防止故障预测模型出现过拟合, 具有独特的长期记忆效应和深度学习能力, 在风电场故障测距中具有较好的预测效果。

(3) 通过算例分析验证, 基于深度学习 LSTM 神经网络的故障测距思路基本不受过渡电阻、故障距离变化的影响。此外, 相较于传统 BP 神经网络、ELM 故障预测模型, 其平均绝对误差分别降低了 169.38 m 和 103.55 m, 具有更高的预测精度和更优的泛化性能, 该算法的精度水平能够满足风电场集电线路的测距应用。

参考文献

- [1] 成和祥. 基于双馈风机短路特性的风电场集电线路继电保护整定方法研究[J]. 电力系统保护与控制, 2020, 48(16): 93-99.
CHENG Hexiang. Discussion on setting scheme of collecting line relay protection in wind farm based on a DFIG short-circuit characteristic[J]. Power System Protection and Control, 2020, 48(16): 93-99.
- [2] GURURAJAPATHY S S, MOKHLIS H, ILLIAS H A. Fault location and detection techniques in power distribution systems with distributed generation: a review[J]. Renewable & Sustainable Energy Reviews, 2017, 74: 949-958.
- [3] 夏远洋, 李啸骢, 陈飞翔, 等. 基于 FastICA 的输电线路行波故障测距方法[J]. 电力系统保护与控制, 2019, 47(1): 138-143.
XIA Yuanyang, LI Xiaocong, CHEN Feixiang, et al. FastICA based traveling wave fault location algorithm for transmission lines[J]. Power System Protection and Control, 2019, 47(1): 138-143.
- [4] 孙广, 王阳, 薛枫, 等. 特高压直流输电线路改进双端行波故障定位方法研究[J]. 电力系统保护与控制, 2020, 48(14): 113-120.
SUN Guang, WANG Yang, XUE Feng, et al. Research on an improved double-terminal traveling wave fault location method for UHVDC project[J]. Power System Protection and Control, 2020, 48(14): 113-120.
- [5] BENATO R, SESSA S D, POLI M, et al. An online travelling wave fault location method for unearthed-operated high-voltage overhead line grids[J]. IEEE Transactions on Power Delivery, 2018, 33(6): 2776-2785.
- [6] 赵海龙, 王鑫红, 高昌龙. 基于 FIMD 和 Hilbert 变换的高压输电线路行波故障定位方法[J]. 电测与仪表, 2020, 57(18): 77-82.
ZHAO Hailong, WANG Xinhong, GAO Changlong. Traveling wave fault location method for high voltage transmission lines based on FIMD and Hilbert transform[J]. Electrical Measurement & Instrumentation, 2020, 57(18): 77-82.
- [7] 田斌, 方覃绍阳, 李振兴, 等. 基于波速修正的多回输电线路行波测距算法[J]. 高压电器, 2019, 55(1): 184-189.
TIAN Bin, FANG Qinshaoyang, LI Zhenxing, et al. Parallel multiloop transmission line travelling wave location algorithm based on amending wave velocity[J]. High Voltage Apparatus, 2019, 55(1): 184-189.
- [8] 齐郑, 杭天琦, 林健雄, 等. 含单相配电网支路的配电网单相接地故障行波测距技术[J]. 电力系统自动化, 2018, 42(20): 144-149.
QI Zheng, HANG Tianqi, LIN Jianxiong, et al. Technology of traveling wave fault location on single phase-to-ground fault in distribution network with single-phase power supply lines[J]. Automation of Electric Power Systems, 2018, 42(20): 144-149.
- [9] 刘晓琴, 王大志, 江雪晨, 等. 利用行波到达时差关系的配电网故障定位算法[J]. 中国电机工程学报, 2017, 37(14): 4109-4115.
LIU Xiaoqin, WANG Dazhi, JIANG Xuechen, et al. Fault location algorithm for distribution power network based on relationship in time difference of arrival of traveling wave[J]. Proceedings of the CSEE, 2017, 37(14): 4109-4115.
- [10] 孙建锋, 徐云飞, 周哲, 等. C-MMC 型电力电子变压器直流故障分析与保护方法研究[J]. 电测与仪表, 2020, 57(17): 123-128.
SUN Jianfeng, XU Yunfei, ZHOU Zhe, et al. Study on DC fault analysis and protection method of C-MMC based power electronic transformer[J]. Electrical Measurement & Instrumentation, 2020, 57(17): 123-128.
- [11] 张斯淇, 李永丽, 陈晓龙, 等. 基于正序电流差的同塔双回 T 型输电线路故障测距新算法[J]. 中国电机工程学报, 2018, 38(5): 1488-1495.
ZHANG Siqi, LI Yongli, CHEN Xiaolong, et al. A new fault location algorithm based on positive sequence current

- difference for double-circuit three-terminal transmission lines[J]. Proceedings of the CSEE, 2018, 38(5): 1488-1495.
- [12] 卢继平, 罗与锋, 钟璐, 等. 基于单侧信息的多支配网单相接地故障定位[J]. 高电压技术, 2016, 42(2): 605-611.
LU Jiping, LUO Yufeng, ZHONG Lu, et al. Single-phase-to-ground fault location in multi-brunch distribution network based on unilateral information[J]. High Voltage Engineering, 2016, 42(2): 605-611.
- [13] 徐子萌, 胡治龙, 张腾, 等. 用于高压直流输电的晶闸管换流阀短路故障分析及其试验方法研究[J]. 高压电器, 2019, 55(12): 145-153.
XU Zimeng, HU Zhilong, ZHANG Teng, et al. Study on test method and analysis for short current fault of thyristor converter valve for high voltage direct current (HVDC) power transmission[J]. High Voltage Apparatus, 2019, 55(12): 145-153.
- [14] 贾科, 冯涛, 赵其娟, 等. 基于故障高频电压稀疏量测的直流配电网双极短路故障定位[J]. 电力系统自动化, 2020, 44(1): 142-151.
JIA Ke, FENG Tao, ZHAO Qijuan, et al. Bipolar short-circuit fault location for DC distribution network based on sparse measurement of fault high-frequency voltage[J]. Automation of Electric Power Systems, 2020, 44(1): 142-151.
- [15] PENG N, CHENG M H, LIANG R, et al. Asynchronous fault location scheme for half-wavelength transmission lines based on propagation characteristics of voltage travelling waves[J]. IET Generation, Transmission & Distribution, 2019, 13(4): 502-510.
- [16] JAMALI S, BAHMANYAR A, RANJBAR S. Hybrid classifier for fault location in active distribution networks[J]. Protection and Control of Modern Power Systems, 2020, 5(2): 174-182. DOI: 10.1186/s41601-020-00162-y.
- [17] 赵乔, 王增平, 董文娜, 等. 基于免疫二进制粒子群优化算法的配电网故障定位方法研究[J]. 电力系统保护与控制, 2020, 48(20): 83-89.
ZHAO Qiao, WANG Zengping, DONG Wenna, et al. Research on fault location in a distribution network based on an immune binary particle swarm algorithm[J]. Power System Protection and Control, 2020, 48(20): 83-89.
- [18] 徐彪, 尹项根, 张哲, 等. 矩阵算法和优化算法相结合的配电网故障定位[J]. 电力系统自动化, 2019, 43(5): 152-158.
XU Biao, YIN Xianggen, ZHANG Zhe, et al. Fault location for distribution network based on matrix algorithm and optimization algorithm[J]. Automation of Electric Power Systems, 2019, 43(5): 152-158.
- [19] 徐瑞东, 陈昊, 胡义华, 等. 基于高斯过程的光伏阵列故障定位[J]. 电工技术学报, 2013, 28(6): 249-256.
XU Ruidong, CHEN Hao, HU Yihua, et al. Fault location of photovoltaic array based on Gaussian process[J]. Transactions of China Electrotechnical Society, 2013, 28(6): 249-256.
- [20] 黄翔东, 王兆华. 基于全相位频谱分析的相位差频谱校正法[J]. 电子与信息学报, 2008, 30(2): 293-297.
HUANG Xiangdong, WANG Zhaohua. Phase difference correcting spectrum method based on all-phase spectrum analysis[J]. Journal of Electronics & Information Technology, 2008, 30(2): 293-297.
- [21] TAN M, YUAN S P, LI S H, et al. Ultra-short-term industrial power demand forecasting using LSTM based hybrid ensemble learning[J]. IEEE Transactions on Power Systems, 2020, 35(4): 2937-2948.
- [22] LI M S, ZHANG Z Y, JI T Y, et al. Ultra-short term wind speed prediction using mathematical morphology decomposition and long short-term memory[J]. CSEE Journal of Power and Energy Systems, 2020, 6(4): 890-900.
- [23] ERGEN T, KOZAT S S. Online training of LSTM networks in distributed systems for variable length data sequences[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(10): 5159-5165.
- [24] KONG W C, DONG Z Y, JIA Y W, et al. Short-term residential load forecasting based on LSTM recurrent neural network[J]. IEEE Transactions on Smart Grid, 2019, 10(1): 841-851.

收稿日期: 2020-11-25; 修回日期: 2021-03-11

作者简介:

彭华(1989—), 男, 通信作者, 博士研究生, 研究方向为风电场集电线路故障定位; E-mail: penghua890415@126.com

朱永利(1963—), 男, 博士, 教授, 研究方向为电力设备状态监测和分析、电力系统分析与控制、电力系统网络化监控和智能信息处理。E-mail: yonglipw@163.com

(编辑 许威)