

基于 BiLSTM-CNN 的配网电压暂降源类型 辨识方法研究

何龙, 刘荣, 朱咏明, 赵诗宇, 张新
(国网新疆电力有限公司昌吉供电公司, 新疆 昌吉 825000)

摘要: 准确辨识电压暂降源类型是供用电双方划分责任以及进行治理的重要依据。针对电压暂降源类型辨识困难、准确率偏低的现存问题,提出一种基于融合 BiLSTM 和 CNN 的电压暂降源类型辨识方法:首先,对电压暂降事件数据进行辨异加权合成后再进行完全集成经验模态分解与自适应噪声分解重构,滤除噪声的影响;其次,利用 BiLSTM 对电压暂降时间序列信号循环特征分解,最大程度挖掘时间序列样本之间的时间相关性,提取全局特征,并生成统一长度的特征向量,接着,利用 CNN 对特征向量的空间相关性进一步加工处理,强调其中局部关键特征;最后将两者得到的特征融合后对暂降源进行分类,实现暂降源类型的确定。搭建 IEEE 33 节点测试系统仿真模型,模拟电压暂降时间,在获得大量包括大电机启动、变压器空投以及各种短路故障仿真数据的基础上,采用所提方法实现电压暂降源类型的辨识与区分,并与 CNN 和 LSTM 分别辨识的结果相对比,结果表明,所提方法的准确率高,鲁棒性好。

关键词: BiLSTM; CNN; 特征提取; 电压暂降源; 辨识

Research on the Type Identification Method of Voltage Sag Source in Distribution Network Based on BiLSTM-CNN

HE Long, LIU Rong, ZHU Yongming, ZHAO Shiyu, ZHANG Xin
(Changji Power Supply Company of State Grid Xinjiang Electric Power Co., Ltd.,
Xinjiang Changji 825000, China)

Abstract: Accurately identifying the type of voltage sag source is an important basis for both responsibility distinction between suppliers and users as well as governance. In view of the existing problems of difficult identification on type of voltage sag sources and low accuracy, a type identification method of voltage sag source based on the fusion of BiLSTM and CNN is proposed: Firstly, the voltage sag event data is subjected to discernment weighting and synthesis before being decomposed and reconstructed using complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) to filter out the effect of noise. Then, BiLSTM is used to decompose the cyclic features of the voltage sag time series signal to possible explore the temporal correlation between time series samples, extract global features, and generate feature vectors of unified length as much as possible. After that, CNN is used to further process and refine the spatial correlation of the feature vectors, emphasizing the local key features. Finally, the features obtained from both methods are fused to classify the sag source and determine the type of the sag source. The IEEE 33-node test system simulation model is set up to simulate voltage sag time and, on the basis of obtaining a large amount of simulation data including start-up of motor, no-load operation of transformer and various short-circuit faults, the proposed method is used for identification and differentiation on the type of voltage sag source and for comparison with the result identified respectively by the CNN and LSTM. The results show that the proposed method has high accuracy and good robustness.

Keywords: BiLSTM; CNN; feature extraction; voltage sag source; identification

0 引言

随着现代电力电子器件、精密仪器以及高速计算机等敏感负荷在电力系统的比重增多,电压暂降已经成为影响电能质量的重要问题^[1-4]。据统计,电压暂降已经给电力负荷尤其是敏感负荷带来了较为严重的经济损失,由电压暂降引发的客户投诉以及经济纠纷近年来也呈上升趋势,大电机启动、变压器空载投切以及各种短路故障等都会引起电压暂降现象,而出现暂降事件带来的损失也会由责任方承担,为了有效客观界定电压暂降事故中供用电双方各自的责任,开展电压暂降源辨识十分必要^[4-7]。

对电压暂降源类型辨识的传统方法大多数集中在利用电压暂降的残压幅值、相移、电压暂降突变点数量以及谐波含量等特征参数来区分和辨识方面,具有简单、快速和直观的优点,但方法的辨识结果受信号采样设备精度以及人员操作的影响较大,当数据存在缺失或噪声干扰时,则会造成较大的判别偏差,为了克服这个缺陷,利用计算机信号处理以及人工智能算法,对暂降源类型加以辨识,取得了不错的研究进展。如小波分析法^[8-10]、经验模态分解法(empirical mode decomposition, EMD)分解法^[11-12]、动态时间弯曲距离^[13]以及傅里叶法^[14]等进行特征提取,以及S变换法^[15]、深度置信网络^[16]、空间矢量法^[17-21]等对暂降源类型加以辨识,上述方法取得了一定的成果,但当电压暂降源为短路故障且过渡电阻较高时,有些故障电压暂降信号比较微弱,则难以达到较好的效果。

相比传统的人工智能技术和机器学习算法,深度学习模型可以不再局限于特征提取,可以进行自主学习获取较高的分类准确率,其中卷积神经网络(convolutional neural network, CNN)有较强的高维数据处理能力和平面感知能力,已应用于各类故障诊断,不过且当样本之间存在较强的时序相关性时, CNN无法对此进行有效的特征挖掘,而电压暂降监测采集的故障波形具有明显的时序性,为了对此特征进行反映,利用双向长短时记忆网络(Bi-directional long-short term memory, BiLSTM)分析并强调故障信号之间隐含的时序关系^[22],则可望提高暂降源辨识准确率。如文献[23-24]采用长短时记忆(long-short term memory, LSTM)对电压暂降事件加以分类辨识,文献[25-28]采用BiLSTM实现了多种电压暂降事件的辨识;文献[29]则是将CNN与LSTM结合起来,分别提取电压暂降事件的数据特征并加以融合,实现电压暂降事件的分类,并与CNN和LSTM对比;文献[31]

则采用S变换先对电压暂降事件数据进行特征指标计算,得到了16个特征指标,然后将特征指标作为输入之一,再利用CNN-BiLSTM辨识模型加以分类,不过S变换后的指标虽然能够有效指征不同暂降事件类型,但对存在噪声干扰的情况以及在噪声干扰对S变换下特征指标的影响,文献[30]没有充分讨论。

鉴于此,提出一种将卷积神经网络和双向长短时记忆网络融合的电压暂降源类型辨识模型,考虑信号采集过程中受到噪声干扰的问题,首先利用完全集成经验模态分解与自适应噪声(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)方法对数据进行预处理,接着利用BiLSTM对样本时间序列信息分析的优势,强化表达电压暂降事件信号局部的特征;再利用CNN对全局信息的把控优势,构建1D-CNN块对CNN模型加以改进,以便更充分的提取特征并挖掘出各类电压暂降事件信号特征的全局隐藏关系;最后将二者结合提高模型对暂降源特征提取的能力和分类的准确率,并结合电压暂降源仿真数据对所提方法进行了验证。

1 基于BiLSTM-CNN电压暂降源辨识框架

基于BiLSTM-CNN电压暂降源类型辨识模型框架见图1,辨识框架一共包括3个部分:

第1步,收集和整理母线三相电压监测数据,经预处理后构建样本集合。获取各种暂降源在系统不同工况下的母线电压监测数据,归一化后构建样本集合,并对数据进行CEEMDAN分解再重构的降噪处理。

第2步,特征提取。BiLSTM和CNN并行进行特征提取。BiLSTM对样本集合进行时间序列前后样本特征关系的相关性分析,并对其中的关键局部特征信息进行强化表达的同时,进一步挖掘其中隐藏的全局特征,其输出为特征序列向量;利用CNN的卷积、池化和操作,也可以对时间序列向量进行空间分布特征提取。

第3步,特征融合与分类。这一部分是先将两个深度模型提取得到的特征进行融合,再利用Softmax分类器确定暂降源类型,输出不同类型暂降源的辨识结果。

2 基于BiLSTM-CNN电压暂降源辨识方法

2.1 数据预处理

在获得的母线三相电压实时监测数据后,为了便于后续的数据特征提取与辨识环节,对电压信号进行预处理,具体流程见图2。




图1 基于BiLSTM-CNN的电压暂降源类型辨识框架

Fig. 1 Identification framework on type of voltage sag source based on BiLSTM -CNN




图2 数据预处理流程

Fig. 2 Data preprocessing process

图2所示数据预处理流程包括实时数据监测、波形辨异合成以及CEEMDAN分解3个环节。对电压暂降三相电压信号进行采集后,再进行数据的辨异加权合成和降噪分解重构。其中,辨异加权合成的思路主要是先对三相电压信号进行异相辨识,这一步可利用波形相似检测法来完成,当辨识出其中的某一相信号与其他两相信号存在较大区别后,对该相信号及其他两相权重进行分配,在此基础上再对三相信号进行加权合成,具体的工作流程如下:

首先,对监测采集到的三相数据进行波形相似度检测,采用动态时间规整(dynamic time warping, DTW)算法对三相信号时间序列之间相似度进行比较度量,DTW算法的基本思想是找到两个时间序列

之间的最佳匹配路径,使得路径上的数据点具有最小的累计距离度量。假定三相电压时间序列分别为A、B和C,长度分别为n和m,则定义矩阵 $M_{m \times n}$,元素 $M(i,j)$ 表示电压序列A的前i个元素和序列B的前j个元素之间的距离。A、B两相电压时间序列与矩阵M构建方式如图3所示。

DTW对两个时间序列波形相似度对比的基本思想是找到两个时间序列之间的最佳匹配路径,使得路径上的数据点具有最小的累积距离度量,目标是找到一条从矩阵 $M(0,0)$ 到矩阵 $M(m,n)$ 的最小路径,采用递归的计算公式为

$$D(i,j) = Dist(i,j) + \min[D(i-1,j), D(i,j-1), D(i-1,j-1)] \tag{1}$$




图3 电压序列辨异矩阵
Fig. 3 Voltage sequence discrimination matrix

迭代后会得到路径长度,长度越大表明两电压时间序列之间的距离越远,意味着两者差异越大。

其次,根据所计算出来的路径确定各相与其他两相的差异情况,并加以排序,并依据排序顺序对三相数据进行分配权重,给最大差异的相别数据赋予最大权重,其余两相赋予相同权重。

最后,将分配的权重与对应相别数据进行乘积,并将乘积后的波形数据叠加起来,得到变异加权波形数据,该数据与中性点监测到的数据存在区别,由于增加了特殊相的权重,因此合成波形比零序信号更能凸显故障数据的特征,即使在不接地系统监测到的零序信号较为微弱的情况下,也能将特征进一步凸显。

辨异加权合成后得到向量的组合 $\{X' | X'_1(t), X'_2(t), \dots, X'_n(t)\}$ 。

数据预处理的第3个环节是降噪重构。考虑到电气量监测信息可能存在噪声,这一步采用自适

应噪声完备集合经验模态分解(CEEMDAN)方法完成,CEEMDAN改进了EMD中的模态混叠现象以及EEMD算法中的残留噪声问题,增强了抗噪性,有利于滤除掉干扰和噪声信息,有效保留电压暂降源信号。其思路是先对监测样本 $X'(t)$ 添加一定信噪比的白噪声序列 $\omega(t)$,即 $X'_i(t) = X'(t) + a\omega_i(t)$ ($i = 1, 2, \dots, n$),然后再利用EMD循环进行分解,在每次得到残差序列基础上,再次增加白噪声生成新序列后继续用EMD分解,直至 n 次EMD分解完成或者残差信号无法继续分解,得到各模态分量,每个模态分量序列都可以表征出暂降源造成的电压波动特点,最后,再将各模态分量 IMF_{id} 分别叠加组合为样本矩阵 $\{X | X_1(t), X_2(t), \dots, X_n(t)\}$,经过上述处理后的时间序列样本具有更好的抗噪性。

2.2 BiLSTM

BiLSTM由两个LSTM相向构成,在每个时间步运行两个独立的LSTM,一个从序列的开始到结束(前向LSTM),另一个从序列的结束到开始(后向LSTM),这样就允许输入的数据信号在网络中双向循环传递,两个LSTM的输出结合在一起,能够同时考虑前后数据中的关联信息。

电压暂降监测构建的时间序列样本之间具有非常显著的时序性,暂降信息往往由前面若干输入和后面若干输入共同决定,为了获取到整个输入序列的关键特征信息,采用BiLSTM网络可以利用前向LSTM层、反向LSTM层同时保存“上行”和“下行”的双向电压暂降信息。具体结构如图4所示。样本序列以正序输入到正向LSTM网络,而反向LSTM网络则以相反顺序输入。

BiLSTM网络对序列特征提取公式为

$$\begin{cases} \vec{h}_t = f(w_1 \times X_t + w_2 \times \vec{h}_{t-1}) \\ \overleftarrow{h}_t = f(w_3 \times X_t + w_5 \times \overleftarrow{h}_{t+1}) \\ y_t = g(w_4 \times \vec{h}_t + w_6 \times \overleftarrow{h}_t) \end{cases} \quad (2)$$




图4 BiLSTM结构
Fig. 4 Structure of BiLSTM

式中: $\vec{h}_t, \vec{h}_t$ 表示 t 时刻前向、后向 LSTM 层状态; $\vec{h}_{t-1}, \vec{h}_t, \vec{h}_{t+1}$ 分别为预处理后的时间序列向量, 输入到 BiLSTM 的 $t-1$ 时刻的前向层、 t 时刻前向层和 $t+1$ 时刻的后向层; y_t 为 BiLSTM 的输出结果, 送到分类器中, 正向 LSTM 网络和反向 LSTM 网络分别执行输入序列前后关系特征提取, 最后通过对正向和反向输出结果的输出结果进行积分计算, 增强各类故障的主体特征信息, 从而有效捕获大电机启动、励磁涌流、单相接地、两相短路接地和相间短路等暂降源信息。相比于单向 LSTM, BiLSTM 能够同时考虑到序列的前后时刻的数据关联信息, 能够捕捉信号序列的双向依赖关系, 提升了全局序列的特征性能。

BiLSTM 模块对电源暂降事件数据提取特征后, 将特征矩阵输出至全连接层。

2.3 1D-CNN

利用 CNN 提取特征时, 因为是对时间序列进行操作, 所以可以采用滑动卷积核的形式进行特征提取, 为了能够充分地提取特征, 构建 1D-CNN 块来进行操作, 1D-CNN 块结构见图 5。




图5 1D-CNN块结构
Fig. 5 Structure of 1D-CNN

图 5 所示的 1D-CNN 块由两个卷积层和两个池化层构成, 其中每个卷积层都由 ReLU 激活函数激活, 卷积层的滑动卷积核尺寸不同, 根据输入样本的数量可以调整。

1D-CNN 块包含卷积层、池化层和全连接层, CNN 接收经过预处理后的样本后, 为了充分挖掘故障特征信息, 可以设置多个卷积层, 每一层均进行特征提取, 后续层级在前一层网路输出特征中进一步提取得到更为复杂特征。当输入层接收特征数据 $H_c = \{h_1, h_2, \dots, h_n\}$ 后, 各个卷积层进行如下操作

$$\alpha^k = g(W^k h_i + b^k) \quad (3)$$

式中: $g(\cdot)$ 代表 sigmoid 激活函数; $k, k-1$ 代表第 k 个卷积层和其之前的层级; α^k 为第 k 个层级提取的特征; W^k, b^k 分别为第 k 个层的权重向量(卷积核)和偏置向量, h_i 则为第 k 个层级所输入的特征, 当 $k=1$ 时则为经过预处理后的特征矩阵。适当增加卷积层级有助于提取各参数受影响而呈现的本质

特征。卷积层之间是池化层, 第 1 个池化层采用最大池化的方式, 可以提取局部区域内最突出的特征, 但同时也保留了所有特征; 第 2 个池化层采用平均池方式, 计算学习特征的平均激活函数, 以获得整个特征图的全局表示, 两个池化层可以分别捕获数据的局部和全局表示, 增强 1D-CNN 块泛化能力和计算效率。

CNN 池化层主要对卷积层输出的高维数据特征进行降采样, 其中最大池化公式为

$$\begin{cases} \alpha^k = \Psi_{\max}(\alpha^{k-1}) \\ \alpha^k = \sum_{k=1}^n \alpha^{k-1} / |R_n| \end{cases} \quad (4)$$

1D-CNN 块处理后将输出数据特征, 特征输入全连接层后, 全连接层将联合 BiLSTM 模块输入的特征值, 对两个模块输出的特征向量进行融合, 方法是通过权重计算特征函数将所有的特征融合在一起, 并将故障特征映射到一维固定长度的特征向量中, 公式为

$$\alpha^k = g(W^k \alpha^{k-1} + b^k) \quad (5)$$

选取合适的卷积核可以提取故障信息的关键特征, 最终将输出序列 $H_c = \{h_1, h_2, \dots, h_n\}$ 输出至输出层, 实现系统暂降源类型诊断, 输出层选择 Softmax 分类器, 将输出不同类型的暂降辨识概率。

2.4 基于 BiLSTM-CNN 暂降源辨识流程

基于 BiLSTM-CNN 暂降源辨识流程如下图 6 所示, 图 6(a) 为暂降源辨识模型工作流程, 图 6(b) 为 CNN-BiLSTM 模型构成及工作流程,

经过 CEEMDAN 分解后, 得到图 6(b) 中样本矩阵 $X_1, X_2, \dots, X_n$, 可以对 BiLSTM-CNN 模型训练和测试。

基于 BiLSTM-CNN 暂降源辨识模型在数据特征提取时有两个分支, 其中的第 1 个分支是由 BiLSTM 实现, 由两个 LSTM 层组成, 通过 LSTM 顺序和逆序计算测量数据中的所有样本而获得的时间相关性特征, 每个 LSTM 根据样本数量构建相应数量的循环单元, 并根据其顺序计算样本。每个循环单元接受前一个循环单元的内部状态和隐藏层状态, 以及当前样本的信息, 并选择性地添加和忘记信息以控制信息累积率。在此两个层均设置 100 个隐藏层节点, 选择最后一个循环单元的隐藏层状态作为输出, 其中包括所有先前循环单元和样本的信息。用于挖掘样本序列之间的时间特征, 这一分支允许保存信息以供后续融合使用, 从而防止信号处理过程中早期信号衰落的问题。




图6 基于BiLSTM-CNN暂降源辨识流程
Fig. 6 Identification process for voltage sag source based on BiL STM-CNN

第2个分支是由1D-CNN实现,由5个1D-CNN块组成,含有卷积层、池化层,用于提取样本序列的空间特征。

BiLSTM和1D-CNN算法的并行连接实现了时空特征的并行提取,确保两种架构在捕获重要的空间和时间信息方面都有自己的路径。在不相互交叉或影响的情况下,他们同时提取特征,从而避免了串行架构中可能出现的信息丢失。这些特征在级联后传递给完全连接层后进行融合。

BiLSTM和1D-CNN的两个分支都分别设置平坦层(Flatten),用于重塑从Bi-LSTM和1D-CNN获得的输出特征,然后将其进一步传递全连接层,将从CNN和Bi-LSTM获得的时空特征连接起来,形成一个完整的序列。最后,将这些融合特征输入到具有单神经元和sigmoid激活函数的全连接层中,将神经元输出转换为0到1之间的有界范围。

最后,利用分类器对暂降源加以分类辨识。

2.5 评价指标

针对电压暂降源辨识结果,采用精确率(Precision)、查全率(Recall)、 F_1 值($F_{1-score}$)和查准率(Accuracy)进行评价,具体公式为

$$\begin{cases} \text{Precision} = \frac{\text{TPR}}{\text{TPR} + \text{FPR}} \\ F_{1-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \\ \text{Recall} = \frac{\text{TPR}}{\text{TPR} + \text{FN}} \\ \text{Accuracy} = \frac{\text{TPR} + \text{TN}}{\text{TPR} + \text{TN} + \text{FPR} + \text{FN}} \end{cases} \quad (6)$$

式中:TPR, FPR 分别为真正类和假正类;TN, FN 分别为真反类和假反类。其中,精确率用于评估故障分类占待分类故障样本数量的百分比,查准率表征正确分类的样本数与总样本数的百分比,查全率用于评估故障类被正确预测占该类别故障样本数量的百分比。 $F_{1-score}$ 值用于评估模型的质量,当 $F_{1-score}$ 值越大则能说明模型性能越好。

3 算例分析

IEEE 33节点测试系统接线图见图7。IEEE 33节点系统基准容量为100 MVA,基准电压为12.66 kV,节点和支路编号均已在图中给出,虚线部分表示装设联络开关的线路。系统参数详见文献[16]。




图7 IEEE 33节点测试系统接线图
Fig. 7 Wiring diagram of IEEE 33-node test system

图中,短路故障设置在支路17-18中部。利用Matlab/Simulink搭建仿真模型,分别模拟各种工况下的电压暂降事件,经过大量仿真实验后,得到暂降监测数据样本见表1。

表1 故障参数设置
Table 1 Setting of fault parameter

暂降类型	工况描述	样本数量
大电机启动	合闸相角位于0°~180°之间	5 600
变压器	同期和非同期, 合闸相角位于	5 400
空载投切	0°~180°之间	
单相接地	不同故障相角、位置过渡电阻 单相接地故障	7 200
两相短路	不同故障相角、位置过渡电阻 单相接地故障	7 200
两相短路接地	不同故障相角、位置过渡电阻 单相接地故障	7 200
三相短路	不同故障相角、位置过渡电阻 单相接地故障	7 200

暂降事件中部分电压的 RMS 波形数据见图 8。

将电压暂降数据进行辨异加权求和, 并利用 CEEMDAN 进行预处理, 构成样本集合, 训练集和测试集的划分采用 5 折交叉验证法。

将 BiLSTM 模块的隐藏单元设置 100 个, 4 个全连接层, 配置 1D-CNN 块输入通道数为 6, 设置两个卷积层, 第 1 个卷积核设置为大小为 3, 6 个滤波器, 滑动步幅为 1; 第 2 层的卷积核为 32 滤波器和步幅与第一层相同。每层激活函数均选择 ReLU; 分类器选择 Softmax。辨识过程如图 9, 为做对比, CEEMDAN-CNN 和 CEEMDAN-BiLSTN 的辨识过程也一并给出。




图8 部分电压暂降源波形
Fig. 8 Waveform of partial voltage sag source




图9 不同方法辨识过程
Fig. 9 Identification process of different methods

不同电压暂降源类型的辨识结果见图 10,为做对比,将 CEEMDAN-CNN 和 CEEMDAN-BiLSTN 的辨识结果也一并给出。




图 10 不同方法电压暂降辨识结果
Fig. 10 Identification results of voltage sag by different methods

图 10 中,TPR、FNR 分别为真正类和假正,由图 10 可见,论文方法比 CEEMDAN-CNN 和 CEEMDAN-BiLSTM 的准确率分别高出约 5%和 7%。此外,论文方法、CEEMDAN-CNN 和 CEEMDAN-BiLSTM 辨识结果的 $F_{1-score}$ 分别为 0.971、0.927 和 0.905。结

合图 9 和图 10,本文所提方法在各类暂降源辨识的综合准确率方面均优于其他两种方法,尤其是对大电机启动和变压器空载合闸暂降事件的准确率可以达到 100%,这一点对电网供需双方的责任划分具有重要的参考意义。

为验证所提方法的鲁棒性和抗噪能力,每个样本中分别加入非高斯噪声,得到信噪比(SNR)分别为 80 dB、60 dB 和 40 dB 的样本。利用辨识模型,仍采用 5 折交叉验证法,得到结果见表 2,为了对比,将利用 EMD 对数据预处理处理后再辨识的结果也一并给出。

表 2 加入噪声后暂降源辨识准确度
Table 2 Identification accuracy of voltage sag source after addition of noise

信噪比	%			
	CEEMDAN-BiLSTM - CNN	EMD-BiLSTM - CNN	CNN	BiLSTM/
80 dB	98.1	93.9	93.1	91.4
60 dB	96.2	92.2	91.2	90.1
40 dB	95.6	89.7	90.3	89.9

表 2 可见,采用 CEEMDAN 对监测数据进行抗噪处理后,即便增加了非高斯噪声含量,所提方法也能够将辨识准确率保持在 95% 以上,同样的预处理方法也用于 CNN 和 BiLSTM 时,两种算法的辨识准确率虽然也会受到噪声的影响,但也能保持在 90% 左右,表明所采用的 CEEMDAN 预处理方法可以保证样本的抗噪性。此外,采用 EMD 预处理后,再利用 BiLSTM-CNN 进行辨识发现,准确率受信噪比的影响比采用 CEEMDAN 预处理方法要更明显。综合来看,将 CEEMDAN 数据预处理的方法与 BiLSTM-CNN 相结合,能够对噪声干扰下的信号样本保持较高的辨识率,与单独采用 CNN 和 BiLSTM 相比,具有更强的抗噪性,证明了所提方法有着明显的优势。

4 结语

针对现有暂降源辨识准确率偏低的问题,提出一种新的暂降源辨识方法,取得了下述结论:

1)所提出的 CEEMDAN 分解重构的数据预处理方法具有良好的信号抗噪能力,当故障信号的信噪比下降时,对信号特征的表达以及电压暂降源类别的辨识影响不大。

2)将 BiLSTM 与 CNN 相结合,能够较为精确地区分供、需量测暂降源,结合数据预处理方法,加入不同信噪比的噪声信号后,所提辨识方法仍能保持较高的准确率,具有较高的工程应用价值。

文中考虑了不同工况下的暂降源事件,但均只是单一暂降源事件,若同时存在两种暂降事件,母线电压监测数据将存在较大随机特征,所提方法辨识准确率有可能会受到影响;此外,所提方法中对短路故障的分类均是针对的对称网络,没有考虑不对称网络,当系统不对称时,会影响电压暂降信号样本的波形与特征,也会对辨识准确率造成影响。上述情况如果考虑将元关系网纳入含有不确定信息的辨识模型,则有望提高对各种形态的暂降源辨识准确率,这也将是下一步研究的工作。

参考文献

- [1] 邵文权,徐嘉鹏,卫晓辉,等. 采用PI+重复控制策略的配电网有源电流消弧方案[J]. 西安工程大学学报, 2022,36(5):87-94.
SHAO Wenquan, XU Jiapeng, WEI Xiaohui, et al. An active current arc suppression scheme using PI and repetitive control strategy for distribution networks[J]. Journal of Xi'an Polytechnic University, 2022,36(5):87-94.
- [2] 车彬,张泽龙,杨燕. 考虑V2G储能特性与负荷需求响应的主动配电网低碳鲁棒调度[J]. 电网与清洁能源, 2024,40(1):29-39.
CHE Bin, ZHANG Zelong, YANG Yan. Research on the low-carbon robust dispatch of active distribution networks considering storage characteristics of V2G and load demand response[J]. Power System and Clean Energy, 2024, 40(1):29-39.
- [3] 周燕,刘卫民,陈帆,等. 不同光伏渗透率下考虑需求响应的配电网储能双层规划[J]. 高压电器, 2024,60(10):64-77.
ZHOU Yan, LIU Weimin, CHEN Fan, et al. Bi-level planning of energy storage in distribution network considering demand response under different penetration rates of photovoltaic[J]. High Voltage Apparatus, 2024,60(10):64-77.
- [4] 李宁,胡佳乐,詹晓暄,等. 故障关联矩阵下弹性配电网可靠性评估[J]. 西安工程大学学报, 2024,38(2):1-8.
LI Ning, HU Jiale, ZHAN Xiaoxuan, et al. Reliability assessment of elastic distribution network based on fault correlation matrix[J]. Journal of Xi'an Polytechnic University, 2024,38(2):1-8.
- [5] 黄代雄,汪志军,袁俑斌,等. 考虑多源协同的主动配电网故障恢复策略[J]. 高压电器, 2024,60(2):210-215.
HUANG Daixiong, WANG Zhijun, YUAN Yongbin, et al. Fault recovery strategy considering multi-source collaborative active distribution network[J]. High Voltage Apparatus, 2024,60(2):210-215.
- [6] 张艳丽,王争冕,薛成,等. 考虑新能源接入的配电网两阶段有功无功协调降损方法[J]. 电网与清洁能源, 2023,39(12):121-129.
ZHANG Yanli, WANG Zhengmian, XUE Cheng, et al. A two-stage active and reactive power coordinated loss reduction method for distribution networks integrated with new energy[J]. Power System and Clean Energy, 2023,39(12):121-129.
- [7] 李建华,朱敏捷,周灵刚. 分布式光伏接入下配电网输出电压振荡抑制研究[J]. 电网与清洁能源, 2024,40(1):156-162.
LI Jianhua, ZHU Minjie, ZHOU Linggang. Research on suppression of output voltage oscillation in distribution network with distributed photovoltaic access[J]. Power System and Clean Energy, 2024,40(1):156-162.
- [8] 储佳伟,袁晓冬,陈兵,等. 结合小波分析和改进型DTW距离的配电网电压暂降源辨识方法[J]. 电网技术, 2018,42(2):637-643.
CHU Jiawei, YUAN Xiaodong, CHEN Bing, et al. A method for distribution network voltage sag source identification combining wavelet analysis and modified DTW distance[J]. Power System Technology, 2018,42(2):637-643.
- [9] 汪颖,敬志凤. 基于小波变换样本熵和深度核极限学习机的电压暂降源辨识[J]. 西安理工大学学报, 2022,38(1):142-150.
WANG Ying, JING Zhifeng. Identification of voltage sag source based on wavelet transform sample entropy and deep kernel extreme learning machine[J]. Journal of Xi'an University of Technology, 2022,38(1):142-150.
- [10] 付华,范国霞. 煤矿配电网电压暂降源辨识模型[J]. 电源学报, 2019,17(1):159-164.
FU Hua, FAN Guoxia. Voltage sag source identification model for distribution network of coal mine[J]. Journal of Power Supply, 2019,17(1):159-164.
- [11] 彭宇文,李瑞,尚筱雅,等. 基于EMD和PSO-KELM的电压暂降源辨识方法[J]. 黑龙江电力, 2023,45(2):102-111.
PENG Yuwen, LI Rui, SHANG Xiaoya, et al. Identification and classification of voltage sag source based on EMD and PSO-KELM[J]. Heilongjiang Electric Power, 2023,45(2):102-111.
- [12] 陈晓华,吴杰康,陈盛语,等. 基于EMD和IABC-SVM算法的复合电压暂降源辨识方法[J]. 广东电力, 2022,35(2):11-18.
CHEN Xiaohua, WU Jiekang, CHEN Shengyu, et al. Compound voltage sag source identification method based on EMD and IABC-SVM algorithm[J]. Guangdong Electric Power, 2022,35(2):11-18.
- [13] 邱海峰,陈兵,袁晓冬,等. 基于动态时间弯曲距离的电压暂降源辨识方法[J]. 电力系统保护与控制, 2017,45(13):7-13.
QIU Haifeng, CHEN Bing, YUAN Xiaodong, et al. Identification of voltage sag source based on dynamic time warping distance[J]. Power System Protection and Control, 2017,45(13):7-13.

- cation of voltage sag sources based on DTW[J]. Power System Protection and Control, 2017, 45(13): 7-13.
- [14] 李胜文, 张世锋, 张敏, 等. 电压暂降与谐波谐振监测点统一优化配置方法[J]. 电测与仪表, 2023, 60(5): 145-153.
- LI Shengwen, ZHANG Shifeng, ZHANG Min, et al. Unified optimal configuration method of voltage sag and harmonic resonance monitoring points[J]. Electrical Measurement & Instrumentation, 2023, 60(5): 145-153.
- [15] 付华, 于田. 电压暂降源自适应S变换辨识模型[J]. 电工电能新技术, 2019, 38(11): 17-23.
- FU Hua, YU Tian. Identification model of voltage sag based on adaptive S-transform[J]. Advanced Technology of Electrical Engineering and Energy, 2019, 38(11): 17-23.
- [16] 李丹奇, 梅飞, 张宸宇, 等. 基于深度置信网络的电压暂降特征提取及源辨识方法[J]. 电力系统自动化, 2020, 44(4): 150-158.
- LI Danqi, MEI Fei, ZHANG Chenyu, et al. Deep belief network based method for feature extraction and source identification of voltage sag[J]. Automation of Electric Power Systems, 2020, 44(4): 150-158.
- [17] 李滨, 汪颖, 肖先勇. 电压暂降扰动源电压空间矢量辨识法[J]. 四川电力技术, 2012, 35(3): 14-19.
- LI Bin, WANG Ying, XIAO Xianyong. Voltage sag disturbance source voltage space vector identification method[J]. Sichuan Electric Power Technology, 2012, 35(3): 14-19.
- [18] 林志超, 罗步升, 宋志坚. 基于非参数估计的电压暂降下敏感设备故障率评估[J]. 电测与仪表, 2023, 60(5): 86-95.
- LIN Zhichao, LUO Busheng, SONG Zhijian. Fault rate assessment of voltage sag sensitive equipment based on non-parametric assessment[J]. Electrical Measurement & Instrumentation, 2023, 60(5): 86-95.
- [19] 王刚, 李志潭, 杨金成, 等. 电网频率控制的新型三电平光储一体机[J]. 西安工程大学学报, 2023, 37(2): 63-70.
- WANG Gang, LI Zhitan, YANG Jincheng, et al. A novel three-level optical storage machine based on grid frequency control[J]. Journal of Xi'an Polytechnic University, 2023, 37(2): 63-70.
- [20] 马莉, 娄景辉, 董鹏远, 等. 基于 μ PMU和二分搜索法的辐射状配电网电压暂降源定位[J]. 电力工程技术, 2023, 42(5): 177-184.
- MA Li, LOU Jinghui, DONG Pengyuan, et al. Location of voltage sag source in radial distribution network based on μ PMU and binary search method[J]. Electric Power Engineering Technology, 2023, 42(5): 177-184.
- [21] 王斌, 周亮. 输电线路增容改造对三相电压不平衡度的影响研究[J]. 电网与清洁能源, 2023, 39(9): 24-31.
- WANG Bin, ZHOU Liang. A study on the influence of capacity expansion on three-phase voltage unbalance degree of transmission lines [J]. Power System and Clean Energy, 2023, 39(9): 24-31.
- [22] RAHMAN Y A, MANJANG S, YUSRAN, et al. Evaluating the effect placement capacitor and distributed photovoltaic generation for power system losses minimization in radial distribution system[C]//Engineering International Conference (EIC2017): Proceedings of the 6th International Conference on Education, Concept, and Application of Green Technology. 2018.
- [23] WANG Qian, LIANG Xue, QIN Sichen. Research on power quality disturbance analysis and identification based on LSTM[J]. Energy Reports, 2022, 8(8): 709-718.
- [24] TUROVI R, DRAGAN D, STANISAVLJEVI A, et al. Training an LSTM voltage sags classifier on a synthetic dataset[C]//2021 21st International Symposium on Power Electronics (Ee). [S. l.]: IEEE, 2021: 1-6.
- [25] 苏婷婷, 彭贺翔, 王灿, 等. 基于BiLSTM的电压暂降原因辨识方法研究[J]. 湖南电力, 2022, 42(1): 32-37.
- SU Tingting, PENG Hexiang, WANG Can, et al. Research on identification method of voltage sag cause based on BiLSTM[J]. Hunan Electric Power, 2022, 42(1): 32-37.
- [26] 苏婷婷. 配电网电压暂降在线监测及原因辨识方法研究[D]. 成都: 西南交通大学, 2022.
- [27] ZHENG Z, QI L, WANG H, et al. Recognition method of voltage sag causes based on Bimstm[J]. IEEE Transactions on Electrical and Electronic Engineering, 2019, 15(3): 418-425.
- [28] WANG Hong, QI Linhai, MA Yongshuo, et al. Method of voltage sag causes based on bidirectional LSTM and attention mechanism[J]. Journal of Electrical Engineering & Technology, 2020, 15(3): 1115-1125.
- [29] GARCIA C I, GRASSO F, LUCHETTA A, et al. A comparison of power quality disturbance detection and classification methods using CNN, LSTM and CNN-LSTM[J]. Applied Sciences, 2020, 10(19): 6755-6776.
- [30] 张峰, 陈雷. 基于S变换和深度学习的多特征融合的电压暂降源识别方法[J]. 国外电子测量技术, 2024, 43(8): 26-36.
- ZHANG Feng, CHEN Lei. Multi-feature fusion based on S-transform and deep learning for voltage transient source identification[J]. Foreign Electronic Measurement Technology, 2024, 43(8): 26-36.

作者简介:

何龙(1988—),男,工程师,主要从事电气设备故障诊断与在线监测。E-mail: helong69@126.com。

刘荣(1989—),女,工程师,主要从事电气设备故障诊断与在线监测。E-mail: helong69@126.com。

朱咏明(1974—),男,工程师,主要从事管理工作。