



DOI:10.12404/j.issn.1671-1815.2309761

引用格式:郑超文,吴浩,吴川兰,等.基于Res-BiLSTM的柔性直流配电网故障选极[J].科学技术与工程,2025,25(5):1954-1962.

Zheng Chaowen, Wu Hao, Wu Chuanlan, et al. Fault pole selection for flexible DC distribution grids based on Res-BiLSTM[J]. Science Technology and Engineering, 2025, 25(5): 1954-1962.

基于 Res-BiLSTM 的柔性直流配电网故障选极

郑超文¹, 吴浩^{1,2*}, 吴川兰¹, 唐丹¹, 钟长华¹

(1. 四川轻化工大学自动化与信息工程学院, 自贡 643000, 2. 人工智能四川省重点实验室, 自贡 643000)

摘要 针对传统的选极方法存在着抗噪、抗高阻能力弱以及阈值整定复杂等问题,提出一种基于 Res-BiLSTM 网络的柔性直流配电网故障选极方法。首先,对原始故障信号进行完全自适应噪声模态分解,再采用相关系数和香农熵进行重构得到重构信号;其次,搭建 Res-BiLSTM 网络模型进行选极,为提高网络精度与收敛速度,在分裂注意力网络中引入通道注意力模块,并使用卷积双向长短期记忆网络与改进分裂注意力网络同时提取重构信号特征,使用注意力特征融合模块融合提取到的特征,并对融合特征进行分类;最后,利用 PSCAD/EMTDC 搭建模型并验证所提方法。仿真结果表明所提选极方法准确性高,抗干扰能力强,不受故障距离影响。

关键词 柔性直流配电网;故障选极;完全自适应噪声模态分解;神经网络

中图分类号 TM721; **文献标志码** A

Fault Pole Selection for Flexible DC Distribution Grids Based on Res-BiLSTM

ZHENG Chao-wen¹, WU Hao^{1,2*}, WU Chuan-lan¹, TANG Dan¹, ZHONG Chang-hua¹

(1. School of Automation and Information Engineering, Sichuan University of Science & Engineering, Zigong 643000, China;

2. Sichuan Key Laboratory of Artificial Intelligence, Zigong 643000, China)

[Abstract] Aiming at the problems of anti-noise, anti-high resistance and complex threshold setting of traditional pole selection methods, a fault selection method of flexible DC distribution line based on Res-BiLSTM network was proposed. Firstly, the original fault signal was subjected to complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN), and then the reconstructed signal was obtained by using the correlation coefficient and Shannon entropy for reconstruction. Secondly, the Res-BiLSTM network model was constructed for the pole selection. In order to improve the network accuracy and the convergence speed, the channel attention module was introduced into the split-attention network. The reconstructed signal features were extracted using the convolutional bidirectional long short-term memory and the improved split-attention network at the same time. The extracted features were fused using the attention feature fusion module, and the fused features are classified. Finally, PSCAD/EMTDC was employed to construct the model and to verify the proposed methodology. The simulation results show that the proposed pole selection method is highly accurate, anti-interference, and independent of fault distance.

[Keywords] flexible DC distribution network; fault pole selection; complete ensemble empirical mode decomposition with adaptive noise; neural network

近年来,随着电力电子技术和直流器件的发展,电力系统的供电和负荷产生了极大的变化,分布式电源在电力供能中所占比例也逐步增加^[1-2],柔性直流配电网具备供电可靠性好、电能质量高、控制灵活、易于分布式电源的接入、线路损耗低等优势,逐渐成为国内外研究重点^[3-5]。然而,柔性直流配电网是一个低阻尼、弱惯性系统,其故障发展

快、影响范围广^[6-7],但目前针对直流配电系统的特点的保护有所欠缺,没能形成完整成熟的柔性直流配电网保护体系。因此,对柔性直流配电网故障的准确识别是当前研究的一个重点。

现有的检测方法主要分为两大类,一种是利用故障暂态量进行分析诊断的传统算法,另一种是智能算法。传统算法中常见的有电气量保护、测距式保护、

收稿日期:2023-12-11 修订日期:2024-11-15

基金项目:四川省科技厅项目(2022YFS0518,2022ZHCG0035);人工智能四川省重点实验室项目(2023RYY06,2022RZY01);企业信息化与物联网测控技术四川省高校重点实验室项目(2022WYY04)

第一作者:郑超文(2001—),女,汉族,四川绵阳人,硕士研究生。研究方向:柔性直流配电网故障诊断。E-mail:1320680121@qq.com。

*通信作者:吴浩(1980—),男,汉族,四川南充人,博士,教授。研究方向:电力系统保护与智能控制。E-mail:11305076@qq.com。

纵联保护、行波保护以及边界保护这几种方法,传统算法的思路大多借鉴柔性直流输电的保护思路^[8-9],但由于柔性直流配电网的拓扑结构复杂,故障特性由多种因素造成且故障特征变化迅速、参数难以识别,导致现有针对柔性直流配电系统的传统保护方法均有所欠缺:电气量幅值保护的选择性不足,微分保护耐受能力不足,距离保护的速动性不足,而基于双端信息的纵联保护存在信息时延的问题,边界保护易受配电网参数、边界设置等因素的影响,且柔性直流配电系统满足不了行波保护所需的高采样频率和行波波头识别率^[10-11]。文献[12]提出一种基于线路两端故障电流拟合曲线斜率的纵联保护方案,该方案算法简单,数据窗短且对数据精度的要求不高,通信延时和同步误差的影响小。文献[13]提出一种结合过流保护、变流保护、瞬时差动电流保护的方案,具备较好的选择性、速动性,但没有针对方案的耐受能力提出研究。

智能算法无需阈值整定,相较于传统方法,智能算法利用算法模型离线训练的识别精度和速度都更好,具备良好的可靠性,且较于传统算法的耐受能力要更好。文献[14]提出了一种柔性直流配电网的高阻故障识别方案,高阻识别上效果好,但没有对所提方法的抗噪性能进行研究。文献[15]提出一种基于门控循环单元深度学习模型的保护方案,具有一定的抗高阻能力,但所提方法的抗噪效果仅到 20 dB。文献[16]提出了一种基于颜色关系分类器的高阻抗故障识别方法,能够在较少样本下实现对各种工况的识别,但低阻状况识别率不足。智能算法作为柔性直流配电网故障诊断的一种方法,针对诊断中的过渡电阻和噪声的干扰情况,相关文献的效果不佳。

针对上述智能故障诊断方法中存在的问题,现提出一种基于完全自适应噪声模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)重构信号和 Res-BiLSTM 网络的柔性直流配电系统故障选极方法。该方案首先对采集到的故障电流进行 CEEMDAN 分解,利用相关系数和香农熵分别选取波形最相近和幅值最接近的本征模态分量来进行信号重构,以此降低模态混叠的影响;然后将归一化后的重构信号输入 Res-BiLSTM 网络中进行测试与训练。网络改进如下:在分裂注意力网络(split-attention network, ResNeSt)增加了通道注意力模块(channel attention module, CAM),加强了 ResNeSt 网络的全局特征提取,得到的故障信号空间特征的效果更好;其次,为更好地提取故障信号的时序特征,引入卷积双向长短期记

忆网络(bidirectional long short-term memory, BiLSTM)网络,并引入注意力特征融合模块(attentional feature fusion, AFF)对故障信号的空间特征与时序特征进行融合,提高网络的精确度;最后,利用 Adam 优化器代替随机梯度下降方式来更新网络权重,提高网络的鲁棒性。通过仿真实验验证本文算法的抗噪能力和耐过渡电阻能力,且在一定的数据丢失情况下仍能较好地实现选极。

1 柔性直流配电网的拓扑结构分析

将 MMC-VSC 四端混合中压柔性直流配电系统作为研究对象,主要由电源、换流站、直流断路器及直流线路等构成,其拓扑结构如图 1 所示。S1 和 S2 是交流电源,经 MMC 换流站与直流线路相连,风力发电和直流负荷经 VSC 换流站与直流线路相连;L1~L4 是直流线路,均为电缆线路;F1~F4 是不同线路故障;变压器 T1、T2 的绕组接地方式为 Y/Δ 接地; I_{p1} 为故障原始信号,是由换流站 MMC1 流向直流线路的正极电流信号,是直流线路 L1 上的电流信号。

柔性直流配电网的保护包括换流站及换流阀保护、交流侧保护以及直流侧保护,主要针对直流线路故障进行分析。直流侧故障主要有单极接地故障、双极短路故障以及断线故障 3 种故障类型,其中,单极接地故障的发生频率最高,但由于系统在单极接地故障发生后的短时间内仍可正常运行,其故障特性与采用的换流器拓扑结构有关,而双极短路故障时不同拓扑结构的换流器下故障特性相似,因此在双极短路故障发生后,故障电流极短时间内就迅速上升,器件极易损坏,危害更大。

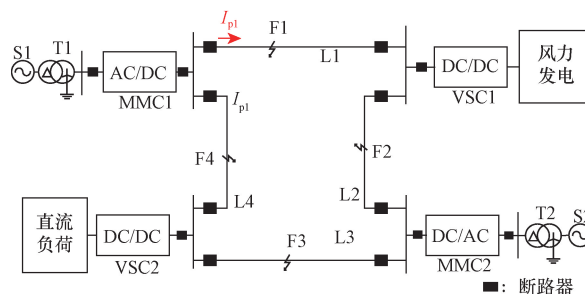


图 1 柔性直流配电网网络拓扑结构

Fig. 1 Flexible DC distribution network topology

2 基于 Res-BiLSTM 网络的选极方法

2.1 CEEMDAN 信号重构方法

CEEMDAN 是在集合经验模态分解(ensemble empirical mode decomposition, EEMD)基础上进行了一定改进的一种自适应数据分解方法,分解得到一系列反映非平稳信号局部特性的本征模态分量(intrin-

sis mode function, IMF), 有效解决了 EMD 和 EEMD 存在的模态混叠和残余噪声过高等问题^[17-18]。

CEEMDAN 的具体步骤如下: 将构建的自适应高斯白噪声序列 $\varepsilon_k \omega^i(t)$ 添加到原始信号 $h(t)$ 中, 形成多个试验信号; 然后对每个试验信号进行 EMD 分解并取均值, 得到一组平均 IMF 及其残余分量 $r(t)$; 最后对平均 IMF 进行再次 EMD 分解并进行平均, 得到最终的分解结果, 如图 2 所示(以 F4 处负极接地故障为例)。

CEEMDAN 的 k 阶分量为

$$IMF_k(t) = \frac{1}{N} \sum_{i=1}^N E_{k-1} \{ r_{k-1}(t) + \varepsilon_k E_k[\omega^i(t)] \} \quad (1)$$

$$r_k(t) = r_{k-1}(t) - IMF_k(t) \quad (2)$$

式中: ε_k 为 k 阶噪声系数; E_k 为 EMD 分解后的第 k 个固有模态; N 为产生的固有模态总数。

由图 2 可知, 前 3 个分量的噪声含量大, 不宜选用其进行数据重构, 因此在除去前 3 个的 IMF 分量中选取信号进行重构。常用相关系数法对 IMF 分量进行筛选, 筛选出的 IMF 分量与原信号波形相似但幅值可能相差过大, 因此引入香农熵与相关系数一起来进行筛选。

相关系数 R 计算公式为

$$R = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (3)$$

式(3)中: \bar{X} 、 \bar{Y} 分别为 X 、 Y 的平均值; n 为序列 X 的元素总数。




图 2 F4 处负极接地故障的 CEEMDAN 分解图
Fig. 2 CEEMDAN decomposition of negative ground fault at F4

若离散变量 $X = \{x_1, x_2, \dots, x_n\}$ 的概率分布为 $P = \{p_1, p_2, \dots, p_n\}$, 则 X 的香农熵为

$$H(X) = - \sum_{i=1}^n p_i \ln p_i \quad (4)$$

R 越大, 则 IMF 与原信号波形越相似; H 越小, 信号的无序性越小, 时频分布越集中; 选取相关系数最大的 IMF 与香农熵值越小的 IMF 作为重构信号的分量, 将选取的两个 IMF 与分解得到的残余分量相加得到最终的重构信号。以 F4 处负极接地故障为例, 图 3(a) 所示原始信号经 CEEMDAN 分解为 10 个 IMF, 在去除前 3 个含噪高的分量后, 计算除残余分量外的剩下 6 个 IMF 的相关系数与香农熵值, 计算结果如表 1 所示, 其中 IMF9 的相关系数最大, IMF8 的香农熵值最小, 因此选取 IMF8 和 IMF9 与残余分量 IMF10 相加得到图 3(b) 所示的重构信号。

表 1 IMF 选取评价值
Table 1 IMF selection of valuation values

方法	IMF4	IMF5	IMF6	IMF7	IMF8	IMF9
相关系数值	0.027	0.017	0.007	0.006	0.075	0.110
香农熵值	7.285	7.262	7.078	6.989	6.957	7.957

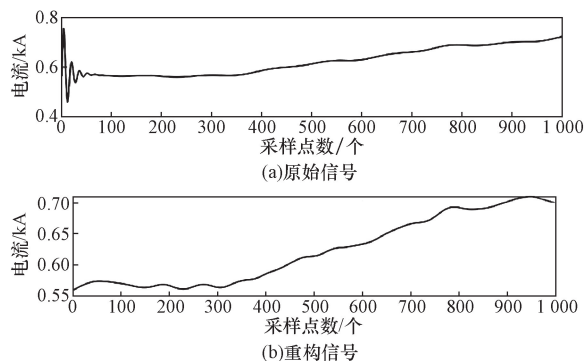


图 3 F4 处负极接地故障的 CEEMDAN 重构信号
Fig. 3 CEEMDAN reconstructed signal for negative ground fault F4

2.2 改进 ResNeSt 网络

ResNeSt^[19] 在 ResNet 的基础上进行了改进, 引入了多通道和拆分注意力 (split-attention, SA), 解决了 ResNet 缺少跨通道交互的问题, 在不显著增加网络参数数量的同时实现特征提取能力的增强。

ResNeSt 借鉴了 ResNeXt^[20] 的思想, 将输入 (长 h 、宽 w 、通道数 c) 分为 K 组, 再将每组分成 R 个, 共分为 $K \times R$ 组; 将 K 组中的 R 个输入进行 1×1 Conv 和 3×3 Conv 后, 在分组输入到 K 个 SA 模块中; 在 SA 模块中, 通过将 R 个输入融合后进行全局平均池化得到集合具有通道统计数据的全局上下文信息, 特征向量为 c' (即 c/K) 维, 池化结果经过全连接层以及 BN + ReLU 后分组进行 Softmax 计算权重, 输入

分别与其权重相乘后,将 R 个输入相加得到 SA 模块的输出;将 K 组输出进行拼接操作,再通过 1×1 Conv 保证通道数与输入相同。ResNeSt 结构如图 4 所示^[21]。

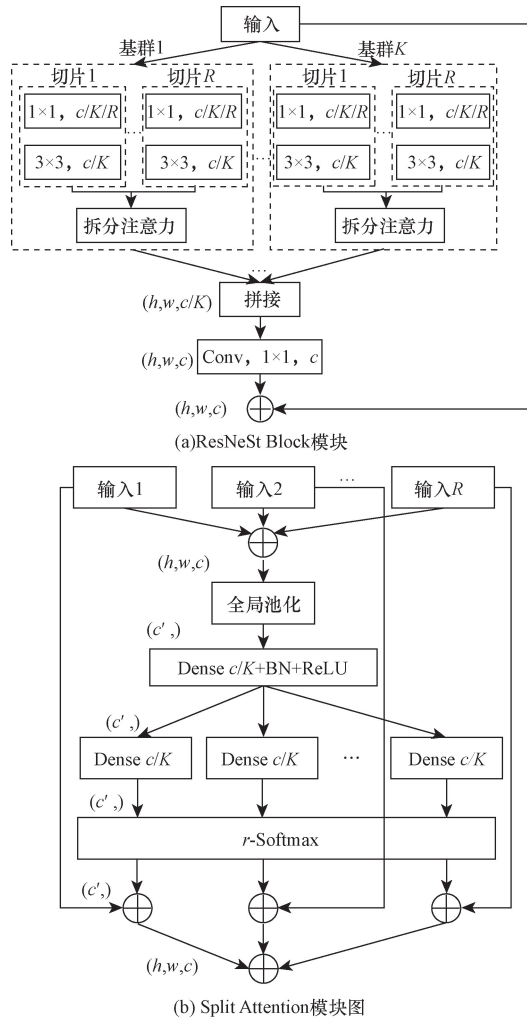


图 4 ResNeSt 结构图
Fig. 4 Structure of ResNeSt

ResNeSt 网络更关注局部特征的提取,为此引入 CAM^[22] 模块,提高模型的准确度。CAM 的结构如图 5 所示,改进 ResNeSt 网络结构如图 6 所示。

注意力机制的实质就是分配输入的权重,CAM 通过整合所有通道映射间的相关特征来选择性地强调存在相互依赖的通道映射,以此模拟通道间的相互依赖性。CAM 通过将输入矩阵 I 分别进行重组得到特征矩阵 X 、 Y 和 Z ,将 X 进行转置得到的特征矩阵和 X 相乘后,再与 Y 相乘后进行 Softmax、与矩阵 Y 相乘、重组、与 Z 相加一系列操作得到输出矩阵 B 。令 a_{ij} 为 A 矩阵中的每一个元素,则输出矩阵 B 中的元素表示为

$$B_j = \beta \sum_{i=1}^c \left(\frac{\exp I_i I_j}{\sum_{n=1}^c \exp I_n I_j} \right) + I_j \quad (5)$$

式(5)中: β 为尺度系数,初始化为 0; C 为通道数; I_i 、 I_j 分别为 I 中第 i 列和第 j 列的元素。




图 5 CAM 结构
Fig. 5 CAM structure

2.3 卷积 BiLSTM 网络

BiLSTM^[23] 是基于长短期记忆神经网络 (long short term memory, LSTM) 的改进网络。LSTM 通过遗忘门、输入门与输出门 3 个门控制函数来调节网络单元,它能将前一时刻的输出作为后一时刻的输入,在分析时间序列时有很好的优势。BiLSTM 由两个分别进行前向传播和反向传播的 LSTM 构成,能够

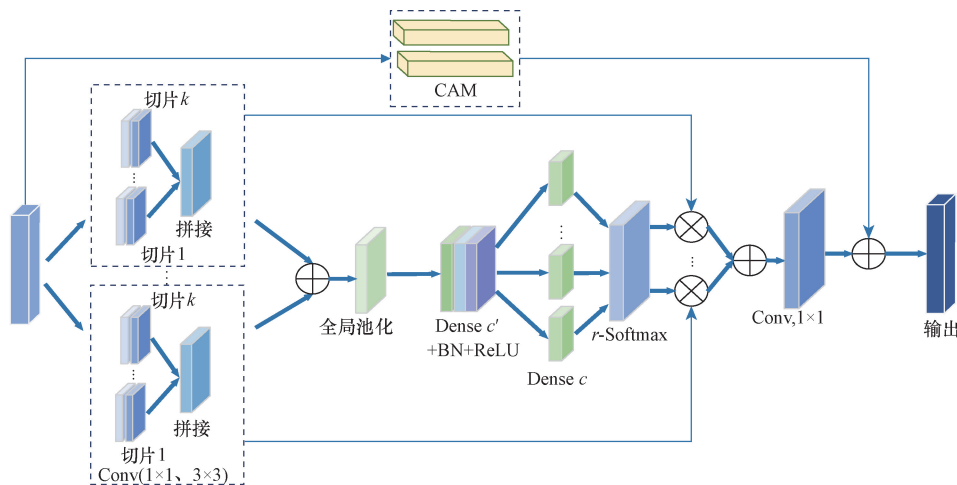


图 6 改进 ResNeSt 网络
Fig. 6 Improved ResNeSt network

更好地处理数据的时序特征。而 ResNeSt 网络针对重构后的故障数据的空间特征进行了提取,但未对数据中的时序特征进行分析,因此,引入卷积 BiLSTM 网络对故障数据的时序特征进行提取分析。卷积 BiLSTM 网络先通过 3 个 Conv + BN + ReLU 层对输入信号进行简单的特征选取,且为了防止网络过拟合,在卷积层引入了 L2 正则化,再将卷积结果输入 BiLSTM 网络进行时序特征的提取,其网络结构如图 7 中的卷积 BiLSTM 模型所示。




图 7 卷积 BiLSTM 网络结构

Fig. 7 Convolutional BiLSTM network structure

2.4 基于 Res-BiLSTM 网络的选极方法

为了解决改进 ResNeSt 网络和卷积 BiLSTM 网络提取出的特征如何融合的问题,引入针对不同网络结构的不同尺度特征融合的注意力问题而提出的 AFF^[24] 模块来代替 Add 层, AFF 结构如图 8 所示。其中,输入的长为 H 、宽为 W 、通道数为 C 。多尺度通道注意模块(MS-CAM)通过改变空间池的大小可以在多个尺度上实现通道关注,通过逐点卷积将输入的特征的通道数减少为原先的 $1/r$,为了尽可能保持轻量级,MS-CAM 将局部上下文添加到注意力模块中的全局上下文中。AFF 是在 MS-CAM 模块的基础改进的一种注意力机制,基于多尺度通道注意模块 M , AFF 可以表示为

$$Z = M(X \oplus Y) \otimes X + [1 - M(X \oplus Y)] \otimes Y \quad (6)$$

式(6)中: $Z \in \mathbf{R}^{C \times H \times W}$ 为融合特征; \oplus 和 \otimes 分别表示逐点相加和逐点相乘; $M(X \oplus Y)$ 和 $[1 - M(X \oplus Y)]$ 分别为 X 、 Y 的融合权重。

基于 Res-BiLSTM 网络的选极模型如图 9 所示,选极方法详细步骤如下。

步骤 1 获取柔性直流配电网故障时的电流数据。

步骤 2 将原始故障数据进行 CEEMDAN 分解得到 IMF 分量,并通过相关系数和香农熵对 IMF 进行筛选,实现数据重构,得到重构信号。

步骤 3 将重构信号按一定比例划分为测试样本和训练样本。

步骤 4 将训练样本输入到 Res-BiLSTM 网络模型进行训练。输入信号分别通过改进 ResNeSt 网络和卷积 BiLSTM 网络对信号的空间特征和时序特征进行提取,提取得到的数据特征通过 AFF 模块进行特征融合,再将融合特征通过两个 FC 层进行分类。

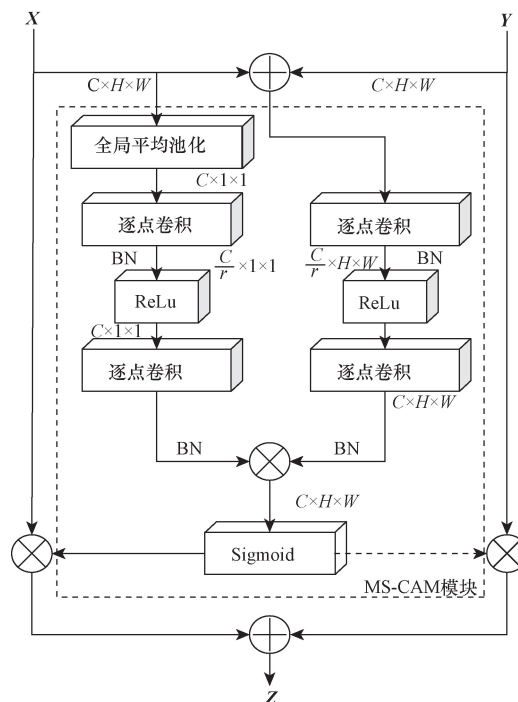


图 8 AFF 结构

Fig. 8 Structure of AFF

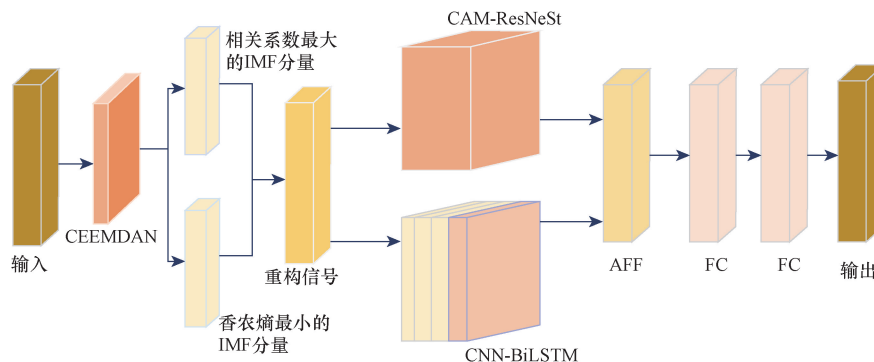


图 9 选极模型

Fig. 9 Electrode selection model

步骤 5 将测试样本放入 Res-BiLSTM 模型进行故障选极分类。Res-BiLSTM 模型采用 Sigmoid 激活函数和 Softmax 函数进行分类,得到分类结果,并采用 Adam 优化器^[25]来优化 Res-BiLSTM 网络的参数,同时选用交叉熵损失函数对网络进行评价,交叉熵是用来评估当前训练得到的概率分布与真实分布的差异情况,交叉熵的值越小,两个分布就越接近。将离线训练好的模型进行保存,发生故障后,对样本数据进行采集和处理,得到网络输入样本向量并将其输入保存的网络模型中,并通过网络模型对故障信号进行分类,实现故障选极。

3 仿真分析

基于 PSCAD/EMTDC 平台上建立如图 1 所示的 ±20 kV 四端柔性直流配电网仿真模型,L1、L2、L3、L4 线路长度分别为 15、10、20、10 km,线路采用直流频变电缆并设置线路参数为标准参数。选取数据采样频率为 10 kHz,并设置故障发生在 0.5 s 时,持续 0.1 s。在 4 个位置 F1 ~ F4 对双极故障、正极故障和负极故障 3 种类型的故障分别进行采样,共采取 1 683 组故障数据,按 9:1 的比例生成训练集和测试集。设置网络的 batch 为 16,epoch 为 80,Adam 优化器的学习率取 2×10^{-5} 。

3.1 选极方法验证

为验证所提算法在不同过渡电阻与不同故障距离下的性能,采集不同线路上过渡电阻为 10 ~ 100 Ω(步长为 10)和距离线路首端 10%、50%、100%的不同故障位置的故障信号来制作数据集。将数据集输入模型中进行训练,经过 80 次迭代后,得到如图 10 所示的准确率和损失率变化曲线。训练集和测试集的混淆矩阵如图 11 所示。

从图 10 和图 11 可以看出,损失函数逐渐下降并接近为 0.1,模型基本收敛,训练集和测试集准确率均能达到 100%,所提算法能够准确实现不同过渡电阻和不同故障距离下故障的选极,能够完成过渡电阻为 100 Ω 的故障工况下的故障选极,效果不错。

3.2 模型抗噪性能分析

实际工况中,设备会产生噪声干扰的现象,为测试噪声干扰对所提算法的影响程度,在不同线路上不同故障距离处采集到的故障原始信号中分别添加 10、20、30 dB 的高斯白噪声,接地电阻设置为 0.01 Ω,将含噪数据集输入选极模型中,为比较 CEEMDAN 信号重构在去噪方面的作用,将加噪原始信号直接输入网络模型中,对比重构信号和原始信号的选极结果如表 2 所示,混淆矩阵如图 12 所示。CEEMDAN 针对 10 dB 加噪信号的分解重构结果如

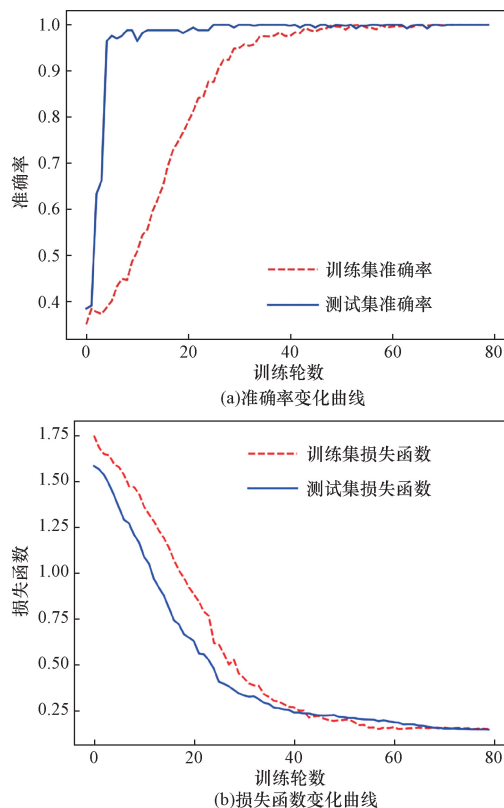


图 10 准确率和损失率变化曲线
Fig. 10 Accuracy and loss rate change curves




图 11 混淆矩阵
Fig. 11 Confusion matrix


图 13 所示(以 F1 处的双极故障为例),可以直观看出本文方法有利于含噪信号的去噪。

由图 12 和表 2 可知,所提算法基本不受噪声影响,能准确识别含 10 dB 噪声干扰的故障信号,而原始信号加噪后直接进行选极时,将含 10 dB 噪声干扰的正极故障信号误分为负极故障信号,其准确率为 99.07%,识别率较本文方法低。本文方法实现了对选极模型的抗干扰能力的增强。


表 2 不同噪声下算法性能分析

Table 2 Algorithm performance analysis under different noises

故障极	信噪比/dB	分类标签	重构信号选极结果		原始信号选极结果	
			输出标签	故障极	输出标签	故障极
双极故障	10	0	0	双极故障	0	双极故障
	20	0	0	双极故障	0	双极故障
	30	0	0	双极故障	0	双极故障
正极故障	10	1	1	正极故障	2	负极故障
	20	1	1	正极故障	1	正极故障
	30	1	1	正极故障	1	正极故障
负极故障	0	2	2	负极故障	2	负极故障
	20	2	2	负极故障	2	负极故障
	30	2	2	负极故障	2	负极故障



(a) 重构信号噪声测试结果



(b) 原始信号噪声测试结果

图 12 噪声测试结果混淆矩阵

Fig. 12 Confusion matrix of noise test results




图 13 10dB 噪声下的 CEEMDAN 信号重构

Fig. 13 CEEMDAN signal reconstruction in 10 dB noise

3.3 数据丢失实验

在采集数据时可能造成数据的丢失,为验证所提算法是否能在数据丢失时完成故障选极,分别设置丢失 100、200、250、300 个采样点的情况,丢失 250 个数据时,数据波形图如图 14 所示。数据丢失时网络测试结果如表 3 所示,混淆矩阵如图 15 所示。

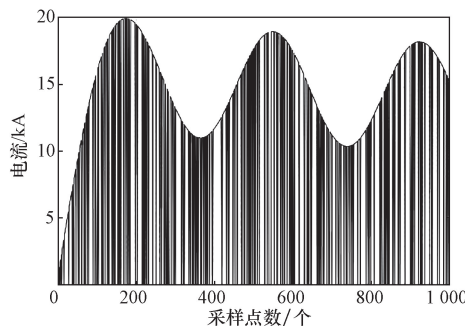


图 14 丢失 250 个数据时的波形图

Fig. 14 Waveform diagram when 250 data are lost

表 3 数据丢失时的测试结果

Table 3 Test results during data loss

故障极	丢失数据	分类标签	选极结果	
			输出标签	故障极
双极故障	100	0	0	双极故障
	200	0	0	双极故障
	250	0	0	双极故障
	300	0	1	正极故障
正极故障	100	1	1	正极故障
	200	1	1	正极故障
	250	1	2	正极故障
	300	1	1	正极故障
负极故障	100	2	2	负极故障
	200	2	2	负极故障
	250	2	2	负极故障
	300	2	2	负极故障




图 15 丢失 300 个数据时的混淆矩阵

Fig. 15 Confusion matrix when 300 data are lost

实验结果表明,所提算法能在丢失 200 个数据的情况下完成故障选极,但在丢失 250 个数据时出现错误,准确率为 99.07%,丢失 300 个数据时准确率为 96.30%。本文方法对数据丢失 100、200 个采样点时仍能准确完成故障选极。

3.4 不同方法对比实验

将本文方法与 ResNeSt、BiLSTM 等方法进行比较,将准确率作为评价指标,进一步验证本文方案的有效性和先进性,比较结果如表 4 所示。可以看出,本文方法效果最佳。本文方法的准确率比 ResNeSt 网络的准确率高出 24.26%,比 BiLSTM 网络的准确率高出 15.98%。相较于其他方案而言,本文方法对故障信号的特征的学习能力更佳,网络泛化能力更好,准确率最高且收敛速度更快,在柔性直流配电网故障选极上具有显著优势。

表 4 不同网络模型比较

Table 4 Comparison of different network models

网络模型	准确率/%
本文方案	100
ResNeSt + BiLSTM + CAM	98.82
ResNeSt + BiLSTM + AFF	96.45
ResNeSt + BiLSTM	90.53
ResNeSt + CAM	88.76
BiLSTM	84.02
ResNeSt	75.74

4 结论

针对多段柔性直流配电系统直流侧故障,提出基于 Res-BiLSTM 网络的故障选极方案,并基于 PSCAD 进行仿真验证,得到以下结论。

(1) 该方案采用 CEEMDAN 对故障电流进行分解,并利用分解所得信号对原始信号进行重构,降低了故障信号的模态混叠。信号重构提高了方案的准确率和抗噪性能。

(2) Res-BiLSTM 网络提取并融合了故障信号的

空间特征和时序特征,提高了网络的准确率和鲁棒性。该方案克服了传统方法阈值整定困难问题,且收敛速度较快。

(3) 仿真验证了本文方法且不受过渡电阻、故障距离、噪声以及部分数据丢失的影响,本文方法在信号含噪 10 dB 时仍能取得不错的效果,且能完成过渡电阻为 100 Ω 的故障工况下的故障选极,抗干扰能力较强。

参考文献

- [1] Li Z N, Duan J D, Lu W C, et al. A fast pilot protection for DC distribution networks considering the whole fault process[J]. IEEE Transactions on Power Delivery, 2021, 37(4): 3121-3132.
- [2] 梁亚峰, 马立红, 邱剑洪, 等. 基于 CEEMD-LSTM 光伏短期功率预测[J]. 科学技术与工程, 2024, 24(13): 5396-5405.
Liang Yafeng, Ma Lihong, Qiu Jianhong, et al. Short-term photovoltaic power forecasting based on CEEMD-LSTM [J]. Science Technology and Engineering, 2024, 24(13): 5396-5405.
- [3] Wang Y, Yuan Z, Fu J, et al. A feasible coordination protection strategy for MMC-MTDC systems under DC faults[J]. International Journal of Electrical Power & Energy Systems, 2017, 90: 103-111.
- [4] 刘刚, 王秀茹, 韩少华, 等. 柔性直流配电系统下垂系数选取范围研究[J]. 电力系统及其自动化学报, 2020, 32(4): 9-13, 20.
Liu Gang, Wang Xiuru, Han Shaohua, et al. Study on the scope of droop coefficient of voltage source converter based DC distribution system[J]. Journal of Power System and Automation, 2020, 32(4): 9-13, 20.
- [5] Jing G, Zhang A, Zhang H. Review on DC distribution network protection technology with distributed power supply[C]//2018 Chinese Automation Congress (CAC). Xi'an: IEEE, 2018: 3583-3586.
- [6] 刘静, 吕睿. 柔性中压直流配电网的新型电流差动保护方案[J]. 科学技术与工程, 2021, 21(7): 2720-2724.
Liu Jing, Lü Rui. A novel current differential protection scheme for flexible medium voltage direct current distribution network[J]. Science Technology and Engineering, 2021, 21(7): 2720-2724.
- [7] 李再男, 段建东, 路文超, 等. 柔性中压直流配电网线路加速纵联保护[J]. 电力系统自动化, 2021, 45(9): 80-88.
Li Zainan, Duan Jiandong, Lu Wenchao, et al. Accelerated line pilot protection of flexible MVDC distribution network[J]. Power System Automation, 2021, 45(9): 80-88.
- [8] 马鋈. 多端柔性直流配电网的后备保护方案研究[D]. 淮南市: 安徽理工大学, 2020.
Ma Yun. Research on backup protection scheme of multi-terminal flexible DC distribution network[D]. Huainan: Anhui University of Science and Technology, 2020.
- [9] Wei X, Zou G, Zhang S, et al. Frequency domain impedance based protection for flexible DC distribution grid[J]. IEEE Access, 2022, 10: 114203-114213.
- [10] Li B, He J, Li Y, et al. High-speed directional pilot protection for MVDC distribution systems[J]. International Journal of Electrical Power & Energy Systems, 2020, 121: 106141.
- [11] Jia K, Shi Z, Wang C, et al. Active converter injection-based protection for a photovoltaic DC distribution system [J]. IEEE

- Transactions on Industrial Electronics, 2021, 69(6): 5911-5921.
- [12] 张鑫宇, 樊艳芳, 马健, 等. 基于拟合电流斜率特性的柔性直流配电网纵联保护方法[J]. 电力系统保护与控制, 2021, 49(18): 128-136.
- Zhang Xinyu, Fan Yanfang, Ma Jian, et al. Pilot protection method for flexible DC distribution lines based on fitted current slope characteristics[J]. Power System Protection and Control, 2021, 49(18): 128-136.
- [13] Jiao Z, Wang Z, Wang X, et al. Protection schemes for distribution lines in DC power grid[C]//2015 IEEE Innovative Smart Grid Technologies-Asia (ISGT ASIA). Bangkok: IEEE, 2015: 1-6.
- [14] 汪光远, 杨德先, 林湘宁, 等. 基于深度置信网络的柔性直流配电网高灵敏故障辨识策略[J]. 电力系统自动化, 2021, 45(17): 180-188.
- Wang Guangyuan, Yang Dexian, Lin Xiangning, et al. High-sensitivity fault identification strategy for flexible DC distribution network based on deep belief networks[J]. Power System Automation, 2021, 45(17): 180-188.
- [15] 杨冬锋, 李绍伟, 刘晓军, 等. 基于 GRU 网络的柔性直流配电网线路保护方案[J]. 电网技术, 2021, 45(10): 3885-3896.
- Yang Dongfeng, Li Shaowei, Liu Xiaojun, et al. Protection scheme for flexible DC distribution lines based on GRU network[J]. Grid Technology, 2021, 45(10): 3885-3896.
- [16] Wei Y, Wang Z, Liu K Z, et al. Fault detection method of flexible DC distribution network based on color relation analysis classifier[J]. Electrical Engineering, 2022, 104(6): 4543-4556.
- [17] 吉兴全, 赵国航, 叶平峰, 等. 基于 QMD-HBi GRU 的短期光伏功率预测方法[J]. 高电压技术, 2024, 50(9): 3850-3859.
- Ji Xingquan, Zhao Guohang, Ye Pingfeng, et al. Short-term PV forecasting method based on QMD-HBi GRU model[J]. High Voltage Engineering, 2024, 50(9): 3850-3859.
- [18] 郎涛, 赵佳伟, 陈刻强, 等. 基于 CEEMDAN 与 RNN 算法的离心泵空化状态识别研究[J]. 水动力学研究与进展 A 辑, 2023, 38(4): 629-636.
- Lang Tao, Zhao Jiawei, Chen Keqiang, et al. Research on cavitation state identification of centrifugal pump based on RNN and CEEMDAN algorithm[J]. Chinese Journal of Hydrodynamics, 2023, 38(4): 629-636.
- [19] Zhang H, Wu C, Zhang Z, et al. Resnest: Split-attention networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 2736-2746.
- [20] Li X, Wang W, Hu X, et al. Selective kernel networks[C]//Proceedings of the IEEE/CVF Conference on computer vision and Pattern Recognition. New York: IEEE, 2019: 510-519.
- [21] 陈奎, 贾立娇, 刘晓, 等. 基于多尺度特征融合的绝缘子缺陷程度检测[J]. 高电压技术, 2024, 50(5): 1889-1899.
- Chen Kui, Jia Lijiao, Liu Xiao, et al. Insulator defect degree detection based on multi-scale feature fusion[J]. High Voltage Engineering, 2024, 50(5): 1889-1899.
- [22] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[C]// Proceedings of the European Conference on Computer Vision (ECCV). Munich: IEEE, 2018: 3-19.
- [23] 程杰, 陈鼎, 李春, 等. 基于 GWO-CNN-BiLSTM 的超短期风电预测[J]. 科学技术与工程, 2023, 23(35): 15091-15099.
- Cheng Jie, Chen Ding, Li Chun, et al. Ultra-short-term wind power prediction based on GWO-CNN-BiLSTM[J]. Science Technology and Engineering, 2023, 23(35): 15091-15099.
- [24] Dai Y, Gieseke F, Oehmcke S, et al. Attentional feature fusion[C]//Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa: IEEE, 2021: 3560-3569.
- [25] 吴青云, 高景辉, 李昭, 等. 基于 Adam 优化卷积神经网络的火电厂大数据平台预警模型测试与应用[J]. 科学技术与工程, 2023, 23(35): 15075-15083.
- Wu Qingyun, Gao Jinghui, Li Zhao, et al. Test and application of early warning model of thermal power plant big data platform based on adam optimization convolutional neural network[J]. Science Technology and Engineering, 2023, 23(35): 15075-15083.