

一种适用于混合三端直流输电线路的故障定位方法

高淑萍^{1,2}, 杨莉莉^{1,2}, 武心宇^{1,2}, 周晋宇^{1,2}, 宋国兵³

(1. 西安科技大学电气与控制工程学院, 710054, 西安; 2. 西安市电气设备状态监测与供电安全重点实验室, 710054, 西安; 3. 西安交通大学电气工程学院, 710049, 西安)

摘要: 针对因结构复杂导致的混合三端直流输电线路故障定位困难的问题,提出了一种结合变分模态分解算法与改进卷积神经网络(CNN)的故障定位方法(VMD-CNN)。首先,利用 PSCAD/EMTDC 软件构建混合三端直流输电系统模型,获得故障电流数据,应用克拉克变换对其解耦,获取故障电流的线模分量;其次,对得到的线模分量进行变分模态分解(VMD),得到多个本征模态函数(IMF)分量,选取特征信息最丰富的 IMF 分量作为 VMD-CNN 模型的输入;然后,利用高效的分类模型支持向量机(SVM)判别故障发生的区域,将提取到的 IMF 分量作为 SVM 输入进行训练学习,可以准确判断出故障发生区域;最后,搭建 VMD-CNN 模型进行故障定位,挖掘出行波信号中蕴藏的故障信息,同时通过麻雀搜索算法优化 CNN 中的超参数,实现混合三端直流输电线路的精确定位。仿真结果表明:过渡电阻为 100 Ω ,不同故障位置情况下的定位相对误差均在 0.17% 以内;故障位置为 460 km,不同过渡电阻情况下的定位相对误差均在 0.25% 以内;过渡电阻为 50 Ω ,不同故障类型情况下的相对误差均在 0.3% 以内。所提方法能够提升不同故障位置、过渡电阻和故障类型下的定位准确性。

关键词: 混合三端直流输电;故障定位;变分模态分解;卷积神经网络;麻雀搜索算法

中图分类号: TM773 **文献标志码:** A

DOI: 10.7652/xjtuxb202501004 **文章编号:** 0253-987X(2025)01-0037-10

A Fault Location Method for Hybrid Three-Terminal High Voltage Direct Current Transmission Lines

GAO Shuping^{1,2}, YANG Lili^{1,2}, WU Xinyu^{1,2}, ZHOU Jinyu^{1,2}, SONG Guobing³

(1. College of Electrical and Control Engineering, Xi'an University of Science and Technology, Xi'an 710054, China;
2. Xi'an Key Laboratory of Electrical Equipment Condition Monitoring and Power Supply Security, Xi'an 710054, China;
3. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To address the challenges posed by complex structures in fault location within hybrid three-terminal high voltage direct current (HVDC) transmission lines, a fault location method based on enhanced convolutional neural network (CNN) is proposed. Firstly, the fault current data of the hybrid three-terminal HVDC transmission system is acquired by modeling the system using PSCAD/EMTDC software, with the fault current being decoupled using the Clarke transform to

收稿日期: 2024-04-25。 作者简介: 高淑萍(1970—),女,副教授,硕士生导师。 基金项目: 国家自然科学基金国际合作与交流资助项目(52061635105);陕西省自然科学基金资助项目(2024JC-YBMS-792);国家电网有限公司总部科技资助项目(52094020006U)。

网络出版时间: 2024-09-14

网络出版地址: <https://link.cnki.net/urlid/61.1069.t.20240914.0908.002>

obtain the line-mode components of the fault current. Secondly, variational mode decomposition (VMD) is applied to decompose the line-mode components into multiple intrinsic mode function (IMF) components, with the most informative IMF component being chosen as input for the VMD-CNN model. Then, an efficient classification model, support vector machine (SVM), is employed to classify the fault occurrence region by training on the extracted IMF components as inputs for SVM, ensuring precise identification of the fault region. Finally, a VMD-CNN model is developed for fault location, extracting fault information from traveling wave signals and optimizing CNN hyperparameters using the sparrow search algorithm to achieve accurate fault location in hybrid three-terminal HVDC transmission lines. The simulation results reveal that with a transition resistance of $100\ \Omega$, the relative error in fault location is below 0.17% for various fault locations; at a fault position of 460 km, the relative error is under 0.25% for different transition resistance scenarios; and with a transition resistance of $50\ \Omega$, the relative error remains below 0.3% for different fault types. The proposed method enhances fault location accuracy under diverse fault locations, transition resistances, and fault types.

Keywords: hybrid three-terminal DC transmission lines; fault location; variational mode decomposition; convolutional neural network; sparrow search algorithm

特高压混合直流输电技术是我国为实现区域间协调发展,开发西部能源并输送至东部,解决能源与用电不平衡的重要措施,是实现“双碳”目标的关键所在^[1-2]。混合直流输电系统综合了直流输电系统和柔性直流输电系统的多项优势,但由于结构复杂,导致其在运行中容易受到多种因素干扰^[3]。尤其是输电线路长期暴露在自然环境下,导致其故障率高于系统内的其他部分^[4-5]。因此,实现输电线路精确的故障定位对于电力系统稳定可靠运行至关重要^[6]。

目前,针对混合直流输电线路故障定位的主要方法包括行波法、固有频率法、故障分析法和人工智能法^[7]。行波法是通过分析故障行波的传播特性定位故障的^[8]。文献[9]利用在不同模态网络中故障行波传播速度不同的特性,推导出基于混合双端直流输电线路故障定位公式。文献[10]先通过小波阈值滤波进行滤波,然后通过互补集合经验模态分解(CEEMD)与希尔伯特变换(HT)获得故障行波到达时刻,提出基于混合三端直流输电线路故障定位方法。行波法具有较高的定位精度,其关键在于行波波头的检测^[11]。

固有频率法利用行波固有主频率与故障距离以及线路边界条件所满足的数学关系实现故障定位^[12]。文献[13]为解决混合直流输电线路频谱混叠的问题,利用变分模态分解(VMD)和 Prony 算法进行时频分析,得到固有频率主成分相对应的频率,实现故障定位。文献[14]针对混合直流输电线路故

障行波传播特性,提出了一种组合型单端故障定位新原理实现故障定位,将固有频率法和单端行波法相结合,实现优势互补、协同定位。固有频率法不需要检测故障行波波头,但其抗干扰能力受限且存在定位死区。

故障分析法主要通过电气量分布进行故障定位^[15]。文献[16]通过钳位双子模块 MMC 逆变器的故障闭锁特性,利用线路两端电压差和整流侧故障电流,计算出线路阻抗,并实现针对混合直流输电系统的故障定位。故障分析法操作简便易行,但在精度方面存在局限性,因此定位结果的准确性无法得到充分保障。

随着智能电网和人工智能技术的发展,将智能算法应用于输电线路故障定位在国内外逐渐成为研究热点^[17]。文献[18]提出了一种基于 KNN 算法的故障定位方法,利用混合式直流断路器故障后的通流支路、换流支路和吸能支路的电流波形作为特征量,实现故障定位。在人工神经网络算法发展的基础上,深度学习算法通过多层结构扩展了模型的复杂性和学习能力,提高了自动提取和识别关键特征量的能力。在故障定位领域,可以利用故障电压或电流信号作为输入数据,进行自主学习。文献[19]将小波能量谱作为特征量,利用麻雀搜索算法(SSA)算法优化门控循环单元(GRU),实现针对混合直流输电线路短路故障的定位。可见,在故障定位领域采用人工智能方法具有一定优势。

尽管混合直流输电系统的故障数据通常表现出

高度耦合,导致数据特征复杂难解,但以卷积神经网络(CNN)为代表的深度学习算法具有较强的提取特征能力,可以自主地提取关键特征^[20]。

鉴于以上分析,本文提出了一种结合 VMD 算法与改进 CNN 的故障定位方法(VMD-CNN)。首先,利用 VMD 算法对故障线模电流进行分解,以解决频谱混叠的问题,得到最优本征模态函数(IMF)分量作为模型的输入;其次,通过 SSA 算法对 CNN 中的超参数寻优,构建 VMD-CNN 模型,提高网络的收敛速度和训练精度;最后,形成本文模型输出定位结果。与其他定位方法相比,本文方法利用行波信号的频谱特征,将其作为 VMD-CNN 的输入,不仅有效避免了对行波波头检测准确性的依赖,而且无需复杂的理论计算和公式推导。

1 混合三端直流输电系统结构

本文以昆柳龙混合三端直流输电工程为研究对象,搭建相应的仿真模型。该工程送端位于云南省昆明市,是常规直流换流站(AC);受端分别位于广东省惠州市和广西省柳州市,均是柔性直流换流站,输电线路长度为 1 489 km,其中线路 a 长 932 km,线路 b 长 557 km,系统结构如图 1 所示。




图 1 混合三端直流输电系统结构
Fig.1 Hybrid three-terminal HVDC transmission system structure

在该系统中,整流站是由电网换相换流器(LCC)构成的,是实现电力转换与控制、保障电网安全稳定运行的关键环节。逆变站由两个独立的模块化多电平换流器(MMC)构成,它们协同工作,以提高系统的灵活性和可靠性。这种混合系统设计能够综合利用 LCC 的经济优势和 MMC 的技术优势,因此十分适用于跨越区域广以及存在多个受端的大规模输电项目,它不仅提高了输电效率,降低了损耗,还能保证系统运行的可靠性和灵活性^[21]。系统参数如表 1 所示。

参数	数值或方式		
	LCC 站	MMC1 站	MMC2 站
直流电压/kV	±800	±800	±800
直流电流/kA	5.0	1.875	3.125
额定功率/MW	8 000	—3 000	—5 000
控制方式	定直流电流	定有功功率	定直流电压
平波电抗器			
电感/mH	150	150	150

2 故障特征提取

2.1 变分模态分解原理

VMD 算法是一种完全非递归且自适应的信号处理的方法,其关键环节为构造变分问题和求解变分问题^[22]。

(1)构造变分问题。假设输入信号 f 由 K 个具有有限带宽的模态分量构成,且估计带宽之和最小,约束条件是各分量和等于输入信号,则约束变分表达式为

$$\left\{ \begin{array}{l} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_{k=1}^K u_k = f \end{array} \right. \quad (1)$$

式中: K 为模态数; u_k 为分解后第 k 个模态分量; ω_k 和 ∂_t 分别为各分量对应的中心频率和梯度; $\delta(t)$ 为单位脉冲函数; $*$ 为卷积运算符。

本征模态函数(IMF)表达式如下

$$u_k(t) = A_k(t) \cos(\varphi(t)) \quad (2)$$

式中: $A_k(t)$ 为瞬时幅值; $\varphi(t)$ 为瞬时相位。

(2)求解变分问题。为求解式(1)所构造的变分问题,约束优化问题可通过增广拉格朗日函数转化为无约束优化问题,表达如下

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \end{aligned} \quad (3)$$

式中: λ 为拉格朗日乘法算子; α 为二次惩罚因子。

结合帕塞瓦尔定理、交替方向乘子迭代算法和傅里叶等距变换,可获得优化后的模态分量和其中心频率。在求解式(2)最优解的过程中,对 u_k 、 ω_k 和 λ 进行寻优迭代,表达式如下

$$u_k^{n+1}(\omega) = \frac{f(\omega) - \sum u_k(\omega) + \lambda^n(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (4)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |u_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |u_k^{n+1}(\omega)|^2 d\omega} \tag{5}$$


$$\lambda^{n+1}(\omega) = \lambda^n(\omega) + \gamma[s(\omega) - \sum u_k^{n+1}(\omega)] \tag{6}$$

式中： γ 为噪声容限参数； $f(\omega)$ 、 $u_k(\omega)$ 、 $\lambda^n(\omega)$ 和 $u_k^{n+1}(\omega)$ 为 $f(t)$ 、 $u_k(t)$ 、 $\lambda^n(t)$ 和 $u_k^{n+1}(t)$ 的傅里叶变换； n 为迭代次数。


2.2 最优模态分量提取

在 VMD 算法中，除分解层数 K (同模态数) 及惩罚因子 α 外的其他参数，对分解效果的影响通常较小，因此这些参数往往基于经验值进行设定^[23]。分解层数 K 对 VMD 的分解效果具有显著影响，为确保良好的分解效果， K 的选取非常重要。因此，本文将聚焦于参数 K 的选取问题。


设置在距离 LCC 侧 600 km 处发生正极接地故障，采样频率为 20 kHz，过渡电阻为 0.01 Ω，选取故障发生前 10 ms 和故障发生后 20 ms 的故障电流数据作为研究对象。鉴于正负极线路之间存在耦合现象，因此利用克拉克变换解耦获得线模电流分量，对其进行 VMD 分解，设置 α 为 1 000， K 取不同值时，各 IMF 分量如图 2 所示。



(a) $K=2$



(b) $K=4$



(c) $K=6$

图 2 不同 K 值下的故障线模电流分解

Fig. 2 Current decomposition of faulty line mode at different K values

包络熵表示输入信号的稀疏特征，当 IMF 中存在大量噪声，而且含量特征信息较少时，其数值相对较高；反之，包络熵较低^[24]。由图 3 可知，IMF4 的包络熵值最小， $K=4$ 为最优模态分解数。所以将 IMF4 作为本文模型的输入特征进行训练，实现故障定位。




图 3 各 IMF 分量包络熵对比

Fig. 3 Comparison of the envelope entropy of each IMF component

3 基于 VMD-CNN 的故障定位方法

3.1 卷积神经网络

卷积神经网络主要包括输入层、多个卷积层-激活层-池化层的组合、全连接层和输出层^[25]。CNN 的核心是卷积运算，这一过程是网络提取特征的关键。

键,表达式如下

$$x_{i+1} = W_i * x_i + b_i \tag{7}$$

式中： x_i 为本层输入特征(上层输出)； x_{i+1} 为本层输出特征； W_i 为权重值； b_i 为偏置值。

经过卷积运算后,结合激活层能够逐层抽象出更高级的特征表示,再通过池化层实现特征降维提升计算效率。在混合三端直流输电系统中,当线路上的不同位置发生故障时,所引起的行波信号在波形中会表现出不同的频率特征。CNN 能够利用其强大的特征提取能力捕捉到其中蕴含的信息,通过训练学习到不同故障条件下的行波信号特征,建立起故障信号与故障位置之间的映射关系,增强了系统的运行的可靠性和稳定性。

3.2 麻雀搜索算法

麻雀搜索算法(SSA)灵感源自麻雀觅食与反捕食的自然行为,模拟了麻雀群体寻找食物的动态过程^[26],算法流程如图 4 所示。利用该算法来优化卷积神经网络中的超参数,旨在进一步提升模型的回归效果。




图 4 麻雀搜索算法流程

Fig. 4 SSA algorithm flow chart

SSA 通过群体智能优化策略,可以在参数空间高效搜索,找到最优网络结构,从而提升 CNN 的预测精度和泛化能力。本文需要优化的超参数有学习率、卷积核数量、网络层数等,这些参数对网络性能有显著影响,具体如表 2 所示。

表 2 VMD-CNN 算法中的超参数

Table 2 Hyperparameters in the VMD-CNN algorithm

参数	超参数	初始化范围
x_1	批大小	1~130
x_2	学习率	0.001~0.01
x_3	卷积层 1 核大小	1~5
x_4	卷积层 1 核数量	1~40
x_5	卷积层 2 核大小	1~5
x_6	卷积层 2 核数量	1~40
x_7	全连接层神经元数量	1~50
x_8	迭代次数	10~50

3.3 VMD-CNN 神经网络模型

基于以上两种算法的各自特点构建预测模型,实现对混合三端直流输电线路故障位置的预测。首先搭建基本的 CNN 模型,结构如图 5 所示,共有 10 层,依次分别为输入层、2 个带有池化与激活的卷积层、丢弃层、全连接层和输出层。激活函数选择 ReLU 函数,设定丢弃层随机断开比例为 10%,然后通过 SSA 对 CNN 中的超参数进行寻优。设置种群数量为 10,其中种群中麻雀发现者占 20%,剩下为加入者,预警值为 0.8,具体流程如图 4 所示。经试验,经 SSA 迭代寻优后的最优参数如表 3 所示。




图 5 卷积神经网络基本结构

Fig. 5 The basic structure of a convolutional neural network

表 3 CNN 算法的最优超参数

Table 3 CNN optimal hyperparameters

参数	超参数	最优参数值
x_1	批大小	128
x_2	学习率	0.002 5
x_3	卷积层 1 核大小	3
x_4	卷积层 1 核数量	16
x_5	卷积层 2 核大小	3
x_6	卷积层 2 核数量	32
x_7	全连接层神经元数量	11
x_8	迭代次数	20

3.4 VMD-CNN 故障定位流程

基于 VMD-CNN 模型实现混合三端系统故障定位的方法主要分为数据处理、特征提取和故障定

位 3 个阶段,流程如图 6 所示,其具体步骤如下。




图 6 故障定位流程
Fig. 6 Flowchart of fault location

- (1)在第 1 节所搭建的模型中设置测量点,用于采集不同故障情况下的电流数据,应用 Clark 变换,将采集到的电流数据解耦,提取故障电流的线模分量,为后续的特征提取提供了基础。
- (2)采用 VMD 对故障线模电流进行分解,筛选得到最优 IMF 分量。随后,对选定的 IMF 进行归一化处理,为模型训练准备标准化的特征数据。
- (3)初始化 SSA 相关参数,如种群规模、麻雀种类比例和最大迭代次数等。
- (4)计算初始适应函数值,并据此对发现者、跟随者和警戒者的位置进行更新。
- (5)计算当前适应度函数值,以判断是否达到了迭代终止的条件。若达到,则输出最优参数;若尚未达到,则继续迭代寻优。
- (6)利用 SSA 寻优后得到的最优参数对 CNN 模型中的参数进行优化,将训练集放入优化后的 VMD-CNN 模型进行训练。

(7)模型建立完成后,将测试集放入本文模型进行验证,输出故障定位预测结果。通过比较预测结果与实际故障位置,评估模型的性能。

4 仿真分析

4.1 数据集构建

为验证本文方法的可行性,基于所搭建的模型,采集不同故障距离、故障类型和过渡电阻值下的故障电流数据。设置采样频率为 20 kHz,仿真时长为 6 s,第 5 s 时发生故障,持续时长为 0.1 s。

在线路 a 中,设定的故障距离指的是从故障点到 LCC 侧的距离;在线路 b 中,指的是从故障点到 MMC2 侧的距离。线路从 10 km 开始每隔 5 km 设置一个故障点。故障类型设置为正极接地故障(PG)、负极接地故障(NG)和极间短路故障(PN)。过渡电阻的变化范围是 0.01~300 Ω,变化间隔为 50 Ω。综上共采集 6 048 组数据,故障参数设置如表 4 所示。

表 4 线路故障参数设置
Table 4 Line fault parameter settings

参数	线路 a	线路 b
故障始端/km	10	10
故障点距离间隔/km	5	5
故障末端/km	920	540
故障类型	正极接地故障	
	负极接地故障	
	极间故障	
过渡电阻/Ω	0.01,50,100,	
	150,200,250,300	

4.2 故障区域选择

基于 SVM 在处理非线性数据分类任务中所展现出的显著优势与广泛的应用背景,本文故障区域选择的分类模型选用的是支持向量机(SVM)。由文献[27]可知,SVM 在处理复杂多变的非线性数据分类中具有一定优势,运行时间短、效率高。这一特性对于故障区域选择尤为重要,因为电力系统中的故障往往伴随着复杂多变的电气信号变化,这些变化呈现出非线性特征。SVM 通过在高维空间中寻找最优超平面来划分不同类别的数据点,从而实现线性可分,进而准确区分不同的故障区域,且不需要设定太多参数。

将构建好的数据集,按照 7 : 3 随机划分训练集和测试集。即训练故障选线模型所使用的数据集是由 4 233 组数据样本构成,剩下的 1 815 组数据用来

评估经过训练后模型的性能。图 7 为测试集的混淆矩阵,由图可知,该模型可以准确地对故障区域进行选择。




图 7 测试集混淆矩阵
Fig. 7 Test set confusion matrix

4.3 故障定位

根据 4.1 节的参数设置,以线路 a 发生故障为例,共采集 3 822 组数据。将采集到的数据按照 2.2 节的方法进行预处理构建数据集,然后按照 8 : 2 随机划分训练集和测试集。通过设置不同的故障距离、过渡电阻和故障类型,分析验证本文模型的适应性。

(1)不同故障距离。为验证故障距离对定位结果是否会造成影响,本文设置多组故障距离进行验证。当故障距离为 80、180、280、380、480、580、680、780 km 时,过渡电阻为 100 Ω 情况下的仿真结果见表 5。

表 5 不同故障距离下定位结果

Table 5 Location results at different fault distances

故障距离/km	定位结果/km	绝对误差/km	相对误差/%
80	80.686 6	0.686 6	0.074
180	180.921 6	0.921 6	0.099
280	280.599 4	0.599 4	0.064
380	381.286 0	1.286 0	0.138
480	480.073 4	0.073 4	0.008
580	581.515 9	1.515 9	0.163
680	679.205 8	0.794 2	0.085
780	779.171 3	0.828 7	0.089

由表 5 可知,在不同故障距离的情况下,故障定位的最大的绝对误差为 1.515 9 km,而最小的绝对误差仅为 0.073 4 km,这一结果表明本文模型几乎不受故障距离因素的影响。此外,所有测试条件下的相对误差均维持在 0.17% 以内,进一步证实了模型具有较高的稳定性和定位精度。

(2)不同过渡电阻。为验证本文模型在不同过渡电阻的情况下依旧能实现准确定位,设置故障发

生在 460 km 处,同时设置不同过渡电阻进行仿真实验,仿真结果如表 6 所示。

表 6 不同过渡电阻下定位结果

Table 6 Positioning results at different transition resistors

过渡电阻/Ω	定位结果/km	绝对误差/km	相对误差/%
0.01	459.508 8	0.491 2	0.053
50	460.075 7	0.075 7	0.008
100	461.075 0	1.075 0	0.115
150	458.276 2	1.723 8	0.185
200	461.961 3	1.961 3	0.210
250	462.253 1	2.253 1	0.242
300	462.217 0	2.217 0	0.238

由表 6 可知,在过渡电阻较小的情况下,定位误差均保持在较低水平,当过渡电阻值超过 200Ω 时,定位误差出现上升趋势,但故障定位的相对误差仍在 0.25% 以内,表明本文模型在不同过渡电阻条件下具有较高的定位精度。因此,可以验证本文模型受不同过渡电阻的影响较小。

(3)不同故障类型。在混合三端直流输电系统中,主要存在两种类型的故障分别是单极接地故障和极间短路故障。为了验证本文模型在不同故障类型时仍能实现准确定位,针对这两种故障类型设置多组不同的故障距离,过渡电阻为 50Ω,仿真结果如表 7 和图 8 所示。其中,PG 表示正极接地故障,NG 表示负极接地故障,PN 表示极间故障。

表 7 不同故障类型下定位结果

Table 7 Locating results for different fault types

故障距离/km	故障类型	定位结果/km	绝对误差/km
100	PG	101.574 5	1.574 5
	NG	101.288 3	1.288 3
	PN	98.669 7	1.330 3
200	PG	201.093 5	1.093 5
	NG	200.898 4	0.898 4
	PN	198.995 0	1.005 0
300	PG	301.304 4	1.304 4
	NG	301.276 2	1.276 2
	PN	299.152 7	0.847 3
400	PG	400.910 6	0.910 6
	NG	401.088 9	1.088 9
	PN	401.985 4	1.985 4
500	PG	500.239 7	0.239 7
	NG	500.348 4	0.348 4
	PN	501.139 6	1.139 6




图 8 不同故障类型下定位结果相对误差
Fig.8 The relative error of the location results under different fault types

由表 7 和图 8 可知,在不同故障类型情况下,首先,故障定位的绝对误差均在 2 km 以内,表明本文模型具有较高的定位精度。其次,相对误差均保持在 0.3%以内,进一步证明了本文模型在不同故障类型下具有较高的稳定性。因此,可以验证本文模型基本不受故障类型的影响。

4.4 算法对比

为验证本文模型的有效性,将其与 CNN、BP 和长短时记忆网络(LSTM)算法进行对比分析。采用 4.3 节中的数据集,对上述模型进行训练学习和性能评估,结果如表 8 和图 9 所示。

表 8 不同算法故障定位结果

故障 距离/km		定位结果/km			
		VMD-CNN	CNN 算法	BP 算法	LSTM 算法
80		80.686 6	77.433 2	80.865 8	83.062 1
180		180.921 6	190.258 1	181.126 7	190.002 3
280		280.594 4	277.705 4	278.204 3	277.788 1
380		381.286 0	381.814 0	378.526 9	382.657 1
480		480.074 3	486.371 6	479.032 6	477.172 4
580		581.515 9	586.184 4	582.508 2	582.949 5
680		679.205 8	687.119 4	678.032 3	681.530 7
780		779.171 3	791.423 5	777.950 0	783.851 1

由表 8 和图 9 可知,当故障发生在接近线路中点处时,上述算法都能较为准确的定位故障位置。随着故障位置逐渐远离线路中点,定位精度呈现出下降趋势,误差也随之增大。其主要原因是:近端故




图 9 不同定位算法误差对比
Fig.9 Comparison of errors of different location algorithms

障区域的固有主频率通常较高,难以被捕捉,且故障行波在近端区域折反射速度较快,导致提取到的故障不够准确,模型不能充分学习故障特征,出现误差增大现象。本文所提故障定位方法误差始终小于其他定位算法,绝对误差均在 2 km 以内,相较于全长 932 km 的输电线路,相对误差仅为 0.21%,可得出本文方法具有一定的优越性。

5 结 论

针对 LCC-MMC 混合三端直流输电系统由于其结构的复杂性所引发的故障定位困难的问题,本文提出了一种更加精确的输电线路故障定位方法,该方法结合 VMD 和 CNN,同时利用 SSA 优化 CNN 网络。通过 PSCAD 和 MATLAB 相结合的方法进行仿真分析,得到以下结论。

(1)采用 VMD 对故障线模电流进行分解,抑制了信号中的噪声成分,避免模态混叠现象,从而更加精准地提取信号的故障特征。

(2)采用 SSA 对 CNN 中的参数进行优化,消除了手动调参过程中的不确定因素,使模型参数更加合理。

(3)本文提出的 VMD-CNN 模型定位精度几乎不受不同故障位置、过渡电阻和故障类型因素的影响。同时与 CNN 神经网络、BP 神经网络和 LSTM 神经网络进行对比,仿真结果表明本文所提方法定位结果更加精确。

参考文献:

[1] 赵成勇,郭春义,刘文静.混合直流输电[M].北京:

- 科学出版社, 2014: 2-5.
- [2] 雷朝煜, 郝良收, 戴甲水, 等. 高压直流输电线路故障定位研究综述 [J]. 电力系统保护与控制, 2022, 50(11): 178-187.
- LEI Zhaoyu, HAO Liangshou, DAI Jiashui, et al. A review of fault location methods in HVDC transmission lines [J]. Power System Protection and Control, 2022, 50(11): 178-187.
- [3] 张东寅, 范志华, 许汉平, 等. LCC 与 FH-MMC 混合直流输电系统直流单极接地故障穿越控制策略 [J]. 高电压技术, 2020, 46(6): 2072-2080.
- ZHANG Dongyin, FAN Zhihua, XU Hanping, et al. DC pole-to-ground fault ride-through strategy of hybrid HVDC system based on LCC and hybrid MMC [J]. High Voltage Engineering, 2020, 46(6): 2072-2080.
- [4] BENDJABEUR A, KOUADRI A, MEKHILEF S. Transmission line fault location by solving line differential equations [J]. Electric Power Systems Research, 2021, 192: 106912.
- [5] 邱晓璇. 混合三端直流输电线路纵联保护与故障测距研究 [D]. 保定: 华北电力大学, 2023.
- [6] XIE Liwei, LUO Longfu, LI Yong, et al. A traveling wave-based fault location method employing VMD-TEO for distribution network [J]. IEEE Transactions on Power Delivery, 2020, 35(4): 1987-1998.
- [7] 杨林, 王宾, 董新洲. 高压直流输电线路故障测距研究综述 [J]. 电力系统自动化, 2018, 42(8): 185-191.
- YANG Lin, WANG Bin, DONG Xinzhou. Overview of fault location methods in high voltage direct current transmission lines [J]. Automation of Electric Power Systems, 2018, 42(8): 185-191.
- [8] 丁佳立, 王昕, 郑益慧, 等. 利用线路中点电流检测的改进单端行波故障测距方法 [J]. 高电压技术, 2020, 46(5): 1814-1822.
- DING Jiali, WANG Xin, ZHENG Yihui, et al. Improved method for fault location of single-ended traveling-wave using line midpoint current measurement [J]. High Voltage Engineering, 2020, 46(5): 1814-1822.
- [9] 王健. 混合双端直流输电系统故障定位方法研究 [D]. 天津: 天津大学, 2022.
- [10] 高淑萍, 徐振曦, 宋国兵, 等. 基于小波阈值去噪和 CEEMD 的混合三端直流输电线路故障测距 [J]. 电力系统保护与控制, 2022, 50(3): 29-40.
- GAO Shuping, XU Zhenxi, SONG Guobing, et al. Fault location of hybrid three-terminal HVDC transmission lines based on wavelet threshold denoising and CEEMD [J]. Power System Protection and Control, 2022, 50(3): 29-40.
- [11] 宋国兵, 蔡新雷, 高淑萍, 等. 高压直流输电线路故障定位研究综述 [J]. 电力系统保护与控制, 2012, 40(5): 133-137.
- SONG Guobing, CAI Xinlei, GAO Shuping, et al. Survey of fault location research for HVDC transmission lines [J]. Power System Protection and Control, 2012, 40(5): 133-137.
- [12] 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(S1): 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, 2023, 43(S1): 114-126.
- [13] 王磊, 黄力, 黄照厅, 等. 基于 VMD-后向预测 prony 的直流混合线故障测距方法 [J]. 电网与清洁能源, 2020, 36(10): 61-67.
- WANG Lei, HUANG Li, HUANG Zhaoting, et al. A fault location method of the DC hybrid line based on VMD-backward prediction Prony [J]. Power System and Clean Energy, 2020, 36(10): 61-67.
- [14] 张艳霞, 王海东, 李婷, 等. LCC-VSC 混合直流输电线路的组合型单端故障定位方法 [J]. 电力系统自动化, 2019, 43(21): 187-194.
- ZHANG Yanxia, WANG Haidong, LI Ting, et al. Combined single-end fault location method for LCC-VSC hybrid HVDC transmission line [J]. Automation of Electric Power Systems, 2019, 43(21): 187-194.
- [15] 薛艳静, 徐岩, 程姝. 基于电流变化的环状直流配电网故障定位方法 [J]. 智慧电力, 2021, 49(2): 76-82.
- XUE Yanjing, XU Yan, CHENG Shu. Fault location method of ring DC distribution network based current variation [J]. Smart Power, 2021, 49(2): 76-82.
- [16] XING Chao, LI Shengnan, XI Xinze. Research on a fault location method for a pole-to-pole short-circuit fault in an LCC-MMC hybrid DC transmission system [J]. IEEE Access, 2020, 8: 165683-165692.
- [17] 和敬涵, 罗国敏, 程梦晓, 等. 新一代人工智能在电力系统故障分析及定位中的研究综述 [J]. 中国电机工程学报, 2020, 40(17): 5506-5515.
- HE Jinghan, LUO Guomin, CHENG Mengxiao, et al. A research review on application of artificial intelligence in power system fault analysis and location [J]. Proceedings of the CSEE, 2020, 40(17): 5506-5515.
- [18] TZELEPIS D, MIRSAEIDI S, DYSKO A, et al. Intelligent fault location in MTDC networks by recognizing patterns in hybrid circuit breaker currents during

- fault clearance process [J]. IEEE Transactions on Industrial Informatics, 2021, 17(5): 3056-3068.
- [19] 王雪芹, 张大海, 李猛, 等. 基于小波能量谱和 SSA-GRU 的混合直流输电系统故障测距方法 [J]. 电力系统保护与控制, 2023, 51(12): 14-24.
- WANG Xueqin, ZHANG Dahai, LI Meng, et al. Fault location method for a hybrid DC transmission system based on wavelet energy spectrum and SSA-GRU [J]. Power System Protection and Control, 2023, 51(12): 14-24.
- [20] 杨玉萍, 吴浩, 田海鹏, 等. 高压直流输电线路单端智能故障定位方法 [J]. 电力系统及其自动化学报, 2023, 35(9): 120-129.
- YANG Yuping, WU Hao, TIAN Haipeng, et al. Single-ended intelligent fault location method for HVDC transmission lines [J]. Proceedings of the CSU-EP-SA, 2023, 35(9): 120-129.
- [21] 李国庆, 娄伟涛, 辛业春, 等. LCC-MMC 型混合直流输电系统送端交流故障穿越控制策略 [J]. 电网技术, 2021, 45(7): 2586-2595.
- LI Guoqing, LOU Weitao, XIN Yechun, et al. AC fault ride-through control strategy for sending end of LCC-MMC hybrid DC transmission system [J]. Power System Technology, 2021, 45(7): 2586-2595.
- [22] 高淑萍, 吕宇星, 宋国兵, 等. 利用改进变分模态分解突变能量的直流配电网保护方法 [J]. 西安交通大学学报, 2023, 57(5): 159-170.
- GAO Shuping, LÜ Yuxing, SONG Guobing, et al. A DC distribution network protection method based on improved VMD and abrupt energy [J]. Journal of Xi'an Jiaotong University, 2023, 57(5): 159-170.
- [23] 姜飞, 林政阳, 王文烨, 等. 考虑最小平均包络熵负荷分解的最优 Bagging 集成超短期多元负荷预测 [J]. 中国电机工程学报, 2024, 44(5): 1777-1788.
- JIANG Fei, LIN Zhengyang, WANG Wenye, et al. Optimal bagging ensemble ultra short term multi-energy load forecasting considering least average envelope entropy load decomposition [J]. Proceedings of the CSEE, 2024, 44(5): 1777-1788.
- [24] 唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用 [J]. 西安交通大学学报, 2015, 49(5): 73-81.
- TANG Guiji, WANG Xiaolong. Parameter optimized variational mode decomposition method with application to incipient fault diagnosis of rolling bearing [J]. Journal of Xi'an Jiaotong University, 2015, 49(5): 73-81.
- [25] 陶唐飞, 周文洁, 况佳臣, 等. 融合多小波分解的深度卷积神经网络轴承故障诊断方法 [J]. 西安交通大学学报, 2024, 58(5): 31-41.
- TAO Tangfei, ZHOU Wenjie, KUANG Jiachen, et al. Bearing fault diagnosis method of deep convolutional neural network based on multiwavelet decomposition [J]. Journal of Xi'an Jiaotong University, 2024, 58(5): 31-41.
- [26] 李雅丽, 王淑琴, 陈倩茹, 等. 若干新型群智能优化算法的对比研究 [J]. 计算机工程与应用, 2020, 56(22): 1-12.
- LI Yali, WANG Shuqin, CHEN Qianru, et al. Comparative study of several new swarm intelligence optimization algorithms [J]. Computer Engineering and Applications, 2020, 56(22): 1-12.
- [27] 田鹏飞, 于游, 董明, 等. 基于 CNN-SVM 的高压输电线路故障识别方法 [J]. 电力系统保护与控制, 2022, 50(13): 119-125.
- TIAN Pengfei, YU You, DONG Ming, et al. A CNN-SVM-based fault identification method for high-voltage transmission lines [J]. Power System Protection and Control, 2022, 50(13): 119-125.

(编辑 杜秀杰)