

基于 APO-MVMD-Transformer 的电缆故障定位方法

孙杰¹, 孙玉玮¹, 胡国栋^{2*}, 尹海海¹, 蒋徐勇¹, 马宏忠²

(1. 国网江苏南通供电公司, 江苏 南通 226000; 2. 河海大学 电气与动力工程学院, 江苏 南京 211100)

摘要:针对现有电力电缆故障定位的准确率和可靠性均偏低的问题,提出一种基于 APO-MVMD-Transformer 的电缆故障定位方法。将采集到的电缆故障信号通过相模变换进行解耦得到故障行波信号,采用经北极海鸮优化算法(APO)寻优后的多元变分模态分解(MVMD)参数分解行波信号,通过 Teager 能量算子获取分解后的高频模态分量的瞬时能量变化,标定行波波头到达时刻,将时刻对应的采样点作为特征值构建特征数据集,再利用 APO 优化 Transformer 模型。最后将数据送入 APO-Transformer 定位模型中,实现电缆故障定位。结果表明,该定位模型的确定系数高达 0.999 91,故障定位相对误差在 1% 以内,定位距离误差在百米以内,具有较高的故障定位精度。

关键词:故障定位;相模变换;北极海鸮优化算法;多元变分模态分解;Teager 能量算子;Transformer 模型

中图分类号:TM247

文献标志码:A

文章编号:1002-4026(2025)06-0094-13

开放科学(资源服务)标志码(OSID):



Cable fault location method based on APO-MVMD-Transformer

SUN Jie¹, SUN Yuwei¹, HU Guodong^{2*}, YIN Haihai¹, JIANG Xuyong¹, MA Hongzhong²

(1. State Grid Nantong Power Supply Company, Nantong 226000, China;

2. School of Electrical and Power Engineering, Hohai University, Nanjing 211100, China)

Abstract: To address the low accuracy and reliability of existing power cable fault-location methods, a new cable fault-location method based on APO-MVMD-Transformer is proposed in this study. The collected cable fault signal is decoupled through phase-mode transformation to obtain the fault traveling wave signal. The Arctic puffin optimization (APO) optimized multivariate variational mode decomposition (MVMD) parameters are then used to decompose this traveling wave signal. The Teager energy operator is applied to extract instantaneous energy variations in the high-frequency modal components, allowing the identification of the wavefront arrival times. The sampling points corresponding to these times are then used as feature values to construct a feature dataset, which is further employed to optimize the APO-Transformed-based model. Finally, feature dataset are input into the APO-Transformer-based location model to locate cable faults. Results showed that the proposed model exhibited a coefficient of determination as high as 0.999 91, a relative fault-location error within 1%, and a distance error within 100 m, thereby demonstrating high fault location accuracy.

Key words: fault location; phase-mode transformation; Arctic puffin optimization; multivariate variational mode decomposition; Teager energy; Transformer

收稿日期:2024-12-11

基金项目:国网江苏省电力有限公司南通供电分公司科技项目(B71080242S59)

作者简介:孙杰(1991—),男,硕士,工程师,研究方向为架空输电线路和输电电缆的运维检修。E-mail:seu_sunjie@163.com

* 通信作者,胡国栋,男,硕士,研究方向为电力电缆故障诊断与定位。E-mail:2543085804@qq.com, Tel:17664400292

地下电缆输电系统因占地面积小、抗天气强、导电优越及供电可靠,成为城市电网首选。但深埋土壤中的电缆易受土壤湿度和外力影响,若发生故障不仅影响系统运行,还可能引发安全事故。因此,及时准确地定位电缆故障点,对于保障电力系统的安全稳定运行具有重要意义^[1-2]。

传统的电缆故障定位方法主要包括阻抗法^[3-4]、行波法^[5-6]等。阻抗法是出现较早的故障定位方法,受三相参数不稳定影响,其难以应用于复杂电路。行波法随着行波传播距离的增加,会导致波形失真。为了解决这一问题,丁希鹏等^[7]提出一种基于改进希尔伯特-黄变换的电缆故障定位方法。针对应用经验模态分解(EMD)方法处理信号的过程中易产生模态混叠现象的问题,提出在进行 EMD 分解的过程中加入辅助信号的方法,来克服模态混叠现象。谢李为等^[8]提出一种基于变分模态分解算法(VMD)和 S 变换的故障行波提取法,通过对故障行波信号进行 VMD 分解,利用 S 变换分析得到故障突变点来确定故障行波达到时刻。但是 EMD 和 VMD 方法的性能往往受到初始参数的选择以及局部极小值的问题的影响,这可能导致结果的不稳定性。而 MVMD 作为 VMD 的扩展,在一定程度上克服模态混叠现象,能够同时处理多个相关信号,并从中提取出独立的故障特征,这对于电缆故障的特征提取具有重要意义。

神经网络因其出色的非线性映射能力和强大的学习功能,在电缆故障定位领域得到了广泛的应用^[9-11]。Transformer 模型作为近年来深度学习领域的一项重大突破,凭借其独特的自注意力机制和位置编码技术,能够高效地处理序列数据,并捕捉到数据中的长距离依赖关系,正逐渐成为众多应用领域的优选方案。此外,结合优化算法,可以进一步提升模型的泛化能力和诊断精度^[12-14]。

为了实现传统故障定位技术与神经网络算法的优势互补,提高电缆故障定位的精度。本文从双端行波测距出发,利用北极海鹦优化算法(APO)优化 MVMD 和 Transformer 模型的参数,提出基于 APO-MVMD-Transformer 的电缆故障定位方法,利用 Matlab/Simulink 建立仿真模型获取故障数据,对 Transformer 模型进行训练和测试,最后通过对比分析,验证了本文所提电缆故障定位方法的准确性和鲁棒性。

1 双端行波定位

在故障定位技术中,行波法分为单端和双端两类。单端行波法仅使用一个监测点,其定位精度受对端母线反射波的影响。双端行波法则在电缆的两端都布置监测装置,通过对比行波首次到达两个监测点的时间差来确定故障点,排除了对端母线反射波的影响,鲁棒性强。因此,本文采用双端行波法进行电缆故障定位。

1.1 定位原理

图 1 为双端行波测距原理图,监测点位于电缆的 L 和 R 两端,电缆的全长为 L 。假设在某一时刻,电缆上的某一点发生了故障,由此产生的故障行波将沿着电缆向两端传播。当故障行波到达 L 和 R 两端监测点时,对应的时间分别为 T_{L1} 和 T_{R1} ,利用这两个时间即可确定电缆故障的确切位置。测距公式如下:

$$d = \frac{L + v(T_{L1} - T_{R1})}{2}, \quad (1)$$

其中, v 为行波波速,取 $v = \frac{1}{\sqrt{L_0 C_0}}$, L_0 为单位长度电感, C_0 为单位长度电容。

1.2 相模变换

在三相电缆系统中,当其中一相发生故障时,由于线路中电感的存在以及三相之间的电磁耦合效应,非故障相上同样会诱发行波,各相之间并不独立。因此,本文借助相模变换技术,将原本的相量转化为相互独




图 1 双端行波法原理图

Fig.1 Schematic of the double-ended traveling wave method

立的模量。鉴于 Karenbauer 变换矩阵具有结构简单且对称的特点,且无需进行复数运算,因此本文选择采用 Karenbauer 变换来进行处理,其相模变换矩阵为:

$$T = \frac{1}{3} \begin{bmatrix} 1 & 1 & 1 \\ 1 & -1 & 0 \\ 1 & 0 & -1 \end{bmatrix}, \quad (2)$$

相模变换过后, a 相、 b 相、 c 相三相分量变换为 α 分量、 β 分量和零模分量。

2 基于 APO-MVMD-TEO 的故障特征提取

2.1 MVMD 原理

多元变态模态分解(multivariate variational mode decomposition, MVMD)技术旨在从数据中提取出预定义的 K 个多元调制振荡信号 $u_k(t)$ 。MVMD 分解的具体步骤如下:

通过谐波移位 u_+^k 的梯度函数的 L_2 范数估计 $u_k(t)$ 的带宽,得到成本函数 f 为:

$$f = \sum_k \sum_c \partial_t [u_+^{k,c}(t) e^{-j\omega_k t}]^2, \quad (3)$$

式中, $u_+^{k,c}(t)$ 为信道数 c 、模式数 k 的解析调制信号; $e^{-j\omega_k t}$ 表示将 $u_+^{k,c}(t)$ 调整至对应的中心频率 ω_k 。

考虑到存在多个线性等式约束,在构造 MVMD 的变分约束模型时,增广拉格朗日函数也需要进行相应的调整,即

$$L(\{u_{k,c}\}, \{\omega_k\}, \lambda_c) = \alpha \sum_{k=1}^K \sum_{c=1}^C \|\partial_t [u_+^{k,c}(t) e^{-j\omega_k t}]\|_2^2 + \sum_{c=1}^C \|x_c(t) - \sum_{k=1}^K u_{k,c}(t)\|_2^2 \\ + \sum_{c=1}^C \langle \lambda_c(t), x_c(t) - \sum_{k=1}^K u_{k,c}(t) \rangle, \quad (4)$$

式中, $u_{k,c}$ 为信道数 c 和模式数 k 的调制信号; λ_c 为信道数 c 的拉格朗日算子; x_c 为信道数 c 的输入数据; α 为 MVMD 算法中的惩罚因子; $\langle \rangle$ 表示内积。

通过乘子交替方向法迭代更新 $u_k(t)$ 、 ω_k 及 λ_c 求取变分优化问题的最优解,求解过程中包括了变分优化问题的模态更新和中心频率更新。

模态更新为:

$$\hat{u}_{k,c}^{n+1}(\omega) = \frac{\hat{x}_c(\omega) - \sum_{i=1}^{k-1} \hat{u}_{i,c}(\omega) - \sum_{i=k+1}^K \hat{u}_{i,c}(\omega) + \frac{\hat{\lambda}_c(\omega)}{2}}{1 - 2\alpha(\omega - \omega_k)^2}, \quad (5)$$

其中, $\hat{x}_c(\omega)$ 、 $\hat{\lambda}_c(\omega)$ 、 $\hat{u}_{i,c}(\omega)$ 分别为傅里叶变换后的信号; n 为迭代次数, $n = 0, 1, 2, \dots, N$ 。

中心频率更新为:

$$\omega_k^{n+1} = \frac{\sum_{c=1}^C \int_0^\infty \omega |\hat{u}_{k,c}(\omega)|^2 d\omega}{\sum_{c=1}^C \int_0^\infty |\hat{u}_{k,c}(\omega)|^2 d\omega}. \quad (6)$$

MVMD 方法能同时计算多个信道数据,保证了信道间各 IMF 分量数和频率尺度均相同,使信号的分析更趋于稳定。

2.2 APO 原理

受北极海鹦生存行为的启发,北极海鹦优化算法(APO)的模型主要包括三个阶段:种群初始化、空中飞行阶段和水下觅食阶段^[15]。

2.1.1 种群初始化

初始化种群的过程如下:

$$\mathbf{X}_i^t = \text{rand} * (\text{ub} - \text{lb}) + \text{lb}, i = 1, 2, 3, \dots, N, \quad (7)$$

其中, \mathbf{X}_i^t 代表第 i 只北极海鸚的位置;rand 生成一个介于 0 和 1 之间的随机数;ub 和 lb 分别代表上界和下界; N 是群体中个体的数量。

2.2.2 空中飞行阶段

在空中搜索时,北极海鸚专注于侦察潜在的猎物,同时警觉附近可能出现的天敌,位置更新公式为式(8)。在捕食过程中北极海鸚利用俯冲迅速改变飞行方向以加快食物捕获的速度,位置更新公式为式(10)。

$$\mathbf{Y}_i^{t+1} = \mathbf{X}_i^t + (\mathbf{X}_i^t - \mathbf{X}_\tau^t) * L(D) + R, \quad (8)$$

$$R = \text{round}(0.5 * (0.05 + \text{rand})) * a, \quad (9)$$

$$\mathbf{Z}_i^{t+1} = \mathbf{Y}_i^{t+1} * S, \quad (10)$$

$$S = \tan((\text{rand} - 0.5) * \pi), \quad (11)$$

其中, τ 是介于 1 和 $N-1$ 之间的随机整数; \mathbf{X}_i^t 表示种群中当前的第 i 个个体; \mathbf{X}_τ^t 是从当前种群中随机选择的一个个体,满足 $\mathbf{X}_i^t \neq \mathbf{X}_\tau^t$; $L(D)$ 表示通过 Levy 飞行产生的随机数; a 为服从标准正态分布的随机数。

为了得到最优解,将两个阶段产生的位置合并成一个新解。更新后的位置公式如下:

$$\mathbf{P}_i^{t+1} = \mathbf{Y}_i^{t+1} \cup \mathbf{Z}_i^{t+1}, \quad (12)$$

$$\text{new} = \text{sort}(\mathbf{P}_i^{t+1}), \quad (13)$$

$$\mathbf{X}_i^{t+1} = \text{new}(1:N), \quad (14)$$

其中,sort 表示根据新种群的适应度值从小到大对新种群 \mathbf{P}_i^{t+1} 进行排序,以产生新种群 \mathbf{X}_i^{t+1} 。

2.2.3 水下觅食阶段

水下觅食主要包括系协同觅食、强化搜索和躲避捕食者 3 个部分,以应对不同的情境,提高捕食效率,其位置更新公式分别为式(15)、式(16)和式(17)。

$$\mathbf{W}_i^{t+1} = \begin{cases} \mathbf{X}_{r_1}^t + F * L(D) * (\mathbf{X}_{r_2}^t - \mathbf{X}_{r_3}^t) \text{rand} \geq 0.5 \\ \mathbf{X}_{r_1}^t + F * (\mathbf{X}_{r_2}^t - \mathbf{X}_{r_3}^t) \text{rand} < 0.5 \end{cases}, \quad (15)$$

$$\mathbf{Y}_i^{t+1} = \mathbf{W}_i^{t+1} * (1 + f), \quad (16)$$

$$\mathbf{Z}_i^{t+1} = \begin{cases} \mathbf{X}_i^t + F * L(D) * (\mathbf{X}_{r_1}^t - \mathbf{X}_{r_2}^t) \text{rand} \geq 0.5 \\ \mathbf{X}_i^t + \beta * (\mathbf{X}_{r_1}^t - \mathbf{X}_{r_2}^t) \text{rand} < 0.5 \end{cases}, \quad (17)$$

其中, F 代表协同因子,调整北极海鸚的捕食行为; r_1, r_2, r_3 是介于 1 和 $N-1$ 之间的随机数; $\mathbf{X}_{r_1}^t, \mathbf{X}_{r_2}^t, \mathbf{X}_{r_3}^t$ 是从当前种群中随机选择的最优种群; t 表示当前的迭代次数; f 是一个自适应因子,用于调整北极海鸚在水中的位置; β 是在 0 到 1 之间均匀分布的随机数。

将 3 个不同位置方程合并成一个,合并公式如下:

$$\mathbf{P}_i^{t+1} = \mathbf{W}_i^{t+1} \cup \mathbf{Y}_i^{t+1} \cup \mathbf{Z}_i^{t+1}, \quad (18)$$

$$\text{new} = \text{sort}(\mathbf{P}_i^{t+1}), \quad (19)$$

$$\mathbf{X}_i^{t+1} = \text{new}(1:N). \quad (20)$$

在 APO 算法中,为了实现从空中搜索到水下觅食的平滑过渡,引入过渡系数 B 。其定义如下:

$$B = 2 * \log(1/\text{rand}) * (1 - t/T), \quad (21)$$

其中, T 代表总的迭代次数。

同时,在引入一个参数 C ,当 $B > C$ 时,算法处于空中搜索阶段;当 $B \leq C$ 时,算法处于水下觅食阶段。

2.3 APO-MVMD 原理

在 MVMD 算法中,模态参数 K 和惩罚因子 α 对信号处理效果起着至关重要的作用。 K 值决定了信号被

分解成多少个本征模态函数分量(intrinsic mode function, IMF)。一个恰当的 IMF 数量能够确保分解结果更具代表性,这对于精确提取行波特征尤为关键。另一方面, α 值则用于调节模态间的稀疏性和光滑性,合理设定其值能有效削弱模态间的相互干扰,从而更好地保留并突出行波局部特征。鉴于此,本文采用 APO 算法来优化 MVMD 中的参数 K 和 α ,适应度函数使用包络熵,包络熵的值越小,其包含输入特征信息越多。优化流程如图 2 所示。

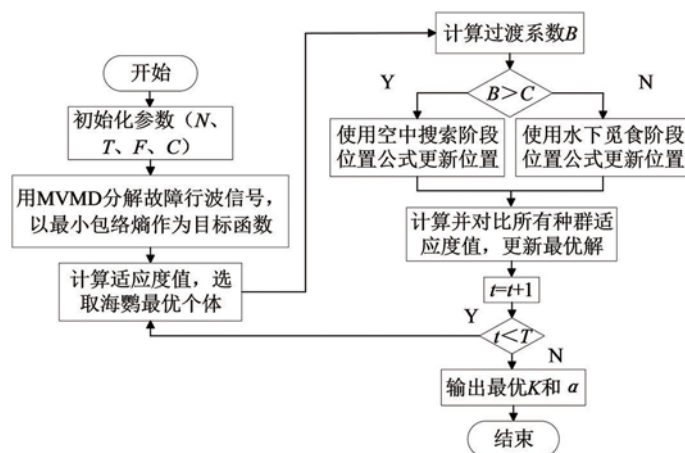


图2 APO-MVMD 流程图

Fig.2 Flow chart of APO-MVMD

2.4 基于 TEO 的故障行波特征提取

2.4.1 Teager 能量算子

TEO 是一种非线性算子,通过计算信号的瞬时能量值,实现信号奇异性的检测。对于离散的电缆故障行波信号 $f(n)$,其 TEO 可以表示为:

$$\varphi[f(n)] = [f(n)]^2 - f(n+1)f(n-1), \quad (22)$$

其中, φ 为能量算子。

2.4.2 故障行波特征提取流程

经过 APO 算法优化后, MVMD 获得了最佳的参数组合,利用 APO-MVMD 对故障行波信号进行分解,从而提取出多个 IMF 分量。在这些分量中,选择峭度值最高的 IMF 进行分析(峭度值的大小反映信号局部的非线性特征和突变程度,峭度值最大的模态分量即为用于电缆故障定位的特征模态分量)。对选定的 IMF 分量计算离散化的能量算子得到能量曲线,其首个波峰峰值所对应的时间点即为电缆故障行波首次到达检测点的确切时间。

3 基于 APO-Transformer 的电缆故障定位模型

3.1 Transformer 模型

Transformer 是一种基于自注意力机制的深度学习模型,主要由编码器(Encoder)和解码器(Decoder)两个部分组成,这两个部分都采用了多层堆叠的自注意力机制和前馈神经网络,其模型结构如图 3 所示。

编码器和解码器是 Transformer 模型的核心,由多个层组成,每层包含自注意力子层和前馈神经网络子层,使用残差连接和层归一化,在处理复杂的电缆故障信号时,能够有效防止梯度消失或爆炸,确保模型能够学习到更深层次的特征。解码器额外有掩码机制(Masking),确保输出只依赖于之前的输出,掩码机制能够模拟电缆故障信号的传播特性,提高定位的准确性。自注意力机制通过计算查询、键和值,确定它们之间的相关性得分,应用 softmax 函数得到注意力权重,捕捉电缆信号序列内部的依赖关系,然后加权求和得到输出。

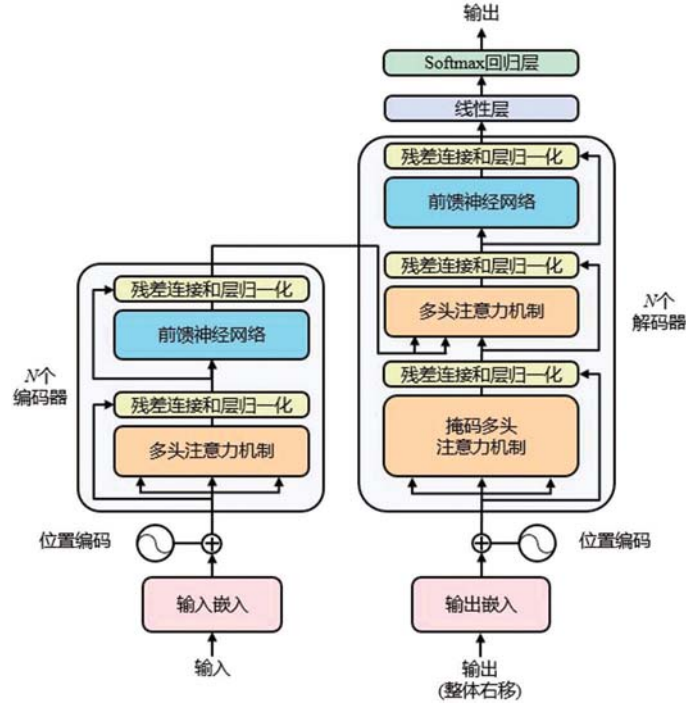


图 3 Transformer 模型结构图

Fig.3 Structure of the Transformer model

3.2 APO-Transformer 原理

在利用 Transformer 模型进行电缆故障定位时,模型的精度与效率受神经网络参数的影响。其中注意力机制头数影响 Transformer 信息分割和并行处理的能力。通过调整头数,可以优化模型对输入信息的捕捉与处理能力;正则化系数的大小直接影响了正则化效果的强弱,寻找一个合适的正则化系数,可以在保证模型性能的同时,减少模型对训练数据的过度依赖,提高模型的泛化能力;学习率决定模型在训练过程中参数更新的步长。一个合适的初始学习率可以加速模型的训练过程,同时避免模型陷入局部最优解。

因此,采用 APO 算法,对 Transformer 模型中的关键参数(注意力机制头数、正则化系数以及初始学习率)进行寻优,克服因参数选择不当导致的性能不稳定问题,进一步提升模型的泛化能力和定位精度,目标函数选择均方根误差,误差越小,说明模型采用此参数对电缆故障定位的精度越高。

3.3 基于 APO-MVMD-Transformer 的电缆故障定位流程

基于 APO 优化 MVMD 和 Transformer 的故障定位模型流程如图 4 所示。

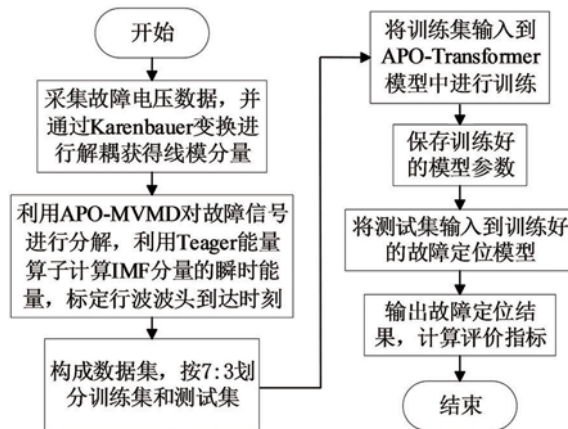


图 4 APO-MVMD-Transformer 定位模型流程图

Fig.4 Flow chart of the APO-MVMD-Transformer-based location model

4 仿真验证

电缆输电线路如图 5 所示,使用 Matlab/Simulink 搭建仿真模型,采用两极供电方式,设置电缆故障为 A 相接地短路故障,仿真时间为 0.15 s,故障发生时间为 0.05 s,过渡电阻为 0.1 Ω ,采样频率取 1 MHz。




图 5 电缆输电线路图

Fig.5 Diagram of cable power transmission

电缆总长度 L 为 100 km,电缆分布式参数见表 1。

表 1 电缆参数

Table 1 Cable parameters

正序电感/ (mH · km ⁻¹)	正序电阻/ (Ω · km ⁻¹)	正序电容/ (nF · km ⁻¹)	零序电感/ (mH · km ⁻¹)	零序电阻/ (Ω · km ⁻¹)	零序电容/ (nF · km ⁻¹)
0.933 7	0.45	12.74	4.124 6	0.74	7.75

4.1 故障特征提取

以 20 km 发生故障为例,用故障信号减去正常运行时的信号,得到故障行波信号,利用 Karenbauer 变换矩阵对故障行波信号进行相模变换,同时为了便于分析,取故障后 1 000 个采样点,得到独立的 α 模分量,如图 6 所示。


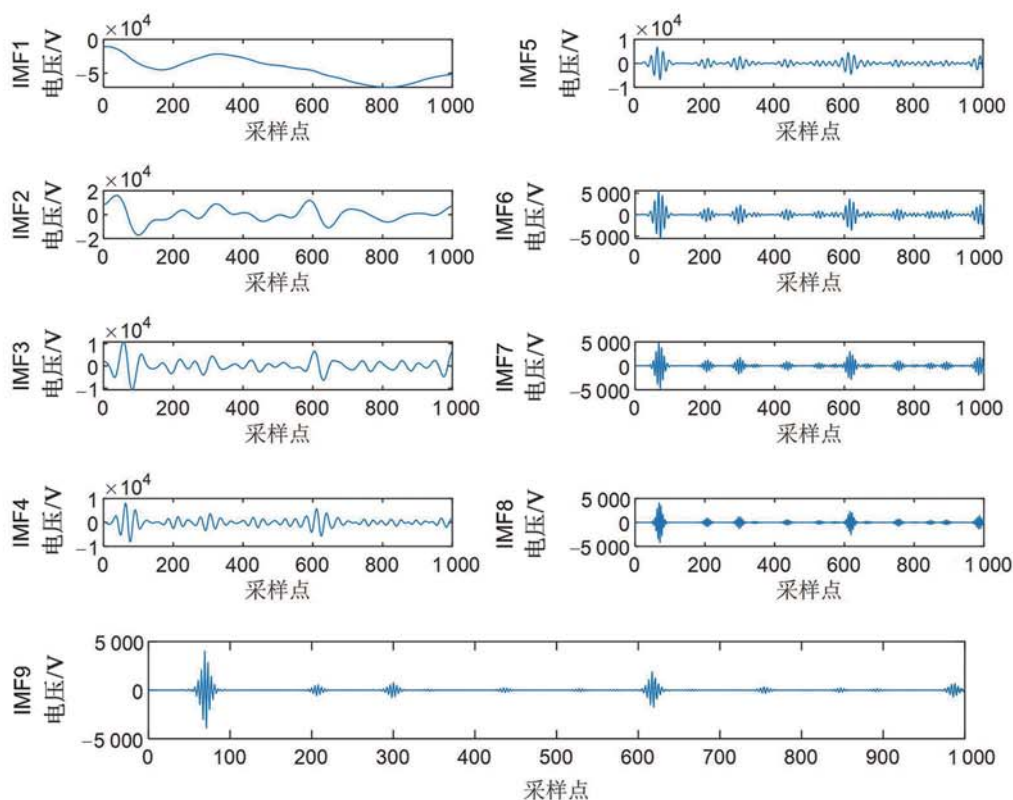


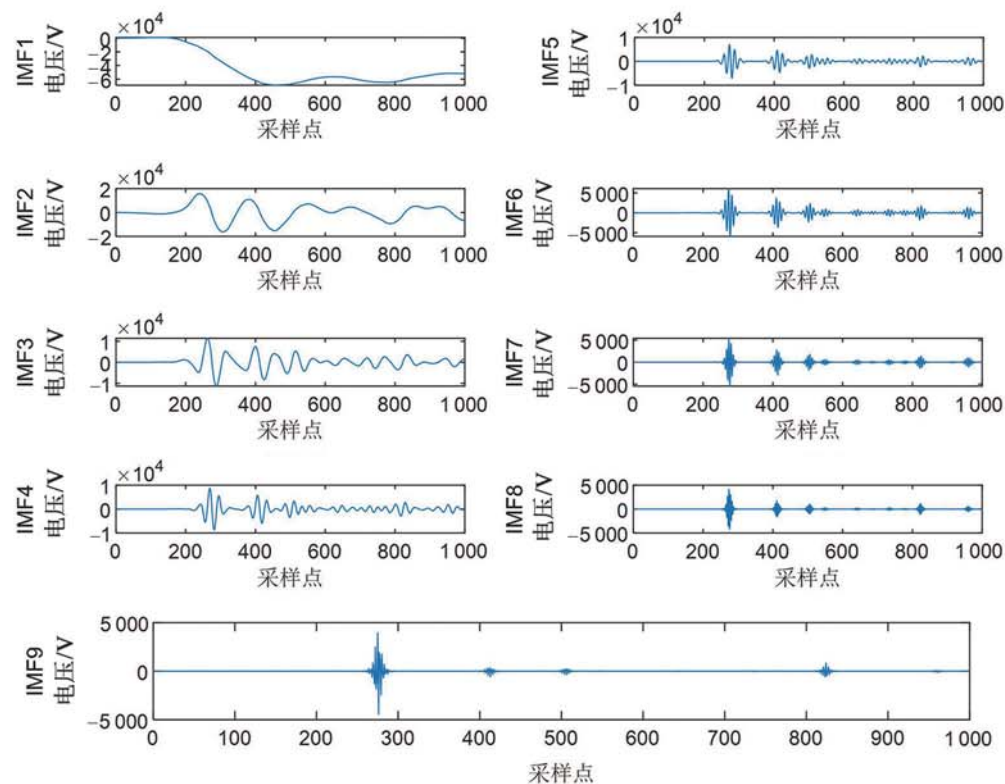
图 6 故障电压 α 模分量

Fig.6 Alpha-mode component of fault voltage

设置 APO 算法的种群规模为 20,最大迭代次数为 30 次,利用其对 MVMD 的参数进行寻优,得到最优 K 值为 9,最优 α 为 355,对故障电压 α 分量进行 MVMD 分解,结果如图 7 所示。



(a) L端故障电压 α 模分量分解



(b) R端故障电压 α 模分量分解

图 7 故障电压 α 模分量分解图

Fig.7 Breakdown of the alpha-mode component of fault voltage

随后计算各个分量的峭度,结果如表 2 所示,选取峭度值最大的分量进行分析。

表2 IMF分量峭度值

Table 2 IMF kurtosis value

IMF分量	L端峭度值	R端峭度值
IMF1	1.982 9	1.976 2
IMF2	3.662 0	3.150 9
IMF3	6.169 8	6.276 4
IMF4	7.326 5	11.034 5
IMF5	9.998 9	15.353 5
IMF6	13.883 1	22.654 6
IMF7	18.728 0	37.088 6
IMF8	32.247 4	59.094 4
IMF9	85.879 7	162.770 3

采用TEO计算L端和R端IMF9分量的能量曲线,并标定行波波头到达时刻,结果如图8所示。




图8 能量曲线图

Fig.8 Energy plots

重复上述操作,设置故障距离从0.5 km到50 km,以0.5 km为间隔,提取100组L端和R端故障行波波头对应的采样点,以采集到的采样点为特征值,故障距离为标签,构成电缆故障定位的特征数据集,按9:1划分训练集和测试集,输入到APO-Transformer定位模型中进行训练。

4.2 故障定位

利用APO算法对Transformer模型的参数进行优化,同样将种群数量设置为20,最大迭代次数设置为30,得到Transformer模型的注意力机制头数为6,初始学习率为0.0064,正则化系数为0.0001。

4.2.1 评价指标

为评估APO-Transformer模型在电缆故障定位中的表现,本研究采用以下4种评价指标:均方根误差(root mean square error, RMSE) E_{RMSE} 、平均绝对误差(mean absolute error, MAE) E_{MAE} 、平均绝对百分比误差(mean absolute percentage error, MAPE) E_{MAPE} ,以及决定系数 R^2 。公式如下所示:

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}, \quad (23)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|, \quad (24)$$

$$E_{\text{MAPE}} = \frac{1}{n} \left(\sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{\hat{y}_i} \right| \right), \quad (25)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\hat{y}_i - \bar{y}_i)^2}, \quad (26)$$

其中, \hat{y}_i 和 y_i 分别代表模型定位距离和实际故障距离。误差越小越接近于 0, R^2 越接近于 1, 则说明模型定位精度越高, 效果越好。

4.2.2 定位结果

训练集训练结果如图 9 所示。训练集的决定系数高达 0.999 91, 说明训练集的定位结果与实际故障距离基本吻合, 同时均方根误差 E_{RMSE} 仅为 0.134 01, 平均绝对误差 E_{MAE} 为 0.104 57, 平均绝对百分比误差 E_{MAPE} 更是低至 0.005 896 8, 这充分证明该故障定位模型具备极高的定位精度, 故障定位效果极为出色。




图 9 训练集定位结果图

Fig.9 Location results of the training set

测试集定位结果如表 3 所示。由表 3 可知, 测试集故障定位的误差均在 1% 以内, 远距离故障定位的误差在 0.1% 以内, 平均故障定位误差在 0.1 km 以内, 说明该模型故障定位精度极高。

表 3 测试集定位结果

Table 3 Location results of the test set

实际故障距离/km	模型定位结果/km	相对误差/%
5	4.956 9	0.862 0
10	9.945 7	0.543 0
15	14.978 9	0.150 7
20	19.967 7	0.161 5
25	25.059 8	0.239 2
30	30.038 6	0.128 7
35	35.027 4	0.078 3
40	40.035 7	0.089 3
45	44.989 7	0.022 9
50	49.958 6	0.082 8

4.3 故障定位影响因素

4.3.1 过渡电阻的影响

为了验证过渡电阻对本文所提故障定位方法的影响,将故障过渡电阻设置为 $1\ 000\ \Omega$ 。经 APO-MVMD-TEO 分解故障信号提取故障特征后,其能量曲线如图 10 所示。




图 10 $1\ 000\ \Omega$ 过渡电阻对应的能量曲线

Fig.10 Energy plots corresponding to $1\ 000\ \Omega$ transition resistance

由图 8 和图 10 可知,行波的瞬时能量值降低,但行波波头对应的采样点不变,说明高过渡电阻不会对本文所提电缆故障定位方法产生影响。

4.3.2 噪声的影响

为了评估噪声对本文故障定位方法的影响,向故障信号叠加 $30\ \text{dB}$ 的白噪声,以模拟真实环境中的信号采集情况。随后,采用小波去噪技术对含噪信号进行处理,并重复故障特征提取的步骤,得到去噪后的能量曲线,如图 11 所示。




图 11 $30\ \text{dB}$ 噪声对应的能量曲线

Fig.11 Energy plots corresponding to $30\ \text{dB}$ noise

由图 8 和图 11 可知,虽然能量曲线有较大波动,但仍可以获取行波波头对应的采样点,其中 L 端采样点没有变化,R 端采样点与之前相比仅相差 1,说明本文所提算法具有较强的抗噪能力。

4.3.3 故障类型的影响

为了验证其他故障类型对本文故障定位方法的影响,以 20 km 处发生 AB 相间短路(AB)、AB 短路接地(ABG)和 ABC 三相短路(ABC)3 种不同故障为例,重复上文故障特征提取流程,结果如表 4 所示。

表 4 不同故障类型下故障特征

Table 4 Fault characteristics of different fault types

故障距离/km	故障类型	故障特征
20	AB	(69,276)
	ABG	(69,276)
	ABC	(69,276)

由图 8 和表 4 可知,不同故障类型得到的故障特征相同,行波波头对应的采样点没有改变,说明本文所提方法不受故障类型的影响可泛化应用。

4.4 方法对比

从测试集中随机选择 5 个故障位置,将本文所提方法与其他方法进行对比,结果如表 5 所示。其中文献[5]、文献[10]和文献[9]分别对应表中的双端测距、BP 和 GA-BP 故障定位方法,Transformer 为本文未经参数寻优的定位方法。

表 5 各方法定位结果对比

Table 5 Comparison of the location results obtained using various methods

单位:m

实际故障距离	各方法定位误差绝对值				
	双端测距 ^[5]	BP ^[10]	GA-BP ^[9]	Transformer	本文方法
15 000	206.9	503.3	183.9	181.1	21.1
20 000	425.8	551.4	213.7	236.6	32.3
35 000	322.3	463.8	142.5	178.8	27.4
40 000	144.6	522.0	239.2	223.2	35.7
45 000	271.9	462.7	254.7	213.3	10.3

作为电缆故障定位的传统技术,双端测距的精度受限于行波速度的不稳定性以及对行波波头到达时刻的精确测定,而人工神经网络则不受这些因素的制约。其中 BP 神经网络虽然简单,但在处理复杂电缆故障数据时,难以捕捉数据间长期依赖性,通过引入优化算法虽然可能提高定位精度,但易陷入局部最优。而 Transformer 的自注意力机制能够捕捉不同尺度下的特征关联,提取出更具有区分性的特征,通过结合优化策略,Transformer 具有更强处理复杂关系的能力,从而在电缆故障定位上表现出更高的精度。

经过对比分析,本文提出的方法在定位精度方面显著高于其他方法,体现了基于 APO-MVMD-Transformer 的电缆故障定位方法的卓越性能。

5 结论

针对现有电缆故障定位的精度偏低和易受干扰的问题,本文提出了基于 APO-MVMD-Transformer 的电缆故障定位方法,经过仿真和对比较证,得出以下结论:

利用经 APO 算法寻优后的 MVMD 参数分解故障行波信号,再借助 TEO 算法计算能量曲线进而标定行波波头到达时刻,提高了行波波头标定的鲁棒性,为定位模型提供了可靠的数据。

利用 APO 算法优化 Transformer 模型的参数,得到最优参数组合,优化后的模型其训练集的决定系数高达 0.999 91,测试集的相对误差在 1% 以内,输出的故障定位距离误差在百米之内,提高了电缆故障定位的精度和准确度。

参考文献:

- [1] 詹惠瑜, 刘科研, 盛万兴, 等. 有源配电网故障诊断与定位方法综述及展望[J]. 高电压技术, 2023, 49(2): 660-671. DOI:10.13336/j.1003-6520.hve.20211604.
- [2] WANG X W, ZHANG H X, SHI F, et al. Location of single phase to ground faults in distribution networks based on synchronous transients energy analysis[J]. IEEE Transactions on Smart Grid, 2020, 11(1): 774-785. DOI:10.1109/TSG.2019.2938667.
- [3] 戴志辉, 王旭. 基于改进阻抗法的有源配电网故障测距算法[J]. 电网技术, 2017, 41(6): 2027-2034. DOI:10.13335/j.1000-3673.pst.2016.2043.
- [4] 彭浩, 沈兴来, 陈奎. 电缆单端故障测距的阻抗-行波组合法[J]. 电力系统保护与控制, 2016, 44(23): 110-114. DOI: 10.7667/PSPC152122.
- [5] 柴鹏, 周灏, 张煜, 等. 基于双端行波法的电缆线路短路故障定位改进[J]. 中国电力, 2020, 53(11): 168-174. DOI: 10.11930/j.issn.1004-9649.201901111.
- [6] SUN G, MA W, WEI S Q, et al. A fault location method for medium voltage distribution network based on ground fault transfer device[J]. Electronics, 2023, 12(23): 4790. DOI: 10.3390/electronics12234790.
- [7] 丁希鹏, 蔺怡, 于浩. 基于改进 HHT 的电缆故障定位研究[J]. 机电信息, 2022(20): 82-85. DOI: 10.19514/j.cnki.cn32-1628/tm.2022.20.021.
- [8] 谢李为, 柳祎璇, 曾祥君, 等. 基于 VMD 和 S 变换的多端输电线路故障定位[J]. 电力系统及其自动化学报, 2019, 31(2): 126-134. DOI: 10.3969/j.issn.1003-8930.2019.02.020.
- [9] 徐先峰, 马志雄, 姚景杰, 等. 基于小波变换和 GA-BP 神经网络的电力电缆故障定位[J]. 电气工程学报, 2024, 19(2): 146-155. DOI: 10.11985/2024.02.017.
- [10] 蒋原, 李擎, 冯茜, 等. 基于 BP 神经网络的直流电网故障定位与保护方法[J]. 高压电器, 2020, 56(8): 23-28. DOI: 10.13296/j.1001-1609.hva.2020.08.005.
- [11] 滕志鹏, 梁远升, 曾德辉, 等. 基于卷积神经网络的高压输电线路故障定位时域法[J]. 广东电力, 2021, 34(6): 1-9. DOI: 10.3969/j.issn.1007-290X.2021.006.001.
- [12] 李瑞灵, 高学军, 王灿, 等. 基于小波熵特征融合和 ISSA-BiTCN 的直流输电故障定位[J]. 科学技术与工程, 2024, 24(26): 11303-11313. DOI: 10.12404/j.issn.1671-1815.2400442.
- [13] 熊芮, 赵林军, 张宇航. 基于灰狼-粒子群算法的有源配电网故障定位[J]. 电力系统及其自动化学报, 2025, 37(5). DOI: 10.19635/j.cnki.csu-epsa.001501.
- [14] 商立群, 刘晗, 郝天奇, 等. 基于 IPOA-LSSVM 模型的高压直流输电线路故障定位[J]. 南京信息工程大学学报, 2024, 16(5): 667-677. DOI: 10.13878/j.cnki.jnuist.20231009002.
- [15] WANG W C, TIAN W C, XU D M, et al. Arctic puffin optimization: A bio-inspired metaheuristic algorithm for solving engineering design optimization[J]. Advances in Engineering Software, 2024, 195: 103694. DOI: 10.1016/j.advengsoft.2024.103694.

