

基于 BWO 优化 VMD 和 KELM 的柔性直流输电线路短路故障定位方法

赵岩, 王梓毅, 徐天

(黑龙江科技大学电气与控制工程学院, 哈尔滨 150022)

摘要: 针对行波波头标定的精度不足以及智能定位模型拟合性能易受参数影响的问题, 提出了一种基于白鲸算法优化变分模态分解和核极限学习机的柔性直流输电线路短路故障定位方法。首先, 采用白鲸算法优化变分模态分解的参数, 结合小波软阈值去噪方法对采集的故障信号进行降噪和分解, 再结合希尔伯特变换标定初始行波的到达时刻。其次, 将行波的到达时刻作为特征值构建特征数据集, 用白鲸算法优化核极限学习机定位模型。最后, 将数据集代入到优化后的定位模型中实现故障定位。结果表明, 该方法的定位模型拟合程度达到 99.4%, 具有较高的定位精度和较好的鲁棒性, 所提方法对噪声和过渡电阻的耐受性能较高, 定位误差在 500 m 以内。

关键词: 柔性直流输电线路; 变分模态分解; 白鲸算法; 核极限学习机; 故障定位

MMC-HVDC Transmission Line Short-Circuit Fault Location Method Based on BWO Optimized VMD and KELM

ZHAO Yan, WANG Ziyi, XU Tian

(School of Electrical and Control Engineering, Heilongjiang University of Science and Technology, Harbin 150022, China)

Abstract: Aiming at the lack of accuracy of traveling wave head calibration and the performance of intelligent location model affected by parameters, a short-circuit fault location method based on the beluga whale algorithm (BWO) is proposed to optimize variable mode decomposition (VMD) and kernel extreme learning machine (KELM) for MMC-HVDC transmission lines. Firstly, the BWO is used to optimize the parameters of VMD, combined with wavelet soft threshold denoising method for noise reduction and decomposition of the collected fault signals. Then the arrival moment of the initial traveling wave is calibrated by combining the Hilbert transform (HT). Next, the arrival moments of traveling waves are used as eigenvalues to construct the feature dataset. The KELM localization model is optimized using BWO. Finally, the dataset is substituted into the optimized localization model to achieve fault localization. The results show that the localization model of the method fits 99.4% with high localization accuracy and good robustness. The proposed method is highly tolerant to noise and transition resistance, and the localization error is within 500m.

Key words: MMC-HVDC transmission lines; variable mode decomposition (VMD); beluga whale algorithm (BWO); kernel extreme learning machine (KELM); fault location

0 引言

柔性直流输电线路作为电力系统领域的关键技术已在全球范围内得到广泛应用。由于直流线路长

距离输电以及气候条件和地区地形的多样性, 线路发生短路故障的概率较高, 故障排查难度较大。因此, 可靠、准确的输电线路短路故障定位技术变得至关重要^[1-4]。

故障定位方法有故障分析法、固有频率法和行波法^[5-6]。相对于前两种方法, 行波法的精度最高, 同时还具有不依赖线路参数、不易受外界干扰等优点, 使其应用更加广泛^[7]。

行波法的定位精度主要受两方面因素的影响,

基金项目: 国家自然科学基金资助项目(51677057); 黑龙江省省属高等学校基本科研业务费项目(2025-KYYWF-ZR0606)。

Foundation item: Supported by the National Natural Science Foundation of China (51677057); the Basic Scientific Research Project of Heilongjiang Provincial Colleges and Universities (2025-KYYWF-ZR0606)。

其一就是标定故障行波的精度。在直流输电线路中,行波的传播距离较长,传播过程中初始行波高频分量的幅值逐渐减小,造成畸变,采集终端难以捕获^[8-9]。为解决这一问题,文献[10]采用小波阈值降噪法对信号进行滤波,在此基础上,结合互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)和希尔伯特变换(Hilbert transform, HT)对行波进行标定,该方法不受噪声的影响,鲁棒性强,但CEEMD参数的选择受先验知识和经验的影响,可能会造成模态混叠现象,计算复杂度较高。文献[11]采用变分模态分解(variable mode decomposition, VMD)对信号进行处理,结合S变换的方法对行波进行标定,VMD算法能够有效克服分解信号模态混叠的影响,精度较高且不依赖先验信息,但其惩罚因子 α 和分解层数 K 需要预先设定,参数选取不当可能会造成行波频率模糊和行波信息丢失,影响行波标定的准确性和可靠性。为此,本文提出用白鲸算法(beluga whale optimization, BWO)优化VMD的参数,快速确定其最优参数,对故障信号进行分解,再结合小波软阈值去噪方法对初始信号进行去噪以及HT算法来标定行波到达时刻,提高了行波标定的精度和鲁棒性。将得到的时刻作为特征值,构建特征数据集。

其二就是由于趋肤效应和线路频变特性引起的波速误差^[12]。近些年来智能算法的应用降低了计算难度,且大多数智能算法均能够克服波速衰减对定位的影响^[13-14]。文献[15]利用极限学习机(extreme learning machines, ELM)来实现故障定位,克服了波速衰减的问题,定位精度和效率都比较高,但需要大量的数据作支撑。文献[16]提出了一种基于核极限学习机(kernel extreme learning machine, KELM)的故障定位方法,在学习速度、测量精度和泛化能力等方面得到极大的提高,在小样本数据中依旧保持较高精度,但参数 σ 和惩罚系数 C 会影响KELM定位模型的拟合性能,容易导致模型输出的定位结果误差较高,影响其定位精度。因此,本文提出BWO算法优化KELM故障定位模型,能够提高定位模型的适应度和拟合性能,将特征数据集带入模型中,输出的定位结果精度更高。

综上,提出基于BWO优化VMD和KELM的柔性直流输电线路短路故障定位方法,能够更快、

更全面地找到VMD和KELM模型的最优参数,提高了故障行波标定的精度和鲁棒性,同时也提高了定位模型的拟合性能。本文研究以张北 ± 500 kV柔性直流输电系统为背景,以其实际的系统参数为依据,利用PSCAD软件建立仿真模型,提取了故障数据,并运用MATLAB软件对这些数据进行了深入处理。通过对定位方法验证,结果显示本文方法在定位精度和鲁棒性方面具有显著优势。

1 短路故障行波提取

1.1 柔性直流输电系统建模

以图1系统原理图为基础,根据表1—2中的输电系统的实际参数,在PSCAD/EMTDC软件中建立仿真模型。系统使用了双极运行方式,其中 L_{ij} 表示平波电抗器, R_{ij} 表示行波测量装置。故障点F1表示正极接地短路故障的发生点。本文重点研究了康宝站至丰宁站输电线路发生的这类故障。




图1 柔性直流输电系统仿真原理图

Fig. 1 Simulation schematic of MMC-HVDC transmission system

1.2 故障行波分析

在双极直流输电线路出现短路故障时,由于正负极信号间存在耦合^[17],因此采用了凯伦贝尔变换矩阵来进行解耦处理,解耦公式如式(1)所示:

$$\begin{bmatrix} u_0(t) \\ u_1(t) \end{bmatrix} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} u_+(t) \\ u_-(t) \end{bmatrix} \quad (1)$$

式中: $u_0(t)$ 为解耦后零模电压分量; $u_1(t)$ 为解耦后线模电压分量; $u_+(t)$ 、 $u_-(t)$ 分别为正、负极电压。

鉴于线模电压分量在线路传输过程中的衰减速度相对于零模电压分量要缓慢,且线模分量更能突出突变量的幅值变化,因此,本文决定将线模电压

分量作为研究对象。

如图 2 所示,在故障发生后的 40 ms 时间里,观察得到的线模电压行波信号,其采样频率设置为 100 kHz。从时域的视角来看,故障行波呈现了故障发生的时间以及行波的波动特性变化。而在频域的角度来分析,故障行波能反映出周期性的频谱特性,在传输过程中可能会因各种因素的干扰,造成不同频率段的信号幅值的衰减。




图 2 线模电压行波信号

Fig. 2 Line-mode voltage traveling wave signal

在行波提取的过程中,若过渡电阻越大,故障行波的幅值变得就越小,就越容易受到各种因素的影响,从而越难准确标定故障行波的波头。不同过渡电阻环境下的故障行波如图 3 所示。




图 3 不同过渡电阻下的故障行波

Fig. 3 Traveling waves with different transition resistors

由图 3 可以看出,随着过渡电阻的不断变大,故障行波的幅值变得就越小,变化越明显。以 300 Ω 的过渡电阻为例,与 1 Ω 过渡电阻状况对比,故障行波的峰值减少了 50 %。

2 基于 BWO-VMD-HT 的行波标定

2.1 VMD 原理

VMD 算法的目的是把原始信号分解为 K 个本征模态函数分量 (intrinsic mode functions, IMF)。VMD 的数学公式^[18-19]为:

$$\begin{cases} f = \sum_{k=1}^K \mu_k \\ \min_{\{\mu_k\}, \{\omega_k\}} \left\| \sum_{k=1}^K \partial_t \left(\left(\delta(t) + \frac{j}{\pi t} \right) \times \mu_k(t) \right) e^{-j\omega_k t} \right\|_2^2 \end{cases} \quad (2)$$

式中: f 为原始信号; $\{\mu_k\}$ 为分解后的模态分量数组; $\delta(t)$ 为脉冲函数; $\{\omega_k\}$ 为模态分量中心频率构成的集合。

引进 Lagrange 乘子 λ 和惩罚因子 α , 得到:

$$\begin{aligned} L(\{\mu_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left(\left(\delta(t) + \frac{j}{\pi t} \right) \times \mu_k(t) \right) e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_k \mu_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k \mu_k(t) \right\rangle \end{aligned} \quad (3)$$

式中: ∂_t 表示时间变量 t 的一阶偏导数; $\mu_k(t)$ 、 $\lambda(t)$ 、 $f(t)$ 分别为时间变量下的模态分量、Lagrange 乘子和原始信号; $\langle x, y \rangle$ 表示 x 与 y 的内积。

基于式 (4) 来更新 μ_k 和 ω_k 。然后再通过 Fourier 反变换将 $\mu_k(\omega)$ 变换成 $\mu_k(t)$ 。通过设置迭代停止条件完成 VMD 分解, 得到 K 个 IMF 分量。

$$\mu_k^{n+1}(\omega) =$$

$$\frac{f(\omega) - \sum_{i < k} \mu_i^{n+1}(\omega) - \sum_{i > k} \mu_i^{n+1}(\omega) + \frac{\lambda^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (4)$$

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

式中: ω 为频域变量; μ_k^{n+1} 为 k 个模态分量第 $n+1$ 次迭代; $\mu_k^{n+1}(\omega)$ 、 $f(\omega)$ 和 $\lambda^n(\omega)$ 分别为经 Fourier 变换后的 $\mu_k^{n+1}(t)$ 、 $f(t)$ 和 $\lambda^n(t)$ 在第 n 次迭代。

2.2 BWO 原理

BWO 算法是一种模拟白鲸种群行为的群智能优化算法。该算法收敛速度快, 有很强的全局巡游能力, 能够有效解决局部最优的问题^[20]。

BWO 算法能够由探索转向开发, 这取决于平衡因子 B_f , 其定义为:

$$B_f = B_0 \left(1 - \frac{T}{2T_{\max}} \right) \quad (6)$$

式中: T 为当前迭代次数; $T_{\max}$ 为最大迭代数量; B_0 为每一次迭代时 (0, 1) 之中随机改变。

当 B_f 大于 0.5 时处于探索阶段, 而 B_f 小于 0.5 时为开发阶段。在探索阶段, 白鲸位置以式 (7)

更新。

$$\begin{cases} X_{i,j}^{T+1} = X_{i,pj}^T + (X_{r,p1}^T - X_{i,pj}^T)(1 + r_1)\sin(2\pi r_2), j = \text{偶数} \\ X_{i,j}^{T+1} = X_{i,pj}^T + (X_{r,p1}^T - X_{i,pj}^T)(1 + r_1)\cos(2\pi r_2), j = \text{奇数} \end{cases} \quad (7)$$

式中: $X_{i,j}^{T+1}$ 为白鲸在 j 维度的新位置; P_j 为从 d 维中的随机整数; $X_{i,pj}^T$ 为白鲸在 P_j 维度上的位置; $X_{i,pj}^T$ 、 $X_{r,p1}^T$ 为白鲸的两个当前位置; r 为随机选择的白鲸; r_1 、 r_2 为 $(0, 1)$ 中的随机数, 增强了探索阶段的随机性; $\sin(2\pi r_2)$ 和 $\cos(2\pi r_2)$ 为白鲸依据选定的偶数或奇数来调整其新位置, 反映了白鲸在游泳过程中的同步性和镜像动作。

在开发阶段引入 Levy 飞行策略以提高收敛性。按式(8)更新位置。

$$X_i^{T+1} = r_3 X_{\text{best}}^T - r_4 X_i^T + C_1 L_F(X_i^T - X_{\text{best}}^T) \quad (8)$$

式中: X_i^T 、 X_r^T 分别为第 i 条白鲸以及随机白鲸 r 的位置; X_i^{T+1} 为第 i 条白鲸的最新位置; X_{best}^T 为白鲸的最优位置; r_3 、 r_4 为 $(0, 1)$ 范围内的随机数; L_F 为 Levy 飞行函数; C_1 为其阶级跳跃强度。

Levy 飞行函数 L_F 和其阶级跳跃强度 C_1 计算公式如式(9)—(11)所示。

$$C_1 = 2r_4 \left(1 - \frac{T}{T_{\max}}\right) \quad (9)$$

$$L_F = 0.05 \times \frac{u \times \sigma}{|v|^{1/\beta}} \quad (10)$$

$$\sigma = \left(\frac{\Gamma(1 + \beta) \times \sin(\pi\beta/2)}{\Gamma((1 + \beta)/2) \times \beta \times 2^{(\beta-1)/2}} \right) \quad (11)$$

式中: $\Gamma(x)$ 为伽马函数; u 、 v 为正态分布随机数; $\beta=1.5$ 。

算法还要经过“鲸落”阶段来得到最优的参数, 鲸鱼坠落概率 W_f 为线性函数, 其表达式为:

$$W_f = 0.1 - \frac{0.05T}{T_{\max}} \quad (12)$$

使用白鲸位置和鲸鱼坠落的步长 X_{step} 来设置新的位置, 如式(13)—(14)所示。

$$X_1^{T+1} = r_5 X_1^T - r_6 X_r^T + r_7 X_{\text{step}} \quad (13)$$

$$X_{\text{step}} = (u_b - l_b) \exp\left(-\frac{C_2 T}{T_{\max}}\right) \quad (14)$$

式中: r_5 、 r_6 和 r_7 为 $(0, 1)$ 范围内的随机数; C_2 为鲸鱼种群数量下降的概率与种群相关的阶级因子; u_b 、 l_b 分别为变量的上下限。

2.3 BWO-VMD优化原理

VMD 分解信号时的惩罚因子 α 以及分解层数 K

均需事先设定, K 值决定了信号被分解为多少组 IMF 分量, 合适的 IMF 数量可以使得分解结果更具有代表性, 能够充分反映信号中存在的不同频率和振幅成分, 有利于更精确地提取出行波的特性。 α 值能够控制模态之间的稀疏性和光滑性, 适当选择其值能够有效减少模态间的干扰, 更好地保留和凸显行波等局部特征。因此, 本文采用 BWO 对 VMD 的参数 α 与 K 进行优化。

信号的包络熵值反映了信号的复杂程度, 因此选择最小包络熵来作为优化过程中的目标函数。先使用 VMD 算法对信号进行了分解, 再计算每个 IMF 分量的包络熵, 如式(15)所示。

$$\begin{cases} E_i = -\sum_{j=1}^N P_{i,j} \lg P_{i,j} \\ P_{i,j} = a_i(j) / \sum_{j=1}^N a_i(j) \end{cases} \quad (15)$$

式中: i 为原始信号经分解后的 IMF 层数; E_i 为第 i 个 IMF 分量的包络熵; $P_{i,j}$ 为经归一化处理后的 $a_i(j)$ 数据; $a_i(j)$ 为经 HT 变换后的 IMF 分量的包络信号。

按照 BWO 算法的流程不断更新 VMD 的参数值, 来刷新分解信号的最小包络熵值, 以此来实现参数的优化。优化流程如图 4 所示。




图4 BWO-VMD优化流程

Fig. 4 BWO-VMD optimization process

2.4 行波标定流程

故障行波波头标定包括3步: 首先, 采用去噪方法对电压行波信号进行预处理, 其次, 对信号进

行BWO-VMD分解,获得由高至低频带排序的IMF分量,最后,采用希尔伯特变换对IMF1分量进行处理,得到其瞬时频率曲线,从而标定出故障行波波头的具体到达时刻。

在实际应用环境中,收集到的故障信号常常含有噪声成分,针对这一点,本文选择了小波软阈值去噪方法,来降低噪声对定位精度的影响。针对电压行波信号为一维的信号,采用一维噪声消除函数wden对其进行小波分解,小波类型选择db2小波,从而获得小波系数。然后再用自适应的SURE阈值方法结合软阈值函数对各小波系数进行处理,从而实现去噪的目的。

经BWO的优化处理后,VMD获得了最优的参数设置,并对信号进行了分解,从而获得了多个IMF分量。IMF分量按照频率范围从高到低进行了排序,其中IMF1分量的频率幅值最高,并且包含了大量的故障信息。因此,本文选择对IMF1分量进行分析处理,并采用希尔伯特变换方法来获取IMF1分量的时频图。

把IMF分量 $C_i(t)$ 进行HT得到 $\hat{C}_i(t)$,用于构造解析函数。

$$\hat{C}_i(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{C_i(\tau)}{t - \tau} d\tau \quad (16)$$

再创造新的时间序列 $Z_i(t)$ 。

$$Z_i(t) = C_i(t) + j\hat{C}_i(t) = A_i(t)e^{j\theta_i(t)} \quad (17)$$

$$\begin{cases} A_i(t) = \sqrt{C_i^2(t) + \hat{C}_i^2(t)} \\ \theta_i(t) = \arctan \frac{C_i(t)}{\hat{C}_i(t)} \\ f_i(t) = \frac{1}{2\pi} \cdot \frac{d\theta_i(t)}{dt} \end{cases} \quad (18)$$

式中 $A_i(t)$ 、 $\theta_i(t)$ 和 $f_i(t)$ 分别为第 i 个IMF分量的瞬时幅值、瞬时相位以及瞬时频率。

故障行波的到达时刻与时频图上第一个突变点的时间一致。将这个提取到的到达时刻作为特征值,用于构建数据集,以便定位模型的训练和验证。

3 基于BWO-KELM故障定位模型

3.1 KELM原理

KELM是在ELM的基础上引入了核函数。相比于传统的ELM,KELM具有更强的泛化能力,同

时还保留了ELM的实时性,使其在实际应用中表现更加出色^[21]。

ELM模型的矩阵形式如下。

$$H\beta = T \quad (19)$$

式中: H 为隐含层的输出矩阵; β 为隐含层与输出层之间的权重; T 为预测的输出结果。

添加最小二乘法,解得 β :

$$\beta = H^+T = H^T(H^TH)^{-1}T \quad (20)$$

式中 H^+ 为 H 的广义逆矩阵。则

$$\begin{cases} h(x_i) = [h(\omega_i \cdot X_1 + b_1) \cdots g(\omega_m \cdot X_m + b_m)] \\ H^TH = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_n) \end{bmatrix}_{n \times m}^T \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_n) \end{bmatrix}_{n \times m} \\ = \begin{bmatrix} h(x_1) \cdot h(x_1) & \cdots & h(x_1) \cdot h(x_n) \\ \cdots & \cdots & \cdots \\ h(x_n) \cdot h(x_1) & \cdots & h(x_n) \cdot h(x_n) \end{bmatrix} \end{cases} \quad (21)$$

式中: m 为输出维度; ω_m 为KELM第 m 个隐层神经元的权重向量; X_m 为第 m 个特征向量; b_m 为第 m 个隐层神经元的偏置; $h(x_i) \cdot h(x_j)$ 表示 $h(x)$ 内积,以此来建立核函数 $K(u, v)$,即 $K(x_i, x_j)$,从而代替了 H^TH ,构建KELM模型的核矩阵 $\Omega_{ELM}(i, j)$ 。

$$\Omega_{ELM}(i, j) = h(x_i) \cdot h(x_j) = K(x_i, x_j) \quad (22)$$

引入惩罚系数 C 到式(23),来增强KELM模型的稳定性,并计算输出权值。

$$\beta^* = H^T \left(H^TH + \frac{1}{C} \right)^{-1} T \quad (23)$$

则KELM模型输出函数 $f_m(x)$ 为:

$$f_m(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_n) \end{bmatrix}^T \left(\Omega_{ELM} + \frac{1}{C} \right)^{-1} T \quad (24)$$

3.2 BWO-KELM原理

由于参数 σ 和惩罚系数 C 会对KELM模型的拟合性能造成影响,选择合适的参数有助于提高模型的泛化能力和学习能力,进而提高故障定位的准确度和可靠性。引入白鲸优化算法对模型参数进行优化。

优化过程中,先选择初始参数,构建KELM模型,然后对训练集进行训练,并计算训练集训练结果的最小绝对误差。然后刷新参数,继续训练,计算最小绝对误差,不断刷新最小绝对误差,直到满

足优化截止条件。训练集的最小绝对误差 M_{AE} 计算公式为:

$$M_{AE} = \frac{1}{N} \sum_{i=1}^N |t_i - f(x_i)| \quad (25)$$

式中: N 为训练集中样本的数量; t_i 为第 i 个样本的真实目标值; $f(x_i)$ 为第 i 个样本在 KELM 模型下的预测输出值。

KELM 的参数优化流程与图 4 类似, 采用模型训练集的最小绝对误差作为适应度函数。

4 基于BWO-VMD-KELM的故障定位流程

基于 BWO 优化的 VMD 和 KELM 的故障定位模型流程如图 5 所示。




图 5 基于BWO优化的VMD和KELM的故障定位流程
Fig. 5 Fault location flow of VMD and KELM based on BWO optimization

- 基本流程如下。
- 1)通过PSCAD平台仿真, 对输电线路的正负极故障电压信号进行采样, 得到故障电压行波信号。
 - 2)基于凯伦贝尔相模变换方法提取线模电压信号。再利用小波软阈值方法对线模电压信号进行去噪。
 - 3)使用BWO对VMD进行优化, 对信号进行分解, 得到高频段的IMF1分量, 再使用HT来标定故障行波波头的到达时刻。

4)按照第 1、2、3 步构造实验的数据集, 然后将数据集按 9: 1 比例进行分割成训练集和验证集, 输入模型进行训练验证。

5)利用训练集对 BWO-KELM 进行训练, 加快网络收敛速度, 保存训练结构及权重参数。

6)用验证集去验证模型的性能, 计算指标, 再将测试集代入已训练好的模型, 输出定位结果。

5 仿真验证

以图 1 展示的直流输电系统搭建仿真模型, 来检验本文所提定位方法的有效性, 系统的参数参考并对照文献[9]中的实际参数, 如表 1 所示, 输电线路参数如表 2 所示。实验环境为电脑 Windows10 64 位操作系统, Intel Core i7 处理器, NVIDIA GeForce GTX 1050 显卡, PSCAD4. 6. 0 版本仿真软件和 MATLAB R2023a 信号处理软件。

表 1 电网系统参数 Tab. 1 Parameters of the grid system				
类别	名称	额定电压/ kV	线路长度/km	直流电抗器/ mH
输电线路	Line1	±500	207	200
	Line2		49. 5	300
	Line3		176. 5	200
	Line4		189. 6	200
类别	名称	作用	额定功率/MW	控制策略
换流站	MMC1	送电端	1 500	定有功功率
	MMC2	送电端	3 000	定有功功率
	MMC3	调节端	1 500	定直流电压
	MMC4	受电端	3 000	定有功功率
其他	子模块电容/mF		桥臂子模块数量	
	15		100	

仿真总时长为 10 s, 在第 5 s 时, Line1 处发生单极接地故障, 利用 R_{AB} 点测得的数据进行了单端故障定位。筛选出了故障发生后 40 ms 的电压行波数据, 采样频率为 100 kHz。采集信号时, 在不同过渡电阻条件下 (1 Ω, 10 Ω, 50 Ω, 100 Ω, 200 Ω, 300 Ω), 从距离 R_{AB} 1 km 处开始, 每隔 1 km 采集一次数据, 直到距 R_{BA} 1 km 处结束, 共计收集了 1 242 组电压样本数据。

5.1 行波提取验证

为了充分说明 BWO-VMD-HT 方法的优势, 以故障发生在 100 km 的位置为例, 从优化算法、算

表 2 输电线路参数

Tab. 2 Transmission line parameters

参数名称	数值
架空线高度/m	33.5
输电线路间距/m	22.2
地线距架空线高度/m	16.5
地线的间距/m	18.2
输电线路的导线分裂数	6
分裂导线的外径/m	0.013 084
分裂导线的间距/m	0.45
架空线直流电阻/($\Omega \cdot \text{km}^{-1}$)	0.046 33
地线外径/m	0.005 524 5
地线直流电阻/($\Omega \cdot \text{km}^{-1}$)	0.709 8

法降噪和分解性能方面进行了验证和分析。

首先,利用第2节中的BWO算法对VMD参数进行优化。其中种群大小设置为10,最大迭代次数为30,参数 α 和 K 的取值范围分别为 $[10, 5\ 000]$ 、 $[3, 10]$,最终得到最优参数(α, K)为(66, 4)。

其次,对图2中的线模电压波形进行VMD分解,分解结果如图6所示。通过对高频分量IMF1、IMF2的观察可以发现BWO-VMD的方法能够凸显出原始信号中的突变性,从而有益于更加精确地提取到突变点,进而实现波头标定。




图6 VMD分解效果图

Fig. 6 VMD decomposition effect

最后,使用Hilbert变换处理IMF1高频分量,波头标定结果如图7所示。可见IMF1时频图的首个突变点对应的时刻为 $t=0.000\ 33\ \text{s}$ 。说明BWO-VMD-HT波头标定方法可以精确检测到故障行波到

达测量端的首个波头时刻。




图7 故障行波标定结果

Fig. 7 Faulty traveling wave calibration results

重复上述操作,提取1 242组故障行波信号的波头达到时刻,形成特征数据集。将这些数据集按9:1的比例划分为训练集和验证集,并输入到定位模型中进行训练。

5.1.1 优化算法对比

为体现BWO算法优化VMD的优越性,在相同条件下,与灰狼算法(grey wolf optimization, GWO)、鲸鱼算法(whale optimization algorithm, WOA)以及粒子群算法(particle swarm optimization, PSO)等优化VMD进行比较,收敛曲线与寻优时间如图8所示,结果表明BWO算法在收敛速度方面具有很大的优势,能够更快找到最优的VMD参数。




图8 不同优化算法的参数优化曲线

Fig. 8 Optimization curves of different optimization algorithms

5.1.2 噪声对行波标定的影响

在实际应用中,故障信号常受到噪声的影响。为应对这一挑战,本文采用小波软阈值去噪方法,以减小噪声对定位精度的干扰。为了验证该方法的去噪效果,以故障位置为100 km的单极接地短路故障为例,信号添加40 dB的白噪声。去噪前后的效果以及VMD分解结果如图9所示。




图9 去噪前后信号分解效果对比

Fig. 9 Comparison of decomposition effect before and after denoising

根据图9的结果显示,采用小波软阈值去噪方法可以有效抑制白噪声,观察到去噪后的信号质量得到了显著提升,噪声干扰明显减小,进而改善了VMD的分解效果,使得波头到达时刻的确定更加精确。在不同白噪声环境下行波标定精度如图10所示。




图10 不同噪声下的行波标定

Fig. 10 Traveling wave calibration under different noises

从图10可以看出,在50 dB噪声环境下行波标定出现了一点误差,但仍能准确标定行波的到达时刻,具有较强的抗噪性能。

考虑到白噪声与故障行波信号的差距较大,很容易就能去噪,因此,在此基础上,本文又加入了与故障行波信号相似的雷电波噪声来验证波头标定方法的可行性,雷电波噪声信号对照参考文献[22]生成。加噪后的行波信号、VMD分解效果以及波头标定结果如图11所示。




图11 雷电波噪声下的波头标定结果

Fig. 11 Wave head calibration results under lightning wave noise

从图11可以看出,加入雷电波噪声后的故障新波信号的波形变化明显,但VMD方法仍可以有效分解信号,最后依然可以准确标定波头的到达时刻,说明波头标定方法的耐噪声能力较强,同时还为后续定位模型的训练提供了更高精度的数据集。

5.1.3 过渡电阻对行波标定的影响

为了检验本文所提方法在高过渡电阻环境下对波头标定的准确性,本文在过渡电阻为300 Ω 的条件下引入了30 dB的白噪声。图12展现了在300 Ω 过渡电阻环境下添加30 dB白噪声的故障电压行波与无噪声且过渡电阻为0.01 Ω 环境下的原始故障行波信号进行了对比。从图12中可以清晰地观察

到行波的幅值有所减小,同时加入的噪声也对行波的标定产生了一定程度的干扰。对 $300\ \Omega$ 的行波信号进行波头标定流程处理,去噪前后的结果如图 13 所示,可以看出即使在 $300\ \Omega$ 过渡电阻的环境中,该行波标定方法依然可以准确地标定行波波头。




图 12 $300\ \Omega$ 过渡电阻 (30 dB) 与 $0.01\ \Omega$ 过渡电阻的故障行波

Fig. 12 Faulty traveling wave with $300\ \Omega$ transition resistor (30 dB) and $0.01\ \Omega$ transition resistor




图 13 $300\ \Omega$ 过渡电阻 (30 dB) 故障行波去噪前后波头标定
Fig. 13 Wave head calibrations before and after denoising of $200\ \Omega$ transition resistor (30 dB) faulty traveling wave signal

5.2 故障定位验证

利用 BWO 对 KELM 的参数进行优化。种群数和最高迭代次数分别设置为 30 和 100,而参数 σ 和 C 的取值范围都设置成 $[0.01, 100]$ 。优化后的模型,训练集的预测拟合度 R^2 为 99.4%,平均误差 e_{ME} 为 0.016 4%。验证集的回归拟合曲线如图 14 所示。输出的定位点距离轴线 $y=x$ 的偏差越小,意味着定位模型的回归拟合效果越出色。由图 14 所示,输出的定位结果与实际故障的距离几乎完全重合,说明模型具有很高的拟合性能,其输出的定位误差较小。

按照训练集的数据采集标准,采集 45 组测试集样本数据。将测试集输入训练好的故障定位模型,定位结果如表 3 所示。




图 14 输出的故障定位回归拟合线

Fig. 14 Output fault localization regression fitting line

表 3 故障定位结果

Tab. 3 Fault location results

故障位置/km	过渡电阻/ Ω	定位结果/km	($\pm$)误差/km
10.5	0.01/80/140/210/300	10.2163	0.284
30.5	0.01/80/140/210/300	30.5945	0.095
50.5	0.01/80/140/210/300	50.3567	0.143
80.5	0.01/80/140/210/300	80.2756	0.224
110.5	0.01/80/140/210/300	110.2073	0.293
130.5	0.01/80/140/210/300	130.3253	0.175
160.5	0.01/80/140/210/300	160.2789	0.221
190.5	0.01/80/140/210/300	190.7554	0.255
205.5	0.01/80/140/210/300	205.7349	0.235

由表 3 可以看出:针对不同过渡电阻,测试集输出的定位结果平均误差为 500 m 以内,精度较高。

5.2.1 定位模型性优化对比

对于 KELM 定位模型的参数优化,与 GWO 和 PSO 优化算法进行对比,3 种算法的收敛速度以及适应度曲线如图 15 所示。从图 15 中明显可见,与 GWO 和 PSO 相比 BWO 在收敛速度和寻优精度两方面具有明显优势,表现更佳。

将本文提出的基于 BWO-KELM 的定位模型与 ELM、KELM、PSO-KELM 以及 GWO-KELM 定位模型进行了详细的比较分析。为确保实验的公正性,使用相同的数据集对各模型进行训练和测试。各模型的平均误差(MAE)、均方误差(RMSE)、平均百分比误差(MAPE)如图 16 所示。选择随机 6 个故障位置,在不同定位模型中的定位误差如图 17 所示。




图15 优化KELM模型的算法对比

Fig. 15 Comparison of algorithms for optimizing KELM




图16 不同定位模型的误差

Fig. 16 Error of different localization models




图17 不同定位模型定位的绝对误差

Fig. 17 Absolute errors in localization of different positioning models

5.3 与其他文献方法比较

将本文提出的方法与其他文献中的方法作了比较,如表4所示。

表4 与其他文献方法比较结果

Tab. 4 Results comparison with other methods in the literature

定位方法	误差范围	抗噪性能/dB	耐过渡电阻能力/ Ω
本文方法	0.5 km 以内	50	300
文献[10]	0.8 km 以内	40	200
文献[23]	小于 1.41 km		100
文献[14]	小于 1.08 km		300

本文所提的方法与上述文献方法进行对比,在定位精度方面最为突出,平均误差在 500 m 以内,抗噪声干扰的能力可达到 50 dB,耐过渡电阻可达到 300 Ω ,鲁棒性强。综合对比,所提方法可用于长距离输电线路的故障定位,抗干扰能力较强,且定位精度最高。

6 结论

针对柔性直流输电线路中定位方法的精度易受行波标定以及智能定位模型参数选取的影响,本文提出了一种BWO优化VMD和KELM的柔性直流输电线路短路故障定位方法,通过大量的仿真验证,得出以下结论。

1)用BWO算法对VMD的参数进行优化,获取最优参数,能够有效提高信号分解和参数寻优的效率。与PSO、GWO和WOA等算法进行对比,BWO算法的收敛速度最快,优化后的VMD分解性能最优。结合小波软阈值去噪方法提高了行波标定的鲁棒性,确保了定位模型数据集的精度。

2)用BWO算法对KELM定位模型的参数进行优化,优化后模型拟合程度达到99.4%,验证集的平均误差为0.0164%,输出的定位结果误差在500 m以内,精度较高。

参考文献

- [1] 束洪春,杨竞及,张广斌.高压直流输电线路的双端行波频差比值故障测距[J].中国电机工程学报,2022,42(18): 6715-6727.
SHU Chunhong, YANG Jingji, ZHANG Guangbin. A novel fault-location method for HVDC transmission lines based on the ratio of two-terminal traveling wave frequency difference [J]. Proceedings of the CSEE, 2022, 42(18): 6715-6727.
- [2] 宋国兵,侯俊杰,郭冰.基于主动探测式的混合MMC直流输电系统单端量故障定位[J].电网技术,2021,45(2): 730

- 740.
- SONG Guobing, HOU Junjie, GUO Bing. Single-ended fault location of hybrid MMC-HVDC system based on active detection[J]. Power System Technology, 2021, 45(2): 730 – 740.
- [3] 王建元, 张宇辉, 刘钺. 基于参数优化 VMD 和改进 K 聚类判据融合的配电网故障选线方法[J]. 南方电网技术, 2023, 17(7): 135 – 145.
- WANG Jianyuan, ZHANG Yuhui, LIU Cheng. Fault line selection method of distribution network based on the fusion of parameter optimized variational modal decomposition and improved K clustering criterion[J]. Southern Power System Technology, 2023, 17(7): 135 – 145.
- [4] 李静正, 杜晓通, 李猛. 海上柔性低频输电线路高频暂态量单端保护[J]. 电力建设, 2025, 46(8): 105 – 115.
- LI Jingzheng, DU Xiaotong, LI Meng. Single-ended protection scheme for offshore flexible low-frequency transmission lines based on high-frequency transient quantities[J]. Electric Power Construction, 2025, 46(8): 105 – 115.
- [5] 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.
- [6] 郑茂然, 陈朝晖, 余江, 等. 基于 MSST 的高压直流线路故障定位方法[J]. 南方电网技术, 2022, 16(3): 8 – 15, 125.
- ZHENG Maoran, CHEN Zhaohui, YU Jiang, et al. Fault location method based on MSST for HVDC lines[J]. Southern Power System Technology, 2022, 16(3): 8 – 15, 125.
- [7] 高淑萍, 姜元月, 宋国兵, 等. 混合三端直流输电线路故障测距方法研究[J]. 电力系统保护与控制, 2021, 49(15): 76 – 83.
- GAO Shuping, JIANG Yuanyue, SONG Guobing, et al. Research on a fault location method for a hybrid three-terminal DC transmission line[J]. Power System Protection and Control, 2021, 49(15): 76 – 83.
- [8] 陶彩霞, 杜雪, 高峰阳, 等. 基于经验小波变换的混合输电线路单相接地故障测距[J]. 电力系统保护与控制, 2021, 49(10): 105 – 112.
- TAO Caixia, DU Xue, GAO Fengyang, et al. Single-phase to ground fault location of hybrid transmission lines based on empirical wavelet transform[J]. Power System Protection and Control, 2021, 49(10): 105 – 112.
- [9] 贺宇阳, 马千里, 于飞, 等. 基于 CRS-LMD 和 SVD 的 MMC-HVDC 线路故障测距方法[J]. 电力系统保护与控制, 2024, 52(1): 121 – 132.
- HE Yuyang, MA Qianli, YU Fei, et al. Fault location of an MMC-HVDC line based on CRS-LMD and SVD[J]. Power System Protection and Control, 2024, 52(1): 121 – 132.
- [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] 谢李为, 柳伟璇, 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.
- XIE Liwei, LIU Yixuan, ZENG Xiangjun, et al. Fault location of multi-terminal transmission lines based on VMD and S transform[J]. Proceedings of the CSU-EPSA, 2019, 31(2): 126 – 134.
- [12] 夏翊翔, 李泽文, 雷柳, 等. 基于动态虚拟故障的行波网络定位新方法[J]. 中国电机工程学报, 2021, 41(14): 4868 – 4878.
- XIA Yixiang, LI Zewen, LEI Liu, et al. A new method of traveling wave network location based on dynamic virtual fault[J]. Proceedings of the CSEE, 2021, 41(14): 4868 – 4878.
- [13] 叶鑫杰, 兰生, 肖思捷, 等. 基于小波包能量熵和 DBN 的 MMC-HVDC 输电线路单极接地故障定位方法[J]. 南方电网技术, 2021, 15(2): 82 – 91.
- YE Xinjie, LAN Sheng, XIAO Sijie, et al. Single pole grounding fault location method of MMC-HVDC transmission line based on wavelet packet energy entropy and DBN[J]. Southern Power System Technology, 2021, 15(2): 82 – 91.
- [14] 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-EPSA, 2023, 35(9): 120 – 129.
- [15] HADAEGHI A, SAMET H, GHANBARI T. Multi extreme learning machine approach for fault location in multi-terminal high-voltage direct current systems[J]. Computers and Electrical Engineering, 2019(78): 313 – 327.
- [16] TRIPATHI P, PILLAI G, GUPTA H O. Kernel-extreme learning machine-based fault location in advanced series-compensated transmission line[J]. Electric Power Components and Systems, 2016, 44(20): 2243 – 2255.
- [17] 慕宗君, 邱俊宏, 李振兴, 等. 多类型故障影响下柔直线路故障机理分析及单端保护方法[J]. 中国电力, 2025, 58(1): 107 – 114.
- MU Zongjun, QIU Junhong, LI Zhenxing, et al. Fault mechanism analysis and one-terminal protection method of flexible DC transmission line under the influence of multi-type faults[J]. Electric Power, 2025, 58(1): 107 – 114.
- [18] 池梓斌, 夏成军, 杨明嘉. 基于参数优化 VMD 和 TET 的柔直线路单端故障测距方法[J]. 电力系统保护与控制, 2024, 52(4): 1 – 11.
- CHI Zibin, XIA Chengjun, YANG Mingjia. Single-end fault location method for MMC-HVDC transmission lines based on parameter-optimized VMD and TET[J]. Power System Protection and Control, 2024, 52(4): 1 – 11.
- [19] 付华, 吴赛, 徐耀松, 等. 基于 VMD 与广义 S 变换的 HVDC 线路故障定位[J]. 电力系统保护与控制, 2020, 48(4): 125 – 133.
- FU Hua, WU Sai, XU Yaosong, et al. HVDC line fault location based on VMD and generalized S-transform[J]. Power System Protection and Control, 2020, 48(4): 125 – 133.
- [20] 朱菊香, 谷卫, 钱炜, 等. 基于 IF-SVMD-BWO-LSTM 的空气品质预测建模[J]. 中国测试, 2024, 50(11): 173 – 184.
- ZHU Juxiang, GU Wei, QIAN Wei, et al. Modeling of air quality prediction based on IF-SVMD-BWO-LSTM[J]. China Measurement & Test, 2024, 50(11): 173 – 184.
- [21] 陈斌, 刘悦, 李庆真, 等. 冰雪天气下基于 MFOA-KELM 残差修正的跑道温度混合预测[J]. 北京航空航天大学学报, 2022, 48(11): 2153 – 2164.
- CHEN Bin, LIU Yue, LI Qingzhen, et al. Residual correction of runway temperature mixed prediction based on MFOA-KELM under snowy weather[J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 48(11): 2153 – 2164.

(下转第 31 页 Continued on Page 31)