

商立群¹ 刘晗¹ 郝天奇¹ 李钊¹ 李朝彪¹ 邓力文¹

基于 IPOA-LSSVM 模型的高压直流输电线路故障定位

摘要

故障定位在长距离高压直流输电系统中起着至关重要的作用。针对线路衰减系数计算不准和二次波头难以捕捉的问题,提出了一种改进鹈鹕优化算法(IPOA)优化最小二乘支持向量(LSSVM)的故障定位模型。根据行波衰减原理,推导故障距离和线路两端线模分量模极大值比的计算公式,发现二者具有非线性关系。使用 LSSVM 泛化二者之间的关系,将改进后的 IPOA 算法对 LSSVM 的关键参数进行寻优,建立 IPOA-LSSVM 故障定位模型。通过在两端采集故障信号,对其进行小波变换得到首波头幅值比作为模型的输入量,故障距离作为输出量进行仿真验证。仿真结果表明,该模型不受过渡电阻和故障类型的影响,能够可靠准确地定位。

关键词

故障定位;高压直流输电系统;首波头幅值比;改进鹈鹕优化算法;最小二乘支持向量机

中图分类号 TM755

文献标志码 A

收稿日期 2023-10-09

资助项目 陕西省自然科学基金(2021JM-393)

作者简介

商立群,男,博士,教授,主要研究方向为电力系统保护与控制。shangliq@xust.edu.cn

1 西安科技大学 电气与控制工程学院,西安, 710054

0 引言

高压直流输电因为其可以远距离、大容量输送电能,被广泛应用于目前的输电网络中。但高压直流输电线路周围环境差异较大、气候环境恶劣,导致其故障概率比较高。输电线路承担着从发电侧向用户输送电力的职能,一旦发生故障,会严重影响电力系统的稳定性。因此,需要快速、准确地找到故障点,以保障电力系统安全稳定地运行^[1]。

现有的直流输电故障定位方法有行波法、故障分析法和固有频率法。行波法是目前最广泛使用的定位方法^[2]。行波法又可分为单端定位法和双端定位法,其共同点在于波头的识别和波速的估计。双端法利用两端波头到达的时间差和波速来实现故障定位,双端法要求两侧信息同步,需要高质量的 GPS 同步对时技术,以确保精确的定位结果^[3]。单端法只需要在线路一侧装设故障检测装置,不需要同步对时技术,其精确定位的关键因素在于首行波和反射波信号的检测及其性质的识别^[4]。行波法的缺陷是其准确性由波头到达时间的正确检测和波速的精确测量决定,这就导致行波法容错率较低。行波的速度主要是依靠线路参数计算的,但实际工程中,这些参数会随着输电走廊周围环境、气候的变化而变化,很难得到正确的波速^[5-6]。总之,波头的正确识别、波速的精确估计和高质量的 GPS 同步对时技术都会对行波的定位性能产生影响。因此,在有限设备的状况下,进一步挖掘行波特征、提高定位精度,成为了研究的重点。

近年来,随着人工智能技术的发展,智能算法不断被引入到输电线路故障诊断与定位中。智能算法着重挖掘故障的特征信息,对硬件设施的要求较低,有着强大的特征学习和非线性拟合能力。文献[7]使用支持向量机实现了故障的分类和定位,仅仅利用了整流侧的电压电流值作为输入特征量。文献[8]提出一种利用卷积神经网络拟合故障特征波形的定位方法,但是该方法需要大量不同故障类型、不同过渡电阻下的数据,不易实现。文献[9]将行进电流浪涌作为堆叠自动编码器(SAE)神经网络的输入,故障距离作为输出进行定位,但这种方式需要很高的采样频率。

为了提高定位的精度,本文进一步挖掘行波的特征,提出一种基于 IPOA-LSSVM 模型的故障定位方法。根据高频量沿着线路衰减这一特性,推导了故障距离和两端首波头幅值比之间的非线性关系。使用改进鹈鹕优化算法(Improved Pelican Optimization Algorithm, IPOA)优

化最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM),泛化首波头幅值比和故障距离的关系.本文通过选取不同频带内整流侧和逆变侧故障行波线模分量首波头幅值比作为模型输入量,故障距离作为输出量,对模型进行训练、测试.仿真结果表明,该故障定位模型耐过渡电阻能力强,定位精度高.

1 双端故障定位原理

直流线路发生故障时,故障点将会产生高频信号分量沿线路向两端传播,高频信号在传播过程中会发生衰减^[10].图1是在 d 点发生故障时的高压直流输电线路拓扑图.




图1 高压直流输电线路故障拓扑图

Fig. 1 Fault topology of HVDC transmission line

双极直流输电线路之间存在相互耦合的问题,为了消除两极之间的耦合影响,利用式(1)进行解耦计算^[11].

$$\begin{bmatrix} U_1 \\ U_0 \end{bmatrix} = \frac{\sqrt{2}}{2} \begin{bmatrix} 1 & 1 \\ -1 & 1 \end{bmatrix} \begin{bmatrix} U_p \\ U_n \end{bmatrix}. \quad (1)$$

式中: U_1, U_0 分别表示整流侧或逆变侧测距装置处的线模电压和零模电压; U_p, U_n 分别为整流侧或逆变侧测距装置处的正极电压和负极电压.

线路传输函数 $A_j(jw)$ 、模特性阻抗 $Z_a(jw)$ 、模量传播系数 ε_j 表达式分别如下:

$$A_j(jw) = e^{-\varepsilon_j x}, \quad (2)$$

$$Z_a(jw) = \sqrt{\frac{R_j + jw L_j}{jw C_j}}, \quad (3)$$

$$\varepsilon_j = \sqrt{(R_j + jw L_j) jw C_j}. \quad (4)$$

式中: $A_j(jw)$ 表示各模量的线路传输函数($j=0,1$ 分别表示为线模分量、零模分量); R_j, L_j, C_j 分别表示单位长度的模量电阻、电感和电容.

由线路传输函数式(2)可知,幅值大小随着频率的增加而减小,随着线路的增长而降低.即频率越高,线路越长,高频信号量衰减越剧烈.

由图1可知,在距离整流侧测距装置处为 x 的线路 d 点发生故障,那么 d 点会产生频率为 f 的高频信

号量沿着线路向两端传播.根据线路传输函数的定义,可得到长度为 x 的直流线路传输函数^[12]:

$$A_j(jw) = \frac{u_{j1}(jw)}{u_j(jw)} = e^{-\varepsilon_j x}. \quad (5)$$

式中: $u_{j1}(jw)$ 表示整流侧测距装置检测到的故障电压; $u_j(jw)$ 表示故障点的故障电压.

由式(5)可以推导出故障点电压与整流侧和逆变侧故障电压之间的函数关系式如下:

$$|u_{j1}(jw)| = e^{-\partial_j x} |u_j(jw)|, \quad (6)$$

$$|u_{j2}(jw)| = e^{-\partial_j (L-x)} |u_j(jw)|. \quad (7)$$

式中: L 是线路总长度; $|u_{j2}(jw)|$ 表示在逆变侧检测到的故障电压幅值; ∂_j 是模量衰减系数,即模量传播系数的实部.

由式(6)、(7)可推出:

$$x = \frac{1}{2} \left(L - \frac{1}{\partial_j} \ln \frac{|u_{j1}(jw)|}{|u_{j2}(jw)|} \right). \quad (8)$$

根据高压直流输电线路的参数,可以得到模量衰减系数 ∂_j .但提取单一频率下的 $u_{j1}(jw), u_{j2}(jw)$ 非常困难,直接用公式求取故障点距离是行不通的.高频量的衰减主要由直流输电线路结构和线路长度决定,因此,选择用某一频带范围内高频量的平均值代替某一高频量.以小波变换为代表的时频分析对波头标定取得了比较好的结果,小波模极大值与信号突变点一一对应,其幅值大小表示突变强度^[13].对检测到的信号进行小波变换可以得到高频段首波头模极大值,代表了故障初始时刻高频量的强度,故用高频段首波头模极大值的衰减分析替代某一高频信号的衰减分析.根据式(8)可得:

$$x = \frac{1}{2} \left(L - \frac{1}{\partial'_j} \ln \frac{|u_{jm}|}{|u_{jn}|} \right). \quad (9)$$

式中: $|u_{jm}|, |u_{jn}|$ 分别表示某一高频带下整流侧和逆变侧的首波头幅值; ∂'_j 是对应频率下的模量衰减系数.

发生故障时,故障点产生的高频量会向两端传播,测量装置便可以捕捉到电压信号的变化.在每个测量装置处收集电压突变的数据,对此进行解耦和小波变换,便可以得到首波头模极大值.模量衰减系数是关于频率的函数,再加上在实际输电系统中,线路参数变化大,很难求取准确的模量衰减系数.分析

式(9)可知,故障距离 x 与 $\frac{|u_{jm}|}{|u_{jn}|}$ 之间有着非线性关系,使用最小二乘支持向量机可以泛化二者之间的函数关系,那么通过两端装置处的首波头幅值,就能

实现故障定位.这种方式对装置要求比较低,大大提高了故障定位的经济性.

2 IPOA-LSSVM 模型的建立

2.1 最小二乘支持向量机

LSSVM 是一种基于统计理论的改进型支持向量机,它将 SVM 中的二次优化问题转化为线性方程组的求解,使参数搜索范围从三维转化为二维,在保证精度的同时,大幅度降低计算复杂性,加快了求解速度^[14].并且在线性回归方面,泛化能力强,更加适用于回归预测.

数据集 $S = \{(\mathbf{x}_i, \mathbf{y}_i), i = 1, 2, 3, \dots, n\}$, 其中, \mathbf{x}_i 是输入向量, \mathbf{y}_i 是输出向量, n 是训练数据的总数.将数据集 S 中的向量通过非线性函数 $\alpha(\mathbf{x})$ 映射到高维特征空间,在高维特征空间中的决策函数为

$$f(\mathbf{x}) = \mathbf{w} \cdot \alpha(\mathbf{x}) + \mathbf{b}. \quad (10)$$

式中: \mathbf{w} 为权值向量; \mathbf{b} 为偏差向量; $\alpha(\mathbf{x})$ 是映射函数.

LSSVM 的目标函数和约束条件为

$$\min J = \frac{1}{2} \|\mathbf{w}\|^2 + \frac{1}{2} \gamma \sum_{i=1}^N \varepsilon_i^2, \quad (11)$$

$$\text{s.t. } \mathbf{y}_i = \mathbf{w}^T \alpha(\mathbf{x}_i) + \mathbf{b} + \varepsilon_i. \quad (12)$$

式中: ε_i 为松弛变量; γ 为惩罚系数,表示对松弛变量的惩罚程度.

引入拉格朗日算子 a_i 求解:

$$L(\mathbf{w}, \mathbf{b}, \varepsilon, \mathbf{a}) = \frac{1}{2} \|\mathbf{w}\|^2 + \frac{1}{2} \gamma \sum_{i=1}^N \varepsilon_i^2 - \sum_{i=1}^N a_i (\mathbf{w}^T \alpha(\mathbf{x}_i) + \mathbf{b} + \varepsilon_i - \mathbf{y}_i). \quad (13)$$

由 KKT 条件求解得:

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0, \mathbf{w} = \sum_{i=1}^N a_i \alpha(\mathbf{x}_i), \\ \frac{\partial L}{\partial \mathbf{b}} = 0, \sum_{i=1}^N a_i = 0, \\ \frac{\partial L}{\partial \varepsilon_i} = 0, a_i = \gamma \varepsilon_i, \\ \frac{\partial L}{\partial a_i} = 0, \mathbf{w}^T \alpha(\mathbf{x}_i) + \mathbf{b} + \varepsilon_i - \mathbf{y}_i = 0. \end{cases} \quad (14)$$

约去权值变量 \mathbf{w} 和松弛变量 ε_i , 得到模型决策函数:

$$f(\mathbf{x}) = \sum_{i=1}^N a_i K(\mathbf{x}_i, \mathbf{x}_j) + \mathbf{b}. \quad (15)$$

式中: $K(\mathbf{x}_i, \mathbf{x}_j) = \alpha^T(\mathbf{x}_i) \alpha(\mathbf{x}_j)$ 为核函数.

本文选择径向基核函数作为模型的核函数,表

达式为

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp \left[\frac{-\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2} \right]. \quad (16)$$

式中: σ 表示带宽.

2.2 鹈鹕优化算法及其改进

2.2.1 鹈鹕优化算法

鹈鹕优化算法 (Pelican Optimization Algorithm, POA) 是在 2022 年基于鹈鹕的自然行为所提出的一种新算法^[15].POA 主要是模拟了鹈鹕在攻击和狩猎时的行为和策略,以更新和得到最优的方案.鹈鹕的狩猎行为主要包括两个阶段,向猎物移动阶段和在水面飞行阶段,即探索阶段和开采阶段.这些狩猎策略有利于找到目标空间,相比于传统的优化算法,适应性更强,更能准确地向全局最优位置收敛.

对鹈鹕种群在搜索空间里进行初始化,表达式为

$$x_{i,j} = l_j + \text{rand} \times (u_j - l_j), i = 1, 2, \dots, N, j = 1, 2, \dots, M. \quad (17)$$

式中: $x_{i,j}$ 是第 i 个候选解中的第 j 个变量; l_j 表示变量的下界; u_j 表示变量的上界; rand 表示在 $[0, 1]$ 间的随机数.

POA 中的鹈鹕种群成员用下列种群矩阵来表示,该矩阵的每一行代表一个候选解,矩阵的列代表变量的建议值.

$$\mathbf{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_i \\ \vdots \\ x_n \end{bmatrix}_{n \times m} = \begin{bmatrix} x_{1,1} & \cdots & x_{1,j} & \cdots & x_{1,m} \\ \vdots & & \vdots & & \vdots \\ x_{i,1} & \cdots & x_{i,j} & \cdots & x_{i,m} \\ \vdots & & \vdots & & \vdots \\ x_{n,1} & \cdots & x_{n,j} & \cdots & x_{n,m} \end{bmatrix}_{n \times m}. \quad (18)$$

式中: \mathbf{x} 表示鹈鹕的种群矩阵; x_i 表示的是第 i 只鹈鹕.

对每个候选解进行评估的目标函数为

$$\mathbf{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_i \\ \vdots \\ y_n \end{bmatrix}_{n \times 1} = \begin{bmatrix} y(\mathbf{x}_1) \\ \vdots \\ y(\mathbf{x}_i) \\ \vdots \\ y(\mathbf{x}_n) \end{bmatrix}_{n \times 1}. \quad (19)$$

式中: \mathbf{y} 表示目标函数向量; y_i 表示第 i 只鹈鹕的目标函数值.

1) 阶段 1: 探索阶段

鹈鹕发现猎物的位置,向这个确定的区域移动.

$$x_{i,j}^{p_1} = \begin{cases} x_{i,j} + (p_j - Ix_{i,j}), & y_p < y_i; \\ x_{i,j} + (x_{i,j} - p_j), & \text{其他.} \end{cases} \quad (20)$$

式中: $x_{i,j}^{p_1}$ 表示的是在第 1 阶段的第 i 只鸬鹚的 j 维下新状态; I 是 1 或者 2 的随机数; p_j 表示的是猎物在 j 维的位置; y_p 表示的是目标函数值.

如果更新后的目标函数值得到改善,则鸬鹚的新位置被接受;否则,拒绝更新.表达式如下:

$$x_i = \begin{cases} x_i^{p_1}, & y_i^{p_1} < y_i; \\ x_i, & \text{其他.} \end{cases} \quad (21)$$

式中: $x_i^{p_1}$ 表示的是在阶段 1 的第 i 只鸬鹚的新状态; $y_i^{p_1}$ 表示的是阶段 1 的目标函数值.

2) 阶段 2: 开采阶段

鸬鹚的狩猎过程为

$$x_{i,j}^{p_2} = x_{i,j} + R \left(1 - \frac{t}{T} \right) (2 \times \text{rand} - 1) x_{i,j}. \quad (22)$$

式中: $x_{i,j}^{p_2}$ 表示的是在阶段 2 的第 i 只鸬鹚的新状态; R 为等于 0.2 的常数; $R \left(1 - \frac{t}{T} \right)$ 表示的是 $x_{i,j}$ 的领域半径; T 为最大迭代次数; t 为迭代计数器.

阶段 2 同样使用了是否进行有效更新来接受或拒绝新位置.

$$x_i = \begin{cases} x_i^{p_2}, & y_i^{p_2} < y_i; \\ x_i, & \text{其他.} \end{cases} \quad (23)$$

式中: $x_i^{p_2}$ 表示的是在阶段 2 的第 i 只鸬鹚的新状态; $y_i^{p_2}$ 表示的是阶段 2 的目标函数值.

在 POA 优化过程中,首先对鸬鹚种群进行初始化,再进行第 1、第 2 阶段的更新,基于种群的新状态和目标函数值,更新最佳候选方案.算法进入下一次迭代,重复式 (20) — (23) 的步骤,直到完全迭代结束.选择最优的目标函数值的鸬鹚位置作为最佳鸬鹚位置,即最优解.

2.2.2 改进鸬鹚优化算法

传统的鸬鹚算法在测试性能上优于其他算法,但仍然有提升的空间,特别是在局部搜索方面.本文将 Tent 混沌映射、精英反向学习和差分进化算法融入 POA 算法中,来提高算法的搜索能力.

1) Tent 混沌映射和精英反向学习

鸬鹚优化算法是随机初始种群位置的,会导致初始解分布不均,影响整体性能.混沌序列常被用于改善初始分布问题.在优化算法中,初始种群在搜索空间里分布越均匀,越利于提高算法的效率和精度.反向解的引入可以扩大算法的搜索区域,对原解适应度值大于反向解的个体,应加强其领域搜索.而原解适应度值小

于反向解适应度值的个体,应对其反向区域加强搜索. Tent 混沌映射在分布性、随机性方面相较于其他混沌序列有着更好的性能,因此,本文选择用 Tent 混沌映射和精英反向学习策略来优化鸬鹚的初始种群,使种群位置在搜索空间里分布更均匀.

Tent 混沌映射的数学表达式为

$$x_{n+1} = \begin{cases} \frac{x_n}{a}, & 0 \leq x_n < a; \\ \frac{1 - x_n}{1 - a}, & a \leq x_n < 1. \end{cases} \quad (24)$$

式中: a 是 $[0, 1]$ 之间的随机数.若 $x_{n+1} > 1$, x_{n+1} 返回 1; 若 $x_{n+1} < 0$, x_{n+1} 返回 0.

Tent 混沌映射产生 N 个 d 维初始解 $x_{i,j}$ ($i = 1, 2, 3, \dots, N, j = 1, 2, 3, \dots, d$), 每个初始解对应一个精英个体,根据式 (25) 生成精英反向解 $x_{i,j}^*$:

$$x_{i,j}^* = k(a_{ij} + b_{ij}) - x_{i,j}. \quad (25)$$

式中: k 为精英反向系数,取值 $[0, 1]$; a_{ij}, b_{ij} 分别为 x_i 在 j 维上的最小值和最大值.

当精英反向解不在区间时,使用式 (26) 约束解的位置:

$$\begin{cases} x_{i,j}^* = a_{ij}, & x_{i,j}^* < a_{ij}; \\ x_{i,j}^* = b_{ij}, & x_{i,j}^* > b_{ij}. \end{cases} \quad (26)$$

最后将 Tent 混沌映射产生的初始解和精英反向解进行混合排序,取前 N 个较优解作为初始种群.

2) 差分进化算法

差分进化算法是基于群体的全局算法,是根据适者生存这一自然法则产生的一种智能优化方法.它保留了基于种群的全局搜索策略,具有不易陷入局部最优的优点.因此,本文选择用差分进化算法来优化鸬鹚种群中适应度小于平均适应度的个体,通过个体的交叉、变异和选择的作用,使得生物体优胜劣汰,得到差分进化后的种群,然后将差分进化后的种群替代原始种群的劣势个体来获得新一代的最优个体,从而逼近最优解.

根据鸬鹚种群的平均适应度值,选择出适应度值小于平均适应度值的鸬鹚个体,作为差分进化算法的初始种群.

种群中的每个个体可以表示为

$$\mathbf{x}_i = [x_{i,1}, x_{i,2}, \dots, x_{i,n}], i = 1, 2, \dots, N. \quad (27)$$

式中: N 指的是劣等鸬鹚的个数; n 表示每个个体由 n 维向量组成.

1) 变异

对于种群中的每个个体 \mathbf{x}_i , 按式 (28) 产生变异:

$$\mathbf{v}_i = \mathbf{x}_{r_1} + F_0(\mathbf{x}_{r_2} - \mathbf{x}_{r_3}). \quad (28)$$

式中: r_1, r_2, r_3 在种群中随机选择, 且 $r_1 \neq r_2 \neq r_3 \neq i$; F_0 用于控制偏差的放大作用, 取值区间为 $[0, 2]$.

2) 交叉

将变异向量 $\mathbf{v}_{i,j}$ 与原向量 $\mathbf{x}_{i,j}$ 进行交叉操作得到新向量 $\mathbf{u}_{i,j}$:

$$\mathbf{u}_{i,j} = \begin{cases} \mathbf{v}_{i,j}, & \text{rand} \leq R \text{ 或 } j = j_r; \\ \mathbf{x}_{i,j}, & \text{rand} > R \text{ 或 } j \neq j_r. \end{cases} \quad (29)$$

式中: $i = 1, 2, \dots, N; j = 1, 2, \dots, n$; 交叉概率 $R \in [0, 1]$; 随机序列 $j_r \in [1, 2, \dots, n]$.

3) 选择

根据适应度来选择新向量是否替代原向量, 表达式为

$$\mathbf{x}_i = \begin{cases} \mathbf{u}_i, & \text{fit}(\mathbf{u}_i) < \text{fit}(\mathbf{x}_i); \\ \mathbf{x}_i, & \text{fit}(\mathbf{u}_i) \geq \text{fit}(\mathbf{x}_i). \end{cases} \quad (30)$$

式中: $\text{fit}(\mathbf{x}_i)$ 指的是 \mathbf{x}_i 的适应度.

2.2.3 改进鹈鹕优化算法的工作流程

对鹈鹕算法有着两个方面的改进: 一是对鹈鹕的初始种群进行优化, 使用 Tent 混沌映射和精英反向学习使得初始种群更加具有遍历性和均匀性; 二是使用差分进化算法优化劣势鹈鹕个体, 替代原始劣势鹈鹕个体, 进而得到最优个体. 改进后的鹈鹕算法具体步骤如下:

步骤 1: 初始化鹈鹕种群数、最大迭代次数.

步骤 2: Tent 混沌映射和精英反向学习确定初始种群位置.

步骤 3: 计算个体目标函数值 y_i 和平均目标函数值 \bar{y} .

步骤 4: 若 $y_i > \bar{y}$, 采用差分进化算法对劣势鹈鹕进行交叉、变异和选择得到新的个体.

步骤 5: 新个体取代原始的劣势鹈鹕形成新的种群, 接着随机生成猎物的位置, 进行鹈鹕的探索和开采阶段, 从而得到最优鹈鹕位置.

步骤 6: 判断迭代次数是否达到最大值, 若是, 则停止寻优, 输出最优解; 否则, 转至步骤 3 继续寻优.

算法流程如图 2 所示.

2.3 算法性能测试

为了验证 IPOA 在优化函数上的优越性, 本文选择用两个测试函数进行仿真. 单峰函数用于验证算法的收敛速度, 多峰函数有多个极值, 可能会陷入局部最优, 用于测算法的寻优能力. 此外, 将本文提出的 IPOA 算法与 POA 算法以及典型的智能优化算

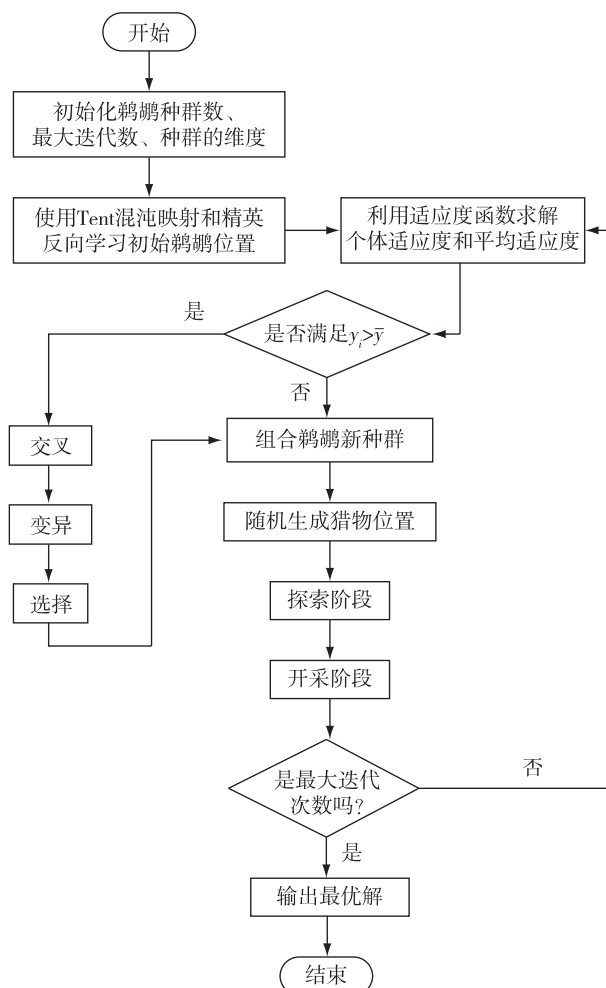


图 2 IPOA 流程

Fig. 2 IPOA flow chart

法, 如粒子群算法 (Particle Swarm Optimization, PSO)、鲸鱼算法 (Whale Optimization Algorithm, WOA) 进行比较. 测试函数如式 (31)、(32) 所示.

$$f_1(x) = \max_i \{ |x_i|, 1 \leq i \leq n \}, \quad (31)$$

$$f_2(x) = \frac{1}{4\,000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1. \quad (32)$$

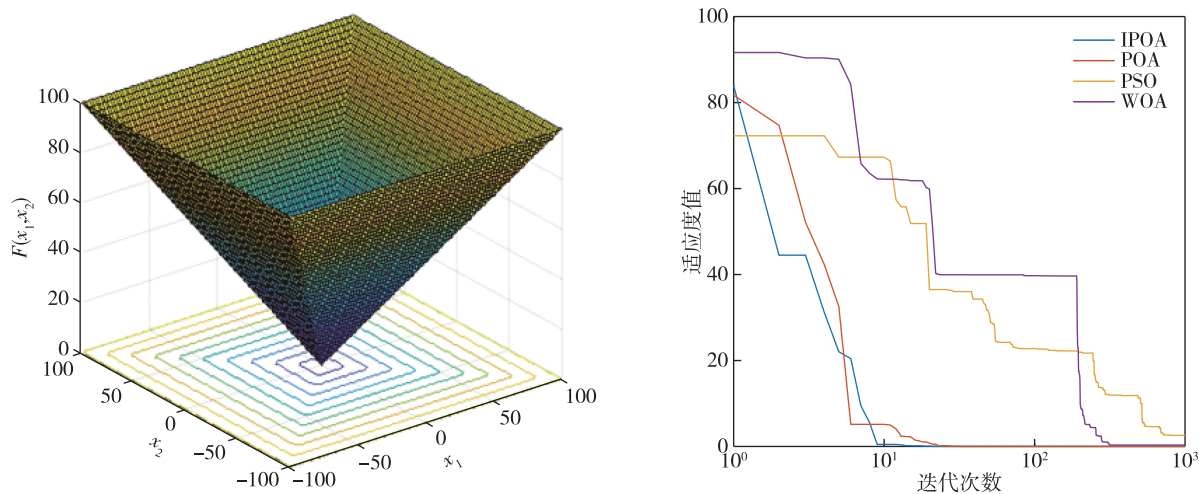
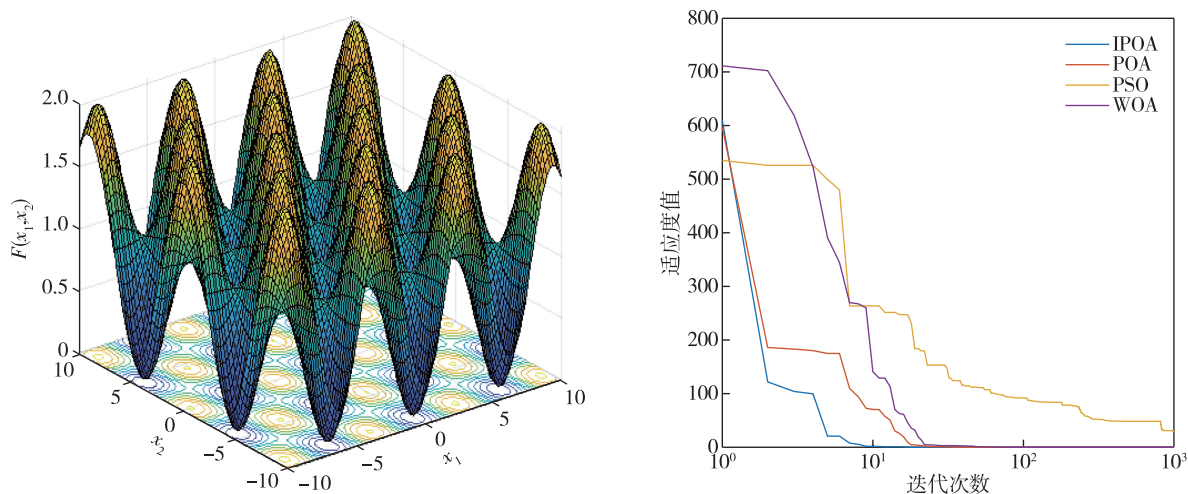
测试函数信息如表 1 所示.

表 1 测试函数

Table 1 Test functions

函数	类型	维度	搜索范围	最小值
f_1	Schwefel	30	$[-100, 100]$	0
f_2	Griewank	30	$[-600, 600]$	0

将 IPOA 独立运行 30 次的测试结果与 POA、PSO、WOA 进行结果比较, 设每种算法的最大迭代次数为 1 000、种群规模为 30. 测试函数的图像和仿真结果如图 3、4 所示.

图3 测试函数 f_1 及其寻优过程Fig. 3 Test function f_1 and its optimization procedure图4 测试函数 f_2 及其寻优过程Fig. 4 Test function f_2 and its optimization procedure

从图3、4可以看出,4种算法都随迭代次数的增加逐渐收敛,WOA和PSO算法不仅收敛速度慢,还容易陷入局部最优,IPOA和POA算法收敛速度相对更快、更稳.改进后的POA算法在收敛速度和寻优能力上都得到提高,并能快速准确定位到最优解.

2.4 建立 IPOA-LSSVM 故障定位预测模型

使用最小二乘支持向量机对故障位置预测,其准确率很大程度上受到学习参数(惩罚系数 C 和核参数 g)的影响.惩罚系数 C 的物理意义是对模型误差的忍受度, C 取值小,也就是对误差的忍受度比较大,容易造成模型的欠拟合问题,模型的精确度会下降, C 取值大,对误差的忍受度比较低,容易产生过拟合问题,模型的泛化能力会下降.核参数 g 是支持

向量的个数, g 取值过大,容易过学习,对训练样本预测的效果比较好,但对测试样本预测效果差强人意,泛化能力差, g 取值过小,会出现欠学习的问题,模型精确度也会下降.因此,对惩罚系数 C 和核参数 g 进行优化十分必要.

传统确定学习参数的方法主要是用交叉验证法和人工试凑法,但效率较低,很难达到最好的精确度.本文通过引入改进后的鹈鹕算法来优化LSSVM模型的学习参数,使得模型获得最佳惩罚系数 C 和核参数 g .IPOA-LSSVM故障定位预测模型的具体流程如下:

步骤1:读取数据,把数据分为训练集和测试集,进行预处理.

步骤 2: 初始鸚鵡优化算法的参数.

步骤 3: 确定适应度函数. 本文选择实际故障位置与模型预测结果的差值平方和作为适应度函数.

步骤 4: IPOA 算法优化最小二乘支持向量机的学习参数, 得到最优惩罚系数 C 和核参数 g .

步骤 5: 将惩罚系数 C 和核参数 g 代入最小二乘支持向量机.

步骤 6: 输入测试集样本, 进行故障位置的预测.

基于 IPOA-LSSVM 模型的故障定位流程如图 5 所示.

3 仿真验证与结果分析

3.1 仿真模型

本文运用 PSCAD/EMTDC 电磁暂态仿真软件搭建了一个 ± 500 kV 的高压直流输电线路模型. 整流器和逆变器均采用 12 脉冲桥式结构, 平波电抗器为 0.597 H, 电压等级为 500 kV, 直流额定功率为 1 000 MW, 滤波器为双调谐滤波器, 线路全长 1 000 km, 采样频率为 200 kHz, 采用 Frequency Dependent (Phase) Model Options 模型. 仿真模型结构如图 6 所示.

高压直流输电线路中有两条输电线路, 其中, 单极接地 (正极或负极接地) 是最为常见的故障, 两极之间短路 (极间短路接地、极间短路不接地) 不常见. 图 7 描述了在 200 km 处 4 种不同类型的故障, 过渡电阻均为 0 的情况下, 整流侧和逆变侧的电压波形. 图 8 描述了在距离整流侧不同位置发生金属性正极接地故障时, 整流侧和逆变侧的故障电压波形.

从图 7 可以看出, 正极短路故障电压是突然下

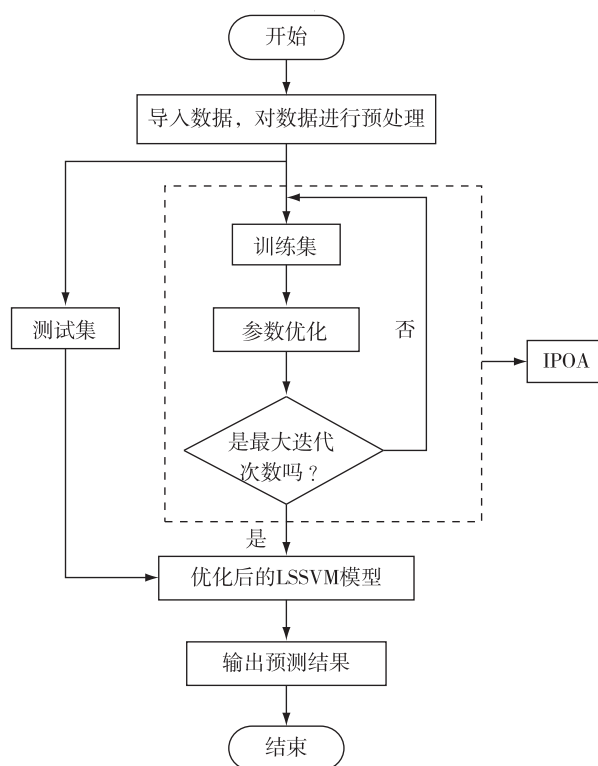


图 5 基于 IPOA-LSSVM 模型的故障定位流程

Fig. 5 Flow chart of fault location via the proposed IPOA-LSSVM model

降的, 而负极短路电压是上下波动的. 两极之间短路, 无论接不接地, 对整流侧和逆变侧测得的电压波形没有大的影响, 但是极间短路造成的电压波动比单极故障的电压波动更明显, 造成的影响更大. 由图 8 可知, 故障位置距离整流侧测距点越近, 波动幅度越大, 相应的首波头幅值越大, 对应的逆变侧故障电

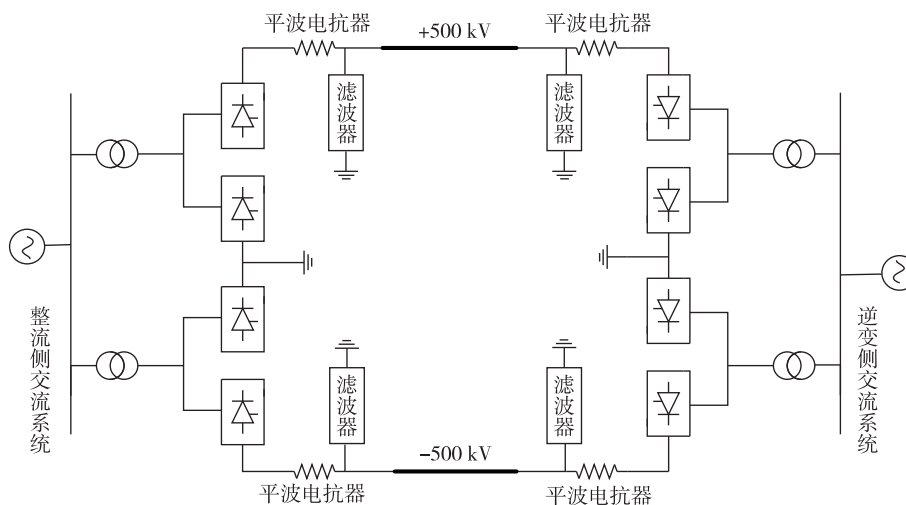


图 6 高压直流输电线路仿真模型

Fig. 6 Simulation model of HVDC transmission line

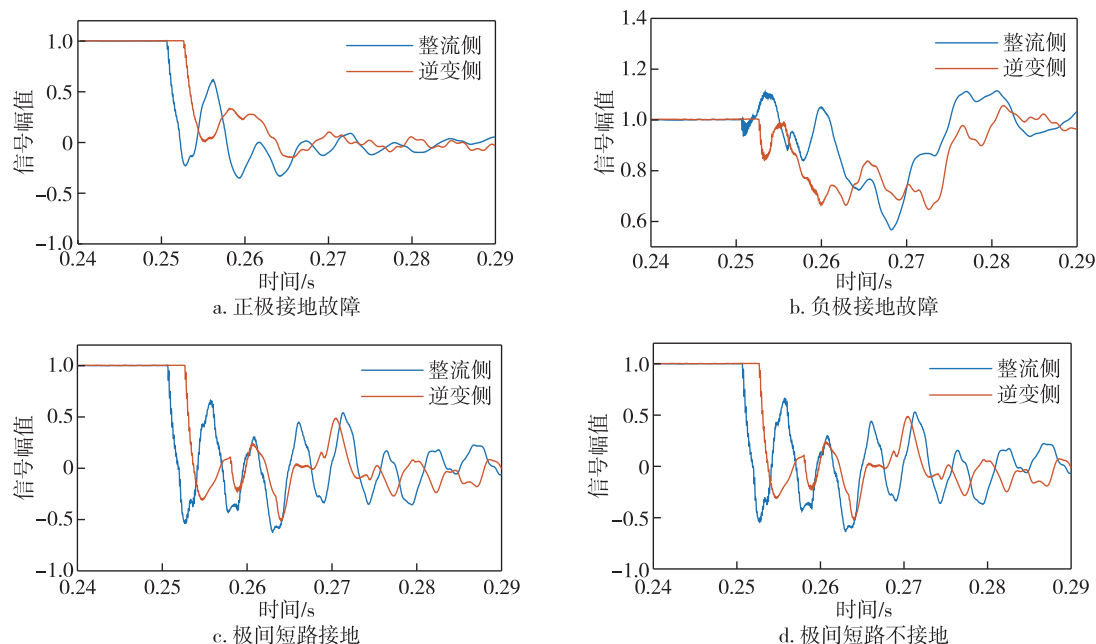


图 7 整流侧和逆变侧的故障电压波形

Fig. 7 Fault voltage waveforms at rectifier side and inverter side




图 8 不同故障点对应的故障电压波形

Fig. 8 Fault voltage waveforms corresponding to different fault points

压波动较小,因此整流侧和逆变侧的首波头幅值比值较大.在 500 km 处发生故障时,两侧故障电压波形相似,首波头幅值比约等于 1.可以看出,随着故障距离的增加,首波头幅值比相应的减小,二者之间呈现某种非线性关系.

3.2 样本的选择和处理

样本的选择和处理是故障定位模型定位的关键,训练样本要尽可能地全面反映不同故障类型和不同故障距离下的首波头幅值特性.对样本的选择过程如下:

1)通过提取故障发生后 5 ms 时窗内整流侧和逆变侧的暂态电压,对其进行解耦计算得到线模分量.分别对整流侧和逆变侧的暂态电压线模分量进行小波变换,提取不同尺度下高频带内整流侧和逆

变侧首波头幅值比,从而构成了 IPOA-LSSVM 模型的输入特征量,故障距离作为输出特征量.

2)从距离整流侧保护装置 5 km 处设置故障点,到 995 km 处结束,故障距离变化步长为 5 km.

3)过渡电阻的范围为 $[0, 100]$,变化步长为 10 Ω .

4)取 4 种不同的故障类型:正极短路接地、负极短路接地、极间短路接地、极间短路不接地.

5)对样本进行归一化处理.

3.3 IPOA 优化性能分析

为了验证 IPOA-LSSVM 的有效性和优越性,将 LSSVM、PSO-LSSVM、POA-LSSVM、IPOA-LSSVM 模型进行对比分析.对 8 组测试数据进行验证分析,得到的定位结果如表 2 所示.

表 2 不同算法优化 LSSVM 的定位结果

Table 2 Localization results of LSSVM optimized by different algorithms

故障位置/ km	LSSVM		PSO-LSSVM		POA-LSSVM		IPOA-LSSVM	
	距离/km	相对误差/%	距离/km	相对误差/%	距离/km	相对误差/%	距离/km	相对误差/%
33	36.23	0.323	33.92	0.092	33.73	0.073	33.48	0.048
176	176.89	0.089	174.43	0.157	175.08	0.092	176.29	0.029
369	366.66	0.234	371.34	0.234	370.31	0.131	368.22	0.078
583	589.70	0.670	583.88	0.088	582.25	0.075	583.09	0.009
678	674.08	0.392	677.37	0.063	678.10	0.010	677.16	0.084
742	743.23	0.123	738.39	0.261	742.83	0.083	741.40	0.060
877	877.38	0.038	877.25	0.025	876.58	0.042	877.55	0.055
967	963.79	0.321	965.80	0.120	965.07	0.193	967.38	0.038

从表 2 中可以看出,未优化过的 LSSVM 模型定位误差比较大,优化过的模型误差明显减小.PSO 优化过模型的误差率波动比较大,IPOA 相较于 POA 优化后的模型误差更小,IPOA-LSSVM 的测距相对误差均小于 0.1%,说明改进鸚鵡优化算法能更有效地提高故障定位的精确性.

3.4 惩罚系数和核参数的影响分析

使用最小二乘支持向量机对故障位置进行预测,其准确率受限于惩罚系数 C 和核参数 g 的影响.表 3 是在惩罚系数 $C=500$ 的情况下,不同的核参数 g 对故障定位的影响.表 4 是在核参数 $g=0.1$ 的情况下,惩罚系数 C 对故障定位的影响.

从表 3、4 可以看出, C 和 g 的取值对故障定位准确率的影响非常大.对于本文故障定位来说, g 的取值偏小些, C 取值偏大些准确率较好.但是过小的

g 和过大的 C 也会使准确率下降.上述结果进一步说明了人工试凑法寻找最优参数的低效性,凸显了智能优化算法的必要性和有效性.

3.5 故障电阻的影响分析

当线路发生故障时,不同的故障电阻可能会影响定位结果的准确性.表 5 是在故障点为 272 km 处发生正极接地故障时,在不同的过渡电阻下,整流侧和逆变侧首波头幅值比的大小.

由表 5 可知,高频信号的衰减与过渡电阻是相关的,随着过渡电阻的增加,整流侧和逆变侧的首波头幅值都会减小,但两侧的首波头幅值比并没有发生变化.

表 6 是在不同过渡电阻下,不同故障距离对应的定位结果.从定位结果可以看出,过渡电阻对定位结果没有影响.

表 3 不同核参数对定位结果的影响

Table 3 Influence of kernel parameter on localization results

故障位置/ km	误差/km							
	$g=0.01$	$g=0.1$	$g=1$	$g=10$	$g=35$	$g=60$	$g=74$	$g=100$
67	4.41	0.89	3.52	-0.64	-1.04	-3.31	-4.48	-5.85
136	-14.73	-0.78	3.51	9.28	7.30	7.49	7.8C8	8.56
484	10.63	0.77	-0.28	-1.03	-1.90	-3.46	-4.20	-5.21
946	-2.61	-0.35	0.08	-5.59	-6.18	0.38	2.19	4.52

表 4 不同惩罚系数对定位结果的影响

Table 4 Influence of penalty coefficient on localization results

故障位置/ km	误差/km							
	$C=0.1$	$C=1$	$C=10$	$C=50$	$C=100$	$C=400$	$C=750$	$C=1\ 000$
67	-172.67	-20.68	-3.57	-1.15	-0.29	0.77	1.10	1.24
136	-115.67	-5.10	5.63	1.92	0.64	-0.68	-0.91	-0.97
484	6.73	1.49	1.65	1.55	1.31	0.83	0.66	0.60
946	240.53	73.6	13.81	2.23	0.53	-0.37	-0.25	-0.14

表 5 不同过渡电阻下首波头幅值比

Table 5 Amplitude ratios of first wave head under different transition resistances

过渡电阻/ Ω	首波头幅值/kV		首波头幅值比
	整流侧	逆变侧	
0	13.25	10.26	1.29
50	10.87	8.42	1.29
100	9.21	7.15	1.29

表 6 不同过渡电阻对定位结果的影响

Table 6 Influence of transition resistance on localization result

故障距离/km	过渡电阻/ Ω	测距结果/km	误差/km	相对误差/%
192	0.01	192.46	0.46	0.046
	30	192.46	0.46	0.046
	70	192.46	0.46	0.046
	100	192.46	0.46	0.046
369	0.01	369.61	0.61	0.061
	30	369.61	0.61	0.061
	70	369.61	0.61	0.061
	100	369.61	0.61	0.061
678	0.01	677.28	-0.72	0.072
	30	677.28	-0.72	0.072
	70	677.28	-0.72	0.072
	100	677.28	-0.72	0.072
841	0.01	840.73	-0.27	0.027
	30	840.73	-0.27	0.027
	70	840.73	-0.27	0.027
	100	840.73	-0.27	0.027

3.6 故障类型的影响分析

在高压直流输电线路中,可能会发生 4 种类型的故障,分别是正极短路、负极短路、极间短路接地、极间短路不接地.表 7 是在一定过渡电阻下,不同故障点在不同故障类型下对应的定位结果.

由表 7 可知,在同一故障点,不同的故障类型对定位结果有影响,但影响效果微乎其微,相对误差都保持在 0.1% 的范围内,即故障类型的影响可忽略不计.

4 结论

本文提出了一种基于 IPOA-LSSVM 模型的双端故障定位方法,并通过大量故障仿真验证,得出以下结论:

1)通过双端测距装置采集故障信号,进行理论分析,得到首波头幅值比和故障距离具有非线性关系,使用最小二乘支持向量机拟合二者之间的关系.

表 7 不同故障类型对定位结果的影响

Table 7 Influence of fault type on localization results

故障距离/km	故障类型	测距结果/km	误差/km	相对误差/%
47	正极短路	47.32	0.32	0.032
	负极短路	47.41	0.41	0.041
	极间短路接地	46.79	-0.21	0.021
	极间短路不接地	46.88	-0.12	0.012
391	正极短路	390.70	-0.30	0.030
	负极短路	390.77	-0.23	0.023
	极间短路接地	391.67	0.67	0.067
	极间短路不接地	391.52	0.52	0.052
776	正极短路	776.03	0.03	0.003
	负极短路	776.34	0.34	0.034
	极间短路接地	775.27	-0.73	0.073
	极间短路不接地	776.68	0.68	0.068
912	正极短路	912.89	0.89	0.089
	负极短路	911.88	-0.12	0.012
	极间短路接地	912.45	0.45	0.045
	极间短路不接地	911.38	-0.62	0.062

2)在 POA 算法的基础上,引入 Tent 混沌映射和精英反向学习以及差分进化算法克服陷入局部最优的问题,增强算法全局搜索的能力.

3)仿真结果表明,使用 IPOA 算法优化 LSSVM 的参数,有着更好的稳定性和泛化能力,能够提高故障定位的精确度.

4)将 IPOA-LSSVM 模型运用到高压直流输电线路故障定位中,定位准确率高,并且该方法不受故障类型和过渡电阻的影响,适用于高压直流输电线路故障定位.

参考文献

References

[1] 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
[2] 段建东,刘静,陆海龙,等.基于行波瞬时频率的高压直流输电线路故障测距方法[J].中国电机工程学报,2016,36(7):1842-1848
DUAN Jiandong,LIU Jing,LU Hailong,et al. Fault location method based on traveling-wave instantaneous frequency for HVDC transmission lines[J].Proceedings of the CSEE,2016,36(7):1842-1848
[3] 任红向,梁睿,丁然,等.双端非同步数据精确线搜索比相的故障定位[J].电网技术,2015,39(10):2972-2978

- REN Hongxiang, LIANG Rui, DING Ran, et al. Fault location research adopted two-terminal asynchronous data and based on accurate line-searching and phase-comparing[J]. Power System Technology, 2015, 39(10): 2972-2978
- [4] Reis R L A, Lopes F V, Neves W L A, et al. An improved single-ended correlation-based fault location technique using traveling waves [J]. International Journal of Electrical Power & Energy Systems, 2021, 132: 107167
- [5] He Z Y, Liao K, Li X P, et al. Natural frequency-based line fault location in HVDC lines[J]. IEEE Transactions on Power Delivery, 2014, 29(2): 851-859
- [6] Liang Y S, Wang G, Li H F. Time-domain fault-location method on HVDC transmission lines under unsynchronized two-end measurement and uncertain line parameters[J]. IEEE Transactions on Power Delivery, 2015, 30(3): 1031-1038
- [7] Johnson J M, Yadav A. Complete protection scheme for fault detection, classification and location estimation in HVDC transmission lines using support vector machines [J]. IET Science, Measurement & Technology, 2017, 11(3): 279-287
- [8] Lan S, Chen M J, Chen D Y. A novel HVDC double-terminal non-synchronous fault location method based on convolutional neural network [J]. IEEE Transactions on Power Delivery, 2019, 34(3): 848-857
- [9] Luo G M, Yao C Y, Liu Y L, et al. Stacked auto-encoder based fault location in VSC-HVDC [J]. IEEE Access, 2018, 6: 33216-33224
- [10] 陈仕龙, 张杰, 毕贵红, 等. 一种基于高频量衰减特性的特高压直流输电线路故障测距方法[J]. 电力系统保护与控制, 2014, 42(10): 77-83
- CHEN Shilong, ZHANG Jie, BI Guihong, et al. A fault location method based on high frequency attenuation characteristic of UHVDC transmission line [J]. Power System Protection and Control, 2014, 42(10): 77-83
- [11] 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
- [12] 陈仕龙, 束洪春, 谢静, 等. 特高压直流输电线路和边界频率特性研究[J]. 电力自动化设备, 2013, 33(11): 134-139, 153
- CHEN Shilong, SHU Hongchun, XIE Jing, et al. Frequency characteristics of UHVDC transmission line and its boundary [J]. Electric Power Automation Equipment, 2013, 33(11): 134-139, 153
- [13] 邢超, 高敬业, 毕贵红, 等. 基于集成神经网络的特高压直流输电线路初始电压行波小波变换模极大值比单端测距方法[J]. 电力自动化设备, 2022, 42(11): 128-134
- XING Chao, GAO Jingye, BI Guihong, et al. Single-end fault location method used ratio between WT modulus maximum values of initial voltage traveling wave for UHVDC transmission line based on integrated neural network [J]. Electric Power Automation Equipment, 2022, 42(11): 128-134
- [14] 李云漠, 咸日常, 张海强, 等. 基于改进灰狼算法与最小二乘支持向量机耦合的电力变压器故障诊断方法[J]. 电网技术, 2023, 47(4): 1470-1478
- LI Yunhao, XIAN Richang, ZHANG Haiqiang, et al. Fault diagnosis for power transformers based on improved grey wolf algorithm coupled with least squares support vector machine [J]. Power System Technology, 2023, 47(4): 1470-1478
- [15] Trojovský P, Dehghani M. Pelican optimization algorithm: a novel nature-inspired algorithm for engineering applications [J]. Sensors, 2022, 22(3): 855

Fault location of HVDC transmission line via IPOA-LSSVM model

SHANG Liqun¹ LIU Han¹ HAO Tianqi¹ LI Zhao¹ LI Chaobiao¹ DENG Liwen¹

¹ College of Electrical and Control Engineering, Xi'an University of Science and Technology, Xi'an 710054, China

Abstract Fault location is crucial for the long-distance HVDC transmission systems. Here, a fault location model using the Improved Pelican Optimization Algorithm (IPOA) to optimize the Least Squares Support Vector Machine (LSSVM) is provided to address the issues of imprecise attenuation coefficient computation and challenging secondary wave head capture. First, in accordance with the traveling wave attenuation concept, the formulas of the fault distance and the modulus maximum ratio of the line mode components at both ends of the line are derived, revealing a nonlinear relationship between them, which is then generalized by LSSVM. Second, the IPOA is employed to optimize the key parameters of LSSVM, thereby constructing the IPOA-LSSVM fault location model. After performing wavelet transform on the fault signals collected at both ends, the amplitude ratio of the first wave head is obtained and then input into the proposed model to output the fault distance as simulation verification. Simulation results show that the proposed model can locate fault reliably and accurately regardless of transition resistance and fault type.

Key words fault location; HVDC transmission system; first wave head amplitude ratio; improved pelican optimization algorithm (IPOA); least squares support vector machine (LSSVM)