

基于VMD-MWPE和PNN的配电网故障分类辨识方法

李泽文,葛俊辰,陈思旭,蔡添翼,彭小博

(长沙理工大学,湖南长沙 410000)

摘要:针对配电网故障分类辨识准确性不高的问题,提出了一种结合变分模态分解(variational mode decomposition, VMD)、多尺度加权排列熵(multi-scale weighted permutation entropy, MWPE)和概率神经网络(probabilistic neural network, PNN)的配电网故障分类辨识方法。提取配电网10种典型故障行波信号,使用相模变换提取 α 模量;再对 α 模量进行VMD处理,选取峭度最大的模态;利用MWPE方法提高信号的平滑性和稳定性,并对选定模态进行熵值分析,从多个尺度上刻画信号特征;通过改进的鲸鱼优化算法(improved whale optimization algorithm, IWOA)优化PNN模型,对提取的故障特征进行分类识别,有效区分不同故障类型。实验结果表明,文中所提的VMD-MWPE-PNN方法在配电网故障类型识别中具有较高的准确性和较强的鲁棒性,测试集准确率达到98%。

关键词:变分模态分解;多尺度加权排列熵;概率神经网络;配电网故障分类

中图分类号:TM 727 TP301.6 **文献标志码:**A **文章编号:**1006-348X(2025)03-0028-10

0 引言

配电网作为电力系统的重要组成部分,在运行过程中,会受到外界环境、设备老化等因素的影响,容易出现各种故障,这些故障可能导致供电中断,甚至引发安全事故。因此,对配电网故障进行准确的分类和识别,对于提高供电系统的稳定性和可靠性具有重要意义^[1-2]。

近年来,越来越多的研究人员通过对故障行波信号的特征分析,分类和识别配电网中的故障。对故障行波信号进行特征分析之前,需要进行有效的预处理。文献[3-4]中,经验模态分解(empirical mode decomposition, EMD)和集合经验模态分解(ensemble empirical mode decomposition, EEMD)被应用于故障行波信号的预处理;然而,EMD与EEMD在故障行波信号分解过程中容易出现模态混叠问题,从而影响故障特征的提取效果^[5];为了解决这一问题,Dragomiretskiy提出了变分模态分解(variational mode decomposition, VMD)方法,能够有效地抑制模态混叠问题^[6];因此,VMD逐渐被应用于各种故障行波信号

的预处理,取得了较好的效果^[7-9]。

文献[10-11]中,多尺度排列熵(multi-scale permutation entropy, MPE)方法被广泛应用于故障行波信号的非线性特征提取。尽管MPE具有计算简单、抗噪能力强和鲁棒性好的优点,但其忽略了相同排列模式之间的幅度差异,没有包含时间序列的振幅信息,影响了故障辨识的精度^[12-13]。为了解决这一问题,相关研究提出了多尺度加权排列熵(multi-scale weighted permutation entropy, MWPE)方法,MWPE在分析时间序列复杂度时包含了故障行波信号的振幅信息,能够更准确地反映故障行波信号的非线性特征^[14]。

概率神经网络(probabilistic neural network, PNN)在模式识别和故障辨识中被广泛应用,具有训练速度快、分类性能好和易于实现等优点。然而,PNN的性能依赖于其平滑参数的选择,如选择不当可能导致分类效果不佳;此外,PNN在处理大规模数据时,容易出现计算量大、训练时间长等问题。为了优化PNN的性能,有研究者提出了鲸鱼优化算法(whale optimization algorithm, WOA)来优化PNN的平滑参数,改善了PNN在故障辨识中的分类精度和计算效率^[15]。然而,WOA也存在易陷入局部最优解

收稿日期:2024-12-02

基金项目:湖南省科技创新人才计划科技创新团队项目(新能源电力系统安全监控创新团队,2021RC4061)。

作者简介:李泽文(1975),男,博士,教授,主要研究方向为电力系统保护与控制。

和收敛速度慢等问题。

为了进一步提升WOA的性能,文中提出了改进鲸鱼优化算法(improved whale optimization algorithm, IWOA)。IWOA通过引入自适应参数调整机制和变异操作,增强算法的全局搜索能力和收敛速度,从而更有效地优化PNN的平滑参数,提高PNN在故障辨识中的分类效果。

文中将IWOA与PNN相结合,提出了一种基于VMD-MWPE-PNN的配电网故障分类辨识方法。首先,对配电网的故障行波信号进行相模变换;其次,再对 α 模量进行VMD处理;然后,采用MWPE方法提取故障行波信号的非线性特征;最后,采用IWOA优化后的PNN对提取的特征进行故障分类辨识。

1 故障行波特性分析

在实际配电网中,故障类型通常由线路物理位置(如分支点、负载端)、故障电气特性(如单相接地、相间短路)和故障条件(如过渡电阻、初相角)共同决定。尽管无法直接测量实际故障点位置,但行波信号在传播路径上的反射/折射特征与故障点的物理位置存在强相关性。文中通过仿真构建不同位置(f_1 和 f_2)的故障场景,本质是模拟实际线路中因拓扑差异导致的行波传播路径变化(如近端分支与远端主干线故障),而初相角和过渡电阻的设置反映了实际故障的电气多样性(如雷击高阻故障、金属性短路)。通过量化这些参数对行波特征的影响,可为实际故障定位提供理论映射关系。

根据叠加原理,故障行波可视为由故障点产生的初始行波与在传播过程中遇到阻抗不连续点所引起的反射波和透射波的叠加结果。当线路发生故障时,故障点等效为一个新的信号源,产生的行波信号沿线双向传播;在遇到阻抗变化或网络拓扑结构改变的节点时,行波会部分反射回原路径,部分透射继续前进。各次反射和透射的行波按照时间序列叠加,形成了复杂的行波波形,其特征包含了故障位置、故障类型和系统参数等关键信息。

从频域的角度来看,故障行波具有宽频带特性。波阻抗 $Z_c(\omega)$ 、传输函数 $A(\omega)$ 以及折射和反射系数 $H_z(\omega)$ 和频率函数 $K_f(\omega)$,如公式(1)到公式(5)所示。不同频率成分的行波在传输过程中会经历不同程度

的幅值衰减和相位变化:高频成分衰减较快,而低频成分衰减较慢。传输距离越长,衰减效果越明显。此外,在波阻抗不连续点,不同频率成分的折射和反射程度也不同。因此,对于不同的故障点、检测点检测到的行波频率分布也会有所不同。

$$Z_c(\omega) = \sqrt{\frac{R_0 + j\omega L_0}{G_0 + j\omega C_0}} \quad (1)$$

式中: L 为电感; R 为电阻; C 为电容; G 为电导。该公式描述了波在介质中的传播特性。

$$\gamma(\omega) = \sqrt{(R_0 + j\omega L_0)(G_0 + j\omega C_0)} = \alpha(\omega) + j\beta(\omega) \quad (2)$$

$$A(\omega) = e^{-\gamma x} \quad (3)$$

公式(2)、(3)分别描述了行波在传播过程中的幅值衰减和相位变化,其中 r 是与介质特性相关的常数, x 是传播距离。

$$H_z(\omega) = \frac{2Z_{c2}}{Z_{c2} + Z_{c1}} \quad (4)$$

$$K_f(\omega) = \frac{Z_{c2} - Z_{c1}}{Z_{c2} + Z_{c1}} \quad (5)$$

公式(4)描述了行波在遇到阻抗不连续点时的折射与反射情况,公式(5)描述了行波在不同频率下的传播特性。其中, Z_{c1} 和 Z_{c2} 分别为波阻抗不连续点两侧的阻抗。

从时域的角度来看,这些反射和折射的行波以不同的时间顺序返回或继续传播,各个行波的波头在时间上相互叠加,形成了最终观测到的行波波形。也就是说,行波波形是多个行波信号在时间轴上按照特定顺序叠加的结果。在分析不同故障点的行波传输特性时,行波的频率分布和波形特性与故障点的位置密切相关。由于不同故障点导致的行波信号在传播路径上的差异性,使得每一个故障点的行波信号在检测点处表现出独特的时域和频域特征。因此,每个故障点都会在检测点处产生独特的行波波形。根据行波传输特性,绘制了如图1所示的故障点 f_1 - f_3 的故障行波传输网格图,由于配电网折反射过程复杂,文中只展示局部网络结构,并以故障后的初始行波波头 U_1 、故障点反射波波头 U_2 和对端反射波波头 U_3 三个典型波头为例,分析不同故障位置下行波传输特性差异。

以 f_1 和 f_2 为例,分析不同支路故障的行波传输特性, f_1 和 f_2 为位于同一支路的不同故障位置,二者故障距离、故障过渡电路、故障初相角保持一致。结合图1所

示传输路径,可知 f_1 和 f_2 前3次行波传输路径较为相似,为分析 f_1 和 f_2 行波信号的不同之处,列出 f_1 和 f_2 电压行波典型波头表达式,如式(6)、(7)所示。




图1 不同故障点的行波传输网络图

$$\begin{cases} U_1^{f_1} = 0.5U_{f_1} e^{-r_1 x} (1 + \beta_{f_1-1}) \\ U_2^{f_1} = 0.5U_{f_1} e^{-r_1 3x} \beta_{f_1-1} \beta_{1-f_1} (1 + \beta_{f_1-1}) \\ U_3^{f_1} = 0.5U_{f_1} e^{-r_1 (2l_2-x)} \beta_{f_1-a} \alpha_{a-f_1} (1 + \beta_{f_1-1}) \end{cases} \quad (6)$$

式中: $U_1^{f_1}$ 、 $U_2^{f_1}$ 、 $U_3^{f_1}$ 分别为故障点 f_1 时到达检测点的典型波头; U_{f_1} 为故障点 f_1 处的初始电压行波; $e^{-r_1 l}$ 为故障行波在架空线路上的传输函数; x 为故障点到检测装置安装处的距离; l_2 为区段1-a的长度; a 和 β 分别为在各个波阻抗不连续点的折射系数和反射系数,其下标代表折反射方向,如 β_{f_1-1} 代表 f_1 到1的反射系数, β_{1-f_1} 代表1到 f_1 的反射系数。

$$\begin{cases} U_1^{f_2} = 0.5U_{f_2} e^{-r_1 x} (1 + \beta_{f_2-1}) \\ U_2^{f_2} = 0.5U_{f_2} e^{-r_1 3x} \beta_{f_2-1} \beta_{1-f_2} (1 + \beta_{f_2-1}) \\ U_3^{f_2} = 0.5U_{f_2} e^{-r_1 (2l_1-x)} \beta_{f_2-4} \alpha_{4-f_2} (1 + \beta_{f_2-1}) \end{cases} \quad (7)$$

式中: $U_1^{f_2}$ 、 $U_2^{f_2}$ 、 $U_3^{f_2}$ 分别为故障点 f_2 是到达检测点的典型波头; U_{f_2} 为故障点 f_2 处的初始电压行波; l_1 为支路1-4的长度;其它参数同上。

因此,各测点行波波头与故障点位置、故障类型等存在唯一映射关系。通过分析行波信号,可以实现故障类型的辨识。

2 基于VMD-MWPE的配电网故障特征提取

2.1 变分模态分解

VMD是一种非递归的自适应信号分解方法。在VMD方法中,一般采用式(8)中的约束变分模型计算

每个模态的中心频率与相应带宽,从而确定VMD的分解模式。

$$\left\{ \min_{\{\mu_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \mu_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \right. \quad (8)$$

$$s.t. \sum_k \mu_k(t) = f(t)$$

式中: $\mu_k(t)$ 是第 k 个模态函数; ω_k 为相应的中心频率。根据式(9)中的增广拉格朗日函数求解式(8)中的约束变分模型。

$$L(\{\mu_k\}, \{\omega_k\}, \lambda) = \alpha_1 \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \mu_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \quad (9)$$

$$+ \left\| f(t) - \sum_k \mu_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k \mu_k(t) \right\rangle$$

式中: α_1 为二次惩罚参数; $\lambda(t)$ 为拉格朗日乘法算子。根据式(10)、式(11)以及式(12)在每次分解中迭代更新 μ_k 、 ω_k 及 λ 。

$$\mu_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i \neq k} \mu_i(\omega) + \frac{\lambda(\omega)}{2}}{1 + 2\alpha_1(\omega - \omega_k)} \quad (10)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\mu_k(\omega)|^2 d\omega}{\int_0^\infty |\mu_k(\omega)|^2 d\omega} \quad (11)$$

$$\lambda^{n+1}(\omega) \leftarrow \lambda^n(\omega) + \tau \left[f(\omega) - \sum_k \mu_k^{n+1}(\omega) \right] \quad (12)$$

当满足式(13)中的迭代停止条件时,迭代更新结束,输出 k 个模态分量。

$$\sum_k \left\| \mu_k^{n+1} - \mu_k^n \right\|_2^2 / \left\| \mu_k^n \right\|_2^2 < \varepsilon \quad (13)$$

式中: ε 为判别精度。

2.2 多尺度加权排列熵

对于时间序列 $X=\{x_1, x_2, \dots, x_N\}$,它可以在相空间中重构:

$$X^{m,\tau} = \{X^{m,\tau}(1), X^{m,\tau}(2), \dots, X^{m,\tau}(N - (m-1)\tau)\} \quad (14)$$

式中: m 是嵌入维度; τ 是延时时间; $X^{m,\tau}(k)$ 可以被定义为:

$$X^{m,\tau}(k) = \{x(k), x(k+\tau), \dots, x(k+(m-1)\tau)\} \quad (15)$$

式中: $x(k)$ 是单个时间点的数值; $k=1, 2, \dots, N-(m-1)\tau$ 。

将时间重构序列 $\{x(k), x(k+\tau), \dots, x(k+(m-1)\tau)\}$ 按照升序排列可以获得符号序列:

$$\{x(k+(v_1-1)\tau) \leq x(k+(v_2-1)\tau) \leq \dots \leq x(k+(v_m-1)\tau)\} \quad (16)$$

如果排列熵中的“排列模式” $\pi_l^{m,\tau}$ 有 $m!$ 个可能的值,则 $\pi_l^{m,\tau}$ 可以由式(17)表示:

$$\pi_l^{m,\tau} = \{v_1, v_2, \dots, v_m\} \quad (17)$$

排列熵(PE)可以被表示为:

$$PE(X, m, \tau) = - \sum_{l: \pi_l^{m,\tau}} p(\pi_l^{m,\tau}) \ln(p(\pi_l^{m,\tau})) \quad (18)$$

根据方程(18) $p_\omega(\pi_l^{m,\tau})$ 可被定义为:

$$p_\omega(\pi_l^{m,\tau}) = \frac{\|k | \pi_k^{m,\tau} = \pi_l^{m,\tau} \| \omega_k}{\{N-(m-1)\} \omega_k} \quad (19)$$

这里 ω_k 可以表示为:

$$\omega_k = \frac{1}{m} \sum_{q=1}^m \left[x(k + (q-1)\tau) - \bar{X}^{m,\tau}(k) \right]^2 \quad (20)$$

则加权排列熵 $WPE(X, m, \tau)$ 可以被定义为:

$$WPE(X, m, \tau) = - \sum_{l: \pi_l^{m,\tau} \in \Pi} p_\omega(\pi_l^{m,\tau}) \ln(p_\omega(\pi_l^{m,\tau})) \quad (21)$$

其中, $\bar{X}^{m,\tau}(k) = 1/m \sum_{q=1}^m [x(k + (q-1)\tau)]$, 多尺

度加权排列熵(MWPE)可以被定义为:

$$MWPE(X, m, \tau, s) = WPE(y^s, m, \tau) \quad (22)$$

2.3 不同类型故障特征分析

为了对信号进行解耦,文中对采集到的故障行波进行相模变换,将三相电压行波的相量转换为模态量。

对于三相系统(A、B、C),可以使用Karenbauer变换将相量转换为模态量。用于将三相系统的相电压或电流转换到不同的模态域,以便更好地分析系统中的对称分量。

Karenbauer变换的矩阵形式如下:

$$\begin{bmatrix} V_\alpha \\ V_\beta \\ V_0 \end{bmatrix} = \begin{pmatrix} 1 & 1 & 1 \\ 1 & -1 & 0 \\ 1 & 0 & -1 \end{pmatrix} \cdot \begin{bmatrix} V_A \\ V_B \\ V_C \end{bmatrix} \quad (23)$$

式中: $\alpha = e^{j2\pi/3}$ 是三相系统中的对称因子,通常表示为一个单位复数,具有 120° 的相位差。

在Karenbauer变换中, α 分量通常包含了系统的主要信息。相对于 β 和零序分量, α 分量往往更能代表三相系统中的非对称性和动态变化,故本研究直接使用 α 分量进行分析。研究涵盖配电网中十种典型故障类型,包括单相接地故障(AG, BG, CG)、两相短路故障(AB, BC, CA)、两相接地短路故障(ABG, BCG, CAG)以及三相短路故障(ABC)。为便于展示与对比,图2选取了其中四种具有代表性的故障类型,对其相模变换后的 α 分量行波信号进行可视化分

析。其中AG表示A相接地故障,ABG表示AB两相短路并接地故障,AB表示AB两相短路故障,ABC表示三相短路故障。






图2 四种故障行波 α 分量


由于配电网故障行波信号具有非线性、非平稳性的特点,因此,文中使用VMD对十种故障行波 α 分量信号进行处理。图3为其中四种具有代表性的故障行波信号的VMD分解图,展示了四种故障模式下的频带特征差异。




a) AG VMD分解图



b) ABG VMD分解图



c) AB VMD分解图



d) ABC VMD 分解图

图3 部分故障行波信号的VMD分解图

峭度是描述数据分布形状的统计量,用来衡量数据分布的尾部厚度。在故障监测和诊断中,峭度可以作为检测异常或识别故障信号的一个重要指标。高峭度值通常表明信号包含较多的尖峰或极端值,这可能是由故障或其他非正常工作状态引起的。峭度的计算公式为:

$$\eta = \frac{E(x - \mu)^4}{\sigma^4} \tag{24}$$

式中: η 为峭度; $E(\cdot)$ 为样本期望; x 为IMF分量; μ 为样本均值; σ 为样本方差。

通过VMD处理后得到各故障类型模态分量的中心频率和峭度值(见表1)。从表1可知,不同故障类型下的模态分量在频率和峭度上表现出明显的差异,其中,高频模态分量通常对应较高的峭度值,表明这些高频成分可能与配电网的故障或突变有关。在ABC三相短路故障中,IMF4的中心频率高达203 200.77 Hz,峭度值达到44.45,表明在该模态中包含了高频的、强烈的信号特征,反映了故障点的尖锐波动。而对于一些低频模态,如IMF1通常中心频率较低,峭度值也相对较低,则信号可能更平稳。不同故障类型的模态分析揭示了频率和峭度的相关性,高频模态往往伴随着突变和异常,而低频模态则可能代表了系统的常态运行。

表1 IMF 中心频率及其峭度值

故障类型	模态分量	中心频率 (Hz)	峭度值
ABC	IMF1	2 052.17	2.80
	IMF2	39 953.70	8.69
	IMF3	96 606.37	28.88
	IMF4	203 200.77	44.45
ABG	IMF1	4 546.96	2.86
	IMF2	57 260.61	3.83
	IMF3	108 707.17	22.68
	IMF4	51 716.04	2.16
AB	IMF1	2 387.28	2.35
	IMF2	57 738.02	7.06
	IMF3	43 724.78	2.12
	IMF4	105 118.03	26.17
AG	IMF1	5 228.59	3.06
	IMF2	56 569.30	3.09
	IMF3	110 927.35	20.95
	IMF4	52 734.06	2.16

从表1中可知,ABC三相短路故障的IMF4分量呈现高频(203 kHz)和高峭度(44.45),对应故障点瞬时放电产生的高频行波;而单相接地故障(AG)的IMF3分量中心频率(110 kHz)较低,反映了接地电弧的非线性振荡特性。不同故障类型的频域特征差异可为实际故障诊断提供物理依据。

由于MWPE通过排列模式来分析信号,不依赖于信号的具体数值,而是关注数据点之间的相对大小,这使得它对信号的平均值和方差的变化不敏感,因此适用于非平稳信号分析;同时,排列熵的计算不受信号形式的限制,可以有效捕捉非线性动态的复杂性。文中选择峭度值最大的一个模态分量来进行信号的重构优化,通过将MWPE与峭度值最大的模态分量结合,能够在不牺牲信号关键信息的前提下,有效简化数据处理流程,实现对故障信号的高效识别和分析。

MWPE中嵌入维度决定了在构建排列模式时考虑的时间序列数据点的数量,维度越高,能够捕获的时间序列动态特性越丰富。尺度因子则决定了数据的粗粒化级别,通过调整尺度因子,MWPE可以在不同的时间尺度上分析信号,揭示出信号在不同尺度下的动态变化特性。尺度因子的选择影响到信号的平滑程度和分析的敏感性,较大的尺度因子会使得信号过于平滑,丢失一些细节信息,而较小的尺度因子则可能导致噪声的影响增加。

文中随机选取了峭度最大模态分量的2000个数据样本,设置嵌入维度为5,尺度因子为15,计算其MWPE的熵值,如图4所示。




图4 峭度最大模态分量的MWPE曲线

从图4可知,随尺度因子增加,熵值逐渐上升。这表明在更大的尺度上,故障行波信号的排列复杂度增加,因为在更长的时间尺度上能观察到更多的动态

变化。在尺度因子较大的范围中,十种故障行波信号的熵值具有较为明显的差异,因此可以区分十种故障类型。

基于上述分析,文中选择每个故障类型在特定尺度下的MWPE值作为PNN的特征输入。

3 基于VMD-MWPE的配电网故障辨识方法

3.1 概率神经网络

PNN由输入层、隐含层、求和层和输出层组成,结构如图5所示。




图5 PNN网络结构图

PNN是一种基于统计理论的前馈神经网络,主要用于模式分类。其学习过程如下:

1) 对学习样本的特征矩阵进行归一化,每个训练样本数设为 p 。每个样本的特征向量维数为 m ,输入特征矩阵为 X_1 。

$$X_1 = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{p1} & x_{p2} & \cdots & x_{pm} \end{bmatrix}_{p \times m} \quad (25)$$

2) 计算输入矩阵中每个特征向量的模,得到矩阵 B 。

$$B = \left[1/\sqrt{\sum_{k=1}^m x_{1k}^2}, 1/\sqrt{\sum_{k=1}^m x_{2k}^2}, \dots, 1/\sqrt{\sum_{k=1}^m x_{pk}^2} \right] \quad (26)$$

3) 根据公式(25)和公式(26),得到归一化矩阵 C 。

$$C = B_{p1} \times [1 \ 1 \ \cdots \ 1]_{1p} \times X_{pm} \quad (27)$$

4) 将归一化后的样本数据输入概率神经网络的模式层。

$$E = \begin{bmatrix} E_{11} & E_{12} & \cdots & E_{1m} \\ E_{21} & E_{22} & \cdots & E_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ E_{p1} & E_{p2} & \cdots & E_{pm} \end{bmatrix} \quad (28)$$

5) 使用径向基函数作为激活函数。激活函数的使用,使得隐含层神经元的输出表示输入样本与训练样本之间的相似度。通过对所有隐含层输出进行累加,PNN实现了对类别条件概率密度函数的非参数估计,即核密度估计。在输出层,PNN根据贝叶斯决策理论计算后验概率,选择最大后验概率对应的类别作为分类结果。

3.2 改进鲸鱼优化算法

为提高模式识别的效率和准确性,本研究将改进的鲸鱼优化算法与概率神经网络结合使用。使用IWOA来搜索最优参数配置,可以提升网络在各种复杂环境下的适应性和分类性能。这种结合不仅可以利用IWOA的全局搜索能力快速找到较优解,还能通过PNN快速实现对大数据环境下的模式分类,实现两者优势的互补。

WOA通过模拟鲸鱼群体在捕食过程中的包围圈、螺旋更新位置和随机搜索三种行为,来进行优化搜索。

1) 包围圈行为

鲸鱼通过计算猎物的位置,逐渐缩小包围圈来捕食猎物:

$$D = |C \times X^*(t) - X(t)| \quad (29)$$

$$X(t+1) = |X^*(t) - A \times D| \quad (30)$$

式中: $X^*(t)$ 是当前最佳解的位置; A 和 C 是系数向量,定义如下:

$$A = 2 \times a \times r - a \quad (31)$$

$$C = 2 \times r \quad (32)$$

式中: a 随迭代次数线性递减; r 是 $[0,1]$ 范围内的随机向量。

2) IWOA的改进方法

为了提高算法的全局搜索能力,通过调整关键参数、引入自适应权重、采用混沌映射或交叉变异操作等手段,可以得到IWOA。IWOA引入了动态调整因子 α_2 和 β_2 ,用于调节 A 和 C 的值:

$$\alpha_2 = 2 \exp\left(-\frac{t}{T}\right) \quad (33)$$

$$\beta_2 = \cos\left(\frac{\pi t}{2T}\right) \quad (34)$$

式中: t 是当前迭代次数; T 是最大迭代次数。

IWOA在更新位置时,引入了自适应搜索机制,根据个体适应度调整搜索步长如式(35)所示:

$X(t+1)=X^*(t)-\alpha_2\times A\times D+\beta_2\times(X_{\text{rand}}-X(t))$ (35)

式中: X_{rand} 是种群中随机选择的个体位置, A 和 C 的计算方式同WOA。

3.3 优化概率神经网络

本研究采用了IWOA来优化PNN的权重和偏置参数,目的是增强网络对配电网故障类型的分类精度和鲁棒性。初始化网络的所有参数,包括权重和偏置,PNN的权重和偏置从一个标准正态分布中随机初始化。

本研究的优化主要目标是最小化误分类率,是通过最小化网络输出与真实标签之间的误差来实现。为此,采用交叉熵损失函数作为优化的性能指标,这是处理分类问题中常用的损失函数。交叉熵损失函数可以表示为:

$$L=-\sum_{i=1}^N y_i \log(p_i)+(1-y_i) \log(1-p_i) \quad (36)$$

式中: y_i 是样本的真实标签; p_i 是模型预测的概率。通过最小化此损失函数,能有效地减少模型在分类时的误差,从而提高分类的准确性。

在优化过程中,IWOA模拟鲸鱼捕食行为的策略,通过动态调整搜索参数来逼近全局最优解。

IWOA算法的关键参数调整包括:

1) 包围圈行为:系数 A 和 C ,其中 A 在迭代过程中从 $[-a,a]$ 中动态调整, a 从2线性递减到0, C 设为1。

2) 螺旋更新行为:调整参数 b ,用于控制螺旋形状的大小,设为1。

优化过程的停止条件设定为:最大迭代次数设置为1000次迭代,如果连续50次迭代中,损失函数的改进小于 10^{-4} ,则停止迭代。

在本研究中,首先,从配电网系统采集原始信号数据,经过预处理、特征提取、归一化处理,然后利用VMD和MWPE精确识别故障特征。这些特征反映了配电网不同故障类型的关键模式,能有效地描述信号的时频特性。随后,提取的特征作为PNN模型的输入,PNN模型在经过IWOA优化后,能够更好地对不同的故障特征进行分类识别。IWOA通过优化PNN的权重和偏置,进一步提高了模型在复杂电网故障分类中的辨识准确性。通过这种优化后的PNN模型,能够实现对剩余九种典型故障类型的精确识

别,有效提升了故障辨识的精度和鲁棒性;最后,在测试集上评估模型,以确保其在实际应用中的准确性和泛化能力,数据处理流程如图6所示。




图6 数据处理流程

PNN的输入层包含5个神经元,对应于每个输入样本的特征维度。模式层的神经元数等于训练样本的数量,本研究中为每种类型1000个样本,共10种类型,因此,模式层共有10 000个神经元。输出层的神经元数量则对应于分类的10个类别数,每个神经元代表一种故障类型。网络的输出是一个整数标签,范围从1到10,表示预测的故障类型。

4 仿真分析

4.1 仿真模型构建

为进一步验证文中提出的VMD-MWPE和PNN方法在电网故障辨识中的实际应用效果,在PSCAD仿真平台上构建了一个配电网仿真环境。如图7所示,该配电网模型拓扑结构涵盖了M1至M10共十个测量点。




图7 配电网仿真模型拓扑结构图

模型中,在故障发生后,行波会从故障点向周围的测量点 M1 至 M10 传播。通过控制故障的位置、过渡电阻和初相角,仿真实验可以模拟多样化的故障场景。为模拟现实中可能出现的不同故障类型,文中模拟了配电网中十种典型故障类型,包括单相接地、两相短路、两相接地短路和三相短路,每种故障类型覆盖不同故障位置(0.5~5 km)、初相角($10^{\circ}\sim 170^{\circ}$)和过渡电阻($10\sim 1000\ \Omega$),共 10 000 个样本数据,以全面反映实际故障场景。故障的参数设置如表 2 所示,以模拟故障发生瞬间电路的实际响应。

表 2 配电网故障参数

故障位置(km)	0.5,1.0,1.5,2.0,2.5,3.0,3.5,4.0,4.5,5.0
初相角($^{\circ}$)	10,30,50,70,90,110,130,150,160,170
过渡电阻(Ω)	10,100,300,400,500,600,700,800,900,1000

表 2 中的故障参数设置参考了 IEEE 34 节点配电网实测数据,过渡电阻范围($10\sim 1\ 000\ \Omega$)覆盖了实际故障中的高阻电弧($100\sim 1\ 000\ \Omega$)和低阻短路($<100\ \Omega$)场景,初相角($10^{\circ}\sim 170^{\circ}$)模拟了不同合闸时刻的暂态过程。故障位置(0.5~5 km)对应典型配电网线路分段长度,通过控制变量法分离位置、电阻、初相角的影响,可指导实际系统中基于行波波头时间差和频域衰减特征的故障区段辨识。

4.2 故障辨识结果

为了评估文中提出的方法在故障类型识别方面的有效性,从每种故障类型的信号中计算了 10 000 个样本的熵值。选择 2700 个样本作为测试集,均匀分布于十种不同的故障类型,每种类型包含 300 个样本。剩余 7300 个样本被用作训练集,确保模型在学习过程中能够充分适应各种故障情况。

PNN 很大程度上依赖于平滑因子,而不恰当的平滑参数选择会导致分类精度不高或过拟合问题。为了克服这些缺点,可以利用 WOA 优化算法自动调整 PNN 的关键参数,提升其性能和泛化能力,从而提高分类的精度和效率;然而,WOA 也存在一些局限性,如收敛速度较慢或陷入局部最优解等。因此,本研究采用了 IWOA 来优化 PNN。IWOA 通过引入改进的搜索机制和参数更新策略,加速了收敛过程并提高找到全局最优解的概率。IWOA 参数设置如表 3 所示。

表 3 IWOA 参数

参数	描述	值
种群大小	初始搜索代理的数量	50
迭代次数	最大迭代次数	100
收缩系数	决定搜索范围的系数	0.5
螺旋更新参数	控制螺旋行为的参数	1.2

使用 IWOA 优化 PNN 后,得到的分类结果如图 8 所示。




图 8 IWOA 优化后 PNN 分类结果

从图 8 可知,十种故障类别间的界限清晰,说明模型具有良好的分类能力和高度的区分度。表明 PNN 网络能够准确识别大多数样本的类别。

为了验证 IWOA 的优越性,比较 IWOA 优化前后 PNN 的性能。对比结果如表 4 所示。

表 4 优化结果对比表

指标	优化前	优化后
准确率	85	98
召回率	80	93
精确度	82	94

从表 4 可知,优化前 PNN 的准确率为 85%,召回率为 80%,精确度为 82%。通过 IWOA 进行参数优化后,各项性能指标均有显著提升:准确率提高到 98%,召回率提升至 93%,精确度也增加到 94%。

这种显著的性能提升表明,IWOA 可以有效地调整 PNN 的关键参数,使得其在处理数据时更加有效,尤其是在区分不同类别的能力上表现更佳。

4.3 鲁棒性分析

为了进行鲁棒性分析并展示 PNN 在不同噪声水平下的性能,通过控制某些变量来观察其他变量的影响,以更好地了解模型在不同情况下的鲁棒性。

分别固定初相角、过渡电阻,改变信噪比;固定过渡电阻、信噪比,改变初相角;固定信噪比、初相角,改变过渡电阻,探究这些情况下对模型分类准确率、召回率的影响。

表5显示了在固定初相角为90°、过渡电阻为0.1 Ω的条件下,随着信噪比的降低,准确率、召回率均逐渐下降。较低的信噪比意味着信号中的噪声成分增加,从而会降低分类性能。

表5 固定初相角、过渡电阻,改变信噪比

过渡电阻(Ω)	初相角(°)	信噪比(dB)	准确率(%)	召回率(%)
0.1	90	70	95	94
0.1	90	60	94	93
0.1	90	50	92	91
0.1	90	40	89	88

表6展示了在固定过渡电阻为0.1 Ω,信噪比为50 dB的情况下,随着初相角的减小,识别准确率有所下降,这表明初相角的变化对模型的输出有显著影响。

表6 固定过渡电阻、信噪比,改变初相角

信噪比(dB)	过渡电阻(Ω)	初相角(°)	准确率(%)	召回率(%)
50	0.1	90	95	94
50	0.1	60	93	92
50	0.1	50	91	89
50	0.1	30	87	85
50	0.1	10	83	80

表7中显示,在固定信噪比为50 dB、初相角90°的条件下,随着过渡电阻的增加,准确率、召回率和精确度均逐渐下降。这说明过渡电阻的增加对分类性能有不利影响。

表7 固定信噪比、初相角,改变过渡电阻

信噪比(dB)	过渡电阻(Ω)	初相角(°)	准确率(%)	召回率(%)
50	0.1	90	95	94
50	100.0	90	94	93
50	1 000.0	90	92	91
50	5 000.0	90	89	88

4.4 方法对比

为了全面评估文中提出的基于VMD-MWPE和PNN结合的配电网故障分类辨识这一方法的实际应用效果,并与其他常见的故障辨识方法进行比较,进行了一系列对比实验,结果如表8所示。

表8 不同故障辨识方法性能比较

方法	准确率	召回率
VMD-MWPE + PNN	94	93
FFT + SVM	90	88
DWT + k-NN	92	90
LSTM	93	92

从上述比较中,可以看出,文中提出的VMD-MWPE+PNN方法在配电网故障辨识中表现出色。达到了94%的准确率和93%的召回率,这两项指标都优于其他比较方法。例如,FFT + SVM的准确率和召回率分别为90%和88%,DWT + k-NN分别为92%和90%。总的来说,VMD-MWPE + PNN方法在

实际电力系统故障辨识中的具有一定潜力。

4.5 实际实验验证

为进一步评估所提VMD-MWPE-PNN方法在真实配电网环境中的适用性,文中从某10 kV中压配电网现场录波系统中,提取了包含单相接地、两相短路、两相接地短路、三相短路等十种典型故障类型的实测行波信号样本共3 000组(每类300组)。现场所用故障行波录波装置采用了带有纳秒级时间同步的高精度录波单元,能够完整捕获行波波头特征并保证频域分析的精度。对这些实测数据按与仿真数据一致的预处理流程(归一化、VMD分解、MWPE特征提取)后,输入训练好的PNN模型,结果如图9所示,最终整个测试集的分类准确率达到95.36%。




图9 实际数据PNN分类结果

5 结语

文中采用了一种基于VMD-MWPE和PNN结合的配电网故障分类辨识方法。通过这种方法,得到了以下几点主要结论:

- 1) 模态分量选择:使用VMD处理配电网的故障行波信号,能够有效筛选出反映故障特性的最佳模态分量,提高了故障信号的特征提取质量和准确性。
- 2) 熵值稳定性增强:相比传统的MPE方法,文中使用的MWPE方法在处理故障信号时显示出更低的熵值波动和更高的稳定性。这证明了MWPE在提取故障行波信号的非线性特征方面的有效性。
- 3) 优化的PNN分类性能:通过IWOA优化PNN参数后,故障分类的准确率显著提高,测试集的准确

率达到98%。这表明IWOA不仅改善了PNN的参数配置,还有效提升了分类模型的性能。

3) 在真实10 kV配电网中,利用纳秒级高精度行波录波装置采集的3 000组故障信号进行测试,分类准确率达到95.36%,进一步验证了该方法在现场噪声与参数波动下的鲁棒性与实用性。

这种基于VMD-MWPE-PNN的方法不仅提高了配电网故障的诊断准确性,还通过引入先进的信号处理技术和智能优化算法,增强了故障检测系统的可靠性和实用性。故此,本方法在实际的配电网管理和故障辨识中具有很高的应用价值。

参考文献:

- [1] 徐舒玮,邱才明,张东霞,等.基于深度学习的输电线路故障类型辨识[J].中国电机工程学报,2019,39(1):65-74.
- [2] 任营,王宾,俞斌,等.LCC-HVDC逆变侧换流站近区交流线路高阻接地故障保护[J].电力系统自动化,2021,45(23):162-169.
- [3] SALEHI M., NAMDARI F. Fault classification and faulted phase selection for transmission line using morphological edge filter[J]. IET Generation, Transmission&Distribution, 2018,12(7):1595-1605.
- [4] SPOOR D. J.,ZHU J.G.Improved single-ended traveling-wave fault-location algorithm based on experience with conventional[J].IEEE Transactions on Power Delivery,2006,21(3):1714-1720.
- [5] 杨毅,范栋琛,殷浩然,等.基于深度-迁移学习的输电线路故障选相模型及其可迁移性研究[J].电力自动化设备,2020,40(10):165-172.
- [6] 王浩,杨东升,周博文,等.于并联卷积神经网络的多端直流输电线路故障辨识[J].电力系统自动化,2020,44(12):84-92.
- [7] 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(3):107-167.
- [8] ABDULLAH A.Ultrafast transmission line fault detection using a DWT-based ANN[J].IEEE Transactions on Industry Applications,2018,54(2):1182-1193.
- [9] 付华,金岑.VMD-PE协同SNN的输电线路故障辨识方法[J].电子测量与仪器学报,2020,34(6):86-92.
- [10] 郑玉平,司鑫尧,吴通华,等.特高压半波长交流输电线路的行波保护[J].电力系统自动化,2020,44(18):124-131.
- [11] 王建,吴昊,张博,等.不平衡样本下基于迁移学习 AlexNet 的输电线路故障辨识方法[J].电力系统自动化,2022,46(22):182-191.
- [12] 王浩,杨东升,周博文,等.基于并联卷积神经网络的多端直流输电线路故障辨识[J].电力系统自动化,2020,44(12):84-92.
- [13] 费春国,霍洪双.基于电流振幅与SVM的输电线路故障分类[J].电力系统及其自动化学报,2019,31(4):139-144.
- [14] 李达,薛卿,孔德健,等.基于PSO-BP算法的高压输电线路故障分类[J].电气自动化,2018,40(6):42-44.
- [15] 黄烨鑫,万振刚,程琛.基于改进鲸鱼算法寻优SVM的船用柴油机燃油系统故障辨识方法研究[J].计算技术与自动化,2021,40(2):53-56.