

基于 BWO-ELM 算法与 VR-GIS 技术的 电力光缆故障诊断及定位研究

蔡海良¹, 胡凯¹, 李军², 邢小雷³

1. 国网浙江省电力有限公司德清县供电公司, 浙江 德清 313200;
2. 浙江华云信息科技有限公司, 杭州 310008;
3. 德清欣电电力建设有限公司, 浙江 德清 313200)

摘要: 针对目前电力光缆故障模式识别精度低和故障点定位误差大的问题, 提出一种基于 BWO-ELM 算法与 VR-GIS 系统的电力光缆故障诊断及定位方法, 首先利用白鲸优化算法 (BWO) 优化极限学习机 (ELM) 初始参数, 构建 BWO-ELM 多分类 OTDR 曲线分析的故障模式识别方法, 获取光纤故障点的直线距离与类型, 为故障定位奠定基础; 其次, 提出基于 VR-GIS 的光缆故障精确定位方法将光纤故障点的直线距离转换为光缆距离, 并与实际地理位置匹配, 得到实际故障点的坐标, 同时直观展示于 VR-GIS 系统; 最后通过仿真实验来验证所提方法的应用效果, 结果表明所提方法故障模式识别精度约为 98.66%, 故障定位误差在 ±3 m 上下浮动, 平均误差为 1.481%, 较其他识别模型和故障定位方法具有较高的性能与准确率。

关键词: 电力光缆; 故障模式识别; 故障定位; BWO-ELM; VR-GIS

Research on Fault Diagnosis and Location of Power Optical Cable Based on BWO-ELM Algorithm and VR-GIS Technology

CAI Hailiang¹, HU Kai¹, LI Jun², XING Xiaolei³

1. Deqing County Power Supply Company of State Grid Zhejiang Electric Power Co., Ltd., Deqing 313200, China;
2. Zhejiang Huayun Information Technology Co., Ltd., Hangzhou 310008, China;
3. Deqing Xindian Electric Power Construction Co., Ltd., Deqing 313200, China)

Abstract: Aiming at the problems of low accuracy of power cable fault pattern recognition and large error of fault location, a method of power cable fault diagnosis and location based on BWO-ELM algorithm and VR-GIS system is proposed. First, the BWO (beluga whale optimization) algorithm is used to optimize the initial parameters of the extreme learning machine (ELM), and the BWO-ELM multi classification OTDR curve analysis fault pattern recognition method is constructed, Obtain the straight-line distance and type of the optical fiber fault point to lay the foundation for fault location; Secondly, the accurate positioning method of optical cable fault based on VR-GIS is proposed, which converts the straight-line distance of the optical fiber fault point into the optical cable distance, and matches it with the actual geographical location to obtain the coordinates of the actual fault point, which is intuitively displayed in the VR-GIS system; Finally, the application effect of the proposed method is verified by simulation experiments. The results show that the fault pattern recognition accuracy of the proposed method is about 98.66%, the fault location error is floating up and down 3M, and the average error is 1.481%. It has higher performance and accuracy than other recognition models and fault location methods.

Keywords: power optical cable; failure mode identification; fault location; BWO-ELM; VR-GIS

0 引言

电力配网通信系统伴随着电网发展建设, 也随之发生深刻变化, 配网通信系统整体规模迅速增长, 体量庞大^[1-3]。电力通信系统配网自动化通信接入网通信光缆呈现出网架覆盖范围广、拓扑结构复杂、光缆及光纤数量多、距离长等特征, 数量同比均有很大程度增长, 整体规模

“创新高”^[4-6]。

但是因为传统的配网通信系统“分散式维护”方法建立在完全依靠维护人员进行巡视的背景下, 想要实现整年全天候不间断巡视和进行故障排查具有很大的难度^[7], 因而光缆故障精确定位逐渐进入国内外专家学者的视野, 成为电力故障诊断与定位领域的研究热点。电力光缆故障精确定位研究主要由两方面构成, 一方面是对光时域反射仪

收稿日期: 2022-08-05; 修回日期: 2022-08-12。

基金项目: 国家电网重点科技项目 (CY841000JS20210264)。

作者简介: 蔡海良 (1979-), 男, 浙江德清人, 大学本科, 工程师, 主要从事配网自动化、通信技术等方向的研究。

引用格式: 蔡海良, 胡凯, 李军, 等. 基于 BWO-ELM 算法与 VR-GIS 技术的电力光缆故障诊断及定位研究 [J]. 计算机测量与控制, 2022, 30(12): 98-104, 111.

(OTDR, optical time-domain reflectometer) 测试曲线的事件点信息进行分析研究, 从而得到光缆故障点的直线距离与类型, 为故障定位奠定基础; 另一方面是对光缆故障实际地理位置精准定位进行研究, 将故障点直线距离与故障点实际地理位置匹配, 并且将实际地理位置坐标通过图像直观展示出来。

国内外学者针对电力光缆故障精准定位开展了大量的研究, 其中针对 OTDR 曲线分析方面, 文献 [8] 利用小波变换与阈值降噪的方法对 OTDR 测试信号的信噪比进行提升, 之后通过比较小波变换与信号突变位置来达到 OTDR 曲线事件点定位的目的, 但是 OTDR 曲线经过小波变换之后仅能获取部分频率的信息, 从而会导致 OTDR 曲线降噪不佳。文献 [9] 为解决 OTDR 曲线幻峰问题, 引入波分析算法与径向基函数神经网络 (RBF 神经网络, radial basis function neural network), 在一定程度上减少因幻峰而产生的故障误判现象, 但是该方法为能进一步解决 OTDR 事件点分类问题。文献 [10] 构建了基于麻雀搜索算法 (SSA, sparrow search algorithm) 一极限学习机 (ELM, extreme learning machine) 的光缆故障识别的模型, 并通过实验验证该模型的性能, 但是 SSA 算法在实际全局寻优过程当中, 不能精确找到最优解的位置。文献 [11] 选取前馈神经网络 (BP 网络, back propagation networks) 归一化处理数据, 结果表明 BP 网络能够应用于光缆故障诊断, 但是该方法整体训练速度慢, 且容易出现局部盲优现象, 最终致使分类效果不佳。

针对光缆故障实际地理位置精准定位, 国内外学者同样进行大量研究, 文献 [12] 基于抢修最优路径提出一种电力光缆故障检测方法, 通过改进 A* 算法在 GIS 平台上展示最佳抢修路径, 在一定程度上提升光缆故障的搜索效率。文献 [13] 将小波变换与 GIS 系统相结合, 实现光缆故障定位, 并且利用线性参考系统实现 OTDR 检测故障距离与实际地理位置的转换, 提升故障定位的精准度。文献 [14] 将改进模极大值去噪方法应用于光缆监测系统当中, 并在实际电网系统中应用, 在提升故障定位精度的同时使整体成本得到控制。

截止目前为止, 在电力通信系统中已经实行了多种类型的网管告警系统, 但是在应用的过程中, 还存在着诸如监控数据分散、管理内容复杂多样以及网络监视方面的问题^[15-18]。随着时间的推进前, 配网通信光缆的数量突增, 前期所敷设的光缆损耗不断提升, 光缆的维护与故障处理问题也日渐突出, 现有的故障分析和定位手段仍处于一个人工现场测试分析为主的低水平阶段, 这给通信专业的运维工作带来巨大压力^[19-20]。

综上所述, OTDR 曲线分析的故障模式识别算法众多研究当中, 普遍存在运行事件长和识别精度低等问题; 光缆故障实际地理位置定位存在相对位置误差较大的现象。考虑到配网安全生产的重要保障, 光缆安全性与健壮性是电网一次系统安全稳定运行的基础^[21-25]。本文提出基于白

鲸优化算法 (BWO, beluga whale optimization) -ELM 与虚拟现实地理信息系统 (VR-GIS, virtual reality-geographic information system) 的电力光缆故障诊断及定位方法, 能够实时精准对电力故障进行检测, 分析故障所处的实际地理位置, 并且将位置用直观的方式进行展示, 在一定程度上提升电力光缆故障在线监测能力与数字化水平。

1 基于 BOW-ELM 故障模式识别方法

基于 BOW-ELM 多分类 OTDR 曲线分析的故障模式识别的基本流程如图 1 所示。




图 1 基于 BOW-ELM 多分类 OTDR 曲线分析的故障模式识别的基本流程

由图 1 可以看出, 首先对原始 OTDR 数据进行去噪; 之后运用小波分析对 OTDR 信号进行分解, 获取高频部分特征数据, 并划分训练集与测试集; 最后将获得的特征数据输入至 BOW-ELM 模式识别模型, 最终实现 OTDR 曲线事件点信息的模式识别。

1.1 极限学习机

极限学习机是一种较为典型单隐层前馈神经网络, 主要由输入、隐含及输出三层构成, 其隐含层偏差与输入层权值均通过随机的方式进行选取, 并基于广义矩阵理论来对输出层的权值进行计算, 利用该权值能够最终获取数据的预测值。

任意 N 个样本 $(x_i, t_i), x_i = [x_{i1}, \dots, x_{im}]^T$, 且 $x_i \in R^n; t_i = [t_{i1}, \dots, t_{im}]^T$, 且 $t_i \in R^m$ 。对于由 L 个隐层节点构成的单隐层神经网络可以由下式表示:

$$\sum_{i=1}^L \beta_i g(\omega_i x_j + b_i) = o_j, j = 1, 2, \dots, N \quad (1)$$

式中, b_i 表示第 i 个隐层单元的偏置; $\omega_i \cdot x_j$ 表示两者的内积; ω_i 表示输入权重; $g(x)$ 表示激活函数; β_i 表示输出权重。输出误差最小是单隐层神经网络训练的目标, 其可以表示为:

$$\sum_{j=1}^N \|o_j - t_j\| = 0 \quad (2)$$

即存在 ω_i, β_i 及 b_i 使得:

$$\sum_{i=1}^L \beta_i g(\omega_i x_j + b_i) = t_j, j = 1, 2, \dots, N \quad (3)$$

用矩阵可以表示为:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (4)$$

式中, \mathbf{H} 表示隐藏层的输出; \mathbf{T} 表示期望输出; $\boldsymbol{\beta}$ 表示输出权重。

那么式 (4) 可转化为:

$$\mathbf{H}(\omega_1, \dots, \omega_l, b_1, \dots, b_l, x_1, \dots, x_l) =$$

$$\begin{bmatrix} g(\omega_1 \cdot x_1 + b_1) & \cdots & g(\omega_l \cdot x_1 + b_l) \\ \vdots & \cdots & \vdots \\ g(\omega_1 \cdot x_N + b_1) & \cdots & g(\omega_l \cdot x_N + b_l) \end{bmatrix}_{N \times l} \quad (5)$$

其中:

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_l^T \end{bmatrix}_{l \times N} \quad \mathbf{T} = \begin{bmatrix} T_1^T \\ \vdots \\ T_N^T \end{bmatrix}_{N \times m} \quad (6)$$

为了对单隐层神经网络进行训练, 希望得到 $\hat{\omega}_i, \hat{b}_i$ 和 $\hat{\beta}_i$, 使得下式成立:

$$\|\mathbf{H}(\hat{\omega}_i, \hat{b}_i)\hat{\beta}_i - \mathbf{T}\| = \min_{\omega_i, b_i, \beta_i} \|\mathbf{H}(\omega_i, b_i)\beta_i - \mathbf{T}\| \quad (7)$$

式中, $i = 1, \dots, L$, 该式等价于如下最小化损失函数。

$$E = \sum_{j=1}^N \left(\sum_{i=1}^l \beta_i g(\omega_i \cdot x_j + b_i) - t_j \right)^2 \quad (8)$$

在 ELM 当中, 训练单隐层神经网络能够转换为对一个线性系统 $\mathbf{H}\boldsymbol{\beta} = \mathbf{T}$ 进行求解, 则输出权重 $\boldsymbol{\beta}$ 为:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T} \quad (9)$$

式中, \mathbf{H}^+ 表示 $\mathbf{H}(\omega_1, \dots, \omega_l, b_1, \dots, b_l, x_1, \dots, x_N)$ 的广义逆矩阵; $\mathbf{T} = [T_1^T \ \cdots \ T_N^T]^T$ 表示网络输出。ELM 中激活函数通常选取非线性函数, 常见的激活函数主要由 Gaussian 函数和 Sigmoid 函数等, 本文选取 Sigmoid 函数作为 ELM 激活函数, 其表达式为:

$$g(x) = \frac{\exp(x)}{\exp(x) + 1} \quad (10)$$

由上述可知, ELM 的初始偏置 b_i 与输入权重 ω_i 均是通过随机得到, 无法保证两者为最佳值, 容易使全局最优解陷入局部最优, 从而得到不佳的分类结果。

1.2 白鲸优化算法

白鲸优化算法 (BWO, beluga whale optimization) 是 2022 年在白鲸游泳、捕鲸及跌倒等行为中得到启发而提出的一种新型基于种群的元启发式算法^[26]。

BWO 主要对白鲸游泳、捕食及跌倒 (坠落) 等行为进行模拟, 其对应探索、开发及鲸鱼坠落三个阶段。BWO 当中鲸落概率与平衡因子均为自适应的, 对开发能力与控制搜索起到决定性作用。除此之外, 在开发阶段引入 Levy 飞行策略来进一步提升该阶段的全局收敛性。

因 BWO 是基于种群机制的算法, 将白鲸当作搜索代理, 而种群中的所用白鲸个体均为候选解, 在优化过程中更新各自的位置。在模拟实验过程中, 白鲸种群可以用下式进行描述:

$$\mathbf{X} = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,d} \\ x_{2,1} & x_{2,2} & \cdots & x_{2,d} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n,1} & x_{n,2} & \cdots & x_{n,d} \end{bmatrix} \quad (11)$$

式中, n 表示白鲸种群数量; d 表示问题变量的维数, 则相应的种群适应度值为:

$$\mathbf{F}_X = \begin{bmatrix} f(x_{1,1}, x_{1,2}, \dots, x_{1,d}) \\ f(x_{2,1}, x_{2,2}, \dots, x_{2,d}) \\ \vdots \\ f(x_{n,1}, x_{n,2}, \dots, x_{n,d}) \end{bmatrix} \quad (12)$$

平衡因子决定探索与开发阶段的转换, 其表达式为:

$$B_f = B_0(1 - T/(2T_{\max})) \quad (13)$$

式中, B_f 表示平衡因子; T_{\max} 表示最大迭代次数; T 表示当前迭代次数; $B_0 \in (0, 1)$, 每次迭代在上述范围内随机变化。

探索阶段发生于 $B_f > 0.5$ 的情况下, 开发阶段发生于 $B_f \leq 0.5$ 的情况下。 B_f 的波动范围随着迭代次数的不断增加而减小, 由原来的 $(0, 1)$ 变为 $(0, 0.5)$ 。

搜索代理在探索阶段的位置是通过白鲸配对游泳来决定的, 白鲸位置更新公式为:

$$\begin{cases} X_{i,j}^{T+1} = X_{i,p_j}^T + (X_{r,p_j}^T - X_{i,p_j}^T)(1 + r_1)\sin(2\pi r_2), j = 2n \\ X_{i,j}^{T+1} = X_{i,p_j}^T + (X_{r,p_j}^T - X_{i,p_j}^T)(1 + r_1)\cos(2\pi r_2), j = 2n + 1 \end{cases} \quad (14)$$

式中, X_{i,p_j}^T 表示第 i 条白鲸在 p_j 维度上的位置; $p_j (j = 1, 2, \dots, d)$ 表示从 d 维当中所选取的随机整数; T 表示当前迭代次数; r_1, r_2 表示随机算子, 均为 $(0, 1)$ 范围内的随机数; $X_{i,j}^{T+1}$ 表示第 i 条白鲸在第 j 维上更新后的位置; X_{i,p_j}^T 与 X_{r,p_j}^T 分别表示第 i 条与第 r 条白鲸当前所处的位置; $\sin(2\pi r_2)$ 、 $\cos(2\pi r_2)$ 代表镜像白鲸的鳍朝向水面; n 为整数。维数通过奇偶数来进行选择, 更新后的位置能够反应白鲸在跳水或游泳时的镜像或同步行为。

为了增强算法的收敛性, BOW 在开发阶段引入 Levy 飞行策略, 假设白鲸在该阶段使用上述策略, 分享彼此的位置进行猎物捕捉, 并且同时考虑其他和最佳候选者, 此过程白鲸的位置更新公式为:

$$X_i^{T+1} = r_3 X_{\text{best}}^T - r_4 X_i^T + C_1 L_F \cdot (X_i^T - X_i^T) \quad (15)$$

式中, X_i^{T+1} 表示第 i 条白鲸更新后的位置; T 表示当前迭代次数; r_3, r_4 表示 $(0, 1)$ 范围内的随机数; X_i^T 表示第 i 条白鲸当前所处的位置; X_r^T 表示随机白鲸 r 当前所处的位置; X_{best}^T 表示白鲸种群当中的最佳位置; C_1 表示随机跳跃强度, 用来对 Levy 飞行强度进行衡量, 其表达式为:

$$C_1 = 2r_1 \left(1 - \frac{T}{T_{\max}} \right) \quad (16)$$

L_F 表示 Levy 飞行函数, 其表达式为:

$$L_F = 0.05 \times \frac{\mu \times \sigma}{|\nu|^{1/\beta}} \quad (17)$$

其中:

$$\sigma = \left[\frac{\Gamma(1 + \beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1 + \beta}{2}\right) \times \beta \times 2^{(\beta-1)/2}} \right]^{1/\beta} \quad (18)$$

式中, μ, ν 表示正态分布随机数; $\beta = 1.5$ 。

为了保证种群数量不变, 使用鲸鱼落体步长与白鲸位置来构建鲸落阶段的位置更新模型, 模型的数学表达式为:

$$X_i^{T+1} = r_5 X_i^T - r_6 X_r^T + r_7 X_{\text{step}} \quad (19)$$

式中, X_{step} 表示鲸鱼坠落的步长 r_5, r_6 及 r_7 表示 $(0, 1)$ 范围内的随机数; X_{step} 表示鲸鱼坠落的步长, 其表达式为:

$$X_{\text{step}} = (u_b - l_b) \exp\left(-\frac{C_2 T}{T_{\max}}\right) \quad (20)$$

式中, u_b 表示变量的上限; l_b 表示变量的下限; C_2 表示与种

群规模和鲸鱼下降概率相关的阶跃因子, 其计算式为:

$$C_2 = 2W_f \times n \quad (21)$$

式中, W_f 表示鲸鱼坠落概率, 其表达式为:

$$W_f = 0.1 - 0.05 \frac{T}{T_{\max}} \quad (22)$$

1.3 BWO 优化 ELM

ELM 在训练之前能够随机产生初始偏置 b_i 与输入权重 ω_i , 仅需要对隐含层神经元激活函数与隐含层神经元进行确定, 便能够实现 ELM 模型的构建。由于 ELM 模型的构建过程中, 仅需要对初始偏置 b_i 与输入权重 ω_i 进行确定, 无需设置其他参数, 故在学习效率与泛化能力方面具有一定的优势。然而在 OTDR 曲线事件点信息的模式识别过程中, 不同参数设置对模型的识别精度造成一定程度的影响, 并且容易出现局部最优现象。此时, ELM 依然采用简单随机方法来选取初始参数, 会导致算法隐含层节点出现冗余现象, 致使 ELM 识别精度低下。因此, 在构建 ELM 模式识别模型的过程中, 可以利用 BWO 算法寻优来获取最佳参数, 即最佳初始偏置 b_i 与输入权重 ω_i , 将 BOW 较强全局搜索能力和 ELM 局部快速搜索能力相结合, 从而使模型具备更快求解能力和更高的识别精度。BWO-ELM 算法流程如图 2 所示。

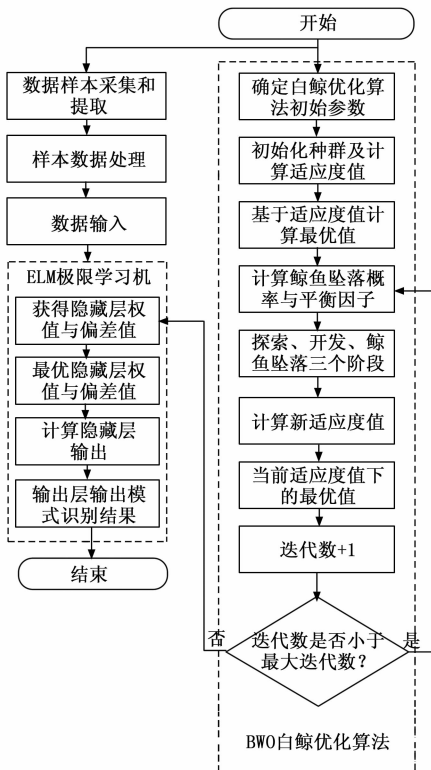


图 2 BWO-ELM 算法流程图

如图 2 所示, BWO-ELM 算法具体流程为:

Step1: 采集 OTDR 检测信号, 对信号进行小波分解, 提取特征数据形成特征样本, 并划分训练集与测试集;

Step2: 构建 ELM 模式识别模型, 对隐含层激活函数和神经元个数等信息进行确定;

Step3: 确定 BOW 最大迭代次数 T_{\max} 与种群数量 n 等初始参数确定;

Step4: 初始化 BOW 种群, 各白鲸初始位置在搜索范围内随机产生, 并基于目标函数计算得到适应的值;

Step5: 利用式 (13) 与 (22) 计算平衡因子 B_f 和鲸鱼坠落概率 W_f ;

Step6: 根据计算所得平衡因子 B_f 的大小判断每条白鲸进入的阶段, 不同阶段的更新机制不同, 假如 $B_f > 0.5$, 白鲸的更新机制处于探索阶段, 由式 (14) 更新白鲸的位置, 假如 $B_f \leq 0.5$ 白鲸的更新机制处于开发阶段, 由式 (15) 更新白鲸的位置, 然后对新位置的适应度值进行计算排序, 找到当前迭代的最优解, 每次迭代均需计算鲸鱼坠落概率 W_f , 并通过式 (19) 来更新鲸鱼的位置;

Step7: 判断当前迭代次数与最大迭代次数的关系, 如果当前迭代次数大于等于最大迭代次数, 则寻优停止输出最优参数, 反之返回 Step5 继续新一轮的寻优搜索。

基于 BWO-ELM 多分类 OTDR 曲线分析的故障模式识别方法得到光纤故障点的直线距离与类型, 为故障定位奠定基础。

2 基于 VR-GIS 的光缆故障精确定位方法

2.1 搭建虚拟光缆线路信息

借助虚拟现实地理信息系统 (VR-GIS, virtual reality-geographic information system) 强大的空间定位与数据分析优势, 本研究利用 SuperMap 与 3DMax 构建某实际区域配电自动化通信接入网虚拟光缆线路信息, 并在该信息当中融合实际光缆线路的坐标位置与基本属性信息, 之后通过 SuperMap iDesktop. Net 来实现基于 VR-GIS 的光缆故障定位、三维场景漫游及数据管理等功能, 从而为后续光缆故障精确定位提供展示平台与精确位置。

2.2 光缆故障精确定位方法

当电力光缆发生故障时, 选取多次 OTDR 测量取平均的方式来降低故障距离的测量误差, 故障距离的表达式为:

$$\bar{S} = \frac{s_1 + \dots + s_n}{n} \quad (23)$$

式中, n 表示测量的次数; s_n 表示第 n 次测量的光纤故障距离。

则光缆故障距离为:

$$S_T = \frac{S}{C_R \times P_r} \quad (24)$$

式中, C_R 表示光缆的弯曲程度; S 表示电力光纤距离; S_T 表示电力光缆距离; P_r 表示光缆胶缩率。

通过式 (24) 得到仅为故障点距离测量的距离, 并未与实际光缆敷设的地理位置进行匹配。

实际电力光缆是由各段电力光缆通过光缆接头盒 (即熔接点) 连接构成, 并且敷设的过程中需要电线塔进行支

撑,故将电力光缆线路上的机房、拐点、熔接点和塔杆等特殊位置作为参考位置,利用手持 GPS 导航仪上述特殊点的实际地理位置,并将去与 OTCR 测量的特殊位置信息进行匹配,最后将匹配后的数据通过表 1 的形式录入数据库。

表 1 数据格式表

编号	经纬度	距测量点距离	余缆长度	弯曲度	胶缩率

将电力光缆距离与表 1 当中的参考位置距离进行作差,可得:

$$O = S_T - C_n \quad (25)$$

式中, C_n 表示数据库当中参考点的距离; O 表示光缆距离与参考点距离的差值; n 表示参考位置点的编号。

计算 O 的最小值,即 $\min |O|$ 获取与电力光缆距离 S_T 最近参考点,即得到该点编号 n 。

则电力光缆距离 S_T 的经纬度为:

$$\begin{cases} x_Q = \frac{x_{n+1} - x_n}{C_{n+1} - C_n} (S_T - \sum_{i=1}^n \delta_i) \\ y_Q = \frac{y_{n+1} - y_n}{C_{n+1} - C_n} (S_T - \sum_{i=1}^n \delta_i) \end{cases} \quad O > 0$$

$$\begin{cases} x_Q = x_n \\ y_Q = y_n \end{cases} \quad O = 0 \quad (26)$$

$$\begin{cases} x_Q = \frac{x_{n+1} - x_n}{C_{n+1} - C_n} (S_T - \sum_{i=1}^n \delta_i) \\ y_Q = \frac{y_{n+1} - y_n}{C_{n+1} - C_n} (S_T - \sum_{i=1}^n \delta_i) \end{cases} \quad O < 0$$

式中, (x_Q, y_Q) 表示故障点坐标; δ_i 表示第 i 个接线盒光缆所预留的长度值。

基于 VR-GIS 的光缆故障精确定位流程如图 3 所示。

光缆故障精确定位具体流程为:

Step1: 在线检测系统检测到故障发生时,启用 OTDR 进行多次测量取平均值,利用基于 BWO-ELM 多分类 OTDR 曲线分析的故障模式识别模型对光纤数据进行分析,得到故障点的直线距离(光纤距离)与故障类型;

Step2: 由式(24)将 Step1 中获得光纤距离转换为光缆距离;

Step3: 利用式(25)与式(26)进行计算,将光缆故障距离与实际地理位置匹配,得到实际故障点的坐标;

Step4: 通过 VR-GIS 虚拟光缆线路信息进行空间定位与数据分析将实际地理位置坐标通过图像直观展示出来。

3 基于 BWO-SVM 算法与 VR-GIS 技术的电力光缆故障诊断及定位

实际运行电力通信发生故障时,首先通过基于 BWO-ELM 算法多分类 OTDR 分析法得到测量点至故障点之间的光纤距离;其次,将上述光纤距离通过基于 VR-GIS 的光缆故障精确定位方法进行光缆距离转化,并将光缆故障距离与实际地理位置匹配,得到实际故障点的坐标;最后,利

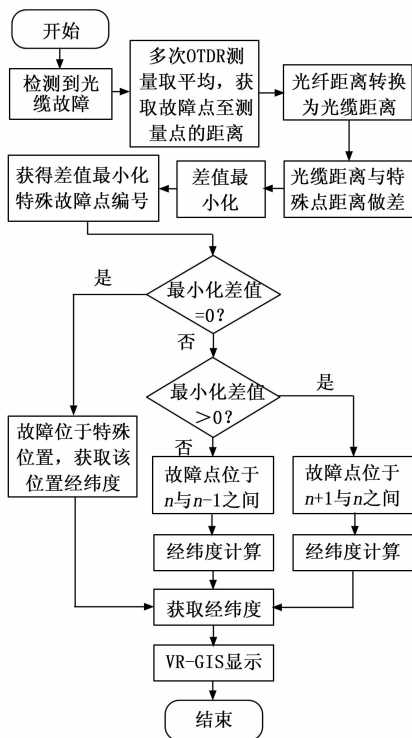


图 3 光缆故障精确定位流程图

用基于 VR-GIS 的虚拟光缆线路信息库将上述定位的坐标在二维与三维图像上进行展示,具体故障检测和定位流程如图 4 所示。

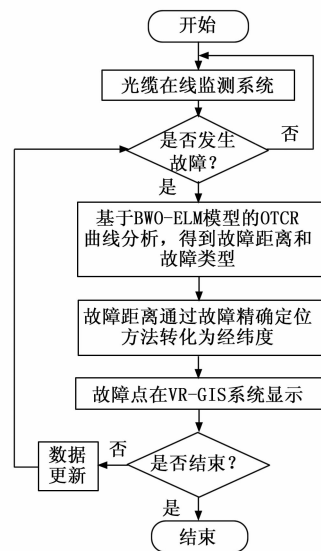


图 4 故障检测和定位流程图

4 仿真实验分析

4.1 实验数据采集与预处理

4.1.1 实验数据采集

采集浙江某 220 kV 变电站电缆线路中某段 OTDR 数据,具体数据曲线如图 5 所示,图中标有 A、B、C、D、E

和 F 六个事件点。图中 A 点有一个尖锐的凸起, 为光纤的起始端; B、D 及 E 均有一定程度的凸起, 其主要是由于光纤断裂造成; C 点为平滑的台阶, 该点为光纤熔接点; F 点为最高凸起点, 为光纤末端。本文主要对 B、C、D 与 E 两类事件点进行分析研究, 其中 B、D 和 E 为反射事件点, C 为非反射事件点。




图 5 OTDR 原始数据图

4.1.2 数据预处理

小波包分析在实际应用中具有时频分辨率高的优势, 通过对频带多层次分解, 能够使信号高频部分得到精细化分解。小波包变换为线性变换, 其满足能量守恒定律, 即:

$$\int_{-\infty}^{+\infty} |f(t)|^2 dt = \sum_j \sum_k |c_{j,k}|^2 \quad (27)$$

式中, $c_{j,k}$ 表示小波包分解系数; $f(t)$ 表示 OTDR 原始信号。

由式 (27) 可以看出小波包分解系数具有能量的量纲, 能够应用于能量分析, 故各频段的能量值可以利用信号的小波系数进行确定。

基于上述小波包原理, 对 OTDR 信号进行预处理, 步骤如下:

1) 选取 “rbio3.1” 为基小波, 分解尺度为 $J = 3$ 来对信号进行小波包分解, 信号被分解为 $K = 2^J = 2^3 = 8$ 个频带, 用 X_{3j} 来表示各个节点的分解系数, 从而与式 (27) 当中的 $c_{j,k}$ 相对应, 其中 ($j = 1, 2, \dots, 8$);

2) 对第 3 层的全部节点进行重构, X_{3j} 重构后的信号用 S_{3j} 进行表示, 原始信号长度用 N 表示, 信号 S_{3j} 离散值得幅度用 x_{jk} 来进行表示, 其中 ($j = 1, 2, \dots, 8; k = 1, 2, \dots, N$), 那么各段频段的总小波能量表达式为:

$$E_{3,j} = \int |S_{3,j}|^2 dt = \sum_{k=1}^N |x_{jk}|^2 \quad (28)$$

3) 对频段能量 $E_{3,j}$ 进行归一化, 获得一个 $E = [E_{\text{norm}}(1), \dots, E_{\text{norm}}(8)]$ 的 8 维能量特征向量, 其中:


$$E_{\text{norm}}(j) = \frac{E_{3j} - E_{\text{min}}}{E_{\text{max}} - E_{\text{min}}} \quad (29)$$

两类事件的特征能量及 100 倍放大如图 6 与图 7 所示。


4.2 光缆故障模式识别结果分析

4.2.1 ELM 识别算法结果分析

基于小波分析包得到能量特征向量, 首先利用 ELM 模型对其进行分类识别。本次实验选取 500 组数据构成数据




(a) 反射事件点原始能量图




(b) 反射事件点 100 倍放大能量图

图 6 反射事件点特征能量图



(a) 非反射事件点原始能量图



(b) 非反射事件点 100 倍放大能量图

图 7 非反射事件点特征能量图

集, 其中测试样本 150 组, 训练样本 350 组。以分类精度作为算法的评判标准, 选取不同的激活对数据进行分类识别, 得到结果如表 2 所示。

表 2 不同激活函数识别算精度对比表

激活函数	识别精度/%
Sine 函数	87.94
Hardline 函数	91.88
Sigmoid 函数	94.85

由表 2 可知, ELM 模型选用 Sigmoid 函数作为激活函数较其他激活函数, 具有较高的分类识别精度和良好的分类结果, 故选用 Sigmoid 函数作为 ELM 模型的激活函数。

为了验证 ELM 分类识别结果的优越性, 本文同时构建 BP 神经网络和 SVM 两种识别模型对相同的数据集进行训练和测试, 三种不同识别模型识别性能如表 3 所示。

表 3 不同识别模型性能表

模式识别算法	识别精度/%	识别时间/s
BP 神经网络	86.88	1.45
SVM	85.03	0.75
ELM	94.86	0.47

通过对比不同识别模型的识别精度与识别时间上，能够看出 ELM 较 BP 神经网络及 SVM 在识别精度及识别时间上具有一定的优势，具有良好的识别效果。

4.2.2 BOW-ELM 识别算法结果分析

为了验证本文所提优化算法识别模型的优越性，本节将 BOW-ELM、SSA-ELM 和 PSO-ELM 模式识别算法对样本进行训练与测试，最终各算法的识别性能如表 4 所示。

表 4 各模式识别算法性能表

模式识别算法	识别精度/%
PSO-ELM	95.97
SSA-ELM	97.69
BOW-ELM	98.66

由表 4 能够看出，本文所构建的模式识别算法的准确率较其他识别模型，具有较高的识别性能。

4.3 光缆故障定位性能分析

人为的将距通信机房 15 km 的一处熔接点进行破坏，利用本文设计的故障定位方法与电网常用 TMS 系列光缆监测系统多次故障定位，故障定位的具体数据如图 8 所示。由图 8 可以看出本文故障定位较常规定位方法，具有更高的性能与准确率，故障定位误差在 ±3 m 上下浮动。




图 8 故障定位对比图

本文通过光纤定位熔接点来对光缆故障定位精度进行验证。利用最大误差与真实值得百分比来对光缆故障定位的精度进行表征，具体为：

$$\varphi = \left| \frac{S_{\max} - \bar{S}}{S} \right| \times 100\% \quad (30)$$

式中， S_{\max} 表示多次系统检测与真实距离的最大差值； \bar{S} 故障点值通信机房的实际距离； δ 表示平台故障定位的误差值，由上式可知 δ 越小则表示故障定位精度越高。

选取距离不等的 5 个故障熔断点，并针对每个点重复进行 50 次故障定位，同时运用本文设计故障诊断算法与常规故障定位算法分别对故障精度进行计算取均值，结算结果如表 5 所示。

表 5 故障定位精度性能表

距离/km	本文平台故障定位误差值/%	现有故障定位误差值/%
5.74	0.646	0.868
9.23	1.214	1.611
15.00	1.592	2.166
24.76	1.763	3.265
38.58	1.875	4.646

由表 5 可知，本文故障定位方法误差随着故障点距离的提升逐步趋向平稳状态，而现有系统故障误差随故障距离提升呈现增长趋势，并且本文故障定位的平均误差为 1.481%，低于现有系统故障定位误差 2.511%。由此可知，本文提出的故障定位方法具有良好的故障定位性能。

5 结束语

为进一步提升电力光缆故障模式识别精度及故障定位精确度，提出一种基于 BWO-ELM 算法与 VR-GIS 系统的电力光缆故障诊断及定位方法，通过研究得到以下结论：

1) 提出一种基于 BOW-ELM 故障模式识别方法，通过 BOW 优化 ELM 初始偏置 b_i 与输入权重 w_i ，得到最佳初始偏置 b_i 与输入权重 w_i ，将 BOW 较强全局搜索能力和 ELM 局部快速搜索能力相结合，从而使模型具备更快求解能力和更高的识别精度，并得到光纤故障点的直线距离与类型，为故障定位奠定基础；

2) 提出一种基于 VR-GIS 的光缆故障精确定位方法，将光纤故障点的直线距离转换为光缆距离，并与实际地理位置匹配，得到实际故障点的坐标，通过 VR-GIS 虚拟光缆线路信息进行空间定位与数据分析将实际地理位置坐标通过图像直观展示出来；

3) 实验仿真表明：BOW-ELM 故障模式识别模型较其他识别模型，在识别精度及识别时间上具有一定的优势，具有良好的识别效果；故障定位较常规定位方法，具有更高的性能与准确率，故障定位误差在 ±3 m 上下浮动，且误差随着故障点距离的提升逐步趋向平稳状态。

随着人工智能技术的不断发展，后续的研究过程中选取更高效准确的识别算法是提升故障识别与定位精度的关键，才能使电力光缆故障检测的数字化管理能力得到进一步的提升。

参考文献：

[1] 缪巍巍, 吴海洋, 于宝辉, 等. 基于状态感知的电力通信设备自动巡检研究 [J]. 无线互联科技, 2018, 15 (22): 7-10.
 [2] 刘丽榕, 王玉东, 马睿, 等. 电网系统保护业务分析及通信承载方案研究 [J]. 电力信息与通信技术, 2017, 15 (12): 12-18.

(下转第 111 页)