

文章编号:1001-5078(2024)02-0312-09

· 光纤传感及光通讯技术 ·

基于光纤温度混合域特征的海缆浅埋状态识别

姜坤¹, 张帅¹, 傅翔¹, 史二祯¹, 安博文², 陈元林², 崔桂艳²

(1. 国家能源集团东台海上风电有限责任公司, 江苏 东台 224200; 2. 上海安馨信息科技有限公司, 上海 201306)

摘要:针对光纤温度信号非平稳、非线性的特点,以及在海床表面温度和海床深处温度近似相等即温度平衡时间段内,利用光纤温差识别海缆浅埋位置存在一定的局限性问题,提出一种基于优化VMD混合域特征和LSTM的海缆浅埋状态识别方法,用于识别海缆深埋和浅埋两种状态。首先,采用参数优化的VMD对光纤温度信号进行分解,提取各阶本征模态分量与原始信号相关系数最大的分量;其次,提取原始温度信号的时域和频域特征,结合所选IMF的时域和频域特征以及能量和熵特征构建混合域特征集,并利用CDET进行敏感特征选择;最后,设计LSTM结构,将训练集输入网络进行训练,测试集验证网络的有效性,实现海缆浅埋状态识别。通过现场采集的海缆光纤温度数据进行验证,测试准确率达到100%,结果表明,该方法能够准确识别海缆浅埋状态。

关键词: 光纤温度; 海缆浅埋识别; 混合域特征; VMD; LSTM

中图分类号: TN915.62; TH74 **文献标识码:** A **DOI:** 10.3969/j.issn.1001-5078.2024.02.023

Recognition of shallow buried state of submarine cable based on fiber optic temperature hybrid domain features

JIANG Kun¹, ZHANG Shuai¹, FU Xiang¹, SHI Er-zhen¹, AN Bo-wen², CHEN Yuan-lin², CUI Gui-yan²

(1. National Energy Group Dongtai Offshore Wind Power Co., Ltd., Dongtai 224200, China;

2. Shanghai Anxin Information Technology Co., Ltd., Shanghai 201306, China)

Abstract: In response to the non-stationary and nonlinear characteristics of fiber optic temperature signals, as well as the limitations of using fiber optic temperature difference to identify the shallow burial position of submarine cables during the temperature equilibrium time period when the surface temperature of the seabed and the temperature at the depth of the seabed are approximately equal, a shallow burial state identification method is proposed based on optimized VMD mixed domain features and LSTM for identifying the two states of deep and shallow burial of the cables. Firstly, a parameter optimized VMD is used to decompose the fiber temperature signal and extract the component with the highest correlation coefficient between the intrinsic modal components of each order and the original signal. Secondly, the time-domain and frequency-domain features of the original temperature signal are extracted, and a mixed-domain feature set is constructed by combining the time-domain and frequency-domain features as well as the energy and entropy features of the selected IMF, and the CDET is used for sensitive feature selection. Finally, an LSTM structure is designed, the training sets are inputted into the network for training, the test set verifies the effectiveness of the network with the test set, and achieve shallow burial state recognition of submarine cables. Through on-site collec-

作者简介: 姜坤(1986-),男,本科,工程师,主要从事陆上风电、海上风电、光伏、氢能等新能源产业生产运维及安全管理。E-mail:11664013@chnenergy.com.cn

通讯作者: 崔桂艳(1994-),女,硕士研究生,主要研究方向为分布式光纤传感技术,海缆在线监测研究。E-mail:1363216917@qq.com

收稿日期: 2023-07-30; **修订日期:** 2023-09-06

tion of submarine cable fiber temperature data for verification, the testing accuracy reaches 100 %, and the results show that this method can accurately identify the shallow burial state of submarine cables.

Keywords: fiber temperature; identification of shallow burial of submarine cables; mixed domain features; VMD; LSTM

1 引言

当海缆敷设深度过浅或裸露在海床表面时,会受到海水腐蚀、船舶锚害、渔网拖拽等。海缆受到损伤后会产生缺陷,容易造成故障发生,若及时发现并修复将会威胁到电网系统的安全稳定运行,因此有必要对海缆浅埋进行识别^[1]。海缆浅埋状态识别常采用温度分析法,而现场采集的温度信号具有非平稳、非线性特点,如何从温度信号中提取有效特征是进行状态识别的关键。随着状态识别理论研究的深入,学者们提出了各种状态识别方法,例如:EMD^[2]、BP神经网络^[3]、小波分析^[4]和SVD^[5]等。随着人工智能技术的不断发展,深度学习体系结构即递归神经网络(RNN)^[6]、卷积神经网络(CNN)^[7]、长短期记忆(LSTM)^[8]等在状态识别领域中得到广泛的应用。

利用经验模态分解(EMD)^[9]处理光纤温度信号可以降低噪声和提取状态特征,但其存在端点效应及模态混叠等问题;Wu等^[10]提出集合经验模态分解(EEMD),在模式混叠问题上比原始EMD有很大改进,但得到的IMF中会残留一定的白噪声;Torres等^[11]提出完备集合经验模态分解(CEEM-DAN),可以有效解决模态混叠和残余噪声问题,但需要一个试错过程来获得信号的良好分解。针对这些问题,Dragomiretskiy等^[12]提出一种非平稳信号处理方法:变分模态分解(VMD),对采样和噪声具有较好的鲁棒性,可以降低复杂度高和非线性强的时间序列非平稳性,分解获得包含多个不同频率尺度且相对平稳的子序列,广泛应用于故障诊断和状态识别。文献[13]提出优化的VMD方法,分别利用遗传算法和包络峰度的最大值确定VMD的模态分量个数。

海缆状态识别的关键在于光纤温度信号的特征提取,通过构建混合域特征集,提取时域特征、频域特征和时频域特征,尽可能全面的从温度信号中提取状态特征信息。但高维特征集中会存在冗余特征,影响模型的识别结果和计算效率。所以,需要对高维特征集进行降维^[14],主要有主成分分析(PCA)^[15]、核主成分分析(KPCA)^[16]、距离评估技

术^[17]等。文献[18]提出一种基于补偿距离评估技术的特征选择方法,从声发射信号中提取特征集,提高故障诊断的准确度。

近年来,深度学习在状态识别领域得到了一定的应用^[19]。长短时记忆网络作为其中的主要方法之一,通过叠加多个LSTM层,利用输入和输出之间的非线性映射层进行分层特征学习,能够从不同方面学习原始信号的特征,加速收敛并细化原始数据的非线性操作^[8]。

针对上述方法,本文提出一种基于优化VMD混合域特征和LSTM的海缆浅埋状态识别方法,实现海缆浅埋状态的准确识别。

2 变分模态分解参数优化

2.1 VMD理论

VMD基于维纳滤波理论,Dragomiretskiy等在2014年引入VMD进行自适应信号处理。VMD是一个完全非递归的变分模态分解模型,在该算法中,本征模态函数(IMF)被定义为一个有带宽限制的调幅-调频函数,VMD算法是通过构造并求解约束变分问题,将原始信号分解为指定个数的IMF分量。在对信号进行VMD分解之前,需要确定VMD的参数,即需要预先确定模数和惩罚因子。确定影响参数后,对信号进行VMD分解,得到一系列本征模态函数^[12]。

2.2 VMD模数确定

采用一种由希尔伯特变换计算包络峰度值的方法,从而有效地优化VMD模数,本文采用惩罚因子和带宽的默认值 $\alpha = 2000, s = 0$,初始模数设为 $K = 2$,借鉴唐等^[20]对模数 K 的讨论范围。如果模数 K 过大,则效率低,计算负荷重;如果模数 K 过小,容易引入噪声。所以选择 $K \in [2, 15]$ 作为模数的搜索域,步长设置为1。

对采集到的光纤温度信号进行VMD分解,计算设定模数 K 下各模态信号的包络峰度值,通过比较得到该模数下包络峰度的最大值,然后 $K = K + 1$ 继续进行上述分析,直到取 $K = 15$,得到各模数下包络峰度的最大值。

假设VMD的模数为 $K, K \in [2, 15]$,可以计算

出每个模数的包络,即:

$$xt_k^i = \left| \frac{1}{\pi t} \cdot x_k^i(t) \right|, i = 1, 2, \dots, K \quad (1)$$

其中, i 代表 K 的第 i 种模式, xt_k^i 是绝对值(K 的第 i 种模式的 HT 的结果), $x_k^i(t)$ 代表当模式为 K 时, VMD 产生的第 i 个模式。

此外, K 的第 i 个模式的包络峰度计算如下:

$$ek(i) = \frac{E(xt_k^i - \mu(xt_k^i))^4}{\sigma(xt_k^i)^4}, i = 1, 2, \dots, K \quad (2)$$

其中, $\mu(xt_k^i)$ 是 xt_k^i 的均值, $\sigma(xt_k^i)$ 是 xt_k^i 的标准偏差,式(2)中的分子表示 xt_k^i 的四阶中心矩。

可以获得局部最大 ek_K^{\max} :

$$ek_K^{\max} = \max(ek_1, ek_2, ek_3, \dots, ek_K) \quad (3)$$

因为 K 的搜索范围为 [2, 15], 搜索步长设置为 1, 所以在整个搜索范围内可以获得 14 个局部最大值。因此, 我们可以得到全局最大值:

$$ek_g^{\max} = \max(ek_2^{\max}, ek_3^{\max}, ek_4^{\max}, \dots, ek_{15}^{\max}) \quad (4)$$

根据式(4)可以得到取 ek_g^{\max} 时, 对应的 K 值, 用 K' 表示, 其中 K' 可以从公式(5)得到:

$$K' = \operatorname{argmax}(ek_g^{\max}) \quad (5)$$

2.3 IMF 分量选择

VMD 方法获得的各 IMF 分量包括了原始信号不同时间尺度的局部特征, 前几个 IMF 分量体现了原始信号的主要特征。为有效保留原始信号的状态特征, 同时避免噪声等成分的干扰, 采用相关系数法筛选分解后的各个 IMF 分量, 筛选相关系数最大的 IMF 分量作为计算混合域特征的数据。相关系数的计算公式如下^[21]:

$$\rho(i) = \frac{\sum_{j=1}^L x(j) IMF_i(j)}{\sqrt{\sum_{j=1}^L x^2(j) \sum_{j=1}^L IMF_i^2(j)}} \quad (6)$$

其中: L 为信号长度; $\rho(i)$ 为第 i 个 IMF 分量与原始信号 $x(t)$ 之间的相关系数。

3 基于混合域特征的海缆浅埋状态识别建模

3.1 海缆覆埋状态光纤温度特征

通过提取原始光纤温度信号的时域和频域特征, 结合所选 IMF 的时域和频域特征以及能量和熵特征构建 54 维混合域特征集, 能够表征信号的频率分布特征和变化趋势以及在不同时刻和频率处的能量信息等, 全面挖掘海缆覆埋状态特征信息。其中,

时域分析方法通常用于表征原始信号的概率统计特征, 能够降低噪声的干扰, 减少冗余数据; 频域分析方法通过傅里叶变换处理时域信号进行频谱分析, 获得信号的主频带、频率能量以及频谱能量等信息; 时频域分析方法采用优化 VMD 对温度信号进行处理, 引入能量和熵特征, 反应信号的能量大小和分布趋势, 以及信号的混乱程度。

傅里叶变换公式如下:

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi ft} dt \quad (7)$$

本文采用统计分析方法归纳总结 15 种时域特征参数; 基于 FFT 得到的频域信号提取 10 种频域特征参数; 基于优化 VMD 筛选的 IMF 分量提取能量、排列熵、样本熵和模糊熵 4 种时频特征参数, 具体特征参数如表 1 所示。

表 1 特征参数表

Tab. 1 Characteristic parameter table

时域特征		
最大值(TF_1)	标准差(TF_6)	方根幅值(TF_{11})
最小值(TF_2)	方差(TF_7)	波形因子(TF_{12})
平均值(TF_3)	RMS(TF_8)	峭度因子(TF_{13})
峰-峰值(TF_4)	峰度(TF_9)	脉冲因子(TF_{14})
绝对均值(TF_5)	峰值(TF_{10})	裕度因子(TF_{15})
频域特征		
频谱幅值均值(FF_1)	表征主频带位置(FF_5)	频率偏度(FF_8)
平均频率(FF_2)	频率能量集中度(FF_6)	频率峭度(FF_9)
频率均方根值(FF_3)	频谱能量集中度(FF_7)	频率方差(FF_{10})
标准频谱均值(FF_4)	/	/
时频域特征		
能量($Energy$)	排列熵(PE)	样本熵($SampEn$)
模糊熵($FuzzyEn$)	/	/

3.2 海缆覆埋状态特征选择与降维

由于高维特征集中可能含有冗余特征, 会影响状态识别精度以及计算效率。因此, 需要对高维特征集进行降维生成具有较高代表性且维度较低的敏感特征集^[15]。补偿距离评估技术(CDET)是利用距离评估指标进行敏感特征选择的方法, 充分考虑特征对状态识别的敏感性, 筛选出状态敏感特征, 降低特征集维度, 其算法原理如下所示^[19]。

设含有 C 个模式类 $\omega_1, \omega_2, \dots, \omega_C$ 的特征集为 $\{p_{c,m,k}\}, c = 1, 2, \dots, C, m = 1, 2, \dots, M_c, k = 1, 2, \dots, K$ 。其中, $p_{c,m,k}$ 为状态 c 下第 m 个样本的第 k 个特征, M_c 为状态 c 下样本总数, K 为每个样本特征数目。

因此总共可得 $\sum_{c=1}^C M_c$ 个样本集, 共计 $K \sum_{c=1}^C M_c$ 个特征。

具体步骤如下:

①计算 $\omega_c (c = 1, 2, \dots, C)$ 类特征向量的平均距离, 如式:

$$d_{c,k} = \frac{1}{M_c(M_c - 1)} \sum_{i=1}^{M_c} \sum_{j=1}^{M_c} |p_{c,i,k} - p_{c,j,k}| \quad (8)$$

对 $d_{c,k} (c = 1, 2, \dots, C)$ 求平均类内距离, 如式:

$$d_k^\omega = \frac{1}{C} \sum_{c=1}^C d_{c,k} \quad (9)$$

②定义并计算 d_k^ω 的方差因子, 如式:

$$v_k^\omega = \frac{\max(d_{c,k})}{\min(d_{c,k})} \quad (10)$$

③计算 C 个模式类的类间距离, 如式:

$$d_k^b = \frac{1}{C(C - 1)} \sum_{c=1}^C \sum_{e=1}^C |\mu_{c,k} - \mu_{e,k}| \quad (11)$$

其中, $\mu_{c,k} = \frac{1}{M} \sum_{m=1}^{M_c} p_{c,m,k}$ 为 ω_c 类中所有第 k 个特征均值。

④定义并计算 d_k^b 的方差因子, 如式:

$$v_k^b = \frac{\max(|\mu_{e,k} - \mu_{c,k}|)}{\min(|\mu_{e,k} - \mu_{c,k}|)} \quad (12)$$

⑤定义并计算补偿因子, 如式:

$$\gamma_k = \frac{1}{v_{\omega_k} / \max(v_k^\omega) + v_k^b / \max(v_k^b)} \quad (13)$$

⑥计算距离评估指标 α_k , 如式:

$$\alpha_k = \gamma_k \frac{d_k^b}{d_k^\omega} \quad (14)$$

对 α_k 进行归一化处理, 得到归一化的距离评估指标为 $\bar{\alpha}_k$, 如式:

$$\bar{\alpha}_k = \frac{\alpha_k}{\max(\alpha_k)} \quad (15)$$

设定阈值 $\phi (\phi \in [0, 1])$ 大小, 从特征集 $\{p_{c,m,k}\}$ 中选择 $\bar{\alpha}_k \geq \phi$ 的特征, 构造降维后的输入特征集。

3.3 海缆浅埋状态识别模型构建

利用长短时记忆网络建立海缆浅埋状态识别模型。叠加多个 LSTM 层, 利用输入和输出之间的非线性映射层进行分层特征学习, LSTM 的内部结构如图 1 所示, LSTM 的模型结构如图 2 所示, 整体网

络结构如图 3 所示。

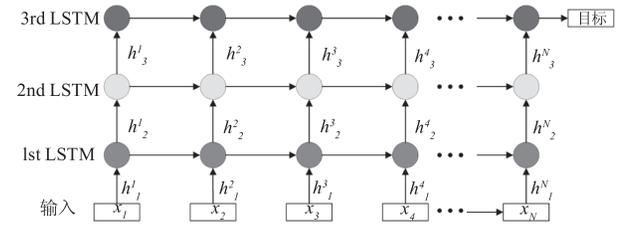


图 1 LSTM 网络内部结构图

Fig. 1 Internal structure of LSTM network

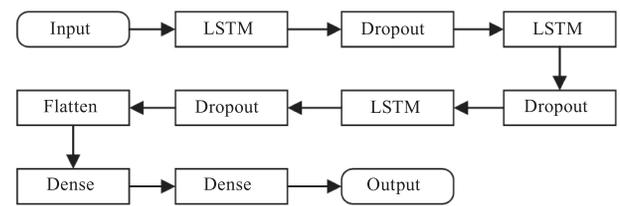


图 2 LSTM 模型结构图

Fig. 2 LSTM model structure diagram

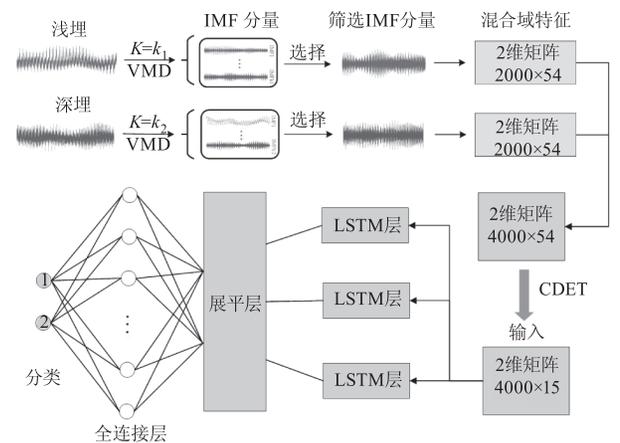


图 3 LSTM 网络结构图

Fig. 3 LSTM network structure diagram

4 基于现场测试数据的模型验证及结果分析

4.1 数据集构造

海缆监测系统中的温度监测以海缆内置光纤为传感介质, 通过分布式光纤测温设备周期性的采集海缆所有位置的温度信息, 形成历史光纤温度数据。目前, 海缆浅埋状态识别主要以温度信号分析为基础, 根据海床表面和海床深处存在温度差异, 夏季海床表面温度高于海床深处温度, 冬季海床表面温度低于海床深处温度。基于该现象, 根据夏季和冬季的光纤温差可以有效识别海缆深埋和浅埋位置。但基于光纤温差识别海缆浅埋位置存在一定的局限性, 在海床表面和海床深处温度近似相等即温度平衡时间(5 月和 10 月), 难以根据光纤温差识别海缆

浅埋位置。

基于历史光纤温度数据提取 1 月和 8 月某一时刻光电复合海缆所有位置的光纤温度数据,选取 1 月光纤温度 T_1 与 8 月光纤温度 T_2 之间温差 $T_s = |T_2 - T_1| \leq 3 \text{ }^\circ\text{C}$ 的区段,构建 5 月份海缆深埋光纤温度数据样本;选取 1 月光纤温度 T_1 与 8 月光纤温度 T_2 之间温差 $T_s = |T_2 - T_1| \geq 18 \text{ }^\circ\text{C}$ 的区段,构建 5 月份海缆浅埋光纤温度数据样本。光纤距离 - 温度关系曲线如图 4 所示。

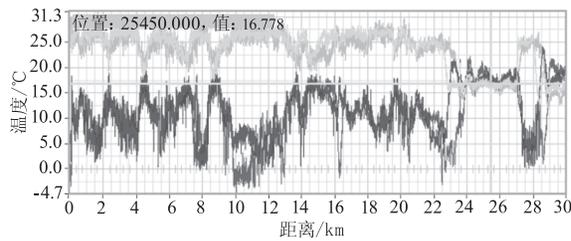


图 4 光纤距离 - 温度关系曲线图

Fig. 4 Optical fiber distance temperature relationship curve

4.2 VMD 模数分析

在搜索域中,浅埋状态和深埋状态模式数 K 和局部包络峰度最大值之间的关系绘制在图 5 中,由 2.2 节“VMD 模数确定”可知,根据 14 个局部包络峰度最大值可以得到全局包络峰度最大值,其对应的 K 值即为样本的最佳模式数 K' 。针对海缆覆埋两种状态样本,可以得到每个样本取最佳模式数 K' 时全局包络峰度的最大值,如表 2 所示。

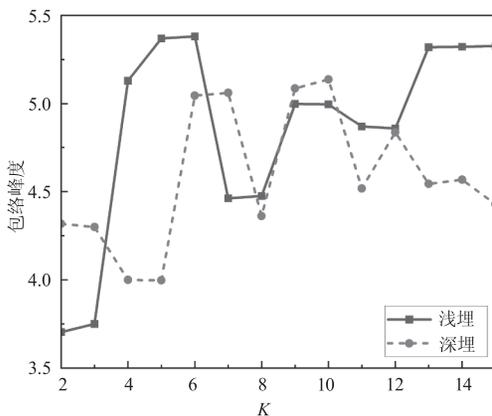


图 5 K 与局部最大包络峰度

Fig. 5 K and local maximum envelope kurtosis

表 2 K' 与全局最大包络峰度

Tab. 2 K' and global maximum envelope kurtosis

样本	浅埋	深埋
K'	6	10
包络峰度	5.3807	5.1364

由表 2 可知,具体海缆状态样本与最佳模式数一一对应,给出浅埋状态样本的 VMD 分解示例。当 $K' = 6$ 时包络峰度最大,对浅埋样本使用具有 6 种模式的 VMD 分析原始温度信号,每个 IMF 分量的时域表示如图 6 所示。计算原始信号与 6 个 IMF 的相关系数,其中 IMF1 相关系数达到 80.4%,IMF2 ~ IMF6 的相关系数在 25% 左右。

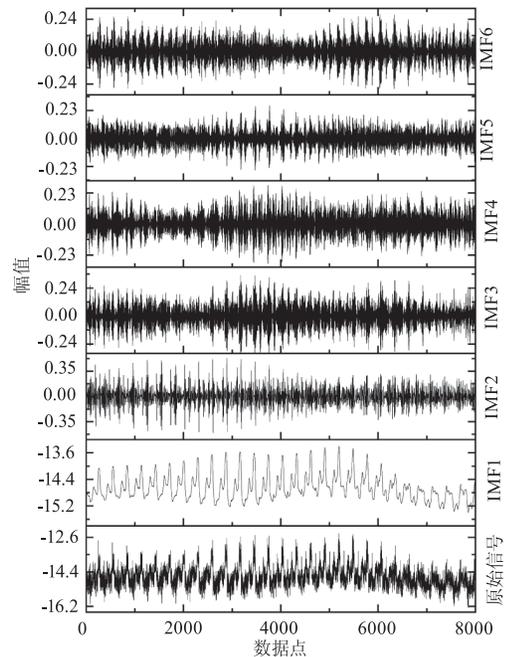


图 6 VMD 分解示例

Fig. 6 VMD decomposition example

4.3 特征对比分析

对海缆覆埋状态的混合域特征集进行归一化处理,浅埋和深埋状态的归一化特征值如图 7 所示,可以看出部分特征对海缆覆埋状态不敏感,即存在部分冗余特征。

基于补偿距离评估技术 (CDET),分别计算混合域全特征集参数的补偿距离评估指标 $\bar{\alpha}_k$,54 维特征集的补偿距离评估指标如图 8(a) 所示,参考已有补偿距离评估方法研究成果,选定阈值 ϕ 为 0.5,将 $\bar{\alpha}_k \geq 0.5$ 的特征选为有效特征,实现高维特征集的降维优化。有效特征在浅埋和深埋状态下的对比如图 8(b) 所示,可以看出经过 CDET 降维获得的低维特征集能够较好地地区分海缆浅埋和深埋两种状态。

降维得到的低维特征集组成如表 3 所示,54 维混合域特征集降为 15 维,其中时域特征 8 维,频域特征 5 维,时频域特征 2 维。

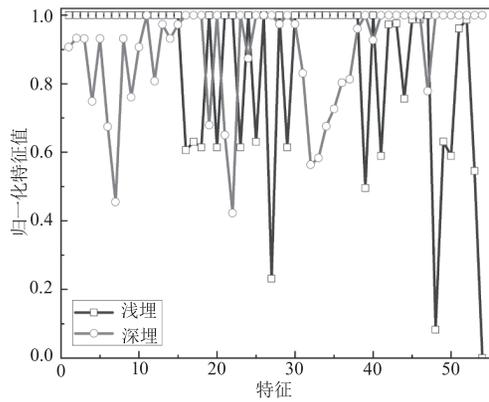
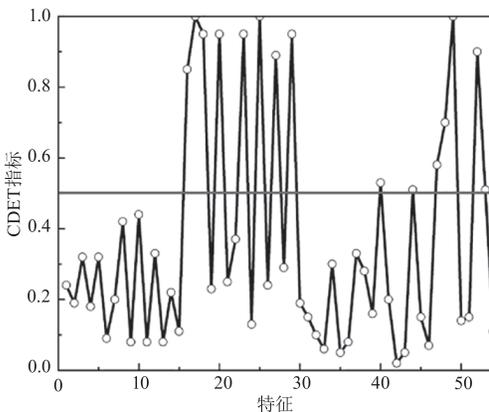
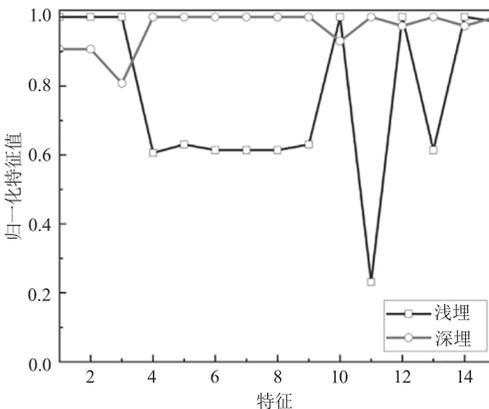


图7 混合域特征集特征值对比

Fig. 7 Comparison of eigenvalues of mixed domain feature set



(a) 距离评估图



(b) 有效特征比较

图8 特征降维

Fig. 8 Feature dimensionality reduction

4.4 状态识别方法实现

基于光纤温度混合域特征的海缆浅埋状态识别方法包括四个部分内容,图9是整体算法流程图,步骤如下:

第一部分:海缆在线监测系统

(1)将分布式光纤传感采集到的海缆光纤温度信号等距分段,制作浅埋和深埋两种海缆覆埋状态

的原始光纤温度信号样本数据集;

(2)数据预处理:首先,利用希尔伯特变换计算包络峰度最大值方法优化VMD模数;其次,对每个数据样本进行VMD分解,并利用相关系数法筛选IMF分量;最后,制作浅埋和深埋状态的IMF分量样本数据集。

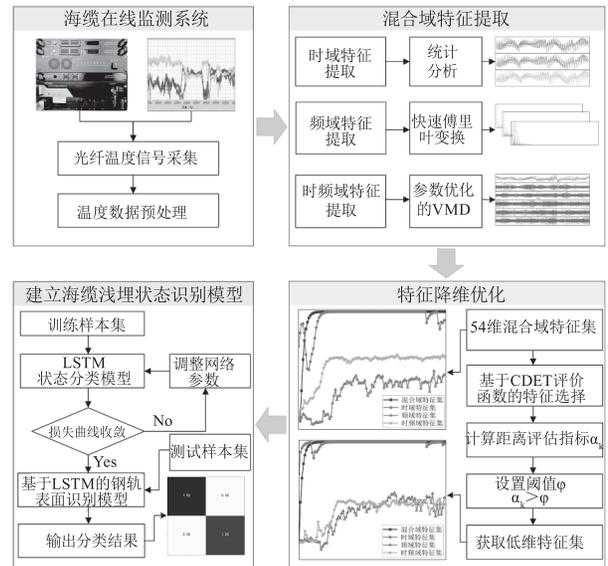


图9 整体算法流程图

Fig. 9 Overall algorithm flow chart

表3 降维后的特征集组成

Tab. 3 Feature set composition after dimensionality reduction

特征类别	维数	特征参数
时域特征	8	IMF分量($TF_1, TF_2, TF_3, TF_5, TF_8, TF_{10}, TF_{12}, TF_{14}$)
频域特征	5	原始信号(FF_1)IMF分量(FF_4, FF_7, FF_8, FF_9)
时频域特征	2	IMF分量($PE, SampEn$)

第二部分:混合域特征提取

(1)计算15维原始光纤温度信号的时域特征和15维IMF分量的时域特征;

(2)计算10维原始光纤温度信号的频域特征和10维IMF分量的频域特征;

(3)计算4维IMF分量的时频域特征;

(4)根据计算得到的时域特征、频域特征和时频域特征组成特征向量构造混合域特征集。

第三部分:输入特征降维优化

(1)利用补偿距离评估技术选取敏感特征;

(2)计算距离评估指标 $\bar{\alpha}_k$;

(3) 设定阈值 ϕ ($\phi \in [0, 1]$) 的大小, 从高维特征集中选择 $\bar{\alpha}_k \geq \phi$ 的特征作为有效特征。

第四部分: 建立海缆浅埋状态识别模型

(1) 根据上述步骤从海缆覆埋状态的光纤温度数据中得到低维特征数据集, 作为 LSTM 训练和测试的数据;

(2) 随机划分训练集和测试集, 利用训练集训练 LSTM 网络, 同时在训练过程中根据损失收敛情况优化调整网络的结构和参数;

(3) 测试集验证网络的有效性, 预测海缆覆埋状态分类结果。

4.5 状态识别结果与分析

根据 3.1 节构建的海缆覆埋状态光纤温度信号数据集验证基于光纤温度混合域特征的海缆浅埋状态识别方法的效果。海缆覆埋状态一共生成 4000 个样本, 每种状态 2000 个样本。随机分配训练集和测试集, 每种状态训练集和测试集的分配数量分别为 1600 和 400。

将网络运行 5 次, 图 10 展示了五次测试得到的测试集识别准确率和损失率。其中, 第 2 次测试的训练集和测试集精度变化曲线如图 11 所示, 第 2 次测试的训练集和测试集损失变化曲线如图 12 所示。

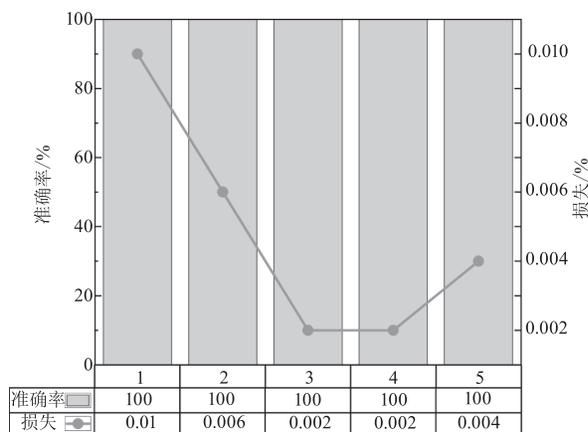


图 10 多次测试的准确率和损失

Fig. 10 Accuracy and loss rates for multiple tests

在训练中一次迭代指所有数据在网络中完成一次前向计算及反向传播的过程。准确率反映了模型正确识别的样本比例, 损失率用来评估模型的预测值与真实值的不一致程度。准确率越大、损失率越小, 说明模型的识别能力和鲁棒性越好。

分析图 10 中的数据, 本文提出的方法获得了较好的结果, 5 次测试的测试集平均识别准确率为 100 %。由此可见, 利用基于光纤温度混合域特征的海缆浅埋状态识别方法能够有效实现海缆浅埋状态识别且稳定性较高。

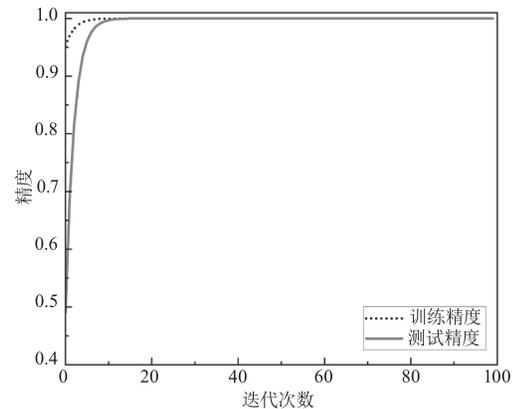


图 11 训练集和测试集的精度变化曲线

Fig. 11 Accuracy change curves for the training and test sets

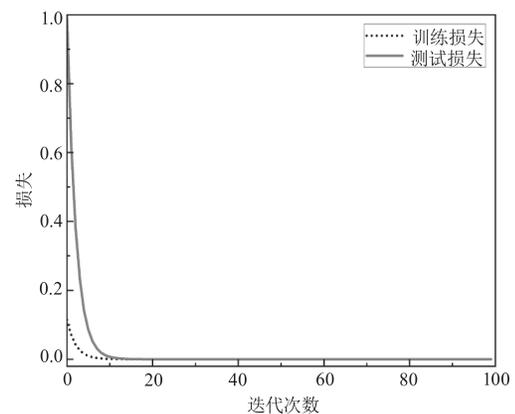


图 12 训练集和测试集的损失变化曲线

Fig. 12 Loss curves for the training and test sets

从图 11 和图 12 可以看出, 无论训练还是测试, 精度变化曲线迅速上升并趋于稳定, 损失变化曲线迅速下降并趋于稳定, 经过 100 次迭代后, 最终的测试精度和损失的值分别为 100 % 和 0.006 %。

为了表示海缆不同覆埋状态的分类情况, 给出分类结果混淆矩阵, 图 13 展示了第 2 次测试结果的混淆矩阵。其中横轴表示预测类别, 纵轴表示实际类别, 对角线数值表示每一类别测试样本的分类准确率, 非对角线位置的数值表示某一状态分类的错误率。从混淆矩阵结果图可以看出, 海缆深埋和浅埋类别的分类正确率均达到 100 %。

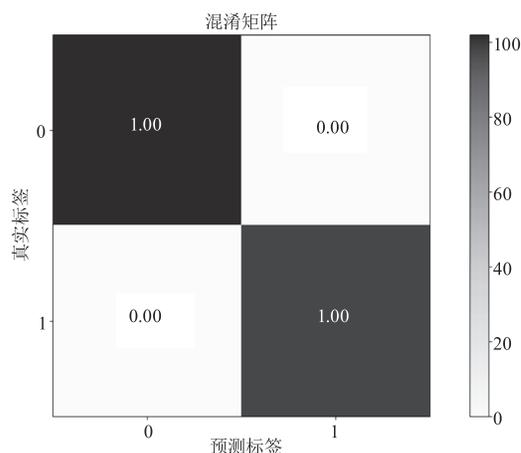


图 13 状态分类混淆矩阵

Fig. 13 Confusion matrix of state classification

4.6 模型性能对比

为了验证基于光纤温度混合域特征的海缆浅埋状态识别方法的有效性,对比其他四种方法。方法 1:对于本文提出的方法,不进行降维处理,以混合域特征集作为 LSTM 网络的输入。方法 2:对于本文提出的方法,仅改变特征集组成,以时域特征集作为 LSTM 网络的输入。方法 3:对于本文提出的方法,仅改变特征集组成,以频域特征集作为 LSTM 网络的输入。方法 4:对于本文提出的方法,仅改变特征集组成,以时频域特征集作为 LSTM 网络的输入。表 4 展示了本文所提方法与其他四种方法的结果对比,可以看出,基于优化 VMD 混合域特征和 LSTM 的海缆浅埋状态识别方法相较于其他四种对比方法识别准确率高,稳定性好。

表 4 不同状态识别方法的比较

Tab. 4 Comparison of different state recognition methods

方法	钢轨表面状态识别方法	准确率/%
方法 1	VMD + 混合域 + LSTM	99.80
方法 2	VMD + 时域 + CDET + LSTM	98.00
方法 3	VMD + 频域 + CDET + LSTM	76.00
方法 4	VMD + 时频域 + CDET + LSTM	79.80
本文方法	VMD + 混合域 + CDET + LSTM	100.00

5 结 语

针对光纤温度信号非平稳、非线性的特点,以及在海底表面温度和海底深处温度近似相等即温度平衡时间段内,利用光纤温差识别海缆浅埋位置存在一定的局限性,提出一种基于优化 VMD 混合

域特征和 LSTM 的海缆浅埋状态识别方法,全面挖掘海缆覆埋状态特征,提高识别模型准确率,实现准确稳定的海缆浅埋状态识别。主要结论如下:

(1) 提出了一种基于希尔伯特变换计算包络峰度最大值的 VMD 参数优化方法处理海缆光纤温度信号,并利用相关系数法筛选 IMF,有效降低噪声干扰。

(2) 通过提取原始温度信号的时域和频域特征,结合所选 IMF 的时域和频域特征以及能量和熵特征构建混合域特征集,充分挖掘训练样本中的海缆覆埋状态信息,提高样本利用率。

(3) 利用补偿距离评估技术(CDET)对高维特征集进行降维,选择距离评估指标 $\bar{\alpha}_k \geq 0.5$ 的特征作为敏感特征,降低模型训练与状态识别所需要的时间。

(4) 所设计的长短时记忆网络收敛速度快且具有较好的鲁棒性,基于现场采集数据,测试准确率达到了 100%,表现出良好的泛化能力。

参考文献:

- [1] Hou Shuai, Wang Yisong, Zhu Wenbo, et al. Review of high voltage submarine cable monitoring technology and applications [J]. Southern Power System Technology, 2023, 17(5): 49-58. (in Chinese)
侯帅,王毅松,朱闻博,等. 高压海底电缆监测技术与应用综述[J]. 南方电网技术, 2023, 17(5): 49-58.
- [2] Li Jingyun, An Bowen, Chen Yuanlin, et al. Research on optical fiber vibration pattern recognition based on time-frequency characteristics [J]. Optical Communication Technology, 2018, 42(7): 55-59. (in Chinese)
李静云,安博文,陈元林,等. 基于时频特征的光纤振动模式识别研究[J]. 光通信技术, 2018, 42(7): 55-59.
- [3] Yang Xiaofeng, Fang Yihang, Zhao Pengzhen, et al. Fan state recognition based on K-means and BPNN [J]. Electric Power, 2023, 56(6): 158-166, 175. (in Chinese)
杨晓峰,方逸航,赵鹏臻,等. 基于 K-means 和 BPNN 的风机状态识别[J]. 中国电力, 2023, 56(6): 158-166, 175.
- [4] Gou Yepeng, Liu Xing, Guo Jiachong, et al. Pulse laser echo signal separation method based on wavelet analysis [J]. Laser & Infrared, 2022, 52(1): 136-144. (in Chinese)
苟晔鹏,刘星,郭甲崇,等. 基于小波分析的脉冲激光回波信号分离方法[J]. 激光与红外, 2022, 52(1):

- 136 – 144.
- [5] Peng Hao, Zhu Zheng, Song Xueyong, et al. Research on grain size detection based on singular value decomposition using a laser ultrasonic technique [J]. *Laser & Infrared*, 2021, 51(12): 1586 – 1593 (in Chinese)
彭昊, 朱振格, 宋学勇, 等. 基于奇异值分解的激光超声晶粒尺寸检测研究 [J]. *激光与红外*, 2021, 51(12): 1586 – 1593.
- [6] Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network [J]. *Physica D: Nonlinear Phenomena*, 2020, 404: 132306.
- [7] Yeh C W, Chen R. Using convolutional neural network for vibration fault diagnosis monitoring in machinery [C] // 2018 IEEE International Conference on Advanced Manufacturing (ICAM). IEEE, 2018: 246 – 249.
- [8] Yu Y, Si X, Hu C, et al. A review of recurrent neural networks: LSTM cells and network architectures [J]. *Neural Computation*, 2019, 31(7): 1235 – 1270.
- [9] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. *Proceedings of the Royal Society A Mathematical Physical & Engineering Sciences*, 1998, 454(1971): 903 – 995.
- [10] Wu Zhaohua, Huang Norden E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. *Advances in Adaptive Data Analysis*, 2009, 1(1): 1 – 41.
- [11] Torres M E, Colominas M A, Schlotthauer G, et al. A complete ensemble empirical mode decomposition with adaptive noise [C] // IEEE International Conference on Acoustics, Speech and Signal Processing, IEEE, 2011: 4144 – 4147.
- [12] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531 – 544.
- [13] Li H, Liu T, Wu X, et al. An optimized VMD method and its applications in bearing fault diagnosis [J]. *Measurement*, 2020, 166: 108185.
- [14] Wang Tianyang, Han Qinkai, Chu Fulei, et al. Vibration based condition monitoring and fault diagnosis of wind turbine planetary gearbox: a review [J]. *Mechanical Systems and Signal Processing*, 2019, 126(1): 662 – 685.
- [15] Sun Xueming, Zhang Dahua, Zhou Zhiqian, et al. Voice signal extraction of laser microphone based on PCA [J]. *Laser & Infrared*, 2022, 52(12): 1761 – 1767. (in Chinese)
孙学明, 张大华, 周志全, 等. 基于主成分分析的激光麦克风的语音信号提取 [J]. *激光与红外*, 2022, 52(12): 1761 – 1767.
- [16] Zhang Tianrui, Li Jinyang. Research on fault diagnosis of rolling bearings based on adaptive VMD-KPCA feature extraction and SSA-SVM method [J]. *Journal of Machine Design*, 2022, 39(7): 63 – 73. (in Chinese)
张天瑞, 李金洋. 基于自适应 VMD-KPCA 特征提取与 SSA-SVM 方法的滚动轴承故障诊断 [J]. *机械设计*, 2022, 39(7): 63 – 73.
- [17] Yang B S, Han T, An J L. ART-KOHONEN neural network for fault diagnosis of rotating machinery [J]. *Mechanical Systems and Signal Processing*, 2004, 18(3): 645 – 657.
- [18] Se Haifeng, Zhou Lei, Xu Shiming, et al. Selecting sensitive features using CDET for bearing fault diagnosis [J]. *Journal of Physics: Conference Series*, 2022, 2218(1): 012063.
- [19] Ren Hao, Qu Jianfeng, Chai Yi, et al. Deep learning for fault diagnosis: the state of the art and challenge [J]. *Control and Decision*, 2017, 32(8): 1345 – 1358. (in Chinese)
任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域中的研究现状与挑战 [J]. *控制与决策*, 2017, 32(8): 1345 – 1358.
- [20] Tang Guiji, Wang Xiaolong. Variational mode decomposition method and its application on incipient fault diagnosis of rolling bearing [J]. *Journal of Vibration Engineering*, 2016, 29(4): 638 – 648. (in Chinese)
唐贵基, 王晓龙. 变分模态分解方法及其在滚动轴承早期故障诊断中的应用 [J]. *振动工程学报*, 2016, 29(4): 638 – 648.
- [21] Wang Cailing, Hu Bingliang, Wang Hongwei, et al. Hyperspectral image target detection algorithm based on constrained maximum correlation coefficient [J]. *Laser & Infrared*, 2016, 46(1): 98 – 102. (in Chinese)
王彩玲, 胡柄樑, 王洪伟, 等. 约束最大相关系数的高光谱影像目标探测研究 [J]. *激光与红外*, 2016, 46(1): 98 – 102.