

# 基于光纤分布式声传感器的煤矿设备健康监测识别

钟翔, 孙宇, 曹翰昱, 任杰, 陈晓珊, 田兵兵

(合肥工业大学, 安徽 合肥 230000)

**摘要:** 现有的煤矿设备异常主要通过硬件设备进行检测, 对人力、设备都有较高的要求, 人工智能的兴起, 为这一问题提供了新的解决方案。针对这些问题, 本作品提出了基于相位敏感光时域反射计 (Phase-sensitive optical time-domain reflectometry,  $\Phi$ -OTDR) 的光纤分布式声音传感器 (Distributed acoustic sensor, DAS), DAS 具有灵敏度高、定位准确等优点。通过 DAS 感知模拟煤矿环境中干扰事件对应的振动信号, 本作品中外界干扰事件主要包括: 煤矿自然环境扰动、人为因素扰动、设备异常声音扰动, 此外本系统使用马赫增德尔干涉仪 (Mach-Zehnder interferometer, MZI) 和两路解调算法对振动信号原始数据进行解调处理, 并利用 Python 中的 librosa 库提取振动信号音频特征作为深度学习模型算法的数据集, 利用随机森林算法模型对音频特征数据集进行训练。实验结果表明, 本作品能够准确地识别沿光纤不同位置同时发生的多种外界干扰事件, 并能有效区分煤矿自然环境扰动、人为因素扰动、设备异常声音扰动等多类振动事件。其中平均识别准确率达到了 99%, 系统响应时间约为 0.4s, 为解决煤矿设备异常振动监测提供了一种简单、准确、实时性强的方案。

**关键词:** DAS; 深度学习; 多分类检测

## Identification of coal mine equipment health monitoring based on optical fiber distributed acoustic sensors

Xiang Zhong, Yu Sun, Hanyu Cao, Jie Ren, Xiaoshan Chen, Bingbing Tian

(Hefei University of Technology)

**Abstract:** Existing coal mine equipment anomalies are mostly detected by hardware devices, which have high requirements on manpower and equipment. The rise of artificial intelligence provides a new solution to this problem. To address these problems, we propose a Distributed acoustic sensor (DAS) based on phase-sensitive optical time-domain reflectometry ( $\Phi$ -OTDR), which has the advantages of high sensitivity and accurate localization. The vibration signals corresponding to disturbance events in the simulated coal mine environment are sensed by the DAS. The external disturbance events in this work mainly include: natural environmental

disturbances , human factors disturbances, abnormal equipment sound disturbances.In addition, this system uses Mach-Zehnder interferometer (MZI) and two-way demodulation algorithm to demodulate the original vibration signal data,then extracts the vibration signal audio features as the data set depend on the librosa library in Python for the deep learning model algorithm, finally uses the random forest algorithm model to train the audio feature data set. Experimental results show that our proposal can accurately identify multiple external disturbance events occurring simultaneously at different locations along the optical fiber, can also effectively distinguish multiple types of vibration events such as natural environmental disturbance, human factor disturbance, and abnormal equipment sound disturbance in coal mines. With an average recognition accuracy of 99% and a system response time of about 0.4s, which provides a simple, accurate, and real-time solution for abnormal vibration monitoring of coal mine equipment.

**Keywords:** DAS; Deep Learning; Multi-classification detection

## 1 传感器设计背景和应用价值

设计背景：我国煤炭资源丰富，开采需求大，并且煤矿安全事故较多，煤矿设备的健康监测的重要性日益提升。目前针对煤矿设备故障检测的方案主要通过专业人员进行技术分析或者利用设备性能的显示量表对设备状态进行专业判定，但大型煤炭设备结构复杂，检修工作量大，对人力和设备都有较高要求。为此，借助煤矿安全监测系统，监控并举，实现信息化、智慧化矿山是今后的发展方向。

近年来，分布式光纤传感技术由于体积小、结构简单、灵敏度高、耐腐蚀耐高温、抗电磁干扰等优点，已成为目前光纤传感应用领域国内外的研究热点<sup>[1-3]</sup>。其中，相位敏感光时域反射计作为一种新型分布式光纤传感技术，凭借结构简单、灵敏度高、实时性好、动态范围广、响应速度快等特点<sup>[4-5]</sup>，在长距离周界安防、油气管线安全状况监测、大型结构健康监测等领域发挥出十分重要的作用<sup>[6-8]</sup>。而基于相位敏感光时域反射计的 DAS 光纤分布式声音传感器在对光纤周围的扰动进行长距离、实时、连续的空间检测上性能更佳。该数据采集系统具有覆盖范围广、时空分辨率高、实现方便、环境适应性强等优点。同时，为了有效地识别不同扰动事件，现已提出了许多识别方法。这些方法结合不同类型的特征和分类模型来选择最优方案，有效地区分不同的扰动事件<sup>[11]</sup>。

应用价值：传统的信号识别方法主要是人工提取特征，包括时域特征、频域特征和能量特

征等，但是特征提取的过程往往很繁琐，计算量也较大<sup>[9]</sup>。这些方法虽然可以取得较好的识别率，但识别效果对信号特征的设计有较强的依赖性，且应用到不同的场景分类性能不一。而本设计中采用 librosa 库提取振动信号音频特征作为初步特征，同时利用深度学习的方法对深度特征进一步处理，最后结合随机森林算法的集成学习算法实现检测分类<sup>[10]</sup>。本设计中光纤分布式声音传感器与深度学习方法结合，实现对设备健康状况的高效检测，识别准确率高且实时性强。

## 2 创新点与优势

本作品主要利用 DAS-MZI 结构，对传感光纤上的振动信号进行收集，利用两路解调算法对数据理解调，再通过提取数据音频特征构建数据集，最后利用随机森林算法模型进行训练识别。该方法的主要优势有：

(1) 本作品设计的实验采集装置可以检测到长达几十公里的光纤上各个位置的外界干扰事件，能够实现实时、多点、多种不同干扰事件的采集。

(2) 本作品提出的煤矿设备异常监测识别方案是利用深度学习模型算法，相比传统的硬件监测方案，节省了人力消耗与设备成本。

(3) 本作品通过 Python 构建随机森林模型算法，具有较强的抗过拟合能力，能够在较短的训练时间里实现高识别准确率，满足了实际工程中对准确率和实时性的需求。

## 3 实现方案简介

### 3.1 设计原理

#### 1) $\Phi$ -OTDR 系统传感理论基础

$\Phi$ -OTDR 相位解调系统是对基于传统 OTDR 技术的扰动定位原理对外部振动信号进行定位和相位解调的一种分布式光纤声学传感器<sup>[1]</sup>。经过光信号调制器调制后的光脉冲信号注入到探测光纤中后，由于在光纤中散射中心的随机分布，在传感光纤中不断向前传播的脉冲光信号会在探测光纤中发生散射现象。根据不同的脉冲光信号发生散射的种类可以分为：通过注入的脉冲光信号与内部的分子运动之间产生作用而引起的光信号频率变化的拉曼散射，由声波引起的布里渊散射，以及由于探测光纤内部折射率不均匀分布而引起的后向瑞利散射。并且对于这几种散射光的波长而言，拉曼散射光和布里渊散射光的波长会发生变化，所以后续要通过波分复用器才会分离出相应的散射光。对于瑞利散射光来说，其中心波长不会发生改变。因此，可以通过对散射光的检测来实现与外部环境中有关的参数的测量。下图是三种散射光的分布情况：

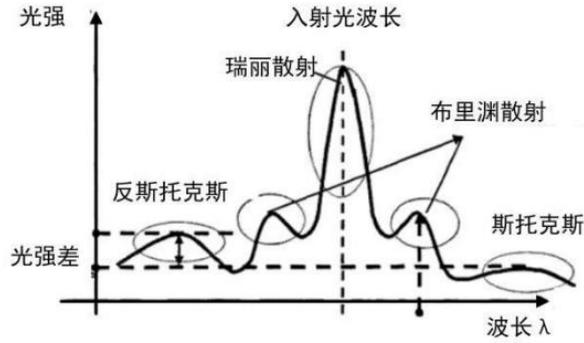


图1 散射光的波长分布图

在实际的应用中,当激光光源的光功率没有达到某一个阈值的时候,这个时候检测到的拉曼散射和布里渊散射的光功率很小,几乎可以忽略不计,在这种情况下,只需要检测瑞丽散射光信号就可以了。 $\Phi$ -OTDR 系统中使用的是窄线宽,较低频率漂移的激光器,激光器发出的光信号经过调制器调之后注入到探测光纤中,探测光纤中不同散射点的瑞丽散射光在相遇的时候会发生干涉,其原理图如下图 2 所示:

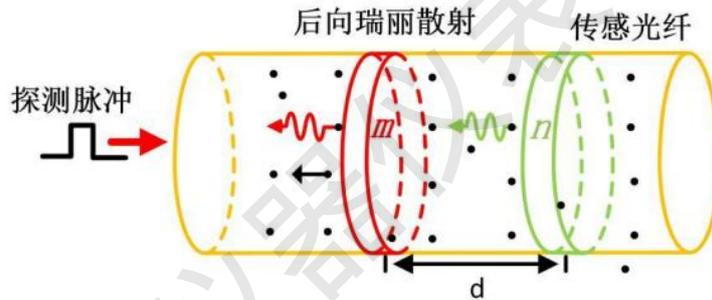


图2 瑞丽散射信号传播示意图

探测脉冲在传输过程中,每个散射点产生的后向瑞丽散射光不断向后方传输,上图中假设 m 点产生的后向瑞丽散射光场的大小表示为:

$$E_p = E_{p_0} \exp [j(\omega t + \varphi_m)] \quad (1)$$

m 点的后向瑞利散射光继续向后传播,同时探测脉冲继续向前传输,在继续向前传输 x 距离处的 n 点产生的后向瑞丽散射光场的大小可以表示为:

$$E_p' = E_{p_0} \exp [j(\omega t + \varphi_n)] \quad (2)$$

当 m 和 n 点处的瑞丽散射光会在相遇时发生干涉,在整个脉冲时间内的后向瑞丽散射

光均会发生干涉，产生的干涉信号的信号光场可以表示为

$$E_t = \sum_{i=1}^n E_i \exp[j(\omega t + \varphi_i)] = E \exp[j(\omega t + \varphi)] \quad (3)$$

式(2.3)中  $n$  是传感光纤中散射单元的总的数量， $E_i$  表示的是传感光纤中第  $i$  个散射中心所产生的散射信号的强度， $\varphi_i$  是传感光纤中第  $i$  个散射中心所产生的后向瑞丽散射信号的初始相位， $E$  是信号的幅度， $\varphi$  是整个干涉信号的相位。所以在外界环境中发生振动和入侵事件的时候，整个干涉信号的强度以及相位会发生变化，研究人员通过后端检测此变化就可以实现对外部振动事件的精确定位以及对振动事件的信号波形进行相位解调，从而就可以得到外部振动事件的完整参数信息。

## 2) 扰动点检测原理

$\Phi$ -OTDR 系统通过传感光纤实现对外界扰动进行实时的监测，量化外界扰动的方式主要有光强度检测和信号相位解调两种<sup>[3-5]</sup>。传统的 $\Phi$ -OTDR 系统实现光强度检测时，最通用的方法是对光时域信号进行差分计算和对光信号进行频域内的频谱分析。假设外部扰动事件的频率为  $\omega_R$  从而引起该扰动位置的后向散射光场发生改变，并且其光场的强度变化可以表示为：

$$E_R = E_{R0} \cos(\omega_R t + \varphi_R) \quad (4)$$

上式中  $E_R$  是光信号的幅值， $E_{R0}$  以及  $\varphi_R$  是一个定值，在  $t_1$  和  $t_2$  这个时间段里，处于此扰动区域处的光信号的强度会出现改变，可以表示为：

$$\Delta E_R = E_{R0} [\cos(\omega_R t_1 + \varphi_R) - \cos(\omega_R t_2 + \varphi_R)] \quad (5)$$

传感光纤中未受到外部振动的位置的散射光的信息不会发生改变，因此可以通过时域差分法可以实现对扰动信号进行精确定位。更进一步如果想要得到扰动信号的频率信息，则需

要对上面的等式进行傅里叶变换从而得到信号的频谱信息，傅里叶变换后的结果可以表示为：

$$E(\omega) = \pi E_{R_0} [\delta(\omega + w_R) + \delta(\omega - w_R)] \quad (6)$$

式中 $\delta$ 是一维冲击函数，上式表示在信号的频谱图中，扰动事件对应的频率处会出现尖峰，因此通过频域分析就可以得到扰动事件的频率信息。

### 3) 分类算法模型原理

随机森林算法是基于 Bagging 的集成学习算法，以决策树为基学习器。是 Leo breiman 在 2001 年提出的机器学习算法，其具有多个优点，如：准确率高、具有二重随机性，不易过拟合、训练速度快，可以得到特征重要性、可以实现并行化等，因此可以用来处理分类、回归问题。而对于分类问题，随机森林算法大致可以分为以下几步：(1)有放回采样  $n$  个数据样本，共进行  $k$  次，得到  $k$  个训练集(2)对于  $k$  个训练集，训练产生  $k$  棵决策树(3)对于分类问题，用投票的方式，投票结果当中的众数作为最后的分类结果。

决策树的构建方法有三种：ID3、C4.5、CART.三种算法的模型构造思想类似，不同之处在于采用的指标。ID3 和 C4.5 可以是多叉树，而 CART 则是二叉树，在生成子节点时，CART 通常是通过选取一个特征及阈值从而分为左右两支。CART 树生成子节点的指标是基尼系数，代表系统的混乱程度，基尼系数越小，分类效果越好，当无子节点分裂时，便形成了决策树，经过  $k$  次，则产生  $k$  棵决策树构成随机森林。在特征  $M$  作为节点时，对应样本  $T$  的基尼系数定义如下：

$$Gini(T) = 1 - \sum p_i^2 \quad (10)$$

式中  $p_i$  为类别  $i$  在样本  $T$  中出现的概率.当引入新的特征  $N$  进行分类时，分割后的基尼系数公式为：

$$Gini(T', N) = \frac{s_1}{s_1+s_2} Gini(T_1) + \frac{s_2}{s_1+s_2} Gini(T_2) \quad (11)$$

式中  $s_1$ 、 $s_2$  为划分后两类的样本数， $Gini(T_1)$ 、 $Gini(T_2)$  为各自样本对应的基尼系数。在进行用新的特征作为子节点分裂时，应使分割后对应的基尼系数最小，此时系统的混乱程度越低。当经过  $k$  次有放回采样产生训练集生成决策树后，最后的分类结果由所有决策树投票选举而得，这在数学上表示为：

$$H(x) = \operatorname{argmax}(h_p(x))$$

(12)

式中  $h_p(x)$  为单个决策树预测各类别的概率结果， $\operatorname{argmax}$  函数为获得概率结果中值最大的下标索引，取所有决策树的预测下标的众数作为随机森林模型预测结果。

### 3.2 设计方法

a. 实验光路结构搭建。将 DAS 和 MZI 结合，得到携带有扰动信息的光强信号利用数据采集卡(DAQ)和上位机 LabView 程序将采集的光强信号送入后续的处理程序中。利用差分算法进行扰动点定位。对一路光强信号进行差分处理，差分处理后即可得到两扰动点处的位置。

利用双路解调算法进行扰动点数据解调。扰动点位置确定后即可提取该点的数据并采用两路解调算法处理，可得到扰动处的相位信号。双路解调算法如图 3。

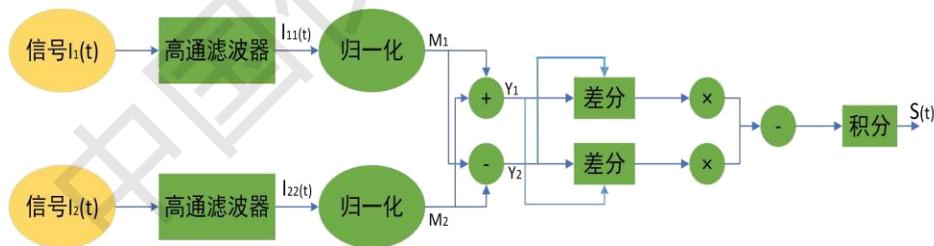


图 3 双路解调算法

b. 小波去噪，解调后的信号含有一定的噪声，需要进行去噪处理，这里采用小波去噪的方法。其流程如图 4 所示。



图 4 小波去噪流程

c.利用 Python 中的 librosa 库提取振动信号音频特征作为训练数据集，具体所选取音频特征有梅尔频率倒谱系数、色度频谱、谱对比度和声谱质心等。

d.构建随机森林算法模型，对所提取的振动信号音频特征数据集进行训练，具体算法流程如图 5 所示，从而实现对煤矿自然环境扰动、人为因素扰动、设备异常声音扰动等多类扰动事件的监测识别。

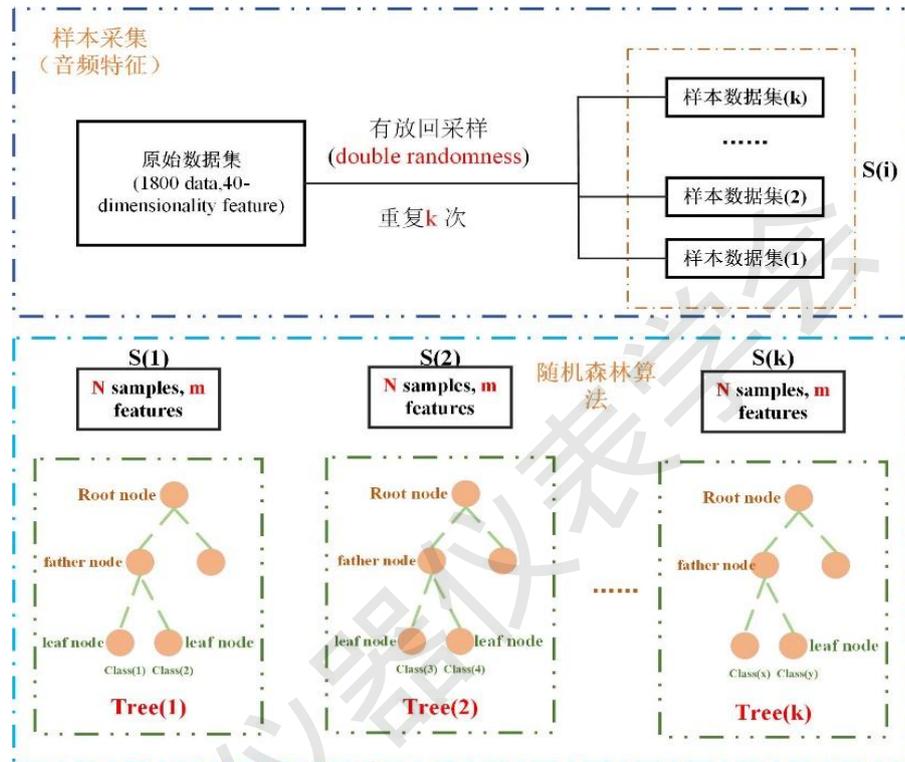


图 5 随机森林算法流程图

### 3.3 实验验证过程

本作品设计的基于 DAS 的煤矿设备异常振动监测识别系统结构如图 6 所示。光源发出的激光经声光调制器调制后产生周期 44us，脉宽 200ns 的光脉冲。在距传感光纤 2km 位置处用音响播放煤炭设备正常运转或产生故障时所发出的声音来模拟实际环境中的场景；2.2km 位置处用木锤敲击光缆或对 PZT 施加固定频率振动来产生声音模拟人为因素干扰，同时采集自然条件下环境干扰产生的对光缆的扰动信号。外界干扰事件会使光信号发生变化，携带有扰动信息的瑞利散射信号经过 MZI 干涉后，最终由光电探测器接收和数据采集卡采集。在后续数据处理阶段，首先将采集到的文本数据转化为音频文件，通过 Python 中的 librosa 库提取相应的音频特征作为随机森林算法的训练集，经过训练测试对六类不同扰

动事件的平均识别准确率达到了 99%，系统响应时间约为 0.4s，信号处理的过程均在 Jupyter notebook 中实现。

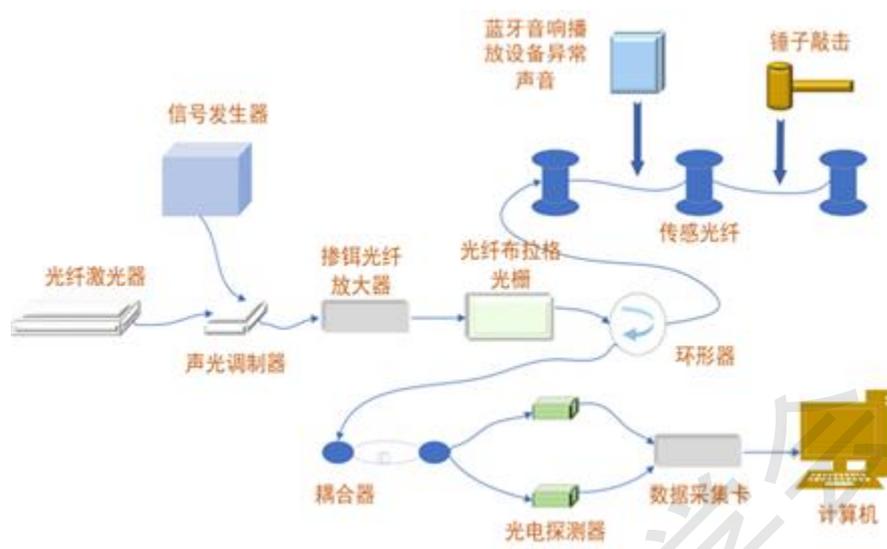


图 6 系统结构图

#### 参考文献:

- [1] Bao X Y, CHEN L.Recent progress in distributed fiber optic sensors [J] . Sensors, 2012, 12(7): 8601-8639.
- [2] JUAREZ J C, MAIER E W, CHOI K N, et al. Distributed fiber-opticintrusion sensor system [J] . Journal of Lightwave Technology, 2005, 23(6):2081-2087.
- [3] YILMAZ G, KARLIK S E. A distributed optical fiber sensor for temperature detection in power cables [J] .Sensors and Actuators, 2006, A125(2): 148-155.
- [4] PENG F, DUAN N, RAO Y J, et al. Real-time position and speed monitoring of trains using phase-sensitive OTDR [J] . IEEE Photonics Technology Letters, 2014, 26(20): 2055-2057.
- [5] ZOU D B, LIU H, ZHAO L, et al. Research on distributed optical fiber vibration sensing signal recognition [J] . Laser Technology, 2016, 40(1):86-89(in Chinese).
- [6] JUAREZ J C, TAYLOR H F. Field test of a distributed fiber-optic intrusion sensor system for long perimeters [J] . Applied Optics, 2007, 46(11): 1968-1971.
- [7] ZHOU L, WANG F, WANG X Ch, et al. Distributed strain and vibration sensing system based on phase-sensitive OTDR [J] .IEEEPhotonics Technology Letters, 2015, 27(17):

1884-1887.

- [8] WATKINS S E. Smart bridges with fiber-optic sensors[J]. IEEE Instrument & Measurement Magazine, 2003, 6(2): 25-30.
- [9] 杨震,封皓.基于深度学习的 $\Phi$ -OTDR 输油管道入侵监测研究[J].激光与光电子学进展,2022,59(08):51-59.
- [10] Shi, Y.; Wang, Y.; Zhao, L.; Fan, Z. An Event Recognition Method for  $\Phi$ -OTDR Sensing System Based on Deep Learning. *Sensors* 2019, 19, 3421.
- [11] Yi Shi, Yuanye Wang, Liyuan Wang, Lei Zhao, Zhun Fan, Multi-event classification for  $\Phi$ -OTDR distributed optical fiber sensing system using deep learning and support vector machine, *Optik*, Volume 221, 2020, 165373, ISSN 0030-4026

中国仪器仪表学报