

Φ -OTDR 系统的振动信号检测和识别算法

欧阳竑¹, 刘承达², 秦祖军², 王 侠¹

(1. 中国电子科技集团公司 第三十四研究所, 广西 桂林 541004; 2. 桂林电子科技大学 电子工程与自动化学院, 广西 桂林 541004)

摘要: 相位敏感光时域反射计(Φ -OTDR)系统在对振动信号位置判断的过程中, 采用幅度差分累加法存在对振动峰位置计算准确率低、不同频率的振动信号需随时修改 N 值的问题。提出了一种经验模态分解(EMD)与神经网络结合的算法, 该算法将振动点的时域信号分解后作为特征值输入到神经网络中训练, 再对信号是否为目标振动信号进行识别, 实验表明该方法的振动信号识别率达到 96.49%。

关键词: 相位敏感光时域反射计; 神经网络; 经验模态分解

中图分类号: TN914 文献标识码: A 文章编号: 1002-5561(2020)03-0037-04

DOI: 10.13921/j.cnki.issn1002-5561.2020.03.009

开放科学(资源服务)标识码(OSID):



Detection and recognition algorithm of vibration signal in Φ -OTDR system

OUYANG Hong¹, LIU Chengda², QIN Zujun², WANG Xia¹

(1. The 34th Research Institute of CETC, Guilin Guangxi 541004, China;

2. School of Electronic Engineering and Automation, Guilin University of Electronic Technology, Guilin Guangxi 541004, China)

Abstract: The phase-sensitive optical time domain reflectometer (Φ -OTDR) system uses the amplitude differential accumulation method to count the position of the vibration signal. There exists the problem of low recognition rate and need to be modified the N for different frequencies. An algorithm combining empirical mode decomposition (EMD) and neural network is proposed. The EMD is used to denoise and analyze the time domain signal at the vibration point, the signal characteristics are extracted by EMD and input to an improved neural network as features for training. The trained neural network is then employed to identify different vibration signals at different frequencies. The experiment shows that the recognition rate of vibration signal is 96.49%.

Key words: Φ -optical time domain reflectometer; neural network; empirical mode decomposition

0 引言

相位敏感光时域反射计(Φ -OTDR)在 1993 年由 Taylor 和 Lee 首次提出^[1,2], 其原理是利用光在光纤中传播时会发生瑞利散射, 后向瑞利散射光会携带光纤沿线的扰动信息, 并沿光纤传播回光纤注入端, 采集并分析后向瑞利散射光即可得到光纤上的形变信息。 Φ -OTDR 系统因其具有全尺度连续性、超长距离和高灵敏度等优点, 已被广泛应用在防入侵检测、大型建

筑结构的裂缝健康检测和石油管道检测等多个领域, 对特定振动信号进行实时定位、识别, 对构建多传感器融合的分布式监测系统有重要参考价值。本文针对 Φ -OTDR 分布式光纤振动检测系统提出一种基于经验模态分解(EMD)与神经网络结合的振动信号检测及识别的数据处理算法, 具体通过 EMD 对振动点的时域信号降噪、分解, 提取出信号的特征, 输入到神经网络中训练, 使用训练后的神经网络对振动信号进行识别。

收稿日期: 2019-09-24。

作者简介: 欧阳竑(1979-), 男, 广西梧州人, 本科, 高级工程师, 主要研究方向是光通信设备、光电子模块、组件研制开发和光电信号处理等。负责完成和在研的国家级、省部级项目 15 项, 获得国防科技进步二、三等奖各 1 次, 中国电科集团科技进步一、二、三等奖各 1 次。



1 Φ -OTDR 系统

由于传统 OTDR 采用的是直接功率探测方式, 线路中掺铒光纤放大器(EDFA)的噪声功率与背向瑞利散射信号功率无法得到区分, 因而系统测量的信噪比会大大降低。本文通过检测传感光纤线路上不同时刻

后向瑞利散射信号叠加干涉的强度来判断振动点的位置,其系统框架如图1所示。




图1 系统结构框图

激光器发射出窄线宽的连续激光,激光线宽为3 kHz,输出功率约为25 mW,输出模式为自动功率控制模式。连续光波首先被90:10的光耦合器分成2部分,其中90%为信号光,10%为本振光,用来与后向瑞利散射光进行相干检测。信号光通过声光调制器调制成100 ns的脉冲光,其上升沿和下降沿均为2.5 ns,周期为30 μ s,同时将脉冲光的主频移动200 MHz以便光电转换后的电信号处理。脉冲光经环形器进入传感光纤,在光纤中发生瑞利散射,返回的后向瑞利散射光再经环形器与本振光进行耦合,耦合后的信号被平衡探测器转换为电信号。电信号经过射频(RF)放大和滤波,再经IQ解调产生I和Q 2路基带信号,最终由示波器进行采集及后期信号处理。经测试,系统的动态范围可以满足25 km长度的传感光纤需求,信噪比为6 dB,空间分辨率为10 m。


如上所述,系统向传感光纤中不断注入探测脉冲光,每个周期的脉冲光都可以得到一条瑞利后向散射的干涉曲线,每条干涉曲线中包含了各个位置的扰动信息。振动点处及其附近的瑞利后向散射幅度信息叠加如图2(a)所示;压电陶瓷(PZT)施加不同调制频率后振动点的时域信号图如图2(b)所示。由图2可知,当PZT位于距光纤注入端约1046 m处(虚线部分),且光纤对PZT的振动较为敏感时,可基本重现PZT振动信号。

2 振动峰检测算法


目前的 Φ -OTDR系统中,振动峰检测算法多使用幅度差分累加法,其受扰动事件的频率影响较大,需针对不同的振动频率改变差分间隔条数,不利于多振动频率事件的探测。而离散度计算法利用振动点与非振动点处时域信号的差异进行判断,对各频段的扰动事件均有较好的响应。

2.1 幅度差分累加法

幅度差分累加算法对振动点的识别原理如下:连



(a) 数十条后向瑞利散射光幅度信息叠加图



(b) 不同频率下振动点的时域信号

图2 实验设备采集的原始数据

续采集 M 条瑞利后向散射信号的幅值信息,用第 $i+N$ 条幅度曲线和第 i 条幅度曲线差分运算(i 的取值范围为1~ $M-N$),取绝对值,并对 $M-N$ 条差分曲线进行累加得到幅度差分曲线,可以从幅度差分曲线上出现峰值的位置得到振动点的位置^[3,4]。

由于 Φ -OTDR系统中光信号受偏振态不稳定和激光器频率漂移的影响,导致差分叠加后的噪声加剧,并且差分累加法对于低频扰动的事件需要更长的探测周期来获取完整的扰动事件。因此,在使用幅度差分累加算法时,需根据不同频率范围的振动信号,随时调整差分间隔 N 的值,以匹配当前振动源的振动频率,并且对于 N 值的选取需要花费大量的时间去测试,没有一个明确的选值依据。此外,幅度差分累加法对振动波形的要求较高,检测振动源为标准正弦波时效果最好,而检测不规则振动源时效果较差。

2.2 离散度计算法

由图2可知,振动点时域信号的离散程度要远大于非振动点时域信号的离散度,所以可以使用统计学中计算离散度的算法对振动点进行检测。统计学中常用的离散度计算法有方差、极值、平均差和变异系数。

方差克服了极差的缺点,全面考虑到每一个观察值,用来度量随机变量和数学期望之间的偏离程度。平均差是所有变量值与平均数的离差绝对值的算术平均数,平均差越大,表示各标志值与算术平均数的差异程度越大。变异系数是将数据的平均值以及标准差同时作为参考依据,其消除了测量尺度和量纲的影

响,可反映数据的离散程度。其中,极值为最大值与最小值之差,系统噪声所产生的极端值对其影响较大、可信度较低,因此本文不采用极值法对数据进行处理。各离散度计算公式详见文献[5]。

3 振动源识别算法

本文针对 Φ-OTDR 系统提出了一种结合经验模态分解(EMD)和神经网络的振动源识别的算法。首先,使用 EMD 对信号进行分解和特征提取,利用 EMD 分解出振动点时域信号的各阶固有模式分量(IMF);其次,求出振动点时域信号的方差和极差;最后,使用各阶 IMF 的能量值、方差和极差共同作为特征值输入到神经网络中进行训练,使用训练好的神经网络实现对振动源的识别。

3.1 EMD

EMD 是由黄镌等人于 1998 年提出的一种信号分析的方法^[6,7],适用于非线性、非平稳信号分析,在振动信号检测领域有着广泛的应用。EMD 利用信号的时间尺度特性进行信号的分解而无需设置基函数,本质上是一种时频分析方法,其主要是完成一个非平稳信号的分解,分解后得到多个 IMF 和一个趋势项的线性组合,即一个非平稳信号 $x(t)$ 可以表示为:

$$x(t) = \sum_{i=0}^n IMF_i(t) + r(t) \quad (1)$$

其中, $IMF_i(t)$ 表示第 i 阶的固有模式函数, $r(t)$ 为很低频率的脉动,即趋势项。

EMD 依据信号自身的时间尺度特征来分解信号,不需要预先设置基函数,对特定形态振动信号和随机振动信号都可以分解出其对应的本征模函数,而各阶本征模函数可以表征一个信号,即各阶本征模函数为一个信号的特征,以此作为特征值输入到神经网络中进行训练。对于一个待测信号(可以是特定形态的振动信号,也可是随机振动信号),也通过 EMD 的方法得到其信号的特征值,输入到训练好的神经网络中来识别。由于随机振动信号样本不足,本文中仅对特定形态的振动信号进行识别。

对一个信号进行 EMD 的具体步骤为:

①找到振动信号 $x(t)$ 所有极大值与极小值点,然后将所有极大值、极小值点用曲线连接起来得到上包络线 $e_{\max}(t)$ 和下包络线 $e_{\min}(t)$,再求出上包络线和下包络线的均值包络线函数 $m(t)$:

$$m(t) = \frac{e_{\max}(t) + e_{\min}(t)}{2} \quad (2)$$

②式(2)记 $x(t)$ 与 $m(t)$ 的差为 $h_1(t)$,若 $h_1(t)$ 不是一个 IMF,则继续上述过程,直到第 k 次循环 $h_{1k}(t)$ 是一个 IMF,记为 $c_1(t)$ 。

③根据分解出的 IMF 获取剩余信号 $x_1(t)$:

$$x_1(t) = x(t) - c_1(t) \quad (3)$$

④重复上述步骤,直至第 n 阶的 $h_n(t)$ 变成一个单调序列,定义趋势项 $r_n(t)$ 为 $x_n(t)$ 。

3.2 神经网络

本文采用基于 Dropout 和 Adam 优化器的改进神经网络^[8-10],使用 ReLU 和 sigmoid 激活函数模拟神经元对激励的响应,进而使用 Adam 优化器反神经网络的连接权值进行最优化训练,直到输出的误差达到符合的要求或者达到设定的迭代数值。ReLU 函数在输入大于 0 时梯度下降较快,可以加速收敛速度;sigmoid 函数可以将输入映射到 [0,1] 范围内,方便进行后续分类。




图3 神经网络模型

($ui_1, ui_2, \dots, ui_{10}$), 隐含层的输出向量 $uo=(uo_1, uo_2, \dots, uo_{30})$; 输出层的输入向量 $si=(s_1, s_2, \dots, s_{30})$, 输出层的输出向量 $yo=(yo_1)$ 。其中, w_{ih} 和 w_{oh} 分别是输入层与隐含层、隐含层与输出层的连接权重。

本文采用 Adam 优化器进行模型最优化, 并使用 Dropout 加强系统的鲁棒性。Dropout 的基本理念为: 对于某层神经网络, 所有的单元以 P 的概率随机丢弃。本文取 $P=0.3$, 即每个单元都有 30% 的机率失活。

3.3 训练神经网络

本文连续采集 1000 条后向瑞利散射干涉曲线, 提取 PZT 位置的时域信号, 对其进行 EMD。由于系统中噪声所带来的不确定性, 分解会得到 9~10 个 IMF (包括趋势项), 不同振动信号之间的 IMF₉ 和 IMF₁₀ 存在相关性, 会造成后续训练神经网络的准确率下降, 所以 IMF₉ 和 IMF₁₀ 不用来表征信号的特征。将 IMF₁~IMF₈ 做积分处理得到不同分量的能量, 8 个能量值加上这个时域信号的方差和极差共同作为一个样本输入到神经网络中进行训练。

神经网络隐含层节点数为 30, 迭代次数设置为




图4 3个数据集下各算法对振动源识别的准确率

2000, 激活函数的输入层为 ReLU 函数, 输出层为 sigmoid 函数, Dropout 为 0.4, 使用 Adam 算法进行最优化。

4 实验结果及分析

4.1 不同算法对振动峰位置判断准确率的分析

实验所使用的传感光纤为 2800 m, PZT 位于距光纤注入端 1046 m 处, 振动频率调节范围为 0~100 Hz。使用相同的后向瑞利散射信号幅值信息的数据集, 对沿光纤各点的时域信号使用差分累加法和离散度计算法进行计算, 得到各算法下振动峰的位置。各算法对振动峰位置判断的准确率结果如图 4 所示。可以看出, 相同数据集下, 幅度差分累加法对振动峰位置判断的准确率不稳定, 误判率高, 在 4 种计算方法中效果最差; 而变异系数法对振动峰位置的判断准确率高, 整体效果好, 且变异系数法无需针对不同频率设置不同的 N 值, 也无需俘获完整周期的扰动事件即可计算振动峰, 变异系数法从准确率和适用性上, 均比幅度差分累加法有优势。

4.2 神经网络训练的结果分析

训练集共 700 个样本, 其中 40 Hz 振动信号的样本和其它频率振动信号各 350 个; 测试集的样本数量为 300 个。实验结果如图 5 所示。可以看出, 当迭代




图5 迭代次数与准确率关系

次数为 1053 时, 对 40 Hz 振动信号的识别率达到了最高 96.49%, 这证明了在 Φ -OTDR 系统中使用本文所提算法对特定振动源进行识别是可行的。

5 结束语

本文使用不同计算离散度的方式对后向瑞利散射信号进行处理, 不同算法对位置判断的准确率与幅度差分累加法比较, 得出变异系数法对数据处理效果最好的结论, 解决了幅度差分法对振动峰检测噪声影响大、识别率低的问题。同时, 本文提出一种基于 EMD 和神经网络相结合的方式对振动点进行识别, 经 EMD 对信号特征提取、神经网络训练, 对 40 Hz 振动信号的识别率达到了 96.49%, 这对 Φ -OTDR 系统识别特定振动源提供了有价值的参考。

参考文献:

- [1] TAYLOR H F, LEE C E. Apparatus and method for fiber optic intrusion sensing: US. 5194847 [P/OL]1993-03-16 [2019-09-24]. <https://worldwide.espacenet.com/publicationDetails/originalDocumentCC=US&NR=5194847&KC=&FT=E>.
- [2] JUAREZ J C, TAYLOR H F. Distributed fiber optic intrusion sensor system for monitoring long perimeters[C]//Sensors, and Command, Control, Communications, and Intelligence (C3I) Technologies for Homeland Security and Homeland Defense IV. March 28–April 1, 2005, Orlando, Florida, United States: International Society for Optics and Photonics, 2005, 5778: 692–703.
- [3] ZHU H, PAN C, SUN X. Vibration pattern recognition and classification in OTDR based distributed optical-fiber vibration sensing system[J]. Proceedings of SPIE The International Society for Optical Engineering, 2014, 906205(11): 3814–3818.
- [4] 贺梦婷, 庞拂飞, 梅烜玮, 等. 基于 IQ 解调的相位敏感 OTDR 的研究[J]. 光通信技术, 2016, 40(9): 23–26.
- [5] ROSS M. Introduction to probability and statistics for engineers and scientists[M]. New York: Academic Press, 2014.
- [6] 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: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903–995.
- [7] 王珍, 郭方, 江亲瑜, 等. EMD 的 LabVIEW 实现及其在滚动轴承故障诊断中的应用[J]. 噪声与振动控制, 2009, 29(4): 54–57.
- [8] SRIVASTAVA N, HINTON G, KRIZHEVSKY A. et al. Dropout: A Simple Way to Prevent Neural Networks from Overfitting [J]. Journal of Machine Learning Research, 2014, 15(1): 1929–1958.
- [9] KINGMA D P, BA J. Adam: A method for stochastic optimization[C]//The 3rd International Conference for Learning Representations, May 7–9, 2015, San Diego, USA. NY: arXiv.org, 2015.
- [10] 杨观赐, 杨静, 李少波, 等. 基于 Dropout 与 ADAM 优化器的改进 CNN 算法[J]. 华中科技大学学报(自然科学版), 2018, 427(7): 127–132.