

# 光学学报

## 基于经验模态分解的马赫-曾德尔干涉仪事件识别方案优化

王鸣<sup>1</sup>, 封皓<sup>1</sup>, 沙洲<sup>1\*</sup>, 赵利<sup>2</sup>

<sup>1</sup>天津大学精密仪器与光电子工程学院精密测试技术及仪器国家重点实验室, 天津 300072;

<sup>2</sup>山东龙泉管道工程股份有限公司, 山东 淄博 255200

**摘要** 事件识别是分布式光纤传感的重要应用, 现有的模式识别手段存在泛化性差和对弱振动识别的准确率低两个主要难题。以马赫-曾德尔干涉仪为应用对象, 从样本来源的角度改善传统的分类器, 以时域信号经经验模态分解所得的本征模态函数构建训练样本, 使用卷积算子提取信号的波形特征、频域特征、时频域特征, 构建深度学习网络, 并在相同的神经网络框架下以原始信号为输入设计了 4 个对照组。所提识别方案在测试集和验证集上对 6 种目标信号的准确率分别为 97.02% 和 94.88%, 泛化性和分类精度均处于最优状态。分类器的平均样本响应时间低于 0.07 s, 具备良好的可行性与发展前景。

**关键词** 深度学习; 经验模态分解; 马赫-曾德尔干涉仪; 本征模态函数; 事件识别

**中图分类号** TP181; TP212

**文献标志码** A

**DOI:** 10.3788/AOS230698

### 1 引言

威胁事件识别是分布式光纤传感领域的研究热点。深度学习作为重要的识别手段<sup>[1]</sup>, 制约其进一步优化的难题主要存在两方面。一个是分类器泛化性不足, 深度学习本质上是基于神经元节点的矩阵运算, 在训练过程中表现出色的模型的参数并不完全适用于真实的应用场景, 这主要是因为不同环境下样本间的差异较大。另一个是对于一些振动强度低、特征不明显的信号, 存在错误识别的可能性, 这主要是由于特征存在模糊以至于目标信号常被淹没于噪声中。

常规的神经网络是端到端的学习方式, 用户可以将其看作一个黑箱模型<sup>[2]</sup>。提升分类精度的主要途径大致分为 3 种。第 1 种是在网络前端对信号进行数据预处理, 如带通滤波、小波去噪与重构<sup>[3]</sup>、希尔伯特变换<sup>[4]</sup>等。第 2 种则是增强对训练样本特征的提取。Pan 等<sup>[5]</sup>从信号和频谱图中提取序列相关性, 从而使传统的卷积神经网络架构能够以较少的计算量实现更好的识别效果。Sun 等<sup>[6]</sup>将时域信号转换为灰度图像, 开发了一种基于串行融合特征提取模型的深度学习方法。Lai 等<sup>[7]</sup>通过解调干涉仪相位信息的快速傅里叶变换获得光谱信号, 并将其作为一维卷积神经网络的输入。第 3 种则是增加特征提取手段。Shi 等<sup>[8]</sup>使用带

通滤波前端处理和预训练的 AlexNet 多层卷积网络提取时空图的空间特征。Ma 等<sup>[9]</sup>使用不同尺度的卷积神经网络(CNN)来提取信号的多层次和多尺度特征。Wang 等<sup>[10]</sup>提出了一种利用基于长短期记忆网络(LSTM)和 CNN 的 LSTM-CNN 来检测非平稳振动信号的策略。另一种思路是从结构上改善传统的神经网络。Song 等<sup>[11]</sup>和 Meerasha 等<sup>[12]</sup>均提出了一种光子神经网络, 理论上相比传统的神经网络, 该网络具有更高的数据处理速度和分类精度。但这种方案依赖于电光干涉系统或对芯片的性能有更高的要求, 并不能直接用于常规的光纤预警系统。

本课题组前期设计了基于 LSTM-CNN 的分类器, 该分类器用于相敏光时域反射仪( $\varphi$ -OTDR)的事件分类<sup>[13]</sup>。本文的传感系统为马赫-曾德尔干涉仪(MZI), 对高采样率的要求导致了每秒采样点数和信号频率范围的增加。同时, 由于 MZI 的干涉曲线受光缆沿线振动场的调制, 其信噪比受到较大的制约。因此设计一种运算量小、特征提取有效度高、识别准确率高的深度学习分类器具有极大的现实意义。在上述优化方案中, 常规的前端处理产生的积极效果有限, 同时还会丢失部分细节信息; 而过多增加卷积层数量或引入 LSTM 则会造成运算量的增加。本文使用经验模态分解(EMD)完成信号的特征增强, 使用筛选后的模

收稿日期: 2023-03-24; 修回日期: 2023-04-13; 录用日期: 2023-04-23; 网络首发日期: 2023-05-08

基金项目: 国家自然科学基金(62005191, 61873183)、广西自动检测技术及仪器重点实验室开放基金(YQ21205)

通信作者: \*shazhou@tju.edu.cn

态作为网络输入,提取其波形特征、频谱特征和时频域特征,结合卷积算子完成对6种目标信号的识别。所提方案在泛化性与分类精度方面优于以原始信号为输入的对照组,其在测试集和验证集上的准确率为97.02%和94.88%,平均响应时间为0.07 s。

## 2 数据采集

依托银川都市圈中线供水工程搭建MZI传感系统,采集管道应用状态下的目标信号。管道全长43 km,光缆为GYTA53高弹性模量多芯光缆,MZI由同一光缆中的3根纤芯搭建,如图1所示。光源为20 mW窄带激光,中心波长为1550 nm,耦合器分光比均为1:1,DAC采样率为50 kHz,每秒采样点数为 $50 \times 10^3$ ,带宽为250 MHz。实验光路结合配套Labview采集程序可直接观测光干涉曲线,利用麦克风控件可侦听光缆沿线声场。

为模拟管道常面临的威胁事件,实验人员采集了6种目标信号,包括无入侵状态下的环境噪声(事件

1)、PCCP预应力钢丝断裂(事件2)、触碰光缆(事件3)、敲击管壁(事件4)、凿砂浆保护层(事件5)、砂轮切割管外壁(事件6)。其中,事件2本质上是一种声信号。事件4是与事件3相对的一种弱振动,这两种信号主要用于检验模型对弱振动的识别性能。事件5与事件6则分别是对管道冲击性与持续性的破坏。这些事件模拟了工程中管道面临的常见破坏行为,包含无振动、强振动、弱振动、瞬时破坏、持续入侵等场景,可以全方位检验所提识别方案的泛化性和应用前景。

每个样本存储过去1 s内的时域干涉曲线,包括50000个采样点。在一个实验周期内,实验人员仅采集一种目标信号,通过实验记录及声场侦听即可完成对样本与标签的精准对应。训练阶段的数据集共包括4524个样本,事件1~6的样本数分别为770、734、774、766、720、760。训练集与测试集划分比例为0.2。验证集由相同的采集方式在新场景下获得,事件1~6的样本数分别为626、484、907、431、510、696。

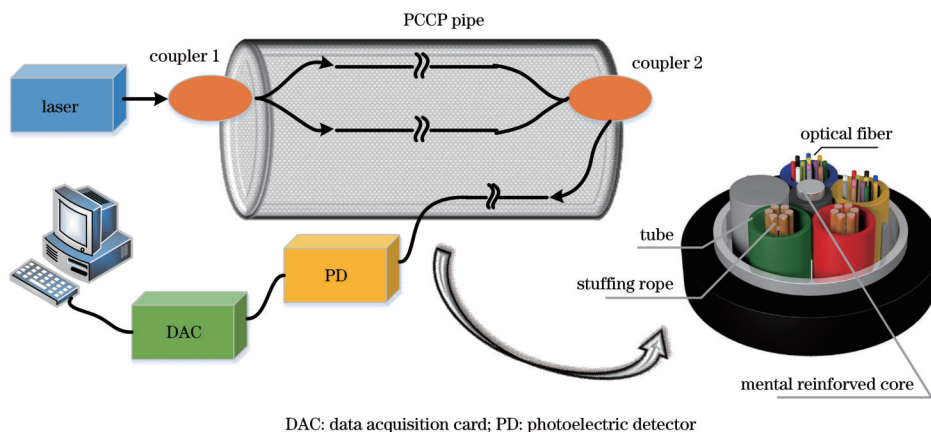


图1 马赫-曾德尔干涉仪的测量光路

Fig. 1 Measurement optical path of the Mach-Zehnder interferometer

## 3 特征分析及神经网络

### 3.1 基本特征

随机选取每种事件的样本,分析基本的时域特征和频域特征差异,如图2所示。就波形而言,事件1属于无规则稳定的波动,整体幅值较低;事件3由于直接接触光缆,呈现出鲜明的局部缆振特征;事件5直接作用于管道且强度较大,表现为较为清晰的局部脉冲。从频谱的角度,事件3与事件5在高频段(500 Hz以上)存在较多的能量分布。结合波形和频谱分布,可以有效识别这些事件。相比之下,事件4和事件6与噪声(事件1)在波形上的相似度很高,很难直接观察到振动的存在,仅能够通过一些特征频段和声场的还原进行区分;事件2的主要标志是钢丝断裂瞬间释放的高能声波,它一定程度上引起了时域波形的响应,但相比事件5,更明显的特征体现在2000 Hz以上频段的能量

增加。

因为图2所呈现的波形及频谱的特征差异,一定程度上可以完成对入侵事件的多分类。但一方面,这些特征会随着振动强度的降低而趋于模糊,另一方面,即使是在同类事件中,这种特殊频段也不是完全一致的,这些都降低了分类器的泛化性和可靠性。为改善这一难题,本文将分析原始信号经EMD所得的本征模态函数IMF<sub>i</sub>,以寻求更清晰的振动特征。

### 3.2 IMF特征

经验模态分解是一种自适应的分解算法,它最大的优点在于保留了原始信号的细节信息,而原本淹没于噪声中的振动信号在某些具体的分量中又得到了进一步放大<sup>[14-16]</sup>。通过对大批量样本的统计分析,这一特征主要的表现如下。

1)在振动信号的部分IMF上,振动发生位置表现为孤立存在的尖脉冲,这与原始波形的响应脉冲是对

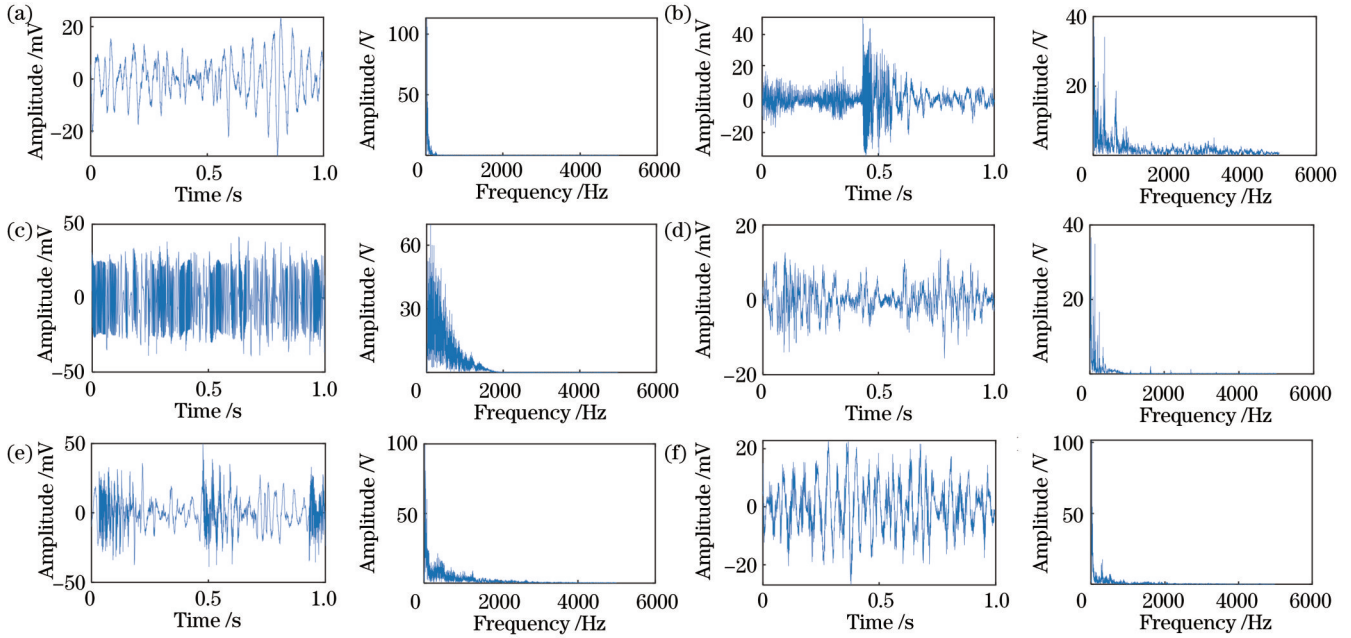


图 2 信号波形和傅里叶频谱。(a)~(f)事件 1~事件 6

Fig. 2 Signal waveforms and Fourier frequency spectra. (a)-(f) Event 1-event 6

应的。相比原始波形,IMF 上的振动特征得到了放大,而基底噪声被抑制。同时脉冲的幅值、密集度与信号类型密切相关。

2)另一方面,这种特征并不是存在于所有分量中的,以 6 层 EMD 为例,事件 4 的特征脉冲存在于 IMF<sub>1</sub>~IMF<sub>4</sub>,而事件 3 的特征脉冲仅存在于 IMF<sub>2</sub> 和 IMF<sub>3</sub>。

MZI 的高采样率和高采样点数导致了巨大的数据体量,将所有的 IMF<sub>i</sub> 都输入神经网络是不合理的,因此需要分析各模态函数的具体特征。考虑到 EMD

的端点对分解精度和两端敛散性的不利影响,实验人员在编写相关程序时采取极值延拓法<sup>[17]</sup>来改善这一情况。分析具体模态的目的是获取共性模态,将其作为神经网络的分析对象,所有类型的信号都需要在这一模态上呈现出振动增强的基本特征。分解层数过多或过少都不利于获取这一共性模态。结合前期数据统计工作,本文将原信号分解至 6 层,统计每个 IMF<sub>i</sub> 占总能量的比例,并观察这一参数的样本间分布。每种事件随机选择 400 组样本,绘制箱线图,如图 3 所示。

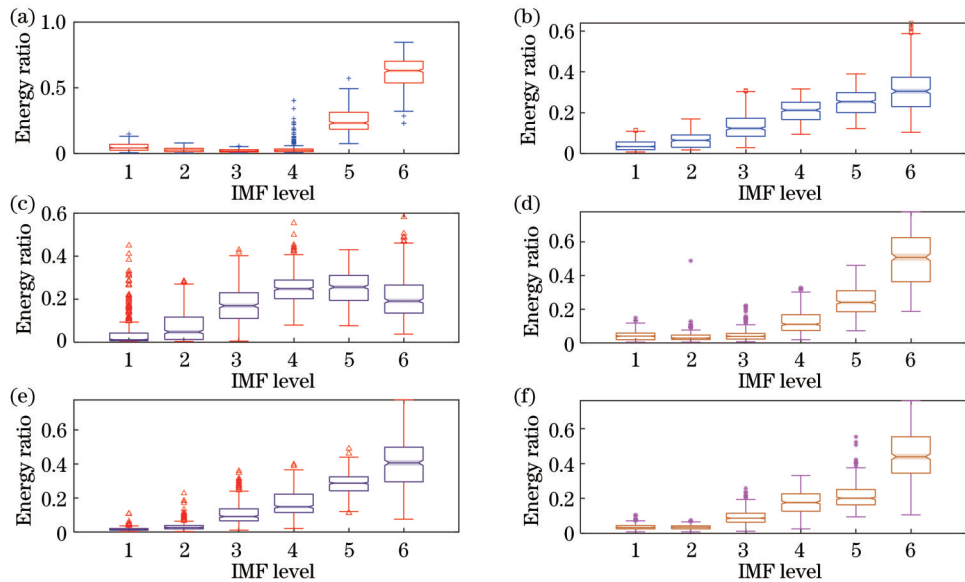


图 3 每层 IMF 能量所占的比例。(a)~(f)事件 1~事件 6

Fig. 3 Proportion of IMF energy per layer. (a)-(f) Event 1-event 6

图 3 中,IMF<sub>1</sub> 上的能量分布最少,而 IMF<sub>6</sub> 上能量分布的浮动区间较大,具备较差的一致性与重复性。

前期调研也呈现相似的结论,即 IMF<sub>1</sub> 与 IMF<sub>6</sub> 的波形无法与原始信号建立基于振动存在的对应关系,这就

导致上述分量不适合用于构建训练样本。在舍弃  $IMF_1$  与  $IMF_6$  之后,进一步对比图 2 中时域曲线

$IMF_2 \sim IMF_5$  的波形,如图 4 所示。

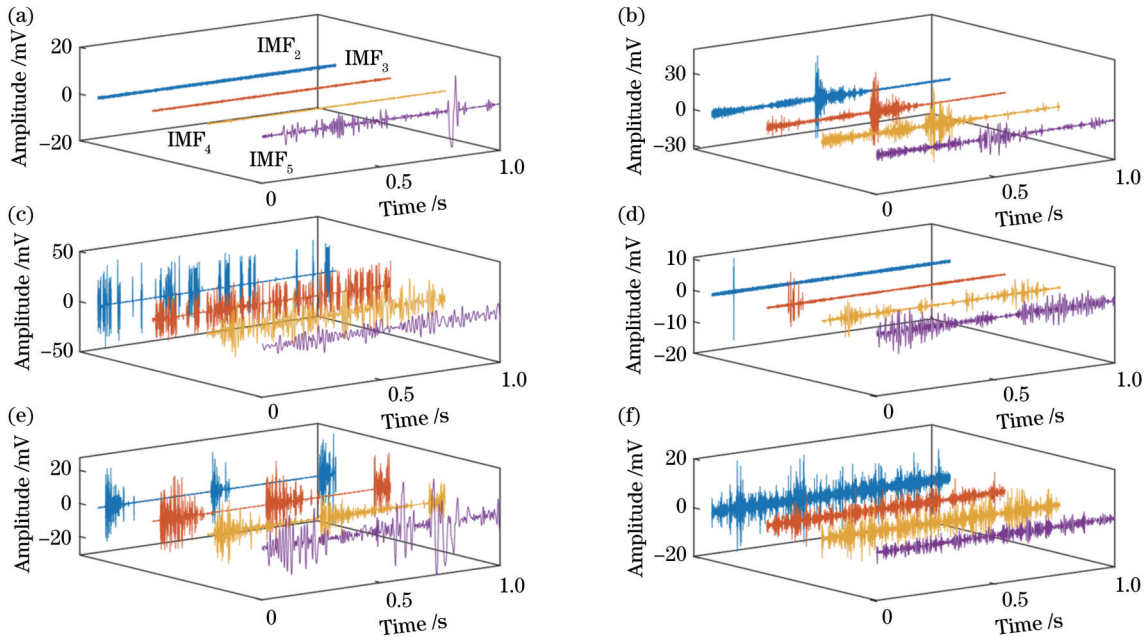


图 4 图 2 中时域信号  $IMF_2 \sim IMF_5$  的波形。(a)~(f)事件 1~事件 6  
Fig. 4 Waveforms of  $IMF_2 \sim IMF_5$  of time-domain signals in Fig. 2. (a)-(f) Event 1-event 6

图 4 中各 IMF 的脉冲与图 2 中原始波形的振动部分呈现出显著的相关性。瞬时冲击振动如事件 2、4、5 都仅表现一个局部脉冲,持续性振动如事件 6 的脉冲在时域上持续存在,这与信号自身的特点是一致的。所有信号在 IMF 上的共性特征是振动部分得到了加强而噪声得到了极大的抑制,这种特征在  $IMF_2$  和  $IMF_3$  上得到了最明显的呈现。一个典型的例子是,通

过图 2 中的时域波形很难判断出事件 4 和事件 6 振动的存在,但是在图 4 中则可以清晰地观察到特征脉冲的位置。至于其他分量,部分事件如事件 3 和事件 4,在  $IMF_4$  和  $IMF_5$  上已经很难通过波形判断其存在,作为神经网络的输入端,这种共性模式的选择必须是一致的,因此最终选择  $IMF_2$  和  $IMF_3$  以提取轮廓特征。进一步分析图 4 中  $IMF_2 \sim IMF_5$  的频谱,如图 5 所示。

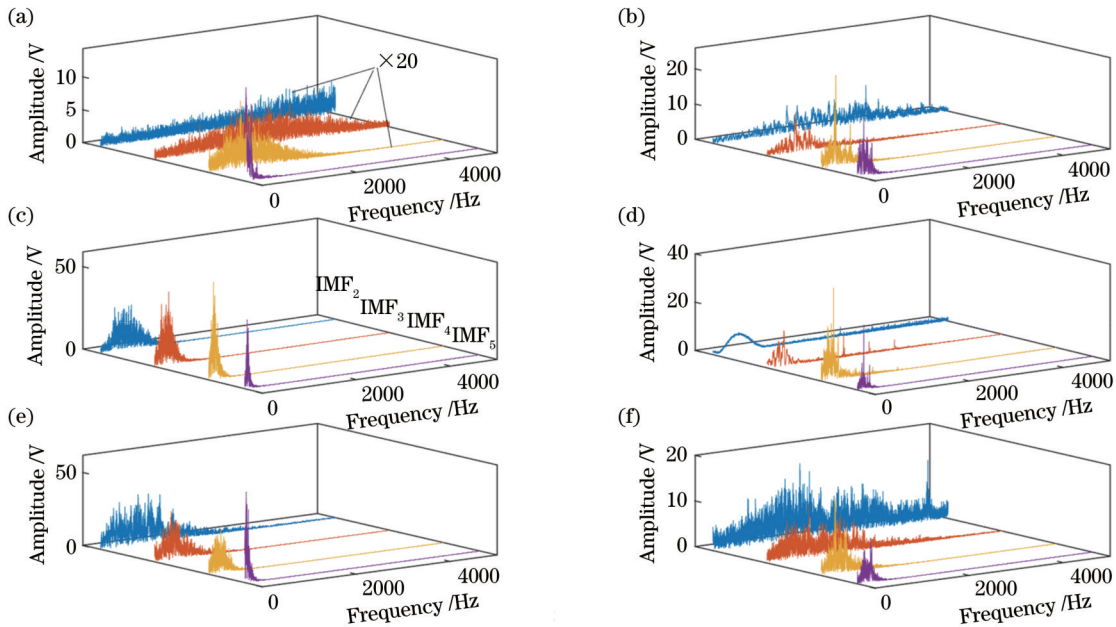


图 5 图 2 中时域信号  $IMF_2 \sim IMF_5$  的傅里叶谱。(a)~(f)事件 1~事件 6  
Fig. 5 Frequency spectra of  $IMF_2 \sim IMF_5$  of time-domain signals in Fig. 2. (a)-(f) Event 1-event 6

由于高频分量极少,因此仅保留了0~5000 Hz的频谱。噪声各分量的频谱幅值远低于其他信号,出于对比形态学特征的目的,对噪声IMF<sub>2</sub>~IMF<sub>4</sub>的频谱放大20倍。与图2中原始信号的频谱相比,IMF的频谱存在两个主要特征。1)同类事件中,原始信号频谱的整体分布趋势一致,但频谱形态、特征频段等细节差异较大;同类事件中,IMF频谱的相似度较高,除噪声外均呈现出三角形分布特征。大批量样本的统计表明,这种频谱特征是广泛存在的。2)振动事件与噪声的IMF频谱差异显著。以噪声为例,IMF<sub>2</sub>的频谱表现为自左至右的梯形,IMF<sub>3</sub>的频谱则近似表现为以2500 Hz为对称轴的等腰三角形。相比之下,振动事件的频谱形态均接近三角形,主要差异体现在三角形的陡峭程度、对称轴位置、频段分布等。例如,由于振动强度较低,图2中砂轮切割(事件6)与噪声(事件1)的频谱存在较高的相似度,极易导致事件的错误识别。但图5中两种信号IMF的频谱却截然不同。

此外,尽管振动事件的频谱总体上呈现三角形轮廓,但是可以通过某些特征频段的能量差异或频谱的形态学特征如重心、峰值频率、峰均比、峰度等对它们做出区分。在本课题组的另一项工作中,通过提取IMF波形的脉冲特征和IMF频谱的形态学特征构建了16维向量,Random Forest、SVM、Gradient boosting等方法实现了超过93%的准确率<sup>[18]</sup>。但这种人为构造的分类向量对特征提取的有效性是有限的。相比之下,深度学习这种端到端的学习方式利用大量感知器构造神经网络<sup>[19-20]</sup>,通过误差反向传播和梯度下降以促进模型的收敛。由于无需人为地提取目标具体特

征,在样本充足和多轮迭代的情况下,深度学习的准确率理论上接近100%。由于本文仅保留了5000 Hz以下的频谱作为研究目标,且四种分量的频谱都具备一定程度的类间差异,因此将IMF<sub>2</sub>~IMF<sub>5</sub>的频谱都用于频域特征的获取。

### 3.3 分类器及对照组设计

输出端干涉信号是MZI主要的信号呈现形式,而响应脉冲是振动事件重要的判断依据。由于时域曲线的采样点按照时间顺序在一维方向排布,因此使用一维卷积算子即可提取其轮廓特征。MZI对于声场的还原可以作为一种辅助手段,更准确地帮助用户判断入侵类型,这是其相比φ-OTDR的主要优势之一。频率是声信号的关键特征,与时域曲线类似,频谱随着频率增加沿一维方向排布,此处使用傅里叶谱和一维卷积算子提取频域能量特征。

轮廓特征与频域特征都仅呈现一个维度的信息,而对于冲击性事件和持续性振动,时频谱可以同时呈现它们在时域和频域的差异,实现对更多细节特征的提取。此处使用短时傅里叶变换(STFT)和二维卷积算子提取时频域特征。

图6为深度学习分类器结构,将筛选后的IMF分量作为网络输入,构造了融合轮廓特征、频域特征、时频域特征的训练样本,结合卷积算子实现对6种目标事件的识别。为验证所提识别方案在分类精度和泛化性方面的优越性,以原始信号为样本来源,在图6框架下设计了4个对照组,其中频域特征分别使用FFT、希尔伯特边缘谱<sup>[21]</sup>、离散小波变换(DWT)<sup>[22-23]</sup>提取,时频域特征分别使用STFT、希尔伯特谱、连续小波变换

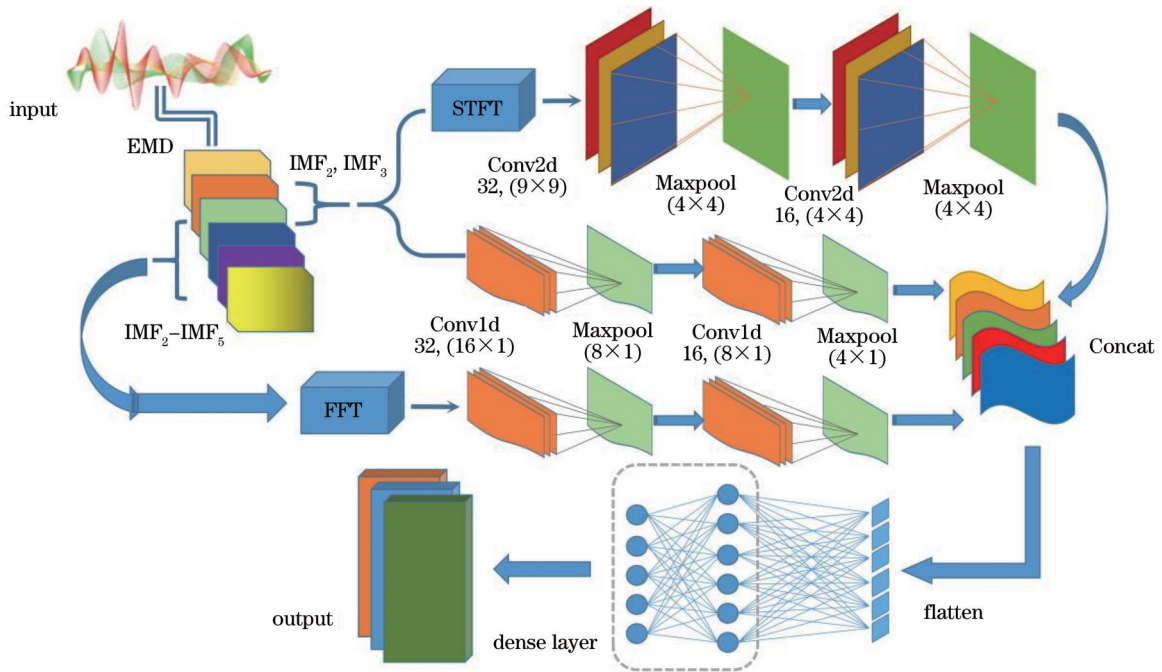


图6 深度学习分类器结构,两组一维卷积的参数相同

Fig. 6 Deep learning classifier structure, two sets of one-dimensional convolutions with the same parameters

(CWT)<sup>[24]</sup>提取。为减少运算量,对轮廓特征保留了所有的采样点,对频谱和时频谱仅保留 0~5000 Hz 部分并均进行 10 倍的降采样。5 种模型使用的卷积算子数

目和卷积核尺寸相同,差异仅在于特征提取的方法和对象,如表 1 所示,若无特殊标注,特征提取对象均为原始信号。

表 1 各分类器的具体组成部分  
Table 1 Specific components of each classifier

Model type	Contour attribute	Frequency attribute	Time-frequency attribute
Model 1	IMF <sub>2</sub> and IMF <sub>3</sub>	FFT (IMF <sub>2</sub> -IMF <sub>5</sub> )	STFT (IMF <sub>2</sub> and IMF <sub>3</sub> )
Model 2	IMF <sub>2</sub> and IMF <sub>3</sub>	FFT	STFT
Model 3	Original signal	FFT	STFT
Model 4	Original signal	Hilbert marginal spectrum	Hilbert spectrum
Model 5	Original signal	DWT	CWT

## 4 模型训练与评估

基于 TensorFlow2.5 和 Python3.9 搭建了表 1 中的 5 种分类器。训练 100 轮,优化器选择 Adam,输入层激活函数选择 ReLU,输出层激活函数选择

Softmax,损失函数选择 Categorical\_crossentropy。评价指标包括训练集的准确率和损失函数、测试集的准确率和损失函数,如图 7 所示。表 2 中统计了每种分类方案的最佳准确率、平均响应时间,以及测试集准确率相对于训练集准确率的浮动程度。




图 7 模型 1 的训练过程。(a) train\_accuracy; (b) test\_accuracy; (c) train\_loss; (d) test\_loss

Fig. 7 Training process of Model 1. (a) train\_accuracy; (b) test\_accuracy; (c) train\_loss; (d) test\_loss

表 2 各分类器训练与评估结果

Table 2 Training and evaluation results of each classifier

Model type	Train accuracy /%	Test accuracy /%	Floating degree /%	Average response time /ms
Model 1	98.74	97.02	-1.74	67.29
Model 2	97.94	94.02	-4.00	62.14
Model 3	97.94	92.09	-5.97	25.16
Model 4	98.61	90.89	-7.83	118.24
Model 5	97.20	91.13	-6.24	281.59

如表 2 所示,尽管 5 种模型的训练集准确率都达到了较高的水平,但是模型 3、4、5 的测试集准确率明显低于模型 1、2。模型 3、4、5 的测试集准确率表明,就本文框架而言,在特征提取有效性方面,FFT-STFT 是最佳方案,在这一框架下,使用 IMF<sub>2</sub> 和 IMF<sub>3</sub> 提取轮廓

特征的模型 2 的表现优于使用原始信号的模型 3。在模型 2 的基础上,模型 1 改用 IMF<sub>2</sub> 和 IMF<sub>3</sub> 的时频谱以及 IMF<sub>2</sub>~IMF<sub>5</sub> 的频谱,进一步提升了识别性能。

训练集准确率通常反映的是模型理论上限,表 1 中 5 种分类器都有效提取了信号的主要特征,通过多

轮迭代都能达到接近 100% 的准确率。测试集不参与模型训练,因此一定程度可以反映模型的泛化性与可靠性。优秀的分类器应同时具备较高的训练集准确率与测试集准确率,表 2 中还统计了测试集准确率相对于训练集准确率的变化程度  $\omega$ 。

对于某一测试集指标  $d_{\text{test}}$ ,其相对于训练集指标  $d_{\text{train}}$  的浮动程度  $\omega$  为

$$\omega = \frac{d_{\text{test}} - d_{\text{train}}}{d_{\text{train}}} \times 100\%, \quad (1)$$

该参数一定程度上可以评估分类器的泛化性,对于泛化性差的模型,其测试集准确率会明显低于训练集准确率。显然模型 1 保持了最佳的稳定性。由于包含大量的卷积运算和频域变换,并且需要对信号进行 EMD 预处理,模型 1 和模型 2 的平均响应时间相比模型 3 存在滞后,但相比模型 4 和模型 5 依旧存在显著的优势。需要指出,由于模型 4 和模型 5 的分解复杂度高于模型 3,因此必然会导致响应时间的增加。本文中所有的神经网络和数据分解均使用 Python3.9 第三方库完成,所用计算机硬件主要配置为 16G 运行内存,CPU 主频

为 2.5 GHz,未配置专门的运算显卡,实际各模型的响应时间会受硬件配置和数据处理程序的影响。

测试集与训练集之间通常具备较高的相似度,因此模型的可靠性还需要通过验证集进行进一步证明。表 3 中统计了各识别器对验证集的平均准确率( $A$ )、精确率( $P$ )、召回率( $R$ )、F1\_score( $F$ )。各指标的计算公式分别为

$$A = \frac{\sum_{i=1}^m N_{\text{TP}_i}}{n}, \quad (2)$$

$$P = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}}, \quad (3)$$

$$R = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}}, \quad (4)$$

$$F = \frac{2 \cdot P \cdot R}{P + R}, \quad (5)$$

式中:对于某一事件  $L$ ,  $N_{\text{TP}}$  表示将其正确识别的部分,  $N_{\text{FP}}$  表示将其他类识别为  $L$  的部分,  $N_{\text{FN}}$  表示将  $L$  识别为其他类别的部分;  $m$  表示事件分类数;  $n$  为总样本数。

表 3 各模型的验证集评价指标

Table 3 Evaluation indexes of each model on validation set

Parameter	Model 1	Model 2	Model 3	Model 4	Model 5
test_accuracy / %	97.02	94.02	92.09	90.89	91.13
val_accuracy / %	94.88	88.32	87.47	87.92	85.41
val_precision / %	95.50	90.17	86.58	87.51	86.67
val_recall / %	92.83	86.17	77.67	87.00	84.16
val_F1_score / %	94.15	88.12	81.84	87.25	85.40

由于验证集与用于模型训练的测试集的相似度较低,因此各模型的验证集准确率均相比测试集准确率有所下降。只有模型 1 的验证集准确率依旧超过了 90%,保持在相对稳定的状态。精确率、召回率、F1\_score 表征对具体事件的分类精度,模型 1 的三种指标均超过 90%,优于其他分类器。进一步比较各分类器对各具体事件的识别效果,结果如图 8 和图 9 所示。图 8 中模型 1 的整体精确率处于最佳状态,尤其在某些振动信号如事件 3、4、5 的识别中存在显著的优势。模型 1 相对于其他分类器的精确率提升程度如表 4 所示。图 9 中,召回率的比较与精确率整体上保持了一致的趋势。类似地,模型 1 相对于其他分类器的召回率提升程度如表 5 所示。对于某一参数  $d_{\text{Model}1}$ ,其

相对于其他分类器  $d_{\text{Model}i}$  的提升程度  $\omega_{\text{up}}$  的表达式为

$$\omega_{\text{up}} = \frac{d_{\text{Model}1} - d_{\text{Model}i}}{d_{\text{Model}i}} \times 100\%, \quad (6)$$

若  $\omega_{\text{up}}$  为正,表明模型 1 的该指标更佳,若  $\omega_{\text{up}}$  为负,则表明其他模型的该指标更佳。模型 1 的综合评价指标明显优于模型 3、4、5,但这并不意味着模型 1 是没有缺点的。表 5 中,模型 1 的部分噪声召回率低于其他分类器,这主要是因为模型 1 的框架主要是基于振动信号在 IMF 分量上的特征脉冲和其频谱呈现的形态学特征。环境噪声中如风、流水等环境也可能导致图 4 中类似的波形特征。相比之下,以原始信号为样本的模型 3、4、5 对噪声的召回率超过 95%。

但是就威胁事件的识别来说,模型 1 显然出色地

表 4 模型 1 相比其他分类器精确率的提升程度

Table 4 Degree of precision improvement of Model 1 compared with other classifiers

unit: %

Model type	Event 1	Event 2	Event 3	Event 4	Event 5	Event 6
2	-1.02	-1.01	13.09	17.95	10.47	0
3	4.30	0	58.33	9.52	6.74	1.05
4	3.19	5.38	11.76	15.06	20.25	2.13
5	2.10	2.08	23.38	6.98	18.75	11.63

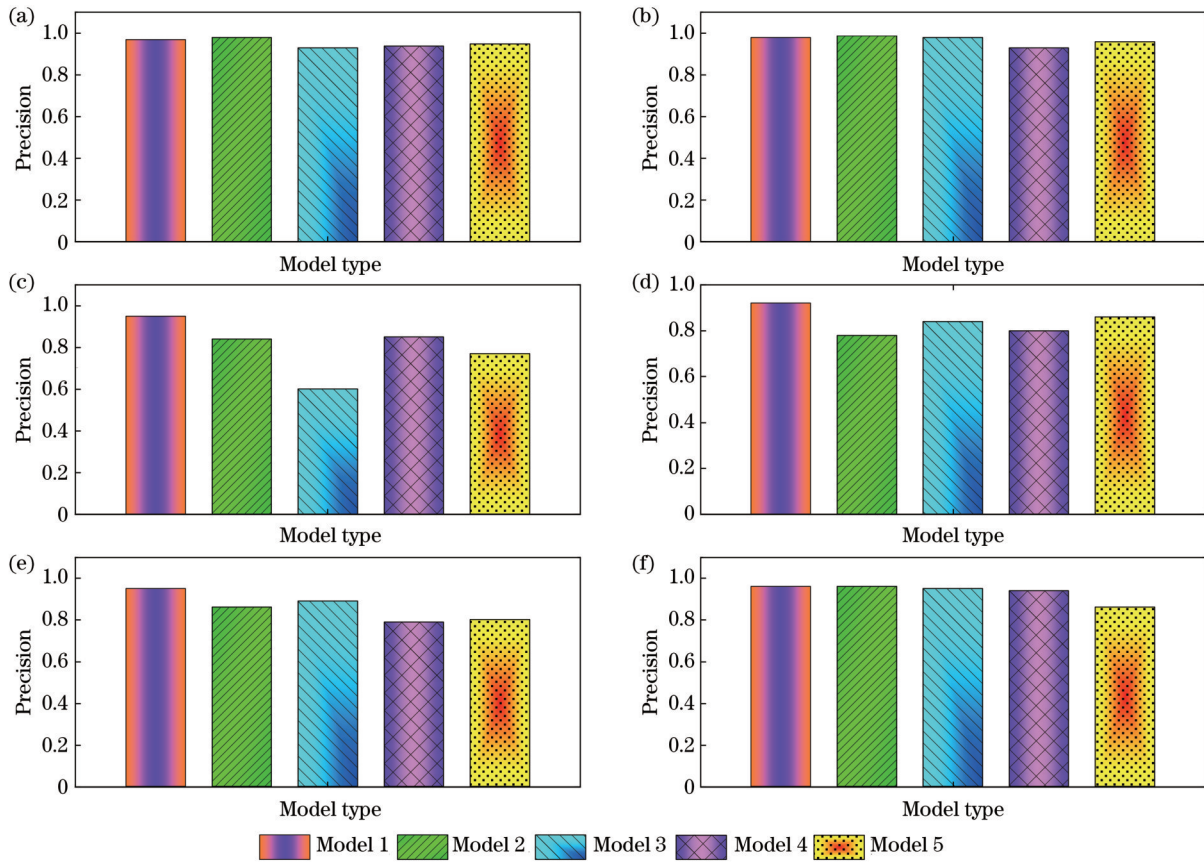


图 8 各分类器的验证集精确率。(a)~(f)事件 1~事件 6  
 Fig. 8 Validation precision of each classifier. (a)-(f) Event 1-event 6

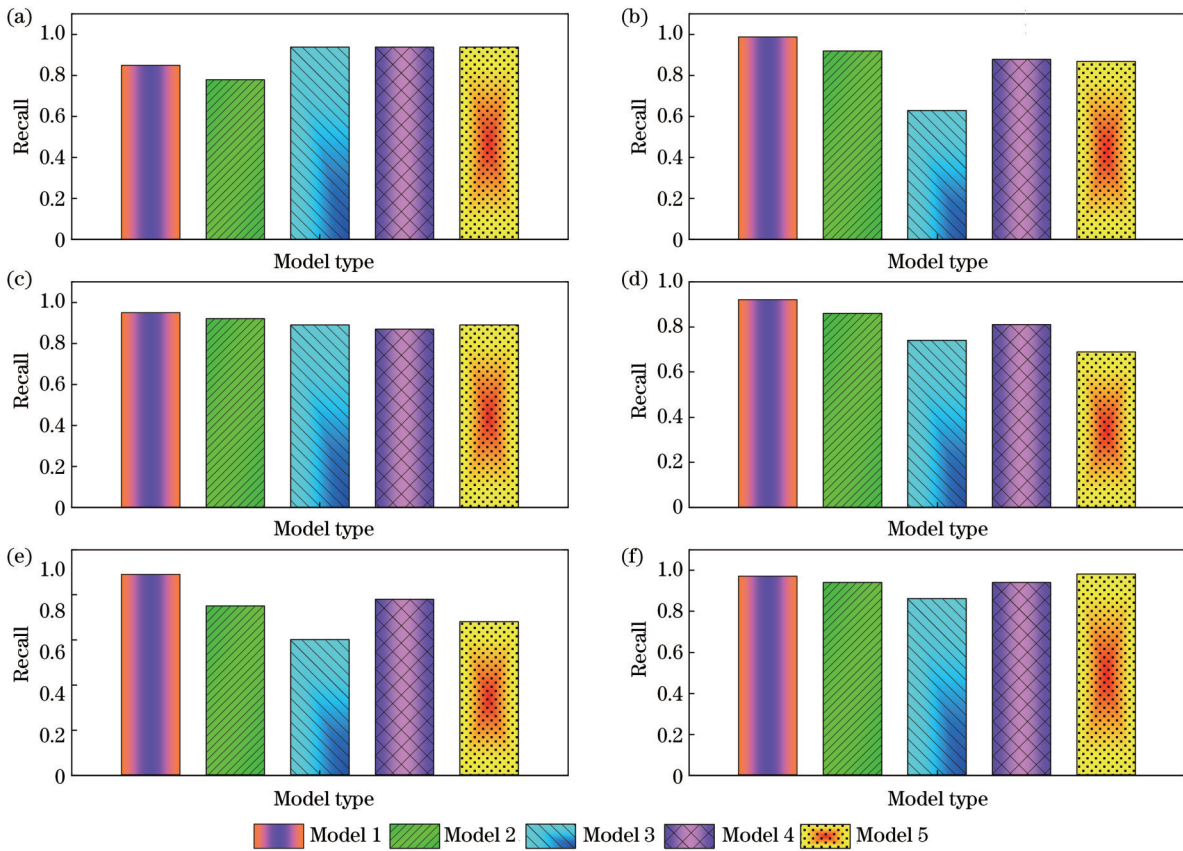


图 9 各分类器的验证集召回率。(a)~(f)事件 1~事件 6  
 Fig. 9 Validation recall of each classifier. (a)-(f) Event 1-event 6



表 5 模型 1 相比其他分类器召回率的提升程度

Table 5 Degree of recall improvement of Model 1 compared with other classifiers

units %

Model type	Event 1	Event 2	Event 3	Event 4	Event 5	Event 6
2	8.97	7.61	3.26	6.98	18.67	3.19
3	-9.57	57.14	6.74	24.32	48.33	12.79
4	-9.57	12.52	9.22	13.58	14.10	3.19
5	-9.57	13.79	6.74	33.33	30.88	-1.02

完成了既定目标。针对模型 1 在噪声识别中的不足,一方面可以通过进一步的参数调优或新的特征提取方式的补充进行改善。另一方面,机器学习算法在噪声与振动的二分类识别中已存在大量成功案例,SVM、Random Forest 等算法的响应时间都在 ms 级,可以将它们作为神经网络的前端预分类机制,从而充分发挥模型 1 在振动事件多分类问题中的优点。

## 5 结 论

以马赫-曾德尔干涉仪为传感系统,提出了基于 EMD 和卷积算子的分类器模型 1。选择了 IMF<sub>2</sub> 和 IMF<sub>3</sub> 代替原始信号用以提取轮廓特征和时频域特征,并选择 IMF<sub>2</sub>~IMF<sub>5</sub> 提取频谱特征。基于相同的特征提取框架,构造了以原始信号为输入的 4 个对照组。模型 1 的测试集准确率和验证集准确率为 97.02% 和 94.88%,其余对照组的验证集准确率均低于 90%。模型 1 对 5 种振动事件的平均验证集精确率和召回率为 95.51% 和 94.42%,尤其是对事件 4 和事件 6 两种弱振动信号,模型 1 的识别精度均超过其他对照组,充分证明本方案在泛化性和振动识别方面的优化效果。尽管模型 1 在噪声的识别中存在一定程度的不足,但是其对威胁性入侵的精准识别仍具备良好的可行性与发展空间。

本文从样本来源的角度优化了传统的深度学习网络,但并没有改变常规的特征提取方式,在后续的发展中还需要进一步增加特征提取维度,从而改善现有分类器的不足。同时文中 IMF 分量的选择及 EMD 层数的选取是基于目标信号特征和大批量样本的统计结果的,在实际应用中可以根据需要进行选择。

## 参 考 文 献

- [1] Kandamali D F, Cao X M, Tian M L, et al. Machine learning methods for identification and classification of events in  $\phi$ -OTDR systems: a review[J]. Applied Optics, 2022, 61(11): 2975-2997.
- [2] Sha Z, Feng H, Rui X B, et al. PIG tracking utilizing fiber optic distributed vibration sensor and YOLO[J]. Journal of Lightwave Technology, 2021, 39(13): 4535-4541.
- [3] Li J F, Feng H, Zhuang X S. Convolutional neural networks for spherical signal processing via area-regular spherical Haar tight framelets[J/OL]. IEEE Transactions on Neural Networks and Learning Systems: 1-11[2023-02-11]. <https://ieeexplore.ieee.org/document/9744330>.
- [4] Fan L M, Hu H, Zhang X J, et al. Magnetic anomaly detection using one-dimensional convolutional neural network with multi-

feature fusion[J]. IEEE Sensors Journal, 2022, 22(12): 11637-11643.

- [5] Pan Y N, Wen T K, Ye W. Time attention analysis method for vibration pattern recognition of distributed optic fiber sensor[J]. Optik, 2022, 251: 168127.
- [6] Sun Z S, Liu K, Jiang J F, et al. Optical fiber distributed vibration sensing using grayscale image and multi-class deep learning framework for multi-event recognition[J]. IEEE Sensors Journal, 2021, 21(17): 19112-19120.
- [7] Lai X, Yu H D, Ma Y X, et al. Disturbance location and pattern recognition of a distributed optical fiber sensor based on dual-Michelson interferometers[J]. Applied Optics, 2022, 61(1): 241-248.
- [8] Shi Y, Li Y H, Zhang Y C, et al. An easy access method for event recognition of  $\Phi$ -OTDR sensing system based on transfer learning[J]. Journal of Lightwave Technology, 2021, 39(13): 4548-4555.
- [9] Ma X R, Mo J Q, Zhang J W, et al. Optical fiber vibration signal recognition based on the fusion of multi-scale features[J]. Sensors, 2022, 22(16): 6012.
- [10] Wang Q, Zhang Y, Chen G N, et al. Assessment of heart rate and respiratory rate for perioperative infants based on ELC model [J]. IEEE Sensors Journal, 2021, 21(12): 13685-13694.
- [11] Song Z W, Xiang S Y, Zhao S T, et al. A hybrid-integrated photonic spiking neural network framework based on an MZI array and VCSELs-SA[J]. IEEE Journal of Selected Topics in Quantum Electronics, 2023, 29(2): 8300211.
- [12] Meerasha M A, Ganesh M, Pandiyan K. Reconfigurable quantum photonic convolutional neural network layer utilizing photonic gate and teleportation mechanism[J]. Optical and Quantum Electronics, 2022, 54(11): 770.
- [13] Wang M, Feng H, Qi D Z, et al.  $\varphi$ -OTDR pattern recognition based on CNN-LSTM[J]. Optik, 2023, 272: 170380.
- [14] Liu K L, Shang Y L, Ouyang Q, et al. A data-driven approach with uncertainty quantification for predicting future capacities and remaining useful life of lithium-ion battery[J]. IEEE Transactions on Industrial Electronics, 2020, 68(4): 3170-3180.
- [15] Liu M D, Ding L, Bai Y L. Application of hybrid model based on empirical mode decomposition, novel recurrent neural networks and the ARIMA to wind speed prediction[J]. Energy Conversion and Management, 2021, 233: 113917.
- [16] Rezaei H, Faaljou H, Mansourfar G. Stock price prediction using deep learning and frequency decomposition[J]. Expert Systems With Applications, 2021, 169: 114332.
- [17] Ge S G, Rum S N B M, Ibrahim H, et al. An effective source number enumeration approach based on SEMD[J]. IEEE Access, 2022, 10: 96066-96078.
- [18] Feng H, Wang M, Sha Z, et al. Research on weak vibration characteristics based on EMD and design of MZI classifier[J/OL]. Journal of Lightwave Technology: 1-10[2023-03-02]. <https://ieeexplore.ieee.org/document/10038540>.
- [19] 陈小威, 朱文越, 钱仙妹, 等. 基于人工神经网络的近地面光学湍流估算[J]. 光学学报, 2020, 40(24): 2401002.  
Chen X W, Zhu W Y, Qian X M, et al. Estimation of surface layer optical turbulence using artificial neural network[J]. Acta Optica Sinica, 2020, 40(24): 2401002.

- [20] 南敬昌, 杜有益, 王明寰, 等. 深度学习架构神经网络对超宽带天线建模优化[J]. 激光与光电子学进展, 2022, 59(13): 1323001.  
Nan J C, Du Y Y, Wang M H, et al. Modeling optimization of ultra-wideband antenna based on deep learning architecture neural network[J]. Laser & Optoelectronics Progress, 2022, 59(13): 1323001.
- [21] Mao W T, He J L, Zuo M J. Predicting remaining useful life of rolling bearings based on deep feature representation and transfer learning[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1594-1608.
- [22] Zou Y Y, Zhang Y D, Mao H C. Fault diagnosis on the bearing of traction motor in high-speed trains based on deep learning[J]. Alexandria Engineering Journal, 2021, 60(1): 1209-1219.
- [23] Houssein E H, Hassaballah M, Ibrahim I E, et al. An automatic arrhythmia classification model based on improved Marine Predators Algorithm and Convolutions Neural Networks[J]. Expert Systems With Applications, 2022, 187: 115936.
- [24] 赵海龙, 甘淑, 袁希平, 等. 基于多尺度连续小波分解的土壤氧化铁反演[J]. 光学学报, 2022, 42(22): 2230002.  
Zhao H L, Gan S, Yuan X P, et al. Inversion of soil iron oxide based on multi-scale continuous wavelet decomposition[J]. Acta Optica Sinica, 2022, 42(22): 2230002.

## Optimization of Mach-Zehnder Interferometer Event Recognition Scheme Based on Empirical Mode Decomposition

Wang Ming<sup>1</sup>, Feng Hao<sup>1</sup>, Sha Zhou<sup>1\*</sup>, Zhao Li<sup>2</sup>

<sup>1</sup>State Key Laboratory of Precision Measuring Technology and Instruments, School of Precision Instrument and Opto-Electronics Engineering, Tianjin University, Tianjin 300072, China;

<sup>2</sup>Shandong Longquan Pipeline Engineering Co., Ltd., Zibo 255200, Shandong, China

### Abstract

**Objective** Threat event recognition is one of the widely researched topics in distributed fiber optic sensing. Deep learning is an important means for pattern recognition. The main challenges that limit its recognition accuracy can be categorized into two aspects: lack of generalization and existence of false recognition for some signals with low vibration intensity and obscure features. On one hand, this is due to ambiguous features, such that the target signal is often obscured in noise, and on the other hand, such signals are easily mislabeled in the process of constructing data sets. The classification accuracy of neural networks can be improved in three ways. The first approach is to preprocess the data from the front end of the network by applying various methods, such as band-pass filtering, wavelet denoising, and Hilbert transform. However, these methods have relatively limited positive effects and will contribute to the loss of detailed information to some extent. The second approach is to increase the extraction of features from training samples, such as inputting multiple features of the signal into the network simultaneously to improve the recognition accuracy through feature fusion. The third approach is to increase the means of feature extraction through various methodologies, such as increasing the number of convolutional layers, introducing recurrent neural networks (RNNs), and supplementing deep belief networks. The design of specific schemes should consider the data characteristics of the sensing system. In this study, the sampling rate and sampling points of the Mach-Zehnder interferometer (MZI) are 50 times greater than those of the phase-sensitive optical time-domain reflectometer. Thus, the third approach will substantially increase the computations and response time. In this paper, we attempted to implement the enhancement of vibration features from the perspective of signal sources for improving the recognition accuracy of weak vibration events under the traditional network framework.

**Methods** The proposed recognition program employs the conventional waveform, frequency spectrum, and time-frequency spectrum feature extraction method; further, RNNs are not introduced in this method to avoid excessive computations. We optimized the conventional recognition strategy from the perspective of sample sources. We used empirical mode decomposition (EMD) to decompose the signal into multiple intrinsic mode functions (IMFs). The target signal exhibits clearer vibration features on certain IMFs. Specifically, the vibration part shows sharp pulses separated from the fundamental noise that exhibit higher contrast than the response pulses at the same location of the original waveform (Fig. 4). Furthermore, the frequency spectrum of the IMF shows distinct morphological features with suitable same-class consistency and inter-class differentiation (Fig. 5). These features are independent of the signal strength, which provides a feasible premise for the effective identification of weak vibration events. Based on the statistics of a large number of samples, IMF<sub>2</sub> and IMF<sub>3</sub> are selected to extract their waveform features and time-frequency spectrum features and for IMF<sub>2</sub>-IMF<sub>5</sub> to extract their frequency features. The neural network consists of convolutional operators and fully connected networks. The waveform and frequency features are extracted using one-dimensional convolutional operators,

while the time-spectrum features are extracted using two-dimensional convolutional operators (Fig. 6). In addition, based on the same feature extraction framework, four control groups were designed with the original signal as the sample source (Table 1).

**Results and Discussions** By comparing val\_accuracy, val\_precision, val\_recall, and other parameters (Fig. 8, Fig. 9, Table 2, Table 3, Table 4, and Table 5), the proposed model was found to be the best in terms of recognition accuracy, stability, and generalization. Although all the models exhibited high accuracy when using the training set, the metrics in the test and validation sets showed a significant decrease compared with the training set. Only the validation accuracy of Model 1 (our strategy) exceeded 90%, which remained relatively stable. The classification accuracy of the model for specific events can be characterized using precision, recall, and F1\_score; all three parameters are greater than 90% in Model 1. The average response time of the proposed model is less than 0.07 s, indicating good feasibility and development space.

**Conclusions** In this paper, we have proposed a classifier Model 1 based on EMD and convolution operators using the Mach-Zehnder interferometer (MZI) as the sensing system. Instead of the original signal,  $IMF_2$  and  $IMF_3$  were selected to extract contour features and time-frequency domain features, and  $IMF_2$ - $IMF_5$  were selected to extract the frequency spectral features. Four control groups were developed based on the same feature extraction framework with the original signal as input. The test\_accuracy and val\_accuracy of Model 1 are 97.02% and 94.88%, respectively, while the val\_accuracy of the remaining control groups is less than 90%. The average val\_precision and val\_recall of Model 1 for the five vibration events are 95.51% and 94.42%, respectively. In particular, for two weak vibrations, Event 4 and Event 6, the recognition accuracy of Model 1 exceeded those of other control groups, thereby fully demonstrating the optimization of this scheme in terms of generalization and vibration recognition. This paper improves the conventional deep learning network from the perspective of sample sources; however, it does not change the conventional feature extraction, and further extension of the feature extraction dimension is required in the subsequent development stage to address the shortcomings of the existing classifier. In addition, the selection of IMF components in this study is based on the target signal features and the statistical results of large batch samples, and the selection in practical applications need not be limited to this paper.

**Key words** deep learning; empirical mode decomposition; Mach-Zehnder interferometer; intrinsic mode function; event recognition