

DOI:10.19651/j.cnki.emt.2209444

# 基于改进 CEEMD 和多域特征融合的 1D-CNN 降雹量级识别算法<sup>\*</sup>

李 鹏<sup>1,2,3</sup> 杨山山<sup>1,2</sup> 徐文校<sup>1,2</sup> 陈守静<sup>1,2</sup> 于心远<sup>1,2</sup> 徐永杰<sup>1,2</sup>(1. 南京信息工程大学江苏省气象探测与信息处理重点实验室 南京 210044;  
2. 南京信息工程大学江苏省大气环境与装备技术协同创新中心 南京 210044; 3. 无锡学院 无锡 214105)

**摘要:** 为便于分析冰雹对社会生产造成的灾害影响,需要对降雹量级进行分类统计,对降雹量级进行定量分析,不仅可以为灾害评估提供依据,还可以对气象预报、虚报现象做出反馈。本文针对降雹声信号提出了一种改进的互补集合经验模态分解(CEEMD)重构算法,重构后的信号最大程度地保持原有时域特征,也能对降雹声信号去噪处理。其次设计了一种多域特征融合 1D-CNN 模型,将重构后的原始数据、时域特征和频域特征分别作为 1D-CNN 的输入,在中间层进行特征拼接,最后输出分类器,结果显示本文设计的多域特征融合 1D-CNN 对降雹量级的识别率高达 99.58%,相比于原始数据与传统 1D-CNN 模型识别率提高了 8.75%。

**关键词:** 降雹量级;互补集合经验模态分解;特征提取;1D-CNN

中图分类号: TB52+9; P414.9+5 文献标识码: A 国家标准学科分类代码: 510.40

## Hail magnitude recognition algorithm based on improved CEEMD and 1D-CNN of multi-domain feature fusion

Li Peng<sup>1,2,3</sup> Yang Shanshan<sup>1,2</sup> Xu Wenxiao<sup>1,2</sup> Chen Shoujing<sup>1,2</sup> Yu Xinyuan<sup>1,2</sup> Xu Yongjie<sup>1,2</sup>(1. Jiangsu Key Laboratory of Meteorological Observation and Information Processing, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China;  
3. Wuxi University, Wuxi 214105, China)

**Abstract:** In order to facilitate the analysis of the disaster impact caused by hail on social production, it is necessary to make classified statistics on hail magnitude and quantitative analysis on hail magnitude, which can not only provide the basis for disaster assessment, but also give feedback to weather forecast and false report. In this paper, an improved complementary set empirical mode decomposition (CEEMD) reconstruction algorithm is proposed for hail sound signal. The reconstructed signal retains the original time domain characteristics to the greatest extent, and can also denoise hail sound signal. Secondly, a multi-domain feature fusion 1D-CNN model is designed. The reconstructed original data, time-domain features and frequency-domain features are used as the input of 1D-CNN, the features are spliced in the middle layer, and finally the classifier is output. The results show that the recognition rate of the multi-domain feature fusion 1D-CNN designed in this paper is as high as 99.58%, which is 8.75% higher than that of the original data and the traditional 1D-CNN model.

**Keywords:** hail magnitude; complementary empirical mode decomposition; feature extraction; 1D-CNN

## 0 引言

在全球变暖的大环境下,极端天气事件频频出现,降雹

为固态降水,一种常见的极端天气灾害,这是由强对流天气系统引起的恶劣天气灾害。冰雹的出现常伴有飓风、大暴雨和断崖式降温等突发性灾害天气现象。中国是冰雹多发

收稿日期:2022-03-29

\* 基金项目:江苏省重点研发计划社会发展项目(BE2015692)、江苏省第11届六大高峰人才项目(2014-XXRJ-006)、无锡市社会发展科技示范工程项目(N20191008)资助

地区,并且冰雹灾害分布广、离散性强。据 2021 年中国气象公报统计,我国总共发生了 47 次区域性强对流天气,全年风雹灾害对农业影响受灾面积高达 271.2 万公顷,死亡失踪人数 129 人,直接经济损失 268.7 亿元。

为有效地减轻降雹对社会生产的影响,大量研究学者通过对气象站冰雹观测资料进行研究,文献[1]基于随机森林算法(random forest, RF)建立了 0~6 h 之间的冰雹预报模型,但是还是存在 20% 的虚警率。在文献[2]中将深度学习方法与气象知识相结合,利用 S 波段多普勒天气雷达采集到的雷达反射率图与卷积神经网络(convolutional neural networks, CNN)来识别雹云。但是所用到的数据需要由气象局所提供,并不易获取。文献[3]分析了山西省北部大同市 2006~2011 年内的冰雹记录,该记录也是通过多普勒雷达获取的数据以及地面观测资料,很显然研究地面上观测到的冰雹过于消耗人力物力,并且冰雹落地时发生撞击,撞击后使得原始形状、大小发生改变,人为观测冰雹尺寸并统计数据必然会造成误差。文献[4]通过降雹声信号对冰雹进行识别,使用小波阈值去噪法后对信号进行特征提取,采用了基于马氏距离的模糊聚类算法对声信号进行识别,但对降雹的识别率仅有 93.3333%。文献[5]也是通过降雹的声信号进行研究,采用熵值法与广义回归神经网络相结合的方法,对降雹的识别率达到了 97.8276%,虽然对降雹有着较高的识别率,但是无法对降雹的量级进行判断识别。

综合上述文献,大多数方法都是基于雷达回波率和卫星云图<sup>[6]</sup>进行研究,仅能简单的预测出雹云,目前并无研究学者通过降雹声信号对降雹的量级进行研究,因此无法起到冰雹对农业致灾强度评估的作用。针对以上问题,为了能够有效地验证气象预报和卫星雷达等对冰雹预测情况,本文从声学的角度对降雹量级展开研究,提出了基于改进的互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)<sup>[7]</sup>和多域特征融合的 1D-CNN 降雹量级识别算法。先对降雹声信号进行 CEEMD 分解,判别各分量的噪声信号,并对其进行滤波处理,重构筛选后的分量,最后再提取信号的时域特征和频域特征,为下一步神经网络算法提供了潜在特征数据。降雹信号预处理后的原始数据、时域特征、频域特征分别作为模型的多通道输入,试验表明多域特征融合 1D-CNN 算法对不同降雹量级的识别率较高,并且提高了模型的泛化能力。

## 1 降雹声信号采集实验

### 1.1 拾音板设计

降雹现象常是由强对流天气引起,在夏季出现概率较大。本文主要研究的是降雹的量级强度,为了能够准确的判断出降雹量级的级别,从降雹声信号的角度进行研究。因此设计了一款冰雹拾音装置,如图 1 所示。使用支架分别从四边用 8 cm 的弹簧将直径为 42 cm 的铜锣勾紧,该装

置能够清晰的发出冰雹砸落在上面的声音,且与其他声音信号相比更为明显。



图 1 冰雹拾音装置

### 1.2 降雹声信号采集实验搭建

本文数据采集系统是由拾音板模块、声波传感器模块、Digilent Analog Discovery2 逻辑器信号采集卡和含有 Waveform 软件的计算机组成,如图 2 所示。将声波传感器固定于拾音装置下方,通过采集卡连接至电脑端,在 Waveform 软件中,设置单通道采样,采用 44.1 kHz 的采样频率分别对轻量级、中量级、重量级和特重量级的降雹声音信号进行采集。

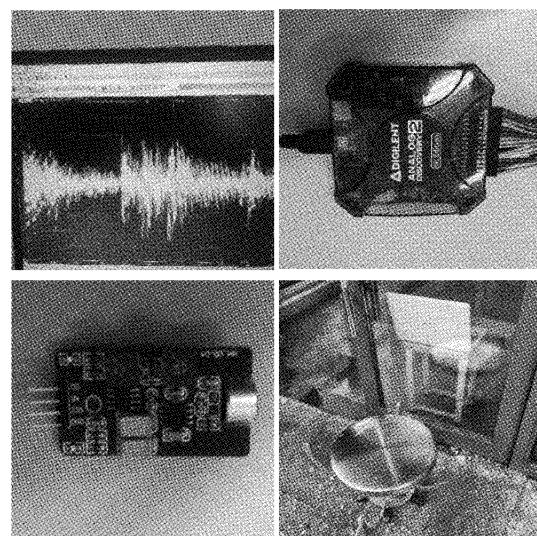


图 2 降雹声信号采集系统

其中冰雹量级划分如表 1 所示。

表 1 冰雹等级划分

| 等级   | 冰雹直径 D                                 |
|------|--|
| 轻量级  | $D < 5 \text{ mm}$                     |
| 中量级  | $5 \text{ mm} \leq D < 20 \text{ mm}$  |
| 重量级  | $20 \text{ mm} \leq D < 50 \text{ mm}$ |
| 特重量级 | $D \geq 50 \text{ mm}$                 |

## 2 研究方法

### 2.1 CEEMD 原理

经验模态分解 (empirical mode decomposition, EMD)<sup>[8]</sup> 广泛运用于非线性、非稳态信号中, EMD 算法可将信号分解为本征模态函数 (IMF) 和残余分量 (residual component, Res)。通过不断的迭代计算原信号  $x(t)$  的局部极大值和局部极小值点, 利用三次样条插值函数对其拟合, 得出上下两种包络。然后再对这两种包络求平均得出平均值函数  $m_{i,j}(t)$ , 其中  $i$  代表第  $i$  个 IMF 分量,  $j$  表示第  $i$  个 IMF 分量的第  $j$  次迭代。将原信号  $x(t)$  减去所有计算所得的 IMF 分量即可得到残余分量 (Res)。不过 EMD 算法从原信号中分离出不同频带的信号容易出现模态混叠现象, 为了减小模态混叠现象, EEMD 算法通过在原始信号  $x(t)$  中加入等长度且具有正态分布的高斯白噪声  $n_i(t)$ , 然后对混合信号  $x(t) + n_i(t)$  进行 EMD 算法分解。这种方法虽然能够有效地抑制模态混叠现象, 但是加入高斯白噪声的同时会使得 EEMD 算法分解出的 IMF 分量残留一部分白噪声。为了能够解决 EEMD 算法分量的混叠现象和重构信号的误差问题。本文使用 CEEMD 算法对信号进行分解。

CEEMD 算法的分解流程如图 3 所示, 实现步骤<sup>[9]</sup>如下:

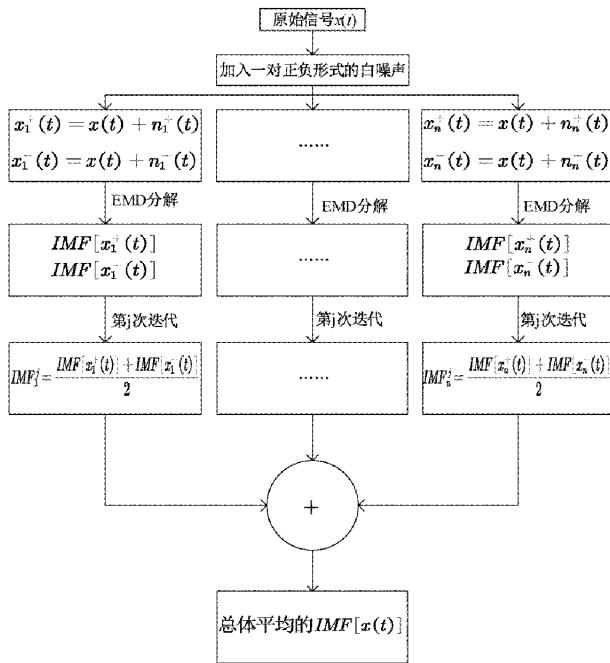


图 3 CEEMD 算法流程图

1) 将一对正负形式的白噪声  $\pm n_m, m = 1, 2, \dots, n$ , 加入到待分解信号  $x(t)$  得出混合高斯白噪声的信号  $x_m^{\pm}(t)$ :

$$x_m^{\pm}(t) = x(t) + n_m^{\pm}(t) \quad (1)$$

$$x_m(t) = x(t) + n_m(t) \quad (2)$$

2) 分别对  $x_m^+(t)$  和  $x_m^-(t)$  时间序列信号进行 EMD 分解, 得出一系列的本征模态函数  $IMF[x_m^-(t)]$  和  $IMF[x_m^+(t)]$ 。

3) 重复步骤 1) 和 2), 分别得出  $m$  个 IMF 分量  $IMF[x_m^+(t)]$  和  $IMF[x_m^-(t)]$ 。

4) 对加入  $m$  对白噪声的  $x_m^{\pm}(t)$  信号求  $IMF[x_m^{\pm}(t)]$  和  $IMF[x_m^{\pm}(t)]$  平均得到  $IMF_m^j$ , 即:

$$IMF_m^j = \frac{IMF[x_m^+(t) + x_m^-(t)]}{2}, m = 1, 2, \dots, n \quad (3)$$

5) 计算出集总平均:

$$IMF = \frac{1}{n} \sum_{m=1}^n IMF_m^j \quad (4)$$

其中,  $j$  表示每次加白噪声的第  $j$  次迭代。

6) 经 CEEMD 运算后, 原始信号为:

$$x(t) = IMF_1 + IMF_2 + \dots + IMF_m + Res_m \quad (5)$$

### 2.2 1D-CNN 基本原理

卷积神经网络是深度学习中具有代表性的深度神经网络, 文献[10]结合信号处理知识与深度学习的方法实现了对故障信号更高的识别精度。早期用来识别手写数字图像的卷积神经网络——LeNet<sup>[11]</sup>第一次将卷积神经网络推上了人工智能时代的舞台, 在之后不断出现了一系列经典网络结构模型: Alex Net 网络<sup>[12]</sup>、VGG 网络<sup>[13]</sup>、Google-Net 网络<sup>[14]</sup>以及 ResNet 网络<sup>[15]</sup>等, 其运用在图像处理<sup>[16]</sup>和目标检测<sup>[17]</sup>等方面成果显著。卷积神经网络的基本结构都是由特征提取器和分类器构成, 特征提取器是由卷积层和池化层组成。卷积层能够有效的提取信号的特征, 不同的卷积核能够提取出不同的特征, 第  $n$  个卷积核提取的特征  $x_j^l$  计算原理如式(6):

$$x_j^l = activation(\sum_{i \in M_j} x_j^{l-1} * \omega_{ij}^l + b_j^l) \quad (6)$$

式(6)中  $x_j^l$  为第  $l$  层的第  $j$  个特征, 即第  $l$  层的输出,  $x_j^{l-1}$  为第  $l-1$  层的输出, 即第  $l$  层的输入, 每一层的输出作为下一层的输入,  $\omega_{ij}^l$  为卷积核,  $M_j$  为卷积核与信号计算时覆盖的区域,  $b_j^l$  为偏置。 $activation(\cdot)$  为激活函数, 用于增强特征的非线性表达潜能, 使得神经网络更容易应用于更多的非线性模型。本文使用的是整流线性单元 (ReLU 激活函数), 该单元是卷积神经网络中的一个重要的结构单元, 计算速度快且使模型更易于优化, 其定义如式(7):

$$f_{ReLU}(x) = \max(0, x) \quad (7)$$

池化层相当于特征压缩器, 能够将卷积后的特征进行压缩, 并且还能保持住原有特征, 有效的减少训练参数, 使得训练模型速度更快。池化函数可以表示为式(8):

$$x_j^l = pool(x_j^{l-1}) \quad (8)$$

$x_j^{l-1}$  表示池化的输入特征,  $x_j^l$  表示池化的输出特征。池化层分为平均池化 (average pooling)、最大池化 (max pooling) 和全局最大池化 (global max pooling, GMP), 本文中采用的是最大池化和全局最大池化。最大池化提取局

部特征的最大值, GMP 在实现减少网络参数的同时还可以实现降维, 过程函数为:

$$X_i^l(j) = \max_{(j-1)W-1 \leq t \leq jW} \{X_i^{l-1}(t)\} \quad (9)$$

式中:  $X_i^{l-1}(t)$  表示第  $l-1$  层第  $i$  个特征向量中第  $t$  个神经元的值,  $W$  为池化宽度,  $X_i^l(t)$  为第  $l$  层神经元对应的值, 通常最后一个池化层的输出打平后作为全连接层的输入。全连接层即分类器层, 通常采用 2~4 层的全连接前馈神经网络, 最后用 Softmax 分类器解决多分类问题。因为神经网络的输出不是一个概率值, 实质是输入的信号做了复杂的加权和非线性处理之后的一个值, Softmax 分类器可将这些值的输出变为概率分布, 函数形式为:

$$\text{softmax}(z)_i = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (10)$$

1D-CNN 与 2D-CNN 基本组成结构类似, 常应用于时间序列信号的研究, 在轴承故障诊断<sup>[18]</sup>效果突出。与 2D-CNN 不同的是 1D-CNN 中的卷积核是一个向量, 而不是矩阵, 网络的输入也是一维数据, 一维卷积运算是通过固定步长滑动卷积核来对一维输入向量进行卷积。1D-CNN 基本结构如图 4 所示, 卷积块由卷积层和池化层组成, 是降雹信号特征提取的关键, 特征经若干隐藏层后, 再由全连接层进行整合每个特征通道传出的特征。

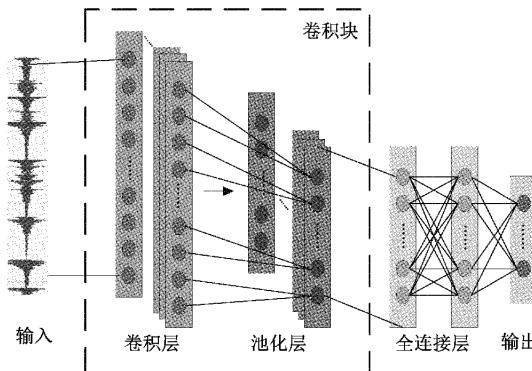


图 4 一维卷积神经网络基本结构

### 3 数据预处理

#### 3.1 数据增强

降雹原始信号是一维时间序列数据, 为了增加更多的样本数量, 本文采用数据增强的方法对降雹原始数据进行重叠采样, 重叠率设置为 50%, 来增加样本数量。假设原始降雹信号的长度为  $N$ , 单个样本的长度为  $n$ , 则单个原始样本最大可扩充样本数量的个数为:  $d = \left\lfloor \frac{2(N-n)}{n} \right\rfloor$ ,

其中  $\lfloor \cdot \rfloor$  为向下取整运算符, 如图 5 所示为数据增强示意图。重叠采样的优点是不仅最大限度地维持降雹信号原有特征, 而且提高了训练样本的数量, 增加了模型的鲁棒性。

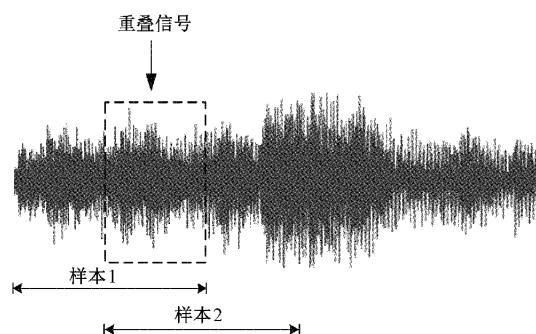


图 5 数据增强示意图

#### 3.2 改进 CEEMD 重构

降雹声信号是非线性、非稳态信号。在采集信号的同时往往会被恶劣天气的环境噪音所影响, 为了将其特征更加明显化, 本文采用 CEEMD 算法, 先将采集到的降雹声信号进行分解。本文对信号进行 13 层分解, 噪声标准差设为 0.02, 总平均次数设为 100, 得出 12 个 IMF 分量和 1 个 Res 分量, 如图 6 所示为各分量的时域图。如图 7 所示为各分量的半谱图。

其中 IMF1 的时域特征较为明显, 能够清晰的表达出降雹击中点所发生的信号。但其频域中有的高频干扰现象较为严重, 若直接剔除该分量, 则在时域中就会缺失一些原有特征。因此设计了一个截至频率为 5 500 Hz, 阻带衰减设置为 45 dB, 陡度 0.85 的低通滤波器, 将 IMF1 的高频信号进行滤除。这样既能够保持时域的原有信息, 也能将高频干扰滤除如图 8 所示, 为重构前后的时域频域对比图。残余分量(Res)为最低频分量, 且幅值整体向上偏移, 因此在本文中属于误差信号, 需要将此信号剔除。重构信号最终为:

$$x(t) = \sum_{i=1}^{12} \text{IMF}(i) \quad (11)$$

重构前后的时域频域对比图, 如图 8 所示, 相比于重构前的时域信号的毛刺明显地得到了抑制, 并且时域的高频噪声也得到了有效抑制。降雹信号的频率主要分布在 1 400 Hz 左右的频段。

#### 3.3 特征提取

原始数据集被划分为 40 960 个数据点的信号, 对每个信号提取 12 种时域特征和 13 种频域特征, 总计 25 种特征参数, 如表 2 和 3 所示。当有降雹信号时, 时域信号会发生突变, 但是不同量级的冰雹在时域上的振幅和分布会不同。与此同时, 不同降雹量级信号的频谱分布也会有所差异。参数  $F_1 \sim F_3$  和  $F_6$  反应了降雹信号时域的振幅和能量, 参数  $F_4 \sim F_5$  和  $F_7 \sim F_{12}$  反映了降雹信号的时序分布情况。参数  $P_1$  表示降雹信号在频域的能量, 参数  $P_2 \sim P_4, P_6$  和  $P_9 \sim P_{12}$  可以描述功率谱的收敛性,  $P_5$  和  $P_7 \sim P_9$  能够反应出不同量级的降雹信号频域中的主要频率位置变化情况。

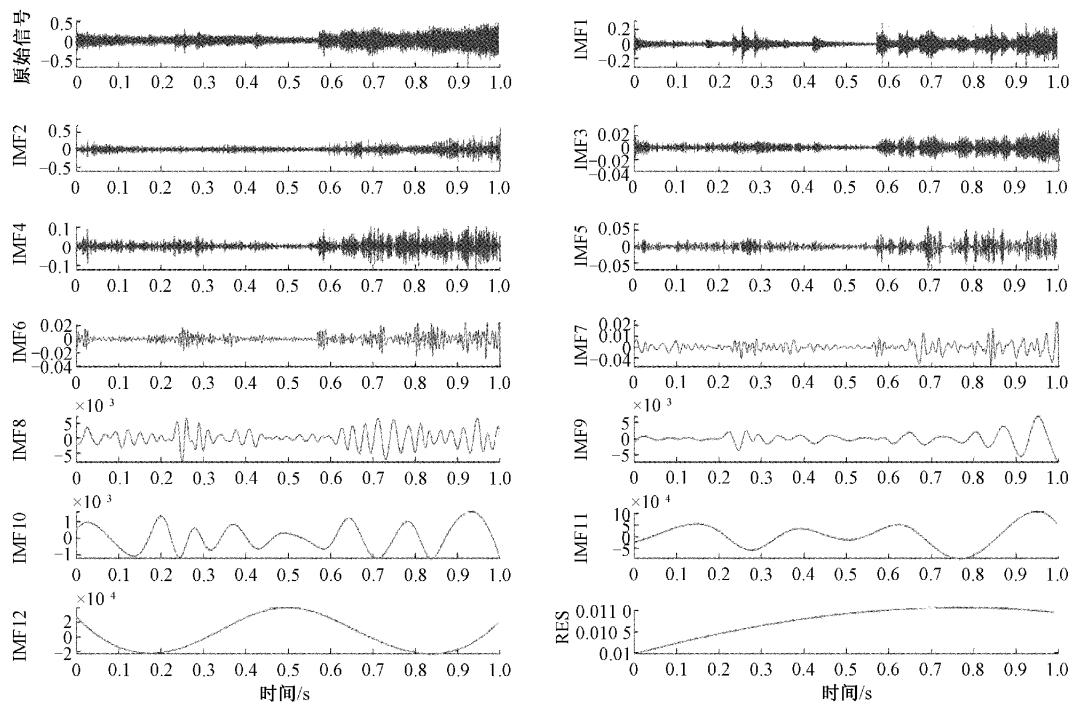


图 6 CEEMD 时域分解图

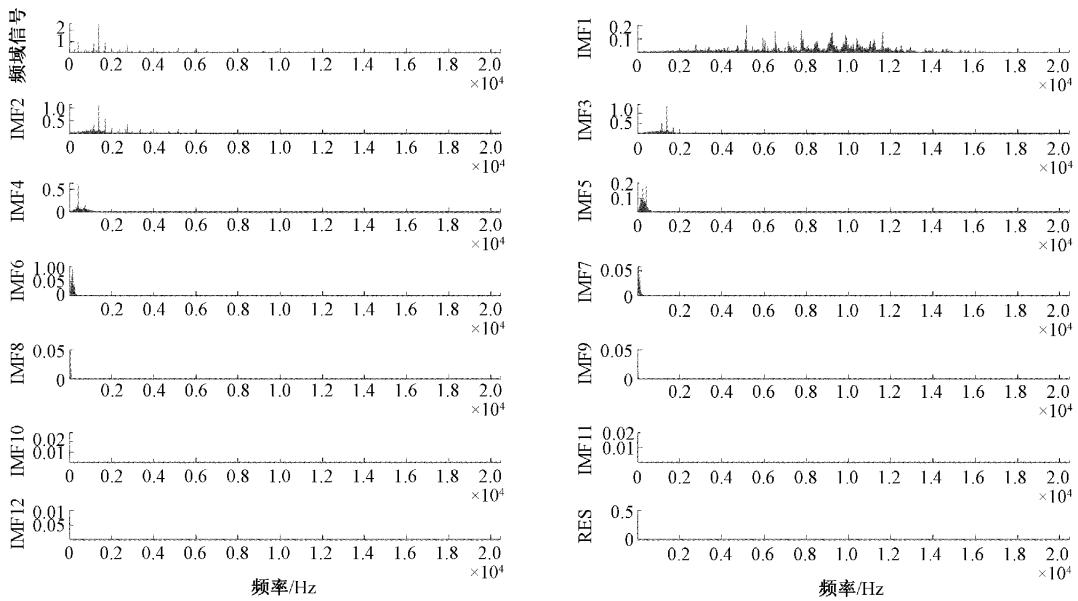
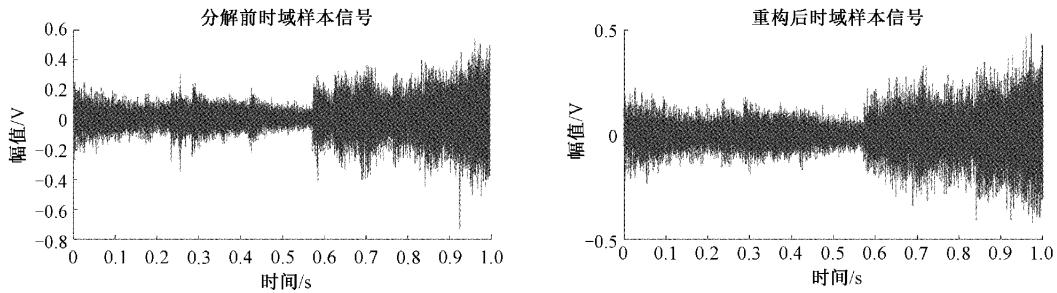


图 7 各分量频谱图



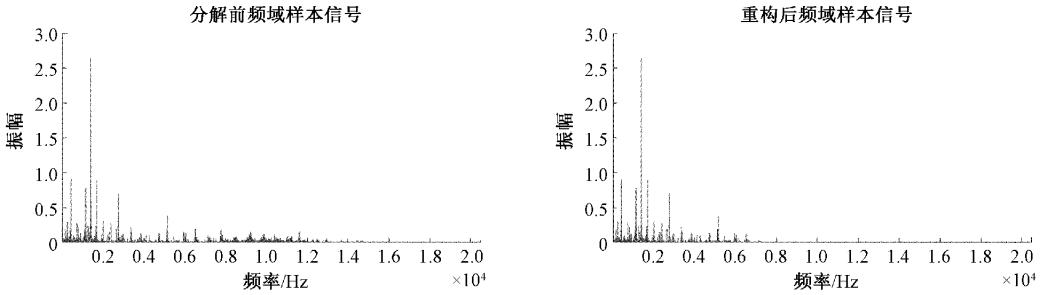


图 8 重构前后时域频域对比图

表 2 时域特征参数

| 时域特征参数   |  |
|--|--|
| $F_1 = \max\{x(n)\} - \min\{x(n)\}$                    | $F_7 = \{\sum_{n=1}^N [x(n) - F_2]^3\} / \{(N-1)F_5^3\}$ |
| $F_2 = \frac{1}{N} \sum_{n=1}^N x(n)$                  | $F_8 = NF_6 / \sum_{n=1}^N  x(n) $                       |
| $F_3 = [\sum_{n=1}^N  x(n) ] / N^2$                    | $F_9 = \frac{\max\{ x(n) \}}{F_6}$                       |
| $F_4 = \frac{1}{N-1} \sum_{n=1}^N (x(n) - F_2)^2$      | $F_{10} = \{N \max[x(n)]\} / \sum_{n=1}^N  x(n) $        |
| $F_5 = \sqrt{\frac{1}{N} \sum_{n=1}^N (x(n) - F_2)^2}$ | $F_{11} = \frac{\max\{ x(n) \}}{F_3}$                    |
| $F_6 = \sqrt{\frac{1}{N} \sum_{n=1}^N (x(n))^2}$       | $F_{12} = \frac{\max\{ x(n) \}}{F_6}$                    |

表 3 频域特征参数

| 频域特征参数  |  |  |
|---|--|--|
| $P_1 = \frac{1}{K} \sum_{k=1}^K s(k)$                                 | $P_8 = \sqrt{[\sum_{k=1}^K f_k^4 s(k)] / [\sum_{k=1}^K f_k^2 s(k)]}$                 |  |
| $P_2 = \frac{1}{K-1} \sum_{k=1}^K (s(k) - P_1)^2$                     | $P_9 = [\sum_{k=1}^K f_k^2 s(k)] / \sqrt{\sum_{k=1}^K s(k) \sum_{k=1}^K f_k^4 s(k)}$ |  |
| $P_3 = \frac{1}{K(\sqrt{P_2})^3} \sum_{k=1}^K (s(k) - P_1)^3$         | $P_{10} = \frac{P_5}{P_4}$   |  |
| $P_4 = \frac{1}{KP_2^2} \sum_{k=1}^K (s(k) - P_1)^4$                  | $P_{11} = \frac{1}{KP_6^3} \sum_{k=1}^K (f_k - P_5)^3 s(k)$                          |  |
| $P_5 = [\sum_{k=1}^K f_k s(k)] / [\sum_{k=1}^K s(k)]$                 | $P_{12} = \frac{1}{KP_6^4} \sum_{k=1}^K (f_k - P_5)^4 s(k)$                          |  |
| $P_6 = \{\frac{1}{K} \sum_{k=1}^K (f_k - P_5)^2 s(k)\}^{\frac{1}{2}}$ | $P_{13} = \frac{1}{KP_6} \sum_{k=1}^K (f_k - P_5)^{\frac{1}{2}} s(k)$                |  |
| $P_7 = \sqrt{[\sum_{k=1}^K f_k^2 s(k)] / [\sum_{k=1}^K s(k)]}$        | 式中: $s(k)$ 为频谱, $k = 1, 2, \dots, K$ , $K$ 是谱线的数量;<br>$f_k$ 表示第 $k$ 条谱线的频率值[19]。     |  |

#### 4 1D-CNN 多域特征融合降雹量级分类模型

为了提高模型的识别率, 本文充分地利用了信号处理领域的特征集与深度 1D-CNN 自适应提取的特征集相融

合, 设计了如图 9 所示的 1D-CNN 多域特征融合的网络结构, 该模型有 3 个分支网络和 1 个融合网络, 每个网络都含有特征提取层。输入 1、输入 2 和输入 3 分别对应着时域特征集、原始数据集和频域特征集, 再通过 1D-CNN 提取

其深度特征,提取的深度特征集通过分支网络结构输出为一维向量,GlobalMaxPooling1D 层实现了对高维特征的“展平”操作。分支 1 和分支 3 的全连接层的输出与分支 2 的输出此时为相同维度的特征向量,再将其作为融合网络的输入特征,提取出特征后利用 softmax 分类器实现了目标的输出类别。该模型实现了对降雹声信号的深度特征提取,能够极大地提高模型的识别率。

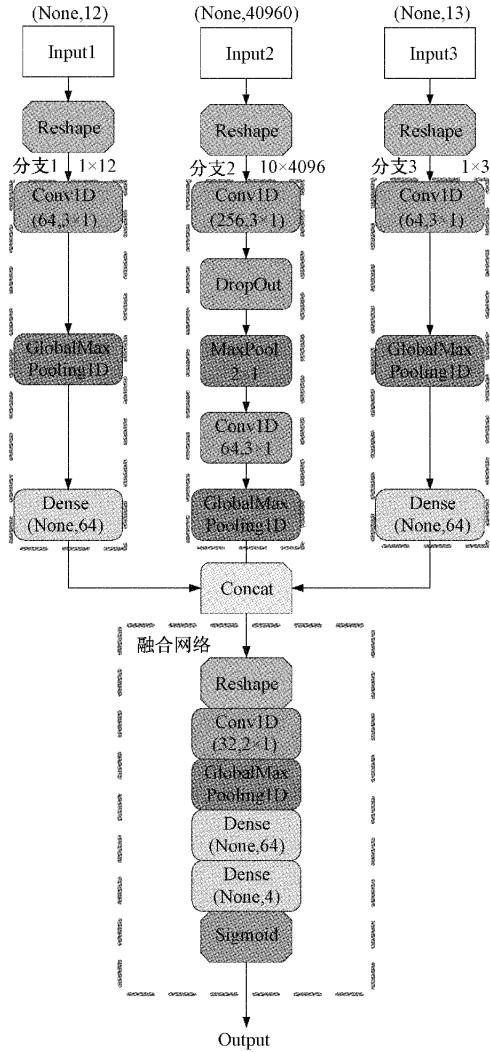


图 9 1D-CNN 多域特征融合网络模型

## 5 实验分析

考虑到真实降雹下落速度会随着阻力的增大而匀速降落,因此采集模拟冰雹从固定高度(10 m)下降产生的声信号作为本文实验所使用的数据集。冰雹是由不同量级的冰雹模具冻制而成。为验证本文提出观点的有效性,基于此数据集进行论证分析,数据预处理部分使用的是 Matlab2020a 版本,时域频域特征提取在 PyCharm2020 中实现。本次实验使用的处理器为 Intel® Core™ i7-11700k@3.6 GHz, GPU 为 NVIDIA GeForce GTX3060Ti 8 G。

### 5.1 实验样本组成

数据的采样频率设为 44.1 kHz,采样时长 2.5 s,每种量级的冰雹采集 100 条样本,以样本长度为 40 960 进行数据增强,若样本长度太短可能会缺失重要的降雹信号,因此数据增强后的每种冰雹量级样本变为 400 个,按照 7:3 的比例进行划分训练集和测试集,如表 4 所示。

表 4 降雹数据集划分

| 样本名称 | 样本长度   | 训练集数量 | 测试集数量 | 总数    | 标签 |
|------|--------|-------|-------|-------|----|
| 轻量级  | 40 960 | 280   | 120   | 400   | 0  |
| 中量级  | 40 960 | 280   | 120   | 400   | 1  |
| 重量级  | 40 960 | 280   | 120   | 400   | 2  |
| 特重量级 | 40 960 | 280   | 120   | 400   | 3  |
| 总数据  | —      | 1 120 | 480   | 1 600 | —  |

### 5.2 本文模型的参数选择

在 CNN 中,网络的深度和神经元数目不仅影响着模型的识别率,还影响着模型训练速度,因此需要选择合适的模型参数。若为了提高识别率不断地增加深度和神经元,会引起过拟合现象,本文在模型分支 2 处的第一层卷积层中引入了 Dropout 方法和  $L_2$  正则化来抑制过拟合。其中 Dropout 方法是根据某一丢弃率的方式随机丢弃某层网络的神经元,本文丢弃率设为 0.5。 $L_2$  正则化项其实是权衡最小化原始损失函数和小权重的过程,两者之间由正则化系数  $\lambda$  控制: $\lambda$  越大,越偏向于小权重为主要目标, $\lambda$  越小,越偏向于最小化原始损失函数为目标。 $L_2$  范数为:

$$L(\omega) = \frac{1}{N} \sum_{i=1}^N [f(x_i; \omega) - y_i]^2 + \frac{\lambda}{2} \|\omega\|_2^2 \quad (12)$$

式中:  $\|\omega\|_2^2 = \sqrt{\sum_j \omega_j^2}$ ,  $\frac{\lambda}{2} \|\omega\|_2^2 = \sum_j \omega_j^2$  为正则化项(惩罚项),此项接近于 0,目的就是在假设空间里面选择一个使目标函数最小的那个模型,让模型变得越来越简单,从而能够有效的防止过拟合。

模型超参数设置为:迭代次数 epochs=50,小批次数目 batch\_size=64,卷积核和神经元数目设置如图 9 所示。在模型训练中选择了使用最为广泛、收敛速度快并且稳定的优化器 Adam,学习率设为 0.001。

### 5.3 算法改进前后对比实验

将原始数据集和经改进 CEEMD 重构算法处理后的数据集分别用传统的 1D-CNN 模型和多域特征融合的 1D-CNN 模型进行实验。原始数据集在两种模型的实验结果如图 10 所示。能够得出多域特征融合的 1D-CNN 模型要优于传统的 1D-CNN 模型,且在训练稳定性上略胜一筹。

为了验证本文提出改进 CEEMD 算法效果,用该算法对原始数据集进行处理,然后再用传统的 1D-CNN 模型和多域特征融合的 1D-CNN 模型进行实验,使用改进 CEEMD

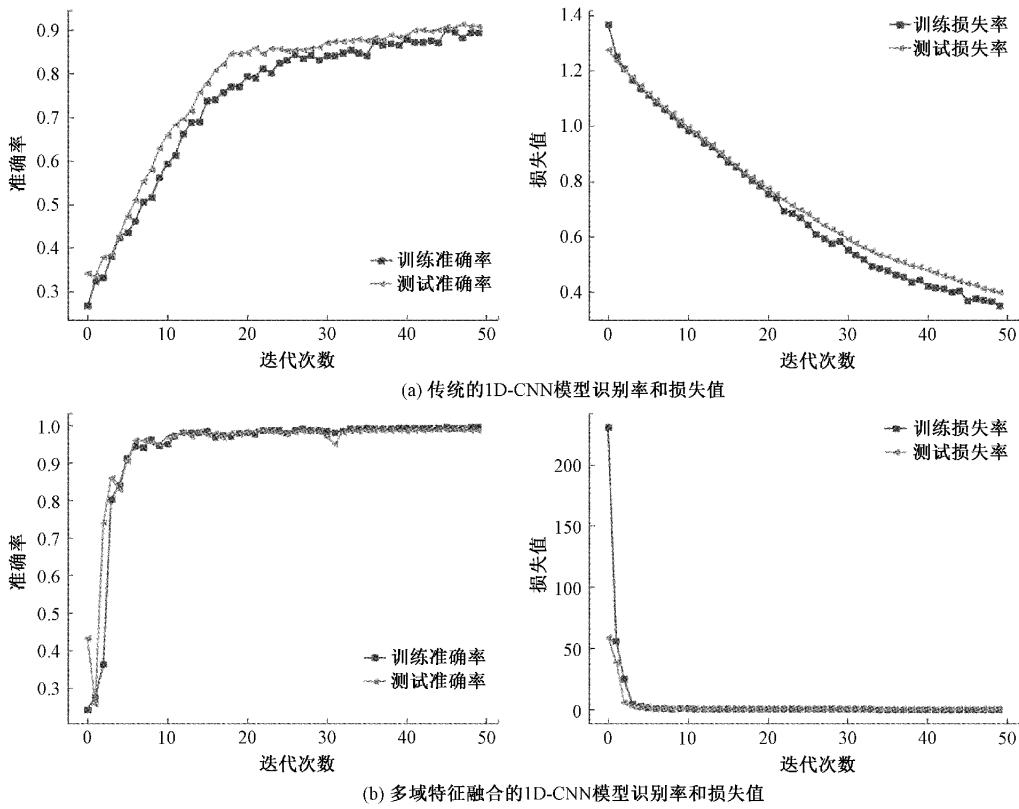


图 10 原始数据集实验结果

重构算法处理后两种模型的实验结果如图 11 所示。结果表明, 多域特征融合的 1D-CNN 模型不仅优于传统的

1D-CNN 模型, 而且经改进 CEEMD 重构算法处理后的训练稳定性和识别率要优于传统的方法。

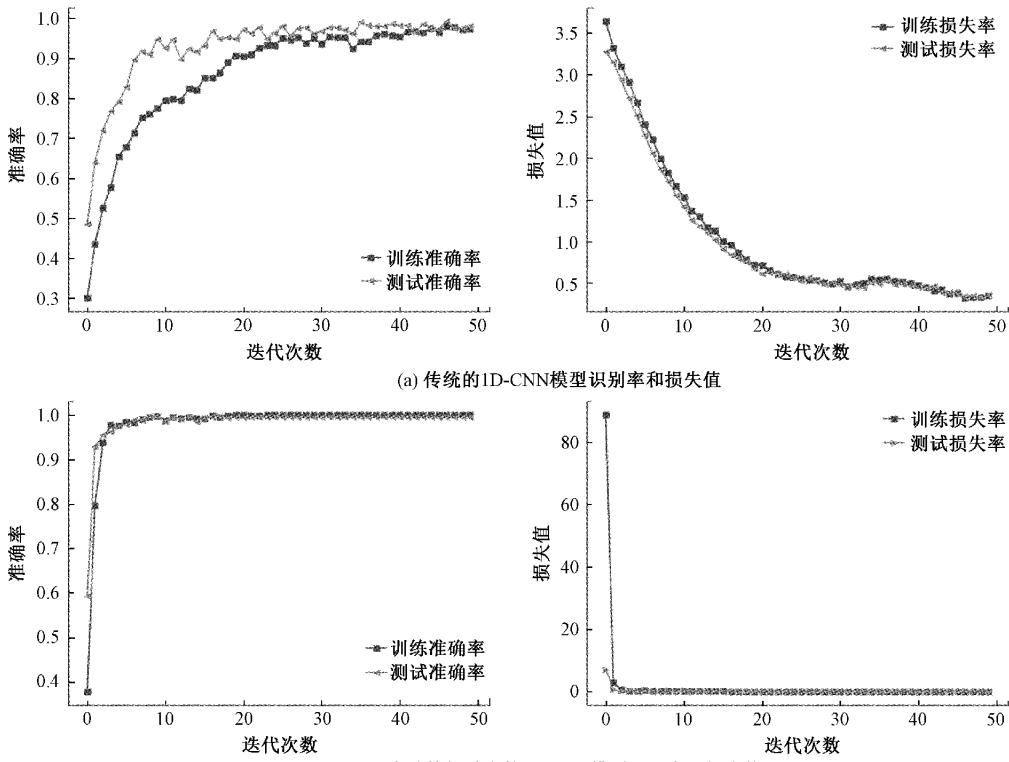


图 11 改进 CEEMD 处理后的数据集实验结果

在以上 4 种实验结果中得到在训练集和测试集在模型上的识别率如表 5 所示。从表中看出本文提出的方法

识别率最高,优于前 3 种算法。

为了更进一步了解算法对不同量级降雹的识别率,排

表 5 实验结果

| 识别方法  | 改进 CEEMD 处理前的数据集与传统 1D-CNN 模型 |       | 改进 CEEMD 处理前的数据集与多域特征融合的 1D-CNN 模型 |       | 改进 CEEMD 处理后的数据集与传统 1D-CNN 模型 |       | 改进 CEEMD 处理后的数据集与多域特征融合的 1D-CNN 模型 |       |
|-------|-------------------------------|-------|------------------------------------|-------|-------------------------------|-------|------------------------------------|-------|
|       | 训练集                           | 测试集   | 训练集                                | 测试集   | 训练集                           | 测试集   | 训练集                                | 测试集   |
| 准确率/% | 90.54                         | 90.83 | 99.46                              | 98.96 | 97.23                         | 97.92 | 100                                | 99.58 |

除对某一量级降雹极端识别率的情况,通过混淆矩阵,对测试结果进行总结,混淆矩阵如图 12 所示。对于轻量级和中量级两种不同量级的降雹,本文算法的识别率高达百分之百,对于重量级和特重量级的降雹,其识别效果稍差,但仍高达 99.17%,仅有极少数降雹被误判,再次证明了所属算法对不同量级降雹的通用性。

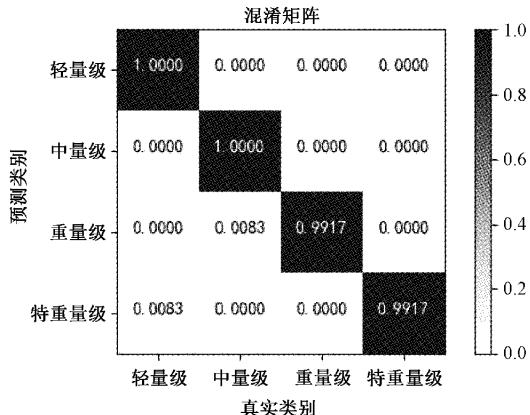


图 12 混淆矩阵结果

#### 5.4 与其他算法对比实验

为了验证本文算法与其他算法对降雹量级的识别性能,将 K-means, SVM 和 LSTM 三种算法分别作为对比算法进行实验。为了防止偶然性,取对比算法的 10 次综合平均准确率作为最终实验结果,实验结果如表 6 所示。K-means 算法的核心是选取合适的 K 值,但本实验所使用的数据量相对较大,对于 K 值的选择较为困难,所以该算法的准确率较低。SVM 由于其内部结构的限制,提取高级语义信息的能力不足,导致其精度上限不够。对于 LSTM 算法,相比前两种传统机器学习算法虽然有较高的识别率,但其在并行处理数据上存在劣势,且本文的数据长度

较长,因此该算法较本文算法仍有差距。与此同时,本文算法的训练过程及识别结果都较为稳定,更进一步验证了本文算法的鲁棒性。

## 6 结 论

本研究基于声学的角度对降雹的量级进行研究,将信号处理的知识与深度学习相结合并应用于对降雹量级的识别,是一种新颖的应用型创新。针对降雹声信号中的毛刺现象,本文提出了改进 CEEMD 重构算法,通过对信号进行分解,使用设计了一款低通滤波器,不仅能够有效的去除高频噪声,而且对信号中毛刺现象也能有效的进行抑制,提出的该改进算法对数据集预处理的效果较好;结合降雹声信号的时域和频域特征,针对性地设计了一种多域特征融合的 1D-CNN 算法,验证了将该算法与改进 CEEMD 重构算法相结合对降雹量级分类的识别率更高。当然,本文的算法仍有些不足,首先是运用了信号处理的方法,增加了工作量。其次是所设计模型的输入具有一定局限性,虽然模型的复杂度较为简化,但需要人为提取的特征作为模型分支 1 和分支 3 的输入。最后,需要说明的是本文所述方法只针对不同量级的降雹声信号识别较高,但是在轻量级降雹与暴雨相融合的天气情况下,有效地区分两者有待进一步研究。

## 参考文献

- [1] YAO H, LI X, PANG H, et al. Application of random forest algorithm in hail forecasting over Shandong Peninsula [J]. Atmospheric Research, 2020, 244:105093.
- [2] WANG P, LV W, WANG C, et al. Hail storms recognition based on convolutional neural network[C]. 2018 13th World Congress on Intelligent Control and Automation(WCICA), 2018: 1703-1708.
- [3] 杨淑华,梁进秋,张玉芳,等.冰雹天气的多普勒雷达特征统计分析[J].自然灾害学报,2014,23(3):101-106.
- [4] 李鹏,嵇佳丽,丁倩雯.基于声信号特征分析的降雹和降雨识别[J].安徽大学学报(自然科学版),2021,45(3):34-41.
- [5] 李鹏,嵇佳丽,丁倩雯.基于熵值法特征筛选的 GRNN

表 6 不同算法实验结果

| 算法      | 综合准确率/% |
|---------|---------|
| K-means | 70.63   |
| SVM     | 89.38   |
| LSTM    | 97.71   |
| 本文      | 99.58   |

- 降雹识别[J]. 气象, 2021, 47(7):854-861.
- [6] WANG R. Estimation of maximum hail diameters from FY-4A satellite data with a machine learning method[J]. Remote Sensing, 2021, 14:73.
- [7] 高桂革, 原阔, 曾宪文, 等. 基于改进 CEEMD-CS-ELM 的短期风速预测[J]. 太阳能学报, 2021, 42(7): 284-289.
- [8] 李孟威, 史元浩, 杨彦茹, 等. 融合 EMD 和 LSTM 的受热面积灰预测研究[J]. 电子测量与仪器学报, 2020, 34(11):166-172.
- [9] 于元潔, 杨光永, 晏婷, 等. 基于 CEEMD 和 MOMEDA 的滚动轴承故障提取[J]. 电子测量技术, 2021, 44(22):96-101.
- [10] 徐文校, 张银胜, 杨山山, 等. 基于广义 S 变换和迁移学习的轴承故障信号的识别算法[J]. 电子测量技术, 2021, 44(24):161-168.
- [11] TANS, TAN Z. Improved LeNet-5 model based on handwritten numeral recognition [C]. 2019 Chinese Control And Decision Conference (CCDC), 2019: 6396-6399.
- [12] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25(2):1-9.
- [13] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014: 1-14.
- [14] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[J]. IEEE Computer Society, 2014: 1-9.
- [15] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[J]. IEEE, 2016: 770-778.
- [16] TSIKALOVSKY D, FIRSOV G. On luminance noise removal using convolutional neural network[C]. 2021 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus), 2021: 710-713.
- [17] PONNAGANTI V, MOH M, MOH T S. Utilizing CNNs for object detection with LiDAR data for autonomous driving [C]. 2021 15th International Conference on Ubiquitous Information Management and Communication(IMCOM), 2021: 1-6.
- [18] 宫文峰, 陈辉, 张美玲, 等. 基于深度学习的电机轴承微小故障智能诊断方法[J]. 仪器仪表学报, 2020, 41(1): 195-205.
- [19] FEI C W, CHOY Y S, BAI G C, et al. Multi-feature entropy distance approach with vibration and acoustic emission signals for process feature recognition of rolling element bearing faults[J]. Structural Health Monitoring, 2018, 17(2):156-168.

### 作者简介

李鹏,教授,博士,主要研究方向为超声成像,北斗定位,图像处理等。

E-mail:20191219086@nuist.edu.cn

杨山山(通信作者),硕士生,主要研究方向为信号处理、深度学习等。

E-mail:417943474@qq.com