

# 基于 FEEMD 算法对小样本电磁信号的识别与分类<sup>\*</sup>

郭钰荣 姚金杰 白建胜 温雪芳  
(中北大学 太原 030051)

**摘 要:**针对当前小样本条件下电磁信号识别算法在不同信噪比下识别准确率较低的问题,提出了一种模糊熵限阈经验模态分解(fuzzy entropy empirical mode decomposition, FEEMD)算法进行电磁信号特征提取,提取表征明显的数据展开短时傅里叶变换(short time Fourier transform, STFT),然后选用 Transformer 模型分类识别各制式信号。该算法采用 8 种不同制式的电磁信号分别在-10、-5、0、5、10 dB 这 5 种信噪比下的识别准确率,确定了该网络的最优超参数。仿真结果表明,在 5 种信噪比下,2FSK、AM、ASK、SSB 这 4 种调制信号识别率均超过 90%,QAM16、QPSK 和 OFDM 的准确率由 30%~40% 提升到了 70% 以上,由此表明了该算法的有效性和可实施性。

**关键词:**短时傅里叶变换;Transformer 网络;FEEMD 算法;信噪比

**中图分类号:** TN911 **文献标识码:** A **国家标准学科分类代码:** 510.4030

## Recognition and classification of small sample electromagnetic signals based on FEEMD algorithm

Guo Yurong Yao Jinjie Bai Jiansheng Wen Xuefang  
(North University of China, Taiyuan 030051, China)

**Abstract:** Aiming at the problem that the identification accuracy of current small sample electromagnetic signal identification algorithm is low under different SNR, a fuzzy entropy empirical mode decomposition (FEEMD) algorithm is proposed to extract electromagnetic signal feature. Extract the data with obvious characterization to expand short-time Fourier transform (STFT), and then select Transformer model to classify and identify each standard signal. The algorithm uses the recognition accuracy of 8 kinds of communication signals under the five SNR of -10, -5, 0, 5 and 10 dB respectively to determine the optimal hyperparameters of the network. Simulation results show that under the five SNR, the recognition rate of the four modulated signals (2FSK, AM, ASK and SSB) is more than 90%, and the accuracy rate of QAM16, QPSK and OFDM is increased from 30%~40% to more than 70%, which shows the effectiveness and practicability of the algorithm.

**Keywords:** STFT; Transformer network; FEEMD algorithm; SNR

### 0 引言

在现代电子对抗中,随着电磁环境日益复杂,电磁信号种类逐渐增多,在形式复杂多变的信号环境下,依据常规参数识别电磁信号显然非常困难。传统的基于脉冲描述外部特征参数测量<sup>[1]</sup>的电磁信号识别手段已经不能满足战场上快速、准确区分信号类别的需求,获取能够反映电磁信号本质信息的脉内特征<sup>[2]</sup>成为研究热点。另外,人为设计提取特征的方法需要依靠专业知识和经验,存在针

对性强、低信噪比下失效等缺陷<sup>[3]</sup>,因此如何自动地从数据中提取有利于电磁信号分类的深层本质特征显得尤为重要。

针对电磁信号具有多样化的制式信号,目前研究人员主要采用时域分析法、频域分析法、调制域分析法、谱相关法<sup>[4]</sup>和时频域分析法等实现信号特征提取,并取得了显著的成果。张贤等<sup>[5]</sup>通过建立信号样本库并提取时域统计学特征,运用模糊 C 均值聚类算法展开信号识别,但是特征提取需具备大量的专业知识,过程复杂,计算量

收稿日期:2023-01-31

<sup>\*</sup> 基金项目:山西省基础研究计划项目(202203021212157)、国家自然科学基金(62201522)项目资助

大。谢存祥等<sup>[6]</sup>提出了基于分数阶傅里叶变换的雷达信号 chirp 基稀疏分解的识别方法,在信噪比(SNR)为 3 dB 环境下能达到 95% 以上的整体识别率,不具备普遍性、全面性。肖祺等<sup>[7]</sup>采用 CWD 获取信号的时频图像,采用 Harris 角点检测和霍夫变换提取角点和直线特征,通过支持向量机(SVM)进行训练、分类和识别,在 SNR 为 0 dB 时,识别正确率达到 92.3%,但是该算法对于大数据的信号矩阵计算消耗较大,信号数据量较大时不适用。曲志昱等<sup>[8]</sup>提出一种基于知识蒸馏与注意力图的雷达信号识别方法,在 0 dB 下识别准确率能够达到 90% 以上,但是在 -10 dB 准确率下降,仅能达到 60% 左右。李世通等<sup>[9]</sup>提出了一种基于时频图像和高次频谱特征联合的雷达信号识别算法,通过支持向量机实现雷达信号的分类识别,在 SNR 为 -8 dB 时不同信号的识别准确率能达到 90% 以上。这些研究成果虽然显著,却局限在某一信噪比下的识别准确率有所提高,不具备全面性。

针对上述问题,本文采用时频域分析方法完成电磁信号的特征提取,在时频分析前加入了预处理模块,通过模糊熵限阈经验模态分解(fuzzy entropy empirical mode decomposition, FEEMD)算法提取表征明显的分量特征,减小特征计算量,抑制噪声对信号特征的影响,然后其进行傅里叶变换,输出的时频图喂入 Transformer 分类识别模型来完成电磁信号在不同低信噪比下的识别与分类。仿真实验表明,在小样本条件下,8 种不同制式的电磁信号分别在 -10、-5、0、5、10 dB 这 5 种 SNR 的识别准确率均有所提高。

## 1 信号特征提取的算法

### 1.1 模糊熵

本文研究的信号是平滑信号,在进行加噪处理之后数据波形会存在多个尖峰、子频率较多的现象,加大了特征提取的难度,故而引用熵值<sup>[10]</sup>,通过均值运算除去基线漂移的影响,且向量的相似性不再由绝对幅值差确定,而是利用指数函数模糊化相似性度公式由指数函数确定的模糊函数形状决定,可反映出一组信号数据中的各个子频率复杂程度,熵值越小,信号中的子频率越少,波形曲线越趋于平滑,数据越趋于稳定。

模糊熵的参数选择如下。

1)  $m$  的选择。模式维数或嵌入维数,本文选择  $m=2$ 。

2)  $r$  的选择。即模糊函数边界的宽度。 $r$  过大会丢失很多统计信息,过小估计出的统计特性的效果不理想,而且会增加对结果噪声的敏感性。本文取的是序列标准差的 0.14 倍。

3)  $n$  的选择。 $n$  决定了相似容限边界的梯度, $n$  越大,梯度越大, $n$  在模糊熵向量间相似性的计算过程中起着权重的作用。为了捕获尽量多的细节信息,本文取较小的整数 2。

### 1.2 短时傅里叶变换(STFT)

STFT<sup>[11]</sup>窗的长度决定频谱图的时间分辨率和频率分辨率,窗长越长,截取的信号越长,信号越长,傅里叶变换后的频率分辨率越高,时间分辨率越差。所以本文选取的窗口长度为 500,每次平移的步长为 1,采样频率为 1 024。对原始信号  $\beta=0.54$  做 STFT 的具体流程如图 1 所示(本文原始信号均以 QPSK 信号在信噪比为 0 dB 为例)。




图1 原始信号做 STFT 流程

STFT 首先需要定义一个窗函数  $w(t)$ ,本文选用的是汉明窗(Hamming window, HW),表达式如下:

$$\text{hamming}(n) = \begin{cases} \beta - (1 - \beta) \cdot \cos\left(\frac{2\pi n}{N-1}\right), & 0 \leq n \leq N-1 \\ 0, & \text{其他} \end{cases} \quad (1)$$

从图 1 可以看出,窗函数选取  $\beta=0.54$  并不能将原始

信号的所有数据包含在内,这样数据缺失明显,造成了窗函数里截取信号的失真。为此,针对这个问题本文所采用的  $\beta$  值是根据每组数据的模糊熵值进行求取的,保证原始信号的数据完整,避免存在信号失真的情况,改进后的窗函数如图 2 所示。

从图 2 可以看到,信号数据失真的情况改善了很多,但是并没有完全克服,所以对数据做进一步的设阈值处理




图2 改进后的窗函数滑窗过程

很有必要,从而剔除部分极大、极小值来减小数据失真。

加窗处理:

$$y(t) = x(t) \cdot w(t - \tau_0) \quad (2)$$

然后,对其进行 STFT:

$$X(\omega) = F(y(t)) = \int_{-\infty}^{+\infty} x(t) \cdot w(t - \tau_0) e^{-j\omega t} dt \quad (3)$$

定义函数  $S(\omega, \tau)$ , 表示在窗函数中心为  $\tau$  时, 对原函数进行变换后的频谱结果  $X(\omega)$ , 即:

$$S(\omega, \tau) = F(x(t)) \cdot w(t - \tau) = \int_{-\infty}^{+\infty} x(t) \cdot w(t - \tau) e^{-j\omega t} dt \quad (4)$$

重复上述操作, 不断滑窗、快速傅里叶变换(FFT), 最终得到  $\tau_0 \sim \tau_N$  所有分段的频谱结果如图3所示。可从图3看到, 存在的两个问题, 一方面, OFDM、QAM16和QPSK 3种信号从直观上看区分度不明显, 另外5种信号相对比较容易识别; 另一方面, 除了ASK信号所生成的时频图中数据干扰和噪声干扰较小之外, 其他制式信号的时频图中干扰均比较大。为了改善上述两种情况, FEEMD方法对信号进行数据特征提取, 提取特征表征明显的信号, 完成数据重构, 使得重构后的数据更具平稳性和抗干扰性。




图3 信噪比为0 dB下的原始信号的STFT图

### 1.3 模糊熵限阈经验模态分解(EMD)

#### 1) 经验模态分解

针对原始信号生成的STFT时频图中存在低频信号的干扰, 为了弱化此现象, 使信号特征表征更加明显, 本文通过EMD<sup>[12]</sup>对信号进行分解, 提取高频平稳信号数据的

同时还可以减少特征计算复杂度。其是依据数据自身的时间尺度特征来进行信号分解, 无需预先设定任何基函数, 具有很好的自适应性。该分解方法能够将任意一个信号分解成若干固有模态函数与一个信号余量的和:

$$x(t) = \sum_{i=1}^N IMF_i + res \quad (5)$$

式中:  $N$  为固有模态函数总个数;  $IMF_i$  为各固有模态;  $res$  为信号余量。

$IMF_i$  固有模态各分量计算过程如下。

(1) 确定原始信号中的所有极值点。

(2) 通过三次样条曲线拟合出上包络线  $e_{\max}(n)$ 、下包络线  $e_{\min}(n)$ 。

(3) 求步骤(2)中三次包络线的均值, 得到均值包络线  $m_i(n)$ 。

(4) 将原始信号与均值包络线的差值组合成新的信号  $h_i(n)$ , 即  $h_i(n) = x_i(n) - m_i(n)$ 。

(5) 判断新的信号  $h_i(n)$  是否满足 IMF 的定义: ①在整个数据段内, 极值点的个数和过零点的个数必须相等或相差最多不能超过一个; ②在任意时刻, 由局部极大值点形成的上包络线和由局部极小值点形成的下包络线的平均值为0, 即上、下包络线于时间轴局部对称。

如果满足步骤(5)的定义条件, 该信号就是一个分量  $IMF_i(n)$ , 作为新的原始信号, 返回步骤(1)。如果不满足, 重复上述步骤  $k$  次, 直到满足为止。  $IMF_i(n)$  筛选停止原则:

$$\frac{\sum_{t=0}^T |h_k(n) - h_{k1}(n)|^2}{\sum_{t=0}^T |h_k(n)|^2} \leq C_r \quad (6)$$

式中:  $C_r$  是作为停止条件认为设定的一个常数, 一般  $C_r = 0.2 \sim 0.3$ 。

EMD的优点是克服了基函数无自适应性的问题, 对于段内信号可以不进行实现的复杂分析或参数调整就可以直接分解出所需的特征信号, 且运算量相对小波分析等算法来说较小, 但是该算法有一个弊端: 分解出来的 IMF 分量很容易出现模态混叠现象, 重构后的数据失真较严

重。虽然也有人提出 EEMD、CEEMD<sup>[13]</sup>、CEEMDAN<sup>[14]</sup>等改进方法,但是该现象并没有得到很好的消除,因此需要对 EMD 分解进行改进。

## 2) FEEMD 算法

针对 EMD 方法分解的分量值存在信号失真的问题,本文提出一种 FEEMD 方法,主要通过两次数据重构完成数据特征提取。首先,将原始信号经过滑窗处理,求得的模糊熵值按大小排序,计算得到阈值  $F$ ;然后,采用改进的拉伊达准则进行判别,剔除阈值之外的数据完成信号数据的一次重构;最后,分解重构信号,得到的分量进行平均值求取,更新残值,通过对分解分量进行数据叠加,完成二次重构,具体流程如图 4 所示。




图 4 FEEMD 方法整体流程

拉伊达准则,就是令每个信号的时域数据为  $x_1, x_2, \dots, x_n$ , 计算出其算数平均值  $v_i = x_i - \bar{x} (i = 1, 2, \dots, n)$ , 并计算出标准差  $\sigma$ , 若某个  $x_i$  的剩余误差满足式(7), 则该测量值应被剔除。

$$|v_i| = |x_i - \bar{x}| > 3\sigma \quad (7)$$

通过计算信号数据的平均值  $\bar{x}$ 、中值、模糊熵  $F$  和标准差  $\sigma$ , 将其进行拉伊达准则判别,发现模糊熵剔除的数据量相对较少,失真度更小,根据表 1 的数据剔除量,选用模糊熵代替平均值来展开阈值设限。

表 1 各值对应的数据剔除量

|      | 平均值 | 中值 | 模糊熵 |
|------|-----|----|-----|
| 剔除个数 | 34  | 39 | 28  |

原始信号经过 EMD 分解后的各固态模式信号与本文提出的 FEEMD 分解后的各固态模式信号的最大差别如下:(1)EMD 分解与本文提出的 FEEMD 分解方法在前两个分量处看不出明显区别,且都同样在 IMF7 处趋于稳定状态,但是在 IMF3、IMF4、IMF5 及 IMF6 这 4 个分量上,本方法的数据波动较为明显,数据提取相对更加精确,进行信号特征提取更具表征性(图 5);(2)把 IMF7 处看作信号分量分界线,IMF7 以前是高频分量,之后是低频分量,最后一个红线部分是计算的剩余分量,本文提出的




图 5 信噪比为 0 dB 下的 QPSK 信号的 FEEMD 分解

FEEMD 方法中的剩余分量拟合速度更慢,且趋于 0, EMD 下的剩余分量有回升的趋势,可见该方法具有可行性。

## 2 训练模型搭建

Transformer 模型<sup>[15]</sup>结构主要包括 4 部分:1)主干网络,主要是对图像进行切割、位置与分类嵌入,完成层规范化操作;2)编码器,将主干网络输出的二维矩阵图和位置编码器堆积并展开为一维数据,送入多层 Transformer 模型中,输出自注意力权重向量  $V_e$ ;3)解码器,通过输入自注意力权重向量和位置编码向量,输出解码特征向量  $V_d$ ;4)前向传递网络,经过  $L$  次编码器模块和 MLP 组合得到信号分类预测结果。具体流程如图 6 所示。




图 6 Transformer 模型分类识别整体框架

主干网络,先把大小为  $3 \times 224 \times 224$  的图像先切割成  $3 \times 16 \times 16$  的块,每个块的像素大小是  $14 \times 14$ ,然后经过全连接层降维成  $768 \times 196$  的二维序列,再加入向量进行

堆叠,形成  $768 \times 197$  的二维序列,最后再通过构建一个可学习的位置向量来表示图片的空间信息,与每个数据元素逐项相加,经过线性映射层产生所需要的  $768 \times 197$  序列。

编码器,输入块的维度是  $[197, 768]$ ,先进行了归一化处理,然后进行多头注意力机制计算或者进行归一化处理输入到全连接层,进行  $L$  次跳跃连接。多层感知机层是由前后两层线性层中间加上 GELU 激活函数和输出层组成,中间的两个线性层中的第 1 个将输入块的长度放大为原来的 4 倍,后一个线性层则将长度重新恢复。

Transformer 网络模型搭建中,采用迁移学习<sup>[16]</sup>的方法,在第 1 次展开模型训练的时候选择已经训练好的权重文件,这样既能够减少训练时间,又能够在较少的轮数迭代之后达到一个好的效果。在模型参数优化下,选择深度为 1 024 作为迁移学习的训练权重文件、优化器 SGD 的梯度值取 0.98 和权重每次更新后的学习衰减率为  $1 \times 10^{-5}$  作为最优值来完成分类模型的预测,如表 2 所示。

表 2 模型各参数的最优值

|                         | 损失函数  |       | 准确率   |       | 时间<br>(轮/s) |
|-------------------------|-------|-------|-------|-------|-------------|
|                         | 训练    | 测试    | 训练    | 测试    |             |
| 深度=768                  |       |       |       |       |             |
| 梯度值=0.9                 | 1.275 | 0.835 | 0.561 | 0.725 | 21          |
| 权重值= $5 \times 10^{-5}$ |       |       |       |       |             |
| 深度=768                  |       |       |       |       |             |
| 梯度值=0.98                | 1.028 | 0.589 | 0.634 | 0.731 | 23          |
| 权重值= $1 \times 10^{-5}$ |       |       |       |       |             |
| 深度=1 024                |       |       |       |       |             |
| 梯度值=0.9                 | 0.965 | 0.619 | 0.697 | 0.804 | 24          |
| 权重值= $5 \times 10^{-5}$ |       |       |       |       |             |
| 深度=1 024                |       |       |       |       |             |
| 梯度值=0.98                | 0.679 | 0.456 | 0.784 | 0.892 | 27          |
| 权重值= $1 \times 10^{-5}$ |       |       |       |       |             |

### 3 仿真实验

#### 3.1 信号数据集

本文所选用的是  $-10$ 、 $-5$ 、 $0$ 、 $5$ 、 $10$  dB 这 5 种信噪比下的 8 种制式信号 (ASK、QPSK、2FSK、OFDM、AM、SSB、DSB、QAM16) 作为研究对象展开信号分类与预测。每种制式在每种信噪比下的数据量为 100,每个制式信号的采集数据量为 1 024。数据集采样信号参数如表 3 所示。

表 3 数据集采样信号参数

| 采样频率/MHz | 采样时长/ms | 频率分辨率/Hz | 信噪比/dB            |
|----------|---------|----------|-------------------|
| 102.4    | 10      | 390.625  | 10、5、0、<br>-5、-10 |

#### 3.2 验证 FEEMD 方法

针对原始信号生成的 STFT 图中 OFDM、QAM16 及

QPSK 这 3 种信号识别准确率较低的问题,本文提出的 FEEMD 方法对信号进行分解,如图 7 所示。对比图 7




图 7 制式信号在  $-10$  dB 下的 FEEMD 分解对比

(a)、(b)和(c)可以看到,该分解图中共有原始信号、各固有模态信号和信号余量3种,其中各固有模态信号 $IMF_2$ 、 $IMF_3$ 、 $IMF_4$ 、 $IMF_5$ 、 $IMF_6$ 及信号余量都存在显著差异,说明对这些数据进行特征提取是可行的,同时还可以增加样本数量,提高识别准确率。除这3种信号之外,又加入了QFSK(图7(d))做对比,从各模态值波形可以直观地看到这4种信号的各 $IMFs$ 值存在差异,对该方法进行特征提取确实可行。另外,为了保证数据不失真,对其进行信号重构,基于 $IMF_7$ 和 $IMF_8$ 处的信号波动较为平缓,为了减小信号数据计算量,选择将这两种分量之外的固有模态信号叠加然后进行STFT。

从图7可以看到,本文提出的FEEMD算法在-10 dB下的特征提取表征明显,在1.3节模块也验证了在0 dB下的特征提取效果更好,证明该算法具有可行性。二次重构后的信号经过STFT变换处理之后如图8所示。从微观来说,OFDM、QAM16及QPSK这3种信号的特征图从肉眼上看有明显差别,较未处理的信号相比,区分度更好;从宏观来看,这8种信号特征表征都存在区别,每个时频图中颜色较深的地方分布各有不同,代表性更强,比改进前效果增强了许多。




图8 信噪比为0 dB下的FEEMD分解后的STFT图

### 3.3 Transformer模型分类识别准确率

通过对原始数据进行基于FEEMD算法的特征提取及STFT处理,再加入Transformer模型进行训练之后,不同信噪比下的原始信号识别准确率结果如表4所示。以本文提出的FEEMD算法处理之后的数据作为输入,根据表2中各参数对比结果,选择最优参数展开模型训练,优化后的模型训练结果如表5所示(训练轮数为100组)。

表4 不同信噪比下的原始信号训练结果


| SNR<br>/dB | 训练<br>损失值 | 训练<br>准确率 | 测试<br>损失值 | 测试<br>准确率 |
|------------|-----------|-----------|-----------|-----------|
| -10        | 1.132     | 0.607     | 0.936     | 0.655     |
| -5         | 1.057     | 0.627     | 0.886     | 0.684     |
| 0          | 1.275     | 0.561     | 0.835     | 0.725     |
| 5          | 0.776     | 0.705     | 0.510     | 0.753     |
| 10         | 0.998     | 0.634     | 0.872     | 0.744     |

表5 不同信噪比下的FEEMD信号训练结果


| SNR<br>/dB | 训练<br>损失值 | 训练<br>准确率 | 测试<br>损失值 | 测试<br>准确率 |
|------------|-----------|-----------|-----------|-----------|
| -10        | 0.699     | 0.701     | 0.534     | 0.811     |
| -5         | 0.674     | 0.719     | 0.494     | 0.857     |
| 0          | 0.609     | 0.784     | 0.456     | 0.892     |
| 5          | 0.482     | 0.883     | 0.204     | 0.916     |
| 10         | 0.531     | 0.757     | 0.412     | 0.877     |

对比表4和5可知,本文提出的算法在5种信噪比下的信号损失值均呈下降趋势,正确率呈上升趋势,测试准确率能达到80%以上,5 dB下的识别效果最好,能达到91.6%,整体性能有一个大的提升,可见本方法在-10~10 dB之间是适用的。

本文将原始信号的信号预测结果以混淆矩阵图的形式展示,如图9所示。从图9(a)可以看到,每种信号的识别准确率是正确的,但是QAM16的识别准确率仅达到30%,且与QPSK和OFDM这两种信号的识别准确率相差不多,在信号预测模型中容易出现错判的现象,针对这个问题,本文提出用FEEMD算法完成特征提取,分类预测结果如图9(b)所示,2FSK、AM、ASK、SSB这4种信号识别准确率提到了95%以上,OFDM、QAM16、QPSK也



(a) 原始信号



(b) FEEMD方法

图9 混淆矩阵对比

能够达到70%以上,整体识别准确率与原始信号相比有大大改善,虽然没能使OFDM、QAM16、QPSK这3种信号的识别准确率效果达到最佳,但是有一定的改进,验证了本方法的可行性。

#### 4 结 论

本文提出了一种FEEMD信号特征提取方法,通过对信号进行阈值设限,以提取信号表征突出的IMFs特征,降低特征计算复杂度并改进窗函数来减少数据失真,对模型进行参数优化,选择最优参数完成信号分类识别。实验结果表明,本方法能够挖掘原始信号的本征数据,各制式信号在小样本下的5种低信噪比下的信号识别准确率均有所上升,最明显的就是QAM16、QPSK和OFDM的识别准确率,且在-10~10 dB之间均适用,验证了本方法的可行性和有效性。

#### 参 考 文 献

- [1] 苏琮智,王美玲,杨承志,等.基于改进EfficientNet的雷达信号调制方式识别[J].电讯技术,2023,63(1):93-100.
- [2] 曹栋,毕研钊,黄秋茗,等.联合改进小波阈值的BOTDR降噪技术研究[J].国外电子测量技术,2022,41(4):83-86.
- [3] 周治国,曹江微,邸顺帆.3D激光雷达SLAM算法综述[J].仪器仪表学报,2021,41(9):13-27.
- [4] 周向宇,程湘爱,彭汕林,等.电磁信号幅频归一化研究[J].电子测试,2022(3):81-83,74.
- [5] 张贤,李帝铨,李晋,等.基于特征提取与聚类识别的人工源电磁伪随机信号处理方法[J].石油地球物理勘探,2022,57(4):973-981,1008.
- [6] 谢存祥,张立民,钟兆根.基于时频特征提取和残差神经网络的雷达信号识别[J].系统工程与电子技术,2021,43(4):917-926.
- [7] 肖祺,陈茂洋.多维时频图像特征组合的电磁辐射源信号识别[J].通信技术,2020,53(6):1364-1368.
- [8] 曲志昱,李根,邓志安.基于知识蒸馏与注意力图的雷达信号识别方法[J].电子与信息学报,2022,44(9):3170-3177.
- [9] 李世通,全大英,唐泽雨,等.基于时频图像和高次频谱特征的雷达信号识别[J].电信科学,2022,38(2):84-91.
- [10] 于玉丹,林伟,俞朝阳.改进Sage-Husa算法结合小波模糊阈值算法的MEMS陀螺去噪[J].电子测量技术,2022,45(19):64-69.
- [11] 郑成香,路树华,徐伟,等.高阶时频变换理论与应用[J].计算技术与自动化,2022,41(1):72-78.
- [12] 徐柳.EMD算法发展及应用综述[J].长江信息通信,2022,35(1):61-64.
- [13] 王民顿,尚俊娜.基于CEEMD和改进小波阈值法的钢架结构沉降数据去噪方法[J].大地测量与地球动力学,2022,42(11):1191-1195.
- [14] 韩龙,谢子殿,王丽.滚动轴承声发射信号降噪的CEEMDAN算法[J].黑龙江科技大学学报,2017,27(3):303-306.
- [15] 刘文婷,卢新明.基于计算机视觉的Transformer研究进展[J].计算机工程与应用,2022,58(6):1-16.
- [16] 苏静雷,王红军,王政博,等.多通道卷积神经网络和迁移学习的燃气轮机转子故障诊断方法[J].电子测量与仪器学报,2023,37(3):132-140.

#### 作 者 简 介

郭钰荣,硕士,主要研究方向为电磁空间的信号识别与分类、道路病害检测技术等。

E-mail:948042260@qq.com

姚金杰,博士,副教授,硕士生导师,主要研究方向为北斗信号。

白建胜,博士,主要研究方向为电磁信号处理、信号处理。

温雪芳,硕士,主要研究方向为深度学习、人工智能。