

改进变分模态分解与多特征的通信辐射源个体识别方法

刘高辉 席宏恩*

(西安理工大学自动化与信息工程学院 西安 710048)

摘要: 针对通信辐射源指纹特征难以提取和单一特征识别率不高的问题,并考虑到通信辐射源细微特征的非线性、非平稳特点,该文提出了一种基于改进变分模态分解和多特征的通信辐射源个体识别方法。首先,为了获得变分模态分解的分解层数和惩罚因子的最优组合,采用鲸鱼优化算法对通信辐射源符号波形信号的变分模态分解方法进行了改进,该方法以序列复杂度为停止准则,使每个符号波形信号能够自适应地分解出包含非线性指纹特征的高频信号分量和数据信息的低频分量;然后,根据相关阈值选取能够最佳表征辐射源非线性特征的高频信号分量层数,分别对其提取模糊熵、排列熵、Higuchi维数以及Katz维数并组成多域联合特征向量;最后,通过卷积神经网络实现通信辐射源个体识别分类,利用ORACLE公开数据集进行实验。实验结果表明:该方法有较高的识别精度且具有良好的抗噪声性能。

关键词: 通信辐射源个体识别; 变分模态分解; 非线性指纹特征; 卷积神经网络

中图分类号: TN911

文献标识码: A

文章编号: 1009-5896(2024)10-4044-09

DOI: 10.11999/JEIT231348

Individual Identification Method for Communication Emitters Based on Improved Variational Modal Decomposition and Multiple Features

LIU Gaohui XI Hongen

(School of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710048, China)

Abstract: Aiming at the difficulties in extracting fingerprint features from communication emitters and the low recognition rate of single features, considering the nonlinear and non-stationary characteristics of subtle features of communication emitters, this paper proposes an individual identification method for communication emitters based on improved variational mode decomposition and multiple features. Firstly, in order to obtain the optimal combination of decomposition levels and penalty factors for variational mode decomposition, the variational modal decomposition of communication emitter symbol waveform signals is improved with whale optimization algorithm, in which the sequence complexity is used as the stopping criterion in this method to enable each symbol waveform signal to adaptively decompose several high-frequency signal components containing nonlinear fingerprint features and low-frequency components of data information; Then, according to the relevant threshold, the number of high-frequency signal component layers is selected that can best represent the nonlinear characteristics of the radiation source and the fuzzy entropy, permutation entropy, Higuchi dimension, and Katz dimension are extracted to form a multi-domain joint feature vector; Finally, the recognition and classification of communication emitters are achieved through convolutional neural networks, and recognition and classification experiments are conducted using the Oracle public dataset. The experimental results show that this method has high recognition accuracy and good noise immunity.

Key words: Specific emitter identification; Variational modal decomposition; Nonlinear fingerprint feature; Convolutional neural network

收稿日期: 2023-12-05; 改回日期: 2024-09-05; 网络出版: 2024-09-11

*通信作者: 席宏恩 2210320062@stu.xaut.edu.cn

基金项目: 国家自然科学基金(61671375)

Foundation Item: The National Natural Science Foundation of China (61671375)

1 引言

通信辐射源个体识别属于特定辐射源识别(Specific Emitter Identification, SEI)技术领域。由于通信辐射源设备内部结构复杂,内部元器件在制造时存在细微误差,导致信号在经过同一制造商的相同型号设备后,也会呈现出细微差异。分析附加在信号上的细微特征,能够实现对通信辐射源设备的唯一识别。

通信辐射源设备内部物理组件的差异与其非线性特性,导致调制后的信号中存在非线性产物。因此,通信辐射源信号具有非平稳和非线性的细微特征。文献[1]将辐射源设备看作非线性动力学系统,对相同类型的信号进行希尔伯特变换后,将其排列熵作为指纹特征,通过实验得到了较高的识别率。文献[2]利用固有时间分解算法对辐射源信号进行分解,然后计算其样本熵、近似熵和排列熵作为特征向量,运用支持向量机来实现辐射源的分类识别。与其他方法相比,该方法表现更优。熵是分析非线性动力学特征的有效参数,其中排列熵计算简单,抗噪声性能强,模糊熵引入了模糊隶属度函数,能够更准确地描述非线性特征。但熵值作为相同类型特征参数存在冗余性,可引入分形维数作为另一参数。其中,Higuchi维数具有较高的准确性,Katz分形维数计算效率高,鲁棒性强。文献[3]通过修改近似熵的容差区间,提出了经验模态分解和改进近似熵相结合的辐射源识别算法,利用支持向量机进行辐射源分类。但信号经过经验模态分解时存在模态混叠和端点效应,且在低信噪比条件下识别效果不佳。在2014年提出的变分模态分解(Variational Mode Decomposition, VMD)能够有效解决模态混

叠等问题,但运用VMD分解信号时,需要预先设定分解模态个数 K 和惩罚因子 α , K 值选择不当会导致欠分解或过分解的问题,而 α 值对模态分量的带宽起决定性作用。针对VMD参数优化问题,文献[4]在旋转机械故障诊断中对振动信号进行VMD分解时,引入能够快速找到全局最优解且收敛性强的鲸鱼优化算法(Whale Optimization Algorithm, WOA),以获得VMD参数的最优组合。为解决基于非线性细微特征通信辐射源个体识别问题,考虑到卷积神经网络(Convolutional neural network, CNN)能够处理更加复杂的非线性关系,文献[5]对采集到的辐射源信号进行过采样,并将其I/Q样本直接送入卷积神经网络中进行分类识别;文献[6]利用固定边界经验小波分解将射频信号分解为16个固定边界经验小波的子信号,而后将其送入卷积神经网络完成分类识别任务。

针对上述问题,本文将通信辐射源作为一个非线性动力学系统,为了保证变分模态分解对通信辐射源信号预处理的精确性,采用鲸鱼优化算法以序列复杂度为停止准则对其进行改进,然后运用改进变分模态分解对通信辐射源信号的每个符号波形信号进行分解,得到主要包含非线性指纹特征的高频信号分量。分别提取高频分量的模糊熵、排列熵、Higuchi分形维数以及Katz分形维数并组成多域非线性特征向量,最后,为了更好地实现辐射源的分类识别,利用处理非平稳特征强大的卷积神经网络进行通信辐射源的分类识别任务。

2 通信辐射源个体特征分析

图1为通信辐射源发射机框架,并标明了辐射源个体特征的可能来源,图中输入符号序列先经过

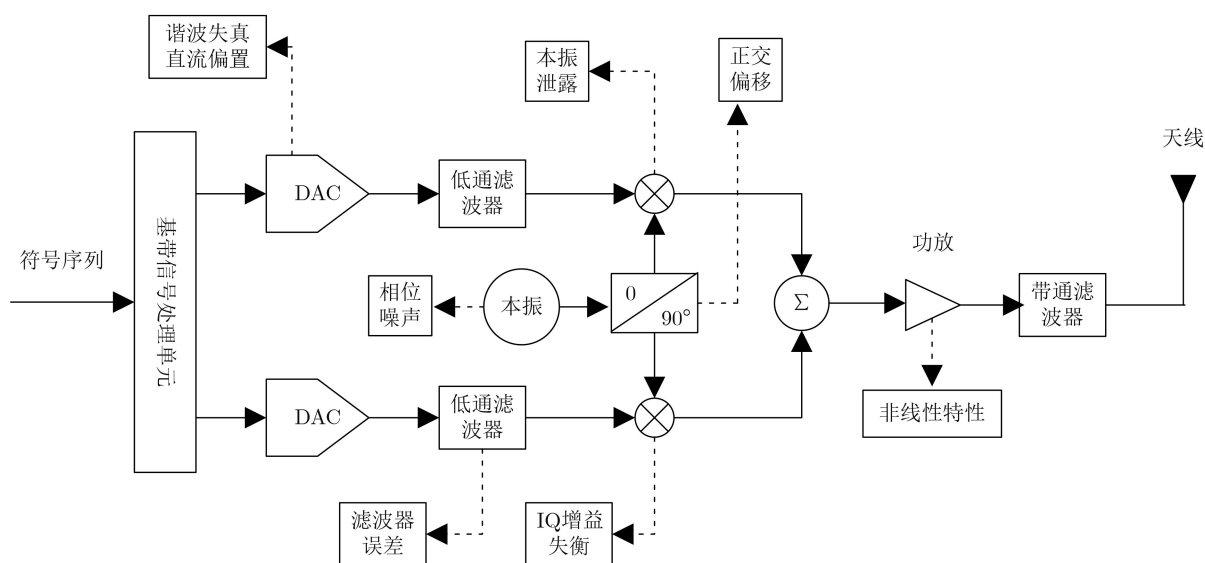


图1 通信辐射源发射机系统模型

基带信号处理单元产生I/Q两路数字基带信号；然后在其经过DAC转换为模拟信号时，会产生直流偏置和谐波失真；再将信号通过低通滤波器滤除高频谐波后，I/Q两路滤波器的频率响应误差也会寄生在信号中；由于本振相位误差和相位抖动，两路正交载波信号间会产生正交相位误差；当I/Q两路信号与载波信号通过混频器时，I/Q两路信号间还会引入增益失配。最后经过混频器后的信号会输入到功率放大器中。所以此发射机中完成正交调制后但未送入功放时的模拟信号可表示为

$$\begin{aligned} X(t) = & F(t) * ((1 - \varepsilon)(S_I(t) + D_I)) \\ & \cdot \cos(\omega_c t - \varphi + \theta(t)) \\ & - F(t) * ((1 + \varepsilon)(S_Q(t) + D_Q)) \\ & \cdot \sin(\omega_c t + \varphi + \theta(t)) \end{aligned} \quad (1)$$

式中， $F(t)$ 为I/Q两路低通滤波器的系统时域冲激响应， ε 为I/Q两路信号的增益失配系数， $S_I(t)$ 和 $S_Q(t)$ 分别表示经过DAC后不含直流偏置的I/Q两路信号， D_I 和 D_Q 为I/Q两路信号的直流偏置量， ω_c 为本振频率， φ 为I/Q两路的相位失配， $\theta(t)$ 为相位噪声， $*$ 为卷积运算符。

在通信辐射源发射机中，功率放大器是主要的非线性器件，信号在经过功放时会产生一定的非线性特性^[7]，可以用泰勒多项式模型描述其系统响应函数：

$$\Phi(t) = \sum_{l=1}^P a_l X(t)^l \quad (2)$$

式中， a_l 是泰勒多项式系数， $X(t)$ 为输入功放的信号， P 为最大非线性阶数。其中，偶数次谐波分量会被后续的滤波器滤除，只有奇数次谐波分量会被保留。因此，发射机功放的输出信号可以表示为

$$y(t) = aX(t) + a_3X(t)^3 + a_5X(t)^5 + \dots \quad (3)$$

功率放大器产生的谐波分量间会产生大量互调分量，其中3阶互调分量对射频信号的影响最大^[8]，因此本文主要对3阶互调分量进行分析讨论，假定功放输出的3阶分量表示为

$$y_D^3 = a_3(V_x \cos \omega_x t + V_c \cos \omega_c t)^3 \quad (4)$$

进一步展开可以得到2个3阶互调分量，可表示为

$$\begin{aligned} y_{IM1}^3 &= a_3 V_x^2 V_c \cos(2\omega_x - \omega_c)t \\ y_{IM2}^3 &= a_3 V_x V_c^2 \cos(2\omega_c - \omega_x)t \end{aligned} \quad (5)$$

式中， ω_x 为射频信号频率， V_x 为射频信号的幅度， V_c 为耦合本振信号的幅度。

结合式(1)可以看出，式(5)所示2个3阶互调分量与图1中发射机产生细微特征的因素有关，其中

频率为 $2\omega_x - \omega_c$ 的3阶互调分量与射频信号的频率过于接近，位于发射信号带内，功率放大后的带通滤波器难以滤除，使得发射信号中存在非线性指纹特征，进而可以作为个体特征以识别不同的辐射源设备。

3 WOA-VMD算法

3.1 VMD基本原理

VMD的核心思想是将信号分解转化为构建和求解变分问题^[9]。设输入信号为 $f(t)$ ，VMD定义各阶本征模态分量(Intrinsic Mode Function, IMF)可以表示为

$$u_k(t) = A_k(t) \cos(\varphi_k(t)) \quad (6)$$

式中， $u_k(t)$ 表示 k 阶IMF分量， $A_k(t)$ 表示信号的瞬时幅值， $\varphi_k(t)$ 表示为相位函数。

计算解调梯度的平方范数作为信号带宽，求解公式为

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_{k=1}^K \left\| \partial(t) \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} & \sum_{k=1}^K u_k = f(t) \end{aligned} \quad (7)$$

式中， $(\delta(t) + j/(\pi t)) * u_k(t)$ 为各分量的解析信号， u_k 表示分解后的各IMF分量， ω_k 表示IMF分量的中心频率，其中 $k = 1, 2, \dots, K$ ， ∂_t 为 t 的偏导。

为了找到约束变分问题的最优解，引入增广拉格朗日函数可以将约束问题转换为非约束问题。

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) &= \alpha \sum_{k=1}^K \left\| \partial(t) \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ &+ \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 \\ &+ \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (8)$$

式中， $\lambda(t)$ 为拉格朗日乘法算子， α 为2次惩罚因子。为得到不同的分解模态和中心频率，连续交替更新 u_k^{n+1} ， ω_k^{n+1} ， λ^{n+1} 。当终止条件满足式(9)时，循环结束。其中 ε 为迭代误差门限值， $\varepsilon > 0$ 。

$$\frac{\sum_{k=1}^K \|U_k^{n+1}(\omega) - U_k^n(\omega)\|_2^2}{\|U_k^n(\omega)\|_2^2} < \varepsilon \quad (9)$$

式中， $U_k(\omega)$ 为 $u_k(t)$ 的傅里叶变换， ε 的取值范围通常为 $10^{-7} \sim 10^{-6}$ ^[9]，本文选取 $\varepsilon = 10^{-7}$ 。

3.2 WOA算法优化VMD

鲸鱼优化算法是采用随机或最佳搜索代理来追逐猎物的模拟狩猎行为，通过更新鲸鱼位置，计算每个鲸鱼的适应度进而求出全局最优解^[10]。其行为可以用式(10)数学模型描述

$$\left. \begin{aligned} \mathbf{R} &= |\mathbf{C} \cdot \mathbf{Y}^*(h) - \mathbf{Y}(h)| \\ \mathbf{Y}(h+1) &= \mathbf{Y}^*(h) - \mathbf{A} \cdot \mathbf{R} \end{aligned} \right\} \quad (10)$$

式中， \mathbf{R} 为猎物距离鲸鱼的位置参数； $\mathbf{Y}(h)$ 为 h 次迭代后鲸鱼的位置； $\mathbf{Y}^*(h)$ 为当前最好的鲸鱼位置， \mathbf{A} 和 \mathbf{C} 为系数向量。座头鲸在狩猎时采用螺旋状移动并逐渐缩小其包围圈。在该行为模型中，鲸鱼算法假设这两种方法发生的比例是1:1，数学模型描述为

$$\mathbf{Y}(h+1) = \begin{cases} \mathbf{Y}(h) - \mathbf{A} \cdot \mathbf{R}, & p < 0.5, |\mathbf{A}| < 1 \\ \mathbf{R}' \cdot e^{mn} \cdot \cos(2\pi n) + \mathbf{Y}^*(h), & p \geq 0.5 \end{cases} \quad (11)$$

式中，螺旋状常量为 m ； n 表示 $[-1,1]$ 的随机值； p 表示螺旋更新概率，取值范围为 $[0,1]$ 。此外，当 $p < 0.5$ 且 $|\mathbf{A}| > 1$ 时，鲸鱼还会随机地对猎物进行搜寻。

根据不同的鲸鱼位置信息不断地进行更新，可以得到全局最优解，进而找到VMD的最优参数组合。

$$N = \begin{cases} \mathbf{R} = |\mathbf{C} \cdot \mathbf{Y}_{ra} - \mathbf{Y}| \\ \mathbf{Y}(h+1) = \mathbf{Y}_{ra} - \mathbf{A} \cdot \mathbf{R} \end{cases} \quad (12)$$

式中， \mathbf{Y}_{ra} 表示鲸鱼的随机位置向量。

本文的WOA-VMD算法流程框图如图2所示，首先对鲸鱼种群向量位置进行初始化，并根据每个鲸鱼位置信息运用VMD对符号波形信号进行分解处理，其次计算每个鲸鱼个体所对应的样本熵值并记录最优个体位置，然后根据鲸鱼捕猎行为的不同对每个鲸鱼的适应度进行计算并更新迭代，最后在满足停止条件时输出全局最优解，得到VMD参数 $[K, \alpha]$ 的最优组合，完成WOA-VMD的优化过程。

4 基于CNN非线性特征提取与分类

4.1 熵特征提取

为了更好地理解非线性动力学系统的非线性特性以及能够更好地分析所提取出的非线性特征，在提取熵特征之前需要进行相空间重构^[11]。对于给定长度为 N 的辐射源信号 $x(n), n = 1, 2, \dots, N$ ，假设相空间的嵌入维数为 m ，时延为 τ ，信号经过相空间重构后的相空间矩阵为

$$\mathbf{X} = \begin{bmatrix} x(1) & x(1+\tau) & \dots & x(1+(m-1)\tau) \\ \vdots & \vdots & \vdots & \vdots \\ x(i) & x(i+\tau) & \dots & x(i+(m-1)\tau) \\ \vdots & \vdots & \vdots & \vdots \\ x(M) & x(M+\tau) & \dots & x(N) \end{bmatrix} \quad (13)$$

式中， $\mathbf{X}(i) = \{x(i), x(i+\tau), \dots, x(i+(m-1)\tau)\}$ ， $i = 1, 2, \dots, N - (m-1)\tau$ ， $M = N - (m-1)\tau$ 为相空间中点的个数。 τ 利用复自相关法可选定 $\tau = 1$ ，嵌入维数 m 的值根据提取的熵特征不同进行具体设定。

排列熵是一种用于分析时间序列数据复杂性的非线性动力学指标^[12]。其算法如下：

设时间序列 $\{x(n), n = 1, 2, \dots, N\}$ 经过相空间重构后，得到 m 个重构向量并按升序排序，进而得到

$$x(i+(j_1-1)\tau) \leq x(i+(j_2-1)\tau) \leq \dots \leq x(i+(j_q-1)\tau) \quad (14)$$

式中， j_q 代表重构元素在列中的索引。对于任何给定的 $\mathbf{X}(i)$ 都可以得到一组符号向量。

$$\mathbf{A}(l) = [j_1, j_2, \dots, j_m] \quad (15)$$

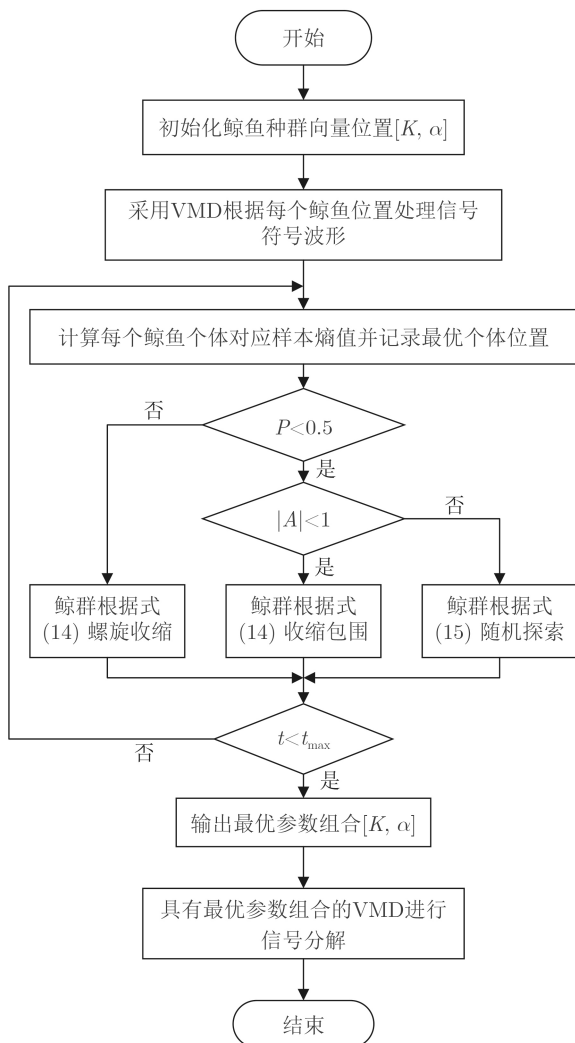


图2 WOA-VMD流程框图

在每组符号向量中共有 $m!$ 种排列顺序, 根据香农熵的定义可以得到排列熵(Permutation Entropy, PE)

$$E_P = - \sum_{j=1}^{m!} p_j \ln p_j \quad (16)$$

排列熵的值与嵌入维数 m 和时延 τ 有关。文献[7]建议 m 的值满足: $m! \leq N - m + 1$ 。

模糊熵是在熵的基础上引入了模糊隶属度函数, 将固定阈值替换为隶属度进行判定^[13]。其算法如下:

设长度为 N 的时间序列 X 进行相空间重构后, 得到的时间序列 Y 为

$$Y(i) = [x(i), x(i+1), \dots, x(i+m-1)] - x_0(i) \quad (17)$$

式中, $i = 1, 2, \dots, N - m + 1$, m 为嵌入维数, $x_0(i)$ 为均值。

定义两个时间序列 $Y(i)$ 与 $Y(j)$ 之间的距离为 $d_{i,j}^m$, 引入模糊隶属度函数, 可利用模糊函数计算时间序列 $Y(i)$ 与 $Y(j)$ 之间的相似度:

$$D_{i,j}^m(n, r) = \mu(d_{i,j}^m, n, r) = \exp\left(-\frac{(d_{i,j}^m)^n}{r}\right) \quad (18)$$

式中, $\mu(d_{i,j}^m, n, r)$ 为模糊函数, r 为相似容限度。定义函数

$$\phi^m(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{i,j}^m \right) \quad (19)$$

将维数变为 $m+1$, 重复之前步骤, 可得到 $\phi^{m+1}(n, r)$, 则其模糊熵(Fuzzy Entropy, FE)可表示为

$$E_F(m, n, r, N) = \ln \phi^m(n, r) - \ln \phi^{m+1}(n, r) \quad (20)$$

在计算模糊熵时, 根据前者经验取嵌入维数 $m=2$, r 为相似容限度, 取值为 $r = 0.2 \times \text{std}$, std 为 $x(n)$ 的标准差。 n 决定了相似容限度边界的梯度, n 的取值为较小的正整数, 如2或3。

图3(a)和3(b)分别为信噪比为10 dB且不经 WOA-VMD处理的条件下, 5个辐射源信号选取其100个符号样本得到的排列熵和模糊熵分布图。由图3可知, 5个辐射源信号的熵值能够相对明显地表征出不同辐射源之间的特性, 但是其熵值分布具有非均匀性, 且个别辐射源熵值之间过于接近, 其次不同理论的熵之间会存在冗余性, 进而会导致识别率下降。

4.2 分形维数特征提取

Katz维数是一种针对信号波形数据计算分形维数的方法^[14], 假设时间序列 $Z(N)$ 由点 (x_i, y_i) 组成, 其中 $i = 1, 2, \dots, N$, N 为信号长度, 其曲线长度可表示为

$$L = \sum_{i=1}^{N-1} \left(\sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \right) \quad (21)$$

进而求出初始点到最远点的距离

$$d = \max \left(\sqrt{(x_i - x_1)^2 + (y_i - y_1)^2} \right) \quad (22)$$

计算Katz维数为

$$FD = \frac{\log(N)}{\log(N) + \log(d/L)} \quad (23)$$

Higuchi通过对Burlage和Klein的算法进行修改, 提出了Higuchi分形维数^[15], 设一个长度为 N 的时间序列用延迟法重构时间序列得到

$$X_g^e = \left\{ X(e), X(e+g), \dots, X\left(e + \left[\frac{N-e}{g} \cdot g\right]\right) \right\}, \quad m = 1, 2, \dots, k \quad (24)$$

计算每一个 X_g^e 的曲线长度 $L_e(g)$

$$L_e(g) = \frac{1}{g} \left[\left(\sum_{i=1}^{\left(\frac{N-e}{g}\right)} |X(e+ig) - X(e+(i-1)g)| \right) \cdot \frac{N-1}{\left(\frac{N-e}{g}\right)g} \right] \quad (25)$$

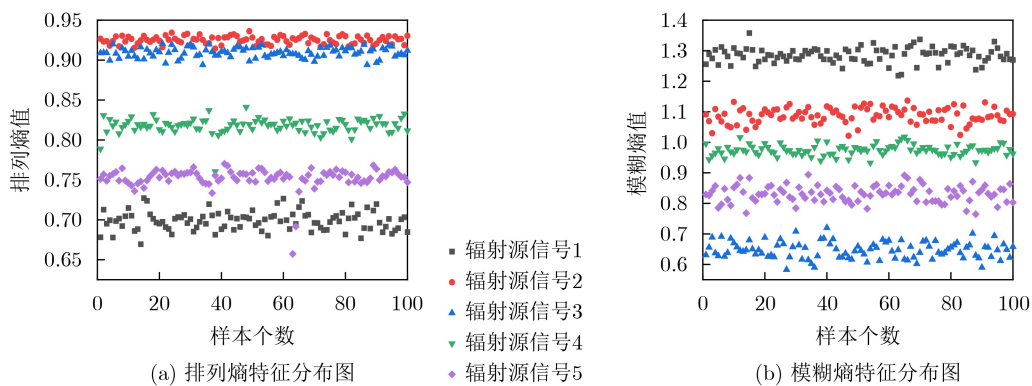


图3 5个辐射源信号熵特征分布图

总序列的曲线长度可以近似为 g 个延迟生成序列曲线长度的平均值。如式(26)所示

$$L(g) = \frac{1}{k} \sum_{e=1}^g L_e(g) \quad (26)$$

对曲线 $\ln(1/g) \sim \ln(L(g))$ 进行最小二乘法拟合,拟合后曲线的斜率即为Higuchi分形维数。

与图3提取熵特征的条件相同,图4(a)和4(b)分别为5个辐射源信号的Katz维数和Higuchi维数分布图。由图4可知,两种分形维数能够根据辐射源信号的不同而表征出不同的细微特征特性,与熵特征反映辐射源信号数值本身的复杂性不同,分形维数反映了其在形状上的复杂性变化。因此,从不同尺度上分析信号的复杂度,提取辐射源信号的熵特征和分形维数特征并组成多域联合特征向量,能够更好地识别通信辐射源设备。

4.3 基于CNN的分类识别

CNN模型在进行分类识别时,对非线性特征具有较强的表达能力。本文通过对通信辐射源信号进行预处理,并提取非线性特征组成多域非线性特征向量作为数据集,将其按8:1:1划分为训练集、验证集和测试集,然后输入卷积神经网络中进行识别。本文构建的卷积神经网络结构为:输入层、卷积层1、池化层1、卷积层2、池化层2、全连接层以及输出层。其中卷积层的激活函数为ReLU,正则化参数为0.0001,卷积核大小为 1×2 。Adam为网络优化器,学习率为0.001。最终输出预测概率分布,以分类识别通信辐射源个体。其整体流程框图如图5所示,首先利用WOA-VMD算法将通信辐射源符号波形信号分解出包含非线性指纹特征的高频信号分量,分别对其提取Higuchi维数和Katz维数以及经相空间重构后提取排列熵和模糊熵,并组成多域联合特征向量,其次将特征向量分为训练集、验证集、测试集,并将训练集输入CNN通过前向传播进行网络训练,计算损失函数后,利用反向传

播实现网络参数更新,依据验证集确定并保存最佳网络参数,最后利用训练好的CNN网络完成通信辐射源个体识别。

5 实验分析

5.1 数据集准备

本文使用调制方式为OFDM的数据集ORACLE^[6]。从数据集中选取5台发射机信号进行实验,其实验硬件平台CPU为Intel Core i9-13900HX,显卡型号为RTX 4060,软件平台包括MATLAB 2020b以及Pytorch深度学习框架。

5.2 算法性能分析

5.2.1 分解层数选取

信号经过WOA-VMD自适应分解后,由于考虑到辐射源信号的细微特征主要集中在高频分量,如果对所有信号分量进行特征提取,在增加算法复杂度的同时,还会使识别率下降。因此,本文通过计算分解后的信号分量与原始信号之间的相关性,设置相关阈值,进而从中选取合适的层数进行细微特征的提取。

表1表示根据相关阈值选取不同层数在不同信噪比下的识别准确率,其识别率是经过卷积神经网络分类识别统计得出的。根据表1可以看出选取6层分解信号能够得到最佳的识别效果。

5.2.2 特征提取分析

对本文选取的5个通信辐射源信号进行WOA-VMD预处理后,在信噪比为10 dB的条件下,对其提取熵特征(PE, FE),分形维数特征(Higuchi, Katz)。为了方便对不同特征进行分析,本文将得到的特征值进行归一化处理,并绘制箱线图如图6所示,其中横坐标1~5表示辐射源设备。图中的“·”为偏离值,实线的上端代表数据上边界,下端代表数据下边界,矩形内的横线表示数据的中位数,矩形的上下沿分别表示数据的3/4和1/4边界。

分析图6可得,辐射源设备1能够通过PE特征




图4 5个辐射源信号分形维数特征分布图

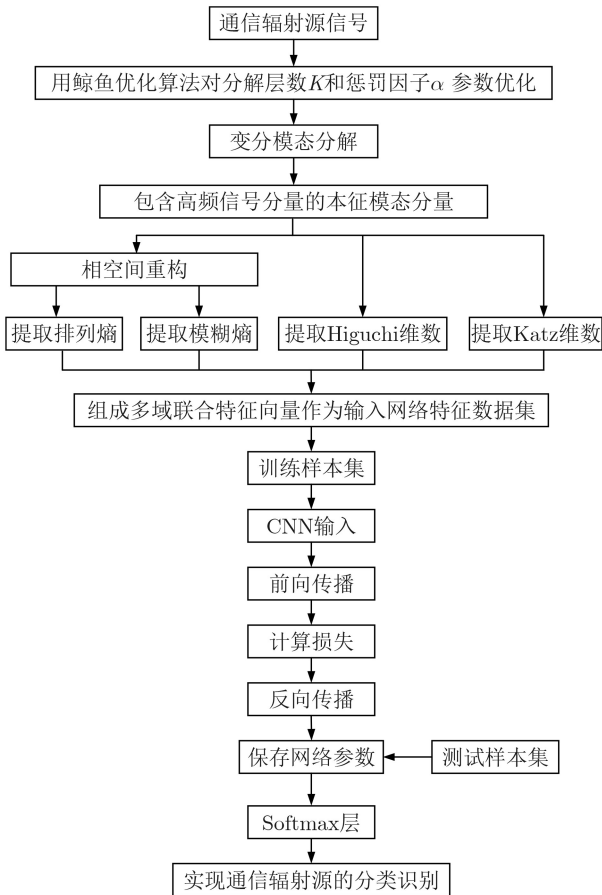


图5 通信辐射源个体识别算法流程图

表1 不同层数在不同信噪比下的识别率(%)

层数	信噪比SNR(dB)				
	-4 dB	-2 dB	0 dB	2 dB	4 dB
3	66.5	69.5	72.1	73.4	75.3
4	64.2	71	73.2	80.3	81
5	67.1	73.8	76	83.1	89
6	69.5	77.9	82	89.8	96.3
7	68.8	78	83.3	89.1	92.6




图6 5个OFDM辐射源信号对应的标准化特征值分布图

和FE特征分离出来；Katz维数和FE特征可以将辐射源设备2从5台辐射源中分离；FE特征和Higuchi维数同样能够将辐射源设备3完全分离；辐射源设备4可以相对容易地从5台辐射源中分离；辐射源设备5可以根据Higuchi维数与Katz维数得到很好的区分。因此，经上述特征分析，能够说明本文的特征提取方法可以将本实验中的5个辐射源设备完全区分。

5.2.3 识别性能分析

图7为本文方法测试集识别结果的混淆矩阵，通过对5个通信辐射源信号提取的特征进行分类识别，均能保持较高的识别准确率，全部测试数据集在不改变噪声的条件下最高准确率为97.8%。

为了验证本文方法的识别性能，将本文方法①WOA-VMD+多域特征与②无分解+多域特征、③WOA-VMD+熵特征(排列熵+模糊熵)、④WOA-VMD+分形维数(Higuchi、Katz)、⑤传统VMD($K=6$, $\alpha=2\ 000$)+多域特征进行对比实验，通过添加高斯白噪声的方式改变数据集信号的信噪比，进行多次重复实验，根据网络分类识别统计出识别结果的平均准确率，以减小误差对实验的影响。

分析图8可得，同样是提取多域非线性指纹特征，方法②直接提取原始信号中的非线性指纹特征无法充分表征通信辐射源的细微差异，识别效果不太理想。不论是方法③还是方法④，单一种类特征对不同的通信辐射源信号的表征能力具有局限性，不能全面地体现不同辐射源个体之间的细微特征差异性，识别效果不佳。与方法⑤对比，可以说明本文通过优化算法寻找VMD的最优参数组合比传统需要预先设定参数的VMD方法分解精度更高，更




图7 测试集混淆矩阵

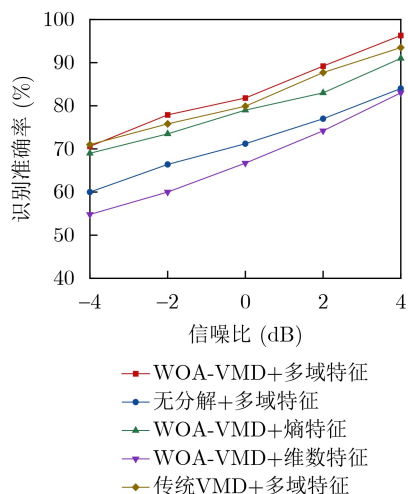


图8 不同信噪比下算法识别率对比曲线




图9 与现有方法的识别率对比曲线

能提取出辐射源信号的指纹特征，进而识别准确率更高。

5.3 对比实验结果及分析

在现有的基于提取通信辐射源设备非线性指纹特征的识别方法中，方法1对辐射源信号进行固有时间分解，然后提取近似熵、样本熵以及排列熵构成特征向量，最后通过支持向量机进行辐射源分类识别^[2]；方法2将辐射源信号的I/Q两路数据送入卷积神经网络中进行特征提取以及识别分类^[5]。方法3利用固定边界经验小波对辐射源信号进行分解，而后将子带信号送入卷积神经网络中进行分类识别^[6]。方法4直接提取多维排列熵作为射频指纹识别^[17]。方法5利用信号前导码的稳态部分，提取多维近似熵的非线性动力学指纹特征，最后利用支持向量机分类识别^[18]。方法6通过固有时间尺度分解之后，从分解的信号中提取峰度和偏度，然后利用支持向量机确定未知的辐射源设备^[19]。使用以上方法在保持训练样本和测试样本比例不变的条件下与本文方法进行对比实验，图9中各识别率是根据每个方法中的分类器统计得出的。

从图9可知，在信噪比为4 dB的条件下方法1对5个发射机的识别准确率为93.7%，方法2到方法6对5个发射机的识别率分别为90.7%，93.1%，92%，81.6%和86.3%。本文方法在信噪比为4 dB下的识别准确率为96.3%，并当信噪比从4 dB下降到-4 dB时，本文的识别方法仍能保持较高的识别率。由此可以说明提取信号分解之后的多域联合特征向量能够更准确地表征通信辐射源设备的指纹特征，并得到更好的识别性能。

6 结论

本文研究了通过提取通信辐射源的非线性指纹

特征进行通信辐射源个体识别的方法。在信号预处理阶段运用改进的变分模态分解使信号自适应地分解为若干个子信号，对其提取更深层次的特征信息。考虑到利用单域特征进行通信辐射源识别的精度不高，本文对经过分解的辐射源信号提取多域联合特征向量，结合卷积神经网络对通信辐射源个体进行分类识别。通过实验表明：在4 dB信噪比下对5个不同的辐射源个体进行识别可以达到96.3%的准确率。与现有方法的比较分析表明：该方法在低信噪比下的辐射源识别中，具有识别率高、抗噪性能好的特点，能够得到更好的识别性能。

参考文献

- [1] HUANG Guangquan, YUAN Yingjun, WANG Xiang, *et al.* Specific emitter identification based on nonlinear dynamical characteristics[J]. *Canadian Journal of Electrical and Computer Engineering*, 2016, 39(1): 34–41. doi: 10.1109/CJCE.2015.2496143.
- [2] 任东方, 张涛, 韩洁. 结合ITD与非线性分析的通信辐射源个体识别方法[J]. *信号处理*, 2018, 34(3): 331–339. doi: 10.16798/j.issn.1003-0530.2018.03.010.
REN Dongfang, ZHANG Tao, and HAN Jie. Approach of specific communication emitter identification combining ITD and nonlinear analysis[J]. *Journal of Signal Processing*, 2018, 34(3): 331–339. doi: 10.16798/j.issn.1003-0530.2018.03.010.
- [3] XIE Yang, WANG Shilian, ZHANG Eryang, *et al.* Specific emitter Identification based on nonlinear complexity of signal[C]. 2016 IEEE International Conference on Signal Processing, Communications and Computing, Hong Kong, China, 2016: 1–6. doi: 10.1109/ICSPCC.2016.7753733.
- [4] LU N, ZHOU T X, WEI J F, *et al.* Application of a whale optimized variational mode decomposition method based on envelope sample entropy in the fault diagnosis of rotating machinery[J]. *Measurement Science and Technology*, 2022,

- 33(1): 015014. doi: [10.1088/1361-6501/ac3470](https://doi.org/10.1088/1361-6501/ac3470).
- [5] ELMAGHBUB A and HAMD AOUI B. Leveraging hardware-impaired out-of-band information through deep neural networks for robust wireless device classification[J]. arXiv: 2004.11126, 2020. doi: [10.48550/arXiv.2004.11126](https://doi.org/10.48550/arXiv.2004.11126).
- [6] BREMNES K, MOEN R, YEDURI S R, *et al.* Classification of UAVs utilizing fixed boundary empirical wavelet sub-bands of RF fingerprints and deep convolutional neural network[J]. *IEEE Sensors Journal*, 2022, 22(21): 21248–21256. doi: [10.1109/JSEN.2022.3208518](https://doi.org/10.1109/JSEN.2022.3208518).
- [7] ZHANG Junqing, WOODS R, SANDELL M, *et al.* Radio frequency fingerprint identification for narrowband systems, modelling and classification[J]. *IEEE Transactions on Information Forensics and Security*, 2021, 16: 3974–3987. doi: [10.1109/TIFS.2021.3088008](https://doi.org/10.1109/TIFS.2021.3088008).
- [8] HUANG Yi, HU Aiqun, FAN Jiayi, *et al.* Joint estimation of transmitter IQ imbalance and nonlinearity with multipath in OFDM systems[C]. 2023 IEEE 98th Vehicular Technology Conference, Hong Kong, China, 2023: 1–6. doi: [10.1109/VTC2023-Fall60731.2023.10333512](https://doi.org/10.1109/VTC2023-Fall60731.2023.10333512).
- [9] DRAGOMIRETSKIY K and ZOSSO D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531–544. doi: [10.1109/TSP.2013.2288675](https://doi.org/10.1109/TSP.2013.2288675).
- [10] MIRJALILI S and LEWIS A. The whale optimization algorithm[J]. *Advances in Engineering Software*, 2016, 95: 51–67. doi: [10.1016/j.advengsoft.2016.01.008](https://doi.org/10.1016/j.advengsoft.2016.01.008).
- [11] ZAHID M U, NISAR M D, and SHAH M H. Radio frequency fingerprint extraction based on multiscale approximate entropy[J]. *Physical Communication*, 2022, 55: 101927. doi: [10.1016/j.phycom.2022.101927](https://doi.org/10.1016/j.phycom.2022.101927).
- [12] BANDT C and POMPE B. Permutation entropy: A natural complexity measure for time series[J]. *Physical Review Letters*, 2002, 88(17): 174102. doi: [10.1103/PhysRevLett.88.174102](https://doi.org/10.1103/PhysRevLett.88.174102).
- [13] CHEN Weiting, WANG Zhizhong, XIE Hongbo, *et al.* Characterization of surface EMG signal based on fuzzy entropy[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2007, 15(2): 266–272. doi: [10.1109/TNSRE.2007.897025](https://doi.org/10.1109/TNSRE.2007.897025).
- [14] KATZ M J. Fractals and the analysis of waveforms[J]. *Computers in Biology and Medicine*, 1988, 18(3): 145–156. doi: [10.1016/0010-4825\(88\)90041-8](https://doi.org/10.1016/0010-4825(88)90041-8).
- [15] SHAMSI E, AHMADI-PAJOUH M A, and SEIFI ALA T. Higuchi fractal dimension: An efficient approach to detection of brain entrainment to theta binaural beats[J]. *Biomedical Signal Processing and Control*, 2021, 68: 102580. doi: [10.1016/j.bspc.2021.102580](https://doi.org/10.1016/j.bspc.2021.102580).
- [16] SANKHE K, BELGIOVINE M, ZHOU Fan, *et al.* No radio left behind: Radio fingerprinting through deep learning of physical-layer hardware impairments[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2020, 6(1): 165–178. doi: [10.1109/TCCN.2019.2949308](https://doi.org/10.1109/TCCN.2019.2949308).
- [17] DENG Shouyun, HUANG Zhitao, WANG Xiang, *et al.* Radio frequency fingerprint extraction based on multidimension permutation entropy[J]. *International Journal of Antennas and Propagation*, 2017, 2017(1): 1538728. doi: [10.1155/2017/1538728](https://doi.org/10.1155/2017/1538728).
- [18] SUN Liting, WANG Xiang, YANG Afeng, *et al.* Radio frequency fingerprint extraction based on multi-dimension approximate entropy[J]. *IEEE Signal Processing Letters*, 2020, 27: 471–475. doi: [10.1109/LSP.2020.2978333](https://doi.org/10.1109/LSP.2020.2978333).
- [19] HE Boxiang and WANG Fanggang. Cooperative specific emitter identification via multiple distorted receivers[J]. *IEEE Transactions on Information Forensics and Security*, 2020, 15: 3791–3806. doi: [10.1109/TIFS.2020.3001721](https://doi.org/10.1109/TIFS.2020.3001721).
- 刘高辉: 男, 博士, 教授, 硕士生导师, 主要研究方向为通信信号处理、认知无线电、通信辐射源识别和无源探测等。
- 席宏恩: 男, 硕士生, 研究方向为通信辐射源个体识别。

责任编辑: 陈倩