

# 基于 VMD 和熵特征的雷达辐射源信号识别

杨洁,岳美君,曾耀平

(西安邮电大学通信与信息工程学院,陕西西安 710121)

**摘要:**将雷达信号的近似熵(ApEn)和范数熵(NoEn)提取出构成特征向量,用粒子群优化的支持向量机进行分类识别,得到结果发现对于相似的特征向量识别正确率较低。为了提高雷达辐射源个体的识别正确率,提出了一种基于变分模态分解(variational mode decomposition, VMD)和熵特征相结合的多维特征雷达辐射源信号识别方法。首先利用 VMD 算法对各雷达信号进行分解,得到两个本征模态组合函数,因为不同的雷达信号分解成各个模态的中心频率也是不同的,然后组合中心频率特征与近似熵、范数熵特征进行特征融合构成 4 维特征向量,最后使用粒子群支持向量机(particle swarm optimization support vector machine, PSOSVM)对辐射源信号进行识别。实验结果表明,经过特征融合构成的特征向量展示了更好的识别效果。集聚多种特征的识别优势来提升雷达辐射源信号识别准确率,相比于原来单一熵特征结合识别方法在分类效果上更具有优势。

**关键词:**变分模态分解;中心频率;特征融合;粒子群支持向量机;熵特征

**中图分类号:**TP301;TN957.51 **文献标识码:**A **文章编号:**1673-629X(2021)10-0013-05

**doi:**10.3969/j.issn.1673-629X.2021.10.003

## Radar Emitter Signal Recognition Based on VMD and Entropy Features

YANG Jie, YUE Mei-jun, ZENG Yao-ping

(School of Communication and Information Engineering, Xi'an University of Posts and Telecommunications, Xi'an 710121, China)

**Abstract:** The approximate entropy (ApEn) and norm entropy (NoEn) of the radar signal are extracted to form the feature vector, and the support vector machine optimized by particle swarm is used for classification and recognition. The result is that the recognition rate of similar feature vectors is low. In order to improve the recognition accuracy of individual radar emitters, a multi-dimensional feature radar emitter signal recognition method based on the combination of variational mode decomposition (VMD) and entropy features is proposed. First, the VMD is used to decompose each radar signal to obtain two eigenmode combination functions, because the center frequency of different radar signals decomposed into each mode is also different. Then the center frequency feature is fused with approximate entropy and norm entropy feature to form a 4-dimensional feature vector. Finally, particle swarm optimization support vector machine (PSOSVM) is used to identify the radiation source signal. The experiment shows that the feature vector composed of feature fusion has a better recognition effect. Integrating the recognition advantages of multiple features to improve the accuracy of radar emitter signal recognition is more advantageous than the traditional single entropy feature combined recognition method.

**Key words:** variational mode decomposition; center frequency; feature fusion; particle swarm support vector machine; entropy feature

## 0 引言

雷达辐射源信号识别分类技术一直是电子对抗领域中重点研究的课题方向。由于信号源特征未知、频率范围大和信号波形日益变化多端,雷达辐射信号的指纹特征就成为准确识别辐射源信号的重要因素。目前雷达体制越来越复杂,传统分析方法无法准确地对雷达信号进行特征提取。因此,近年来涌现出新的特

征提取方法,如变分模态分解(variational mode decomposition, VMD)是 Dragomireskiy 等<sup>[1]</sup>在 2014 年提出的一种新的自适应信号分解方法,经过预设模态分量的个数达到有效分离模态信号的目的,可以解决经验模态分解中存在的模态混叠和端点效应问题。国外学者<sup>[2-5]</sup>使用 VMD 对信号进行处理可以达到很好的分类效果。崔芮华等将 VMD 与近似熵结合应用在航空

收稿日期:2020-11-24

修回日期:2021-03-25

基金项目:陕西省重点研发计划项目(2020NY-161)

作者简介:杨洁(1976-),女,硕士,副教授,研究方向为信号处理及应用;通信作者:岳美君(1998-),女,硕士研究生,研究方向为信号处理技术及应用;曾耀平,硕士,副教授,研究方向为物联网技术及应用。

串联型电弧故障检测中,很好地抑制了模态混叠<sup>[6]</sup>。史丽敏将近似熵与能量熵用于电力变压器振动信号特征提取,取得了很好的效果<sup>[7]</sup>。万书亭等将 VMD 与样本熵用于对高压断路器振动信号进行特征提取,也达到了很好的识别效果<sup>[8]</sup>。

文中提出了基于 VMD 和熵特征结合的雷达辐射源个体识别法,该方法使用 VMD 算法得到雷达信号 2 个本征模态函数,得到 2 个模态的中心频率结合近似熵与范数熵组合成多维雷达特征送入粒子群支持向量机 (particle swarm optimization support vector machine, PSOSVM) 分类器进行分类识别,集聚多种特征的识别优势来提升雷达辐射源信号识别准确率,相比于原来单一熵特征结合识别方法在分类效果上更具有优势。针对辐射源指纹问题,未来对于多特征综合利用的想法会以促进原有特征的优势互补为出发点,来提高辐射源指纹特征对不同信号的分类性能<sup>[9]</sup>。

## 1 熵特征

### 1.1 近似熵

近似熵是 Pincus 于 1991 年从衡量时间序列复杂度的角度提出的, K 氏熵将近似熵定义为:相似向量在由  $m$  维增加至  $m+1$  维时其相似性的条件概率可以继续保持,物理意义是当维数发生变化时,时间序列中新模式诞生的概率,新模式越可能产生则序列也越复杂,近似熵就越大。近似熵的优点有:计算所需数据短, 1 000 个数据点适宜;在抗噪声和抗干扰方面有很好的表现;近似熵算法可用于确定性信号,随机信号及确定性信号和随机信号组成的混合信号。雷达辐射源信号内含有有用信号和噪声,有用信号是确定的,噪声是随机的,所以 ApEn 可以应用于判别雷达辐射源信号。

近似熵算法的步骤如下:

(1) 以等时间间隔进行采样得到  $N$  维的时间序列  $x(1), x(2), \dots, x(N)$ ;

(2) 定义算法相关参数  $m, r$ , 其中  $m$  为整数,表示比较向量的长度,  $r$  为实数,表示“相似度”的度量值;

(3) 重构一个  $m$  维向量,其  $X(i) = [x(i), x(i+1), \dots, x(i+m-1)]$ ;

(4) 对于  $1 < i < N - m + 1$ , 统计满足以下条件的向量个数:

$$C_i^m(r) = \frac{\sum d[X(i), X(j) \leq r]}{N - M + 1} \quad (1)$$

其中,  $d[X, X^*]$  定义为:  $d[X, X^*] = \max_a |x(a) - x^*(a)|$ 。

(5) 对符合条件向量取自然对数,再对所有的  $r$  求平均值,记为:

$$\Phi^m(r) = (N - m + 1)^{-1} \sum_{i=1}^{N-m+1} \log(C_i^m(r)) \quad (2)$$

(6) 近似熵 ApEn 定义为:

$$\text{ApEn} = \Phi^m(r) - \Phi^{m+1}(r) \quad (3)$$

选择的参数  $m$  和  $r$  会决定 ApEn 的值,通常取  $m = 2, r = 0.1 \sim 0.25 \text{ STD}$ , STD 为信号序列  $\{X(i)\}$  的标准差,此时近似熵有较合适的统计特性。若一个时间序列的规律性比较强,则其近似熵值 ApEn 比较小,相反则对应一个较大的熵值。

### 1.2 范数熵

脉内调制方式的不同会使雷达辐射源信号的频谱不同、信号能量分布和集中程度不同,在张葛祥<sup>[10]</sup>的研究中发现范数熵 NoEn 可以定量描述信号的能量分布情况。

设信号  $X = \{x(i), i = 1, 2, \dots, N\}, E_i = |x(i)|^p, 1 < p < 2$ , 则称:

$$\text{NoEn}(x) = \sum_{i=1}^N E_i = \sum_{i=1}^N |x(i)|^p \quad (4)$$

为信号  $X$  的范数熵 NoEn。

范数熵算法步骤如下:

(1) 信号预处理:对雷达信号  $\{x(i), i = 1, 2, \dots, M_1\}$  进行傅里叶变换,信号幅变谱是对称的,因此只考虑半边信号幅变谱  $\{x(i), i = 1, 2, \dots, N\}$ , 其中  $N = M/2$ ;

(2) 去噪声:在雷达信号  $x(i)$  中,雷达信号能量会集聚在一段较窄的频带内,同时噪声能量是均匀分布在频带上的,将  $M_x$  定为信号  $x(i)$  的均值,则去噪过程可表达为:

$$x_d(i) = \begin{cases} x(i) - M_x & x(i) > M_x \\ 0 & x(i) < M_x \end{cases} \quad i = 1, 2, \dots, N \quad (5)$$

(3) 将  $x_d(i)$  进行能量归一化处理,记为  $\{x_p(i), i = 1, 2, \dots, N\}$ ;

(4) 根据上式,可计算出 NoEn 的值,即:

$$\text{NoEn}(x_p) = \sum_{i=1}^N E_i = \sum_{i=1}^N |x_p(i)|^p \quad (6)$$

信号能量分布得越集中, NoEn 值就越大,反之,信号能量分布得越分散, NoEn 值就越小,这说明 NoEn 能充分反映信号能量分布情况。

## 2 变分模态分解算法

### 2.1 VMD 分解算法

VMD 算法用来确定模态分解个数,其自适应性通过确定序列给定的模态分解个数,算法在搜索和求解过程自适应地匹配每种模态的最佳中心频率和有限带宽,可以达到固有模态分量的有效分离、信号频域划分

的效果,继而得到给定信号的分解模态,最终求得变分问题的最优解。该算法的思路是将输入信号的实部分解为  $K$  个模态信号,在迭代求解变分过程中不断地更新每个模态分量  $u_k$ ,模态分量  $u_k$  的中心频率  $\omega_k$ ,最终实现信号的自适应分解<sup>[11]</sup>。

变分问题的数学表达式为:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \bullet u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t.} \quad \sum_k u_k = x(t) \end{cases} \quad (7)$$

引入增广的拉格朗日的好处是可以更严格实现约束,结合二次惩罚可以实现重建保真度:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \\ & \partial \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \bullet u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| x(t) - \sum_k u_k(t) \right\|_2^2 + \lambda(t), x(t) - \\ & \sum_k u_k(t) > \end{aligned} \quad (8)$$

上式非约束性变分问题是由 VMD 算法中采用交替方向乘子(ADMM)解决,再通过循环求解  $u_k^{n+1}$ 、 $w_k^{n+1}$  和  $\lambda^{n+1}$  得到扩展拉格朗日表达式的“鞍点”<sup>[12]</sup>。

### 2.2 VMD 分解 LFM 信号

文中 LFM 信号的脉冲宽度为 1 000 s,载波频率为 10 MHz,带宽为 4 MHz,采样频率为 90 MHz,使用加入相位噪声的 LFM 信号进行 VMD 分解。VMD 算法就是将信号分解为需要的模态,并且对于不同的信号,分解后模态提取的信号特征是不同的。

图 1 依次是辐射源信号经过 VMD 分解后的时域波形图及经过 VMD 分解得到两个模态分量的波形图<sup>[13]</sup>。




图 1 LFM 信号 VMD 分解图

以 LFM 信号 VMD 分解图为例,经过 VMD 模态分解后得到两个子信号,其频谱的中心频率就反映了辐射源信号的指纹特征。VMD 的重建模态构成了输入信号频谱的一个很好的分区,每种模态在其各自的中心频率附近都占据优势,两种模态显现出很好的区分性。

### 3 PSOSVM

SVM 使用距离最优决策超平面最近的样本数据刻画出样本数据范围空间,正例标签  $y = 1$ ,负例标签  $y = -1$ ,点到平面的距离公式为:

$$d = \frac{|\mathbf{w}^T \cdot \mathbf{x} + \mathbf{b}|}{\|\mathbf{w}\|} \quad (9)$$

$$y \cdot (\mathbf{w}^T \cdot \mathbf{x} + \mathbf{b}) \geq 1 \quad (10)$$

式(10)即可表示正例,负例标签代表的空间。

任一类数据到分隔实线的距离关系为:

$$\frac{|\mathbf{w}^T \cdot \mathbf{x} + \mathbf{b}|}{\|\mathbf{w}\|} \geq \frac{1}{\|\mathbf{w}\|} \quad (11)$$

即两类数据分隔开的最近距离表达式为  $\frac{2}{\|\mathbf{w}\|}$ 。

SVM 要做的就是使得分隔开的距离最大化,因此得出优化方程为:

$$\begin{cases} \min_{\mathbf{w}, \mathbf{b}} \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{s. t.} \quad y_i (\mathbf{w} \cdot \mathbf{x}_i + \mathbf{b}) \geq 1, i = 1, 2, 3 \dots \end{cases} \quad (12)$$

利用拉格朗日乘数法构建函数:

$$\begin{aligned} L(\mathbf{w}, \mathbf{b}, a) = & \frac{1}{2} \|\mathbf{w}\|^2 - \\ & \sum_{i=1}^n a_i [y_i (\mathbf{w} \cdot \mathbf{x}_i + \mathbf{b}) - 1] \end{aligned} \quad (13)$$

求偏导:

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^n a_i y_i \mathbf{x}_i \\ \frac{\partial L}{\partial \mathbf{b}} = 0 \Rightarrow \sum_{i=1}^n a_i y_i = 0 \end{cases} \quad (14)$$

因此在约束条件下  $\sum_{i=1}^n a \cdot y = 0$ ,权向量  $\mathbf{w} = \sum_{i=1}^n a \cdot y \cdot \mathbf{x}$  就实现分类间隔最大。求解  $\mathbf{b} = y - \mathbf{w}^T \cdot \mathbf{x}$ ,即分类决策函数为:

$$\begin{aligned} f(\mathbf{x}) = & \text{sgn}(\mathbf{w}^T \cdot \mathbf{x} + \mathbf{b}) = \\ & \text{sgn}\left(\sum_{i=1}^n y \cdot a \cdot \mathbf{x}^T \cdot \mathbf{x} + \mathbf{b}\right) \end{aligned} \quad (15)$$

PSO 粒子群优化算法主要是通过群体中个体之间的协作和信息共享来寻找最优解。PSO 初始化为一群随机粒子,通过迭代找到最优解,每个粒子都会跟踪两个“极值”来更新自己,一个是个体极值 pBest,另一个是全体极值 gBest<sup>[14]</sup>。

更新公式为:

$$\begin{aligned} V_{i+1} = & w \cdot V_i + c_1 \text{random}(0,1) (pBest - X_i) + \\ & c_2 \text{random}(0,1) (gBest - X_i) \end{aligned} \quad (16)$$

$$X_i = X_i + V_{i+1} \quad (17)$$

其中,  $w$  称为惯性因子,  $c_1$  和  $c_2$  称为加速常数,  $\text{random}(0,1)$  表示区间  $[0,1]$  上的随机数,  $X_i$  是粒子的当前位置。

用 PSO 算法的全局搜索优化,对雷达辐射源识别

分类器的参数进行了优化,克服了支持向量机难以获得合理参数的缺陷,提升了雷达辐射源的识别分类效果。

## 4 实验结果分析

### 4.1 信号建模

文中根据相位噪声单边带功率谱密度指标,通过多项式拟合出单边带功率谱估计值,得到相位噪声的拟合曲线,如图 2 所示。

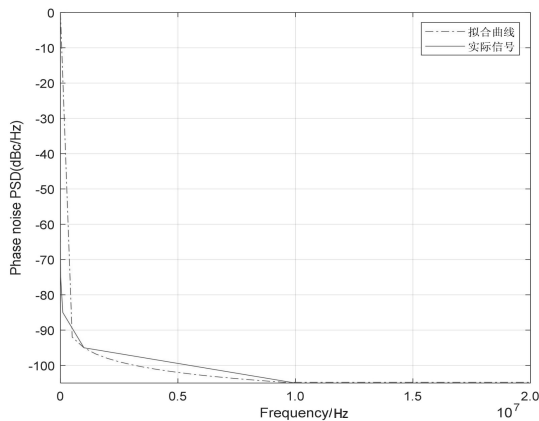


图 2 相位噪声曲线

对相位噪声进行建模仿真,同时在频谱中加入随机噪声以更好地模仿实际的雷达辐射源信号。以 LFM 为例,LFM 信号的表达式为:

$$S(t) = A \sin(2\pi f_c t + k\pi t^2 + \varphi_0), 0 \leq t \leq T \quad (18)$$

相位噪声  $\varphi(t)$  可表示为:

$$\varphi(t) = M \sin(2\pi f_m t) \quad (19)$$

将  $\varphi(t)$  带入 LFM 信号并展开:

$$S(t) = A \sin(2\pi f_c t + k\pi t^2) \cos(M \sin(2\pi f_m t)) + A \cos(2\pi f_c t + k\pi t^2) \sin(M \sin(2\pi f_m t)) \quad (20)$$

将贝塞尔函数取近似值为:

$$M \rightarrow 1, J_0(M) = 1, J_1(M) = \frac{M}{2}, J_n \approx 0, n \geq 2 \quad (21)$$

LFM 信号的相位噪声看作很多个  $M_n$  随机组成,则含有噪声 LFM 信号为:

$$S(t) = A \sin(2\pi f_c t + k\pi t^2) + \sum_{n=1}^{\infty} \frac{M_n}{2} A \sin[2\pi(f_c + \frac{kt}{2} + f_n)t] - \sum_{n=1}^{\infty} \frac{M_n}{2} A \sin[2\pi(f_c + \frac{kt}{2} - f_n)t] \quad (22)$$

### 4.2 算法流程

算法流程如图 3 所示。

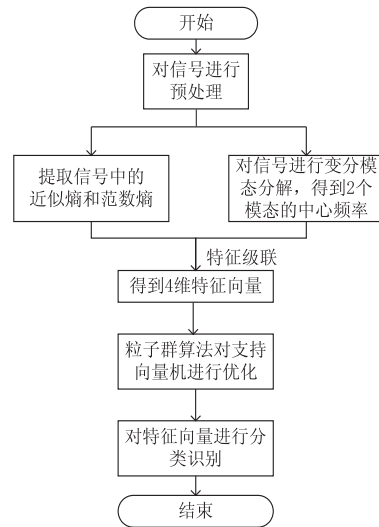


图 3 算法流程

文中首先仿真加入相位噪声的雷达辐射源信号,在信号中提取近似熵和范数熵的特征向量,将近似熵 (ApEn) 和范数熵 (NoEn) 和经过变分模态算法分解得到的 2 维模态中心频率相结合构成 4 维特征向量,用粒子群算法优化的支持向量机进行分类识别。

### 4.3 熵特征分类结果

由图 4 得,标签 1 是 LFM 信号,标签 2 是正弦载波信号,标签 3 是 Bpsk 信号。如图所示,仅通过近似熵和范数熵组成的熵特征对信号进行分类,图 4 中正弦载波信号与 Bpsk 信号并没有很好地区分开。这也说明单一特征不利于区分一些调制方法比较相像的信号,所以采用相似的熵特征向量很容易发生错误判断。当存在多种雷达辐射信号时,可能使用单一特征作为分类依据的识别率不高,所以文中结合变分模态算法分解得到的模态中心频率进行特征融合。利用将不同类型特征结合的朴素思想,最简单的就是将不同的特征的优势结合在一起,形成一个新的多维特征向量就会达到更好的效果<sup>[15]</sup>。

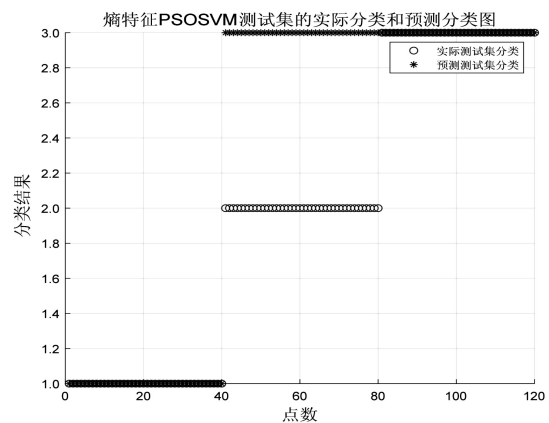


图 4 熵特征分类结果

### 4.4 特征融合分类结果

由图 5 得,在相同的信噪比、相位噪声和信号参数

下,将近似熵和范数熵与 VMD 分解模态的中心频率相结合送入向量机中进行分类,通过对比可以发现特征结合方法可以正确将正弦载波信号与 Bpsk 信号区分开,信号判别正确率提高,说明当前结合多种特征的方法对于当前雷达信号样本分类是有效的。可以看到集聚不同辐射源信号的多种特征可以更好地提高雷达辐射源信号识别准确率,相对原来的单一熵特征结合识别方法准确率明显提高了。从指纹特征中找到能作为识别与分类性能较好的特征,可以获得更高的识别率。特征方法的综合利用,可以发挥不同类别指纹特征对辐射源指纹不同角度刻画能力。

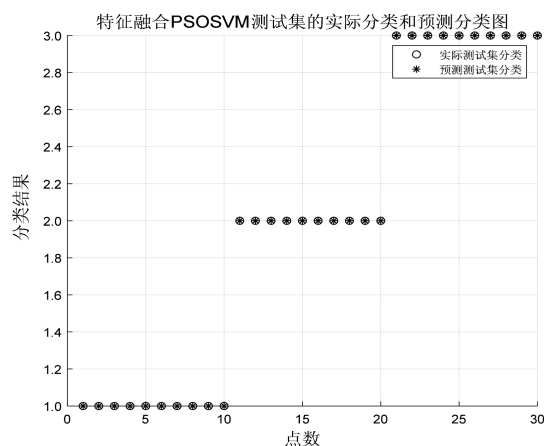


图 5 特征融合分类结果

## 5 结束语

文中提出了基于 VMD 和熵特征组合的雷达辐射源个体识别法。首先对加入相位噪声的雷达信号进行信号预处理,再提取雷达信号的近似熵特征和范数熵特征,同时对每类信号进行 VMD 分解得到 2 个模态子信号,得到 2 个模态信号的中心频率结合两种熵特征组成 4 维雷达特征向量,输入到 PSOSVM 分类器进行分类识别。

仿真结果表明,通过对比只使用熵特征对雷达信号分类识别的方法,文中所用的多维特征的方法能大幅度提升识别率,特征方法合理地进行综合利用可以达到更好的分类效果。关于雷达信号的分类问题,在雷达信号的指纹特征中筛选出识别与分类性能较好的特征,如何结合多种指纹特征的优点以获得更高的识别率将成为十分具有研究意义的工作。

## 参考文献:

- [1] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [2] GENG Qi, WEN Yinghong, LIU Shanghe, et al. A VMD based improved de-noising of onboard BTM receiving signal [J]. Chinese Journal of Electronics, 2020, 29(1): 66-72.
- [3] XIAO Feiyun, YANG Decai, GUO Xiaohui, et al. VMD-based denoising methods for surface electromyography signals [J]. Journal of Neural Engineering, 2019, 16(5): 056017.
- [4] LUO Derong, WU Ting, LI Ming, et al. Application of VMD and Hilbert transform algorithms on detection of the ripple components of the DC signal [J]. Energies, 2020, 13(4): 935-955.
- [5] BI Xiaobo, LIN Jiansheng, TANG Daijie, et al. VMD-KF-CM algorithm for the fault diagnosis of diesel engine vibration signals [J]. Energies, 2020, 13(1): 228-248.
- [6] 崔芮华, 王传宇, 王洋. VMD-ApEn 在航空交流串联型电弧故障检测中的应用 [J]. 电机与控制学报, 2020, 24(8): 141-149.
- [7] 史丽敏. 基于 ApEn 和 EMD 能量熵的电力变压器振动信号特征仿真研究 [J]. 自动化技术与应用, 2019, 38(10): 98-102.
- [8] 万书亭, 豆龙江, 李聪, 等. 基于 VMD 和样本熵的高压断路器故障特征提取及分类 [J]. 振动与冲击, 2018, 37(20): 32-38.
- [9] 孙丽婷, 黄知涛, 王翔, 等. 辐射源指纹特征提取方法述评 [J]. 雷达学报, 2020, 9(6): 1014-1031.
- [10] 张葛祥, 胡来招, 金炜东. 基于熵特征的雷达辐射源信号识别 [J]. 电波科学学报, 2005, 20(4): 440-445.
- [11] 李亚兰, 金炜东, 葛鹏. 基于 VMD 和特征融合的辐射源信号识别 [J]. 系统工程与电子技术, 2020, 42(7): 1499-1503.
- [12] 张忠民, 刘刚. 基于 VMD 和 ABC-SVM 的雷达辐射源个体识别 [J]. 哈尔滨商业大学学报: 自然科学版, 2020, 36(2): 176-182.
- [13] 吴莹. 雷达辐射源指纹特征提取和识别技术研究 [D]. 西安: 西安电子科技大学, 2018.
- [14] 杨倩, 孙双林. 基于粒子群优化算法的雷达辐射源识别 [J]. 激光杂志, 2018, 39(2): 118-121.
- [15] 金秋, 王宏艳, 马方方. 雷达辐射源分类识别方法综述 [J]. 电讯技术, 2019, 59(3): 360-368.