

## 基于改进 VMD 和 TWSVM 的雷达辐射源个体识别

蒋 闯<sup>1</sup>

JIANG Chuang

## 摘 要

为提高雷达辐射源个体在不同信噪比下的识别准确率, 提出基于改进 VMD 和 TWSVM 的雷达辐射源个体识别方法。首先利用斑马优化算法 (ZOA) 优化变分模态分解 (VMD) 过程, 找到最优分解参数组合; 然后通过奇异值分解对辐射源信号经变分模态分解后得到的各模态分量进行二次特征提取, 选取奇异值作为个体特征组成特征向量; 最后送入孪生支持向量机 (TWSVM) 中, 完成分类识别。通过线性调频信号的仿真建模实验, 初步验证了算法的可行性。再通过 5 部信号源所采集的实测数据验证, 信噪比为 15 dB 时, 识别效果已十分理想, 可达 94% 以上的识别率。

## 关键词

雷达辐射源个体识别; 斑马优化算法; 变分模态分解; 奇异值分解; 孪生支持向量机

doi: 10.3969/j.issn.1672-9528.2024.05.022

## 0 引言

雷达辐射源个体识别技术是一种通过采集辐射源自身的无意调制信息, 提取信号主成分外的细微特征, 再对比已有数据来确定辐射源个体的技术<sup>[1-2]</sup>。变分模态分解 (variational mode decomposition, VMD) 能够根据实际输入的信号, 自适应地进行分解, 分解后每个分量拥有各自的中心频率, 分量之间不存在混叠, 故分离效果良好<sup>[3]</sup>。翟金秀等人<sup>[4]</sup>利用麻雀搜索算法优化 VMD, 提取模态分量的排列熵特征, 用于粘弹夹层结构老化的识别。单玉庭等人<sup>[5]</sup>利用遗传算法全局寻优的优点, 优化 VMD 参数寻优过程, 对模态分量进行包络解调, 用于轴承故障特征的提取。马愈昭等人<sup>[6]</sup>利用鸮鹗算法优化 VMD, 并引入多尺度排列熵判决机制筛选信号组成重构信号, 实现信号降噪。

本文通过将斑马优化算法 (zebra optimization algorithm, ZOA) 用于 VMD 过程, 实现分解参数组合的自动寻优。再利用奇异值分解 (singular value decomposition, SVD) 提取模态分量的奇异值组成特征向量, 送入孪生支持向量机 (twin support vector machine, TWSVM) 中完成分类识别。

## 1 基础理论

## 1.1 VMD 基本原理

在变分模态分解过程中, 需要确定信号的每一个模态分量, 并对其进行调制, 具体公式<sup>[7]</sup>为:

$$\left[ \left( \delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \quad (1)$$

式中:  $t$  为时间;  $\delta(t)$  为冲击函数;  $u_k(t)$  表示信号分解获得的模态分量;  $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$  表示各模态分量  $u_k(t)$  的中心频率。实际分解过程中, 每个分量的中心频率及带宽在不断修正更新, 故可将变分模态分解问题转换为以获得最优带宽为目标的带宽约束优化问题, 约束变分表达式为:

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

式中:  $\{u_k\} = \{u_1, u_2, \dots, u_k\}$  表示模态分量的集合;  $\partial$  表示求导操作。引入惩罚项及拉格朗日乘法算子, 得到扩展后的拉格朗日表达式为:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) &= \alpha \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ &+ \left\| x(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), x(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (3)$$

经  $n+1$  次迭代, 傅里叶变换映射到频域后的模态分量、中心频率、拉格朗日乘子的迭代求解公式分别为:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{x}(\omega) - \sum_{j \neq k} \hat{u}_j(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (4)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (5)$$

$$\hat{\lambda}^{n+1}(\omega) = \lambda^n(\omega) + \tau \left[ \hat{x}(\omega) - \sum_{k=1}^K \hat{u}_k^{n+1}(\omega) \right] \quad (6)$$

令  $\lambda^1 = n = 0$  初始化模态分量与中心频率, 根据公式 (4)、公式 (5) 迭代更新  $\hat{u}_k$ 、 $\omega_k$ , 根据公式 (6) 迭代更新  $\hat{\lambda}$ , 并以公式 (7) 作为迭代终止条件:

$$\sum_{k=1}^K \frac{\|\hat{u}_k^{n+1} - u_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} \quad (7)$$

迭代完成, 得到信号分解后的模态分量和中心频率。在实际情况下, 模态数  $K$  和二次惩罚因子  $\alpha$  设置过大或过小, 会引起过分解或欠分解的情况。因此, 可通过群集智能算法对  $K$  与  $\alpha$  值自动寻优, 以快速准确地获得最优分解参数组合。

## 1.2 斑马优化算法

本文提出基于斑马优化算法 (ZOA) 实现 VMD 参数组合的自动寻优。ZOA 原理源于斑马的觅食和防御策略, 模拟斑马的行为来搜索最优解, 每一次迭代生成一组候选解, 这些解被称为“斑马”, 斑马间通过互相交流信息协作, 寻找更优的解<sup>[8]</sup>。在寻优空间里随机初始化种群的公式为:

$$x_{i,j} = l_j + r \times (u_j - l_j) \quad (8)$$

式中:  $x_{i,j}$  为个体;  $l_j$ 、 $u_j$  为寻优上、下边界;  $r$  为 [0,1] 间的随机数。

第一阶段, 觅食行为。根据斑马在草原上寻找野草的行为, 种群中最好的斑马被认为是先锋, 会引导种群内的其他成员走向该位置, 更新斑马新的觅食位置的公式为:

$$x_{i,j}^{new,P1} = x_{i,j} + r \times (P_j - I \times x_{i,j}) \quad (9)$$

$$X_i = \begin{cases} X_i^{new,P1}, & F_i^{new,P1} < F_i \\ X_i, & \text{else} \end{cases} \quad (10)$$

式中:  $x_{i,j}^{new,P1}$  表示经过第一阶段后斑马的新位置;  $x_{i,j}$  表示斑马原位置;  $r$  为 [0,1] 间的随机数;  $P_j$  表示第  $j$  轮的先锋斑马, 即群体内最优的斑马位置;  $I$  为 [1,2] 间的随机数;  $F_i^{new,P1}$  表示第一阶段新位置的目标函数值;  $F_i$  表示当前未知的目标函数值。

第二阶段, 防御策略。该阶段是模拟斑马对捕食者的防御策略, 根据攻击对象的不同, 斑马会选择不同的防御策略: 遇到狮子, 斑马群体会选择逃跑策略; 遇到其他动物, 斑马群体会选择进攻策略, 向受攻击的斑马移动, 并试图建立防御体系。在 ZOA 过程中, 假设上述两种情况以相同的概率发生, 用公式 (11) 和 (12) 模拟两种情况分别建模:

$$x_{i,j}^{new,P2} = \begin{cases} S_1: x_{i,j} + R \times (2r - 1) \times \left(1 - \frac{t}{T}\right) \times x_{i,j}, & P_s \leq 0.5 \\ S_2: x_{i,j} + r \times (AZ_j - I \times x_{i,j}), & \text{else} \end{cases} \quad (11)$$

$$X_i = \begin{cases} X_i^{new,P2}, & F_i^{new,P2} < F_i \\ X_i, & \text{else} \end{cases} \quad (12)$$

式中:  $x_{i,j}^{new,P2}$  表示经过第二阶段后斑马的新位置;  $x_{i,j}$  表示斑马原位置;  $R$  表示控制系数, 一般为 0.01;  $r$  为 [0,1] 间的随机数

$t$  表示当前迭代轮数;  $T$  表示最大迭代数;  $P_s$  表示两种策略的切换概率;  $A_j$  表示第  $j$  轮中随机选中被攻击的斑马;  $I$  为 [1,2] 间的随机数;  $F_i^{new,P2}$  表示第二阶段新位置的目标函数值,  $F_i$  表示当前未知的目标函数值。通过上述两个阶段, 每轮迭代每个斑马, 更新解决方案, 可逐渐收敛到最优解, ZOA 的具体流程如图 1 所示。




图 1 斑马优化算法流程图

## 1.3 基于 ZOA 的 VMD 参数优化

利用斑马优化算法进行寻优, 首先需要有一个目标函数来进行优化, 通过计算目标函数值并进行最优比较, 实现寻优操作。本文以包络熵为基准, 将其作为适应度函数, 具体计算公式为:

$$E_p = - \sum_{i=1}^N p_i \lg p_i \quad (13)$$

$$p_i = b_i / \sum_{i=1}^N b_i \quad (14)$$

式中:  $b_i$  表示包络信号,  $p_i$  为包络信号的归一化值。包络熵主要衡量信号的稀疏特性, 包络熵的值越大, 信号稀疏性越弱, 说明信号越分散, 模态分量混叠的可能性越高; 若包络熵的值越小, 信号稀疏性越强, 主要集中在模态分量中, 混叠的可能性越低。本文利用斑马优化算法来求取使包络熵最小时的模态数  $K$  和二次惩罚因子  $\alpha$  值。

ZOA-VMD 的具体步骤如下。

步骤 1: 设置斑马算法的基本参数, 包括斑马数量、最大迭代数; 设置分解模态数  $K$  与二次惩罚因子  $\alpha$  的最小值和最大值。

步骤 2: 按照斑马数量, 随机生成模态数  $K$  和二次惩罚因子  $\alpha$  值, 计算每个  $K$  和  $\alpha$  值下所获得的模态分量的包络熵, 最小者作为先锋斑马。

步骤 3: 使用斑马优化算法觅食行为, 更新各个斑马的  $K$  和  $\alpha$  值。

步骤 4: 利用斑马优化算法的防御行为, 再次更新各个斑马的  $K$  和  $\alpha$  值。各个斑马按新的  $K$  和  $\alpha$  值进行变分模态分解, 再次计算目标函数值, 重复步骤 3 ~ 4, 直到满足迭代终止条件, 得到最优的模态数  $K_0$  和二次惩罚因子  $\alpha_0$ 。

步骤 5: 利用  $K_0$  和  $\alpha_0$  进行变分模态分解, 获得不同的模态分量。

#### 1.4 奇异值分解

奇异值分解是一种非线性滤波过程, 奇异值可分别代表信号经 VMD 后所得不同模态对无意调制特征的贡献, 每个模态分量的能量与奇异值大小成正比, 有如下矩阵公式<sup>[9]</sup>:

$$Y = \begin{bmatrix} u_1(1) & u_1(2) & \dots & u_1(t) \\ u_2(1) & u_2(2) & \dots & u_2(t) \\ \vdots & \vdots & \ddots & \vdots \\ u_k(1) & u_k(2) & \dots & u_k(t) \end{bmatrix} \quad (15)$$

式中:  $Y \in \mathbf{R}^{K \times t}$  为模态分量矩阵, 行向量代表每个模态分量, 其长度为  $t$ 。对矩阵  $Y$  进行奇异值分解, 公式如下:

$$Y = SAV^H \quad (16)$$

式中: 左、右奇异矩阵  $S \in \mathbf{R}^{K \times K}$ ,  $V \in \mathbf{R}^{t \times t}$ , 满足  $SS^H = I$ ,  $VV^H = I$ ;  $K \times t$  矩阵  $A$  的主对角线只有非负数和实数, 其元素  $A_{i,j}$  为第  $i$  个最大奇异值  $\lambda_i (1 \leq i \leq t)$ , 对角线上元素满足  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_t \geq 0$ 。本文选取 SVD 中前两个较大奇异值  $\lambda_1, \lambda_2$  作为信号经 VMD 所得模态分量的二次特征。

#### 1.5 孪生支持向量机

在实际工程应用中, 研究发现支持向量机采用二次规划求解, 在寻找两个平行的超平面时, 计算量大、计算时间长且占用大量内存。针对此问题, 本文选取孪生支持向量机作为分类识别器, 将传统支持向量机的大分类问题转变为两个小分类问题, 寻找两个非平行的超平面来分离数据, 能够有效减少求解的约束条件, 从而降低训练速度, 提高支持向量机的计算性能和泛化能力<sup>[10]</sup>。

## 2 仿真实验

### 2.1 无意调制建模

线性调频信号 (LFM) 是雷达系统常用的一种调制信号, 其特点是频率随时间呈现线性的变化, 具体表达式为<sup>[11]</sup>:

$$x(t) = A(t) \sin(2\pi f_c t + k\pi t^2 + \varphi_0), 0 \leq t \leq T \quad (17)$$

式中:  $A(t)$  表示信号的幅度, 其大小变化相对较小, 可以看作是某一特定常数  $A$ ;  $f_c$  表示信号的中心频率;  $k$  为频率的变化速率;  $\varphi_0$  为信号的初始相位。

若信号的初始相位  $\varphi_0 = 0$ , 则线性调频信号加入相位噪声后, 公式如下:

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

式中:  $\varphi(t)$  为加入的相位噪声, 可表示为:

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

式中:  $M_m$  为调相系数;  $f_m$  为频率分量。将式 (19) 代入式 (18) 中, 并利用三角函数公式, 得到:

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

利用贝塞尔函数进行展开, 式 (20) 可近似表示为:

$$\cos(M_m \sin(2\pi f_m t)) = J_0(M_m) \quad (21)$$

$$+ 2 \sum_{n=1}^{\infty} J_{2n}(M_m) \cos(2n \cdot 2\pi f_m t) \sin(M_m \sin(2\pi f_m t)) = 2 \sum_{n=1}^{\infty} J_{2n-1}(M_m) \sin[(2n-1) \cdot 2\pi f_m t] \quad (22)$$

式中:  $J_n(M_m)$  表示  $M_m$  的  $n$  阶贝塞尔函数, 其公式为:

$$J_n(M_m) = \sum_{k=0}^{\infty} \frac{(-1)^k}{k!(n+k)!} \left(\frac{M_m}{2}\right)^{n+2k} \quad (23)$$

可将  $M_m$  的 0 阶和  $n$  阶贝塞尔函数表示为:

$$J_0(M_m) = 1 - \left(\frac{M_m}{2}\right)^2, \quad (24)$$

$$J_n(M_m) = \frac{1}{n!} \left(\frac{M_m}{2}\right)^n (n \geq 1)$$

由于相位噪声的系数相对较小, 根据贝塞尔函数的定义, 当  $M_m \leq 1$  时, 有:

$$J_0(M_m) = 1, J_1(M_m) = \frac{M_m}{2} \quad (25)$$

$$J_n(M_m) = 0 (n \geq 2)$$

将式 (21) ~ (25) 代入式 (20) 中, 得到:

$$x(t) = A \sin(2\pi f_c t + k\pi t^2) + \frac{M_m}{2} A \cos\left[2\pi\left(f_c + \frac{kt}{2} + f_m\right)t\right] - \frac{M_m}{2} A \sin\left[2\pi\left(f_c + \frac{kt}{2} - f_m\right)t\right] \quad (26)$$

式 (26) 表示一组相位噪声对线性调频信号的影响, 而实际情况是多组相位噪声叠加影响, 故总的线性调频信号添加无意调制相位噪声的信号模型表示为:

$$x(t) = A \sin(2\pi f_c t + k\pi t^2) + \sum_{m=1}^{\infty} \frac{M_m}{2} A \sin\left[2\pi\left(f_c + \frac{kt}{2} + f_m\right)t\right] - \sum_{m=1}^{\infty} \frac{M_m}{2} A \sin\left[2\pi\left(f_c + \frac{kt}{2} - f_m\right)t\right] \quad (27)$$

### 2.2 仿真参数设置

建立线性调频信号的数学模型, 并添加无意调制的相位噪声, 分析无意调制如何影响信号。根据式 (27), 通过设置多组不同的  $M_m$  和  $f_m$ , 可实现对雷达辐射源添加相位噪声的仿真。本文仿真参数设置如下: 采样频率 1 GHz, 信号带宽 20 MHz, 载频 500 MHz, 脉冲宽度 10  $\mu$ s, 具体频率分量和调相系数的设置如表 1 所示。同时, 为每个辐射源分别添加 10 dB、15 dB、20 dB 的高斯白噪声, 每个信噪比下的辐射源各生成 500 组信号, 其中 75% 用于训练, 25% 用于识别。

表 1 不同雷达辐射源的仿真参数设置

| 个体    | 参数                                                                                |
|-------|-----------------------------------------------------------------------------------|
| 辐射源 1 | $f_{a1}=[10, 50, 100, 150, 200, 220, 300, 350, 500, 600]$ MHz                     |
|       | $M_1=[0.2, 0.01, 0.008\ 1, 0.003\ 2, 0.009\ 3, 0.009\ 1, 0.021, 0.009\ 6, 0.002]$ |
| 辐射源 2 | $f_{a2}=[100, 200, 250, 300, 400, 500, 530, 550, 600, 650]$ MHz                   |
|       | $M_2=[0.001, 0.054, 0.031, 0.021, 0.023, 0.006, 0.017, 0.003, 0.001\ 3, 0.004]$   |
| 辐射源 3 | $f_{a3}=[100, 150, 200, 250, 280, 300, 500, 530, 580, 650]$ MHz                   |
|       | $M_3=[0.021, 0.014, 0.011, 0.009\ 6, 0.04, 0.028, 0.003, 0.002\ 3, 0.001, 0.005]$ |

## 2.3 实验与算法流程

本文实验设计流程如图 2 所示。




图 2 实验设计流程图

将采集到的辐射源信号作为目标函数，初始化 ZOA 参数。设置  $K$  与  $\alpha$  搜索范围，使用预设参数进行 VMD 过程，计算分解后各模态分量的包络熵。不断迭代更新，以包络熵为适应度函数，其是否最小作为判定条件。若不满足，则由斑马优化算法更新  $K$  与  $\alpha$  值后，继续实验；若满足，则得到全局最优参数  $K_0$  与  $\alpha_0$ 。

获取最优分解参数组合后，进行变分模态分解获得  $K_0$  个模态分量，对每个模态分量进行奇异值分解，提取  $\lambda_1$ 、 $\lambda_2$ ，组成特征向量，送入 TWSVM 分类器中进行分类识别，得到识别结果。

## 2.4 实验设计

运用 ZOA-VMD 算法分解辐射源信号，设置 ZOA 基本参数，包括斑马数量 10、最大迭代数 50；设置  $K$  取值范围为  $[2, 10]$ ， $\alpha$  取值范围为  $[2000, 10\ 000]$ ，步长 50，依据包络熵是否最小在给定空间搜索最优分解参数组合。仿真实验中，ZOA 在迭代次数为 5 时，已达到包络熵最小值，如图 3 所示。得到最优分解参数组合为  $[3, 7500]$ ，基于此，参数组合分解辐射源信号，得到 3 个模态分量。提取各模态分量的奇异值特征组成特征向量，送入 TWSVM 进行分类识别。结果表

明，在 10 dB 时，识别率为 83.26%；在 15 dB 时，识别率可达 95.32%；在 20 dB 时，识别率已达 100%。可见，此算法具有一定的可行性。现基于此算法，用实测信号进一步实验。




图 3 ZOA 优化值随迭代次数变化（仿真数据）

## 3 实测数据实验

### 3.1 实测数据采集

5 部信号发生器作为辐射源，信号源 1 为 E4438C，信号源 2 为 N5172B，信号源 3 为 AWG70001，信号源 4 为 N5182B，信号源 5 为 N5172B\_HOU，其中 N5172B、N5182B、N5172B\_HOU 属于同一型号信号源。将 5 部信号源分别用 Radar1、Radar2、Radar3、Radar4 和 Radar5 表示。信号源分别产生正负线性调频信号和二进制相移键控信号，采样频率 25 GB，信号的采集参数设置如表 2 所示，每个信号源每组信号脉冲采集 120 个，其中 75% 用于训练，25% 用于识别。以 5 dB 为步长，分别添加 0 ~ 25 dB 的高斯白噪声信号。

表 2 实测信号采集参数设置

| 信号调制方式           | 参数          | 参数范围                |
|------------------|-------------|---------------------|
| 线性调频信号 (LFM)     | 调制方式 $Mod$  | 正斜率 $P$ ，负斜率 $N$    |
|                  | 载频 $f_{c1}$ | 0.5 GB, 1 GB        |
|                  | 带宽 $B$      | 10 MB, 20 MB, 30 MB |
| 二进制相移键控信号 (BPSK) | 载频 $f_{c2}$ | 0.5 GB, 1 GB        |
|                  | 巴克码 $N_c$   | 13                  |

### 3.2 基于 ZOA 的 VMD 最优分解值分析

实测数据下的实验参数设置与仿真实验一致，得到 ZOA 优化函数值随迭代次数变化曲线如图 4 所示。




图 4 ZOA 优化值随迭代次数变化（实测数据）

由图 4 可知, ZOA 收敛速度很快, 第 13 代时, 已经达到目标函数的极小值, 此时对应的  $K$  值为 4,  $\alpha$  值为 2000, 即最优分解参数组合为 [4, 2000]。对辐射源信号进行分解, 得到 4 个模态分量, 以 rader1 为例, 如图 5 所示。






图 5 radar1 基于斑马优化算法的变分模态分解

### 3.3 奇异值特征提取

现进行二次特征提取, 提取各模态分量的奇异值特征。在信噪比 15 dB 下, LFM 和 BPSK 信号基于 ZOA-VMD 方法的部分奇异值特征如图 6 所示, 可知奇异值特征非常稳定, 有着良好的分类效果。



(a) LFM 信号奇异值特征



(b) BPSK 信号奇异值特征

图 6 信号基于 ZOA-VMD 方法的部分奇异值特征

### 3.4 基于 TWSVM 的辐射源个体识别

将利用 ZOA 优化 VMD 提取到的辐射源奇异值特征组成特征向量, 送入 TWSVM 中, 在信噪比为 15 dB 时, 得到如图 7 所示的个体识别率。




图 7 ZOA-VMD+TWSVM 的识别效果

本文利用基于 ZOA-VMD 来提取辐射源个体的特征, 输入到 TWSVM 中进行训练, 建立分类模型, 信噪比为 15 dB 时, 整体识别准确率可达 94.1%。如图 8 和图 9 所示, 分别为 ZOA-VMD+TWSVM 训练和测试时的混淆矩阵。训练和测试的混淆矩阵正确率相差不大, 由此可知 TWSVM 不存在过拟合问题。综上所述, 本文提出 ZOA-VMD+TWSVM 的雷达辐射源个体识别方法有效可行, 稳定性良好。

|      |             | Training Confusion Matrix |            |            |             |             |             |            |             |            |             |
|------|-------------|---------------------------|------------|------------|-------------|-------------|-------------|------------|-------------|------------|-------------|
| True | radar1_LFM  | 155                       | 0          | 0          | 0           | 0           | 0           | 0          | 0           | 0          | 0           |
|      | radar2_LFM  | 0                         | 144        | 0          | 1           | 0           | 0           | 10         | 0           | 0          | 0           |
|      | radar3_LFM  | 0                         | 0          | 155        | 0           | 0           | 0           | 0          | 0           | 0          | 0           |
|      | radar1_BPSK | 0                         | 1          | 0          | 140         | 0           | 2           | 6          | 0           | 6          | 0           |
|      | radar2_BPSK | 0                         | 0          | 0          | 0           | 155         | 0           | 0          | 0           | 0          | 0           |
|      | radar3_BPSK | 0                         | 1          | 0          | 1           | 7           | 135         | 10         | 0           | 0          | 1           |
|      | radar4_LFM  | 0                         | 3          | 0          | 4           | 0           | 4           | 144        | 0           | 0          | 0           |
|      | radar4_BPSK | 0                         | 0          | 0          | 0           | 0           | 0           | 0          | 155         | 0          | 0           |
|      | radar5_LFM  | 0                         | 0          | 0          | 0           | 0           | 0           | 0          | 0           | 155        | 0           |
|      | radar5_BPSK | 0                         | 0          | 0          | 0           | 0           | 0           | 0          | 0           | 0          | 155         |
|      |             | radar1_LFM                | radar2_LFM | radar3_LFM | radar1_BPSK | radar2_BPSK | radar3_BPSK | radar4_LFM | radar4_BPSK | radar5_LFM | radar5_BPSK |
|      |             | Predicted                 |            |            |             |             |             |            |             |            |             |

图 8 TWSVM 训练时的混淆矩阵

|      |             | Test Confusion Matrix |            |            |             |             |             |            |             |            |             |
|------|-------------|-----------------------|------------|------------|-------------|-------------|-------------|------------|-------------|------------|-------------|
| True | radar1_LFM  | 75                    | 0          | 0          | 0           | 0           | 0           | 0          | 0           | 0          | 0           |
|      | radar2_LFM  | 0                     | 71         | 0          | 0           | 0           | 0           | 4          | 0           | 0          | 0           |
|      | radar3_LFM  | 0                     | 0          | 75         | 0           | 0           | 0           | 0          | 0           | 0          | 0           |
|      | radar1_BPSK | 0                     | 1          | 0          | 67          | 0           | 1           | 4          | 0           | 0          | 2           |
|      | radar2_BPSK | 0                     | 0          | 0          | 0           | 75          | 0           | 0          | 0           | 0          | 0           |
|      | radar3_BPSK | 0                     | 1          | 0          | 2           | 2           | 67          | 3          | 0           | 0          | 0           |
|      | radar4_LFM  | 0                     | 0          | 0          | 6           | 0           | 2           | 67         | 0           | 0          | 0           |
|      | radar4_BPSK | 0                     | 0          | 0          | 0           | 0           | 0           | 0          | 75          | 0          | 0           |
|      | radar5_LFM  | 0                     | 0          | 0          | 0           | 0           | 0           | 0          | 0           | 75         | 0           |
|      | radar5_BPSK | 1                     | 0          | 0          | 0           | 0           | 0           | 0          | 0           | 0          | 74          |
|      |             | radar1_LFM            | radar2_LFM | radar3_LFM | radar1_BPSK | radar2_BPSK | radar3_BPSK | radar4_LFM | radar4_BPSK | radar5_LFM | radar5_BPSK |
|      |             | Predicted             |            |            |             |             |             |            |             |            |             |

图 9 TWSVM 测试时的混淆矩阵

### 3.5 算法对比

将本文方法与文献 [3]、文献 [12] 及文献 [13] 的方法进行对比。文献 [3] 基于麻雀搜索算法优化 VMD 参数寻优过

程并提取模态分量的能量熵与样本熵作为联合特征向量,送入 LightGBM 中进行分类识别;文献 [12] 基于蛙跳算法优化 VMD 参数寻优过程并提取信号奇异值特征,送入 SVM 中进行分类识别;文献 [13] 基于 VMD 算法提取中心频率作为特征,送入人工蜂群算法优化后的 SVM 中进行分类识别。

现进行对比实验,分别将结合本文 ZOA-VMD 与文献 [3] 的 LightGBM 分类识别算法,结合文献 [12] 的蛙跳算法优化 VMD 与本文的 TWSVM 分类识别算法,以及文献 [13] 的方法与本文方法进行对比,如图 10 所示。由图 10 可得,识别率随信噪比提高也逐步提高。实测数据下,本文算法在信噪比为 15 dB 时,5 部辐射源的个体识别率达到 94% 以上,在 20 dB 时达到了 100%。




图 10 辐射源在不同信噪比下的个体识别率

对比分析可得出以下结果。

- (1) 本文识别效果较文献 [3]、文献 [12] 及文献 [13], 在高信噪比的条件下均有所提升。
- (2) 本文识别效果较 ZOA-VMD+ 文献 [3]LightGBM 在部分信噪比下的识别率更高, 表明 TWSVM 较 LightGBM 在识别分类上有一定的优势。
- (3) 本文识别效果较文献 [12] 特征提取算法+TWSVM 在各个信噪比下的识别率均更优, 表明本文 ZOA-VMD 略优于蛙跳算法-VMD。
- (4) 本文识别效果较文献 [13] 方法在各个信噪比下的识别率均更优, 表明本文提出的 ZOA-VMD+TWSVM 方法无论在特征提取还是分类识别上都较 VMD+ 基本优化算法后的 SVM 有一定的优势。

#### 4 结论

VMD 算法因其能够依据不同中心频率分解信号, 普遍适用于辐射源无意特征的提取。ZOA 能够快速准确地获取 VMD 最优分解模态数  $K$  和二次惩罚因子  $\alpha$  组合, 而选取奇异值作为二次特征有着良好的分类效果。结果显示, 孪生支持向量机在识别率方面也有一定的提升且稳定性良好。本文

虽基于实测数据分析, 但信号源样本数量相对较小, 未来有必要采集更多的数据去开展研究, 以使该方法更具有广泛适用性。

#### 参考文献:

- [1] 王磊. 雷达辐射源个体识别的方法研究 [D]. 西安: 西安电子科技大学, 2011.
- [2] 乔平娟, 谢钧, 李林, 等. 辐射源个体识别研究综述 [J]. 信息技术与信息化, 2023(12):156-164.
- [3] 肖易寒, 李栋年, 于祥祯, 等. 基于参数优化 VMD 和 LightGBM 的雷达辐射源个体识别 [J]. 航空兵器, 2022, 29(2): 93-100.
- [4] 瞿金秀, 史小伟, 石长全, 等. 基于 SSA-VMD 和 ANFIS 的粘弹夹层结构老化状态智能识别方法 [J/OL]. 振动工程学报: 1-11[2024-03-01].<http://kns.cnki.net/kcms/detail/32.1349.TB.20240202.1046.004.html>.
- [5] 单玉庭, 刘韬, 褚惟, 等. 遗传算法优化变分模态分解在轴承故障特征提取中的应用 [J]. 噪声与振动控制, 2024, 44(1): 148-153+204.
- [6] 马愈昭, 朱庆啸, 吕其明, 等. 基于 POA-VMD 和 MPE 的光纤周界入侵信号降噪方法 [J/OL]. 激光与光电子学进展: 1-17[2024-03-01].<http://kns.cnki.net/kcms/detail/31.1690.TN.20240220.1052.040.html>.
- [7] MOJTABA N, MAHMOUD S S. Successive variational mode decomposition [J]. Signal processing, 2020, 174:107610.
- [8] TROJOVSKÁ E, DEHGHANI M, TROJOVSKÝ P. Zebra optimization algorithm: a new bio-inspired optimization algorithm for solving optimization algorithm [J]. IEEE access, 2022, 10: 49445-49473.
- [9] 尚秋峰, 谷元宇. 基于 GWO-VMD-SVD 的  $\Phi$ -OTDR 信号降噪方法 [J]. 半导体光电, 2023, 44(6):913-918.
- [10] 谭金龙, 熊小伏, 陈军, 等. 基于改进孪生支持向量机的新型电力系统继电保护故障诊断模型 [J]. 沈阳工业大学学报, 2023, 45(6):631-636.
- [11] 李博. 雷达辐射源个体识别中特征提取与分类器的研究 [D]. 北京: 北京邮电大学, 2022.
- [12] 刘刚. 雷达辐射源个体识别方法研究 [D]. 哈尔滨: 哈尔滨工程大学, 2020.
- [13] 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+189.

#### 【作者简介】

蒋闾 (2000—), 男, 江苏盐城人, 硕士研究生, 研究方向: 雷达辐射源个体识别。

(收稿日期: 2024-03-08)