

基于核协同表示与鉴别投影的 辐射源调制识别

李东瑾, 杨瑞娟, 李晓柏, 董睿杰
(中国人民解放军空军预警学院, 湖北武汉 430019)

摘 要: 针对辐射源识别中的特征稳定性不高和低信噪比环境适应性不足等问题, 提出了一种基于二次时频分布、核协同表示与鉴别投影的识别方法. 首先, 通过时频变换、稀疏域降噪和二次特征提取的预处理算法降低噪声干扰和特征冗余, 以获取高稳定性的二次时频分布特征; 然后, 采用核协同表示和鉴别投影思想进行降维学习和字典学习, 以提升数据低维表征和类间鉴别能力; 最后, 通过离线训练完成系统优化并用于分类验证. 仿真结果表明, 二次时频分布特征具备较高稳定性, 识别方法具备较强鲁棒性、时效性和适应性; 当信噪比为 -10dB 时, 该方法对 8 类辐射源信号的整体平均识别率达到 96.88%.

关键词: 辐射源识别; 核协同表示; 鉴别投影; 二次时频分布; 批量随机梯度下降法

中图分类号: TN957.51 **文献标识码:** A **文章编号:** 0372-2112 (2020)09-1695-08

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2020.09.005

Emitter Signal Modulation Recognition Based on Kernel Collaborative Representation and Discriminative Projection

LI Dong-jin, YANG Rui-juan, LI Xiao-bai, DONG Rui-jie
(PLA Air Force Early Warning Academy, Wuhan, Hubei 430019, China)

Abstract: Aiming at the problems of low feature stability in emitter signal recognition and poor adaptability to low signal-to-noise (SNR) environment, a recognition method based on secondary time-frequency distribution, kernel collaborative representation and discriminative projection (KCRDP) was proposed. First, the pre-processing algorithms of time-frequency transform, sparse domain noise reduction, and secondary feature extraction are used to reduce noise interference and feature redundancy, and secondary time-frequency distribution features with high stability were obtained. Then, the kernel collaborative representation and discriminative projection ideas are used to complete the dimensionality reduction learning and dictionary learning to improve the low-dimensional representation and inter-class discrimination capabilities of the data. Finally, the system is optimized through offline training and used for classification verification. Simulation results show that the secondary time-frequency distribution feature has high stability, and the recognition method has strong robustness, timeliness and adaptability. When the SNR is -10dB , the overall average recognition rate of the eight signals reaches 96.88%.

Key words: emitter signal recognition; kernel collaborative representation; discriminative projection; secondary time-frequency distribution (STFD); mini-batch stochastic gradient descent (MSGD)

1 引言

在现代电磁频谱对抗域, 辐射源调制识别为提升系统无源增益和保障任务精准化实施提供重要支撑. 该技术的实现依赖于特征工程和分类器模型, 各类非线性特征变换和机器学习技术因而在研究早期备受青睐^[1]. 近年来, 卷积神经网络 (CNN, Convolutional Neural

Network) 等智能调制识别算法表现出极强的竞争力^[2]. 综合来看, 常规识别方式难以有效兼顾环境适应性和时效性; 智能识别方式显著降低了人为影响和特征需求, 但依赖于大数据样本. 实际应用中, 数据容量通常难以满足深度学习需求, 特征工程与分类器相结合方式在缓解样本容量需求等方面仍具备较大优势. 基于此, 本文充分考虑特征稳定性和分类时效性, 从特征工程

和分类器角度出发进行联合设计:(1)特征工程部分.时频特征具备较高辨识度,采用计算复杂度较低的短时傅里叶变换(STFT, Short Time Fourier Transform)获取初始特征,并通过算法设计降低噪声与冗余信息影响;(2)分类器部分.稀疏表示和字典学习^[3]分类方式能够有效挖掘数据内在特征,在认知无线电等领域得到广泛应用.文献[4]将其用于辐射源识别,但存在计算复杂度高等问题;文献[5]采用协同表示分类增强分类时效性,但其判别能力受限于未优化字典.判别设计和字典学习能够增强判别能力,因而衍生出标签一致性 K-SVD(LC-KSVD, Label Consistent K-SVD)等^[6]字典分类方式.此外,低维判别和非线性表征是实现高效判别的关键因素^[7-9].基于此,本文综合核协同表示和鉴别投影进行联合识别算法设计,以强化类间差异性并实现非线性空间的低维判别.

本文所提联合识别算法的主要功能如下:(1)二次时频分布(STFD)特征提取,通过 STFT 处理获取初始特征并利用时频域稀疏性完成降噪,采用信号子空间系数优化方法完成二次特征提取;(2)基于核协同表示和鉴别投影(KCRDP)的分类识别,利用 Fisher 准则构建目标函数,采用小批量随机梯度下降法(MSGD)进行优化.

2 辐射源信号 STFD 特征提取

2.1 信号模型

高斯白噪声环境下截获辐射源单脉冲序列为

$$x(k) = A \exp(j(2\pi f_0 k + \varphi(k))) + n(k) \quad (1)$$

其中, A 为幅度信息, f_0 为信号载频, n 为高斯白噪声干扰项, φ 为脉内调制信息. NLFM 满足 $\varphi(k) = \pi\beta_1 k^2/\tau + 2\pi\beta_2 k^3/3\tau^2$, τ 为脉冲宽度; Frank 满足 $\varphi(k) = 2\pi(k - k(\text{mod}M))[k(\text{mod}M)]/M$, M 为步进频率. 本文主要考虑单载频信号(SCS, Single Carrier Signal)、BFSK、QFSK、LFM、NLFM、BPSK、QPSK、Frank 八种调制方式.

2.2 STFT 时频特征与降噪

STFT 对局部特征和整体结构具备较稳定表征能力且时效性较高. 离散域短时傅里叶变换为

$$\text{STFT}_x(m_1, n_1) = \sum_{k=0}^{N-1} x(k) \cdot h^*(k - m_1) \exp\left(-j \frac{2\pi n_1}{N} k\right) \quad (2)$$

其中, m_1 、 n_1 分别为时域、频域索引, N 为傅里叶变换长度, h^* 为 $N/4$ 长度的 Hamming 窗函数共轭.

不同采样率和信号参数下时频空间分布存在较大差异,直接处理往往存在较大冗余,尤其不利于窄带信号识别.因此采用图 1 所示流程提取 STFD 特征,降噪和二次特征提取用于降低特征中噪声干扰和信息冗余.具体降噪处理流程如下:

(1) 构建滤波系数矩阵 $F_{m \times n} = [f_1, f_2, \dots, f_n]$, 初始值为 $F_{m \times n} = A_{m \times n}$, $A_{m \times n}$ 为原始时频信号;

(2) 列信号 $f_j (j \in [1, n])$ 对应局部频域维特征,具备较强稀疏性. 设 μ_j 为列向量 f_j 的最大值,逐列进行如下归一化处理

$$f_j = \frac{f_j}{\mu_j} \quad (3)$$

(3) 滤波系数优化. 选取函数 $g(x) = x^3$ 进行如下系数稀疏化表示

$$F_{ij} = \begin{cases} g(F_{ij}), & F_{ij} \geq a_j \\ 0, & F_{ij} < a_j \end{cases}, \quad i \in [1, m], j \in [1, n] \quad (4)$$

其中, a_j 为列向量 f_j 的均值. 由于 $g(x)$ 收敛较快,重复步骤(2)、(3)两次即完成优化;

(4) 降噪后时频信号更新为 $\tilde{A} = A \odot F$, 其中 \odot 为 Hadamard 积. 随后将信号统一调整为 $\tilde{A}_{M \times M}$.

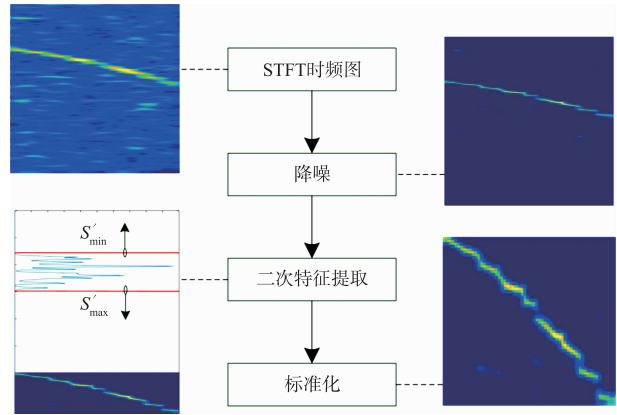


图1 STFD特征提取流程

2.3 二次特征提取

引入信号子空间系数对冗余信息进行定量描述,并采用滑窗检测机制进行系数优化,获取信号子空间位置并降低信息冗余.

(1) 定义 γ_F 为频域投影的子空间权重系数,用于表征频率分布的能量差异. 设 i 、 j 分别为时域、频域索引,则

$$\gamma_F(j) = \sum_{i=1}^M \tilde{A}_{ji}, \quad j \in [1, M] \quad (5)$$

(2) 对 γ_F 进行归一化处理. 进一步考虑信号分布连续性,引入滑窗检测机制,则

$$\tilde{\gamma}(p, k) = \sum_{q=(p-1)\tau_1+1}^{p\tau_1} \frac{1}{\tau_1} \gamma_F(q) h_1(p-q) \quad (6)$$

其中, h_1 为窗宽为 τ_1 的单位矩形窗函数, $p \in [1, M/\tau_1]$ 为窗索引, $k \in [1, \tau_1]$ 为窗内索引且 $\tilde{\gamma}(p, k) = \tilde{\gamma}(p, 1)$, 滑窗检测结果为 $\tilde{\gamma}_F = [\tilde{\gamma}_1^T, \tilde{\gamma}_2^T, \dots, \tilde{\gamma}_L^T]$, $\tilde{\gamma}_i^T$ 为 $\tilde{\gamma}$ 的第 i 行元素且 $L = M/\tau_1$, 多窗检测时对 $\tilde{\gamma}_F$ 求加权平均.

(3) 为增强稳定性,引入时域投影的子空间占比

系数 η_T 表征信号连续性和占比状态,运用二值化数据进行运算. 利用 $\tilde{\mathbf{A}}_{M \times M}$ 初始化窗索引 $p \in [1, M/\tau_1]$ 内的二值化时频分布 $\tilde{\mathbf{A}}_p$, 并以 $\tilde{\mathbf{A}}_p$ 的过零均值 μ_p 为门限进行数据二值量化, 则

$$\mathbf{A}'_p(q, i) = \begin{cases} 1, & \mathbf{A}_p(q, i) > \mu_p \\ 0, & \mathbf{A}_p(q, i) \leq \mu_p \end{cases} \quad (7)$$

其中, $q \in [(p-1)\tau_1 + 1, p\tau_1]$. 状态累积量 $f(p, i)$ 表示为

$$f(p, i) = \sum_{q=(p-1)\tau_1+1}^{p\tau_1} \mathbf{A}'_p(q, i) h_1(p-q) \quad (8)$$

随后, 对窗 $[(p-1)\tau_1 + 1, p\tau_1]$ 内信号在各时域位置 $i \in [1, M]$ 处信号的有无状态 $w(p, i)$ 进行定量描述, 即

$$w(p, i) = \begin{cases} 1, & f(p, i) > 0 \\ 0, & f(p, i) \leq 0 \end{cases} \quad (9)$$

窗内信号在时域投影空间 $k \in [1, M]$ 的占空比系数为

$$\eta_T(p, k) = \frac{1}{M} \sum_{i=1}^M w(p, i) \quad (10)$$

$\eta_T(p, k)$ 在窗内含整个信号子空间时为 1, 仅含噪声子空间时为 0. 滑窗检测结果为 $\boldsymbol{\eta}'_T = [\boldsymbol{\eta}'_1, \boldsymbol{\eta}'_2, \dots, \boldsymbol{\eta}'_L]$, $\boldsymbol{\eta}'_i$ 为 $\boldsymbol{\eta}_T$ 的第 i 行元素, 多窗检测对 $\boldsymbol{\eta}'_T$ 求加权平均.

(4) $\boldsymbol{\gamma}'_F$ 与 $\boldsymbol{\eta}'_T$ 分别从频域投影和时域投影角度反映了信号主体信息, 分别对 $\boldsymbol{\gamma}'_F$ 和 $\boldsymbol{\eta}'_T$ 进行最值归一化处理, 信号子空间位置分布函数 S 为

$$S(j) = \boldsymbol{\gamma}'_F(j) \cdot \boldsymbol{\gamma}'_F(j) \cdot \boldsymbol{\eta}'_T(j) \quad (11)$$

对 S 进行最值归一化处理. 以其均值 μ_s 为门限得到信号子空间的位置分布为 $[S_{\min}, S_{\max}]$, 即

$$\begin{cases} S_{\min} = \arg \min_j (S(j) > \mu_s) \\ S_{\max} = \arg \min_j (S(j) > \mu_s) \end{cases} \quad (12)$$

此时, 截取时频空间中信号子空间即可降低冗余信息. 将二次特征数据 \mathbf{A}_s 进行标准化处理, 统一调整为 $\tilde{\mathbf{A}}_{M_1 \times M_1}$ 后输出. 若 $S_{\max} - S_{\min} < M1$, 则 $\mathbf{A}_s = \tilde{\mathbf{A}}(S_{m_1} : S_{m_2}, 1 : M)$ 且 $S_{m_2} = \min(\max(S_{m_1} + M, S_{\max} + \delta), M)$, $S_{m_1} = \min(S_{\min}, \delta)$ 且满足 $\delta = (M1 - S_{\max} - 1 + S_{\min})/2$; 若 $S_{\max} - S_{\min} \geq M1$, 则 $\mathbf{A}_s = \tilde{\mathbf{A}}(S_{\min} : S_{\max}, 1 : M)$.

设置 $M = 600$, $M1 = 60$, 系数优化时选取不同尺度窗结合方式, 对应窗宽分别为 50、10, 窗加权系数为 2/3 和 1/3. 以 -5dB 条件下 NLFM 信号为例, 对应各阶段特征如图 1 所示. 二次特征提取部分的红线对应二次特征数据位置 S_{m_1} 和 S_{m_2} . 二次特征提取使得冗余降低, 更多强细节特征得以保留.

3 基于核协同表示与鉴别投影的识别系统

3.1 KCRDP 信号模型

设 l 维特征空间任意样本为 $\mathbf{y} \in R^l$, C 类辐射源信号的样本表示为 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_C] \in R^{l \times M}$, \mathbf{X}_i 为第 i 类样本数据且样本量为 M_i . 字典表示为 $\mathbf{D} = [\mathbf{D}_1, \mathbf{D}_2,$

$\dots, \mathbf{D}_C] \in R^{l \times N}$, \mathbf{D}_i 为第 i 类子字典且字典原子数为 N_i , \mathbf{y} 为任意样本. CRC 模型为

$$J = \arg \min_{\mathbf{D}, \boldsymbol{\alpha}} \|\mathbf{y} - \mathbf{D}\boldsymbol{\alpha}\|_F^2 + \lambda \|\boldsymbol{\alpha}\|_F^2 \quad (13)$$

式中: $\boldsymbol{\alpha} \in R^N$ 为编码系数, λ 为正则化参数. 引入鉴别投影矩阵 $\mathbf{P} = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_m] \in R^{l \times m}$ 实现特征降维, 引入核映射增强特征非线性, 对应 KCRDP 模型为

$$J = \arg \min_{\mathbf{P}, \mathbf{D}, \boldsymbol{\alpha}} \|\mathbf{P}^T \boldsymbol{\varphi}(\mathbf{y}) - \mathbf{P}^T \boldsymbol{\varphi}(\mathbf{D})\boldsymbol{\alpha}\|_F^2 + \lambda \|\boldsymbol{\alpha}\|_F^2 \quad (14)$$

式中: $\boldsymbol{\varphi}(\cdot)$ 为隐式核函数. \mathbf{P} 和 \mathbf{D} 均可利用核样本张成空间的基原子进行线性表示. 设 $\mathbf{Q} \in R^{M \times m}$ 为伪随机变换矩阵, 则 $\mathbf{P} = \boldsymbol{\varphi}(\mathbf{X})\mathbf{Q}$. 核字典 $\boldsymbol{\varphi}(\mathbf{D})$ 可表示为 $\boldsymbol{\varphi}(\mathbf{D}) = \boldsymbol{\varphi}(\mathbf{X})\mathbf{A}$, 其中 $\boldsymbol{\varphi}(\mathbf{D}_i) = \boldsymbol{\varphi}(\mathbf{X}_i)\mathbf{A}_i$ 为第 i 类核子字典, $\mathbf{A} \in R^{M \times N}$ 为字典系数矩阵. \mathbf{A} 由子字典系数矩阵 \mathbf{A}_i 按对角形式排列构成. 代入式(14)得到

$$J = \arg \min_{\mathbf{Q}, \mathbf{A}, \boldsymbol{\alpha}} \|\mathbf{Q}^T K_{xy} - \mathbf{Q}^T K_x \mathbf{A} \boldsymbol{\alpha}\|_F^2 + \lambda \|\boldsymbol{\alpha}\|_F^2 \quad (15)$$

式中: $K(\cdot)$ 为核表示, $K_{xy} = K(\mathbf{X}, \mathbf{y}) = \boldsymbol{\varphi}(\mathbf{X})^T \boldsymbol{\varphi}(\mathbf{y})$, $K_x = \boldsymbol{\varphi}(\mathbf{X})^T \boldsymbol{\varphi}(\mathbf{X})$ 为半正定矩阵. \mathbf{y} 的编码系数为

$$\tilde{\boldsymbol{\alpha}} = (\mathbf{A}^T K_x^T \mathbf{Q} \mathbf{Q}^T K_x \mathbf{A} + \lambda \mathbf{I})^{-1} \mathbf{A}^T K_x^T \mathbf{Q} \mathbf{Q}^T K_{xy} \quad (16)$$

式中: $\tilde{\boldsymbol{\alpha}} = [\tilde{\boldsymbol{\alpha}}_1; \tilde{\boldsymbol{\alpha}}_2; \dots; \tilde{\boldsymbol{\alpha}}_C] \in R^N$ 为编码系数, $\tilde{\boldsymbol{\alpha}}_i$ 为第 i 类编码系数. \mathbf{y} 的对应误差表示和分类结果分别为

$$\begin{aligned} e_i(\mathbf{y}) &= \|\mathbf{Q}^T K_{xy} - \mathbf{Q}^T K_{xx} \mathbf{A}_i \tilde{\boldsymbol{\alpha}}_i\|_F^2 / \|\tilde{\boldsymbol{\alpha}}_i\|_F^2 \\ \text{Id}(\mathbf{y}) &= \arg \min_i \{e_i\} \end{aligned} \quad (17)$$

设 \bar{E}^c 和 \bar{E}^d 分别为正确分类、最易错分类对应的类内重构误差, d 对应错分类中的最小误差类, 则

$$\begin{cases} d = \arg \min_k \bar{E}^k \quad \text{s. t. } k \neq c \\ \bar{E}^k = \|\mathbf{Q}^T K_{xx} - \mathbf{Q}^T K_{xx} \mathbf{A}_k \tilde{\boldsymbol{\alpha}}_k\|_F^2 \end{cases} \quad (18)$$

增大 c 和 d 类差异性有助于提升鉴别能力. 借鉴 Fisher 判别^[8,9] 等思想设计的 KCRDP 模型为

$$J_B(\mathbf{Q}, \mathbf{A}) = \arg \min_{\mathbf{Q}, \mathbf{A}} \frac{1}{B} \sum_{i=1}^C \sum_{j=1}^{B_i} (S_\beta(R(\mathbf{x}_{ij})) + \lambda \|\tilde{\boldsymbol{\alpha}}^{(i,j)}\|_F^2) \quad (19)$$

其中, $\mathbf{x}_{ij} \in R^l$ 对应第 i 类第 j 个训练样本, $B = \sum_{i=1}^C B_i$ 为批量训练参数, B_i 为第 i 类数据的样本量. 选择 sigmoid 函数 $S_\beta(\mathbf{x}) = 1/(1 + e^{\beta(1-x)})$ 进行误差量化, β 为斜率参数. 类内、最近类间差异性量化函数定义为

$$R(\mathbf{x}) = \frac{\bar{E}^c}{\bar{E}^d} \quad (20)$$

其中, $R(\mathbf{x})$ 为 1 时对应临界状态 $\bar{E}^c = \bar{E}^d$, 此外主要分两种情况: (1) $\bar{E}^c < \bar{E}^d$ 时, $R(\mathbf{x})$ 较小, 误分类概率降低; (2) $\bar{E}^c > \bar{E}^d$ 时, $R(\mathbf{x})$ 较大, 易误分为 d 类, 利用 MSGD 对其进行误差修正.

3.2 KCRDP 模型优化

损失函数 $J_B(\mathbf{Q}, \mathbf{A})$ 的梯度表示为

$$g_Q = \frac{1}{B} \sum_i \sum_j S'_\beta(z) z \left(\frac{\nabla_Q \bar{E}_{i,j}^c}{\bar{E}_{i,j}^c} - \frac{\nabla_Q \bar{E}_{i,j}^d}{\bar{E}_{i,j}^d} \right)$$

$$g_A = \frac{1}{B} \sum_i \sum_j S'_\beta(z) z \left(\frac{\nabla_A \tilde{E}_{i,j}^c}{\tilde{E}_{i,j}^c} - \frac{\nabla_A \tilde{E}_{i,j}^d}{\tilde{E}_{i,j}^d} \right) \quad (21)$$

$$S'_\beta(z) = \beta e^{\beta(1-z)} / (1 + e^{\beta(1-z)})^2$$

其中, $z = R(\mathbf{x}_{i,j})$, 忽略编码系数影响, 则

$$\begin{aligned} \nabla_Q \tilde{E}^g &= 2(K(\mathbf{X}, \mathbf{x}) - K(\mathbf{X}, \mathbf{X}_g) \mathbf{A}_g \tilde{\alpha}_g) \\ &\quad \cdot (\mathbf{Q}^T K(\mathbf{X}, \mathbf{x}) - \mathbf{Q}^T K(\mathbf{X}, \mathbf{X}_g) \mathbf{A}_g \tilde{\alpha}_g)^T \\ \nabla_A \tilde{E}^g &= -2K^T(\mathbf{X}, \mathbf{X}_g) \mathbf{Q} \\ &\quad \cdot (\mathbf{Q}^T K(\mathbf{X}, \mathbf{x}) - \mathbf{Q}^T K(\mathbf{X}, \mathbf{X}_g) \mathbf{A}_g \tilde{\alpha}_g) \tilde{\alpha}_g^T \end{aligned} \quad (22)$$

求得批量数据的梯度表示后, \mathbf{Q} 和 \mathbf{A} 更新方式为

$$\begin{cases} \mathbf{Q}(t) = \mathbf{Q}(t-1) + \mathbf{U}(t) \\ \mathbf{A}(t) = \mathbf{A}(t-1) + \mathbf{V}(t) \\ \mathbf{U}(t) = \alpha_Q \mathbf{U}(t-1) - \gamma g_Q \\ \mathbf{V}(t) = \alpha_A \mathbf{V}(t-1) - \eta g_A \end{cases} \quad (23)$$

其中, α_Q 和 α_A 为动量因子, γ 和 η 为学习率. 采用批量学习策略时, 取 $\gamma = B\gamma_0/C$, $\eta = B\eta_0/C$, γ_0 和 η_0 为初始学习率. 具体求解过程如算法 1 所示.

算法 1 基于 MSGD 的 KCRDP 算法

输入: 训练样本, 模型参数和终止条件.

初始化: 利用高斯随机矩阵初始化字典系数矩阵 \mathbf{A} , 利用 KPCA 算法初始化伪随机变换矩阵 \mathbf{Q} , 设迭代次数 $t=0$.

重复执行

随机打乱样本顺序, 将数据集划分为 NUM 批次;

for $i=1$:NUM do

利用式(16)计算编码系数 $\tilde{\alpha}^{(i)}$, 利用式(18)获取对应最近错分类别 $d^{(i)}$;

利用式(21)和(22)计算梯度变量 $g_Q^{(i)}$ 和 $g_A^{(i)}$;

利用式(23)更新 $\mathbf{Q}^{(i)}$ 和 $\mathbf{A}^{(i)}$;

end for

$t=t+1$;

直到收敛

输出: \mathbf{Q} 和 \mathbf{A} .

3.3 基于 KCRDP 的辐射源调制识别

基于 KCRDP 的辐射源调制识别系统如图 2 所示, 模型优化在离线训练阶段完成, 对应流程为: 首先提取信号 STFD 特征数据并完成向量化表示, 所得训练样本集送至 KCRDP 并利用算法 1 完成优化. 测试阶段采用无监督方式完成, 利用相同处理流程所得的测试数据集送至 KCRDP 进行性能验证, 利用式(17)进行误差计算和预测类别判定.

4 仿真与分析

4.1 实验环境

充分考虑信号多样性, 信号参数如表 1 所示, 其中 U 表示区间内数据的均匀随机分布, 采样总时长 T 为 $10\mu\text{s}$, 采样频率为 200MHz 并以此为表 1 频率项的参考




图2 基于KCRDP的辐射源调制识别系统

频率. QPSK 和 QFSK 的码序列为 '3,1,0,0,2,1,0,3,0,2,1,2,3'、'0,0,2,1,1,3,3,2,1,2,3' 或 '3,0,1,2,2,1,3'。测试环境如下: 数据集在 $-12 \sim 10\text{dB}$ (步长 2dB) 信噪比条件下生成, 各信噪比下单类信号样本为 200, 样本容量为 19200. 本文设置两种数据集用于验证: (1) 数据集 A1. 用于不同信噪比下模型的独立训练与测试, 训练集由数据集中各信噪比下每类随机抽取的 100 样本构成, 各信噪比下训练和测试样本容量均为 800; (2) 数据集 A2. 用于验证预处理算法及统一识别模型的有效性. 训练集在 10dB 条件下随机生成, 容量为 1600, 测试集为上述整个数据集. 计算机配置为 CPU i7-9750H, 6GB GPU (NVIDIA GeForce RTX 2060), 内存 16GB, 仿真环境为 Matlab-R2019b.

表 1 信号参数设置

信号类型	参数名称	取值范围
SCS	载频	$U[1/40, 1/5]$
	信号持续时间	$U[T/2, T]$
BFSK	跳频巴克码长度	{7, 11, 13}
	基频	$U[1/40, 1/8]$
	频率间隔	$U[1/40, 1/10]$
QFSK	信号持续时间	$U[T/2, T]$
	跳频码长度	{7, 11, 13}
	基频	$U[1/40, 3/40]$
LFM	频率间隔	$U[1/40, 1/20]$
	信号持续时间	$U[T/2, T]$
	初始频率	$U[1/40, 1/8]$
NLFM	带宽	$U[1/40, 1/10]$
	初始频率	$U[1/40, 1/8]$
	调制参数 β_1	$U[1/40, 1/20]$
BPSK	调制参数 β_2	$U[1/40, 1/20]$
	信号持续时间	$U[T/2, T]$
	巴克码长度	{7, 11, 13}
QPSK	载频	$U[3/20, 1/5]$
	码元内载波周期	[20, 23]
	码序列长度	{7, 11, 13}
Frank	载频	$U[3/20, 1/5]$
	码元内载波周期	[20, 23]
	步进频率	[5, 8]
Frank	载频	$U[3/20, 1/5]$
	码元内载波周期	{4, 5, 6}

4.2 参数设置

降噪及系数优化参数同第 2 节,为减少细节特征失真,STFD 特征标准输出维度为 60×60 ,向量化特征维度为 3600. A1 数据集用于参数验证,正则参数 λ 为 0.01,核函数选择 Gaussian 函数,终止条件为迭代误差小于 0.001 或达到最大迭代次数 10,MSGD 中动量因子 α_Q 和 α_A 均为 0.5,其余参数为 $\beta = 10$ 、 $\gamma_0 = 1$ 、 $\eta_0 = 0.001$ 、 $B = 400$ 、降维参数 $m = 300$ 、各子字典原子数相同均为 $N_0 = 100$. 实际应用时,字典原子数、降维参数、学习率参数更为重要,其余部分参数对识别性能的影响分析如下:(1)斜率参数 β 能够灵活调节 $S_\beta(x)$ 平滑程度和梯度权值, β 越小收敛越慢; β 越大收敛速度越快,但易陷入饱和区. 批量训练时,梯度平均方式能够有效降低陷入饱和区概率,取 $\beta \in [5, 10]$ 性能较好;(2)批量计算方式降低了小样本计算引入的梯度方向不确定性和计算开销. 批量参数 B 较小时效性不强,较大时稳定性下降,本文设置适中值 $B = 200$.






图3 不同学习率对识别率性能影响

学习率一定程度影响识别性能,取 $\gamma_0 \in [0.01, 1]$ 且 $\eta_0 \in [0.001, 1]$,不同学习率参数下的整体平均识别率如图 3 所示. 结果表明:当 γ_0 和 η_0 均为 1 时梯度更新的稳定性较低,识别性能相对较差;其余条件下识别性能相当且均能有效收敛. 实际应用时,选择适中的学习率即可,本文设置 $\gamma_0 = 1$ 、 $\eta_0 = 0.001$.

子字典原子数 N_0 和降维参数 m 较大程度影响子字典的类内表征和类间辨识能力,合理降低 N_0 和 m 有利于降低特征冗余和计算复杂度. 选取 $N_0 \in [50, 200]$ 与 $m \in [50, 500]$ 进行测试,不同 N_0 与 m 对应识别性能如图 4 所示. 图 4(a) 为 N_0 与 m 对整体平均识别率影响, $N_0 \geq 100$ 且 $m \geq 100$ 时性能较优, N_0 较小时字典表征能力不足, m 较小时特征辨识度不高. 图 4(b) 为各信噪比下平均测试时间受参数 N_0 与 m 影响情况,参数与测试时间保持正相关关系,随着 N_0 与 m 增大,计算复杂度逐渐增大. 综合考虑识别率与计算复杂度,子字典原子数和降维参数和分别设为 $N_0 = 100$ 、 $m = 300$.



(a)参数对识别影响



(b)参数对测试时间影响

图4 子字典原子数 N_0 与降维参数 m 对比识别性能影响

4.3 实验结果对比

4.3.1 特征稳定性分析

特征稳定性直接影响识别性能,选择数据集 A1 中 -4dB 环境数据进行测试,每类数据随机选择 100 个样本,采用 TSNE 算法^[10] 进行特征可视化处理,结果如图 5 所示. 特征预处理阶段共包含 STFT 时频特征、降噪处理后 DSTFT 特征和 STFD 特征三种特征. 对比 TSNE 二维特征图得出:初始 STFT 特征类内聚集性较差且类间距离较小,其中 BPSK、QPSK 和 SCS 信号类间辨识度相对较低;降噪后 DSTFT 特征在特征图上的表现与 STFT 特征差异性不大;STFD 特征具备较高的类内聚集性和类间辨识度. 为验证预处理算法有效性并分析其性能增益,引入文献[2]的预处理算法提取 STFT-TFI 特征进行对比. 数据集 A1 和 A2 上的测试结果如图 6 所示. 综合对比四类特征下的识别性能得出:STFT 特征受噪声影响较大,降噪等预处理方式能够有效改善低信噪比环境下识别性能;本文降噪处理方式有效抑制了噪声

干扰,但引入了一定程度信息损失,在高信噪比条件下(例如 A2 数据集下 0dB 以上环境)识别性能受到影响;STFD 特征进一步降低了特征冗余,使得细节特征更为

稳定,识别性能整体较优;文献[2]的 STFT-TFI 特征在 -2dB 以上环境较为稳定,优于 STFT 特征和 DSTFT 特征,但低信噪比环境适应性不佳。




图5 -4dB条件下不同特征在TSNE空间的二维特征图

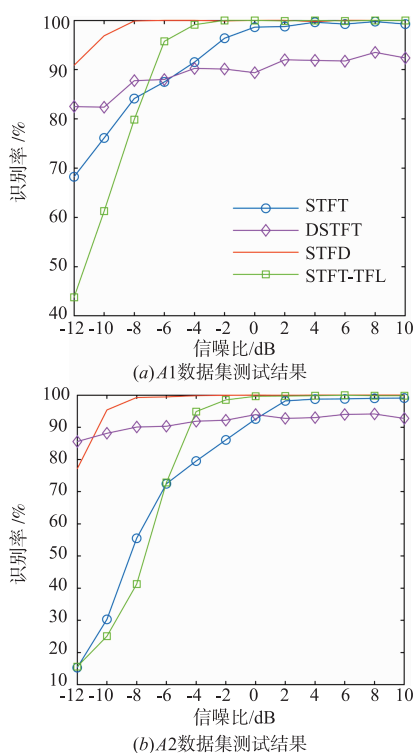


图6 A1、A2数据集下不同特征的识别性能对比

综合对比分析得出:(1)A2 数据集仅利用 10dB 训练集优化系统,取得了与 A1 相当的识别性能,降低了系统冗余,间接表明了特征预处理算法的有效性和对系统冗余的改善能力;(2)A1 数据集下,针对各信噪比环境进行模型独立训练方式更具针对性,模型可自主学习噪声背景下的特征。但需要较高精度信噪比估计;(3)A2 数据集下,系统性能依赖于特征预处理算法,STFD 特征具备较高稳定性,在 -4dB 以下环境明显优于文献[2]的预处理方式。实际应用中,针对低信噪比环境样本难获取、系统冗余不宜过高等情况,利用高信噪比数据完成系统优化可行性更高,具备应用价值。

4.3.2 不同识别算法对比

为验证本文 KCRDP 识别方法的综合性能,选用数据集 A1 与 STFD 特征进行测试,并与如下方式进行对比:(1)K 最近邻(KNN, K-Nearest Neighbor);(2)SVM;(3)LC-KSVD^[6];(4)CNN^[2];(5)随机投影与压缩协作表示(RP-CCR, Random Projection and Compressively Collaborative Representation)^[5]。其中,KNN 最近邻参数为 4,SVM 选择径向基核函数;LC-KSVD 中稀疏度为 12,稀疏编码项和分类判别项系数分别为 4、2,子字典原子数均为 100;CNN 结构同文献[2],采用 Adam 算法优化,最大迭代 50 次,初始学习率为 0.001,批量参数为 128,一阶及二阶矩估计分别为 0.9、0.999,扰动项为 $1e^{-8}$;RP-CCR 降维参数和正则参数同 KCRDP。

各类算法的识别结果如图 7 所示,其识别性能均随信噪比保持递增趋势。图 7(a)中,STFD 特征具备较高稳定性,各方式均取得了优于 84% 的识别率且差异性相对较小。当信噪比大于 -4dB 时,识别效果基本趋于稳定。其中,KCRDP 性能最优,较其余方式在 -12dB 时能够获得约 2%~7% 的性能增益。图 7(b)中,STFT 特征稳定性较低,各方式的性能差异较明显。其中,KCRDP 和 CNN 方式的性能较优,KCRDP 方式仅在 -4dB 时弱于 CNN 方式。综合分析表明,STFD 特征具备较高稳定性,KCRDP 方式具备较优的识别性能。

选取 -10dB 信噪比环境,按表 1 顺序将信号依次记为 S1~S8,KCRDP 方式下各信号识别结果如表 2 所示。其中,BFSK 和 QFSK 存在一定程度混淆;LFM 和 NLFM 相似度较高,混淆程度相对较大。综合来看,整体平均识别率达到 96.88%,系统对低信噪比环境适应性较强。

4.3.3 系统鲁棒性分析

为分析系统在小样本训练集下的鲁棒性,选择 [-12, -10, -8] dB 信噪比环境数据进行测试。每个信噪比下的测试样本为每类 50 个;训练样本量对应每

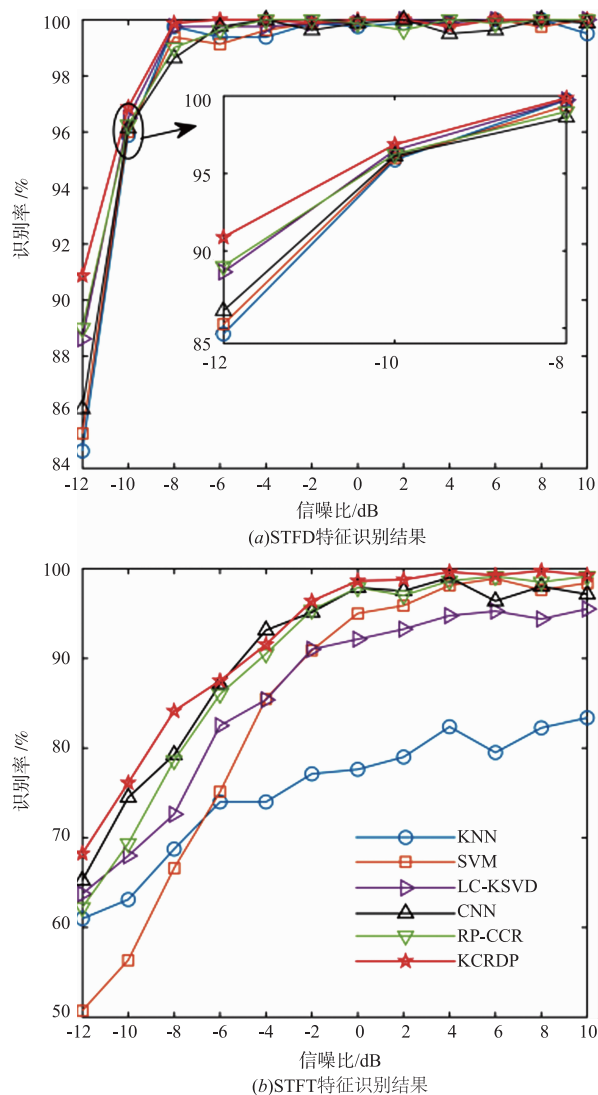


图7 不同信噪比条件下各识别算法性能比较

个信噪比每类 30 ~ 150 个(间隔 30). 识别结果循环十次取平均,得到图 8 所示三种不同信噪比环境下训练样本量与识别率关系曲线. 当训练数据量为 30 个样本时, -12dB 环境下识别率约为 82.75%;随着训练数据量增加,识别率呈递增趋势,当训练样本量达到 150 时,识别率均高于 90%,表明系统具备较强鲁棒性,能够有效适应小样本数据集.

表 2 -10dB 条件下辐射源识别混淆矩阵(单位: %)

	S1	S2	S3	S4	S5	S6	S7	S8
S1	100	0	0	0	0	0	0	0
S2	1	97	2	0	0	0	0	0
S3	0	1	99	0	0	0	0	0
S4	0	1	0	94	4	0	0	1
S5	0	0	1	6	93	0	0	0
S6	0	0	0	0	0	100	0	0
S7	1	0	0	0	0	4	93	2
S8	0	1	0	0	0	0	0	99




图8 不同信噪比条件下训练样本量与识别率关系曲线

4.3.4 系统复杂度分析

计算复杂度是衡量系统性能的重要指标. 预处理阶段,STFT 的时效性受采样序列长度和窗长度影响,降噪时效性主要受原始时频信号维度影响,STFD 的时效性主要受窗宽和输出特征维度影响. 选择 10dB 环境数据进行测试,单个样本在 STFT、降噪和 STFD 处理各阶段的平均时耗分别为 0.1450s、0.0167s 和 0.0235s. 其中,时频变换计算复杂度更高,特征预处理需要一定的计算复杂度以提高特征稳定性. 分类阶段,选用数据集 A1 和 STFD 特征进行测试,仿真条件同 4.3.2 节,训练时间和测试时间均为单个信噪比环境下的平均运行时间,除 CNN 外均在 CPU 上测试,具体结果如表 3 所示. 其中,KNN 和 SVM 方式训练耗时较短,但测试过程时效性一般;LC-KSVD 测试时效性较优;CNN 给出了 GPU 和 CPU 两种环境下的计算复杂度,GPU 具备较高时效性,测试时间仅次于 RP-CCR 和 KCRDP 方式;RP-CCR 无需字典学习,其 ℓ_2 优化形式的分类时效性较高. 相比之下,本文 KCRDP 的训练过程涉及优化迭代,需一定计算复杂度,但鉴别投影与 ℓ_2 优化形式降低了测试复杂度,保证了测试时间最优. 监督学习方式的优化过程一般通过离线学习完成,训练阶段耗时可暂不考虑,系统时效性取决于测试时间. 综合对比识别结果及计算复杂度,本文方式在识别准确率和识别效率上均具备一定优势.

表 3 不同识别方式计算复杂度对比

识别算法	训练时间/s	测试时间/s
KNN	0.0435	0.4466
SVM	0.7921	0.1946
LC-KSVD	38.1873	0.1150
CNN(CPU)	34.5075	0.4073
CNN(GPU)	7.5912	0.1007
RP-CCR	0	0.0917
KCRDP	12.1824	0.0764

5 结论

本文提出了一种基于核协同表示与鉴别投影的分类识别系统,充分考虑了特征稳定性与分类时效性,通过时频变换、降噪及二次特征处理强化特征差异,利用 KCRDP 实现特征高效降维和分类识别. 在两种不同数据集设置下,仿真验证了 STFD 特征的稳定性和 KCRDP 识别方式的有效性. 实验结果表明, KCRDP 在识别率和测试时效性方面均表现出一定优势,具备较强的鲁棒性和时效性,能够有效适应低信噪比环境和数据样本容量变化. 此外,当实际应用中难以获取低信噪比环境下样本时,可利用高信噪比训练集完成系统优化.

参考文献

- [1] IGLESIAS V, et al. Real-time low-complexity automatic modulation classifier for pulsed radar signals [J]. IEEE Transactions on Aerospace and Electronic Systems, 2015, 51(1): 108 - 126.
- [2] ZHANG M, et al. Convolutional neural networks for automatic cognitive radio waveform recognition [J]. IEEE Access, 2017(5): 11074 - 11082.
- [3] BAO C, et al. Dictionary learning for sparse coding: algorithms and convergence analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(7):

1356 - 1369.

- [4] MA J, et al. Robust radar waveform recognition algorithm based on random projections and sparse classification [J]. IET Radar Sonar & Navigation, 2014, 8(4): 290 - 296.
- [5] 周志文, 等. 基于压缩协作表示的辐射源识别算法 [J]. 航空学报, 2016, 37(7): 2251 - 2258.
ZHOU Zhi-wen, et al. Emitter recognition algorithm based on compressively collaborative representation [J]. Acta Aeronautica et Astronautica Sinica, 2016, 37(7): 2251 - 2258. (in Chinese)
- [6] JIANG Z, et al. Label consistent K-SVD: learning a discriminative dictionary for recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(11): 2651 - 2664.
- [7] HUA J, et al. Dimension reduction using collaborative representation reconstruction based projections [J]. Neurocomputing, 2016, 193: 1 - 6.
- [8] ZHANG G, et al. Kernel dictionary learning based discriminant analysis [J]. Journal of Visual Communication and Image Representation, 2016, 40(7): 470 - 484.
- [9] ZHANG H, et al. Simultaneous discriminative projection and dictionary learning for sparse representation based classification [J]. Pattern Recognition, 2013, 46(1): 346 - 354.
- [10] GUO Q, et al. LPI radar waveform recognition based on deep convolutional neural network transfer learning [J]. Symmetry, 2019, 11(4): 540.

作者简介



李东瑾 男, 1992 年出生, 四川广元人, 空军预警学院博士研究生, 主要研究方向为一体化系统智能应用及表示学习.
E-mail: li_dong_jin@163.com



杨瑞娟 女, 1964 年出生, 四川中江人, 空军预警学院教授、博士生导师, 主要研究方向为雷达通信一体化及雷达组网.
E-mail: ruijuany@sohu.com



李晓柏 男, 1983 年出生, 甘肃陇西人, 空军预警学院讲师、博士. 主要研究方向为雷达通信一体化及波形设计.
E-mail: lxb2cici@163.com



董睿杰 男, 1995 年出生, 新疆库尔勒人, 硕士. 主要研究方向为一体化系统智能应用.
E-mail: drjkuw@126.com