

基于栈式稀疏降噪自编码网络的 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: 针对辐射源识别中噪声敏感和识别能力不足等问题,提出了一种基于核空间时频特征与栈式稀疏降噪自编码网络的识别系统. 通过时频变换、稀疏域降噪和核空间降维投影降低噪声干扰和特征冗余,基于降噪自编码与稀疏自编码思想构建栈式稀疏降噪自编码识别网络. 实验结果表明系统在识别率和时效性上综合性能最优,能够显著降低噪声敏感性,低信噪比环境下适应性较强. 当信噪比为 -12dB 时,系统对 8 类辐射源信号的整体平均识别率达到 96.75%.

关键词: 辐射源识别; 稀疏降噪自编码; 时频特征; 核映射; 批量随机梯度下降法; dropout 正则化
中图分类号: TN957.51 **文献标识码:** A **文章编号:** 0372-2112 (2020)06-1198-11
电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.06.022

Emitter Signal Modulation Recognition Based on Stacked Sparse Denoising Auto-Encoders

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

Abstract: To enhance the classification performance and noise sensitivity of emitter signal recognition, a recognition system based on kernel space time-frequency feature and stacked sparse denoising auto-encoders (SSDAE) is proposed. Firstly, the noise interference and feature redundancy reduced by time-frequency transform, sparse-domain denoising and kernel space dimensionality reduction. Then, it is based on the idea of sparse auto-encoder (SAE) and denoising auto-encoder (DAE), an SSDAE based recognition network is constructed. Experimental results show that the system has the best comprehensive performance in recognition rate and time efficiency, which can significantly reduce noise sensitivity and improve low SNR environment adaptability. When the SNR is -12dB , the overall average recognition rate of the system for the 8 types of emitter signals reaches 96.75%.

Key words: emitter signal recognition; sparse denoising auto-encoder; time-frequency feature; kernel mapping; mini-batch stochastic gradient descent method (MSGD); dropout regularization

1 引言

随着信息化技术和新型装备地不断革新,辐射源调制识别技术在电磁频谱域对抗中的重要性日益凸显,高效识别带来的无源信息增益将直接影响电磁对抗等后续任务实施的精准化程度. 近年来,基于深度学习的识别技术成为热点. 文献[1]和[2]分别采用栈式稀疏自编码网络(SSAE, Stacked Sparse Auto-Encoders)、卷积神经网络(CNN, Convolutional Neural Network)进行

信号识别,但需信噪比先验估计,存在噪声敏感和系统复杂度高问题. 深度学习应用于已知领域信号处理时,人工经验仍具备较强的指导性,特征工程带来的确定性增益能够有效降低数据量和网络深度等需求. 基于此,本文对辐射源识别系统的特征工程和分类网络进行联合设计,特征工程部分获取信号低维表征并降低噪声污染,以便形成统一表征模型并增强低信噪比环境适应性;分类网络设计考虑训练与测试样本中噪声成分不同引入的差异性,引入噪声干扰和约束准则

增强泛化能力;同时,采用无监督学习机制初始化网络参数,避免陷入局部最优解。

本文提出了基于时频变换、稀疏域降噪和核映射降维的联合特征提取算法,同时,建模了基于栈式稀疏降噪自编码的分类识别网络,系统主要功能如下:(1)核空间时频特征提取,通过加权短时傅里叶变换(STFT, Short Time Fourier Transform)获取初始特征并利用时频域稀疏性完成降噪,采用核空间降维映射完成特征提取,降低冗余信息并保留低维特征;(2)基于栈式稀疏降噪自编码网络(SSDAE)的分类识别,聚焦于分类器模型表征与泛化能力提升,引入稀疏与正则约束降低过拟合风险,利用交叉熵准则构建全局目标函数,采用链式求导法则和动力增量约束的小批量随机梯度下降法(MSGD)^[3]进行优化。

2 核空间 STFT 特征提取及预处理

2.1 辐射源信号数学模型

高斯白噪声环境下截获辐射源单脉冲序列为

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

其中, A 为幅度信息, f_0 为信号载频, θ 为脉内调制信息, n 为高斯白噪声干扰项。本文考虑单载频(SCS, Single Carrier Signals)、BFSK、QFSK、LFM、NLFM、BPSK、QPSK、Frank 八种调制方式。

2.2 STFT 时频特征与稀疏域降噪

短时傅里叶变换对局部特性和整体结构具备较稳定表征能力且时效性较高。实际应用中,截获数字信号常包含过采样信息增益,但计算负载较大。本文通过等比加权方式降低数据率并提高时效性。设中频带宽内信号实际采样率和奈奎斯特采样率分别为 F_s 和 f_s , 过采样因子为 β_0 , 上限为 F_s/f_s 且为整数。加权处理的离散域短时傅里叶变换为

$$T(m_1, n_1, \beta_0) = \sum_{k=0}^{N-1} \sum_{i=0}^{\beta_0-1} x(i + k\beta_0) \cdot h^*(k - m_1) \exp\left(-j \frac{2\pi n_1 k}{N}\right) \quad (2)$$

其中, m_1 、 n_1 分别为时域、频域索引,过采样序列 $x(k)$ 长度为 $N\beta_0$, N 为傅里叶变换长度, $h^*(k)$ 为 $N/4$ 长度的 Hamming 窗函数共轭。相邻 β_0 个采样点的频率分辨范围对应一个奈奎斯特分辨单元,加权处理不影响整体时频结构,且一定程度改善信噪比。实际应用中,辐射源信号在带宽和时频空间分布等方面存在差异性,直接处理往往存在较大冗余。因此采用降噪、核空间映射及降维提取低维特征,降噪处理用于降低噪声干扰,具体流程如下:

- (1) 对原始时频信号下采样,降维至 $T_{m \times m}$;
- (2) 构建滤波系数矩阵 $F_{m \times m} = [f_1, f_2, \dots, f_m]$, 列

向量 $f_j (j \in [1, m])$ 对应局部频域维特征,具备稀疏性,逐列进行归一化处理

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

其中, μ_j 为列向量 f_j 的最大值;

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

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

其中, α_j 为列向量 f_j 的均值。表示函数 $g(k)$ 收敛较快,重复式步骤(2)、(3)两次即完成优化;

(4) 降噪后二维时频信号更新为 $T = T \odot F$, 其中 \odot 为 Hadamard 积。随后对时频信号进行向量化表示且 $T \in R^{mn}$ 。

由于信号不确定性,进一步降低二维表征尺度易丢失细节特征,但此时特征空间维度较高且存在较大冗余,影响后续识别时效性。

2.3 核空间特征映射及降维

降维处理是挖掘低维数据特征的主流技术,常规降维算法主要分为两类:(1)监督学习降维;(2)无监督降维,如随机投影(RP, Random Projection)和主成分分析(PCA, Principal Component Analysis)等。常规线性降维方式使得高维冗余特征具备更紧致的低维形式,降低了计算开销,但对线性不可分特征增益较小;而非线性核映射方式能够有效改善特征分辨能力。本文采用非线性核主成分分析(KPCA, Kernel Principal Component Analysis)算法^[4]将特征映射至高维核空间,并在核空间完成线性降维。KPCA 能无监督完成核空间特征紧致表示,特征可分性更高且有利于降低计算开销。

3 基于栈式稀疏降噪自编码网络的辐射源调制识别系统

常规稀疏自编码器通过无监督稀疏约束完成优化,而降噪自编码器通过随机破坏原始数据分布增强泛化能力,本文深度融合二者优势并构建 SSDAE,网络具备以下特点:(1)考虑样本差异性,引入随机噪声干扰^[5]破坏训练样本数据分布,增强网络泛化能力;(2)引入稀疏限制和 l_2 正则约束增强无监督学习能力;(3)考虑过拟合风险,微调阶段引入 dropout 正则约束^[6]增强网络泛化能力;(4)利用栈式网络增强数据深层表征能力。

3.1 稀疏降噪自编码

栈式稀疏降噪自编码深度融合了常规 SSAE 和栈式降噪自编码器(SDAE, Stacked Denoising Auto-Encoders)^[5]特性,对受噪声污染类数据的适应性更强。图 1 所示($v^{(0)}, h^{(1)}, \tilde{v}^{(0)}$)为单层稀疏降噪自编码网络,分

别对应输入层、编码层和解码层,其目标为恢复原信号空间,使得 $\tilde{\mathbf{v}}^{(0)}$ 尽量接近 $\mathbf{v}^{(0)}$. 以第 l 隐含层为例,神经元激活状态为

$$\begin{aligned} \mathbf{h}^{(l)} &= f(\mathbf{W}^{(l)}\mathbf{h}^{(l-1)} + \mathbf{b}^{(l)}) \\ \tilde{\mathbf{v}}^{(l-1)} &= g(\tilde{\mathbf{W}}^{(l-1)}\mathbf{h}^{(l)} + \tilde{\mathbf{b}}^{(l-1)}) \end{aligned} \quad (5)$$

其中, f 与 g 分别为隐含层、解码输出层激活函数; $\mathbf{h}^{(l)}$ 为第 l 隐含层神经元激活值, $\mathbf{h}^{(0)}$ 为输入层数据且 $\mathbf{h}^{(0)} = \mathbf{v}^{(0)}$; $\mathbf{W}^{(l)}$ 为第 $l-1$ 至 l 层的编码权重项, $\mathbf{b}^{(l)}$ 为偏置项; $\tilde{\mathbf{v}}^{(l-1)}$ 为 $\mathbf{h}^{(l)}$ 隐含层的重构输出, $\tilde{\mathbf{W}}^{(l-1)}$ 为第 l 至 $l-1$ 层的编码权重项, $\tilde{\mathbf{b}}^{(l-1)}$ 为偏置项. 单层稀疏降噪自编码网络采用逐层贪心训练方式,训练完成后 $\mathbf{h}^{(l)}$ 作为下一级 $\mathbf{h}^{(l+1)}$ 的输入.

无监督自编码过程选择 Sigmoid 激活方式,均方误差作为误差表征,附加稀疏和 l_2 正则约束. 考虑梯度更新稳定性,批量优化的目标函数定义为

$$\begin{aligned} J^{(l)} &= \frac{\lambda}{2} \sum_i \sum_j ((W_{ij}^{(l)})^2 + (\tilde{W}_{ji}^{(l-1)})^2) + \beta \varphi^{(l)} \\ &+ \beta \tilde{\varphi}^{(l-1)} + \frac{1}{2m} \sum_{k=1}^m (\|\tilde{v}^{(l-1,k)} - h^{(l-1,k)}\|^2) \end{aligned} \quad (6)$$

其中,第一项为正则约束,中间项为稀疏约束,第四项为均方误差损失. λ , β 分别为正则约束系数和稀疏惩罚系数, m 为批量参数, $\mathbf{h}^{(l,k)}$ 为 l 隐含层第 k 个样本的神经元激活值. 为量测输入与重构数据的概率分布差异性,引入 KL 散度^[7]量化, $\varphi^{(l)}$ 为

$$\begin{aligned} \varphi^{(l)} &= \sum_{i=1}^{n_i} \left(\rho_0 \log\left(\frac{\rho_0}{\rho_i^{(l)}}\right) + (1 - \rho_0) \log\left(\frac{1 - \rho_0}{1 - \rho_i^{(l)}}\right) \right) \\ \rho_i^{(l)} &= \frac{1}{m} \sum_{k=1}^m f(\mathbf{W}_i^{(l)\top} \mathbf{h}^{(l-1,k)} + \mathbf{b}_i^{(l)}) \end{aligned} \quad (7)$$

其中, $\mathbf{W}_i^{(l)\top}$ 为 $\mathbf{W}^{(l)}$ 第 i 行权重项, n_i 为第 l 层神经元数, $\rho_i^{(l)}$ 为第 l 层第 i 神经元的加权平均激活值, $\rho_i^{(l)}$ 越接近期望激活值 ρ_0 , 二者概率分布越接近, $\varphi^{(l)}$ 越小. 各隐含层无监督训练时,采用链式求导法则和 MSGD 算法完成参数 $\mathbf{W}^{(l)}$ 和 $\mathbf{b}^{(l)}$ 优化更新.

噪声干扰添加在输入端,用于平衡训练集与测试集的差异性. 扰动噪声为 $\mathbf{r}^{(0)} = B(\zeta)$ 且 $\mathbf{v}^{(0)} = \mathbf{x} \odot \mathbf{r}^{(0)}$, ζ 为噪声比例. B 为伯努利分布函数,以概率值 ζ 对随机位置数据置零.

3.2 基于栈式稀疏降噪自编码的识别网络

逐层完成隐含层训练后,移除解码层并添加 Softmax 分类器得到 SSDAE 识别网络. SSDAE 可整体迁移至深度神经网络架构中,仅需进行有监督微调即可避免复杂的参数调优过程. 为防止网络过拟合并增强泛化能力,微调阶段采用 dropout 正则替代 l_2 正则,即以一定失活概率 p 随机对神经元激活值置 0,随机失活函数为 $\mathbf{r}^{(l)} = B(p)$. 因此,隐含层激活表示为 $\bar{\mathbf{h}}^{(l)} =$

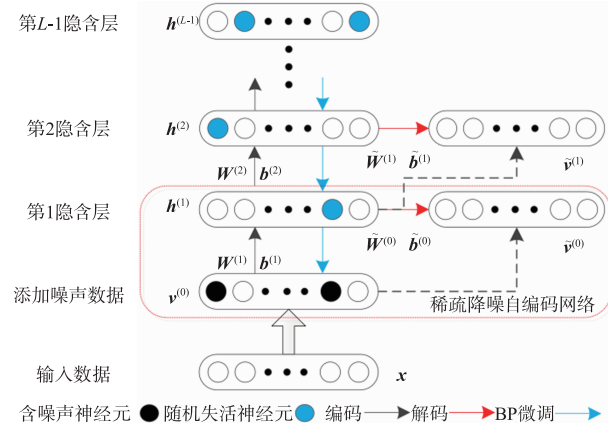


图1 栈式稀疏降噪自编码网络

$\mathbf{h}^{(l)} \odot \mathbf{r}^{(l)}$, 稀疏项加权平均激活值表示为 $\tilde{\rho}^{(l)}$. 对于 L 层 SSDAE, 定义 l 层未激活状态为 $\mathbf{z}^{(l)}$, 则 $\mathbf{h}^{(l)} = f(\mathbf{z}^{(l)})$, 对应激活状态为

$$\mathbf{h}^{(l)} = f(\mathbf{W}^{(l)}\mathbf{h}^{(l-1)} \odot \mathbf{r}^{(l-1)} + \mathbf{b}^{(l)}) \quad (8)$$

对于 C 分类问题, Softmax 输出层激活状态为

$$h_i^{(L)} = \frac{\exp\left(\sum_{j=1}^{n_{L-1}} W_{ij}^{(L)} \bar{h}_j^{(L-1)} + b_i^{(L)}\right)}{\sum_{i=1}^C \exp\left(\sum_{j=1}^{n_{L-1}} W_{ij}^{(L)} \bar{h}_j^{(L-1)} + b_i^{(L)}\right)} \quad (9)$$

其中, $\bar{\mathbf{h}}^{(L)} = \mathbf{h}^{(L)}$. 利用交叉熵进行全局误差表征, 附加稀疏与正则约束的全局目标函数定义为

$$J = \frac{1}{m} \sum_{k=1}^m \left(- \sum_{i=1}^C (y_{i,k} \log(h_i^{(L,k)})) \right) + \beta \sum_{i=1}^L \varphi^{(i)} \quad (10)$$

其中, 第一项括号内为交叉熵误差 J_L , 第二项为稀疏约束项 J_1 , $y_{i,k}$ 为第 i 类第 k 个样本的标签. 采用链式法则进行误差反向传播, 设分类误差为 $\delta \in R^C$, 则第 i 类误差为 $\delta_i = y_i - h_i^{(L)}$, 则 J_L 的输出层传播误差为 $\delta^{(L)} = -\delta$. 当 $l \leq L-1$ 时, 各隐含层传播误差 $\delta^{(l)}$ 为

$$\delta^{(l)} = (\mathbf{W}^{(l+1)})^\top \delta^{(l+1)} \odot f'(\mathbf{z}^{(l)}) \odot \mathbf{r}^{(l)} \quad (11)$$

其中, f' 为激活函数偏导数. 部分表示简化如下

$$\begin{aligned} \mathbf{K}_1^{(l)} &= \beta \left(-\frac{\rho}{\tilde{\rho}^{(l)}} + \frac{1-\rho}{1-\tilde{\rho}^{(l)}} \right) \\ \mathbf{K}_2^{(l)} &= f'(\mathbf{z}^{(l)}) \odot \mathbf{r}^{(l)} \end{aligned} \quad (12)$$

其中, $\tilde{\rho}^{(l)} = \sum_{k=1}^m \bar{h}^{(l,k)} / m$, J_1 对应梯度表示为

$$\begin{aligned} \frac{\partial J_1}{\partial \mathbf{W}^{(l)}} &= \mathbf{K}_1^{(l)} \odot \frac{1}{m} \sum_{k=1}^m (\mathbf{K}_2^{(l,k)} \odot (\bar{\mathbf{h}}^{(l-1,k)})^\top) \\ \frac{\partial J_1}{\partial \mathbf{b}^{(l)}} &= \mathbf{K}_1^{(l)} \odot \frac{1}{m} \sum_{k=1}^m \mathbf{K}_2^{(l,k)} \end{aligned} \quad (13)$$

综合式(11)~(13), 参数 \mathbf{W} 与 \mathbf{b} 的梯度表示为

$$\mathbf{g}_W^{(l)} = \frac{1}{m} \sum_{k=1}^m \psi^{(l,k)} \odot (\bar{\mathbf{h}}^{(l-1,k)})^\top$$

$$\mathbf{g}_b^{(l)} = \frac{1}{m} \sum_{k=1}^m \boldsymbol{\psi}^{(l,k)}$$

$$\boldsymbol{\psi}^{(l,k)} = ((\mathbf{W}^{(l+1)})^T \boldsymbol{\delta}^{(l+1,k)} + \mathbf{K}_1^{(l)}) \odot \mathbf{K}_2^{(l,k)} \quad (14)$$

任意层的 \mathbf{W} 和 \mathbf{b} 均可通过式(14)及误差反向传播机制实现更新,终止条件为达到误差下限或最大迭代次数,具体求解步骤见算法 1:

算法 1 栈式稀疏降噪自编码网络优化算法

输入:训练样本与网络超参数

预训练:

随机打乱训练样本,并按批量参数 m 划分批次;

对输入样本添加比例为 ζ 的随机噪声;

利用式(6)初始化各层网络参数 \mathbf{W} 和 \mathbf{b} ;

微调:

利用式(10)计算每个批次样本损失,通过式(14)逐层进行反向梯度更新;

利用 MSGD 算法更新当前批次的各层参数 \mathbf{W} 和 \mathbf{b} ;

达到终止条件停止迭代.

输出:SSDAE 及各层参数 \mathbf{W} 和 \mathbf{b}

3.3 基于 SSDAE 的辐射源识别

识别系统如图 2 所示,模型优化在训练阶段完成,对应有监督学习流程为:(1)利用第二节方法提取向量化特征;(2)将训练样本集送至 SSDAE,添加随机噪声干扰;(3)通过无监督预训练完成网络参数初始化;(4)通过监督训练完成网络参数微调.测试阶段采用无监督方式完成,测试数据集经过相同特征处理后送至 SSDAE 完成识别验证.

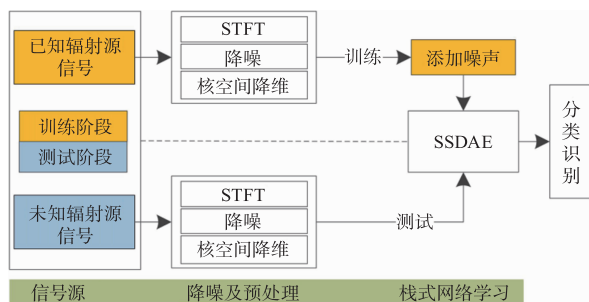


图2 基于SSDAE的辐射源识别系统

4 仿真与分析


4.1 实验环境

信号仿真参数满足均匀随机分布,以此保证样本同分布且无重叠.采样总时长 T 为 $10\mu\text{s}$,奈奎斯特采样率 f_s 为 100MHz ,采样频率 300MHz .信号频率范围 $f_s/2 \sim f_s/2$,持续时间 $T/2 \sim T$.其中,BPSK 和 BFSK 随机采用 7、11 或 13 位巴克码序列,QPSK 和 QFSK 随机采用 7、11 或 13 位码序列,FRANK 信号步进频为 5~8.测试环境如下:(1)训练集在 10dB 条件下生成,每类信号


1400 个样本,样本容量为 11200;(2)测试集在 $-14 \sim 10\text{dB}$ (步长 2dB)条件下生成,每个信噪比下单类信号样本为 200,样本容量为 20800.

4.2 参数设置

特征预处理阶段,采用三倍过采样处理,核映射选择二阶 Poly 核函数,为兼顾特征损失和时效性,二维时频空间下采样后维度为 $(60, 60)$,降维参数为 1000. SSDAE 超参数设置如下: λ 、 β 和 ρ 分别设置为 0.01、0.1 和 0.05,批量参数 m 为 100,动量因子和学习率分别为 0.9、0.1,循环迭代最大次数为 100,噪声比例和失活概率均为 0.2,网络结构为 1000-1600-100-8.



(a)神经网络数对识别率影响



(b)神经网络数对优化时长影响

图3 各层神经元数对识别性能影响

实际应用中,网络越深更易提取高阶特征,但本文特征复杂度和类别数均相对较小,综合考虑识别性能和时效性,设计三层 SSDAE.其中第一层神经元数取 $[800, 1600]$,中间隐含层神经元数取 $[100, 800]$,最高层进行分类识别.固定噪声比例和失活概率为 0.2,对应识别性能如图 3 所示.对比分析得出:所有网络均能实现优于 98% 的整体平均识别率,网络性能与神经元数量为非线性关系,优化时长与神经元数量呈同步递增趋势.当第一层、第二层神经元分别取 1600、100 时整体性能较优,第一层神经元数量适当高于输入数据维度能够获取较好的稀疏性和高维表征能力.

表 1 噪声比例和失活概率对识别性能影响(单位:%)

$\zeta \backslash p$	0	0.2	0.4	0.6	0.8
0	97.532	98.288	98.288	98.212	91.534
0.1	98.529	98.635	98.409	98.337	90.389
0.2	98.534	98.750	98.625	98.313	87.712
0.3	98.529	98.567	98.548	97.807	87.014
0.4	98.644	98.471	98.260	97.615	87.548
0.5	98.202	98.269	97.899	95.091	74.024

设定 ζ 取值范围 $[0, 0.5]$, 随机失活概率 p 范围 $[0, 0.8]$, 对应整体平均识别率如表 1 所示. 结果表明: (1) ζ 过低泛化能力不足, 过高易偏离数据原始分布导致性能下降, 综合考虑选择 0.2; (2) p 越大随机性越大, 取值为 0.8 时失活神经元过多导致性能损失, 设置为 0.2 时性能较优. 实际应用中, p 为 0.5 时随机性最大, 常作为经验设置.

4.3 实验结果对比

4.3.1 不同特征处理方式对比

图 4 所示为过采样因子 $\beta_0 \in [1, 3]$ 时识别性能随信噪比变化曲线以及不同降维方式下识别性能曲线. 对比不同过采样因子曲线得出: 识别性能均随信噪比呈递增趋势, 高信噪比时趋于稳定. 过采样率越高, 加权处理获取的信噪比改善增益越高, 对应识别性能越好, 过采样加权处理使得低信噪比环境下性能明显改善. 对比不同特征降维方式性能得出: RP 随机投影方式性能较差, PCA 对线性不可分特征改善能力不及 KPCA, 非线性降维方式 KPCA 性能最佳.




图 4 不同过采样因子与降维方式下识别性能

为对比不同特征处理方式带来的定量性能增益, 选择如下特征进行对比实验: (1) 未降噪且不降维的 STFT 特征; (2) 降噪不降维的 DSTFT 特征; (3) 未降噪但降维的 STFT-KPCA 特征. 记本文特征为 DSTFT-KPCA, 实验结果如图 5 所示. 分析得出: (1) STFT 特征包含较多噪声干扰和特征冗余, 在 $-10\text{dB} \sim 4\text{dB}$ 时稳定性

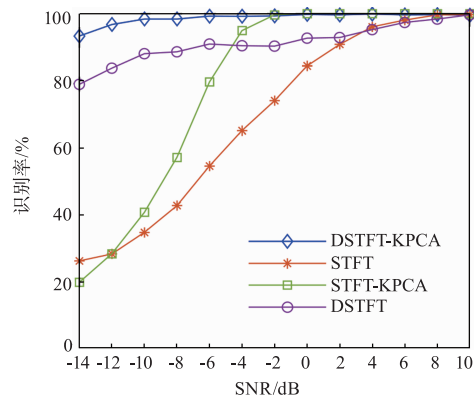


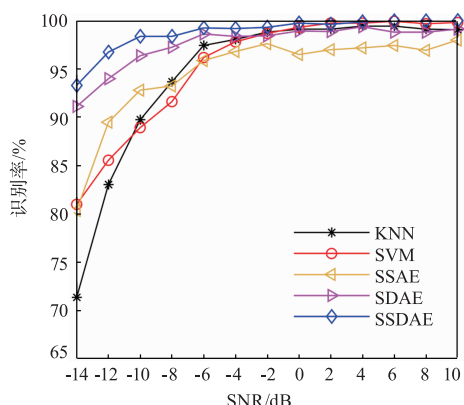
图 5 不同特征处理方式对识别性能影响

较低; (2) DSTFT 特征在 $-14 \sim 2\text{dB}$ 低信噪比环境下识别性能较 STFT 特征明显改善, 但 $4 \sim 10\text{dB}$ 时性能不及 STFT 特征. 原因在于降噪处理无需信噪比先验估计, 侧重于保留能量聚焦部分特征, 在高信噪比时易弱化细节特征; (3) STFT-KPCA 特征经过核映射降维提高了分辨能力, $-12\text{dB} \sim 10\text{dB}$ 时性能优于 STFT 特征, 但在更低信噪比环境下难以改善特征辨识度; (4) DSTFT-KPCA 特征兼顾了降噪与降维处理, 具备更紧凑的特征表示和更高稳定性, 核映射机制进一步改善了特征辨识度, 低信噪比环境下稳定性优于其余几类特征, 整体识别性能最优. 综合来看, 高维特征冗余度较高且辨识度不强, 会显著增大计算开销和网络优化时长; 降噪与降维处理分别改善了噪声敏感性和特征细节分辨能力, 同时提高了分类时效性, 使得特征具备低维高效表征能力.

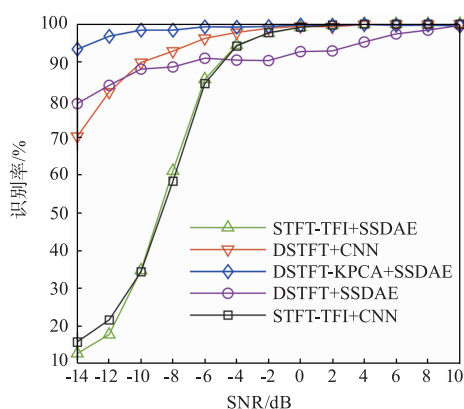
4.3.2 不同识别算法对比

为验证 SSDAE 综合性能, 选择如下五种识别方式进行对比: (1) KNN; (2) SVM^[8]; (3) SDAE^[1]; (4) SDAE^[5]; (5) CNN^[2]. 结果如图 6 所示, 图 (a) 为本文特征下各识别算法性能, 综合对比得出: (1) SSDAE 性能最佳, -14dB 时识别率达到 93.31%, 较常规机器学习方式性能明显提升; (2) SDAE 性能不及 SDAE 和 SSDAE, 其稀疏正则约束对含噪数据集的泛化能力不足; (3) SDAE 在 $0 \sim 10\text{dB}$ 时性能存在一定局限性. 本文特征工程和栈式网络综合考虑噪声影响, 随机噪声干扰有助于性能提升, 稀疏与正则约束有利于增强泛化能力.

CNN 识别方式需要二维或三维特征向量, 输入 DSTFT 特征进行对比. 为充分对比性能, 同时采用文献 [2] 的预处理方式提取 STFT-TFI 特征进行对比, 图 6 (b) 为识别结果. 对比得出: (1) 采用 CNN 识别时, STFT-TFI 稳定性不及 DSTFT, 对应的图像降噪算法在低信噪比环境下的噪声抑制性能不佳; (2) 选用 DSTFT 特征时, CNN 的卷积核形式能够获取更多时频局部特



(a)DSTFT-KPCA特征下识别结果



(b)不同特征与识别方式综合对比

图6 不同识别算法性能比较

征,对二维时频特征随机位置变化适应性较强,在 -10dB ~ 10dB 环境下性能优于 SSDAE;(3) 选用 STFT-TFI 特征时,低信噪比下识别性能较差.原因在于文献 [2] 针对每个信噪比训练识别模型,需要预估信噪比,且特征处理更侧重完整性而非噪声抑制,因此不同信噪比环境下数据差异性较大,采用高信噪比数据训练难以提高低信噪比环境下数据的泛化性能;(4) 综合对比本文方式和 CNN, -14dB ~ 0dB 环境下本文识别方式性能更优,在低信噪比环境下具备优势.

表 2 8 类辐射源识别混淆矩阵(单位:%)

	S1	S2	S3	S4	S5	S6	S7	S8
S1	94.5	1.5	0	0	0	2.5	1.5	0
S2	1.5	98	0.5	0	0	0	0	0
S3	0	0	100	0	0	0	0	0
S4	0	0	0	97	3	0	0	0
S5	0	0	0	2	98	0	0	0
S6	0.5	0	0	0	0	90	9.5	0
S7	0	0	0	0	0	3	97	0
S8	0	0	0	0	0	0	0.5	99.5

按 2.1 节顺序将信号记为 S1 ~ S8,表 2 所示为

-12dB 环境下 SSDAE 识别的混淆矩阵.其中 SCS 识别性能相对较低,LFM 与 NLFM、BPSK 与 QPSK 混淆程度相对较大.综合来看,整体平均识别率达到 96.75%,系统在低信噪比环境下识别能力较强.

4.3.3 系统鲁棒性分析

为验证高信噪比数据训练所得统一表征模型有效性,记原训练集为 A1,选择训练集 A2(每个信噪比下单类样本数为 250,信噪比范围 0 ~ 10dB,步长 2dB,样本容量 12000)进行对比测试.在样本容量相当前提下,A1 和 A2 整体平均识别率分别为 98.75%、98.79%,A2 包含更多真实残留噪声成分,最终性能二者相当,间接表明了系统有效性.




图7 不同样本容量下识别性能对比

网络性能一定程度依赖于大数据样本,选择每类样本数为 [200:1400] (步长 300),得到图 7 所示为不同训练样本容量下识别性能.对比得出:识别性能随样本容量呈递增趋势,样本容量为 200 时网络欠拟合,识别性能不佳;样本容量为 1400 时性能较理想且趋于稳定.实际应用中,低信噪比环境样本的人工筛选和标注耗费巨大,而该系统能够有效利用高信噪比易标注样本完成系统优化,显著降低了系统噪声敏感性和样本需求;若能进一步获取低信噪比标注数据,性能可进一步提升.因此,利用易标注高信噪比数据训练统一表征模型更具实用性.

4.3.4 系统复杂度分析

表 3 所示为不同识别方式计算复杂度比较,综合对比得出:KNN、SVM 训练耗时较短,测试耗时较长;SSAE、SDAE 和 SSDAE 训练耗时相对较大,但测试时效性较高;CNN 对计算资源需求较高,时效性相对较差.其中,SSDAE 采用 dropout 正则时需标记随机失活位置用于梯度更新,训练耗时略大于 SSAE 和 SDAE,测试时长差异性不大.监督学习方式可离线完成,测试阶段时效性直接影响识别效率.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效率上综合性能较优.

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	3.211	291.330
SVM	211.478	307.286
SSAE	413.455	7.214
SDAE	404.764	6.452
CNN	5475.02	718.52
SSDAE	447.903	7.692

5 结论

深度学习的性能优势依赖于大数据样本,将其应用于辐射源识别必须解决噪声敏感、数据获取及标注等一系列问题,而特征工程的合理利用将有助于降低深度学习的应用限制. 本文识别系统兼顾特征工程和分类网络设计,利用特征工程降噪和栈式网络随机添加噪声形式降低系统的噪声敏感性,同时考虑了特征非线性与网络过拟合风险对性能影响. 该系统可直接利用高信噪比易标注数据样本训练获取统一表征模型,进而降低系统冗余和数据需求,提高模型对低信噪比环境适应性;同时其自动化处理流程也避免了人工特征提取与决策方式带来的困难,在自动化信号识别等领域具备一定实用价值.

参考文献

- [1] 郭立民,等. 基于栈式稀疏自编码器的低信噪比下低截获概率雷达信号调制类型识别[J]. 电子与信息学报,2018,

40(4):875-881.

GUO Li-ming, et al. Low probability of intercept radar signal recognition based on stacked sparse auto-encoder [J]. Journal of Electronics & Information Technology, 2018, 40(4):875-881. (in Chinese)

- [2] ZHANG M, et al. Convolutional neural networks for automatic cognitive radio waveform recognition [J]. IEEE Access, 2017(5):11074-11082.
- [3] LI H, et al. MSGD: A novel matrix factorization approach for large-scale collaborative filtering recommender systems on GPUs [J]. IEEE Transactions on Parallel and Distributed Systems, 2017, 29(7):1530-1544.
- [4] LI Z, et al. Mean Laplacian mappings-based difference LDA for face recognition [J]. Multimedia Tools and Applications, 2017, 76(2):2243-2265.
- [5] LIANG P, et al. Remote sensing image classification based on stacked denoising autoencoder [J]. Remote Sensing, 2018, 10(1):17.
- [6] SUN W, et al. A sparse auto-encoder-based deep neural network approach for induction motor faults classification [J]. Measurement, 2016(89):171-178.
- [7] VAN E T, et al. Rényi divergence and Kullback-Leibler divergence [J]. IEEE Transactions on Information Theory, 2014, 60(7):3797-3820.
- [8] MAVROFORAKIS M E, et al. A geometric approach to support vector machine (SVM) classification [J]. IEEE Transactions on Neural Networks, 2006, 17(3):671-682.

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.
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