

基于模糊函数主脊切片和深度置信网络的 雷达辐射源信号识别

董鹏宇¹, 王红卫¹, 陈游¹, 舒明²

(1. 空军工程大学航空工程学院, 西安 710038; 2. 93131 部队, 北京, 100843)

摘要 雷达辐射源信号识别是电子侦察系统的关键组成部分, 为了提高低信噪比条件下对低截获概率雷达信号识别的准确率, 提出了一种基于模糊函数主脊切片(MRSAF)与深度置信网络(DBN)的雷达辐射源信号识别方法。首先对雷达信号进行奇异值分解(SVD)进行降噪预处理, 求解雷达信号的模糊函数并提取其主脊切片包络, 采用奇异值分解方法降低噪声对主脊切片包络的影响, 然后建立基于受限波尔兹曼机的 DBN 模型并运用标签数据有监督微调模型参数完成训练, 最后基于该算法模型实现辐射源信号的分类和识别。仿真结果表明: 该方法在低信噪比条件下也有较高的识别率, 信噪比高于 -4 dB 时, 识别率可以达到 90% 以上, 验证了本算法的有效性和应用价值。

关键词 辐射源信号识别; 模糊函数主脊切片; 深度置信网络; 奇异值分解

DOI 10.3969/j.issn.1009-3516.2020.02.013

中图分类号 TN97 文献标志码 A 文章编号 1009-3516(2020)02-0084-07

A Recognition Method of Radar Emitter Signals Based on SVD of MRSAF and DBN

DONG Pengyu¹, WANG Hongwei¹, CHEN You¹, JU MING²

(1. Aeronautics Engineering College, Air Force Engineering University, Xi'an 710038, China;

2. Unit 93131, Beijing 100843, China)

Abstract Recognition of radar emitter signals is one of core elements in radar reconnaissance systems. In order to attain a higher correct recognition rate of radar emitter signals under condition of low signal-to-noise (SNR) ratio, a novel method based on Main Ridge Slice of Ambiguity Function (MRSAF) and Deep Belief Network (DBN) is presented. Firstly, the singular value decomposition (SVD) is preprocessed for noise reduction, and then this paper calculates the AF of the sorted signal and ascertains the main ridge slice envelope. To improve the recognition performance, the SVD is employed to eliminate the influence of noise on the main ridge slice envelope. A DBN model is established on the stacked Restricted Boltzmann Machines (RBM) and the labeled data with the supervisory fine-tuning model parameters are used to complete the training. Finally, the model is used to achieve the radar emitter signals recognition and classification. The simulation results indicate that the novel algorithm provides significant performance and the validity and application value of this algorithm are verified. Compared to the existing methods, the novel

收稿日期: 2019-07-24

作者简介: 董鹏宇(1995—), 男, 山西文水人, 硕士生, 主要从事信息对抗理论与技术研究。E-mail: hickey1212@163.com

引用格式: 董鹏宇, 王红卫, 陈游, 等. 基于模糊函数主脊切片和深度置信网络的雷达辐射源信号识别[J]. 空军工程大学学报(自然科学版), 2020, 21(2): 84-90. DONG Pengyu, WANG Hongwei, CHEN You, et al. A Recognition Method of Radar Emitter Signals Based on SVD of MRSAF and DBN[J]. Journal of Air Force Engineering University (Natural Science Edition), 2020, 21(2): 84-90.

method can achieve a higher correct recognition rate even at a low SNR.

Key words recognition of radar emitter signal; main ridge slice of ambiguity function (MRSAF); deep belief network (DBN); singular value decomposition (SVD)

雷达辐射源信号识别是电子对抗侦察的关键环节,是在雷达辐射源信号进行有效分选的基础上完成的,并为后续的目标识别、定位、威胁告警以及电子支援等提供重要的先验情报信息^[1-2]。辐射源信号识别结果直接影响到电子侦察系统的性能。传统的雷达辐射源信号识别利用的是脉间参数,如载频(RF)、脉宽(PW)、幅度(PA)、到达时间(TOA)和到达角(DOA)等^[3],然而随着电子对抗环境的复杂度越来越高以及低截获概率雷达的大量应用,基于脉间参数特征提取的效果越来越不适应环境的变化,为了适应现代新体制雷达辐射源信号识别的需要,脉内特征参数成为研究的热点,基于信号脉内特征的辐射源信号识别就成为了研究的突破口^[4]。

诸多学者对信号脉内特征开展了研究,主要包括有能量聚焦效率检验^[5]、模糊函数多普勒切片^[6]以及时频变化进行二次特征提取^[7-8],虽然这些方法取得了一定的进展,但仍难以有效获得有意义的信号特征,并且主要依赖人工选取与专业知识。深度学习凭借其强大的特征表达能力得到了广泛的应用^[9-11],尤其在图像、语音信号、手写数字等领域受到越来越多的关注,它是一种无监督的特征学习方法,能够实现从标记或未标记的数据集中提取特征的深层、抽象表达,且更容易处理非线性的复杂高维数据,也能有效避免特征提取过程中的人为表达^[12-13],可以完成从获取的原始高维数据到低维特征数据的转换,已成功应用于路面裂缝检测^[14]、评估指标约简^[15]、目标检测^[16]等。目前,深度学习算法也已经应用到了辐射源识别领域^[17-18],文献[19]将深度学习算法用于对雷达工作模式的识别,文献[20]在二维时频图像的基础上运用深度自动编码器实现雷达辐射源识别。

对于侦察到的原始雷达信号,其时域特征隐藏在数据中表现不明显,具有很大的冗余性,且直接输入到深度神经网络中的维数很高,这在一定程度上增加了学习特征的难度。针对上述问题,本文提出了一种基于模糊函数主脊切片(Main Ridge Slice of Ambiguity Function, MRSAF)奇异值分解(Singular Value Decomposition, SVD)与深度置信网络(Deep Belief Network, DBN)的雷达辐射源信号识别算法:首先求取辐射源信号模糊函数并提取主脊切片包络特征以降低输入到DBN模型的维度,对包络序列进行奇异值分解重构以降低噪声的影响并

减少学习特征的冗余性,提高识别效率;建立基于DBN的识别模型,输出学习到的雷达辐射源信号深层特征,进一步降低特征维数并进行分类识别。

1 雷达辐射源信号模糊函数分析

1.1 辐射源信号模型

本文给出线性调频-二相编码(Linear Frequency Modulation and the Binary Phase-Coded Signal, LFM-BC)复合调制信号的模型^[21]:

$$\frac{1}{\sqrt{P}} \sum_{n=0}^{P-1} c_n \delta(t-nT_r) = y_1(t) y_2(t) \quad (1)$$

$$u_p(t) = \begin{cases} 1/\sqrt{T_p}, & 0 < t < T_p \\ 0, & \text{其他} \end{cases} \quad (2)$$

$$y_1(t) = u_p(t) \exp[j(2\pi f_c t + \pi k t^2)] \quad (3)$$

$$y_2(t) = c_n \delta(t-nT_r) / \sqrt{P} \quad (4)$$

式中: P 为码长; T_p 为子脉冲宽度,且有 $T_p = T_r$,表示LFM信号的频率变化范围和脉冲宽度; c_n 为二相编码信号序列; $y_1(t)$ 为LFM信号; $y_2(t)$ 为编码信号;这种信号的每个子脉冲均为具有相同斜率的LFM信号,故将这类信号叫做线性调频-二相编码信号。

1.2 模糊函数特征分析

任意窄带雷达信号的解析形式可表示如下:

$$\chi_s(\tau, \xi) = \int_{-\infty}^{+\infty} s(t + \frac{\tau}{2}) s^*(t - \frac{\tau}{2}) e^{-j2\pi\xi t} dt \quad (5)$$

式中: $s^*(t - \frac{\tau}{2})$ 为信号 $s(t + \frac{\tau}{2})$ 的共轭, t 为时间, τ 为信号时延; ξ 为多普勒频移。从式(5)可以看出,模糊函数的实质是信号 $\tau \sim \xi$ 联合二维平面的能量分布。

以下列出雷达模糊函数的几点特性:

1)模糊函数是对称的,即:

$$|\chi(\tau, \xi_d)|^2 = |\chi(-\tau, -\xi_d)|^2 \quad (6)$$

2)模糊函数的最大值发生在 $(\tau, \xi_d) = (0, 0)$ 的情况下,即:

$$s(t) = g(t) e^{j(2\pi f_0 t + \varphi_0)} \quad (7)$$

式中: f_0 为信号的载波频率; φ_0 为信号的初始相位。

对于信号 $s(t)$,它的模糊函数定义为:

$$\max\{|\chi(\tau, \xi_d)|^2\} = |\chi(0, 0)|^2 \quad (8)$$

$$|\chi(\tau, \xi_d)|^2 \leq |\chi(0, 0)|^2 \quad (9)$$

3)若 $\chi_1(\tau, \xi)$ 和 $\chi_2(\tau, \xi)$ 分别是信号 $s_1(t)$ 和 $s_2(t)$ 的模糊函数, 若 $\chi_1(\tau, \xi) = \chi_2(\tau, \xi)$ 成立, 则 $s_1(t)$ 和 $s_2(t)$ 仅相差一个模为 1 的常数因子, 即:

$$s_1(t) = ks_2(t) (\lvert k \rvert = 1) \quad (10)$$

4) 模糊函数的总体积是定值, 即:

$$\iint |\chi(\tau, \xi_d)|^2 d\tau d\xi_d = 2E_s \quad (11)$$

式中: E_s 表示信号 $s(t)$ 的能量。

从理论分析可以看出, 不同调制类型的雷达辐射源信号具有不同的模糊函数, 可以选择信号模糊函数作为识别的依据。图 1 为 4 种典型复杂调制雷达信号的模糊函数图, 从图中可以直观地看到不同信号间模糊函数的差异, 验证了将模糊函数作为特征的可行性。

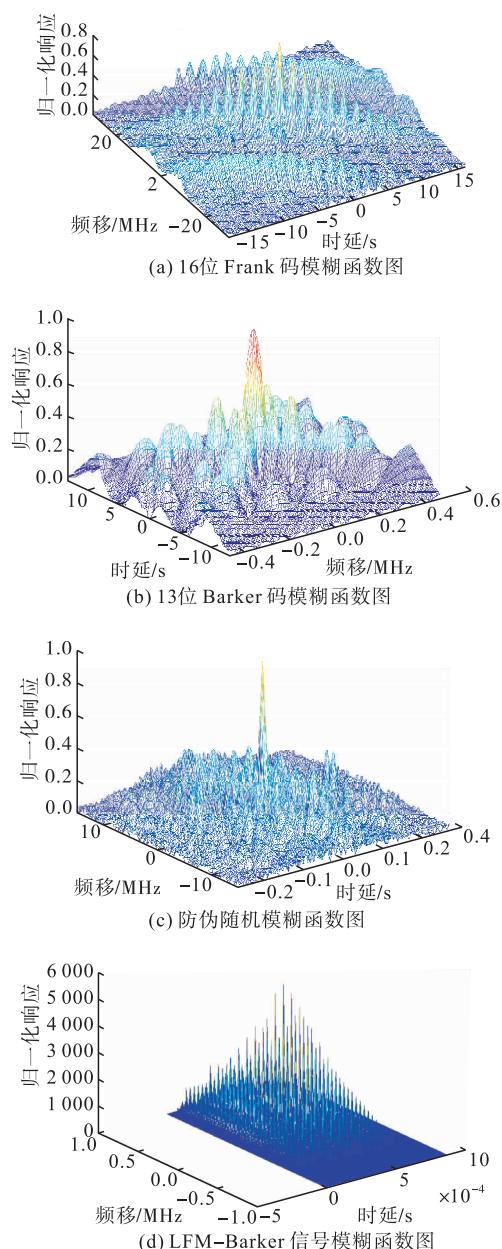


图 1 典型复杂调制雷达信号模糊函数

1.3 模糊函数主脊切片(MRSAF)的提取

本文为降低计算量并深入分析不同调制信号模糊函数能量分布特征的差异, 提取信号模糊函数的所有径向切面中最能反映不同信号时频特征差异的模糊函数主脊切片(Main Ridge Slice of Ambiguity Function, MRSAF)作为进行信号有效识别的特征。图 2 为图 1 中 4 种调制类型信号样本模糊函数主脊切片, 从图中可以看出, 不同调制类型信号的模糊函数主脊切片均具有对称性, 但其切面形状区分明显, 因此可以作为信号有效识别的依据。

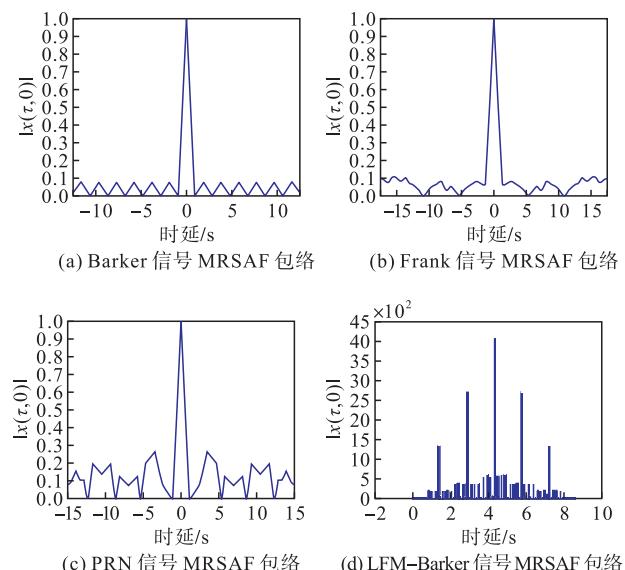


图 2 典型复杂调制雷达信号 MRSAF 包络

2 奇异值分解降噪

对于复杂电磁环境下接收到的雷达辐射源信号, 由于信噪比较低, 会导致辐射源信号模糊函数主脊切片整体包络严重失真, 造成其形状发生一定程度畸变。奇异值分解(SVD)是一种广泛应用于数据特征提取的非线性滤波器, 采用奇异值分解得到的奇异值能够很好地反映信号本身所具有的特征。所以本文采用奇异值分解的方法对雷达信号进行降噪处理, 以保证后续提取特征参数的稳定性。

定义含噪雷达辐射源信号序列为 $\mathbf{X} = [x(1), x(2), \dots, x(N)]^T$, N 为序列长度, 其对应的 $P \times Q$ Hankel 矩阵为:

$$\mathbf{Y} = \begin{bmatrix} x(1) & x(2) & \cdots & x(1+Q-1) \\ x(2) & x(3) & \cdots & x(2+Q-1) \\ \vdots & \vdots & & \vdots \\ x(P) & x(Q) & \cdots & x(P+Q-1) \end{bmatrix} \quad (12)$$

式中: $P+Q=N+1$ 。

对于任意矩阵 $\mathbf{A} \in \mathbf{R}^{m \times n}$, 存在酉矩阵 $\mathbf{U} \in \mathbf{R}^{m \times m}$ 和 $\mathbf{V} \in \mathbf{R}^{n \times n}$, 使得 $\mathbf{A} = \mathbf{U} \sum \mathbf{V}$, 该式称为矩阵的奇异

值分解(SVD)。这样,矩阵 \mathbf{Y} 的奇异值分解为:

$$\mathbf{Y} = \mathbf{U} \sum \mathbf{V} \quad (13)$$

其中矩阵的非零对角元素 $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_Q \geq 0$ 称为矩阵 \mathbf{A} 的非零奇异值。奇异值分解具有以下 2 个特点:①稳定,对于含噪信号序列构成的 Hankel 矩阵 \mathbf{Y} 的细微的变化,其奇异值变化小,具有良好的稳定性;②具有旋转、位移、位置和镜像不变性。不同矩阵在进行奇异值分解后,奇异值的大小是不同的,其反映了信号包络不同区域能量的分布,而且其分布能量越大,所对应的奇异值也越大。考虑在一定低信噪比范围内,辐射源信号仍主导着含噪信号模糊函数主脊切片包络的整体趋势,因此我们可以得到这样的结论:有用信号成分对应前几个较大的奇异值而噪声分量对应剩余的奇异值,通过 SVD 去噪处理可以保留辐射源信号包络中与有用信号对应的最大趋势分量,大幅度减小噪声对包络的不利影响。本文取矩阵 \mathbf{Y} 所有奇异值的平均值作为阈值用来区分有用信号和噪声,设阈值为 t 。

$$t = (\sigma_1 + \sigma_2 + \dots + \sigma_Q)/Q \quad (14)$$

存在 k 使得 $\sigma_k \geq t \geq \sigma_{k+1}$,可以重新构造如下对角矩阵:

$$\Sigma'_k = \begin{bmatrix} \Sigma_k & 0 \\ 0 & 0 \end{bmatrix} \quad (15)$$

式中: Σ_k 是矩阵 \mathbf{Y} 前 k 个较大奇异值组成的对角阵:

$$\Sigma_k = \begin{bmatrix} \sigma_1 & \dots & 0 \\ \vdots & & \vdots \\ 0 & \dots & \sigma_k \end{bmatrix} \quad (16)$$

在式(15)中,小于设定阈值的奇异值 $\sigma_{k+1}, \dots, \sigma_Q$ 对应的是噪声分量,将其设置为 0,目的是为了抑制噪声对模糊函数主脊切片的影响。

根据式(13)~(16),雷达信号序列 Hankel 矩阵 \mathbf{Y} 重新构造为下式:

$$\mathbf{Y}_k = \mathbf{U}_k \sum_k \mathbf{V}_k^T \quad (17)$$

式中: \mathbf{U}_k 和 \mathbf{V}_k 分别为对应 k 个奇异值的左右奇异矩阵。

为了验证奇异值滤波的有效性,本文以 LFM-BC 复合调制信号为例进行验证。调制信号的载频为 10 MHz,脉宽为 10 μ s,BC 部分采用 7 位 Barker 码: $C_d(t) = (1 \ 1 \ 1 \ -1 \ -1 \ 1 \ -1)$ 。奇异值滤波前后模糊函数主脊切片如图 3 所示,可以清晰地看出 SVD 降噪的效果是很明显的。

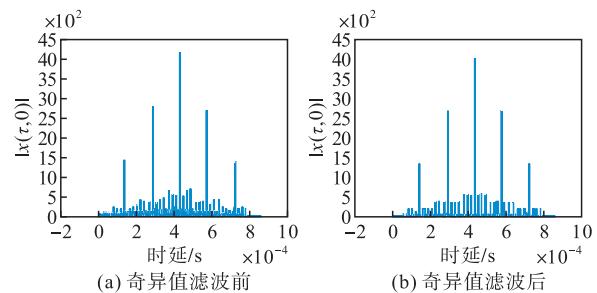


图 3 SVD 滤波前后 LFM-BC 信号模糊函数主脊切片

3 深度置信网络 DBN

深度置信网络(Deep Belief Network, DBN)由 Hinton G E 在 2006 年初次提出^[22], 它是由多层受限玻耳兹曼机(Restricted Boltzmann Machine, RBM)叠加形成的深度结构。DBN 更多强调的是特征学习的重要性, 其良好的特征提取以及维数约减能力使得分类和预测更加容易, 这一点已经在多年的应用中得到验证。作为 DBN 的基本组成结构,RBM 是一种无监督的机器学习模型,由可视层和隐含层组成,两层级之间采用权值全连接而层内各单元之间相互独立,具体结构如图 4 所示。

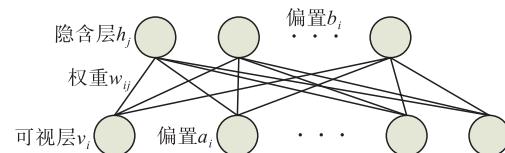


图 4 RBM 结构

假设可视层包含 m 个可视单元 $v = (v_1, v_2, \dots, v_m)$ 作为隐含层的输入, 隐含层包含 n 个隐含单元 $h = (h_1, h_2, \dots, h_n)$, v_i 和 h_j 是取值 0 或 1 的二值变量, 分别代表神经元未激活和激活状态。 a_i 和 b_j 分别是可视层和隐含层神经元的偏置, w_{ij} 是连接权值, 统将 a_i, b_j, w_{ij} 记为参数 θ 。RBM 能量函数定义为:

$$E(v, h; \theta) = -\sum_{i=1}^m \sum_{j=1}^n w_{ij} v_i h_j - \sum_{i=1}^m a_i v_i - \sum_{j=1}^n b_j h_j \quad (18)$$

能量函数指数化和正则化后,即得可视层和隐含层的联合概率分布为:

$$p(v, h; \theta) = \frac{\exp(-E(v, h; \theta))}{Z} = \frac{\exp(-E(v, h; \theta))}{\sum_{v, h} \exp(-E(v, h; \theta))} \quad (19)$$

进一步分解后得到隐含单元 h_j 和可视单元 v_i 的条件概率:

$$p(h_j = 1 | v) = 1 / [1 + \exp(-a_i - \sum_{i=1}^m w_{ij} v_i)] \quad (20)$$

$$p(v_i = 1 | h) = 1/[1 + \exp(-b_j - \sum_{j=1}^n w_{ij} h_j)] \quad (21)$$

当输入的可视层 v 已知时,由于层内神经元的独立性,此时隐含层 h 的条件概率表示成连乘形式

$$p(h | v) = \prod_{j=1}^n p(h_j | v), \text{ 然后基于隐含层 } h \text{ 通过计算条件概率 } p(v' | h) = \prod_{i=1}^m p(v'_i | h) \text{ 重构出新的可视层 } v'.$$

RBM 训练过程就是逐步调整网络参数 θ 最小化 v' 的重构误差的过程,使重构的概率分布与样本数据趋同。这一重构过程既是对辐射源信号特征提取的过程,RBM 可减少重构维数实现数据维度约减,挖掘样本的内在特点,剔除冗余特征。

DBN 由多个 RBM 自底向上堆叠形成,在 DBN 中前一个 RBM 的输出作为下一个 RBM 的输入,底层 RBM 训练完成过后将输出作为高一层的输入,再依次对高层 RBM 训练;预训练结束后在网络后添加对应的分类器,然后利用有标签样本数据并采用 BP 算法反向对权值参数调整,这样的训练过程克服了单纯 BP 算法的过拟合和陷入局部极值的问题,只需要在预训练参数的局部范围内搜索即可。DBN 的结构和训练过程见图 5。

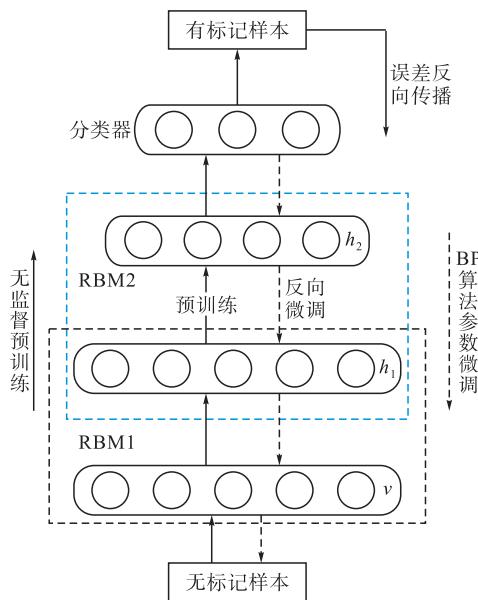


图 5 DBN 结构和训练流程

4 基于 DBN 和 MRSAF 奇异值分解的雷达辐射源信号识别流程

鉴于 DBN 具有强大的特征提取能力,能对原始数据自主学习良好的特征,不需要人为过多干预,本文提出一种基于 DBN 和 MRSAF 的雷达辐射源信号识别方法,具体流程见图 6。

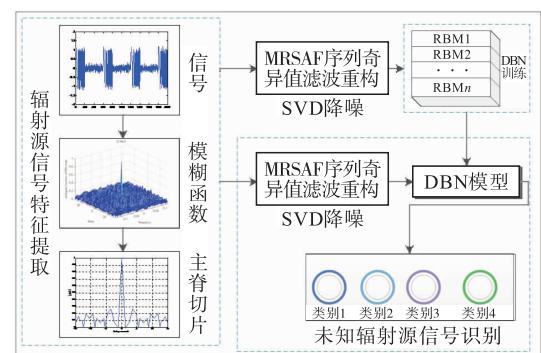


图 6 辐射源信号识别流程

本文提出的基于 DBN 的辐射源信号识别模型,包括 3 个阶段:

Step1 辐射源信号 MRSAF 提取。首先将接收到的辐射源射频信号进行奇异值分解预处理,然后计算各类信号的模糊函数并提取其主脊切片;

Step2 DBN 训练阶段。首先对经过 SVD 处理的包络数据归一化处理,然后建立具有多隐层神经网络的 DBN 模型,并根据输入数据维数设置输入层节点数,采用上节中的训练方法对 DBN 训练。

Step3 未知辐射源信号识别。如 **Step1** 所述对未知的辐射源信号进行 MRSAF 提取,运用训练完成的 DBN 模型对未知辐射源信号进行识别并获得识别结果。

5 实验仿真及分析

5.1 实验设置

为验证本文提出基于 MRSAF 奇异值分解和 DBN 的辐射源信号识别模型的有效性,对该模型进行仿真分析。首先生成由 Barker、Frank、M-sequence(M-SEQ)、LFM-BC 调制类型信号组成的信号集。参数设置如下:所有信号的载频为 10 GHz,脉宽为 10 μ s。LFM-BC 信号模型在第 2 部分已经给出,BC 部分采用 7 位 Barker 码: $C_d(t) = (1 \ 1 \ -1 \ -1 \ 1 \ -1)$; Barker 信号采用 13 位 Barker 码: $C_d(t) = (1 \ 1 \ 1 \ 1 \ 1 \ -1 \ -1 \ 1 \ 1 \ -1 \ 1 \ -1 \ 1)$;

Frank 信号采用 8 个步进频率,采样频率 100 MHz,采用 16 位 Frank 码: $C_d(t) = (1 \ 1 \ 1 \ 1 \ i \ -1 \ -i \ 1 \ -1 \ 1 \ -1 \ 1 \ -i \ -1 \ i)$; M-SEQ 信号采用 15 位 PRN 码: $C_d(t) = (1 \ -1 \ -1 \ -1 \ 1 \ 1 \ 1 \ 1 \ -1 \ 1 \ -1 \ 1 \ 1 \ -1 \ -1)$ 。分别对上述信号求其模糊函数并提取主脊切片,再对包络序列进行奇异值分解降噪,将降噪后的包络数据作为模型的输入。

对于 DBN 隐含层数以及节点设置,本文对此进行多次实验分析,识别结果见表 1。结果表明 DBN 层数过深或节点数降低过多时识别效果会下降,根据实验结果本文采用 3 层的 DBN 模型。

表 1 DBN 结构对识别率影响

DBN 模型	识别率(%)
256-150-100-50	25
256-150-100	99.8
256-150-50	97.9
256-150	99.2

5.2 特征提取

DBN 具有强大的特征提取能力,为验证该模型对于辐射源数据的特征提取效果,对原始数据以及第 1 隐层和第 2 隐层的输出特征进行比较。为便于比较,对数据进行特征可视化处理,将高维数据降维到三维以图像形式呈现。图 7(a)显示了对原始数据特征降维后的结果,可以看出不同雷达辐射源信号 MRSAF 数据交叠严重,若仅分析原始数据难以对雷达辐射源进行有效区分。图 7(b)显示了对 DBN 第 1 隐层输出后的降维结果,从图中看出同一类辐射源信号的 MRSAF 逐渐被聚集到一起;图 7(c)是经过第 2 层隐含层特征提取后的降维结果,相比较第 1 层特征提取结果,同类辐射源信号的聚集程度更加紧密,区分性更大。从第 1、2 层特征提取的结果可以看出,DBN 模型可以自主地提取原始数据更深层的有效特征,在原始信号交叠严重的情况下,通过挖掘采样数据的差异从而将交叠严重的信号区分开。

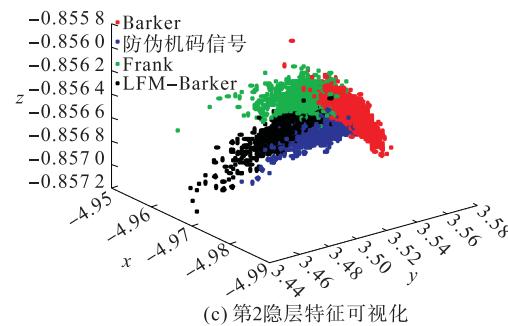
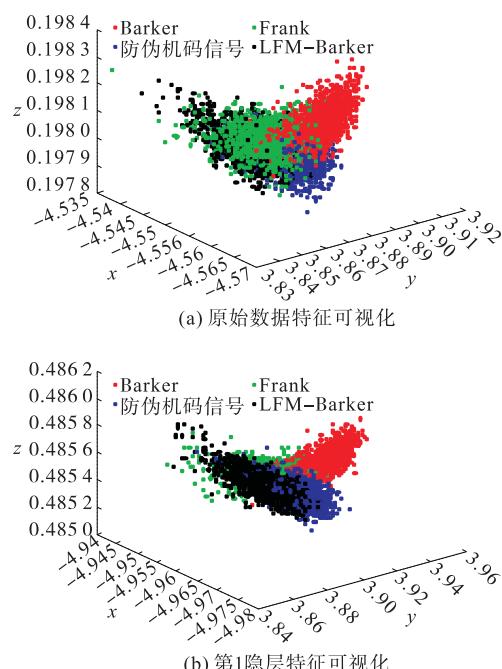


图 7 原始数据特征可视化

5.3 对比仿真及分析

为验证本文提出算法的有效性及识别能力,将本文提出的算法与 PCA-ANN 算法以及小波变换算法进行比较,在不同信噪比条件下对 4 种调制信号进行识别,识别率对比结果见表 2。

表 2 不同算法平均识别率 单位: %

识别算法	信噪比/dB				
	-10	-5	0	5	10
本文算法	74.03	86.63	98.83	100	100
PCA-ANN	<50	55.30	72.20	88.10	98.00
小波变换	<50	51.00	69.10	82.80	92.00

通过以上几种算法的识别率比较可以看出,本文算法在各个信噪比环境下识别效果最佳。这是因为 DBN 通过 RBM 单元提取了数据的深层特征,对 MRSAF 数据的内在结构学习更充分,因而 DBN 提取的特征更加有效,更能表征信号之间的差异。

6 结语

针对低信噪比条件下雷达辐射源信号识别率低的问题,本文提出了基于 MRSAF 和 DBN 的雷达辐射源信号识别方法。在信号特征提取方面,通过对辐射源信号的模糊函数进行分析,并提取其主脊切片包络,基于信号模糊函数主脊切片包络特征拓展了电子侦察中的信息维度,采用奇异值分解对信号进行降噪处理后,主脊切片包络更加有效地表征了雷达信号特征;在信号识别方面,基于 MRSAF 和 DBN 的辐射源信号识别方法可以获得良好的识别正确率。与现有识别方法比较可知,本文所提方法在低信噪比条件下仍有较高的正确识别率,验证了该方法的有效性。但本文只讨论了单特征变量与深度学习模型相结合的雷达辐射源信号识别方法,提取更多脉内特征组成特征向量组进而实现辐射源信号识别是值得进一步研究的。

参考文献

- [1] ZHOU Z W, HUANG G M, CHEN H Y, et al. Au-

- tomatic Radar Emitter Waveform Recognition Based on Deep Convolutional Denoising Auto-Encoders[J]. Circuits Systems and Signal Process, 2018, 37 (9): 4034-4048.
- [2] 周成, 黄高明, 单鸿昌, 等. 基于最大似然估计的 TDOA/FDOA 无源定位偏差补偿算法[J]. 航空学报, 2015, 36(3): 979-986.
- [3] YANG Z T, WU Z L, YIN Z D, et al. Hybrid Radar Emitter Recognition Based on Rough K-means Classifier and Relevance Vector Machine[J]. Sensors, 2013, 13(1): 848-864.
- [4] RU X H, LIU Z, JIANG W L, et al. Recognition Performance Analysis of Instantaneous Phase and Its Transformed Features for Radar Emitter Identification [J]. IET Radar Sonar and Navigation, 2016, 10(5): 945-952.
- [5] 胡国兵, 徐立中, 徐淑芬, 等. 基于能量聚焦效率检验的信号脉内调制识别[J]. 通信学报, 2013, 34(6): 136-145.
- [6] 王磊, 史亚, 姬红兵. 基于多集典型相关分析的雷达辐射源指纹识别[J]. 西安电子科技大学学报(自然科学版), 2013, 40(2): 164-171.
- [7] 白航, 赵拥军, 胡德秀. 时频图像局部二值模式特征在雷达信号分类识别中的应用[J]. 宇航学报, 2013, 34(1): 139-146.
- [8] 孟凡杰, 唐宏, 王义哲. 基于多特征融合的雷达辐射源信号识别平[J]. 计算机仿真, 2016, 33(3): 18-22.
- [9] MAMOSHINA P, VIEIRA A, PUTIN E, et al. Applications of Deep Learning in Biomedicine[J]. Mol Pharm, 2016, 13(5): 1445-1454.
- [10] ZHAO Z Q, JIAO L H, ZHAO J Q, et al. Discriminant Deep Belief Network for High-Resolution SAR Image Classification[J]. Pattern Recognition, 2017, 61(SI): 686-701.
- [11] KIM S W, PARK B G, SONG B S, et al. Deep Belief Network Based Statistical Feature Learning for Fingerprint Liveness Detection[J]. Pattern Recognition Letters, 2016, 77(7): 58-65.
- [12] 杨杰, 孙亚东, 张良俊, 等. 基于弱监督学习的去噪受限波尔兹曼机特征提取算法[J]. 电子学报, 2014, 42(12): 2365-2370.
- [13] 仲训杲, 徐敏, 仲训显, 等. 基于多模特征深度学习的机器人抓取判别方法[J]. 自动化学报, 2016, 42(7): 1022-1029.
- [14] 钱彬, 唐振民, 徐威. 基于稀疏自编码的路面裂缝检测[J]. 北京理工大学学报, 2015, 35(8): 800-809.
- [15] 张乐, 刘忠, 张建强, 等. 基于自编码神经网络的装备体系评估指标约简方法[J]. 中南大学学报(自然科学版), 2013, 44(10): 4130-4137.
- [16] 徐培, 蔡小路, 何文伟, 等. 基于深度自编码网络的运动目标检测[J]. 计算机应用, 2014, 34(10): 2934-2937, 2962.
- [17] 周冬青, 王玉冰, 王星, 等. 基于深度限制玻耳兹曼机的辐射源信号识别[J]. 国防科技大学学报, 2016, 38(6): 137-141.
- [18] LI H, JING W, BAI Y. Radar Emitter Recognition Based on Deep Learning Architecture[C]//CIE International Conference on Radar. [S. l.]: IEEE, 2016: 1-5.
- [19] LI H, JIN W D, LIU H D, et al. Work Mode Identification of Airborne Phased Array Radar Based on the Combination of Multi-Level Modeling and Deep Learning[C]// Proceedings of the 35th Chinese Control Conference. Chengdu, China: IEEE, 2016: 27-29.
- [20] 周志文, 黄高明, 高俊, 等. 一种深度学习的雷达辐射源识别算法[J]. 西安电子科技大学学报:自然科学版, 2017, 44(13): 77-82.
- [21] 宋军, 刘渝, 薛妍妍. LFM-BPSK 复合调制信号识别与参数估计[J]. 南京航空航天大学学报, 2013, 45(2): 217-224.
- [22] HINTON G E, SALAKHUTDINOV R R. Reducing the Dimensionality of Data with Neural Network[J]. Science, 2006, 313(5786): 504-507.

(编辑:徐楠楠)