

基于 DBN 特征提取的雷达辐射源个体识别

徐宇恒¹, 程嗣怡¹, 董晓璇², 周一鹏¹, 董鹏宇¹

(1. 空军工程大学航空工程学院, 西安, 710038; 2. 空军工程大学航空机务士官学校, 河南信阳, 464000)

摘要 针对传统特征参数难以表征复杂体制雷达信号个体特征的问题, 基于深度置信网络 DBN 的深层特征提取和高维数据处理能力, 提出一种基于 DBN 特征提取的雷达辐射源个体识别算法。首先建立基于多层受限玻尔兹曼机的 DBN 模型, 然后通过 DBN 无监督提取脉冲包络前沿特征, 再利用标签数据对模型参数进行有监督微调完成训练, 最后输入未知辐射源信号脉冲包络前沿特征实现辐射源个体识别。与传统算法相比, 该方法能够自适应地提取脉冲深层次细微差异, 提取过程减少了对人为经验的依赖。实验结果表明, 该算法对脉冲包络特征提取效果明显, 有较高的识别精度。

关键词 辐射源个体识别; 深度置信网络; 包络前沿; 特征提取

DOI 10.3969/j.issn.1009-3516.2019.06.014

中图分类号 TN97 **文献标志码** A **文章编号** 1009-3516(2019)06-0091-06

Radar Specific Emitter Identification Based on DBN Feature Extraction

XU Yuheng¹, CHENG Siyi¹, DONG Xiaoxuan², ZHOU Yipeng¹, DONG Pengyu¹

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

2. Aviation Maintenance NCO Academy, Air Force Engineering University,
Xinyang 464000, Henan, China)

Abstract: Aimed at the problem that the traditional characteristic parameters have difficulty in characterizing the specific characteristics of complex system radar signals, a specific emitter identification algorithm based on deep belief network feature extraction is proposed on account of the deep feature extracting and high-dimensional data processing ability of deep belief network. Firstly, a DBN model based on multi-layer restricted Boltzmann machine is established. Then, unsupervised extraction of pulse envelope frontier is realized via deep belief network. After that, the model parameters are fine-tuned with label data in a supervised way to complete the training. Finally, the pulse envelope frontier features of the unknown source signals are input to realize the radar specific emitter identification. Compared with the traditional algorithm, the novel algorithm can adaptively extract from deep pulse features, and can also reduce the process of feature extraction to the dependence on human experiences. The experimental results show that the proposed algorithm provides satisfactory performance of pulse envelope feature extraction and higher recognition accuracy. The validity and application value of the algorithm are verified.

Key words: specific emitter identification; deep belief network; envelope frontier; feature extraction

收稿日期: 2019-05-29

作者简介: 徐宇恒(1997—), 男, 湖北天门人, 硕士生, 主要从事信息对抗理论与技术研究。E-mail: 18192200837@163.com

引用格式: 徐宇恒, 程嗣怡, 董晓璇, 等. 基于 DBN 特征提取的雷达辐射源个体识别[J]. 空军工程大学学报(自然科学版), 2019, 20(6): 91-96. XU Yuheng, CHENG Siyi, DONG Xiaoxuan. Radar Specific Emitter Identification Based on DBN Feature Extraction[J]. Journal of Air Force Engineering University (Natural Science Edition), 2019, 20(6): 91-96.

雷达辐射源个体识别技术,又称为特定辐射源识别(Specific Emitter Identification, SEI),是指通过侦收雷达辐射源信号,提取并分析信号特征,从而判定雷达辐射源个体以及工作状态的过程^[1]。随着多功能雷达的发展,雷达辐射源信号样式日趋复杂多变,传统方法依据脉冲到达时间、到达角、重频、脉宽、载频等特征参数很难满足现代雷达辐射源识别需求。所以,目前通过提取雷达辐射源信号脉冲内部细微特征实现个体识别成为雷达辐射源识别研究的突破点^[2]。

雷达脉冲的细微特征(“指纹特征”)主要是由雷达发射器件对脉冲附加的无意调制,主要包括包络前沿、相位噪声、频率漂移等^[3]。不同的雷达发射器件具有差异,使得细微特征能区分不同辐射源个体。细微特征具有可测性、普遍性、唯一性和独立性等特性^[4]。目前在雷达辐射源个体识别研究领域,存在通过提取雷达辐射源信号的模糊函数切片作为识别辐射源个体的依据^[5],提取脉冲频谱和带宽的无意调制特征^[6],以及提取辐射源信号的双谱^[7]、希尔伯特黄变换^[8]、时频能量谱^[9]等变换特征。以上特征是人为提取出来的,特征的优劣依赖于信号处理技术和专家经验,在先验信息缺乏的情况下对信号细微差异表征能力有限,而且无法挖掘雷达辐射源信号深层次特征,降低识别准确率。

深度学习相对于浅层学习而言具有多隐含层的深层次网络结构,凭借其强大的特征表达能力得到了广泛的应用^[10-12]。与浅层学习相比,深度学习不需要人为进行样本特征提取,其特有的深层次结构能够从样本的低层特征中抽象出高层表示^[13],克服了人为提取特征的不确定性和冗余性。目前,深度学习算法已经应用到了辐射源识别领域^[14-15],文献^[16]将深度学习算法用于对雷达工作模式的识别;文献^[17]用深度置信网络(Deep Belief Network, DBN)模型对雷达辐射源信号的双谱切片进行特征提取后识别调制模式。本文在前人研究的基础上将DBN应用于雷达辐射源个体识别,提出了基于DBN的辐射源个体识别模型。通过DBN自主地学习雷达辐射源信号关键特征,提取出不同雷达脉冲包络的细微差异,从而区分不同的辐射源个体。

1 雷达脉冲包络特征

任意窄带雷达辐射源信号的解析形式可表示如下^[18]:

$$s(t) = g(t)e^{j(2\pi f_0 t + \varphi_0)} \quad (1)$$

式中: f_0 和 φ_0 分别为信号的载频和初相; $g(t) =$

$a(t)e^{j\theta(t)}$ 是其复数包络函数, $a(t)$ 是幅度, $\theta(t)$ 是相位调制函数。

从式(1)可以看出,同一种雷达调制信号具有相同的属性。无意调制细微特征是实现辐射源个体识别的主要依据,而在多种细微特征中,脉冲包络畸变特征提取方便且易于区分,是常用的个体识别特征。理想的脉冲信号如图1(a)所示,是规则的矩形脉冲串,但实际上不同雷达个体产生的脉冲其包络存在差异,具体表现在包络上升沿、下降沿等。这些特征不随雷达工作状态而改变,即使在载频、脉宽、重频等参数都相同时,不同个体之间仍然可以区分。

图1(b)给出了实测雷达辐射源信号的脉冲图,从图中看出脉冲的前沿和后沿发生畸变,不同脉冲的前沿陡峭程度和顶降存在差异,这些差异可以作为个体识别的依据。




图1 雷达脉冲信号示意图

2 深度置信网络 DBN

辐射源信号的脉冲包络前沿包含着丰富的细微特征,不同辐射源个体的细微特征稳定而独特。基于脉冲包络前沿进行辐射源个体识别的准确度取决于对细微特征的提取程度,如果仅依赖人工提取,一方面可能因主观性导致特征提取不全、精度不高,另一方面难以适应信号数量大、信号样式复杂的情况。

深度置信网络(DBN)作为一种深度学习的模型,具有良好的特征提取和维数约减能力,能够充分挖掘和提取脉冲包络前沿的细微特征,从而提高分类效果。本文以脉冲包络前沿为依据进行辐射源个

体识别,通过 DBN 对包络前沿进行特征提取,不仅取代了复杂的人为提取过程,而且能获得更深层次的抽象表达,并达到更优的识别效果。

2.1 DBN 基本组成结构

深度置信网络由 Hinton G E 在 2006 年初次提出^[19]。它的深度结构由多层受限玻耳兹曼机叠加形成,与传统的浅层网络相比,深度置信网络具有更好的特征提取以及维数约减能力。DBN 通过特征变换,将样本在原空间的特征表示变换到新的特征空间,使分类和预测更容易,这一点已经在十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,具有由可视层和隐含层组成的双层结构,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 2 所示。




图 2 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,统一将 a_i, b_j, w_{ij} 记为参数 θ 。RBM 能量函数定义为:

$$E(v, h; \theta) = - \sum_{i=1}^m \sum_{j=1}^n w_{ij} v_i h_j - \sum_{i=1}^m a_i v_i - \sum_{j=1}^n b_j h_j \quad (2)$$

能量函数指数化和正则化后,得到可视层和隐含层的联合概率分布为:

$$p(v, h; \theta) = \frac{\exp(-E(v, h; \theta))}{Z} = \frac{\exp(-E(v, h; \theta))}{\sum_{v, h} \exp(-E(v, h; \theta))} \quad (3)$$

进一步分解后得到隐含单元 h_j 和可视单元 v_i 的条件概率为:

$$p(h_j = 1 | v) = \frac{1}{1 + \exp(-a_j - \sum_{i=1}^m w_{ij} v_i)} \quad (4)$$

$$p(v_i = 1 | h) = \frac{1}{1 + \exp(-a_i - \sum_{j=1}^n w_{ij} h_j)} \quad (5)$$

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 $p(h | v) = \prod_{j=1}^n p(h_j | v)$,然后通过计算条件概率

$$p(v' | h) = \prod_{i=1}^m p(v'_i | h) \text{ 重构出新的可视层 } v'.$$

2.2 RBM 训练过程

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,使重构的概率分布与样本数据趋同的过程。这一重构过程即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数约减,挖掘样本的内在特点,剔除冗余特征。

DBN 是由多个 RBM 自底向上堆叠形成,在前一个 RBM 的输出作为下一个 RBM 的输入。DBN 训练的核心是前向无监督预训练和反向有监督参数微调。预训练是对 RBM 进行逐层贪心训练提取特征的过程,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。这样的训练过程能克服单纯 BP 算法的过拟合和陷入局部极值的问题,只需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 3。




图 3 DBN 结构和训练流程

3 基于 DBN 的雷达辐射源个体识别

不同雷达辐射源个体的脉冲包络前沿存在差异,基于脉冲包络前沿进行辐射源个体识别的前提是得到包络前沿,并进行细微特征分析和提取。DBN 具有强大的特征提取能力,能对原始数据自主学习,大幅减少对人的依赖程度。且 DBN 的多层结构能对辐射源包络前沿进行逐层学习和初步识别,同时,BP 反向算法通过不断调整 DBN 模型参数,促进最终对包络前沿的准确识别。

鉴于以上优势,本文运用 DBN 对雷达辐射源信号进行特征提取并实现个体识别,提出了一种基于 DBN 的辐射源个体识别模型。具体流程如图 4

所示。本文提出的基于 DBN 的辐射源个体识别模型,包括 3 个阶段:

1)辐射源信号预处理。首先将接收到的辐射源射频信号下变频到中频信号,再对中频信号进行检波得到脉冲包络,最后对脉冲包络的前沿进行采样获得离散的包络数据,将这些包络数据作为 DBN 网络的输入。

2)DBN 训练阶段。首先对脉冲包络的采样数据归一化处理,并建立多隐含层的 DBN 模型,然后根据输入数据维数设置输入层节点数。将 1)中的包络数据输入到 DBN 模型最底层 RBM,逐层进行前向无监督贪心预训练,随后基于有标签样本数据,采用 BP 算法进行反向有监督参数微调,最后得到基于 DBN 特征提取的雷达辐射源个体识别模型。

3)未知辐射源个体识别。利用 1)所述的方法对未知辐射源信号进行预处理,得到其脉冲包络前沿采样后的数据点,运用训练完的模型对这些数据点进行识别,获得未知辐射源信号的识别结果。




图 4 辐射源个体识别流程

4 仿真分析

4.1 模型参数设置

为验证本文提出基于 DBN 的辐射源个体识别模型的有效性,对该模型进行仿真分析。本文在分析了雷达辐射源信号的基础上,模拟产生 4 类相似度较高的雷达辐射源信号脉冲前沿。具体包络前沿的表达式如下:雷达 1 前沿: $y=1-e^{-2x}$;雷达 2 前沿: $y=1-e^{-3x}$;雷达 3 前沿: $y=1-e^{-x^3}$;雷达 4 前沿: $y=1-e^{-x^5}$ 。

为使模拟产生的信号更加贴近实际,在每个模拟信号的包络上增加随机高斯白噪声,图 5 显示了仿真生成的 4 类雷达辐射源信号脉冲前沿。仿真信号的信噪比为 25 dB,脉冲幅度为 1,脉冲前沿采样的采用频率为 100 MHz,总采样时长为 2 μ s,每个

脉冲前沿的采样点为 200 点。

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,识别结果如表 1 所示。结果表明,在样本数据库有限的情况下,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。设置底层 RBM 输入节点数为 200,和信号的采样点数一致,其他层节点数依次递减,设置为 200-150-100。DBN 的学习率和动量参数对识别结果影响较大,经过多次实验设置学习率为 0.1,动量参数为 0.1。




图 5 4 类雷达脉冲包络前沿

表 1 DBN 结构对识别率影响

DBN 模型	识别率/%
200-150-100-50	25.0
200-150-100	99.8
200-150-50	97.9
200-150	99.2

4.2 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,将高维数据运用 PCA 算法降维到三维以图像形式呈现。图 6 中显示了对原始时域采样数据特征降维后的结果,可以看出 4 个雷达辐射源信号采样数据交叠严重,若仅分析原始数据难以对雷达个体进行有效区分。

图 7 显示了对 DBN 第 1 隐层输出后的降维结果,从图中看出同一类的雷达辐射源信号被聚集到一起,而不同类雷达辐射源信号被有效地分离,只有少量数据点发生重叠。图 8 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,图 8 中同类信号的聚集程度更加紧密,区分性更大,不同类的数据点之间没有重叠。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信号更深层的有效特征,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 6 原始数据特征可视化




图 7 第 1 隐层特征可视化




图 8 第 2 隐层特征可视化

4.3 对比仿真

为验证本文提出算法的有效性,对基于 DBN 的识别模型和文献[5]中的模糊函数切片算法、文献[7]中的选择双谱算法、主元分析-支持向量机 (Principal Component Analysis-Support Vector Machine, PCA-SVM) 算法、线性判别分析-支持向量机 (Linear Discriminant Analysis-Support Vector Machine, LDA-SVM) 算法和正交局部保持投影-反向传播 (Orthogonal Locality Preserving Projection-Back Propagation, OLPP-BP) 算法进行仿真对比。其中,模糊函数切片是人为提取的辐射源信号个体特征。PCA、LDA 和 OLPP 是 3 种常用的降维算法。每部雷达生成训练数据各 1 000 个,共 4 000 个;同时再生成 4 000 个测试数据,并在测试数据中增加信噪比分别为 20 dB、15 dB、10 dB 的随机噪声。识别率对比结果如表 2 所示。

通过以上几种算法的识别率比较可以看出,本文提出 DBN 识别模型在各个信噪比环境下识别效

果最佳,信噪比 20 dB 时识别率为 98.8%,比有监督的 OLPP 降维算法识别率高 5%。原因是,DBN 模型提取了原始雷达辐射源信号的深层特征,与人为提取的局部模糊函数切片特征以及多种降维算法相比,DBN 提取的特征更加有效,更能表征信号之间的差异。

为检验噪声对算法识别率的影响,在不同信噪比的环境中,对算法进行仿真,控制信噪比范围为 8 dB 到 30 dB,将不同信噪比下的识别率绘成曲线。图 9 中呈现了不同信噪比下 DBN 算法的识别率曲线,可以看出当信噪比高于 15 dB 时,算法识别率达到 90% 以上。而在信噪比低于 10 dB 时识别率下降严重,识别率低于 80%,这是因为对信号增加的高斯白噪声覆盖了不同包络之间的微小差异,在时域的采样无法区分不同的信号,可以考虑在其他域进行采样识别。

表 2 不同算法识别率对比 单位: %

算法	信噪比		
	20 dB	15 dB	10 dB
DBN 算法	98.80	91.57	79.70
AF-SVM ^[5]	89.58	78.30	69.10
BDS-SVM ^[7]	87.60	76.40	70.50
BDS-PCA-SVM	86.08	72.12	61.93
BDS-LDA-SVM	94.62	90.70	72.03
BDS-OLPP-BP	93.45	91.07	73.18




图 9 不同信噪比的识别率

4.4 实测数据仿真

以上仿真是针对于模拟产生的雷达脉冲包络前沿,为验证 DBN 模型在实际使用中可靠性以及对实测信号的识别效果,运用本文提出的方法对实测的雷达信号进行识别。首先从侦察的波形库中选取 5 部不同的雷达信号,从每部雷达中选取 500 个脉冲,共选取 2 500 个脉冲作为训练数据,同时每部雷达选取 100 个脉冲作为测试数据;其次对脉冲信号进行预处理,提取信号的包络并对包络前沿采样;最后训练 DBN 模型,并用测试数据对模型的识别效果进行检验。图 10 是其中实测的 4 部雷达脉冲的

示例。




图 10 实测 4 部雷达信号波形

表 3 中显示了对实测雷达信号的识别仿真结果,通过表中的对比可以看出本文提出的 DBN 算法识别效果最佳,对实测信号的识别率达 99.2%,较 BDS-OLPP-BP 识别率提高 5%,验证了该算法在实测雷达信号个体识别中的有效性。

表 3 实测数据识别率对比

识别算法	识别率/%
DBN 算法	99.2
AF-SVM	91.4
BDS-SVM	88.2
BDS-PCA-SVM	86.5
BDS-LDA-SVM	92.6
BDS-OLPP-BP	94.2

5 结语

针对雷达辐射源个体识别问题,本文提出了基于 DBN 特征提取的雷达辐射源个体识别方法。从雷达脉冲包络前沿的个体差异出发,在时域对包络前沿采样后运用 DBN 进行无监督特征提取,然后通过与标签数据对比来微调网络参数,最终运用训练完成的模型实现分类。所提方法克服了人为特征提取的复杂性,直接在时域提取雷达辐射源信号深层特征。仿真结果表明,在相同信噪比下所提方法与传统方法相比识别率较高,验证了该方法的有效性。但是该方法仍存在不足,由于时域采样的原因在信噪比较低时识别效果不佳,依赖于包络的提取技术,下一步研究方向考虑在其他域中采样识别,克服噪声影响。

参考文献(References):

[1] YUAN Yingjun, HUANG Zhitao, WU Hao. Specific Emitter Identification Based on Hilbert-Huang Transform-based Time-frequency-energy Distribution Features [J]. IET Communications, 2014, 8 (13): 2404-2412.

[2] RU Xiaohu, LIU Zheng, JIANG Wenli, 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.

[3] DUDCZYK J. A Method of Feature Selection in the Aspect of Specific Identification of Radar Signals[J]. Bulletin of the Polish Academy of Sciences, 2017, 65 (1): 113-119.

[4] JIA Yongqiang, ZHU Shengli, GAN Lu. Specific Emitter Identification Based on the Natural Measure[J]. Entropy, 2017, 19(3):117.

[5] 李林, 姬红兵. 基于模糊函数的雷达辐射源个体识别[J]. 电子与信息学报, 2009, 31(11): 2546-2551.

LI L, JI H B. Specific Emitter Identification Based on Ambiguity Function[J]. Journal of Electronics & Information Technology, 2009, 31(11): 2546-2551. (in Chinese)

[6] RU Xiaohu, HUANG Zhitao, LIU Zheng, et al. Frequency-Domain Distribution and Band-Width of Unintentional Modulation on Pulse[J]. Electronics Letters, 2016, 52(22): 1853-1855.

[7] 蔡忠伟, 李建东. 基于双谱的通信辐射源个体识别[J]. 通信学报, 2007, 28(2): 75-79.

CAI Z W, LI J D. Study of Transmitter Individual Identification Based on Bispectra[J]. Journal on Communications, 2007, 28(2): 75-79. (in Chinese)

[8] ZHANG Jingwen, WANG Fanggang, OCTAVIA A Dobre, et al. Specific Emitter Identification via Hilbert-Huang Transform in Single-Hop and Relaying Scenarios[J]. IEEE Transactions on Information Forensics and Security, 2016, 11(6): 1192-1205.

[9] YUAN Yingjun, HUANG Zhitao, WU Hao, et al. Specific Emitter Identification Based on Hilbert-Huang Transform-Based Time-Frequency-Energy Distribution Features. The Institution of Engineering and Technology, 2014, 13(8): 2404-2412.

[10] POLINA Mamoshina, ARMANDO Vieira, EVGENY Putin, et al. Applications of Deep Learning in Biomedicine[J]. Mol Pharm, 2016, 13(5): 1445-1454.

[11] ZHAO Zhiqiang, JIAO Licheng, ZHAO Jiaqi, et al. Discriminant Deep Belief Network for High-Resolution SAR Image Classification[J]. Pattern Recognition, 2017, 61: 686-701.

[12] SOOWOONG Kim, BOGUN Park, BONG Seop Song, et al. Deep Belief Network Based Statistical Feature Learning for Fingerprint Liveness Detection[J]. Pattern Recognition Letters, 2016, 77(C): 58-65.

(下转第 108 页)