

DOI: 10.19650/j.cnki.cjsi.J2006953

基于模糊函数等高线与栈式降噪自编码器的 雷达辐射源信号识别*

普运伟^{1,2}, 郭江¹, 刘涛涛¹, 吴海潇¹

(1. 昆明理工大学信息工程与自动化学院 昆明 650500; 2. 昆明理工大学计算中心 昆明 650500)

摘要:针对当前复杂体制雷达辐射源信号识别方法抗噪性能差、识别率低等问题,提出一种基于模糊函数等高线与栈式降噪自编码器的新识别方法。首先对辐射源信号的模糊函数进行高斯滤波并根据线性插值计算等高线,然后采用主成分分析方法降低其特征维度,保留主要模糊能量信息,最后构建深度学习栈式降噪自编码器,学习并提取等高线深层、泛在的特征,并通过 Softmax 分类器进行分类识别。实验结果表明,该方法在信噪比为 0 dB 时对 6 类典型雷达信号的整体平均识别率均保持在 99.83% 以上,即便是在 -6 dB 环境中,识别率也可达到 83.67%,验证了所提方法在极低信噪比条件下良好的性能和可行性。

关键词: 雷达辐射源信号;模糊函数;信号识别;深度学习;栈式降噪自编码器

中图分类号: TN974 TH89 **文献标识码:** A **国家标准学科分类代码:** 510.40

Radar emitter signal recognition based on ambiguity function contour lines and stacked denoising auto-encoders

Pu Yunwei^{1,2}, Guo Jiang¹, Liu Taotao¹, Wu Haixiao¹

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China; 2. Computing Center, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: The complex radar emitter signal recognition methods have problems of poor anti-noise performance, low recognition rate, etc. To address these issues, we propose a new recognition method based on ambiguity function contour lines and stacked denoising auto-encoders. First, the ambiguity function is processed by the Gaussian smoothing and the contour lines are calculated by linear interpolation. Then, principal component analysis is used to reduce its feature dimension. The main ambiguity energy information is remained. Finally, deep learning stacked denoising auto-encoders are established to learn and extract the deep and more ubiquitous features of contour lines. The Softmax classifier is used to classify them. Simulation experiments show that the overall average recognition rates of six types of typical radar signals are all above 99.83% when the signal-noise ratio is 0 dB. The recognition rate can also reach 83.67% when the signal-noise ratio is -6 dB. Results prove that this method has good performance and feasibility under the extremely low signal-noise ratio conditions.

Keywords: radar emitter signal; ambiguity function; signal recognition; deep learning; stacked denoising auto-encoders

0 引言

随着现代战场电磁环境不断向密集、复杂、多变的方向发展,以及新型复杂体制雷达大量投入使用,要对其进行可靠的分选和识别,仅依靠传统的载波频率(radio frequency, RF)、脉冲宽度(pulse width, PW)、到达角度

(direction of arrival, DOA)、脉冲幅度(pulse amplitude, PA)和到达时间(time of arrival, TOA)五个经典参数已很难满足实际需求。因此,深入研究各种新型复杂体制雷达辐射源信号的深层特征分布、进而构建高效分选识别模型与方法已成为现代电子侦察信号处理的关键问题。

针对雷达辐射源信号脉内特征参数的提取,国外研

收稿日期:2020-09-27 Received Date: 2020-09-27

* 基金项目:国家自然科学基金(61561028)项目资助

究人员提出了瞬时频率^[1]、脉内调制特征^[2]、Chirplet 原子^[3]等特征来弥补常规五参数分选识别性能的不足。近年来,国内部分专家对复杂体制雷达信号脉内细微特征提取做了大量分析和研究,提出了小波变换提取信号包络特征^[4]、分形维数特征^[5]、双谱二维特征^[6]、小波脊频特征^[7]、复杂度特征^[8]、Holder 系数特征^[9]等。但这些方法仅对特定的辐射源信号形式有效,且缺乏从整体上对分选识别模型与方法的系统研究。

目前,深度神经网络(deep neural network, DNN)已在图像识别^[10]、语音识别^[11]、自然语言处理^[12]等领域广泛应用。鉴于 DNN 能学习数据的低层特征以形成更抽象的高层表示属性类别或特征,进而挖掘出信号更泛在的深层内在信息,因此将其应用到雷达辐射源信号识别具有较好的可行性。

为解决复杂体制雷达特征提取困难及识别率低等问题,本文构建了一种栈式降噪自编码器(stacked denoising auto-encoders, SDAE)网络,用以学习辐射源信号模糊函数等高线(ambiguity function contour lines, AFCL)内在特征规律,提取其深层模糊能量特征。然后用反向传播算法对网络参数进行微调,并用 Softmax 分类器进行分类识别。实验结果表明,此方法的分类识别效果较强,且在极低信噪比环境下仍可保持较好性能。

1 理论基础

1.1 模糊函数

模糊函数(ambiguity function, AF)是对辐射源信号进行分析研究的有效工具,任意窄带雷达辐射源信号 $s(t)$ 的 AF 定义为^[13]:

$$AF(\tau, \xi) = \int_{-\infty}^{+\infty} s(t + \frac{\tau}{2}) s^*(t - \frac{\tau}{2}) e^{-j2\pi\xi t} dt \quad (1)$$

式中: $s^*(t)$ 为 $s(t)$ 的共轭; τ 为时延; ξ 为频移。由 AF 唯一性定理可知,不同的信号形式其 AF 模糊能量信息分布各异,为等高线的计算和后续分类识别提供了可行性。

1) 模糊函数等高线

AF 图是三维的,直接进行特征提取复杂度太高,降维是可行思路,但要遵从两个基本原则:一是减少计算

量,保证神经网络的特征提取速度;二是降维后能最大限度地保留 AF 模糊能量分布特性。从三维空间中观察到不同辐射源信号的 AF 图的主峰和副峰此起彼伏,且峰值差别较大,利用等高线的思想能有效解决该问题。

在计算和绘制 AFCL 时,高度的确定以及等值点坐标的计算是关键。考虑到线性插值对网格数据计算精度较高且自适应性强,本文用线性插值的方法来求解 AFCL,具体过程如下:

首先将高斯滤波后的 AF 海拔分为 P 个递增的等高线高度 H_p :

$$H_p = \overline{AF}_{\min} + p \times \frac{\overline{AF}_{\max} - \overline{AF}_{\min}}{P + 1}, (p = 1, 2, \dots, P) \quad (2)$$

然后依据线性插值法,任意网格 (i, j) 在水平方向高度为 H_p 的等值点坐标 (x_h, y_h) 为:

$$x_h = j + \frac{H_p - \overline{AF}(i, j)}{\overline{AF}(i, j+1) - \overline{AF}(i, j)} \quad (3)$$

$$y_h = i \quad (4)$$


在竖直方向高度为 H_p 的等值点坐标 (x_v, y_v) 为:

$$x_v = j \quad (5)$$

$$y_v = i + \frac{H_p - \overline{AF}(i, j)}{\overline{AF}(i+1, j) - \overline{AF}(i, j)} \quad (6)$$

最后根据水平和竖直等值点的坐标,连接相邻的等值点即可得到等高线。

高度 P 的大小决定等高线的疏密性, P 值越大对 AF 三维地形描述越细致,但过大会导致图像变模糊,清晰度不够,并且增加了计算量。通常情况下,考虑到 AF 主要能量分布集中在以原点为中心的附近区域,为增加 AF 主峰和副峰之间等高线密集程度的区分度,以此作为辐射源信号的识别依据,图像的清晰度以及密集程度需同时兼顾。综合考虑,本文选择绘制 3 个高度的等高线。图 1 所示为常规(convention, CON)、线性调频(linear frequency modulation, LFM)、二相编码(binary phase shift keying, BPSK)、四相编码(quadrature phase shift keying, QPSK)、M 伪随机序列(m-sequence, M-SEQ)和二频编码(binary frequency shift keying, BFSK)6 种辐射源信号的 AFCL 图,采样长度为 N 。






图 1 6 种雷达辐射源信号的 AFCL 图

Fig. 1 AF contour lines of six radar emitter signals

2) 利用 PCA 方法进行特征降维

为去除 AFCL 数据间的冗余并降低特征维度,可采用具有特征值分解性能的 PCA 方法。降维后得到的主成分能最大化保留等高线数据的内在信息,基本过程如下^[14]。

(1) 数据标准化:

$$\bar{V} = (V - \mu)_{\min} \quad (7)$$

式中: $\bar{V}$ ($\bar{V} \in R^{m \times n}$) 为标准化后的 AFCL 数据集; V 为原始数据; μ 为均值。

(2) 计算协方差矩阵:

$$C = \frac{1}{m} \bar{V} \bar{V}^T \quad (8)$$

式中: C ($C \in R^{m \times n}$) 为 $\bar{V}$ 的协方差矩阵; m 为行数, $\bar{V}^T$ ($\bar{V}^T \in R^{n \times m}$) 为 $\bar{V}$ 的转置。

(3) 特征值分解:

$$G = U \Lambda U^T \quad (9)$$

式中: Λ ($\Lambda \in R^{m \times m}$) 为对角特征值矩阵, Λ 中元素数值越大,则特征向量包含的信息越多; U ($U \in R^{m \times m}$) 为 Λ 对应的特征向量矩阵; U^T ($U^T \in R^{m \times m}$) 是 U 的转置,用于主成分的转化。

(4) 计算累计贡献率:

$$\eta = \frac{\sum_{k=1}^i \lambda_k}{\sum_{k=1}^p \lambda_k}, (i = 1, 2, \dots, p) \quad (10)$$

式中: p 为特征根个数; λ_k 为第 k 个特征根。本文取累计贡献率为 95% 时对应的主成分。

1.2 自编码模型

1) 自编码器

自编码器 (auto-encoder, AE) 是非监督式的 3 层神经网络,有编码和解码两个过程,包含 1 个输入层、1 个隐层、1 个输出层。AE 是一种将输入向量 x 通过中间层 y 映射到输出层的网络结构,如图 2 所示。

编码过程如下:




图 2 AE 模型

Fig. 2 The AE model

$$y = f_c(W_c \cdot x + b_c) \in R^v \quad (11)$$

式中: x 为原始信号; y 为编码后的信号; W_c 和 b_c 分别为权值项和偏置项; f_c 为激活项。本文为 Sigmoid 函数: $s(x) = 1/(1 + e^{-x})$ 。

解码过程如下:

$$\hat{x} = f_d(W_d \cdot y + b_d) \in R^u \quad (12)$$

式中: $\hat{x}$ 为重构信号; W_d 和 b_d 分别为权值项和偏置项; f_d 为激活项。

通过重构信号 $\hat{x}$ 与原始信号 x 的误差设定损失函数:

$$J(x, \hat{x}) = \varepsilon(x, \hat{x}) + \lambda R(W) \quad (13)$$

式中: $\varepsilon(x, \hat{x})$ 为交叉熵函数; $R(W)$ 是权重衰减项,用以防止过拟合。

2) 降噪自编码器

降噪自编码器 (denoising auto-encoder, DAE) 由 Vincent 等^[15]提出。先对输入数据加入适当噪声,破坏数据的特性,再让 DAE 学习并去除噪声,在输入已被噪声污染的情况下,DAE 能够找到更稳定和更深层次的特征,因此拥有良好的鲁棒性和健壮性。

设原始信号为 x , 加入噪声后为 x_1 , 由 x_1 编码后得到 y , 再由 y 解码后得到 z , 即为输入 x 的重构, 结构如图 3

所示。




图3 DAE模型

Fig. 3 The DAE model

本文加入的干扰噪声为二值噪声,即指定噪声系数 $\gamma(\gamma \in [0, 1])$ 。并按照比例随机将 $\mathbf{x}$ 中部分分量赋值为0,其余不变,作为新输入 $\mathbf{x}_1$,此时网络的重建误差为:

$$L_D = \|\mathbf{x} - g(f(\mathbf{x}_1))\|^2 \quad (14)$$

网络的代价函数为:

$$J_D(\mathbf{W}, \mathbf{b}) = \left[\frac{1}{N} \sum_{i=1}^N \frac{1}{2} \|\mathbf{x}^{(i)} - g(f(\mathbf{x}_1))\|^2 \right] + \frac{\lambda}{2} \sum_{l=1}^2 \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (\mathbf{W}_{jl}^{(i)})^2 \quad (15)$$

式中: N 为总样本数; $\mathbf{x}^{(i)}$ 为第 i 个样本; $\mathbf{W}_{jl}^{(i)}$ 和 s_l 分别为连接权重及单元数; λ 为正则化系数。

3) 栈式降噪自编码器

SDAE由若干个DAE堆叠形成,上一层DAE的输出是下一层的输入,直至输出层。通过逐层贪婪训练法,依次对各层参数进行训练,预训练后用BP算法做有监督地微调,使参数达到收敛,模型结构如图4所示。




图4 SDAE模型

Fig. 4 The SDAE model

4) Softmax 分类器

深度学习模型常用分类器主要有Softmax、SVM、决策树等分类器。考虑到雷达辐射源信号识别属于多分类问题,故选用Softmax分类器。若输入为 $\mathbf{x}$,被判定为第 j 类的概率表示为 $p = (y = j/k)$, Softmax分类器会依据参数 θ 估算出每一种 $\mathbf{x}$ 分类成功的概率。现用假设函数 $h_\theta(x)$ 对有标签的辐射源信号分类概率表达为:

$$h_\theta(\mathbf{x}^{(i)}) = \begin{bmatrix} p(y^{(i)} = 1 | \mathbf{x}^{(i)}; \theta) \\ p(y^{(i)} = 2 | \mathbf{x}^{(i)}; \theta) \\ \vdots \\ p(y^{(i)} = k | \mathbf{x}^{(i)}; \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T \mathbf{x}^{(i)}}} \begin{bmatrix} e^{\theta_1^T \mathbf{x}^{(i)}} \\ e^{\theta_2^T \mathbf{x}^{(i)}} \\ \vdots \\ e^{\theta_k^T \mathbf{x}^{(i)}} \end{bmatrix} \quad (16)$$

式中: $\theta_i(\theta_i \in R^{n+1})$ 为输入层与第 i 个输出神经元连接的权重。分母项为归一化处理,使输出概率和为1。

2 基于AFCL与SDAE的雷达辐射源信号识别算法

对雷达辐射源信号从时延和频移角度进行联合二维时频表示,得到模糊函数,并对其进行线性插值绘制出模糊函数等高线,但是模糊函数等高线图不能直接作为SDAE网络的输入,需要对其进行预处理。

2.1 模糊函数等高线预处理

以常规雷达信号CON信号 $s(t)$ 为例,对CON信号进行时延和频移上的联合二维时频表示,得到其模糊函数 $AF(\tau, \xi)$,如图5所示。




图5 CON信号的AF图

Fig. 5 The AF image of CON

构建尺寸为 5×5 , 标准差为1的高斯掩膜,对AF进行高斯平滑处理,消除噪声带来的毛刺和畸变,结果如图6所示。




图6 平滑后CON信号的AF图

Fig. 6 The AF image of CON after smoothing

对平滑后的 AF 进行线性插值计算并绘制出 AFCL, 结果如图 7 所示。




图 7 CON 信号的 AFCL

Fig. 7 AF contour lines of CON

对 AFCL 进行重采样, 消除信号长度对特征提取的影响, 并进行灰度化, 如图 8 所示。

对处理后的 AFCL 图像归一化和向量化, 变为向量 α^T , 作为 SDAE 网络的输入, 则 n 个输入样本可表示为:

$$V = (\alpha_1^T, \alpha_2^T, \dots, \alpha_n^T) \quad (17)$$

2.2 辐射源信号识别流程

以 CON 信号为例, 图 9 所示为本文算法识别流程。对该识别流程简要说明如下:

1) AFCL 预处理。首先对 AF 进行高斯平滑, 去除毛




图 9 本文算法识别流程

Fig. 9 Flow of the algorithm recognition of this paper

3 仿真实验与结果分析

为验证本文方法的可行性和有效性, 采用 CON、LFM、BPSK、QPSK、M-SEQ、BFSK 6 种雷达辐射源信号进行仿真实验, 重采样点数 $N = 1024$ 。其中 LFM 带宽为 10 MHz, BPSK 和 BFSK 均为 13 位 Barker 码, M-SEQ 生成多项式为 1 011 100, QPSK 则为 16 位 Frank 码。所有信号 PW 均为 10 μ s, 采样频率 60 MHz。此外, 除 BFSK 的两个频点分别取 2 MHz 和 10 MHz 外, 其余信号 RF 为 10 MHz。在 $\text{SNR} \in [-8, 12]$ 环境下, 6 类信号每类各生成 20 个样本, 步长 2 dB, 即训练集为 1 320 个信号样本。根据实验方案的具体需要, 测试集每类各生成 100 个信




图 8 灰度化后 CON 信号的 AFCL

Fig. 8 AF contour lines of CON after graying

刺和畸变, 然后用线性插值法计算出 AFCL, 对其进行预处理, 主要有重采样、灰度化、归一化, 最后进行向量化, 得到特征向量, 并通过 PCA 算法将特征向量矩阵 V 进行降维, 保障特征提取速度。

2) SDAE 网络特征提取。将预处理后的 AFCL 向量矩阵输入 SDAE 网络, 作为前端处理, 调节网络参数, 构建最优的网络结构。无监督学习调节每一层隐藏层权值, 并用 BP 算法有监督地学习特征, 对参数进行微调。

3) 辐射源信号分类识别。对 SDAE 网络中提取的 AFCL 深层模糊能量特征进行分类识别, 并通过 Softmax 分类器对输入信号进行分类识别。

号, 即每个 SNR 条件下共 600 个样本。实验所用计算机为联想启天 M410-N000, CPU 为 3.6 GHz, 内存为 8G, 仿真平台为 MATLAB R2019a。

3.1 SDAE 参数和结构寻优

神经网络的学习性能依赖于其参数结构, 需寻求最优的参数, 建立最适合提取 AFCL 特征的 SDAE 模型。实验中 SDAE 结构与各层节点参数设置为 363-200-100-6, 指定网络预训练和微调过程的学习率分别为 α_1 和 α_2 , 实验选用 $\text{SNR} = -6$ dB 时的数据集, 识别率变化情况如图 10 所示。

从图 10 可以看出, α_1 和 α_2 在 0.01 ~ 0.1 附近时, 信号识别率均较高, 但当 α_1 和 α_2 上升并大于 0.1 时, 识别率反而下降, 这是因为网络梯度步长变大, 损失函数收敛




图 10 不同学习率下识别率的变化

Fig. 10 Recognition rate change under different learning rates

变慢。考虑到上述原因,本文实验中设置 $\alpha_1 = 0.01$, $\alpha_2 = 0.1$ 。

SDAE 的优点在于叠加 DAE 来增加网络的深度,以学习并提取 AFCL 更抽象且深层的能量特征。图 11 所示为信噪比为 -6 dB 环境下,6 类辐射源信号识别率随隐藏层层数的变化情况。




图 11 不同隐藏层层数下识别率的变化

Fig. 11 Recognition rate change under different hidden layers

由图 11 可知,在 SNR = -6 dB 情况下,起初增加层数能较好地提升 SDAE 网络提取 AFCL 深层模糊能量特征的能力,识别效果也随之上升。但当层数不断堆叠,层之间的节点数增多,那么层之间的连接权重和偏置数也因此变多,训练和识别时间也在增加,网络结构变得复杂化。当层数太多时,AFCL 数据每经过一个隐藏层,进行一次编码过程,即一次降维,会造成一定的 AF 能量信息损失,网络所提取到的 AFCL 模糊能量特征也会含有一定的误差,此时若不增加网络中的 AFCL 训练样本量,信号识别效果反而不佳。通常情况下,考虑到网络 AFCL 训练数据量的要求,当数据规模不大时,隐藏层的层数一般选择 3 层即可。

设置好上述网络常规参数后,调节网络中的噪声系数,以 SNR = -6 dB 时的数据集进行实验,研究噪声系数

对信号识别率的影响,结果如图 12 所示。




图 12 不同噪声系数下识别率的变化

Fig. 12 Recognition rate change under different noise coefficients

从图 12 结果来看,噪声系数的合理选择能有效提高网络的识别准确率,在噪声系数为 0.5 时,整个网络的识别精度最高,达到 83.67%,当大于 0.5 时识别率较不添加噪声时有明显下降,这是因为尽管 SDAE 网络能很好地学习混入噪声的原始数据,并提取其特征,但加入了过多的噪声会让原始数据被破坏严重,导致网络的学习性能不理想,因此本文噪声系数设置为 0.5。

3.2 实验性能比较

本组实验通过对不同 AFCL 特征降维算法、人工提取特征方法、其他 DNN 模型算法以及不同信号输入形式 4 个部分进行综合性能比较与分析,验证本文各阶段所采用的方法与模型所组成的整个识别系统的有效性和泛化能力。

1) 不同降维算法识别性能比较

深度学习网络常用的降维方法有很多种,为探讨不同模型对等高线的特征降维能力,采用流形学习局部线性嵌入算法^[16](locally linear embedding, LLE) + SDAE、SDAE 及本文的 PCA + SDAE 3 种降维模型进行对比实验,识别率变化结果如表 1 所示。

由表 1 可知,LLE + SDAE 模型识别效果不理想且下降较快,识别率从 SNR = 0 dB 时的 93.83% 下降到 -8 dB 时仅有 58.80%,原因在于 LLE 算法仅能保持 AF 流形结构,由于数据类内方差偏大,导致网络分类识别效果不佳。而 SDAE 模型和 PCA + SDAE 模型识别率明显优于上者,在 0 dB 时分别能达到 96.67% 和 99.83%。但从平均耗时角度分析,LLE + SDAE 模型平均提取特征和识别耗时大约为 9 min 57 s,SDAE 模型大概为 32 min 42 s,而 PCA + SDAE 结构仅需要 58 s 左右,因为尽管 SDAE 网络具有一定的降维性能,但其输入维数远大于 PCA + SDAE 结构的维数,网络隐层节点数变大,训练和识别时间增加。考虑到 AFCL 模糊能量分布特性和神经网络提取特征的时间复杂度,PCA + SDAE 模型结构要优于以上两种。

表 1 不同降维模型的识别率

Table 1 The recognition rate of different dimensional reduction models

模型结构	动态 SNR 下信号的识别率/%								平均耗时/s
	-8 dB	-6 dB	-4 dB	-2 dB	0 dB	2 dB	4 dB	6 dB	
LLE+SDAE	58.80	70.51	78.83	87.17	93.83	96.70	98.83	99.50	597
SDAE	68.33	80.50	90.50	93.83	96.67	99.10	100.00	100.00	1 962
PCA+SDAE	70.50	83.67	93.33	99.83	99.83	100.00	100.00	100.00	58

2) 与人工特征提取性能比较

相较于人工特征的提取方法,深度学习模型更利于对复杂调制类型辐射源信号的 AFCL 提取出其内部更加泛在的模糊能量特征。为研究低 SNR 情况下 SDAE 网络提取特征的能力,选取文献[6]提出的双谱特征、文献[17]的 AF 三维特征、文献[18]的 AF 极坐标域特征 3 种人工提取特征方法做对比实验,结果如图 13 所示。




图 13 与人工特征提取性能的比较

Fig. 13 Performance comparison with manual feature extraction

由图 13 可知,文献[6]提出的双谱特征是对信号相位噪声特性进行提取,因而在低 SNR 情况下受噪声干扰大,在-2 dB 时识别率仅为 72%。文献[17]从主、侧视角提取 AF 的主岭重心和主峰分布半径等三维特征,平均分选成功率在-2 dB 时为 79%,原因是 AF 三维图能量信息较多且维数太大,噪声带来的毛刺和畸变比较多,直接对其提取特征耗时和复杂度也会提高。文献[18]对 AF 进行极坐标域转换,相较于上述方法,在低 SNR 环境下分选成功率大大提升,-2 dB 时能达到 88.5%。可见,本文方法在低信噪比环境下,能提取 AFCL 深层模糊能量特征,在-2 dB 时识别率仍保持在 99.83%,识别效果优于以上 3 种方法。由此可见,人工提取浅层特征的方法在低 SNR 条件下抗噪性能欠缺,难以对调制类型不同的辐射源信号有效分选识别。深度学习虽依靠信号的先验信息,但由此训练并提取的特征,受噪声干扰小,能更完备地表达辐射源信号深层更泛在的信息,从而提高识别率。

3) 与其他深度学习模型性能比较

为验证本文深度学习算法模型的有效性,实验选取文献[19]提出的集成学习模型、AFCL+AE 模型和 AFCL+CNN 模型 3 种结构,与本文方法进行比较,观察动态 SNR 环境下信号的整体识别率变化,结果如图 14 所示。




图 14 与其他深度学习模型性能比较

Fig. 14 Performance comparison with other deep learning models

从图 14 中看出,在 SNR>2 dB 时,4 种方法的抗噪性能都较好,但在低 SNR 环境下,后 3 种方法的识别率下降较快,而本文方法仍能保持稳定的识别效果。分析原因,文献[19]用 Morlet 小波变换对辐射源信号时频分析,采用多分类器组合来对提取的特征进行分类,导致部分信号被错分,识别率受到影响。AFCL+CNN 的方法在 SNR=0 dB 识别率虽能达到 93.83%,但在低 SNR 下的效果相较于本文方法仍显劣势。而 AFCL+AE 的方法,在 0 dB 时为 86.67%,仅一层的隐藏层不能保证网络较好地学习和提取到 AFCL 的本质特征,况且未对信号去噪,整个模型的鲁棒性和泛化能力也没有本文方法强。因此可见,本文的 AFCL+SDAE 算法模型在低 SNR 条件下,信息利用率更高,相比浅层神经网络具备较强的抗噪性能和稳定的泛化性能。

4) 不同信号输入形式的性能比较

为验证本文系统的泛化能力,选取雷达信号由 STFT 得到的时频特征图、AF、模糊函数主脊 (AF main ridge, AFMR) 以及 AFCL 四种信号输入形式进行对比实验。时频特征图数据量多且特征维数大,考虑到 SDAE 网络节

点数的限制,用 PCA 和随机投影对其进行联合降维后作为输入。而 AF 属于三维特征,其能量分布主要分布在原点附近,对 AF 中心 30×30 能量分布区域进行裁剪作为输入。AFMR 由于其原点对称性,选取一半即维数为 512 作为输入。图 15 所示为 4 种形式的输入在不同 SNR 环境下的识别率变化情况。




图 15 不同信号输入形式的性能比较

Fig. 15 Performance comparison of different signal input forms

由图 15 可知,AFCL 和 AFMR 在 $\text{SNR} \geq -2$ dB 时,识别准确率均能达到 95% 以上,且相差不到 3%。在低 SNR 环境下,以时频特征和 AF 作为输入时的识别率下降幅度较大,其中以 AF 作为输入时在 -6 dB 时识别率仅为 56%,远不如其他 3 种形式。以 AFMR 作为输入在此条件下保持在 82%,而以 AFCL 作为输入能达到 83.67%,明显优于其他 3 种输入形式,说明在复杂的噪声环境下,AFCL 仍能保留信号深层模糊能量信息,抗噪性能较强。而时频特征维数较大,在联合降维中信息损耗较多,且未采取任何降噪措施,因此同等条件下识别率仅为 72%。综合分析,从辐射源信号的 AF 中计算并绘制出 AFCL,既能有效降低 AF 的特征维数,又能契合 SDAE 网络的降噪性能,即使在低 SNR 环境下识别率也能得到有效保障。

3.3 特征维数分析

数据的维数同样影响着深度学习网络的性能,用更少的数据尽可能保留更多的特征是所有模式识别问题所关注的细节。本文采用 PCA 算法对 AFCL 数据进行特征降维,为研究特征维数对 SDAE 网络识别率的影响,选择 $\text{SNR} = -6$ dB 的数据集进行实验,结果如图 16 所示。

从图 16 中分析得出,特征维数越低,代表着经过 PCA 处理后的 AFCL 所保留的模糊能量信息越少,此时 SDAE 网络学习效果不理想,整体识别率偏低。随着维数增加,识别率准确率在不断上升,可以看到,当特征维数大于 300 时,识别效果比较稳定。综合考虑网络的特征提取速度和数据的完整性,因此本文特征维数选择 363,这与表 1 实验结果基本一致。




图 16 特征维数对识别率的影响

Fig. 16 The effect of the feature dimension on the recognition rate

3.4 系统鲁棒性分析

训练数据量的大小影响系统的整体准确率,通过不同数量训练样本的整体平均识别率,来考察本文系统的鲁棒性。每类雷达辐射源信号训练数据从 100 组逐渐增加到 600 组,步长 100 组,测试数据为 100 组。为使实验更具充分性,选取 $\text{SNR} = -8, -6, -4$ dB 三种信噪比环境进行实验,结果如图 17 所示。




图 17 不同训练样本下识别率的变化

Fig. 17 Comparison of recognition rates of different training samples

从图 17 结果来看,6 类信号的整体平均识别率随训练数据的增加而平缓上升,信噪比越低,系统整体识别率上升越明显。当训练样本量大于 400 组时,3 种信噪比情形下的信号识别准确率上升都比较细微,说明此时网络分类器的整体性能已趋于平稳。在 $\text{SNR} = -4$ dB 环境下,当训练数据从 100 组增加到 600 组时,其识别准确率变化大小不到 3%,证实了在小样本的环境下,本文系统仍具有良好的分类性能和鲁棒性。

4 实测雷达数据实验

采用某外场部分雷达实测数据,进一步验证本文

方法在实际战场环境下的工程价值。选取 5 种雷达辐射源信号各生成 100 个样本,即 500 个样本作为测试

集。辐射源信号集参数设置如表 2 所示,识别结果如表 3 所示。

表 2 实测雷达辐射源信号数据集参数
Table 2 Parameters of measured radar emitter signals data set

辐射源集	辐射源集参数		
	调制类型	RF/MHz	PW/ μ s
1	线性调频	8645、8810、8682、8750 四个频点波位组变,频率分集	20
2	非线性调制	8850 固定	16
3	非线性调制	8822、8773、8792、8807、8833 五个频点波位组变	4~6 个脉冲一组,每组 PW 在 8、14 任意
4	常规脉冲	8600~8800 单脉冲捷变	4~6 个脉冲一组,每组 PW 在 0.5、0.6、0.7、0.8 任意
5	线性调频	8518、8523、8548、8553、8563 五个频点波位组变	4~6 个脉冲一组,每组 PW 在 8、16、24 任意

表 3 实测数据集实验结果
Table 3 Experimental results of measured data set

实测数据集	识别率/%	平均识别率/%
1	100	87.4
2	100	
3	72	
4	70	
5	95	

从表 2 中可以看出,不同辐射源集的调制类型、RF 和 PW 都有明显的交叠,且部分 RF 和 PW 还伴有捷变和抖动,极大增加了辐射源信号的整体识别难度。从表 3 中可以看出,本文方法对于线性调频及固定 RF 的非线性调制信号集的识别效果较好,而 3、4 辐射源集参数跳变显著且预处理的复杂度较大,因而分类识别效果有限。但总体来讲,5 个实测雷达辐射源信号集的整体平均识别率保持在 87.4%,证明在复杂多变的信号环境中,本文方法具有一定的工程可行性。

5 结 论

复杂体制雷达辐射源信号常规识别方法特征提取耗时长、识别性能差。为此,本文提出一种基于 AFCL 与 SDAE 的识别新方法,把信号识别问题转变为图像输入并由深度学习模型提取特征的过程。通过仿真实验表明,AFCL 保留了信号更多的模糊能量信息,而 SDAE 网络的构建,既能对 AFCL 做进一步的降噪处理,又契合了其能量信息特征分布,具有维数低,抗噪性能强,系统鲁棒性良好等优势。此外,实测数据集 3、4 辐射源信号的识别效果不理想,有待提高,因此构建更完备的深度学习模型结构以及补偿由噪声带来的 AF 图形塌陷是下一步要研究的问题。

参考文献

[1] DELPART N. Asymptotic wavelet and Gabor analysis: Extraction of instantaneous frequencies [J]. IEEE Trans. Information Theory, 1992, 38(3): 644-664.

[2] MORAITAKIS I, FARGUES M P. Feature extraction of intra-pulse modulated signals using time-frequency analysis [C]. Proceedings of 21st Century Military Communications Conference, 2000:737-741.

[3] LOPEZ R G, GRAJAL J, YESTE O O. Atomic decomposition-based radar complex signal interception [J]. Radar, Sonar and Navigation, IEE Proceedings, 2003, 150(4):323-331.

[4] 龙英,何怡刚,张镇,等. 基于信息熵和 Haar 小波变换的开关电流电路故障诊断新方法[J]. 仪器仪表学报, 2015,36(3):701-711.

LONG Y, HE Y G, ZHANG ZH, et al. Switched-current circuit fault diagnosis based on entropy and Haar wavelet transform [J]. Chinese Journal of Scientific Instrument, 2015, 36(3):701-711.

[5] CHEN CH X, HE M H, XU J, et al. A new method for sorting unknown radar emitter signal [J]. Chinese Journal of Electronics, 2014, 23(3): 499-502.

[6] CAO R, CAO J W, MEI J P, et al. Radar emitter identification with bispectrum and hierarchical extreme learning machine [J]. Multimedia Tools and Applications, 2019, 78(20):28953-28970.

[7] 王建华,杨延西,马晨. 基于价值函数的二维小波变换小波脊提取算法[J]. 仪器仪表学报, 2017, 38(12): 2915-2923.

WANG J H, YANG Y X, MA CH. Wavelet ridge extraction algorithm using a cost function in two dimensional wavelet transform [J]. Chinese Journal of Scientific Instrument, 2017, 38(12):2915-2923.

[8] 韩俊,何明浩,朱振波,等. 基于复杂度特征的未知雷

- 达辐射源信号分选[J]. 电子与信息学报, 2009, 31(11):2552-2556.
- HAN J, HE M H, ZHU ZH B, et al. Sorting unknown radar emitter signal based on the complexity characteristics [J]. Journal of Electronics & Information technology, 2009, 31(11):2552-2556.
- [9] GUO Q, NAN P L, ZHANG X Y, et al. Recognition of radar emitter signals based on SVD and AF main ridge slice [J]. IEEE Journals & Magazines, Journal of Communications & Networks, 2015, 17(5):491-498.
- [10] 朱阳光,刘瑞敏,黄琼桃. 基于深度神经网络的弱监督信息细粒度图像识别[J]. 电子测量与仪器学报, 2020,34(2):115-122.
- ZHU Y G, LIU R M, HUANG Q T. Fine-grained image recognition of weak supervisory information based on deep neural network [J]. Journal of Electronic Measurement and Instrumentation, 2020,34(2):115-122.
- [11] JIANG W B, LIU P L, WEN F. Speech magnitude spectrum reconstruction from MFCCs using deep neural network [J]. Chinese Journal of Electronics, 2018, 27(2):393-398.
- [12] 奚雪峰,周国栋. 面向自然语言处理的深度学习研究[J]. 自动化学报,2016,42(10):1446-1465.
- XI X F, ZHOU G D. A survey on deep learning for natural language processing [J]. Acta Automation Sinica, 2016,42(10):1446-1465.
- [13] 普运伟,金炜东,朱明,等. 雷达辐射源信号模糊函数主脊切面特征提取方法[J]. 红外与毫米波学报, 2008,27(2):133-137.
- PU Y W, JIN W D, ZHU M, et al. Extraction the main ridge slice characteristics of ambiguity function for radar emitter signals [J]. Journal of Infrared and Millimeter Waves, 2008, 27(2):133-137.
- [14] MA J, YUAN Y. Dimension reduction of image deep feature using PCA [J]. Journal of Visual Communication and Image Representation, 2019, DOI: 10.1016/j.jvcir.2019.102578.
- [15] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders [C]. Proceedings of the Twenty - Fifth International Conference on Machine Learning, 2008: 1096-1103.
- [16] LUO L, LI Y H, LUAN Y H. LLE-based classification algorithm for MMW radar target recognition [J]. Journal of Electronics (China), 2010, 27(1):139-144.
- [17] 普运伟,侯文太,郭媛蒲,等. 基于模糊函数三维特征的雷达辐射源信号分选方法[J]. 控制与决策, 2019, 34(10):2178-2184.
- PU Y W, HOU W T, GUO Y P, et al. A sorting method of radar emitter signal based on three dimensional feature of ambiguity function [J]. Control and Decision, 2019, 34(10):2178-2184.
- [18] 普运伟,郭媛蒲,侯文太,等. 模糊函数主脊切面极坐标域形态特征提取方法[J]. 仪器仪表学报,2018, 39(10):1-9.
- PU Y W, GUO Y P, HOU W T, et al. Morphological feature extraction based on the polar transformation of the slice of ambiguity function main ridge [J]. Chinese Journal of Scientific Instrument, 2018,39(10):1-9.
- [19] 黄颖坤,金炜东,余志斌,等. 基于深度学习和集成学习的辐射源信号识别[J]. 系统工程与电子技术, 2018,40(11):2420-2425.
- HUANG Y K, JIN W D, YU ZH B, et al. Radar emitter signal recognition based on deep learning and ensemble learning [J]. Systems Engineering and Electronics, 2018, 40(11):2420-2425.

作者简介



普运伟(通信作者),分别于1995年和1998年在西南师范大学获得学士学位和硕士学位,2007年于西南交通大学获得博士学位,现为昆明理工大学教授、博士生导师,主要研究方向为智能信息处理、智能信号处理等。

E-mail: puyunwei@126.com

Pu Yunwei (Corresponding author) received his B. Sc. degree and M. Sc. degree both from Southwestern Normal University in 1995 and 1998, and received his Ph. D. degree from Southwestern Jiaotong University in 2007. He is currently a professor and a Ph. D. advisor at Kunming University of Science and Technology. His main research interests include intelligent information processing, intelligent signal processing, etc.



郭江,2018年于楚雄师范学院获得学士学位,现为昆明理工大学硕士研究生,主要研究方向为智能信号处理、模式识别等。

E-mail: 923755435@qq.com

Guo Jiang received his B. Sc. degree from Chuxiong Normal University in 2018. He is currently a master student at Kunming University of Science and Technology. His main research interests include intelligent signal processing, pattern recognition, etc.