

栈式降噪自编码器在辐射源信号识别中的应用

叶文强^{1,2}, 俞志富², 张 奎², 王虎帮²

(1. 63768 部队, 西安, 710600; 2. 国防科技大学电子对抗学院, 合肥, 230037)

摘要 针对传统辐射源信号识别方法在低信噪比条件下提取特征困难且识别率低的问题, 提出了一种基于短时傅里叶(STFT)变换和栈式降噪自编码器(sDAE)的识别系统。首先对雷达辐射源信号进行短时傅里叶变化, 然后对时频图像进行一系列预处理, 将处理后的图像输入到栈式降噪自编码器中, 将提取的特征输入到 softmax 分类器中, 完成分类识别。通过仿真表明: 该系统在 SNR = -10 dB 的时候, 识别率能够达到 80% 以上, 在低信噪比的情况下, 识别效果明显优于传统识别方法。

关键词 雷达辐射源; 短时傅里叶; 图像预处理; 栈式降噪自编码器; 分类器

DOI 10.3969/j.issn.1009-3516.2019.06.008

中图分类号 TN973 **文献标志码** A **文章编号** 1009-3516(2019)06-0047-07

Application of sDAE in Emitter Signal Recognition

YE Wenqiang^{1,2}, YU Zhifu², ZHANG Kui², WANG Hubang²

(1. Unit 63768, Xi'an 710600, China;

2. College of Electronic Countermeasure, National University of Defense Technology, Hefei 230037, China)

Abstract: Aimed at the problems that by the traditional recognition method the recognition rate is low and the feature extraction is difficult under condition of low signal to noise ratio, an automatic classification and recognition system based on short time Fourier transform (STFT) and stacked de-noising Auto-Encoder (sDAE) is proposed. Firstly, the radar emitter signal is changed by the short time Fourier transform, then a series of preprocessing is carried out to the time frequency image. The processed image is input into the stacked denoising auto-encoder, and the extracted features are input into the soft-max classifier to complete the classification recognition. The simulation shows that the recognition rate can reach more than 80% when the system is in SNR = -10 dB. In the case of low SNR, the recognition rate is obviously better than that by the traditional recognition method.

Key words: radar emitter; short time Fourier transform(STFT); image processing; stacked de-noising auto-encoder (sDAE); classifier

在现代化战争中, 雷达辐射源信号识别起着非常重要的作用, 对电子侦察设备的效能有关键影响, 并在后续作战中无可替代。信号识别不仅可以作用

于侦察敌方系统, 还可以判断敌方作战武器对我方能否构成威胁, 对整个战争的发展有着至关重要的意义。随着现代化科技的发展, 传统的识别方法已

收稿日期: 2018-06-05

基金项目: 安徽省自然科学基金(1808085QF182)

作者简介: 叶文强(1994—), 男, 安徽合肥人, 硕士生, 主要从事智能信息处理研究。E-mail: 869440437@qq.com

引用格式: 叶文强, 俞志富, 张奎, 等. 栈式降噪自编码器在辐射源信号识别中的应用[J]. 空军工程大学学报(自然科学版), 2019, 20(6): 47-53. YE Wenqiang, YU Zhifu, ZHANG Kui. Application of sDAE in Emitter Signal Recognition[J]. Journal of Air Force Engineering University (Natural Science Edition), 2019, 20(6): 47-53.

经无法满足现代化战争形势,需要引入人工智能的方法来应对瞬息万变的新型作战^[1]。雷达辐射源信号特征提取是信号分选和识别的重要基础,并且能够决定信号识别的准确性和高效性,最终影响电子情报侦察能力,对后续战争决策有着至关重要的影响^[2]。文献[3]利用时频图像局部二值模式纹理特征,运用支持向量机进行分类识别,该算法运算效率高,具有较强的适应能力,但是在低信噪比情况下效果有待提高。文献[4]利用稀疏自编码器对信号时频图像进行分类识别,运行速度快,鲁棒性较强,由于在前期处理使用不同降维提取联合时频特征,导致识别率不高。文献[5]利用 CNN 结合全双谱进行信号识别,对信号双谱进行特征提取分类识别,相位编码和频率编码区分效果明显,但是没有对其它类型调制信号识别。

本文提出了一种基于短时傅里叶时频分析和栈式降噪自编码器(sDAE)的辐射源信号识别算法。对信号进行时频变换,将一维信号变成二维时频图像,然后对时频图像进行一系列图像变换,最后将处理好的图像数据调整为向量输入到 sDAE 模型中,进行分类识别。

1 基本概念

1.1 降噪自编码器

Vincent 等人在 2010 年提出了降噪自编码器结构^[6],此类编码器为了能够实现更好的特征表达,主要改变是对编码器的输入进行加噪处理。自编码器(Auto Encoder, AE)是一种非监督式的 3 层神经网络^[7],主要是由输入层、隐藏层和输出层构成,网络结构如图 1 所示。

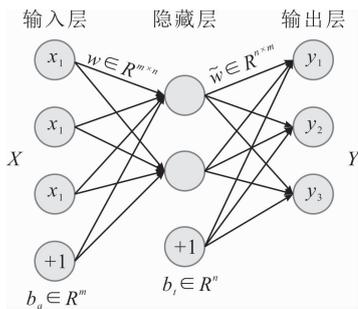


图 1 自编码器结构示意图

将输入向量映射到隐藏层的过程就是编码,经过编码可以得到新的特征表达,表示如下:

$$z = f(x) = f(W^{(1)}x + b^{(1)}) \quad (1)$$

式中: $x \in R^{n \times 1}$ 是输入向量; $W^{(1)} \in R^{m \times n}$ 为隐藏层权重矩阵; $b^{(1)} \in R^{m \times 1}$ 为隐藏层的输入偏置, $z \in R^{m \times 1}$ 是输出向量。 $f(\cdot)$ 为激活函数,常用的激活函数有 Sigmoid 函数: $f(x) = \frac{1}{1+e^{-x}}$, 以及 tanh 函数: $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ 。

将隐藏层 Z 映射回输入 x 就是解码的过程,函数表示为:

$$x = g(z) = s(W^{(2)}z + b^{(2)}) \quad (2)$$

式中: $W^{(2)} \in R^{n \times m}$; $b^{(2)} \in R^{n \times 1}$, 综合式(1)和式(2),可以得到数据的重建误差为:

$$L = \|x - g(f(x))\|^2 \quad (3)$$

定义代价函数为:

$$J(W, b) = \left[\frac{1}{N} \sum_{i=1}^N \left(\frac{1}{2} \|x^{(i)} - g(f(x^{(i)}))\|^2 \right) \right] + \frac{\lambda}{2} \sum_{l=1}^2 \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (W_{ji}^{(l)})^2 \quad (4)$$

式中: $x^{(i)}$ 代表第 i 个样本; $W_{ji}^{(l)}$ 代表第 l 层第 i 个单元与第 l+1 层第 j 单元之间的连接权重; N 代表样本的数量; s_l 代表第 l 层的单元数; λ 是正则化系数,本文取 1。

最优解 W 和 b 可以通过误差方向传导和批量下降算法^[8]得到。

在降噪自编码器中,通过加噪迫使自动编码器学习去除噪声。为了可以得到未被污染的输入数据^[9],在输入已经有噪声污染的情况下,降噪自编码器可以找到更稳定和更深层次的特征,降噪训练的原理如图 2 所示。

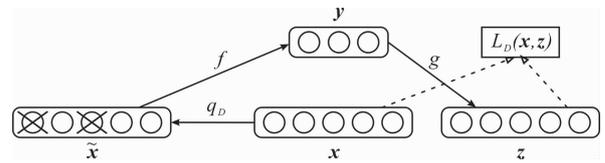


图 2 降噪自编码器结构

图 2 中, x 表示原始输入数据, \tilde{x} 表示受损的输入数据, y 是对 \tilde{x} 进行编码得到的新数据, z 是对 y 进行解码后的输出。重建误差表示为:

$$L_D = \|x - g(f(\tilde{x}))\|^2 \quad (5)$$

代价函数为:

$$J_D(W, b) = \left[\frac{1}{N} \sum_{i=1}^N \left(\frac{1}{2} \|x^{(i)} - g(f(\tilde{x}^{(i)}))\|^2 \right) \right] + \frac{\lambda}{2} \sum_{l=1}^2 \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (W_{ji}^{(l)})^2 \quad (6)$$

1.2 栈式降噪自编码器模型

栈式降噪自编码器模型就是由多个无监督的降噪自编码器堆栈和一层有监督的 BP 神经网络构成的^[10]。

先利用没有标记的样本对降噪自编码器进行贪婪逐层学习^[11],学习过程为:假设网络总共有 N 个隐藏层,将原始输入数据作为第 1 层 DAE 的输入进行无监督训练,得到第 1 个隐藏层的参数 $\mathbf{W}^{(1)}$,一直往下训练,把训练好的 $l-1$ 层的输出作为第 1 层的输入进行训练,可以得到 $\mathbf{W}^{(l)}$ 。通过反向传播微调整个网络的参数,使参数达到最优的收敛状态。

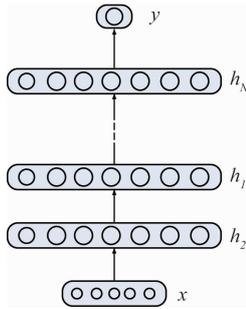


图 3 栈式降噪自编码器结构

1.3 Softmax 分类器

分类器主要有 Softmax 分类器,SVM 分类器,贝叶斯分类器等。本文采用 Softmax 分类器。现在有训练集 $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$,其中 $y^{(i)} \in \{1, 2, \dots, k\}$ 。该模型是一种有监督的算法,输入样本之间的类别区分很明确,同一个的样本不会属于多个类别之中^[12]。假设输入为 x ,那么它是类别 j 的概率表示为 $p(y=j/k)$ 。Softmax 所对应的神经网络的假设函数为:

$$h_{\theta}(x^{(i)}) = \begin{bmatrix} p(y^{(i)}=1|x^{(i)};\theta) \\ p(y^{(i)}=2|x^{(i)};\theta) \\ \vdots \\ p(y^{(i)}=k|x^{(i)};\theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}} \begin{bmatrix} e^{\theta_1^T x^{(i)}} \\ e^{\theta_2^T x^{(i)}} \\ \vdots \\ e^{\theta_k^T x^{(i)}} \end{bmatrix} \quad (7)$$

式中: $\theta = [\theta_1, \theta_2, \dots, \theta_k]^T, \theta_i \in R^{n+1}$,表示第 i 个输出神经元与输入层相连接的权重; $\frac{1}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}}$ 表示归一化项,从而使得模型的输出的概率值和为 1^[13]。

雷达辐射源信号时频特征区别不是很大,甚至很小,在区别较小的样本,Softmax 会找到一个权重值,以尽可能放大样本之间的差异,Softmax 的分类会更加细致,SVM 分类器主要用来区别较大的样本,并且 Softmax 分类器是将 Logistics 回归二分类问题变为 k 分类问题,每个类别通过公式得出输出概率,计算简单,因此,本文选用 Softmax 分类器。

2 基于 sDAE 的时频特征识别算法实现

对雷达辐射源信号进行短时傅里叶变换,得到时频图像,但是时频图像不能直接作为 sDAE 网络的输入,因此需要对时频图像进行预处理。

2.1 图像预处理

以 LFM 信号 $s(t)$ 为例进行说明,对 LFM 信号进行短时傅里叶变换,得到 $S(t, f)$,如图 4 所示。

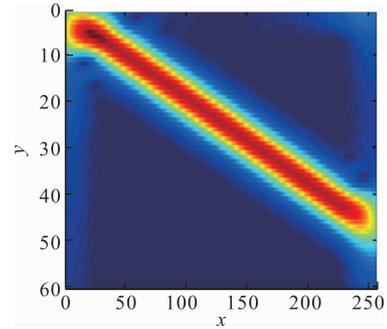


图 4 LFM 信号时频图像

对时频图像每个点做归一化处理:

$$S^a(t, f) = \frac{|S^a(t, f)|}{|S(t, f)|_{\max}} \quad (8)$$

时频图像转化为的灰度图像如图 5 所示。

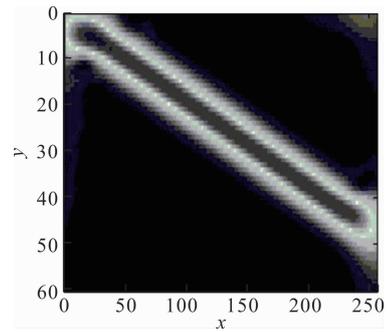


图 5 时频图像灰度图

为了去除一部分噪声,减少噪声对后续识别的影响,对灰度图像进行阈值二值化操作:

$$S^a(t, f) = \begin{cases} S^a(t, f), & S^a(t, f) \geq \text{thred} \\ 0, & S^a(t, f) < \text{thred} \end{cases} \quad (9)$$

将处理后的时频图像进行向量化操作,变成向量 α_n^T ,作为特征向量输入到网络模型中,那么 n 个输入样本就可以表示成:

$$\mathbf{V} = (\alpha_0^T, \alpha_1^T, \dots, \alpha_n^T)^T \quad (10)$$

2.2 本文算法识别框图

算法识别框图见图 6。

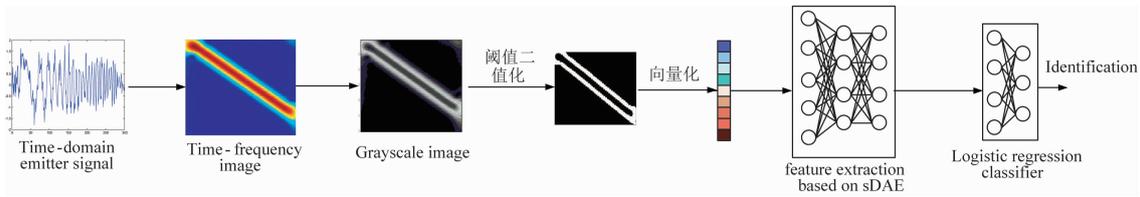


图6 本文算法识别框图

本文提出的算法框架流程如下所示:

1)数据预处理。对雷达辐射源信号进行短时傅里叶时频变换,对信号的时频图像进行图像处理,主要包括归一化、灰度、阈值二值化操作,最后将处理后的时频图像进行向量化操作,得到特征向量 V 。

2)特征提取。将特征向量 V 输入到 sDAE 网络中,调节网络参数,确定合适的网络结构。主要有 2 个步骤:①通过无监督学习调节每一层隐藏层权重矩阵 W ;②通过 BP 算法有监督学习,对整个网络的参数进行微调。

3)分类识别。结合本文的深度学习模型和识别任务,利用最后的 Softmax 分类器进行分类识别,输出每一种信号的识别概率。

集。试验硬件平台为:CPUi5-7300,内存为 8 G, MATLAB 版本为 R2014a。

定义雷达辐射源信号的总体识别正确率为:

$$P_r = \frac{N_r^1 + N_r^2 + \dots + N_r^6}{N^1 + N^2 + \dots + N^6} \quad (11)$$

定义单个种类雷达辐射源信号识别正确率:

$$P_r^i = \frac{N_r^i}{N^i}, i = 1, 2, \dots, 6 \quad (12)$$

式(11)和(12)中: P_r 表示总体识别率; N_r^i 表示第 i 类辐射源信号能够正确识别的个数; P_r^i 表示第 i 类辐射源信号的识别率; N^i 为第 i 类辐射源信号总的数目^[14]。

信噪比 $SNR = 10 \ln \frac{P_s}{P_n}$, P_s 表示信号有效功率,

P_n 表示噪声有效功率,当 $SNR = -10$ 的时候, $P_s = 0.1 P_n$,随着信噪比的提高,信号与噪声的比值会越来越大,当 $SNR = 0$ dB 的时候, $P_s = P_n$ 。所以,仿真中信号的信噪比很好地反映信号与噪声的关系。

3.1 参数调节

深度学习 sDAE 结构设置为 1 600-1 000-500-200-6,输入层为 1 600,3 个隐藏层分别为 1 000, 500,200,输出信号种类为 6 种,所以输出层设置为 6,学习率为 0.1,批训练样本数为 10,改变噪声系数,观察 $SNR = -8$ dB 时信号总体识别率变化,如图 8 所示。

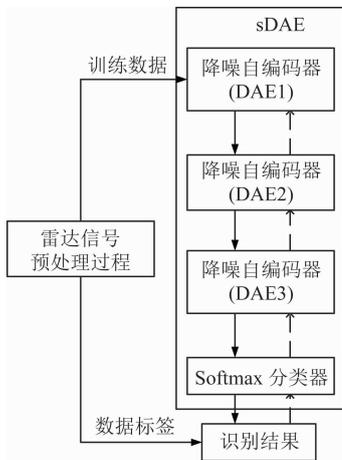


图7 sDAE 学习过程

3 仿真分析

为了验证本文算法有效性和对准确性,利用常见雷达辐射源信号进行仿真实验,分别是常规信号(CW)、二相编码压缩信号(BPSK)、二频率编码信号(BFSK)和四频率编码信号(QFSK)、线性调频信号(LFM)、非线性调频信号(NLFM)。信号参数设置载频为 200 MHz,采样率为 2 GHz,BPSK 和 BFSK 采用 11 位 Barker 码,QFSK 采用 16 位 Frank 码,信号在信噪比 -10 dB 到 2 dB 的范围内,每种信号每隔 2 dB 产生 200 个辐射源信号,作为测试集,在 $SNR \in [0 \text{ dB}, 10 \text{ dB}]$ 范围内每种信号随机产生 500 个样本,6 种信号总共 3 000 个样本作为训练

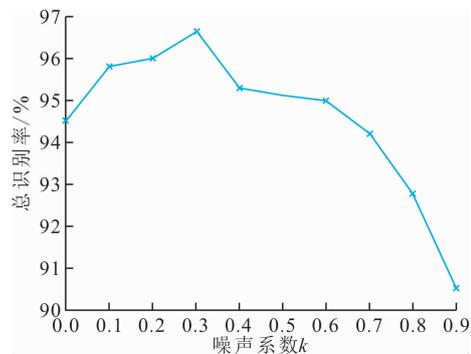


图8 噪声系数对识别效果的影响

从图 8 可以分析得到,合适的噪声能够提高模型的识别精度,在噪声系数 $k = 0.3$ 的时候,算法的识别率最高,达到 96.71%,在 $k \geq 0.7$ 的时候,识别精度较不添加噪声有明显下滑,这主要是因为过大的噪声会造成数据损坏,导致模型的学习能力大幅

度下降。

深度学习结构直接影响算法识别精度,控制学习率为 0.1,批训练样本数为 10,噪声系数 k 取 0.3,深度学习结构层数 $n \in [1,4]$,探究隐藏层数目对识别效果的影响,结果如表 1 所示。

从表 1 可知,网络结构层数并不是越多,识别效

表 1 隐藏层数目对识别结果的影响

隐藏层 数目 n	SNR/dB							平均训练 时间/s	平均识别 时间/s
	-10	-8	-6	-4	-2	0	2		
1	83.75%	92.21%	98.25%	100%	100%	100%	100%	26.75	0.06
2	85.42%	94.92%	99.20%	100%	100%	100%	100%	30.65	0.08
3	87.25%	96.71%	100%	100%	100%	100%	100%	32.15	0.10
4	85.66%	95.72%	98.91%	100%	100%	100%	100%	35.78	0.14

3.2 具体单个信号识别性能

确定 sDAE 结构 1 600-1 000-500-200-6,学习率为 0.1,批训练样本数为 10,噪声系数 k 为 0.3,改变信噪比,得到 6 种信号具体识别率,如图 9 所示。

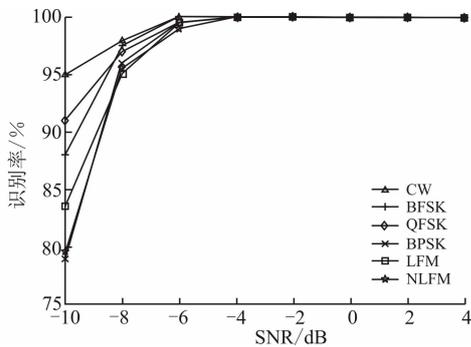


图 9 6 种信号具体识别率

分析图 9 可以得到:在 SNR=-10 dB 的时候,CW 信号识别效果最好,识别率达到 95%,NLFM 和 BPSK 的识别效果相对最差,识别率分别为 79% 和 79.5%,在 SNR=-4 dB 的时候,6 种信号识别率都达到 100%。

表 2 为 SNR=-8 dB 时测试集混淆矩阵,各信号在识别过程中出现混淆现象。在低信噪比的情况下,噪声所占比例大,有用信息被掩盖,信号微弱,导致识别效果差,每一种信号调制特征不明显,导致存

果就越好,因为网络层数过多会导致模型对数据产生过拟合现象^[15],导致识别效果下降。隐藏层数目越多,会导致训练时间和识别时间增加,模型运行时间主要集中在训练过程中,这是因为模型需要训练来调节每一层结构的权值矩阵,确定合适的权值系数,因此会占据模型大部分的时间。

在混淆。随着信噪比的提高,噪声降低,时频图像中的信号特征明显,不同种类信号区分度增强,从而识别效果提高。

表 2 SNR=-8 dB 时测试集混淆矩阵

	CW	LFM	NLFM	BPSK	QFSK	QFSK
CW	196	1	0	1	2	0
LFM	2	190	1	2	2	3
NLFM	1	0	191	3	2	3
BPSK	1	2	1	192	2	2
BFSK	0	2	0	2	195	1
QFSK	1	1	0	1	1	195

3.3 降维性能对比

sDAE 的框架结构中,每一次数据经过隐藏层,本质上都相当于一次降维处理,用更少的数据尽可能保留更多的特征。在上述结构中,数据输入为 1 600 维,在经过第 1 个隐藏层 1 000 个神经元处理,数据会变成 1 000 维。在这里,对比现在主流的 PCA 降维,进行 DAE 降维与 PCA 降维效果对比。先将输入数据 1 600 维进行 PCA 降维处理,降成 1 000 维,然后将这 1 000 维数据作为输入数据输入到框架结构为 1 000-500-200-6 的 sDAE 模型中。识别效果见表 3。

表 3 PCA+sDAE 模型识别结果

模型	SNR/dB							训练时间/s	识别时间/s	
	-10	-8	-6	-4	-2	0	2			
PCA+sDAE	48.88%	56.67%	74.25%	88.67%	96.5%	100%	100%	100%	22.15	0.08

从表 1 与表 3 对比分析得到,使用 PCA + sDAE 方法进行识别,在 SNR<0 dB 时,识别效果大幅度下降,主要是因为 DAE 降维能够保持数据多个特征,PCA 只能保持能量单一特征^[16],从而导

致识别效果下降。但是从框架运算速度上可以分析得到,PCA+sDAE 明显要优于 sDAE,接近快 10 s,这是因为 sDAE 的原始输入数据特征多于经过 PCA 降维的数据,导致前者框架结构在训练的时间

多于后者,识别时间基本保持一致。

3.4 与传统方法算法性能对比

图 10 为不同特征提取方法识别情况。

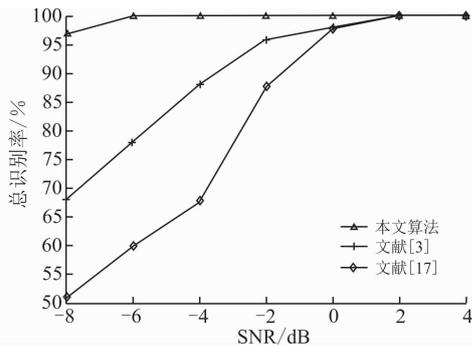


图 10 不同特征提取方法识别率

文献[3]利用改进的局部二值模式算法提取时频图调制特征,文献[17]提取信号时频图 SVD 特征

和 LDA 特征,这 2 种算法都是提取信号确定有限的特征,本文算法能够自动提取时频图多种特征,从而导致识别率差距较大。

3.5 与深度学习算法性能对比

文献[18]利用栈式稀疏编码器 (sSAE) 进行分类识别,CNN 表示的是实验室利用卷积神经网络进行分类识别,具体识别情况如表 4 所示。从平均时间来看,利用 CNN 时间最短,优于另外 2 种算法,sDAE 时间要比 sSAE 快 2.2 s,提高 6.1%;从识别性能上看,CNN 识别效果在 $SNR \leq -6$ dB 时明显不如其它 2 种算法,sDAE 在 $SNR = -10$ dB 时要优于 sSAE,在 $SNR \geq -8$ dB 时 2 种算法识别效果差不多。综合而言,本文算法性能更佳,更适用于要求高的场景。

表 4 不同深度学习结构识别效果对比

不同深度学习结构	SNR/dB								模型总时间/s
	-10	-8	-6	-4	-2	0	2	4	
sDAE	87.25%	96.70%	100%	100%	100%	100%	100%	100%	35.99
sSAE	80.25%	94.78%	99.75%	100%	100%	100%	100%	100%	38.19
CNN	72.81%	80.81%	92.82%	98.83%	99.72%	100%	100%	100%	21.75

4 结语

本文提出了一种基于栈式降噪自编码器 (sDAE) 雷达辐射源信号处理方法。通过对信号时频图像预处理,利用深度学习结构对处理后图像进行分类识别。通过仿真表明算法的可行性。与传统方法相比,本文算法在低信噪比时,明显优于其它算法。与其它深度学习方法相比,在综合模型运算时间和识别效果二者因素,本文算法更具有实用性。但是本文算法还是存在不足,比如在运行时间还是过长,参数设定上还是利用经验确定,如何进一步优化深度学习结构需要下一步扩展研究。

参考文献 (References):

[1] FRATER M, RYAN M. Electronic Warfare for the Digitized Battlefield [M]. Fitchburg, MA: Artech House Publisher, 2001.

[2] RAO G N, SASTRY C V S, DIVAKAR N. Trends in Electronic Warfare [J]. IETE Technical Review, 2003, 20(2):139-150.

[3] 孟凡杰,唐宏,王义哲,等. 基于时频图像纹理特征的雷达辐射源信号识别[J]. 弹箭与制导学报, 2017, 37(3):152-156.

MENG F J, TANG H, WANG Y Z, et al. Radar Emitter Signal Recognition Based on Texture Feature of Time-Frequency Image [J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2017, 37(3): 152-156. (in Chinese)

[4] 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, 2017, 44(3): 77-82.

ZHOU Z W, HUANG G M, GAO J. Radar Emitter Recognition Algorithm Based on Deep Learning [J]. Journal of Xidian University, 2017, 44(3):77-82. (in Chinese)

[5] 方成,薛质. 基于全双谱和卷积神经网络的信号分类方法[J]. 计算机应用研究, 2018, 35(12):3766-3769.

FANG C, XUE Z. Signal Classification Method Based on Complete Bispectrum and Convolutional Neural Network [J]. Application Research of Computers, 2018, 35(12):3766-3769. (in Chinese)

[6] PANG Y, YUAN Y, LI X. Gabor-Based Region Covariance Matrices for Face Recognition [J]. IEEE Transactions on Circuits & Systems for Video Technology, 2008, 18(7):989-993.

[7] ZNEG K, YU J, WANG R, et al. Coupled Deep Autoencoder for Single Image Super-Resolution [J]. IEEE Transactions on Cybernetics, 2017, 47(1):27-37.

- [8] 张一飞,陈忠,张峰,等. 基于栈式去噪自编码器的遥感图像分类[J]. 计算机应用, 2016, 36(2):171-174.
ZHANG Y F, CHEN Z, ZHANG F, et al. Remote Sensing Image Classification Based on Stacked Denoising Autoencoder [J]. Journal of Computer Application, 2016, 36(2):171-174. (in Chinese)
- [9] SHAO L, CAI Z, LU K, et al. Performance Evaluation of Deep Feature Learning for RGB-D Image/Video Classification[J]. Information Sciences, 2017, 385(C):266-283.
- [10] 周洋, 陈家琪. 基于栈式降噪自编码器的协同过滤算法[J]. 计算机应用研究, 2017, 34(8):2336-2339.
ZHOU Y, CHEN J Q. Stacked Denoising Autoencoder for Collaborative Filtering Algorithm [J]. Application Research of Computers, 2017, 34 (8): 2336-2339. (in Chinese)
- [11] 梁淑芬, 刘银华, 李立琛. 基于LBP和深度学习的非限制条件下人脸识别算法[J]. 通信学报, 2014, 35(6):154-160.
LIANG S F, LIU Y H, LI L C. Face Recognition under Unconstrained Based on LBP and Deep Learning [J]. Journal on Communications, 2014, 35 (6): 154-160. (in Chinese)
- [12] REVERDY P, LEONARD N E. Parameter Estimation in Softmax Decision-Making Models with Linear Objective Functions[J]. IEEE Transactions on Automation Science & Engineering, 2016, 13(1): 54-67.
- [13] 刘亚冲, 唐智灵. 基于 softmax 回归的通信辐射源特征分类识别方法[J]. 计算机工程, 2018, 44(2):98-102.
LIU Y C, TANG Z L. Classification and Identification Method of Communication Radiation Source Feature based on Softmax Regression [J]. Computer Engineering, 2018, 44 (2):98-102. (in Chinese)
- [14] 周东青, 王玉冰, 王星, 等. 基于深度限制波尔兹曼机的辐射源信号识别[J]. 国防科技大学学报, 2016, 38(6):136-141.
ZHOU D Q, WANG Y B, WANG X, et al. Radar Emitter Signal Recognition Based on Deep Restricted Boltzmann Machine [J]. Journal of National University of Defense Technology, 2016 38(6):136-141. (in Chinese)
- [15] ELHEWY A H, MESBAHI E, PU Y. Reliability Analysis of Structure Using Neural Network Method [J]. Probabilistic Engineering Mechanics, 2006, 21(1):44-53.
- [16] YANG J, ZHANG D, FRANGI A F, et al. Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition [J]. IEEE Trans Pattern Anal Mach Intell, 2004, 26 (1): 131-137.
- [17] 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[J]. 计算机仿真, 2016, 33(3):18-22.
MENG F J, TANG H, WANG Y Z. Radar Emitter Signal Recognition Based on Fusion of Feature [J]. Computer Simulation, 2016, 33(3):18-22. (in Chinese)
- [18] 郭立民, 寇韵涵, 陈涛, 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 L M, KOU Y H, CHEN T. et al. Low Probability of Intercept Radar Signal Recognition Based on Stacked Sparse Auto-Encoder [J]. Journal of Electronics & Information Technology, 2018, 40 (4):18-22. (in Chinese)

(编辑:徐楠楠)