

基于半监督矩形网络的通信电台个体识别

黄健航,雷迎科

(国防科技大学电子对抗学院,安徽合肥 230037)

摘 要: 通信电台信号的小样本条件造成了电台个体识别准确性欠佳的问题,本文首次提出基于半监督矩形网络进行通信电台个体识别,克服小样本条件对电台个体识别效果的影响. 首先提取电台信号的矩形积分双谱特征,人为注入噪声构成污染样本,在半监督矩形网络编码器中有监督训练,其训练结果通过网络径向连接传给解码器,解码器再无监督学习,重构未污染的原始样本,从网络顶层提取电台个体特征,输入 softmax 分类器实现分类识别. 在实际采集的电台数据集上的实验结果说明,本算法在小样本条件下相比现有算法能更准确识别同型号的电台个体.

关键词: 小样本条件; 电台个体识别; 半监督学习; 矩形积分双谱; 自编码器

中图分类号: TN 975; TP 911.7 **文献标识码:** A **文章编号:** 0372-2112 (2019)01-0001-08

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2019.01.001

Communication Radio Individual Recognition Based on Semi-Supervised Rectangular Network

HUANG Jian-hang, LEI Ying-ke

(Electronic Countermeasures Institution of National University of Defense Technology, Hefei, Anhui 230037, China)

Abstract: Small sample condition of communication radio signal caused poor individual recognition on radios. To solve this problem, a method about communication radio individual recognition based on semi-supervised rectangular network was proposed innovatively. Firstly, the square integral bispectrum feature was extracted from radio signal and then was corrupted by Gaussian noise. The corrupted sample was passed to the encoder of semi-supervised rectangular network for supervised training. The trained parameterization was then mirrored to decoder through the lateral connection across the model. And the output was forced by decoder through unsupervised learning to be close to the clean input. Then the essential feature extracted was referred as the individual feature of radio signals. Individual recognition was finally accomplished by a softmax classifier. The experiment results on several radio datasets collected in actual environment indicated that the method had superior performance on identifying radio individuals with the same types under small sample condition.

Key words: small sample condition; radio individual recognition; semi-supervised learning; square integral bispectra; auto-encoder

1 引言

通信电台个体识别^[1,2]是现代电子战中获取制信息权的关键环节,指的是利用信号处理技术对截获的通信电台信号进行分析,提取其中包含电台个体信息的特征,对电台个体进行区分识别. 该技术不仅可以准确获悉通信电台个体的属性信息,还可以用于跟踪敌电台,进而推断敌军兵力调动部署、分析通信网组成,为我军把握战场态势提供重要情报.

通信电台个体识别的研究思路分为两个方向,一是利用电台信号的暂态特征^[3-5],另一种是利用电台信号的稳态特征^[6-13]. 暂态特征的优点是特征明显、易于识别,但具有对截获信号质量要求高、对环境噪声抵抗性差、只能区分不同类型的通信电台等缺点. 而稳态特征具有更强的环境适应性,具有隐蔽度高,不易被噪声干扰的优点,但由于形成机理复杂,无法用单一模型描述,故提取难度大,识别性能依赖有标签样本的数量. 基于稳态特征的电台个体识别方法,现主要有对杂散特

收稿日期:2017-07-03;修回日期:2018-02-16;责任编辑:孙瑶

基金项目:国家自然科学基金(No. 61272333);国防科技重点实验室基金(No. 9140C130502140C13068);总装预研项目基金(No. 9140A33030114JB39470)

征^[6,7]、时频特性^[8,9]、调制参数^[10,11]以及高阶统计量^[12,13]分析等方法.徐书华^[6]在2007年提出基于信号杂散特征识别电台的方法,可以识别同类型的电台个体,但在低信噪比条件下表现不佳.2013年唐智灵^[7]对杂散特征进行研究,在实际信号数据集上验证了算法性能的有效性.梁江海^[8]利用经验模态分解模型,从时域和频域分析电台信号进行识别.2017年韩洁^[9]将信号转换成3D-Hibert能量谱,一定程度实现了少量样本条件下对电台个体的识别.此外,汪勇^[10]、顾晨辉^[11]、陈志伟^[12]以及唐哲^[13]等人分别利用多种信号稳态特征提取方法,成功对多部同类型电台进行了个体识别.基于稳态特征的电台个体识别方法对样本规模的要求较高,因此有标签样本的数量成为了制约算法实际识别性能的最大因素.

小样本条件带来的问题在于实际环境中的有标签样本数量不足以充分提取电台个体特征,使得识别分类结果不理想.有标签样本的最大价值即具有人工标注的类别信息,但其中包含的个体信息却是固有的.由于人力有限,实际环境中还存在大量的无标签样本未经标注,但其中包含的个体信息与有标签样本中的完全相同,因此若通过有标签样本中的个体特征指导学习模型从无标签样本中提取相应的个体信息,则可以克服小样本问题.半监督学习即是基于以上思想,用有监督学习对模型进行指导性训练,再由无监督学习利用大量无标签样本将模型优化,提取电台信号样本中的本质个体特征.在半监督学习过程中,最关键的是无监督学习过程,它必须能够准确捕捉大量无标签样本中的固有特征.孙志军^[14]将深度自编码器算法与边际Fisher分析结合识别雷达图像,在样本量较小时准确率虽然下降,但仍然优于有监督方法.2015年Wu^[15]设计的降噪自编码器算法可以从高阶语音信号样本中快速提取低维特征,并且在重构后可以准确还原高阶输入样本,说明降噪自编码器算法对于语音信号具有较好的学习能力.2017年,赵飞翔^[16]利用栈式降噪稀疏自编码器准确识别仿真雷达目标,说明降噪自编码器模型能够有效进行目标识别,但抗噪性能还需进一步优化.

Valpola^[17]提出的矩形网络框架可以嵌入无监督学习网络模型,在多层感知神经网络模型^[18]的前提下,对MNIST与CIFAR-10图像数据集的识别达到了当前最高的结果.为从无标签样本中提取有效的电台个体信息,并与有标签样本中的标签信息结合,进行半监督学习,在该矩形网络框架的基础上,本文首次提出一种半监督矩形网络算法(Semi-Supervised Rectangular Network, SRN)识别电台个体,并且在三种同型号通信电台数据集上验证算法的鲁棒性,并与其他三种基于矩形积分双谱特征的电台个体识别算法进行对照.实验结

果显示,本文的SRN算法在小样本条件下能够达到优于对照方法的识别性能.

2 基于SRN的电台个体识别方法

基于SRN识别电台个体的流程如图1所示.

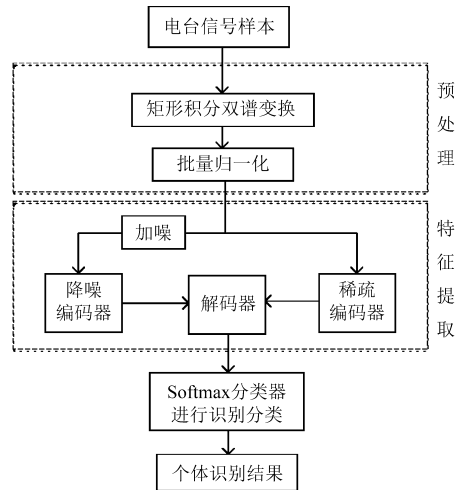


图1 算法基本流程

首先对电台信号样本进行矩形积分双谱变换,去除样本中的高斯噪声并完整表达样本的稳态特征.随后利用SRN进行低维电台个体特征提取,将输入特征进行批量归一化后,由人工注入噪声污染的有标签样本进行有监督编码,获得压缩表示的样本特征,通过网络径向连接用于初始化解码器学习起点,解码器无监督学习,优化网络代价函数.将代价函数最小时网络顶层所表征的低维特征输入softmax分类器,进行电台个体识别.其中,样本所用矩形积分双谱变换操作参照XU^[5]所提出的方法进行,本节直接从SRN提取电台个体特征开始介绍.

2.1 半监督矩形网络算法步骤

SRN算法在阶梯网络^[17]的基础上加入了有监督学习,可使无监督学习的起点处于有监督学习的终点,加快学习过程并且提升对样本学习的拟合程度.

本文采用的3层SRN算法的概念如图2所示,其中从左至右分别是编码器降噪路径、解码器、编码器稀疏路径,网络径向连接将编码器降噪路径与解码器对应各层连接,用于传递有监督学习结果;编码器降噪路径是实现样本特征提取的核心,通过训练与已知标签 $t(n)$ 匹配;解码器的功能是从有监督训练所得低维特征出发,借助无标签样本训练对代价函数优化,重构无污染输入样本;编码器稀疏路径的非线性映射与降噪路径相同,对高维样本进行相同的压缩表示,为代价函数中的重构误差项提供参考值.

算法的基本步骤如下.

步骤1 批量归一化后的少量有标签样本输入降

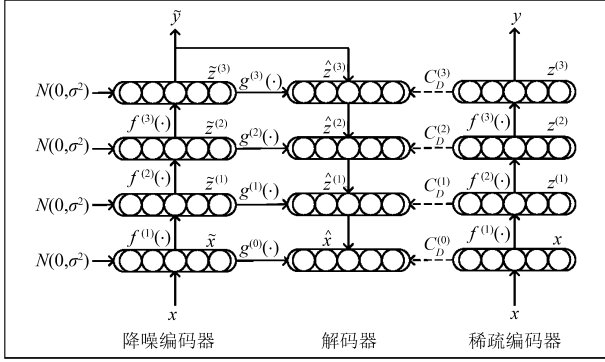


图2 SRN算法概念说明

噪编码器与稀疏编码器进行有监督学习,将有监督代价最小化;

步骤 2 网络径向连接传递编码器降噪路径各层的编码特征,初始化解码器各层的潜在变量;

步骤 3 解码器对大量无标签样本进行无监督学习,优化无监督代价函数;

步骤 4 梯度下降迭代最小化各层代价函数之和使网络最优,提取顶层编码特征输入分类器进行个体识别。

2.2 有监督式编码器

编码器所用前馈网络模型需要能够完整反映有标签样本中的类别信息,并提取其中属于样本固有信息的抽象特征,故选用了全连接型多层感知机^[18] (Multiple Layer Perceptron, MLP) 作为基本结构,基本单元为整流线性单元 (Rectified Linear Unit, ReLU)。

为提高代价函数的收敛性、避免梯度下降出现无意义解,需要对输入特征样本进行预处理,批量归一化处理^[19]可以防止编码器的输出为常数值 $l=1:L$

$$\mathbf{z}^{(l)} = \mathbf{N}_B(\mathbf{W}^{(l)} \mathbf{h}^{(l-1)}) \quad (1)$$

$$\mathbf{h}^{(l)} = \mathcal{O}(\mathbf{Y}^{(l)}(\mathbf{z}^{(l)} + \boldsymbol{\beta}^{(l)})) \quad (2)$$

其中, $\mathbf{z}^{(l)}$ 是稀疏路径编码输出的特征,即网络的潜在变量; $\mathbf{W}^{(l)}$ 是每层神经元的权重矩阵, $\mathbf{h}^{(l)}$ 是各层的隐元激励,且 $\mathbf{h}^{(0)} = \mathbf{x}$, \mathbf{N}_B 为逐元素批量归一化函数

$$\mathbf{N}_B(\mathbf{x}_i) = \frac{\mathbf{x}_i - \hat{\boldsymbol{\mu}}_{x_i}}{\hat{\boldsymbol{\sigma}}_{x_i}} \quad (3)$$

式中 $\hat{\boldsymbol{\mu}}_{x_i}$ 和 $\hat{\boldsymbol{\sigma}}_{x_i}$ 是由迷你批量^[19] 计算所得估计值, $\mathbf{Y}^{(l)}$ 和 $\boldsymbol{\beta}^{(l)}$ 是训练中变化的参数。 $\mathcal{O}(\cdot)$ 是 ReLU 的激励函数

$$\mathcal{O}(\cdot) = \max(0, \cdot) \quad (4)$$

将归一化的输入样本复制,向其中一组注入全向高斯噪声 \mathbf{n} (本文中 \mathbf{n} 满足均值为 0、方差为 0.01 的高斯分布),按比例覆盖部分样本特征,迫使编码器降噪路径能够重构出未污染样本^[20]。污染样本为

$$\tilde{\mathbf{x}} = \bar{\mathbf{h}}^{(0)} = \mathbf{x} + \mathbf{n}^{(0)} \quad (5)$$

此时降噪路径的编码器

$$\tilde{\mathbf{z}}^{(l)} = \mathbf{N}_B(\mathbf{W}^{(l)} \bar{\mathbf{h}}^{(l-1)}) + \mathbf{n}^{(l)} \quad (6)$$

$$\bar{\mathbf{h}}^{(l)} = \mathcal{O}(\mathbf{Y}^{(l)}(\tilde{\mathbf{z}}^{(l)} + \boldsymbol{\beta}^{(l)})) \quad (7)$$

假设输入的有标签样本 $x(n)$ 已知,对应标签 $t(n)$ 的污染样本重构 $\tilde{\mathbf{y}}$ 的平均负对数概率即为编码器的代价函数,在半监督矩形网络中为有监督代价,记为

$$C_c = -\frac{1}{N} \sum_{n=1}^N \log \mathcal{P}(\tilde{\mathbf{y}} = t(n) | x(n)) \quad (8)$$

通过梯度下降^[21] 使 C_c 最小时,将此时编码器各层的输出特征通过网络径向连接映射到解码器上,作为无监督学习的起点。

2.3 网络径向连接

网络径向连接的作用是将降噪编码器各层的压缩特征镜像映射到解码器各层,辅助解码器无监督训练达到对污染样本的最佳映射效果,使重构误差尽可能地小。Pezeshki^[22] 对比了各种映射函数的效果,据其研究结果,本算法选取了高斯潜在变量^[23] 的最佳映射函数作为径向连接。

假设网络其中第 l 层潜在变量 \mathbf{z} 的分布对第 $l+1$ 层满足高斯条件概率分布,则第 l 层潜在变量 $\mathbf{z}^{(l)}$ 对第 $l+1$ 层潜在变量 $\mathbf{z}^{(l+1)}$ 是条件独立的,即潜在变量 $\mathbf{z}^{(l)}$ 的分布假设为

$$p(\mathbf{z}^{(l)} | \mathbf{z}^{(l+1)}) = \prod_i p(z_i^{(l)} | z_i^{(l+1)}) \quad (9)$$

其中 $p(z_i^{(l)} | z_i^{(l+1)})$ 是条件独立高斯分布。

以上潜在变量分布假设可视作将高斯变量对角协方差矩阵作为潜在变量 $\mathbf{z}^{(l)}$ 的分布,较高层 $\mathbf{z}^{(l+1)}$ 对较低层 $\mathbf{z}^{(l)}$ 的分布形式进行调整。在本算法中采用两个函数: ν 和 μ , 表达解码器各层潜在变量映射函数值 $\hat{\mathbf{z}}_i^{(l)}$ 的非线性,则映射函数为

$$\begin{aligned} \hat{\mathbf{z}}_i^{(l)} &= \mathbf{g}_i(\tilde{\mathbf{z}}_i^{(l)}, \mathbf{u}_i^{(l)}) \\ &= (\tilde{\mathbf{z}}_i^{(l)} - \boldsymbol{\mu}_i(\mathbf{u}_i^{(l)})) \nu_i(\mathbf{u}_i^{(l)}) + \boldsymbol{\mu}_i(\mathbf{u}_i^{(l)}) \end{aligned} \quad (10)$$

其中 $\mathbf{u}_i^{(l)}$ 是投影向量,通过批量归一化投影传递映射函数值 $\hat{\mathbf{z}}^{(l+1)}$ 的信息

$$\mathbf{u}_i^{(l)} = \mathbf{N}_B(\mathbf{V}^{(l+1)} \hat{\mathbf{z}}^{(l+1)}) \quad (11)$$

式(11)中,投影矩阵 $\mathbf{V}^{(l+1)}$ 的维度与编码器中权重矩阵 $\mathbf{W}^{(l)}$ 相同,则投影向量 $\mathbf{u}^{(l)}$ 与网络潜在变量 $\mathbf{z}^{(l)}$ 的维度相同。非线性函数 $\mu_i(\mathbf{u}_i^{(l)})$ 与 $\nu_i(\mathbf{u}_i^{(l)})$ 的表达式为

$$\begin{aligned} \mu_i(\mathbf{u}_i^{(l)}) &= \mathbf{a}_{1,i}^{(l)} \text{sigmoid}(\mathbf{a}_{2,i}^{(l)} \mathbf{u}_i^{(l)} + \mathbf{a}_{3,i}^{(l)}) \\ &\quad + \mathbf{a}_{4,i}^{(l)} \mathbf{u}_i^{(l)} + \mathbf{a}_{5,i}^{(l)} \end{aligned} \quad (12)$$

$$\begin{aligned} \nu_i(\mathbf{u}_i^{(l)}) &= \mathbf{a}_{6,i}^{(l)} \text{sigmoid}(\mathbf{a}_{7,i}^{(l)} \mathbf{u}_i^{(l)} + \mathbf{a}_{8,i}^{(l)}) \\ &\quad + \mathbf{a}_{9,i}^{(l)} \mathbf{u}_i^{(l)} + \mathbf{a}_{10,i}^{(l)} \end{aligned} \quad (13)$$

其中的 $\mathbf{a}_{1,i}^{(l)} \cdots \mathbf{a}_{10,i}^{(l)}$ 表示的是各层各神经元的非线性训练参数。注意当 $l=0$ 时, $\hat{\mathbf{x}} = \mathbf{z}^{(0)}$, $\bar{\mathbf{x}} = \tilde{\mathbf{z}}^{(0)}$; 当 $l=L$ 时,令 $\mathbf{u}^{(L)} = \tilde{\mathbf{y}}$, 可使顶层的映射函数能利用有标签样本中的类别先验信息,只需要少量有标签样本即可快速收敛。

2.4 无监督式解码器

SRN 中的解码器将径向连接传来的降噪编码器各

层的压缩特征作为无监督学习起点,提取无标签样本中表现形式与有监督学习所得结果相同的信息,使输出的重构能够恢复污染样本的原有信息,令整体代价函数最小.

无监督解码器的代价函数应当是每个神经元输出的均方重构误差,但由于样本被批量归一化处理,引入了噪声干扰了降噪编码器与稀疏编码器中的梯度传输,噪声在 $\mathbf{z}^{(l)}$ 与 $\hat{\mathbf{z}}^{(l)}$ 间是高度相关的,造成的影响是使降噪函数倾向于简单地复制 $\mathbf{z}^{(l)}$,从而有 $\hat{\mathbf{z}}^{(l)} \approx \mathbf{z}^{(l)}$.

为解决输入样本批量归一化带来的问题,需要借助稀疏编码器中的投影向量 $\mathbf{z}_{pre}^{(l)}$,将其作为映射函数的目标值,并将代价函数缩放,令批量归一化的 $\mathbf{z}^{(l)}$ 替代出现传输误差的特征项:

$$\frac{1}{\sigma^2} \mathbf{z}_{pre} - \hat{\mathbf{z}}^2 = \frac{\mathbf{z}_{pre} - \mu}{\sigma} - \frac{\hat{\mathbf{z}} - \mu}{\sigma} = \mathbf{z} - \hat{\mathbf{z}}_{BN}^2 \quad (14)$$

其中稀疏路径编码结果表示为

$$\mathbf{z} = N_B(\mathbf{z}_{pre}) = \frac{\mathbf{z}_{pre} - \mu}{\sigma} \quad (15)$$

故批量归一化误差修正项表示为

$$\hat{\mathbf{z}}_{BN} = \frac{\hat{\mathbf{z}} - \mu}{\sigma} \quad (16)$$

在式(14)~(16)中的 μ 、 σ 分别是 \mathbf{z}_{pre} 的批量均值与批量标准差,用于将 \mathbf{z}_{pre} 批量归一化为 \mathbf{z} .

此时解码器无监督代价函数 C_D 表示为

$$\begin{aligned} C_D &= \sum_{l=0}^L \lambda_l C_D^{(l)} \\ &= \sum_{l=0}^L \frac{\lambda_l}{Nm_l} \sum_{n=1}^N \mathbf{z}^{(l)}(n) - \hat{\mathbf{z}}_{BN}(n)^2 \end{aligned} \quad (17)$$

其中 m_l 为层宽, N 为训练样本数,超参数 λ_l 是一个逐层相乘器,决定每层代价的权重.

根据式(8)和(17),整体代价函数为

$$C = C_C + C_D \quad (18)$$

有监督代价函数与无监督代价函数均可由梯度下降法^[21]实现最小化,此时顶层低维特征包含表征电台个体的信息,输入 softmax 分类器^[24]即可完成电台个体识别.

3 实验与分析

3.1 实验数据

为验证算法识别电台个体性能的鲁棒性,实验采用了三种型号的电台信号数据集,分别是 5 部 kirisun 手持式电台数据集(Kirisun Handhold Radio, KHR), 5 部背负式超短波可跳频电台数据集(Ultimate Short Wave Radio, USW)以及 5 部背负式短波调频电台数据集(Short Wave Radio, SW). 三种电台的工作参数如表 1 所示.


表 1 实验数据集所用电台工作参数

电台类型	信号样式	工作频率	采集增益
KHR	零中频 L/Q 双路正交信号	400.25MHz	6dB
USW		50MHz	6dB
SW		25MHz	48dB


电台在冬季晴天下午室外(约 0℃)无高大建筑遮挡物环境下进行语音通信,信号通过非协作方信号接收机采集,采集实况如图 3 所示. 信号带宽为 25kHz,接收机带宽为 100kHz,采样率为 312.5kHz,所得信号样本规模在表 2 中列出.

表 2 实验数据集的样本规模

电台类型	采样率	样本数据点个数
KHR	312.5kHz	7.11×10^8
USW		7.51×10^8
SW		7.26×10^8



(a) 数据采集情况



(b) 数据采集软件界面

图3 数据采集实况

为保证实验必需的小样本前提,将已得信号样本分别划分为有标签训练样本集、无标签训练样本集和测试样本集,其中训练样本集包含大部分的样本,供模型学习;无标签样本集中所有样本在抹除了标签信息后随机排列;分类器根据从训练集中学得的个体特征对测试集中各样本进行分类识别,区分电台个体. 每个数据集对应的样本集规模如表 3 所示.

表 3 各数据集小样本条件设置

电台类型	有标签训练样本数据点数	无标签训练样本数据点数	测试样本数据点数
KHR	7.11×10^7	3.555×10^8	7.11×10^7
	1.422×10^8		
	2.133×10^8		
USW	7.51×10^7	3.755×10^8	7.51×10^7
	1.502×10^8		
	2.253×10^8		
SW	7.26×10^7	3.63×10^8	7.26×10^7
	01.452×10^8		
	2.178×10^8		

3.2 实验准备工作

采集的原始电台信号样本首先需要经由矩形积分双谱(SIB)变换去除样本中携带的高斯噪声,以 KHR 数据集为例,其信号多种维度的 SIB 特征如图 4 所示.可以发现,SIB 特征的维度只影响信息在全部维度上的密集程度,不影响信息的准确表达.为加速识别过程,选取维度最低的 64 维 SIB 特征进行实验.

此外,SRN 中降噪编码器需要对输入样本先注入噪声造成污染,以迫使有监督学习能够利用最终的低维特征重构被遮盖的信息.在实验中选取了简单的全向高斯噪声,其分布满足均值为 0,方差为 0.01 的高斯分布.降噪编码器输入样本在加噪前后的效果如图 5 所示.

由于采用 MLP 网络学习电台信号样本中的个体信息,需要设计合适的深度模型结构.图 6 是几种相同深度的模型对未加噪的 KHR 电台信号 SIB 特征的学习重构误差(输入层单元数随输入 SIB 特征维度的不同会发生变化,因而此处只列出隐藏层结构).可以看出,模型结构为 1024-256-64 的 MLP 网络重构误差最小,学习能力最强,故本文实验中 MLP 网络均采用此结构.

为验证 SRN 方法在小样本条件下是否具有鲁棒性,实验采用基于高阶谱的对照方法在有标签样本充足前提下均能够有效在低信噪比环境中区分相同类型通信电台,而从无标签样本中提取电台个体信息用于分类识别的方法至今未有相关文献提出,因此在本文实验中将半监督的 SRN 方法与有监督的 3 种传统方法进行对照,在实验中采用的对照方法分别是 SIB/PCA 法(SIB/PCA)^[6,25]、局部围线积分双谱法(LSIB)^[26]、SIB 最大相关熵法(MCER)^[13].

实验首先将预处理过的训练集样本输入各算法的学习模型中,训练完成后,对测试样本集进行分类识别,重复 50 次识别后,取识别平均正确率作为评价所用性能指标.识别实验平台是一台 CPU 为 Intel E5-2620v4

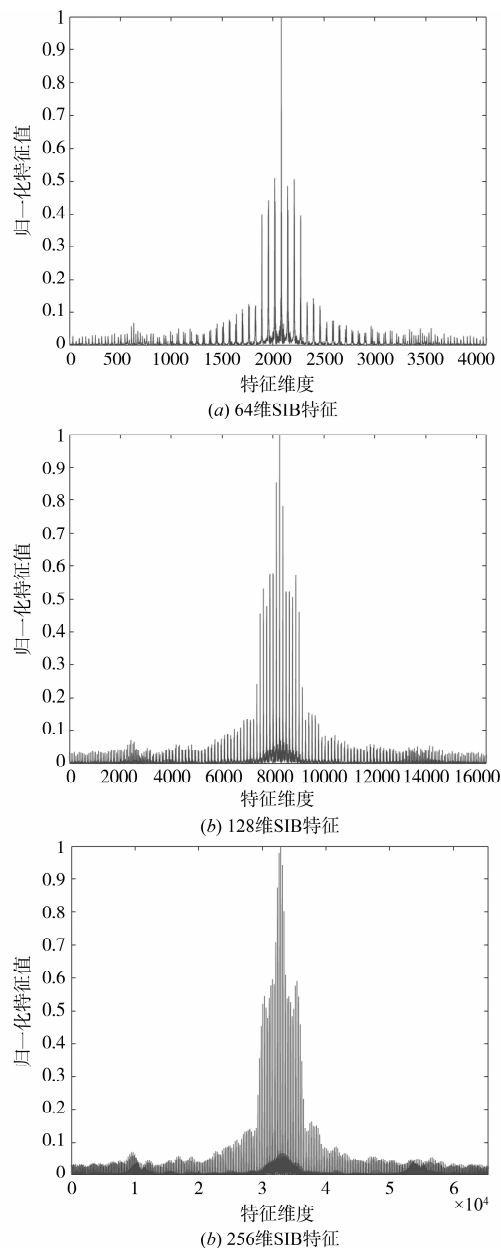


图 4 不同维度 SIB 特征的表现形式

2.6GHz 的主机.

3.3 结果与分析

KHR、USW、SW 数据集的实验结果如表 4 所示,观察其中数据及其变化情况可得以下四个结论.

(1) 小样本条件下,三种对照方法的识别性能不佳,识别率相比样本充足时^[6,13,26]出现大幅下降,而 SRN 方法则能够有效区分相同类型的不同电台个体,对 KHR 的识别性能最佳,最高达 95.62%.

(2) 随着有标签样本规模增加,对照方法的识别准确率提升 10%~20% 左右,高于 SRN 方法识别准确率的增幅,但是识别准确率仍然低于 SRN,说明 SRN 方法对有标签样本的依赖较小,准确率仍保持较高.




图5 KHR数据集加噪前后样本SIB特征




图6 相同深度的不同模型重构误差

(3) 在不同电台数据集上, 实验中采用的几种方法在 KHR 数据集上表现最佳, USW 数据集次之, 对 SW 数据集识别的性能最差, 说明电台信号的个体信息隐蔽度在三种数据集上依次增强, 明显影响识别性能。

(4) 尽管不同数据集中电台信号的个体信息隐蔽度不同, 但在最小样本的条件下, SRN 方法相比对照方法, 依然具有绝对占优的识别性能, 在三种数据集上分别比对照方法高出约 35%、30% 和 22%。

表 4 KHR、USW、SW 数据集上的分类识别结果

小样本条件 序号	KHR 数据集				USW 数据集				SW 数据集			
	SIB/PCA	LSIB	MCER	SRN	SIB/PCA	LSIB	MCER	SRN	SIB/PCA	LSIB	MCER	SRN
1	43.10	47.40	47.94	81.86	39.00	41.71	40.25	69.01	44.13	36.71	47.13	65.28
2	54.03	56.88	62.22	88.54	51.71	50.05	53.86	72.93	49.14	44.05	50.86	72.93
3	62.55	66.36	76.37	95.62	55.33	58.40	56.33	83.64	54.00	51.39	54.50	77.18

对照 SRN 方法的理论与验证实验的结果, 可以得到以下四个推论。

(1) 无论样本是否带有标签, 矩形积分双谱特征中确实存在表征电台个体的信息, 通过 SRN 方法能够提取包含该信息的特征。

(2) 降噪编码器具有很强的学习能力, 对有标签样本的依赖度低, 只需要提供少量有标签样本, 就能学习得到有效的标签类别信息。

(3) 径向连接准确地将有监督学习获得的类别信息映射到无监督解码器的各层, 使无监督学习更为准确有效, 实现了半监督学习。

(4) 无监督学习过程充分利用了电台信号无标签样本规模大的优势, 提取了丰富的电台个体类别信息, 大大提高了最终分类识别的准确性。

SRN 方法在小样本条件下电台个体识别效果上取得较为明显的提升, 其主要原因有如下三点分析。

(1) 与现有从有限有标签样本中提取通信电台个体信息的处理方法不同, 在小样本条件下 SRN 方法回避了有标签样本不足的问题, 从无标签样本中提取能够反映不同电台个体之间差异的信息构造特征, 从而获得了丰富的训练样本, 对于提高算法模型对电台个体描述的准确性有显著效果。

(2) 编码过程采用的降噪自编码器通过对训练样本注入人工噪声, 再对噪声遮蔽部分的样本信息进行重构, 在正确重构的基础上, 能够有效增强所提取电台个体特征的抗噪声干扰能力, 可以在小样本条件下从大量无标签样本中准确寻找有效信息, 从而促进了最终分类识别性能的提高。

(3) SRN 算法模型通过径向连接将有监督编码与无监督解码过程结合, 通过有标签样本中的标签信息对输入样本进行编码, 而无标签样本中的聚类特征可以为代价函数最小化过程提供更多的数据信息, 从而

对编码系数进行更全面的优化,使个体特征的刻画更加准确细致,获得更加鲁棒的分类识别信息,能够适应多种通信电台数据集.

以上结论证明了 SRN 方法具有较强的鲁棒性,但是离实用化依然有较大的差距,原因有如下三点.

(1)文中实验为求快速、简洁,预处理电台信号样本时只采用了最简单的 64 维 SIB 特征,没有全面研究 SRN 方法对各类高阶谱特征的学习性能.

(2)在加噪污染样本时采用了简单全向高斯噪声,且污染比例较小,有利降噪编码器快速重构原始信息,没有最大激发降噪编码器的学习性能,可能会降低最终特征的准确性.

(3)径向连接的使用前提是编、解码器的潜在变量模型满足条件高斯分布,未全面考虑多种数据集的情况.

4 结论

本文提出了基于半监督矩形网络的通信电台个体识别方法,并在三种实际同型号通信电台数据集上的实验验证了算法的鲁棒性.与其他三种基于矩形积分双谱特征的电台个体识别算法进行对照的结果显示,半监督矩形网络算法在小样本条件下识别电台个体能够达到优于对照方法的识别性能.

参考文献

- [1] 任春辉. 通信电台个体特征分析[D]. 成都:电子科技大学,2006.
REN Chun-hui. Individual Character Analysis of Communication Transmitter[D]. Chengdu: University of Electronic Science and Technology of China,2006. (in Chinese)
- [2] 许丹,柳征,姜文利,周一宇. 窄带信号中的放大器“指纹”特征提取:原理分析及 FM 广播实测实验[J]. 电子学报,2008,36(5):917-932.
XU Dan, LIU Zheng, JIANG Wen-li, ZHOU Yi-yu. Extraction of amplifier fingerprints from narrow band signal: principle analysis and FM broadcast experiment[J]. Acta Electronica Sinica,2008,36(5):917-932. (in Chinese)
- [3] 张旻,钟子发,王若冰. 通信电台个体识别技术研究[J]. 电子学报,2009,37(10):2125-2129.
ZHANG Min, ZHONG Zi-fa, WANG Ruo-bin. Research on the technique of individual communication transmitter identification[J]. Acta Electronica Sinica,2009,37(10):2125-2129. (in Chinese)
- [4] HALL J, BARBEAU M, KRANAKIS E. Radio frequency fingerprinting for intrusion detection in wireless networks [J]. IEEE Transactions on Dependable and Secure Computing,2005(12):1-35.
- [5] BERTONCINI C, RUDD K, NOUSAIN B, et al. Wavelet fingerprinting of radio-frequency identification(RFID) tags [J]. IEEE Transactions on Industrial Electronics,2012,59(12):4843-4850.
- [6] XU S H. Radio transmitter classification using a new method of stray features analysis combined with PCA[A]. Military Communication Conference [C]. Orlando, FL, USA: IEEE,2007. 1-5.
- [7] 唐智灵. 通信辐射源非线性个体识别方法研究[D]. 西安:西安电子科技大学,2013.
TANG Zhi-ling. A Study of Nonlinear Method for Specific Communications Emitter Identification [D]. Xian: Xidian University,2013. (in Chinese)
- [8] 梁江海. 一种基于经验模态分解的通信辐射源个体识别方法[J]. 中国电子科学研究院学报,2013,8(4):393-397.
LIANG Jiang-hai. A method based on empirical mode decomposition for identifying transmitter individuals [J]. Journal of CAEIT,2013,8(4):393-397. (in Chinese)
- [9] 韩洁,张涛,王欢欢,等. 基于 3D-Hibert 能量谱和多尺度分形特征的通信辐射源个体识别[J]. 通信学报,2017,38(4):99-109.
HAN Jie, ZHANG Tao, WANG Huan-huan, et al. Communication emitter individual identification based on 3D-Hibert energy spectrum and multi-scale fractal features [J]. Journal on Communications, 2017, 38(4): 99-109. (in Chinese)
- [10] 汪勇,段田东,刘瑞东,等. 短时频率稳定度特征分析的 FSK 信号个体识别方法[J]. 太赫兹科学与电子信息学报,2013,(6):880-885.
WANG yong, DUAN Tian-dong, LIU Rui-dong, et al. Individual identification of FSK signals based on stability of transient carrier frequency [J]. Journal of Terahertz Science and Electronic Information Technology, 2013, (6): 880-885. (in Chinese)
- [11] 顾晨辉,王伦文. 基于瞬时包络特征的跳频电台个体识别方法[J]. 信号处理,2012,28(9):1335-1340.
GU Chen-hui, WANG Lun-wen. Individual frequency hopping radio identification method based on instantaneous envelope characteristics [J]. Signal Processing, 2012, 28(9):1335-1340. (in Chinese)
- [12] 陈志伟,徐志军,王金明. 一种基于循环谱切片的通信辐射源识别方法[J]. 数据采集与处理,2013,28(3):284-288.
CHEN Zhi-wei, XU Zhi-jun, WANG Jin-ming, et al. Emitter identification method based on cyclic spectrum density slice [J]. Journal of Data Acquisition and Processing, 2013,28(3):284-288. (in Chinese)
- [13] 唐哲,雷迎科. 基于最大相关熵的通信辐射源个体识别

- 方法[J]. 通信学报, 2016, 37(12): 171 - 175.
- TANG Zhe, LEI Ying-ke. Method of individual communication transmitter identification based on maximum corentropy[J]. Journal on Communications, 2016, 37(12): 171 - 175. (in Chinese)
- [14] 孙志军, 薛磊, 徐阳明. 基于深度学习的边际 Fisher 分析特征提取算法[J]. 电子与信息学报, 2013, 35(4): 805 - 811.
- SUN Zhi-jun, XUE Lei, XU Yang-ming. Marginal fisher feature extraction algorithm based on deep learning[J]. Journal of Electronics and Information Technology, 2013, 35(4): 805 - 811. (in Chinese)
- [15] WU Z, TAKAKI S, YAMAGASHI J. Deep Denoising Auto-Encoder for Statistical Speech Synthesis[OL]. <https://arxiv.org/abs/1511.06430>, 2015.
- [16] 赵飞翔, 刘永祥, 霍凯. 基于栈式降噪稀疏自动编码器的雷达目标识别方法[J]. 雷达学报, 2017, 6(2): 149 - 156.
- ZHAO Fei-xiang, LIU Yong-xiang, HUO Kai. Radar target recognition based on stacked denoising sparse autoencoder[J]. Journal of Radars, 2017, 6(2): 149 - 156. (in Chinese)
- [17] VALPOLA H. Chapter 8-From Neural PCA to Deep Un-supervised Learning[A]. Advances in Independent Component Analysis and Learning Machines [M]. USA: Elsevier Ltd, 2015.
- [18] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11(12): 3371 - 3408.
- [19] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift[OL]. <https://arxiv.org/abs/1502.03167>, 2015.
- [20] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising auto-encoders[A]. International Conference on Machine Learning [C]. Helsinki, Finland: ACM, 2008. 1096 - 1103.
- [21] HAGER W, ZHANG H. The limited memory conjugate gradient method[J]. Siam Journal on Optimization, 2013, 23(4): 2150 - 2168.
- [22] PEZESHKI M, FAN L, BRAKEL P, et al. Deconstructing the Ladder Network Architecture [OL]. <https://arxiv.org/abs/1511.06430>, 2015.
- [23] ZHANG X, CHEUNG W K, LI C H. Learning latent variable models from distributed and abstracted data[J]. Information Sciences, 2011, 181(4): 2964 - 2988.
- [24] SCHMIDHUBER J. Deep learning in neural networks: An overview[J]. Neural Networks the Official Journal of the International Neural Network Society, 2014, 61: 85 - 117.
- [25] 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 Zhong-wei, LI Jian-dong. Study of transmitter individual identification based on bispectra [J]. Journal on Communications, 2007, 28(2): 75 - 79. (in Chinese)
- [26] 陶旺林, 卢选民, 刘李娟. 基于局部围线双谱的通信辐射源个体识别[J]. 计算机工程与应用, 2013, 49(1): 131 - 133.
- TAO Wang-lin, LU Xuan-min, LIU Li-juan. Transmitter individual identification based on local surrounding-line integral bispectrum[J]. Computer Engineering and Applications, 2013, 49(1): 131 - 133. (in Chinese)

作者简介



黄健航 男, 1994年2月出生于广东深圳. 国防科技大学电子对抗学院硕士研究生, 研究方向为通信信号处理.



雷迎科 男, 1975年2月出生于安徽安庆. 国防科技大学电子对抗学院指挥与控制系副教授, 研究方向为通信信号处理、模式识别.