

通信特定辐射源识别的多特征融合分类方法

何遵文, 侯帅, 张万成, 张焱

(北京理工大学信息与电子学院, 北京 100081)

摘 要: 针对通信辐射源个体识别问题, 提出了一种基于多通道变换投影、集成深度学习和生成对抗网络的融合分类方法。首先, 通过对原始信号进行多种变换得到三维特征图像, 据此构建信号的时频域投影以构建特征数据集, 并使用生成对抗网络对数据集进行扩充。然后, 设计了一种基于多特征融合的双阶段识别分类方法, 利用神经网络初级分类器分别对 3 类特征数据集进行学习, 得到初始分类结果。最后, 通过叠加融合学习初始分类结果, 得到最终的分类结果。实测数据分析结果证明, 所提方法相比基于单一特征提取方法和经典多特征提取方法有更高的准确率, 使用室外典型场景多径衰落信道模型对辐射源信号进行了处理, 所提模型仍可进行有效识别, 能够适用于复杂无线信道环境的应用。

关键词: 特定辐射源识别; 生成对抗网络; 多特征融合; 集成学习

中图分类号: TN911.7

文献标识码: A

DOI: 10.11959/j.issn.1000-436x.2021028

Multi-feature fusion classification method for communication specific emitter identification

HE Zunwen, HOU Shuai, ZHANG Wancheng, ZHANG Yan

School of Information and Electronics, Beijing Institute of Technology, Beijing 100081, China

Abstract: A multi-feature fusion classification method based on multi-channel transform projection, integrated deep learning and generative adversarial network (GAN) was proposed for communication specific emitter identification. First, three-dimensional feature images were obtained by performing various transformations, the time and frequency domain projection of the signal was constructed to construct the feature datasets. GAN was used to expand the datasets. Then, a two-stage recognition and classification method based on multi-feature fusion was designed. Deep neural networks were used to learn the three feature datasets, and the initial classification results were obtained. Finally, through fusion and re-learning of the initial classification result, the final classification result was obtained. Based on the measurement and analysis of the actual signals, the experimental results show that the method has higher accuracy than the single feature extraction method. The multipath fading channel has been used to simulate the outdoor propagation environment, and the method has certain generalization performance to adapt to the complex wireless channel environments.

Keywords: specific emitter identification, generative adversarial network, multi-feature fusion, ensemble learning

1 引言

特定辐射源识别 (SEI, specific emitter identification) 是将接收到的脉冲波形与唯一发射器进行

关联^[1]。5G 使数据传输速率和可靠性得到了跳跃式的提升, 促进了物联网应用的普及和发展。6G 将进一步向万物互联的时代迈进, 接入物联网的无线设备呈爆炸式增长, 设备的安全性值得关注。物联

收稿日期: 2020-07-23; 修回日期: 2020-11-04

通信作者: 张万成, zhangwancheng@bit.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61871035)

Foundation Item: The National Natural Science Foundation of China (No.61871035)

网中未知的辐射源设备需要能被准确地识别身份,而电磁环境日益复杂,辐射源数目庞大,信号密度极高,这为 SEI 技术带来了更多的挑战^[2]。

用于个体识别的辐射源信号通常分为瞬态信号和稳态信号^[3]。瞬态信号是发射体开关打开时或状态改变时的信号,但是瞬态信号持续时间较短,在实际通信环境特别是非合作通信情况下截获难度较大。相比之下,稳态信号更容易获取,具备较强的操作性,基于稳态信号的 SEI 技术在实际应用中具有更强的适用性^[4]。

近年来,深度学习在 SEI 领域有了广泛的发展和应用^[5],深度神经网络能够通过具有非线性激活函数的多个隐含层来检索抽象特征,有利于提取辐射源信号的深层次的细微特征^[6]。因此,一些文献使用基于深度神经网络的端到端的 SEI 方法,如文献[7-8]将原始 I/Q 信号直接送入神经网络,完成端到端的 SEI 任务,整体性强。但是这种方法过于依赖神经网络的设计,并且对不同的原始数据类型都要设计不同的神经网络,可扩展性不强。另外,常用的卷积神经网络(CNN, convolutional neural network)更擅长识别二维图像数据,直接处理 I/Q 数据效果会有一些的折扣。

因此,更有效和可靠的方案仍是将智能学习与信号处理技术相结合,将 SEI 任务分为两步,一是数据的预处理和特征提取,二是分类器设计和训练。通过数据预处理和变换以提取稳态信号的细微特征,细微特征由器件内部的物理特性和器件之间的相互作用产生,整个过程被称为信号的非有意调制。信号细微特征也被称为射频指纹,通常表现为不可避免的非平稳、非高斯、非线性^[9]。现有的研究主要分为利用信号的时域特征和变换域特征的方法。例如针对信号的时域特征,文献[10]将瞬时振幅和频率直接定义为指纹特征,文献[11]利用经验模态分解(EMD, empirical mode decomposition)相关维数和小波熵提取信号的细微特征,文献[12]基于盒维数和方差维数的分形特征进行识别,文献[13]基于实际信号的固有非线性动力学特性将排列熵提取为信号的射频指纹。但是,这些利用时域波形的非线性特征的方法容易受到噪声的影响,识别准确率波动很大,并且计算量较大,具有一定的局限性。现在更主流的是基于变换域特征的方法,时频分析能够提供信号的时频联合域信息,反映不同信号之间更加细微的差别^[14]。文献[15]提取动态小波

指纹特征以识别各个射频发射器。文献[16-17]使用短时傅里叶变换时频图表示特征,然而,这种方法本质上是线性的,对于非线性信号的分析效果并不好。希尔伯特-黄变换(HHT, Hilbert-Huang transform)是一种著名的处理非线性非平稳信号的方法^[18],因此,HHT 被广泛用于 SEI 中。文献[19]将希尔伯特光谱转换为灰度图像表示特征;文献[20]使用 HHT,并研究了它们在单跳和中继场景下的各种渠道方案。除此之外,基于高阶谱方法也是研究的热点,高阶谱可以保持信号的幅值和相位信息,抑制噪声对非高斯信号的负面影响。文献[21-22]充分利用了双谱的特点进行 SEI 任务。

对于 SEI 任务的第二步,即分类器的设计和训练,可以使用传统机器学习方法和深度学习方法。文献[14]使用支持向量机(SVM, support vector machine)作为分类器,文献[13,23-24]在每次实验的分类过程中,采用 K 近邻判别分类器。深度神经网络对二维图像有很好的识别效果,因此一些文献使用网络学习能够体现信号特征的二维图像来完成 SEI 任务,如文献[19]构造了一个深层的残差网络,用于学习希尔伯特光谱图像中反映的视觉差异以辨别设备;文献[24]利用 CNN,将 I/Q 信号转换成轮廓 Stella 图像进行分类。

上述方法中,一方面,无论是使用基于时域特征还是变换域特征和高阶谱的方法,其大多是使用单一信号处理方法提取其中的一种细微特征,而实际通信信号复杂多变,单一的信号特征并不足以全面准确地表示辐射源信号之间的细微差别,最终识别准确率受到限制,具有很大的局限性。另一方面,为了增强识别准确率,多数模型使用深度神经网络作为强分类器;数据驱动的深度学习方法需要大量的数据,实际通信中受限于时间和人力成本,很难获得充足的辐射源信号数据用于深度学习的训练,如果数据量过少,较深层和复杂的神经网络很容易发生过拟合,进而严重影响最终的识别效果。

基于以上讨论,本文提出了一种新型的多特征融合分类方法用于通信辐射源识别。针对信号单一特征的局限性,设计了基于多通道变换投影的特征提取方法,对原始数据集进行小波、双谱、HHT 等多种不同的信号变换,以实现原始信号不同维度细微特征的提取,丰富信号特征数据集的多样性。将信号变换后的特征矩阵表示为三维张量,为了充分利用深度神经网络对二维图像特征提取的优势,选

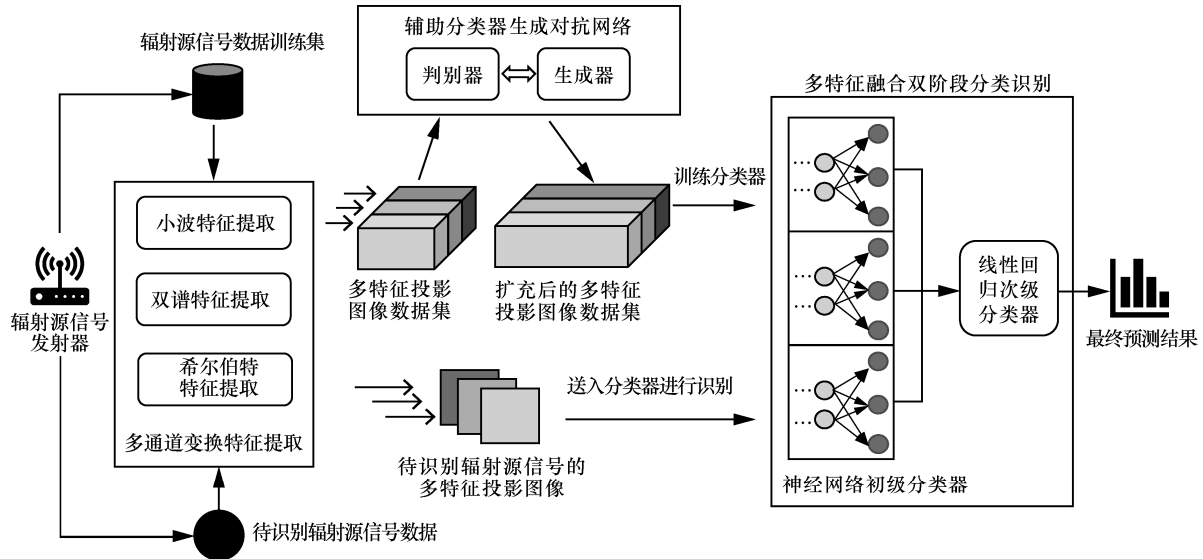


图 1 SEI 系统整体流程

取合适的视角得到二维投影。本文研究了基于多特征融合的双阶段识别分类方法，先利用不同的神经网络对不同的图像特征集分别进行学习和初始分类得到概率表示的特征向量，之后对初始分类的特征向量进行融合学习，得到最终的分类结果。

此外，针对深度学习数据量不足的问题，本文利用改进的辅助分类器（AC, auxiliary classifier）生成对抗网络（GAN, generative adversarial network），对不同的图像特征集进行学习并扩充增强数据集以满足训练需求。基于实测数据集对所提方法进行验证，结果表明该方法相比其他方法具有更高的识别准确率，在低信噪比下仍有较好的表现。

2 基于多通道变换的特征提取与数据增强

SEI 问题本质上是一个信号分类问题，将接收机采集的无线通信信号输入系统，最终得到这个信号的分类结果。所提出的 SEI 多特征融合分类方法主要包括 4 个部分：多特征提取、数据扩充和增强、初级分类、集成融合，整体流程如图 1 所示。

首先，对信号进行多特征提取得到多种不同的特征图像，并在模型的训练阶段使用 GAN 对图像特征集进行扩充，进而训练分类器。在识别阶段，直接将特征图像送入分类器，分类器设计包括初级分类器和次级分类器两级结构，采用集成融合学习算法将多种初级分类器的识别结果进行再学习，通过次级分类器得到最终识别结果。

考虑系统内共有 K 个辐射源信号发射器，接收

机接收来自 K 个发射机发出的理论上相同的信号。接收机接收到的通信辐射源信号可以表示为

$$s^k(t) = s_I^k(t) + js_Q^k(t) + n(t), k = 0, \dots, K - 1 \quad (1)$$

其中， $s_I^k(t)$ 表示 I 路信号， $s_Q^k(t)$ 表示 Q 路信号， $n(t)$ 表示信号在传输信道中叠加的高斯白噪声， k 表示辐射源的类别编号。式(1)采集到的是 IQ 正交信号，所以 $s^k(t)$ 用复信号形式表示。

算法 1 K 个辐射源信号的特征提取与数据增强特征提取

输入 对于每个类别的辐射源，输入时域信号 $s^k(t)$ 的切片样本，每 1 000 个点作为一个信号样本，每个类别的辐射源信号共 n 个样本，共有 K 个辐射源

输出 对于每个类别的辐射源，输出 3 个二维特征图像数据集，每个数据集有 n 张图像，共有 K 个辐射源

- 1) 一共 n 个样本
- 2) 对每个输入样本进行离散小波变换得到小波系数特征矩阵，并表示为三维图像形式
- 3) 取投影视角(90,0,0)得到二维小波特征图像
- 4) 进行双谱变换得到双谱系数特征矩阵，并表示为三维图像形式
- 5) 取投影视角(-45,0,0)得到二维双谱特征图像
- 6) 进行希尔伯特-黄变换得到 HHT 系数特征矩阵，并表示为三维图像形式
- 7) 取投影视角(90,0,0)得到二维 HHT 特征图像
- 8) 重复步骤 1)~步骤 7) K 次，每个类别的辐射

源信号都得到 3 个二维特征图像数据集，每个数据集有 n 张图像

数据增强

输入 每次输入一个特征投影图像数据集，包含 Kn 张图像，共 3 个特征投影图像数据集（小波、双谱、HHT）

输出 每次输出一个增强的数据集，最终输出 3 个特征图像数据集，每个数据集包含 $K(m+n)$ 张图像

- 1) 对每个输入的特征投影图像数据集
- 2) 将图像输入 AC-GAN 训练至收敛
- 3) 得到 m 张模拟特征图像作为补充数据集
- 4) 扩充数据集与原始数据集共同构成增强数据集
- 5) 得到 3 个增强图像数据集（小波、双谱、HHT），每个数据集包含 $K(m+n)$ 张图像

2.1 基于多通道变换投影的特征提取

单一的信号特征很难准确表示辐射源信号之间的差别，而过多的特征融合可能会影响模型性能。因此选取小波变换、双谱变换、HHT 这 3 种有代表性并被证明有效的信号处理方法提取 3 种不同的信号变换域特征，小波变换是时间（空间）频率的局部化分析，更能关注信号的区域性信息^[25]；双谱变换可以更多地关注信号的相位信息，同时可以用来描述信号的不对称程度和非线性程度^[21]；HHT 理论上最适合处理非线性非平稳信号，且更能关注一些突变信号的细微特征，提供有关信号的非线性和非平稳特性的大量信息^[18]。以上 3 种特征可以从不同维度利用各自的优势，丰富信号特征数据集的多样性。二维图像更有利于深度学习和分类，因此，本文设计一种变换投影的方法对信号变换后的三维特征图像选取合适的视角进行投影，进而将其表示为二维特征图像。

2.1.1 基于小波的特征提取

小波变换（WT, wavelet transform）通过对时间（空间）频率进行局部化分析^[25]，能够凸显信号区域性的细微特征，在个体识别领域有着独特的优势。Morlet 小波为复值小波，在时域和频域都有很好的聚集性，本文采集的实测数据均为复信号，因此选取 Morlet 小波作为基小波函数用于时频分析。

利用尺度参数 $scale$ 来衡量小波的频率 f ，两者之间的转换关系为

$$scalef = F_s F_c \tag{2}$$

其中， F_s 为信号的采样频率， F_c 为小波的中心频率。

为使小波尺度图的频率范围为 $(0, F_s/2)$ ，尺度范围应为 $(2F_c, +\infty)$ 。实际中，尺度应为等差数列形式，即 $scale=2F_c, \dots, 2F_c \cdot totalscale$ ，其中 $totalscale$ 是预先设定好对信号进行小波变换时所用尺度序列的长度。完成参数设定后，小波变换的过程可以表示为

$$WT(s^k(t)) = \frac{1}{\sqrt{|scale|}} \int_{-\infty}^{\infty} s^k(t) \varphi\left(\frac{t-\tau}{scale}\right) d\tau \tag{3}$$

其中， $s^k(t)$ 为原始时间信号； $\varphi\left(\frac{t-\tau}{scale}\right)$ 为小波基函数，具有平移和伸缩特性； $scale$ 为尺度参数，控制小波函数的伸缩； τ 为平移参数，控制小波函数的平移。尺度对应于频率，平移量 τ 对应于时间。用 M_{cwt}^k 表示得到的频率-时间-小波系数矩阵，三维图像如图 2(a) 所示。

2.1.2 基于双谱的特征提取

双谱的物理定义可以近似为信号偏态在频域上的分解，用来描述信号的不对称性和非线性程度，测量信号偏离高斯分布的程度。在实际通信过程中，辐射源个体的一些细微特征更多以非平稳、非线性、非高斯的形式附加在信号中，例如由于发射系统中使用的电路和设备的不同而产生的不同的发射端噪声，可以作为区分辐射源信号的指纹特征。接收系统中大量散射体和热噪声形成的杂波呈高斯分布，通过双谱变换，可以有效地抑制一定数量的高斯噪声，使发射机噪声充分反映在双谱信息中。双谱定义为

$$B(\omega_1, \omega_2) = \sum_{\tau_1=-\infty}^{\infty} \sum_{\tau_2=-\infty}^{\infty} c_{3x}(\tau_1, \tau_2) \exp[-j2\pi(\omega_1\tau_1 + \omega_2\tau_2)] \tag{4}$$

其中， $c_{3x}(\tau_1, \tau_2) = E\{x^*(t)x(t+\tau_1)(t+\tau_2)(t+\tau_3)\}$ 表示信号的三阶累积量。将输入信号 $s^k(t)$ 进行双谱变换得到双谱系数矩阵 M_{bis}^k ，其三维图像如图 2(c) 所示。

2.1.3 基于 HHT 的特征提取

HHT 相比傅里叶变换和小波变换这类传统方法，彻底摆脱了线性和平稳性束缚，更适用于分析非线性非平稳信号^[20]。为了使瞬时频率具有明显的物理意义，HHT 首先需要进行经验模态分解，也通常被称为一个筛选过程，依据信号特点自适应地把任意一个复杂信号分解为一系列本征模态函数（IMF, intrinsic mode function）^[18]。这个过程可以表示为

$$s^k(t) = \sum_{i=1}^n c_i(t) + r_n(t) \tag{5}$$

原始输入信号 $s^k(t)$ 被表示成一系列 IMF 分量

$c_i(t)$ 和一个余项 $r_n(t)$ 的组合。之后对每个 IMF 分量进行希尔伯特变换来提供时频分布

$$\tilde{c}_i(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{c_i(\tau)}{t - \tau} d\tau \quad (6)$$

构造解析函数

$$Z_i(t) = c_i(t) + j\tilde{c}_i(t) = a_i(t)e^{j\varphi_i(t)} \quad (7)$$

其中, $a_i(t)$ 、 $\varphi_i(t)$ 和 $\omega_i(t)$ 分别表示瞬时振幅、相位和频率, 计算式分别为

$$a_i(t) = \sqrt{c_i(t)^2 + \tilde{c}_i(t)^2}$$

$$\varphi_i(t) = \arctan\left(\frac{\tilde{c}_i(t)}{c_i(t)}\right)$$

$$\omega_i(t) = \frac{d\varphi_i(t)}{dt}$$

进而希尔伯特谱可以表示为

$$H(\omega, t) = \text{Re}\left(\sum_{i=1}^n a_i(t)e^{j\int \omega_i(t) dt}\right) \quad (8)$$

用 M_{hht}^k 表示 HHT 生成的信号特征系数矩阵, 即信号的希尔伯特时频谱, 三维图像如图 2(e)所示。

2.1.4 信号特征表示

原始信号经过 3 种变换得到了三维特征矩阵, 为了更好地表示特征并利于后续进行深度学习, 将三维特征矩阵取投影生成二维特征图像。同一类别的不同辐射源信号样本是基于同一信号的不同时

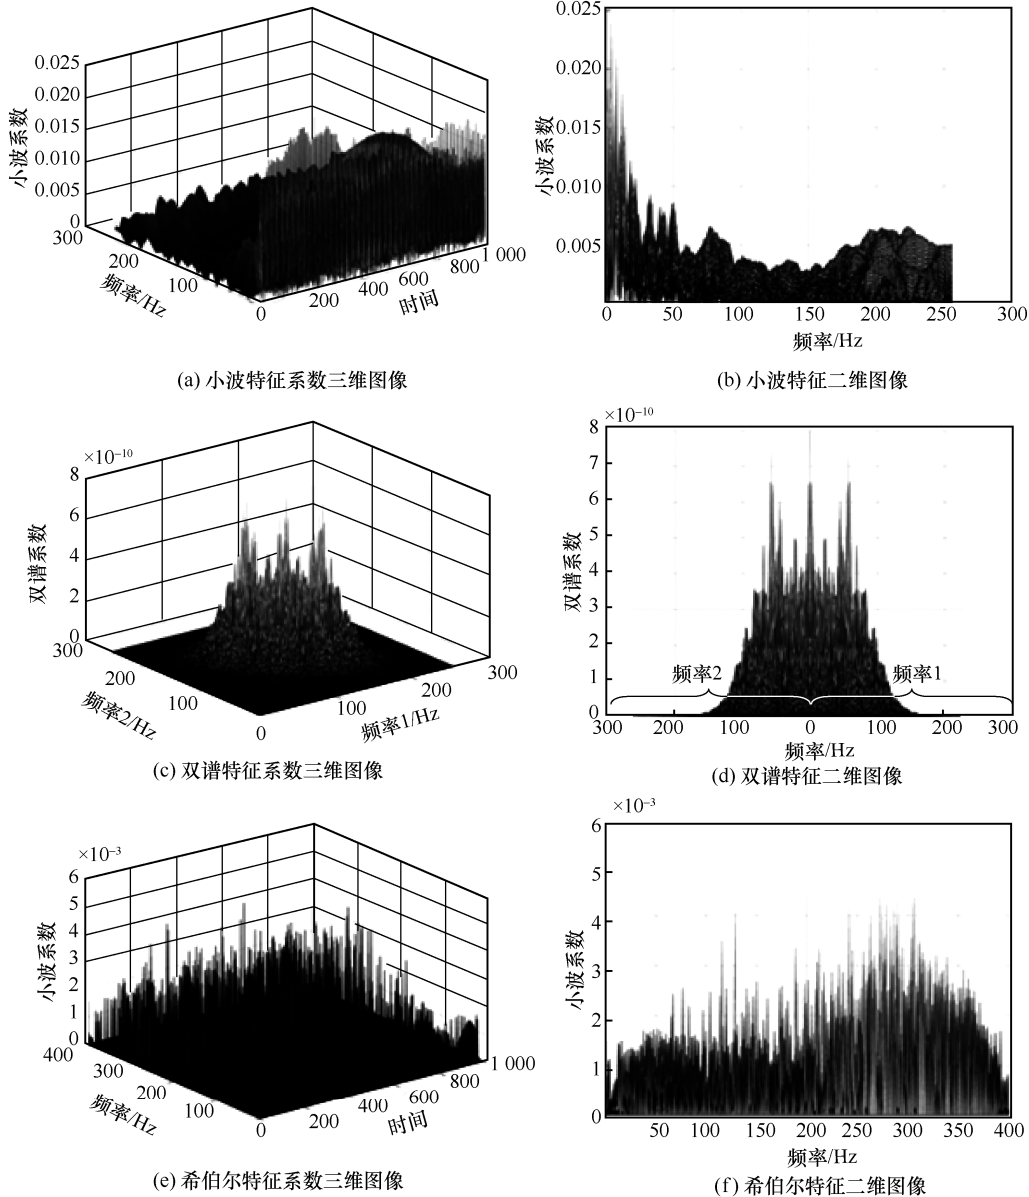


图 2 信号变换生成的特征图像

间切片生成的，而不同时间切片的信号差异可能会影响同类信号样本的相似度。因此对于小波和希尔伯特时频特征矩阵，取投影视角(90, 0,0)表示投影角度为 90°将三维图像投影在 YZ 平面上，淡化时间维度的影响，更加突出频率和系数的关系，这样更能保证同类信号样本之间的相似度。对于双谱三维特征矩阵，双谱在 2 个频率主轴形成的平面上其第一、三象限包含的内容较多，根据双谱的对称性，投影视角(-45,0,0)包含三维双谱图像的轮廓、纹理特征最多，且完全对称，是对 2 个频率主轴形成的平面上第一、三象限内容的完全体现，因此选用投影视角(-45,0,0)表征的双谱特征最完备^[27]。

最终得到 3 种特征的二维投影图像 I_i^k ，分别如图 2(b)、图 2(d)和图 2(f)所示。

2.2 基于 AC-GAN 的数据增强扩充

后续用于识别的初级分类器使用深度残差网络，网络层数和参数较多，因此在模型的训练阶段需要大量的数据提供给网络学习，受限与信号接收采集的时间长度等因素，原始数据量难以满足训练需求。

因此，所提方法使用 AC-GAN 来进行数据增强，通过这种方式能够实现基于有限样本的数据扩充，生成和实测数据具有相似分布与特征的大量训练数据，从而为后续分类识别提供支撑。增强后的数据集可表示为 D_i' 。传统 GAN 只能生成单一类别的图像，AC-GAN 将类别标签作为条件信息和噪声一起放入生成器后生成样本，判别器在判断输入样本是否为真的同时，利用辅助分类器来判断输入样本的所属类别，因此 AC-GAN 可以生成不同类别的图像。使用 3 个 AC-GAN 对 3 种投影图像数据集进行扩充。AC-GAN 的结构和工作流程如图 3 所示。

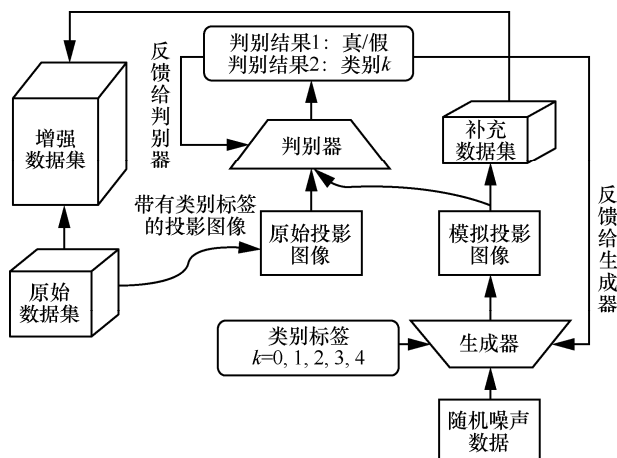


图 3 AC-GAN 的结构和工作流程

生成器有 2 个输入，一个是投影图像所属的辐射源类别标签 $k, k=0, \dots, K-1$ ；另一个是随机噪声数据，用于生成模拟的投影图像 I_{fake} 。网络可以自动学习 3 种不同投影图像的内在特征，进而生成对应的模拟投影图像。判别器分别给出图像（真假）的概率分布 $P(S|I)$ 以及分类标签的概率分布 $P(K|I)$ 。

AC-GAN 的目标函数包含 2 个部分。第一部分是面向输入的投影图像真实与否的代价函数 L_S

$$L_S = E[\log P(S = \text{real} | I_{\text{real}})] + E[\log P(S = \text{fake} | I_{\text{fake}})] \quad (9)$$

第二部分是针对输入的投影图像分类准确性的代价函数 L_K

$$L_K = E[\log P(K = k | I_{\text{real}})] + E[\log P(K = k | I_{\text{fake}})] \quad (10)$$

在优化过程中，希望判别器能够尽可能地区分原始真实的投影图像和模拟的投影图像，并且能有效分类，即令 L_S+L_K 尽可能地最大。另外希望生成器生成的模拟投影图像被尽可能认为是真实的，即令 L_K-L_S 尽可能地最大。迭代数次后，判别器对生成器生成的模拟投影图像识别准确率趋于稳定，模拟的投影图像已经可以满足数据要求，此时生成器生成的模拟投影图像构成补充数据集，与原始数据集一起构成扩充后的增强数据集。

3 多特征融合双阶段分类识别

通过多特征提取与增强步骤，基于小波变换、双谱变换和 HHT 分别获取了原始辐射源信号的某个方面的特征，并将信号特征转换为了二维图像 I_i^k 。基于 AC-GAN 进一步实现了数据集的增强。基于增强后的特征数据集，在分类识别阶段采用双阶段分类识别方法，融合多种特征识别结果以提升 SEI 的准确率。

算法 2 模型训练和分类识别

模型训练

输入 每次输入一个增强图像数据集，一共 3 个增强图像数据集

输出 每次输出对每张图像的预测结果，用于训练反馈

1) 将小波特征数据集输入残差网络 1 进行训练，输出初始分类结果 P_{cwt} ，并保存模型参数

2) 将双谱特征数据集输入残差网络 2 进行训练，输出初始分类结果 P_{bis} ，并保存模型参数

3) 将 HHT 特征数据集输入残差网络 3 进行训练, 输出初始分类结果 P_{hht} , 并保存模型参数

4) 将 P_{cwt} 、 P_{bis} 和 P_{hht} 输入次级分类器进行训练, 保存模型参数

分类识别

输入 每次输入待识别信号的一张特征图像 I_i^k , 一共 3 张特征图像

输出 每次输出对待识别信号的最终分类预测结果 P_{final}

1) 将待识别信号的小波特征图像输入残差网络 1 输出初始预测结果 P_{cwt}

2) 将待识别信号的双谱特征图像输入残差网络 2 输出初始预测结果 P_{bis}

3) 将待识别信号的 HHT 特征图像输入残差网络 3 输出初始预测结果 P_{hht}

4) 将 P_{cwt} 、 P_{bis} 和 P_{hht} 输入次级分类器进行最终识别, 输出最终分类预测结果 P_{final}

3.1 基于残差网络的初级分类

把原始信号特征转化为二维图像表征, 分类器实现方面选用了当前在图像分类领域较成熟的深度学习模型 ResNet18, 残差网络 ResNet 因其高效和易优化而被广泛利用在深度学习的研究中^[28], 网络的参数经过公开数据集 ImageNet 预训练, 这样不仅可以进一步避免过拟合等问题, 还充分利用了网络中已有的参数, 使网络具有更好的适应性。更改网络的全连接层, 将输出类别更改为 K 个, 输入增强数据集 D'_i 训练网络全连接层的权重, 完成训练保存完整模型。在用网络进行 SEI 识别时, 将图像 I_i^k 输入网络, 网络的输出是 Softmax 层输出的各个类别概率, 可以表示为 $P_i=[p_0, p_1, \dots, p_k]$ 。3 个网络输出的预测分别为 P_{cwt} 、 P_{bis} 和 P_{hht} 。

3.2 基于集成融合的次级分类

次级分类器需要完成最终的分类, 使用集成学习中的 Stacking 方法, 将 3 个神经网络分类器的初级分类结果进行融合, 即使某一个初级分类器预测错误, 也能通过另外 2 个分类器将错误纠正回来, 最大化整体模型的分能力。为了降低模型整体过拟合的风险, 次级学习器选择结构相对简单的线性回归模型 (LRM, linear regression model), 降低模型的整体复杂度, 减少计算开支。

3 个初级分类器基于完整的训练集进行训练, 为了防止过拟合, 每一个初级分类器需要通过 5 折交叉检验的方式进行训练。将训练集样本随机分为

5 份, 每折训练取其中 4 份对一个初级分类器进行训练, 取剩下的一份数据进行预测分类, 保留分类结果。同时也对测试集所有样本进行分类, 直到 5 份训练集样本都被分类, 得到该残差网络对所有训练集样本的分类结果, 此时测试集样本被分类了 5 次, 最终对分类结果取平均值。训练集和测试集的使用流程如图 4 所示。

训练集和测试集中每个样本的分类结果都表示为 $P_i=[p_0, p_1, \dots, p_k]$ 。将 3 个初级分类器对原训练集的分类结果整合在一起, 用作次级分类器的训练样本, 而测试集的分类结果用作新的测试样本对次级分类器进行测试。对同一个样本, 3 个初级分类器有 3 个分类结果, 次级分类器分配这 3 个结果的权重以进行取舍, 得到最终分类结果为 P_{final} 。

4 实验测试和结果分析

4.1 实验环境配置和数据准备

为了验证所提 SEI 框架和方法的可行性, 并使应用场景更符合实际, 本文选用了 5 个型号为 Tenda U6 的 USB 无线网卡作为辐射源发射器。将无线网卡安装在电脑主机作为信号发射端, 工作频率为 2.462 GHz, 带宽为 40 MHz, 最大发射功率为 20 dBmW, 均使用 IEEE 802.11b 协议。接收机使用 NI-PXI8106 机柜和 NI 矢量信号分析仪连接天线, 固定于接收端 15 cm 处采集无线网卡信号, 采集的信号为 I/Q 双路复信号, 信号采样率为 100 MSPS (million sample per second)。为了对比模型在不同信噪比 (SNR, signal-to-noise ratio) 下的性能, 对原始信号加入高斯白噪声模拟噪声环境, 得到 5~25 dB 每隔 5 dB 的不同 SNR 条件下的无线网卡信号采样数据。

将每 1 000 个点的信号采样数据作为一个辐射源信号样本, 最终识别准确率定义为用于测试的正确分类的样本数量在整体测试样本数量中的占比。

实验在 MATLAB 环境进行信号处理工作, 深度学习环境为 Python3.6+Pytorch1.0。

4.2 实验结果分析

4.2.1 多层融合分类方法的整体表现

首先对整个多层融合框架的性能表现进行测试。选取一种单一特征提取方法^[19]、2 种多特征提取方法^[4,23]与本文方法进行对比。文献[19]作为对比方法 1 仅采用 HHT 方法进行识别。与本文方法类似, 文献[4]同样使用多特征提取思想, 提取信号的能量分布信息、分形特征和双谱特征等多

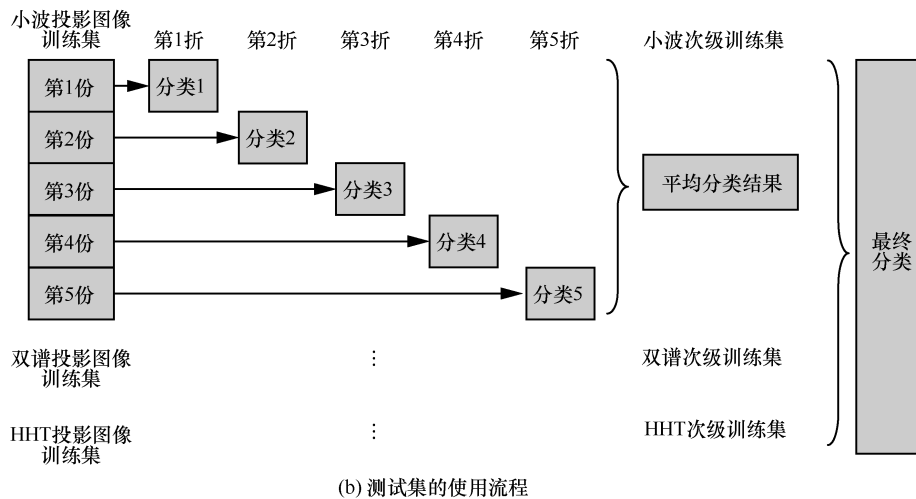
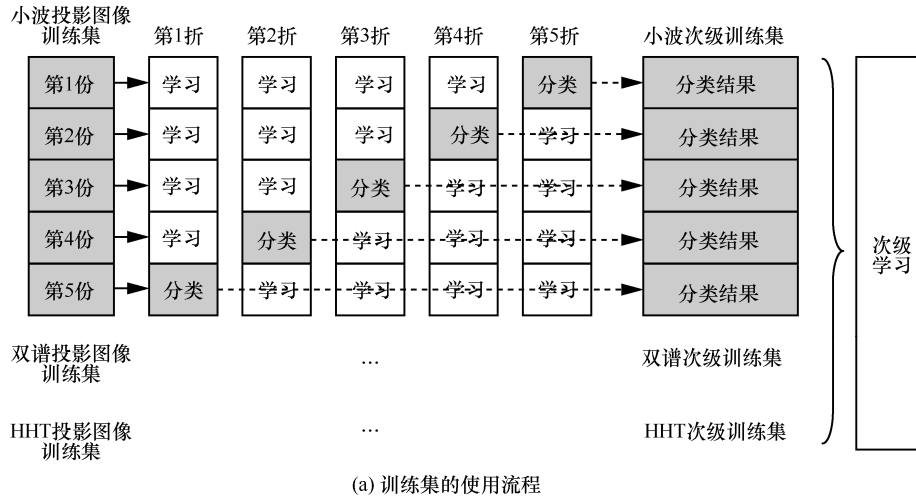


图 4 训练集和测试集的使用流程

种杂散特征，并利用 SVM 进行分类，以此作为对比方法 2。文献[23]利用 PCA 算法对样本进行降维，实现特征提取，然后利用 K 近邻、随机森林和神经网络构建混合分类模型，同样使用多分类器融合的设计，以此作为对比方法 3。结果如表 1 和图 5 所示。

可以看出，本文方法的最终识别率最高，在识别准确率和抗噪表现上都优于其他方法。对比方法 1 使用单一特征提取算法 HHT，整体表现不如融合模型；对比方法 2 虽然同样使用多特征提取，时域方法在特征的选择上具有局限性，且其分类器使用 SVM 的分类效果弱于神经网络对图像的分类效果；对比方法 3 虽然使用了多分类器集成，但使用 PCA 方法降维并未充分提取表示信号差别的细微特征，整体表现不佳。本文方法使用基于变换域的多特征提取，并使用神经网络集成识别特征图像的方法，具有更好的性能表现。

表 1 实测不同方法的辐射源识别准确率

| 方法 | 5 dB | 10 dB | 15 dB | 20 dB | 25 dB |
|--------|-------|-------|-------|-------|-------|
| 本文方法 | 60.5% | 74.4% | 85.5% | 94.3% | 96.2% |
| 对比方法 1 | 56.2% | 67.3% | 81.5% | 91.2% | 92% |
| 对比方法 2 | 48.8% | 56.4% | 67.8% | 78.3% | 82.2% |
| 对比方法 3 | 38.2% | 46.3% | 55.4% | 58.5% | 61.7% |




图 5 不同方法在不同信噪比下的识别效果对比

4.2.2 使用 AC-GAN 扩充数据的影响

比较使用 AC-GAN 进行不同比例的数据扩充的最终识别准确率, 按扩充数据占原始数据的比例为 0~90%进行对比试验, 结果如图 6 所示。从图 6 可以看出, 当数据扩充比例为 50%时, 模型的识别精度不再随着数据扩充比例的增加而明显提高, 而是逐渐趋于稳定。使用 AC-GAN 扩充数据集的模型在抗噪表现和识别准确率都表现更好, 特别是在高信噪比的情况下, 模型整体识别效果有显著提升, 说明使用 AC-GAN 对数据集进行增强, 能够提升整体识别准确率, 从而改善数据量不充足条件下模型整体识别率不高的问题。




图6 模型使用 AC-GAN 进行不同比例的数据扩充的最终识别准确率

4.2.3 衰落信道对信号识别的影响

本节使用室外典型场景多径衰落信道模型对辐射源信号进行了处理, 选用瑞利衰落信道模型, 将辐射源产生的信号通过多径传播模型以模拟其在室外场景下的传播特性^[29]。由图 7 可以看出, 衰落信道环境对辐射源识别效果产生了负面影响, 但模型仍可较好地完成分类识别任务, 即使是在瑞利衰落信道这种相对恶劣的信道环境下, 本文方法在 20 dB 信噪比条件下的识别准确率也有 80%以上, 相比其他对比方法, 本文方法有明显的优势。通过上述结果表明, 本文方法能够适用于复杂无线信道环境的应用。

5 结束语

本文提出了一种基于多特征提取、集成融合学习和生成对抗网络的通信辐射源融合分类识别方法。通过对原始信号进行小波变换、双谱变换、HHT 等信号变换处理, 得到 3 种可反映信号细微

特征的系数矩阵, 对系数矩阵的三维图像进行二维投影以得到特征图像数据集, 并采用 AC-GAN 对图像数据集进行增强。此外, 本文设计了一种多特征融合双阶段分类识别方法, 利用多个残差网络对不同图像特征集分别进行训练学习, 得到初始分类结果, 并通过融合得到最终分类结果。结果表明, 相对于其他相关的 SEI 方法, 本文方法在不同信噪比下的平均识别率较高, 即使在低信噪比条件下也有较好的表现。通过引入基于 AC-GAN 的数据增强机制, 能够提升整体识别准确率, 改善数据量不足而影响识别效果的问题。




图7 在衰落信道环境下辐射源信号的识别效果对比

参考文献:

- [1] LANGLEY L E. Specific emitter identification (SEI) and classical parameter fusion technology[C]//Proceedings of WESCON'93. Piscataway: IEEE Press, 2002: 377-381.
- [2] 桂冠, 王禹, 黄浩. 基于深度学习的物理层无线通信技术: 机遇与挑战[J]. 通信学报, 2019, 40(2): 19-23.
GUI G, WANG Y, HUANG H. Deep learning based physical layer wireless communication techniques: opportunities and challenges[J]. Journal on Communications, 2019, 40(2): 19-23.
- [3] 曾勇虎, 陈翔, 林云, 等. 射频指纹识别的研究现状及趋势[J]. 电波科学学报, 2020, 35(3): 305-315.
ZENG Y H, CHEN X, LIN Y, et al. Review of radio frequency fingerprinting identification[J]. Chinese Journal of Radio Science, 2020, 35(3): 305-315.
- [4] WANG W, LIU H, YANG J, et al. Specific emitter identification using decomposed hierarchical feature extraction methods[C]//International Conference on Natural Computation. Piscataway: IEEE Press, 2017: 1639-1643.
- [5] MCGINTHY J M, WONG L J, MICHAELS A J. Groundwork for neural network-based specific emitter identification authentication for IoT[J]. IEEE Internet of Things Journal, 2019, 6(4): 6429-6440.
- [6] ROBINSON J, KUZDEBA S, STANKOWICZ J, et al. Dilated causal convolutional model for RF fingerprinting[C]//Computing and Communication Workshop and Conference. Piscataway: IEEE Press, 2020: 157-162.

- [7] WONG L J, HEADLRY W C, MICHAELS A J. Specific emitter identification using convolutional neural network-based IQ imbalance estimators[J]. IEEE Access, 2019, 7: 33544-33555.
- [8] GONG J, XU X, QIN Y, et al. A generative adversarial network based framework for specific emitter characterization and identification[C]//2019 11th International Conference on Wireless Communications and Signal Processing. Piscataway: IEEE Press, 2019: 1-6.
- [9] DENG S, HUANG Z, WANG X. A novel specific emitter identification method based on radio frequency fingerprints[C]//2017 2nd IEEE International Conference on Computational Intelligence and Applications. Piscataway: IEEE Press, 2017: 368-371.
- [10] CHEN P, XU K, LI G, et al. Local frechet distance in specific emitter identification[C]//2017 IEEE 9th International Conference on Communication Software and Networks. Piscataway: IEEE Press, 2017: 842-845.
- [11] WANG H, ZHANG T. Specific emitter identification based on fractal and wavelet theories[C]//IEEE Advanced Information Technology Electronic and Automation Control Conference. Piscataway: IEEE Press, 2017: 1613-1617.
- [12] WU L, ZHAO Y, WANG Z, et al. Specific emitter identification using fractal features based on box-counting dimension and variance dimension[C]//IEEE International Symposium on Signal Processing & Information Technology. Piscataway: IEEE Press, 2017: 226-231.
- [13] HUANG G, YUAN Y, WANG X, et al. Specific emitter identification based on nonlinear dynamical characteristics[J]. Canadian Journal of Electrical & Computer Engineering, 2016, 39(1): 34-41.
- [14] 任东方, 张涛, 韩洁, 等. 基于 ITD 与纹理分析的特定辐射源识别方法[J]. 通信学报, 2017, 38(12): 160-168.
REN D F, ZHANG T, HAN J, et al. Specific emitter identification based on ITD and texture analysis[J]. Journal on Communications, 2017, 38(12): 160-168.
- [15] 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.
- [16] KONG M, ZHANG J, LIU W, et al. Radar emitter identification based on deep convolutional neural network[C]//International Conference on Control and Automation. Piscataway: IEEE Press, 2018: 309-314.
- [17] YE W, PENG C. Recognition algorithm of emitter signals based on PCA+CNN[C]// 2018 IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference. Piscataway: IEEE Press, 2018: 2410-2414.
- [18] 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 J, ZHANG T, WANG H H, 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.
- [19] PAN Y, YANG S, PENG H, et al. Specific emitter identification based on deep residual networks[J]. IEEE Access, 2019, 7: 54425-54434.
- [20] ZHANG J, WANG F, DOBRE O A, 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.
- [21] HAN J, ZHANG T, REN D, et al. Communication emitter identification based on distribution of bispectrum amplitude and phase[J]. Measurement & Technology, IET, 2017, 11(8): 1104-1112.
- [22] DING L, WANG S, WANG F, et al. Specific emitter identification via convolutional neural networks[J]. IEEE Communications Letters, 2018, 22(12): 2591-2594.
- [23] ZHANG X, LUO P, HU X, et al. A hybrid method for classification and identification of emitter signals[C]// International Conference on Systems & Informatics. Piscataway: IEEE Press, 2017: 1060-1065.
- [24] SA K, LANG D, WANG C, et al. Specific emitter identification techniques for the Internet of things[J]. IEEE Access, 2019, 8: 1644-1652.
- [25] 齐建文, 陈慧贤, 吴彦华, 等. 通信辐射源信号细微特征分析与处理[M]. 北京: 国防工业出版社, 2015.
QI J W, CHEN H X, WU Y H, et al. Analysis and processing of the subtle features of communication emitter signal[M]. Beijing: National Defense Industry Press, 2015.
- [26] 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 Z, LEI Y K. Method of individual communication transmitter identification based on maximum correntropy[J]. Journal on Communications, 2016, 37(12): 171-175.
- [27] YU J, HE Z, ZHANG Y. A modulation recognition method based on bispectrum and DNN[C]//International Conference on Communications, Signal Processing, and Systems. Piscataway: IEEE Press, 2018: 898-906.
- [28] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision & Pattern Recognition. Piscataway: IEEE Press, 2016: 770-778.
- [29] FADUL M, REISING D, LOVELESS D, et al. RF-DNA fingerprint classification of OFDM signals using a rayleigh fading channel model[C]//2019 IEEE Wireless Communications and Networking Conference. Piscataway: IEEE Press, 2019: 1-7.

[作者简介]



何遵文 (1964-), 男, 湖北潜江人, 博士, 北京理工大学副教授, 主要研究方向为无线通信安全、通信与信息系统等。

侯帅 (1996-), 男, 河北唐山人, 北京理工大学硕士生, 主要研究方向为通信辐射源识别。

张万成 (1982-), 男, 河北张家口人, 博士, 北京理工大学讲师, 主要研究方向为语音信号处理。

张焱 (1983-), 男, 山东德州人, 博士, 北京理工大学副教授, 主要研究方向为无线与移动通信技术、无线信道建模理论与物理层安全技术。