

DOI: 10.13382/j.jemi.B2104031

特定辐射源个体识别算法研究^{*}

许 敏 李博涵 王 凯 谭守标
(安徽大学 电子信息工程学院 合肥 230000)

摘 要:针对特定辐射源个体识别(specific emitter identification,SEI)方法,指纹特征提取需要复杂公式演算推理,特征差异小、提取困难,提取后特定辐射源个体识别正确率低的问题,提出一种基于密集连接结构与注意力机制的特定辐射源识别算法,称之为特定辐射源识别网络(specific emitter identification network,SEIN)。首先使用包络提取算法提取含噪声较少的辐射源信号包络,得到含有丰富指纹特征的包络图,进而进行 SEIN 指纹特征的提取及个体识别。实验结果表明,SEIN 可达到 95.12% 的分类识别效果,具有准确率高、指纹特征提取自动化特点,最终较好实现了复杂环境下特定辐射源个体识别。

关键词: 特定辐射源个体识别;密集连接;注意力机制;指纹特征

中图分类号: TP391.41;TP183 **文献标识码:** A **国家标准学科分类代码:** 490.10

Research on individual identification method of specific emitter

Xu Min Li Bohan Wang Kai Tan Shoubiao

(School of Electronics and Information Engineering, Anhui University, Hefei 230000, China)

Abstract:For the specific emitter identification method, fingerprint feature extraction needs complex formula calculus reasoning, the feature difference is small, the extraction is difficult, and the accuracy of specific emitter identification after extraction is low. In order to better extract fingerprint features, a specific emitter identification algorithm based on dense connection structure and attention mechanism is proposed, which is called specific emitter identification network (SEIN). First, the envelope extraction algorithm is used to extract the envelope of the radiation source signal with less noise, and an envelope map with rich fingerprint features is obtained, then the SEIN fingerprint feature extraction and individual recognition are performed. The experimental results show that SEIN can achieve a classification and recognition effect of 95.12%, has the characteristics of high accuracy and automatic fingerprint feature extraction, and finally achieves better specific emitter identification in complex environments.

Keywords:specific emitter identification; dense connection; attention mechanism; fingerprint features

0 引 言

电子侦察技术利用我方的一些相关侦察的设备来完成另一方信号相关的检测、分析工作,并得到与信号相关的重要信息,在电子对抗领域中有非常重要的作用。作为电子对抗的一部分,现今信号的有意调制识别在一些复杂的电磁情景难以实现不同调制类型的信号的判别。并且,在信号的调制类型和参数几乎相近情况下,信号很有可能来自不同雷达发射器,这样一来就给信号识别带

来了困难。信号的脉内无意调制又称为“指纹”特征,对雷达信号的“指纹”特征分析,可以有效实现在调制类型和参数几乎相近的情况下,不同雷达发射器的识别。因此,本文从信号脉内无意调制内容入手,使用雷达信号“指纹”特征实现特定辐射源个体识别。

目前,基于传统的辐射源识别方法,包含基于包络指纹特征识别^[1-2],但是在提取指纹特征时,会由于所处的复杂电磁环境等原因,造成指纹特征提取不够完整,从而影响了辐射源信号的分类识别。除去基于脉冲包络指纹特征实现辐射源信号识别外,还有一些基于辐射源信号

脉冲描述字的算法^[3-4],但是这种方法只针对在电磁环境较简单情况下,完成信号识别,并且现今属于不同类别的辐射源信号仍可能具有相同的脉冲描述字。除此之外还有一些基于辐射源调制信息来完成分类识别,在不同的调制模式下,其瞬时频率存在差别^[5-7]。上述基于传统的方法实现的特定辐射源个体识别(specific emitter identification, SEI)算法,虽然在一定程度上面,可以得到分类识别的目的。但是,相关参数提取复杂,很多情况下很难达到识别的目的。现今机器学习的相关算法,也在辐射源信息识别方面得到使用,文献[8]对该方面的内容进行了系统综述分析。

此外,卷积神经网络(convolutional neural network, CNN)相关算法发展迅速,基于 CNN 的雷达信号识别的算法也逐渐被研究与提出。在调制域中,信号的时频分析图,会存在不同特征,在某种程度上可利用这些差异完成信号识别,有研究学者提出,使用 CNN 结构对时频图进行特征自动提取,可实现辐射源信号的识别^[9-10]。同时,文献[11]将信号脉冲描述字中脉宽、脉冲重复间隔、载频数据同时输入到 CNN 中,实现信号识别。此外有研究对雷达信号数据进行降维、升维,处理后使用 CNN 进行信号识别研究^[12-13]。由于雷达辐射源信号是一维信号,也有研究使用一维卷积结构,实现雷达信号识别。文献[14]对脉冲描述字相关数据进行处理,并设计使用一维 CNN 网络,实现雷达信号识别。对于雷达辐射源个体,其脉冲特征参数会由于电子器件中细微差异发生变化。这些变化主要包含包络上升沿、下降沿、顶部起伏等一些小的不同之处。所以可以通过这些小的不同之处,应用 CNN,实现特定辐射源个体的识别。本文将 CNN 相关结构为基础,创造性的使用雷达辐射源个体的包络特征实现信号识别,设计包络提取算法完成雷达辐射源个体包络信息提取,并通过 CNN 实现包络特征的自动提取,将复杂的辐射源个体的指纹特征提取工作交给机器完成,加强了特征的传递,有效的完成特征的提取,更好的实现辐射源信号的自动识别。

1 雷达信号

雷达信号的表达式定义为:

$$x(t) = A(t) \times f(t), 0 \leq t \leq T \quad (1)$$

式中: $A(t)$ 幅值函数; $f(t)$ 是雷达信号的调制函数。

$$f(t) = \exp[j(2\pi f_0 t + c(t) + \varphi_0)] \quad (2)$$

式中: f_0 表示载频; $c(t)$ 表示相位函数,初始相位大小用 φ_0 表示。一般情况下,不同的雷达信号其调制方式存在着差异,由于雷达相关技术的进步,很多情况下面不同的辐射源信号之间,往往有相同的调制方式。所以,在进行辐射源信号识别时,采用调制方式不同来区分不同的类

别,往往很难达到识别的需求。而包络特征作为辐射源信号本身自带的属性,是由发射机中一些细微的差异产生,因此具有专属的特征。所以可以考虑将其作为不同信号之间分类的特征来进行信号识别。

1.1 包络提取算法设计

特定辐射源个体的包络通常会在,信号的脉冲上升沿的部分以及下降沿的部分存在着细微的差异。而在一般情况下,不同辐射源信号间,包络的差异变换主要由相位变换带来。一般的包络信号的模型包含 S 型函数包络、二次包络、正切包络及其线性包络这 4 种类型^[15]。

S 型函数包络的表达式为:

$$S(\eta) = \begin{cases} \frac{1 + e^{-\mu}}{1 + e^{\mu - \frac{2\mu}{\eta T}}}, & 0 \leq t \leq \eta T \\ 1, & \eta T \leq t \leq T - \eta T \\ \frac{1 + e^{-\mu}}{1 + e^{\mu - \frac{2\mu}{T - \eta T}}}, & T - \eta T \leq t \leq T \end{cases} \quad (3)$$

式中: μ 用来调整上升沿波形的形状; η 表示上升沿在整个脉冲宽度时间 T 中所占的比例,除了有相关干扰信号的影响外,通常情况下 η' 与 η 大小是相同的。

二次包络的函数表达式为:

$$Q(a, b, \eta) = \begin{cases} \frac{at^2 + bt}{a\eta'^2 T^2 + b\eta' T}, & 0 \leq t \leq \eta T \\ 1, & \eta T \leq t \leq T - \eta T \\ \frac{a(T-t)^2 + b(T-t)}{a\eta'^2 T^2 + b\eta' T}, & T - \eta T \leq t \leq T \end{cases} \quad (4)$$

式中: a, b 用来调整包络在上升的过程当中,曲率的变换的幅度; η' 表示在有相关干扰信号的影响下,上升沿在整个脉冲宽度时间 T 中所占的比例。

正切包络函数的表达式为:

$$T(\eta) = \begin{cases} \tan(\frac{\theta}{\eta' T} t), & 0 \leq t \leq \eta T \\ 1, & \eta T \leq t \leq T - \eta T \\ \tan(\frac{\theta}{\eta' T} (T - t)), & T - \eta T \leq t \leq T \end{cases} \quad (5)$$

式中: a, b 的作用同式(4); θ 用于改变包络在上升下降过程中变换的幅度; η' 同样表示在有相关干扰信号的影响下,上升沿在整个脉冲宽度时间 T 中所占的比例。

线性包络函数的表达式为:

$$L(\eta) = \begin{cases} \frac{t}{\eta' T}, & 0 \leq t \leq \eta T \\ 1, & \eta T \leq t \leq T - \eta T \\ \frac{T - t}{\eta' T}, & T - \eta T \leq t \leq T \end{cases} \quad (6)$$

式中: η' 表示在有相关干扰信号的影响下, 上升沿在整个脉冲宽度时间 T 中所占的比例。

不同类型的包络函数, 会呈现出不同包络特征, 可以通过这些特征来完成辐射源信号的识别工作。

本文需要得到辐射源信号的包络图即 I/Q 两路信号的幅值函数。为了得到 I/Q 中频数据中雷达辐射源信号个体所对应的幅值数据, 在对雷达信号噪声滤波后, 使用包络提取算法将中频数据中的脉冲包络信号提取出来, 得到 I/Q-幅值图的幅值数据、I 路数据以及 Q 路数据。该算法的实现过程总结如下。

1) $I(t)/Q(t)$ 两路数据求出 $A(t)$;

$$A(t) = \sqrt{I(t)^2 + Q(t)^2} \quad (7)$$

2) 设置门限值 δ_1 , 记录所有 $A(t) - \delta_1 \leq 1 \times 10^{-4}$ 的点位置 $t(n)$ 。

3) 设置门限值 δ_2 取 $[t(n - \delta_2), t(n + 1 + \delta_2)]$ 之间幅值 $A(t)$ 。

4) 求取相邻幅值信号变化率 $\Delta A(t)$ 。

5) 设置门限 δ_3 , 若 $\Delta A(t) * \Delta A(t + 1) > 0$, 且个数大于等于 δ_3 , 那么能够判断该段信号的包络为辐射源信号包络。

6) 根据包络数据、I/Q 数据, 组成 I/Q-幅值数据, 最终得到辐射源信号的指纹特征。

算法中门限值 δ_1 、 δ_2 、 δ_3 对于指纹特征的提取起关键作用, 首先门限值 δ_1 受到信号中噪声影响。因为噪声会对信号的幅值的大小产生影响, 所以 δ_1 设定是通过幅值求取平均值的方法来确定。门限 δ_2 反映的是包络特征的提取是否完整, 不同的 δ_2 值影响最后包络图所含指纹信息的多少, 它的数值的选取将在实验部分进行对比验证。最后门限 δ_3 反应了信号上升沿及下降沿的变化趋势, δ_3 恰当设置能够实现上升沿及下降沿的正确提取, 而该部分中含有的指纹特征信息较多, 因此它的设置也将对最后的实验结果产生影响, 具体的数值设置将在实验部分进行对比分析。

2 特定辐射源识别网络 (SEIN) 设计

CNN 在每次卷积计算时, 它在所有层中权值的参数大小相同, 这样进一步的降低了网络中参数数量和计算量, 减少了模型体积, 使其更加具有使用的价值。现今, CNN 逐渐在很多的领域得到使用^[16-18]。因此, 本文使用 CNN 相关结构完成 SEIN 算法设计, 特定辐射源信号个体识别系统框图如图 1 所示, 总体算法步骤如下。

1) 将原始的辐射源信号通过包络提取算法, 得到真实的包络数据。

2) 根据 I 路、Q 路以及幅值数据, 得到 I/Q-幅值图。

3) 使用密集连接块结构完成通道维度上 I/Q-幅值

图中相关指纹特征提取与学习。

4) 加入基于通道维度上的注意力结构, 将此结构加入到每个密集块后。实现密集连接结构在每个通道维度上特征提取后, 通道上权重数据的重新学习与更新, 进一步实现 I/Q-幅值图中相关信息的学习与传递。

5) 完成特征提取后, 通过全连接层及 Softmax 层后, 完成特定辐射源信号个体识别分类, 最终得到识别之后的结果。




图 1 特定辐射源个体识别系统

Fig. 1 Specific radiation source individual identification system

SEIN 网络, 完成指纹特征的自动提取, 并通过增强指纹特征的提取过程, 加强特征信息的传递, 实现特定辐射源个体识别。SEIN 特征提取部分有两个模块组成, 一个是基于密集连接方式的 CNN 结构, 另外一个则是基于注意力思想的 Attention 结构。接下来将对这个两个模块的相关内容进行分析。

2.1 密集连接模块

文献[19]提出的网络, 最突出的特点是 Dense Block 采用密集连接的思想, 它每一层的输入都是与该层前面所有层的输出连接在一起, 前面所有卷积层输出共同输入到下一层网络中, 通过学习之后得到的当前层输出的特征图在输入到下一层网络中。本文在 SEIN 设计时, 借鉴了这种思想, 考虑到输入的数据为脉冲波形图, 使用深层网络会出现过拟合现象, SEIN 将 Dense Block 的个数减少, 以降低网络的层数。

在 SEIN 网络中, Dense Block 特征图之间有 $L(L+1)/2$ 种连接方式, 在这样的结构中, 通过将所有层的输出直接输入的下一层网络中, 这样可以充分的利用所有的特征信息, 对于包络识别, 由于不同辐射源信号之间, 脉冲包络之间的差异较小, 所以为了能够更好的提取指纹特征, SEIN 网络中, 采用了密集连接结构, 将包络图通过 Dense Block 提取指纹特征。

Dense Block 网络结构如图 2 所示, 该结构使用 Conv(1×1) 与 Conv(3×3) 的卷积结构组成, 其中

Conv(1×1)可以减少参数量,达到降低特征图维度的目的,Conv(3×3)的结构可以完成特征的提取工作。下面的一个网络层中,它的特征参数是由前面的所有的层输入,SEIN 网络结构如图 3 所示。

Dense Block 完成雷达信号个体的特征提取后,将在每个 Dense Block 之间使用一个过渡层(transition layer)建立过渡连接,结构如图 4 所示,每个结构中包含了一个 1×1 的卷积和一个平均池化操作,这么做是既实现了特征在空间上的下采样,还能够减少特征图的数量,从而减少参数量。




图 3 SEIN 网络结构

Fig. 3 SEIN network structure





图 4 过渡层结构

Fig. 4 Transition layer structure

2.2 注意力模块

文献[20]提出了一种基于注意力模块来进行分类识别的方法,该方法通过使用了一个轻量的门控机制,加强了模型中通道之间的相互联系作用,从而能更好的利用通道上面特征图的信息。本文在借鉴文献[19]密集连接结构思想的同时,考虑将注意力加入到密集连接的结构中。在完成通道上面特征图信息重复利用的同时,增强对通道上重要信息的学习并达到权重更新的目的。

由于辐射源信号的指纹特征,相互之间的差异性比较小,在进行人工的提取指纹特征时往往很难达到精确

图 2 一个 $L=4$ 的 Dense Block 结构Fig. 2 A Dense Block structure with $L=4$

的提取到相关特征的目的。需要经过一系列的复杂运算才可以实现。基于深度学习的方法,将指纹特征的提取交给 SEIN 网络来进行,所以为了更好的提取指纹特征,本文加入了注意力模块部分,结构如图 5 所示。前面层的输入的特征图信息为 $a_c \in R^{H \times W \times C}$, W 、 H 是特征图在空间维度上的宽与高。首先将 Dense Block 模块输入的特征图输入到注意力模块中,经过一个全局池化(global average pooling, GAP)操作,得到一个 $1 \times 1 \times C$ 的特征图从而得到关于特征的全局的信息,公式为:

$$F_{sq}(a_c) = \frac{1}{W \times H} \sum_{i=1}^W \sum_{j=1}^H a_c(i, j) \quad (8)$$

之后为了达到减少参数量的目的,本文用 Conv(1×1)的结构来实现通道数量的减少,并使用激活函数实现非线性之间的转换,并将特征图送入到一个 Conv(1×1)的结构中,完成通道的升维,实现与输入特征图相乘。在通道特征图实现升维后,同样需要使用一个激活函数实现非线性的转换。这样的一个过程被称之为激活过程,它的表达式为:

$$Y = F_{sq}(a, W) = S(g(a, W)) = S(W_2 R(W_1 a)) \quad (9)$$

式中: Y 为注意力模块的输出; W 为每次卷积输出的维




图 5 注意力模块

Fig. 5 Attention module

度; W_2 是第 1 个 $conv(1 \times 1)$ 操作实现降维; W_1 是第 2 个 $conv(1 \times 1)$ 操作实现升维; S 为 Sigmoid 函数; R 为 ReLU 函数。

之后将注意力模块输出的通道权重数据 Y_c 与 Dense Block 模块输出的特征图数据 a_c 相乘, 得到最终的特征图参数信息, 它的表达式为:

$$F_{scale}(a_c, Y_c) = a_c \times Y_c \quad (10)$$

将提取到的所有特征送入到下一个结构中, 继续完成特征图相关辐射源信号个体特征学习。特征提取完成后通过 MaxPooling 完成降维操作, 使用 GAP 来完成提取全局特征, 同时实现特征图在空间维度上, 维度降低的操作, 最后经过全连接层与 Softmax 完成 SEI 分类识别。

3 实验结果分析

本文采用设备采集的 ADS-B 信号作为数据集, 图 6 所示是其中 4 类辐射源原始信号, 数据中包含 32 个不同的辐射源个体。数据的频率为 0.5~5 MHz, 最大采样频率为 20 MHz。设备采集后得到的数据包含 I 路与 Q 路两路信号, 采集到的数据为时域信号, 每个类型的数据包含多个通道下采集得到的数据, 每个通道中 I 路与 Q 路信号的点数在 65 536~206 640。对采集到的数据进行文件解析处理, 得到不同通道下, 信号 I、Q 两路数据。同时采集到的数据, 并非全部为辐射源信号, 可能会存在部分干扰信号, 所以需要采用包络提取算法, 进行含有“指纹”特征的包络数据提取, 并将提取到的包络数据按照时序通过 MATLAB 绘制成 I/Q-幅值图, 图 7 所示为采用包

络提取算法得到的其中 6 类 I/Q-幅值图。实验中的数据集, 包含了 32 类不同的数据, 共有 7 836 张雷达辐射源个体 I/Q-幅值图, 将其中 70% 用于训练数据、30% 进行模型测试数据, 每类数据反映在包络图上面存在不同程度的差异。




图 6 某 4 类 ADB-S 原始信号

Fig. 6 A type 4 ADB-S original signal




图 7 某 6 类 I/Q-幅值图

Fig. 7 A 6 type I/Q-amplitude diagram

3.1 实验分析评价指标

实验采用准确率来完成仿真结果的分析,使用 SEIN 训练后的模型,进行不同类别分类结果测量。统计特定辐射源个体经过 Softmax 分类结果后,得到 Softmax 层中分类置信度排名第一的特定辐射源个体类别并与真实的类别比较,得到分类正确的雷达个体的数量,之后完成准确率的计算,从而得到最终的准确率(top-1)。准确率计算的公式为:

$$acc = \frac{TP + TN}{total}$$

(11)

式中:TP 为特定辐射源个体识别正确个数;TN 为非特定辐射源个体识别正确的个数;total 是所有的样本数据的总数。

3.2 实验过程

本文实验基于深度学习库 PyTorch 实现深度卷积神经网络搭建、训练与测试。系统环境为 ubuntu16. 04LTS,主要硬件为 i5-8500 及 NVIDIA GTX 1080Ti。训练时,输入的图片的大小为 224×224×3,采用微调的方法完成模型训练,Batchsize 大小设置为 32,初始学习率的大小设置为 0. 000 1,之后每经过 100 个 epoch 后将学习率设置衰减为原来的 0. 6 倍,在优化器选择上,使用 Adam 优化器完成,它在梯度值的估算时,同时使用了一阶矩和二阶矩,进而将估算值用到步长的更新与计算上,是一种一阶优化算法。此外,损失函数选择交叉熵损失函数,它通过表示分类的真实结果在概率上面的分布与分类的预测结果在概率上面分布的差距,实现损失计算,当损失越小时,这两者之间差距就会越小。这样选择能够实现模型的更加快速的收敛,实验一共训练了 500 个 epoch。

在进行包络提取时,包络提取算法中门限值的设定,会影响最终提取到的包络数据的准确性,实验首先进行了包络提取算法中,不同门限值大小的分析。

由于数据中包含干扰样本,所以在一些情况下面分离得到的样本中,混有非指纹特征的样本。同时信号也会混有噪声。为了减少这两种因素带来的影响,需要设置合适 δ_2 、 δ_3 值,来实现最终含指纹特征的包络图的提取,实验中,设备采集到的 ADS-B 信号根据其采样率,得到 δ_2 的点数在 75 左右, δ_3 的点数则在 10,所以进行了不同 δ_2 、 δ_3 值的对比验证。在不同的 δ_2 、 δ_3 数值下,使用本文所设计的包络提取算法,进行数据提取,并绘制成幅值图,通过 SEIN 训练后得到分类模型,之后再计算准确率(top-1)的计算,结果如表 1、2 所示。

从表 1、2 可以看出,当 δ_3 固定时, δ_2 在变化时,它的准确率在波动增加,当 $\delta_2 = 80$ 时,准确率达到最大,之后准确率又会降低。这主要是因为 $\delta_2 = 80$ 时能够较好的实现整个脉冲变化的曲线变化特征。当 δ_2 固定时,随着 δ_3 的变化,它的准确率在一直增加,当 $\delta_3 = 8$ 时,准确率达

表 1 不同 δ_2 Top-1 变化

Table 1 Different δ_2 Top-1 changes

方法	准确率 (Top-1) / %
$\delta_2 = 65, \delta_3 = 8$	91
$\delta_2 = 70, \delta_3 = 8$	92. 8
$\delta_2 = 75, \delta_3 = 8$	94. 5
$\delta_2 = 80, \delta_3 = 8$	95. 12
$\delta_2 = 85, \delta_3 = 8$	93. 9

表 2 不同 δ_3 Top-1 变化

Table 2 Different δ_3 Top-1 changes

方法	准确率 (Top-1) / %
$\delta_2 = 80, \delta_3 = 6$	92. 5
$\delta_2 = 80, \delta_3 = 8$	95. 12
$\delta_2 = 80, \delta_3 = 10$	94. 8
$\delta_2 = 80, \delta_3 = 12$	93. 2
$\delta_2 = 80, \delta_3 = 14$	92. 4

到最大,之后准确率又会降低。

这是因为当 $\delta_3 = 8$ 能够更好的实现脉冲上升沿及下降沿正确提取,使得提取到的信息能够充分的反应脉冲的“指纹”特征。因此,选择 $\delta_2 = 80, \delta_3 = 8$ 来完成包络数据提取及后面相关实验。

SEIN 网络中由密集块连接的结构组成,它的个数的不同会对雷达信号个体的指纹特征的提取带来影响,为了找到密集块最合适的数值,进行了相关的实验验证。

实验结果如表 3 所示,由 2 个 Dense Block 组成的 SEIN 结构它在 SEI 识别中所表现的效果更好,当个数为 3 时,准确率反而下降,这是由于网络中输入的数据较简单,使用更深的网络虽然在训练时可能会达到较好的效果,但是测试时却出现下降,网络达到了过拟合的状态。因此,SEIN 共有 2 个 Dense Block 结构组成。

表 3 不同 Dense Block 个数 Top-1 变化

Table 3 Top-1 changes in the number of different dense blocks

方法	1/Q-幅值图准确率 (Top-1) %
1	89. 2
1+2	94. 3
1+2+3	94. 17

注:1 表示 Dense block (1)-6;2 表示 Dense block (2)-12;3 表示 Dense block (3)-10

注意力模块的加入,使得网络在提取指纹特征时不同的特征图之间在通道间的相互关联的信息连接到一起,这样通道内所有的信息都融合到了一起,达到对通道上重要信息的注意与学习。实验进行了注意力模块的加入到 SEIN 网络中对分类准确度产生的影响。为了同时验证模块抗噪性能,对采集到的数据进行噪声的随机加

入,信噪比的变换区间为 $[0,25]$ dB,在噪声的选择上选取高斯白噪声,噪声每间隔 5 dB,加入到采集到的数据中,组成不同噪声下的数据。在 0~25 dB 信噪比下,进行加入注意力模块与不加入分类准确率的验证。




图 8 注意力模块分类结果
Fig. 8 Attention module classification results

图 8 所示是最终实验结果,在不同的 SNR 下产生雷达信号数据,组成的 I/Q-幅值图,注意力模块的网络中具有较好的分类准确率,可以看到在信噪比为 15 dB 的环境下,SEIN 网络达到了 95.12% 的分类效果。而没有加入该模块的网络虽然也能够完成分类,但是其分类的准确率一直低于 SEIN 网络,并且在 SEIN 网络信噪比为 15 dB,识别率为 95.12% 的情况下,未加入相应模块的网络仅仅只达到了 94.3% 的分类识别效果。可以得出加入该模块,可以更好的提取辐射源信号个体在指纹特征,充分识别不同雷达个体之间的差异性,更加准确的实现了特定辐射源个体的识别的任务。由于受到不同信噪比的影响所设计的脉冲包络提取算法在 15 dB 后提取的包络数据比在 15 dB 下所提取的包络数据完整性上存在差异,使得网络在高信噪比下分类效果出现小幅度下降情况,但这并不影响注意力模块对分类识别的作用。

CNN 最先被提出时,主要被应用于图像分类的相关问题,目前有很多基于 CNN 的图像分类网络,本文将 SEIN 与 AlexNet、Vgg19、ResNet18、加入 Attention 结构 ResNet18 网络、DenseNet121 结构进行对比实验分析,验证 SEIN 分类识别的有效性。

在信噪比为 15 dB 下,完成不同网络对 I/Q-幅值图分类的实验。它们的分类结果,如表 4 所示。

从表 4 可以得出,SEIN 网络在分类准确率上,和主流的分类网络 AlexNet、Vgg19、ResNet18、ResNet18 + Attention、DenseNet121 相比分别提高 8.55%、3.28%、2.84%、2.1%、0.98%。在提取包络特征上面,SEIN 网络相比于其他的网络,由于注意力在每个通道上面特征图

表 4 I/Q-幅值图在不同网络实验结果
Table 4 I/Q-amplitude graph experiment results in different networks

方法	I/Q-幅值图准确率	速度/s	模型大小
	(Top-1)/%		/MB
AlexNet	86.87	0.3	212
Vgg19	91.84	0.54	550
ResNet18	92.28	0.058	44.7
ResNet18+Attention	93.02	0.062	46.5
DenseNet121	94.15	0.045	36.5
SEIN	95.12	0.036	25

的相关信息的学习与权重更新,以及密集连接思想对于通道上面特征图相关内容的重复使用,使得 SEIN 对雷达辐射源信号的脉冲包络信息进行了充分的学习,最终与其他网络相比达到了较高的分类识别率。同时,在速度及模型大小上面,SEIN 和其他的网络相比,也具有明显的优势。

从上述内容可以得出,通过通道上注意力与密集连接思想建立 SEIN 网络,并使用 I/Q-幅值图进行分类训练,可以较好的实现辐射源信号个体“指纹”特征提取,并在 SEIN 中达到 95.12% 的分类效果,和主流网络与标准 CNN 结构相比均有的一定的提高,较好的实现了对特定辐射源个体分类识别的要求。

4 结 论

本文设计了一种基于密集连接与注意力模型的 SEIN 网络结构,并将这种网络结构应用到了特定雷达辐射源个体的分类上,通过网络来提取特定辐射源个体的“指纹”特征来实现分类,分类准确率为 95.12%。训练得到的模型和其他的模型相比在一定程度上得到了改进,分类效果良好,能够实现复杂的电磁环境下雷达特定辐射源个体的识别。该方法也为特定雷达特定辐射源识别提供了一种新思路。本文所使用的数据停留在时域,可以考虑信号的多种变换形式如频域,这将会是未来研究内容。

参考文献

[1] 刘旭,罗鹏飞,李纲. 基于拟合角特征及 SVM 的雷达辐射源个体识别[J]. 计算机工程与应用, 2011, 47(8S):281-284.
LIU X, LUO P F, LI G. Radar emitter individual identification based on fitting angle features and SVM[J]. Computer Engineering & Applications, 2011, 47(8S): 281-284.
[2] WU L, ZHAO Y, FENG M, et al. Specific emitter identification using IMF-DNA with a joint feature selection algorithm[J]. Electronics, 2019, 8(9):934.
[3] WANG S Q, BAI J, HUANG X Y, et al. Analysis of

- radar emitter signal sorting and recognition model structure[J]. *Procedia Computer Science*, 2019, 154: 500-503.
- [4] LIU Y, ZHANG Q. Improved method for deinterleaving radar signals and estimating PRI values[J]. *Radar Sonar & Navigation*, 2018, 12(5):506-514.
- [5] FENG Z P, ZHANG D, ZUO M J. Adaptive mode decomposition methods and their applications in signal analysis for machinery fault diagnosis: A review with examples[J]. *IEEE Access*, 2017(5):24301-24331.
- [6] PADILLA P, VALENZUELA VALDES J F, PADILLA J L. Radio frequency identification of wireless devices based on RF fingerprinting [J]. *Electronics Letters*, 2013, 49(22):1409-1410.
- [7] 黄渊凌, 郑辉. 基于瞬时频率畸变特性的 FSK 电台指纹特征提取[J]. *电讯技术*, 2013, 53(7): 868-872.
HUANG Y L, ZHENG H. FSK radio fingerprints extraction based on distortions of instantaneous frequency [J]. *Telecommunications Engineering*. 2013, 53 (7): 868-872.
- [8] 李昆, 朱卫纲. 基于机器学习的雷达辐射源识别综述[J]. *电子测量技术*, 2019, 42(18):69-75.
LI K, ZHU W G. Review of radar radiation source recognition based on machine learning [J]. *Electronic Measurement Technology*, 2019, 42(18):69-75.
- [9] PAN Y, YANG S, PENG H, et al. Specific emitter identification based on deep residual networks[J]. *IEEE Access*, 2019(7):54425-54434.
- [10] SATIJA U, TRIVEDI N, BISWALI G, et al. Specific emitter identification based on variational mode decomposition and spectral features in single hop and relaying scenarios[J]. *IEEE Transactions on Information Forensics and Security*, 2018, 14(3):581-591.
- [11] CAIN L, CLARK J, PAULS E, et al. Convolutional neural networks for radar emitter classification[C]. *IEEE Computing and Communication Workshop and Conference (CCWC)*, 2018.
- [12] MATUSZEWSKI J and SIKORSKAS L K. Neural network application for emitter identification [C]. *18th International Radar Symposium*, 2017: 1-8.
- [13] LAUREN J W, WILLIAM C H, ALAN J M. Specific emitter identification using convolutional neural network-based IQ imbalance estimators[J]. *IEEE Transactions on Access*, 2019(7): 33544-33555.
- [14] JUN S, GUANGLUAN X, WENJUAN R, et al. Radar emitter classification based on unidimensional convolutional neural network [J]. *IET Radar Sonar Navigation*, 2018, 12(8):862-867.
- [15] WU L W, ZHAO Y Q, FENG M F, et al. Specific emitter identification using IMF-DNA with a joint feature selection algorithm[J]. *Electronics*, 2019, 8(9): 934.
- [16] 汤一平, 韩国栋, 鲁少辉, 等. 基于 CNN 的火炮身管全景图像疵病识别方法[J]. *仪器仪表学报*, 2016, 37(4):871-878.
TANG Y P, HAN G D, LU S H, et al. CNN-based defect recognition method for artillery barrel panoramic image [J]. *Chinese Journal of Scientific Instrument*, 2016, 37(4):871-878.
- [17] 曲景影, 孙显, 高鑫. 基于 CNN 模型的高分辨率遥感图像目标识别[J]. *国外电子测量技术*, 2016, 35(8): 45-50.
QU J Y, SUN X, GAO X. Target recognition of high-resolution remote sensing images based on CNN model[J]. *Foreign Electronic Measurement Technology*, 2016, 35(8):45-50.
- [18] 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, L R M, HUANG Q T. Fine grained image recognition with weak supervised information based on deep neural network [J]. *Journal of Electronic Measurement and Instrumentation*, 2020, 34 (2): 115-122.
- [19] GAO H, ZHANG L, MAATEN L V D. Densely connected convolutional networks[C]. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017.
- [20] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(8): 2011-2023.

作者简介



许敏, 2017 年于潍坊学院获得学士学位, 现为安徽大学硕士研究生, 主要研究方向为计算机视觉与雷达信号处理。

E-mail: 185863511@qq.com

Xu Min received her B. Sc. degree from Wei Fang University in 2017. She is currently a M. Sc. candidate at Anhui University. Her main research interests include computer vision and radar signal processing.



谭守标 (通信作者), 2004 年于中国科学技术大学获得博士学位, 现为安徽大学教授, 主要研究方向为计算机视觉与模式识别。

E-mail: starry226@ahu.edu.cn

Tan Shoubiao (Corresponding author) received his Ph. D. degree from the University of Science and Technology of China in 2004. He is currently a professor at Anhui University. His main research interests include computer vision and pattern recognition.