

doi: 10.7690/bgzd.2022.04.014

基于残差重构网络的射频信号个体识别

赵火军, 程 旗, 李 捷, 高晓利, 王 维

(九州电器集团有限责任公司技术创新中心, 四川 绵阳 621000)

摘要: 针对主流方法对信号个体识别效率低、误识别的问题, 提出一种基于残差重构网络的射频信号个体识别方法。通过傅里叶变换得到侦收信号的频域特征, 作为神经网络的输入向量; 利用残差网络能够解决网络退化和梯度消失的优势, 重构残差网络, 并将其作为射频信号个体识别的核心网络模型; 通过固定每层网络的通道数, 实现减少模型参数量, 达到神经网络轻量化目的。实验结果表明: 与 ResNet18 方法相比, 该方法针对 30 个目标信号的个体识别率提升了约 3.8%, 模型大小降低了 13 倍, 能较好地解决模型压缩与识别算法性能无法平衡的问题。

关键词: 残差重构; 射频信号个体识别; 频域特征; 轻量化

中图分类号: TP391 **文献标志码:** A

Individual Recognition of RF Signal Based on Residual Reconstruction Network

Zhao Huojun, Cheng Qi, Li Jie, Gao Xiaoli, Wang Wei

(Technological Innovation Center, Sichuan Jiuzhou Electrical Group Co., Ltd., Mianyang 621000, China)

Abstract: In order to solve the problem of low efficiency and misrecognition of the mainstream method for individual signal recognition, a method for individual RF signal recognition based on residual reconstruction network is proposed. The frequency domain characteristics of the intercepted signal are obtained through Fourier transform and used as the input vector of the neural network; the residual network is reconstructed by using the advantage that the residual network can solve the problems of network degradation and gradient disappearance, and is used as a core network model for identifying individual radio frequency signals; and the number of model parameters is reduced by fixing the number of channels of each layer of network, so that the purpose of lightening the neural network is achieved. Experimental results show that compared with the ResNet18 method, the proposed method improves the individual recognition rate by about 3.8% for 30 target signals, and reduces the model size by 13 times, which can better solve the problem that the performance of model compression and recognition algorithm can not be balanced.

Keywords: residual reconstruction; RF signal individual identification; frequency domain characteristics; lightweight

0 引言

射频信号个体识别是指利用设备的硬件差异对设备进行分类识别, 又称为特定辐射源识别, 核心思想是通过对收到的射频信号进行射频指纹特征提取, 然后与已知射频指纹数据库进行对比, 判断目标类别的一种技术。通过分析射频信号的有效特征属性, 能够区分伪装目标, 识别敌我; 同时在民用的频谱管理和无线网络安全等领域也有较大的应用潜力。

射频信号预处理一般分为 3 个步骤: 信号预处理、信号特征提取和信号分类。信号预处理主要为后续处理环节提供合适的单个信号, 包含信号解译、异常点剔除、有效信号数据截取等方法; 特征提取主要基于稳态信号和暂态信号的特征提取^[1-2]; 提取的特征作为分类识别算法的输入, 实现对射频信号

的分类识别。

深度学习技术已被广泛地应用到射频信号分类识别中。徐熊^[3]提出改进型 AlexNet 的辐射源个体识别方法, 实现对广播式自动相关监视技术 (automatic dependent surveillance-broadcast, ADS-B) 单个脉冲基于卷积神经网络端到端的智能学习。叶文强等^[4]提出了基于卷积神经网络辐射源信号识别算法, 核心思想是将信号转化为时频图像, 通过卷积神经网络完成对图像的分类识别而最终达到对信号的分类识别。翁琳天然等^[5]提出基于深度残差网络的 ADS-B 信号辐射源个体识别, 采用改进残差的思想提高了射频信号的个体识别率。严科等^[6]提出基于深度学习的 ADS-B 辐射源个体识别, 采用卷积神经网络结合中心损失函数提高辐射源个体识别率。陈悦等^[7]提出基于 IQ 图特征的通信辐射源个

收稿日期: 2021-12-23; 修回日期: 2022-01-28

作者简介: 赵火军(1984—), 男, 四川人, 硕士, 高级工程师, 从事系统仿真、人工智能和目标识别等研究。E-mail: turkey-huo@163.com。

体识别，采用 IQ 信号数据转换为矩阵的方式进行分类识别，提高了个体识别率。

目前提高射频信号个体识别率主要有 2 种方法：1) 通过特征提取算法获得更好的细微特征从而提高个体识别率；2) 通过深度学习模型来提取更多的细微特征达到提高个体识别率。笔者主要针对第 2 种方法进行研究，即利用残差重构的深度学习技术对侦收的 ADS-B 信号进行个体识别，并通过固化每层通道数来减少模型参数量。仿真结果表明：该方法不仅提升了射频信号个体识别率，而且减少了模型存储资源。

1 特征提取

目前射频信号特征提取分为暂态特征和稳态特征：暂态特征是指模式变换、开关机切换和系统外部激励变换等过程，暂态信号与设备的物理层特征相关，不包含任何通信数据，可较好地体现射频信号的无意调制特征^[8-9]，提取方法主要集中在时域和频率；稳态特征是指信号发射设备在功率稳定后发射的信号部分，包括射频信号的包络、载频、相位和频率等瞬时特征。

按照特征的基本变换信息可以分为时频谱、循环谱和高阶谱等。为利于工程化实现，要求特征提取方法简单有效，易于工程实现；因此，本文中的特征提取方法集中在时频率方向，主要针对傅里叶变换和小波变换等特征变换方面进行研究。

1.1 小波变换

笔者主要利用小波变换来去除信号中的噪声^[10]，其步骤如下：1) 选择一个小波，确定小波分解的层次 M ，然后利用离散小波变换对含噪信号进行 M 层分解。由于噪声信号主要位于每层信号分解后的细节部分，因此对这些细节部分进行处理即可实现去噪。同一个信号用不同的小波基进行分解得到的去噪效果是不同的，找到合适的小波基是信号去噪的关键。2) 对第 1 层到第 M 层的每一层高频系数进行阈值化处理。3) 根据小波分解的第 M 层的低频系数和经过量化处理后的第 1 层到第 M 层的高频系数，进行信号的小波重构。

目前阈值的处理主要有硬阈值和软阈值 2 种处理方法：

硬阈值处理公式如下：

$$W_u = \begin{cases} w, & |w| \geq u \\ 0, & |w| < u \end{cases}.$$

当小波系数的绝对值大于阈值时保持不变，而小于阈值时为 0；

软阈值处理公式如下：

$$W_u = \begin{cases} [\text{sign}(w)](|w| - u), & |w| \geq u \\ 0, & |w| < u \end{cases}.$$

硬阈值方法可以较好保留信号边缘等局部特征，软阈值方法处理后的数据相对平滑，但会造成边缘模糊等失真现象；因此，针对阈值的选择需要根据最后的效果选择合适的阈值方法。

1.2 快速傅里叶变换

快速傅里叶变换是计算离散傅里叶变换 (discrete fourier transform, DFT) 的一种快速方法。该方法能减少计算离散傅里叶变换所需的乘法次数，特别是被变换的抽样点 N 越大，快速傅里叶算法计算量就越节省。

DFT 的定义如下：

$$X(k) = \sum_{n=0}^{N-1} x(n)w_N^{nk}, 0 \leq k \leq N-1.$$

式中 $w_N^{nk} = e^{-j(2\pi/N)nk}$ 为一个周期函数，其周期性和对称性可用来改进运算，提高计算效率。

笔者将 ADS-B 射频信号作为个体识别研究对象是因其为民用航空数据链，采用广播方式传播信号，易于获取；同时其自身带有地址码，可对每个 ADS-B 射频信号直接进行分类，易于制作深度学习数据集。ADS-B 信号由 8 μs 的同步头和 112 μs 的数据块信息组成。信息位中需要编码多种信息，ADS-B 在每次发射信号时，由于编码的信息不同，信息位对应的信号可能有差异；因此，仅选用前 8 μs 同步头信号作为深度学习信号片段，且前 8 μs 同步头信号不携带信息，信号特征仅受发射机影响，非常适合于信号个体分类识别。

2 基于残差重构射频信号个体识别

卷积神经网络的发展趋势是足够深、足够广。随着网络的深入，一些经典的问题也就随之出现，例如梯度弥散和梯度爆炸。这是由于随着网络层数的增加，网络中反向传播的梯度会随着连乘 (链式求导法则) 变得不稳定，变得特别大或者特别小；理论上网络越深效果越好，但实际上是深层网络并没有浅层网络效果好，这是由退化问题造成的。

何凯明团队提出的残差网络算法解决了卷积神经网络退化问题。如图 1 所示，该网络通过引入一个恒等映射实现了数据的跨层流动。




图 1 残差网络学习模块

残差网络具体定义如下：假设某段神经网络的输入是 x ，期望输出为 $H(x)$ ，如果直接将输入 x 传到输出作为初始结果，则需要学习的目标函数就是 $F(x)=H(x)-x$ ，而不是学习没有捷径连接的输出 $H(x)$ ，且前者优化比后者简单。由于传统的卷积层或全连接层在信息传递时，或多或少存在信息丢失、损耗等问题，而残差网络在某种程度上缓解了这个问题，通过直接将输入信息绕道传到输出，保护信息的完整性，整个网络只需要学习输入、输出差别的那一部分，简化了学习目标和难度。

通过对侦收的 ADS-B 信号进行具体分析，对侦收的 I、Q 2 路信号做特征提取后，直接把特征提取后的特征向量数据放入残差重构卷积神经网络进行分类^[11-12]，使其符合射频基带信号细微特征识别的特点，为辐射源个体识别工程化提供技术指导。设计的残差重构卷积神经网络架构如图 2 所示。

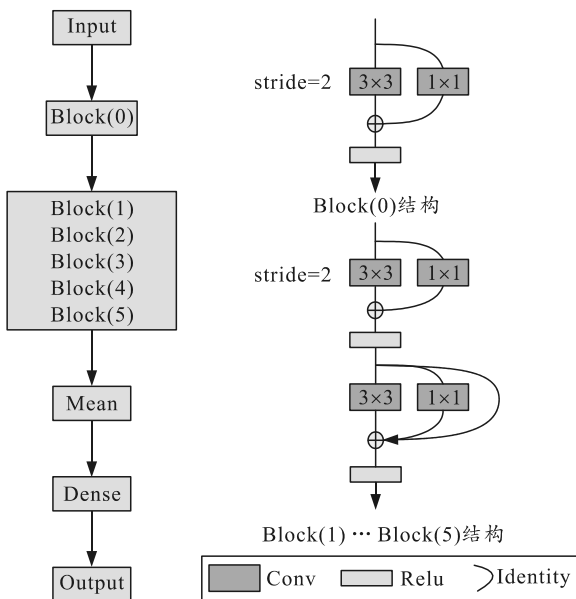


图 2 基于残差重构的卷积神经网络架构

从上图可知：残差重构卷积神经网络包含 2 种残差结构块，一种残差结构仅仅包含 1×1 卷积的残

差分支，如 Block(0)；另一种不仅包含 1×1 卷积的残差结构，而且包含 Identity 残差结构。由于残差结构具有多个分支，相当于给网络增加了多条梯度流动的路径。训练一个这样的网络，类似于训练了多个网络，并将多个网络融合在一个网络中，充分提取射频信号的细微特征。

针对 I、Q 2 路信号，侦收 ADS-B 信号的前 4 个同步头数据长度为 1 024(具体解释见 3.2 节)，经过特征提取后的特征向量的残差重构卷积神经网络具体结构如表 1 所示。

表 1 残差重构网络结构

名称	输出尺寸	卷积核	通道数	步长
Input	1 024 × 2			
Block(0)	512 × 1	3 × 2	filter0	2
Block(1)	256 × 1	3 × 1	filter0	2
		3 × 1	filter0	1
Block(2)	128 × 1	3 × 1	filter0	2
		3 × 1	filter0	1
Block(3)	64 × 1	3 × 1	filter0	2
		3 × 1	filter0	1
Block(4)	32 × 1	3 × 1	filter0	2
		3 × 1	filter0	1
Block(5)	16 × 1	3 × 1	filter1	2
		3 × 1	filter1	1
	1 × 1		Average pool	
			Class-num	

从上表可看出，残差重构卷积神经网络主要由 6 个残差块 (Block(0)~Block(5)) 组成。通道数 filter0 和 filter1 根据具体分类个数自行设计。

3 试验结果与分析

ADS-B 信号实时采集平台由实时频谱分析仪 RSA6114(频率范围 9 kHz~14 GHz)，ADS-B 接收机和天线等设备组成，实现空中真实 ADS-B 等信号的侦收，采样率设置为 150 MHz。依托 DELL TOWER 5810 的 Pytorch 开发环境，验证笔者提出的基于残差重构的射频信号个体识别方法的有效性。

3.1 实采信号

由前文可知，ADS-B 信号前 8 μs 同步头信号不携带信息，信号特征仅受发射机影响，非常适合于信号个体分类识别。重点对前 8 μs 的 4 个同步头进行射频信号的细微特征研究，后面将前 8 μs 的 4 个同步头简称为同步头信号。

ADS-B 实采信号的原始信号、同步头信号、同步头信号+FFT 变换、同步头信号+小波变换+FFT 变换如图 3—5 所示。




图 3 ADS-B 和同步头原始信号




图 4 ADS-B 同步头+FFT 变换后的频谱




图 5 ADS-B 同步头信号+小波变换+FFT 变换的频谱

3.2 仿真结果分析

针对侦收的 ADS-B 实采信号，制作深度学习数据集。数据集总共 30 类，每类 800 个，其中训练集和测试集按照 8:2 的比例分配，即训练集每类 640 个，测试集每类 160 个。由于采用 150 MHz 采样率，因此包含前 4 个同步头的采样点为 1 200 个，实际中只需要 900 个采样点就能包含前 4 个同步头信息，为方便卷积神经网络计算，最好取得数据长度为 2 的 N 次幂，即输入为 I、Q 2 路信号，每路取 1 024 个采样点。

基于 ADS-B 同步头信号，利用 BP、VGG 和 ResNet18 3 种智能分类方法进行仿真，对比如表 2 所示。

表 2 基于同步头特征的仿真结果对比

智能算法	BP	VGG(13)	VGG(16)	ResNet(18)
原始数据	0.484 8	0.600 5	0.532 6	0.654 2
FFT 特征提取数据	0.811 6	0.838 5	0.816 6	0.882 5
小波+FFT 特征提取数据	0.829 8	0.852 5	0.834 6	0.900 2

由以上分析可知，针对 ADS-B 射频信号 4 个同步头信号进行分析，采用残差网络效果最好。VGG16 的效果没有 VGG13 效果好是因为卷积层的增加产生了网络退化，即网络层数的增加并不一定会提高分类的准确率。由于最高个体识别率只有 90%，需要进一步提升个体识别率，于是基于 ADS-B 同步头信号，利用 ResNet18 和残差重构的

卷积神经网络方法进行仿真。由于特征提取最后的步骤是对 I、Q 2 路取模、归一化作为深度学习的输入；因此，残差重构输入应由表 1 的 Block(0)的卷积核大小 3×2 改为 3×1 ，通道数统一为 64。该方法称为残差重构方法 1。结果如表 3 所示。

表 3 基于同步头特征的仿真结果对比

智能算法	ResNet(18)	残差重构方法 1
原始数据	0.654 2	0.700 5
FFT 特征提取数据	0.882 5	0.916 6
小波+FFT 特征提取数据	0.900 2	0.922 5

由以上分析可知，改进的网络有大概 2% 的提升，说明残差重构的改进方法是有效的。为了易于工程化实现，使特征提取步骤高效、快速，进一步减少特征提取的步骤，将侦收的 I、Q 2 路信号进行快速傅里叶变换后，保留其 I、Q 2 路特性，不做取模操作，通道数统一为 64。该方法被称为残差重构方法 2。

数值实验结果表明：残差重构方法 2 的识别率为 93.38%，比残差重构方法 1 提高了 1%；同时，方法 2 比方法 1 减少了小波去噪的步骤，节约了整个流程的处理时间，说明残差重构方法 2 是有效的。

设计残差重构的卷积神经网络中，一般最后一层的通道数要大一些，即表 1 中 $\text{filter1} > \text{filter0}$ 。因为期望最后一层具有更丰富的特征，能提高整个网络的个体识别率；因此，针对残差重构方法 2，对网络的最后一个残差块进行了对比实验， filter0 固定为 64，仿真结果如表 4 所示。

表 4 基于不同通道数仿真结果对比

filter1	残差重构方法 2
64	0.933 8
128	0.938 6
256	0.934 5

由以上分析可知，通道数并没有随着通道数的增加而增加，通道数 filter0 取 64，通道数 filter1 取 128 能够达到 ADS-B 射频信号的最好分类准确率。由于通道数固定，模型参数也大大减少，模型存储大小仅为 3.4 M，而 ResNet18 模型存储大小为 44.6 M，降低了约 13 倍，从而达到了轻量化的目的。

4 结束语

笔者结合快速傅里叶变换高效和易实现的优势，提出一种基于残差重构的射频信号个体识别方法。通过对侦收的 ADS-B 的 I、Q 2 路信号直接进

行快速傅里叶变换(不取模，保留 I、Q 2 路信号频域特征)，变换后的信号直接送入残差重构的卷积神经网络；同时对网络中的通道数进行固化，减少网络中每层的参数量。仿真结果表明：相对于 BP、VGG 和 ResNet18 等常见网络分类方法，笔者提出的新方法不仅能够有效地识别射频信号的细微特征，提高射频信号个体识别率，与 ResNet18 相比个体识别率提高了约 3.8%；而且能在满足精度的同时减少参数量，与 ResNet18 相比存储资源约降低 13 倍，达到了轻量化的目的，有利于工程化实现。

参考文献：

- [1] 郑娜娥, 王盛, 张靖志. 基于射频指纹的辐射源个体识别技术综述[J]. 信息工程大学学报, 2020, 21(3): 285-289.
- [2] 孙丽婷, 黄知涛, 王翔, 等. 辐射源指纹特征提取方法述评[J]. 雷达学报, 2020, 9(6): 1014-1031.
- [3] 徐熊. 采用改进型 AlexNet 的辐射源目标个体识别方法[J]. 电讯技术, 2018, 58(6): 625-630.
- [4] 叶文强, 俞志富, 王虎帮, 等. 基于卷积神经网络辐射源信号识别算法[J]. 计算机仿真, 2019, 36(9): 33-37.
- [5] 翁琳天然, 彭进霖, 何元, 等. 基于深度残差网络的 ADS-B 信号辐射源个体识别[J/OL]. 航空兵器, 2021, 28.
- [6] 严科, 谢焯. 基于深度学习的 ADS-B 辐射源个体识别[J]. 信息技术, 2021(2): 120-125.
- [7] 陈悦, 雷迎科, 李昕, 等. 基于 IQ 图特征的通信辐射源个体识别[J]. 信号处理, 2021, 37(1): 120-125.
- [8] DANEV B, CAPKUN S. Transient-based identification of wireless sensor nodes[C]. 2009 International Conference on Information Processing in Sensor Networks, San Francisco, USA, 2009: 25-36.
- [9] YUAN Y J, HUANG Z T, WU H, et al. Specific emitter identification based on Hilbert-Huang transform-based time-frequency-energy distribution features[J]. IET Communications, 2014, 8(13): 2404-2412.
- [10] 张鹏, 谢艳, 魏志. 一种基于新阈值函数的小波降噪方法在高速风洞中的应用[J]. 兵工自动化, 2016, 35(4): 52-55.
- [11] TIMOTHY J, ROY T, CLANCY T C. Over the Air Deep Learning Based Radio Signal Classification[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1): 168-179.
- [12] DING X H, ZHANG X Y, MA N N, et al. RepVGG: Making VGG-style ConvNets Great Again[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021.