

基于射频指纹的卫星测控地面站身份识别方法

唐晓刚^{*①} 冯俊豪^① 张斌权^① 邰浩^② 任彦洁^① 李海滨^①

^①(航天工程大学信息学院 北京 101407)

^②(北京理工大学信息与电子学院 北京 100081)

摘要: 传统卫星测控通常采用加密认证安全机制, 存在身份假冒、欺骗等安全问题, 该文提出一种基于射频指纹的卫星测控地面站身份识别方法, 并设计了一种面向星载平台的轻量化卷积神经网络。该网络首先使用IQ方向上的卷积层提取IQ信号相关特征, 将2维数据降成了1维, 再使用时序方向上的多层卷积提取信号的时域结构特征, 之后使用最大池化层降低数据维度, 在充分利用IQ信号中包含的原始特征信息的同时减小计算量, 最后经过两层全连接层进行分类, 实现对卫星测控地面站身份识别。仿真实验表明, 该方法对21台发射机个体的平均准确率为93.8%, 较传统的支持向量机方法提高了39.8%, 较DLRF网络模型、ORACLE网络模型分别提高了11.5%, 29.8%, 且具有鲁棒性强、轻量化的优点。该文所提方法对于提高卫星测控链路安全性具有一定的理论参考和工程应用价值。

关键词: 测控安全; 射频指纹; 身份识别; 深度学习

中图分类号: TN975

文献标识码: A

文章编号: 1009-5896(2023)07-2554-07

DOI: 10.11999/JEIT220804

Satellite Telemetry Track and Command Ground Station Identification Method Based on RF Fingerprint

TANG Xiaogang^① FENG Junhao^① ZHANG Binqun^① HUAN Hao^②
REN Yanjie^① LI Haibin^①

^①(School of Aerospace Information, Space Engineering University, Beijing 101407, China)

^②(School of Information and Electronics, Beijing Institute of Technology, Beijing 100081, China)

Abstract: Encryption authentication is generally adopted to ensure the security of traditional satellite Telemetry Track and Command (TT&C). However, several security limitations remain to be improved such as identity counterfeiting and deception. A satellite TT&C ground station identity recognition method via radio frequency fingerprint is presented, and a lightweight convolutional neural network for satellite platforms is designed. Relevant features of the IQ signal are extracted through the convolution layer in the IQ direction, which converts the two-dimensional data to one dimension. The time-domain structural features of the signal are extracted by using the multi-layer convolution in the time-series direction. Then a maximum pooling layer is developed to reduce the data dimension, ensuring that the original feature information contained in the IQ signal is fully utilized and the computation burden is reduced. Finally, the identification of the satellite TT&C ground station is realized by two full connection layers. Simulation experiments show that the average accuracy of the proposed method for 21 transmitters is 93.8%, which is 39.8% higher than the traditional support vector machine method, 11.5% higher than the DLRF network model, and 29.8% higher than the Oracle network model. And the results indicate that the proposed method is robust and requires less computation, which shows the theoretical references and engineering application value for improving the security of the satellite TT&C link.

Key words: Telemetry Track and Command (TT&C) security; RF fingerprinting; Identity recognition; Deep learning

收稿日期: 2022-06-17; 改回日期: 2022-09-13; 网络出版: 2022-10-14

*通信作者: 唐晓刚 titantxg@163.com

基金项目: 国家自然科学基金(62027801)

Foundation Item: The National Natural Science Foundation of China (62027801)

1 引言

卫星通信具有通信距离远、覆盖范围广等优势，被广泛应用于民事和军事领域^[1]。但其测控信号的信道具有开放性的特点，易被电子侦察截获，存在假冒身份、欺骗等安全问题。通常卫星测控安全采用加密的身份认证机制，但随着大数据和人工智能的飞速发展，密码破译难度越来越小，存在着安全风险^[2,3]。

无线通信设备电子元器件在生产过程中的容差会导致不同发射器产生的信号具有细微的差别，这些细微的差别就形成了信号的“指纹”特征。射频指纹识别技术就是检测和识别出无线电信号中所独有的、不可伪造的信号“指纹”特征，能够识别特定发射器，是一种基于设备物理层硬件的非密码认证方法。与加密认证相比，它具有认证速度快、兼容性好等优点^[4]。传统的射频指纹识别方法需要先人工选择特征，再设计分类器，需要一定的专家领域知识，且受环境影响较大。深度学习的方法可将提取特征和分类识别结合到一起，无需人工选择特征，实现端到端的身份识别，也可结合变换域、星座图等特征进行识别，可有效避免传统方法在面对复杂环境时识别率低的问题^[5]。

文献[6]利用信号的双谱特征结合卷积神经网络进行识别，效果优于传统的基于Hilbert-Huang变换等方法；文献[7]将原始的IQ信号变换成差分轮廓星图，再利用深度卷积神经网络进行图像识别，对20台WiFi network设备进行识别实验，准确率达到了98.6%；文献[8]直接将原始IQ基带信号送入1维卷积神经网络进行识别，在信噪比为40 dB下达到了91.38%的准确率；文献[9]同样用原始IQ信号作为输入，对于16台USRP设备具有99%的识别准确率。但这些方法都旨在提高算法的识别准确率，忽视了模型大小和计算复杂度，其网络结构参数过多，运算复杂。

考虑到星载平台计算存储能力有限，本文提出了一种轻量化的卷积神经网络。首先使用原始IQ

信号作为输入，减小变化所需的计算量，提取IQ相关特征和时域结构特征，再通过优化网络模型、使用最大池化层降维减小参数数量和算法复杂度，同时兼顾识别准确率和模型鲁棒性，仿真实验表明，所提网络具有识别准确率高、轻量化且鲁棒性强的优点，可用于对测控信号进行身份识别。

2 射频指纹特征分析

测控信号是地面站发射出的无线信号，如图1是一个简化的IQ正交调制发射机模型，基带信号经过数字信号处理后进入数模转换模块，经过滤波、上变频，最后由功率放大器将信号发送到天线发射出去。发射机中电子元器件在生产过程中的容差会导致不同的无线通信设备产生的信号具有细微的差别，即使是同一厂家同一型号的无线通信设备也会因为容差效应存在一定程度的差异，包括功放的非线性、滤波的失真以及振荡器的频偏等，这些差异并不影响所传输的信息内容，但却附加在信号上形成了每个信号独有的特征，即射频指纹，本文将根据正交调制器的模型分析调制器带来的差异。

使用的调制方式不同其调制模型也会不同，即使是相同的调制方式，调制器硬件的细微差别也会有所不同。对于正交调制器而言，往往由于I路和Q路增益不平衡、相位不平衡和延时不平衡等引入非线性畸变^[10,11]。

数字信号经过基带滤波成型后将分成I/Q两路信号，原编码序列分别用 $c_I(t)$ 和 $c_Q(t)$ 表示，其表达式分别为

$$I(t) = \sum_{n=-\infty}^{+\infty} c_I(t)g\left(t - kT + \frac{\tau}{2}\right) + I_0 \quad (1)$$

$$Q(t) = \sum_{n=-\infty}^{+\infty} c_Q(t)g\left(t - kT + \frac{\tau}{2}\right) + Q_0 \quad (2)$$

其中， $g(t)$ 表示滤波器函数， τ 表示I/Q延时不平衡带来的误差， I_0 和 Q_0 分别为I和Q路的偏置，即载波




图1 IQ正交调制发射机模型

泄露, T 为数模转换的周期。信号经过正交调制后, 其输出信号可以表示为

$$x(t) = I(t)G_0 \left(1 - \frac{\Delta}{2}\right) \cos\left(w_0 t - \frac{\varepsilon}{2}\right) + Q(t)G_0 \left(1 + \frac{\Delta}{2}\right) \sin\left(w_0 t + \frac{\varepsilon}{2}\right) \quad (3)$$

其中, G_0 表示基本增益, Δ 和 ε 分别表示增益不平衡参数和I/Q两路相位不平衡参数, w_0 则表示载波频率。调制器所带来的差异表现在星座图上为星座点偏离理论值。以简单的单边带调制为例, 令 $G_0 = 1$, $I(t) = 2 \sin w_1 t$, $Q(t) = 2 \cos w_1 t$, w_1 是信号频率, 则

$$x(t) = 2 \sin w_1 t \left(1 - \frac{\Delta}{2}\right) \cos\left(w_0 t - \frac{\varepsilon}{2}\right) + 2 \cos w_1 t \left(1 + \frac{\Delta}{2}\right) \sin\left(w_0 t + \frac{\varepsilon}{2}\right) = A_1 \sin(w_2 t + a) + A_2 \sin(w_2 t + b) \quad (4)$$

其中, $w_2 = w_0 + w_1$

$$A_1 = \sqrt{4 \cos^2\left(\frac{\varepsilon}{2}\right) + \Delta^2 \sin^2\left(\frac{\varepsilon}{2}\right)} \quad (5)$$

$$A_2 = \sqrt{4 \sin^2\left(\frac{\varepsilon}{2}\right) + \Delta^2 \cos^2\left(\frac{\varepsilon}{2}\right)} \quad (6)$$

$$a = \arctan\left[\frac{\Delta}{2} \tan\left(\frac{\varepsilon}{2}\right)\right] \quad (7)$$

$$b = \arctan\left[\frac{2}{\Delta} \tan\left(\frac{\varepsilon}{2}\right)\right] \quad (8)$$

定义边带拒绝(Sideband Rejection, SBR)为不需要的信号功率与期望信号功率比

$$\text{SBR}_{(\text{dB})} = 10 \lg \frac{A_2^2}{A_1^2} \quad (9)$$

理想条件下, SBR对星座图误差向量幅度(Error Vector Magnitude, EVM)的影响可以定义为

$$\text{EVM} = 10^{\frac{\text{SBR}}{20}} \quad (10)$$

如图2所示, EVM反映了实际星座点与理论星座点的偏移程度, 不同调制器的差异所带来的幅

度误差和相位误差必定是不同的, 因此IQ基带信号包含的幅度、相位的相关信息可作为射频指纹。

3 轻量化卷积神经网络结构设计

目前用于射频指纹识别的卷积神经网络大多基于改进的AlexNet^[12]等计算机视觉领域的经典网络, 图像一般表示为 $M \times M$, 具有各向同性的性质, 而信号的表示方式一般为 $N \times 2$ 格式, N 代表时间序列, 2代表原始IQ信号的实部和虚部, 无法如图像般进行对称操作。因此通常会将信号变换成特征图谱以提高识别准确率, 但这增加了额外计算量, 经过网络中的数据压平(Flatten)操作, 送入全连接层分类, 又增加了大量参数, 而用于直接处理IQ信号的1维网络结构忽视了信号之间的相位信息。

本文是以IQ信号作为基本处理单元, 针对星载平台计算存储能力有限的特点设计了一种轻量化的卷积神经网络结构(RFFI), 如图3所示, 设计模型的思路为首先对2维的IQ原始数据进行降维, 使用5层卷积以提高特征提取能力, 中间使用最大池化层降低维数, 最后使用两层神经元个数少的全连接层实现识别, 同时使用32通道以减小计算量。从特征提取角度来说即先构造IQ信号方向上的卷积核提取相关特征, 再使用1维卷积提取时域结构特征, 最后通过多层次的特征提取充分利用IQ信号的相关信息实现识别。

在特征提取阶段, 输入的信号格式为 $N \times 2$ 的形




图2 EVM示意图




图3 RFFI网络结构模型

式，首先利用(1, 2)的卷积核提取IQ方向上的相关特征，同时将2维数据降维成1维，减小后续时域卷积的计算量，在使用5层(7, 1)的卷积核提取时序方向上的时域结构特征，在保证提取足够时域结构特征的前提下提高特征提取能力，之后使用卷积核和步长均为(2, 1)的最大池化层减小数据维数，并使用批标准化(Batch Normalization, BN)增加模型的泛化能力和加快收敛速度，通过这种多层次的特征提取，充分利用IQ信号信息的同时，还减少了计算量。

在分类阶段，RFFI使用了2层全连接层作为分类器，但由于之前用了最大池化层降维，这里的全连接层神经元个数大幅度减少，在保证特征非线性映射能力的同时降低计算量，为了避免过拟合现象，全连接层之间使用了50%的Dropout层，最后使用Softmax函数输出结果，输出为 L 个类别，编号是0至 $L-1$ 。

此外卷积层之间的激活函数使用ReLU，使用Adam优化器训练网络的权值，初始学习率为0.001，使用交叉熵作为损失函数，实验迭代训练30次，每训练1轮验证1次，参数的选择来源于实验验证的结果。

4 实验结果与分析

本文的实验平台为CentOS Linux release 7.9.2009 (Core)操作系统，CPU为Intel(R) Xeon(R) Gold 5218 CPU @ 2.30 GHz，使用的GPU为NVIDIA A30, CUDA版本为11.4，编程语言为Python3.8.5，深度学习架构为Pytorch1.10.0。

4.1 FIT/Corte Xlab数据集

为仿真复杂的测控信道环境和信号接收处理方法，本文所使用的是FIT/Corte Xlab数据集^[13]，数据是以接收机采样接收到的原始IQ数据流的格式存储，这和测控终端使用数字接收机接收的信号格式是一致的，其仿真接收的信号中包含变功率发射的信号，这能够很好地模拟因距离和环境干扰对测控信号所造成的影响，多种信道类型可模拟复杂的电磁信道环境。

FIT/Corte Xlab数据集由22台NI USRP N2932 SDR设备生成，其中21台为发射器、1台用作接收器，通信频点为433 MHz，采样速率为5M Sample/s，所有发射器都使用相同的频带。

数据集中发送的数据类型有3种，一是QPSK调制位的固定序列：发射器发送完全相同的802.15.4序言的位序列，以下称为固定包；二是QPSK随机调制位序列：发射器产生随机的位序列，称为随机

包；三是噪声序列：噪声源随机均匀产生的位序列，称为噪声包。

发送到数据信道类型包括两种：固定功率：所有发射器以相同的振幅发送；变化功率：发射器以变化的振幅发送，模拟每个发射器的路径损失变化，其中变功率信号的信噪比变化范围为9~14 dB。

机器人干扰：有效载荷的发送方式为固定包，在场景中引入一辆遥控车，用金属板覆盖以增加无线电波的反射，在房间内随机移动形成干扰。此外还有一把金属椅子静止放置，引入了新反射来随机化多路径参数。

本文使用了10个场景下的数据集，表1列出了所使用的各个场景的数据类型、发射功率和信道类型，以此设计了两组实验，场景1—场景6为1组，训练和测试都来自同一组，比较不同方法的准确性；场景7—场景10为1组，训练和测试在不同的场景，在场景7中训练在场景8中测试，在场景9中训练在场景10中测试，比较不同方法的鲁棒性。

4.2 数据预处理

在实验过程中需对信号进行一定的处理才能送入识别网络，本文采取的预处理方式如下：

(1)数据归一化处理，加快模型求解速度；

(2)对数据进行截取，对归一化的IQ两路数据，每隔一定数目的采样点(即 N 个点)作为一个数据样本进行截取，如图4所示，本文取 $N=600$ ，以原作者的截取方式能够更好地进行对比实验；

表1 数据集说明

场景	数据类型	发射功率	干扰
1	固定包	固定	无
2	随机包	固定	无
3	噪声包	固定	无
4	固定包	变化	无
5	随机包	变化	无
6	噪声包	变化	无
7	固定包	变化	无
8	固定包	变化	金属椅干扰
9	固定包	变化	机器人干扰
10	固定包	变化	机器人+金属椅干扰




图4 信号截取片段示意图

(3)把截取的IQ两路1维数据按对应的时间段合成2维矩阵,送入识别模型。在训练过程中把每个样本打上标签,合成数据集,按照6:2:2的比例随机划分为训练集、验证集和测试集。

4.3 识别方法

4.3.1 深度学习方法

为了对比本文所提出的网络结构的优势,选取了DLRF^[8]和ORACLE^[9]两种典型的卷积神经网络模型进行比较,验证模型性能。

DLRF网络由3个卷积层和3个全连接层组成,卷积核分别是(19, 1), (15, 1)和(11, 1),通道数分别为128, 32和16,层间使用核大小和步长都是(2, 1)的最大池化层,3个全连接层的神经元个数分别为128, 16和21,使用50%的Dropout层,激活函数为ELU,分类函数为Softmax。

ORACLE模型由两个卷积层和两个全连接层组成,卷积核分别为(7, 1), (7, 2),通道数为50,全连接层的神经元个数为256和80,激活函数为ReLU,还使用50%的Dropout层避免过拟合,分类函数使用Softmax。

采用Pytorch的torchstat库计算卷积网络结构的各种参数,本文提供了3个指标:参数、浮点操作计算量(FLOPs)以及内存使用量。

在参数上,本文所提出的RFFI网络结构具有最少的参数,参数量是ORACLE的0.7%,是DLRF的26.9%,FLOPs是指浮点运算的次数,用来衡量在不同设备上训练模型的复杂性,对比3个网络,ORACLE和DLRF分别是RFFI计算量的2.4倍、3.3倍,第3个是存储量方面,RFFI占用的内存读写使用量同样最小。各网络模型的参数如表2所示。

对比另外两个网络结构,本文所提出的网络结构无论是参数上、计算量上还是内存使用量上均具有明显的优势,更加的轻量化。

4.3.2 传统人工特征方法

使用文献[14]中方法,将功率谱密度作为信号的特征向量,用支持向量机(Support Vector Machine, SVM)分类器进行分类识别,作为传统人工特征方法的代表。

SVM常用于二分类问题,处理多分类问题时,可通过修改目标函数、将多个分类面的参数求解合并到一个最优化问题中实现多分类,或组合多个二分类器实现多分类器的构造。文中使用sklearn库中封装的SVM函数实现多分类,SVM分类器使用默认高斯核函数,系数为0.05,最大迭代次数200。

4.4 实验结果

采用识别准确率(Accuracy)对网络模型的识别

性能进行评估,对于二分类的问题,根据预测值和真实值的结果,可将整个样本集划分为真正例(True Positive, TP)、伪正例(False Positive, FP)、真反例(True Negative, TN)和伪反例(False Negative, FN),其中 $\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN})$,即所有正确分类的样本数与全体样本数的比例。

4.4.1 RFFI模型性能验证

为验证本文模型的性能,使用场景4中的变功率固定包来进行训练、验证和测试,比较了卷积核尺寸、卷积层数量和卷积核数量对模型识别性能的影响。

表3展示了卷积核尺寸对模型性能的影响,先固定卷积层数为5层和卷积核数为32的情况下,比较卷积核分别为(3, 1), (5, 1), (7, 1)和(9, 1)的识别准确率。根据结果可知,增大卷积核会使得识别准确率有所增加,但大卷积核也会带来明显的参数量和计算量增加,导致模型较大,本文在选取卷积核时考虑了高识别率和轻量化的要求,因此取(7, 1)的卷积核。

表4是卷积层数对网络性能的影响,固定卷积核大小和卷积核数量,比较卷积层数为1, 3, 5和7时的识别准确率,大体来看增加卷积层数能够提高识别准确率,在综合识别准确率、参数量和计算量来说,5层的卷积是性价比最高的,参数量会减小是因为卷积层数多了所带来的最大池化层降维次数也多了,输入全连接层的数据也就小了。

表 2 网络模型各参数比较

名称	Params	Flops(M)	MemR+W(MB)
DLRF	205 495	20.96	2.42
ORACLE	7 584 367	28.72	30.3
RFFI	55 445	8.59	1.65

表 3 卷积核尺寸对模型性能的影响

卷积核尺寸	识别准确率(%)	参数量	Flops(M)
(3, 1)	94.9	34 965	3.83
(5, 1)	97.1	45 205	6.21
(7, 1)	97.5	55 445	8.59
(9, 1)	97.9	65 685	10.97

表 4 卷积层数对模型性能的影响

卷积层数	识别准确率(%)	参数量	Flops(M)
1	89.9	315 285	4.78
3	96.2	99 349	7.83
5	97.5	55 445	8.59
7	97.2	55 573	8.78

表5是卷积核数量对模型性能的影响, 固定卷积核尺寸为(7, 1)、卷积层数为5层, 比较卷积核数量分别为16, 32, 64和128时的识别准确率。增加卷积核数量会在一定程度上增加识别准确率, 同时参数和计算量也会大幅增加, 综合来看卷积核数为32时, 识别准确率较高而参数和计算量较小。

4.4.2 准确率比较

图5展示了不同场景下的识别效果, 即发送包类型与功率是否变化对识别准确率的影响, 在这些场景中没有其他干扰影响, RFFI, DLRF, ORACLE和SVM模型的平均识别率分别为93.8%, 82.3%, 64%, 54%, 由结果可知, 本文的RFFI模型在各个场景下均高于ORACLE, DLRF模型, 说明通过增加IQ相关特征提取能够使RFFI模型提高识别准确率。与传统的SVM方法相比, 深度学习的方法明显有着更好的识别效果, 而本文所提的RFFI网络结构在各种场景下均具有最高的识别准确率, 说明本文方法的优越性。

图5中横坐标为实验场景编号, 数据类型依次为固定功率固定包、固定功率随机包、固定功率噪声包、变功率固定包、变功率随机包以及变功率噪声包。

实验选取了3种深度学习模型的训练和推理时间进行对比, 并选取场景4的数据集作为对比的代表, 其中, 算法推理时间的实验主要关注不同模型推理过程所需要的时间, 使用的是测试样本。表6展示的是在场景4中数据集的训练时间和推理时间, 可知RFFI的训练时间少于另外两种网络模型, 时间最短。同时对比了3种模型的推理时间, RFFI模型

表 5 卷积核数量对模型性能的影响

卷积核数量	识别准确率(%)	参数量	Flops(M)
16	94.7	19 125	2.21
32	97.5	55 445	8.59
64	98.7	181 845	33.84
128	97.7	649 685	134.32




图 5 不同发送数据类型与功率变化对识别准确率的影响

的推理时间明显少于DLRF和ORACLE模型, 说明RFFI模型运行速度更快, 更有利于星载平台的部署。

4.4.3 鲁棒性比较

鲁棒性测试是在一种场景下训练模型, 然后增加信道干扰后, 测试模型对信道干扰的鲁棒性。选取了两种方案测试模型的鲁棒性: 一是在干扰的条件下(场景7)训练, 在增加一把静止放置的金属椅子的场景下(场景8)测试; 二是在有机器人干扰场景下(场景9)训练, 在这个场景基础上再静止放置一个金属椅子(场景10), 用来测试。两个实验中所发射的信号都是变功率的固定包, 验证各个方法对路径变化的鲁棒性。

图6显示了各个方法在不同场景下训练和测试的准确率, 增加干扰会使模型的识别准确率下降, 模型的鲁棒性越强, 则下降幅度越小。结果表明RFFI模型无论在训练场景下还是测试场景下都有着最高的识别准确率, 而且模型的鲁棒性优于另外ORACLE, DLRF两种网络结构和传统的SVM方法。说明本文所提的RFFI模型较ORACLE模型而言, 使用5层卷积层提高了特征提取能力, 而批标准化层(BN)的使用能够增加模型的鲁棒性, 因此有着更好的效果。

图6的横坐标为实验场景, 数据类型为变功率固定包, 干扰方式分别为无干扰、金属椅干扰、机器人干扰以及金属椅和机器人干扰, 训练的两种场景分别为场景7和场景9, 测试的两种场景分别为场景8和场景10。

5 结束语

本文提出了一种利用射频指纹识别测控地面站身份的方法, 并通过轻量化的卷积神经网络对仿真

表 6 运行时间对比(s)

	RFFI	DLRF	ORACLE
训练时间	740	786	2091
推理时间	9.1	12.9	15.5




图 6 不同方法的鲁棒性比较

的信号进行了识别验证。相比于为了传统加密认证方法,通过本文提出的物理层认证个体识别方法能从本质上提高卫星测控的安全性。通过仿真实验表明,本文的轻量化RFFI模型的平均识别准确率为93.8%,优于现有的其他深度学习方法和传统的SVM方法,且有着较强的鲁棒性,在卫星终端部署方面具有一定的前景。

参 考 文 献

- [1] 宋宇飞, 周文辉, 刘建东, 等. 基于零信任的卫星互联网安全防护研究[J]. 天地一体化信息网络, 2021, 2(3): 15–23. doi: 10.11959/j.issn.2096-8930.2021027.
- [2] WANG Gang, SHEN Dan, CHEN Genshe, *et al.* SATCOM link adaptive configuration design in radio frequency interference environment[C]. 2017 IEEE Aerospace Conference, Big Sky, USA, 2017: 1–8. doi: 10.1109/AERO.2017.7943820.
- [3] 崔天舒, 赵文杰, 黄永辉, 等. 基于射频指纹的测控地面站身份识别方法[J]. 航天电子对抗, 2021, 37(3): 6–9, 23. doi: 10.3969/j.issn.1673-2421.2021.03.002.
- [4] CUI Tianshu, ZHAO Wenjie, HUANG Yonghui, *et al.* Radio frequency fingerprint-based TT&C ground station identification method[J]. *Aerospace Electronic Warfare*, 2021, 37(3): 6–9, 23. doi: 10.3969/j.issn.1673-2421.2021.03.002.
- [5] WANG Xianbin, HAO Peng, and HANZO L. Physical-layer authentication for wireless security enhancement: Current challenges and future developments[J]. *IEEE Communications Magazine*, 2016, 54(6): 152–158. doi: 10.1109/MCOM.2016.7498103.
- [6] 张振, 贾济铖, 康健, 等. 射频指纹识别技术方法综述[J]. 无线电通信技术, 2021, 47(3): 249–258. doi: 10.3969/j.issn.1003-3114.2021.03.001.
- [7] ZHANG Zhen, JIA Jicheng, KANG Jian, *et al.* Overview of RF fingerprint identification technology methods[J]. *Radio Communications Technology*, 2021, 47(3): 249–258. doi: 10.3969/j.issn.1003-3114.2021.03.001.
- [8] DING Lida, WANG Shilian, WANG Fanggang, *et al.* Specific emitter identification via convolutional neural networks[J]. *IEEE Communications Letters*, 2018, 22(12): 2591–2594. doi: 10.1109/LCOMM.2018.2871465.
- [9] LI Jingchao, YING Yulong, JI Chunlei, *et al.* Differential contour stellar-based radio frequency fingerprint identification for Internet of things[J]. *IEEE Access*, 2021, 9: 53745–53753. doi: 10.1109/ACCESS.2021.3071352.
- [10] MERCHANT K, REVAY S, STANTCHEV G, *et al.* Deep learning for RF device fingerprinting in cognitive communication networks[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 160–167. doi: 10.1109/JSTSP.2018.2796446.
- [11] SANKHE K, BELGIOVINE M, ZHOU Fan, *et al.* ORACLE: Optimized radio classification through convolutional neural networks[C]. IEEE INFOCOM 2019–IEEE Conference on Computer Communications, Paris, France, 2019: 370–378. doi: 10.1109/INFOCOM.2019.8737463.
- [12] 贾永强. 通信辐射源个体识别技术研究[D]. [博士学位], 电子科技大学, 2017.
- [13] JIA Yongqiang. The research on communication emitters identification technology[D]. [Ph. D. dissertation], University of Electronic Science and Technology of China, 2017.
- [14] 王培. 基于稳态信号的射频指纹算法的研究[D]. [硕士学位论文], 电子科技大学, 2020.
- [15] WANG Pei. Research on RF fingerprint algorithm based on steady state signal[D]. [Master dissertation], University of Electronic Science and Technology of China, 2020.
- [16] KRIZHEVSKY A, SUTSKEVER I, and HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84–90. doi: 10.1145/3065386.
- [17] MORIN C, CARDOSO L S, HOYDIS J, *et al.* Transmitter classification with supervised deep learning[C]. The 14th International Conference on Cognitive Radio Oriented Wireless Networks, Poznan, Poland, 2019: 73–86. doi: 10.1007/978-3-030-25748-4_6.
- [18] ZHANG Jingbo, WANG Qingwen, GUO Xiaochen, *et al.* Radio frequency fingerprint identification based on logarithmic power cosine spectrum[J]. *IEEE Access*, 2022, 10: 79165–79179. doi: 10.1109/ACCESS.2022.3194124.

唐晓刚: 男, 副教授, 研究方向为人工智能、射频指纹识别。

冯俊豪: 男, 硕士生, 研究方向为射频指纹识别。

张斌权: 男, 博士, 研究方向为智能信息处理与机器人。

郇 浩: 男, 副教授, 研究方向为分数阶傅里叶变换及其在雷达信号处理中的应用。

任彦洁: 女, 硕士生, 研究方向为通信信号调制识别。

李海滨: 男, 硕士生, 研究方向为空间信息应用。

责任编辑: 马秀强