

文章编号: 2095-4980(2022)05-0458-06

## 基于星座图和卷积神经网络的射频指纹识别

刘鑫尧, 秋勇涛, 皇甫雅帆, 刘友江\*

(中国工程物理研究院 电子工程研究所, 四川 绵阳 621999)

**摘要:** 基于无线设备物理层的射频指纹识别是保障通信安全的有效途径。传统射频特征提取方法容易受到信道的信噪比变化的干扰, 难以适应动态信噪比下的通信场景。因此, 本文提出了一种基于卷积神经网络的射频指纹识别方法, 实现了动态信噪比下的射频指纹识别, 显著改善了低信噪比下的识别准确率。本文通过搭建实验系统对 4 台不同功放设备进行识别, 实验结果表明, 在信噪比为 0.5~14.5 dB 范围内, 该方法的综合识别率达 89.4%。

**关键词:** 卷积神经网络; 深度学习; 功放非线性; 射频指纹

中图分类号: TN510.5015

文献标志码: A

doi: 10.11805/TKYDA2020091

## Radio frequency fingerprint identification based on constellation and convolutional neural network

LIU Xinyao, QIU Yongtao, HUANGFU Yafan, LIU Youjiang\*

(Institute of Electronic Engineering, China Academy of Engineering Physics, Mianyang Sichuan 621999, China)

**Abstract:** Radio Frequency(RF) fingerprinting identification based on the physical layer of wireless devices is an effective way to ensure communication security. The conventional RF feature extraction methods are susceptible to interference from changes in the Signal-to-Noise Ratio(SNR) of the channel, which are not suitable to dynamic SNR communication situation. A RF fingerprint identification method based on Convolutional Neural Network(CNN) is proposed, which could fulfill RF fingerprinting identification under dynamic SNR condition and significantly improve the recognition rate under low SNR condition. In addition, the experiments are implemented to identify four different power amplifier devices. The experimental results show that the comprehensive recognition rate of the proposed method is 89.4% under dynamic SNR of 0.5~14.5 dB.

**Keywords:** Convolutional Neural Network; deep learning; Power Amplifier(PA) nonlinearity; RF fingerprint

无线通信在民用和军事两方面发挥着越来越重要的作用, 同时也为各行各业的发展带来了积极影响。然而, 无线网络本身固有的开放性使得无线网络相较于有线网络更容易受到恶意攻击, 并且无线通信设备的数量激增, 使得如何保障无线通信安全已经成为亟待解决的问题<sup>[1]</sup>。射频指纹识别是保障无线通信安全的一种可行方法<sup>[2-3]</sup>。传统的射频指纹识别分为特征提取和分类识别两个部分。特征提取分为瞬态特征和稳态特征两个大类。瞬态特征是无线设备开启或关闭的瞬间信号的起伏变化, 它与发射的内容无关, 只与发射机本身有关。瞬态特征中, 文献[4]中提取的特征是小波变换的系数, 文献[5]提取了复包络的瞬时幅度、相位和频率。由于瞬态信号有持续时间很短, 信号很难被捕获等缺点, 研究重点逐渐转向稳态特征。在提取稳态特征的文献中, 文献[6]中提取了前导信号的功率谱密度, 文献[7]提取了调制信号的频偏、前导相关、I/Q 偏移、幅度误差和相位误差。分类识别主要是采用机器学习算法。文献[8]采用的最近邻算法, 文献[9]采用了 K 均值算法, 文献[10]采用了支持向量机算法。由于卷积神经网络在图像识别等方面取得了巨大成功, 2018 年, 文献[3,11-13]均采用卷积神经网络进行射频指纹识别, 避免了人为提取特征这个繁琐的过程。本文在前人的基础上, 改变了数据预处理方式和卷积神经网络的结构, 既是一种相对独立的射频指纹识别方法, 也是对基于卷积神经网络方法的补充。

收稿日期: 2020-03-08; 修回日期: 2020-08-17

\*通信作者: 刘友江 email:lyj04@163.com

## 1 射频指纹技术研究

### 1.1 射频指纹产生

产生射频指纹的主要原因是设备的容差，即设备的材料和加工工艺误差等原因导致不同电子元器件的电参数与标称值存在一定差别。文献[3]指出，在发射机中，混频器引起的 I/Q 不平衡和相位噪声、晶体振荡器引起的载波频率和相位偏移、数模转换器的非线性引起的谐波失真以及功率放大器的非线性失真是射频指纹产生的主要原因。本文将主要针对发射机中的功放非线性特征进行识别。

### 1.2 卷积神经网络参数传播

如图 2 所示， $W_{ij}^{(l)}$  表示第  $l$  个神经网络层的第  $j$  个神经节点与第  $l+1$  神经网络层的第  $i$  个神经节点之间的连接参数，即连接线所代表的权值， $b_i^{(l)}$  是第  $l+1$  个神经网络层的第  $i$  个神经节点的偏置项。 $a_i^{(l)}$  表示第  $l$  层神经网络层的第  $i$  个神经节点的输出值。 $(W, b)$  为神经网络需要学习的参数，式(1)~式(4)为卷积神经网络的前向传播，神经元的输入是由前面网络层的神经元的输出的线性组合得到。




Fig.1 Block diagram of RF front-end for radio communication system  
图1 无线通信系统射频前端框图




Fig.2 Structure of simple neural network  
图2 简单神经网络结构图

$$a_1^{(2)} = f(W_{11}^{(1)}x_1 + W_{12}^{(1)}x_2 + W_{13}^{(1)}x_3 + b_1^{(1)}) \tag{1}$$

$$a_2^{(2)} = f(W_{21}^{(1)}x_1 + W_{22}^{(1)}x_2 + W_{23}^{(1)}x_3 + b_2^{(1)}) \tag{2}$$

$$a_3^{(2)} = f(W_{31}^{(1)}x_1 + W_{32}^{(1)}x_2 + W_{33}^{(1)}x_3 + b_3^{(1)}) \tag{3}$$

$$h_{w,b}(x) = a_1^{(3)} = f(W_{11}^{(2)}a_1^{(2)} + W_{12}^{(2)}a_2^{(2)} + W_{13}^{(2)}a_3^{(2)} + b_1^{(2)}) \tag{4}$$

假设卷积神经网络的训练集有  $m$  个样本  $\{(x^{(l)}, y^{(l)}), \dots, (x^{(m)}, y^{(m)})\}$ ，选取平方差作为损失函数，整体的损失函数为：

$$J(W, b) = \frac{1}{m} \sum_{i=1}^m \|h_{w,b}x^{(i)} - y^{(i)}\|^2 \tag{5}$$

用梯度下降法更新网络参数得：

$$W_{ij}^{(l)} = W_{ij}^{(l)} - \alpha \frac{\partial}{\partial W_{ij}^{(l)}} J(W, b) \tag{6}$$

$$b_i^{(l)} = b_i^{(l-1)} - \alpha \frac{\partial}{\partial b_i^{(l)}} J(W, b) \quad (7)$$

式中  $\alpha$  为学习率，最后再利用反向传播算法<sup>[14]</sup>求出偏导数  $\frac{\partial}{\partial W_{ij}^{(l)}}$  和  $\frac{\partial}{\partial b_i^{(l)}}$ 。针对第  $l$  层神经网络层的每一个神经节点  $i$ ，得出其残差  $\delta_i^{(l)}$ ，损失函数对于参数的偏导数与节点之间的关系如下：

$$\frac{\partial}{\partial W_{ij}^{(l)}} J(W, b; x, y) = a_i^{(l)} \delta_i^{(l)} \quad (8)$$

$$\frac{\partial}{\partial b_i^{(l)}} J(W, b; x, y) = \delta_i^{(l+1)} \quad (9)$$

卷积神经网络经过前向传播和反向传播更新参数，当神经网络足够复杂，数据量足够大时，卷积神经网络可以提取出人为难以提取的特征。

### 1.3 低信噪比下射频指纹识别问题

图 3 为不同信噪比下的星座图。图 3(a) 可以明显看出功放非线性造成星座图的信号频率偏移和相位偏移，随着噪声的增大，信号中跟发射机相关的射频特征容易被噪声淹没，图 3(c) 在信噪比为 0 dB 条件下已无法解调出明晰的星座图，人为提取的特征易受到噪声的干扰，因而识别率较低。

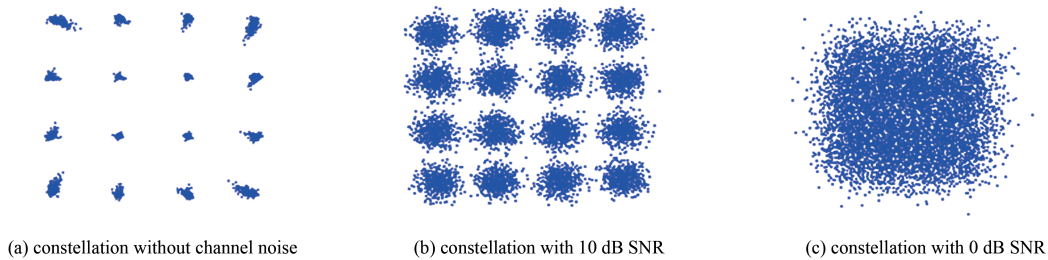


Fig.3 Constellation without channel noise, and constellation with 10 dB, 0 dB SNR

图3 无信道噪声,以及信噪比为 10 dB、0 dB 的星座图

研究表明<sup>[15]</sup>，人工设计的特征缺乏良好的泛化性能，而卷积神经网络作为一种深度学习模型，具有分层学习特征的能力，相对于人工设计特征具有更强的判别能力和泛化能力。因此本文采用卷积神经网络提取低信噪比下人为难以提取的发射机射频指纹特征。

## 2 实验系统

### 2.1 通信系统

如图 4 所示，通信系统由信号源、频谱仪、4 个不同功放和电脑主机构成。




Fig.4 Experiment system of RF fingerprint recognition

图4 射频指纹识别实验系统

为了证明本方法与传输的信息无关，主机端产生 600 000 个随机信号，将其发送到信号源中进行调制，信号源将信号发送给 4 个不同的功放，其中 1,2,3 号功放的型号相同，均为 ZFL-2500VHX+，4 号功放的型号为 ZX60-332N-S+。信号载波频率为 2.4 GHz，带宽为 20 MHz，采样率为 100 MHz，发射功率为 -1 dBm，信号的调制体制为 16QAM。之后用频谱仪接收不同功放经过信道传输的信号，频谱仪再将接收到的信号传输给主机端，主机端经过预处理后得到星座图。图 5 为信号经过不同功放产生的星座图。因为相同型号的功放非线性特性相似，因此解调后的星座图相似，经过 4 号功放解调后的星座图有较明显的差异。



(a) constellation diagram of PA 1 (b) constellation diagram of PA 2 (c) constellation diagram of PA 3 (d) constellation diagram of PA 4

Fig.5 Constellation diagram of different PAs without noise

图5 没有噪声条件下不同功放的星座图

### 2.2 信噪比调整

整个实验系统是在实验室条件下进行的，本实验用 Matlab 的 awgn 函数添加高斯白噪声得到不同信噪比下的数据。频谱仪接收到的前 400 000 个点，在 0~15 dB 的范围内，以 1 dB 作为步长添加噪声，最终得到 400 000×16 组数据作为训练数据。频谱仪接收到的后 20 000 个点，在 0.5~14.5 dB 的范围内，以 1 dB 作为步长添加噪声，最终得到 200 000×15 组数据作为验证数据不参与训练。

### 2.3 星座点个数

在数字通信中，接收机经过预处理得到了基带信号后，再通过时间同步得到用于采样的判决点，将处理过的信号在复平面上表示就是星座图。星座图可以直观地表示信号之间的关系。深度学习是利用星座图信号的统计特性进行识别，若一张星座图上包含的星座点太少，则会导致识别率过低。若星座图包含的点太多，则在射频指纹识别时速度会变慢。所以需要进行实验确定每张星座图的点数。如图 6 所示，本实验在信噪比为 7 dB 下，每一张星座图中星座点数分别为 1 000、2 000、5 000、10 000、20 000 下的识别率分别为 75%、83%、87%、95%、95%。故本实验选取有 10 000 个点的星座图作为卷积神经网络的输入。

### 2.4 样本生成方法

卷积神经网络需要大量的数据进行训练，所以对接收到的星座点用滑窗法增加数据集。在每一个 dB 下的数据都间隔 500 个点进行滑窗，每个窗的长度为 10 000。每个 dB 下训练集有 780 张星座图，同理每个 dB 下的验证集有 380 张星座图。输入卷积神经网络的训练集共有 780×16=12 480 张星座图，验证集共有 380×15=5 700 张星座图。

### 2.5 卷积神经网络结构

本文采用的卷积神经网络模型如图 7 所示，本文采用的卷积神经网络在 Alexnet 的基础上进行了优化，取消了不能显著提升识别率且需耗费大量计算的 LRN 层；也改变了全连接层的节点数。本文对神经网络的超参数进行了改进。减小初始学习率至  $10^{-4}$ ，网络迭代至第 5 个周期之后学习率进一步降为  $10^{-6}$ 。因为初始学习率太高网络无法收敛，学习率太低网络收敛较慢。最小批处理数 (Mini Batch Size) 设置为 50，因为较大的最小批处理数会降低识别率。不同于文献[3]所采用的卷积神经网络，本文采用的神经网络卷积层的层数更多，同时卷积层的卷积核的数量更多。更深的网络和更多的卷积核可以提高卷积神经网络的特征提取能力。




Fig.6 Sample recognition rate of different constellation points

图6 不同星座点的样本识别率

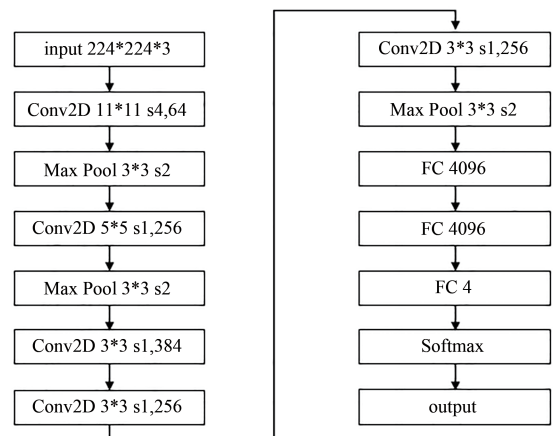


Fig.7 Diagram of convolutional neural network

图7 卷积神经网络结构

### 3 实验结果及分析

图 8 为在动态信噪比为 0~15 dB 时的卷积神经网络的训练曲线, 训练集的最终识别率达到 100%。验证集第一次迭代完成后的识别率为 72%, 大约迭代至第 6 次网络收敛, 识别率不再有较大的改变, 最终在验证集上的识别率为 89.4%。

以生成训练集相同的方法生成信噪比分别为 0 dB、5 dB、10 dB、15 dB 的测试集, 此测试集独立于训练集和验证集。如图 9 所示, 该卷积神经网络对这 4 个信噪比下的测试集的识别率分别为 71.25%、82.08%、95.83% 和 95.83%。再提取信号的频率偏移和相位偏移, 用支持向量机算法(Support Vector Machine, SVM)进行识别, 识别率分别为 25%、25%、25% 和 51%。由于噪声对支持向量机提取的特征造成了较大的干扰, 支持向量机在低信噪比下几乎无法识别这 4 个设备。本文采用的方法对噪声具有鲁棒性。




Fig.8 Recognition results of convolutional neural network  
图 8 卷积神经网络识别结果




Fig.9 Recognition rate of CNN and SVM test sets  
图 9 卷积神经网络与支持向量机测试集识别率

本文虽然在低信噪比下能更好地识别射频设备, 但是增加了神经网络的复杂度与训练的时间开销。本文仅考虑了通信中信噪比的变化, 没有考虑实际信道中的多径效应和多普勒效应。这也是目前射频指纹识别的一个难点。

### 4 结论

本文提出了一种基于星座图和卷积神经网络的射频指纹识别方法。相比于传统方法, 本文改变了数据预处理方法, 将卷积神经网络的输入从接收机接收到的原始 I/Q 数据变为解调后的星座图, 同时改进了卷积神经网络结构, 之前的研究主要是针对固定信噪比下的射频指纹识别, 本文考虑到实际通信环境, 首次提出动态信噪比下的识别。实验表明, 在动态信噪比为 0~15 dB 时 4 个功放的识别率为 89.4%。后续的工作将主要围绕如何降低神经网络的复杂度展开。此外, 更为复杂的信道中进行射频指纹识别也是下一步需要重点研究的内容。

#### 参考文献:

- [1] 彭林宁,胡爱群,朱长明,等. 基于星座轨迹图的射频指纹提取方法[J]. 信息安全学报, 2016,55(36):50-58. (PENG Linning, HU Aiqun, ZHU Changming, et al. Radio fingerprint extraction based on constellation trace figure[J]. Journal of Information Security, 2016,55(36):50-58.)
- [2] 俞佳宝,胡爱群,朱长明,等. 无线通信设备的射频指纹提取与识别方法[J]. 密码学报, 2016,3(5):433-446. (YU Jiabao, HU Aiqun, ZHU Changming, et al. RF fingerprinting extraction and identification of wireless communication devices[J]. Journal of Cryptologic Research, 2016,3(5):433-446.)
- [3] RIYAZ Shamnaz, SANKHE Kunal, IOANNIDIS Stratis, et al. Deep learning convolutional neural networks for radio identification[J]. IEEE Communications Magazine, 2018,25(2):146-152.
- [4] SZU H H. Novel identification of intercepted signals from unknown radio transmitters[J]. Proceedings of SPIE, 1995,2491(1): 504-517.
- [5] ELLIS K J, SERINKEN N. Characteristics of radio transmitter fingerprints[J]. Radio Science, 2001,36(4):585-597.
- [6] SUSKI W C, TEMPLE M A, MENDENHALL M J, et al. Using spectral fingerprints to improve wireless network security[C]// Global Telecommunications Conference, 2008. New Orleans, LO, USA: IEEE, 2008:1-5.
- [7] BRIK V, BANERJEE S, GRUTESER M, et al. Wireless device identification with radiometric signatures[C]// ACM International Conference on Mobile Computing and Networking. San Francisco, California, USA: ACM, 2008.
- [8] KENNEDY I O, BUDDHIKOT M M. Radio transmitter fingerprinting: a steady state frequency domain approach[C]// IEEE 68th Vehicular Technology Conference. Calgary, Canada: IEEE, 2008.

- [9] LI Qiyue, FAN Hailong, SUN Wei, et al. Fingerprints in the air: unique identification of wireless devices using RF RSS fingerprints [J]. IEEE Sensors Journal, 2017, 11(17): 3568–3579.
- [10] BERTONCINI Crystal, RUDD Kevin, NOUSAIN Bryan, et al. Wavelet fingerprinting of Radio-Frequency Identification (RFID) tags [J]. IEEE Transactions on Industrial Electronics, 2012, 59(12): 4843–4850.
- [11] YOUSSEF K, BOUCHARD L S, HAIGH K Z, et al. Machine learning approach to RF transmitter identification [J]. CANADIAN Journal of Electrical and Computer Engineering, 2018, 1(39): 1–8.
- [12] BALDINI Gianmarco, GIULIANI Raimondo, DIMC Franc. Physical layer authentication of Internet of Things wireless devices using convolutional neural networks and recurrence plots [J]. Internet Technology Letters, 2018, 2(2): e81.
- [13] MERCHANT Kevin, REVAY Shauna, STANTCHEV George, 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.
- [14] DONAHUE J, JIA Y, VINYALS O, et al. DeCAF: a deep convolutional activation feature for generic visual recognition [J]. Computer Science, 2013, 50(1): 815–830.
- [15] BOUVRIE J. Notes on convolutional neural networks [R]. Cambridge, MA, USA: Massachusetts Institute of Technology, 2006.

#### 作者简介：

刘鑫尧(1994-), 男, 四川省绵阳市人, 在读硕士研究生, 主要研究方向为射频指纹识别. email: 983343424@qq.com.

秋勇涛(1991-), 男, 陕西省咸阳市人, 在读博士研究生, 主要研究方向为电子信息技术.

皇甫雅帆(1993-), 男, 贵州省毕节市人, 在读硕士研究生, 主要研究方向为无人机控制.

刘友江(1986-), 男, 贵州省毕节市人, 博士, 特聘研究员, 主要研究方向为智能化无线电系统.

(上接第 448 页)

- [8] JOHN G P, MASOUD S. 数字通信[M]. 5 版. 张力军, 张宗橙, 宋荣方, 等译. 北京: 电子工业出版社, 2017: 140–141. (JOHN G P, MASOUD S. Digital communications[M]. 5th ed. Translated by ZHANG Lijun, ZHANG Zongcheng, SONG Rongfang, et al. Beijing: Publishing House of Electronics Industry, 2017: 140–141.)

#### 作者简介：

石先华(1987-), 男, 四川省北川县人, 在读博士研究生, 主要研究方向为遥测遥控技术. email: eccmail@163.com.

解楠(1975-), 男, 山东省胶州县人, 博士, 研究员, 主要研究方向为遥测遥控及卫星导航技术.

刘友江(1986-), 男, 贵州省毕节市人, 博士, 特聘研究员, 主要研究方向为智能化无线电系统.