

文章编号: 2095-4980(2022)12-1298-07

基于 CLDNN 的物联网设备个体识别

王 凡¹, 卢冬鸣¹, 王翰红^{*2}

(1. 中国电波传播研究所, 山东 青岛 266107; 2. 哈尔滨工程大学 信息通信工程学院, 黑龙江 哈尔滨 150001)

摘 要: 针对目前个体识别中特征工程存在信号序列长、特征鲁棒性差等问题, 研究了基于深度神经网络的个体识别技术。借鉴语音识别中的卷积长短时全连接神经网络(CLDNN), 通过卷积神经网络提取信号的局部幅度特征, 通过长短期记忆网络提取信号的全局时域特征, 使用全连接网络实现特征图到设备标签的映射。在视距(LOS)信道下, 采集 8 台 LoRa 调制的无线数传电台数据, 加入高斯白噪声进行仿真测试。仿真表明, 本文所提方法在信号序列长度为 2 048 点和低信噪比(0 dB)时, 模型准确率达到 95%; 此外相较 VGG16 模型, 本模型参数更少, 在物联网设备部署方面具有一定的应用前景。

关键词: 物理层安全; 射频指纹; CLDNN 网络; 物联网

中图分类号: TN918

文献标志码: A

doi: 10.11805/TKYDA2021352

Individual identification of Internet of things devices based on CLDNN

WANG Fan¹, LU Dongming¹, WANG Hanhong^{*2}

(1.China Research Institute of Radiowave Propagation, Qingdao Shandong 266107, China; 2.College of Information and Communication Engineering, Harbin Engineering University, Harbin Heilongjiang 150001, China)

Abstract: Aiming at the problems of long signal sequence and poor feature robustness in Feature Engineering in individual recognition, the technology based on deep neural network is studied. Drawing lessons from Convolutional, Long Short-Term Memory, Fully Connected Deep Neural Networks(CLDNN) in speech recognition, the local amplitude features of the signal are extracted through convolution neural network and the global time-domain features of the signal are extracted through long-term and short-term memory network. A fully connected network is utilized to map the feature to the device label. Under the line of sight channel, the data of eight Lora modulated wireless data transmission stations are collected, and the Gaussian white noise is added to the simulation test. The simulation shows that when the Signal-to-Noise Ratio is low(0 dB), the accuracy of the model can reach nearly 95% under the signal sequence length of 2 048 points. In addition, this model needs fewer parameters compared with VGG16 model. The proposed model has a certain application prospect in the deployment of Internet of things devices.

Keywords: physical layer security; RF Fingerprint(RFF); CLDNN; Internet of Things

随着快速发展的 5G 通信和物联网技术, 未来将有成千上万的物联网设备接入网络, 并广泛用于智能家居、环境监控、车联网、远程医疗、智慧城市等方面^[1]。与此同时, 也带来了设备监管和身份认证的相关问题。传统的基于密码机制的网络侧身份认证服务存在一定的安全问题^[2], 且无法适应物联网复杂的拓扑结构以及设备硬件资源的限制。因此, 为快速发展的物联网技术寻找一种与协议无关的方式, 实现在复杂的电磁环境中设备身份认证是一项挑战。

射频指纹识别作为一种重要的非密码认证物理层识别技术, 因其充分利用难以仿冒的设备硬件特性在无线侧实现身份识别, 近年来在物理层安全领域得到学术界和工业界的广泛关注^[3-7]。2019 年, Yu 等^[8]采用了一种多采样卷积神经网络从选定的感兴趣区域中提取射频指纹, 用于 ZigBee 设备分类。该神经网络采用多次下采样变

收稿日期: 2021-09-30; 修回日期: 2021-11-28

*通信作者: 王翰红 email:wanghanhong@hrbeu.edu.cn

换实现多尺度特征的自动提取，特征提取之后，通过两个级联的全连接层以及一个 Softmax 分类器，自动学习用于分类特征的最佳组合。仿真结果表明，该方法在 LOS 场景和非视距(Non Line Of Sight, NLOS)场景中的大范围信噪比下都是鲁棒的。由于通信信号一般为复数形式，文献[9]提出了一种复数神经网络的调制信号识别模型，并在 RadioML2016.10A 数据集上取得了优异性能。文献[10]中，作者参考 WaveNet 模型，设计了一种用于信号识别的网络-扩展因果卷积(Augmented Dilated Causal Convolution, ADCC)网络，之后探讨了用于射频指纹识别的 ADCC 的性能表现。文献[11]针对资源受限的边缘设备节点，提出一种二值化深度神经网络，实现识别准确率和模型开销的平衡。针对目前信号识别领域中存在的模型鲁棒性差的问题，文献[12]将迁移学习引入通信领域，并对不同无线通信领域中使用 TL(Transfer Learning)算法进行了全面的回顾。文献[13]中，作者为了解决小样本情况下深度网络不能成功训练的问题，采用迁移学习的方法实现电磁目标识别中的同类目标迁移和异类目标迁移。

针对目前已有特征工程方案中所需信号长度长、人工构建合适特征、模型鲁棒性差等问题，本文借鉴语音和信号之间的关联性，提出了一种基于卷积长短时全连接神经网络(CLDNN)的设备指纹识别方法，实现对无线数传电台设备的端到端识别。该方法将特征提取和分类器联合优化，其中卷积神经网络(CNN)与长短期记忆网络(LSTM)两种不同类型的网络结合，自动挖掘数据的深层特征表示，将初级的幅度特征转化为更高维的信号语义特征，最后通过全连接网络实现特征的分类识别。通过对不同设备实测电磁信号数据的仿真，在 0 dB 信噪比(Signal-Noise-Ratio, SNR)条件下，识别准确率可以达到 95% 以上，显著优于特征工程方法和 VGG16 网络。此外，本模型所占体积小，对于物联网中轻量化的识别具有一定的潜力。

1 个体识别理论

1.1 个体识别机理

个体识别是指通过对接收端收到的信号进行处理，分析出信号中隐藏的发射设备“指纹”，实现对发射设备身份的准确识别。与人类的指纹一样，通信发射机设备的“指纹”也能够用来唯一表征设备身份的信息^[4]。在通信系统中，发射机主要实现将数字基带信号转换为模拟射频信号，并通过天线辐射到自由空间中。图 1 为无线数字发射机结构图，由数字部分和模拟部分组成，其中发射机模拟元件是射频指纹产生的主要来源。尽管数十年来，科技飞速发展，半导体制造工艺不断提升，但仍旧无法制造出两个没有任何差别的电子元器件，在 IEEE802 无线通信的协议中也允许设备发射机存在一定范围的容差；同时由于后期的人为影响以及元器件的老化等，这些硬件上的差异将会进一步拉大，而这些差异也会体现在无线设备的通信信号上，并随信息内容发射出去。这使得通过提取无线信号的指纹特征来唯一表示硬件设备成为可能。

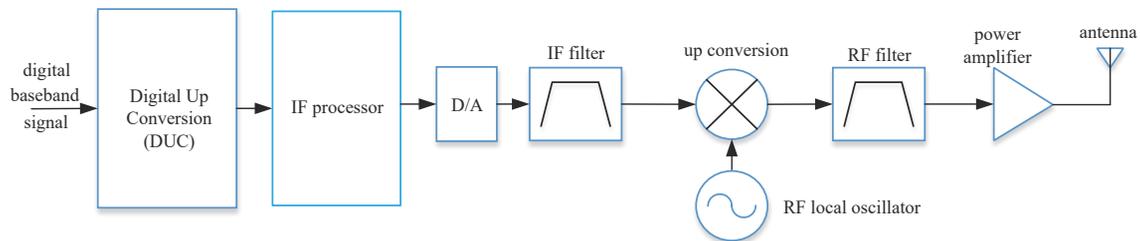


Fig.1 Structure diagram of digital radio transmitter

图 1 数字无线电发射机结构图

由于制造容差的存在，不同生产批次甚至同一生产批次的不同元器件之间也会存在细微差别^[15]。如：金属氧化物半导体晶体管作为一种常见的电路元件，其主要器件参数(如沟道长度、沟道掺杂浓度、氧化物厚度)在不同生产批次之间有很大差异。这些变化可能是由于洁净室中湿度或温度的微小变化，或由于芯片相对于晶片中心的位置而产生的。参数的变化会影响晶体管的开关速度，从而影响元件特性。此外这种元器件的差异性还包括时钟电路偏移、ADC 的量化误差和非线性积分效应、放大器的非线性等。接收机接收到的信号则是这些差异耦合作用的“合力”表现。

1.2 CLDNN 网络

深度学习作为一种有效利用标签数据驱动提取对象特征并实现准确识别的方法，非常擅长发现高维数据的内在结构和特征，无需人工设计特征，实现端到端的模型训练，从而节省大量进行特征设计的时间。在通信辐射源个体识别领域，因为信号缺陷(主要是无意的波形调制效应)通常是各种来源的综合，并表现出独特的空间和时间模式，这与深度学习的应用场景类似。2015 年 Sainath 等为了解决 NLP 中的一个难题 LVCSR(Large-

Vocabulary-Continuous-Speech-Recognition), 提出一种新的网络架构——CLDNN^[16], CLDNN 网络由 CNN、LSTM 和 DNN 3 部分组成, 图 2 为 CLDNN 的网络架构。

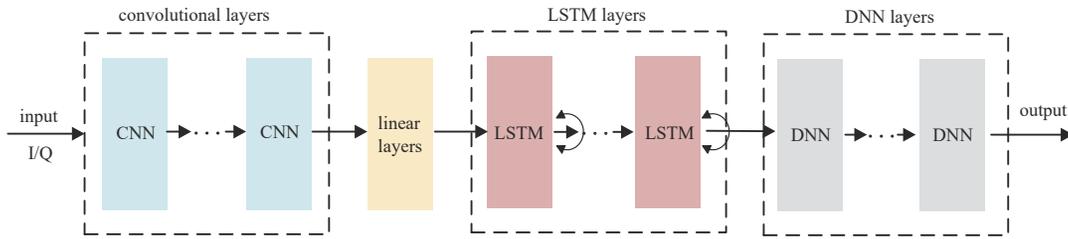


Fig.2 CLDNN network architecture
图2 CLDNN 网络架构

虽然射频或中频信号能够更好地保留无线设备的细微指纹特征, 也能够尽量减少接收机干扰的引入, 但为了获取射频或中频信号, 往往需要昂贵的设备以及非常高的采样率。由于高采样率以及采样时长, 会产生非常大的数据量, 这对于处理时间以及嵌入式设备的部署非常不利, 而且对于现在市面上流行的数字接收机, 尤其是软件无线电平台(Software Defination Radio, SDR), 接收到的通信信号常常是基带 I/Q 复数序列。因此, 从基带 I/Q 数据入手非常必要。

传统的特征提取方法, 从接收到的 I/Q 序列提取特征时, 往往只利用其中的一路数据或选取 I/Q 两路数据的幅值。为了能够更多地保留发射机的细微特征, 本文将 I/Q 两路数据保存为 2 个独立的通道, 拼接为二维矩阵的形式, 即 $Input=[N \times 2]$, 其中 N 代表信号长度, 一般取为 1 024 或 2 048 点, 之后输入神经网络。模型的输出为对应的类别数神经输出构成的向量, 即 $output=[M \times 1]$, M 表示总的类别数, 经过 Softmax 函数将输出值进行概率归一化, 输出概率最大值的索引作为网络对输入样本信号的预测标签。

CLDNN 网络中长输入序列通过特征提取和降维处理(通常由卷积核池化操作完成)转化为高级特征的较短表示, 而后较短的序列成为后续 LSTM 层的输入。信号本质为一维的时间序列, LSTM 能够根据输入信号获得长短时记忆, 并利用递归计算, 从高阶特征入手对时序信号进行感知与建模, 以此得到输入信号在时间上更加细微的特征。将当前特征状态与之前的特征状态关联起来, 通过反馈机制确定更为合理的网络参数, 弥补卷积神经网络在时间上提取特征不足的缺点。CNN 和 LSTM 实现对信号空间和时间维度的深层表征, 最后将 LSTM 得到的特征输入 DNN 层, 将其映射至预测类别概率。

2 个体识别算法

2.1 数据采集

本文采用 LoRa 调制的无线数传电台设备作为发射机进行实测数据采集和模型仿真验证。LoRa 为远距离无线电(Long Range Radio), 其最大特点是在功耗相同的条件下, 相较其他无线传播方式, 能实现更远的通信, 完成低功耗和远距离的统一, 因此广泛用于物联网通信。

为验证本文所提模型的有效性, 待识别辐射源设备选用 8 台同批次生产的同型号 EBYTE 数传电台设备。信号采集设备采用 Signal Hound 生产的 BB60C 频谱分析仪。详细的信号采集参数如表 1 所示, 本文不考虑无线信道的复杂多径衰落影响, 在实际采集过程中选择接收机和发射机距离较近的视距(LOS)无线传输。此外, 为了提取到有效、独特的稳态信号设备指纹信息, 本文的数传电台发送相同的信息内容, 以此消除信息内容对指纹特征的影响。

每台数传电台设备采集 40 条信号, 每次采集 1×10^7 个数据点, 总计得到 1 000 个射频信号。为了验证模型的鲁棒性, 在仿真数据中加入不同信噪比的高斯白噪声, 模拟加性高斯白噪声(Additive White Gaussian Noise, AWGN)信道环境。

2.2 个体识别算法

人工手动为 BB60C 采集到的射频信号打标签, 并存储为 $\{D_i, i=1, 2, 3, \dots, 8\}$ 。将第 l 个采集信号第 k 个采样信号记为 $x_k^{(l)}(1), x_k^{(l)}(2), x_k^{(l)}(3), \dots, x_k^{(l)}(N)$, 其中, $N=1 \times 10^7$ 为样本点数, $l=1, 2, 3, \dots, 8$ 为要区分的设备编号, $k=$

表 1 信号采集参数

Table 1 Measured signal parameters

| acquisition parameter | parameter value |
|------------------------|-----------------|
| modulation | LoRa |
| working frequency/MHz | 433 |
| sampling rate/MHz | 6 |
| sampling points | 1×10^7 |
| collection environment | Los |

1, 2, 3, ..., 40 为观测到的数据组数。

基于 CLDNN 网络的个体识别系统整体框图如图 3 所示。

步骤 1 对 BB60C 采集到的信号 $\{D_i, i = 1, 2, 3, \dots, 8\}$ 进行预处理, 使用基于能量的变点检测法进行样本信号的起始点检测, 截取出信号的稳态 I/Q 数据段, 并进行中心化和归一化处理。

步骤 2 对步骤 1 处理完的原始纯净数据集信号加上 0~20 dB 高斯白噪声信号, 以此模拟 AWGN 信道模型, 验证训练模型的鲁棒性。

步骤 3 随机分割训练集、验证集、测试集, 并将不同信噪比的训练数据集输入神经网络, 采用梯度下降法更新网络参数, 保存至验证集上表现最佳的参数模型。

步骤 4 模型达到最大迭代次数或在验证集上性能不再提升时, 停止模型训练, 导入最优模型参数, 预测测试集标签, 绘制测试集的混淆矩阵和模型训练曲线。

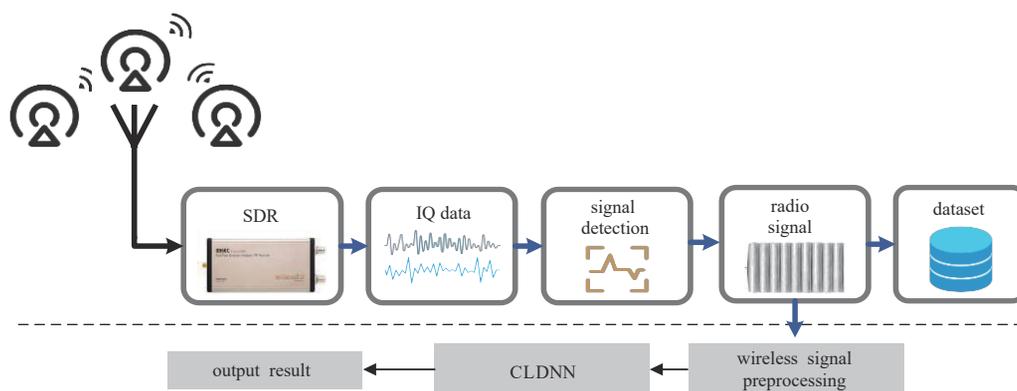


Fig.3 Block diagram of RFF identification based on CLDNN

图3 基于CLDNN的RFF识别框图

3 实验与仿真分析

3.1 模型仿真参数设置

数据集采用 2.1 节中介绍的数据集, 总共 8 类设备, 每类设备 1 000 条样本。模型训练过程中, 训练集、验证集、测试集的划分比例为 8:1:1, 模型参数结构如表 2 所示。仿真实验的硬件环境采用 Intel Core(TM)i7-10875H CPU、NVIDIA RTX 2060 GPU 的笔记本。深度学习模型训练过程中, 信号长度为 2 048 点, 优化器调整和改变模型的参数(即权重), 以最小化损失函数(交叉熵)使预测尽可能正确。实验中, mini-batch 设置为 128; 所有的深度学习模型都选择 Adam 优化器, 初始学习率为 0.000 1, 学习率调度算法采用分段恒定调度, 即每 20 轮, 学习率衰减为原来的 0.5。同时, 为了提高模型的泛化能力, 全连接层中加入 Dropout 正则化技术, 模型训练过程中加入早停法。特征工程方法选择围线积分双谱(Surrounding-line Integral Bispectrum, SIB)和功率谱密度函数(Power Spectral Density, PSD), 信号长度为 15 000 点, 分类器选择支持向量机(Support Vector Machines, SVM), 采用 10 折交叉验证和网格搜索法寻找模型最优参数。

3.2 仿真结果分析

按照 2.2 节步骤在信号中加入 20 dB 噪声, 模型的训练曲线如图 4 所示, 最终模型在测试集上准确率达到 97.75%。同时, 由训练曲线可以看出, 随着迭代次数的增加, 模型在训练集和验证集上均取得了较好的泛化能力; 此外还可以看出, 模型在验证集上的准确率波动较大(图 4 中黄色线所示), 其原因主要是由于模型初始阶段学习率较大, 且模型没有学习到训练集的稳定分布。图 5 为 20 dB 信噪比时, CLDNN 网络模型在测试集上的混淆矩阵。其中, 矩阵中主对角线数字表示分类正确样本所占的比例, 可以看出, 设备 3, 4, 6, 7, 8 分离准确率较高; 同时, 设备 5 的识别结果较差, 有 2% 的概率被识别为设备 2。

为了直观地显示网络提取的特征分布, 保存 Softmax 之前的特征图进行 2 维可视化。采用 T-SNE 降维可视化, 如图 6 所示。模型提取的特征较为鲁棒, 不同类别的聚类中心距离较远, 实现了对设备有效分离; 同时可以看出, 网络提取的特征中, 设备 2 和设备 5、设备 1 和设备 3 之间存在部分混叠, 这与混淆矩阵中对应部分错误率提高相对应。

表2 CLDNN网络参数

Table2 CLDNN network parameters

| network architecture diagram | layer | kernel parameters | output dimension |
|------------------------------|-----------------------|-------------------|--------------------|
| 1*9 Conv, 64 | convolutional layer | (64,9) | (none, 2 048, 64) |
| Pool 1/2 | maximum pooling layer | (2,2) | (none, 1 024, 64) |
| 1*9 Conv, 128 | convolutional layer | (128,9) | (none, 1 024, 128) |
| Pool 1/2 | maximum pooling layer | (2,2) | (none, 512, 128) |
| 1*5 Conv, 256 | convolutional layer | (256,5) | (none, 512, 256) |
| Pool 1/2 | maximum pooling layer | (2,2) | (none, 256, 256) |
| 1*5 Conv, 512 | convolutional layer | (512,5) | (none, 256, 512) |
| Pool 1/2 | maximum pooling layer | (2,2) | (none, 128, 512) |
| 1*5 Conv, 512 | convolutional layer | (512,5) | (none, 128, 512) |
| Pool 1/2 | maximum pooling layer | (2,2) | (none, 64, 512) |
| LSTM | LSTM layer | none | (none, 64, 50) |
| LSTM | LSTM layer | none | (none, 50) |
| Fc, 128 | fully connected layer | 128 | (none, 128) |
| | dropout layer | (none) | (none, 128) |
| Fc, 64 | fully connected layer | 64 | (none, 64) |
| | dropout layer | (none) | (none, 64) |
| Fc, 8 | output layer | 8 | (none, 8) |

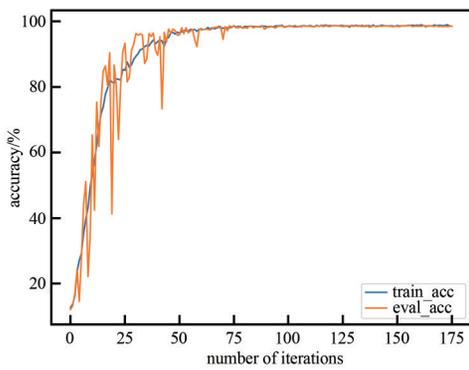


Fig.4 Training accuracy curves
图4 训练准确率曲线

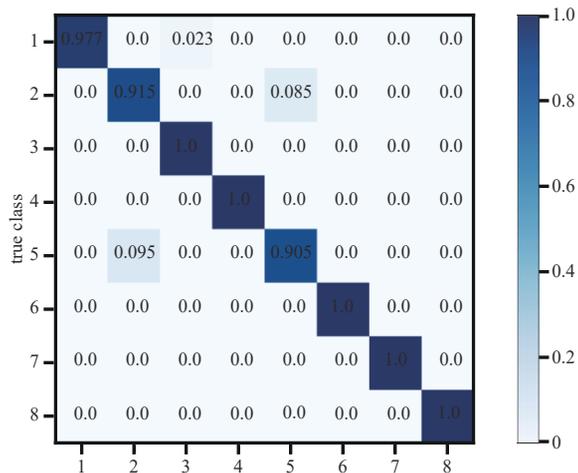


Fig.5 Confusion matrix of 20 dB CLDNN classification results
图5 20 dB CLDNN分类结果混淆矩阵

此外，为了充分验证 CLDNN 模型在信号识别领域的优势，将 CLDNN 模型与特征工程方法进行对比，绘制了准确率-信噪比(Accuracy-Signal Noise Ratio, ACC-SNR)曲线，如图 7 所示。由图 7 可知，CLDNN 网络性能显著优于特征工程方法，在低信噪比条件下尤为明显。其原因主要是因为低信噪下，部分信号特征会被噪声所淹没，导致模型的准确率下降，而 CLDNN 网络采用特征提取和分类识别的联合优化，会根据信号的幅度变化，通过 CNN 和 LSTM 网络，自适应地挖掘信号空间和时间上的细微差异，最后通过 DNN 网络实现特征到标签的映射，实现优异的性能。进一步，特征工程方法是计算每一个样本的指定统计特性，一般需要的信号长度长(本实验中选择为 15 000 点)，而 CLDNN 仅需 2 048 点，就取得了优于特征工程的性能。此外，图 7 还比较了 CLDNN 和 VGG16(Visual Geometry Group 16)两种深度神经网络模型在不同信噪比下的性能，可以看出，高信噪比时，两者的准确率相当；低信噪比时，CLDNN 模型具有较高的正确率和鲁棒性；另一方面，CLDNN 网络参数数量为 1 422 122，VGG16 网络参数数量为 9 775 048，相较于 VGG16 网络，参数更少，适用于轻量化的物联网设备识别。

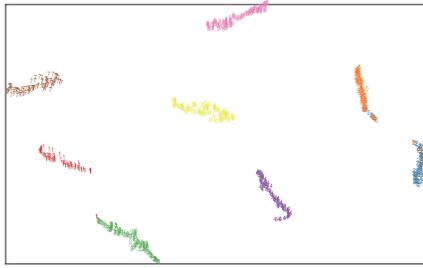


Fig.6 Visualization results of T-SNE dimensionality reduction of network characteristic diagram
图6 网络特征图T-SNE降维可视化结果

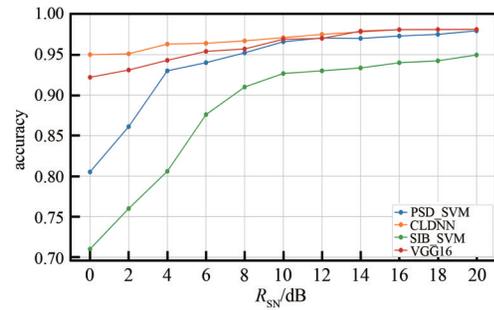


Fig.7 Comparison of deep learning and feature-based engineering algorithms under different SNRs
图7 不同信噪比下深度学习与基于特征工程算法对比

4 结论

本文采用 CLDNN 网络将特征提取和分类识别联合优化，实现了设备端到端的识别，一定程度上解决了特征工程中所需信号长、构造复杂等问题。将本文提出的模型与特征工程、VGG16 进行比较，发现 CLDNN 模型所需信号长度短，在不同噪声条件下，表现出较高的鲁棒性，且模型网络参数较少，为后续物联网中模型的轻量化部署奠定了基础。尽管本文方法取得了较好的信号分类性能，但仍有很多方面需进一步改善，如：在实际设备通信过程中，信道的影响是复杂且不可忽略的，因此，本模型在实际衰落信道中是否也具有鲁棒性是后续研究的一个方向；在实际设备通信过程中，设备每次发送的数据信息必然存在差异，这会导致设备时域波形的差异。因此，提取独立于发送数据内容的指纹特征具有重要意义。

参考文献：

- [1] KHAN M A,SALAH K. IoT security:review,blockchain solutions,and open challenges[J]. Future Generation Computer Systems, 2018(82):395-411.
- [2] DANEV B,ZANETTI D,CAPKUN S. On physical-layer identification of wireless devices[J]. ACM Computing Surveys(CSUR), 2013,45(1):1-29.
- [3] LIN Y,TU Y,DOU Z,et al. Contour stella image and deep learning for signal recognition in the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2021,7(1):34-46.
- [4] GOPALAKRISHNAN S,CEKIC M,MADHOW U. Robust wireless fingerprinting via complex-valued neural networks[C]// 2019 IEEE Global Communications Conference(GLOBECOM). Waikoloa,HI,USA,USA:IEEE, 2019:1-6.
- [5] LIN Y,ZHU X,ZHENG Z,et al. The individual identification method of wireless device based on dimensionality reduction and machine learning[J]. The Journal of Supercomputing, 2019,75(6):3010-3027.
- [6] ROBINSON J,KUZDEBA S. Riftnet:radio frequency classification for large populations[C]// 2021 IEEE 18th Annual Consumer Communications & Networking Conference(CCNC). Las Vegas,NV,USA:IEEE, 2021:1-6.
- [7] LIN Y,TU Y,DOU Z. An improved neural network pruning technology for automatic modulation classification in edge devices[J]. IEEE Transactions on Vehicular Technology, 2020,69(5):5703-5706.
- [8] YU J,HU A,LI G,et al. A robust RF fingerprinting approach using multisampling convolutional neural network[J]. IEEE Internet of Things Journal, 2019,6(4):6786-6799.
- [9] TU Y,LIN Y,HOU C,et al. Complex-valued networks for automatic modulation classification[J]. IEEE Transactions on Vehicular Technology, 2020,69(9):10085-10089.
- [10] ROBINSON J,KUZDEBA S,STANKOWICZ J,et al. Dilated causal convolutional model for RF fingerprinting[C]// 2020 10th Annual Computing and Communication Workshop and Conference(CCWC). Las Vegas,NV,USA:IEEE, 2020:157-162.
- [11] 张思成,林云,涂涯,等. 基于轻量级深度神经网络的电磁信号调制识别技术[J]. 通信学报, 2020,41(11):12-21. (ZHANG Sicheng,LIN Yun,TU Ya,et al. Electromagnetic signal modulation recognition technology based on lightweight deep neural network[J]. Journal on Communications, 2020,41(11):12-21.)
- [12] WANG M,LIN Y,TIAN Q,et al. Transfer learning promotes 6G wireless communications:recent advances and future challenges [J]. IEEE Transactions on Reliability, 2021,70(2):790-807.
- [13] 王美玉,田乔. 迁移学习用于电磁目标识别[J]. 太赫兹科学与电子信息学报, 2021,19(4):556-561. (WANG Meiyu,TIAN Qiao. Transfer learning for electromagnetic target recognition[J]. Journal of Terahertz Science and Electronic Information

Technology, 2021,19(4):556–561.) doi:10.11805/TKYDA2021214.

- [14] 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.)
- [15] POLAK A C,GOECKEL D L. Wireless device identification based on RF oscillator imperfections[J]. IEEE Transactions on Information Forensics and Security. 2015,10(12):2492–2501.
- [16] SAINATH T N,VINYALS O,SENIOR A,et al. Convolutional,long short-term memory,fully connected deep neural networks[C]// 2015 IEEE International Conference on Acoustics,Speech and Signal Processing(ICASSP). South Brisbane:IEEE, 2015:4580–4584.

作者简介:

王 凡(1982–),女,硕士,高级工程师,主要研究方向为电磁频谱管控、智能优化决策和电磁信号识别等.email:wangfan_01@126.com.

王翰红(1999–),男,在读硕士研究生,主要研究方向为通信信号处理等.

卢冬鸣(1981–),男,学士,高级工程师,主要研究方向为短波智能选频和电磁信号识别等.

(上接第1297页)

- [11] 何友,陆大瑜,彭应宁,等. 基于模糊综合函数的航迹关联算法[J]. 电子科学学报, 1999(1):91–96. (HE You,LU Dajin,PENG Yingning,et al. Track correlation algorithm based on fuzzy synthesis function[J]. Journal of Electronics, 1999(1):91–96.)
- [12] 何友,黄晓东. 基于模糊综合决策的航迹相关算法[J]. 海军工程学院学报, 1999,89(4):1–11. (HE You,HUANG Xiaodong. Track correlation algorithm based on fuzzy comprehensive decision making[J]. Journal of Naval University of Engineering, 1999, 89(4):1–11.)
- [13] 张天舒,周正,李寅龙,等. 对等式结构下的航迹关联算法[J]. 兵器装备工程学报, 2021,42(6):223–229. (ZHANG Tianshu,ZHOU Zheng,LI Yinlong,et al. Track association algorithm based on peer-to-peer structure[J]. Journal of Ordnance Equipment Engineering, 2021,42(6):223–229.)
- [14] 连宇杰,杨露菁,卢凌峰,等. 基于集对分析和双门限的航迹关联算法研究[J]. 指挥控制与仿真, 2020,42(1):40–46. (LIAN Yujie,YANG Lujing,LU Lingfeng,et al. Research on track association algorithm based on set pair analysis and double thresholds[J]. Command Control & Simulation, 2020,42(1):40–46.)
- [15] GRAVES A,SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks, 2005,18(5/6):602–610.
- [16] HOCHREITER S,SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997,9(8):1735–1780.
- [17] 修建娟,张敬艳,董凯. 空间目标航迹片段关联算法研究[J]. 弹道学报, 2020,32(3):85–90. (XIU Jianjuan,ZHANG Jingyan,DONG Kai. Research on space-target track segments association algorithm[J]. Journal of Ballistics, 2020,32(3):85–90.)

作者简介:

魏 博(1997–),男,在读硕士研究生,主要从事深度学习 and 态势感知方面的研究. email:weibo2019@mail.hfut.edu.cn.

樊玉琦(1976–),男,博士,副教授,主要研究方向为人工智能、云计算、区块链等.