# 应用 FFB-EWT 的 OFDM 辐射源个体识别<sup>①</sup>

刘高辉, 李瑞琛

(西安理工大学自动化与信息工程学院,西安710048) 通信作者: 刘高辉, E-mail: liugh68@xaut.edu.cn



摘 要: 针对在传统辐射源个体识别方法中 OFDM 辐射源细微指纹特征信息会受到数据信号成分和信道噪声的影 响会导致分类识别率低的问题, 根据短导码的子载波频谱特点设计了一种基于固定频率边界的经验小波变换 (frequency fixed boundary-empirical wavelet transform, FFB-EWT) 和深度残差网络的 OFDM 辐射源个体识别方法. 首先, 提取 OFDM 信号的短导码, 根据短导码中传输信号子载波的频率间隔划分固定边界条件, 将频域边界值应用 于 FFB-EWT 对信号进行分解, 去除包含前导序列信息的子载波分量; 其次, 对相邻帧中包含指纹特征的空子载波 分量进行积累, 提高指纹特征信号的信噪比; 然后, 使用双通道的结合了非局部注意力模块和通道注意力模块的 ResNet18 残差网络, 对 IQ 两路数据输入进行特征提取, 通过 Softmax 函数进行分类; 最后, 选择 Oracle 公开数据集 验证方法的可行性. 实验结果表明利用 FFB-EWT 方法对 6 个不同辐射源个体在 6 dB 和 0 dB 条件下进行识别, 准 确率可以达到98.17%和89.33%,证明了该方法在低信噪比条件下的有效性.

关键词:辐射源个体识别;固定频率边界;经验小波变换;残差网络

引用格式: 刘高辉,李瑞琛.应用 FFB-EWT 的 OFDM 辐射源个体识别.计算机系统应用,2024,33(9):226-234. http://www.c-s-a.org.cn/1003-3254/ 9610.html

## **OFDM Specific Emitter Identification Using FFB-EWT**

LIU Gao-Hui, LI Rui-Chen

(School of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710048, China)

Abstract: This study proposes a novel identification method for OFDM emitters to address the issue of low classification accuracy in traditional methods for specific emitter identification, where subtle fingerprint features of OFDM emitters are affected by data signal components and channel noise. Considering the subcarrier spectrum of the short preamble, this method utilizes the fixed frequency boundary-based empirical wavelet transform (FFB-EWT) and a deep residual network. Initially, the short preamble of OFDM signals is extracted to define fixed boundary conditions based on the frequency intervals of the subcarriers in the short preamble. The boundary values in the frequency domain are then applied to FFB-EWT for signal decomposition to remove the subcarrier components containing preamble information. Subsequently, the signal-to-noise ratio of fingerprint features is enhanced by accumulating the null subcarrier components of adjacent frames. Next, a dual-channel residual network called ResNet18, integrated with a non-local attention module and a channel attention module, is used for feature extraction from IQ data inputs, with classification performed via the Softmax function. Finally, the Oracle public dataset is chosen to validate the feasibility of the method. Experimental results demonstrate that the FFB-EWT method achieves accuracy rates of 98.17% and 89.33% for identifying six different emitters under 6 dB and 0 dB conditions, respectively, proving the effectiveness of the method in environments with low signal-to-noise ratios.

**Key words**: specific emitter identification; fixed frequency boundary; empirical wavelet transform; residual network

① 基金项目: 国家自然科学基金 (61671375)

收稿时间: 2024-03-06; 修改时间: 2024-04-03; 采用时间: 2024-04-19; csa 在线出版时间: 2024-07-24

CNKI 网络首发时间: 2024-07-25

226 研究开发 Research and Development



辐射源个体识别又称特定辐射源识别 (specific emitter identification, SEI), 目标是通过分析和识别辐射 源产生的射频指纹特征,来对不同的辐射源设备进行 识别[1]. 射频指纹特征是发射机在物理层层面的基本特 征,很难被伪造,因此 SEI 技术被认为是维护无线通信 安全的重要技术之一. 通信辐射源个体识别是针对通 信调制信号为目标的 SEI 技术研究, 目前许多通信辐 射源个体方法研究已经被应用于商业领域. 例如应用 于识别空中交通管制的自动相关监视广播 (automatic dependent surveillance-broadcast, ADS-B) 系统中的飞 机[2,3]; 在物联网领域, 通信辐射源个体识别技术可以提 供可靠的设备认证功能来维护物联网网络安全[4,5].

通信辐射源个体识别是一个模式识别问题, 主要分 为特征提取和模式分类两个阶段. 如何提取信号的指纹 特征是通信辐射源个体识别问题的重点. 随着研究的深 入,单域特征并不能完全代表发射机的射频指纹,因此 越来越多的研究采用基于时频特征提取的方法. 文 献[6]提出了一种基于 Wigner 和 Choi-Williams 时频分 布特征的辐射源识别方法. 文献[7]通过经验模态分解 (empirical mode decomposition, EMD) 分解信号, 提出 了提取能量熵、均值、方差这3种特征基于 Hilbert 谱 的算法,证明了在单跳和中继及不同信噪场景下的有效 性. 但在经验模态分解过程中会存在模态混叠等分解不 充分的问题, 因此其在低信噪比下识别效果较差. 文献[8] 对信号进行差分处理, 通过变分模态分解 (variational mode decomposition, VMD) 差分信号, 然后求取对应的 希尔伯特谱. 针对希尔伯特谱的稀疏性, 运用改进的全 局信息分析模块对辐射源的细微特征进行提取. 文献[9] 使用双变量 VMD 来降噪, 并使用分解后的样本直接作 为射频指纹送入复值神经网络. 目前在通信辐射源个体 识别的信号时频特征提取方面, EMD、VMD 等分解技 术与深度学习结合的研究已有许多进展.

经验小波变换 (empirical wavelet transform, EWT) 技术[10]是由 Gilles 等在 2013 年提出的一种结合了小 波理论和 EMD 两者优点的信号处理方法,能有效地提 取信号的时频域特征,同时具有完备的小波数学模型, 与 VMD 技术相比拥有更低的算法复杂度. 从频域角 度来看,它等同于构造一组带通滤波器,根据通信信号 的频谱特性将其分解为分布于各个频段的时域模态信 号. 但 EWT 技术对每个信号分解的边界选择是自适应 的,在低信噪比条件下,对信号频域分割的边界选取会 受到噪声的影响, 使得同一批类信号分解的尺度不同, 导致每一层子信号携带原信号对应的不同频谱特征, 因此不能直接将 EWT 技术应用于通信辐射源个体识 别任务中. 固定边界范围经验小波变换 (fixed boundary range-based-empirical wavelet transform, FBR-EWT) 是 一种针对非平稳信号分解的 EWT 改进算法[11], 可以有 效地解决 EWT 技术在低信噪比条件下面对同一类信 号分解时分解尺度不一的情形, 让处理后的数据更适 用于神经网络训练. 文献[12]已经应用 FBR-EWT 技术 和深度卷积神经网络对无人机的射频信号进行分类, 通过 FBR-EWT 技术增强网络对细微特征的敏感度, 从而提高神经网络对个体进行识别的准确性和可靠性. 但与其他分解方法类似, FBR-EWT 方法并没有通过分 解方法来分离信号成分和指纹特征, 使通信辐射源的 指纹特征更容易被分类器识别. 同时其分解边界的选 取是按照经验进行等距划分的,没有理论依据.

为此, 本文根据 IEEE 802.11a 信号短导码的子载 波频率分布情况来提出了一种通过固定频率边界经验 小波变换和残差网络对 IEEE 802.11a 信号进行识别和 分类的方法. 来解决 OFDM 辐射源个体识别任务中指 纹特征信息受数据信号分量和信道噪声影响而分类识 别率低的问题,本文工作的主要贡献如下.

- (1) 根据 IEEE 802.11a 短导码的子载波频率特性, 设计 FFB-EWT 方法对短前导进行分解, 提取包含指纹 特征信号的空子载波分量,从而消除信号信息对识别 通信辐射源指纹特征时的干扰.
- (2) 根据噪声的统计特性对各空子载波分量进行 相干积累,提高指纹特征信号的信噪比.
- (3) 采用双通道 ResNet18 网络, 嵌入通道注意机 制和非局部注意机制相结合的模块, 对经过 FFB-EWT 分解和相干积累的 I/O 信号数据进行特征提取和分类.

## 1 OFDM 辐射源前导射频指纹模型

# 1.1 OFDM 前导信号帧结构

OFDM 信号中的前导部分通常应用于同步接收端 以获得信道估计和同步时序信息. 在 IEEE 802.11a 协 议下, OFDM 信号的帧结构由前导码、信令段、数据 段3部分组成,帧结构如图1所示,前导码由持续时间 均为 8 μs 的短导码和长导码组成, 其中短导码由 t1t10的10个短训练序列组成,长导码由循环前缀GI2 和 2 个长训练符号组成, 信令段部分为 1 个 OFDM 符



号, 其包含数据的调制类型、编码速率和数据长度等信息, 数据部分即所要传输的数据信息. 对接收到的 OFDM 信号与短导码进行互相关计算有:

$$d = \underset{d}{\operatorname{argmax}} \sum_{C=0}^{D-1} \left| \sum_{n=0}^{D-1} r(d+n, C) \cdot x^{p}(n) \right|^{2}$$
 (1)

其中, C 为载波索引,  $x^p(n)$  为短训练序列, 长度为 D, 以

峰值最大处 d 作为 OFDM 信号每一帧的起点, 根据信号的采样率计算得到的短导码长度, 来对前导信号中的短导码进行截取.

## 1.2 OFDM 前导射频指纹

OFDM 辐射源指纹特征通常由发射机中的硬件因素产生,如图 2 所示为 OFDM 设备的发机简化模型.

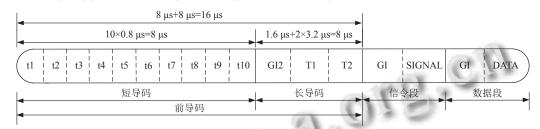


图 1 IEEE 802.11a 协议信号帧结构

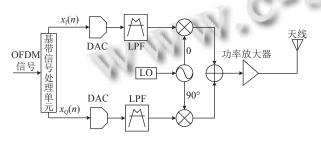


图 2 OFDM 设备的发射机简化模型

OFDM 信号送入基带信号处理单元,将信号分为 I/Q 两路,分别通过数模转换 (digital to analog converter, DAC),将信号转变为模拟信号,然后通过低通滤波器 (low pass filter, LPF),滤除掉高频分量,接着通过混频器对信号进行正交调制,最后通过功率放大器,通过天线发出射频信号.根据文献[2]可以将射频信号建模为:

$$RFF(\cdot) = A_0^{\gamma} (1 + h_{PA}(\tilde{a}_{tx})) \times \exp\left\{i\theta + h_t \left(\sigma_{TIE}^m\right) + h_{\Delta}(\Delta_n, \Delta_{INL}) + h_m(\xi) + h_p(\rho_h, \rho_v)\right\}$$
(2)

其中, $A_0^{\gamma}$ 和 $\theta$ 分别为发射信号的幅值信息和相位信息.  $h_{PA}(\tilde{a}_{tx})$ 、 $h_t(\sigma_{TIE}^m)$ 、 $h_{\Delta}(\Delta_n,\Delta_{INL})$ 、 $h_m(\xi)$ 、 $h_p(\rho_h,\rho_v)$ 分别是由放大器、基带信号处理、DAC、混频器和天线引入的非线性参数. 这些特征会寄生在整个射频信号中. 同时在射频发射机架构中,本地振荡器 (local oscillator, LO) 负责产生周期振荡信号,这些信号可被混频器用于在载波频率上转换基带信号. 在理想的LO中,产生的信号可以表示为正弦波形 $\cos(\omega_c t)$ ,这允许将基带信号变频到载波频率 $\omega_c$ 上,同时保持其原始频谱形状. 而在真实的本振中,产生的信号的时域不稳定性会发生随机相位波动,从而导致信号频谱在载波

频率两侧的扩展或再生. 因此, 实际的 LO 振荡信号可以表示为 $\cos(\omega_c t + \theta(t))$ , 其中 $\theta(t)$ 是相位偏差或噪声项. 这种噪声的影响, 通常被称为本振相位噪声, 如图 3 所示, 图 3(a) 为使用理想本振的输出频谱, 图 3(b) 为使用实际本振的输出频谱.

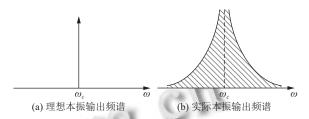


图 3 振荡器输出频谱

发射设备的本振中相位波动引起的频谱扩展或再生,在信号混频时,会使发射信号的频谱展宽.发射机器件的非线性会与本振相位噪声导致的频谱展宽相互作用,寄生在 OFDM 信号中,可以作为射频指纹特征用于识别. OFDM 信号中的短导码由固定的短训练序列生成,与其他信号成分相比更加稳定,更容易分离通信信息和指纹特征,因此从短导码中提取射频指纹更具有可行性.

## 2 基于 FFB-EWT 的信号分解算法

#### 2.1 FFB-EWT 算法原理

本文使用的 FFB-EWT 多尺度信号分解技术, 将接收的短导码分解为若干时频分量. 在通信系统中, 接收到的 I/Q 信号经过解调和模数转换后得到两路信号记为I(n)和O(n),信号的采样率为 $F_s$ ,I路信号的离散傅里

228 研究开发 Research and Development

叶变换结果 $\tilde{I}(k)$ 为:

$$\tilde{I}(k) = \sum_{n=0}^{N-1} I(n) e^{-j\frac{2\pi nk}{N}}$$
 (3)

其中,  $k = 0, 1, 2, \dots, N/2 - 1$ 是信号在 $[0, F_s/2]$ 的离散频 点, 参数N代表信号的长度,  $n = 0, 1, 2, \dots, N-1$ . 在 FFB-EWT 中, 滤波器组是基于[0,π]范围内的固定边界点列 表或[0,F<sub>s</sub>/2]范围内的频率点列表,将信号的傅立叶谱 切片成不同的子信号而生成的. 为了评估给定 I 路信 号的子信号的个数"L", 我们需要有L-1个边界点, 不 包括 0 和  $\pi$ . 第l个边界点 $B_l$ 为:

$$B_l = 2\pi F_l / F_s \tag{4}$$

其中,  $B_l$ 的下限为 $B_0 = 0$ , 上限为 $B_L = N/2$ ,  $l = 1, 2, \dots, L$ ,  $F_l$ 是每个子信号的边界对应的先验频率. 按照 Meyer 小波的方式构建经验小波, 经验尺度函数 $\phi(k)$ 和经验小 波函数 $\psi_l(k)$ 如下<sup>[4]</sup>:

$$\phi(k) = \begin{cases} 1, & \text{if } |k| \leq B_l - T_l \\ \cos\left[\frac{\pi}{2}B\left(\frac{1}{2\tau_l}(|k| - B_l + \tau_l)\right)\right], \\ & \text{if } B_l - \tau_l \leq |k| \leq B_l + \tau_l \\ 0, & \text{Otherwise} \end{cases}$$
 (5)

$$\psi_{l}(k) = \begin{cases}
1, & \text{if } B_{l} + T_{l} \leq |k| \leq B_{l} - T_{l} \\
\cos\left[\frac{\pi}{2}f\left(\frac{1}{2\tau_{l+1}}(|k| - B_{l+1} + \tau_{l+1})\right)\right], \\
& \text{if } B_{l+1} - \tau_{l+1} \leq |k| \leq B_{l+1} + \tau_{l+1} \\
\sin\left[\frac{\pi}{2}f\left(\frac{1}{2\tau_{1}}(|k| - B_{l} + \tau_{l})\right)\right], \\
& \text{if } B_{l} - \tau_{l} \leq |k| \leq B_{l} + \tau_{l} \\
0, & \text{Otherwise}
\end{cases} \tag{6}$$

其中,  $f(y) = x^4(35 - 84x + 79x^2 - 20x^3)$ ,  $l = 2, 3, \dots, L$ , 因 子 $\psi_l(k)$ 表示为 $\tau_l = \gamma \cdot B_l$ ,代表边界点处的过渡带宽度, 当满足 $\gamma < \min_{l} \left( \frac{B_{l+1} - B_{l}}{B_{l+1} + B_{l}} \right)$ 时,信号构成紧支撑框架. 分 解得到的第 1 层子信号 $y_1(n)$ 和第l层子信号 $y_l(n)$ 为:

$$y_1(n) = Re \left[ \frac{1}{N} \sum_{k=0}^{N-1} \left( \tilde{I}(k) \times \overline{\varphi}(k) \right) e^{j\frac{2\pi nk}{N}} \right]$$
 (7)

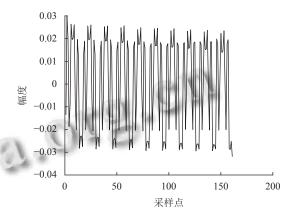
$$y_l(n) = Re \left[ \frac{1}{N} \sum_{k=0}^{N-1} \left( \tilde{I}(k) \times \overline{\psi}_l(k) \right) e^{j\frac{2\pi nk}{N}} \right]$$
(8)

其中,  $\bar{\phi}(k)$ 为经验尺度函数 $\phi(k)$ 的复共轭,  $\bar{\psi}_l(k)$ 为经验

小波函数的复共轭, Re[:]表示取信号的实部.

## 2.2 基于短导码子载波分布的固定频率边界

OFDM 信号的短导码是根据 $S_{-26,26} = \sqrt{\frac{13}{\epsilon}} \{0, 0, 0\}$ 1+j, 0, 0, 0, -1-j, 0, 0, 0, 1+j, 0, 0, 0, -1-j, 0, 0, 0, -1-j, 0, 0, 0, 1+i, 0, 0, 0, 0, 0, 0, 0, -1-i, 0, 0, 0, -1-i, 0, 0, 01+j, 0, 0, 0, 1+j, 0, 0, 0, 1+j, 0, 0, 0, 1+j, 0, 0}的特定子 载波分布模式生成的. 在 IEEE 802.11a 标准的 OFDM 系统中,每个子载波中心频率是固定的,互相正交.图 4 为实际接收的 I 路信号中短导码的时域波形, 采样率 为 20 MHz. 因为频谱的对称性, 在 I/Q 解调后的实信 号中, 短导码相当于使用了 6 个子载波, 用于传输短训 练序列, 根据 IEEE 802.11a 协议规定每个子载波间隔 312.5 kHz, 通过计算可以得到他们的固定边界条件对 应的先验频率点为 $F_l$ =[1.09375, 1.40625, 2.34375, 2.65625, 3.59375, 3.90625, 4.84375, 5.15625, 6.09375, 6.40625, 7.34375, 7.65625] MHz. 将这些频率点代入 式 (4) 中, 可以得到固定频率边界 $B_1$ . 如图 5 所示为按 照固定频率边界划分的频谱.



实际接收的短导码的时域波形

图 5 中 2、4、6、8、10 这几层的子载波分量、携 带信号的有效信息. 在指纹特征的提取过程中, 这些信 号信息本身就是一种干扰,影响对指纹特征的提取,而 剩余的空子载波分量中含有因频谱展宽而携带的指纹 信息,因此去除掉分解后包含信息成分的非空子载波 分量, 选取剩余的 1、3、5、7、9、11、13 这 7 层空 子载波分量,来进行下一步的处理.

## 3 相邻帧空子载波分量时域相干积累

在低信噪比条件下,通信辐射源信号的细微特征

信号易被噪声淹没. 考虑到短导码上附加的辐射源细 微指纹信息在相邻帧具有稳态特性, 而噪声没有相干 性,对短导码信号在相邻帧进行积累可以效提高信噪 比. 而直接对信号在时域进行积累需要定位到每一帧 信号短导码的精确起始位置, 否则即使是微小的偏差, 对相邻帧的短导码进行时域相干积累后,会对信号的 频谱造成影响,导致 FFB-EWT 技术不能完整的分离信 号成分. 为此本文采用对相邻帧的各层子信号分量在 时域进行积累来提高指纹特征信号的信噪比. 假设 FFB-EWT 分解后的第 i 层空子载波分量 $v_i(n)$ 由指纹特 征信号 $\rho_i(n)$ 和噪声 $w_i(n)$ 组成:

$$y_i(n) = \rho_i(n) + w_i(n) \tag{9}$$

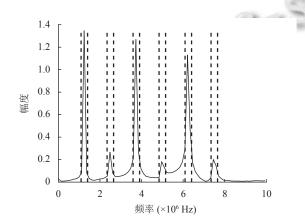


图 5 划分固定边界条件后的频谱

对 M 帧的信号各空子载波分量在时域进行积累:

$$\sum_{j=1}^{M} y_{ij}(n) = \sum_{j=1}^{M} \rho_{ij}(n) + \sum_{j=1}^{M} w_{ij}(n)$$
 (10)

其中,  $\sum_{i=1}^{m} \rho_{ij}(n)$ 和  $\sum_{i=1}^{m} w_{ij}(n)$ 分别代表对第 i 层空子载波 分量中指纹特征信号和噪声的 M 次积累. 考虑到计算 量,选取 M=3,即对相邻帧的空子载波分量进行相干积 累. 因为 FFB-EWT 是一种线性处理方法, 不会改变各 层子信号中噪声的非相干性, 所以各层空子载波分量 中的噪声项 $w_i(n)$ 是非相干随机分布的. 对相邻帧的空 子载波分量进行相干积累,可以使指纹特征信号 $\rho_i(n)$ 的幅度线性增长,而相邻帧的噪声项 $w_i(n)$ 之间不相干, 积累时功率的增长速度小于指纹特征信号相干积累的 功率增长速度. 因此对各层子载波分量进行相干积累, 可以有效增强细微特征信号的强度,提高指纹特征信 号与噪声的信噪比.

230 研究开发 Research and Development

## 4 基于 NCAB-ResNet18 网络结构

## 4.1 基于 NCAB 残差模块的特征提取

残差网络 (ResNet) 由 He 等人于 2016 年提出的[13]. 它引入了残差学习的概念, 通过添加残差块 (residual blocks) 来解决深层神经网络训练过程中的梯度消失和 梯度爆炸问题. ResNet 的核心思想是, 通过加入了 Shortcut 结构, 进行跨层的残差连接, 加快了网络收敛 速度, 让卷积网络学习在多个层次上的复用特征, 提高 了卷积神经网络在图像分类、目标检测等任务中的识 别性能. 残差模块可以简化的定义为:

$$y^i = F(x^i) + x^i \tag{11}$$

其中,  $x^i$ 表示经过 i 层卷积层模块的输入特征,  $v^i$ 是模 块的输出特征、 $F(x^i)$ 是待学习的残差映射. 理想情况 下, 当网络到达最优, 残差映射将降为 0. ResNet 属于 一种深度卷积神经网络, 卷积层能建立信号数据点与 点之间的关系,但很难获取信号数据的整体特征,在实 际信道接收的信号, 会受到噪声干扰, 影响网络对各分 量提取特征的效果. 为此本文构造了结合非局部注意 力机制 (non-local attention block) 模块和通道注意力机 制 (channel attention block) 的残差模块. 本文将结合非 局部注意力和通道注意力的模块称为 NCAB 残差模 块,具体模型结构如图 6 所示.

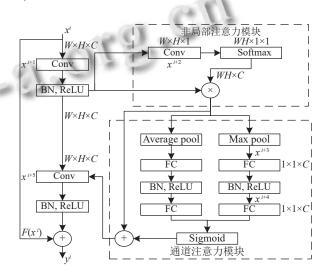


图 6 结合非局部注意力和通道注意力的残差模块

输入的特征图 $x^i$ 的尺寸为 $W \times H \times C$ , 其中W代表特 征图宽度, H 代表特征图高度, C 代表特征图输入的通 道数, Conv 代表卷积层, ReLU 为激活函数, BN 代表对 数据进行批规范化处理. 在非局部注意力模块中对输 入信号转换计算相关性权重, 然后使用相关性权重来 加权平均所有值点, 获得非局部特征图[14]. 对获得非局 部特征图与输入信号进行残差连接, 确保信息完整性 然后再将对整合好的信号进行输出. 非局部注意力模 块可以从空间的角度建立对局部特征的长期依赖性, 使网络更佳关注特征图的细节特征. 通道注意力模 块[15]通过全局平均池化和全局最大池化分别将信号的 每张特征图挤压成1个一维向量,我们可以通过将特 征图对应的全局特征点从 WH×WH 变成 WH×1×1, 其 输出从 W×H×C 变成 1×1×C, 然后将挤压结果作为每 个特征图的通道注意力的权重,然后通过两个全连接 层和一个 ReLU 激活函数, 为每个通道学习权重. 然后 将通过全连接层的全局平均池化和全局最大池化处理 的结果求和,用 Sigmoid 函数处理输出结果,将其映射 到0和1之间,表示不同通道特征的权重.这些权重表 示每个通道对于最终预测的重要性. 然后计算不同通 道的特征权重,将得到的通道权重与输入张量相乘,以 通过对应通道的加权和来生成最终的输出.

在 OFDM 辐射源个体识别任务当中, 不同频段信 号的指纹特征含量不同,对最终的识别贡献不同,而 NCAB 残差模块可以使网络更加关注指纹特征贡献更 多的信号分量上的特征,同时可以弥补残差神经网络 的局部感受野的缺陷, 提升网络在低信噪比条件下对 指纹特征的提取性能, 最终提高识别率.

#### 4.2 基于双通道的 NCAB-ResNet18 网络的分类

在 ResNet 系列中, ResNet18 相较于 ResNet34, ResNet50 有较低的网络复杂度, 具体的网络结构见文 献[9]. 同时因为经过 FFB-EWT 分解后的样本尺寸较 小, 浅层网络就可以有效提取特征, 因此本文选取 ResNet18 网络框架作为参考, 将改进的 NCAB 残差模 块嵌入到 ResNet18 中, 得到 NCAB-ResNet18 作为主 体网络进行特征提取.

在通信系统中 I 路信号与 Q 路信号是正交的, 两 路信号在时域和频域上呈现通信辐射源不同的指 纹特征. 将两路信号的特征融合起来, 可以更全面地 利用信号中包含的全部信息,从而提高识别的准确性 和可靠性. 为此本文采用如图 7 所示的双通道的网络 结构.

如图 7 所示, 将经过 FFB-EWT 分解和时域相干积 累处理后的 IO 两路信号分别使用相同参数的 NCAB-ResNet18 网络来提取特征, 通过最大池化降低特征图 的维度, 捕捉特征图中的显著特征. 然后通过 Cat 操作, 将两路的特征沿同一维度进行串联,送入全连接网络 中将特征进行整合, 最后通过 Softmax 层进行最终的 分类决策输出.

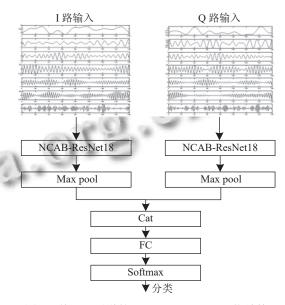


图 7 基于双通道的 NCAB-ResNet18 网络结构

## 5 算法主要流程

本文算法主要处理流程如下.

- 1) 将采样率为 20 MHz 的 I/Q 信号解调为两路实 信号,对接收信号计算短训练序列和信号的互相关.确 定信号起始位置.
- 2) 使用移动窗口对 I 路信号和 Q 路信号的短导码 进行对齐切片. 处理后的数据为 2×160 格式.
- 3) 对两路信号的输入数据 z(n) 进行式 (12) 的标准 化处理, 让使对每一路信号中的据样本的均值等于 0, 方差为1,使数据在一个标准的尺度上.

$$z_{n} = \frac{z_{n} - \frac{1}{N} \sum_{i=1}^{N} z_{n}}{\sqrt{\frac{1}{N} \sum_{i=1}^{N} \left(z_{n} - \frac{1}{N} \sum_{i=1}^{N} z_{n}\right)^{2}}}$$
(12)

4) 使用 FFB-EWT 技术对两路标准化处理后的 短导码进行分解,输入的频率边界为 $F_l$ =[1.09375, 1.40625, 2.34375, 2.65625, 3.59375, 3.90625, 4.84375, 5.15625, 6.09375, 6.40625, 7.34375, 7.65625] MHz. 去 除每路信号中包含信息的2、4、6、8、10子载波分

量、保留剩余包含指纹特征的1、3、5、7、9、11、 13 这 7 层空子子载波分量, 处理后每个样本的数据格 式为 2×7×160.

- 5) 对每一层子信号与相邻帧同层的空子载波分 量进行相干积累. 处理后每个样本的数据格式仍为  $2\times7\times160$ .
- 6) 将相干积累后的数据样本使用双通道的 NCAB-ResNet18 网络模型进行训练,每个通道输入为 1×7× 160, 在通过 NCAB-ResNet18 网络模型提取特征后, 进 行最大池化对数据降维, 然后将 2 路特征通过 Cat 操 作进行拼接, 使用 Softmax 函数进行分类.
- 7) 根据验证集的实验结果选择最优的网络参数, 用训练好的网络模型去对测试集中样本进行测试,得 到识别结果.

## 6 实验结果及仿真

## 6.1 实验条件设置

实验所使用的硬件平台为 Gen InterCore(TM) i7-12700H CPU, GPU 为 NVIDIA GeForce RTX 3070 Ti Laptop GPU. 信号处理部分在 Matlab 2021a 环境下进 行, 深度学习网络训练环境为 Python 3.9+PyTorch 1.9.

## 6.2 数据集处理

实验所使用的数据集为开源数据集 ORACLE[16], 该数据使用相同型号的 URSP 作为发射器、由 Matlab WLAN 系统工具箱生成信号,产生具有相同的硬件、 协议、物理地址和介质访问控制地址的数据帧,并使 用同一个设备来对信号进行接收. 本文选取 6 台发射 机的信号数据, 信号采样率为 20 MHz, 信噪比取值区 间[-4, 6] dB, 以 2 dB 为间隔, 每类提取 1000 个信号前 导部分样本,每个样本长度为160,训练集数据、验证 集、测试集数据按照8:1:1的比例进行划分,其中训 练集样本数为4800,验证集和测试集样本数为600,网 络的 batch size 设置为 64, 训练轮次为 50, 使用 Adam 算法来对网络进行优化.

# 6.3 不同分解方法对比

为了验证 FFB-EWT 分解方法的有效性,与 FBR-EWT, EMD, VMD 方法进行对比, 同时使用 NCAB-ResNet18 网络模型在 0 dB 信噪比条件下进行实验, FFB-EWT 分解层数设置为 13, FBR-EWT 分解层数设 置为 6, VMD 分解层数设置为 6, EMD 最大迭代次数 设置为 5, 统计对所有 6000 个样本的处理时间, 并记

录准确率, 如表 1 为 0 dB 信噪比条件下不同分解方法 对比.

表 1 0 dB 信噪比条件不同分解方法对比

对比项	FFB-EWT	FBR-EWT	VMD	EMD
准确率 (%)	83.33	80.17	84.67	58.67
处理时间 (s)	124.39	111.8	483.87	134.5

由表 1 可知, 除 EMD 方法外, FFB-EWT, FBR-EWT, VMD 方法在 0 dB 条件下都取得高于了 80% 的 识别准确率,说明了在使用短导码进行实验的过程中, 网络更容易提取到射频指纹特征. 分解相同层数的 VMD 方法比 FBR-EWT 方法的识别准确率高 4.60%, VMD 方法的处理时间为 FBR-EWT 方法的处理时间 的 435.1%. 分析出现这样的结果是因为 VMD 方法本 质是多个自适应的维纳滤波器, 对噪声有更强的鲁棒 性, 因此识别精度高于 FBR-EWT 方法, 但同时计算开 销更大. 而本文提出的 FFB-EWT 方法在去掉含信号信 息的子载波分量后进行识别取得了接近 VMD 方法的 识别率, 说明了 FFB-EWT 方法的有效性. 同时在分解 层数更多的情况下所有样本的处理时间只比 FBR-EWT 多 11.3%, 说明了 FFB-EWT 方法在计算开销不 大的同时,能有效地对信号进行分解,帮助网络更好地 提取出信号中的时频特征.

#### 6.4 对比实验

为了验证本文方法对 I/Q 通信辐射源信号识别的 有效性,本文与其他文献方法进行了对比.对比文献[12] 使用了 FBR-EWT 对信号进行分解,并使用深度卷积 神经网络进行识别. 文献[17]设计了一种 ResNet50-1D 网络模型对一维时间序列的 IQ 数据进行识别; 文献[18] 设计一种复数 CNN (CV-CNN) 网络, 可将复数 IQ 信 号直接输入网络进行识别; 文献[19]使用 VGG16 的类 似网络模型提取 I/Q 两路的相关特征. 使用以上文献 中应用的相关方法与本文方法进行对比实验.图8为 对比实验结果图.

如图 8 所示, 本文提出的方法在各种信噪比条件 下均取得了最高的识别率,同时随着信噪比逐渐降低, 识别准确率相较别的方法越高. 表 2 为不同信噪比条 件下各个方法的识别准确率.

由表 2 可知在 0 dB 条件下文献[17-19]的网络对 I/Q 信号的前导部分识别准确率分别为 68.17%, 79.50%, 76.83%. 与本文使用类似方法对信号先进行 FBR-EWT

232 研究开发 Research and Development

的文献[12]在此信噪比条件下的识别率为81.83%,而 本文方法在 0 dB 信噪比条件下识别率达到 89.33%, 比 文献[12]的方法识别率高 8.5%, 分析出现的结果一是 因为文献[17-19]都是将原始 I/Q 路信号直接送入神经 网络中而本文方法与文献[12]的方法都是在对信号进 行时频域分解后送入神经网络中,这样能放大信号特 征, 让网络能更好地提取指纹特征. 二是因为使用 FFB-EWT 方法能够去掉含有信号信息干扰的子载波. 同时本文使用相邻帧间相同层子载波的相干积累方法, 能有效提高指纹信号的信噪比, 因此在低信噪比条件 下能准确提取通信辐射源信号的指纹特征,说明了本 文方法对噪声具有较强的鲁棒性.

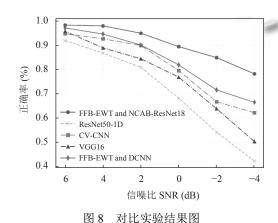


表 2 不同信噪比条件下各个方法的识别准确率 (%)

SNR	FFB-EWT和	FBR-EWT和	RES50-	CUCNNI	VCC16
(dB)	NCAB-ResNet18	DCNN	1D	CVCNN	VGG16
6	98.17	97.00	91.83	94.67	95.67
4	97.83	94.50	86.67	92.50	88.83
2	94.83	90.00	80.83	89.83	84.33
0	89.33	81.83	68.17	79.50	76.83
-2	84.83	71.57	54.17	66.67	63.83
-4	78.17	66.47	42.33	62.17	50.33

#### 6.5 消融实验

为了进一步研究对空子载波分量进行相干积累和 NCAB-ResNet18 带来的影响, 在分别在对子载波不进 行积累,不使用 NCAB-ResNet18 进行消融实验,如表 3 所示为 0 dB 条件下消融实验的识别率.

由表 3 可知, 使用 ResNet18、NCAB-ResNet18、 进行子载波积累的 ResNet18、进行子载波积累的 NCAB-ResNet18的方法,在0dB条件下的进行消融实 验的识别结果分别为77.67%、83.33%、81.00%、 89.33%. 可以看出使用在对空子载波分量进行积累后, ResNet18 和 NCAB-ResNet18 分别提高了 3.33% 和 11.66%, 在不对空子载波分量进行积累时, NCAB-ResNet18 较 ResNet18 提高了 5.66%, 能够体现 NCAB-ResNet18 在低信噪比条件下对经过 FFB-EWT 去除信 号成分后进行识别辐射源信号的有效性.

表 3 0 dB 条件下消融实验的识别率 (%)

结构	不相干积累	相干积累
ResNet18	77.67	81.00
NCAB-ResNet18	83.33	89.33

## 结论

针对在传统辐射源个体识别方法中 OFDM 辐射 源细微指纹特征信息会受到信号成分和信道噪声的影 响导致分类识别率低的问题,本文对 OFDM 信号进行 FFB-EWT 分解, 有效去除信号成分干扰, 通过对空子 载波分量进行相干积累,来提高指纹特征信号的信噪 比; 使用通过嵌入非局部注意力机制模块和通道注意 力机制模块, 来提升 ResNet18 的识别性能, 使用双通 道的 NCAB-ResNet18 网络模型来对 I/Q 两路数据提 取特征及分类. 实验表明通过对 6 个不同辐射源个体在 6 dB 和 0 dB 条件下进行识别, 准确率可以达到 98.17% 和 89.33%, 通过对比实验, 使用 FFB-EWT 和 NCAB-ResNet18的 OFDM 辐射源个体识别方法与其他处理 方法相比, 具有识别率高、抗噪性能好的优势.

## 参考文献

- 1 Fu X, Shi SN, Wang Y, et al. Semi-supervised specific emitter identification via dual consistency regularization. IEEE Internet of Things Journal, 2023, 19257-19269. [doi: 10.1109/JIOT.2023.3281668]
- 2 Zhang YB, Peng Y, Sun JL, et al. GPU-free specific emitter identification using signal feature embedded broad learning. IEEE Internet of Things Journal, 2023, 13028-13039.
- 3 Zha HR, Wang HH, Feng ZM, et al. LT-SEI: Long-tailed specific emitter identification based on decoupled representation learning in low-resource scenarios. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(1): 929-943. [doi: 10.1109/TITS.2023.3308716]
- 4 Halder S, Newe T. Radio fingerprinting for anomaly detection using federated learning in LoRa-enabled industrial Internet of Things. Future Generation Computer Systems, 2023, 143: 322–336. [doi: 10.1016/j.future.2023.01.021]



- 5 Wu WW, Hu S, Lin D, *et al.* Radio-frequency fingerprinting for distributed IoT networks: Authentication and QoS optimization. IEEE Systems Journal, 2023, 17(3): 4440–4451. [doi: 10.1109/JSYST.2023.3248685]
- 6 Lundén J, Koivunen V. Automatic radar waveform recognition. IEEE Journal of Selected Topics in Signal Processing, 2007, 1(1): 124–136. [doi: 10.1109/JSTSP.2007. 897055]
- 7 Zhang JW, Wang FG, Dobre OA, *et al.* Specific emitter identification via Hilbert-Huang transform in single-hop and relaying scenarios. IEEE Transactions on Information Forensics and Security, 2016, 11(6): 1192–1205. [doi: 10. 1109/TIFS.2016.2520908]
- 8 韦建宇, 彭来献, 俞璐, 等. 基于差分-变分模态分解与全局信息分析网络的辐射源个体识别方法. 信号处理, 2022, 38(10): 2092-2101.
- 9 Jiang Q, Sha J. RF fingerprinting identification in low SNR scenarios for automatic identification system. IEEE Transactions on Wireless Communications, 2024, 23(3): 2070–2081. [doi: 10.1109/TWC.2023.3294988]
- 10 Gilles J. Empirical wavelet transform. IEEE Transactions on Signal Processing, 2013, 61(16): 3999–4010. [doi: 10.1109/ TSP.2013.2265222]
- 11 Panda R, Jain S, Tripathy R, et al. Detection of shockable ventricular cardiac arrhythmias from ECG signals using FFREWT filter-bank and deep convolutional neural network. Computers in Biology and Medicine, 2020, 124: 103939. [doi: 10.1016/j.compbiomed.2020.103939]
- 12 Bremnes K, Moen R, Yeduri SR, *et al.* Classification of UAVs utilizing fixed boundary empirical wavelet sub-bands of RF fingerprints and deep convolutional neural network. IEEE Sensors Journal, 2022, 22(21): 21248–21256. [doi: 10.1109/JSEN.2022.3208518]

- 13 He KM, Zhang XY, Ren SQ, et al. Deep residual learning for image recognition. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016. 770–778.
- 14 Wang XL, Girshick R, Gupta A, et al. Non-local neural networks. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 7794–7803.
- 15 Woo S, Park J, Lee JY, et al. CBAM: Convolutional block attention module. Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 2018. 3–19.
- 16 Sankhe K, Belgiovine M, Zhou F, et al. No Radio Left Behind: Radio fingerprinting through deep learning of physical-layer hardware impairments. IEEE Transactions on Cognitive Communications and Networking, 2020, 6(1): 165–78
- 17 Gritsenko A, Wang ZF, Jian T, et al. Finding a 'new' needle in the haystack: Unseen radio detection in large populations using deep learning. Proceedings of the 2019 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN). Newark: IEEE, 2019. 1–10.
- 18 Agadakos I, Agadakos N, Polakis J, et al. Chameleons' oblivion: Complex-valued deep neural networks for protocolagnostic RF device fingerprinting. Proceedings of the 2020 IEEE European Symposium on Security and Privacy (EuroS&P). Genoa: IEEE, 2020. 322–338.
- 19 Elmaghbub A, Hamdaoui B. LoRa device fingerprinting in the wild: Disclosing RF data-driven fingerprint sensitivity to deployment variability. IEEE Access, 2021, 9: 142893– 142909. [doi: 10.1109/ACCESS.2021.3121606]

(校对责编: 张重毅)