

# 智能多载波波形调制系统：信号的产生与识别

邵凯<sup>\*①②③</sup> 付旭阳<sup>①②</sup> 王光宇<sup>①②③</sup>

<sup>①</sup>(重庆邮电大学通信与信息工程学院 重庆 400065)

<sup>②</sup>(移动通信技术重庆市重点实验室 重庆 400065)

<sup>③</sup>(移动通信教育部工程研究中心 重庆 400065)

**摘要：**移动通信应用场景逐渐呈现复杂化和多变化趋势，很难有一种普适性传输波形满足所有通信需求，这对多种波形的配合与协作提出了较高的要求。该文提出一种适用于复杂场景下的智能化多载波波形调制系统，发送端可通过波形激活因子选择产生合适的传输波形，接收端将不同波形信号的I/Q分量作为自适应因子，使用主成分分析法处理数据后送入智能波形识别网络(IWR-Net)完成信号的识别。所提系统融合深度学习网络，具有较为统一的硬件架构。仿真结果表明，所提方案在5G多场景下对不同发送波形识别准确率最高可达98.2%，并且在不同测试环境中具有良好的泛化性能。

**关键词：**智能化多载波波形调制系统；多载波波形识别；深度学习；智能波形识别网络

中图分类号：TN911

文献标识码：A

文章编号：1009-5896(2021)11-3096-09

DOI: 10.11999/JEIT201064

## Intelligent Multi-carrier Waveform Modulation System: Signal Generation and Recognition

SHAO Kai<sup>①②③</sup> FU Xuyang<sup>①②</sup> WANG Guangyu<sup>①②③</sup>

<sup>①</sup>(School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

<sup>②</sup>(Chongqing Key Laboratory of Mobile Communications Technology, Chongqing 400065, China)

<sup>③</sup>(Engineering Research Center of Mobile Communications, Ministry of Education, Chongqing 400065, China)

**Abstract:** Mobile communication applications scenarios are becoming complexity and diversity. It is difficult to have a universal transmission waveform to meet all communication needs, which puts forward high requirements for the coordination and collaboration of multiple waveforms. In this paper, an intelligent multi-carrier waveform modulation system is proposed for complex scenarios, the sending end can select a suitable transmission waveform by the waveform activation factor, the receiving end will take the I/Q component of different waveform signals as an adaptive factor, and use the main component analysis method to process the data and feed it into the Intelligent Waveform Recognition Network (IWR-Net) to complete the identification of the signal. The proposed system is integrated with deep learning network and has a more unified hardware architecture. The simulation results show that the accuracy of different send waveform recognition can be as high as 98.2% in 5G multi-scenes, and it has good generalization performance in different test environments.

**Key words:** Intelligent multi-carrier waveform modulation system; Multi-carrier waveform recognition; Deep learning; Intelligent Waveform Recognition Networks (IWR-Net)

### 1 引言

随着信息技术的不断发展，人类对信息通信提出了更高的个性化需求。2019年全球首份6G白皮书认为未来通信将深度融合人工智能，智能传感、智能定位、智能资源分配等将成为现实<sup>[1]</sup>。通信技

术的应用趋势会逐渐向智能化、自适应化发展<sup>[2,3]</sup>。

在不同应用场景，信息传输业务逐渐呈现多元化趋势。例如，新空口(New Radio, NR)标准定义的部分带宽(BandWidth Part, BWP)技术为用户设备灵活分配多个不同参数集的BWP，根据场景需求激活某个BWP承载不同业务<sup>[4]</sup>。目前，业界已提出多种新型多载波候选波形，例如正交频分复用(Orthogonal Frequency-Division Multiplexing,

OFDM)、滤波正交频分复用(Filtered Orthogonal Frequency-Division Multiplexing, FOFDM)、通用滤波多载波(Universal Filtered MultiCarrier, UFMC)、滤波器组多载波(Filter Bank MultiCarrier, FBMC)、广义频分复用(Generalized Frequency Division Multiplexing, GFDM)等,各波形根据实际场景为物理帧结构配置带宽、循环前缀(Cyclic Prefix, CP)、子载波间隔、传输时间间隔(Transmission Time Interval, TTI)等参数。FOFDM将频段划分为多个子带并通过子带间滤波减少干扰,灵活配置子带参数以实现自适应空口,如物联网业务中为传输子带配置较窄的载波宽度来实现大覆盖,低功耗需求<sup>[5]</sup>。FBMC基于子载波滤波,以复数域的正交性为代价换取波形时域局限性的设计自由度,由于该波形无CP,系统开销减少,适用于低时延业务中由于短的TTI设计导致CP开销过大的场景<sup>[6]</sup>。UFMC对一组连续子载波进行滤波,波形可以根据业务差异配置不同参数,既支持高带宽的高清视频业务,也支持低带宽物联网业务,系统具有高灵活性和可扩展性<sup>[7]</sup>。目前,基于应用场景的复杂性和多变性,很难有一种普适性传输波形满足所有通信需求,这对多种波形的配合与协作提出了较高的要求。但是,传统通信系统中不同波形的产生与接收需要不同的硬件收发结构,不仅增加了设备的部署成本和维护成本<sup>[8]</sup>,更限制了多种波形相互协作的灵活性与自适性。因此,本文提出设计一种更具智能化和自适应化的通信调制结构,在发送端,可以按用户需求产生不同多载波波形,而在接收端可以对信号进行精准识别和接收。

设计智能化调制系统的首要难题是对发送波形的准确识别。目前,信号调制识别已经成为学术界普遍关注的焦点。传统的信号调制识别方案如基于似然性的方法<sup>[9]</sup>,基于特征的方法<sup>[10]</sup>用于单载波或多载波调制信号分类,但是这些方案具有手工提取特征不充分,信号识别鲁棒性较差等问题,基于深度学习(Deep Learning, DL)的信号识别方法能很好地解决以上问题。文献<sup>[11]</sup>将原始接收信号转化为模糊函数图像,使用堆叠稀疏自编码器从模糊函数图像中提取特征并输入到分类器中实现的信号分类。文献<sup>[12]</sup>使用深度残差网络实现信号调制识别,将同向/正交(In-phase/Quadrature, I/Q)信号视为图像数据训练神经网络,设置不同超参数分析模型性能,验证模型鲁棒性。文献<sup>[13]</sup>提出结合两个不同数据集上训练的卷积神经网络(Convolutional Neural Networks, CNN),先以I/Q数据训练CNN1模型,然后以信号星座图对CNN2模型进行

训练,主要针对CNN1模型中难以区分的调制信号样本的识别。文献<sup>[14]</sup>提出使用时域信号幅度序列作为输入特征训练CNN识别FBMC, OFDM, UFMC 3种多载波信号。采用幅度序列作为输入特征对波形识别具有一定的局限性,缺失了原始I/Q信号的部分特征并且对噪声干扰较敏感,训练模型的泛化性有待验证。

因为受到经典通信结构技术限制,现有文献对多种多载波波形产生和识别的研究相对较少。随着无线通信系统与人工智能深度融合<sup>[15,16]</sup>,无线物理层结合人工智能的设计必是值得关注的重点方向。本文提出一种融合DL的智能化波形调制系统,主要贡献为:(1)提出一种集成化的多载波波形发送模型,根据实际应用场景需求,通过波形激活因子控制OFDM, FOFDM, UFMC 3种波形的发送。(2)提出一种智能波形识别网络(Intelligent Waveform Recognition Network, IWR-Net),根据发送波形特征的差异性,采用基于DL的方法自动提取并学习特征,实现对发送波形准确地,智能地识别。受篇幅所限,本文未对所提系统识别后解码部分详细阐述。文章其余部分结构如下:第2节给出智能波形收发系统基本模型;第3节、4节分别详细介绍集成化波形发送模块及IWR-Net设计;第5节为仿真及结果分析;最后给出结论。

## 2 系统模型

图1给出智能波形收发系统基本模型,由多载波波形集成发送模块、智能波形识别网络、解调网络组成。在发送端,根据实时业务需求及应用场景关键指标(时延、连接数量、信息速率等),多载波波形集成发送模块通过设置波形激活因子,按场景需求生成一种多载波波形。在接收端,首先由波形识别网络自动提取接收信号特征,识别波形种类,然后将对应类别波形数据送入离线训练好的解调网络中完成信号恢复。

## 3 波形集成发送模块

OFDM要求按照完整频段统一配置波形参数,它能有效对抗多径衰落,支持灵活的频率选择性调度,适合低复杂度条件下的移动宽带业务场景;FOFDM和UFMC都具有滤波的机制,其中UFMC使用了冲击响应较短的滤波器,支持突发通信场景,适用于短小数据包类业务;FOFDM则使用了时域冲击响应较长的滤波器,子带内部采用和OFDM一致的信号处理方案,兼容OFDM相关技术,并且波形参数配置灵活,可基本满足其他5G应用场景。

波形集成发送模块的设计主要遵循模块化合并

原则。在OFDM标准结构基础上，通过对完整的OFDM信号增加窗函数滤波处理，可以得到FOFDM信号。而UFMC方案综合了子带滤波的概念，对OFDM信号子载波进行分簇的后置滤波处理。鉴于3种波形调制结构的相似性和差异性，提出如图2所示的集成化波形发送模型。首先根据业务需求由网络上层决策配置波形参数，然后完成业务类型与波形激活因子的映射，最后通过配置不同的波形激活因子( $a, b \in \{0,1\}$ )，实现智能化发送不同多载波波形(OFDM, FOFDM, UFMC)的功能。数据源随机产生二进制向量，通过星座映射得到符号序列，将符号序列进行快速傅里叶逆变换(Invert Fast Fourier Transformation, IFFT)被不同子载波调制。此时，进入波形激活因子配置阶段：

**情况1** 当波形激活因子取 $b = 1, a = 0$ 时，将经过 $N$ 点IFFT后的待发射信号中插入CP，生成OFDM符号 $S_1$ 。

**情况2** 当取 $b = 1, a = 1$ 时，为OFDM发送端增加滤波器进行子带滤波处理，生成FOFDM符号 $S_2$ 。

**情况3** 当取 $b = 0$ 时，对一组连续子载波进行滤波，生成UFMC符号 $S_3$ 。

对比传统一种波形的发送结构设计，所提集成化模型实现了模块化的共用，能够有效地减少硬件设备部署成本，在多种波形相互协作的多场景复杂通信中更具适用性和灵活性，只需根据场景需求对激活因子完成配置，便可实现不同多载波波形的发送。

### 4 智能波形识别网络

在本文所提智能波形收发系统中，波形识别网络是接收端正确解码的关键。实现步骤为：(1)生成3种波形接收数据合并后作为原始数据集；(2)通过数据预处理使原始数据集中不同参数配置下的波形信号实现维度统一；(3)设计一种智能波形识别网络，自动提取波形的频谱特征，在接收端实现准确识别。图3为所提IWR-Net的流程框图，分别由以下部分组成：生成训练数据集和数据预处理、搭建神经网络及模型训练。

#### 4.1 生成训练数据集

随机生成比特流通过发送端，3种波形信号




图1 智能波形收发系统

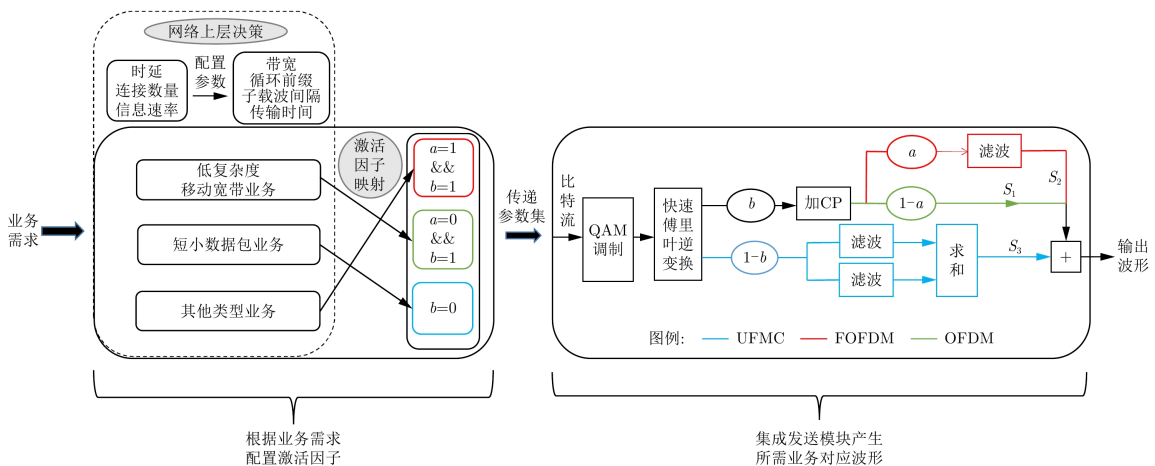


图2 集成化波形发送模型

OFDM, FOFDM, UPMC的发送数据可以分别表示为

$$S_1(k) = \sum_n \sum_m x_{m,n} P_1(k - mN) \cdot \exp [2j\pi(k - mN)n/N] \quad (1)$$

$$S_2(k) = \sum_n \sum_m x_{m,n} \exp [2j\pi(k - mN)n/N] \times P_2(k) \quad (2)$$

$$S_3(k) = \sum_{i=1}^B \sum_m \sum_{n=-\infty}^{\infty} a_{m,n,i} P_3(k - mL_1) \cdot \exp [2j\pi(k - mL_1)/N] \quad (3)$$

将3种发送信号经信道衰落和高斯白噪声干扰后合并，得到原始训练数据集 $y_o$ ，表示为

$$y_o(k) = \sum_{r=1}^3 S_r(k) * h_r(k) + w_r(k) \quad (4)$$

参数定义如下： $N$ 为子载波个数， $x_{m,n}$ 为第 $n$ 个子载波上第 $m$ 个发送符号， $P_1$ 为原型滤波器， $P_2$ 为子带滤波器， $B$ 代表子带数量， $a_{m,n,i}$ 表示第 $m$ 个UPMC符号第 $i$ 个子带的第 $n$ 个子载波上的调制数据， $P_3$ 是长度为 $L$ 的滤波器， $L_1$ 表示UPMC发送数据长度， $*$ 表示卷积运算， $S_r(k)$ 表示不同波形发送数据， $h_r(k)$ 代表不同信道增益， $w_r(k)$ 为高斯白噪声。

### 4.2 数据预处理

由于不同波形参数设置的差异性和灵活性，不同维度大小的接收信号不能直接作为训练数据集，原始训练集中复数数据需要处理后再送入神经网络。

处理方法如图4所示，首先提取各波形复数数据的实部和虚部进行合并，然后采用主成分分析法(Principal Components Analysis, PCA)对原始数据降维，最后将2维数据升维为3维数据，处理后的输入数据被重塑为单通道的 $2 \times d^*$ 大小的图像(Channel×Width×Height)送入网络训练模型。由于神经网络不能输入非文本数据，波形对应的标签进行独热编码处理，编码结果为：OFDM波形的标签表示为[1,0,0]；FOFDM表示为[0,1,0]；UPMC表示为[0,0,1]。

由于接收信号高维特征中存在数据冗余及信道噪声污染，如表1，采用PCA分别处理3种波形接收数据，把高维特征降到低维。假设数据集 $X$ 中有 $m$ 个波形训练样本： $X = (x_1, x_2, \dots, x_m)$ ，提取复数信号I/Q两路视为每个样本的两个特征，每个特征具有 $d$ 维。T表示矩阵转置，第 $i$ 个波形样本 $x_i$ 表示为

$$x_i = \begin{bmatrix} x_{i1}^1, x_{i1}^2, \dots, x_{i1}^d \\ x_{i2}^1, x_{i2}^2, \dots, x_{i2}^d \end{bmatrix}_{d \times 2}^T \quad (5)$$

输入数据 $X$ 表示为

$$X = (x_1, x_2, \dots, x_m)_{d \times 2 \times m}^T \quad (6)$$

在生成训练集过程中，接收端原始数据的维度大小为：OFDM(1,1510)，FOFDM(1,841)，UPMC(1,328)，通过对比实验后选择原始数据的前200个特征维度作为主成分。降维后的数据送入神经网络训练模型，不但能抑制噪声干扰，而且减少模型拟合时间，使网络更容易训练。

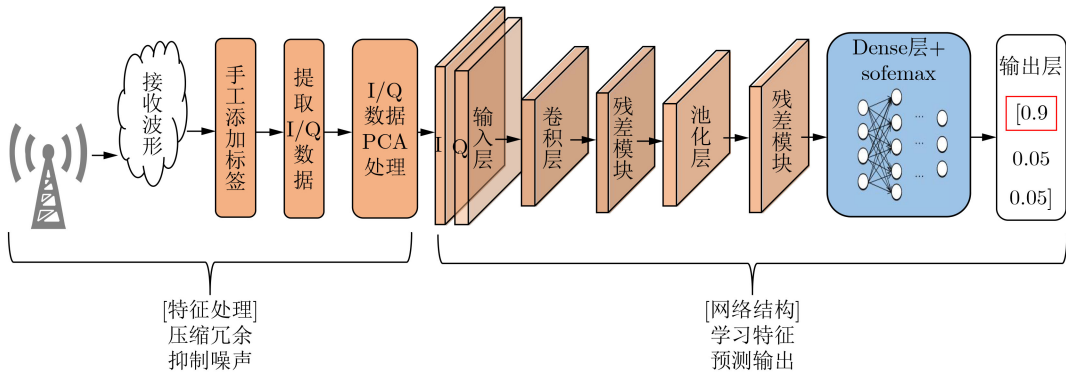


图3 IWR-Net流程图




图4 复数信号处理

### 4.3 网络结构设计与训练

神经网络的深度能保证特征的抽象能力和泛化性能,为了获得波形信号的深层参数同时避免网络的退化问题,本文参考ResNet18网络构造框架,结合波形信号自身性质,设计如图5所示具有残差连接结构的15层网络,将输入信号视为单通道大小为 $2 \times 200$ 的特征向量,实现信号特征的自动提取。采用的DL模型共有4个残差连接,一个最大池化层、全连接层、Dropout层和Softmax层,卷积结束后使用修正线性单元(Rectified Linear Unit, ReLU)作为激活函数,有效解决正区间梯度消失所造成训练困难等问题。

如图5所示,在第1个残差层中,首先由一个 $1 \times 1$ 大小的卷积核对输入图像 $X$ 进行升维处理,拓宽网络通道。接着将输出数据传递到卷积核大小为 $3 \times 2$ 的卷积层,卷积核重复作用于整个特征图的感受野获取波形数据最主要的特征,并通过ReLU激活函数获取输入的非线性映射关系,得到更具表达能力的波形特征。为了卷积核能充分提取边缘信息,添加零填充,最后再次经过卷积核大小为 $3 \times 2$ 的卷积层,将输出结果使用残差连接合并作为新的输入数据逐层传递。残差连接使网络旁路支

将输入直接连接到后面的层,缓解了因网络层数加深而导致信息传递过程中的损耗问题,保证了信息传递的完整性。上述中残差连接过程可表示为

$$Y = w_3 * f(w_2 * Y_1 + b_2) + b_3 + Y_1 \quad (7)$$

其中 $Y_1$ ,  $w_i$ ,  $b_i$ ,  $f$ 分别表示第1层隐藏层输出、第 $i$ 隐藏层权重矩阵、偏置、激活函数,\*表示卷积操作。

文中使用大小为 $2 \times 2$ 的最大池化层执行下采样操作,通过池化窗口找到滤波器输出的最大值,减少参数和网络训练复杂度。最后由全连接层整合输出特征图中的特征,帮助模型获取波形特征具有的高层含义,加入防止模型训练过拟合的Dropout层,通过Softmax函数实现波形正确分类。

训练IWR-Net过程中,使用Glorot均匀分布初始化器随机设置起始权重和偏置,采用自适应矩(Adaptive moment, Adam)估计算法更新参数集,根据梯度1阶矩估计和2阶矩估计动态设置每个参数的学习率,通过参数迭代实现更好的收敛效果。使用交叉熵损失函数计算损失值,模型预测损失表示为

$$\text{Loss} = -\frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \lg(p_{ic}) \quad (8)$$

表1 PCA算法处理接收信号流程

输入: 原始波形样本数据 $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m)^T_{d \times 2 \times m}$ , 降维后维度大小 $d^*$ ;
输出: 降维后的波形数据 $\mathbf{Y} = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_m)^T_{d^* \times 2 \times m}$ ;
(1) for(int $j=0$ ; $i<3$ ; $i++$ ), do
(2) [OFDM, FOFDM, UFMFC]: $\mathbf{x}_i \leftarrow \mathbf{x}_i - \frac{1}{m} \sum_{i=1}^m \mathbf{x}_i$ ; //对第 $j$ 种波形数据样本中心化处理
(3) $\mathbf{C} = \frac{1}{m} \mathbf{X} \mathbf{X}^T$ ; //计算波形样本的协方差矩阵
(4) 从最大可分性出发,构造优化目标: $\Rightarrow \max_{\mathbf{W}} \text{tr}(\mathbf{W}^T \mathbf{X} \mathbf{X}^T \mathbf{W})$ , s.t. $\mathbf{W}^T \mathbf{W} = \mathbf{I}$ ;
(5) 使用拉格朗日乘法得: $\mathbf{X} \mathbf{X}^T \mathbf{W} = \lambda \mathbf{W}$ ;
(6) 协方差矩阵 $\mathbf{X} \mathbf{X}^T$ 特征值分解,特征值大小排序后: $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$ ;
(7) 取最大的 $d^*$ 个特征值所对应的特征向量 $\omega_1, \omega_2, \dots, \omega_{d^*}$ 组成矩阵 $\mathbf{P}$ ;
(8) 计算降维后的矩阵 $\mathbf{Y} = \mathbf{P} \mathbf{X}$ ;
(9) end

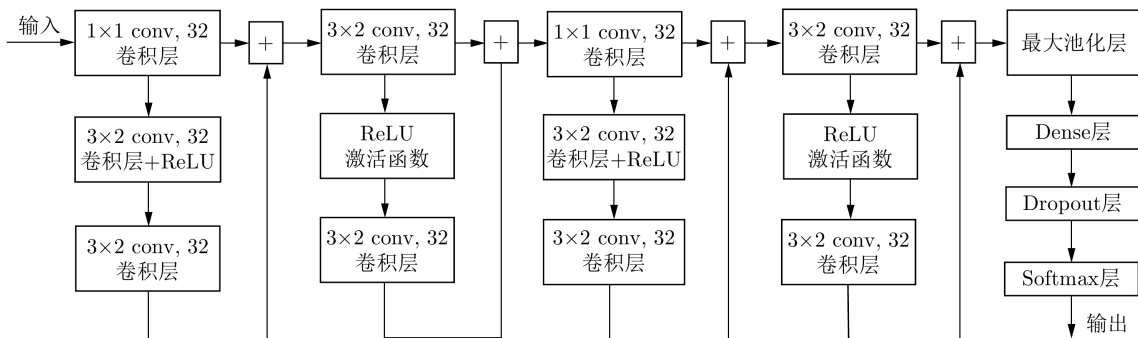


图5 IWR-Net结构

$N, M$  分别表示训练波形总数和波形种类数,  $y_{ic}$  为指示变量(0/1),  $p_{ic}$  表示波形  $i$  属于波形  $c$  的预测概率。

### 5 系统仿真

为全面对比分析不同噪声环境对模型训练的影响, 在 Flat 衰落信道下, 分别采用多信噪比(1~10 dB, 记为多信噪比)条件和单信噪比(10 dB, 记为单信噪比)条件生成两份数量为 30000 的样本(每种波形 10000)构成训练集, 送入神经网络训练得到最优模型, 分别记为  $M_{ten}, M_{one}$ 。设置 4 组仿真实验测试模型性能: (1) 生成经 Flat 衰落信道的两类信噪比数据集 D1, D2, 分别测试模型  $M_{ten}, M_{one}$  性能; (2) 为了验证模型在快衰落信道中对新样本的泛化能力, 生成经 Rayleigh 衰落信道的两类信噪比数据集 D3, D4, 测试模型鲁棒性; (3) 分别产生 64QAM, 256QAM 调制下两类信噪比数据集 D5, D6, D7, D8, 测试高阶数调制方式下模型的预测准确率; (4) 发送端通过波形集成发送模块随机生成一种波形, 接收端加载模型在线预测波形种类并统计正确识别的数量, 评估系统性能。

本文仿真数据采集使用 Matlab 产生, 仿真环境为 Python 3.7 版本, DL 框架为 Tensorflow 2.0.0 版本。系统仿真主要参数, 训练神经网络参数配置如表 2 所示。仿真设备如下: Intel(R)Core(TM)i5-8500 CPU @3.00 GHz, 内存(RAM)为 8 GB, 64 位操作系统。

#### 5.1 不同信道条件下波形识别测试实验

**实验 1 Flat 衰落条件。** Flat 衰落信道条件下, 分别生成两类信噪比条件下各 3000 个测试样本, 经过数据预处理, 输入数据形状为 (3000, 1, 2, 200), 标签为 (3000, 3)。为保证学习到最佳权重, 通过网格搜索算法筛选测试集损失值最小的一组参数值, 最小批量大小设置为 1024, 初始学习率设置为 0.001, 迭代次数为 100, 迭代过程中自动调整学习率  $\alpha$ , 当验证集损失值大小不再变化, 执行早停操作结束训练, 保存最优模型, 最终在训练集上准确率分别达到 99.5%(多信噪比), 99.2%(单信噪

表 2 系统参数配置

参数	数值	参数	数值
FFT 长度	256	卷积层激活函数	ReLU
映射方式	16QAM	Dropout 率	0.3
子带大小	10	过滤器数量	32
子带偏移	78	过滤器大小	(3,2)
切比雪夫滤波器长度	73	优化器	Adam
旁瓣衰减	40 dB	最大池化层大小	(2,2)
CP 长度	73	全连接层神经元数量	128

比), 测试集准确率如图 6 所示。可以看出, 用于波形识别的两种模型曲线变化轨迹相似, 随着信噪比逐渐改善, 预测准确率提高, 二者都没有过拟合问题, 在 5 dB 信噪比条件下, 准确率最高可达到 98.2%。模型  $M_{ten}$  在低信噪比情况下优于模型  $M_{one}$ , 证明训练集中存在低信噪比样本时, 权值共享的卷积层通过运算使  $M_{ten}$  模型学习到低信噪比信号中的抽象特征, 并应用在新数据集中实现正确分类。

**实验 2 Rayleigh 衰落条件。** 为了进一步验证训练模型对经快衰落信道干扰后波形识别鲁棒性, 采用具有频率选择性衰落的 Rayleigh 信道作为测试仿真信道。鉴于多径传输条件影响, 分别生成两类信噪比条件下各 30000 个测试样本, 加载实验 1 中训练好的  $M_{ten}$  和  $M_{one}$  进行泛化性能测试。结果如图 7 所示, 训练好的两种模型对通过 Rayleigh 信道后的接收数据依然具有很好的识别效果, 并且在所有信噪比点处多信噪比模型准确率均大于单信噪比。在 10 dB 信噪比条件下, 多信噪比模型预测准确率达到 94.4%, 这进一步说明本文提出的 IWR-Net 能有效地提取信号特征, 具有较强的抗信道衰落能力。

#### 5.2 不同调制方式下波形识别测试实验

**实验 3 64QAM 和 256QAM 调制。** 通信业务中不同的调制方式能以不同速率传输数据。为了更深




图 6 Flat衰落信道测试结果




图 7 Rayleigh衰落信道测试结果

入地验证模型鲁棒性,测试在高阶数调制中不同波形的识别性能,使用16QAM调制作为训练集,64QAM和256QAM调制作为测试集。加载实验1中模型在线预测,图8、图9分别给出 $M_{ten}$ 和 $M_{one}$ 对两种高阶调制方式的测试结果。可以看出,3种调制方式测试曲线变化趋势基本一致,多信噪比模型在各信噪比点处具有更好的预测效果,在信噪比大于5 dB条件下,多信噪比模型对高阶调制的最高识别准确率达97.5%,能精确预测同一种多载波波形在不同调制方式下的类别。

### 5.3 完整智能收发系统的实现及测试

**实验4 完整智能收发系统。**本实验激活波形集成发送模块,根据不同业务类型中的需求发送多载波波形,接收端加载模型进行智能化识别。为了保证仿真结果的全面性,依次生成信噪比为1~10 dB的OFDM, FOFDM, UPMC波形样本各10000个,送入模型 $M_{ten}$ 中预测发送波形种类,实验混淆矩阵如图10,统计正确预测波形的数量分别为9588, 9633, 8828;接着,依次生成信噪比为10 dB的OFDM, FOFDM, UPMC波形样本各10000个,送入模型 $M_{one}$ 中得到混淆矩阵如图11,正确预测的数量分别为9628, 9611, 9760。仿真结果显示,所提两种模




图8 多信噪比调制方式下测试结果




图9 单信噪比调制方式下测试结果

型都能在随机噪声干扰的情况下对波形种类准确识别,满足实验预期效果。

### 5.4 复杂度分析

经典的通信系统通过改变发送模块的结构产生不同波形,但设计和实现复杂度将随业务种类不断增长,部署成本也随之增加。本文提出的集成化波形发送模块能有效地解决以上问题。在发送端,根据业务需求配置波形激活因子,集成化发送模块在不增加系统实现复杂度的情况下实现不同波形的发送。这种遵循模块化合并原则的设计结构合理地将不同调制模块中相同功能的硬件结构实现共用化,大大降低硬件部署成本,缓解了多场景通信中因改变发送模块的结构而造成系统部署复杂度增加的问题。

在DL模型应用研究领域,神经网络模型的计算复杂度使用浮点运算数量来描述。模型的计算复杂度决定了它的训练和预测时间。文中所提IWR-Net是一种卷积神经网络,针对卷积神经网络计算复杂度由式(9)和式(10)表示为<sup>[17]</sup>

$$\text{Time} \sim O\left(\sum_{l=1}^D M_l^2 \cdot K_l^2 \cdot C_{in} \cdot C_{out}\right) \quad (9)$$

$$M = \frac{(X - K + 2 \cdot \text{Padding})}{\text{Stride}} + 1 \quad (10)$$

其中 $D, l, M$ 分别表示网络深度、当前卷积层数、卷积核输出特征图边长, $K$ 表示卷积核边长, $C_{in}$ 和 $C_{out}$ 分别为卷积核输入通道数和输出通道数; $X, \text{Padding}$ ,




图10 多信噪比模型混淆矩阵图




图11 单信噪比模型混淆矩阵图

Stride分别表示输入矩阵尺寸、特征图填充数、卷积步长。通过计算最坏情况下的复杂度: (1)卷积运算共消耗的浮点数运算数量为 $1.28 \times 10^5$ ; (2)全连接层共消耗浮点运算数量为 $8.192 \times 10^5$ , 模型总的计算复杂度为 $9.472 \times 10^5$ 。为了更全面分析时间复杂度, 本文接着对模型训练和预测时间进行统计<sup>[4]</sup>。训练多信噪比模型 $M_{ten}$ 和单信比模型 $M_{one}$ 的时间、测试实验4中3种波形预测所耗费的时间如表3所示, 虽然DL模型离线训练阶段花费了一定的时间成本, 但训练好的模型对新数据集进行预测时可直接调用, 快速预测发送波形种类。

表3 模型训练及测试运行时间(s)

模型	训练时间	测试时间		
		OFDM	FOFDM	UFMC
—	—	—	—	—
多信噪比模型	684.60	3.30	3.26	3.27
单信噪比模型	874.52	3.24	3.76	3.34

## 6 结束语

本文提出一种融合DL的智能化波形调制系统。在发送端, 根据通信业务需求配置波形激活因子, 集成波形发送模块发送合适的多载波波形。在接收端, 首先由波形识别网络自动提取接收信号特征, 识别波形类别, 然后将对应类别波形数据送入离线训练的解调网络中实现信号恢复。仿真结果表明, 训练模型在5 dB信噪比下超过98%的测试准确率, 模型鲁棒性检验方面, 中信噪比条件下对Rayleigh信道衰落条件和高阶调制产生的新数据测试准确率均超过94%。在利用人工智能技术研究通信系统的工作中, 该方案保留了多载波产生和发送装置, 可以在信息传输过程中保留多载波通信技术的优点。本文将接收端工作分解为识别和解码, 因受篇幅限制, 没有详细介绍解码部分。在后续工作中, 接收端的设计重点是研究多载波的识别和解码的同步完成。

## 参考文献

- [1] AAZHANG B, AHOKANGAS P, ALVES H, *et al.* Key drivers and research challenges for 6G ubiquitous wireless intelligence[EB/OL]. <http://jultika.oulu.fi/files/isbn9789526223544.pdf>, 2019.
- [2] TOMKOS I, KLONIDIS D, PIKASIS E, *et al.* Toward the 6G network era: Opportunities and challenges[J]. *IT Professional*, 2020, 22(1): 34–38. doi: [10.1109/MITP.2019.2963491](https://doi.org/10.1109/MITP.2019.2963491).
- [3] SAAD W, BENNIS M, and CHEN Mingzhe. A vision of 6G wireless systems: Applications, trends, technologies, and open research problems[J]. *IEEE Network*, 2020, 34(3): 134–142. doi: [10.1109/MNET.001.1900287](https://doi.org/10.1109/MNET.001.1900287).
- [4] SADI Y, ERKUCUK S, and PANAYIRCI E. Flexible physical layer based resource allocation for machine type communications towards 6G[C]. 2020 2nd 6G Wireless Summit (6G SUMMIT), Levi, 2020: 1–5. doi: [10.1109/6GSUMMIT49458.2020.9083921](https://doi.org/10.1109/6GSUMMIT49458.2020.9083921).
- [5] SAHIN A, GUVENC I, and ARSLAN H. A survey on multicarrier communications: Prototype filters, lattice structures, and implementation aspects[J]. *IEEE Communications Surveys & Tutorials*, 2014, 16(3): 1312–1338. doi: [10.1109/SURV.2013.121213.00263](https://doi.org/10.1109/SURV.2013.121213.00263).
- [6] MT-2020(5G)推进组. IMT-2020(5G)推进组发布5G技术白皮书[J]. *中国无线电*, 2015(5): 6. IMT-2020 Promotion Group. 5G wireless technology architecture white paper[J]. *China Radio*, 2015(5): 6.
- [7] VIHRIALA J, ERMOLOVA N, LAHETKANGAS E, *et al.* On the waveforms for 5G mobile broadband communications[C]. 2015 IEEE 81st Vehicular Technology Conference (VTC Spring), Glasgow, Scotland, 2015: 1–5. doi: [10.1109/VTCSPRING.2015.7145977](https://doi.org/10.1109/VTCSPRING.2015.7145977).
- [8] HAN Shuangfeng, XIE Tian, CHIH-LIN I, *et al.* Artificial-intelligence-enabled air interface for 6G: Solutions, challenges, and standardization impacts[J]. *IEEE Communications Magazine*, 2020, 58(10): 73–79. doi: [10.1109/MCOM.001.2000218](https://doi.org/10.1109/MCOM.001.2000218).
- [9] YUAN Yabo, ZHAO Peng, WANG Bo, *et al.* Hybrid maximum likelihood modulation classification for continuous phase modulations[J]. *IEEE Communications Letters*, 2016, 20(3): 450–453. doi: [10.1109/LCOMM.2016.2517007](https://doi.org/10.1109/LCOMM.2016.2517007).
- [10] WANG Hui and GUO Lili. A new method of automatic modulation recognition based on dimension reduction[C]. 2017 Forum on Cooperative Positioning and Service (CPGPS), Harbin, China, 2017: 316–320. doi: [10.1109/CPGPS.2017.8075146](https://doi.org/10.1109/CPGPS.2017.8075146).
- [11] SU Wei. Feature space analysis of modulation classification using very high-order statistics[J]. *IEEE Communications Letters*, 2013, 17(9): 1688–1691. doi: [10.1109/LCOMM.2013.080613.130070](https://doi.org/10.1109/LCOMM.2013.080613.130070).
- [12] O'SHEA T J, ROY T, and 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. doi: [10.1109/JSTSP.2018.2797022](https://doi.org/10.1109/JSTSP.2018.2797022).
- [13] WANG Yu, LIU Miao, YANG Jie, *et al.* Data-driven deep learning for automatic modulation recognition in cognitive radios[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(4): 4074–4077. doi: [10.1109/TVT.2019.2900460](https://doi.org/10.1109/TVT.2019.2900460).
- [14] DUAN Sirui, CHEN Kan, YU Xiang, *et al.* Automatic multicarrier waveform classification via PCA and

- convolutional neural networks[J]. *IEEE Access*, 2018, 6: 51365–51373. doi: [10.1109/ACCESS.2018.2869901](https://doi.org/10.1109/ACCESS.2018.2869901).
- [15] 邵凯, 李述栋, 王光宇, 等. 基于迟滞噪声混沌神经网络的导频分配[J]. *电子与信息学报*, 2020, 42(10): 2454–2461. doi: [10.11999/JEIT190748](https://doi.org/10.11999/JEIT190748).
- SHAO Kai, LI Shudong, WANG Guangyu, *et al.* Hysteretic noisy chaotic neural networks based pilot assignment[J]. *Journal of Electronics & Information Technology*, 2020, 42(10): 2454–2461. doi: [10.11999/JEIT190748](https://doi.org/10.11999/JEIT190748).
- [16] 桂冠, 王禹, 黄浩. 基于深度学习的物理层无线通信技术: 机遇与挑战[J]. *通信学报*, 2019, 40(2): 19–23. doi: [10.11959/j.issn.1000?436x.2019043](https://doi.org/10.11959/j.issn.1000?436x.2019043).
- GUI Guan, WANG Yu, and HUANG Hao. Deep learning based physical layer wireless communication techniques: Opportunities and challenges[J]. *Journal on Communications*, 2019, 40(2): 19–23. doi: [10.11959/j.issn.1000?436x.2019043](https://doi.org/10.11959/j.issn.1000?436x.2019043).
- [17] HE Kaiming and SUN Jian. Convolutional neural networks at constrained time cost[C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, USA, 2015. doi: [10.1109/CVPR.2015.7299173](https://doi.org/10.1109/CVPR.2015.7299173).
- [18] 盖建新, 薛宪峰, 吴静谊, 等. 基于深度卷积神经网络的协作频谱感知方法[J]. *电子与信息学报*, 2021, 43(10): 2911–2919. doi: [10.11999/JEIT201005](https://doi.org/10.11999/JEIT201005).
- GAI Jianxin, XUE Xianfeng, WU Jingyi, *et al.* Cooperative spectrum sensing method based on deep convolutional neural network[J]. *Journal of Electronics & Information Technology*, 2021, 43(10): 2911–2919. doi: [10.11999/JEIT201005](https://doi.org/10.11999/JEIT201005).
- 邵 凯: 男, 1977年生, 副教授, 研究方向为新型多载波调制技术、新型多址接入技术.
- 付旭阳: 男, 1995年生, 硕士生, 研究方向为AI在无线通信中的应用.
- 王光宇: 男, 1964年生, 教授, 研究方向为新型多载波调制技术、新型多址接入技术.

责任编辑: 余 蓉