

DOI:10.19651/j.cnki.emt.2518235

# 基于特征结合的 MIMO-OFDM 系统调制识别算法<sup>\*</sup>

李璋培 张天骐 孙浩源 钟 扬

(重庆邮电大学通信与信息工程学院 重庆 400065)

**摘要:** 目前非协作通信多输入多输出正交频分复用(MIMO-OFDM)系统中的子载波调制识别方法,存在低信噪比下识别精度不够高,识别阶数不够高的问题。对此,本文提出一种基于特征结合的调制识别算法。首先对接收信号进行预处理;接着提取信号的同相正交分量并计算信号的小波变换、四次方谱、高阶累积量、零中心归一化瞬时幅度作为输入特征;接着将输入特征送入神经网络进行训练;最后对 MIMO-OFDM 系统子载波进行调制识别。实验结果表明,本文提出的算法能够有效识别 BPSK、QPSK、8PSK、16QAM、64QAM、128QAM 共 6 种信号,且识别精度在信噪比为 6 dB 时可达 90%。

**关键词:** 多输入多输出正交频分复用;调制识别;同相正交序列;四次方谱;小波变换;高阶累积量

**中图分类号:** TN911.7 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Modulation recognition algorithm for MIMO-OFDM systems based on feature combination

Li Zhangpei Zhang Tianqi Sun Haoyuan Zhong Yang

(School of Communications and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

**Abstract:** Currently, the subcarrier modulation recognition methods in non-cooperative multiple-input multiple-output orthogonal frequency division multiplexing (MIMO-OFDM) systems suffer from insufficient recognition accuracy under low signal-to-noise ratio (SNR) conditions and limitations in recognizing higher-order modulation schemes. To address these issues, this paper proposes a modulation recognition algorithm based on feature fusion. First, the received signal undergoes preprocessing. Subsequently, the in-phase and quadrature (I/Q) components of the signal are extracted, and multiple features—including wavelet transform, fourth-power spectrum, higher-order cumulants, and zero-centered normalized instantaneous amplitude—are computed as input features. These features are then fed into a neural network for training. Finally, the modulation scheme of the MIMO-OFDM subcarriers is classified. Experimental results demonstrate that the proposed algorithm effectively recognizes six modulation types: BPSK, QPSK, 8PSK, 16QAM, 64QAM and 128QAM, achieving a recognition accuracy of 90% at an SNR of 6 dB.

**Keywords:** multiple-input multiple-output orthogonal frequency division multiplexing; modulation recognition; in-phase quadrature sequence; fourth-power spectrum; wavelet transform; high-order cumulant

## 0 引言

多输入多输出(multiple-input multiple-output, MIMO)与正交频分复用(orthogonal frequency division multiplexing, OFDM)作为通信中的核心技术<sup>[1]</sup>,二者的有机结合催生出了 MIMO-OFDM 系统,该系统在现代通信领域展现出了非凡的性能优势。在较大提升频谱效率与数据传输速率的同时,能够保障信号在复杂通信环境下的稳

定性及可靠性。

然而伴随着现代通信系统复杂性的增加,传统的信号处理方法逐渐显现出局限性。在实际通信、认知无线电、电子对抗等场景中,接收端通常无法获取发送端的先验信息,如调制方式、信道状态信息、训练序列等。为满足对未知信号和复杂环境的处理需求,信号盲处理技术的研究应运而生。信号盲处理技术旨在解决传统信号处理方法所面临的局限性,通过一系列创新的理论和算法,能够在缺乏信号源

收稿日期:2025-03-03

<sup>\*</sup> 基金项目:重庆市自然科学基金(cstc2021jcyj-msxmX0836)项目资助

先验信息的情况下,实现对观测信号的有效处理。调制识别是盲处理中重要的研究方向,因此对 MIMO-OFDM 信号的调制识别具有重要意义<sup>[2]</sup>。

盲调制识别(blind modulation recognition, BMR)是非协作通信中的关键技术之一。BMR 的目标是通过数学方法分析信号中的特性,并提取信号中的关键特征,从而实现未知条件下的调制识别。早期的 BMR 使用手工设计的信号特征,再通过分类器完成调制类型的识别<sup>[3]</sup>。不同调制信号的特征参数具有较大的差距,如基于高阶统计特性的高阶累积量<sup>[4]</sup>、基于周期统计特性的循环谱<sup>[5]</sup>等。分类器则使用感知机、支持向量机、朴素贝叶斯、决策树等完成最后的调制识别。

上述基于特征驱动的调制识别方法具有计算复杂度较低,易于实现的特点,但其性能受到复杂信道和低信噪比的制约。随着通信技术的发展,各种调制方式积累了大量的数据资源,同时图形处理单元等硬件技术的发展使得深度学习的运行时间大大缩短,深度学习在信号调制识别方法中逐渐成为主流。2016 年, O'Shea 等<sup>[6]</sup>提出一种基于深度学习的调制识别算法,该算法将时域同相正交分量(in phase and quadrature, I/Q)直接作为信号的原始特征来区分不同的调制方式。通过将原始特征序列输入 CNN 进行训练,使得该算法能够实现信号的调制识别,但调制识别的精度较低。Zhang 等<sup>[7]</sup>使用双向长短时记忆网络并结合了 I/Q 特征与四阶统计量特征,有效提升了低信噪比下的识别精度。Liu 等<sup>[8]</sup>使用引入注意力机制的深度残差网络,将 I/Q 特征、星座特征、信号频谱特征进行多特征融合作为神经网络的输入,实现了低信噪比下多种调制方式的识别。周顺勇等<sup>[9]</sup>引入奇异值分解算法对接收的 I/Q 信号进行去噪,再利用卷积神经网络对去噪后的信号进行多通道空间特征提取,在低信噪比环境下显著提高了调制识别精度。童子滔等<sup>[10]</sup>通过自编码器提取调制信号的特征,有效提升了模型识别率。

在单载波系统中,基于深度学习的调制识别算法已取得良好性能,研究人员因此开始探索将深度学习方法应用

于 MIMO-OFDM 系统,以进一步提升其识别性能。张天骐等<sup>[11]</sup>尝试在 MIMO-OFDM 系统中仅使用 I/Q 序列作为特征,构建 CNN 网络完成调制识别。但该算法只能完成 BPSK、QPSK、8PSK 信号与 16QAM 共计 4 种调制方式的识别。张天骐等<sup>[12]</sup>提出的算法在保留 I/Q 序列特征表达能力的同时,选择加入抗噪性能较好的循环谱作为另一特征。通过训练优化后的 CNN,在文献[11]的分类基础上进一步实现了 64QAM 信号的调制识别。但该算法在低信噪比条件下对 PSK 类信号的区分精度不够高。An 等<sup>[13]</sup>提出的算法不仅使用 I/Q 序列作为特征,还对下变频后的信号提取星座图作为特征,并采用分段预处理进一步加强星座图的特征表达能力。该算法虽然在信噪比为 4 dB 时能够有效识别 BPSK、QPSK、8PSK、16QAM、32QAM 五种信号,但无法识别更高阶的 QAM 类信号。

综上所述, MIMO-OFDM 系统调制识别算法低信噪比下识别精度不够高,对 QAM 类信号识别阶数不够高等问题。为此,本文提出一种特征结合的调制识别算法,利用信号的时域特征、变换域特征以及高阶特征完成调制识别。首先,使用盲源分离算法从混合信号中恢复出发送信号;然后,提取信号的 I/Q 序列,计算信号的小波变换、四阶累积量、四次方谱、高阶累积量和零中心归一化瞬时幅度,将上述参数构成的数据矩阵作为神经网络的输入特征;最后,使用基于一维 CNN 的神经网络对输入特征进行训练,从而完成调制识别。

为验证本文所提算法的有效性,本文首先选取文献[11-12]中出现的 BPSK、QPSK、8PSK、16QAM、64QAM 共 5 种调制方式作为调制识别目标,再增加误符号率较低的 128QAM 调制<sup>[14]</sup>作为识别目标,共计完成 6 种调制方式的识别。

## 1 系统模型

### 1.1 MIMO-OFDM 系统模型

图 1 为本文构建的 MIMO-OFDM 系统。




图 1 MIMO-OFDM 系统框图

Fig. 1 MIMO-OFDM system model

图 1 中,  $N_t$  表示发送天线的数量;  $N_r$  表示接收天线的数量。系统通信过程如下:首先,原始二进制比特流进入系统,经星座映射转化为信道传输所需符号。接着,对映射后的符号开展 MIMO 编码,编码后的信号分成多个支

路进行 OFDM 调制,即将高速流分成多个低速子流并调制到正交子载波上后通过多天线发射。接收端进行 OFDM 解调进而完成调制识别。本文中的系统模型假设信道为莱斯信道,第  $N_r$  根天线上的接收信号  $y_{r_n}(t)$  可

以表示为:

$$y_{n_r}(t) = \sum_{n_t=1}^{N_t} h_{n_r,n_t}(t)x_{n_t}(t) + v_{n_r}(t) \quad (1)$$

式中:  $h_{n_r,n_t}(t)$  为第  $n_r$  根接收天线与第  $n_t$  根发送天线之间的信道转移系数;  $x_{n_t}(t)$  为发送信号;  $v_{n_r}(t)$  为第  $n_r$  根天线上的复高斯加性白噪声。

若采用矩阵形式描述 MIMO-OFDM 接收信号,则可以表示为:

$$\mathbf{y}(t) = \mathbf{H}\mathbf{x}(t) + \mathbf{v}(t) \quad (2)$$

式中:  $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_{N_t}(t)]^T$  表示发送信号;  $\mathbf{v}(t) = [v_1(t), v_2(t), \dots, v_{N_r}(t)]^T$  表示高斯白噪声;  $\mathbf{H}$  表示信道系数,即:

$$\mathbf{H} = \begin{bmatrix} h_{1,1} & h_{1,2} & h_{1,3} & \cdots & h_{1,N_t} \\ h_{2,1} & h_{2,2} & h_{2,3} & \cdots & h_{2,N_t} \\ h_{3,1} & h_{3,2} & h_{3,3} & \cdots & h_{3,N_t} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ h_{N_r,1} & h_{N_r,2} & h_{N_r,3} & \cdots & h_{N_r,N_t} \end{bmatrix} \quad (3)$$

### 1.2 发送信号恢复

在 MIMO 系统中,信号经发送后失去原本的统计特性,不能直接提取所需要的特征参数,故需要先对接收到的信号进行预处理,恢复发送信号。在非协作通信中,接收端没有发送端的先验信息,故需要进行盲估计。盲源分离算法通常用于从多个接收信号中分离出原始的独立源信号。常见的盲源分离算法有独立成分分析、非负矩阵分解、高阶统计量方法等。由文献[15]可知,高阶统计量方法中的联合近似对角化(joint approximate diagonalization of eigen-matrices, JADE)算法对源信号的独立性要求相对宽松,故本文选用 JADE 算法分离出原始的独立源信号。在使用 JADE 算法之前,还需要推算出发送天线的个数。最小描述长度(minimum description length, MDL)算法推算信源数是一种统计模型选择方法,用于在给定的数据中估计信号源的数量。推算发送天线数量的过程如下所示:

步骤 1) 求接收信号  $\mathbf{y}$  的自相关矩阵:

$$\mathbf{R}_y = E[\mathbf{y}(t)\mathbf{y}^H(t)] \quad (4)$$

式中:  $(\cdot)^H$  表示共轭转置。

步骤 2) 对自相关函数  $\mathbf{R}_y$  做特征值分解,得到  $N_r$  个特征值并按照降序排序。

步骤 3) 根据如下公式计算出  $N_t$ :

$$\hat{N}_t = \operatorname{argmin}_n \left\{ -\lg \frac{\prod_{i=n+1}^{N_r} \lambda_i^{1/N_r-n}}{\sum_{i=n+1}^{N_r} \lambda_i} + \frac{n(N_r-n)+1}{2} \lg L \right\},$$

$$n = 0, 1, \dots, N_r - 1 \quad (5)$$

文献[11]指出为贴合实际移动通信的应用环境,在使用 JADE 算法之前应对信号进行白化处理,从而降低信号维数。信号的白化操作过程为:

首先计算接收信号的协方差矩阵  $\mathbf{C}_y$ , 公式如下:

$$\mathbf{C}_y = E[\mathbf{y}\mathbf{y}^T] \quad (6)$$

将协方差矩阵  $\mathbf{C}_y$  进行特征分解,公式如下:

$$\mathbf{C}_y = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^T \quad (7)$$

式中:  $\mathbf{U}$  是由特征向量组成的正交矩阵;  $\mathbf{\Lambda}$  是由特征值组成的对角矩阵,  $\mathbf{\Lambda} = \operatorname{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ 。白化矩阵  $\mathbf{W}$  可通过以下公式计算:

$$\mathbf{W} = \mathbf{U}\mathbf{\Lambda}^{-1/2}\mathbf{U}^T \quad (8)$$

最后将接收信号进行白化,白化后的信号矩阵可以表示为:

$$\mathbf{q} = \mathbf{W}\mathbf{y} \quad (9)$$

经过白化操作,信号维数由原本的  $N_r \times 1$  变为  $N_t \times 1$ , 有效减少了 JADE 算法的计算量。

进行白化操作并对天线数量估计后,使用 JADE 算法恢复子载波信号。首先计算  $\mathbf{q}$  的四阶乘积量矩阵  $\mathbf{C}$ , 接着对  $\mathbf{C}$  进行奇异值分解,构成矩阵  $\mathbf{A} = \{\phi_i, \mathbf{U}_i \mid 1 \leq i \leq N_t\}$ ,  $\phi_i$  表示模最大的前  $N_t$  个特征值,  $\mathbf{U}_i$  表示特征矩阵。最后对  $\mathbf{A}$  做近似对角化,得到分离矩阵  $\mathbf{X}$ , 恢复信号最终表示为:

$$\hat{\mathbf{s}} = \mathbf{X} \cdot \mathbf{q} \quad (10)$$

图 2 展示了 6 dB 信噪比条件下,使用 QPSK 作为子载波调制方式的 MIMO-OFDM 系统的接收信号星座图以及经过 JADE 算法恢复后的信号星座图。可以看出即使是在低信噪比条件下,使用 JADE 算法仍能够有效的恢复源信号的特征。

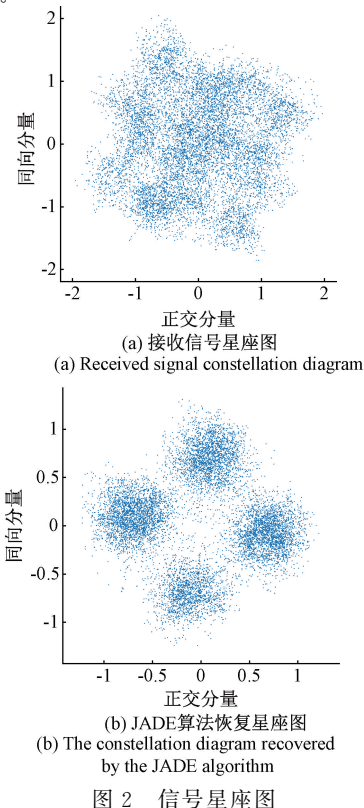


图 2 信号星座图

Fig. 2 Signal constellation diagram

## 2 特征提取

### 2.1 I/Q 序列

不同调制方式在 I/Q 序列上呈现出一定差异,例如频谱分布、幅度动态范围以及相位变化规律。将 I/Q 序列作为神经网络的输入特征,能够有效提升识别精度。

图 3 展示了部分信号的 I/Q 序列图像。通过观察同

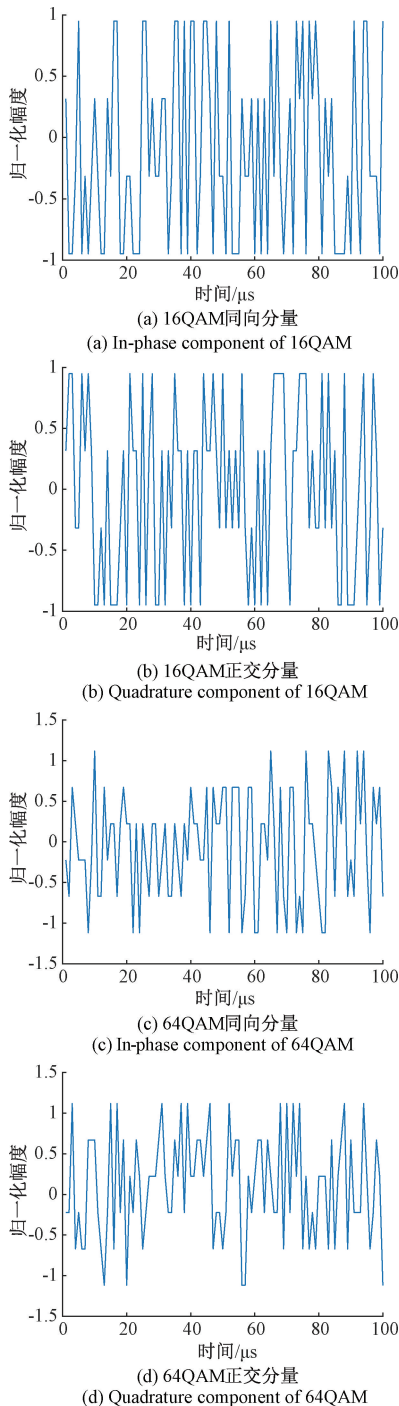


图 3 部分信号 I/Q 序列

Fig. 3 Partial signal I/Q sequences

向分量可知,16QAM 信号出现 4 次振幅变化,而 64QAM 出现振幅变化的次数是 8 次。

### 2.2 小波变换

小波变换是一种信号处理技术,通过对原始信号与一组小波函数及其尺度函数进行内积运算,将信号分解为低频和低频成分,即通过不同的分辨率捕捉信号的细节信息。信号  $s(t)$  小波变换的计算公式为:

$$\text{CWT}(a, \tau) = \int s(t) \Psi_a^*(t) dt = \frac{1}{\sqrt{a}} \int s(t) \Psi^* \left( \frac{t-\tau}{a} \right) dt \quad (11)$$

由文献[16]可知,信号的小波变换幅值为:

$$|\text{CWT}(a, \tau)| = \frac{4\sqrt{S_i}}{\sqrt{a}\omega_c} \sin^2 \left( \frac{\omega_c a}{4} \right) \quad (12)$$

式中:  $S_i$  是第  $i$  个符号的幅度;  $\omega_c$  为载波频率。图 4 给出了 QAM 类信号与 PSK 类信号在 SNR 为 10 dB 的小波变换幅值图。由于 PSK 类信号为恒模信号,其  $|\text{CWT}(a, \tau)|$  值变化幅度不大,而 QAM 信号的幅度存在变化,其  $|\text{CWT}(a, \tau)|$  值变化较为显著。故可以通过计算小波变换幅度的方差作为输入特征,增强对 QAM 类信号与 PSK 类信号的区分。

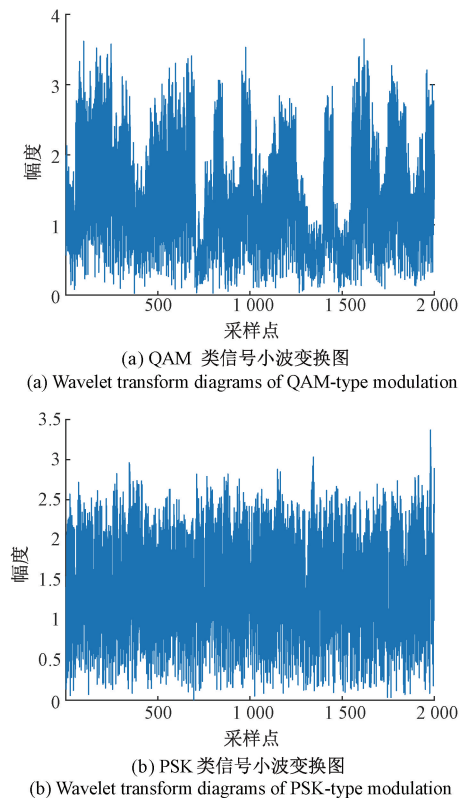


图 4 不同调制的小波变化图

Fig. 4 Wavelet transformation diagrams of different modulations


### 2.3 四次方谱

四次方谱是一种基于信号四次方的频谱分析方法,能


够揭示信号中的非高斯和非线性成分。四次方谱的计算公式为：

$$P(f) = \int_{-\infty}^{\infty} x^4(t) \exp(-j2\pi ft) dt \quad (13)$$


图 5 展示了不同调制信号在信噪比为 10 dB 时的四次方谱特征。从图中可以观察到,PSK 类信号的四次方谱呈现显著差异。BPSK 信号的四次方谱呈现单一尖峰;QPSK 信号和 8PSK 信号在 2 倍载频处表现出更多尖峰分布,而 QPSK 信号在更高频段还会出现明显的孤立尖峰。因此可以将四次方谱作为输入特征从而有效区分不同的 PSK 类信号。



(a) BPSK 四次方谱  
(a) The fourth-power spectrum of BPSK



(b) QPSK 四次方谱  
(b) The fourth-power spectrum of QPSK



(c) 8PSK 四次方谱  
(c) The fourth-power spectrum of 8PSK

图 5 PSK 类信号四次方谱

Fig. 5 The fourth-power spectrum of PSK-type signals

## 2.4 高阶累积量

高阶统计特性中包含着信号的调制特点,并且由于阶

以上的累积量可以抑制高斯噪声,故本文选用高阶累积量作为输入特征对不同阶数的 QAM 调制进行区分。高阶累积量的计算公式如下:

设  $s^*(k)$  为信号的复共轭,  $M_{pq}$  表示信号的各阶矩,计算公式为:

$$M_{pq} = E[s(k)^{p-q} (s^*(k))^q] \quad (14)$$

式中:  $E[\cdot]$  表示取均值,则有:

$$C_{20} = \text{Cum}[s(k), s(k)] = M_{20} \quad (15)$$

$$C_{40} = \text{Cum}[s(k), s(k), s(k), s(k)] = M_{40} - 3M_{20}^2 \quad (16)$$

$$C_{42} = \text{Cum}[s(k), s(k), s^*(k), s^*(k)] = M_{42} - M_{20}^2 - 2M_{21}^2 \quad (17)$$

表 1 列出了 3 种 QAM 信号的四阶累积量理论值。通过观察可知,128QAM 的四阶累积量  $|C_{40}|$  与 16QAM、64QAM 的四阶累积量  $|C_{40}|$  具有较大的差异。为保证特征参数的稳健性和通用性,本文引入  $|C_{42}|$  与  $|C_{40}|$  一并构建新的特征参数  $F$ ,  $F$  的计算公式为:

$$F = \frac{|C_{40}|}{|C_{42}|} \quad (18)$$

将表 1 的参数带入  $F$  的计算公式,16QAM 与 64QAM 的  $F$  值接近 1,而 128QAM 的特征参数小于 1,故利用特征参数  $F$  可以将 128QAM 信号识别。

表 1 信号的高阶累积量理论值

Table 1 The theoretical values of the high-order cumulants of the signal

信号类型	$ C_{40} $	$ C_{42} $
16QAM	0.680 0	0.680 0
64QAM	0.619 00	0.619 00
128QAM	0.181 4	0.657 4

## 2.5 零中心归一化瞬时幅度

零中心归一化瞬时幅度紧致性计算公式为:

$$\mu = \frac{E[\alpha_{cn}^4(n)]}{\{E[\alpha_{cn}^2(n)]\}^2} \quad (19)$$

式中:  $\alpha_{cn}^4(n)$  为零中心归一化瞬时幅度。文献[17]给出了特征参数  $u$  随信噪比变化的曲线,如图 6 所示。通过观察可以发现 16QAM 与 64QAM 信号的特征参数  $u$  存在差距,故可以利用特征参数  $u$  对两种信号进行区分。

## 2.6 数据集构造

文献[15]对比了发送天线数为 2、3、4,接收天线为 5、6、7 时 MDL 算法以及 JADE 算法的性能。当发送天线数  $N_t$  与接收天线数  $N_r$  的差值越大时,两种算法的性能越好。本文 MIMO-OFDM 系统设置参考其仿真结果,采用 3 发 5 收的 MIMO-OFDM 系统。为符合真实传输环境,本文使用的信道为莱斯信道<sup>[18]</sup>,莱斯因子设置为 0.5;采样频率与载波频率则分别设定为 100 kHz 与 15 kHz<sup>[19]</sup>;在接收

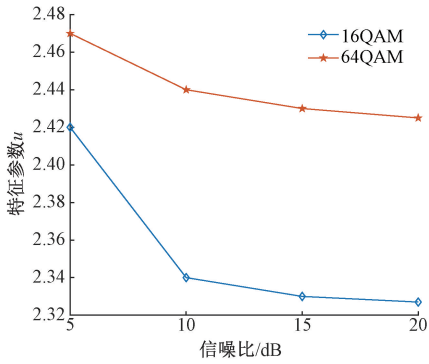
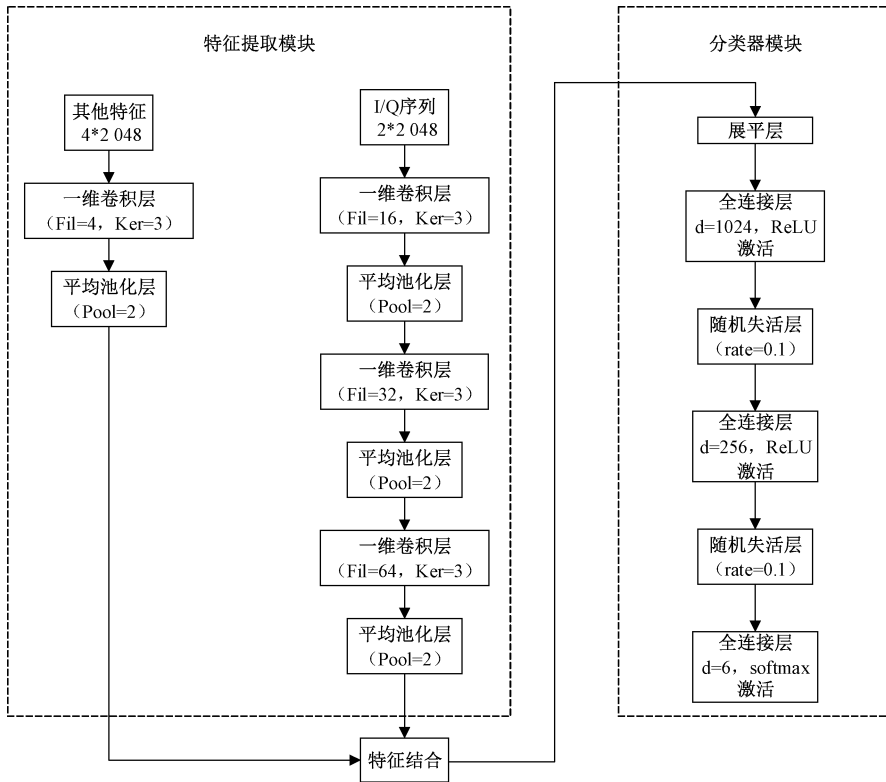
图 6 特征参数  $u$  随信噪比变化曲线Fig. 6 The curve of the characteristic parameter  $u$  changing with the signal-to-noise ratio

图 7 网络模型

Fig. 7 Network mode

行特征提取;而对于其他的特征,只使用一个卷积层与一个池化层进行特征提取。文献[19]指出一维 CNN 在处理矢量方面具有较好的效果,同时拥有较低的计算复杂度,故本文的 CNN 使用一维 CNN。图中 Fil 为卷积核的数量,即输出通道的数量,Ker 表示卷积核的尺寸。

在特征提取后,为提高调制识别的正确率,需要将两条支路得到的特征数据进行结合。而特征结合中的拼接(Concatenate)操作能够完整地保留原始特征的所有信息,不会因为数值差异而丢失某些特征的细节,同时利用多个特征的信息进行学习,故本文采用 Concatenate 操作对两

端使用 JADE 算法对发送信号进行还原后,提取提取数据的 I/Q 序列,计算小波变换幅度方差、特征参数  $F$ 、特征参数  $u$ 、四次方谱,上述参数构成大小为  $6 \times 2048$  的二维数据,用于后续神经网络的训练。

### 3 基于 CNN 的调制识别

为充分提取数据特征,本文提出如图 7 所示的神经网络架构。I/Q 分量与其他输入特征通过不同的支路提取高维特征,通过特征结合后在经过展平层展平为一维数据矢量,最后进入分类器模块完成调制识别。

#### 3.1 特征提取模块

在特征提取模块,为有效捕获不同调制方式的 I/Q 序列特征,本文使用 3 个卷积层与 3 个池化层对 I/Q 序列进

条支路的特征进行结合。

#### 3.2 分类模块

分类模块由全连接层、随机失活层、输出层构成。数据由特征提取模块处理完成后,先通过展平层变为一维特征向量,再经过 2 个线性层与 2 个随机失活层,最后由输出层生成最终预测结果。为加强模型的非线性能力,同时保证参数能够正常更新,全连接层后接入 ReLU 激活函数,其数学表达式为:

$$\text{ReLU}(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (20)$$

为增强模型的鲁棒性,同时防止出现过拟合,数据在进入下一个线性层之前先进入随机失活层。随机失活层的置零比设置为 0.1,即被赋予零权重的神经元的个数占比为 10%。

输出层采用 Softmax 激活函数,经 Softmax 函数处理后输出  $1 \times 6$  的概率向量  $\mathbf{P}, \mathbf{P} = [p_1, p_2, \dots, p_5], p_j$  为输出层的第  $j$  个概率,其数学表达式为:

$$p_j = \text{softmax}(y_j) = \frac{\exp(y_j)}{\sum_{n=1}^K \exp(y_n)} \quad (21)$$

接着找到  $\mathbf{P}$  中最大元素的位置索引,这个索引就对应着预测的调制类型。

为使得预测结果尽可能接近真实结果,需要引入损失函数来衡量神经网络预测结果与真实结果之间的差异,以便不断优化神经网络的各个参数从而提升性能。损失函数的数学表达式为:

$$L_{\text{BCE}}(\theta) = \frac{\sum_{j=1}^{K_b} [y_j^{\text{real}} \lg(y_j) + (1 - y_j^{\text{real}}) \lg(1 - y_j)]}{-K_b} \quad (22)$$

式中:  $y_j$  是预测标签;  $y_j^{\text{real}}$  是真实标签;  $K_b$  是一个批次包含的样本数。损失函数的值越小,表示预测的调制类型越准确。为此,本文使用随机梯度下降策略更新神经网络的参数,使损失函数的值逐渐减小。随机梯度下降策略对神经网络参数  $\mathbf{W}$  和  $\mathbf{b}$  的计算公式可表示为:

$$J(\mathbf{W}, \mathbf{b}, x, y) = -y \ln \hat{y} - (1 - y) \ln(1 - \hat{y}) \quad (23)$$

$$\mathbf{W}' = \mathbf{W}' - \eta \frac{\partial J(\mathbf{W}, \mathbf{b}, x, y)}{\partial \mathbf{W}'} \quad (24)$$

$$\mathbf{b}' = \mathbf{b}' - \eta \frac{\partial J(\mathbf{W}, \mathbf{b}, x, y)}{\partial \mathbf{b}'} \quad (25)$$

### 4 仿真实验

本节对本文提出的特征结合算法展开仿真实验。本文使用 Matlab 作为仿真平台,首先通过仿真产生 BPSK、QPSK、8PSK、16QAM、64QAM、128QAM 这 6 种信号。为贴合实际,仿真信道加入复高斯白噪声,噪声强度逐渐减小,具体设置为信号信噪比从 0 dB 以 2 dB 为间隔逐渐增大至 20 dB。为确保神经网络得到有效训练,每个信噪比下的每种调制信号均生成 1 000 条用于训练神经网络,生成 300 条用来测试识别性能。在训练神经网络时,部分参数设置情况如表 2 所示。

#### 4.1 MIMO-OFDM 信号子载波调制识别精度

本实验测试了不同信噪比下不同子载波调制方式的识别精度。图 8 展示了不同调制方式随信噪比的变化,图 9 展示了 SNR 为 8 dB 的混淆矩阵。通过图 8 可以观察到,PSK 类信号与 128QAM 信号在 4 dB 条件下就可以达到 100% 识别精度,这是因为小波变换、四次方谱和特征参

表 2 神经网络部分设置

Table 2 Settings for neural networks

名称	值
优化器	Adam
批次大小(Batch)	128
初始学习率(lr)	0.001
迭代次数(epoch)	100
损失函数	Categorical_Crossentropy

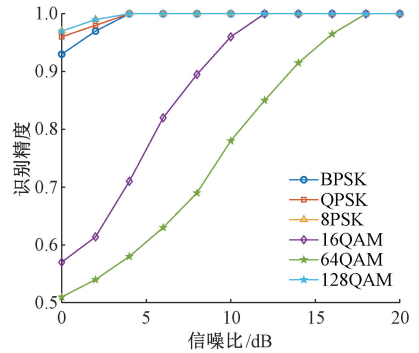


图 8 不同调制方式识别精度

Fig. 8 Recognition accuracy of different modulation methods

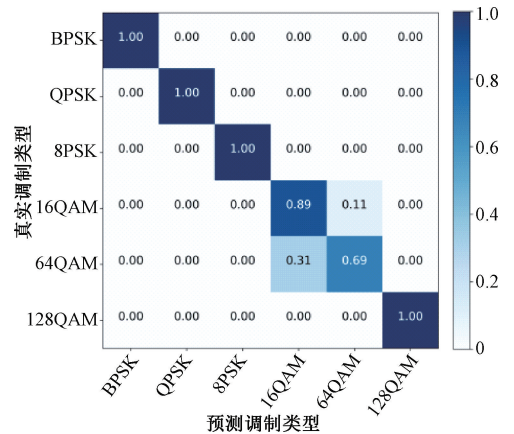


图 9 8 dB 信噪比下的混淆矩阵

Fig. 9 Confusion matrix at a signal-to-noise ratio of 8 dB

数  $F$  具有较好的抗噪声能力。而 16QAM 与 64QAM 两种调制方式由于特征相近,在低信噪比条件下识别精度不够理想。从图 9 可以看出,16QAM 对比 64QAM 识别精度更高,这是因为 16QAM 的 I/Q 分量特征更为明显。随着 SNR 的上升,16QAM 和 64QAM 的识别精度逐渐上升。在 SNR 达到 6 dB 时,综合调制识别精度可达到 90%。除 64QAM 调制外,其他调制方式在 SNR 为 12 dB 时识别正确率均能达到 100%。

#### 4.2 不同网络参数对识别精度的影响

本实验通过修改卷积核的大小与用于训练神经网络的样本数,来测试识别精度的变化。

图 10 展示了训练样本数的改变对算法性能的影响。通过观察可知,在样本数为 1 000 的时候,识别精度是最好的。当样本数为 500 时,识别精度会降低。当信噪比大于 12 dB 时,500 样本数的精度逐渐接近 1 000 样本数。而当样本数降低至 300 时,由于数据量不足,不能满足神经网络训练的需求,识别精度会进一步降低。




图 10 不同样本数识别精度

Fig. 10 Recognition accuracy for different numbers of samples

图 11 展示了不同卷积核尺寸对识别精度的影响。通过观察可知,识别精度随着卷积核尺寸的增加,先变高后降低,因为当卷积核较小时,对 I/Q 序列的特征提取能力不足;而当卷积核较大时,数据中的噪声和局部特征对神经网络的影响增加,从而降低模型的识别精度。本文通过实验证明将卷积核大小设置为 3 可以使得识别精度达到最高。




图 11 不同卷积核大小识别精度

Fig. 11 Recognition accuracies of different convolutional kernel sizes

#### 4.3 不同算法实验性能对比

本实验将本文算法与其他文献算法进行对比,结果如图 12 所示。文献[6]使用原始 I/Q 序列作为输入特征进行调制识别。由于 I/Q 序列易受噪声干扰,该方法在低信噪比条件下的识别精度较低。随着信噪比的增加,I/Q 序列的表达力逐渐增加,该方法的分类精度与本文方法逐渐接近。文献[20]将信号的 I/Q 序列与幅度相位序列结合,通过长短期记忆网络与 CNN 完成调制识别。然而,幅度/相位序列仍属于原始信号的浅层特征,其对识别精度

的提升作用有限。文献[12]使用 I/Q 序列与循环谱作为输入特征完成调制识别,但由于未对循环谱做降噪处理,故识别精度仍然低于本文。文献[19]则使用循环谱和四次方谱作为输入特征完成调制识别,对 3 种 PSK 信号识别效果较好,但由于缺少区分不同 QAM 调制的特征,导致总识别精度较低。本文算法精度较高的原因是针对 QAM 类与 PSK 类信号、不同 PSK 信号以及不同 QAM 信号设计了不同特征参数,使得神经网络能够有效学习到不同信号的特征,从而完成调制识别。

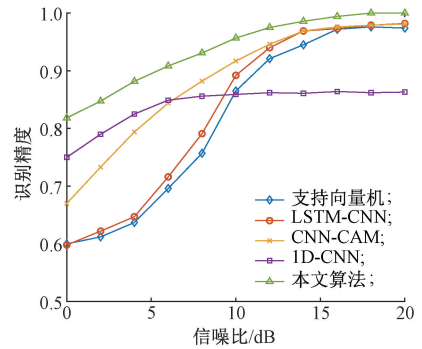


图 12 不同算法的识别精度

Fig. 12 Recognition accuracies of different algorithms

## 5 结 论

本文提出了一种基于特征结合 MIMO-OFDM 调制识别算法。首先,利用 JADE 算法恢复源信号,并计算其四次方谱、小波变换、高阶累积量以及幅度特征参数。然后,将这些特征与直接提取的 I/Q 序列构成数据集,对一维 CNN 进行训练完成调制识别。实验结果表明,在低信噪比环境下,所提算法表现出较好的识别性能,在信噪比高于 6 dB 时,MIMO-OFDM 系统中的子载波调制方式的识别精度可达到 90%。此外,本文方法无需依赖先验信息,具有较强的鲁棒性,适用于非协作通信场景。

实验表明利用特征结合对 MIMO-OFDM 系统子载波调制方式进行识别效果较好,但是本文仅仅测试了 3 种 QAM 信号,后续需要考虑更高阶 QAM 信号的识别。

## 参考文献

- [1] CARLOS B B, TANELI R, MATIAS T, et al. Full-Duplex OFDM radar with LTE and 5G NR Waveforms: Challenges, solutions, and measurements [J]. IEEE Transactions on Microwave Theory and Techniques, 2019, 67(10): 4042-4054.
- [2] ANAND K, SUDHAN M, GUAN G, et al. A survey of blind modulation classification techniques for OFDM signals[J]. Sensors, 2022, 22(3): 1020.
- [3] BSCHIR J, HONG W L, IYAD D, et al. Robust automatic modulation recognition through joint contribution of hand-crafted and contextual features[J]. IEEE ACCESS, 2021, DOI:10.1109/ACCESS.2021.3099222.



- [4] ABDELMUTALAB A, ASSALEH K, EL-TARHUNI M. Automatic modulation classification based on high order cumulants and hierarchical polynomial classifiers[J]. *Physical Communication*, 2016, DOI:10.1016/j.phycom.2016.08.001.
- [5] YAN X, ZHANG G, WU H, et al. Automatic modulation classification in  $\alpha$ -stable noise using graph-based generalized second-order cyclic spectrum analysis [J]. *Physical Communication*, 2019, 37(C): 100854.
- [6] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]. Cham: Springer, 2016: 213-226.
- [7] ZHANG M, ZENG Y, HAN Z, et al. Automatic modulation recognition using deep learning architectures [C]. 2018 IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). IEEE, 2018: 1-5.
- [8] LIU X, WU Z, TANG C. Modulation recognition algorithm based on ResNet50 multi-feature fusion[C]. 2021 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS). IEEE, 2021: 677-680.
- [9] 周顺勇, 陆欢, 胡琴, 等. 基于 SVD 与混合神经网络模型的自动调制识别[J]. *电子测量技术*, 2024, 47(21): 111-121.
- ZHOU SH Y, LU H, HU Q, et al. Automatic modulation recognition based on SVD and Hybrid Neural Network model[J]. *Electronic Measurement Technology*, 2024, 47(21): 111-121.
- [10] 童子滔, 张治中, 张涛, 等. 基于零样本学习和自编码器的调制信号识别研究[J]. *电子测量技术*, 2024, 47(14): 1-9.
- TONG Z T, ZHANG ZH ZH, ZHANG T, et al. Research on modulation signal recognition based on Zero-Shot Learning and autoencoder[J]. *Electronic Measurement Technology*, 2024, 47(14): 1-9.
- [11] 张天骐, 汪锐, 安泽亮, 等. 基于多任务学习的 MIMO-OFDM 信噪比估计与调制识别[J]. *北京邮电大学学报*, 2022, 45(6): 95-100.
- ZHANG T Q, WANG R, AN Z L, et al. SNR estimation and modulation recognition for MIMO-OFDM based on multi-task learning[J]. *Journal of Beijing University of Posts and Telecommunications*, 2022, 45(6): 95-100.
- [12] 张天骐, 汪锐, 安泽亮, 等. 基于多端特征融合模型的 MIMO-OFDM 系统盲调制识别[J]. *信号处理*, 2022, 38(9): 1940-1953.
- ZHANG T Q, WANG R, AN Z L, et al. Blind modulation recognition of MIMO-OFDM system based on multi-terminal feature fusion model [J]. *Signal Processing*, 2022, 38(9): 1940-1953.
- [13] AN Z L, ZHANG T Q, SHEN M, et al. Series-constellation feature based blind modulation recognition for beyond 5G MIMO-OFDM systems with channel fading [J]. *IEEE Transactions on Cognitive Communications and Networking*, 2022, 8(2): 793-811.
- [14] 丛文胜. 高阶 QAM 信号的盲均衡方法研究[D]. 兰州: 兰州大学, 2019.
- CONG W SH. Research on blind equalization methods for high-order QAM signals[D]. Lanzhou: Lanzhou University, 2019.
- [15] 张天骐, 范聪聪, 葛宛莹, 等. 基于 ICA 和特征提取的 MIMO 信号调制识别算法[J]. *电子与信息学报*, 2020, 42(9): 2208-2215.
- ZHANG T Q, FAN C C, GE W Y, et al. MIMO signal modulation recognition algorithm based on ICA and feature extraction[J]. *Journal of Electronics & Information Technology*, 2020, 42(9): 2208-2215.
- [16] LI W, DOU Z, QI L, et al. Wavelet transform based modulation classification for 5G and UAV communication in multipath fading channel [J]. *Physical Communication*, 2019, 34: 272-282. DOI: 10.1016/j.phycom.2019.05.011.
- [17] 张华娣, 楼华勋. MQAM 信号调制方式自动识别方法[J]. *通信学报*, 2019, 40(8): 200-211.
- ZHANG H D, LOU H X. Automatic modulation recognition method for MQAM signals[J]. *Journal of Communications*, 2019, 40(8): 200-211.
- [18] 吴云戈, 张天骐, 李春运, 等. 基于特征融合的 UFMC 系统调制识别算法[J]. *电子测量技术*, 2024, 47(11): 51-58.
- WU Y G, ZHANG T Q, LI CH Y, et al. Modulation recognition algorithm for UFMC system based on feature fusion [J]. *Electronic Measurement Technology*, 2024, 47(11): 51-58.
- [19] 汪锐, 张天骐, 安泽亮, 等. 基于联合特征参数和一维 CNN 的 MIMO-OFDM 系统调制识别算法[J]. *系统工程与电子技术*, 2023, 45(3): 902-912.
- WANG R, ZHANG T Q, AN Z L, et al. Modulation recognition algorithm of MIMO-OFDM system based on joint feature parameters and one-dimensional CNN[J]. *Systems Engineering and Electronics*, 2023, 45(3): 902-912.
- [20] ZHANG Z F, LUO H, WANG CH, et al. Automatic modulation classification using CNN-LSTM based dual-stream structure [J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(11): 13521-13531.

### 作者简介

李璋培(通信作者), 硕士研究生, 主要研究方向为多载波信号盲处理、深度学习。

E-mail: 1302967874@qq.com

张天骐, 教授, 博士生导师, 主要研究方向为通信信号的调制解调、盲处理、语音信号处理、神经网络实现以及 FPGA、VLSI 实现。

孙浩源, 硕士研究生, 主要研究方向为卫星通信系统中的定时同步与载波同步。

钟扬, 硕士研究生, 主要研究方向为数字水印、信息隐藏技术。