

基于可微分架构搜索的多载波信号自动调制识别

李杰, 李靖, 吕璐, 宫丰奎

(西安电子科技大学空天地一体化综合业务网全国重点实验室, 陕西 西安 710071)

摘要: 针对城市多径信道下缺乏多载波信号通用数据集, 以及传统信号特征与网络模型难以有效识别低信噪比下失真信号调制类型的问题, 提出一种基于可微分架构搜索的多载波信号自动调制识别算法。首先, 产生了常见 OFDM、FBMC 与 OTFS 多载波信号经过典型城市多径信道的接收信号数据集, 选取对调制参数不敏感的信号时频图作为特征向量来训练神经网络; 其次, 采用可微分架构搜索方法自动搜索最佳网络结构, 避免了网络结构设计的反复验证工作; 最后, 在特征学习过程中引入联合注意力机制, 将失真信号特征进行空间转换以降低多径干扰影响, 同时计算特征图各通道信息权重并排序, 以提升相关特征图通道的分类效果。仿真结果表明, 所提算法不仅能提升在城市多径信道环境下尤其是低信噪比时的识别正确率, 而且对调制参数变化和小样本场景具有更好的鲁棒性。

关键词: 可微分架构搜索; 多载波信号; 自动调制识别; 城市多径信道; 联合注意力机制

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2024164

Differentiable architecture search-based automatic modulation recognition for multi-carrier signals

LI Jie, LI Jing, LYU Lu, GONG Fengkui

State Key Laboratory of Integrated Service Networks, Xidian University, Xi'an 710071, China

Abstract: Considering the lack of a general multi-carrier signal dataset in urban multipath channels, and the challenge of recognizing the modulation types of distorted signals at low signal-to-noise ratio (SNR), a differentiable architecture search-based (DARTS) automatic modulation recognition algorithm for multi-carrier signals was proposed. Firstly, the received signal datasets of commonly used multi-carrier signals, i. e., orthogonal frequency division multiplexing, filter bank multi-carrier, and orthogonal time frequency space, were generated over typical urban multipath channels. The time-frequency images, which were insensitive to modulation parameters, were selected as feature vectors to train the neural network. Secondly, DARTS was employed to automatically search the optimal network architecture. Finally, a joint attention mechanism was introduced into the feature learning process. This mechanism spatially transforming distorted signal features to mitigate the impact of multipath interference, while also calculating and sorting the information weights for each channel of the feature maps to improve the recognition performance of the relevant feature map channels. Simulation results demonstrate that the proposed algorithm improves accuracy in urban multipath channels, especially at low SNR, while simultaneously providing better robustness to modulation parameter variations and small-sample scenarios.

Keywords: differentiable architecture search, multi-carrier signal, automatic modulation recognition, urban multipath channel, joint attention mechanism

收稿日期: 2024-05-10; 修回日期: 2024-08-17

通信作者: 李靖, jli@xidian.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62271368, No.62001354); 陕西省重点研发计划基金资助项目 (No.2023-YBGY-041); 中国博士后科学基金资助项目 (No.BX20190264, No.2019M650258)

Foundation Items: The National Natural Science Foundation of China (No.62271368, No.62001354), The Key Research and Development Program of Shaanxi Province (No.2023-YBGY-041), China Postdoctoral Science Foundation Project (No.BX20190264, No.2019M650258)

0 引言

从1987年1G开始商用化,到2020年正式推出5G,再到预计2030年应用推广6G,伴随通信技术发展带来的不仅仅是更高的数据传输速率和更大的通信带宽,还有愈发复杂的电磁环境与更加紧缺的频谱资源^[1]。要想实现频谱资源的动态管理,就要利用认知无线电技术实时分析电磁环境,提取有用信息以进行后续决策^[2]。自动调制识别(AMR, automatic modulation recognition)作为认知无线电系统的重要组成模块之一,能够实现信号检测、调制方式识别与参数估计等功能,无论在频谱接入、干扰检测,还是电磁频谱作战、信号情报分析等场景都有广阔的应用空间^[3]。

AMR可以分为基于似然比(LB-AMR, likelihood-based AMR)和统计特征(FB-AMR, feature-based AMR)两大类^[4]。LB-AMR将概率论与假定模型相结合,在已知调制信号类型集合与信道信息的前提下可达到理论最优准确率,但LB-AMR计算复杂度较高,且在仅已知采样率的非协作通信场景中,难以完成信号调制识别与参数识别任务,因此现有研究主要以无须先验信息和计算成本低的FB-AMR为主。FB-AMR对信号进行处理以得到算法输入特征,可设定门限值采用决策树进行分类,也可采用支持向量机或机器学习相关算法进行分类^[5]。

现有AMR工作主要面向单载波信号,对常用多载波信号的研究较少,随着通感一体化技术的不断发展,多载波信号在城市中的应用愈加广泛,如正交频分复用(OFDM, orthogonal frequency division multiplexing)、滤波器组多载波(FBMC, filter bank multi-carrier)与正交时频空间(OTFS, orthogonal time frequency space)信号。受频谱资源共享、无线电管理和电磁频谱战需求的推动,研究城市多径信道环境下的多载波信号自动调制识别算法,以推动基于感知数据的电磁频谱感知和智能频谱管理是十分必要的。

由于OFDM、FBMC和OTFS信号具有相似的功率谱特性,对功率谱作快速傅里叶变换(FFT, fast Fourier transform)或小波变换均无明显差异,难以实现区分^[6]。虽然不同多载波信号的循环自相关函数(CAF, cyclic autocorrelation function)^[7]与循环相关熵谱^[8]表现出不同的特征,能够估计出信

号的载频与时延等参数^[9],但谱线特征与调制参数密切相关,难以适用于缺乏先验信息的非协作通信场景。由于多载波信号均具有渐进高斯性,因此其高阶统计量计算均趋于0,难以实现有效区分^[10]。同相/正交(I/Q, in-phase/quadrature)序列虽然在平坦瑞利衰落信道下经过迫零均衡能有效实现特征提取与调制识别^[11],或在理想信道下通过主成分分析实现信号去噪与特征向量的维度缩减^[12],但仅从时域角度不能充分反映多载波信号携带的信息^[13],而且在城市多径信道环境尤其是低信噪比(SNR, signal-to-noise ratio)时,I/Q序列受衰减、时延等影响严重失真^[14],在非协作场景下难以实现完美的信道估计与补偿。而其他常用的输入特征如零中心归一化瞬时参数^[15]、星座图^[16]和轮廓星座图^[17]等,虽然在单载波调制识别或区分单一类型多载波内不同子载波调制方式时效果较好,但在实现多载波调制识别任务时区分度不明显,效果较差。因此,寻求一种能有效区分不同多载波信号,且对调制参数不敏感的特征量至关重要;而研究在城市多径信道尤其是低SNR环境下,网络模型如何有效提取失真信号特征的关键信息也具有非常重要的理论意义和应用前景。

考虑到设计适用于特定场景和任务的神经网络需要丰富的专家经验,网络性能与人为设计网络结构的好坏紧密相关,因此神经架构搜索(NAS, neural architecture search)技术被提出以实现用神经网络来设计神经网络,极大提升了非协作通信场景中部署的网络架构的灵活性与鲁棒性^[18]。采用梯度下降作为搜索策略的NAS也称可微分架构搜索(DARTS, differentiable architectural search),通过将离散结构连续化来构建可微分的超网络结构,大大降低了内存消耗^[19]。但DARTS技术仍然存在内存短缺的问题^[20],部分通道连接的DARTS(PC-DARTS, partial channel connections DARTS)在结构参数迭代过程中,只选取部分通道参与候选操作运算,在进一步减少计算复杂度的同时,允许使用更大的批尺寸BatchSize来规范与加速训练过程^[21]。要想实现对城市多径环境下的多载波信号自动调制识别,除了利用PC-DARTS算法来提升网络结构的鲁棒性之外,对于多径信道尤其是低SNR时在幅度、相位、频率等维度产生非期望突变的失真信号,探寻如何更有效地提取失真信号所包含的关键

信息, 进而提升神经网络的 AMR 正确率也是十分关键的。

本文主要的研究工作如下。

1) 目前通用的 AMR 数据集为 RadioML2016.10 A^[22]和 RadioML2018.01A^[23], 信号样本均为莱斯衰落下的单载波信号, 其时延点分别为[0,0.5,1.0,2.0], 对于多载波信号被广泛使用的城市多径信道, 缺乏一个通用数据集以评估并改进多载波信号 AMR 算法。本文产生了 OFDM、FBMC 和 OTFS 信号在加性白高斯噪声 (AWGN, additive white Gaussian noise)、扩展行人 A (EPA, extended pedestrian A)、扩展车辆 A (EVA, extended vehicular A) 和扩展典型城市 (ETU, extended typical urban) 4 种典型城市多径信道下的接收数据集, 扩展了现有模拟数据集以支持 AMR 算法在实际环境中获得更佳性能。

2) 在非协作通信场景下, 一部分常用特征量难以区分不同类型多载波信号, 另一部分对调制参数十分敏感, 需要寻找一种能有效区分不同多载波信号且对调制参数具有较强鲁棒性的特征量。通过对 OFDM、FBMC 与 OTFS 信号时频域上不同表现特性的分析, 时频图 (TFI, time frequency image) 不仅能从时域、频域 2 个维度充分展现不同调制类型信号的差异信息, 而且对调制参数不敏感, 因此本文选择 TFI 作为神经网络输入以完成多载波信号 AMR 任务。

3) 为了保证在城市多径信道尤其是低 SNR 环境下提升对失真信号关键信息的有效提取, 在 DARTS 算法中引入联合注意力机制, 分别从空间与通道维度增加对有效特征的关注程度, 增强所生成的网络模型在多径信道下的空间不变性与低 SNR 时的特征聚焦能力, 从而提升对多载波信号调制识别的准确率。

4) 仿真结果表明, 本文所提算法在计算复杂度与识别准确率方面均优于现有算法, 对于不同调制参数具有较强的鲁棒性, 在小样本场景下仍然能保持稳定性能, 有效提升在典型城市多径信道尤其是低 SNR 环境下对常用多载波信号的 AMR 准确率。

1 信号模型

OFDM 与 FBMC 信号在 4G/5G 通信系统中已经得到了广泛应用, 在此主要介绍 6G 关键技术之一

的 OTFS 信号原理^[24]。在 OTFS 信号发送端, 位于时延-多普勒域的信息序列 $x(k,l)$ 首先经过辛有限傅里叶逆变换被转换为时频域的离散信号 $X(m,n)$ ^[25], 可表示为

$$X(m,n) = \frac{1}{\sqrt{MN}} \sum_{k=0}^{M-1} \sum_{l=0}^{N-1} x(k,l) e^{[-j2\pi(\frac{km}{M} - \frac{nl}{N})]} \quad (1)$$

其中, M 和 N 分别为时延域与多普勒域的最大序号值。为使时频域离散信号在时域上连续化, 需要对 $X(m,n)$ 进行 Heisenberg 变换^[26], 可表示为

$$s(t) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} X(m,n) g_{tx}(t-nT) e^{j2\pi m \Delta f (t-nT)} \quad (2)$$

其中, $g_{tx}(t)$ 表示发送端成形滤波器, T 为符号周期, Δf 为子载波间隔。多径信道的冲激响应可建模为

$$h(t) = \sum_{i=0}^{N_h} a_i \delta(t-t_i) e^{j\theta_i} \quad (3)$$

其中, N_h 为多径数目, a_i 、 t_i 和 θ_i 分别为不同径的幅值、时延和相位, $\delta(\cdot)$ 表示冲激函数, 接收信号的表达式为

$$r(t) = s(t) * h(t) + n(t) = \int s(t) h(t-\tau) d\tau + n(t) \quad (4)$$

其中, $*$ 表示卷积操作, $\int(\cdot)$ 表示积分操作, $n(t)$ 为信道高斯噪声。在 OTFS 信号接收端, 首先对接收信号 $r(t)$ 作 Wigner 变换^[27], 将时域连续信号转换为时频域离散信号, 表达式为

$$Y(m,n) = \int r(t) g_{rx}^*(t-nT) e^{-j2\pi m \Delta f (t-nT)} dt \quad (5)$$

其中, $(\cdot)^*$ 表示共轭操作, $g_{rx}(t)$ 表示接收端成形滤波器。对 $Y(m,n)$ 进行周期延拓后得到 $Y_p(m,n)$, 可表示为

$$Y_p(m,n) = \sum_{k,l=-\infty}^{\infty} Y(m-kM, n-lN) \quad (6)$$

然后利用辛有限傅里叶变换得到解调信号^[25], 可表示为

$$y(k,l) = \frac{1}{\sqrt{MN}} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} Y_p(m,n) e^{[-j2\pi(\frac{km}{M} - \frac{nl}{N})]} \quad (7)$$

2 算法设计

对基于可微分架构搜索的多载波信号自动调制识别算法的设计主要分为 2 个部分: 首先是产生 3 种多载波信号在 4 种典型城市多径信道环境下的接收

信号数据集;其次是基于联合注意力的PC-DARTS (JAPC-DARTS, joint attention-based PC-DARTS) 整体架构的实现。

2.1 产生数据集

本文在 MATLAB R2022a 上产生了 OFDM、FBMC 与 OTFS 这 3 种常用多载波信号在 AWGN、EPA、EVA 与 ETU 这 4 种典型城市多径信道下的接收信号数据集。SNR 范围为 $-11\sim 33$ dB, 在网络训练过程中, 为了在不影响 AMR 准确率的前提下降低计算量, 在上述 SNR 范围内以 2 dB 间隔采样作为输入数据集。每个 SNR 下都包含 1 000 组随机截取采样点长度为 1 024 点的 I/Q 序列及其时频图, 按 8:1:1 比例划分为训练集、验证集与测试集。假设调制方式均为 4 点正交幅度调制, 接收信号仅在频域混叠, 同时在后续分析时, 还产生了不同采样长度的小样本信号数据、不同子载波数、不同子载波调制方式的扩展数据。表 1 为所产生信号的部分关键参数。

表 1 信号参数

参数	值
带宽 B/MHz	20
采样率 f_s/MHz	80
虚拟子载波 $N_{vc}/\text{个}$	32
非虚拟子载波 $N_{usc}/\text{个}$	480
FFT 大小 $N_{\text{FFT}}/\text{点}$	512
保护间隔长度 $N_{\text{GI}}/\text{点}$	128
符号总长度 $N_{\text{sym}}/\text{点}$	640
子载波间隔 Δ/kHz	39.062 5
FBMC 重叠因子 K	4

考虑在非协作通信场景中, 传统特征无法有效区分不同多载波信号, 本文将一维 I/Q 序列转换为信号时频图, 从时/频域维度更充分地揭示多载波信号的特征差异, 同时克服了现有工作所用信号特征对调制参数的非鲁棒性。AWGN 信道下 SNR=20 dB 时的多载波信号时频图如图 1 所示。由图 1 可以观察到, 由于多载波信号常加入虚拟子载波以抑制峰值平均功率比, 因此 OFDM 与 FBMC 信号在零频附近会出现信号强度近似为零的情况; 而 FBMC 信号为了避免 OFDM 信号带外衰减慢以及要求子载波严格正交的情况, 引入非矩形脉冲成形滤波器组, 在时域上会出现“拖尾”现象; OTFS 信号由于不同于其他多载波信号的调制解调原理, 并不会出现

上述情况。因此, 可以根据上述分析利用接收信号的时频图来有效识别多载波信号的调制方式。

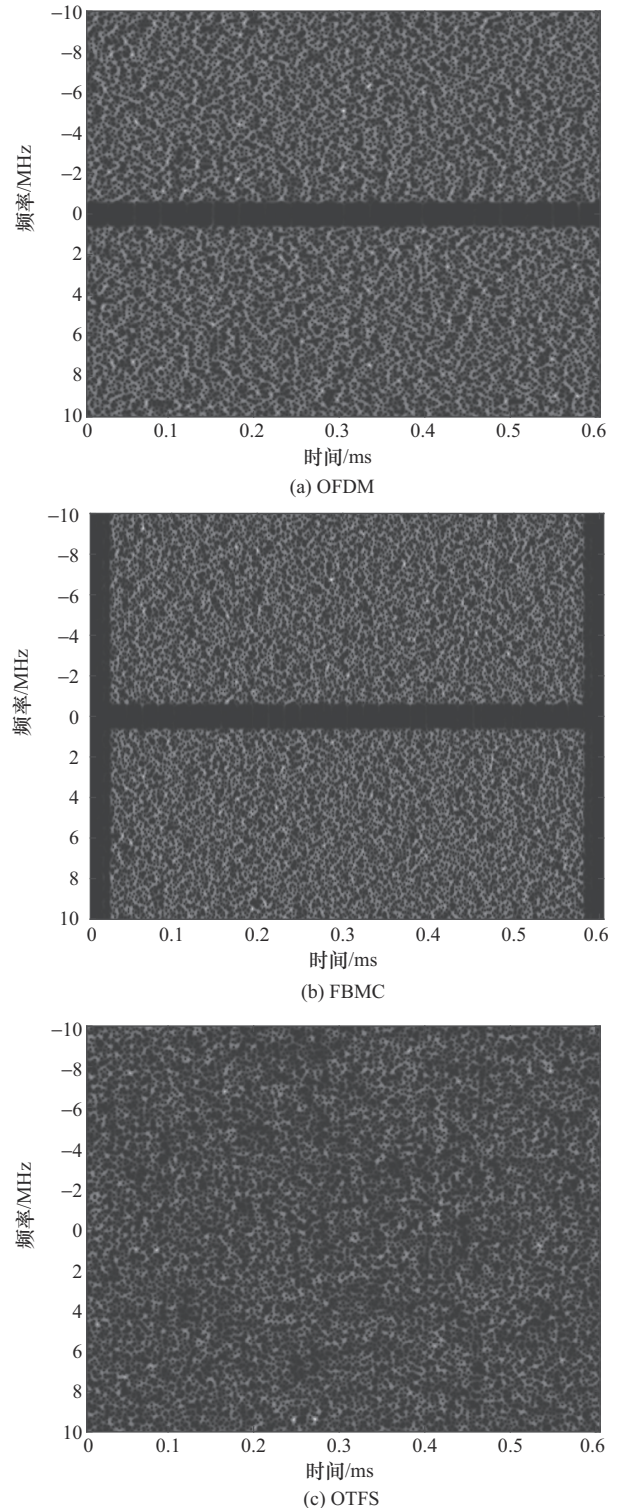


图 1 AWGN 信道下 SNR=20 dB 时的多载波信号时频图

2.2 算法框架

JAPC-DRATS 算法主要包括 3 个部分: 构建

单元网络并重复堆叠得到神经网络，求解权重参数与结构参数双层优化问题得到最优神经网络，将该结构按一定顺序堆叠并进行训练得到最终神经网络。JAPC-DARTS 算法框架如图 2 所示。

具体而言，在预设的搜索空间中使用基于梯度的搜索策略，通过更新每条边上各个候选操作的权重即结构参数及权重参数，搜索组成神经网络的最优单元网络；然后将最优单元网络按特定顺序重复堆叠确定最终网络结构；执行通用的网络训练流程更新权重参数以得到最终的预训练神经网络。单元网络分为 2 类：输入与输出维度保持一致的普通单元（normal cell）和输出维度约减为输入维度一半的缩减单元（reduction cell）。

2.2.1 构建单元网络

JAPC-DARTS 使用基于单元网络的搜索空间，每个单元网络都可以被看作一个由 N 个有序节点 $\{x_1, x_2, \dots, x_N\}$ 组成的有向无环图，每个节点均由边 $E = \{e_{i,j} | 1 \leq i < j \leq N\}$ 相连接，如果一共有 M 个候选操作 $\mathcal{O} = \{o_1, o_2, \dots, o_M\}$ ，那么每条边 $e_{i,j}$ 上均包含一系列由结构参数 $\alpha_{i,j}^k$ 衡量的候选操作 $o_{i,j}^k$ 及该操作在对应边 $e_{i,j}$ 上的权重参数 $\omega_{i,j}^k$ ， k 表示选择第 k 个候选操作。候选操作集如表 2 所示^[28]。

名称	含义
none	零操作
max_pool_3 × 3	3 × 3 最大池化
avg_pool_3 × 3	3 × 3 平均池化
skip_connect	跳跃连接
sep_conv_3 × 3	3 × 3 可分离卷积
sep_conv_5 × 5	5 × 5 可分离卷积
dil_conv_3 × 3	3 × 3 扩张卷积
dil_conv_5 × 5	5 × 5 扩张卷积

此时，问题为对特定候选操作 \mathcal{O} 进行选择，为了将离散搜索空间连续化，可将原问题放缩为所有候选操作的加权求和问题，每个节点的输出为

$$x_j = \sum_{i < j} \sum_{k=1}^M p_{i,j}^k o_{i,j}^k (\omega_{i,j}^k x_i) \quad (8)$$

其中， $p_{i,j}^k$ 是候选操作的概率分布，可由将结构参数 $\alpha_{i,j}^k$ 输入 Softmax 函数得到，表示为

$$p_{i,j}^k = \frac{e^{\alpha_{i,j}^k}}{\sum_{k=1}^M e^{\alpha_{i,j}^k}} \quad (9)$$

此时，通过搜索空间实现连续化编码， $\alpha_{i,j}^k$ 是连续的，超网络结构可以表示为 $N(A(\alpha), \omega)$ ， α 与 ω 均为连续可学习的一组变量，由 α 决定的网络结




图 2 JAPC-DARTS 算法框架

构用 $A(\alpha)$ 表示。

$$\begin{cases} \alpha = \{\alpha_{ij}^k\} \\ \omega = \{\omega_{ij}^k\} \end{cases} \quad (10)$$

因此,原问题可以改写为一个通过随机梯度下降(SGD, stochastic gradient descent)法交替优化训练损失与验证损失的双层优化问题。具体而言,上层外部优化问题通过不断更新 α 以最小化验证损失函数值 L_{val} ,下层内部优化问题通过在训练集上学习以得到最小化训练损失函数值 L_{train} 时的 ω ,可表示为

$$\begin{aligned} \min_{\alpha} \quad & L_{\text{val}}(w^*(\alpha), \alpha) \\ \text{s.t.} \quad & w^*(\alpha) = \arg \min_{\omega} L_{\text{train}}(w, \alpha) \end{aligned} \quad (11)$$

该问题的迭代求解公式可表示为

$$\begin{cases} \alpha_{k+1} = \alpha_k - \zeta_{\alpha} \nabla_{\alpha} L_{\text{val}}(w_{k+1}, \alpha_k) \\ \omega_{k+1} = \omega_k - \zeta_{\omega} \nabla_{\omega} L_{\text{train}}(w_k, \alpha_{k+1}) \end{cases} \quad (12)$$

其中, ζ_{α} 与 ζ_{ω} 分别表示 α 与 ω 的学习率。详细的算法流程如第2.3节所示。

通过对双层优化问题的求解,结构参数 α 与权重参数 ω 将在每一次迭代中更新,最后一次迭代结束后,将根据 α 的取值大小离散化处理 $A(\alpha)$,即对每个中心节点 x_j ,选取 α_{ij}^k 值最大的2个前置连接边 e_{ij} 与其相对应的操作 o_{ij}^k ,此时将移除剩余的边与候选操作,根据选择的边与操作得到最优单元网络;再将该单元网络按照特定顺序进行堆叠以得到最终用于识别分类任务的网络结构;在对应的训练集与验证集上执行通用的网络训练流程,即可得到能用于特定任务的已训练神经网络。

2.2.2 部分通道连接

JAPC-DARTS在搜索空间中采用部分通道连接的方法,即进行候选操作运算时只选取一部分通道,其余通道直接与进行候选操作运算后的通道相连接,该方法能大大减少计算资源的消耗,允许使用更大的批尺寸来增加采样数据的范围,提升算法运行效率的同时减弱了搜索过程中的非期望波动。如果对通道进行 λ 倍下采样,即选取 $\frac{1}{\lambda}$ 数量的通道进行候选操作运算,该部分通道可以被标记为1,其余未被选取的掩码通道将会被标记为0。对于一个图片数据输入 F 而言,其尺寸大小为 $C \times H \times W$,这表明 F 的通道数为 C 、高度为 H 、宽度为 W ,掩码过程可表示为

$$M_{ij}^c = \begin{cases} 1, & F_c \in \text{random } \frac{1}{\lambda} \text{ of } F \\ 0, & F_c \notin \text{random } \frac{1}{\lambda} \text{ of } F \end{cases} \quad (13)$$

其中, $1 \leq c \leq C$ 。此时掩码通道就可以跳过该运算步骤直接复制到输出,等待与运算后的选取通道合并。每个节点的输出公式将改写为

$$\begin{aligned} f_{ij}(x_i; M_{ij}) = & \\ & \sum_{i < j, k=1}^M p_{ij}^k o_{ij}^k(\omega_{ij}^k, S_{ij} x_i) + (1 - S_{ij}) x_i = \\ & \sum_{i < j, k=1}^M \sum p_{ij}^k o_{ij}^k(\omega_{ij}^k, M_{ij} x_i) + (1 - M_{ij}) x_i \end{aligned} \quad (14)$$

其中, $S_{ij} x_i$ 与 $(1 - S_{ij}) x_i$ 分别表示被选取通道与掩码通道, $S_{ij} x_i$ 的数量为通道总数量的 $\frac{1}{\lambda}$ 。

此外,每个节点最终输出将通过在训练过程中共享的参数 β_{ij} 进行边缘规范化得到 q_{ij} ,以改善时变情况下最佳连接可能出现的非期望波动,确保迭代过程中生成的网络架构的稳定性,表达式为

$$q_{ij} = \frac{e^{\beta_{ij}}}{\sum_{i < j} e^{\beta_{ij}}} \quad (15)$$

此时,节点 x_j 可表示为

$$x_j = \sum_{i < j} q_{ij} f_{ij}(x_i; M_{ij}) \quad (16)$$

2.2.3 联合注意力机制

在多载波信号被广泛应用的城市多径信道环境下,接收端收到的失真信号将会在幅频特性等方面均发生明显突变,当SNR较小时这种现象会更加严重。因此本文引入联合注意力机制,如图3所示。不同于现有算法,为了提升系统模型的空间不变性与特征提取能力,算法首先对时频图上的输入特征计算空间注意力并加权,保证能对失真信号进行时频空间转换并捕获关键信息。为了在降低复杂度的同时保证性能稳定性,选取通道时按照特征图中各通道的关键信息权重排序选取,抑制不相关特征对识别结果的影响。通过引入联合注意力机制,对时频图上可反应的信号时/频域信息,从空间和通道维度提取更加准确和有效的特征,利用神经网络设计最优的网络架构并进行充分学习,最终得到一个适用于城市多径传播,尤其是低SNR环境下失真多载波信号的最优网络模型和架构参数,从而有效提升识别准确率。

空间注意力机制,就是将 F 分别经过全局平均池化GAP与全局最大池化GMP得到2个大小为 $1 \times$




图3 联合注意力机制

$H \times W$ 的特征数据 f_{SA_gap} 和 f_{SA_gmp} , 输出拼接后用 7×7 的卷积核执行一次卷积操作, 卷积结果输入 sigmoid 激活函数, 得到大小为 $1 \times H \times W$ 的空间注意力权重 F_{SA} 。表达式为

$$F_{SA} = \sigma \left\{ f^{7 \times 7} [\text{GAP}(F); \text{GMP}(F)] \right\} = \sigma \left[f^{7 \times 7} (f_{SA_gap}; f_{SA_gmp}) \right] \quad (17)$$

考虑到空间维度不必进行下采样, 因此只需得到空间注意力加权后的特征图 $F' = F_{SA} \times F$ 即可。

尽管部分通道连接能将计算花费降低为原来的 $\frac{1}{\lambda}$, 但是算法的识别准确率并不稳定, 这是因为随机选取通道无法保证每次都选取到特征图上含有重要信息的通道, 要想让算法性能稳定, 就需要在选取通道时尽可能地选取含有高价值特征的通道, 而通道注意力机制可以实现此需求。

通道注意力机制, 即在通道维度衡量哪些通道含有更有价值的特征信息并给出介于 0~1 的通道注意力权重, 进而确保网络在训练学习时能关注特征图上更重要的通道。要想得到其通道注意力权重, 先要对 F 分别进行 GAP 和 GMP 以得到 2 个大小为 $C \times 1 \times 1$ 的特征数据 f_{CA_gap} 和 f_{CA_gmp} ; 然后将特征数据输入一个 2 层参数共享的全连接网络 MLP, 将输出结果 f'_{CA_gap} 与 f'_{CA_gmp} 相加; 最后, 将求和结果输入 sigmoid 激活函数得到最终大小为 $C \times 1 \times 1$ 的通道注意力权重 F_{CA} 。表达式为

$$F_{CA} = \sigma \left\{ \text{MLP}[\text{GAP}(F)] + \text{MLP}[\text{GMP}(F)] \right\} = \sigma \left[\text{MLP}(f_{CA_gap}) + \text{MLP}(f_{CA_gmp}) \right] = \sigma (f'_{CA_gap} + f'_{CA_gmp}) \quad (18)$$

在节点 i 与节点 j 之间选取数量占比 $\frac{1}{\lambda}$ 的通道连接候选操作运算时, 可将通道注意力权重 F_{CA} 与输入特征数据 F 相乘, 对可在通道维度衡量特征信息重要程度的 $F' = F_{CA} \times F$ 按大小进行排序, 根据排序结果依次选取通道, 被选取通道将被标记为 1,

掩码通道则被标记为 0。如果不同节点间通道的掩码值为 M_{ij} , 则表达式为

$$M_{ij}^c = \begin{cases} 1, & F'_c \in \text{top } \frac{1}{\lambda} \text{ of } F' \\ 0, & F'_c \notin \text{top } \frac{1}{\lambda} \text{ of } F' \end{cases} \quad (19)$$

在联合注意力机制中, 空间注意力模块将会被部署在通道注意力模块之前, 确保在选取包含关键信息的通道之前就已经补偿了信号特征的失真效应, 因此加权后的空间维度与通道维度特征图将表示为

$$F'' = F_{CA} \times F' \quad (20)$$

2.3 算法流程

基于可微分架构搜索的多载波信号调制识别算法如算法 1 所示, 其输入为随机采样信号的时频图将被裁剪为 $32 \times 32 \times 3$ 。此外, 还应预设算法的一些关键超参数, 基于联合注意力机制得到包含信息重要程度的特征图; 通过梯度下降法求解双层优化问题以完成最优单元网络搜索, 按特定顺序堆叠后得到最终网络结构; 对该网络进行通用神经网络训练更新权重参数, 即得到可用于不同信道环境下多载波信号调制方式识别的预训练神经网络。

算法 1 基于可微分架构搜索的多载波信号调制识别算法

输入 TFI, 给定通道选取因子 λ , 节点数 N , 搜索轮数 E_s , 训练轮数 E_t , 预热轮数 E' , 其他超参数如 $\mathcal{O}, \zeta_a, \zeta_w$ 等

- 1) <网络搜索>
- 2) 初始化参数;
- 3) for $t = 1, 2, \dots, E_s$
- 4) for $1 \leq i < j \leq N$
- 5) if $t \leq E'$
- 6) 随机选取 $\frac{1}{\lambda}$ 数量通道;
- 7) else
- 8) 基于联合注意力机制选取排序后的前 $\frac{1}{\lambda}$

数量通道, 根据式(11)更新 α ;

- 9) end if
- 10) end for
- 11) 根据式(11)更新 ω ;
- 12) end for
- 13) <网络训练>
- 14) 根据 α 与 ω 得到最优单元网络, 按一定顺序堆叠得到最终网络架构, 初始化参数;
- 15) for $t = 1, 2, \dots, E_t$
- 16) 按通用网络流程训练该网络, 更新 α ;
- 17) end for

3 参数设定与仿真分析

3.1 参数设定

本文仿真所用GPU为NVIDIA GTX 4060Ti, 此处给出网络搜索与网络训练模块部分通用参数, 参数设定如表3所示, 为保证算法性能对比的公平性, 采用与现有算法一致的网络训练方法与参数设置^[28]。

参数	网络搜索	网络训练
网络层数/层	8	30
初始通道数/个	16	36
搜索/训练轮数/轮	20	60
预热轮数/轮	5	0
批尺寸BatchSize/个	$16\lambda, \lambda \in \{1, 2, 4, 8, 16\}$	64

SGD方法中引入的动量值设为0.9, 初始学习率为0.1, 正则化参数概率取0.3, 权重衰退设为 3×10^{-4} 。给定Adam优化器的固定学习率为 6×10^{-4} , 该参数可用于更新结构参数, 动量取值范围为[0.5, 0.999], 权重衰退设为 1×10^{-3} 。每层包括7个节点, 网络搜索模块中有8种候选操作。

3.2 仿真分析

在网络搜索模块, 按 λ 取值分别进行最优单元网络的结构搜索, 通道选取因子对算法性能的影响如表4所示。可以看到当 $\lambda = 4$ 时本文所提算法对不同信道环境、不同SNR下的多载波信号的平均识别准确率最高, 而随着 λ 的增大, 搜索成本会逐步减小, 最终用于网络训练模块的参数运算量也会下降。

表4 通道选取因子对算法性能的影响

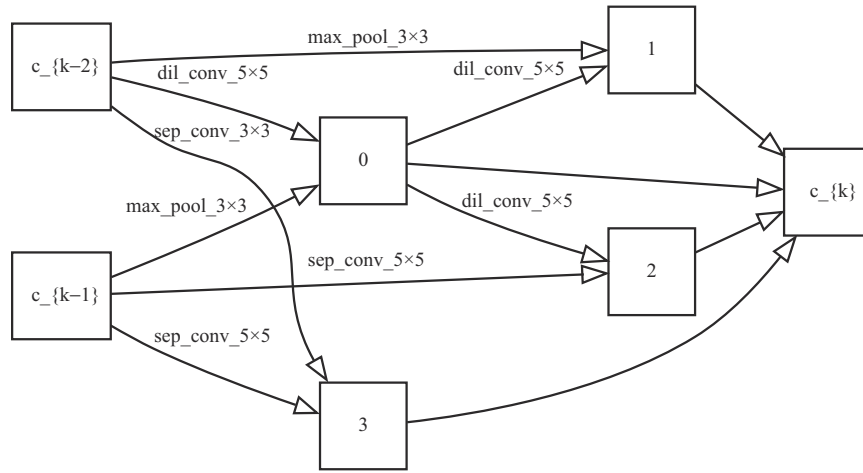
λ	平均正确率	搜索成本/(GPU·day ⁻¹)
1	88.68%	2.67
2	88.50%	1.45
4	89.04%	1.03
8	88.76%	0.64
16	88.66%	0.48

根据预设定的节点数与候选操作集等信息, 可以得到 $\lambda = 4$ 时normal cell与reduction cell的可视化结构如图4所示。


在网络训练模块, 利用 $\lambda = 4$ 时得到的最优单元网络按照一定顺序堆叠, 并按照通用网络训练流程进行训练, 最终得到可用于多载波信号调制方式识别的预训练网络JAPC-DARTS, 与仅包含通道注意力的PC-DARTS (CAPC-DARTS, channel attention PC-DARTS)、PC-DARTS、DARTS、NAS和I/Q-CNN算法进行对比, 不同算法识别准确率结果如图5所示。

由图5可以看出, 传统的基于I/Q序列的CNN模型识别效果较差, 从多径传播后的I/Q序列中提取的高维特征远不如TFI经过多次非线性变换所展现的抽象特征更具有区分度。而NAS (参数量为1.247 MB) 虽然避免了基于专家经验设计的神经网络难以完全适用特定场景的缺点, 但相比于高搜索效率与低计算复杂度的DARTS (参数量为0.935 MB) 与PC-DARTS (参数量为0.164 MB) 而言, 网络结构的参数量较大, 神经网络的训练时间较长。CAPC-DARTS在通道注意力影响下能更好地学习通道维度上的高信息量特征, 但在多载波信号常用的城市多径信道尤其是低SNR环境下, 该算法不能充分且有效地提取到失真信号TFI中所包含的关键信息。而本文所提算法JAPC-DARTS通过在空间与通道2个维度根据注意力联合加权, 提升了网络模型的空间不变性与特征聚焦能力, 解决了噪声与干扰影响下失真信号的有效特征缺乏关注度的问题, 因此相比于其他算法, 在多径信道尤其是低SNR环境下具有更高的识别准确率。

本文还绘制了 $\lambda = 4$ 时JAPC-DARTS在不同信道环境下的信号识别混淆矩阵, 如图6所示。随着SNR的增加, 多载波信号AMR的准确率也不断提高, 在SNR=5 dB与SNR=15 dB时, 平均准确率已经达到92.8%和98.1%, 证明JAPC-DARTS可以有效完成多径信道环境下的多载波信号AMR任务。



(a) normal cell



(b) reduction cell

图4 normal cell与reduction cell的可视化结构

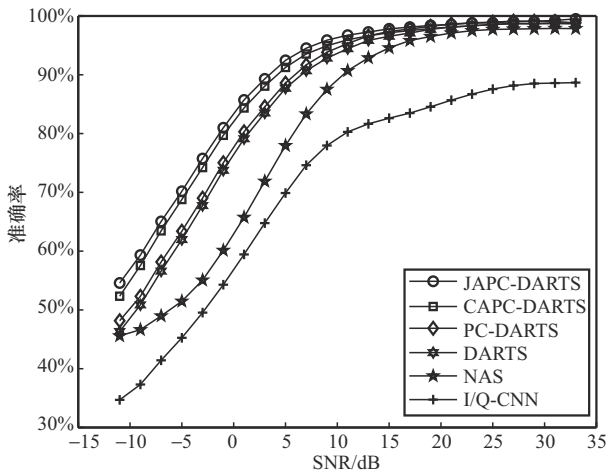


图5 不同算法识别准确率结果

在相同 SNR 环境下，由于 EVA 信道的时延最大、ETU 信道的功率衰减最大，因此 EVA 与 ETU 信道环境下的 AMR 准确率相比较差。但本文算法在这 2 个信道的低 SNR 时也能分别达到 64.3% 与 69.7% 的识别率。当 SNR=5 dB 时，识别率将快速上升到 93% 与 93.3%，这表明 TFI 能有效揭示不同多载波信号间的差异特征。在 SNR 取 15 dB 时，EVA

与 ETU 信道环境下的准确率可以分别达到 99.3% 和 98%，信道衰减与时延情况较好的 EPA 信道正确识别率可以达到 96.7%，信道环境最好的 AWGN 信道则可以达到 98.3%。对混淆矩阵的分析表明，即便在时延与衰减影响严重的典型多径信道环境下，本文所提算法仍然可以高效完成 AMR 任务，准确地识别出不同多载波调制类型的调制方式。

考虑到非协作环境下信号产生的突发性和采集的不可预测性，信号采集的样本数往往较小，为了验证所提算法在小样本数据场景下的泛化性能，本文还产生了在 -11~33 dB 内间隔 2 dB 范围每个 SNR 下 50 组随机截取采样点数为 1 024、512、256 的时频图，利用 JAPC-DARTS 算法识别 4 种多载波信号，小样本场景下 JAPC-DARTS 算法识别准确率如图 7 所示。由图 7 可以看出，随着多载波信号采样点数的减小，JAPC-DARTS 算法的识别准确率会随之下降，这是因为较小采样点数的信号样本所构成的 TFI 只能反映一部分信号特征，神经网络难以有效识别出对应的多载波信号调制类型；当采样点数为 256 时，在高信噪比时可以达到 75.67% 的

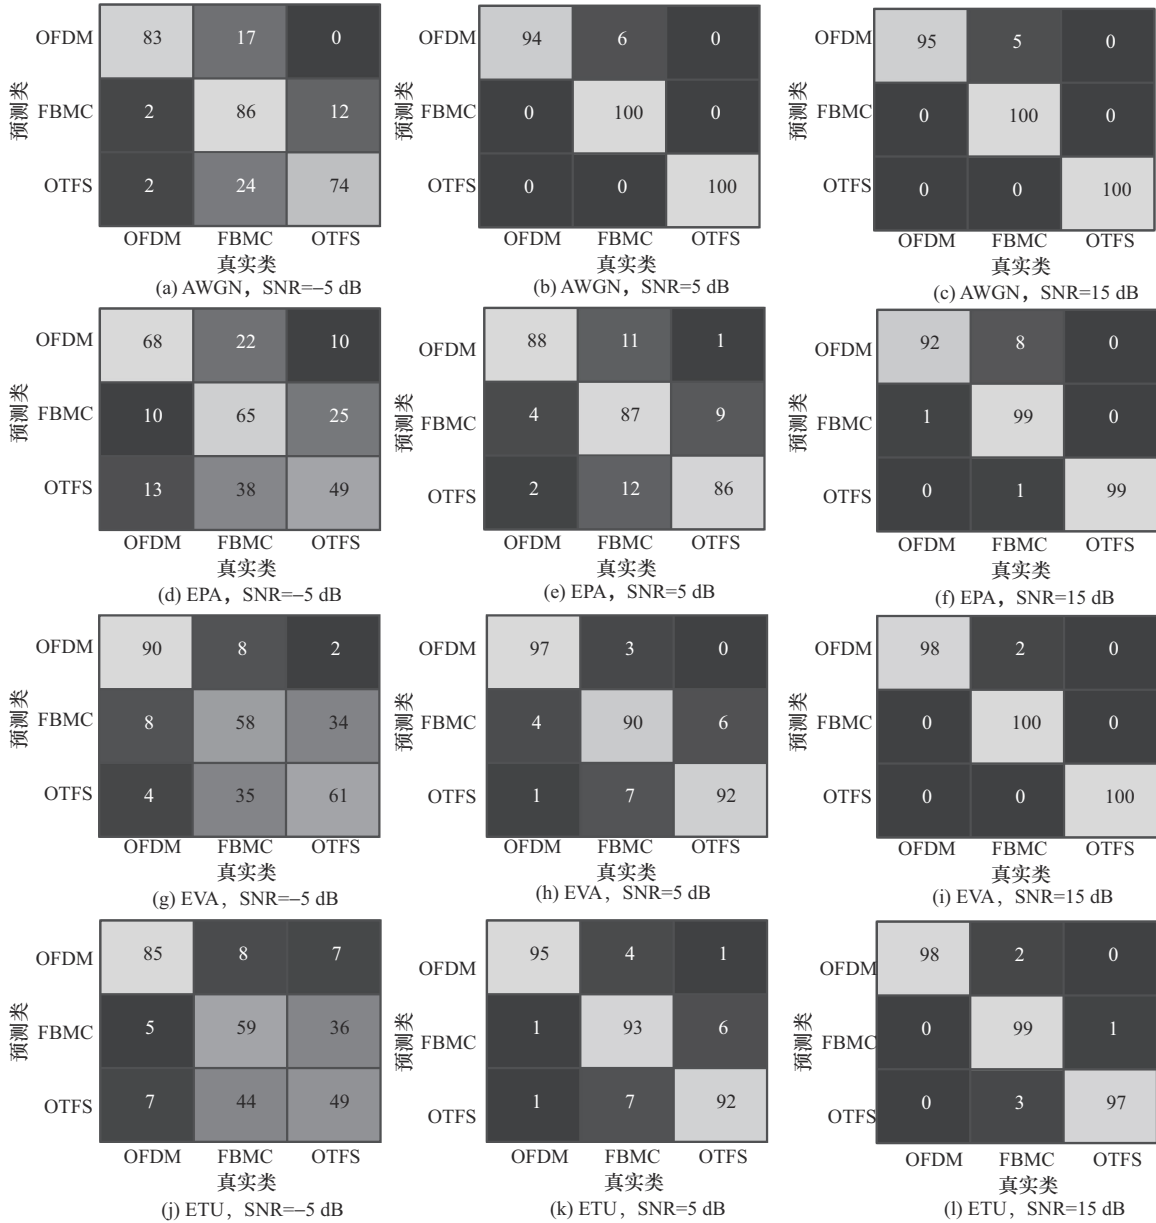


图6 $\lambda = 4$ 时 JAPC-DARTS在不同信道环境下的信号识别混淆矩阵




图7 小样本场景下 JAPC-DARTS 算法识别准确率

识别准确率, 这说明了本文所提算法在小样本数据场景下, 仍然具有良好的表现性能。

由于多载波信号在不同应用场景下往往具有不同数目的子载波, 不同子载波数对 JAPC-DARTS 算法的影响如图 8 所示。从图 8 中可以看出, 子载波数的变化对于多载波信号的调制识别影响较小, 当子载波数目变为原来的 $\frac{1}{4}$ 时, 识别准确率最大仅下降了 8%。相较于传统算法如 CAF 的谱线特征与子载波数密切相关, 不同子载波数的多载波信号在时频图上的表现差异不大, 对时频图所承载的信号特征影响较小, 因此 JAPC-DARTS 算法在不同子

载波数下仍可以高效地完成多载波信号的调制识别任务。




图8 不同子载波数对JAPC-DARTS算法的影响

此外,对于不同的任务需求,多载波信号需要设定不同的子载波调制方式以实现信息高效可靠传输,不同子载波调制方式对JAPC-DARTS算法的影响如图9所示。由于神经网络是由4QAM调制方式的信号进行训练,因此4QAM子载波类型的多载波信号平均准确率最高,对于其他常见的子载波调制方式,平均准确率最大下降0.79%。这是因为不同子载波调制方式在时频图上的表现特征差别不大,仅在能量以及发散程度上略有区别。因此本文所提算法在不同子载波调制方式下仍然具有较好的鲁棒性,能有效解决非协作场景下对多径传播的多载波信号的调制方式识别问题。

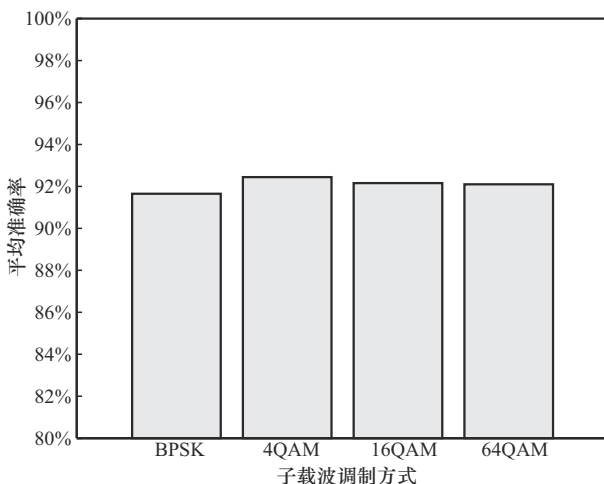


图9 不同子载波调制方式对JAPC-DARTS算法的影响

4 结束语

本文对多载波信号AMR有效特征选取与多径信道低SNR环境下的关键信息提取问题进行研究,提出一种基于可微分架构搜索的多载波自动调制识别算法。选取多载波信号常用的典型城市多径信道环境,产生一个可用于多载波信号AMR的通用数据集;分析OFDM、FBMC与OTFS信号在时频域上的差异,选择对调制参数不敏感的有效特征即信号时频图作为神经网络的输入;在DARTS算法中引入联合注意力机制,从空间与通道增加对失真信号时频图中关键特征的关注程度,提升网络模型对多径传播的空间不变性与低SNR时的特征提取与学习能力。仿真结果表明,相比于现有算法,本文所提算法在具有较低的计算复杂度的同时可以保证更高的识别准确率,对于不同的调制参数及小样本场景仍然能保持稳定的识别准确率,在典型城市多径信道尤其是低SNR环境下,能实现对常用多载波信号调制方式的有效识别。

参考文献:

- [1] DOAN V S, HUYNH-THE T, KIM D S. Underwater acoustic target classification based on dense convolutional neural network[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 19: 1-5.
- [2] WANG C X, YOU X H, GAO X Q, et al. On the road to 6G: visions, requirements, key technologies, and testbeds[J]. IEEE Communications Surveys & Tutorials, 2023, 25(2): 905-974.
- [3] ELDEMERDASH Y A, DOBRE O A, ÖNER M. Signal identification for multiple-antenna wireless systems: achievements and challenges[J]. IEEE Communications Surveys & Tutorials, 2016, 18(3): 1524-1551.
- [4] LIU X Y, LI C J, JIN C T, et al. Wireless signal representation techniques for automatic modulation classification[J]. IEEE Access, 2022, 10: 84166-84187.
- [5] GAMAGE S, SAMARABANDU J. Deep learning methods in network intrusion detection: a survey and an objective comparison[J]. Journal of Network and Computer Applications, 2020, 169(6): 102-107.
- [6] KEBEDE T, WONDIE Y, STEINBRUNN J, et al. Multi-carrier waveforms and multiple access strategies in wireless networks: performance, applications, and challenges[J]. IEEE Access, 2022, 10: 21120-21140.
- [7] AN Z L, ZHANG T Q, XU Y Q, et al. Multimodality-aided multicarrier waveform recognition in low SNR regimes based on denoised cyclic autocorrelation transformation[J]. IEEE Transactions on Aerospace and Electronic Systems, 2023, 59(5): 5859-5875.
- [8] 戴江安, 栾声扬, 赵明龙, 等. 脉冲噪声下基于平滑循环相关熵谱的调制识别方法[J]. 通信学报, 2021, 42(12): 121-133.
- [9] DAI J A, LUAN S Y, ZHAO M L, et al. Pol-CCES based modulation recognition method under impulsive noise[J]. Journal of Communications, 2021, 42(12): 121-133.
- [9] ZERHOUNI K, AMHOUD E M, CHAFII M. Filtered multicarrier wave-

- forms classification: a deep learning-based approach[J]. IEEE Access, 2021, 9: 2169-3536.
- [10] KUMAR A, MAJHI S, GUI G, et al. A survey of blind modulation classification techniques for OFDM signals[J]. Sensors, 2022, 22(3): 1020-1051.
- [11] 安泽亮, 张天骐, 马宝泽, 等. 基于一维CNN的多入多出OSTBC信号协作调制识别[J]. 通信学报, 2021, 42(7): 84-94.
AN Z L, ZHANG T Q, MA B Z, et al. Cooperative modulation recognition based on one-dimensional convolutional neural network for MIMO-OSTBC signal[J]. Journal on Communications, 2021, 42(7): 84-94.
- [12] DUAN S R, CHEN K, YU X, et al. Automatic multicarrier waveform classification via PCA and convolutional neural networks[J]. IEEE Access, 2018, 6: 51365-51373.
- [13] XIAO W S, LUO Z Q, HU Q. A review of research on signal modulation recognition based on deep learning[J]. Electronics, 2022, 11(17): 2764-2792.
- [14] ZHANG F X, LUO C B, XU J L, et al. Deep learning based automatic modulation recognition: Models, datasets, and challenges[J]. Digital Signal Processing, 2022, 129: 103650-103663.
- [15] AZZOUEZ E E, NANDI A K. Automatic identification of digital modulation types[J]. Signal Processing, 1995, 47(1): 55-69.
- [16] HUANG S, JIANG Y Z, GAO Y, et al. Automatic modulation classification using contrastive fully convolutional network[J]. IEEE Wireless Communications Letters, 2019, 8(4): 1044-1047.
- [17] AN Z L, ZHANG T Q, MA B Z, et al. Blind high-order modulation recognition for beyond 5G OSTBC-OFDM systems via projected constellation vector learning network[J]. IEEE Communications Letters, 2022, 26(1): 84-88.
- [18] ZOPH B, LE Q V. Neural architecture search with reinforcement learning[C]//Proceedings of 2017 International Conference on Learning Representations. Vancouver: ICLR, 2017: 1-16.
- [19] LIU H, SIMONYAN K, YANG Y. DARTS: differentiable architecture search[C]//Proceedings of 2018 International Conference on Learning Representations. Vancouver: ICLR, 2018: 1-13.
- [20] 张睿, 张鹏云, 孙超利. 基于多域融合及神经架构搜索的语音增强方法[J]. 通信学报, 2024, 45(2): 225-239.
ZHANG R, ZHANG P Y, SUN L C. Speech enhancement method based on multi-domain fusion and neural architecture search[J]. Journal on Communications, 2024, 45(2): 225-239.
- [21] XU Y H, XIE L X, ZHANG X P, et al. PC-DARTS: partial channel connections for memory-efficient architecture search[C]//Proceedings of 2019 International Conference on Learning Representations. Vancouver: ICLR, 2019: 1-13.
- [22] O'SHEA T J, WEST N. Radio machine learning dataset generation with gnu radio[C]//Proceedings of the GNU Radio Conference. Piscataway: IEEE Press, 2016: 1-6.
- [23] O'SHEA T J, ROY T, 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.
- [24] YUAN W J, WEI Z Q, LI S Y, et al. Orthogonal time frequency space modulation: Part III: ISAC and potential applications[J]. IEEE Communications Letters, 2023, 27(1): 14-18.
- [25] HADANI R, RAKIB S, TSATSANIS M, et al. Orthogonal time frequency space modulation[C]//Proceedings of the 2017 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2017: 1-6.
- [26] 邢旺, 唐晓刚, 周一青, 等. 面向OTFS的时延-多普勒域信道估计方法综述[J]. 通信学报, 2022, 43(12): 188-201.
XING W, TANG X G, ZHOU Y Q, et al. Survey of channel estimation method in delay-Doppler domain for OTFS[J]. Journal on Communications, 2022, 43(12): 188-201.
- [27] LONGO G, BERNARD P. Time and frequency representation of signals and systems[M]. Berlin: Springer, 1989.
- [28] ZHANG X X, ZHAO H T, ZHU H B, et al. NAS-AMR: neural architecture search-based automatic modulation recognition for integrated sensing and communication systems[J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(3): 1374-1386.


[作者简介]




李杰 (2001-), 男, 陕西铜川人, 西安电子科技大学博士生, 主要研究方向为卫星通信信号分析与处理。



李靖 (1980-), 男, 湖北荆州人, 博士, 西安电子科技大学教授, 主要研究方向为宽带无线传输、人工智能与无线通信融合。



吕璐 (1990-), 男, 河北张家口人, 博士, 西安电子科技大学副教授, 主要研究方向为物理层安全、通信感知一体化。



宫丰奎 (1979-), 男, 山东潍坊人, 博士, 西安电子科技大学教授, 主要研究方向为新一代无线通信关键技术。