

基于频域数据压缩感知的复合调制 信号盲识别



何 羚^{1,2}, 阳鹏飞¹, 阎 啸^{1,2*}, 钟旭诺¹, 白泰礼¹

(1. 电子科技大学 航空航天学院, 成都 611731; 2. 飞行器集群智能感知与协同控制四川省重点实验室, 成都 611731)

摘要 现有基于特征提取和模式识别的复合调制盲识别方法对特征和样本量敏感, 且在多子载波情况下流程繁琐。基于统一载波体制复合调制信号建模, 提出了以压缩后的复合调制信号频域数据为特征、利用倒残差分组卷积结构的轻量化神经网络对压缩数据进行训练和分类的盲识别新思路。通过实验平台搭建和 Python 代码实现, 对 10 种复合调制信号进行了不同信噪比下的盲识别对比试验, 结果表明: 该方法在 0 dB 信噪比条件下识别率可达 94.5%, 5 dB 信噪比条件下识别率为 100%; 精确识别所需数据量少于基于统计特征和决策树的识别方法, 分类所用神经网络的准确率和参数量亦优于基准网络。

关键词 复合调制; 盲识别; 统一载波体制; 频域数据; 压缩感知; 轻量化神经网络

中图分类号 TN971.4

文献标志码 A

DOI 10.12178/1001-0548.2023096

Blind Recognition for Composite Modulation Signal Based on Frequency-Domain Data Compressed Sensing

HE Ling^{1,2}, YANG Pengfei¹, YAN Xiao^{1,2*}, ZHONG Xunuo¹, and BAI Taili¹

(1. School of Aeronautics and Astronautics, University of Electronic and Technology of China, Chengdu 611731, China;

2. Aircraft Swarm Intelligent Sensing and Cooperative Control Key Laboratory of Sichuan Province, Chengdu 611731, China)

Abstract Modern TT&C (Tracking, Telemetry and Command) system mostly adopts the composite modulation in a form of “pulse coding/multi-subcarrier internal modulation/external modulation”. This complicated scheme brings great challenges to signal accurate recognition in the absence of prior information and low signal-to-noise ratio (SNR) scenario. The existing composite modulation blind recognition methods based on feature extraction and pattern recognition are sensitive to signal features and sample size, and the whole process becomes even more cumbersome in the case of multiple subcarriers. In this paper, based on the unified carrier system composite modulated signal modeling, a new idea of blind recognition is proposed to train and classify the compressed composite modulated signal frequency domain data by using the inverse residual packet convolutional structure of lightweight neural network. By means of experiment platform construction and Python code designing, the proposed method verification for 10 composite modulated signals in condition of various SNRs is implemented. The results show that the recognition accuracy of the proposed method can reach 94.5% (SNR=0 dB) and 100% (SNR=5 dB) respectively; moreover, the sample size required for equal recognition accuracy is less than the existing statistical features and decision tree-based methods, and both the performance and amount of neural networks parameters used for classification are better than those of the benchmark network.

Key words composite modulation; blind recognition; unified carrier scheme; frequency-domain data; compressed sensing; lightweight neural network

为应对空间测控通信对频谱利用率和安全可靠通信的高要求, 现代测控通信系统的信号体制多采用复合调制 (Composite Modulation, CM) 方式。根据空间数据系统咨询委员会 (Consultive Committee

for Space Data Systems, CCSDS) 建议^[1], 常用复合调制信号包括统一载波体制和扩频通信体制。其中统一载波体制应用最为广泛, 它首先将基带信号码元进行脉冲编码调制 (Pulse Code Modulation,

收稿日期: 2023-04-06; 修回日期: 2023-10-23

基金项目: 四川省自然科学基金面上项目 (2022NSFC0545)

作者简介: 何羚, 副教授, 主要从事空间信息获取与处理方面的研究。

*通信作者 E-mail: yanxiao@uestc.edu.cn

PCM), 再调制到不同频率的副载波上——称为内调制, 内调制的副载波常采用多进制相移键控 (Multi-Phase Shift Keying, MPSK) 方式; 然后将多个可能的副载波调制到统一的主载波上——称为外调制, 外调制的主载波采用频率调制 (Frequency Modulation, FM) 或相位调制 (Phase Modulation, PM) 方式。相较于单一调制的通信信号, 这种“脉冲编码/多副载波内调制/外调制”形式的复杂体制无疑增加了信号认知难度, 在无先验信息的非合作通信及低信噪比条件下尤为困难。

对信号进行认知的基本思路包括基于最大似然假设^[2]的方法、基于特征提取和模式识别的方法。前者基于严格的数学推导, 通过求解概率密度函数的未知数来获得理论上的最优性能, 但该方法需要充分的先验信息, 且当未知变量较多时计算复杂度较高, 工程实现困难^[3]; 后者通过提取信号的特征并构造特征集, 然后选取特定的分类器来实现模式识别, 该方法不依赖于先验知识, 在一定信噪比条件下对非合作通信信号的识别性能较好。因此, 本文主要基于特征提取和模式识别的思路来讨论复合调制信号盲识别问题。

借鉴单一调制类型识别的常用特征, 瞬时幅度^[4]、谱线特征^[5]、高阶累积量 (Higher-Order Cumulant, HOC)^[6]、循环谱等也常被用作复合调制信号的特征并基于此完成分类。文献 [7] 给出了一种基于信号瞬时幅度、谱线特征、频谱特征及信号信息分量的识别方法, 研究了决策树、支持向量机 (Support Vector Machine, SVM)、反向传播 (Back-Propagation, BP) 神经网络和向量匹配 4 种分类器, 结果显示当信噪比高于 5 dB 时, 采用决策树分类器的正确识别率可达 97.31%。文献 [8] 基于瞬时直方图特征和循环谱分别构造特征量, 区分了外调制为 PM 和 FM 的信号; 指出在低信噪比条件下, 基于循环谱的识别方法效果更佳。文献 [9] 基于四阶 HOC 和平方谱特征, 采用决策树分类器完成了 PCM/MPSK/PM 信号的调制识别, 结果显示在信噪比 2 dB 时对各类 CM 信号的正确识别率均达到 95% 以上。上述方法的识别效果一方面依赖于所构造的 CM 信号特征集是否具有唯一性和完备性; 与此同时, 因候选 CM 特征通常涉及统计特性, 故而不可避免地要对信号样本量有较高要求。

另外在测控通信应用中, 为提高电磁兼容性和增加遥测距离, 常将多个子载波一并调制到主载波上实现联合传输。在这种 CM 策略下, 由于内调制

信号包括多路用户数据, 每路的调制方式可能不同, 因此不得不采取所谓的间接识别方法: 先进行外调制识别, 经解调^[10]、提取信号瞬时相位或瞬时频率, 得到内调制信号, 再进行内调制方式识别。文献 [11] 提出一种基于双重锁相环的 CM 识别方法, 用第一个锁相环解调基带信息, 并利用解调信息的相位分布来区分 MPSK 和 MPSK/FM 信号; 用第二个锁相环解调 MPSK/FM 内调制, 并基于 MPSK 信号的相位积累分布进一步区分二进制相移键控 (Binary Phase Shift Keying, BPSK) /FM 和正交相移键控 (Quadrature Phase Shift Keying, QPSK) /FM。文献 [12] 为了获取内调制信号, 对外调制为 PM 和 FM 的 CM 信号分别提取瞬时相位和瞬时频率, 并计算相应的特征参数完成识别。

总体上, 现有基于特征提取和模式识别的复合调制盲识别方法对 CM 信号特征、样本数很敏感, 且在多子载波情况下识别流程繁琐, 不利于实际应用。针对这些问题, 本文研究建立了脉冲编码调制 (PCM) /相移键控 (PSK) /相位调制 (PM)、脉冲编码调制 (PCM) /相移键控 (PSK) /频率调制 (FM) 两大类 CM 信号模型, 以其频域数据为特征并通过压缩感知进行特征降维, 同时构建了一个基于倒残差结构和分组卷积思想的轻量化神经网络, 由此实现对压缩数据的训练和分类识别。

1 复合调制信号模型

根据 CCSDS 建议^[1], 本文研究以下 10 种复合调制信号: PCM/BPSK/PM、PCM/BPSK/FM、PCM/QPSK/PM、PCM/QPSK/FM、PCM/BPSK1+BPSK2/PM、PCM/BPSK1+BPSK2/FM、PCM/QPSK1+QPSK2/PM、PCM/QPSK1+QPSK2/FM、PCM/QPSK+BPSK/PM、PCM/QPSK+BPSK/FM。这些 CM 信号的时域数学模型推导如下。

设 $a_i(t)$ 和 $b_i(t)$ 为调制在第 i 个子载波上的多用户信息数据流, 均通过非归零 PCM 编码得到, 其表达式为:

$$a_i(t) = \sum_k c_{i,k} g_i(t - kT_i) \quad (1)$$

$$b_i(t) = \sum_k d_{i,k} g_i(t - kT_i) \quad (2)$$

式中, $c_{i,k} \in \{-1, 1\}$; $d_{i,k} \in \{-1, 1\}$; T_i 表示第 i 个子载波的符号周期; $g_i(t)$ 表示脉冲波形, 定义为:

$$g_i(t) = \begin{cases} 1 & 0 \leq t < T_i \\ 0 & \text{其他} \end{cases} \quad (3)$$

设复合调制信号的内调制包含 N 个子载波, 则 PCM/BPSK 或 PCM/QPSK 格式的复合调制信号 $s_i(t)$ ($i \in \{1, 2, \dots, n\}$) 可由下式获得:

$$s_i(t) = a_i(t) \cos(2\pi f_i t + \varphi_{i,0}) - b_i(t) \sin(2\pi f_i t + \varphi_{i,0}) \quad (4)$$

式中, f_i 和 $\varphi_{i,0}$ ($i \in \{1, 2, \dots, N\}$) 分别为第 i 个子载波的频率和初始相位。根据文献 [1], 子载波频率 f_i 为 8 kHz 或 16 kHz; PCM/PSK 的符号率 R_s 在 [7.8125, 4 000] sps 范围内, 子载波频率应为相应符号率的整数倍; 对于 PCM/BPSK 调制, 有 $b_i(t) = 0$ 。

由 N 个子载波组成的通带传输的 PCM/PSK/PM 信号 $S_{\text{PCM/PSK/PM}}(t)$ 可表示为^[13]:

$$S_{\text{PCM/PSK/PM}}(t) = A_p \cos \left[2\pi f_p t + K_p \sum_{i=1}^N s_i(t) + \Phi_0 \right] \quad (5)$$

式中, A_p 、 f_p 、 Φ_0 分别表示外层 PM 调制信号的幅度、载波频率和初始载波相位; K_p 为相位调制指数, 正常范围为 $0.2 \leq K_p \leq 1.4$ ^[1]。对每个内调制信号 $s_i(t)$, 子载波波形与其承载的数据流在过零点处同步, 因而有 $\varphi_{i,0} = 0$ ($i \in \{1, 2, \dots, N\}$)。

因此, 传输的 PCM/PSK/PM 信号 $S_{\text{PCM/PSK/PM}}(t)$ 可重写为:

$$S_{\text{PCM/PSK/PM}}(t) = \text{Re} \left\{ x_B^P(t) \exp[j2\pi f_p t + \Phi_0] \right\} \quad (6)$$

式中, $\text{Re}\{\}$ 表示对括号内的复数取实部; $x_B^P(t)$ 表示由 $s_i(t)$ 所给出的等价复基带信号, 有:

$$x_B^P(t) = A_p \exp \left[jK_p \sum_{i=1}^N s_i(t) \right] = x_I^P(t) + jx_Q^P(t) \quad (7)$$

其中实部和虚部分别为:

$$x_I^P(t) = A_p \cos \left[K_p \sum_{i=1}^N s_i(t) \right] \quad (8)$$

$$x_Q^P(t) = A_p \sin \left[K_p \sum_{i=1}^N s_i(t) \right] \quad (9)$$

类似地, 由 N 个子载波组成的通带传输的 PCM/PSK/FM 信号 $S_{\text{PCM/PSK/FM}}(t)$ 可表示为:

$$S_{\text{PCM/PSK/FM}}(t) = A_f \cos \left[2\pi f_f t + K_f \int_0^t \sum_{i=1}^N s_i(\tau) d\tau + \Phi_0 \right] \quad (10)$$

式中, A_f 、 f_f 、 Φ_0 分别为外层 FM 调制信号的幅度、载波频率和初始相位; K_f 为频率调制指数, 其正常范围为 $0.2 \leq K_f \leq 1.4$ ^[1]。

传输的 PCM/PSK/FM 信号 $S_{\text{PCM/PSK/PM}}(t)$ 可重新表示为:

$$S_{\text{PCM/PSK/FM}}(t) = \text{Re} \left\{ x_B^F(t) \exp[j2\pi f_f t + \Phi_0] \right\} \quad (11)$$

式中, $\text{Re}\{\}$ 表示取实部; 等价复基带信号 $x_B^F(t)$ 为:

$$x_B^F(t) = A_f \exp \left[jK_f \sum_{i=1}^N s_i(t) \right] = x_I^F(t) + jx_Q^F(t) \quad (12)$$

其中实部和虚部分别为:

$$x_I^F(t) = A_f \cos \left[K_f \int_0^t \sum_{i=1}^N s_i(\tau) d\tau \right] \quad (13)$$

$$x_Q^F(t) = A_f \sin \left[K_f \int_0^t \sum_{i=1}^N s_i(\tau) d\tau \right] \quad (14)$$

更进一步地, 用加性高斯白噪声 (Additive White Gaussian Noise, AWGN) 信道模拟存在多普勒频移和相位噪声的情况, 则接收到的 CM 信号可表示为:

$$r(t) = \begin{cases} \text{Re} \{ \tilde{x}_B^P(t) \exp[j\phi_d + \phi_p] + n(t) \} & \text{PCM/PSK/PM} \\ \text{Re} \{ \tilde{x}_B^F(t) \exp[j\phi_d + \phi_p] + n(t) \} & \text{PCM/PSK/FM} \end{cases} = \begin{cases} \text{Re} \{ A_p \exp[jK_p \sum_{i=1}^n s_i(t) + \phi_p] + n(t) \} & \text{PCM/PSK/PM} \\ \text{Re} \{ A_f \exp[jK_f \int_0^t \sum_{i=1}^n s_i(\tau) d\tau + \phi_d] + \phi_p + n(t) \} & \text{PCM/PSK/FM} \end{cases} \quad (15)$$

式中, ϕ_d 表示与多普勒相关的载波相位; ϕ_p 表示传输信道中的相位噪声; 其初始相位为 ϕ_0 ; $n(t)$ 表示均值和方差为零的 AWGN; $\tilde{x}_B(t)$ 表示存在多普勒频偏的复基带信号。

2 频域数据压缩感知模型

压缩感知 (Compressed Sensing, CS) 是一种信号处理与信号恢复的方法^[14-15], 它在特定条件下允许将信号线性投影到比原始信号维度小得多的空间上, 且能由投影信号精确恢复出原始信号^[16], 实现数据的压缩。针对复合调制信号盲识别问题, 如直接用 CM 信号样本的原始频域数据作为神经网络的输入, 会导致输入层神经元过多, 整个网络的参数量过大。考虑到实际工程中原始频域信息存在冗余, 即频谱很可能存在稀疏特性, 本文借鉴压缩感知理论中的测量矩阵, 对复合调制信号的原始频域数据进行降维处理。

2.1 测量矩阵

测量矩阵的设计是压缩感知的关键, 适宜的测量矩阵可确保在将原始高维空间信号通过变换 Φ 投影到低维空间的同时, 尽量保留原始信号所含的特征信息。假定原始信号为 $\mathbf{x} \in \mathbb{R}^{q \times 1}$ (q 为原始数据长度), 将其与变换矩阵 $\Phi \in \mathbb{R}^{n \times q}$ 相乘后得到长度为 n 的压缩信号, 则设计测量矩阵就是找到 1 个变换基 Φ 和非相干矩阵 $\Psi \in \mathbb{R}^{m \times n}$, 通过原始信号的低维投影 $\mathbf{X} \in \mathbb{R}^{n \times 1}$ 来获得压缩信号 $\mathbf{y} \in \mathbb{R}^{m \times 1}$ ^[17]。上述测量过程可表示为:

$$\mathbf{y} = \Psi \mathbf{X} = \Psi \Phi \mathbf{x} = \mathbf{A} \mathbf{x} \quad (16)$$

式中, $\mathbf{A} \in \mathbb{R}^{m \times q}$, 即为 $m \times q$ 维测量矩阵, 有 $\mathbf{A} = \Psi \Phi$ 。

测量矩阵应该满足约束等距特性 (Restricted Isometry Property, RIP) 条件^[18-19]。RIP 条件表述如下: 存在常数 $\varepsilon_k \in (0, 1)$, 当对任意稀疏度为 k 、长度为 q 的稀疏向量, 均可使 $\mathbf{A} = \Psi \Phi$ 满足下式时, 矩阵 \mathbf{A} 满足 RIP 条件:

$$1 - \varepsilon_k \leq \frac{\|\mathbf{A}\mathbf{x}\|_2^2}{\|\mathbf{x}\|_2^2} \leq 1 + \varepsilon_k \quad (17)$$

式中, $\mathbf{x} \in \mathbb{R}^{q \times 1}$ 为稀疏信号; $\|\mathbf{x}\|_2$ 表示 \mathbf{x} 的欧几里得范数; k 表示稀疏系数。

事实上对于矩阵方程 $\mathbf{y} = \mathbf{A}\mathbf{x}$, 直接判定其是否满足式 (17) 并非易事, 因此, 文献 [19] 提出了等价于式 (17) 的非相关性原理, 只要 Φ 和 Ψ 之间满足不相关性, 即可在很大程度上满足 RIP 条件。测量矩阵的相关性可表示为:

$$\Gamma(\mathbf{A}) = \max_{u \neq v} \frac{|\mathbf{a}_u^T \mathbf{a}_v|}{\|\mathbf{a}_u\| \|\mathbf{a}_v\|} \quad (18)$$

式中, \mathbf{a}_u ($u \in \{1, 2, \dots, m\}$)、 \mathbf{a}_v ($v \in \{1, 2, \dots, q\}$) 分别表示矩阵 \mathbf{A} 的行向量和列向量。

$\Gamma(\mathbf{A})$ 的大小决定了测量矩阵的相关性: $\Gamma(\mathbf{A})$ 越小, 说明矩阵 \mathbf{A} 中各列的相关性越低, 亦即矩阵 \mathbf{A} 越能满足 RIP 条件。

可用的测量矩阵有随机高斯测量矩阵、随机伯努利测量矩阵、部分哈达玛测量矩阵和部分正交测量矩阵等。本文选用高度不相关的 $m \times q$ 维随机高斯测量矩阵 \mathbf{A} , 其中每个元素 $a_{u,v}$ 都独立地服从均值为 0、方差为 $1/m$ 的高斯分布, 即:

$$a_{u,v} \sim N\left(0, \frac{1}{m}\right) \quad (19)$$

当该矩阵的测量数满足 $m \geq ck \log(q/k)$ 时 (其中 c 为很小的常数, k 为稀疏度), 便会以极大的概率

满足 RIP 条件。

2.2 矩阵压缩

利用测量矩阵对频域数据进行降维, 选定随机高斯测量矩阵 $\mathbf{A} \in \mathbb{R}^{64 \times 1024}$, 其中每个元素 $a_{u,v}$ 在 $p=1/2$ 时, 均满足如下定义:

$$a_{u,v} = 1 \text{ 或 } -1 \quad (20)$$

且满足独立同分布:

$$a_{u,v} \sim N\left(0, \frac{1}{64}\right) \quad (21)$$

利用上述 64×1024 维随机高斯测量矩阵 \mathbf{A} 并根据式 $\mathbf{y} = \mathbf{A}\mathbf{x}$, 可将原始维度为 1024×1 的复合调制信号的频域数据 $\mathbf{x} \in \mathbb{R}^{1024 \times 1}$ 压缩为维度为 64×1 的数据 $\mathbf{y} \in \mathbb{R}^{64 \times 1}$ 。将 \mathbf{y} 转置为 1×64 的特征向量, 以此作为后续模式识别的输入。

3 基于倒残差分组卷积的轻量化网络模型

受算力和性能限制, 传统的重量级深度神经网络如 ResNet^[20] 等难以在小型或便携式计算设备上成功部署。从智能算法推广应用角度, 有必要进行轻量化神经网络设计。本文基于倒残差结构和分组卷积思想, 构造了一种倒残差分组卷积的轻量化网络模型 G-ConvNet, 其整体结构如图 1 所示。

由图 1 可知, G-ConvNet 在输入层之后首先设置了 1 个特征提取模块 (E-Unit), 然后是倒残差分组卷积模块 (Inverted residual G-Unit), 最后由分类模块 (C-Unit) 实现分类。

3.1 特征提取模块 (E-unit)

特征提取模块 (E-unit) 的第一层为普通二维卷积层 (conv1), 卷积核大小为 1×3 , 步长为 2。该层用于提取压缩感知所得的 1×64 一维特征向量的浅层特征, 同时将原始长度从 64 降为 32。

为了使卷积层在训练时更稳定和加快训练速度, 卷积层之后加入 1 个 BatchNorm (BN) 层。BN 层将卷积层的输出分为多个 mini-batch 分别进行归一化, 以降低网络对初值的敏感性, 并可在一定程度上抑制过拟合。对任意 1 个 mini-batch 数据 $B = \{b_1, b_2, \dots, b_L\}$ (L 为该 mini-batch 中的数据个数), 相应的输出 z_l 可经由以下过程得到^[21]。

首先求 mini-batch 中数据的均值 μ 和均方差 σ^2 :

$$\mu = \frac{1}{L} \sum_{l=1}^L b_l \quad (22)$$

$$\sigma^2 = \frac{1}{L} \sum_{l=1}^L (b_l - \mu)^2 \quad (23)$$

然后对 mini-batch 的输入数据进行归一化处理:

$$\hat{b}_l = \frac{b_l - \mu}{\sqrt{\sigma^2 + \varepsilon}} \quad (24)$$

式中, ε 为保证均方差稳定性的常数, 通常取 $\varepsilon = 10^{-5}$ 。

最后对归一化数据进行平移和尺度变换, 得到输出 z_l :

$$z_l = \gamma \hat{b}_l + \beta \quad (25)$$

式中, γ, β 分别表示尺度因子和偏置值, 均为网络的超参数, 可通过训练优化得到。

BN 层之后是非线性激活函数 relu6 。与 ResNet 模型中采用的 relu 函数相比, relu6 的取值范围被限制在 (0,6) 范围内, 适于小型或便携式终端应用。其定义如下:

$$f(z_l) = \begin{cases} 6 & z_l \geq 0 \\ z_l & 0 \leq z_l < 6 \\ 0 & z_l < 0 \end{cases} \quad (26)$$

经过 E-Unit 之后, 输入矩阵的维度由 1×64 变为 1×32 。

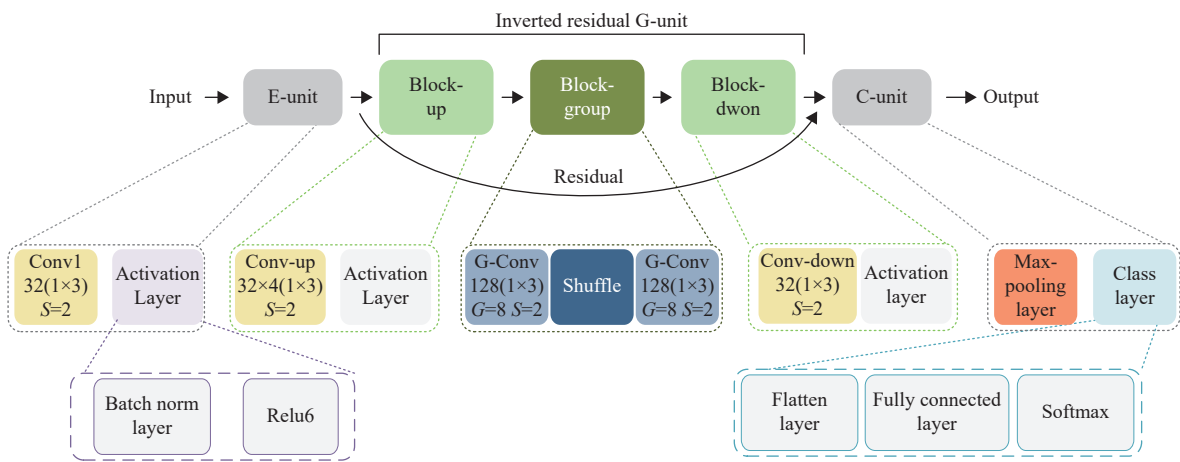


图 1 G-ConvNet 网络的整体结构

3.2 倒残差分组卷积模块 (Inverted Residual G-Unit)

在 ResNet 提出的 Residuals 结构中, 先使用卷积对输入层进行降维, 然后经过若干中间隐层提取特征, 最后再通过卷积实现输出层升维, 网络模型整体呈现两头大、中间小的形态。本文构建的 G-ConvNet 网络的 Inverted residual 部分则是一种倒置的残差结构: 先使用 1×1 卷积进行升维, 以期将低维空间映射到高维空间, 为之后的分组卷积提供更多信息; 然后进行 2 次 1×3 分组卷积和 1 次 shuffle 操作, 最后通过 1×1 卷积实现降维, 整体呈现出两头小、中间大的形态。分组卷积的结构如图 2 所示。图中, g 为分组数; H, W 分别代表输入特征层和输出特征层的高度和宽度; c_1, c_2 分别为输入特征层和输出特征层通道维数。通过 c_1 进行 g 个分组, 将卷积滤波器的尺寸从 $c_1 \times H \times W$ 减少为 $(c_2 \times H \times W) / g$, 只要选择适宜的 g 值, 即可降低卷积的计算复杂度和参数量; g 越大, 参数量降低越明显, 逐层分组卷积还可进一步减少参数, 从而达到网络轻量化目

的。考虑到对于一定的输入特征层参数集 $\{c_1, H, W\}$, g 的增加虽然能降低每秒浮点运算次数 (Floating-Point Operations Per Second, FLOPs), 但同时会导致内存访问量需求加剧, 即分组数不能无限增大^[22]。经权衡, 本文将 g 取值为 8。

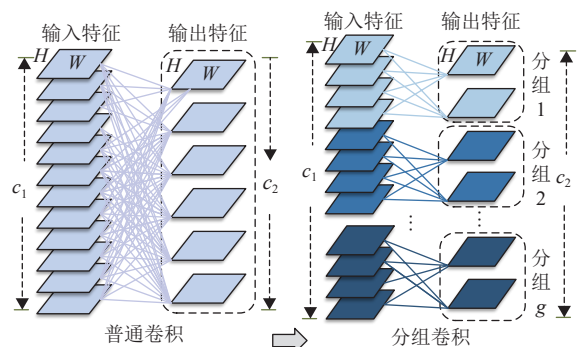


图 2 分组卷积结构

分组卷积的数据信息只在本组内, 各通道之间没有交互, 会产生类似于近亲繁殖现象而使分类器精度下降。因此在分组卷积层后加入通道重排 (shuffle) 层, 通过 shuffle 操作将不同分组的通道

进行信息交互, 如图 3 所示。




图 3 shuffle 操作

Shuffle 层之后是 BN 层和 relu6 层, 与 E-unit 相同, 不再赘述。

3.3 分类模块 (C-unit)

倒残差分组卷积模块对输入数据的维度不做改变。通过 1 个最大池化 (max pooling) 层, 将特征降维为 1×16 ; 然后通过 1 个 Flatten 层, 将最大池化层的输出压缩为一维特征, 为输入到全连接 (Fully Connected, FC) 层做准备。FC 层之后, 用 softmax 函数作为最后的输出层, 其定义如下:

$$F_{\text{softmax}} = \text{softmax}(F_{\text{fc}}) = \frac{\exp(F_{\text{fc}})}{\sum \exp(F_{\text{fc}})} \quad (27)$$

式中, F_{fc} 为 FC 层的输出。

4 复合调制信号盲识别试验

4.1 数据集获取

本文研究的 10 种 CM 信号分属于 PCM/PSK/PM 和 PCM/PSK/FM 两大类。按照第一部分所述的数学模型产生时域信号, 经采样和离散傅氏变换 (Discrete Fourier Transform, DFT) 得到频域数据。仿真参数设置如表 1 所示。

表 1 CM 信号仿真参数表

参数	设置值
主载波频率/GHz	2.2
中频/MHz	70
子载波 1 频率/kHz	8
子载波 2 频率/kHz	16
符号率/kbps	4
采样率/Msps	200
衰落因子	0.35
传输信道	AWGN
信噪比范围/dB	-20~20

在不同信噪比下, 取每种 CM 信号的频域数据

各 300 条, 每条原始频域数据长度为 1 024 点。按照数据条数 2:1 的比例划分为训练集和测试集。

4.2 试验环境搭建

对上述复合调制信号频域数据集进行压缩感知变换, 将每条长 1 024 点的原始频域数据压缩为长度为 64 的压缩数据, 然后使用本文所提的 G-ConvNet 网络模型对压缩数据进行训练和测试。

试验平台搭建在 Window11 操作系统中, G-ConvNet 网络代码实现使用 Python 3.10。相关环境配置情况如下: CPU 为 AMD Ryzen 7 5800H with Radeon Graphics; GPU 为 NVIDIA GeForce RTX3060 Laptop GPU; 神经网络训练框架为 Pytorch 1.21.1; 网络优化器为 Adam。学习率固定设为 0.000 1, batch-size 设为 16, 训练回合数设为 100。

G-ConvNet 网络各层的输入输出尺寸见表 2。

表 2 G-ConvNet 各层输入输出一览

层名称	输入尺寸	输出尺寸
E-unit	1×64	1×32
conv-up	1×32	1×128
G-conv	1×128	1×128
conv-down	1×128	1×32
max pooling	1×32	1×16
FC	1×16	$1 \times \text{分类数} L$

4.3 试验结果分析

按照本文第一部分所述信号模型, 仿真产生 10 种复合调制信号, 采用本文“压缩感知+倒残差分组卷积轻量化网络” (CS+G-ConvNet) 复合调制信号盲识别方法, 所得的正确识别率曲线如图 4 所示; 在信噪比分别为 -5、0、5 dB 时的混淆矩阵如图 5 所示。

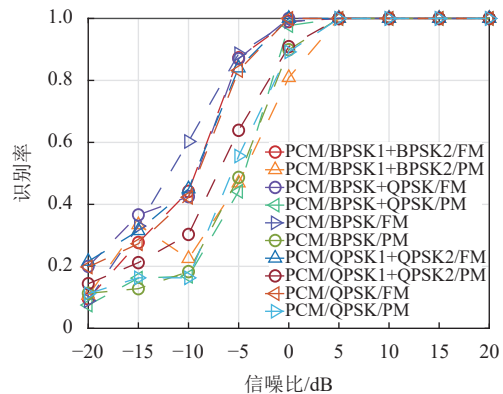



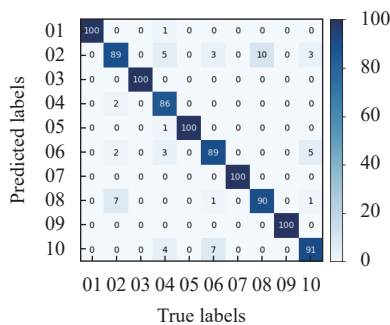
图 4 本文方法对 10 种 CM 信号的识别率

在 AWGN 信道下, 本文方法与文献 [23] 所提


方法的仿真结果对比如图 6 所示。由图 6 可知, 文献 [23] 所提“基于 HOC 和平方谱特征+决策树”的 CM 识别方法有一个明显缺陷: 因其提取的是统计特征, 识别结果的正确率很大程度上依赖于 CM 信号的样本数量, 一旦样本长度减小, 识别性能将急剧下降, 如图中以“existing-样本数”表示的曲线。相较之下, 本文方法在压缩感知所得样本本长度为 64 时, 0 dB 信噪比条件下的识别率可达 94.5%, 5 dB 信噪比条件下识别率为 100%, 如图中以“CS+G-ConvNet”表示的曲线。



a. 信噪比=-5 dB



b. 信噪比=0 dB



c. 信噪比=5 dB

01 为 PCM/BPSK/FM; 02 为 PCM/BPSK/PM;
 03 为 PCM/BPSK1+BPSK2/FM; 04 为 PCM/BPSK1+BPSK2/PM;
 05 为 PCM/QPSK+BPSK/FM; 06 为 PCM/QPSK+BPSK/PM;
 07 为 PCM/QPSK/FM; 08 为 PCM/QPSK/PM;
 09 为 PCM/QPSK1+QPSK2/PM; 10 为 PCM/QPSK1+QPSK2/FM

图 5 本文方法在不同信噪比条件下的混淆矩阵

此外, 为验证本文所提基于倒残差分组卷积

的轻量化网络 (G-ConvNet) 的有效性, 选择 ResNet50^[20]、ShuffleNetV2^[22]、MobileNetV2^[24] 这 3 种基准网络与 G-ConvNet 进行对比。各网络对于本文建模产生的 10 种复合调制信号的平均识别率如图 7 所示。




图 6 不同方法在不同信噪比条件下的 CM 识别率对比

对比可知, 对于长度为 64 的一维特征输入, 本文构建的 G-ConvNet 网络在信噪比为 0 dB 时的识别率达到 94.5%; 而 MobileNetV2 的识别率仅为 67.4%, ShuffleNetV2 的识别率为 76.4%, ResNet50 的识别率为 80.1%。可见对于低维特征, 神经网络更易出现梯度消失问题以致影响分类正确率, 故而采用 ResNet50 等深层网络的 CM 信号识别效果不及本文所提的层数较少的轻量化网络。




图 7 4 种网络的 CM 信号识别率对比

表 3 进一步给出了现有方法与本文方法在参数量、FLOPs 和计算时间 3 个方面的对比。表中, “existing-样本数” 为文献 [23] 所提方法, 因其未采用网络模型, 故只能给出等比条件下的整体计算时间。由表 3 可知, 本文提出的“CS+G-ConvNet”

方法的计算复杂度低于现有其他方法。

表 3 各方法的计算复杂度对比 (分类总数=10)

方法名称	参数量	FLOPs	计算时间/ms
existing-1 024	\	\	4.6
existing-200 000	\	\	108.9
CS+ResNet50	23.52×10^6	73.61×10^6	11.1
CS+ShuffleNetV2	1.26×10^6	3.39×10^6	9.2
CS+MobileNetV2	2.24×10^6	6.17×10^6	8.2
CS+G-ConvNet	0.034×10^6	1.54×10^6	4.2

5 结束语

本文研究了 PCM/BPSK/PM、PCM/BPSK/FM、PCM/QPSK/PM、PCM/QPSK/FM、PCM/BPSK1+BPSK2/PM、PCM/BPSK1+BPSK2/FM、PCM/QPSK1+QPSK2/PM、PCM/QPSK1+QPSK2/FM、PCM/QPSK+BPSK/PM、PCM/QPSK+BPSK/FM 共 10 种复合调制信号的时域表示模型,以它们的频域数据为复合调制特征,通过压缩感知进行特征向量降维,然后构建了一个基于倒残差结构和分组卷积思想的轻量化神经网络,最终实现了压缩频域数据的分类识别。试验结果显示,上述“压缩感知+轻量化神经网络”的 CM 盲识别方法在较低信噪比时可获得优良的识别率,且在同比条件下具有优于相关文献方法和基准网络的识别效果。但面向实际应用,仍有一些关键问题待深入研究,如根据实测测控通信频段的频谱稀疏性讨论本文所提方法的普适性;以及遵从 CCSDS 建议,进一步对扩频体制的 CM 信号进行盲识别研究等。

参考文献

- [1] Radio frequency and modulation systems - part 1. Earth stations and spacecraft[M]. Washington D. C.: Consultative Committee for Space Data Systems (CCSDS), 2019.
- [2] AMIRI ARA H, ZAHABI M R, EBRAHIMZADEH A. Blind digital modulation identification using an efficient method-of-moments estimator[J]. Wireless Personal Communications, 2021, 116: 301-310.
- [3] 司海飞, 胡兴柳, 史震, 等. 基于联合特征参数提取的非合作信号调制识别算法[J]. 通信学报, 2020, 41(7): 172-185. SI H F, HU X L, SHI Z, et al. Non-cooperative signal modulation recognition algorithm based on joint feature parameter extraction[J]. Journal on Communications, 2020, 41(7): 172-185.
- [4] XIE L, WAN Q. Automatic modulation recognition for phase shift keying signals with compressive measurements [J]. IEEE Wireless Communication Letters, 2018, 7(2): 194-197.
- [5] HUYNH-THE T, HUA C H, DOAN V S, et al. Deep learning for constellation-based modulation classification under multipath fading channels[C]//2020 International Conference on Information and Communication Technology Convergence (ICTC). Jeju: IEEE, 2020: 300-304.
- [6] LIU Y, YANG C. Modulation recognition with graph convolutional network[J]. IEEE Wireless Communications Letters, 2020, 9(5): 624-627.
- [7] 王世剑. 测控系统中复合调制信号的识别与参数估计[D]. 哈尔滨: 哈尔滨工程大学, 2019. WANG S J. Recognition and parameter estimation of hybrid modulation signal in TT&C[D]. Harbin: Harbin Engineering University, 2019.
- [8] 聂瑾. 基于复合调制特征的遥测信号调制识别方法研究[D]. 成都: 电子科技大学, 2021. NIE J. Research on modulation recognition method of telemetry signal based on composite modulation characteristics[D]. Chengdu: University of Electronic Science and Technology of China, 2021.
- [9] 许琦敏. 复合调制信号的识别与处理研究[D]. 成都: 电子科技大学, 2022. XU Q M. Research on recognition and processing of composite modulation signals[D]. Chengdu: University of Electronic Science and Technology of China, 2022.
- [10] CHU P, XIE L, DAI C, et al. Automatic modulation recognition for secondary modulated signals[J]. IEEE Wireless Communications Letters, 2021, 10(5): 962-965.
- [11] WANG L, HAN Y, ZHOU P, et al. Modulation recognition of composite modulation signal based on two-fold digital receiver and goodness of fit test[C]//2021 IEEE International Conference on Electronic Technology, Communication and Information (ICETCI). Changchun: IEEE, 2021: 433-437.
- [12] 王利全. 数传信号的调制识别与参数估计[D]. 成都: 电子科技大学, 2020. WANG L Q. Modulation recognition and parameter estimation of signals for data communication[D]. Chengdu: University of Electronic Science and Technology of China, 2020.
- [13] VILÀ-VALLS J, NAVARRO M, CLOSAS P, et al. Synchronization challenges in deep space communications [J]. IEEE Aerospace and Electronic Systems Magazine, 2019, 34(1): 16-27.
- [14] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- [15] CANDÈS E J, WAKIN M. B. An introduction to compressive sampling[J]. IEEE Signal Processing Magazine, 2008, 25(2): 21-30.
- [16] 魏子然. 基于压缩感知的信号重建技术及其成像系统的研究[D]. 成都: 电子科技大学, 2021. WEI Z R. Research on signal reconstruction technology and imaging system based on compressed sensing[D]. Chengdu: University of Electronic Science and

- Technology of China, 2021.
- [17] 蒋烈勤. 基于惯性神经网络的压缩感知信号重构[D]. 重庆: 西南大学, 2022.
- JIANG L Q. Reconstruction of compressed sensing signal based on inertial neural network[D]. Chongqing: Southwest University, 2022.
- [18] SAHOO S K, MAKUR A. Signal recovery from random measurements via extended orthogonal matching pursuit[J]. IEEE Transactions on Signal Processing, 2015, 63(10): 2572-2581.
- [19] CANDES E, ROMBERG J. Sparsity and incoherence in compressive sampling[EB/OL]. (2006-11-30). <https://www.arxiv.org/abs/math/0611957>.
- [20] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 770-778.
- [21] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[EB/OL]. [2023-01-13]. <https://arxiv.org/pdf/1502.03167.pdf>.
- [22] MA N, ZHANG X, ZHENG H T, et al. ShuffleNet V2: Practical guidelines for efficient CNN architecture design [EB/OL]. [2023-03-30]. <https://arxiv.org/abs/1807.11164>.
- [23] 许琦敏, 万峻, 何羚, 等. 基于高阶累积量和信号平方谱特征的复合调制信号盲识别[J]. 电子学报, 2022, 50(2): 426-431.
- XU Q M, WAN J, HE L, et al. Blind recognition for hybrid modulation signals based on high-order cumulant and squared spectrum feature[J]. Acta Electronica Sinica, 2022, 50(2): 426-431.
- [24] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 4510-4520.

编辑 税红