

# 基于多模态特征融合网络的空时分组码识别算法

张聿远, 闫文君, 张立民

(海军航空大学信息融合研究所, 山东烟台 264001)

**摘要:** 针对现有算法在空时分组码(Space-Time Block Code, STBC)识别过程中存在的低信噪比下误判率高、识别效率低等问题, 本文提出了一种基于多模态特征融合网络(Multi-Modality Features Fusion Network, MMFFN)的空时分组码自动识别方法. 首先, 在合并卷积层将STBC时域样本映射为一维特征向量的基础上, 采用多扩张率下的扩张卷积提取非连续时间窗的STBC码内特征, 实现多时延特征自提取; 然后, 构建多时序特征自提取模块以提取码间时序特征, 进一步扩展映射特征类型; 最后, 将多时延拼接层获取的最大时延特征作为深层融合特征, 并增加了带跨越连接的残差层以提升融合特征利用率, 实现空时分组码识别. 仿真实验结果表明, 本文算法在-9dB下对6类STBC信号的识别准确率达到了90%以上, 较现有识别算法的性能获得了显著提升, 对低信噪比有较强的适应性. 本文提出的STBC多时延特征提取和融合方法, 为结合传统算法设计深度学习网络结构提供了新思路, 其思想同样可应用于其他通信信号识别领域.

**关键词:** 空时分组码; 深度学习; 扩张卷积; 多时延特征; 多时序特征; 最大时延融合

**基金项目:** 国家自然科学基金重大研究计划(No.91538201); 泰山学者工程专项经费(No.Ts201511020)

**中图分类号:** TN911.7 **文献标识码:** A **文章编号:** 0372-2112(2023)02-0489-10

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20210326

## Space-Time Block Code Recognition Algorithm Based on Multi-Modality Features Fusion Network

ZHANG Yu-yuan, YAN Wen-jun, ZHANG Li-min

(Department of Information Fusion, Naval Astronautical University, Yantai, Shandong 264001, China)

**Abstract:** Aiming at the problems of the existing algorithms in the process of space-time block code (STBC) recognition, such as high misdiagnosis probability and low recognition efficiency under low signal to noise ratio (SNR), this paper proposes an automatic space-time block code recognition method based on multi-modality feature fusion network (MMFFN). Firstly, on the basis of mapping STBC time-domain samples into one-dimensional feature vectors by merging convolution layers, the dilated convolution at multiple dilation rates is used to extract STBC code features from discontinuous time windows, and the self-extraction of multi-delay features is realized. Then, the multi-sequence feature self-extraction module is constructed to extract the inter-code sequence feature, and the mapping feature types are further extended. Finally, the maximum delay feature of the multi-delay mosaic layer is extracted as the deep fusion feature, and the residual layer with span connection is added to improve the utilization of fusion feature and realize space-time block code recognition. Simulation results show that the recognition accuracy of the proposed algorithm for 6 types of STBC signals reaches more than 90% under -9dB, which is significantly improved compared with the performance of existing recognition algorithms, and has a strong adaptability to low SNR. The STBC multi-delay feature extraction and fusion method proposed in this paper provides a new idea for the design of deep learning network structure by combining traditional algorithms, and the idea can also be applied to other communication signal recognition fields.

**Key words:** space-time block code; deep learning; dilated convolution; multi-delay features; multi-sequential features; maximum delay fusion

**Foundation Item(s):** National Natural Science Foundation of China (No.91538201); Taishan Scholar Special Foundation (No.Ts201511020)

## 1 引言

空时分组码(Space-Time Block Code, STBC)识别在频谱管理、通信侦查和电磁对抗等军事通信领域具有重要作用,是通信信号识别领域的一个重要研究课题<sup>[1]</sup>.近年来,电磁环境与信息化技术日益密集化、复杂化,传统基于特征提取与阈值决策的STBC识别方法,已不能满足实际通信环境中精准快速识别的现实需求.依据STBC自身编码方式差异,传统算法获取能够反映信号本质信息的统计特征,如循环统计特征<sup>[2]</sup>、高阶统计特征<sup>[3-6]</sup>和虚拟信道相关矩阵特征<sup>[7]</sup>等,但需要人为提取特征和设置检验阈值,存在调参过程复杂,对噪声较敏感等问题.因此,如何在信号衰减较大的低信噪比条件下识别空时分组码具有重要意义.

近年来,伴随着深度学习技术在计算机视觉(Computer Vision, CV)领域的快速发展,得益于GPU并行运算能力的提升,深度学习模型以其对海量数据的强大映射能力而获得了更强的分类性能.结合该技术的性能优势,国内外学者逐步将其应用于STBC识别领域<sup>[8-10]</sup>.文献[8]通过借鉴调制识别中已成功应用的卷积神经网络(Convolutional Neural Network, CNN)框架与数据集样式<sup>[11]</sup>,首次将深度学习引入本领域,实现了空间复用(Special Multiplexing, SM)和Alamouti(AL)两类最常用STBC的识别.文献[9]通过计算接收信号的频域自相关函数(Frequency Domain Self-Correlation Function, FDSCF),将预处理后的样本输入CNN进行识别.该方法首次在频域上使用CNN实现STBC识别,但存在低信噪比下识别准确率低、样本处理流程繁琐等问题.文献[10]将长短期记忆(Long Short-Term Memory, LSTM)层引入空时分组码识别,提出了一种直接采用时域I/Q信号作为训练样本,构建卷积-循环神经网络提取空间和时序特征的STBC识别方法,优化了信号样本的处理流程.但该方法仅能识别SM和AL码,识别性能也不够理想.以上深度学习方法<sup>[8-10]</sup>取得了识别性能与效率上的提升,但仅局限于网络的迁移学习和简单深度学习框架的搭建,对模型结构的研究不够深入,并且没有结合STBC自身编码特点优化网络架构.

包括传统算法在内,上述STBC识别算法<sup>[2-10]</sup>只考虑了单一特征,算法特征多样性不足,而实际的通信环境复杂多变,单一的信号特征不足以全面准确地表示STBC编码方式之间的差别,导致在低信噪比下识别性能受限,具有一定的局限性.实际上,在如调制识别<sup>[12-15]</sup>、雷达辐射源识别<sup>[16]</sup>和组群行为识别<sup>[17,18]</sup>等诸多分类识别问题中,特征融合已成为了深度学习模型设计过程采用的一种重要方法,得到了越来越广泛的应用.这些方法<sup>[12-18]</sup>的成功实践说明了在本领域采用多特征融合深度学习模型的可行性.

为解决上述问题,充分结合空时分组码自身编码特性,本文提出了一种基于多模态特征融合网络(Multi-Modality Features Fusion Network, MMFFN)的STBC识别算法.具体而言,该算法首先提取接收信号的实部和虚部组成 $2 \times N$ 维STBC样本,通过合并卷积层将实虚部合并成一维特征向量,利用不同STBC编码矩阵相关性差异,采用多扩张率下的扩张卷积提取非连续时间窗的STBC码内特征,实现多时延特征自提取(Multi-Delay Feature Self-Extraction, MDFSE);然后,在连续采样点卷积核进行深度卷积的基础上,采用LSTM层提取STBC信号的多时间步码间特征,实现多时序特征自提取(Multi-Sequential Feature Self-Extraction, MSFSE),有效地提升了特征多样性和鲁棒性;最后,提出了最大时延特征融合(Maximum Delay Feature Fusion, MDFF)模块,将深层映射特征进行拼接后,提取最大时延特征作为深层融合特征,并引入残差层进一步增强深层融合特征的利用率和表征能力,提升了映射特征的辨识度和稳定性.

## 2 信号模型

考虑 $n_t$ 个发射天线和1个接收天线的空时分组码通信系统.发射端将符号数为 $K$ 的第 $v$ 组发射信号 $\mathbf{s}_v = [s_1, s_2, \dots, s_K]^T$ 编码成 $N_t \times L$ 维的传输矩阵,具体表示为<sup>[9]</sup>

$$\mathbf{G} = [\mathbf{A}_1 \tilde{\mathbf{s}}_v, \mathbf{A}_2 \tilde{\mathbf{s}}_v, \dots, \mathbf{A}_L \tilde{\mathbf{s}}_v] \quad (1)$$

其中, $\mathbf{A}_i (i=1, 2, \dots, L)$ 为 $N_t \times 2K$ 维编码矩阵,由STBC编码方式决定; $\tilde{\mathbf{s}}_v = [\text{Re}(\mathbf{s}_v^T), \text{Im}(\mathbf{s}_v^T)]^T$ 由发射信号 $\mathbf{s}_v$ 的实部和虚部组成.本文选取最常用的空间复用(Special Multiplexing, SM)和Alamouti(AL)码,并增加了两组易混淆的STBC3-1与STBC3-2、STBC3-3与STBC4码,对SM、AL、3种STBC3和STBC4共6类正交空时分组码进行区分,其具体的编码方式为

(1) SM码的发送矩阵为

$$\mathbf{G}^{\text{SM}} = \begin{bmatrix} s_1 \\ s_2 \end{bmatrix} \quad (2)$$

(2) AL码的发送矩阵为

$$\mathbf{G}^{\text{AL}} = \begin{bmatrix} s_1 & -s_2^* \\ s_2 & s_1^* \end{bmatrix} \quad (3)$$

(3) STBC3-1码的发送矩阵为

$$\mathbf{G}^{\text{STBC3-1}} = \begin{bmatrix} s_1 & 0 & s_2 & -s_3 \\ 0 & s_1 & s_3^* & s_2^* \\ -s_2^* & s_3 & s_1^* & 0 \end{bmatrix} \quad (4)$$

(4) STBC3-2码的发送矩阵为

$$\mathbf{G}^{\text{STBC3-2}} = \begin{bmatrix} s_1 & -s_2^* & s_3^* & 0 \\ s_2 & s_1^* & 0 & -s_3^* \\ s_3 & 0 & -s_1^* & s_2^* \end{bmatrix} \quad (5)$$

(5) STBC3-3 码的发送矩阵为

$$\mathbf{G}^{\text{STBC3-3}} = \begin{bmatrix} s_1 & -s_2 & -s_3 & -s_4 & s_1^* & -s_2^* & -s_3^* & -s_4^* \\ s_2 & s_1 & s_4 & -s_3 & s_2^* & s_1^* & s_4^* & -s_3^* \\ s_3 & -s_4 & s_1 & s_2 & s_3^* & -s_4^* & s_1^* & s_2^* \end{bmatrix} \quad (6)$$

(6) STBC4 码的发送矩阵为

$$\mathbf{G}^{\text{STBC4}} = \begin{bmatrix} s_1 & -s_2 & -s_3 & -s_4 & s_1^* & -s_2^* & -s_3^* & -s_4^* \\ s_2 & s_1 & s_4 & -s_3 & s_2^* & s_1^* & s_4^* & -s_3^* \\ s_3 & -s_4 & s_1 & s_2 & s_3^* & -s_4^* & s_1^* & s_2^* \\ s_4 & s_3 & -s_2 & s_1 & s_4^* & s_3^* & -s_2^* & s_1^* \end{bmatrix} \quad (7)$$

大多数传统算法<sup>[2-7]</sup>无法区分 STBC3-1 与 STBC3-2、STBC3-3 与 STBC4 这两组编码方式,这是由于传统算法需要利用 STBC 相关性不同的特点进行识别,而以上两组 STBC 的相关性分布一致.假设传输信道  $\mathbf{H}$  为平坦衰落信道,则经过信道后的第  $k$  时刻的接收信号  $r(k)$  可表示为

$$r(k) = \mathbf{H}\mathbf{G}(k) + n(k) \quad (8)$$

其中,  $\mathbf{G}(k)$  为第  $k$  时刻的  $N_t \times 1$  维发射信号;  $\mathbf{H} = [h_1, h_2, \dots, h_{N_t}]$  为  $1 \times N_t$  维传输信道系数,其中  $h_i$  为第  $i$  个发射天线与接收天线之间的信道系数;  $n(k)$  为复高斯白噪声,其均值为 0,方差为  $\sigma_n^2$ .

### 3 多模态特征融合网络

在空时分组码识别领域,现有的深度学习模型较少,且以简单神经网络模型的迁移学习为主<sup>[8-10]</sup>,对 STBC 自身编码方式和特征互补性考虑不够充分.为设计一种更适于 STBC 识别的深度学习框架,本文提出了 MMFFN 网络框架,如图 1 所示.首先利用 STBC 编码矩阵相关性差异提取多时延特征,融合构建多时序特征自提取模块提取 STBC 码间时序特征,最后采用最大时延特征融合模块对各时延特征进行深度融合.该模型具备以下特点:(1)考虑接收端 STBC 相关性差异,引入扩张卷积提取多时延特征,增强网络的码内特征映射能力;(2)引入 LSTM 层提取多时间步的码间信息,增强时序特征自提取能力;(3)借鉴传统算法识别 STBC 的思路,采用最大时延特征进行特征融合,突出深层融合

特征的可辨识程度;(4)添加带跨越连接的残差层以增加深度融合特征的利用率与表征能力.

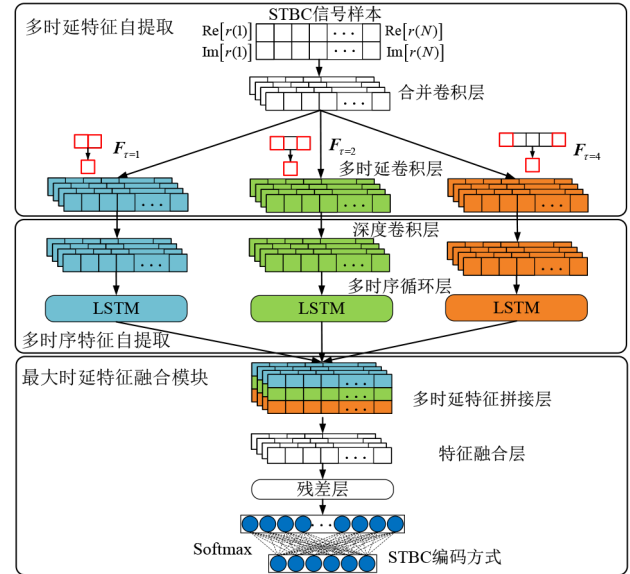


图 1 多模态特征融合网络框架

#### 3.1 多时延特征自提取

考虑到传统算法<sup>[2-7]</sup>常通过计算 STBC 在不同时延下的统计量,进而分析各阶统计量与理论阈值的大小关系完成识别,而这一计算时延特征的方法恰与深度学习中的扩张卷积 (Dilated Convolution, DC) 过程不谋而合<sup>[17]</sup>,即扩张卷积与时延特征同样是提取间隔点的信息,而非连续时间窗的信号特征.受这一特性的启发,本文将传统识别方法中计算多时延统计特征的思路通过扩张卷积应用到深度学习框架中,结合 STBC 自身相关性特征设计网络框架,提出了多时延特征自提取 (Multi-Delay Feature Self-Extraction, MDFSE) 模块,充分利用空时分组码信号的多时延特征信息,提升模型的特征映射能力.在接收端,经过信道和噪声的各类 STBC 相关性分布如图 2 所示.

由图 2 可知,由于在同一个编码矩阵内的接收信号相关,而不同矩阵间的信号不相关,因此接收信号的相

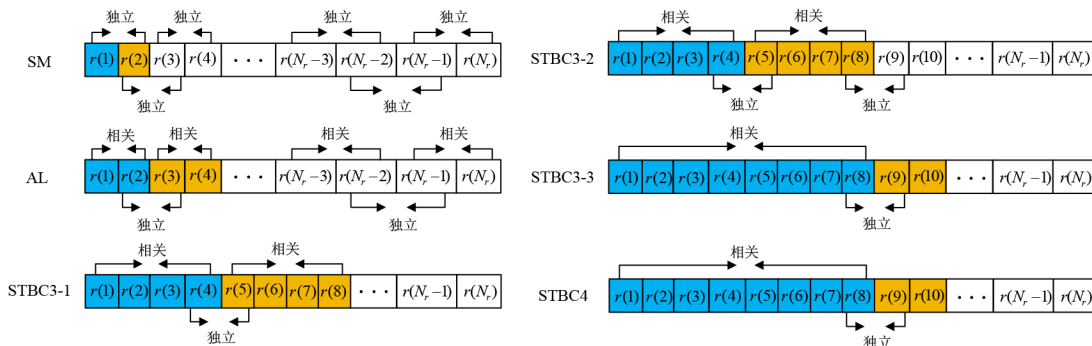


图 2 空时分组码相关性分布

关性分布与STBC编码矩阵的长度保持一致.在不同时延下,6类STBC的相关性分布差异如表1所示.

表1 STBC多时延相关性分布

STBC类型	时延 $\tau=1$	时延 $\tau=2$	时延 $\tau=4$
SM	×	×	×
AL	√	×	×
STBC3-1	√	√	×
STBC3-2	√	√	×
STBC3-3	√	√	√
STBC4	√	√	√

为利用STBC相关性分布的差异设计网络框架,本文首先对STBC实虚部组成的输入样本 $\mathbf{x}_{l/Q}$ 进行合并卷积,在不改变相关性的情况下将其合并成一维特征向量,则由第 $l$ 个卷积核提取出的特征向量 $\mathbf{h}^l$ 可表示为

$$\mathbf{h}^l = f(\mathbf{x}_{l/Q} * \mathbf{W}^l + \mathbf{b}^l) \quad (9)$$

其中, $\mathbf{W}^l$ 和 $\mathbf{b}^l$ 分别表示第 $l$ 个卷积核的待学习权值和偏置,\*表示卷积运算, $f(\cdot)$ 为激活函数.由于该合并层的卷积核尺寸是 $2 \times 1$ 维的,因此在卷积过程中只有同一个信号的实虚部会被合并,且合并后的 $L$ 个一维特征向量 $\mathbf{h}^l(l=1,2,\dots,L)$ 的相关性与输入样本 $\mathbf{x}_{l/Q}$ 保存一致.

为进一步提取信号的多时延特征,本模块依据STBC相关性分布差异,采用与多时延参数相同的多扩张率对特征向量进行扩张卷积.在扩张率 $\tau$ 下(即时延 $\tau$ )第 $k$ 个卷积核提取的时延向量 $\mathbf{F}_\tau^k$ 在 $i$ 位置处的值可表示为

$$F_{ii}^k = f\left(\sum_{s=1}^S \sum_{l=1}^L h_{i+\tau s}^l W_s^k + b^k\right) \quad (10)$$

其中, $h_{i+\tau s}^l$ 为合并卷积层输出的一维特征向量 $\mathbf{h}^l$ 在 $i+\tau s$ 处的值, $S$ 为卷积核的长度, $L$ 为合并卷积层的特征图个数, $W_s^k$ 为第 $k$ 个卷积核在 $s$ 处的待学习权值, $b^k$ 为待学习偏置.对于给定的STBC信号,其在不同时延下的统计特征存在较大差异,故采用扩张率 $\tau=1,2,4$ 的3类时延卷积得到的特征向量 $\mathbf{F}_\tau$ 也会具有明显不同.

值得说明的是,虽然编码矩阵长度相同的STBC3-1与STBC3-2、STBC3-3与STBC4两组空时分组码相关性分布一致,但得益于MMFFN网络对信号特征强大的映射能力,本文算法对以上相似度较高的两组STBC仍具有优异的识别性能.

### 3.2 多时序特征自提取

在本领域中,虽然CNN与循环神经网络(Recurrent Neural Network, RNN)的结合已有应用<sup>[10]</sup>,但该方法仅采用循环层堆叠的方式提取信号特征,对模型框架的研究不够深入,导致其在恶劣信道条件下的识别准确率急剧恶化.此外,该方法只能识别最基本的SM和AL两种编码方式,可识别的STBC类型甚至较传统算法更少<sup>[3-7]</sup>.为增强网络的特征映射能力,探究更适合STBC

识别的时序特征提取方法,本模块在多时延特征提取框架的基础上,首先利用连续采样点卷积核进行深度卷积,然后采用LSTM层提取STBC信号的前后多时间步特征,实现多时序特征自提取(Multi-Sequential Feature Self-Extraction, MSFSE).

在MMFFN网络中,多时序循环层提取的多时序编码特征恰与多扩张率卷积层获取的多时延卷积特征互补,使得本文模型能够学习到具有更强区分性的深层特征,增强了对STBC特征的映射能力.具体而言,多时序特征自提取模块首先使用连续卷积核进一步提取深层多时延特征,在时延 $\tau$ 下第 $g$ 个卷积核输出的一维向量为

$$\mathbf{J}_\tau^g = f\left(\sum_{k=1}^K \mathbf{F}_\tau^k * \mathbf{W}^g + \mathbf{b}^g\right) \quad (11)$$

其中, $\mathbf{W}^g$ 和 $\mathbf{b}^g$ 分别为该卷积核的待学习权值和偏置.为适应LSTM层的输入维度,需要将深度卷积层输出的3通道转换为2通道.考虑到卷积层提取的是一维特征向量,故本模块进一步对输出的 $g$ 个一维向量进行拼接操作

$$\mathbf{P}_\tau = \left[ (\mathbf{J}_\tau^1)^T, \dots, (\mathbf{J}_\tau^g)^T, \dots, (\mathbf{J}_\tau^G)^T \right]^T \quad (12)$$

将维度重塑后的拼接矩阵 $\mathbf{P}_\tau$ 输入LSTM层,则当LSTM记忆单元移动至 $t$ 时刻时,其遗忘门 $f_\tau^t$ 、输入门 $i_\tau^t$ 和输出门 $o_\tau^t$ 的状态由当前时间步的输入 $\mathbf{J}_\tau^t$ 和在 $t-1$ 时刻隐藏层的状态 $\mathbf{h}_\tau^{t-1}$ 共同决定

$$f_\tau^t = \sigma(\mathbf{W}_f^t [\mathbf{h}_\tau^{t-1}, \mathbf{J}_\tau^t] + \mathbf{b}_f^t) \quad (13)$$

$$i_\tau^t = \sigma(\mathbf{W}_i^t [\mathbf{h}_\tau^{t-1}, \mathbf{J}_\tau^t] + \mathbf{b}_i^t) \quad (14)$$

$$o_\tau^t = \sigma(\mathbf{W}_o^t [\mathbf{h}_\tau^{t-1}, \mathbf{J}_\tau^t] + \mathbf{b}_o^t) \quad (15)$$

其中, $\mathbf{W}_f$ 与 $\mathbf{b}_f$ 、 $\mathbf{W}_i$ 与 $\mathbf{b}_i$ 和 $\mathbf{W}_o$ 与 $\mathbf{b}_o$ 表示遗忘门、输入门和输出门的权值与偏置, $\sigma(\cdot)$ 为sigmoid函数.更新后的记忆单元状态 $\mathbf{c}_\tau^t$ 由当前时间步的遗忘门 $f_\tau^t$ 与输入门 $i_\tau^t$ 控制

$$\mathbf{c}_\tau^t = f_\tau^t \cdot \mathbf{c}_\tau^{t-1} + i_\tau^t \cdot \tanh(\mathbf{W}_c^t [\mathbf{h}_\tau^{t-1}, \mathbf{J}_\tau^t] + \mathbf{b}_c^t) \quad (16)$$

其中, $\mathbf{c}_\tau^{t-1}$ 为 $t-1$ 时刻记忆单元的状态, $\mathbf{W}_c$ 和 $\mathbf{b}_c$ 表示记忆单元当前状态的权值与偏置, $\tanh$ 为输出在 $(-1,1)$ 之间激活函数,满足 $\tanh(\cdot) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ .在 $t$ 时刻隐藏层的输出为

$$\mathbf{y}_\tau^t = o_\tau^t \cdot \tanh(\mathbf{c}_\tau^t) \quad (17)$$

其中, $o_\tau^t$ 为当前时刻的输出门状态.通过三个控制门的联合控制与多个记忆单元信息的长期存储,LSTM单元得以利用前后多时间步的特征,从而实现多时序特征的自提取,进一步增强了MMFFN网络对STBC信号的特征映射能力.

### 3.3 最大时延特征融合模块

相比于单一的信号特征,融合信息因其对各类特征互补性的充分利用而具有更强的表征能力.为充分融合多模态特征,本文借鉴了传统算法识别STBC的思路,即依据其相关性计算在各类时延下的高阶统计特征(High Order Statistics, HOS),并将距离度量最大的高阶时延统计量作为鉴别特征<sup>[4]</sup>.在上述模型框架的基础上,本文进一步增加了最大时延特征融合(Maximum Delay Feature Fusion, MDFF)模块,将多时延下的特征进行拼接后,提取最大时延特征作为深层融合特征,并且增加了带跨越连接的残差层,使融合信息得以被充分利用,从而有效地解决了单一特征表征能力差、各时延信息互补性利用不充分的问题.

为实现对各时延特征的拼接,需首先将LSTM层的输出的2通道重新变换为3通道,故将时延 $\tau$ 下LSTM层的输出 $y_\tau$ 按行拆分为一维特征向量

$$y_\tau = \left[ \left( \mathbf{K}_\tau^1 \right)^\top, \dots, \left( \mathbf{K}_\tau^q \right)^\top, \dots, \left( \mathbf{K}_\tau^Q \right)^\top \right]^\top \quad (18)$$

其中, $Q$ 为一维向量的个数.将同一序号的3类时延下的 $1 \times N$ 维特征向量 $\mathbf{K}_\tau^q$ 按行进行拼接

$$\mathbf{S}^q = \left[ \left( \mathbf{K}_{\tau=1}^q \right)^\top, \left( \mathbf{K}_{\tau=2}^q \right)^\top, \left( \mathbf{K}_{\tau=4}^q \right)^\top \right]^\top \quad (19)$$

其中, $\mathbf{S}^q$ 为拼接得到的第 $q$ 个 $3 \times N$ 维矩阵,包含了各类时延下的特征信息.将得到的拼接矩阵 $\mathbf{S}^q$ 进行特征融合,按列遍历矩阵 $\mathbf{S}^q$ ,选取其最大时延特征作为深层融合特征

$$U^q(j) = \max \mathbf{S}^q(j) \quad (20)$$

其中, $\mathbf{S}^q(j)$ 为第 $q$ 个拼接矩阵的第 $j$ 列.为提升深层融合特征利用率,克服梯度下降导致的网络退化问题,本模块引入带跨越连接的残差层以提升网络表征能力.对于第 $q$ 个融合特征向量,经过残差层后的输出为

$$\mathbf{R}^q = f(h(\mathbf{U}^q) + F(\mathbf{U}^q, \mathbf{W}^q)) \quad (21)$$

其中, $h(\cdot)$ 为跨越连接的映射函数,本文采用 $h(\mathbf{U}^q) = \mathbf{U}^q$ 的恒等映射, $\mathbf{W}^q$ 为待学习的权重.通过恒等连接 $h(\mathbf{U}^q)$ ,残差层能够充分利用深层融合特征 $\mathbf{U}^q$ ,进一步挖掘其潜在映射效能.

## 4 实验结果与分析

### 4.1 实验环境与数据集

在实验中针对SM、AL、STBC3-1、STBC3-2、STBC3-3和STBC4共6类空时分组码信号进行仿真,采用Nakagami- $m$ 衰落信道,信道参数默认 $m=3$ ,调制方式为QPSK调制,噪声为复高斯白噪声.接收端每128个时钟信号截取一段数据,分别提取其实虚部后得到 $2 \times 128$ 维矩阵作为一个学习样本,类别标签采用独热编码(One-Hot Encoding)形式表示,向量大小为 $1 \times 6$ ,与待识

别信号类别相对应.训练集与测试集均在 $-10$  dB~ $10$  dB下产生,训练集每个信噪比下的单类信号样本数为800,共100 800个训练样本,测试集每类信号产生200个样本,共25 200个测试样本.

MMFFN网络的设计与训练过程利用Pycharm软件完成,使用的深度学习模型为基于TensorFlow后端的keras框架,并使用NVIDIA RTX2080ti GPU加速训练速度.硬件配置为Intel(R) Core(TM) i9-9900K CPU,主频3.6 GHz,运行内存16 GB.模型训练过程使用Adam优化器进行权重与偏置的优化,并采用分类交叉熵损失函数(Categorical Cross Entropy Loss Function, CCELF)衡量指标的优劣.

### 4.2 网络参数设置

由于本文模型需要对多模态特征进行深度融合,以增强MMFFN网络的码间与码内特征映射能力,提升STBC样本深层融合特征的可区分性,因此模型存在3条维度一致的并行多时延分支结构,并采用拼接融合模块合并各时延分支.网络具体参数如表2所示,其中,输入层维度设置为 $2 \times 128$ 以适应样本大小,网络经 $2 \times 1$ 维卷积核合并卷积后,采用扩张率 $\tau=1, 2, 4$ 的3类卷积提取多时延特征,LSTM层提取多时序特征,return\_sequences设置为True以返回所有时间步的隐藏值,输出层为包含了6个神经元的全连接层,采用Softmax激活函数,对应6种STBC分类结果,除最后一层全连接层外,其余各层均采用ReLU激活函数,所有卷积层步长均为strides=(1,1).

### 4.3 实验仿真与结果分析

#### 4.3.1 多时延融合有效性验证

为验证采用多时延融合特征的有效性,本节将多模态特征融合网络与单时延多时序网络(Single-Delay Muti-Sequential Network, SDMSN)进行对比.测试的SDMSN各层参数设置与MMFFN网络一致,区别在于SDMSN网络仅保留了图1中提取特征 $\mathbf{F}_{\tau=1}$ 的一条支路,即只包含连续时间窗的单时延特征.两种测试网络识别准确率随信噪比的变化图像如图3所示.从图中可以看出,MMFFN识别性能随信噪比稳步递增,在低信噪比下较SDMSN获得明显提升, $-10$  dB下的准确率增益达7.1%,说明引入扩张卷积提取的非连续时间窗特征有效地丰富了特征类型,多时延融合的深层码内特征具有更强的表征能力,从而验证了采用MDFSE模块的有效性.

为进一步分析多时延特征在各类码型下性能增益,图4给出了MMFFN与SDMSN网络在 $-10$  dB、 $-8$  dB和 $-6$  dB下6类STBC的混淆矩阵.对比同一信噪比下不同模型的混淆矩阵可知:除AL码准确率略低外,MMFFN对SM、STBC3-1等5类空时分组码的识别率均

表 2 MMFFN 网络参数设置

模块名称	参数设置		
多时延特征自提取	输入层: input = 2 × 128		
	合并卷积层: filters = 128, kernel size = (2,1), padding = 'valid'		
	扩张卷积层: filters = 64, kernel size = (1,2), dilation_rate = (1,1), padding = 'same'	扩张卷积层: filters = 64, kernel size = (1,2), dilation_rate = (1,2), padding = 'same'	扩张卷积层: filters = 64, kernel size = (1,2), dilation_rate = (1,4), padding = 'same'
多时序特征自提取	卷积层: filters = 128, kernel size = (1,4), padding = 'same'	卷积层: filters = 128, kernel size = (1,4), padding = 'same'	卷积层: filters = 128, kernel size = (1,4), padding = 'same'
	尺度变换: (128, 1, 128) → (128, 128)	尺度变换: (128, 1, 128) → (128, 128)	尺度变换: (128, 1, 128) → (128, 128)
	LSTM 层: units = 32, recurrent_dropout = 0.5, return_sequences = True	LSTM 层: units = 32, recurrent_dropout = 0.5, return_sequences = True	LSTM 层: units = 32, recurrent_dropout = 0.5, return_sequences = True
最大时延特征融合模块	尺度变换: (128, 32) → (32, 1, 128) (X_0)	尺度变换: (128, 32) → (32, 1, 128) (X_1)	尺度变换: (128, 32) → (32, 1, 128) (X_2)
	拼接层: concatenate ([X_0, X_1, X_2], axis=2) (X_shortcut)		
	最大时延融合层: MaxPooling2D (pool_size = (3, 1), padding = 'valid')		
	卷积层: filters = 32, kernel size = (1,2), padding = 'same'		
	卷积层: filters = 32, kernel size = (1,2), padding = 'same' (X_3)		
	跨越连接层: layers.add ([X_3, X_shortcut])		
全连接层: units = 64, ReLU 激活函数			
全连接层: units = 6, Softmax 激活函数			




图 3 不同时延特征网络的识别性能

高于 SDMSN, 其混淆矩阵的对角线分布明显, 误判率较 SDMSN 明显降低. 在信道环境较恶劣的情况下 (-10 dB), 得益于依据 STBC 相关性差异提取的时延特征  $F_{\tau=2}$  与  $F_{\tau=4}$ , MMFFN 在识别编码矩阵长度大于 2 的四类 STBC 时, 可获取针对性和统计特征差异性更强的辨识特征, 使其对该四类 STBC 的识别性能明显优于 SDMSN, 四类码的增益分别达到了 15.1% (STBC3-1)、8.5% (STBC3-2)、10.1% (STBC3-3) 和 4.0% (STBC4). 在各种信噪比条件下, SM 和 AL 的混淆均是导致 MMFFN 识别性能差的主要原因, 这可能是由于 SM 和 AL 码的编码矩阵长度过短, 使得时延特征  $F_{\tau=2}$  与  $F_{\tau=4}$  效能发挥不明显, 因此, 进一步提升编码矩阵较短 STBC 的识别率是未来改善算法性能的关键之一.

#### 4.3.2 多时序特征对识别效果的影响

为分析多时序特征给算法带来的识别性能增益, 在上节所述的 MMFFN 与 SDMSN 网络的基础上, 去除其中提取码间多时序特征的 MSFSE 模块, 得到多时延融合网络 (Multi-Delay Features Fusion Network, MDFFN) 与单时延网络 (Single-Delay Network, SDN), 其中, 单时延网络仅有图 1 网络的左侧支路, 且不包含多时序特征自提取模块. 仿真对比 MDFFN+MSFSE、MDFFN、SDN+MSFSE 和 SDN 网络的识别性能, 其中, MDFFN+MSFSE 网络即为本文的多模态特征融合网络, 实验结果如图 5 所示.

由该图可知, 得益于码间时序特征与码内时延特征的互补性, 通过在 MDFFN 网络的适当位置添加 MSFSE 模块能有效提升网络性能, 说明引入码间多时序特征有效地扩展了特征类型, 使得网络深层特征的多样性进一步增强, 从而具备更丰富的特征表示和更高稳定性. 在 -10 dB ~ -2 dB 的低信噪比环境下, SDN 网络增加 MSFSE 模块的性能增益较 MDFFN 更明显, 说明在特征类型较匮乏的情况下, 引入多时序特征对模型表征能力的提升更显著, 可有效地增强映射特征的可辨识程度. 将 MDFFN 与 MSFSE 模块相结合的网络识别率最高, 识别性能也最稳定.

为分析 LSTM 参数对识别性能与训练复杂度的影响, 本文分别采用 -5 dB 下的识别准确率与训练过程单轮迭代耗时对两者进行衡量, 参数设置主要从 LSTM 层数和循环单元数两个层面进行优化. 除 LSTM 层参数

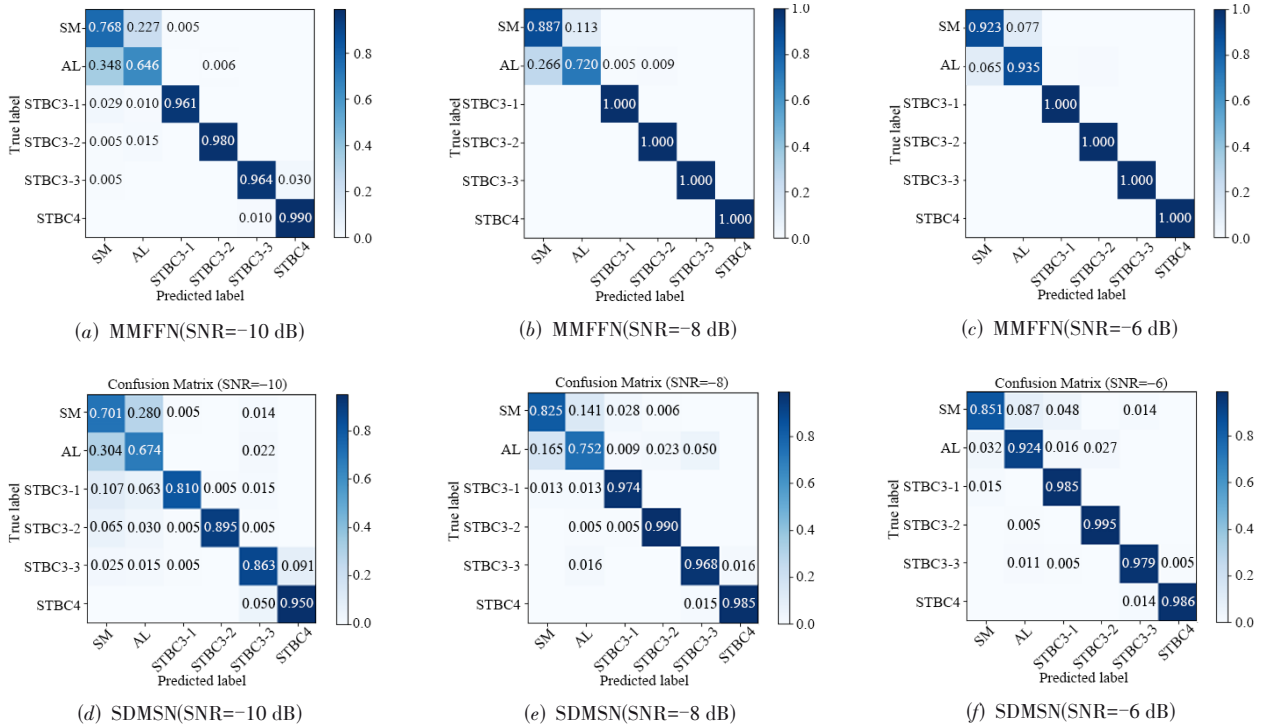


图4 不同时延特征网络的混淆矩阵

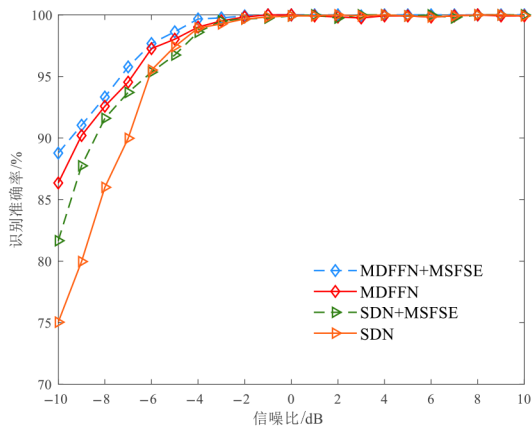


图5 不同时序与时延特征网络的识别性能

不同外, MMFFN 网络其余部分结构均相同, 批处理参数统一设置为 128, 训练样本维度、容量与比例的设置保持一致, 实验结果如图 6 所示. 其中, LSTM 单元数与层数取 [5, 128] 时, 网络因过拟合导致收敛困难, STBC 识别准确率较差. 除该结构参数组合外, 所有 MMFFN 网络的整体识别准确率均达到了 96% 以上, 模型性能与 LSTM 层数、单元数呈非线性关系, 单轮迭代耗时主要随 LSTM 层数的增加而同步递增, 随 LSTM 单元数增加的变化不大. 本文网络采用单层 32 个 LSTM 单元时即达到了 98.63% 的识别率, 与最高 98.80% 的准确率 (LSTM 结构参数为 [3, 128]) 仅相差不到 0.2%, 性能差异不大, 且 LSTM 结构参数取 [1, 32] 时迭代耗时最短,

综合考虑性能增益与识别过程的时效性, 本文采用了 [1, 32] 的单层结构参数设置.

#### 4.3.3 与其他识别算法的比较

为进一步说明基于多模态特征融合网络识别 STBC 的性能优势, 该节对本文提出的 MMFFN、HOS<sup>[6]</sup>、JADE<sup>[7]</sup>、FDSCF+CNN<sup>[9]</sup> 和 CNN+LSTM<sup>[10]</sup> 共 5 种算法进行对比. 其中, HOS 算法使用高阶累积量作为统计特征, 将累积量协方差矩阵的均值和 Frobenius 范数作为阈值检测 STBC; JADE 基于特征值矩阵联合近似对角化与特征提取实现 STBC 识别; FDSCF+CNN 对信号样本进行频域自相关预处理, 使用 CNN 网络实现对 6 种 STBC 的识别; CNN+LSTM 利用 CNN 与 LSTM 分别提取空间和时序特征, 可识别 SM 和 AL 两类基本编码方式. 以上算法中, HOS 与 JADE 为基于假设检验与统计特征量识别 STBC 的典型传统算法, FDSCF+CNN 和 CNN+LSTM 为本领域基于深度学习模型的先进算法, 各算法的识别准确率如图 7 所示.

由该图可知, MMFFN 识别性能最优, -10dB 下的识别率达到了 88.78%, 较 HOS、FDSCF+CNN 和 CNN+LSTM 分别提升 11.78%、28.63% 和 35.28%, 算法性能增益明显. JADE 在 -5 dB~5 dB 时的识别率达到了 100%, 但在更低信噪比下难以提取可辨识特征, 算法性能急剧恶化. 基于深度学习与特征预处理的 FDSCF+CNN 和 CNN+LSTM 的性能较 JADE 更稳定, 但与传统算法中较成熟的 HOS 算法还有一定的差距, 这是由于以上网

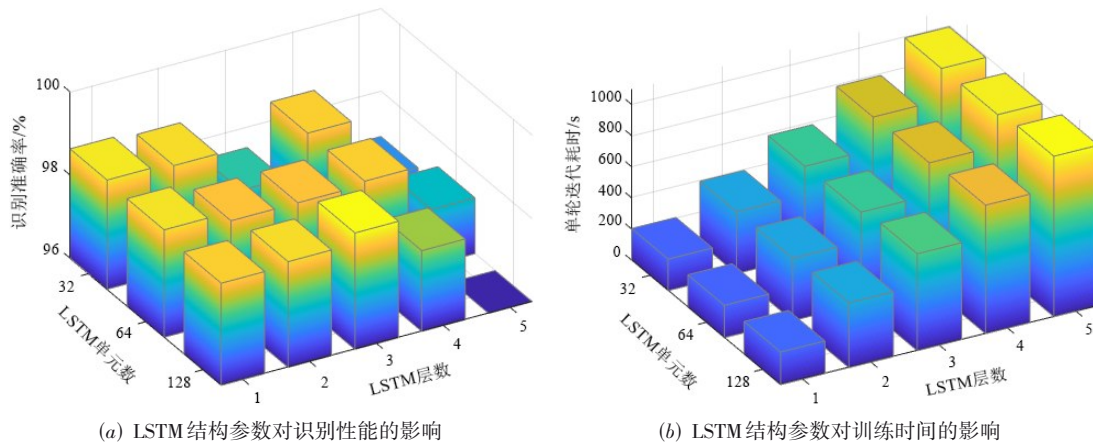


图6 LSTM层结构参数对识别性能的影响

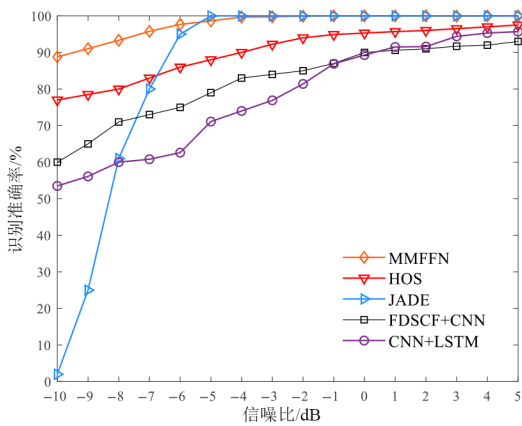


图7 不同识别算法的性能对比

络<sup>[9,10]</sup>在设计时未充分考虑STBC自身编码特性,对模型结构的研究不够深入,模型架构较为单一.本文网络兼顾了多时延与多时序特征的互补性和深度学习模型的特征自提取能力,在低信噪比下的性能较传统算法和现有深度学习算法均有显著提升,考虑到通信信号常在低信噪比下的复杂环境中传输,因而提升空时分组码在低信噪比下的识别性能具有重要意义.

为分析本文算法与现有深度学习算法的复杂度,从网络的空间(模型参数量)和时间复杂度(单个样本识别耗时,样本维度均为 $2 \times 128$ )两个角度进行对比,不同网络的计算复杂度如表3所示.

表3 网络复杂度分析

网络	空间复杂度	时间复杂度/ms
MMFFN	476 998	0.106
FDSCF+CNN	2 645 078	0.015
CNN+LSTM	1 059 522	0.319

从表中可以看出,本文网络的空间复杂度最低,结构框架精炼,模型设计较现有深度学习算法更具合理性.时间复杂度方面,由于MMFFN网络嵌入的LSTM

层需依赖多时间步信息更新神经元,单样本识别耗时大于仅采用前馈结构的FDSCF+CNN算法,但FDSCF+CNN需首先对接收信号进行频域自相关预处理,无法直接实现对接收端I/Q信号的识别.综合考虑识别性能与计算复杂度,本文网络在识别准确率和效率上的综合性能较优.CNN+LSTM由于堆叠了多层LSTM使得识别时间大幅增加,且仅能识别最基本的SM和AL两类STBC编码方式,低信噪比下识别准确率低,而MMFFN通过单层LSTM即获取了性能上的较大提升,由此反向验证了本文嵌入的LSTM层在网络框架构建过程中的有效性.

#### 4.3.4 算法鲁棒性分析

深度学习模型的识别性能一定程度上依赖于训练样本的容量,为分析不同样本数下MMFFN网络的识别准确率,本文对每个信噪比下单类训练样本数为100~800时的算法性能进行了仿真,实验结果如图8所示.由该图可知,样本数为800时的识别性能理想且趋于稳定,样本数为100~600时的识别率均存在一定的波动,但各样本条件下的性能相差不大,且MMFFN在每类信噪比样本数仅为100时仍能保持优异的识别性能,从而




图8 不同样本数下的识别性能对比

验证了本文算法鲁棒性和对 STBC 信号强大的表征能力. 考虑到在实际通信环境中, 高质量样本的采集与标注过程常常难以完成且开销较大, 因此本文算法在少量样本下获取的稳定性能对 STBC 识别更具实用性.

## 5 结论


针对低信噪比下空时分组码识别算法识别率较低、识别稳定性较差等问题, 本文结合融合特征互补性与深度学习技术优势, 提出了一种基于多模态特征融合识别网络的空时分组码识别算法. 该算法依据接收端不同 STBC 信号相关性差异, 采用非连续时间窗的扩张卷积提取时域合并特征向量的多时延特征; 利用码间时序特征与码内时延特征的互补性, 构建多时序特征自提取模块提取 STBC 多时间步特征, 进一步增强了特征的多样性和对低信噪比环境适应性; 设计最大时延特征融合模块融合各类映射特征, 从而有效地解决了单一特征表征能力差、各时延信息互补性利用不充分的问题. 不同于现有深度学习算法的是, 本文网络充分考虑了传统识别算法依据的 STBC 编码特性——相关性, 将传统算法的识别思路通过扩张卷积引入到深度学习模型中, 该思想可为其他通信信号识别提供有力借鉴.

## 参考文献

- [1] 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.
- [2] KARAMI E, DOBRE O A. Identification of SM-OFDM and AL-OFDM signals based on their second-order cyclostationarity[J]. *IEEE Transactions on Vehicular Technology*, 2015, 64(3): 942-953.
- [3] LING Q, ZHANG L, YAN W, et al. Hierarchical space-time block codes signals classification using higher order cumulants[J]. *Chinese Journal of Aeronautics*, 2016, 29(3): 754-762.
- [4] 闫文君, 张立民, 凌青, 等. 基于高阶统计特征的空时分组码盲识别方法[J]. *电子与信息学报*, 2016, 38(3): 668-673. YAN W J, ZHANG L M, LING Q, et al. An algorithm for blind classification of space-time block code based on higher-order statistics[J]. *Journal of Electronics & Information Technology*, 2016, 38(3): 668-673. (in Chinese)
- [5] DEHRI B, BESSEGHIER M, DJEBBAR A B, et al. Blind digital modulation classification for STBC-OFDM system in presence of CFO and channels estimation errors[J]. *IET Communications*, 2019, 13(17): 2827-2833.
- [6] KHOSRAVIYANI M, KALBKHANI H, SHAYESTEH M G. Higher order statistics for modulation and STBC recognition in MIMO systems[J]. *IET Communications*, 2019, 13(16): 2436-2446.
- [7] 张天琪, 范聪聪, 喻盛琪, 等. 基于 JADE 与特征提取的正交/非正交空时分组码盲识别[J]. *系统工程与电子技术*, 2020, 42(4): 933-939. ZHANG T Q, FAN C C, YU S Q, et al. Blind recognition of orthogonal and non-orthogonal space-time block codes based on JADE and feature extraction[J]. *Systems Engineering and Electronics*, 2020, 42(4): 933-939. (in Chinese)
- [8] YAN W, LING Q, ZHANG L, et al. Convolutional neural networks for space-time block coding recognition[EB/OL]. (2019-10-09)[2021-03-09]. <https://arxiv.org/abs/1910.09952v1>.
- [9] 于柯远, 张立民, 闫文君, 等. 基于深度学习的多 STBC 盲识别算法[J/OL]. *系统工程与电子技术*. <https://kns.cnki.net/kcms/detail/11.2422.TN.20201014.1326.022.html>. YU K Y, ZHANG L M, YAN W J, et al. Blind recognition algorithm for multi-STBC based on deep learning[J/OL]. *Systems Engineering and Electronics*. <https://kns.cnki.net/kcms/detail/11.2422.TN.20201014.1326.022.html> (in Chinese)
- [10] 张聿远, 闫文君, 林冲, 等. 利用卷积-循环神经网络的串行序列空时分组码识别方法[J]. *信号处理*, 2021, 37(1): 19-27. ZHANG Y Y, YAN W J, LIN C, et al. Serial sequence space-time block code recognition method by using convolutional-recurrent neural networks[J]. *Journal of Signal Processing*, 2021, 37(1): 19-27. (in Chinese)
- [11] O' SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]//*International Conference on Engineering Applications of Neural Networks*. Aberdeen: Springer, 2016: 213-226.
- [12] ZHANG Z F, WANG C, GAN C Q, et al. Automatic modulation classification using convolutional neural network with features fusion of SPWVD and BJD[J]. *IEEE Transactions on Signal and Information Processing over Networks*, 2019, 5(3): 469-478.
- [13] ZHENG S L, QI P H, CHEN S C, et al. Fusion methods for CNN-based automatic modulation classification[J]. *IEEE Access*, 2019, 7: 66496-66504.
- [14] BU K, HE Y, JING X J, et al. Adversarial transfer learning for deep learning based automatic modulation classification[J]. *IEEE Signal Processing Letters*, 2020, 27: 880-884.
- [15] TUNZE G B, HUYNH-THE T, LEE J M, et al. Sparsely connected CNN for efficient automatic modulation recog-

- nitition[J]. IEEE Transactions on Vehicular Technology, 2020, 69(12): 15557-15568.
- [16] ZHAO S Q, WANG W H, ZENG D G, et al. A novel aggregated multi-path extreme gradient boosting approach for radar emitter classification[J/OL]. IEEE Transactions on Industrial Electronics, 2022, 69(1): 703-712. DOI:10.1109/TIE.2021.3055155.
- [17] 王传旭, 薛豪. 基于GFU和分层LSTM的组群行为识别研究方法[J]. 电子学报, 2020, 48(8): 1465-1471.  
WANG C X, XUE H. Group activity recognition based on GFU and hierarchical LSTM[J]. Acta Electronica Sinica, 2020, 48(8): 1465-1471. (in Chinese)
- [18] 王传旭, 胡小悦, 孟唯佳, 等. 基于多流架构与长短时记忆网络的组群行为识别方法研究[J]. 电子学报, 2020, 48(4): 800-807.  
WANG C X, HU X Y, MENG W J, et al. Research on group behavior recognition method based on multi-stream architecture and long short-term memory network[J]. Acta Electronica Sinica, 2020, 48(4): 800-807. (in Chinese)

#### 作者简介



张聿远 男,1997年1月生,山西长治人. 现为海军航空大学硕士研究生. 主要研究方向为空时分组码识别.  
E-mail: 2932484433@qq.com



闫文君(通讯作者) 男,1986年生,山东莱州人. 现为海军航空大学副教授. 主要研究方向为空时分组码识别.  
E-mail: wj\_yan@foxmail.com



张立民 男,1966年生,辽宁开原人. 现为海军航空大学教授、博士生导师. 主要研究方向为卫星信号处理及应用.  
E-mail: iamzlm@163.com