



计算机科学

COMPUTER SCIENCE

基于多模态融合和深度学习的调制信号识别

杨小蒙, 张涛, 庄建军, 乔晓强, 杜奕航

引用本文

杨小蒙, 张涛, 庄建军, 乔晓强, 杜奕航. 基于多模态融合和深度学习的调制信号识别[J]. 计算机科学, 2023, 50(11A): 220900007-7.

YANG Xiaomeng, ZHANG Tao, ZHUANG Jianjun, QIAO Xiaoqiang, DU Yihang. [Modulation Signal Recognition Based on Multimodal Fusion and Deep Learning](#) [J]. Computer Science, 2023, 50(11A): 220900007-7.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于边缘引导的多尺度医学影像分割方法](#)

Medical Image Segmentation Based on Multi-scale Edge Guidance

计算机科学, 2023, 50(11A): 220900059-7. <https://doi.org/10.11896/jsjcx.220900059>

[基于语义注意力的医学图像超分辨率方法](#)

Medical Image Super-resolution Method Based on Semantic Attention

计算机科学, 2023, 50(11A): 221200107-6. <https://doi.org/10.11896/jsjcx.221200107>

[一种基于因果推理的垃圾分类方法](#)

Novel Method for Trash Classification Based on Causal Inference

计算机科学, 2023, 50(11A): 220800218-6. <https://doi.org/10.11896/jsjcx.220800218>

[接诉即办智能派单业务调度算法研究](#)

Study on Scheduling Algorithm of Intelligent Order Dispatching

计算机科学, 2023, 50(11A): 230300029-7. <https://doi.org/10.11896/jsjcx.230300029>

[基于MILP的GIFT积分区分器搜索及优化](#)

Search and Optimization of GIFT Integral Distinguisher Based on MILP

计算机科学, 2023, 50(11A): 220900231-8. <https://doi.org/10.11896/jsjcx.220900231>

基于多模态融合和深度学习的调制信号识别

杨小蒙^{1,2} 张涛¹ 庄建军² 乔晓强¹ 杜奕航¹

1 国防科技大学第六十三研究所 南京 210007

2 南京信息工程大学电子与信息工程学院 南京 210044

(1402420186@qq.com)

摘要 针对现有的调制分类算法大多忽略了不同特征之间的互补性和特征融合的问题,提出了一种利用深度学习模型进行特征融合的方法。该方法试图融合调制信号的时序特征和空间特征,以获得差异性更加明显的识别特征。首先,获取调制信号的 A/P 信号和 I/Q 信号;然后,搭建卷积长短时记忆模块与复数密集残差卷积模块分别提取 A/P 信号的时序特征和 I/Q 信号的空间特征并将之进行融合,获取融合互补的识别特征;最后,将识别特征输入分类网络,得到识别结果。实验结果表明,基于开源数据集,当信噪比大于 5dB 时,识别率达到了 93.25%,与基于单一特征识别相比,识别准确率高出 3%~11%;利用实际采集数据进行分类识别,进一步证实了所提特征提取模型与融合策略的有效性。

关键词 自动调制分类;多模态融合;深度学习

中图分类号 TN911.7

Modulation Signal Recognition Based on Multimodal Fusion and Deep Learning

YANG Xiaomeng^{1,2}, ZHANG Tao¹, ZHUANG Jianjun², QIAO Xiaoqiang¹ and DU Yihang¹

1 The 63rd Research Institute, National University of Defense Technology, Nanjing 210007, China

2 School of Electronics and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China

Abstract Aiming at the problem that most of the existing modulation classification algorithms ignore the complementarity between different features and feature fusion, this paper proposes a method of feature fusion using deep learning model. This method attempts to fuse the temporal and spatial features of modulated signals to obtain more distinct recognition features. First, the A/P signal and I/Q signal of the modulation signal are obtained. Then, the convolution long-term and short-term memory module and the complex dense residual convolution module are built to extract the temporal features of A/P signal and the spatial features of I/Q signal respectively, and fuse them to obtain the fusion complementary recognition features. Finally, the recognition features are input into the classification network to obtain the recognition results. Experimental results show that based on the open source data set, when the signal-to-noise ratio is greater than 5dB, the recognition rate reaches 93.25%, and the recognition accuracy is 3%~11% higher than that based on single feature recognition. The actual collected data is used for classification and recognition, which further proves the effectiveness of the proposed feature extraction model and fusion strategy.

Keywords Automatic modulation classification, Multimodal fusion, Deep learning

自动调制识别^[1-2]是通信领域的一项重要内容。在自动调制识别领域中,基于特征提取的模式识别^[3]作为一种非协作通信系统中的关键技术,一直是通信界的主要研究课题之一。早期电磁环境相对简单,通信功能较为单一,信号调制类型相对较少,传统的方法大多从时域、频域等多种域人工提取特征。如文献[4]从时域和频域提取常见数字信号的4种相关特征,利用决策树完成了对调制信号的识别;文献[5]提取8种常见调制信号的6个瞬时统计信息作为分类特征,采用支持向量机(Support Vector Machines, SVM)完成了信号的调制识别;文献[6]基于四阶累积量完成了信号的调制识别。这些方法在一定情况下能够准确识别不同调制类型的信号,识别速度相对较快,但是选择哪种特征依赖于人的专业

知识,而且选取的特征大多数无法适应如今复杂的信号类型,尤其是在低信噪、信道干扰严重时,这类方法更加难以有效识别不同调制信号的区别。

深度学习凭借其强大的拟合复杂模型的能力,在近几年得到了迅猛的发展,在各项研究领域中都取得了突破性的进展,其在信号识别与处理问题中已经有丰富的成果。由于深度学习能够自动提取数据的特征,克服了传统调制识别算法的不足, Wu 等^[7]将调制信号转换成时频图,利用卷积自编码器和残差网络完成了对调制信号的识别。Peng 等^[8]将8种调制信号转换为星座图并处理得到灰度图像和增强灰度图像,使用卷积神经网络(Convolutional Neural Network, CNN)对其进行训练和测试,仿真结果表明该方法可以有效地对

基金项目:国家自然科学基金项目(61801496,61801497);军委科技委基础加强计划领域基金项目(2019-JCJQ-JJ-221)

This work was supported by the National Natural Science Foundation of China(61801496,61801497) and Strengthening Program Area Foundation of China (2019-JCJQ-JJ-221).

通信作者:张涛(ztcool@126.com)

8种调制信号进行分类。上述基于深度学习的调制信号识别方法将信号的识别转换为二维图像的识别,这类方法人为提取特征的过程较少,但是将信号进行二维变换需要较大的计算量,而且对于图像的识别往往需要复杂的预处理,识别速度较慢,不适合样本较大的情况。此外,一些学者提出一种端到端的调制识别模型,避免将调制信号转换为图像的过程,将调制信号的时序特征直接输入到深度模型当中进行学习^[9]。不管是图像域的调制识别,还是端到端的调制识别,上述方法通常只关注信号的单一特征,而忽略了不同特征之间的相关性。利用不同模态特征之间的互补性进行研究,可以得到更高的识别率和更稳定的识别模型^[10-12]。

基于上述理论和方法,为利用特征之间的互补性,本文提出一种基于多模态融合和深度学习的电磁信号调制识别方法。首先,获取数据集的同相/正交(In-phase/Quadrature, I/Q)分量,并将之转换为幅度/相位(Amplitude/phase, A/P)信息。然后,将CNN与长短时记忆(Long Short-Term Memory, LSTM)网络串联形成支路一提取A/P信号的时序特征;同时,将密集连接结构和残差结构进行融合形成密集残差网络,并通过线性组合的方式在实值密集残差网络中实现复数卷积运算,以此形成支路二提取I/Q信号的空间特征。接着,将支路一提取的时序特征和支路二提取的空间特征融合成识别特征。最后,将识别特征输入分类网络进行识别。实验结果表明,本文提出的多模态融合(Multimodal Fusion, MMF)模型具有较好的识别性能,分别采用开源数据集与实际采集数据集进行实验,在一定信噪比范围内,识别性能都要优于传统识别模型以及单一特征识别方法。

1 调制信号模型及预处理

1.1 调制信号模型

本文研究基于一个单输入单输出的通信系统,如图1所示,发送符号序列通过调制变换并经由信道到达接收端。接收信号的公式如下所示:

$$r(t) = f(s(t)) * h(t) + n(t) \quad (1)$$

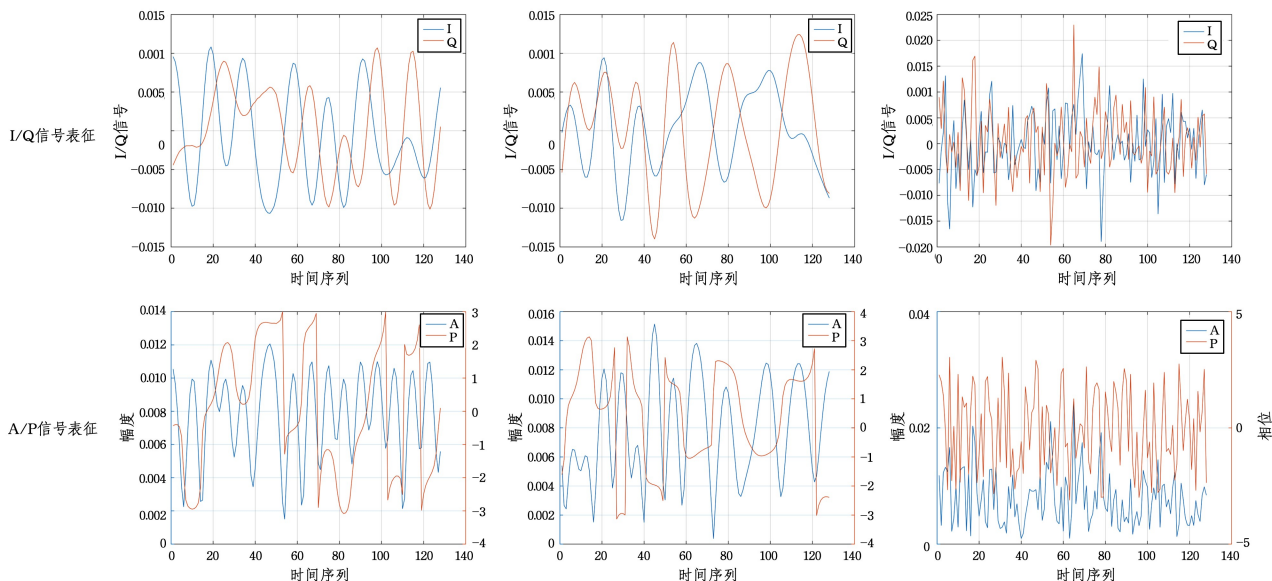


图2 8PSK, QAM16, AM-SSB 3类调制信号的两信号表征

Fig. 2 Two signal characterization of 8PSK, QAM16 and AM-SSB modulation signals

其中, $s(t)$ 代表发送符号序列, $f(\cdot)$ 是调制函数, $h(t)$ 是通信信道的冲激响应, $n(t)$ 是加性高斯白噪声, $r(t)$ 是接收端的接收信号,而调制识别的目的便是解码调制函数 f , 识别出 f 的调制类型。

在本文中,接收信号 $r(t)$ 通过采样速率 $f_s = 1/T_s$ 转换为离散信号 $r_n = r(nT_s)$ 。离散信号 r_n 经正交解调由同相分量 r_I 和正交分量 r_Q 组成,其一般表达式如下所示:

$$r_n = r_I(n) + jr_Q(n) \quad (2)$$

假设每条信号采样有 N 个采样点,则可以表示为一个长度为 N 的数据向量,第 m 条数据向量为:

$$r_m = [r(0), r(1), \dots, r(N-1)]^T \quad (3)$$

其中, T 表示转置运算符。这些数据向量携带着相关调制类型的信息。



图1 通信流程图

Fig. 1 Communication flow chart

1.2 信号预处理

信号预处理包括对信号进行分析和转换,以获得更好的信号表示。为了减少复杂特征工程的工作,同时直接从原始信号中学习信号的原始特征,本文采用两种基本的信号表示方法:一种是利用原始信号的同相和正交分量表征信号,即 r_I 和 r_Q ;另一种是采用基于原始信号的幅度和相位信息表示信号,即 r_A 和 r_P 。

利用正交分量 r_I 和同相分量 r_Q 提取信号的幅度 r_A 和相位 r_P ,如式(4)和式(5)所示:

$$r_A = \sqrt{r_I^2 + r_Q^2} \quad (4)$$

$$r_P = \tan^{-1}(r_Q/r_I) \quad (5)$$

为了直观地观察不同的信号表示,本文采用具有相同调制信号模型的开源数据集 RadioML2016_10a,以 8PSK, QAM16, AM-SSB 为例,分别给出 3 类调制信号在 18dB 情况下的两种信号表征,如图 2 所示。

2 多模态特征融合模型

在自动调制识别领域,现有的调制分类方法大多忽略了不同特征之间的互补性和特征融合的重要性。针对这些缺陷,本文提出多模态融合方法,1.2节介绍了调制信号的 I/Q 和 A/P 两种特征表达,本节将介绍如何提取 I/Q 信号的空间特征和 A/P 信号的时序特征,以及如何将两种特征进行融合并进行分类识别的方法。

2.1 A/P 信号时序特征提取

CNN 能够提取抽象特征,有效地减少频率分量和无效数据;LSTM 擅长处理时间相关的问题,可以对时间序列进行建模。将这两种网络按 CNN-LSTM 的顺序组合在一起形成卷积长短期记忆模块 (Convolution Long-Short Term Memory Block, CLB),也即时序特征提取模块,如图 3 所示,首先通过 CNN 提取时间维度上高质量的隐藏信息,然后将这些信息传递给 LSTM 网络进行时序建模,提取信号的高维时序特征。




图 3 时序特征提取模块

Fig. 3 Timing feature extraction module

为了利用时序特征提取模块提取信号的时序特征,对 CNN 和 LSTM 进行网络构建,如图 4 所示,整体结构由 2 部分组成:4 层卷积层,1 层 LSTM 层。首先利用第 2 节中从 I/Q 信号中提取的维度为 2×128 的 AP 数据作为网络的输入数据,然后经 4 层卷积层提取高维度的抽象特征,接着将卷

积层提取的特征经 LSTM 层提取数据的时序特征。




图 4 时序特征提取模块结构图

Fig. 4 Structure diagram of timing feature extraction module

2.2 I/Q 信号空间特征提取

在传统 CNN 网络对于调制信号的识别方法中,一般随着网络深度的增加,网络提取特征的能力将逐渐增强,识别效果也会逐渐提高,但是事实上随着网络达到一定深度,效果会变差。出现这种现象的原因是由于网络堆叠的层数过多,当反向传播更新权重、偏置以及损失函数时,会导致梯度消失。因此为了在加深网络的同时解决梯度消失的问题,本文首先利用不同网络层之间特征的互补性,对卷积层以密集连接的方式形成密集卷积模块,将上一层提取到的特征输入到下一层提取更加抽象和全面的特征。同时,在密集卷积模块内部采用快捷连接的残差卷积模块,将提取到的浅层特征和残差特征进行融合,得到深层特征。进一步,由于在调制信号识别领域,I/Q 信号在复平面存在特定的结构特征,I/Q 调制分类是一个独特的模式识别问题,因此本文采用线性组合的方式在实值框架中实现复数卷积的运算,提取 I/Q 信号更加丰富的信息。模型整体结构如图 5 所示。以 I/Q 信号作为模型的输入,利用一层卷积层提取信号的浅层特征,然后利用 3 个复数密集残差卷积模块提取信号的深层特征,复数密集残差卷积模块之间由过渡层进行连接,最后得到空间特征输出。

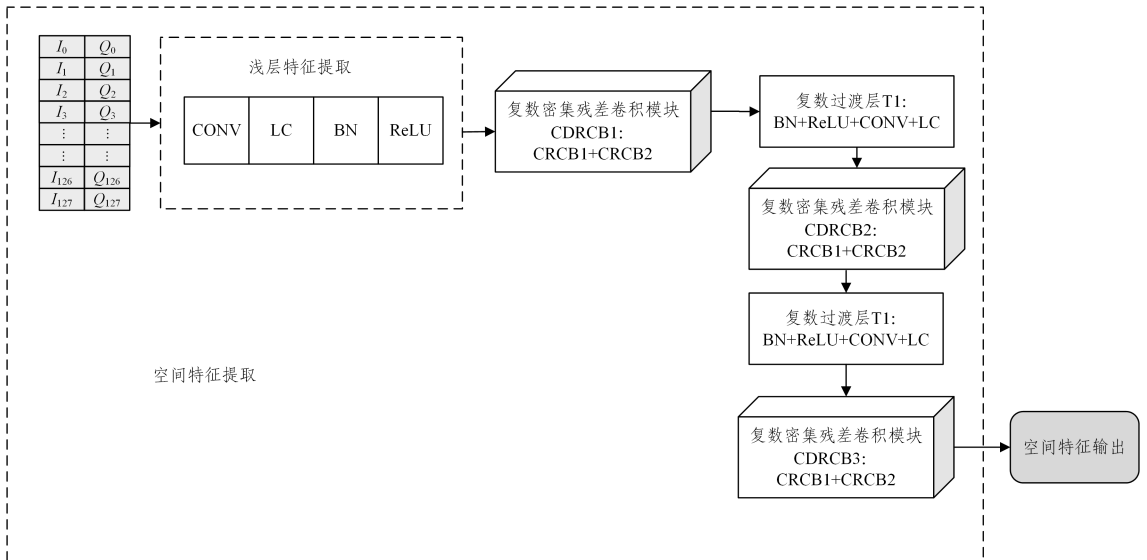


图 5 复数密集残差网络对 I/Q 信号的识别结构

Fig. 5 Identification structure of complex dense residual network for I/Q signal

如图 5 所示,模型由 3 个复数密集残差卷积模块 (Complex Dense Residual Convolution Block, CDRCB) 提取信号的深层特征,其中每一个复数密集残差卷积模块由两个复数残差卷积模块 (Complex Residual Convolution Block, CRCB) 组成,如图 6 所示。为了多次利用每个 CRCB 模块输出的信息,加强 CDRCB 模块提取特征的能力,CRCB 模块之间采用

密集连接的方式将前面所有层的特征作为下一层的输入,最大程度地传递特征。设第 n 个 CRCB 模块的输出为 $x_{res(n)}$, $[x_{res(0)}, x_{res(1)}, \dots, x_{res(n-1)}]$, 其代表第 n 个 CRCB 模块的所有特征输入,可由式 (6) 来表示它们之间的关系。其中 $w_{res(n)}$ 和 $b_{res(n)}$ 分别是卷积层的权重和偏置,‘*’代表卷积运算。

$$x_{res(n)} = \max(0, \omega_{res(n)} * [x_{res(0)}, x_{res(1)}, \dots, x_{res(n-1)}]) + b_{res(n)}, n=2 \quad (6)$$




图 6 CDRCB 结构图
Fig. 6 CDRCB structure diagram

CRCB 之间采用密集连接的方式充分利用了每个 CRCB 模块输出的信息。进一步地,为了在加深网络的同时解决梯度消失的问题,CRCB 内部有 5 个基本复数残差块(Basic Complex Residual Block,BCRB),BCRB 采用快捷连接方式改变梯度的流向,通过跳过两个复数卷积层实现输出与输入特征数据之间的残差映射,结构如图 7 所示,其中 Conv 是卷积运算,LC 是线性组合函数,Conv 与 LC 组合成复数卷积模块,BN 以及 ReLU 分别代表批归一化和激活函数。 x_{m-1} 和 x_m 分别是上个 BCRB 模块的输出和下个 BCRB 模块的输入, $F(\cdot)$ 表示复数残差特征映射函数, x_{m-1} 的梯度通过快捷连接连接到 x_m ,它们之间的关系如下所示:

$$x_m = F(x_{m-1}) + x_{m-1} \quad (7)$$




图 7 BCRB 结构图
Fig. 7 BCRB structure diagram

如图 7 所示,Conv 和 LC 模块通过线性组合的方式在实值深度学习框架中实现复数卷积的运算。具体实现如下所示,首先假设一个二维 I/Q 复数信号为 $Z_n (n \in 1, 2 \dots N)$,定义如下所示:

$$Z_n = I_n + iQ_n, I_n, Q_n \in \mathbb{R} \quad (8)$$

其中, I_n 和 Q_n 分别是 Z_n 的同相分量和正交分量,在深度学习框架中作为卷积层的输入,输入的数据格式为 $2 \times N$ 矩阵,

$$\begin{bmatrix} I^*R & I^*V + Q^*R \\ I^*R & I^*V + Q^*R \end{bmatrix} \times \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ -1 & 0 \end{bmatrix} = \begin{bmatrix} I^*R - Q^*V & I^*V + Q^*R \end{bmatrix} \leftarrow \begin{bmatrix} I_n^*R_n - Q_n^*V_n + i(I_n^*V_n + Q_n^*R_n) \end{bmatrix} \begin{bmatrix} C_{2D} & C_{1D} \end{bmatrix}$$

图 8 二维实值卷积运算实现一维复数卷积运算结构图

Fig. 8 Structure diagram of one-dimensional complex convolution operation realized by two-dimensional real value convolution operation

通过图 8 的线性运算,对密集残差结构的卷积层进行线性组合后便可以在实值深度学习框架中实现复数卷积的运算,进而形成复数密集残差模块 CDRN 提取 I/Q 信号的空间特征。

2.3 多模态特征融合

为利用不同特征之间的互补性,弥补单一特征识别的不足,对同一信号的不同特征表达进行融合,如图 9 所示。首先,将 CNN 与 LSTM 串联搭建时序特征提取模块,提取 A/P 信号的时序特征,同时利用复数密集残差网络 CDRN 提取 I/Q 信号的空间特征;然后,将两个模型提取的信号特征输入特征融合层进行特征融合;最后,将融合后的特征经全连接层进行分类识别。

具体形式如式(9)所示:

$$\begin{bmatrix} I_0 & Q_0 \\ I_1 & Q_1 \\ I_2 & Q_2 \\ \dots & \dots \\ I_N & Q_N \end{bmatrix} \quad (9)$$

假设另一个复数信号 $W_m (m \in 1, 2 \dots M)$ 作为深度学习框架中卷积运算中的卷积核,定义如下所示:

$$W_m = R_m + iV_m, R_m, V_m \in \mathbb{R} \quad (10)$$

其中, R_m 和 V_m 分别是 W_m 的实部和虚部,也即深度学习模型中的权重参数。在深度学习框架中,卷积核充当卷积运算的滑动窗口,与输入数据进行卷积运算,存储形式如式(11)所示:

$$\begin{bmatrix} V_0 & R_0 \\ V_1 & R_1 \\ V_2 & R_2 \\ \dots & \dots \\ V_M & R_M \end{bmatrix} \quad (11)$$

在数学体系下,复数输入数据 Z_n 与复数卷积核 W_m 的卷积运算,即式(8)与式(10)的卷积运算如式(12)所示:

$$C_{1D} = Z_n * W_m = (I_n * R_m - Q_n * V_m) + i(I_n * V_m + Q_n * R_m) \quad (12)$$

而在深度学习框架中,在没有实现复数运算的卷积模块下,零填充之后的复数输入数据 Z_n 与复数卷积核 W_m 的矩阵卷积运算,即式(8)与式(10)的二维矩阵卷积运算如式(13)所示:

$$C_{2D} = \begin{bmatrix} 0 & I_0 & Q_0 & 0 \\ 0 & I_1 & Q_1 & 0 \\ 0 & I_2 & Q_2 & 0 \\ \dots & \dots & \dots & \dots \\ 0 & I_N & Q_N & 0 \end{bmatrix} * \begin{bmatrix} V_0 & R_0 \\ V_1 & R_1 \\ V_2 & R_2 \\ \dots & \dots \\ V_M & R_M \end{bmatrix} = [I^*R \ I^*V + Q^*R \ Q^*V] \quad (13)$$

如图 8 所示,通过线性组合,将等式(13)右侧矩阵的第一列减去第三列作为一维复数卷积运算的实部,第二列直接作为虚部来实现一维复数卷积的结果。

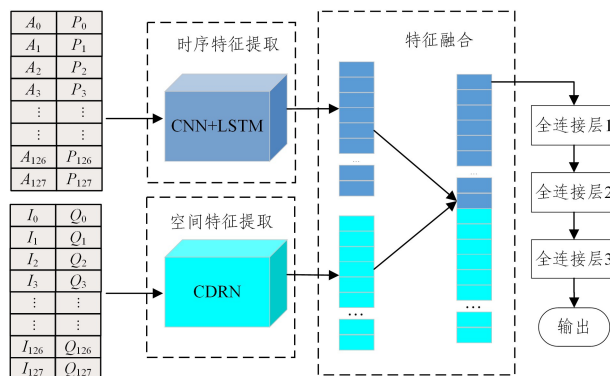


图 9 多模态特征融合结构

Fig. 9 Multimodal feature fusion structure

3 实验及结果分析

实验使用开源数据集 RadioML2016.10a 评估提出的调制识别模型。RadioML2016.10a 包括模拟和数字调制方式,包括通信系统中常用的 11 种调制方式,即 8PSK, AM-DSB, AM-SSB, BPSK, CPFSK, GFSK, PAM4, QAM16, QAM64, QPSK 和 WBFM。该数据集包括 220 000 个调制信号,具有 20 种不同的信噪比(SNR),范围从 -20 dB 到 18 dB,步长为 2,每种调制模式每信噪比有 1 000 个信号。数据集中的每个信号都由 2×128 的 IQ 信号组成。为了模拟实际的无线电通信环境,RadioML2016.10a 是在恶劣的模拟传播条件下产生的,包括加性高斯白噪声(AWGN)、多径衰落、采样率偏移和中心频率偏移。本文实验将数据集按 8:2 的比例划分为训练集和测试集,并基于 PyTorch 深度学习框架构建多模态融合模型,选取 Adam 作为优化器进行特征融合实验,分别对数据集进行训练和测试。特征融合实验主要分 3 步:(1)特征提取;(2)模型融合;(3)分类识别。其中,特征提取部分首先获取数据集的 I/Q 信号,并通过 I/Q 信号获取 A/P 信号;模型融合部分为 3 步融合策略,第一步是搭建时序特征提取模块 CLB 提取 A/P 信号的时序特征,第二步是搭建空间特征提取模块 CDRN 提取 I/Q 信号的空间特征,第三步是将提取的深层时序特征和空间特征进行融合。为了探究多模态融合的性能,进行对比实验,分类识别部分将分别对 CLB 提取的时序特征、CDRN 提取的空间特征和融合特征进行分类识别。

3.1 融合模型识别实验及性能分析

为了探究不同融合模型对于调制信号的识别性能,实验采用 3 步融合策略搭建了 CLB 模型对调制信号的 A/P 特征进行特征提取和识别,搭建了 CDRN 模型对调制信号的 I/Q 特征进行特征提取和识别,以及融合两个模型提取的特征进行多模态融合特征分类实验。如图 4 所示,CLB 模型由 CNN 和 LSTM 依次连接而成,为分析 CLB 相对于各子模型对时间序列信号的识别性能,利用划分好的训练集分别对 CNN, LSTM, CLB 模型进行训练,然后利用测试集分别进行测试,评估模型分类性能。如图 6 所示,CDRN 模型融合了密集连接结构和残差结构,并使用了复数卷积运算,为分析 CDRN 模型对于残差网络、密集连接网络以及没有采用复数卷积运算的密集残差网络的识别性能,利用划分好的训练集分别对 ResNet, DenseNet, Dense ResNet, CDRN 模型进行训练,然后利用测试集分别进行测试,评估模型分类性能。同时,为分析

融合特征相对于单一特征的识别性能,将 CLB 提取的时序特征和 CDRN 提取的空间特征进行融合并输入分类器进行识别。各模型对于测试集的总体识别率结果如图 10 所示。




图 10 融合模型及其子模型的总体识别率
Fig. 10 Overall recognition rate of fusion model and its sub models

从图 10 可以看出,MMF 模型的整体识别率与 CLB 和 CDRN 模型相比,分别高出 2% 和 4%,而 CLB 和 CDRN 模型的整体识别率相对于各自的子模型要高出 3%~10%。同时,为分析融合模型及其各子模型在不同信噪比下对信号的识别效果,将测试集各个信噪比下的调制信号输入到模型当中进行识别,实验结果如图 11 所示。




图 11 不同信噪比下融合模型及其子模型的识别率
Fig. 11 Recognition rate of fusion model and its sub model with different signal-to-noise ratio

从图 11 可以发现,一方面融合模型和各子模型的识别率都随着信噪比的增加而呈现上升的趋势;另一方面,融合模型在不同信噪比下的识别性能都要优于各自的子模型,在高信噪比下,当信噪比大于 5 dB 时,各模型的识别率如表 1 所列,MMF 模型的识别率达到 93.25%,与 CLB 和 CDRN 模型相比较,约高出 3%~4%;CLB 模型的识别率为 89.67%,与其子模型 CNN 和 LSTM 模型相比较,约高出 5%~6%;CDRN 模型的识别率为 90.63%,与其相关的子模型 ResNet, DenseNet 和 Dense ResNet 相比较,要高出 5%~11%。

表 1 信噪比大于 5 dB 时各模型的识别率

Table 1 Recognition rate of each model when signal-to-noise ratio is greater than 5 dB
(单位:%)

模型	CNN	LSTM	CLB	ResNet	DenseNet	Dense ResNet	CDRN	MMF
识别率	83.30	84.86	89.67	79.39	84.36	85.77	90.63	93.25

如图 12(a) 所示,MMF 模型由于融合了 CLB 提取的 A/P 信号时序特征和 CDRN 提取的 I/Q 信号空间特征,无论是整体识别率还是不同信噪比下的识别率,都要优于 CLB 和 CDRN 模型。

如图 12(b) 所示,CLB 模型经过 CNN 和 LSTM 两步提取特征的方式,特征空间的区分度更加明显,识别性能要优于

CNN 和 LSTM。

如图 12(c) 所示,与 CLB 模型类似,从 CDRN 及其各子模型的实验结果来看,密集连接以及残差连接的融合模型 Dense ResNet 的识别效果要优于没有融合的效果。进一步分析,在 Dense ResNet 模型的基础上将原来的实值卷积运算通过线性组合的方式实现复数卷积运算,识别性能显著增加。




图 12 3 种融合模型与其子模型的对比

Fig. 12 Comparison of three fusion models and their sub models

3.2 高信噪比下各类调制信号的识别性能分析

由 3.1 节实验可知,无论是整体识别率还是不同信噪比下的识别率,MMF 模型都优于 CLB 和 CDRN 模型。在此实验基础上,为探究 MMF 融合模型对于各类调制信号的分类性能,进一步绘制了模型在 10 dB 信噪比下的混淆矩阵,如图 13 所示,横坐标代表真实标签,纵坐标代表预测标签,真实标签与预测标签交叉对应的区域为分类的混淆矩阵,模型对于 8 种数字调制信号基本实现了 100% 的识别。进一步分析,由于 3 种模拟信号之间时域特征和空间特征比较相似,对于 AM-SSB 以及 WBFM 信号,模型主要将其与 AM-DSB 信号发生了混淆,符合实际情况。




图 14 实际采集数据在不同模型下的识别率对比

Fig. 14 Comparison of recognition rate of actual collected data in different models

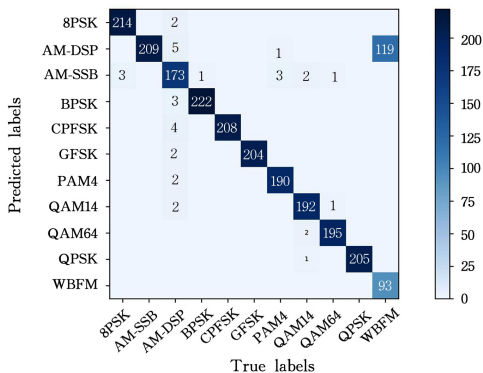


图 13 MMF 融合模型在 10 dB 信噪比下的混淆矩阵

Fig. 13 Confusion matrix of MMF fusion model at 10 dB signal-to-noise ratio

3.3 调制信号采集与识别


为进一步验证 MMF 模型性能,用软件无线电设备采集常见的调制信号进行识别,识别信号类型为: AM, FM, 2ASK, BPSK, QPSK, 8PSK, 2FSK, 4FSK, 16QAM 和 64QAM。发射端采用矢量信号发生器 VSG60A 作为信号源,发射功率为 -5 dbm,信噪比为 0 dB 以及符号速率为 1 MHz 时,分别发射 400 M, 800 M, 1.2 G, 1.6 G 以及 2 G 频段的信号;接收端采用 SAM-60 MK2 作为接收机接收信号,接收信号在非合作情况下,在空旷的密闭环境中进行。实际采集时,每个频段采集 1 000 个样本,每类调制信号总共 5 000 个样本,并按 7:3 的比例划分为训练集和测试集。实际测试时,将测试集分别输入传统模型(SVM, CNN)以及本文所提模型(CLB, CDRN, MMF)中进行识别。识别结果如图 14 所示,本文所提出的 MMF 模型的识别性能都要优于各自的子模型,并且相比于传统的 SVM 与 CNN 模型,识别率高出 20%~30%。

结束语 在深度学习的基础上,本文提出了一种基于多模态特征融合方法来解决通信信号调制识别问题。搭建并行支路特征提取模块提取 A/P 信号的时序特征和 I/Q 信号的空间特征,并将两种不同模式之间的特征串联融合,最后将融合后的特征输入分类网络,获得识别结果。实验表明,在完整的开源数据集 RadioML2016.10a 上,本文提出的方法可以充分利用不同模态特征之间的互补性,提高不同信噪比下的识别准确率,在信噪比大于 5 dB 时,识别率达到 93.15%,与单模态相比提高了 3%~11%;进一步利用软件无线电设备采集调制信号进行识别,识别性能优于传统的识别模型以及单一特征提取方法,验证了本文所提特征提取模型和融合方法的有效性。

参考文献

- [1] ZENG Y, ZHANG M, HAN F, et al. Spectrum Analysis and Convolutional Neural Network for Automatic Modulation Recognition [J]. IEEE Wireless Communication Letters, 2019, 8(3): 929-932.
- [2] WANG Y, LIU M, YANG J, et al. Data-Driven Deep Learning for Automatic Modulation Recognition in Cognitive Radios [J]. IEEE Transactions on Vehicular Technology, 2019, 68(4): 4074-4077.
- [3] HAZZA A, SHOAB M, ALSHEBEILI S A, et al. An overview of feature-based methods for digital modulation classification [C]//2013 1st International Conference on Communications, Signal Processing, and their Applications (ICCSIPA). IEEE, 2013: 1-6.
- [4] ZENG C Z, JIA X. Modulation recognition method of communication signals based on correlation characteristics [C]//IEEE International Conference on Signal Processing. IEEE, 2015: 1-5.
- [5] ZHANG X, GE T, CHEN Z. Automatic Modulation Recognition of Communication Signals Based on Instantaneous Statistical

- Characteristics and SVM Classifier[C]//IEEE Asia-Pacific Conference on Antennas and Propagation, 2018:344-346.
- [6] SWAMI A, SADLER B M. Hierarchical digital modulation classification using cumulants [J]. IEEE Trans Commun, 2000, 48(3):416-429.
- [7] WU X, ZHANG J, HOU C, et al. Signal Modulation Recognition based on Convolutional Autoencoder and Time-Frequency Analysis[C] // 2021 8th International Conference on Dependable Systems and Their Applications(DSA), 2021:664-668.
- [8] PENG S L, JIANG H Y, WANG H X, et al. Modulation classification based on signal constellation diagrams and deep learning [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 30(3):718-727.
- [9] YU X, LI L, YIN J, et al. Modulation Pattern Recognition of Non-cooperative Underwater Acoustic Communication Signals Based on LSTM Network[C]//2019 IEEE International Conference on Signal, Information and Data Processing (ICSIDP). IEEE, 2019.
- [10] WANG Y. Kernel Cross-Modal Factor Analysis for Information Fusion With Application to Bimodal Emotion Recognition[J]. IEEE Transactions on Multimedia, 2012, 14(3):597-607.
- [11] LIU W, ZHENG W L, LU B L. Emotion Recognition Using Multimodal Deep Learning [C] // Neural Information Processing; 23rd International Conference (ICONIP 2016), 2016:521-529.
- [12] SIMONYAN K, ZISSERMAN A. Two-stream convolutional networks for action recognition in videos[C]//Advances in Neural Information Processing Systems, 2014:568-576.



YANG Xiaomeng, born in 1996, post-graduate. His main research interests include modulation recognition and deep learning.



ZHANG Tao, born in 1988, Ph.D, associate researcher. His main research interests include wireless sensor networks, machine learning and physical layer security.