

文章编号: 2095-4980(2022)12-1326-09

基于多模态深度学习的信号调制识别

冯忠明, 王景岩, 李奎贤*

(哈尔滨工程大学 信息与通信工程学院, 黑龙江 哈尔滨 150001)

摘 要: 信号调制识别技术在民用和军事领域都有重要应用。当前信息化战场中, 由于各类雷达、通信、导航、电子战武器等信息辐射源的数量愈来愈多, 调制形式也日益多样化, 信号密度愈来愈大, 战争电磁环境日趋复杂化, 传统的信号调制识别技术已无法适应。因此, 提出基于深度学习的 AlexNet 网络和复数神经网络, 同时采用多模态特征融合和模型融合技术, 融合信号统计图域和信号 I/Q 波形域的多模态信息, 实现信号调制识别。仿真结果表明, 所提方法的识别精确度在不同信噪比下均优于单模态识别方法和未采用多模态协同融合框架的方法。

关键词: 调制信号识别; 深度学习; 多模态特征; 模型融合

中图分类号: TN911.2

文献标志码: A

doi: 10.11805/TKYDA2022036

Signal modulation recognition based on multimodal depth learning

FENG Zhongming, WANG Jingyan, LI Kuixian*

(College of Information and Communication Engineering, Harbin Engineering University, Harbin Heilongjiang 150001, China)

Abstract: Signal modulation identification technology has important applications in both civilian and military fields. In the current information battlefield, due to the increasing number of information radiation sources such as various radars, communications, navigation, and electronic warfare weapons, the modulation forms are becoming more and more diverse, and the signal density is increasing, which makes the electromagnetic environment of war increasingly complicated, therefore the traditional signal modulation identification technology has been unable to adapt. A robust feature extraction, fusion and recognition technology of complex communication modulation signals is put forward, and a deep learning-based AlexNet network and complex neural network are proposed. Multimodal information in the statistical graph domain and signal I/Q waveform domain is fused for signal modulation identification. The simulation results show that the recognition accuracy of the proposed method is higher than that of the single-modal recognition method and the method without the multi-modal collaborative fusion framework under different Signal-to-Noise Ratios(SNRs).

Keywords: modulation signal recognition; deep learning; multi-modal features; model fusion

随着现代信息技术不断发展, 经济发展、社会安全和人民生活对电磁空间的依赖程度越来越高, 通信信号是电磁空间中承载信息的载体, 是实现信息无线交互的重要途径^[1-2]。在军工与民用工程范畴中, 信息调制识别技术都发挥了巨大的作用, 如在电子对抗中, 为了对敌方实施有效的干扰, 需要提前侦察到敌方所使用的信号辐射源。当前的信息化战争中, 由于各类雷达、通信、导航、电子战武器等辐射源的数量愈来愈多, 调制形式也越来越多样化, 信息密度愈来愈大, 导致电磁环境问题越来越复杂, 传统的信号识别技术已经无法适应日趋复杂的战争电磁环境。因此, 探索一种更有效的信号调制识别方法是十分重要和紧迫的^[3]。近年来, 随着人工智能的不断发展, 深度学习技术在很多领域已引起了广泛关注, 深度学习也成为信号调制识别领域的一个研究热点^[4-5]。通过模式识别和特征表达等优点, 能够提高模型的识别性能。基于图像识别网络模型的调制识别方法的大致思想是: 把调制识别任务转化为图像识别任务, 最后采用深度学习模型中的图像识别网络处理调制识别任务。这种计算流程第一步是对所有输入数据进行预处理, 把原始信息转换为某种人为选择的图像数据, 通常情

收稿日期: 2022-02-13; 修回日期: 2022-03-04

基金项目: 中央高校基本科研业务费资助项目(3072022CF0804); 哈尔滨工程大学先进船舶通信与信息技术工业和信息化部重点实验室资助

*通信作者: 李奎贤 email:kuixianli@hrbeu.edu.cn

形下都是图像的二维数据，如时频图^[6]、循环谱^[7]、星座图^[8]等。PENG S 等^[8]使用信号数据转换方法，将原始信号数据分别转化成灰度图像、增强灰度图像和三通道图像。LIN Yun 等^[9]提出一种将原始信号转换为具有统计显著性的图像框架，称为等势星球图(Contour Stellar Image, CSI)，可以将原始无线信号波形中的深层统计信息以图像数据格式表示出来。

当前，用于深度学习模型的大多数体系结构和基本模块都是以实数进行操作和表示的。然而近年来，一些学者针对递归神经网络进行的研究表明，复数在某些情况下具有更优异的代表能力^[10]。信号相位中的信息量足以恢复大部分以幅度编码的信息^[11-12]，因此大多数通信模型都倾向于采用复数信号来表示其幅度和相位信息。TU Ya 等^[13]提出了将深度复数网络用于信号调制识别领域，并介绍了复数神经网络中的关键模块，如复数卷积层、复数批量归一化等，实验证明，复数网络的性能优于信号调制识别中的实数网络。然而大多数现有的基于深度学习的信号调制识别方法^[14-15]仅使用来自单一维度的单模态信息，这些方法的共同缺点是没有合理利用现有的多模态信息，忽略了它们之间的互补性^[16-17]。为了解决这个问题，多模态技术^[18-19]已被应用于信号调制识别领域。本文提出一种基于多模态深度融合框架的信号调制识别方法，将多模态特征融合模型和等势星球图域以及 I/Q 波形域这两种单模态模型的融合目标用一个损失函数表示，从而保持了模态间和模态内的相似性结构。

1 信号模型

采用的信号模型如图 1 所示，其中， $\{b_k\}$ 为信源产生的二进制序列， $r(t)$ 为接收到的信号，可表示为：

$$r(t) = s(t) * h(t, \tau) e^{j(2\pi\Delta f t + \phi(t))} + n(t) \quad (1)$$

式中： $s(t)$ 为被传输的基带调制信号； $n(t)$ 为高斯白噪声； Δf 为经过粗略变频之后产生的频偏； $\phi(t)$ 为信号的相位偏移； $h(t, \tau)$ 为无线信道时变脉冲响应，它的一般表达式为：

$$h(t, \tau) = \sum_{l=0}^L \alpha(t, \tau_l) e^{j2\pi f_c \tau_l(t)} \delta(t - \tau_l) \quad (2)$$

式中： l 为路径的数量； $\alpha(t, \tau_l)$ 为多径衰落； τ_l 为路径延迟。

假设每一个信号都有 N 个采样点，则每一个信号可以表示成一个长度为 N 的数据向量，其中第 j 个数据向量为：

$$\mathbf{r}_j = [r(0), r(1), \dots, r(N-1)]^T \quad (3)$$

用 $\mathbf{C}$ 和 $\mathbf{R}$ 分别表示复数集和实数集，由于数据向量 $\mathbf{r}_i \in \mathbf{C}^N$ 含有调制类型的信息，因此也可以看作特征向量 $\mathbf{x}_i \in \mathbf{R}^N$ 。

2 信号预处理

大多数现有的信号调制识别方法都是基于单一描述维的单模态信息，忽略了电磁信号多模态信息之间的互补性。本文研究了信号 I/Q 波形域和统计图的两种模态表示方法。利用信号多模态数据之间的相关性，消除多模态数据之间的冗余，学习一种更准确的数据特征表示方法。

2.1 信号 I/Q 波形域

接收信号 $r(t)$ 被转换成一个离散信号 $r[n]$ ，采样率 $f_s = 1/T_s$ ，它由同相分量 $r^I \in \mathbf{R}$ 和正交分量 $r^Q \in \mathbf{R}$ 组成，因此离散信号 $r[n]$ 可描述为：

$$r[n] = r^I[n] + jr^Q[n] \quad (4)$$

假设在一个采样周期内总共可以收集 N 个样本，且样本 $r[n] \in \mathbf{C}, n = 0, 1, \dots, N-1$ 可视为数据向量。将第 j 个数据向量写成：

$$\mathbf{r}_j = [r_j[0], r_j[1], \dots, r_j[N-1]]^T \quad (5)$$

第一种模态是信号的 I/Q 复数波形域序列模态，由接收到的复数离散信号 $r[n]$ 的实部和虚部构成。信号的第 i




Fig.1 Schematic diagram of the signal model
图 1 信号模型示意图

个采样点 x_i 的 I/Q 向量定义为:

$$\mathbf{x}_i^{IQ} = \begin{bmatrix} x_i^I \\ x_i^Q \end{bmatrix} \quad (6)$$

式中: $x_i^I = \text{Re}[r[n]]$; $x_i^Q = \text{Im}[r[n]]$ 。

2.2 信号等势星球图域

信息以电磁波形的形式传输, 并作为数字调制系统中的一系列采样点, 由接收器接收并捕获信息。数字调制系统的特征可以由信号的星座图(Constellation Diagrams, CD)表示。一个信号的 CD 图可看做是复数坐标轴上点的集合, 如图 2 所示。等势星球图(Contour Stellar Image, CSI)是在星座图的基础上, 为增强星座图中点密度的信息而转化的。

针对星座图中不同区域、不同采样点的密度不同的特性, 利用一个大小为 $W \times H$ 的矩形密度窗函数在星座图上滑动, 并同时统计每个区域窗口中采样点的数量。定义一个度量点密度(dot density)来表示有多少样本点位于复值平面窗口中, 设矩形窗口在复平面上的中心坐标为 (i, j) , 可以得到归一化的点密度值:

$$\rho_{(W,H)}(i,j) = \frac{\text{dots}(W,H)^{(i,j)}}{N} \quad (7)$$

式中: $\text{dots}(W,H)^{(i,j)}$ 为矩形窗口内点的个数; N 为信号 I/Q 波形的长度。

将不同区域的点密度 CD 映射为不同的颜色, 得到具有 RGB 三通道信息的等势星球图, 如图 3 所示。CD 是一种二进制图像, 并不区分采样点数的密度图像。相比之下, CSI 中的 RGB 三通道颜色表现出无线通信的更多细节, 它可以表征星座图中点密度的信息, 并提供细粒度特征。即使在噪声干扰下, 仍保留信号统计信息的特征。




Fig.2 Constellation diagram of complex domain signal
图2 复数域信号的星座图




Fig.3 Process of converting a CD to a CSI
图3 CD转为CSI的过程

3 基于多模态深度学习的信号调制识别方法

为了有针对性地提取原始信号的以上两种模态的深层特征, 对于等势星球图域的模式, 采用常用于图像分类问题的 AlexNet 网络作为特征提取器; 针对原始信号的 I/Q 复数波形域序列模式, 采用深度复数神经网络作为

特征提取器。

3.1 基于 AlexNet 网络的信号图域特征提取

AlexNet 由 Alex Krizevsky 于 2012 年提出, 由 5 个卷积层和 3 个全连接层组成, 包括 6 000 万个连接、6 000 万个参数和 65 万个神经元, 其输入数据的大小为 $227 \times 227 \times 3$ 。采用基于迁移学习的 AlexNet 网络作为特征提取器, 具体的, 将原始 AlexNet 网络的基本模型架构迁移到信号调制识别领域^[20]。为了适应本文所使用的数据集大小, 仅将原始 AlexNet 网络的第 8 层全连接层数由原来的 4 096 个神经元改为 1 024 个神经元, 其他结构与原始 AlexNet 网络保持一致。其输入是大小为 $227 \times 227 \times 3$ 的 RGB 三通道等势星球图, 最后第 8 层全连接层的输出作为提取出的大小为 1 024 的信号等势星球图的深层特征, 其提取过程如图 4 所示。




Fig.4 Feature extraction process of AlexNet network based on transfer learning

图4 基于迁移学习的 AlexNet 网络特征提取过程

3.2 基于复数网络的信号 I/Q 波形域特征提取

当前, 主流的深度学习技术和体系结构都是采用实数进行操作以及表示的。近年来, 一些基础理论结果分析显示, 在某些情况下, 复数具有更丰富的表示能力, 尤其是在信号调制识别领域, 因为原始信号数据是复数形式的。由于信号多以 I/Q 复数形式出现, 调制信号的相位信息也可以表征信号的时域特征, 因此具有表达和处理复数形式的网络对于提高信号调制识别率有一定帮助。本文将复数神经网络作为信号 I/Q 波形域模态的特征提取器, 复数神经网络的基本构造块的实现, 包括复数卷积核、复数批归一化、复数密集块。

3.2.1 复数卷积核

为了在复数域中模拟传统实数 2D 卷积的运算过程, 可以通过使用复数向量 $\mathbf{h} = \mathbf{x} + \mathbf{j}\mathbf{y}$ 对复数滤波器矩阵 $\mathbf{W} = \mathbf{A} + \mathbf{j}\mathbf{B}$ 进行卷积处理, 达到通过使用实数来模拟复数的运算目的。式中 $\mathbf{A}$ 和 $\mathbf{B}$ 为实矩阵, $\mathbf{x}$ 和 $\mathbf{y}$ 为实向量。由于卷积算子为分布式的, 通过滤波器 $\mathbf{W}$ 对向量 $\mathbf{h}$ 进行卷积, 可得:

$$\mathbf{W} * \mathbf{h} = (\mathbf{A} * \mathbf{x} - \mathbf{B} * \mathbf{y}) + \mathbf{j}(\mathbf{B} * \mathbf{x} + \mathbf{A} * \mathbf{y}) \quad (8)$$

神经网络实现复数卷积运算的过程如图 5 所示, 其中 M_I, M_R 表示虚部和实部特征图, K_I 和 K_R 表示虚核和实核。 $M_I K_I$ 为虚核 K_I 与虚特征图 M_I 之间的实数卷积的结果。




Fig.5 Neural networks implement complex convolution operations

图5 神经网络实现复数卷积运算

3.2.2 复数批归一化

批归一化方法的目的是为了加速深度学习的学习，对于优化模型非常重要。可以将此问题看作为一个二维向量的问题，即可以根据 2 个主分量的方差的平方根来缩放数据。这一步骤可以通过将以“0”为中心的数据 $(\mathbf{x} - E[\mathbf{x}])$ 乘以 2×2 协方差矩阵 V 的平方根的倒数来完成：

$$\tilde{\mathbf{x}} = (V)^{-\frac{1}{2}} (\mathbf{x} - E[\mathbf{x}]) \quad (9)$$

协方差矩阵 V 为：

$$V = \gamma \begin{bmatrix} \text{Cov}(\Re\{\mathbf{x}\}, \Re\{\mathbf{x}\}) & \text{Cov}(\Re\{\mathbf{x}\}, \Im\{\mathbf{x}\}) \\ \text{Cov}(\Im\{\mathbf{x}\}, \Re\{\mathbf{x}\}) & \text{Cov}(\Im\{\mathbf{x}\}, \Im\{\mathbf{x}\}) \end{bmatrix} \quad (10)$$

式中： γ 为缩放参数矩阵； $\text{Cov}(\cdot, \cdot)$ 为 2 个向量变量的协方差。

归一化过程可以去除虚部和实部的关联性，减少了模型过度拟合的风险。与实数批归一化算法相似，使用 2 个参数 β 和 γ 。移位参数 β 为一个复数参数；缩放参数 γ 为 2×2 半正定矩阵，只有 3 个自由度，因此只有 3 个可学习的部分。缩放参数 γ 为：

$$\gamma = \begin{bmatrix} \gamma_{rr} & \gamma_{ri} \\ \gamma_{ir} & \gamma_{ii} \end{bmatrix} \quad (11)$$

由于归一化输入 $\tilde{\mathbf{x}}$ 具有方差为 1 的实部和虚部，将 γ_{rr} 和 γ_{ii} 都初始化为 $1/\sqrt{2}$ ，使归一化值的方差模数为 1。 γ_{ri} 、 $\Re\{\beta\}$ 和 $\Im\{\beta\}$ 初始化为 0，而复数批归一化可表示为：

$$\text{BN}(\tilde{\mathbf{x}}) = \gamma \tilde{\mathbf{x}} + \beta \quad (12)$$

3.2.3 复数密集层

密集层通常作为神经网络的分类器。复数密集层机制是为了充分利用复数的统计信息，在计算复数分类结果时接受复数特征。定义一个复数密度向量权值 $\mathbf{W} = \mathbf{A} + \mathbf{j}\mathbf{B}$ 和一个复数向量 $\mathbf{S} = \mathbf{x} + \mathbf{j}\mathbf{y}$ 来表示复数输入。与复卷积运算核类似，可以得到：

$$\mathbf{W} \cdot \mathbf{S} = (\mathbf{A} \cdot \mathbf{x} - \mathbf{B} \cdot \mathbf{y}) + \mathbf{j}(\mathbf{B} \cdot \mathbf{x} + \mathbf{A} \cdot \mathbf{y}) \quad (13)$$

3.3 基于多模态融合的信号调制识别

本文所提出的基于多模态深度学习的信号调制识别方法，首先，利用 AlexNet 网络和复数神经网络对信号的等势星球图域模态和 I/Q 波形域模态进行特征提取，将两种模态的深层特征进行特征级的融合；然后将此联合特征最终输入至含有 12 个神经元的 Softmax 层中进行识别结果的预测。在这过程中涉及到 3 种模型：特征融合的多峰模型、AlexNet 单峰模型和复数神经网络单峰模型。因各模型之间的预测结果会有所差异，需要考虑各个模型预测的标签分布之间的损失，期望预测结果相同的标签之间的距离尽可能地小，不同的标签之间的距离尽可能地大。因此将这 3 种模型的融合目标用一个损失函数表示，达到多模态模型融合的目标，从而进一步提高模型的性能。在这过程中涉及到多模态的对齐，即两种模态数据输入至各自的特征提取器网络的过程中，来自同一个样本的两个模态数据需要同时输入网络中，保持对应的关系，其技术流程框图如图 6 所示。

使用协同融合架构实现多模态模型的融合，使多种模态在约束条件下能够保持相互协作，从而有助于保持每种模态的独特性和排他性，进一步提高深度学习模型的性能。

首先使用交叉熵计算两种预测标签分布之间的损失， $p_\theta(x_i)$ 和 $q_\theta(x_i)$ 分别代表两个预测标签的概率分布，交叉熵损失函数可定义为：

$$E_{\text{cross}} = - \sum_{i=1}^n p_\theta(x_i) \ln[q_\theta(x_i)] \quad (14)$$

式中 $p_\theta(x_i)$ 为分布函数，由 Softmax 函数计算而来：

$$p_\theta(x_i) = \text{Softmax}(x_i) = \frac{1}{\sum_{k=1}^K e^{\theta_k^T x_i}} [e^{\theta_1^T x_i}, e^{\theta_2^T x_i}, \dots, e^{\theta_K^T x_i}]^T \quad (15)$$

式中 K 为模态种类的数量。

式(14)能够展示真实概率分布与预测概率分布之间的区别，预测效果和交叉熵的值成负相关。本文将这 3 种模型的融合目标用一个损失函数表示：

$$F_{\text{loss}} = -\frac{1}{N} \sum_{i=1}^N t_i \ln[p_{\theta^c}(x_i^c)] - \frac{1}{N} \sum_{m=1}^2 \sum_{i=1}^N p_{\theta^m}(x_i^c) \ln[p_{\theta^m}(x_i^m)] \quad (16)$$

式中： t_i 为真实的概率分布； x_i^m ($m \in \{1, 2\}, i \in \{1, 2, \dots, N\}$) 为第 m 种模态的第 i 个样本的特征信息，本文中第 1 种模态是信号等势星球图域模态，第 2 种模态是信号 I/Q 波形域模态； x_i^c 为第 i 个样本的联合特征； N 为样本数。




Fig.6 Block diagram of the technical flow of the proposed scheme

图6 所提出方案的技术流程框图

4 仿真结果分析

4.1 实验数据集介绍

根据开放协议和标准，5G 移动通信业务信道中的调制类型为 BPSK, QPSK, 16QAM, 64QAM 和 256QAM。展望 5G 移动通信中的动态频谱接入，数字调制识别具有更大的现实意义。因此，使用 Matlab 2019b 仿真软件生成 12 种数字调制信号，包括 2ASK, 4ASK, BPSK, QPSK, OPQSK, 8PSK, 16QAM, 64QAM, 246QAM, CPFSK, GFSK, PAM4。此外，为了研究信号采样点对方法性能的影响，产生 3 种不同采样的数据集，分别为 1 024, 3 072, 5 012 个采样点。仿真实验中考虑到噪声环境为加性高斯白噪声，信噪比为 $-10 \sim 8$ dB，步长为 2 dB。为了满足仿真实验的需要，本节对每种调制类型每信噪比产生 1 250 个样本，采用 4:1 的比例随机分成训练集和测试集，其中训练样本 1 000 个，测试样本 250 个。

4.2 不同信号采样点下的平均分类精确度对比结果分析

将本文提出的基于信号等势星球图域和 I/Q 波形域的特征融合和模型融合 (Signal CSI-I/Q Waveform Multimodal Fusion Method, CWMF) 的方法简称为 CWMF 方法。图 7 为 CWMF 方法、特征融合方法、基于 AlexNet 的单峰模型方法、基于复数网络的单峰模型方法在不同信号采样点下的平均精确度与信噪比 (Signal-to-Noise Ratio, SNR) 的关系。从图 7 中可以得出以下结论：a) 在不同信号采样点的情况下，本文提出的 CWMF 方法的平均识别精确度明显好于其他 3 种方法，当信噪比为 -2 dB 时，识别精确度比特征融合方法提高了 5% 左右，特别是当信噪比大于 0 dB 时，准确率达到 100%；b) 特征融合的多模态模型的平均精确度显著高于其他 2 种单峰模型。这表明多模态融合方法可以实现多模态信息之间的互补，从而获得更全面的联合特征，进而提高识别精确度和模型鲁棒性；c) 随着信号采样点数量的减少，可以看到基于 AlexNet 的单峰模型的性能显著下降。信号采样点数越小，基于 AlexNet 的单峰模型的平均精确度越低。这是因为信号的采样点数越小，其信号的等势星球图二维平面上的点数就越少，其特征就越不明显；d) 基于 AlexNet 的单峰模型的性能同时也易受信噪比的影响，其平均精确度随信噪比的降低而显著降低。这是由于信号的相位易受噪声的影响，导致信号的等势星球图失真，使不同信号的图域特征不明显，易混淆；e) 在信号采样点多、信噪比高的情况下，基于 AlexNet 的单峰模型的性能优于复数网络单峰模型。此外，信号采样点数对复数网络单峰模型影响不大，在低信噪比下可以获得更好的分类精确度；f) 由于多模态模型的融合可以结合 2 种单峰模型的优点，因此多模态模型在总体信噪比中的精确度得

到显著提高。当信号采样点数为 1 024 时, 基于 AlexNet 的单峰模型的局限性, CWMF 方法和特征融合多峰模型的性能没有显著提高。




Fig.7 Relationship between the average classification accuracy and the SNR at different signal sampling points

图 7 在不同信号采样点下的平均分类精确度与信噪比的关系

4.3 不同方法的混淆矩阵结果对比分析

图 8 为 $R_{\text{SN}}=-2$ dB 时, 不同信号调制识别方法的混淆矩阵。对角线上的单元格表示预测标签与真实标签一致, 颜色越接近橙色, 预测精确度越高。




Fig.8 Confusion matrices of different methods at $R_{\text{SN}}=-2$ dB

图 8 $R_{\text{SN}}=-2$ dB 下不同方法的混淆矩阵

从图 8 可以看出, AlexNet 单峰模型的主要误差发生在 8PSK 和 2ASK, 4ASK 和 PAM4 之间, 以及 16QAM, 64QAM 和 256QAM 之间, 这是因为它们的等势星球图相似。从图 8 可以看出, 复数神经网络单峰模型的主要误差发生在 8PSK 和 QPSK 之间。相比之下, 特征融合多模态模型可以实现 2 个多模态特征之间的优势互补, 因此正确识别的概率显著提高。最重要的是, 可以从图 8 中看出, 本文提出的 CWMF 方法与其他 3 种模型相比, 由于其结合了特征融合和模型的协同融合架构, 使各模型在一定的约束条件下能够保持模态之间的独特性和排他性, 同时又能实现多模态特征之间的信息互补性, 因此在识别精确度方面具有更明显的优势。

4.4 每种信号的识别精确度与信噪比的关系结果分析

为更明显地显示出 12 种调制类型的识别性能随信噪比的变化, 评估了 12 种调制类型的正确识别概率随信噪比的变化情况。从图 9 中可以看出, 当信噪比低于 2 dB 时, AlexNet 单峰模型的每种数字信号的识别正确率均存在一定误差, 识别结果较为混乱。这是因为信号的等势星球图受 SNR 的影响很大。然而, 对于 8PSK 和 QPSK 信号, 复数网络单峰模型的识别精确度始终较低, 这是因为当仅使用信号的 I/Q 分量模态作为模型的输入时, 模型无法学习足够的特征来区分这些类别。相比之下, 本文提出的 CWMF 方法在信噪比大于 0 dB 时, 可以达到 100% 的精确度, 这同样得益于特征融合和基于模型的协同融合架构的结合, 使模型性能得到提升。




Fig.9 Relationship between the recognition accuracy of each signal and the SNR for different methods

图9 不同方法下的每种信号的识别精确度与信噪比的关系图

5 结论

为了利用多模态信息之间的互补性, 实现多域信息的转换与融合, 提出基于信号统计图域和信号 I/Q 波形域的多模态信息融合的方法来实现信号调制识别。特征融合的方法可以得到信息更加丰富的多模态特征的联合特征表示, 此外, 采用协调的集成架构, 实现多模态之间的相互合作和约束, 有利于保持各模态的独特性和排他性。仿真结果表明, 在整个信噪比条件下, 提出的方案比其他单模态模型和多模态模型具有更好的性能, 信噪比为 -2dB 时, 识别精确度比联合特征融合方法提高了 5% 左右, 在高信噪比下可以达到 100% 的精确度。

参考文献:

- [1] YOU X, ZHANG C, TAN X, et al. AI for 5G: research directions and paradigms[J]. Science China(Information Sciences), 2019, 62(2): 1-13.

- [2] 刘松涛,雷震烁,温镇铭,等. 认知电子战研究进展[J]. 探测与控制学报, 2020,42(5):1-15. (LIU Songtao,LEI Zhenshuo,WEN Zhenming,et al. A development review on cognitive electronic warfare[J]. Journal of Detection and Control, 2020,42(5):1-15.)
- [3] 陈勇,张余,柳永祥. 电磁频谱战发展剖析与思考[J]. 指挥与控制学报, 2018,4(4):319-324. (CHEN Yong,ZHANG Yu, LIU Yongxiang. Analysis and thinking on the development of electromagnetic spectrum warfare[J]. Journal of Command and Control, 2018,4(4):319-324.)
- [4] WANG X,ZHAO Y,POURPANAH F. Recent advances in deep learning[J]. International Journal of Machine Learning and Cybernetics, 2020,11(4):747-750.
- [5] WANG Y,WANG J,ZHANG W,et al. Deep learning-based cooperative automatic modulation classification method for MIMO systems[J]. IEEE Transactions on Vehicular Technology, 2020,69(4):4575-4579.
- [6] ZHANG M,DIAO M,GUO L. Convolutional neural networks for automatic cognitive radio waveform recognition[J]. IEEE Access, 2017(5):11074-11082.
- [7] LI J,QI L,LIN Y. Research on modulation identification of digital signals based on deep learning[C]// Proceedings of the IEEE International Conference on Electronic Information and Communication Technology. Harbin,China:IEEE, 2016:402-405.
- [8] PENG S,JIANG H,WANG H,et al. Modulation classification based on signal constellation diagrams and deep learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019,30(3):718-727.
- [9] LIN Y,TU Y,DOU Z,et al. Contour stella image and deep learning for signal recognition in the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2020,7(1):34-46.
- [10] TU Ya,LIN Yun,ZHA Haoran,et al. Large-scale real-world radio signal recognition with deep learning[J]. Chinese Journal of Aeronautics, 2022,35(9):35-48.
- [11] SHI G,SHANECHI M M,ARABI P. On the importance of phase in human speech recognition[J]. IEEE Transactions on Audio, Speech, and Language Processing, 2006,14(5):1867-1874.
- [12] XIN R,ZHANG J,SHAO Y. Complex network classification with convolutional neural network[J]. Tsinghua Science and Technology, 2020,25(4):447-457.
- [13] TU Y,LIN Y,HOU C,et al. Complex-valued networks for automatic modulation classification[J]. IEEE Transactions on Vehicular Technology, 2020,69(9):10085-10089.
- [14] TU Ya,LIN Yun,WANG Jin,et al. Semi-supervised learning with generative adversarial networks on digital signal modulation classification[J]. Computers Materials & Continua, 2019,55(2):243-254.
- [15] 张思成,林云,涂涯,等. 基于轻量级深度神经网络的电磁信号调制识别技术[J]. 通信学报, 2020,41(11):12-21. (ZHANG Sicheng,LIN Yun,TU Ya,et al. Electromagnetic signal modulation recognition technology based on lightweight deep neural network[J]. Journal on Communications, 2020,41(11):12-21.)
- [16] ZHANG Z,WANG C,GAN C,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.
- [17] HOU C,ZHANG X,CHEN X. Electromagnetic signal feature fusion and recognition based on multi-modal deep learning[J]. International Journal of Performability Engineering, 2020,16(6):941-949.
- [18] 何俊,张彩庆,李小珍,等. 面向深度学习的多模态融合技术研究综述[J]. 计算机工程, 2020,46(5):1-11. (HE Jun,ZHANG Caiqing,LI Xiaozhen,et al. Survey of research on multimodal fusion technology for deep learning[J]. Computer Engineering, 2020,46(5):1-11.)
- [19] ZHANG C,YANG Z,HE X,et al. Multimodal intelligence:representation learning,information fusion,and applications[J]. IEEE Journal of Selected Topics in Signal Processing, 2020,14(3):478-493.
- [20] WANG M,LIN Y,TIAN Q,et al. Transfer learning promotes 6G wireless communications:recent advances and future challenges[J]. IEEE Transactions on Reliability, 2021,70(2):790-807.

作者简介:

冯忠明(1998-),男,在读硕士研究生,主要研究方向为信号处理、深度学习等,email:fzm98@hrbeu.edu.cn.

王景岩(1997-),男,在读硕士研究生,主要研究方向为轻量化部署、深度学习等.

李奎贤(1998-),男,在读硕士研究生,主要研究方向为人工智能、群体智能等.