

基于双置信度融合机制的半监督信号调制识别方法

刘文学¹, 苗响宸^{1,2}, 杨超三¹, 宋留斌¹, 李金海¹, 邱昕¹

(1. 中国科学院微电子研究所通信与信息工程研发中心, 北京 100029; 2. 中国科学院大学集成电路学院, 北京 100049)

摘要: 针对复杂信道环境下调制识别对标注数据高度依赖的问题, 提出一种基于双置信度融合机制的半监督信号调制识别方法。该方法采用基于自训练半监督学习的多通道卷积长短期深度神经网络 (MCLDNN) 框架, 利用高阶累积量、瞬时参数与小波系数构建特征向量, 通过高斯混合模型 (GMM) 聚类并评估聚类置信度, 动态融合基于自训练的半监督学习模型置信度形成双置信度机制。在公开数据集 RML2016.10b 上的实验表明, 该方法在 0~18 dB 信噪比下对 7 种数字调制信号的平均识别准确率达 97.78%, 较传统半监督方法提升 4.88%, 接近全监督性能; 模型收敛速度提升约 20%, 有效解决了传统基于自训练的半监督学习中模型认知闭环导致的过拟合问题, 为低标注成本场景下的调制识别提供了高效解决方案。

关键词: 调制识别; 半监督学习; 高斯混合模型; 置信度融合

中图分类号: TN911; TP391

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025175

Semi-supervised signal modulation recognition method based on dual-confidence fusion mechanism

LIU Wenxue¹, MIAO Xuchen^{1,2}, YANG Chaosan¹, SONG Liubin¹, LI Jinhai¹, QIU Xin¹

1. Communications and Information Engineering R&D Center IMECAS, Beijing 100029, China

2. School of Integrated Circuits, University of Chinese Academy of Sciences, Beijing 100049, China

Abstract: In response to the problem of modulation identification with high dependence on labeled data in complex communication channel environments, a semi-supervised signal modulation recognition method based on dual-confidence fusion mechanism was proposed. This method adopted the multichannel convolutional long short-term deep neural network (MCLDNN) framework based on self-training semi-supervised learning, used high-order cumulants, instantaneous parameters and wavelet coefficients to construct feature vectors, clusters and evaluated clustering confidence through the Gaussian mixture model (GMM), and dynamically integrated the confidence of the semi-supervised learning model based on self-training to form the dual confidence mechanism. Experiments on the public dataset RML2016.10b shows that under the test scenarios of 0~18 dB SNR and 7 digital modulation signals, the average recognition accuracy of this method reaches 97.78%, which is 4.88% higher than the traditional semi-supervised method and is close to the full supervision performance. At the same time, the model convergence speed has improved by about 20%. This method effectively solves the overfitting problem caused by the model cognitive loop in traditional self-training based on semi-supervised learning, and provides an efficient solution for modulation recognition in low-labeling cost scenarios.

Keywords: modulation recognition, semi-supervised learning, Gaussian mixture model, confidence fusion

收稿日期: 2025-06-24; 修回日期: 2025-09-15

通信作者: 苗响宸, miaoxuchen24@ime.ac.cn

基金项目: 国家重点研发计划基金资助项目 (No.2022YFB3903900)

Foundation Item: The National Key Research and Development Program of China (No.2022YFB3903900)

0 引言

信号的调制方式识别是通信系统实现智能化的核心技术之一,其性能直接影响信息提取的准确性与通信链路的可靠性。它在认知无线电、频谱感知以及6G分布式节点智能化技术(如自适应调制编码、联合信道估计和符号检测、自适应传输功率控制)^[1]等很多方面具有广泛用途。当前,经典的调制识别算法主要分为2类:基于似然的方法^[2-4]通过统计模型和参数估计实现理论最优性能,但对先验知识依赖性较强;基于特征的方法依赖人工提取信号特征(如瞬时参数^[5]、高阶累积量^[6]、星座图^[7]等)并设置门限进行识别。然而,这2类方法难以适应动态变化的通信场景^[8],在具有加性白高斯噪声、多径衰落(如瑞利衰落和莱斯衰落)、中心频率偏移和采样率偏移等信道效应的复杂信道环境下鲁棒性不足,泛化能力严重受限,且对信道畸变与突发干扰极为敏感^[9]。

相比于经典的调制识别算法,基于深度学习的方法因其能够直接从原始I/Q信号中学习多层次特征并捕捉到更复杂的信号表征,从而展现出更高的准确率和更强的泛化性^[10],逐渐成为当前调制识别研究中的主流方向之一。O'SHEA等^[11]首次将卷积神经网络(CNN, convolutional neural network)引入调制分类领域,开启了该领域的新纪元。Rajendran等^[12]提出了基于长短期记忆(LSTM, long short-term memory)网络的深度学习模型,实现了在0~20 dB信噪比(SNR, signal-to-noise ratio)上90%的平均分类准确率。Huynh-The等^[13]采用非对称卷积核的多分支设计和轻量级多尺度特征融合架构的卷积神经网络,实现了在20 dB SNR上24种调制方式信噪比93.59%的准确率。Xu等^[14]提出多通道卷积长短期深度神经网络(MCLDNN, multi-channel convolutional long short-term deep neural network),首次将I/Q多通道信号、独立I通道和Q通道信号作为三流输入,通过1D-CNN、2D-CNN和LSTM联合提取时空特征,显著改善高维调制混淆问题,并实现了在0 dB SNR下对64正交幅度调制信号(QAM, quadrature amplitude modulation)的分类准确率较基准模型约15%的提高。Njoku等^[15]提出CGDNet深度学习模型,将用作特征提取的CNN、时序建模的门控循环单元(GRU, gated recurrent unit)和分类的深度神经网络(DNN, deep

neural network)深度融合,形成端到端调制识别框架,在RadioML2016.10a和RadioML2016.10b数据集上平均识别准确率达到93.5%和90.38%。Feng等^[16]提出迭代双线性时频融合方法和多视角注意力机制结合的时频特征融合网络(TSFFN, temporal-spectral feature fusion network),在RML2016.10a、RML2016.10b等5个数据集上达到了论文发表时期平均准确率的最高值,在低信噪比(-10~0 dB)和高信噪比(0~18 dB)下分别实现了59.65%和92.18%准确率,鲁棒性显著优于对比方法。Zhai等^[17]将多模态深度学习引入调制识别,通过双路径信号变换器实现跨域特征学习与融合,突破了传统单域学习方法的局限性,一定程度上解决了复杂电磁环境中单域特征可靠性不足的问题。可见,基于深度学习的全监督学习调制识别方法能够直接从原始I/Q信号中自动提取信号特征实现端到端学习,显著提升了各类信号尤其是高阶调制信号的识别准确率,同时在复杂信道环境下具备更强的适应能力。

尽管上述方法在识别准确率和复杂环境适应性方面取得了较好效果,但其性能高度依赖于大规模标注数据集的支持。然而,在实际通信场景中,信号传输环境的复杂性和载体动态性使得获取充足且精确标注的数据成本代价高昂,甚至在某些低信噪比或非协作条件下难以实现。为应对这一挑战,近年来学者开始探索半监督学习(SSL, semi-supervised learning)在调制识别中的应用。O'Shea等^[18]提出结合基于卷积自编码器的无监督稀疏表示学习与基于预训练CNN的监督特征提取的半监督方法,显著降低对标注数据的依赖。Dong等^[19]提出了一种将交叉熵损失、中心损失和KL散度损失加权的组合损失函数,充分利用了标注样本和未标注样本的信息,显著提升了半监督学习的性能和鲁棒性。张柏林等^[1]提出在鉴别器中加入梯度逆转层,通过反向传播时反转梯度方向,降低了噪声样本与原始样本特征之间的差异,避免了传统KL散度损失的非对称性问题,显著提升了模型在低信噪比场景下的鲁棒性,同时可以实现更有效地对抗噪声干扰。

综上所述,现有的研究成果已经从协同训练、数据增强、构建新的损失函数和修改网络结构等方面尽可能地利用未标注样本的信息,显著提升了模型的性能,但是高置信度伪标签样本往往已被当前

模型准确分类,其重复参与训练过程从实质上并未引入新的决策边界信息,反而可能诱导模型在已掌握的特征空间内陷入参数振荡,这种自增强机制下的认知闭环现象将会导致模型在有限知识域上的过拟合^[20]。针对此问题,本文提出了一种基于双置信度融合机制的半监督信号调制识别方法,将高阶累积量、瞬时参数、小波系数等人工特征作为特征向量进行聚类,对每个样本评估置信度并将其与基于自训练的半监督学习的置信度相结合,从而引入更多的模型之外信息,提高伪标签的质量,从根本上改善高置信度伪标签难以带来新知识导致训练集过拟合问题。实验结果表明,本文方法相比于传统的基于自训练的半监督学习方法在调制识别这一任务上能够达到更高的准确率,同时方法所需标注数据量远低于全监督学习方法,为基于半监督学习的调制识别技术的发展提供了一种新的技术参考。本文工作的主要贡献如下。

1) 针对传统半监督学习中高置信度伪标签仅强化现有知识、易导致模型认知闭环和过拟合的问题,创新性地提出了一种双置信度融合机制。该机制将基于高斯混合模型聚类结果的聚类置信度与基于深度神经网络预测的自训练置信度进行动态融合,共同生成伪标签。

2) 本文设计了一个置信度融合函数,通过提取信号本身所具有的结构特征,有效利用了信号处理领域的先验知识,为模型提供了来自训练集之外的深层信息,有效补充了模型在标注稀缺条件下学习的不足。

3) 本文分别在调制识别经典公开数据集 RML 2016.10b 的 0~18 dB SNR 范围下和 RML2016.10a、RML2016.10b、RML2016.04c 的 -20~18 dB SNR 范围下进行实验,并重点分析 RML2016.10b 的 0~18 dB SNR 范围下的实验结果,通过与传统的基于自训练的半监督学习对比可知,本文方法显著提升了伪标签的质量,具有更高的准确率和更快的收敛速度。

1 信号特征参数

1.1 信号高阶累积量参数

高阶累积量作为信号处理领域的重要特征参数,不仅可以抑制信号加性高斯噪声的干扰,还能保持对载波相位偏移的非敏感性,在数字调制类型的识别中被广泛应用。信号的高阶累积量由信号的

高阶矩定义,对于一个零均值的复随机过程 $X(t)$,其 p 阶混合矩可表示为

$$M_{pq} = E \left[X(t)^{p-q} X^*(t)^q \right] \quad (1)$$

依据上述定义,给出如下高阶累积量^[21]

$$\begin{aligned} C_{40} &= \text{cum}(X, X, X, X) = M_{40} - 3M_{20}^2 \\ C_{42} &= \text{cum}(X, X, X^*, X^*) = M_{42} - |M_{20}|^2 - 2M_{21}^2 \\ C_{63} &= \text{cum}(X, X, X, X^*, X^*, X^*) = \\ &M_{63} - 6M_{20}M_{41} - 9M_{42}M_{21} + 18M_{20}^2M_{21} + 12M_{21}^3 \\ C_{80} &= \text{cum}(X, X, X, X, X, X, X, X) = \\ &M_{80} - 28M_{60}M_{20} - 35M_{40}^2 - 420M_{40}M_{20}^2 + 630M_{20}^4 \end{aligned} \quad (2)$$

其中, $\text{cum}(\cdot)$ 为联合累积量, X 为上文中的 $X(t)$ 。为消除量纲影响并构建对调制识别有效的特征,本文选取已经被证明在调制识别中具备良好性能的高阶累积量构建如下特征参数^[21-22]

$$\begin{aligned} F_1 &= \frac{C_{40}}{C_{42}} \\ F_2 &= \frac{C_{63}^2}{C_{42}^3} \\ F_3 &= \frac{C_{80}}{C_{42}^2} \end{aligned} \quad (3)$$

1.2 瞬时参数

信号的瞬时参数能够反映信号的变化情况,为调制识别提供关键的时频域判别依据。通过分析这些参数的统计特性或变化规律,可有效区分不同调制类型的信号差异。本文根据信号的瞬时参数构建了一套瞬时参数,具体如下。

1) 零中心归一化瞬时幅度之谱密度的最大值^[23]

$$\gamma_{\max} = \frac{\max |\text{FFT}[a_{\text{cn}}(i)]|^2}{N_s} \quad (4)$$

其中, N_s 为采样点数; $a_{\text{cn}}(i)$ 为零中心归一化瞬时幅度,可表示为

$$a_{\text{cn}}(i) = \frac{a(i)}{m_a} - 1 \quad (5)$$

其中, m_a 为瞬时幅度的平均值, $a(i)$ 为瞬时幅度。

γ_{\max} 主要是用来区分频移键控 (FSK, frequency shift keying) 信号和幅移键控 (ASK, amplitude shift keying) 信号或相移键控 (PSK, phase shift keying) 信号的。由于现如今使用的 FSK 信号调制系统绝大多数为连续相位的,信号包络为常数,因此其 γ_{\max} 会很接近零; ASK 信号的信息处在

信号的包络上, PSK 信号受信道带宽的限制, 在相位变化时刻会产生幅度突变, 所以也含有幅度变化信息, γ_{\max} 不为零^[23]。

2) 瞬时幅度的四阶谱峰因子

$$P = \frac{\max | \text{FFT} [a^4(i)] |}{E [| \text{FFT} [a^4(i)] |]} \quad (6)$$

P 主要用于区分正交相移键控 (QPSK, quadrature phase shift keying) 信号和 QAM 信号。假设 QPSK 信号的平均符号能量为 E_s , 则 QPSK 信号的 4 个符号可以表示为

$$s_k = \sqrt{E_s} \cdot e^{j \left[\frac{\pi}{4} + \frac{k\pi}{2} \right]}, k = 0, 1, 2, 3 \quad (7)$$

通过四次方运算消除掉相位调制后, QPSK 信号的瞬时幅度的四次方 $a^4(i)$ 为一个常数 E_s^2 , 瞬时幅度恒定, 则其快速傅里叶变换后的结果呈一个明显的谱峰; QAM 信号瞬时幅度的四次方 $a^4(i)$ 仍与调制信息有关, 幅度仍然是变化的, 快速傅里叶变换后的谱能量相对分散, 导致其谱峰因子显著低于 QPSK 信号。

3) 零中心归一化瞬时频率绝对值的峰度

$$\kappa = \frac{E [(f(i) - \mu)^4]}{\sigma^4} - 3 \quad (8)$$

其中, $f(i)$ 为瞬时频率^[23], μ 为瞬时频率的平均值, σ 为瞬时频率的标准差。

κ 主要是用来区分 FSK 信号和 PSK 或 QAM 信号的, 假设一段 2FSK 信号的 2 个符号的频率分别为 f_1 和 f_2 , 统计这段信号的瞬时频率, 则这段信号中的各个采样点的瞬时频率将集中在 f_1 和 f_2 附近, 所有采样点的瞬时频率构成的分布呈双峰形态, 这样的分布峰度值相对较低; PSK 或 QAM 信号仅在符号切换时会由于相位突变产生高频分量, 其余采样点的瞬时频率均在信号中心频率附近, 则这段信号的瞬时频率形成的分布呈多数围绕载波中心小幅波动, 极少数偏离载波中心, 这样的分布由于少数高频瞬时频率的存在, 为一个重尾分布, 峰度值较高。另外, 由于不同调制阶数的 PSK 信号符号切换时产生的相位跳变不同, 则符号切换时产生的瞬时频率大小也不同, 最终不同的 PSK 信号每个采样点的瞬时频率形成的分布也会有差别, 所以该参数对 PSK 信号的类内识别也有一定帮助。

1.3 小波系数

1) 小波包能量熵

小波包能量熵通过量化信号在时频域的能量分布特性, 能够捕捉到不同调制信号的时频结构差异, 从而为调制识别提供依据^[24]。鉴于 Daubechies 小波族具有广泛的适用性和良好的抗噪声性能, 尤其适合本文所涉及的多种调制类型及复杂信道条件, 因此选择 db4 小波基进行小波分解。具体实现过程如下: 首先对信号进行零均值归一化处理, 随后进行 2 层小波包分解, 并计算各子带的能量分布

$$E_i = \sum_{k=1}^N |x_i(k)|^2 \quad (9)$$

其中, $x_i(k)$ 为第 i 个子带的时域采样点, N 为点数。然后计算能量概率分布

$$p_i = \frac{E_i}{\sum_{j=1}^M E_j} \quad (10)$$

最后计算小波包能量熵^[25]

$$H = - \sum_{i=1}^M p_i \text{lb} p_i \quad (11)$$

2) 小波系数的统计特性

小波分解通过短时高频基函数捕捉信号的瞬态细节, 通过长时低频基函数描述信号的整体趋势, 其将信号分解为不同频带的子信号, 实现了局部瞬态特征和全局趋势信息的获取。本文选取了小波系数的方差^[26]、偏度^[27]、峰度^[27]和相关性^[28] 4 种统计特性作为特征向量, 这些统计特征通过多维度描述小波系数的分布特性, 为调制识别提供互补的信息。

小波系数的统计特性计算同样选取 db4 小波基对信号进行 2 层小波分解, 假设 s_n 为小波系数, N 为小波系数的长度, 则具体公式如下。

方差为

$$\text{Var}(s_n) = \frac{1}{N-1} \sum_{k=1}^N (s_n[k] - \bar{s}_n)^2 \quad (12)$$

偏度为

$$\text{Skew}(s_n) = \frac{\frac{1}{N} \sum_{k=1}^N (s_n[k] - \bar{s}_n)^3}{\left(\frac{1}{N} \sum_{k=1}^N (s_n[k] - \bar{s}_n)^2 \right)^{\frac{3}{2}}} \quad (13)$$

峰度为

$$\text{Kurt}(s_n) = \frac{\frac{1}{N} \sum_{k=1}^N (s_n[k] - \bar{s}_n)^4}{\left(\frac{1}{N} \sum_{k=1}^N (s_n[k] - \bar{s}_n)^2\right)^2} - 3 \quad (14)$$

相关函数为

$$R(n) = \frac{\sum_{k=1}^{N-1} (s_n[k] - \bar{s}_n)(s_n[k+n] - \bar{s}_n)}{\sum_{k=1}^N (s_n[k] - \bar{s}_n)^2} \quad (15)$$

其中,对于小波系数 s_n ,本文选择了第二层的近似系数和细节系数,相关函数选择了时延 $n=1,2,3$ 。

2 系统模型

2.1 数字调制信号识别框架

本文提出的数字调制信号识别框架如图1所示。

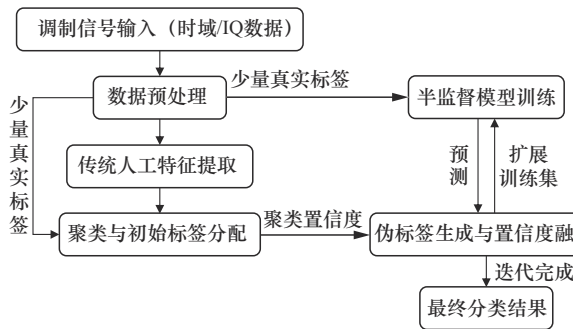


图1 数字调制信号识别框架

首先,对调制信号进行预处理,消除信号量纲并进行归一化,提取上文所述的信号特征参数构建特征向量,利用高斯混合模型(GMM, Gaussian mixture model)对原始样本进行聚类划分;其次,基于GMM后验概率与少量有标签样本的簇内分布,综合评估生成聚类置信度,同时通过有标签样本初始化模型并预测无标签样本,生成自训练置信度。二者通过双置信度融合机制形成伪标签;最后,采用渐进式样本扩展策略,每轮迭代筛选伪标签置信度高于置信度阈值的样本加入训练集,并线性衰减置信阈值至预设下限,逐步扩大高质量训练样本规模,直至全部无标签样本都被添加进训练集或模型收敛后得到最终分类结果。

2.2 聚类方法

假设理想情况下,某种调制方式的某个特征参数为确定值 μ ,由于实际中信号会同时受到噪声、信道衰落、多普勒效应等多种随机因素干扰,

实际中接收到的该调制方式的一段信号的特征参数变为 m_i (即图1中提取的传统人工特征),则 m_i 可由包含独立随机变量的函数 f_i 来建模,其中 f_i 表示多种随机因素的干扰的总和。根据中心极限定理,当 i 的数量足够大时,实际特征参量 $m_i = f_i(\mu)$ 的分布函数会趋近于正态分布(即高斯分布),该特征与GMM每个簇都服从高斯分布的假设相符合,因此本文选取GMM作为聚类方法,发掘不同调制方式下信号特征参数的内在结构,最终实现将信号的特征参数分类,得到聚类结果。算法原理介绍如下。

首先定义GMM的概率密度函数可以表示为

$$P(x|\theta) = \sum_{k=1}^K \alpha_k \phi(x|\theta_k) \quad (16)$$

其中, x 表示当前被观测数据, K 为混合模型中高斯成分的数量, α_k 为观测数据属于第 k 个高斯成分的概率, $\alpha_k \geq 0, \sum_{k=1}^K \alpha_k = 1, \phi(x|\theta_k)$ 为第 k 个高斯成分的概率密度函数。

GMM聚类基于期望最大化(EM)算法^[29],通过迭代优化模型的参数 θ_k 和 α_k ,将数据划分为多个高斯分布成分对应的簇,具体流程如下。

1) 参数初始化:本文选用K-means聚类中心初始化均值 μ_k ,单位矩阵初始化协方差矩阵 Σ_k ,均匀初始化权重 α_k 。

2) E步:计算每个数据点 x_j 属于第 k 个高斯成分的后验概率。

$$\gamma_{jk} = \frac{\alpha_k \phi(x_j|\theta_k)}{\sum_{k=1}^K \alpha_k \phi(x_j|\theta_k)} \quad j = 1, 2, \dots, N; k = 1, 2, \dots, K \quad (17)$$

其中, γ_{jk} 表示第 j 个观测数据属于第 k 个高斯成分的概率

3) M步:基于当前的 γ_{jk} ,更新模型参数。

更新均值

$$\mu_k = \frac{\sum_j (\gamma_{jk} x_j)}{\sum_j \gamma_{jk}}, k = 1, 2, \dots, K \quad (18)$$

更新协方差矩阵

$$\Sigma_k = \frac{\sum_j \gamma_{jk} (x_j - \mu_k)(x_j - \mu_k)^T}{\sum_j \gamma_{jk}}, k = 1, 2, \dots, K \quad (19)$$

更新权重

$$\alpha_k = \frac{\sum_{j=1}^N \gamma_{jk}}{N}, k = 1, 2, \dots, K \quad (20)$$

4) 收敛判断: 重复步骤 2) 和步骤 3), 直至 $|\theta_{i+1} - \theta_i| < \varepsilon$ 或超出最大步长, 本文 ε 为 1×10^{-4} , 最大步长为 3 000 步^[30]。

2.3 网络结构

本文基于自训练的半监督学习框架选用了 MCLDNN^[12], 将全监督学习调制识别任务中性能优异且较为前沿的 MCLDNN 结构应用于半监督学习调制识别任务中, 该网络通过 CLDNN^[31] 改进而来。CLDNN 将 CNN 和 LSTM 结合起来, 融合了 CNN 的局部特征提取、LSTM 的时序建模和 DNN 的高层语义整合能力, 充分利用了不同结构的优势来提取信号的时域和频域信息, 从而提高了识别准确性。

MCLDNN 在 CLDNN 的基础上将输入信号增加为 I/Q 多通道信号、独立 I 通道和 Q 通道信号三通道输入, 将 CNN 层替换为 1D-CNN、2D-CNN 以融合 3 个通道的多维度信息, 再将其输入 LSTM, 从中提取出相应的时序特征。MCLDNN 的网络结构如图 2 所示。

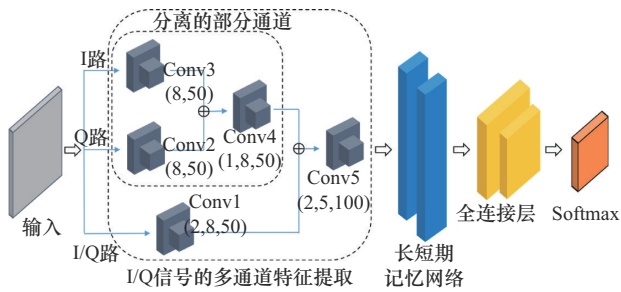


图 2 MCLDNN 的网络结构

MCLDNN 主要包括 3 个网络层, 具体介绍如下。

CNN 层: 该层网络的作用主要是通过卷积核捕捉输入数据的局部特征。

LSTM 层: 该层网络通过捕捉序列数据的长期依赖关系对样本进行时序建模

DNN 层: 通过全连接层对前两层提取的特征进行非线性组合与抽象, 最终映射到分类结果。

2.4 双置信度融合机制设计

双置信度融合机制的设计是本文的主要创新

点, 该机制通过融合本文针对性设计的聚类置信度与传统模型置信度生成更高质量的伪标签。具体地, 将各簇的后验概率与各类标签在簇内的所占比例相乘得到聚类置信度值, 其可表征各样本的调制类型概率, 然后通过将其与基于自训练的半监督学习模型置信度加权求和形成融合置信度, 选取融合置信度最高的类别作为无标签样本的伪标签。

设 S 为簇的数量, L 为调制类型类别数, N 为无标签样本的数量, 则本文双置信度融合机制具体流程如下。

1) 采用基于密度的簇纯度评估策略, 根据有标签样本在簇内的标签数量分布构建簇的调制类型概率矩阵 $\mathbf{P} \in \mathbb{R}^{S \times L}$, 假设第 s 个簇中有真实标签的样本总数为 m , 第 s 个簇中有第 l 种调制类型真实标签的样本数为 n , 则 $P_{sl} = \frac{n}{m}$ 为第 s 个簇对第 l 类调制类型的概率估计。

2) 通过 GMM 输出的后验概率生成每个样本属于任一簇的概率矩阵 $\mathbf{Q} \in \mathbb{R}^{N \times S}$, 其中 Q_{ns} 为第 n 个样本属于第 s 个簇的概率。

3) 将上述 2 个矩阵相乘, 得到全部样本的调制类型概率矩阵 $\mathbf{R} = \mathbf{QP} \in \mathbb{R}^{N \times L}$, 其中 $R_{nl} = \sum_{s=1}^K Q_{ns} P_{sl}$ 表示第 n 个样本属于第 l 类调制类型的置信度, 即聚类置信度。

4) 将上述聚类置信度矩阵与模型自训练所得的模型置信度矩阵 $\mathbf{C} \in \mathbb{R}^{N \times L}$ 按照式(21)融合

$$\mathbf{D} = \beta \mathbf{R} + (1 - \beta) \mathbf{C} \quad (21)$$

其中, β 为权重因子, 矩阵 $\mathbf{D} \in \mathbb{R}^{N \times L}$ 为最终的全样本置信度矩阵, 选取其中置信度最高的调制类型作为无标签样本的伪标签。

综上所述, 完整的伪标签生成的数理公式为

$$\mathbf{Y}_{\text{hat}} = I_{\max} [\beta \mathbf{QP} + (1 - \beta) \mathbf{C}] \quad (22)$$

其中, I_{\max} 表示将矩阵中每行的最大值变成 1, 其余变成 0; \mathbf{Y}_{hat} 为伪标签矩阵, 矩阵的每一行均为独热码, 1 所在的列数代表对应样本的预测调制类型, 即伪标签。

本文提出的双置信度融合机制之所以能够发挥作用, 核心在于其为神经网络引入了模型之外的额外信息。相比仅依赖自训练策略的半监督学习方法, 该机制能够将模型预测置信度相对较低但聚类置信度较高的伪标签样本补充到训练集中, 从而帮

助模型获取更多潜在知识。然而,在训练初始阶段,由于训练集较小模型容易过拟合,其预测置信度往往表现为过高或过低。当预测置信度过低时,会使融合置信度超过阈值对聚类置信度的要求过于严苛,限制机制的有效性。为改善这一问题,本文设计初始权重因子略大于置信度阈值,并提出了相应的调整策略如下

$$\beta = th + 0.01 \quad (23)$$

其中,th为动态置信度阈值。

在训练集扩展中,最终仅选择融合置信度高于动态置信度阈值的伪标签样本加入数据集进行迭代训练。动态置信度阈值通过线性衰减、指数衰减或验证集驱动的自适应策略,在训练初期设置较高阈值以确保伪标签可靠性,随着模型表征能力的提升逐步降低阈值。这种渐进式放松策略符合由易到难的学习规律,既保证了模型早期从高置信样本中稳定学习,又在训练后期通过纳入更多边缘样本来增强决策边界的分辨能力。聚类置信度的引入为学习过程中提供了辅助,在模型训练不充分的时候帮助模型提高伪标签的质量,在模型性能优于聚类性能后降低权重,从而避免低聚类置信度对样本伪标签的影响,加快模型收敛速度,增强性能,相较于固定阈值,其场景适应性更强。

3 实验结果及分析

本文主要使用公开数据集 RML2016.10b 完成所提模型与方法的性能实验验证。公开数据集 RML2016.10b 内容覆盖复杂场景,能够有效支撑本文实验验证,其包含 8 种数字调制类型信号: 8PSK、二进制相移键控 (BPSK, binary phase shift keying)、连续相位频移键控 (CPFSK, continuous phase frequency shift keying)、高斯频移键 (GFSK, Gaussian frequency shift keying)、四阶脉冲幅度调制 (4PAM, 4 level pulse amplitude modulation)、16QAM、64QAM、QPSK 和 2 种模拟调制类型信号: 双边带调幅 (AM-DSB, amplitude modulation - double sideband) 和宽带调频 (WBFM, wideband frequency modulation)。模拟真实通信场景中的信号传播特性,信道模型包含加性白高斯噪声、多径衰落 (如瑞利衰落和莱斯衰落)、中心频率偏移和采样率偏移等复杂信道效应。具体参数设置如下: 采样率偏移标准为 0.01 Hz; 最大采样率偏移为 50 Hz;

中心频率偏移标准为 0.01 Hz; 最大中心频率偏移为 500 Hz; 频率选择性衰落中使用的正弦波数为 8。数据集包括从 -20~18 dB (步长为 2 dB) 的 20 种信噪比信号,每个样本的数据格式为 2×128,表示同相和正交两路信号,每路 128 个采样点,每 8 个采样点为一个符号,每个样本 16 个符号。

由于本文所述的人工特征主要是针对数字调制信号提取的,且部分人工特征受符号分布影响较大,而数据集的每个样本长度较短,仅含有 16 个符号,无法体现 QAM64 的符号统计特性,因此本文实验中选择了除 QAM64 以外的 7 种数字调制信号。鉴于现有研究在负信噪比条件下的调制识别准确率普遍缺乏显著进展,相关研究成果普遍集中于 0 dB 以上信噪比场景。本文实验也重点考察方法在 0 dB 以上信噪比条件下的性能,全信噪比下的实验结果将在 3.4 节中展示以供参考。在实验测试中,每个信噪比的样本按照训练集 80%、测试集 20% 的比例进行划分,同时,在训练集中选择总样本数的 10% 作为标记样本,按照 1:1 划分初始训练集和验证集,其余 70% 为无标记样本。

实验中的网络训练均基于 Python 下的 Keras 深度学习框架实现,优化器为 Adam,硬件平台为 Intel Core i9-14900K 的 CPU, NVIDIA GeForce 4080Super 的 GPU。实验初始学习率为 0.001,样本的批处理大小为 400。在实验中,每 40 个训练轮次为一次迭代,每次迭代结束后执行一次伪标签预测并将伪标签样本添加到训练集中,初始置信度阈值为 0.97,每次迭代减少 0.07 直至达到最小值 0.5 后保持不变。初始权重为 0.98,同样每次迭代减少 0.07 直至达到最小值 0 后保持不变。迭代的最大次数为 20,若连续 3 次迭代验证集的损失未下降,则触发早停机制,提前终止迭代。

3.1 识别效果分析

实验将本文方法与以下方法进行比较。

1) 全监督学习: 采用深度学习中较为通用的数据集划分方式,60% 样本作为训练集,20% 作为验证集,20% 作为测试集。

2) 部分监督学习: 仅使用 5% 样本作为训练集,5% 作为验证集,20% 作为测试集,模拟标签极度稀缺场景下的全监督学习。

3) GMM 聚类: 仅使用 2.3 节描述的 GMM 聚类方法进行分类。

4) 基线方法：传统的基于自训练的半监督学习方法。

为构建公平且具有代表性的基线方法，本文参考文献[19]所提出的半监督信号识别卷积神经网络(SSRCNN, semi-supervised signal recognition convolutional neural network)构建了传统的基于自训练的半监督学习模型作为基线方法。考虑到本文中使用的数据集RML2016.10b规模远大于文献[19]中的RML2016.04c，且本文核心并非新型网络结构，直接对比原始SSRCNN配置可能缺乏公平性。因此，本文保留了SSRCNN中交叉熵、KL散度和中心损失联合优化的损失函数设计以及动态噪声注入与KL约束的噪声增强策略，将其网络结构替换为本文中所使用的较为先进的MCLDNN，具体实验结果如图3所示。




图3 各信噪比条件下结果对比

从图3可以看出，本文方法在仅使用10%有标签样本的情况下分类性能明显优于同样使用10%有标签样本的基线方法，并且非常接近使用60%有标签样本的全监督学习的分类性能。具体地，当信噪比为0 dB时，本文方法准确率达到92.79%，

比基线方法高4.27%，比全监督学习方法仅低1.87%；当信噪比为18 dB时，本文方法准确率达到98.3%，比基线方法高5.36%，比全监督学习方法低0.3%，同时在实验信噪比下远高于部分监督学习方法和GMM聚类方法。

本文方法性能提升主要归功于本文提出的双置信度融合机制，基线方法在产生伪标签时难以准确预测，而双置信度融合机制提高了伪标签的质量，使模型能够更好地学到信号的深度特征。本文双置信度融合机制一方面可有效克服单一置信度指标的认知局限性，通过无标签样本本身所具有的信号结构特征补偿模型预测的不确定性，为模型提供了来自训练集之外的先验信息，有效提高伪标签质量，帮助模型学习更鲁棒的特征，从而打破传统自训练中高置信伪标签仅强化现有知识的认知闭环，缓解过拟合；另一方面相较于GMM聚类方法对特征空间的静态概率建模，双置信度融合后的半监督学习模型利用了神经网络的深层架构强大的非线性建模能力，不仅可拟合复杂的非线性分类边界，还可过滤无关噪声，通过更充分地挖掘原始样本中的信息，获得了比GMM聚类方法更高的特征鉴别能力和模型泛化性能。

在0~18 dB信噪比条件下本文方法和基线方法的混淆矩阵如图4所示。通过对比可以发现，本文方法在0~18 dB信噪比范围内的平均分类准确率达97.78%，显著高于基线方法的92.90%。在本文方法下，所选7种调制方式的分类精度均稳定维持在95%以上，其中对8PSK和QPSK的识别性能提升尤其明显。分析原因是：同调制类型不同阶数的信号间具有较高的相似性，这类样本在半监督学习中极易产生错误伪标签，属于半监督学习中的顽固样

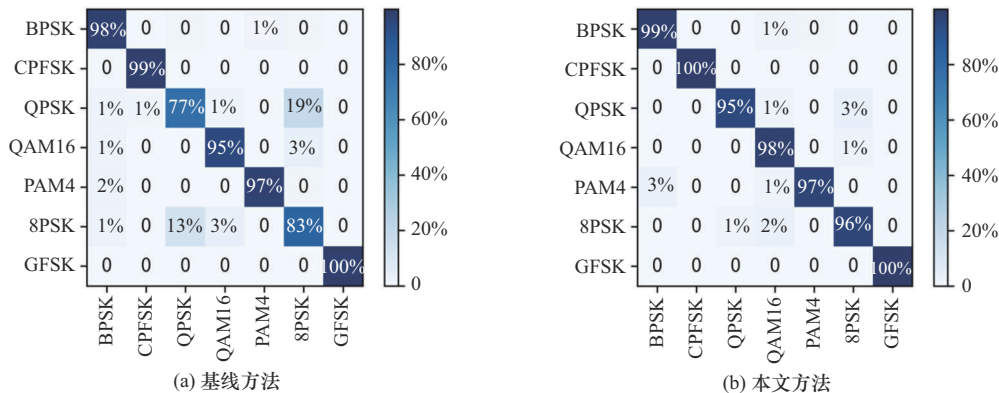


图4 在0~18 dB信噪比条件下本文方法和基线方法的混淆矩阵

本,难以被模型有效学习;本文方法通过聚类方法引入了更多的信息,有效地抑制了伪标签中的噪声。实验结果表明,本文方法对半监督学习中顽固样本难以学习的问题进行了有效改善。

3.2 伪标签质量分析

为进一步评估本文方法在信号调制识别任务中生成伪标签的有效性,本文从伪标签准确率与信息量2个角度展开相关分析验证。具体是,通过对比无标签样本的伪标签与真实标签的一致性得到伪标签准确率;利用模型的损失值下降曲线分析伪标签对模型泛化能力的贡献。

伪标签准确率及覆盖情况结果对比如图5所示。实验结果表明,本文方法生成的伪标签准确率几乎在全部迭代次数中高于基线方法,且其在前几次迭代中不仅具有较高的伪标签准确率,还覆盖了更多的样本,显著降低了错误标注引入的噪声,为模型提供了近乎真实的标注信息。原因是:在训练的初始阶段,当模型尚未达到收敛状态且其表征能力仍处于次优水平时,可以从聚类结果中学到未标注数据中潜在的类间可分性特征。进一步分析,其过程本质上是通过挖掘高维特征空间的底层数据结构,为标签稀缺条件下的参数优化提供补充性引导信息,从而缓解初始阶段因标注数据不足导致的模型表征能力受限问题,加快收敛速度。同时,从图5可以看出,本文方法的伪标签准确率并未随着置信度阈值的下降而显著下降,而基线方法在后期伪标签准确率波动较大,结合上文基线方法中全信噪比下混淆矩阵中8PSK和QPSK信号的识别准确率均远低于本文方法,进一步说明聚类置信度的引入抑

制了伪标签噪声的传播,减少了模型训练初始阶段针对8PSK和QPSK信号难以区分而带来的噪声。

图6展示了本文方法与基线方法的损失值随训练轮次的变化趋势。从图6可以看出,相较于基线方法,本文方法最终达到了更低的稳态损失值和更短的收敛周期。分析原因:一是聚类置信度的引入使得本文方法可以在训练前期添加更多的伪标签样本进入训练集,加速了参数空间定向搜索的过程;二是基于双置信度融合机制的置信度函数通过提供高可靠性样本和梯度贡献,减少了训练集低质量伪标签的噪声干扰。

进一步分析图6损失值变化曲线可以发现,本文方法与基线方法在训练集损失值下降过程中均存在幅度突增现象,说明每次迭代所加入的伪标签样本带来了更多的信息,有效打破了模型在当前训练集上的过拟合僵局。验证集损失值的波动则表明模型在参数空间中探索到新的优化方向。通过对比本文方法与基线方法损失值下降曲线可以发现:本文方法在第80、120等迭代开始的训练轮次节点出现了较大的损失值上升,基线方法损失值则上升较小。这种差异说明由于结合了聚类置信度的样本筛选策略可以在训练早期就引入更多的高置信度伪标签,使训练集中样本多样性更丰富,信息量更大,模型能够更快地捕获数据本质特征。

3.3 消融实验

为了验证动态置信度阈值以及更新策略对半监督学习性能的影响,本文在自训练半监督学习中常用的初始置信度阈值和递减步长范围内,选取若干代表值设计了消融实验。实验结果如表1所示。




图5 伪标签准确率及覆盖情况结果对比




图6 损失值随训练轮次的变化趋势

表1 不同初始阈值和递减步长下的平均准确率

初始置信度阈值	递减步长		
	0.09	0.07	0.05
0.99	96.8%	97.2%	97.4%
0.97	96.4%	97.8%	97.3%
0.95	96.7%	97.3%	97.0%
0.93	95.8%	97.5%	97.6%
0.91	95.8%	97.3%	96.6%
0.89	95.5%	94.1%	96.0%
0.87	93.9%	94.4%	95.6%
0.85	94.8%	93.4%	95.2%

从表1可以看出，初始置信度阈值设置为0.97且递减步长为0.07时，模型的最终性能达到最佳。过低的初始值会导致初期伪标签质量下降，过大的递减步长则会导致阈值快速下降，降低模型收敛稳定性。

3.4 其他实验结果

为了进一步论证本文方法的有效性，在上述实验结果的基础上，在RML2016.10b的全信噪比条件下与另外2个调制识别研究中较为通用的公开数据集RML2016.10a和RML2016.04c进行了进一步的对比实验。这2个数据集与RML2016.10b相似，只是信号样本略少。实验设置方面，选择全信噪比环境，由于RML2016.10a和RML2016.04c数据集较小，选择10%的有标签样本，其他条件均与第3节中的条件相同。

不同数据集的比较结果如图7所示。由图7可知，本文方法在RML2016.10a、RML2016.10b及RML2016.04c数据集上的平均准确率分别达到

57.22%、64.21%和69.22%，该结果显著优于基线方法的52.63%、62.38%和66.95%，充分说明了本文方法的有效性和鲁棒性。进一步分析图7可知，本文方法的性能提升在0 dB信噪比以上较为明显，负信噪比条件下较小。分析原因是：在极低信噪比条件下，现有特征向量难以有效提取判别性特征，聚类效果较差；当SNR提升至0 dB及以上时，聚类效果得到改善，从而为模型提供了更可靠的特征表示作为参考。

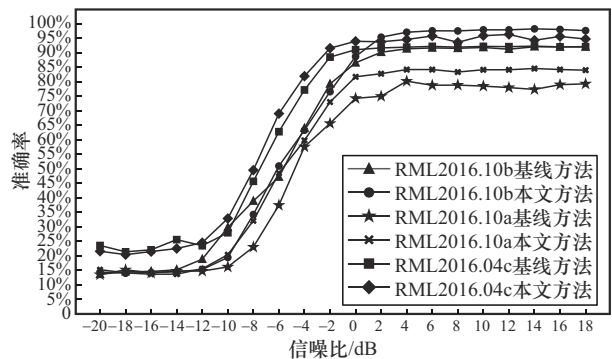


图7 不同数据集的比较结果

4 结束语

随着无线通信技术的快速发展，信号调制方式的智能识别已成为现代通信系统实现自适应、高可靠信息传输的核心技术之一。本文针对全监督学习在复杂信道环境下对大规模标注数据的高度依赖问题，提出了一种基于双置信度融合机制的半监督数字调制信号识别方法，设计了融合聚类置信度与自训练置信度的双置信度融合机制，显著提升了伪标签质量与模型泛化能力。本文在无线电公开数据集RML2016.10b上对其完成了方法的实验验证，结果

表明,本文方法在0 dB以上信噪比环境下达到了97.78%的准确率,较传统的基于自训练的半监督学习方法提升4.88%,与全监督分类方法非常接近,仅相差0.3%,证明了本文方法的有效性。其次,引入聚类置信度后,模型仅需320个训练轮次即可收敛,相较基线方法提升了约20%,显著提高了训练效率。

尽管本文方法在实验中展现出显著优势,但仍存在相关局限性,例如,信号特征的研究依赖于领域知识,面对新型调制类型的识别可能需要使用新的特征参量,未来研究需要探索更通用的信号特征或自适应特征提取方法。此外,当前调制识别领域在负信噪比条件下普遍存在性能瓶颈,现有方法依然存在强噪声淹没的信号特征退化问题,需要进一步寻找抗干扰特征的代表方案。

参考文献:

- [1] 张柏林, 姬港, 朱宇轩, 等. 基于深度学习的半监督信号调制样式识别算法[J]. 电子科技大学学报, 2024, 53(4): 511-518.
ZHANG B L, JI G, ZHU Y X, et al. A semi-supervised signal modulation mode recognition algorithm based on deep learning[J]. Journal of University of Electronic Science and Technology of China, 2024, 53(4): 511-518.
- [2] ABDI A, DOBRE O A, CHOUDHRY R, et al. Modulation classification in fading channels using antenna arrays[C]//Proceedings of the IEEE Military Communications Conference. Piscataway: IEEE Press, 2004: 211-217.
- [3] LUO M G, LI L P, TANG B. A blind modulation recognition algorithm suitable for MIMO-STBC systems[C]//Proceedings of the 2012 IEEE 12th International Conference on Computer and Information Technology. Piscataway: IEEE Press, 2012: 271-276.
- [4] BAYER Ö, ÖNER M. Joint space time block code and modulation classification for MIMO systems[J]. IEEE Wireless Communications Letters, 2016, 6(1): 62-65.
- [5] AZZOUEZ E E, NANDI A K. Automatic identification of digital modulation types[J]. Signal Processing, 1995, 47(1): 55-69.
- [6] 陈卫东, 杨绍全, 董春曦, 等. 多径信道中MPSK信号的调制识别算法[J]. 通信学报, 2002, 23(6): 14-21.
CHEN W D, YANG S Q, DONG C X, et al. Algorithm for classification of MPSK signals in multipath channel environments[J]. Journal of China Institute of Communications, 2002, 23(6): 14-21.
- [7] 王建新, 宋辉. 基于星座图的数字调制方式识别[J]. 通信学报, 2004, 25(6): 166-173.
WANG J X, SONG H. Digital modulation recognition based on constellation diagram[J]. Journal of China Institute of Communications, 2004, 25(6): 166-173.
- [8] MENDIS G J, WEI-KOCSIS J, MADANAYAKE A. Deep learning based radio-signal identification with hardware design[J]. IEEE Transactions on Aerospace and Electronic Systems, 2019, 55(5): 2516-2531.
- [9] 沈丹阳, 麦文. 基于ResNet-Transformer的通信信号自动调制识别[J]. 计算机工程, 2024, doi: 10.19678/j.issn.1000-3428.0069677.
SHEN D Y, MAI W. Automatic modulation recognition of communication signals based on ResNet-transformer network[J]. Computer Engineering, 2024, doi: 10.19678/j.issn.1000-3428.0069677.
- [10] 李昱辰, 余尔聪, 潘雪, 等. 干扰环境下通信信号的调制识别技术研究[J]. 电子科技大学学报, 2025, 54(3): 369-376.
LI Y C, YU E C, PAN X, et al. Research on modulation recognition technology of communication signals in interference environment[J]. Journal of University of Electronic Science and Technology of China, 2025, 54(3): 369-376.
- [11] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]//International Conference on Engineering Applications of Neural Networks. Berlin: Springer, 2016: 213-226.
- [12] RAJENDRAN S, MEERT W, GIUSTINIANO D, et al. Deep learning models for wireless signal classification with distributed low-cost spectrum sensors[J]. IEEE Transactions on Cognitive Communications and Networking, 2018, 4(3): 433-445.
- [13] HUYNH-THE T, HUA C H, PHAM Q V, et al. MCNet: an efficient CNN architecture for robust automatic modulation classification[J]. IEEE Communications Letters, 2020, 24(4): 811-815.
- [14] XU J L, LUO C B, PARR G, et al. A spatiotemporal multi-channel learning framework for automatic modulation recognition[J]. IEEE Wireless Communications Letters, 2020, 9(10): 1629-1632.
- [15] NJOKU J N, MOROCHO-CAYAMCELA M E, LIM W. CGDNet: efficient hybrid deep learning model for robust automatic modulation recognition[J]. IEEE Networking Letters, 2021, 3(2): 47-51.
- [16] FENG Z X, CHEN S, MA Y, et al. Learning temporal - spectral feature fusion representation for radio signal classification[J]. IEEE Transactions on Industrial Informatics, 2025, 21(1): 791-800.
- [17] ZHAI L, LI Y T, FENG Z X, et al. Learning cross-domain features with dual-path signal transformer[J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36(2): 3863-3869.
- [18] O'SHEA T J, WEST N, VONDAL M, et al. Semi-supervised radio signal identification[C]//Proceedings of the 2017 19th International Conference on Advanced Communication Technology (ICACT). Piscataway: IEEE Press, 2017: 33-38.
- [19] DONG Y H, JIANG X H, CHENG L, et al. SSRCNN: a semi-supervised learning framework for signal recognition[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(3): 780-789.
- [20] WANG X H, WANG L, FENG Y N, et al. Pseudo-label generation guided semi-supervised network for hyperspectral image and LiDAR data classification[J]. Expert Systems with Applications, 2025, 286: 128110.
- [21] 陈震峰, 吴明, 孙卫华. 基于高阶累积量和BP神经网络的数字调制识别[J]. 舰船电子工程, 2024, 44(1): 60-62.
CHEN Z F, WU M, SUN W H. Digital modulation recognition based on high order cumulant and BP neural network[J]. Ship Electronic En-

gincering, 2024, 44(1): 60-62.

- [22] 谭晓衡, 褚国星, 张雪静, 等. 基于高阶累积量和小波变换的调制识别算法[J]. 系统工程与电子技术, 2018, 40(1): 171-177.
TAN X H, CHU G X, ZHANG X J, et al. Modulation recognition algorithm based on high-order cumulants and wavelet transform[J]. Systems Engineering and Electronics, 2018, 40(1): 171-177.
- [23] 杨小牛, 楼小义, 徐建良. 软件无线电原理与应用[M]. 北京: 电子工业出版社, 2001.
YANG X N, LOU X Y, XU J L. Software-defined radio: principles and practice[M]. Beijing: Publishing House of Electronics Industry, 2001.
- [24] 高建勤, 熊淑华, 赵婧. 一种基于小波的数字调制信号识别算法[J]. 四川大学学报(自然科学版), 2007, 44(6): 1281-1284.
GAO J Q, XIONG S H, ZHAO J. A wavelet-based identification algorithm of digital modulation signals[J]. Journal of Sichuan University (Natural Science Edition), 2007, 44(6): 1281-1284.
- [25] 金银波, 张冰, 朱志宇. 基于改进的半监督 AP 聚类雷达信号分选[J]. 现代电子技术, 2014, 37(19): 6-9, 13.
JIN Y B, ZHANG B, ZHU Z Y. Radar signal sorting based on improved semi-supervised affinity propagation clustering[J]. Modern Electronics Technique, 2014, 37(19): 6-9, 13.
- [26] 黄腾飞, 李帮义, 熊季霞. 基于小波方差分解的混沌时间序列噪声估计和阈值去噪[J]. 计算机应用, 2013, 33(3): 890-895.
HUANG T F, LI B Y, XIONG J X. Noise estimation and reduction for chaotic time series by wavelet variance decomposition[J]. Journal of Computer Applications, 2013, 33(3): 890-895.
- [27] 钱莉, 姚恒, 刘华. 基于小波高频系数统计特征的电路故障诊断[J]. 电子科技, 2015, 28(6): 118-122.
QIAN L, YAO H, LIU J. Analog circuits fault diagnosis using wavelet statistical features[J]. Electronic Science and Technology, 2015, 28(6): 118-122.
- [28] 蔡政, 陶少华. 基于小波系数关系的图像去噪方法[J]. 计算机应用, 2011, 31(9): 2515-2517.
CAI Z, TAO S H. Image denoising method using inter-scale and intra-scale dependencies of wavelet coefficients[J]. Journal of Computer Applications, 2011, 31(9): 2515-2517.
- [29] DEMPSTER A P, LAIRD N M, RUBIN D B. Maximum likelihood from incomplete data via the EM algorithm[J]. Journal of the Royal Statistical Society Series B: Statistical Methodology, 1977, 39(1): 1-22.
- [30] PANIĆ B, KLEMENC J, NAGODE M. Improved initialization of the EM algorithm for mixture model parameter estimation[J]. Mathematics, 2020, 8(3): 373.
- [31] EMAM A, SHALABY M, ABOELAZM M A, et al. A comparative study between CNN, LSTM, and CLDNN models in the context of radio modulation classification[C]//Proceedings of the 2020 12th International Conference on Electrical Engineering (ICEENG). Piscataway: IEEE Press, 2020: 190-195.

[作者简介]



刘文学 (1985-), 男, 陕西渭南人, 博士, 中国科学院微电子研究所高级工程师, 主要研究方向为卫星导航信号与信息处理、ISAC (通信感知一体化) 等。




苗昀宸 (2001-), 男, 山西长治人, 中国科学院大学硕士生, 主要研究方向为认知无线电、人工智能等。



杨超三 (1989-), 男, 山东滕州人, 博士, 中国科学院微电子研究所助理研究员, 主要研究方向为抗干扰通信处理、ISAC 等。



宋留斌 (1987-), 男, 江苏海安人, 中国科学院微电子研究所高级工程师, 主要研究方向为抗干扰通信、无线自组网、强化学习等。



李金海 (1978-), 男, 山东济南人, 中国科学院微电子研究所正高级工程师、博士生导师, 主要研究方向为综合 PNT 定位与授时技术、分布式组网、自适应联合通信与协同调度技术等。



邱昕 (1980-), 男, 河南平顶山人, 中国科学院微电子研究所研究员、博士生导师, 主要研究方向为 SOC 芯片设计、无线通信系统设计、信息系统工程等。