

DOI:10.20079/j.issn.1001-893x.220721005

“电磁信号智能感知”专题

引用格式:潘成胜,蔡韧,石怀峰,等.基于协同学习的频谱智能感知方法[J].电讯技术,2023,63(12):1839-1846.[PAN C S,CAI R,SHI H F,et al.
An intelligent spectrum sensing method based on collaborative learning[J].Telecommunication Engineering,2023,63(12):1839-1846.]

基于协同学习的频谱智能感知方法*

潘成胜¹,蔡韧¹,石怀峰^{1,2},施建锋^{1,3},王钰玥¹

(1.南京信息工程大学 电子与信息工程学院,南京 210044;2.南京理工大学 自动化学院,南京 210094;
3.东南大学 移动通信国家重点实验室,南京 211189)

摘要:目前无线网络频谱环境时空分布复杂多变,现有多用户协同感知方法数据预处理繁琐,感知效率低下。为此,在由用户感知层和边缘融合层构成的系统架构下,提出了一种基于协同学习的频谱智能感知算法。用户感知层采用多分支卷积循环门控神经网络,利用原始归一化能量信号的底层结构信息,实现本地感知。边缘融合层基于自注意力机制进行消息传播,融合用户感知层中各个非授权用户的感知结果得出最终决策。实验表明,在信噪比为-20 dB 以及 5 个用户协同感知的情况下,该方法能在虚警概率为 1.91% 时达到 18.3% 的检测概率,相比对比模型提升了 6.1%,且不需要对原始数据额外预处理,降低了算法的复杂度。

关键词:智能频谱感知;协同学习;卷积神经网络;门控循环单元;自注意力机制

开放科学(资源服务)标识码(OSID):



微信扫描二维码
听独家语音释文
与作者在线交流
享本刊专属服务

中图分类号:TN911.23 文献标志码:A 文章编号:1001-893X(2023)12-1839-08

An Intelligent Spectrum Sensing Method Based on Collaborative Learning

PAN Chengsheng¹,CAI Ren¹,SHI Huaifeng^{1,2},SHI Jianfeng^{1,3},WANG Yuyue¹

(1. School of Electronics and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China;

2. School of Automation, Nanjing University of Science and Technology, Nanjing 210094, China;

3. National Mobile Communications Research Laboratory, Southeast University, Nanjing 211189, China)

Abstract: The spatial and temporal distribution of current heterogeneous network spectrum environment is complex and variable, the data preprocessing of existing multi-user cooperative sensing methods is cumbersome, and the sensing efficiency is low. For above problems, a cooperative learning-based spectrum intelligent sensing algorithm is proposed under a system architecture consisting of user sensing layer and edge fusion layer. The user-aware layer uses a multi-branch convolutional recurrent gated neural network to realize local sensing by using the underlying structural information of the original normalized energy signal. The edge fusion layer performs message propagation based on a self-attention mechanism and fuses the sensing results of each unauthorized user in the user-aware layer to arrive at the final decision. Experiments show that when the signal-to-noise ratio is -20 dB and five users are sensing cooperatively, the proposed method is able to achieve a detection probability of 18.3% at a false alarm probability of 1.91%, an improvement of 6.1% compared with the comparison model, and does not require additional pre-processing of the raw data, thus reducing the complexity of the algorithm.

Key words: intelligent spectrum sensing; collaborative learning; convolutional neural network; gated cycle unit; self-attention mechanism

* 收稿日期:2022-07-21;修回日期:2022-08-23

基金项目:国家自然科学基金资助项目(61931004,61801073);江苏省自然科学基金项目(BK20210641)

通信作者:潘成胜

0 引言

随着通信网络技术的不断发展,无线通信呈现出多种异构网络共存、多样化业务需求繁多的场景,如在 5G 超密集网络、物联网、战术通信网络中,各种用频终端在有限地域内密集开设、自由进出,导致频谱环境时空分布复杂,频谱资源异常紧张。同时,传统授权分配策略导致频谱利用率不高以及系统内部互相干扰严重。认知无线电技术通过频谱感知和智能学习实现频谱的动态分配,在不干扰授权用户通信的前提下,非授权用户可以在时间、空间和频率上进行多维频谱复用,提高频谱资源的整体利用率^[1]。频谱感知作为认知无线电的重要环节,只有可靠准确的感知才能有正确的分析和决策。

现有的频谱感知方法按照感知节点的个数可以分为单用户感知和多用户协同感知,其中单用户感知又可以分为模型驱动和数据驱动算法。模型驱动算法主要包括能量检测^[2-4]、循环平稳特征检测^[5-6]、匹配滤波检测^[7]以及协方差检测^[8-9]等。这些算法难以在检测成本和检测性能之间取得较好的平衡。近年来,随着机器学习技术的发展,学者们通过机器学习、深度学习等数据驱动算法实现了高效频谱感知的方法。例如,Gao 等人^[10]提出了一种利用调制信号固有结构信息的深度学习检测模型,对调制方案具有良好的泛化能力。Yang 等人^[11]提出了一种盲频谱感知方法,将序列输入到卷积神经网络和长短时记忆网络提取特征后由全连接层实现分类,与传统能量检测算法相比,在低信噪比下具有更好的性能。

然而在复杂电磁环境中,由于多径衰落、隐藏终端和低信噪比等问题,单用户的检测性能降低。为了解决这一问题,学者们通过采用多用户协同感知,利用不同空间的感知结果来提高检测性能。多用户协同感知可以分为集中式协同感知和分布式协同感知。集中式协同感知结构简单,效率高,应用较为广泛;文献[12]对协方差矩阵进行归一化灰度处理并作为神经网络的输入,通过图像分类的方式解决频谱感知问题;文献[13]通过连续小波变换得到采样信号的时频矩阵,同样将频谱感知问题转换为图像分类问题进行处理;文献[14]提出了基于多特征组合网络的协同频谱感知算法,利用 CNN-GRU 获取单用户感知的局部信息,然后将每个用户的局部信息组合后通过分类网络实现协同感知。

现有协同感知的研究虽然能够在一定程度上提

高感知性能,但多是通过收集采样信号,计算协方差矩阵并从中获取特征值。在这种方式下,本地用户只负责数据采样和上传,计算任务全部集中于融合中心,导致本地用户不能及时应对频谱环境变化。针对这些问题,本文在由用户感知层和边缘融合层构成的系统架构下,提出一种分层协同频谱智能感知算法。该算法主要分两个阶段实现:第一阶段由各个感知用户独立采样数据,通过多分支卷积门控循环神经网络(Multi-branch Convolutional Gated Cycle Network, MBCGN)完成本地感知并将感知结果报告给边缘融合层;第二阶段边缘融合层基于自注意力机制进行消息传播,每个感知结果以不同权重融合其他感知结果,然后通过非线性层对表示学习后的特征分类得出最终决策下发给感知用户。分层设计将终端设备部署在电磁环境中,能够快速响应频谱环境变化,将计算任务适当卸载给终端设备,可以提高总体运行效率。

1 问题定义与系统模型

1.1 问题定义

用户感知是针对某个窄带在特定的时间内是否有授权用户占用情况的判断,因此可建模为二元假设检验问题^[1]。

$$y(n) = \begin{cases} \omega(n), & H_0 \\ h(n)x(n) + \omega(n), & H_1 \end{cases} \quad (1)$$

式中: $y(n)$ 是本地感知机的接收信号; $x(n)$ 是授权用户发送信号; $h(n)$ 表示信道增益; $\omega(n)$ 代表信道噪声;假设 H_0 表示信道中只有噪声信号, H_1 表示信道中有主用户占用。

协同频谱智能感知是对用户感知结果的融合,感知用户对接收信号 $y(n)$ 进行检验得到感知概率向量 p ,然后融合法则完成感知融合,如式(2)所示:

$$s = f(p_1; p_2; \dots; p_M) \quad (2)$$

式中: $p_i (i = 1, 2, \dots; M)$ 是第 i 个用户的感知概率向量; f 是融合法则; s 是最终融合结果。

1.2 系统模型

如图 1 所示,基于协同学习的频谱智能感知系统模型分为用户感知层和边缘融合层。在用户感知层中,有一组授权通信终端和 M 个非授权通信终端。通信终端具有监测频谱、收集数据和用户计算的能力。每个终端从频谱环境中独立采集数据并通过神经网络模型训练后做出推断,将本地感知结果上报给边缘融合层。在边缘融合层中,基站具有数

据通信、数据存储和更为强大的边缘计算的能力。基站通过接收通信终端的本地感知结果,利用神经网络融合算法做出最终决策,并下发给各个参与感知的终端用户。

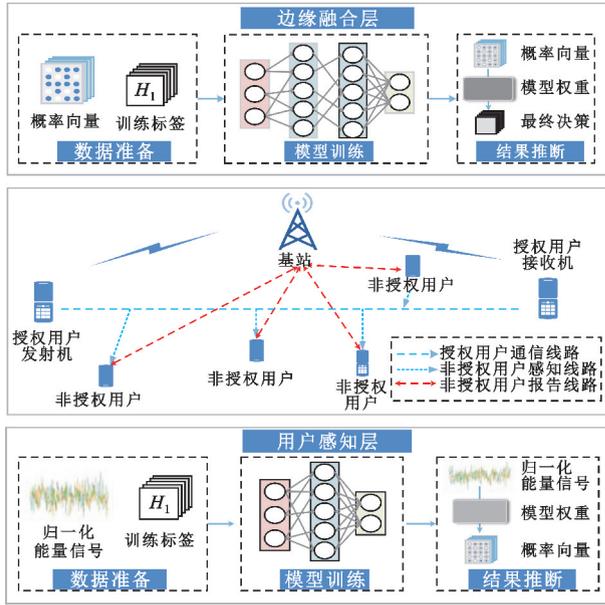


图 1 分层协同频谱智能感知模型

2 分层协同频谱感知模型

2.1 用户感知模型

2.1.1 网络结构

如图 2 所示,本文提出一种多分支卷积门控循环神经网络实现本地感知。将原始归一化能量信号作为输入,分别通过卷积网络分支和循环门控单元 (Gated Cycle Unit, GRU) 分支提取频谱数据的局部特征和全局特征,然后将多分支提取到的特征合并后输入到全连接网络得到本地感知概率向量。

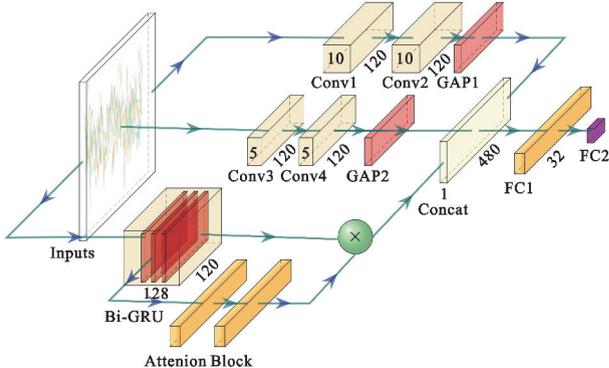


图 2 MBCGN 网络模型结构

MBCGN 网络有 3 个分支,第一个分支是卷积核

大小为 10 的一维卷积网络,第二个分支是卷积核大小为 5 的一维卷积网络,第三个分支是双向门控循环神经网络 (Bi-directional Gated Cycle Unit, Bi-GRU)。具体来说,一方面,使用一个大卷积核和一个小卷积核来捕获局部特征。每个分支两层卷积之后使用全局平均池化对卷积提取特征进行降维。使用全局平均池化操作的优点有两个方面:一是维持和第三个分支提取的全局特征维度相近,便于特征合并;二是对所有卷积学习到的特征进行全局平均池化操作可以提高学习的稳定性。另一方面,使用 Bi-GRU 提取输入信号的全局特征,并利用注意力网络降低噪声数据的影响。此后,3 个分支的输出通过一个级联层输入到两个全连接层,得到本地感知概率向量。为了防止过拟合,在每层卷积后都使用了 Dropout。

2.1.2 卷积模块

卷积神经网络局部连接、权值共享、平移不变性等特性使其具有强大的表征学习能力和高效的深度计算能力,已广泛应用于语音、传感器数据等时间序列的分析与处理。同样地,频谱数据也是一种典型的时间序列,每条序列可以表示为 $x \in \mathbb{R}^{L_{in} \times C_{in}}$,其中, L_{in} 表示采样长度, C_{in} 表示每条序列采样 I 路和 Q 路两个通道数据。因此,本文引入卷积神经网络实现对原始归一化能量信号的特征提取,计算方式如式 (3) 所示^[15]:

$$z = \sigma \left(\sum_{k=0}^{C_{in}-1} w(k) * x(k) + b \right). \quad (3)$$

式中: $z \in \mathbb{R}^{C_{out} \times L_{out}}$ 表示输入序列经过卷积层后的输出矩阵; $*$ 表示卷积运算; w 和 b 是可学习参数,分别表示权重矩阵和偏置矩阵; σ 表示非线性激活函数。

2.1.3 GRU 模块

虽然卷积神经网络能够很好地提取局部特征,但其无法充分捕获长距离信息。循环神经网络则可以通过重复执行单元网络结构来捕获当前时刻状态与之前状态的关系,具有处理任意长度时间序列的能力。GRU 是长短期记忆网络 (Long Short-Term Memory, LSTM) 结构简化的变体,通过减少一个隐藏状态降低计算开销,同时也达到了 LSTM 相近的性能^[16]。为了提高感知的实时性,本文使用双向 GRU 网络提取频谱数据的全局特征。

如图 3 所示,GRU 中有一个隐藏状态 h_t ,两个门控单元为重置门 r_t 和更新门 z_t 以及类似于传统循环

神经网络单元的候选状态 \tilde{h}_t , 具体计算方式如下:

$$\begin{cases} r_t = \sigma(W_r x_t + U_r h_{t-1}) \\ z_t = \sigma(W_z x_t + U_z h_{t-1}) \\ \tilde{h}_t = \tanh(W \tilde{x}_t + U(r_t \odot h_{t-1})) \\ h_t = (1 - z_t) h_{t-1} + z_t \tilde{h}_t \end{cases} \quad (4)$$

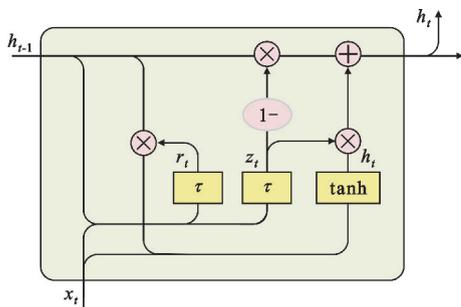


图3 GRU 模型结构

在 GRU 门控单元中, 重置门控制短期依赖, 更新门控制长期依赖, 输入均是当前时刻的特征 x_t 和上一时刻的隐藏状态 h_{t-1} , 输出激活函数是 sigmoid 函数, 能够将输出映射到 0~1 之间, 控制信息的流入。候选状态 \tilde{h}_t 通过重置门控制当前时刻输入与之前状态的依赖关系, 如果重置门趋向 0, 则完全遗忘之前的状态, 候选状态相当于当前时刻的输入信息。当前时刻的状态 h_t 也是网络的输出, 由候选状态和前一时刻状态线性插值得到。

双向 GRU 中包含了前向隐藏状态和后向隐藏状态, 每个方向的计算方式和上述一致, 双向网络能够较好地捕获频谱数据的前后联系。对于双向 GRU 捕获的全局特征通过乘性注意力降低噪声影响, 计算方式如式(5)所示^[17]:

$$\begin{cases} S = \tanh(h_t) \\ \alpha = \text{softmax}(w^T S) \\ O = h_t \cdot \alpha^T \end{cases} \quad (5)$$

式中: S 是注意力隐藏状态; α 是注意力系数。

2.2 边缘融合模型

协同感知的融合准则可以分为硬判决和软判决两类, 硬判决主要有 AND 准则、OR 准则和 K 秩准则, 软判决有对数似然比算法和线性加权算法^[18]。硬判决由于只是对感知结果进行逻辑运算, 存在一定的缺陷, 例如 AND 准确检测概率低, OR 准确虚警概率高, 而 K 秩融合准则需要选择合适判断阈值; 软判决算法是将采集信息直接发送至融合中心, 这个过程开销较大, 系统实现复杂, 实时性较差。本文

提出的基于自注意力机制的消息融合网络 (Messages Fusion Based on Self-attention, SA-MF) 是对感知结果的融合, 以自注意力的方式引入感知信息交流, 在保持感知实时性的同时提高感知的可靠性。

2.2.1 网络结构

融合网络具体结构如图 4 所示, 网络的输入是 M 个终端用户通过 MBCGN 网络进行本地感知的概率矩阵 $P \in \mathbb{R}^{M \times 2}$, 然后使用金字塔型一维卷积学习概率矩阵的高维表示, 即输入矩阵通过 3 个一维卷积组成的嵌入层得到 d 维特征表示, 嵌入特征通过基于自注意力机制的自注意力编码器模块完成感知信息交互, 最后经全局平均池化得到最终融合特征, 再由一个全连接层得到融合决策。

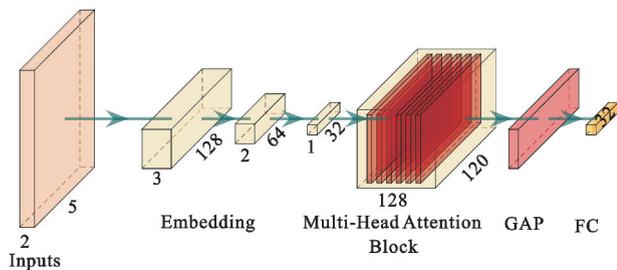


图4 SA-MF 网络模型结构

2.2.2 自注意力编码器模块

Transformer 是谷歌提出的一种编解码网络结构, 最初应用在机器翻译任务上, 通过自注意力机制实现快速并行计算, 解决循环神经网络训练慢的缺点。随后, Transformer 各种变体广泛应用在自然语言、计算机视觉、语音等领域。编码器网络能够有效地学习特征表示, 并且自注意力机制模型是一种弱归纳偏置的学习方式, 每个感知用户可以利用这种学习方式感知结果交流。本文使用一维卷积完成概率矩阵的嵌入表示, 然后由编码器学习感知信息交互的过程。对于编码器表示学习后的特征采用全局平均池化的方式进行降维, 能够有效融合各个感知用户的特征表示, 实现共同决策。

如图 5 所示, 编码器结构主要由多头自注意力模块和位置全连接前馈网络模块组成, 多头自注意力模块帮助节点关注其他的节点的内容, 位置全连接前馈网络提供非线性变化, 同时保证输出特征维度和输入特征维度相同。在网络层连接上使用了残差连接解决梯度消失和权重矩阵的退化问题, 使用了层归一化对同一层神经元做归一化, 避免变长输

人和批处理大小的影响^[19]。

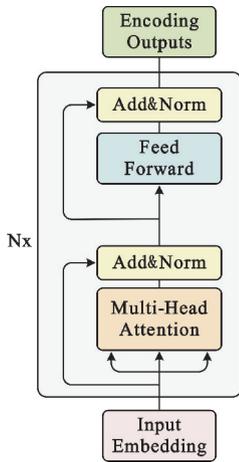


图 5 自注意力编码器网络结构

编码器的计算过程如式(6)所示:

$$\begin{cases} \text{subLayer}(x_e) = \text{MultiHead}(x_e, x_e, x_e) \\ y_1 = \text{LayerNorm}(x_e + \text{subLayer}(x_e)) \\ \text{FFN}(y_1) = \max(0, y_1 W_1 + b_1) W_2 + b_2 \\ y_2 = \text{LayerNorm}(y_1 + \text{FFN}(y_1)) \end{cases} \quad (6)$$

式中:MultiHead 为多头注意力层;LayerNorm 为层归一化运算;FFN 是位置前馈神经网络。多头注意力层的计算方式如下:

$$\begin{cases} \text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Con}(\text{head}_1, \text{head}_2, \dots, \text{head}_n) \mathbf{W}^o \\ \text{head}_i = \text{Attention}(\mathbf{Q} \mathbf{W}_i^q, \mathbf{K} \mathbf{W}_i^k, \mathbf{V} \mathbf{W}_i^v) \\ \text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q} \mathbf{K}^T}{\sqrt{d_k}}\right) \mathbf{V} \end{cases} \quad (7)$$

式中: $\mathbf{Q}, \mathbf{V}, \mathbf{K}$ 分别为查询矩阵、键矩阵和值矩阵,在自注意力模型中 $\mathbf{Q} = \mathbf{V} = \mathbf{K}$;Con 运算表示将多头学习到的特征合并; \mathbf{W}^o 为权重矩阵,引入线性变化; \mathbf{W}_i 为对应多头中的投影矩阵;Attention 是缩放点积注意力; d_k 是缩放系数。

3 实验与结果分析

3.1 数据集构造

为了模拟真实的环境,本文采用文献[20]中提供的基准数据集,模拟了正交相移键控(Quadrature Phase Shift Keying, QPSK)调制信号。信道模拟考虑了中心频率偏移、采样率偏移、加性高斯白噪声、多径和衰落的随机过程。数据采集是从仿真输出中随机采样时间片段,同时保持了 I 路和 Q 路两个通道

数据。为了考虑低信噪比的通信环境,设定数据信噪比范围为 $-20 \sim 5$ dB,间隔为 1 dB,每个信噪比下分别设置 64, 128, 256, 512 个采样点情况,各采集 1 000 个样本。对于协同感知任务,本文设定了有 1, 3, 5 和 8 个终端用户的情况,每种情况下数据结构和上述一致。对于授权用户不存在的负样本,本文采用循环对称复高斯噪声表示,按照 1:1 的比例和正样本组成最终频谱感知数据集,数据集按照 6:2:2 划分为训练集、验证集和测试集。

3.2 模型训练

检测算法有两个重要的衡量指标,分别是检测概率 P_d 和虚警概率 P_f ,它们在传统能量检测算法中可以表示为

$$P_d = P(\text{Tr} > \gamma | H_1), \quad (8)$$

$$P_f = P(\text{Tr} > \gamma | H_0). \quad (9)$$

式中:Tr 和 γ 分别为能量统计值和能量检测门限。能量检测算法可以通过设定检测门限实现恒虚警检测,但是基于深度学习方法以分类概率作为判定结果并不存在预设的门限值,所以无法实现精准性能控制。本文参照文献[11]将验证集虚警概率作为额外的训练指标指导模型训练,训练损失函数采用交叉熵损失函数。如果验证集虚警概率处于预设虚警概率范围内,则结束模型训练。通过此方法可以解决模型上限后检测概率与虚警概率此消彼长的问题,实现了近似恒虚警检测,提高了模型的稳定性。

在分层协同频谱感知模型中,首先在本地感知数据集上训练 MBCGN 网络,具体的网络超参数设置如表 1 所示;然后使用训练好的 MBCGN 网络在多用户协作数据集上推断两种假设的概率矩阵并作为 SA-MF 网络的数据集;最后对 SA-MF 网络进行训练,训练损失函数也采用交叉熵损失函数,网络的超参数设置如表 2 所示。

表 1 MBCGN 网络参数

超参数	参数值
Number of convolution kernels	120
Convolution kernels size	5&10
GRU hidden units	120
FC hidden units	64&2
Batch size	200
Dropout ratio	0.2
Optimizer	Adam
Learning rate	0.000 3

表 2 SA-MF 网络超参数

超参数	参数值
Embedding units	32
Number of heads	8
Number of encoding layers	2
FFN units	32
Dropout ratio	0.2
Batch size	200
Optimizer	Adam
Learning rate	0.000 1

3.3 MBCGN 网络性能

图 6 所示是本文模型与其他几种同样以时间序列处理方式模型在采样长度为 128 的 QPSK 信号的检测性能的对比。为了实验的公平性,对比模型的参数依照相应给出的超参数进行设定。文献[10]提出的 DetectNet 先通过两层一维卷积提取局部,然后通过两个神经元的全连接层组合特征后与输入进行残差连接,残差连接后的特征再通过 LSTM 提取时间特征,最后通过全连接层实现分类。文献[11]提出的 CNN-LSTM 网络将序列输入到卷积神经网络和长短时记忆网络提取特征后由全连接层实现分类。

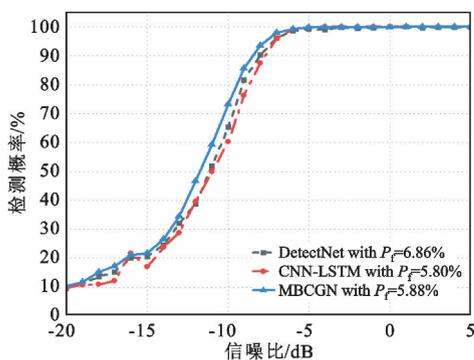


图 6 本地感知模型对比实验结果

从不同信噪比下的检测概率结果可以看出,在这 3 种模型中,本文提出的 MBCGN 模型具有更好的检测性能,尤其是在信噪比为 $-15 \sim -5$ dB 时,检测概率明显高于另外两种模型,如信噪比为 -10 dB 时,MBCGN 的检测概率为 74.3%,DetectNet 的检测概率为 66.2%,CNN-LSTM 的检测概率为 60%,本文模型在检测概率上相对提升了 8.1% 和 14.3%,同时 MBCGN 的虚警概率在这 3 个模型中只比最低的并行 CNN-LSTM 模型高 0.08%,但检测概率却有

着明显的提升。在表 3 中,参数量是模型可训练参数的个数,训练时间为模型单个 epoch 所用时间,感知时间为单个样本的在线感知时间。由于使用大卷积核的原因,MBCGN 网络在参数量上大于 DetectNet,但多分支并行计算以及使用 GRU 代替 LSTM 使得其在训练时间和在线感知时间上有较为明显的提升,说明 MBCGN 网络取得了感知性能与感知成本的较好平衡。

表 3 用户感知模型的参数量和训练时间

模型名称	参数量	训练时间/s	感知时间/ms
MBCGN	440 498	16	28
DetectNet	268 108	80	175
CNN-LSTM	662 018	74	148

采样长度是影响检测性能的重要因素。从图 7 所示的结果中可以直观看出,随着采样长度的增加检测的性能就越好。当采样长度为 512,在信噪比为 -7.5 dB 时就已经达到了 100% 的检测概率;而采样长度为 64,在信噪比为 2.5 dB 时才达到 100% 检测概率。然而在信噪比为 $-20 \sim -16$ dB 时,长采样序列的检测概率并没有比短采样序列高很多。这是因为长序列需要更大的卷积核和更深层次的卷积神经网络来捕获局部特征,本文主要针对采样长度为 128 时优化参数设置,这自然使得在低信噪比时长采样序列的优势没有发挥出来。但采样长度越长,意味采样所需时间就越长,计算和存储消耗就越大,对实时性检测有一定的影响。本文通过适中的采样长度和多用户协作感知的方式提高检测性能。

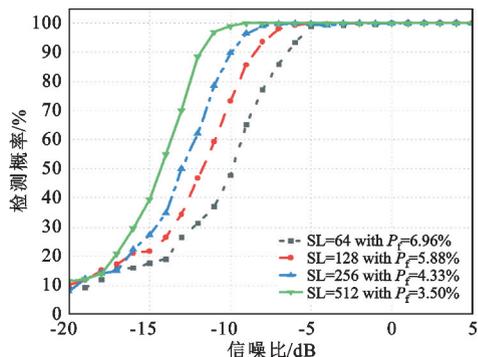


图 7 不同采样长度结果

3.4 SA-MF 网络性能

为了验证 SA-MF 网络的检测性能,本文选择采样长度为 128 的 QPSK 调制模式数据进行实验。首先是与文献[10]的柔性组合网络(Soft Combination Network,SCN)模型、文献[14]的多特征组合网络

(Multifeatures Combination Network, MCN) 模型以及传统的硬判决法则的对比,结果如图 8 所示,非智能的 OR 硬判决融合准则实现了最高的检测概率,但也有着最高的虚警概率,而 AND 准则有着最低的虚警概率和最低的检测概率。过高的虚警概率和过低的检测概率会系统资源的浪费,传输效率低下。K 秩融合准则、SCN 和 MCN 模型的检测概率较为接近,其中组合多特征的 MCN 具有较低的虚警概率,而本文模型实现了更高检测概率和更低的虚警概率,整体检测概率相对于这三种模型分别提高 1.93%, 1.62% 和 1.92%, 虚警概率分别降低了 1.24%, 0.31% 和 0.03%。这得益于自注意力机制消息融合能够充分利用终端用户感知结果。

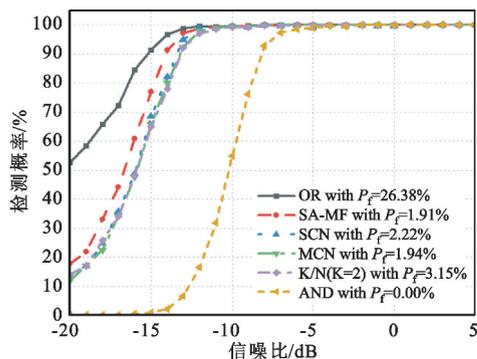


图 8 融合模型对比结果

最后,本文对终端用户的个数对检测性能的影响进行了实验,如图 9 所示,分别是 1,3,5,8 个用户的检测结果,可以直观看出随着感知用户的增加,检测性能也得到显著的提升。当信噪比为 -15 dB 时,4 种情况下的检测概率分别为 29.4%, 43.9%, 77.6% 和 98.9%, 虚警概率分别为 6.02%, 2.96%, 1.91% 和 1.24%。因此,多用户协作感知可以很好地解决单用户由于多径衰落、隐藏终端和低信噪比等造成检测性能降低的问题。

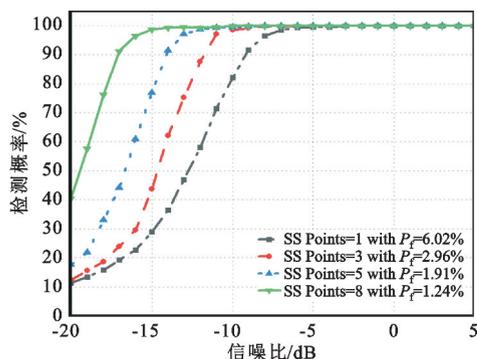


图 9 不同感知用户个数结果

4 结束语

面对无线网络中复杂多变的频谱环境,而现有多用户协同感知方法存在数据预处理繁琐、感知效率低下的问题,本文在由用户感知层和边缘融合层构成的系统架构下,提出了一种基于协同学习的频谱智能感知算法。用户感知层采用多分支卷积循环门控神经网络利用原始归一化能量信号的底层结构信息,实现本地感知;边缘融合层基于自注意力机制进行消息传播,融合用户感知层中各个非授权用户的感知结果得出最终决策。实验结果表明,所提本地感知模型不仅提高了检测概率,降低了虚警概率,而且减少了模型参数量和训练时间,取得了检测性能与检测成本的较好平衡;感知融合模型有效融合多个用户感知结果,在低信噪比时检测性能有显著提升。

后续将主要针对本地感知模型进行优化,进一步提高感知融合的性能。

参考文献:

- [1] NAHAR A, EMMA P G, WANG J, et al. Spatial-temporal opportunity detection for spectrum-heterogeneous cognitive radio networks: two-dimensional sensing [J]. IEEE Transactions on Wireless Communications, 2013, 12(2): 516-526.
- [2] DIGHAM F F, ALOUINI M S, SIMON M K. On the energy detection of unknown signals over fading channels [J]. IEEE Transactions on Communications, 2007, 55(1): 21-24.
- [3] ATAPATTU S, TELLAMBRA C, HAI J. Spectrum sensing via energy detector in low SNR [C]// Proceedings of 2011 IEEE International Conference on Communications. Piscataway: IEEE, 2011: 1-5.
- [4] LOPEZ-BENITEZ M, CASADEVALL F. Improved energy detection spectrum sensing for cognitive radio [J]. IET Communications, 2012, 6(8): 785-796.
- [5] GARDNER W A. The spectral correlation theory of cyclostationary time-series [J]. Signal Processing, 1986, 11(1): 13-36.
- [6] 束学渊, 汪立新. 联合循环平稳特征 PCA 与 XGBoost 的频谱感知 [J]. 计算机应用与软件, 2020, 37(4): 114-118.
- [7] CABRIC D S, MISHRA S M, BRODERSEN R W. Implementation issues in spectrum sensing for cognitive radio [C]// Proceedings of Signals Systems and Computers. Piscataway: IEEE, 2004: 772-776.
- [8] ZENG Y, LIANG Y C. Eigenvalue based spectrum sensing algorithms for cognitive radio [J]. IEEE Transactions on

- Communications,2008,57(6):1784-1793.
- [9] 丁凯,刘占军,李召义,等. 家庭基站中基于随机矩阵的能量动态检测频谱分配机制[J]. 电讯技术,2018,58(3):239-244.
- [10] GAO J, YI X, ZHONG C, et al. Deep learning for spectrum sensing [J]. IEEE Wireless Communications Letters,2019,8(6):1727-1730.
- [11] YANG K, HUANG Z, WANG X, et al. A blind spectrum sensing method based on deep learning [J]. Sensors, 2019,19(10):1-11.
- [12] 盖建新,薛宪峰,吴静谊,等. 基于深度卷积神经网络的协作频谱感知方法[J]. 电子与信息学报,2021,43(10):2911-2919.
- [13] 罗聪,鲁进,钱琼. 基于小波变换和残差神经网络的全盲频谱感知方法[J]. 电讯技术,2023,63(6):775-780.
- [14] XU M, YIN Z, ZHAO Y, et al. Cooperative spectrum sensing based on multi-features combination network in cognitive radio network [J]. Entropy 2022,24:129-137.
- [15] KIM Y. Convolutional neural networks for sentence classification [C]//Proceedings of Conference on Empirical Methods in Natural Language Processing. Stroudsburg: Association for Computational Linguistics, 2014:1746-1751.
- [16] CHUNG J, GULCEHRE C, CHO K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling [C]//Proceedings of the 27th Advances in Neural Information Processing Systems. Montreal:IEEE,2014:457-465.
- [17] ZHOU P, SHI W, TIAN J, et al. Attention-based bidirectional long short-term memory networks for relation classification [C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics. Berlin: Association for Computational Linguistics,2016:207-212.
- [18] 李承原. 认知无线电中节能的协作频谱感知研究 [D]. 南京:南京邮电大学,2020.
- [19] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//Proceedings of the Thirty-first Annual Conference on Neural Information Processing Systems. California: NIPS,2017:6000-6010.
- [20] O'SHEA T J, WEST N. Radiomachine learning dataset generation with GNU radio [C]//Proceedings of the 6th GNU Radio Conference. Colorado:CRCon,2016:1-6.

作者简介:

潘成胜 男,1962 年生于江苏无锡,2001 年获博士学位,现为教授,主要研究方向为智能网络理论与关键技术。

蔡 韧 男,1997 年生于江苏宿迁,2020 年获学士学位,现为硕士研究生,主要研究方向为频谱感知技术。

石怀峰 男,1989 年生于江苏徐州,2014 年获硕士学位,现为讲师,主要研究方向为异构链路汇聚技术。

施建锋 男,1994 年生于江苏盐城,2019 年获博士学位,现为讲师,主要研究方向为无线资源管理技术。

王钰玥 女,1998 年生于江苏盐城,2020 年获学士学位,现为硕士研究生,主要研究方向为智能网络流量预测技术。