

DOI:10.19651/j.cnki.emt.2417393

基于 Inception-BiGRU 和注意力机制的频谱感知方法研究^{*}

殷晓虎 张安熠 张珂珂 田冲

(西安科技大学通信与信息工程学院 西安 710600)

摘要: 频谱感知是缓解频谱资源短缺的关键技术之一,其中智能频谱感知已成为当前研究的热点方向。针对现有频谱感知方法对信号特征提取不充分以及在低信噪比下频谱感知效果不佳的问题,提出一种由 Inception 模块、双向门控循环单元、时间注意力机制和全连接层网络组成的频谱感知混合模型。首先,Inception 模块对接收到的 I/Q 信号进行多尺度空间特征的提取;然后,采用双向门控循环单元获取信号的时间序列特征,并通过时间注意力机制强化重要时序特征;最后,全连接层网络将提取到的特征映射到频谱状态的分类空间完成分类识别。实验结果表明,本文方法与多种现有频谱感知方法相比显著提升了感知性能,模型的整体检测准确率达到 84.55%,当信噪比为 -20 dB 时,该方法的感知误差为 24%;且对多种调制类型的无线电信号具有较好的适应性。所提方法无需依赖任何先验信息,在低信噪比和复杂无线电环境下展现出较强的鲁棒性,实现了感知性能与模型复杂度的有效平衡,为智能频谱感知提供了一种新的解决方案。

关键词: 频谱感知;深度学习;Inception 模块;双向门控循环单元;时间注意力机制

中图分类号: TN92 文献标识码: A 国家标准学科分类代码: 510.5015

Spectrum sensing method based on Inception-BiGRU and attention mechanism

Yin Xiaohu Zhang Anyi Zhang Keke Tian Chong

(School of Communication and Information Engineering, Xi'an University of Science and Technology, Xi'an 710600, China)

Abstract: Spectrum sensing is one of the key technologies to alleviate spectrum resource shortages, and intelligent spectrum sensing has become a hot research direction. To address the issues of insufficient feature extraction in existing spectrum sensing methods and poor sensing performance under low signal-to-noise (SNR) ratio conditions, a hybrid spectrum sensing model is proposed. The model consists of an Inception module, bidirectional gated recurrent unit, temporal attention mechanism, and fully connected layer network. Firstly, the Inception module extracts multi-scale spatial features from the received I/Q signals. Then, the bidirectional gated recurrent unit is used to capture the temporal sequence features of the signals, while the temporal attention mechanism enhances important temporal features. Finally, the fully connected layer network maps the extracted features to the classification space of spectrum states to complete classification and recognition. The experimental results show that the proposed method significantly improves perception performance compared to several existing spectrum sensing methods. The overall detection accuracy of the model reaches 84.55%, and when the SNR is -20 dB, the perception error of the method is 24%. The proposed method also demonstrates good adaptability to various modulation types of radio signals. It does not rely on any prior information and exhibits strong robustness in low SNR and complex radio environments. This approach achieves an effective balance between perception performance and model complexity, providing a new solution for intelligent spectrum sensing.

Keywords: spectrum sensing; deep learning; Inception module; bidirectional gated recurrent unit; temporal attention mechanism

0 引言

随着 5G 网络的大规模部署、物联网 (internet of

things, IoT) 和人工智能 (artificial intelligence, AI) 技术的广泛应用,以及无线通信系统和设备数量的迅速增长,有限的频谱资源越来越难以满足需求^[1],根据美国联邦通信委

收稿日期:2024-11-18

* 基金项目:陕西省科技计划项目(2020GY-029)资助

员会(federal communications commission,FCC)研究,固定频谱分配策略下频谱资源未被充分利用。为了解决这一问题,Mitola 提出了认知无线电(cognitive radio,CR)概念^[2],CR 通过检测授权用户(primary user,PU)状态使非授权用户(secondary user,SU)能够机会性地使用空闲频段,从而为缓解频谱资源受限与需求增长之间的矛盾提供了潜在解决方案。频谱感知(spectrum sensing,SS)能够检测 PU 频段的占用状态,是认知无线电系统中的一项关键技术^[3]。

传统频谱感知算法包括能量检测(energy detection,ED)^[4]、匹配滤波器检测^[5]、循环平稳特征检测^[6]和特征值检测^[7]等,这些算法属于模型驱动方法,在实际应用中往往缺乏信号和噪声的先验知识支撑,且难以实现检测成本与检测性能的平衡。在数据驱动的频谱感知方法中,经典的机器学习(machine learning,ML)方法包括基于随机森林(random forest,RF)、k 近邻(k-nearest neighbors,KNN)和支持向量机(support vector machine,SVM)等,这些方法能够在小规模数据集上实现频谱感知,但由于依赖人工特征提取且易受噪声干扰,在低信噪比和复杂环境下表现不佳^[8-9]。

近年来,随着人工智能的快速发展,已有许多研究将深度学习(deep learning,DL)应用于频谱感知领域。相比于传统频谱感知算法和 ML 方法,DL 方法能够直接从信号数据中学习并提取深层特征,实现灵活建模,对频谱环境的动态变化具有更强的自适应能力^[10-11]。文献[12]提出了一种卷积神经网络(convolutional neural network,CNN)和长短时记忆网络(long short-term memory,LSTM)串行的 DetectNet 频谱感知方法,适用于任何调制方式,并在检测性能上相比 ED、LSTM 和深度神经网络(deep neural network,DNN)有所提升;文献[13]提出了一种基于时间卷积网络(temporal convolutional network,TCN)的检测方法,与 ED 和传统的深度学习算法 CNN、DNN 相比提高了检测性能,降低了计算复杂度;文献[14]提出了基于 LSTM 的频谱感知方法,分别使用原始信号数据和循环平稳特征作为输入来评估 LSTM 网络的分类精度,实验结果显示原始数据的 LSTM 分类器的分类精度优于基于循环平稳的分类器;文献[15]提出了一种由 CNN、双向长短时记忆网络(bidirectional long short-term memory,BiLSTM)和自注意力机制(self-attention,SA)组成的深度神经网络频谱感知模型,实现了较低的感知误差;文献[16]提出了一种基于 CNN 和 LSTM 并行网络的频谱感知方法,提取被测信号的时空特征,在检测概率和虚警概率方面优于传统的 ED、CNN 和 DetectNet 方法,并且相比 DetectNet 方法具有更低的复杂度;文献[17]将 CNN、TCN 和卷积注意力模块(convolution block attention module,CBAM)结合起来通过二分类进行频谱状态检测,其检测性能相比于 DNN、CNN、LSTM 和 TCN 网络有所改善。

在认知无线电的频谱感知领域,DL 凭借其出色的特

征学习能力,能够自动从数据中提取关键信息,显著提升感知性能。在信号质量较好的情况下,信号特征明显,感知准确率较高,然而,在极低信噪比条件下,由于噪声干扰和无线信道环境的复杂多变,现有方法难以有效提取关键特征,频谱状态的识别准确率明显受限。这使得低信噪比环境下的频谱感知任务依然面临着巨大挑战。

因此,为了在低信噪比条件下充分提取频谱状态的关键特征,本文提出了一种结合 Inception、双向门控循环单元(bidirectional gated recurrent unit,BiGRU)、时间注意力机制(temporal attention mechanism,TAM)和全连接层网络的(H-IBT)新型频谱感知模型。该模型通过 Inception 模块提取接收信号的空间特征,丰富特征表达;然后,采用 BiGRU 深入挖掘信号的时间特征,并通过 TAM 强化关键时序特征。实验过程包括数据集生成、离线训练和在线检测,数据集尽可能模拟真实无线电环境中 SU 对 PU 频段的感知过程;在离线训练阶段,将带有状态标签的接收信号样本输入 H-IBT 模型进行训练;在线检测阶段,将接收到的实时频谱数据输入到训练完成的模型中,得到 PU 频段的占用情况。所提方法显著提升了感知性能且模型复杂度有所减少,满足实时频谱感知要求,同时还展现出在不同调制方式下的良好鲁棒性。

1 系统模型

本研究考虑单天线认知无线电场景,SU 在没有任何先验知识的情况下进行频谱感知,在认知无线电中,根据授权频段是否存在 PU 信号,频谱感知可以建模为二元假设检验问题:

$$\{x_i(n)\}_{n=1}^N = \begin{cases} H_0 : \{\omega_i(n)\}_{n=1}^N \\ H_1 : \{h e^{j(2\pi n f_c + \varphi_u(n))} s_i(n) + \omega_i(n)\}_{n=1}^N \end{cases} \quad (1)$$

式中: H_0 表示频段中不存在 PU 信号, H_1 表示频段中存在 PU 信号; $s_i(n)$ 为 PU 发送的信号, $\omega_i(n)$ 表示均值为零、方差为 σ_w^2 的加性高斯白噪声, h 为检测周期内的信道增益; f_c 为中心频率偏移; $\varphi_u(n)$ 为相位噪声, N 为接收信号的采样长度。

评价频谱感知方法的性能指标主要有检测概率 P_d 、虚警概率 P_f 和漏检概率 P_m , 定义为:

$$\begin{cases} P_d = P(H_1 | H_1) \\ P_f = P(H_1 | H_0) \\ P_m = P(H_0 | H_1) \end{cases} \quad (2)$$

其中, P 表示概率分布函数。需要注意的是,如果 P_f 值过高,SU 将无法有效使用频谱,导致频谱利用率下降;较高的 P_m 会导致 PU 工作受到严重干扰,从而降低系统的可靠性。一个优秀的频谱感知模型应在低信噪比下保持较低的 P_f 和 P_m , 本文使用感知误差(sensing error,SE)作为评价频谱感知方法的性能指标^[18],即 P_f 和 P_m 的平均值,

表示为:

$$SE = \frac{P_f + P_m}{2} \quad (3)$$

2 H-IBT 模型基本原理

2.1 Inception 模块

Inception 网络结构由 Christian Szegedy 在 GoogLeNet 架构中首次提出^[19], 通过采用并行结构, 拓宽网络宽度, 同时突破了传统 CNN 仅依赖深度优化的限制^[20]。主要思想是在并行网络中不同分组使用不同尺寸的卷积, 从而实现对输入数据的多尺度特征提取, 这种设计增强了网络对不同尺度特征的适应性, 扩大了感受野, 并将提取的特征进行聚合。在不增加网络深度和参数量的情况下, Inception 模块能够捕获更丰富、多样的特征, 从而提升模型的表达能力和对特征的识别效率。

信号数据属于时间序列数据, 不同时间尺度包含的信息各不相同。本文采用卷积神经网络中的 Inception 结构对时序信号进行特征提取, 通过在同一神经网络层上并置不同尺度的卷积核, 使网络能够同时提取多个尺度上的特征信息, 每个卷积层后应用修正线性单元(rectified linear unit, ReLU)进行非线性处理, 提升模型的计算效率和收敛速度; 然后, 将不同尺度的卷积输出在深度维度上进行拼接, 生成更为丰富的特征表示, 其结构如图 1 所示。

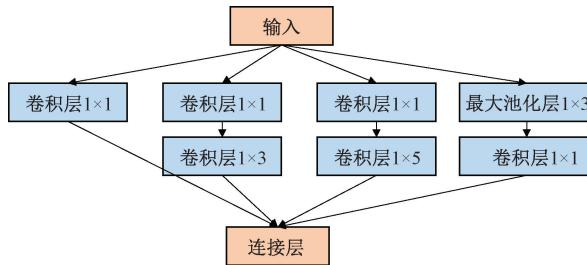


图 1 Inception 网络模块

Fig. 1 Inception network module

Inception 模块实现了对输入信号的多尺度特征提取, 从而使得网络能够同时捕捉细粒度的局部特征和更高层次的特征, 这种多尺度特征学习有助于模型更加准确地识别和检测频谱状态。在使用该模块处理信号数据时, 为了保留数据的原始结构和连续性, 同时避免信息损失, 采用一维卷积进行特征提取。一维卷积是指卷积核沿着单一维度滑动并进行卷积运算的过程, 在这一过程中, 卷积核沿着信号数据的时间维度移动并逐点计算, 对信号数据进行特定尺度的空间特征提取, 有效挖掘数据中的重要信息。一维卷积层的输出公式如下:

$$y = \sigma(\mathbf{W} * x + \mathbf{b}) \quad (4)$$

式中: x 为卷积层输入, y 为卷积层输出, \mathbf{W} 为卷积层的权重矩阵, \mathbf{b} 为偏置, σ 为激活函数。

2.2 BiGRU

卷积神经网络缺乏对时序依赖性的长期建模能力, 适用于提取局部特征, 而信号数据具有时间连续性, 因此, 需要充分考虑数据在时间维度上的特征及其动态变化。门控循环单元(gated recurrent unit, GRU)是一种特殊类型的循环神经网络(recurrent neural network, RNN), 有效缓解了传统 RNN 的梯度消失或爆炸问题, 同时简化了 LSTM 的网络结构并提高了训练效率^[21]。GRU 在解决时间序列问题时表现出优异的建模能力, 其通过更新门和重置门控制信息流动, 能够有效保留重要特征并捕获数据的长短期依赖关系, GRU 网络的结构如图 2 所示, 具体计算过程如式(5)所示。

$$\begin{cases} r_t = \text{sigmoid}(\mathbf{W}_r[h_{t-1}, x_t]) \\ z_t = \text{sigmoid}(\mathbf{W}_z[h_{t-1}, x_t]) \\ \tilde{h}_t = \tanh(\mathbf{W}_h[r_t \odot h_{t-1}, x_t]) \\ h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \end{cases} \quad (5)$$

式中: r_t, z_t 分别代表重置门和更新门, sigmoid 和 tanh 为激活函数, $\mathbf{W}_r, \mathbf{W}_z, \mathbf{W}_h$ 均为可训练的权重矩阵, x_t 是 t 时刻的输入, h_{t-1} 是 $t-1$ 时刻的隐藏状态, h_t 是 t 时刻的输出隐藏状态, \tilde{h}_t 是 t 时刻的候选隐藏状态, \odot 是哈达玛积, 即逐元素乘积。

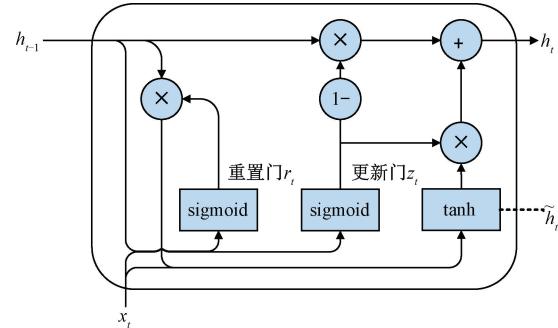


图 2 GRU 基本单元结构

Fig. 2 GRU basic unit structure

GRU 网络仅能单向处理时间序列, 但时序信号的前后信息具有明显的相关性, 因此双向挖掘数据信息将有助于提升感知性能。BiGRU 由两个独立的 GRU 组成, 分别沿着正向和反向处理输入序列^[22], 其结构如图 3 所示。通过这种双向循环结构, BiGRU 能够获得更全面的时间序列信息, 并能够捕捉到 GRU 无法获取的特征。在 t 时刻, BiGRU 的输出如式(6)所示。

$$\begin{cases} \vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = \text{GRU}(x_t, \overleftarrow{h}_{t-1}) \\ H_t = [\vec{h}_t, \overleftarrow{h}_t] \end{cases} \quad (6)$$

式中: \vec{h}_t 和 \overleftarrow{h}_t 分别代表 t 时刻正向 GRU 和反向 GRU 的隐藏层输出, H_t 为 t 时刻 BiGRU 的隐藏层输出, 即正向和反向 GRU 隐藏层输出的拼接。

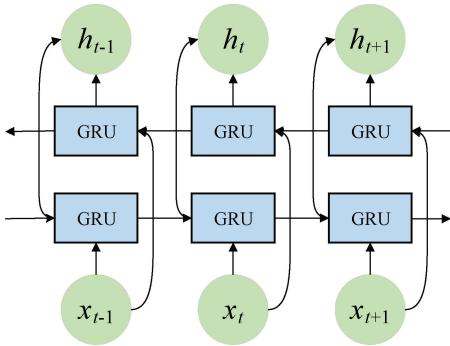


图 3 BiGRU 网络结构

Fig. 3 BiGRU network structure

2.3 TAM

时间注意力机制是一种用于处理时序数据的深度学习技术。在时间序列分类任务中,数据的某些部分对最终决策至关重要,而 BiGRU 缺乏对时序数据中重要信息的关注,因此,本文在 BiGRU 的基础上引入了 TAM^[23]。TAM 能够动态分配权重,使模型关注时序数据中重要时间点的特征信息。首先,通过 BiGRU 得到输出 H , $H = [H_1, H_2, \dots, H_T]$;然后,根据式(7)获取不同时间点的注意力权重;最后,使用注意力权重对 BiGRU 的输出 H 进行加权求和,得到注意力加权表示,如式(8)所示。

$$\alpha_t = \text{softmax}(\mathbf{U}_a \tanh(\mathbf{W}_a H_t)) \quad (7)$$

式中: \mathbf{W}_a 、 \mathbf{U}_a 是可训练的权重矩阵。

$$\text{output}_{\text{TAM}} = \sum_{t=1}^T \alpha_t H_t \quad (8)$$

2.4 H-IBT 模型

结合上述对各模块的分析,本研究综合了这些模块的特点与优势,构建了一种基于深度学习的频谱感知模型,该模型由 Inception 模块、BiGRU、TAM 及全连接层网络构成,即 H-IBT 模型,图 4 展示了该模型架构。首先,由 Inception 模块对接收的同相正交(in-phase quadrature, I/Q)信号数据进行初步提取,有效捕获时间序列数据中的多尺度空间特征,如信号中由外界干扰或环境变化引起的局部特征波动,CONCAT 层将 Inception 模块的输出与原始数据进行拼接,补偿传输过程中丢失的特征信息,确保后续层能够获取完整的特征表示。然后,将拼接后的特征输入到 BiGRU 网络,通过学习信号特征的全局依赖关系更好的提取时间序列特征信息,并利用 TAM 对 BiGRU 网络的输出进行加权处理,以增强重要时间特征的影响力。最后,提取的特征通过 3 层全连接层(fully connected layer, FC)进行处理,前两层将网络的输出进行特征变换,并使用 ReLU 激活函数引入非线性,提升了网络对复杂特征的表达能力,同时增强了梯度传递的稳定性,促进网络的高效训练和快速收敛;最后一层对频谱状态进行识别,采用 softmax 激活函数输出频谱占用状态的概率分布,完成最终决策。因此,本文所提模型利用 Inception 模块、BiGRU 和 TAM 在建模能力上的互

补性及其协同作用充分提取接收信号的时空特征,进而提升模型在复杂无线电环境和低信噪比下的感知精准率和鲁棒性。

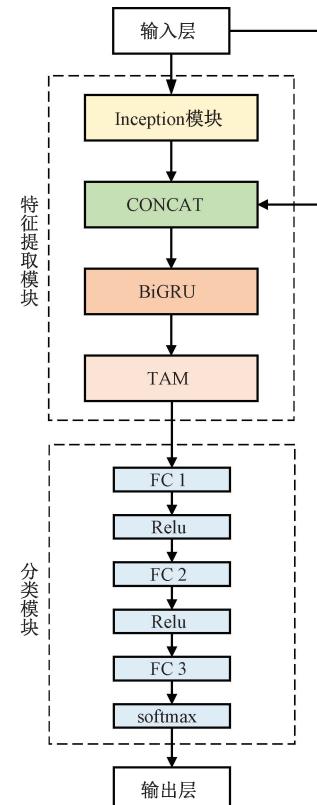


图 4 H-IBT 网络模型架构

Fig. 4 H-IBT network model structure

3 基于 H-IBT 的频谱感知框架

本文提出的基于 H-IBT 的频谱感知方法包括离线训练和在线检测两个阶段,在离线训练阶段,对 SU 接收机在感知 PU 频段过程中收集的样本进行标记,将标记后的样本输入 H-IBT 模型进行训练;在线检测阶段,将测试样本输入训练完成的模型,并根据模型输出判断频谱是否空闲。其工作流程如图 5 所示。

3.1 离线训练

在离线训练阶段,对 SU 在感知 PU 频段过程中收集的历史信号样本进行处理,具体来说,每个样本由 N 个连续时间采样值组成,表示为 $x_k = [x_k(1), x_k(2), \dots, x_k(N)]$;然后,将这些样本与其对应的状态标签进行组合,以构建训练数据集:

$$(X, Z) = \{(x_1, z_1), (x_2, z_2), \dots, (x_K, z_K)\} \quad (9)$$

式中: (x_k, z_k) 表示训练数据集 (X, Z) 的第 k 个 ($k = 1, 2, \dots, K$) 样本, K 是训练数据集样本的数量, X 表示模型的输入数据, $Z \in \{1, 0\}$ 表示标签, (X, Z) 包含不同信噪比条件下的训练样本和标签,经过训练后模型能够处理不同信噪比下的情况。

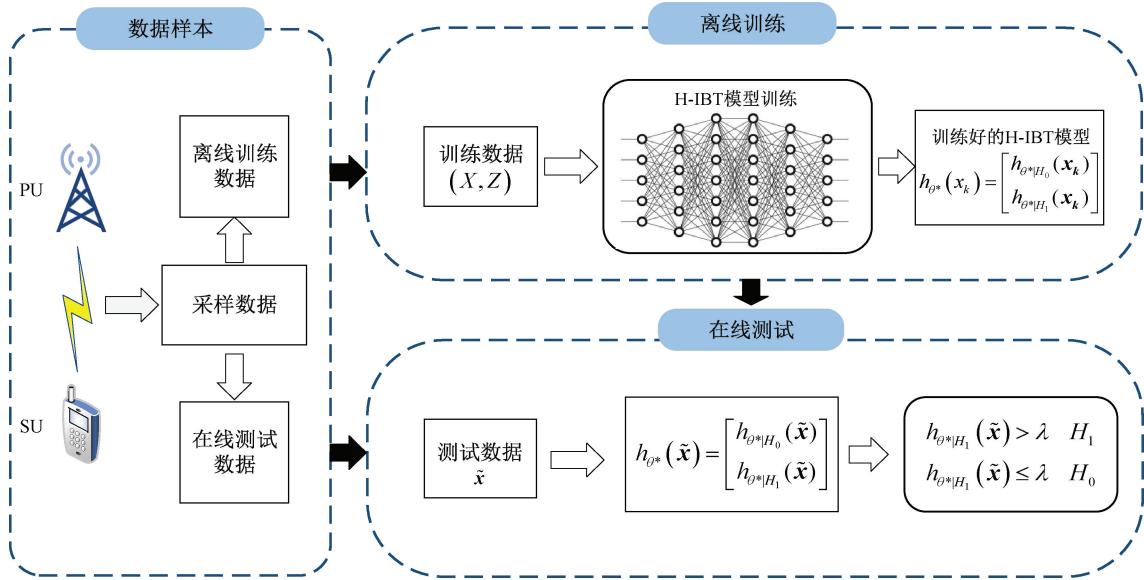


图 5 基于 H-IBT 的频谱感知方法工作流程

Fig. 5 Workflow of the spectrum sensing method based on H-IBT

频谱感知是二元假设检验问题,因此,H-IBT 模型的训练过程被转化为二元分类问题。对于第 k 个样本 (x_k, z_k) ,根据 H_1 和 H_0 状态对标签 z_k 进行独热编码:

$$z_k = \begin{cases} [1, 0]^T, H_0 \\ [0, 1]^T, H_1 \end{cases} \quad (10)$$

相应的,模型输出是通过 softmax 函数归一化的 2×1 类别概率向量:

$$h_\theta(x_k) = \begin{bmatrix} h_{\theta|H_0}(x_k) \\ h_{\theta|H_1}(x_k) \end{bmatrix} \quad (11)$$

且:

$$h_{\theta|H_0}(x_k) + h_{\theta|H_1}(x_k) = 1 \quad (12)$$

式中: $h_\theta(\cdot)$ 表示整体参数为 θ 的 H-IBT 模型, $h_{\theta|H_0}(x_k)$ 和 $h_{\theta|H_1}(x_k)$ 表示 H_0 和 H_1 的分类分数。

本研究使用交叉熵作为模型的损失函数^[24]:

$$L(\theta) = - \sum_{k=1}^K z_k \log(h_{\theta|H_1}(x_k)) + (1-z_k) \log(h_{\theta|H_0}(x_k)) \quad (13)$$

模型训练的目标是最小化损失函数 $L(\theta)$,以获得最优参数集合 θ^* :

$$\theta^* = \underset{\theta}{\operatorname{argmin}} L(\theta) \quad (14)$$

在模型训练过程中,使用回调函数监控每个训练周期结束时验证集的损失。如果损失在连续若干训练周期内未改善,则触发早停机制提前结束训练。并将验证集损失最低时的模型参数保存为最优 H-IBT 模型,以防止过拟合并提高模型的泛化能力。

3.2 在线检测

在线检测过程中,为了确定 PU 频段的状态,将测试样本 \tilde{x} 输入训练好的 H-IBT 模型中,输出结果为:

$$h_{\theta^*}(\tilde{x}) = \begin{bmatrix} h_{\theta^*|H_0}(\tilde{x}) \\ h_{\theta^*|H_1}(\tilde{x}) \end{bmatrix} \quad (15)$$

式中: $h_{\theta^*}(\cdot)$ 和 $h_{\theta^*|H_i}(\tilde{x})$ 分别表示训练好的模型和 H_i 的分类分数。

通过比较 H_1 的分类分数 $h_{\theta^*|H_1}(\tilde{x})$ 与检测阈值 λ 确定最终的检测结果:

$$\begin{cases} H_1 : h_{\theta^*|H_1}(\tilde{x}) > \lambda \\ H_0 : h_{\theta^*|H_1}(\tilde{x}) \leq \lambda \end{cases} \quad (16)$$

具体来说,如果 $h_{\theta^*|H_1}(\tilde{x}) > \lambda$ 时,授权频段存在 PU 信号;否则,不存在 PU 信号;阈值 λ 设置为 0.5。

4 仿真与结果分析

4.1 数据集生成

本研究基于文献[25]中的方法,使用 GNURadio 软件平台模拟生成频谱感知数据集。该数据集模拟了 PU 和 SU 之间的感知过程,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、多径效应和瑞利衰落等无线电通信系统中的多种干扰因素,以尽可能真实地再现信号在复杂无线电环境中的传播情况。数据集包含两部分:PU 存在时 SU 接收到的信号 H_1 和 PU 不存在时 SU 收到的信号 H_0 。每个数据样本为已经过能量归一化处理的离散时间序列数据,格式为 $N \times 2$,其中 N 为样本的长度,即采样长度,2 表示复值信号的 I/Q 分量。

数据集涵盖八种广泛使用的调制方式,分别为 BPSK、QPSK、8PSK、CPFSK、GFSK、16QAM、64QAM 和 PAM4。对于每种调制方式,在 $-20 \sim 5$ dB 的信噪比范围内,以 1 dB 为增量,每个信噪比生成 10 000 个 H_1 样本和

10 000 个 H_0 样本, 共计生成 520 000 个样本, 将这些样本按 3:1:1 的比例划分为训练集、验证集和测试集。数据集关键参数设置如表 1 所示。

表 1 数据集参数配置

Table 1 Dataset parameters configuration

参数	值
采样率/Hz	200 000
每个符号的采样数	8
样本长度	64,128,256,512
调制类型	BPSK, QPSK, 8PSK, CPFSK, GFSK, 16QAM, 64QAM, PAM4
信噪比范围/dB	[−20,5]
最大中心频率偏移/Hz	50
最大采样率偏移/Hz	50
衰落模型	瑞利衰落

4.2 超参数设置和实验环境

Inception 模块包含 6 个卷积层和 1 个最大池化层。全连接层网络由 3 个 FC 构成, 并通过添加 Dropout 层 (Dropout 率为 0.3) 以防止过拟合。实验在配备 NVIDIA GeForce RTX 2080 Ti (11 GB) GPU 的 AutoDL 云平台上完成, 使用基于 Python3.8 的 TensorFlow 2.2.0 深度学习框架。在训练过程中, 采用 Adam 优化器反向传播更新网络参数, 损失函数为交叉熵, 学习率为 0.003, 批量大小为 200, 最大训练轮次为 100, 早停耐心值设置为 6。H-IBT 模型的超参数设置如表 2 所示。

表 2 H-IBT 的超参数

Table 2 Hyperparameters of H-IBT

超参数	值
每层卷积的卷积核数	100
卷积核大小	$1 \times 1, 1 \times 3, 1 \times 5$
池化核大小	1×3
BiGRU 的隐藏单元数	128
FC 的神经元数	128,64,2
Dropout 率	0.3
优化器	Adam
损失函数	交叉熵
学习率	0.003
批量大小	200
最大轮次	100
早停耐心值	6

4.3 仿真结果分析

1) 不同模型感知性能比较

为了评估所提方法的性能, 将其与本研究领域中的五

种先进模型 LSTM^[14]、CNN-BiLSTM-SA^[15]、CBAMTCN^[17]、CNN-LSTM^[26]、CNN^[27]进行对比, 实验采用 16QAM 调制方式, 采样长度为 128。为确保比较的公平性, 所有模型均在同一数据集上进行训练和测试, 并采用各自文献中默认的超参数设置。

图 6 展示了 6 种模型的感知误差结果, 在信噪比低于 −7 dB 时, 本文模型的感知误差低于其他模型, 表现出更优的性能, 例如, 当信噪比为 −20 dB 时, CNN、LSTM、CNN-LSTM、CBAMTCN、CNN-LSTM-SA 和 H-IBT 的感知误差结果分别为 0.47、0.48、0.45、0.32、0.39 和 0.24, 说明在信号质量较差的环境中, H-IBT 模型能够更有效地进行频谱特征提取, 具备更强的抗干扰能力; 当信噪比高于 −5 dB 时, 各模型都获得较好的感知性能, 感知误差在 5% 附近。说明在该信噪比条件下, 信号和噪声特征区分度更高, 各模型均能够实现较为准确的频谱状态检测。因此, 本文模型在复杂无线电环境和低信噪比条件下的频谱感知任务中表现出较强的鲁棒性和抗干扰能力, 具有较高的应用潜力。

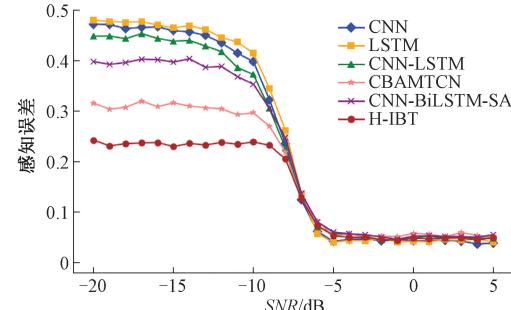


图 6 不同模型的感知误差对比

Fig. 6 Comparison of sensing error of different models

表 3 展示了不同频谱感知模型在总参数量、在线感知时间及整体感知准确率上的对比。从表中可以看出, 相比之下, CNN 和 LSTM 模型的参数量较低, 但其整体准确率仅为 74.32% 和 73.86%, 难以满足高精度的要求; 本文的方法整体准确率达到了 84.55%, 在保证较高准确率的同时, 参数量相比于 CNN-LSTM 和 CNN-BiLSTM-SA 大幅减少, 在线感知符合实时应用需求。这表明本文方法在模型复杂度与性能提升之间取得了良好的平衡, 从整体性能上验证了本文构造的网络模型的有效性和实用性。

2) 不同模型的 ROC 曲线比较

受试者工作特征曲线(receiver operating characteristic curve, ROC)是一种用于评估二分类模型性能的常用方法, 显示了检测概率 P_d 与虚警概率 P_f 之间的关系。ROC 曲线越靠近左上角, 模型性能越优。在目标信噪比为 −15 dB 时, 不同模型的 ROC 曲线如图 7 所示, 从仿真结果可以看出, 本文模型在所有虚警概率下的检测概率均高于其他模型, 表明其在频谱感知任务中具有更优的检测性能, 例如, 当 $P_f = 0.1$ 时, 本文模型的 $P_d = 63\%$, 相比性能次优的

表 3 不同模型性能对比

Table 3 Performance comparison of different models

模型	总参数量	在线感知时间/ms	整体感知准确率/%
LSTM	121 802	26.90	73.86
CNN	295 618	19.12	74.32
CNN-LSTM	662 018	27.95	76.74
CNN-BiLSTM-SA	2 053 186	29.85	77.75
CBAMTCN	453 708	24.45	80.28
本文	564 154	26.29	84.55

CBAMTCN 模型检测概率提高了超过 10% (CBAMTCN 模型的 $P_d = 51\%$)。这种性能的提升得益于 H-IBT 模型对信号特征的深度挖掘以及对关键特征的有效强化。

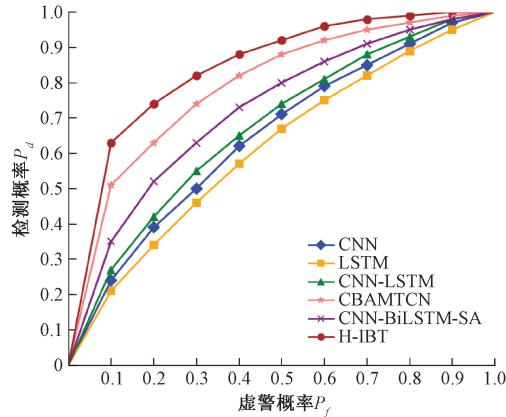


图 7 不同模型的 ROC 曲线对比

Fig. 7 Comparison of ROC of different models

3) 消融实验

消融实验的目的是通过逐步移除或添加特定模块来评估各模块对模型整体性能的贡献。为验证本文模型中每个模块的有效性,比较了 Inception、Inception-GRU、Inception-BiGRU、Inception-BiGRU-TAM 和 Inception-BiGRU-TAM-CONCAT 5 种模型的感知误差。实验使用 16QAM 调制方式,采样长度为 128。图 8 是消融实验中不同模型的感知误差结果,当信噪比低于 -7 dB 时,5 种模型的感知误差存在显著差异。Inception-GRU 的感知误差低于 Inception,而 Inception-BiGRU 的感知误差又低于 Inception-GRU,表明对输入时间序列数据进行空间和时间相关性的特征提取是必要的;此外,双向处理数据比单向处理在感知误差上表现更好,验证了 BiGRU 的有效性。同时,Inception-BiGRU-TAM 的性能优于 Inception-BiGRU,说明 TAM 通过突出时间序列中特定位置的特征,进一步降低了感知误差。而 Inception-BiGRU-TAM-CONCAT 的性能优于 Inception-BiGRU-TAM,表明 CONCAT 层有助于补偿传输过程中丢失的特征。在信噪比高于 -5 dB 时,除 Inception 模块的感知误差略高,其他

模型都取得了较低的感知误差,说明在此条件下信号特征相对于噪声更为明显,使得各模型能够更准确地进行区分。综上,BiGRU、TAM 和 CONCAT 层在提升模型感知性能方面都起到了重要作用,尤其在低信噪比环境中。

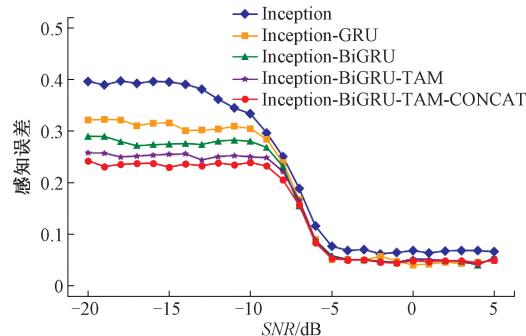


图 8 消融实验结果

Fig. 8 Ablation experiment results

4) 采样长度对感知性能的影响

采样长度对频谱感知性能具有显著影响。在调制方式为 16QAM 的条件下,将采样长度设置为 64、128、256 和 512。图 9 为这 4 种不同采样长度下所提 H-IBT 模型的感知误差结果。可以看出,采样长度越长,感知误差越低,例如,当 SNR = -20 dB 时,采样点数分别为 64、128、256 和 512 时的感知误差分别为 0.39、0.24、0.12 和 0.04;此外,采样长度为 512 时,模型在整个信噪比范围内的感知误差始终保持在较低水平;表明随着采样长度的增加,信号中包含的相关信息和结构特征更丰富,从而降低了感知误差。然而,采样长度的增加也会提升计算复杂性和时间开销。因此,在实际应用中,需要在感知性能与计算开销之间进行权衡。在多数情况下,通常使用 128 个采样长度。

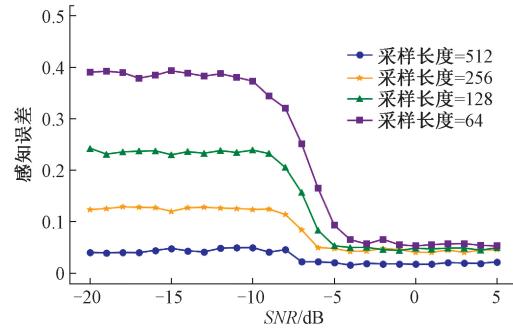


图 9 不同采样长度下的感知误差

Fig. 9 Sensing error at different sampling lengths

5) 不同调制方式的鲁棒性实验

为验证所提方法的鲁棒性,采用八种不同调制方式的信号数据对模型进行训练和测试,采样长度统一设置为 128。各调制方式下的感知误差结果如图 10 所示,可以看出,不同调制方式间的感知误差差异较小,说明模型对调制方式变化不敏感,具有较好的鲁棒性,在实际频谱感知任务中展现出较强的适用性。

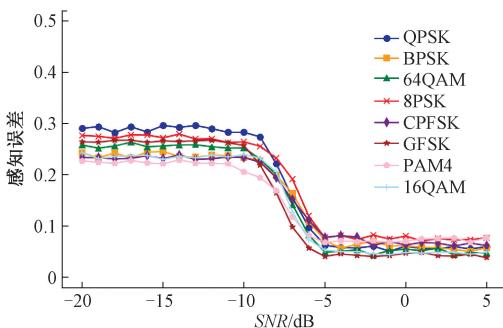


图 10 不同调制方式下的感知误差

Fig. 10 Sensing error under different modulation schemes

5 结 论

本研究应用深度学习技术解决低信噪比环境下的单用户频谱感知问题,提出了一种基于 H-IBT 的全盲频谱感知方法。仿真结果表明,该方法具有比 CNN、LSTM、CNN-LSTM、CBAMTCN 和 CNN-LSTM-SA 频谱感知方法更低的感知误差和更高的检测概率,并在减少模型参数量的同时提升了感知准确率,且对多种不同调制类型的信号展现出良好的鲁棒性,同时还分析了采样长度对检测结果的影响。所提方法具备较强的特征学习与提取能力,在复杂的无线电环境下依然能够保持优异的检测性能,同时在线感知时间满足实际应用需求,为认知无线电智能频谱感知领域提供了一种切实可行的解决方案。下一步将构建基于深度学习的协作网络架构,引入多个辅助用户,进一步提升感知性能。

参考文献

- [1] RAWAT B S, SRIVASTAVA A, SHRIVASTAVA V, et al. A comprehensive analysis of applications in internet of things networks in 5G and 6G [C]. 2024 IEEE 2nd International Conference on Computer, Communication and Control(IC4), 2024: 1-6.
- [2] 张回国. 认知无线电技术研究综述[J]. 广东通信技术, 2023, 43(7): 23-27.
- ZHANG H G. A review of cognitive radio technology research[J]. Guangdong Communication Technology, 2023, 43(7): 23-27.
- [3] MANCO J, DAYOUB I, NAFKHA A, et al. Spectrum sensing using software defined radio for cognitive radio networks: A survey[J]. IEEE Access, 2022, 10: 131887-131908.
- [4] PANDYA P, DURVESH A, PAREKH N. Energy detection based spectrum sensing for cognitive radio network [C]. 2015 IEEE Fifth International Conference on Communication Systems and Network Technologies, 2015: 201-206.
- [5] DANNANA S, CHAPA B P, RAO G S. Spectrum sensing using matched filter detection[C]. Intelligent Engineering Informatics: 6th International Conference on FICTA, 2018: 497-503.
- [6] SHERBIN K, SINDHU V. Cyclostationary feature detection for spectrum sensing in cognitive radio network[C]. IEEE 2019 International Conference on Intelligent Computing and Control Systems (ICCS), 2019: 1250-1254.
- [7] ZHAO W J, ALI S S, JIN M L, et al. Extreme eigenvalues-based detectors for spectrum sensing in cognitive radio networks[J]. IEEE Transactions on Communications, 2021, 70(1): 538-551.
- [8] SABER M, EL-RHARRAS A, SAADANE R, et al. An optimized spectrum sensing implementation based on SVM, KNN and TREE algorithms[C]. 2019 IEEE 15th International Conference on Signal-Image Technology and Internet-Based Systems (SITIS), 2019: 383-389.
- [9] 杨波. 循环谱与随机森林融合改进频谱检测算法[J]. 机械设计与制造, 2021(2): 282-285.
- YANG B. Improved spectrum sensing algorithm based on cyclostationary features and random forest [J]. Mechanical Design and Manufacturing, 2021 (2): 282-285.
- [10] SYED S N, LAZARIDIS P I, KHAN F A, et al. Deep learning approaches for spectrum sensing in cognitive radio networks [C]. 2022 IEEE 25th International Symposium on Wireless Personal Multimedia Communications (WPMC), 2022: 480-485.
- [11] SYED S N, LAZARIDIS P I, KHAN F A, et al. Deep neural networks for spectrum sensing: A review [J]. IEEE Access, 2023, 11: 89591-89615.
- [12] GAO J B, YI X M, ZHONG C J, et al. Deep learning for spectrum sensing [J]. IEEE Wireless Communications Letters, 2019, 8(6): 1727-1730.
- [13] NI T, DING X J, WANG Y F, et al. Spectrum sensing via temporal convolutional network[J]. China Communications, 2021, 18(9): 37-47.
- [14] BKASSINY M. A deep learning-based signal classification approach for spectrum sensing using long short-term memory (LSTM) networks [C]. 2022 IEEE 6th International Conference on Information Technology, Information Systems and Electrical Engineering(ICITSEE), 2022: 667-672.
- [15] XING H L, QIN H X, LUO SH X, et al. Spectrum sensing in cognitive radio: A deep learning based model[J]. Transactions on Emerging Telecommunications

- Technologies, 2022, 33(1): e4388.
- [16] DING X J, NI T, ZOU Y L, et al. Deep learning for satellites based spectrum sensing systems: A low computational complexity perspective [J]. IEEE Transactions on Vehicular Technology, 2023, 72(1): 1366-1371.
- [17] 梁晶, 杨晶晶, 黄铭. 基于深度学习的无线通信信号检测与识别研究[J]. 无线电工程, 2023, 53(3): 611-618.
LIANG J, YANG J J, HUANG M. Research on wireless communication signal detection and recognition based on deep learning [J]. Radio Engineering, 2023, 53(3): 611-618.
- [18] LEE W, KIM M, CHO D H. Deep cooperative sensing: Cooperative spectrum sensing based on convolutional neural networks[J]. IEEE Transactions on Vehicular Technology, 2019, 68(3): 3005-3009.
- [19] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [20] 范志伟, 郭世伟, 罗鑫, 等. 基于 Inception-DLSTM 双通道的滚动轴承故障诊断方法[J]. 电子测量技术, 2023, 46(7): 53-59.
FAN ZH W, GUO SH W, LUO X, et al. Fault diagnosis method for rolling bearings based on Inception-DLSTM dual-channel [J]. Electronic Measurement Technology, 2023, 46(7): 53-59.
- [21] ZHAO Z N, YUN S N, JIA L Y, et al. Hybrid VMD-CNN-GRU-based model for short-term forecasting of wind power considering spatio-temporal features[J]. Engineering Applications of Artificial Intelligence, 2023, 121: 105982.
- [22] 张朝龙, 罗来劲, 刘惠汉, 等. 基于增量能量法和 BiGRU-Dropout 的锂电池健康状态估计[J]. 电子测量与仪器学报, 2023, 37(1): 167-176.
ZHANG ZH L, LUO L J, LIU H H, et al. Health state estimation of lithium batteries based on incremental energy method and BiGRU-Dropout [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 167-176.
- [23] SAMUDRALA D S, MISHRA S K, SENAPATI R. Advanced temporal attention mechanism based 5G traffic prediction model for IoT ecosystems[C]. 2024 IEEE 21st International Conference on Mobile Ad-Hoc and Smart Systems (MASS). IEEE, 2024: 569-573.
- [24] SU ZH Y, TEH K C, RAZUL S G, et al. Deep non-cooperative spectrum sensing over Rayleigh fading channel [J]. IEEE Transactions on Vehicular Technology, 2022, 71(4): 4460-4464.
- [25] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]. Engineering Applications of Neural Networks: 17th International Conference, 2016: 213-226.
- [26] XU M D, YIN ZH D, WU M Y, et al. Spectrum sensing based on parallel CNN-LSTM network[C]. 2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring), 2020: 1-5.
- [27] MEHRABIAN A, SABBAGHIAN M, YANIKOMEROGLU H. CNN-based detector for spectrum sensing with general noise models[J]. IEEE Transactions on Wireless Communications, 2023, 22(2): 1235-1249.

作者简介

殷晓虎,副教授,主要研究方向为无线通信理论及技术应用等。

E-mail:42093332@qq.com

张安熠(通信作者),硕士研究生,主要研究方向为认知无线电、频谱感知。

E-mail:18291919597@163.com

张珂珂,硕士研究生,主要研究方向为认知无线电、频谱感知。

E-mail:zkk0428@foxmail.com

田冲,硕士研究生,主要研究方向为认知无线电、频谱感知。

E-mail:t12070707@outlook.com