

基于 Bi-LSTM 及贝叶斯似然比检验的 GEO 与 LEO 卫星组合频谱感知*

杨 凯^{1,2} 胡圣波² 张 欣¹

1(贵州大学大数据与信息工程学院 贵阳 550025)

2(贵州师范大学智能信息处理研究所 贵阳 550001)

摘 要 目前的频谱感知算法以模型驱动为主,其感知性能过于依赖预定的统计模型,这使得其在信道环境复杂的卫星通信场景中的部署变得困难。对 LEO 卫星过境期间的信噪比波动情况进行分析,结果显示信噪比的波动达到 14 dB。针对该复杂场景提出了一种基于双向长短期记忆网络及贝叶斯似然比检验联合的频谱感知算法。该算法不需要任何主信号的先验知识,可自动从主信号中学习隐藏特征并做出决策。基于 Neyman-Pearson 准则,在神经网络输出端设计了一种基于阈值的检测方案,可方便地控制恒定的虚警概率。仿真结果表明,所提算法在信噪比为-14 dB 的情况下,仍能达到 83% 的检测性能,且始终优于卷积神经网络、多层感知机和基于模型驱动的能量检测算法。

关键词 认知卫星通信, 频谱感知, 深度学习, LSTM, 贝叶斯似然比检验

中图分类号 TN927

Spectrum Sensing for Combined GEO and LEO Satellites Based on Bi-LSTM and Bayesian Likelihood Ratio Test

YANG Kai^{1,2} HU Shengbo² ZHANG Xin¹

1(School of Big Data and Information Engineering, Guizhou University, Guiyang 550025)

2(Intelligent Information Processing Research Institute, Guizhou Normal University, Guiyang 550001)

Abstract With LEO mega satellite constellations coming into operation, the available spectrum resources are more crowded. To improve spectrum utilization, the cognitive satellite communication network composed of GEO relay satellites and LEO satellites has become one of the important candidate

* 国家自然科学基金项目(61561009)和贵州省教育厅项目(KY [2017]031, KY [2020]007)共同资助

2022-05-05 收到原稿, 2022-11-29 收到修定稿

E-mail: hsb@nssc.ac.cn

©The Author(s) 2023. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

technologies to solve the above problem. In this scenario, LEO satellites are permitted to access the authorized spectrum of the GEO satellites through spectrum sensing technology. To avoid interferences from secondary users, spectrum sensing, which is used to quickly determine the presence or absence of primary users, is the most critical step in the scenario of cognitive satellite communication. Since most current spectrum sensing algorithms are model-driven, they rely heavily on the predetermined statistical model for their detection performance, which makes it more difficult to be modeled and deployed in satellite communication scenarios with complex channel environments. In this paper, we first analyze the fluctuation of the Signal-to-Noise Ratio (SNR) at the LEO satellite's receiving end with the satellite-to-ground link loss model. The results show that the SNR's fluctuation reaches 14 dB during satellite transit. Secondly, in this complex channel environment, a spectrum sensing algorithm combining a Bidirectional Long Short-Term Memory (Bi-LSTM) network and a Bayesian likelihood ratio test is proposed. The algorithm can automatically learn hidden features from the primary user signals and make final decisions without requiring any prior knowledge of the primary user signals. Additionally, according to the Neyman-Pearson criterion, we design a threshold-based detection mechanism at the output of the Bi-LSTM network, which can conveniently control the false alarm probability. Finally, the simulation results show that even with an SNR of -14 dB, the proposed algorithm achieves an excellent detection performance of 83% and always outperforms convolutional neural networks, multilayer perceptrons, and model-driven energy detection algorithms.

Key words Cognitive satellite communications, Spectrum sensing, Deep learning, LSTM, Bayesian likelihood ratio test

0 引言

为实现低时延的全球覆盖,基于立方体卫星的LEO巨型卫星星座,即由多个轨道平面和数百颗小卫星组成的卫星系统,已成为B5G和6G的一项重要候选技术^[1]。

随着大量LEO卫星星座投入运营,可用的频谱资源变得更加拥挤。为了提高频谱利用率,认知卫星通信(Cognitive Satellite Communication)技术^[2]已成为重要的候选技术之一。在认知卫星通信领域,最为关键的问题是如何在特定空间和特定频段内快速检测主用户(Primary User)的存在。为避免对主用户的通信造成干扰,次用户(Secondary User)只有在主用户不存在的情况下,才能接入当前频段进行通信。频谱感知(Spectrum Sensing)作为认知卫星通信的第一步,可用于解决上述问题。目前大多数的频谱感知技术均基于模型驱动,其检测性能很大程度上依赖于预定的统计模型,这将加大在实际环境中建模部署的难度^[3]。当下较为流行的频谱感知算法包括能量

检测、匹配滤波检测、循环平稳检测和特征值检测等。其中匹配滤波器和循环平稳检测均需要主用户的先验知识,这对于卫星通信场景是难以获取的,特征值检测虽不需要相应的先验知识,但其计算复杂度高而难以部署。能量检测算法简单、易于部署,常被用于卫星频谱感知场景^[4],然而当信噪比(Signal-to-Noise Ratio, SNR)低于检测下限后,其性能会急剧下降,甚至无法工作。

随着基于数据驱动的信号处理技术的迅速发展^[5],深度学习(Deep Learning)技术在未来无线网络的背景下得到工业界和学术界的广泛关注^[6]。认知卫星通信的主要优势在于其认知能力,即无线电环境中的自我学习能力,此特性类似于深度学习,因此深度学习技术被广泛用于认知网络场景^[7]。此外,其不需要任何数据的先验知识,可从数据中挖掘隐藏的特征,并对这些特征进行分类,且能取得优异的效果^[8]。近年来有相关研究将深度学习用于认知卫星通信领域,其将频谱感知处理为信号的分类问题,文献^[9]提出了基于机器学习的协作频谱感知方法,虽然取得了

良好的感知性能,但是当噪声功率较大时,非常影响其鲁棒性。文献 [10] 提出了基于人工神经网络的频谱感知方法,将信号能量和循环平稳特征作为输入特征,然后通过大规模的数据进行训练,但是人工神经网络容易出现过拟合问题,过拟合问题将直接影响测试数据的感知结果。文献 [11] 将卷积神经网络(Convolutional Neural Network, CNN)应用于认识无线电,利用信号的波形图作为输入,进行一系列卷积操作,提取波形图隐层特征并进行分类。但是这需要大量的信号波形图 CNN 对进行训练,数据集的采集过程过于繁杂。

无线频谱数据是一种时间序列数据^[12],序列中存在特有的时间相关性。长短期记忆网络(Long Short-term Memory Network, LSTM)作为循环神经网络(Recurrent Neural Network, RNN)的一个改进模型,继承了 RNN 处理时间序列的强大能力,在学习顺序数据^[13]中的时间依赖关系方面表现优异,同时还解决了 RNN 处理长序列时梯度消失和梯度爆炸的问题。与传统 LSTM 不同,双向长短期记忆网络(Bi-directional Long Short-term Memory Network, Bi-LSTM)可以从过去(向后)和未来(向前)的状态中获取序列的时间相关性等特征信息^[14],Bi-LSTM 对于长时间序列的特征提取更具优势。

在本文所考虑的认知卫星通信场景中,用于全天候和全时段遥测、跟踪和命令的 GEO 中继卫星作为主用户,LEO 卫星作为次用户与主用户共享频谱。基于此场景,设计了一个基于 Bi-LSTM 及贝叶斯似然比检验联合的频谱感知算法,该算法依赖于线下训练

和线上检测两个阶段。首先,次用户接收到来自主用户卫星地面站的频谱信息数据,经预处理后发送给频谱感知模型,完成线下训练目标。其次,由于频谱感知中漏检问题比虚警问题更为严峻^[15],因此为了能够在给定的虚警概率(Probability of False Alarm, P_F)下去最大化检测概率(Detection Probability, P_D),在 Neyman-Pearson 准则的启发下,以贝叶斯似然比(Bayesian Likelihood Ratio, BLR)作为测试统计量,在 Bi-LSTM 的输出端设计了一种基于阈值的检测机制,该阈值主要由噪声样本的统计量及给定 P_F 决定;在训练完成的 Bi-LSTM 模型的输出端,结合该检测机制对线上接收的频谱信息数据进行频谱感知。实验结果表明,即使是在 SNR 为 -14 dB 的信道环境下,所提算法仍能达到 83% 以上的 P_D ,且始终优于卷积神经网络、多层感知机(Multi-layer Perceptron, MLP)和传统能量检测算法(Energy Detection, ED),表现出较强的检测能力。

1 系统建模及问题建模

GEO 中继卫星和 LEO 卫星组成的认知卫星通信场景如图 1 所示。工作在 Ka 波段的 GEO 中继卫星作为主用户,轨道高度为 550 km 的 LEO 卫星作为次用户,主用户的波束覆盖范围内包含多个 GEO 地面站(GEO Earth Station, GES)和 LEO 地面站(LEO Earth Station, LES)。次用户卫星天线的覆盖范围与主用户卫星的波束重叠,当主用户卫星与 GES 进行通信时,如果次用户卫星接入当前频段进行




图 1 认知卫星通信场景及所提的频谱感知模型

Fig. 1 Scenario of cognitive satellite communications and the proposed spectrum sensing model

通信,将对主用户卫星的通信造成严重干扰。此外,在当前认知卫星通信场景中,下行链路为单颗主用户卫星向 GES 发送信息,而上行链路则是单个 GES 向主用户卫星发送信息,这里假设主用户卫星波束覆盖范围内的次用户卫星均可以接收到来自主用户卫星或者 GES 的频谱信息数据。本文所提频谱感知算法主要面向单颗主用户卫星与 GES 通信的频谱信息数据,因此两种链路情况均适用。本文主要针对上行链路场景展开分析。由于当前 LEO 卫星具有较强的算力^[16],所提频谱感知模型将被部署于 LEO 卫星,对来自 GES 的信息数据进行决策,如果不存在正在与主用户进行通信的 GES,则当前波束覆盖范围内的 LES 在当前频段可与次用户进行通信。基于此,频谱感知问题可被定义为如下二元假设检验问题^[17]:

$$\mathbf{y}(n) = \begin{cases} \mathbf{w}(n) : H_0, \\ h\mathbf{s}(n) + \mathbf{w}(n) : H_1. \end{cases} \quad (1)$$

其中, $\mathbf{y}(n)$ 为次用户接收到的信号数据, $\mathbf{s}(n)$ 为 GES 发送给主用户的信号样本, $\mathbf{w}(n)$ 表示服从圆对称复高斯分布的噪声样本,其均值为 0, 方差为 σ_w^2 , h 为信道增益^[18], 可表示为如下对数阴影模型:

$$h = \frac{P_{\text{leo}}^r}{P_{\text{ges}}^t} = G_{\text{ges}}^t G_{\text{leo}}^r \left(\frac{c}{4\pi f d_{\text{ges,leo}}} \right)^2 10^{-\frac{A_g + A_c}{10}}. \quad (2)$$

式中, G_{ges}^t 为 GES 发送天线增益, G_{leo}^r 为次用户接收天线增益, P_{leo}^r 为次用户的接收功率, P_{ges}^t 为 GES 的发射功率, $d_{\text{ges,leo}}$ 表示 GES 与次用户之间的距离, c 为光速, f 表示工作频率。 A_g 和 A_c 分别表示在上行链路中大气吸收和云雾衰减的传播因素^[18]。因此,次用户接收信号数据的信噪比(SNR, S/N)可表示为

$$S/N = \frac{P_{\text{ges}}^t G_{\text{ges}}^t G_{\text{leo}}^r}{k T_{\text{leo}} B} \left(\frac{c}{4\pi f d_{\text{ges,leo}}} \right)^2 10^{-\frac{A_g + A_c}{10}}. \quad (3)$$

其中, $k = 1.3806 \times 10^{-23} \text{ J} \cdot \text{K}^{-1}$ 为玻尔兹曼常数, B 为信道带宽, T_{leo} 为次用户接收机的噪声温度。图 1 表明 LEO 卫星沿轨道高速飞行过程中 $d_{\text{ges,leo}}$ 的变化遵循先变小后变大的规律, $d_{\text{ges,leo}}$ 可表示为

$$d_{\text{ges,leo}} = \sqrt{R_e^2 \sin^2 \alpha + 2 H_{\text{leo}} R_e + H_{\text{leo}}^2} - R_e \sin \alpha. \quad (4)$$

其中, R_e 为地球半径, H_{leo} 为次用户的轨道高度, α 表示次用户与 GES 之间的仰角。由式 (4) 可见, 当 $\alpha = 0^\circ$ 和 $\alpha = 90^\circ$ 时, $d_{\text{ges,leo}}$ 分别达到最小值和最大值。此外, 当工作频率 f 、噪声温度 T_{leo} 不变时, SNR 波动主要受到 $d_{\text{ges,leo}}$ 影响。如图 2 所示, LEO 卫星过境期




图 2 信噪比随仰角 α 波动曲线

Fig. 2 Curve of SNR fluctuation with elevation α

间 SNR 的波动达到近 14 dB。虽然在当前 SNR 波动范围下, LEO 卫星可进行正常的通信状态^[18], 但是为能够准确检测主用户的状态, 一个鲁棒的频谱感知方案是必要的。

2 基于 Bi-LSTM 的频谱感知方案

2.1 线下训练及测试统计量的设计

在线下训练过程中, 由于所提的 Bi-LSTM 算法仅适合处理实数类型的数据, 首先需要将次用户接收到的复信号数据的实部与虚部分离, 并组合为 $N \times 2$ 的信号样本, 可表示为

$$\mathbf{y}_m = \{R(y_m(0)), I(y_m(0)); R(y_m(1)), I(y_m(1)); \dots R(y_m(N)), I(y_m(N))\}; \\ m = 1, 2, \dots, M. \quad (5)$$

其中, $R(\cdot)$ 和 $I(\cdot)$ 分别表示复信号的实部和虚部, N 为样本采样点数, M 为样本数量。对于线下训练阶段的信号数据样本, 需对其进行标记, 标记后的数据样本可表示为

$$(\mathbf{Y}, \mathbf{Z}) = \{(\mathbf{y}_1, z_1), (\mathbf{y}_2, z_2), \dots, (\mathbf{y}_M, z_M)\}; \\ m = 1, 2, \dots, M. \quad (6)$$

其中, $(\mathbf{y}_m, z_m)$ 表示训练集 $(\mathbf{Y}, \mathbf{Z})$ 中第 m 个信号样本, $z_m \in \{0, 1\}$ 表示接收样本 $\mathbf{y}_m$ 的标签, $z_m = 1$ 和 $z_m = 0$ 分别对应式 (1) 中的假设 H_1 和 H_0 。为方便分析, 可将标签 z_m 编码为 one-hot 向量表示主用户的状态, 即

$$z_m = \begin{cases} [1, 0]^T : H_1; \\ [0, 1]^T : H_0. \end{cases} \quad (7)$$




图 3 Bi-LSTM 神经网络架构

Fig. 3 Architecture of Bi-LSTM neural network

图 3 给出了 Bi-LSTM 的网络架构, 其中两个 Bi-LSTM 层作为特征提取器, 提取输入信号数据的时间相关性特征, 三个全连接(Fully Connected, FC)层作为特征分类器, 对 Bi-LSTM 层输出的特征进行分类, 将高维特征映射到一个二维类别概率向量。此外, $Tanh$ 作为两个 Bi-LSTM 之间的激活函数, $Softmax$ 用于最后一个全连接层, 其余层之间均用 $Relu$ 作为激活函数, 为了防止过拟合, $Dropout$ 用于每个连接层之间, 神经元失活率被设置为 0.1。

此外, 所提神经网络的输出 $\hat{\mathbf{Y}}$ 可被表示为输入样本向量 $\mathbf{Y}$ 的非线性变换, 即

$$\hat{\mathbf{Y}} = f_{\text{Softmax}}^{(L-1)} \{ f_{\text{Relu}}^{(L-2)} [\dots f_{\text{Relu}}^{(1)} (\mathbf{Y}, \boldsymbol{\theta})] \}. \quad (8)$$

其中, L 表示隐藏层的数量, $\boldsymbol{\theta}$ 表示所有层的权重和偏置向量。为便于分析, 将经过 $SoftMax$ 层的输出 $\hat{\mathbf{Y}}$ 表示为一个类别概率向量, 有

$$\hat{\mathbf{Y}} = h_{\boldsymbol{\theta}}(\mathbf{y}_m) = \begin{bmatrix} h_{\boldsymbol{\theta}|H_1}(\mathbf{y}_m) \\ h_{\boldsymbol{\theta}|H_0}(\mathbf{y}_m) \end{bmatrix}. \quad (9)$$

其中, $h_{\boldsymbol{\theta}|H_1}(\mathbf{y}_m) + h_{\boldsymbol{\theta}|H_0}(\mathbf{y}_m) = 1$, $h_{\boldsymbol{\theta}}(\cdot)$ 表示整个神经网络模型, $h_{\boldsymbol{\theta}|H_i}(\mathbf{y}_m)$ 表示假设 H_i 的类别概率。然后, 可得式 (1) 中两个假设的后验概率表达式, 即

$$\begin{cases} P(z_m = 0 | \mathbf{y}_m, \boldsymbol{\theta}) = h_{\boldsymbol{\theta}|H_0}(\mathbf{y}_m) : H_0, \\ P(z_m = 1 | \mathbf{y}_m, \boldsymbol{\theta}) = h_{\boldsymbol{\theta}|H_1}(\mathbf{y}_m) : H_1. \end{cases} \quad (10)$$

式中, $P(z_m = i | \mathbf{y}_m, \boldsymbol{\theta})$ 表示在当前模型参数 $\boldsymbol{\theta}$ 下的后验概率 $P(z_m = i | \mathbf{y}_m)$ 。基于此, Bi-LSTM 神经网络训练的目标是去最大化此似然函数, 有

$$L(\boldsymbol{\theta}) = P(\mathbf{Z} | \mathbf{Y}, \boldsymbol{\theta}) =$$

$$\prod_{m=1}^M [h_{\boldsymbol{\theta}|H_1}(\mathbf{y}_m)]^{z_m} [h_{\boldsymbol{\theta}|H_0}(\mathbf{y}_m)]^{1-z_m}. \quad (11)$$

最大化式 (11) 即等价于去最小化此交叉熵损失函数, 有

$$J(\boldsymbol{\theta}) = -\frac{1}{M} \sum_{m=1}^M \{ z_m \lg[h_{\boldsymbol{\theta}|H_1}(\mathbf{y}_m)] + (1 - z_m) \lg[1 - h_{\boldsymbol{\theta}|H_1}(\mathbf{y}_m)] \}. \quad (12)$$

通过对 Bi-LSTM 网络模型的训练去最大化后验概率 $P(\mathbf{Z} | \mathbf{Y})$, 可以获得一个最优的模型权重参数, 即

$$\boldsymbol{\theta}' = \underset{\boldsymbol{\theta}}{\operatorname{argmax}} P(\mathbf{Z} | \mathbf{Y}, \boldsymbol{\theta}) = \underset{\boldsymbol{\theta}}{\operatorname{argmin}} J(\boldsymbol{\theta}), \quad (13)$$

其中, $\boldsymbol{\theta}'$ 表示最大后验概率准则下的最优权重参数^[19]。

Neyman-Pearson 定理证明最优的测试统计量为似然比^[19]。因此, 根据贝叶斯定理^[19] 和式 (10), 贝叶斯似然比统计量可表示为

$$T_{\text{Bi-LSTM}}(\mathbf{y}_m) = \frac{P(\mathbf{y}_m | H_1)}{P(\mathbf{y}_m | H_0)} = \frac{h_{\boldsymbol{\theta}'|H_1}(\mathbf{y}_m) P(H_0)}{h_{\boldsymbol{\theta}'|H_0}(\mathbf{y}_m) P(H_1)} = \frac{h_{\boldsymbol{\theta}'|H_1}(\mathbf{y}_m)}{h_{\boldsymbol{\theta}'|H_0}(\mathbf{y}_m)}. \quad (14)$$

其中, $P(\mathbf{y}_m | H_i)$ 为假设 H_i 的似然概率, $P(H_i)$ 为 H_i 的先验概率, 在训练过程中, 令 $P(H_0) = P(H_1) = 0.5$ 。 $h_{\boldsymbol{\theta}'|H_i}(\mathbf{y}_m)$ 为训练完成的 Bi-LSTM 网络模型的输出类别概率。基于式 (12), 采用 Adam 作为优化器, 通过反向传播算法对网络模型进行训练, 具体超参数设定见表 1。

2.2 线上测试

近年来有研究提出了基于深度学习的频谱感知算法^[20],直接采用端到端的神经网络分类器代替整个频谱感知系统,以神经网络输出的最大类别概率作为主用户的状态。但是该方法无法控制所需的 P_F 。因此在 Neyman-Pearson 准则的启发下,这里在 Bi-LSTM 网络模型的输出端设计了一种基于阈值的检测机制,可通过更新阈值的方法方便地设定所需 P_F 。首先,采用蒙特卡罗方案,从训练数据中选取 K 个 H_0 标签下的样本,表示为 $\mathbf{W} = [w_1, w_2, \dots, w_K]$,即次用户接收到的纯噪声样本。其次,将 $\mathbf{W}$ 输入到训练完成的 Bi-LSTM 网络模型,根据式 (14) 获取测试统计量 $T_{\text{Bi-LSTM}}|H_0$,然后将 K 个测试统计量进行降序排列并存入列表 $\mathcal{L}_{T_{\text{Bi-LSTM}}|H_0}$ 中。则关于 P_F 的检测门限 λ 可以表示为

$$\lambda = \mathcal{L}_{T_{\text{Bi-LSTM}}|H_0}(f(P_F K)). \quad (15)$$

其中, $f(\cdot)$ 表示向下取整函数, $\mathcal{L}_{T_{\text{Bi-LSTM}}|H_0}(k)$ 表示列表 $\mathcal{L}_{T_{\text{Bi-LSTM}}|H_0}$ 中的第 k 个元素。因此,在线上检验阶段,通过将次用户线上接收到的测试样本 $\mathbf{y}'_m$ 输入到训练好的 Bi-LSTM 模型获取测试统计量 $T_{\text{Bi-LSTM}}(\mathbf{y}'_m)$,然后将测试统计量与门限 λ 进行对比确定主用户的状态,即

表 1 仿真参数

Table 1 Simulation parameters

参数名	值
调制类型	GMSK
GES发送功率 $P_{\text{ges}}^t/\text{dBm}$	40
LEO接收机噪声温度 T_{leo}/K	175
GES发送天线增益 $G_{\text{ges}}^t/\text{dB}$	30
LEO接收天线增益 $G_{\text{leo}}^r/\text{dB}$	10
工作频率 f/GHz	29.9
带宽 B/MHz	24
大气吸收传播因子 A_g/dB	0.75
云雾衰减传播因子 A_c/dB	1.25
训练轮数	20
损失函数	Cross entropy loss
优化器	Adam
训练集样本数	32000
验证集样本数	3200
测试集样本数	8000

$$T_{\text{Bi-LSTM}}(\mathbf{y}'_m) \underset{H_0}{\overset{H_1}{\gtrless}} \lambda. \quad (16)$$

基于 Bi-LSTM 网络及贝叶斯似然比检验的频谱感知算法流程如图 4 所示。

3 仿真分析

3.1 实验环境及仿真参数

应用 MATLAB-R2020 b 和卫星工具箱 (Satellite Tool Kit, STK 8.1) 生成主用户信号样本数据集以及 GEO 中继卫星和 LEO 卫星场景的轨道数据。主用户信号为 LEO 卫星通信场景中常用的 GM-SK 调制信号^[21]。此外,所有算法的实现均基于 Python 3.7。具体仿真参数的设定见表 1。




图 4 基于 Bi-LSTM 及贝叶斯似然比检验联合的频谱感知算法流程

Fig. 4 Flow diagram of the spectrum sensing algorithm based on Bi-LSTM and Bayesian likelihood ratio test

3.2 检测性能分析

在感知性能的分析中,将通过两个关键的性能指标对算法性能进行评估,即虚警概率 P_F 和检测概率 P_D ,分别为 $P_F = P\{T|H_0 > \lambda\}$ 和 $P_D = P\{T|H_1 > \lambda\}$,其中 T 和 λ 分别为对应算法的测试统计量及检测门限。

在 Bi-LSTM 网络模型中,全连接层作为特征分类器具有重要作用,然而全连接层的数目通常对分类效果存在重要影响。为了探索更优的检测性能,分别搭建了不同全连接层数的 Bi-LSTM 网络模型进行对比实验。图 5 给出了不同全连接层数下 P_D 随 SNR 的变化曲线,从图 5 中可以看出,当模型中只有 3 个全连接层时,尽管 SNR 低至 -20 dB,依旧能保持 50% 左右的检测性能,且随着 SNR 的增长, P_D 的增速也最快。由此可见,在网络模型中,并非全连接层数越多检测性能越好,合适的全连接层数选择对于网络模型而言是必要的。

为了探索所提算法的泛化能力,采用不同的数据集进行实验分析。图 6 给出不同训练样本下所提算法的检测性能,从图中可见,随着训练样本数量及样本采样点数 N 的增加,所提算法的检测性能也随之增加,这是因为对于较大训练样本数和样本采样点数的数据集,所提算法能够在训练过程中提取到更多主用户信息数据的时间相关性特征,同时也能够进一步避免过拟合的情况,因此采用较大数据样本训练完成的模型对于主用户信号具有更高的检测能力。此外,本文还采用 RadioML2016.10 a^[22] 数据集进行了类比实验,该数据集包含 8 种类型的调制方式,被广泛用于




图 5 不同全连接层数下 P_D 随信噪比变化曲线

Fig. 5 P_D versus SNR with different number of FC layers

调制识别任务,其由基带 I/Q 信号向量组成,考虑了常见的无线电信号损耗,例如频率偏移、时延和采样率漂移等。如图 7 所示,其中 BPSK, QPSK 和 16 QAM 信号样本均来自 RadioML2016.10 a 数据集,在 SNR 低于 -18 dB 时,所提算法对于这三种调制信号样本的 P_D 均能够达到 60% 以上,且始终优于传统能量检测算法,可见所提算法对于其他样本数据均具有较好的检测能力。

为进一步验证所提算法的性能,采用其他深度学习网络模型,例如 CNN, MLP 和传统能量检测算法进行对比实验。其中 CNN 模型主要由 1 个 $64 \times 11 \times 1$ 的卷积层、1 个最大池化层和 3 个全连接层组成,MLP 主要由 5 个全连接层组成,神经元个数分别 2048, 1024, 512, 256 和 2。首先,改变 P_F 值,根据式




图 6 不同训练样本数下 P_D 随信噪比的变化曲线

Fig. 6 P_D versus SNR curves with different numbers of training samples




图 7 不同调制方式下 P_D 随信噪比的变化曲线

Fig. 7 P_D versus SNR curves with different modulation types

(15) 可得到不同的阈值, 在不同的阈值下, 选择 SNR 为 -14 dB 的测试样本输入到不同算法中, 可得到对应的 ROC 特性曲线。如图 8 所示, 本文所提 Bi-LSTM 模型即使在较低 P_F 情况下, 仍能够保持 P_D 在 83% 以上, CNN 和 MLP 的性能次之。可见, 在当前 SNR 环境下, 基于模型驱动的传统能量检测算法性能最差。

分别把 P_F 设定为 0.1 和 0.01, 采用 SNR 范围为 $-20 \sim 10$ dB 的测试样本作为各种算法的输入数据, 得到 P_D 随 SNR 的变化曲线如图 9 所示, 可以看到本文所提算法依旧具有最优检测性能, 且其 P_D 随 SNR 的增长速度也是最快的。当 SNR 低于 -14 dB 时, 对于传统能量检测算法, 其检测性能急剧恶化, 在 P_F 为 0.01 的情况下其 P_D 几乎为 0, 而基于数据驱动的神经网络模型均表现出更优的检测性能, 这是由于神经网络模型具有自适应学习能力, 能够自发学习主用户




图 8 信噪比为 -14 dB 情况下的 ROC 曲线

Fig. 8 ROC curves with SNR = -14 dB




图 9 不同频谱感知算法下 P_D 随信噪比的变化曲线

Fig. 9 P_D versus SNR with different SS algorithms

信号特性。与其他深度学习算法相比, 所提算法可达到 80% 以上的检测概率, 再次证明所提算法具有较强的检测能力, 而传统能量检测算法在低 SNR 环境下几乎无法工作。

如图 10 所示, 分析每个频谱感知算法在 LEO 卫星过境期间的检测性能。在卫星过境期间 LEO 卫星与 GES 的距离 $d_{ges,leo}$ 遵循先变小后变大的规律, 因此图 10 呈现一个对称的检测性能曲线。根据式 (3) 可计算每个时刻下对应的 SNR 情况, 在 500 s 时刻, LEO 卫星刚好位于 GES 的头顶上方, 此时 SNR 最大, 每个频谱感知算法均能 100% 检测。然而在 $0 \sim 200$ s 的时间间隔内, 能量检测算法的 P_D 几乎为 0, 所提算法仍具有最优的检测性能, 在 270 s 时刻, 其 P_D 已到达 100%。该结果也表明所提算法将在本文所提的认知卫星通信场景具有较好的应用前景。

4 结语

考虑在 GEO 中继卫星和 LEO 卫星频谱共存的认知卫星通信场景, 针对传统模型驱动算法过度依赖预定的统计模型的弊端, 提出了一种基于 Bi-LSTM 网络及贝叶斯似然比检验联合的频谱感知算法, 该算法以贝叶斯似然比作为测试统计量, 可方便控制所需 P_F 。

在本文所提的认知卫星通信场景中, 根据星地链路间的传输损耗模型, 分析了 LEO 卫星过境期间 SNR 的波动情况, 结果表明其最大波动达到 14 dB。

在当前认知卫星通信场景下, 提出了一种基于




图 10 LEO 卫星过境期间 P_D 的变化曲线

Fig. 10 Change curves of P_D during the transit of LEO satellites

Bi-LSTM 网络和贝叶斯似然比联合的频谱感知模型, 该模型以次用户接收到的信号数据作为输入, Bi-LSTM 网络可通过训练自动提取接收信号的时间相关性特征, 并对接收信号进行决策, 无需进行其他复杂运算, 也无需接收信号先验知识。

为验证所提算法的优势, 针对其泛化能力和不同 SNR 下的检测能力等方面进行了广泛实验, 实验结果表明, 所提算法对于不同调制方案的信号样本均具有较好的检测性能。即使在 SNR 为 -14 dB 的信道环境下, 所提算法仍能达到 83% 以上的检测性能, 且始终优于 CNN, MLP 以及传统能量检测算法。

参考文献

- [1] YOU X H, WANG C X, HUANG J, *et al.* Towards 6 G wireless communication networks: vision, enabling technologies, and new paradigm shifts[J]. *Science China Information Sciences*, 2021, **64**(1): 110301
- [2] LIU R, ZHU S B, LI C Q. Review of cognitive satellite communication technology[C]//2020 IEEE 9 th Joint International Information Technology and Artificial Intelligence Conference (ITAIC). Chongqing: IEEE, 2020: 1378-1385
- [3] LIU C, LIU X M, LIANG Y C. Deep CNN for spectrum sensing in cognitive radio[C]//ICC 2019 - 2019 IEEE International Conference on Communications (ICC). Shanghai: IEEE, 2019: 1-6
- [4] NI T, DING X J, WANG Y F, *et al.* Spectrum sensing via temporal convolutional network[J]. *China Communications*, 2021, **18**(9): 37-47
- [5] TIAN J J, PEI Y Y, HUANG Y D, *et al.* Modulation-constrained clustering approach to blind modulation classification for MIMO systems[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2018, **4**(4): 894-907
- [6] JIANG C X, ZHANG H J, REN Y, *et al.* Machine learning paradigms for next-generation wireless networks[J]. *IEEE Wireless Communications*, 2017, **24**(2): 98-105
- [7] CLANCY C, HECKER J, STUNTEBECK E, *et al.* Applications of machine learning to cognitive radio networks[J]. *IEEE Wireless Communications*, 2007, **14**(4): 47-52
- [8] HAN D, SOBABE G C, ZHANG C J, *et al.* Spectrum sensing for cognitive radio based on convolution neural network[C]//2017 10 th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI). Shanghai: IEEE, 2017: 1-6
- [9] THILINA K M, CHOI K W, SAQUIB N, *et al.* Machine learning techniques for cooperative spectrum sensing in cognitive radio networks[J]. *IEEE Journal on Selected Areas in Communications*, 2013, **31**(11): 2209-2221
- [10] TANG Y J, ZHANG Q Y, LIN W. Artificial neural network based spectrum sensing method for cognitive radio[C]//2010 6 th International Conference on Wireless Communications Networking and Mobile Computing (WiCOM). Chengdu: IEEE, 2010: 1-4
- [11] ZHANG M, DIAO M, GUO L M. Convolutional neural networks for automatic cognitive radio waveform recognition[J]. *IEEE Access*, 2017, **5**: 11074-11082
- [12] WANG J, TANG J, XU Z Y, *et al.* Spatiotemporal modeling and prediction in cellular networks: a big data enabled deep learning approach[C]//IEEE INFOCOM 2017 - IEEE Conference on Computer Communications. Atlanta: IEEE, 2017: 1-9
- [13] SHAWEL B S, WOLDEGEGBREAL D H, POLLIN S. Convolutional LSTM-based long-term spectrum prediction for dynamic spectrum access[C]//2019 27 th European Signal Processing Conference (EUSIPCO). A Coruna: IEEE, 2019: 1-5
- [14] WU T. CNN and RNN-based deep learning methods for digital signal demodulation[C]//Proceedings of the 2019 International Conference on Image, Video and Signal Processing. Shanghai: Association for Computing Machinery, 2019: 122-127
- [15] XIE J D, FANG J, LIU C, *et al.* Deep learning-based spectrum sensing in cognitive radio: a CNN-LSTM approach[J]. *IEEE Communications Letters*, 2020, **24**(10): 2196-2200
- [16] GIUFFRIDA G, DIANA L, DE GIOIA F, *et al.* Cloud-Scout: a deep neural network for on-board cloud detection on hyperspectral images[J]. *Remote Sensing*, 2020, **12**(14): 2205
- [17] LI F L, LI Z Q, LI G X, *et al.* Efficient wideband spectrum sensing with maximal spectral efficiency for LEO mobile satellite systems[J]. *Sensors*, 2017, **17**(1): 193
- [18] ZHANG C, JIANG C X, JIN J, *et al.* Spectrum sensing and recognition in satellite systems[J]. *IEEE Transactions on Vehicular Technology*, 2019, **68**(3): 2502-2516
- [19] SENGLIPTA S K. Fundamentals of statistical signal processing: estimation theory[J]. *Technometrics*, 1995, **37**(4): 465-466
- [20] ZHENG S L, CHEN S C, QI P H, *et al.* Spectrum sensing based on deep learning classification for cognitive radios[J]. *China Communications*, 2020, **17**(2): 138-148
- [21] SAEED N, ELZANATY A, ALMORAD H, *et al.* Cube-Sat communications: recent advances and future challenges[J]. *IEEE Communications Surveys & Tutorials*, 2020, **22**(3): 1839-1862
- [22] O'SHEA T J, WEST N. Radio machine learning dataset generation with GNU radio[C]//Proceedings of the 6 th GNU Radio Conference. Boulder: GRCon, 2016