



研究与开发

基于深度神经网络的铁路通信系统频谱感知方法

袁张付¹, 宋宗莹¹, 王兴中¹, 周一鸣²

(1. 中国神华能源股份有限公司, 北京 100011;

2. 北京邮电大学电子工程学院, 北京 100876)

摘要: 针对当前铁路通信系统400 MHz专用频段中存在的频谱资源紧张问题, 提出了一种基于深度神经网络的频谱感知方法。该方法通过联合分析信号的空-频-时联合表征, 在保障主用户通信质量的前提下实现高精度频谱空穴检测。具体实现如下: 首先, 认知用户对接收到的感知样本进行信号处理, 提取信号的能量、功率谱和循环谱特征, 并拼接为信号特征矩阵, 作为神经网络的输入; 其次, 通过特征嵌入模块对各模态特征进行深层表示; 最后, 在混合感知层中利用2个多层感知机(multilayer perceptron, MLP)模块分别提取各模态特征及特征间的关联性, 并完成频谱判决。实验结果表明, 在虚警概率为0.01、信噪比为-10 dB的仿真环境下, 该方法的检测概率可达99.8%。与目前基于卷积神经网络和卷积长短期记忆深度神经网络的频谱感知方法相比, 该方法的检测概率平均可提升3.23%、2.61%。所提方法为铁路异构通信系统的动态频谱接入提供了高可靠性解决方案。

关键词: 铁路通信; 频谱感知; MLP; DNN; 信号特征

中图分类号: TN929.5

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025157

Spectrum sensing method of railway communication system based on deep neural network

YUAN Zhangfu¹, SONG Zongying¹, WANG Xingzhong¹, ZHOU Yiming²

1. Shenhua Energy Company Limited, Beijing 100011, China

2. School of Electronic Engineering, Beijing University of Posts and Telecommunications, Beijing 100876, China

Abstract: To address the spectrum scarcity issue in the 400 MHz dedicated frequency band of railway communication systems, a deep neural network (DNN)-based spectrum sensing method was proposed. By jointly analyzing the spatial-frequency-temporal joint characterization of signals, high-precision spectrum hole detection was achieved while ensuring the communication quality of primary users. The implementation procedure was conducted as follows: firstly, the received sensing samples were processed by cognitive users, where energy features, power spectral density,

收稿日期: 2025-02-12; 修回日期: 2025-06-24

基金项目: 中国神华能源股份有限公司科技项目 (No.SHGF-24-02)

Foundation Item: Science and Technology Project of China Shenhua Energy Company Limited (No.SHGF-24-02)

and cyclostationary characteristics were extracted and concatenated into a signal feature matrix as the neural network input. Subsequently, each modal feature was deeply represented through a feature embedding module. Finally, two multilayer perceptron (MLP) modules in the hybrid sensing layer were utilized to extract both intra-modal features and inter-modal correlations, followed by spectrum decision-making. Experimental results demonstrate that under simulated conditions with a false alarm probability of 0.01 and signal-to-noise ratio (SNR) of -10 dB, the proposed method achieves a detection probability of 99.8%. Compared with existing spectrum sensing methods based on convolutional neural networks (CNN) and convolutional long short-term memory deep neural networks, the detection probability was improved by 3.23% and 2.61% on average, respectively. This method provides a highly reliable solution for dynamic spectrum access in heterogeneous railway communication systems.

Key words: railway communication, spectrum sensing, MLP, DNN, signal feature

0 引言

近年来,随着高速铁路的快速发展,铁路通信业务的数据承载量与日俱增。面对持续增加的数据业务需求,依靠单一的通信网络已无法承担通信容量需求^[1],认知异构网络技术可以为高速铁路无线频谱资源短缺的问题提供有效的解决方向。目前的铁路通信系统采用 GSM-R (global system for mobile communications - railway) 作为主干网络,并逐步引入 LTE-R (long-term evolution for railway)、卫星通信和 Wi-Fi 等通信技术作为补充,共同构成了异构铁路通信系统 (heterogeneous railway communication system, HRCS)^[2]。

在目前的异构无线网络环境中,有限的频谱资源无法解决多业务的共存问题^[3],例如,国有铁路业务与地方铁路业务的冲突,安全运行服务与互联网接入的矛盾。国际电信联盟 (International Telecommunications Union, ITU) 在 2020 年发布了铁路通信和智能交通系统 (intelligent transportation systems, ITS) 集成的技术标准,该标准重点关注了如何在铁路系统中集成智能交通技术,通过频谱管理技术解决铁路和交通系统之间的通信互操作性及频谱共享问题^[4]。因此,认知无线电作为面对频谱资源短缺的一种潜在解决方案,受到了学术界和工业界的广泛关注^[5]。该技术可以在不影响主用户 (primary user, PU) 工作的前提下,将空闲频段分

配给认知用户 (secondary user, SU),在很大程度上提高了对频谱资源的利用率。频谱感知是认知无线电的基础,其主要目的在于检测 PU 当前是否正在使用授权频谱。同时,频谱感知也是解决目前铁路通信系统频谱资源紧张问题的关键技术^[6]。

2024 年北京全路通信信号研究设计院集团有限公司研发的铁路 400 MHz 数字无线列调系统正式开通试用。当前铁路通信系统需兼容 450 MHz 模拟列调、GSM-R 及未来 5G-R 等多制式网络,频谱碎片化问题突出^[7]。频谱感知技术可优化 400 MHz 频段内的动态分配,避免与相邻频段的冲突。除此之外,400 MHz 系统需要支持语音调度与数据调度同步传输,而频谱感知技术可以通过快速识别空闲频段或低干扰通道,确保关键指令的优先传输。在干扰管理方面,铁路沿线存在电力牵引架、隧道、桥梁等复杂结构,易导致多径效应和电磁干扰,频谱感知技术可通过实时监测频段能量、识别阻塞干扰源,动态调整调制参数或切换信道,以降低通信中断风险。因此,设计出能够在低 SNR (signal-to-noise ratio, SNR) 场景下稳定工作的频谱感知算法对当前铁路 400 MHz 的频谱管理至关重要。

频谱感知算法的核心挑战在于检测统计量的设计优化^[8],其本质是挖掘信号与噪声的差异化特征以实现鲁棒判决。传统频谱感知算法通常基于信号的单一物理层特征构建检测统计量,包括



能量检测 (energy detection, ED)^[9]、协方差矩阵特征值检测 (如最大特征值检测)^[10]、循环平稳特征检测 (cyclostationary feature detection, CFD)^[11]和匹配滤波检测 (matched filter detection, MFD)^[12]等。ED通过计算接收信号能量特征实现快速感知,但对噪声不确定性敏感;协方差矩阵特征值检测依赖信号协方差矩阵特性(如最大特征值)区分信号和噪声,在低SNR下,特征值分布趋近 Tracy-Widom分布,导致判决门限模糊;MFD在检测概率方面优于基于能量和特征的算法,但其依赖于信号样本的先验信息,在信号样本统计独立的情况下实用性较低。这些方法均存在明显的短板,且普遍受限于单维度特征的表达能力。

近年来,深度学习 (deep learning, DL)在信号处理方面显示出巨大的潜力^[13-15]。为了进一步提高检测性能,一些研究人员也将深度学习应用于频谱感知算法模型中。基于卷积神经网络 (convolutional neural network, CNN)的频谱感知算法^[16]将信号时频图转化为图像分类问题,在特定场景下检测概率显著提升。长短期记忆 (long short-term memory, LSTM)网络通过捕捉信号时序相关性^[17],获得信号的长距离特征表示。Gao等^[18]提出了一种基于卷积长短期记忆神经网络 (convolutional long short-term deep neural network, CLDNN)的频谱感知模型,并在神经网络中加入特征融合层。实验结果表明,该模型在检测概率上优于传统的CNN模型。然而,现有深度学习模型仍存在两方面缺陷。

(1) 特征表示浅层化:多数研究直接采用原始信号或单一特征作为输入,未能充分挖掘多维度特征的协同表征潜力,特别是对频域-循环频率等联合分布特征的深层提取能力不足。

(2) 模态关联性缺失:现有特征融合方法多停留在简单拼接层面,缺乏跨模态的深度关联建

模,导致低SNR环境下单模态特征误判率显著上升。

这些不足驱动本文从多模态特征互补和深度关联建模两方面进行模型改进,因此本文提出了一种基于深度神经网络 (deep neural network, DNN)的特征频谱感知方法。该方法首先对认知用户接收到的信号样本从能量、功率谱和循环谱3个角度提取信号特征,并作为神经网络的输入。其中,能量特征反映信号全局强度,功率谱刻画频域能量分布,循环谱揭示调制周期特性,三者构成信号的空-频-时联合表征。然后通过特征嵌入模块实现各模态的深层语义表示。最后利用多层感知机 (multilayer perceptron, MLP)的深度神经网络提取模态内特征与模态间非线性关联。实验结果显示,在虚警概率为0.01、SNR为-10 dB的环境下,本文所提方法的检测概率可达到99.8%。

1 系统模型

频谱感知是一个二分类问题,即PU存在和不存在2种状态。因此,可以将次级用户的频谱感知问题建模为二元假设检验模型,表示为:

$$\{y(n)_i\}_{n=1}^N = \begin{cases} \{w(n)_i\}_{n=1}^N, & H_0 \\ \{s(n)_i + w(n)_i\}_{n=1}^N, & H_1 \end{cases} \quad (1)$$

其中, H_0 和 H_1 分别表示频谱空缺和占用, $y(n)_i$ 表示认知用户在第 i 个感知周期中接收到的第 n 个样本, N 表示一个感知周期所接收到的样本长度, $s(n)_i$ 表示PU所传输的信号, $w(n)_i$ 为信号传输过程中受到的干扰噪声。

噪声服从圆对称复高斯分布^[19],噪声的实部和虚部满足零均值,独立且方差相等,概率密度函数 $p(z)$ 可表示为:

$$p(z) = \frac{1}{\pi\sigma^2} \exp\left\{-\frac{|z|^2}{\sigma^2}\right\} \quad (2)$$

其中, $|z|^2$ 为复数模的平方, σ^2 是每个实数维度的方差。该形式表明复高斯变量在复平面上呈圆对称分布, 相位均匀分布, 模长服从瑞利分布。

在实际的认知无线电系统中, PU 和 SU 之间存在着诸多障碍物, 导致 SU 接收到的信号通常会受到多径衰落的影响。因此采用瑞利衰落信道, 每一个感知周期所接收到的信号 \mathbf{Y}_i 可表示为:

$$\mathbf{Y}_i = [y(1)_i, y(2)_i, \dots, y(N)_i] \quad (3)$$

SU 对接收到的信号进行采样后, 分别提取样本序列的能量、功率谱和循环谱特征, 并拼接得到信号特征矩阵, 然后通过神经网络对处理信号进行深层特征提取, 以此来构建检验统计量, 最后判决频谱状态。系统感知流程如图 1 所示。




图1 系统感知流程

频谱感知模型的评价指标主要包括检测概率和虚警概率。检测概率可定义为 $P_d = P(H_1|H_1)$, 即当 PU 存在时, 认知用户准确识别出 PU 的概率。虚警概率可定义为 $P_f = P(H_1|H_0)$, 即 PU 不存在, 但认知用户错误识别出 PU 的概率。虚警概率偏高会导致频谱利用率低, 虚警概率低又可能导致漏检, 进而影响 PU 通信的安全性。因此, 在提高感知模型性能时, 需要在控制虚警概率的前提下, 尽可能地提高频谱感知模型的检测概率。

2 感知信号处理

2.1 能量特征

ED 是目前应用广泛的频谱感知方案。能量检测器通过获取信号样本的能量, 并与预定阈值

比较以此判决频谱状态, 能量特征 $T(y)$ 的计算方式如下。

$$T(y) = \frac{1}{N} \sum_{n=0}^{N-1} |y(n)|^2 \quad (4)$$

其中, $y(n)$ 为信号样本, N 为一个感知片段的长度。

该表达式计算了每个感知片段的平均能量。本文模型将感知样本切分为 64 个片段, 得到感知信号的能量统计特征 $T_E = [E_1, E_2, \dots, E_{64}]^T$ 。

2.2 功率谱特征

信号的功率谱是信号的关键特征, 功率谱密度可以从频域的角度反映信号的功率分布。假设认知用户接收到的样本序列为 $x(n)$, 则功率谱密度 $S_x(k)$ 可以表示为:

$$S_x(k) = \frac{1}{N} |X(k)|^2 = \frac{1}{N} |\text{FFT}[x(n)]|^2 \quad (k=0, 1, \dots, N-1) \quad (5)$$

$\text{FFT}[x(n)]$ 是样本序列 $x(n)$ 的傅里叶变换, $X(k)$ 表示信号的第 k 个频率分量。

选取傅里叶变换的周期 N 作为计算功率谱的周期, 将计算得到的功率谱密度函数进行 64 点采样, 得到信号的功率统计特征 $T_P = [P_1, P_2, \dots, P_{64}]^T$ 。

2.3 循环谱特征

发送信号经过载波调制和编码等信号处理后, 通常会具有噪声所没有的周期性特征, 这种周期性特征可以通过谱相关函数来表示。通过计算谱相关函数来构建检测统计量的方法, 便是基于循环谱特征的频谱感知模型。

若一个随机过程 $x(t)$ 的自相关函数是周期函数, 则认为 $x(t)$ 是二阶循环平稳过程。假设信号自相关函数的傅里叶级数 $R_x^\alpha(\tau)$ 是收敛的, 则其傅里叶级数展开式为:

$$R_x(t, t+\tau) = E\{x(t)x^*(t+\tau)\} = \sum_{\alpha} R_x^\alpha(\tau) e^{j2\pi\alpha t} \quad (6)$$

其中, $\alpha = m/T$ ($m=0, 1, 2, \dots$) 表示循环频率, 是信号基频的整数倍; $R_x^\alpha(\tau)$ 为信号的循环自相关函



数, 表示信号 $x(t)$ 在不同循环频率处的循环自相关强度。

然后对 $R_x^\alpha(\tau)$ 做傅里叶变换, 即谱相关函数, 计算式为:

$$R_x^\alpha(\tau) = \frac{1}{T} \int_0^T R_x(t, t-\tau) e^{-j2\pi\alpha t} dt \quad (7)$$

$$S_x^\alpha(f) = \int_{-\infty}^{\infty} R_x^\alpha(\tau) e^{-j2\pi f\tau} d\tau \quad (8)$$

其中, $S_x^\alpha(f)$ 为信号的谱相关函数。当接收端信号包含 PU 信号时, 即 $y(t) = s(t) + n(t)$, 其循环自相关函数和谱相关函数分别为:

$$R_y^\alpha(\tau) = \frac{1}{T} \int_0^T R_y(t, t-\tau) e^{-j2\pi\alpha t} dt = \frac{1}{T} \int_0^T E\{y(t)y^*(t-\tau)\} e^{-j2\pi\alpha t} dt = \frac{1}{T} \int_0^T E\{s(t)s^*(t-\tau) + s(t)n^*(t-\tau) + n(t)s^*(t-\tau) + n(t)n^*(t-\tau)\} e^{-j2\pi\alpha t} dt = R_{ss}^\alpha(\tau) + R_{nn}^\alpha(\tau) + R_{sn}^\alpha(\tau) + R_{ns}^\alpha(\tau) \quad (9)$$

$$S_r^\alpha(f) = \int_{-\infty}^{\infty} R_r^\alpha(\tau) e^{-j2\pi f\tau} d\tau = S_{ss}^\alpha(f) + S_{nn}^\alpha(f) + S_{sn}^\alpha(f) + S_{ns}^\alpha(f) \quad (10)$$

此时, 接收信号的谱相关函数由 $s(t)$ 的谱相关函数 $S_{ss}^\alpha(f)$, $n(t)$ 的谱相关函数 $S_{nn}^\alpha(f)$ 以及 $s(t)$ 和 $n(t)$ 的互相关函数组成。本系统假设接收端的信号样本与噪声独立, 相关程度可以忽略。其中噪声的谱相关函数计算式如下。

$$S_{nn}^\alpha(f) = \int_{-\infty}^{\infty} R_{nn}^\alpha(\tau) e^{-j2\pi f\tau} d\tau = \sigma^2 \delta(\alpha) \quad (11)$$

其中, σ^2 为方差, $\delta(\alpha)$ 为冲激函数。由此可见, 信号样本的谱相关函数会在信号载波对应的频率和循环频率处出现较大的幅值, 而噪声的谱相关函数仅在 $\alpha=0$ 时出现峰值。当接收样本中包含 PU 信号时, 接收信号循环谱密度函数的循环平稳特征图如图 2 所示。

因此, 为表达感知信号的循环谱特征可对感知样本的谱相关函数从载波频率 $f=0$ 和循环频率 $\alpha=0$ 所在的 2 条直线上进行 64 点采样得到循环平

稳特征向量 $T_{CS} = [CS_1, CS_2, \dots, CS_{64}]^T$ 。与上述能量特征和功率谱特征拼接得到维度为 64×4 的信号特征矩阵。




图2 接收信号循环谱密度函数的循环平稳特征图

3 多模态特征感知网络

目前基于深度神经网络的频谱感知模型以 CNN 和 LSTM 网络框架为主, 但是 CNN 无法捕捉信号特征的长距离依赖关系, LSTM 网络存在训练速度缓慢的问题。基于自注意力机制的神经网络在图像和自然语言处理等领域被广泛使用, 但其计算复杂度为 $O(n^2)$, 计算和内存需求随着输入序列长度的平方增加而增长, 推理速度降低。考虑上述不同检测信号的特性, 本文设计一种综合能量、功率谱和循环谱这 3 种模态数据的频谱感知网络, 其网络模型结构如图 3 所示。该网络结构是针对上述多模态信号特征矩阵量身定制的, 采用纯粹的 MLP 模型作为网络的主要架构, 在模型的参数量、推理速度和准确率上相较传统的深度学习模型更具优势, 更加符合实际铁路感知场景^[20]。

本文所提出的多模态特征感知网络分为特征嵌入层和混合感知层两部分。其中, 特征嵌入部分将上文得到的特征矩阵的每一行通过卷积映射到高维向量, 目的在于独立地对每种信号特征进行深层表示。之后, 再将得到的高维特征作为混

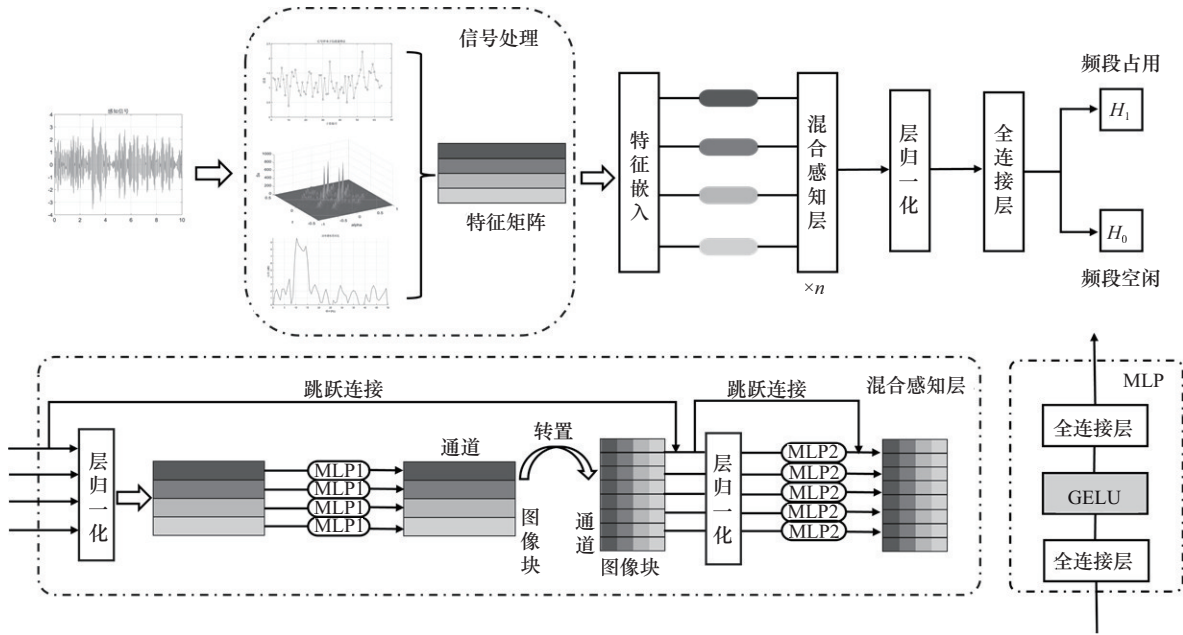


图3 网络模型结构

合感知层的输入，通过2个MLP模块分别从行和列2个维度进行感知。最后通过特征融合来构建检验统计量，完成频谱判决。

3.1 特征嵌入

目前常用的特征嵌入层的操作流程是将输入的特征矩阵分为多个局部特征段，通过全连接层后，作为后续网络的输入。多模态特征感知网络将信号特征矩阵的每一行作为一段局部特征，通过卷积扩展至高维向量，目的在于通过卷积挖掘每种信号特征的深层信息。具体而言，首先，在特征嵌入层输入矩阵 $I \in \mathbb{R}^{N \times S}$ ， N 为信号采样点数， S 为提取的信号特征个数。其次，为降低网络复杂度，所有信号特征采用相同的卷积运算进行统一的线性投影，卷积核和步长与采样点数相同，卷积运算的输出表示为 $O \in \mathbb{R}^{C \times 1 \times S}$ ，其中 C 为卷积运算的输出通道数。最后，将其重塑为 $\tilde{O} \in \mathbb{R}^{S \times C}$ 作为混合感知层的输入。

3.2 混合感知层

混合感知层由2个MLP模块组成，分别用于映射输入矩阵 $X \in \mathbb{R}^{S \times C}$ 的行和列。具体而言，混合感知层首先通过MLP1对输入矩阵的每种信号

特征进行单独处理，来分别提取感知信号的能量、功率谱和循环谱信息，从时域、频域和统计特性等方面挖掘PU信号和纯噪声信号的区别。然后采用矩阵转置操作，并通过MLP2来捕获不同特征间的关联性和冗余信息。采用所有的MLP1共享权重来映射不同的行，表示对各模态特征的提取；采用所有的MLP2共享权重来映射不同的列，表示对不同模态特征之间关联性的捕捉。虽然2个MLP模块只能提取局部特征，但通过两者的结合，可以捕获输入矩阵的全局信息和长距离依赖^[21]。在每个MLP模块处理完成后，通过跳跃连接保留原始特征信息，防止特征在多层非线性变换中过度失真，同时避免梯度消失问题。

MLP1和MLP2均由全连接层实现，且中间通过非线性单元GELU函数连接，相应的隐藏层神经元个数分别为 D_S 和 D_C ，则混合感知操作可使用如下计算式表示：

$$\begin{aligned} U_{*,i} &= X_{*,i} + W_2 \sigma(W_1 \text{LN}(X)_{*,i}) \\ Y_{j,*} &= X_{j,*} + W_4 \sigma(W_3 \text{LN}(X)_{j,*}) \end{aligned} \quad (12)$$



其中, \mathbf{X} 为混合感知层的输入矩阵; i 为行索引, 表示每种信号特征, $i=1, 2, \dots, C$; j 为列索引, 表示每个采样时刻, $j=1, 2, \dots, S$; \mathbf{U} 和 \mathbf{Y} 分别为特征混合MLP1和通道混合MLP2的输出; σ 表示激活函数GELU, 用于提取输入矩阵的非线性特征; LN为归一化层; \mathbf{W}_1 和 \mathbf{W}_2 为MLP1的模型参数, \mathbf{W}_3 和 \mathbf{W}_4 为MLP2的模型参数。

上述所介绍的混合感知层可作为一个感知块, 在实际应用中可以根据SU端的计算资源, 动态增加感知块的数目, 以获得更高的感知性能。

4 实验与结果分析

4.1 实验设置

为验证本文所提出方法的合理性和有效性, 实验将从检测概率、虚警概率和SNR等方面对模型进行分析和验证。实验数据集的构造面向铁路通信的业务需求, 重点针对当前400 MHz数字无线列调系统中的动态频谱感知任务, 数据生成参照《专用数字对讲设备技术要求和测试方法》(GB/T 32659—2016)的相关技术要求, 符合铁路通信数据范式。

本实验所采用的数据集通过MATLAB仿真生成, 数据集中正样本是具有循环特征的周期平稳信号, 调制方式采用广泛应用的铁路控制信号QPSK和4FSK, 载波频率设置为目前铁路通信系统工作的400 MHz频段, 背景噪声为加性高斯白噪声并通过多径瑞利信道传输。同时考虑列车运动带来的多普勒效应, 设置最大多普勒频移为100 Hz。接收信号样本的长度为256 bit, 对应16 ms的传输时长, 满足列车控制指令的实时性要求。负样本则为仅含噪声的信号样本。SNR范围为-20~5 dB, 每种SNR下生成1 000个信号样本, 并将数据集按照3:1:1的比例划分为训练集、验证集和测试集。

模型训练部分通过Pytorch框架实现, 在参

数设置上, 特征嵌入层采用 64×1 的卷积核将信号特征矩阵的每一行通过卷积扩展至 128×1 , 作为混合感知层的输入。MLP1和MLP2的隐藏层维度设置为输入维度的2倍。模型训练的其余超参数设置见表1。

表1 模型训练的其余超参数设置

模型超参数	参数设置
Epoch	50
Batch size	16
Dropout ratio	0.2
学习率	0.001
优化器	SGD
混合感知层数	3
损失函数	交叉熵损失函数

使用基于DNN的多模态特征频谱感知方法进行仿真实验, 仿真实验流程如图4所示, 具体步骤如下。

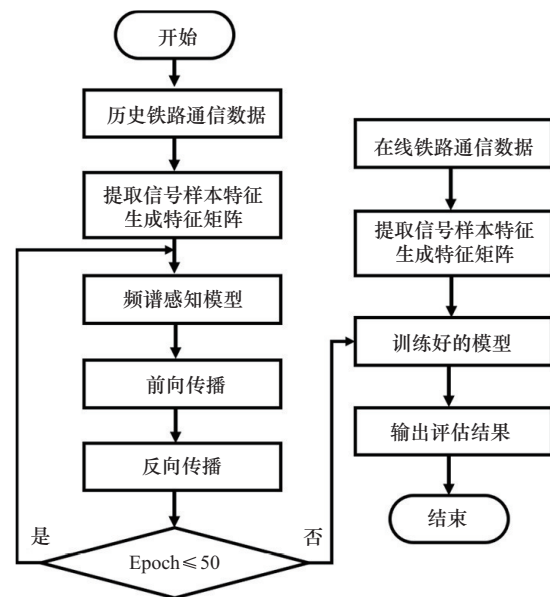


图4 仿真实验流程

步骤1 将MATLAB仿真的信号作为SU接收到的感知样本, 并将数据集划分为训练集、验证集和测试集。

步骤 2 设置训练集和验证集为历史铁路通信数据，并通过信号处理，提取感知样本的能量、功率谱和循环谱，并拼接为信号特征矩阵。

步骤 3 将数据输入频谱感知模型，前向传播通过特征嵌入层和混合感知层，反向传播更新模型参数，直到训练结束。

步骤 4 设置测试集为在线铁路通信数据，测试数据通过信号特征提取后输入训练好的模型。

步骤 5 测试数据经特征嵌入和混合感知后得到频谱判决结果，并输出模型在测试集上的检测概率和虚警概率。根据测试结果评估本文所提模型的有效性。

4.2 仿真结果分析

将本文提出的基于 MLP 架构的频谱感知网络模型与 CNN 和 CLDNN 模型进行性能比较。CNN 模型采用文献[22]中的参数设定，由 2 个卷积块和全连接层组成。CLDNN 模型包含 3 个卷积模块和 2 个 LSTM 层，且已经在文献[18]中验证了其在频谱感知任务中的优势。

在使用 QPSK 和 4FSK 调制信号的情况下，3 种网络模型的信号检测概率对比分别如图 5、图 6 所示。本文提出的基于 MLP 架构的频谱感知网络模型，可在 SNR 为 -13 dB 时达到 90% 以上的检测概率，在 SNR 为 -10 dB 时达到接近 100% 的检测概率，可以满足实际铁路通信场景中的频谱感知任务，且可以适配不同调制方案的通信系统。由图 5、图 6 可知，本文模型在检测概率上整体高于 CNN 和 CLDNN 模型。CNN 模型在提取信号空间特征上具有优势，但是无法捕捉信号的长距离依赖；CLDNN 模型在卷积层的基础上添加了 2 个 LSTM 层，用于提取信号样本的时间特征，但是无法对信号的能量、功率等多模态特征进行融合。本文模型采用基于 MLP 架构的多模态特征感知网络，不仅对输入矩阵的每一行进行了特征提取，也

对不同行的特征建立了关联，获得了更高的检测概率。

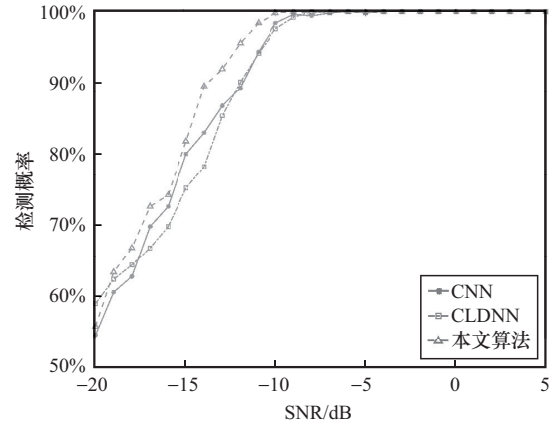


图 5 使用 QPSK 的信号检测概率对比

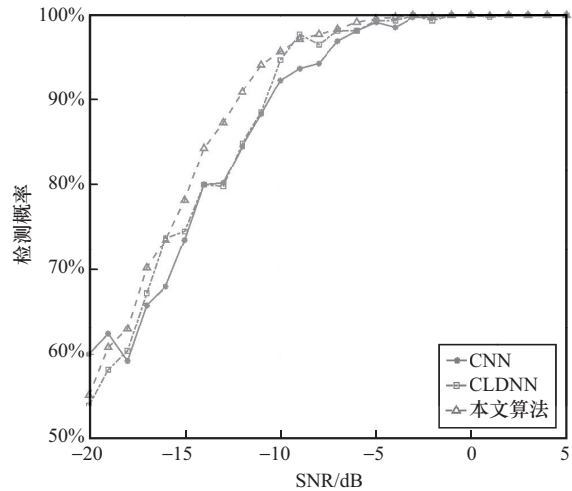


图 6 使用 4FSK 的信号检测概率对比

在追求高检测概率的同时，需要注意控制频谱感知的虚警概率。较高的虚警概率会导致频谱利用率低；虚警概率低又可能导致漏检，从而影响 PU 通信的安全性。因此，需要在控制虚警概率的情况下，对模型的检测概率进行比较。在将虚警概率设置为 0.01 时，3 种模型的信号检测概率对比如图 7 所示。由图 7 可知，本文模型在控制虚警概率方面同样优于对比模型，且可在虚警概率为 0.01 和 SNR 为 -10 dB 的情况下，达到 99% 以上的检测概率，保证了该模型在实际应用中的安全性和稳定性。

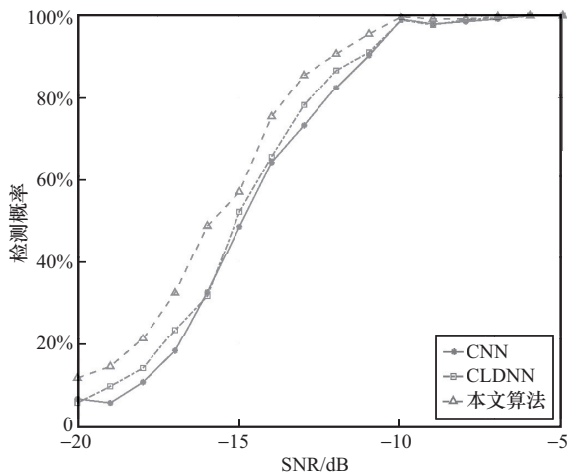


图7 0.01虚警概率下检测概率比较

由于不同通信场景对虚警概率的要求不同，因此需要比对不同虚警概率下的模型性能。在SNR=-12 dB的情况下，不同虚警概率中3种模型检测概率的ROC曲线对比如图8所示。本文模型在所有虚警概率下的感知性能都优于CNN和CLDNN模型。尽管模型采用纯粹的MLP框架，并未添加注意力机制，但通过特征嵌入层的高维映射和混合感知层特征提取，使得模型在较低SNR和虚警概率的实验设定下，仍具备较高的感知精度。

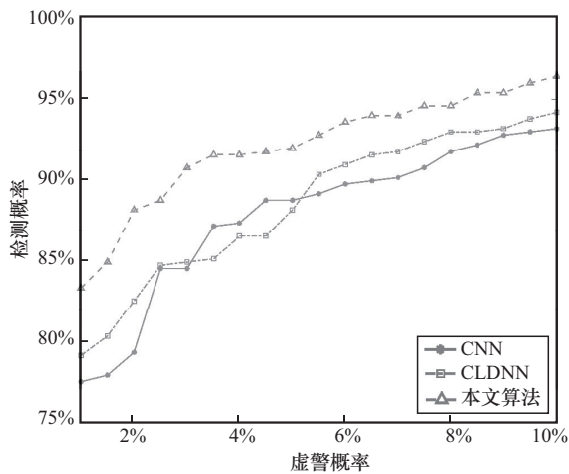


图8 3种模型检测概率的ROC曲线对比

为进一步评估各种信号特征在频谱感知任务中的作用，在MLP框架下将上述信号特征矩阵进行拆分，使用仅包含部分信号特征的数据来训练

模型。通信系统采用QPSK调制信号，对比了不同SNR环境下能量、功率谱、能量+功率谱、循环谱、循环谱+能量+功率谱5种信号特征的检测概率，其结果如图9所示。




图9 不同信号特征的检测概率比较

由图9可知，在单一使用周期平稳特征时，模型在低SNR下表现不佳。在只使用能量和只使用功率谱特征时，模型的检测概率相近。不过在SNR低于-15 dB时，功率谱特征表现更为优秀，这是因为在SNR较低时，时域特征几乎被噪声掩盖，信号的频域特征发挥主要作用；在SNR超出-15 dB时，能量特征则发挥主导作用。因此，在同时使用能量和功率谱特征时，模型输入矩阵同时包含了信号的时域和频域特征，模型性能整体优于基于单一特征的感知模型。而本文模型将上述多种模态特征作为模型输入，在单独处理各模态特征的同时，通过基于MLP框架的混合感知网络捕捉了不同特征间的关联，由此获得了优于其余模型的检测概率。

为验证本文所提模型能否满足实际铁路场景中的低时延需求，在复杂度上与CNN和CLDNN模型进行对比。3种模型的复杂度对比见表2。其中，参数量反映模型的空间复杂度，参数量越小占用内存越少，便于部署至移动设备；FLOPS为计算量，反映模型的时间复杂度，即推理速度；

检测概率为模型在虚警概率为0.01、SNR为-12 dB下的测试结果。与CNN和CLDNN模型相比，本文模型大大降低了模型的参数量，在移动端的部署上更具优势。计算量上，本文模型优于CLDNN模型，虽然与CNN模型相比有所提高，但计算量整体较小，可以满足实际感知场景中的低时延需求，且在检测概率上获得了较大幅度的提升。以上结果验证了本文方法的优越性。

表2 3种模型的复杂度对比

模型	参数量	FLOPS	检测概率
CNN	83.9 K	210.8 K	90.4%
CLDNN	121.3 K	279.1 K	91.2%
本文模型	36.6 K	238.7 K	95.6%

5 结束语

针对铁路通信系统频谱利用率低的问题，本文提出了一种基于深度神经网络的多模态特征频谱感知方法，其包含信号处理、特征嵌入和混合感知3个部分。该方法先通过信号处理提取感知样本的多模态特征，并将其作为特征矩阵，再通过神经网络分别提取各模态信号特征的深层信息和特征间的关联性来完成频谱判决。实验结果表明，本文所提模型在较低SNR下能较好完成铁路通信中的频谱感知任务，可有效适应隧道峡谷、多径效应等复杂环境带来的噪声干扰，且在不同的调制方式、SNR和虚警概率下，本文模型均优于CNN和CLDNN模型。然而，当前模型还存在以下局限性：若需要采集实际铁路运行场景下的通信数据，则需要较大的通信开销；当铁路通信环境发生较大变化，需要对模型进行微调。在今后的工作中，将通过不同复用频率管理技术，提高铁路系统的频谱利用率。

参考文献：

- [1] ZHONG Z D, AI B, ZHU G, et al. Dedicated mobile communications for high-speed railway[M]. Heidelberg: Springer, 2018.
- [2] HE R S, AI B, WANG G P, et al. High-speed railway communications: from GSM-R to LTE-R[J]. IEEE Vehicular Technology Magazine, 2016, 11(3): 49-58.
- [3] YIN Z J, WANG Y M, WU C. A multi-agent collaborative model for Bayesian opportunistic channel accessibility in railway cognitive radio[J]. International Journal of Performability Engineering, 2017,13(4):479-489.
- [4] CHAE K, PARK J, KIM Y. Rethinking autocorrelation for deep spectrum sensing in cognitive radio networks[J]. IEEE Internet of Things Journal, 2023, 10(1): 31-41.
- [5] 王琳, 张世龙, 王树彬. 基于注意力多尺度特征融合的频谱感知方法[J]. 无线电工程, 2024, 54(11): 2520-2526.
WANG L, ZHANG S L, WANG S B. A spectrum sensing method based on attention multi-scale feature fusion[J]. Radio Engineering, 2024, 54(11): 2520-2526.
- [6] CAI L N, CAO K T, WU Y P, et al. Spectrum sensing based on spectrogram-aware CNN for cognitive radio network[J]. IEEE Wireless Communications Letters, 2022, 11(10): 2135-2139.
- [7] 李盼盼, 吴昊, 刘佳佳, 等. 智能铁路5G安全技术与策略综述[J]. 计算机科学, 2024, 51(5): 1-11.
LI P P, WU H, LIU J J, et al. Overview of security technologies and strategies for intelligent railway 5G[J]. Computer Science, 2024, 51(5): 1-11.
- [8] LIU C, WANG J, LIU X M, et al. Deep CM-CNN for spectrum sensing in cognitive radio[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(10): 2306-2321.
- [9] DIGHAM F F, ALOUINI M S, SIMON M K. On the energy detection of unknown signals over fading channels[C]//Proceedings of the IEEE International Conference on Communications, 2003. Piscataway: IEEE Press, 2003: 3575-3579.
- [10] ZENG Y, KOH C L, LIANG Y C. Maximum eigenvalue detection: theory and application[C]//Proceedings of the 2008 IEEE International Conference on Communications. Piscataway: IEEE Press, 2008: 4160-4164.
- [11] SALAH DINE F, EL GHAZI H, KAABOUCH N, et al. Matched filter detection with dynamic threshold for cognitive radio networks[C]//Proceedings of the 2015 International Conference on Wireless Networks and Mobile Communications (WINCOM). Piscataway: IEEE Press, 2015: 1-6.
- [12] JANG W M. Blind cyclostationary spectrum sensing in cognitive radios[J]. IEEE Communications Letters, 2014, 18(3): 393-396.
- [13] PAN G L, LI J, LIN F. A cognitive radio spectrum sensing method for an OFDM signal based on deep learning and cycle spectrum[J]. International Journal of Digital Multimedia Broad-



- casting, 2020(1): 5069021.
- [14] 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.
- [15] XIE J D, FANG J, LIU C, et al. Unsupervised deep spectrum sensing: a variational auto-encoder based approach[J]. IEEE Transactions on Vehicular Technology, 2020, 69(5): 5307-5319.
- [16] LI H Q, BORHANI-DARIAN P, WU P, et al. Deep learning of GNSS signal correlation[C]//Proceedings of the 33rd International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2020). Manassas: Institute of Navigation, 2020: 2836-2847.
- [17] PATEL D K, LÓPEZ-BENÍTEZ M, SONI B, et al. Artificial neural network design for improved spectrum sensing in cognitive radio[J]. Wireless Networks, 2020, 26(8): 6155-6174.
- [18] 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.
- [19] 刘思佚, 徐东辉, 刘丁胤, 等. 基于 CNN-Transformer 融合的频谱感知方法研究[J]. 无线电通信技术, 2024: 1-7.
LIU S Y, XU D H, LIU D Y, et al. Research on spectrum sensing method based on CNN-Transformer fusion [J]. Radio Communications, 2024: 1-7.
- [20] TOLSTIKHIN I, HOULSBY N, KOLESNIKOV A, et al. MLP-Mixer: an all-MLP architecture for vision[J]. arXiv preprint, 2021, arXiv:2105.01601.
- [21] YU Y X, TENG Y L, WANG B H, et al. M-Net: a lightweight network based on multilayer perceptron for massive MIMO CSI feedback[C]//Proceedings of the 2023 IEEE Globecom Workshops (GC Wkshps). Piscataway: IEEE Press, 2023: 26-31.
- [22] GENG Y, HUANG J Y, YANG J X, et al. Spectrum sensing for cognitive radio based on feature extraction and deep learning[J]. Journal of Physics: Conference Series, 2022, 2261(1): 012016.

[作者简介]



袁张付 (1979-), 男, 现就职于中国神华能源股份有限公司, 主要研究方向为移动通信、光传输、核心网通信技术、标准及测试。

宋宗莹 (1981-), 男, 博士, 中国神华能源股份有限公司正高级工程师, 主要研究方向为重载铁路调度、运输、专网、列控技术和智慧化等。

王兴中 (1968-), 男, 博士, 中国神华能源股份有限公司高级工程师, 主要研究方向为列车网络化控制。

周一鸣 (2001-), 男, 北京邮电大学电子工程学院硕士生, 主要研究方向为信号频谱感知和深度学习。