

基于时间累积的低信噪比智能频谱感知方法

张陆鑫^{1,2}, 郑仕链¹, 齐佩汉², 杨小牛¹

(1. 电磁空间安全全国重点实验室, 浙江 嘉兴 314033; 2. 西安电子科技大学通信工程学院, 陕西 西安 710071)

摘要: 面向认知无线电系统低信噪比条件下信号检测性能受限的问题, 提出一种基于时间累积的智能频谱感知方法, 在不需要重新训练模型的前提下, 实现对不同观测时长信号数据的有效检测。针对不同输入表征的智能感知模型, 设计了输入数据累积、感知模型累积和检测统计量累积 3 种时间累积策略。实验结果表明, 所提方法可显著提升低信噪比下的检测性能, 且对不同输入表征的感知模型及不同信道条件均表现出良好的鲁棒性, 从而验证了该方法的有效性 with 工程实用潜力。

关键词: 认知无线电; 频谱感知; 时间累积; 人工智能

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2026059

Temporal accumulation-driven intelligent spectrum sensing method under low-SNR conditions

Zhang Luxin^{1,2}, Zheng Shilian¹, Qi Peihan², Yang Xiaoniu¹

1. National Key Laboratory of Electromagnetic Space Security, Jiaxing 314033, China

2. School of Telecommunications Engineering, Xidian University, Xi'an 710071, China

Abstract: To address the limitation of signal detection performance in low signal-to-noise ratio (SNR) scenarios of cognitive radio systems, a temporal-accumulation-driven intelligent spectrum sensing method that enabled effective sensing across different observation durations without retraining the model was proposed. For different types of intelligent sensing models, three time-accumulation strategies were developed, such as input-data accumulation, perception-model accumulation, and detection-statistic accumulation. Experimental results demonstrate that the proposed method can markedly improve detection performance under low SNR and exhibit strong robustness across intelligent spectrum sensing models with different input representations and under different channel conditions, further demonstrating the effectiveness and practical engineering potential of the proposed method.

Keywords: cognitive radio, spectrum sensing, temporal accumulation, artificial intelligence

0 引言

随着 6G、物联网 (Internet of things, IoT) 等新型通信系统的加速演进, 电磁频谱资源稀缺性问题日益凸显, 对频谱资源精细化管理与带宽高效利用的需求愈发迫切^[1]。认知无线电 (cognitive radio, CR) 被普遍视为缓解频谱资源短缺的有效手

段之一^[2]。在 CR 系统中, 首要任务是通过频谱感知技术对主用户 (primary user, PU) 的存在性进行检测, 从而判断次用户 (secondary user, SU) 是否能够机会式地接入可用的空闲频谱^[3]。借助认知无线电技术, 各类新型无线通信系统能够实现从未占用频段的动态访问, 在很大程度上缓解频谱资

收稿日期: 2025-11-29; 修回日期: 2026-02-15

通信作者: 郑仕链, lianshizheng@126.com

基金项目: 国家自然科学基金资助项目 (No.62171334)

Foundation Item: The National Natural Science Foundation of China (No.62171334)

源紧张矛盾。然而,当前电磁空间中大规模多用户接入以及多样化交互的特性,也使频谱感知过程面临更严苛的可靠性与灵活性挑战。

传统频谱感知方法一般通过比较检测统计量与预设的门限完成判决,如匹配滤波检测^[4-6]、能量检测^[7-9]以及基于协方差矩阵的检测^[10-12]等。这类方法虽结构清晰、易于实现,但往往依赖较强的先验假设或对噪声不确定性、相关性较敏感,且在低信噪比条件下检测性能受限。因此,广大研究人员开始致力于探索基于深度学习的新型频谱感知方法^[13-14]。该类方法利用神经网络的自动特征提取能力,以特征化的电磁信号数据为输入,通过监督学习实现对主用户存在性的判决。现有深度学习频谱感知研究主要在网络结构与输入表征两方面展开。Liu 等^[15]和 Chen 等^[16]设计了基于协方差矩阵和卷积神经网络(convolutional neural network, CNN)的频谱感知框架,实现了数据驱动的检测统计量构造和频谱判决。Zheng 等^[17]和 Cai 等^[18]将接收的电磁信号进行时频变换后,建立频域或时频域特征化数据,作为 CNN 的输入进行频谱判决。盖建新等^[19]和 Zhang^[20]等直接基于采样信号的同相(in-phase, I)和正交(quadrature, Q)序列训练频谱感知模型,以解决单天线和多天线场景下的频谱感知问题。Soni 等^[21]将频谱数据视为时间序列样本,并利用长短期记忆网络(long short-term memory, LSTM)构建频谱感知框架,以提升检测性能。为同时考虑接收信号的空间特征与时序特征, Xie 等^[22]提出了结合 CNN 与 LSTM 的检测器,先利用 CNN 从协方差矩阵中提取一系列信号能量相关特征,再将其输入 LSTM 以学习主用户的活动状态。尽管此类基于深度学习的频谱感知方法在多种应用场景下取得了良好的检测效果,但在数据构建与模型设计上普遍隐含“固定观测窗长/固定输入维度”的假设:I/Q 序列被切分为固定长度的片段,协方差矩阵阶数与接收通道数相关并保持固定维度,时频表征则以固定帧长与固定分辨率输入网络。由此训练与推理阶段一般默认输入长度一致,使模型应用与输入尺寸强耦合。当需要在更长观测时间下提升检测性能时,现有方法往往需要针对新的观测时长重新构造标注数据,并在此基础上对感知模型进行再训练。这种“为每一种观测时长单独训练模型”的策略,一方面显著增加了标注数据构建的成

本与复杂度,另一方面也带来了可观的训练开销和部署维护负担,难以满足资源受限终端或大规模分布式通信网络场景的实际需求。因此,如何在不需要重新训练模型的前提下,通过对更大尺度观测时间下的信号样本进行累积与利用,持续提升低信噪比条件下的频谱感知性能,成为亟待研究的重要课题。

针对这一挑战,本文提出基于时间累积的低信噪比智能频谱感知方法,旨在不需要重新训练模型的前提下,对延长观测时间后的频谱数据进行有效检测。具体而言,首先构建了基于深度学习的频谱感知基本框架,系统阐述了如何分别基于原始采样信号序列或其变换域表征以及人工特征来训练智能感知模型,并在恒虚警原则下利用训练好的模型完成频谱占用判决。进一步地,本文围绕“智能感知模型的时间累积策略”这一核心问题,在输入数据、模型推理和检测统计量构建 3 个环节上分别设计了相应的累积策略。最后,通过仿真实验对所提方法在不同信噪比条件、不同信道场景、不同输入表征形式以及不同时间累积配置下的检测性能进行了系统评估,结果表明,该方法能够在不重新训练模型的前提下,显著提升低信噪比场景下的频谱感知性能。

本文的主要工作如下。

1) 建立了基于时间累积的低信噪比智能频谱感知方法,在观测时间延长的情况下,仅需利用噪声数据重新划定检测门限,而不需要基于变长信号样本重新训练感知模型。

2) 面向深度学习频谱感知模型设计了 3 类时间累积策略:输入数据累积、感知模型累积和检测统计量累积。其中,输入数据累积在不改变特征化数据维度的前提下实现时间累积特征构建;感知模型累积在变尺寸输入下实现模型输出特征维度保持;检测统计量累积设计了切片式多检测统计量融合的频谱判决机制。这些方法均实现了在不需要重新训练模型的前提下,对长观测时长信号的有效利用与检测性能的提升。

3) 通过多组仿真实验对所提方法进行了系统验证。结果表明,所提方法能为不同输入表征下的智能频谱感知模型带来显著的时间累积增益,整体性能优于多判决投票方法,并在非理想信道条件下仍表现出良好的鲁棒性。对于 I/Q 序列输入模型,

其时间累积策略获得的检测性能与在长观测时间下重新训练模型的检测性能基本相当。

1 系统模型

本文考虑单天线频谱感知系统,即SU基于其观测数据(由单天线接收)判断PU是否存在,及时发现可利用的频谱资源。在数学建模上,频谱感知可以表示为一个二元假设检验问题。设 $s(n)$ 表示PU辐射的电磁信号, $h(n)$ 表示传播信道, $w(n)$ 表示背景噪声, $r(n)$ 表示SU接收的信号,则该假设检验问题可以表示为

$$\begin{cases} \mathcal{H}_0:r(n) = w(n) \\ \mathcal{H}_1:r(n) = h(n)s(n) + w(n) \end{cases} \quad (1)$$

其中, \mathcal{H}_0 表示纯噪声环境, \mathcal{H}_1 表示存在PU信号, $n = 0,1,\dots,N-1$, N 为信号的采样点数,也可称为观测数据的长度。

SU根据观测数据,构造相应的检测统计量 Z ,在确定的检测门限 λ 下,判断频谱感知结果是处于假设 \mathcal{H}_0 还是处于假设 \mathcal{H}_1 ,判决表达式为

$$\begin{cases} \mathcal{H}_0:Z < \lambda \\ \mathcal{H}_1:Z \geq \lambda \end{cases} \quad (2)$$

在二元假设检验中,检测性能一般由虚警概率和检测概率两个指标来衡量。虚警概率指将纯噪声背景错误地判断为存在PU信号的概率,即

$$P_f = P(\mathcal{H}_1|\mathcal{H}_0) \quad (3)$$

其中, $P(\cdot)$ 表示概率。检测概率指PU真实存在时,其成功被SU感知的概率,即

$$P_d = P(\mathcal{H}_1|\mathcal{H}_1) \quad (4)$$

在实际应用中,SU需根据特定的信道和噪声模型构建二元假设检验,并以所使用的频谱感知方法为基础,设计相应的检测统计量,设定检测门限,以获得尽可能高的检测概率和尽可能低的虚警概率。

2 基于深度学习的频谱感知方法

相较于需依赖人工精心设计检测统计量的传统方法,基于数据驱动的深度学习方法能够端到端地从信号数据中自动学习深层特征,从而完成检测任务。凭借其强大的特征自动提取能力,此类方法已被证明可更有效地适应多样性电磁环境^[23-26],从而进一步提升检测性能。

2.1 深度学习频谱感知方法基本框架

在利用深度学习技术解决频谱感知问题时,通常将二元假设检验建模为一个二分类任务,旨在通过有监督学习区分“主用户信号”与“纯背景噪声”。此类方法一般包含离线训练阶段和在线推理阶段。深度学习频谱感知的通用基线流程如图1所示。在训练阶段,首先基于采样信号构建特征化数据样本,与对应标签共同组成标准训练数据集,通过最小化网络输出与真实标签之间的损失,完成二元分类模型的训练。在推理阶段,则依据网络输出的特征构建检测统计量,基于纯噪声数据在恒虚警概率准则下确定检测门限,并通过比较统计量与门限值得到最终的感知结果。本文后续研究的时间累积策略将以图1为参考框架,分别在不同环节实现长观测时间累积以提升低信噪比条件检测性能。

2.1.1 深度学习频谱感知模型训练

为支撑深度学习频谱感知模型的训练,首先需基于SU的观测信号构建训练数据集。作为一种数据驱动的频谱感知范式,其感知性能与输入数据的表征形式紧密相关。现有基于深度学习的频谱感知方法在输入数据上大致可分为3类:直接采用原始采样数据、提取变换域表征以及构造人工特征。相应地,本文考虑原始I/Q序列、功率谱和协方差3种代表性输入形式。

1) 原始I/Q序列

基于原始I/Q序列的频谱感知方法直接将I/Q

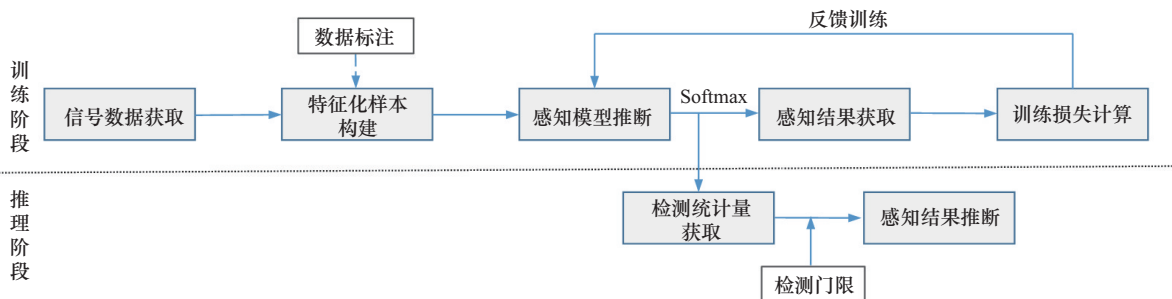


图1 深度学习频谱感知的通用基线流程

采样序列输入神经网络进行训练。此类方法在不对观测信号进行额外处理或变换的前提下,保留了原始采样数据中全部时域与统计信息,由网络自动从数据中挖掘隐式特征,从而避免了人工预处理与特征构造带来的复杂度和主观性^[20]。根据复包络理论,式(1)中SU接收的采样信号 $r(n)$ 可以进一步表示为

$$r(n) = I(n) + jQ(n) \quad (5)$$

基于原始I/Q信号的深度学习频谱感知模型提取接收信号的实部和虚部,堆叠为二维实数矩阵,其标准输入为 $\mathbf{x} \in \mathbb{R}^{N \times 2}$,具体可表示为

$$\begin{aligned} \mathbf{x} &= [\mathbf{I} \ \mathbf{Q}] \\ \mathbf{I} &= [I(0) \ I(1) \ \cdots \ I(N-1)]^T \\ \mathbf{Q} &= [Q(0) \ Q(1) \ \cdots \ Q(N-1)]^T \end{aligned} \quad (6)$$

其中, $[\cdot]^T$ 表示矩阵转置。

2) 功率谱

鉴于噪声和主用户信号在频谱幅度上的统计分布存在明显差异,因此在开展基于深度学习的频谱感知任务时,可将SU的观测数据进行频域变换,并将功率谱作为神经网络输入来训练感知模型^[17]。接收信号 $r(n)$ 的功率谱可表示为

$$\mathcal{P}_{rr} = \frac{|F(r(n))|^2}{N} \quad (7)$$

其中, $F(\cdot)$ 表示傅里叶变换。当使用功率谱作为深度学习频谱感知模型的输入时,其输入数据 $\mathbf{x} \in \mathbb{R}^{N \times 1}$ 具体可表示为

$$\mathbf{x} = [\mathcal{P}_{rr}(0) \ \mathcal{P}_{rr}(1) \ \cdots \ \mathcal{P}_{rr}(N-1)]^T \quad (8)$$

3) 协方差

在频谱感知任务中,协方差矩阵被认为蕴含丰富的判别信息,因而大量传统检测方法均围绕协方差矩阵构造检验统计量以完成信号存在性判决。类似地,在深度学习框架下,协方差矩阵同样可以作为一种人工特征输入神经网络,用于提升检测性能。在协方差矩阵计算中,首先考虑 L 个连续的采样点,定义接收信号向量为

$$\mathbf{r}(n) = [r(n), r(n-1), \cdots, r(n-L+1)]^T \quad (9)$$

其中, L 是平滑因子。那么信号的统计协方差矩阵定义为

$$\mathbf{R}_{rr} = \mathbb{E}\{\mathbf{r}(n)\mathbf{r}^H(n)\} \quad (10)$$

其中, $\mathbb{E}\{\cdot\}$ 表示期望, $(\cdot)^H$ 表示共轭转置。实际上,统计协方差只能依靠有限的信号样本来估计。接收信号的自相关函数可以表示为

$$R_{rr}(l) = \frac{1}{N} \sum_{n=0}^{N-1} r(n)r^H(n-l), l=0,1,\cdots,L-1 \quad (11)$$

统计协方差矩阵为

$$\mathbf{R}_{rr} = \begin{bmatrix} R_{rr}(0) & R_{rr}(1) & \cdots & R_{rr}(L-1) \\ R_{rr}(1) & R_{rr}(0) & \cdots & R_{rr}(L-2) \\ \vdots & \vdots & & \vdots \\ R_{rr}(L-1) & R_{rr}(L-2) & \cdots & R_{rr}(0) \end{bmatrix} \quad (12)$$

对于单天线SU,本文通过采样点时移的方式将单通道接收信号转换为多通道数据构造协方差矩阵^[10],其接收通道数为 L 。所述协方差矩阵 \mathbf{R}_{rr} 为二维复数矩阵 $\mathbf{R}_{rr} \in \mathbb{C}^{L \times L}$ 。同样地,将协方差矩阵 \mathbf{R}_{rr} 提取实虚部后堆叠可得深度学习频谱感知模型的输入数据 \mathbf{x} ,且 $\mathbf{x} \in \mathbb{R}^{L \times L \times 2}$ 。

通过上述方式得到信号特征化数据表示,将其与主用户占用状态的真实感知标注一并构成训练样本,从而形成用于深度学习频谱感知模型训练的完整数据集 $D_{\text{train}} = \{\mathbf{x}_{\text{train}}, \mathbf{y}_{\text{train}}\}$,其中, $\mathbf{x}_{\text{train}}$ 为神经网络模型的输入, $\mathbf{y}_{\text{train}}$ 为训练标签。根据前述的I/Q序列、功率谱和协方差矩阵3种代表性输入形式,本文基于卷积神经网络对应构建了3种频谱感知模型,整体结构由卷积层、池化层和全连接层组成,末端输出层为含有两个神经元的全连接层,以适应二元分类任务。针对不同形式和尺度的输入数据,感知模型在前端卷积层与池化层的结构配置上进行了相应设计与调整,具体模型结构如表1所示,其中,“Conv(15×1, stride=2×1)”表示卷积核尺寸为15×1、滑动步长为2×1的卷积层,“MaxPool(3×1, stride=2×1)”表示池化核尺寸为3×1、滑动步长为2×1的最大池化层,“Residual(16, stride=1×1)”表示标准残差结构、输出通道为16,“GavgPool”表示全局平均池化层,“Fc(2)”表示含有两个神经元的全连接层。

在完成数据和模型准备后,使用带动量的随机梯度下降(stochastic gradient with momentum, SGDM)法^[27]对频谱感知模型进行训练,并通过最小化交叉熵损失函数来优化模型,损失函数表达式为

表1 频谱感知模型结构

I/Q序列输入		功率谱输入		协方差输入	
网络层	输出维度	网络层	输出维度	网络层	输出维度
输入层	$N \times 1 \times 2$	输入层	$N \times 1 \times 1$	输入层	$L \times L \times 2$
Conv (15×1, stride=2×1)	$\frac{N}{2} \times 1 \times 16$	Conv (15×1, stride=2×1)	$\frac{N}{2} \times 1 \times 16$	Conv (5×5, stride=1×1)	$L \times L \times 16$
MaxPool (3×1, stride=2×1)	$\frac{N}{4} \times 1 \times 16$	MaxPool (3×1, stride=2×1)	$\frac{N}{4} \times 1 \times 16$	MaxPool (3×3, stride=1×1)	$L \times L \times 16$
Residual (16, stride=1×1)	$\frac{N}{4} \times 1 \times 16$	Residual (16, stride=1×1)	$\frac{N}{4} \times 1 \times 16$	Residual (16, stride=1×1)	$L \times L \times 16$
Residual (32, stride=2×1)	$\frac{N}{8} \times 1 \times 32$	Residual (32, stride=2×1)	$\frac{N}{8} \times 1 \times 32$	Residual (32, stride=2×1)	$L \times L \times 32$
Residual (64, stride=2×1)	$\frac{N}{16} \times 1 \times 64$	Residual (64, stride=2×1)	$\frac{N}{16} \times 1 \times 64$	Residual (64, stride=2×1)	$L \times L \times 64$
Residual (128, stride=2×1)	$\frac{N}{32} \times 1 \times 128$	Residual (128, stride=2×1)	$\frac{N}{32} \times 1 \times 128$	Residual (128, stride=2×1)	$L \times L \times 128$
GavgPool	$1 \times 1 \times 128$	GavgPool	$1 \times 1 \times 128$	GavgPool	$1 \times 1 \times 128$
Fc (2)	$1 \times 1 \times 2$	Fc (2)	$1 \times 1 \times 2$	Fc (2)	$1 \times 1 \times 2$

$$\mathcal{L}(\mathbf{y}_{\text{train}}, \mathcal{F}(\mathbf{x}_{\text{train}}; \boldsymbol{\theta})) = - \sum_{d=1}^D y_d \log \text{Softmax}(\mathcal{F}_d(\mathbf{x}_{\text{train}}; \boldsymbol{\theta})) \quad (13)$$

$$\begin{cases} \mathcal{H}_0: \mathcal{F}_{\mathcal{H}_1}(\mathbf{x}_{\text{test}}; \boldsymbol{\theta}) < \lambda \\ \mathcal{H}_1: \mathcal{F}_{\mathcal{H}_1}(\mathbf{x}_{\text{test}}; \boldsymbol{\theta}) \geq \lambda \end{cases} \quad (16)$$

其中, $\mathcal{F}(\mathbf{x}; \boldsymbol{\theta})$ 为神经网络的参数化函数, \mathbf{x} 为网络的输入, \mathbf{y} 为对应的标签, $\boldsymbol{\theta}$ 为可学习参数, D 为神经网络的分类类别数, 本文取 $D=2$, $\text{Softmax}(\cdot)$ 为分类问题常用的激活函数。基于上述训练损失, 模型参数可按照式(14)进行更新。

$$\boldsymbol{\theta}_{i+1} = \boldsymbol{\theta}_i - \alpha \nabla_{\boldsymbol{\theta}_i} \mathcal{L}(\boldsymbol{\theta}_i) + \zeta (\boldsymbol{\theta}_i - \boldsymbol{\theta}_{i-1}) \quad (14)$$

其中, i 为更新迭代的索引, α 为学习率, ∇ 为梯度运算, ζ 为步长超参数, 用于控制上一轮梯度更新对当前迭代的影响程度。在训练过程中, 将记录并保存训练损失最小的模型, 用于执行频谱感知任务。

2.1.2 频谱感知结果推理

在频谱感知的推理阶段, 将待检测信号按照与训练阶段一致的方式输入经过训练的神经网络模型, 模型即可输出对应的二维特征结果

$$\mathcal{F}(\mathbf{x}_{\text{test}}; \boldsymbol{\theta}) = \begin{bmatrix} \mathcal{F}_{\mathcal{H}_1}(\mathbf{x}_{\text{test}}; \boldsymbol{\theta}) \\ \mathcal{F}_{\mathcal{H}_0}(\mathbf{x}_{\text{test}}; \boldsymbol{\theta}) \end{bmatrix} \quad (15)$$

在推理阶段, 为满足恒虚警概率检测需求, 本文不直接对二维特征经 Softmax 后进行硬判决, 而是将网络在 \mathcal{H}_1 分支上的输出 $\mathcal{F}_{\mathcal{H}_1}(\mathbf{x}_{\text{test}}; \boldsymbol{\theta})$ 作为检测统计量 Z , 那么式(2)可进一步表示为

对于判决门限的设定, 根据 Neyman-Pearson 准则, 只需在给定目标虚警概率 P_f 的约束下计算一个门限, 使得在假设 \mathcal{H}_0 下的统计量满足 $P(Z \geq \lambda | \mathcal{H}_0) = P_f$ 。那么, 只要能够获得噪声条件下统计量的分布 (或其一致估计), 即可将虚警概率稳定约束在预设值, 从而实现 “恒虚警”。考虑到深度神经网络的非线性映射使统计量 Z 的累积分布难以准确建模, 本文采用分布无关的经验分位数标定方式: 收集 S 个噪声样本 $\{\mathbf{x}_{\text{noise}}^{(i)}\}_{i=1}^S$, 计算对应检测统计量 $Z_i = \mathcal{F}_{\mathcal{H}_1}(\mathbf{x}_{\text{noise}}^{(i)}; \boldsymbol{\theta})$, $i=1, 2, \dots, S$, 并将 $\{Z_i\}_{i=1}^S$ 进行升序排序

$$Z_{(1)} \leq \dots \leq Z_{(S)} \quad (17)$$

则给定目标虚警概率 P_f 后, 可将检测门限取为经验分布的上尾分位点

$$\lambda = Z_{(\lceil (1-P_f) * S \rceil)} \quad (18)$$

其中, $\lceil \cdot \rceil$ 表示向下取整, 以此来实现近似恒虚警控制。需要指出的是, 当检测统计量的构造方式发生变化时, 门限必须在相同统计量定义下重新标定。此外, 样本量 S 的选取需权衡门限估计稳定性与获取代价, 样本量越大则门限抖动越小, 虚警概率越稳定, 但门限标定的代价相对较大。

2.2 基于时间累积的低信噪比频谱感知

在频谱感知任务中，待检测数据通常表现为时间采样序列。在低信噪比条件下，适当延长观测时间有助于提升检测性能。对于如图 1 所示的传统深度学习频谱感知流程，当观测时长发生变化时，直接复用既有模型面临输入维度不匹配的问题，进而需要重新执行训练和推理两个流程以完成场景适配，这显著增加了计算和部署开销。为此，本文设计了一种基于已训练感知模型和时间累积策略的频谱感知方法，框架如图 2 所示。在该方法下，不需要执行模型训练流程，只需要在检测模型推理阶段进行适当调整即可适配长观测检测的情况。具体来说，首先，在延长观测时间条件下准备纯噪声数据，并按照已训练感知模型所需的数据格式输入模型，得到对应的检测统计量。随后，依据这些统计量的经验分布，在恒虚警概率约束下标定对应观测时长下的检测门限。最后，对于实际待感知的数据，只需按照相同的时间累积与特征构建方式输入感知模型，得到检测统计量，并将其与新标定的判决门限进行比较，即可实现频谱占用状态的判决。

针对基于神经网络的感知模型，本文设计了 3 种累积策略，包括输入数据累积、感知模型累积和检测统计量累积。3 种时间累积策略本质上对应融合层级不同，其适用性可由“维度一致性”与“信息可加性/相关性”两类约束统一刻画。输入数据累积属于输入层融合，要求延长观测时间后的数据经分段变换与聚合后仍映射为与观测时间变化前一致的固定输入维度，且聚合对象具有可加性，因此更适用于协方差矩阵、功率谱等统计表征输入，即可通过分段估计与平均实现稳健累积，对 I/Q 序列简单分段聚合易破坏相位连续与时

序结构，一般不作为首选；感知模型累积属于特征层融合，依赖网络具备全局池化等“变长输入-一定长输出”机制，使输出特征维度与输入长度无关，从而可直接利用更长时间窗带来的更充分时频证据，因而更适用于 I/Q 序列与功率谱模型，对于输入尺寸仅与接收通道相关的协方差模型，难以获得额外累积增益；检测统计量累积属于决策层融合，将延长观测划分为多段分别进行推理，得到相同维度统计量再加权融合，结构约束最弱且 3 类模型均可适配，但其收益可能受段间相关性限制。综上，上述 3 种频谱感知模型可适配的累积策略归纳如表 2 所示。

表 2 不同频谱感知模型适配的累积策略

感知模型	输入数据累积	感知模型累积	检测统计量累积
I/Q 序列模型	不适配	适配	适配
协方差模型	适配	不适配	适配
功率谱模型	适配	适配	适配

2.2.1 输入数据累积

输入数据累积旨在对传统深度学习频谱感知推理流程中的特征化样本构建环节进行针对性优化。假定将观测时间延长至 K 倍后，SU 接收的采样信号可记为 $r^{(K)}(n) = [r(0)r(1)\dots r(N)\dots r(KN - 1)]^T$ ，其中 $K \in \mathbb{N}$ 且 $K \geq 1$ ， $K = 1$ 表示未累积时的基础观测。输入数据累积的基本思想是：当采样信号由 $r(n)$ 扩展为 $r^{(K)}(n)$ 时，在不改变单次输入样本尺寸的前提下，根据智能频谱感知模型的输入格式对长序列进行融合处理，使得到的输入样本维度与仅使用 $r(n)$ 时保持一致，基本原理如图 3 所示。对于不同频谱感知模型，其输入数据累积策略的表现形式不同。

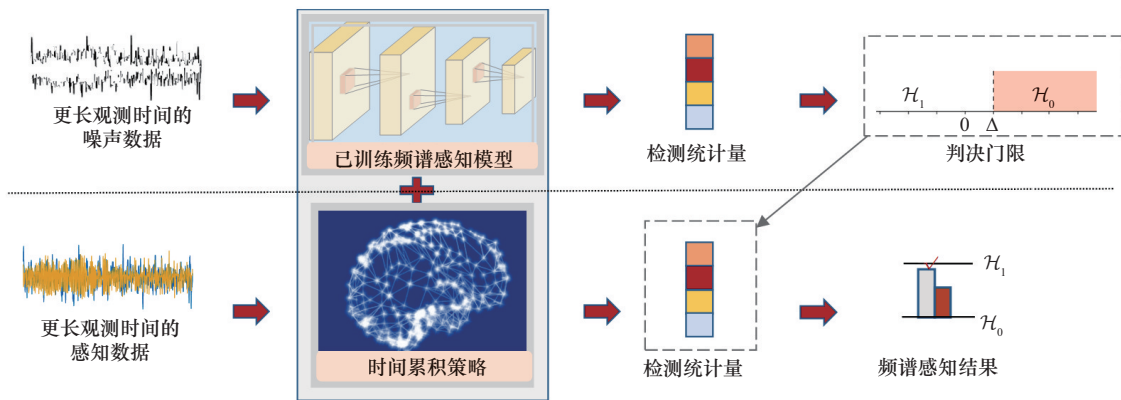


图 2 基于时间累积的频谱感知框架

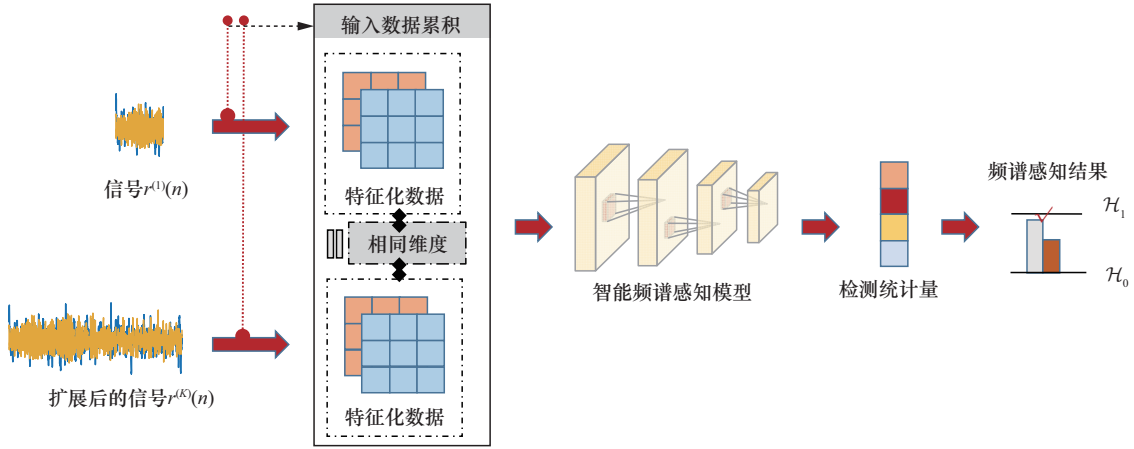


图3 输入数据累积方法基本原理

对于功率谱输入模型，数据累积发生在获得特征化数据之后：将 $r^{(K)}(n)$ 均匀划分成 K 段，对每一段按式(7)分别计算功率谱，再对各段功率谱进行加权累积，以获得模型的最终输入样本，计算式为

$$\bar{\mathcal{P}}_{rr} = \sum_{k=1}^K \mathcal{P}_{rr^{(k)}} \quad (19)$$

对于协方差输入模型，数据累积发生在特征化数据计算阶段：在构建多通道数据时，将每个通道的信号长度由 $N - L + 1$ 延长至 $KN - L + 1$ ，并在累积后的多通道数据基础上计算协方差矩阵，从而获得感知模型的输入样本 \mathbf{x} ，其维度依然保持为原有的 $\mathbf{x} \in \mathbb{R}^{L \times L \times 2}$ 。

在该累积策略下，由于输入样本未发生变化，因此后续频谱感知的执行流程与未经时间累积时保持一致。

2.2.2 感知模型累积

感知模型累积针对传统深度学习频谱感知推理

流程中的检测统计量获取环节进行优化，通过模型结构设计使不同观测时长下模型的输出维度保持一致，从而实现检测统计量的维度固定。具体来讲，在观测时间延长后，基于 $r^{(K)}(n)$ 构造感知模型的输入样本，将更大尺寸的输入样本直接输入模型，由模型在前向传播过程中自动完成时间累积和特征融合，其基本原理如图4所示。对于 I/Q 序列输入模型，输入样本维度从 $\mathbf{x} \in \mathbb{R}^{N \times 2}$ 扩展成 $\mathbf{x} \in \mathbb{R}^{KN \times 2}$ ；对于功率谱输入模型，输入样本维度从 $\mathbf{x} \in \mathbb{R}^{N \times 1}$ 扩展成 $\mathbf{x} \in \mathbb{R}^{KN \times 1}$ 。为保证感知模型在更大尺寸输入样本下仍能正常完成推理，本文在模型设计中于末端输出层之前引入全局池化层。如表1所示，中间层特征图在经过全局池化层后，其维度均统一为 $1 \times 1 \times 128$ 。

2.2.3 检测统计量累积

检测统计量累积也是对传统深度学习频谱感知推理流程中统计量获取环节的优化，不同于感知模

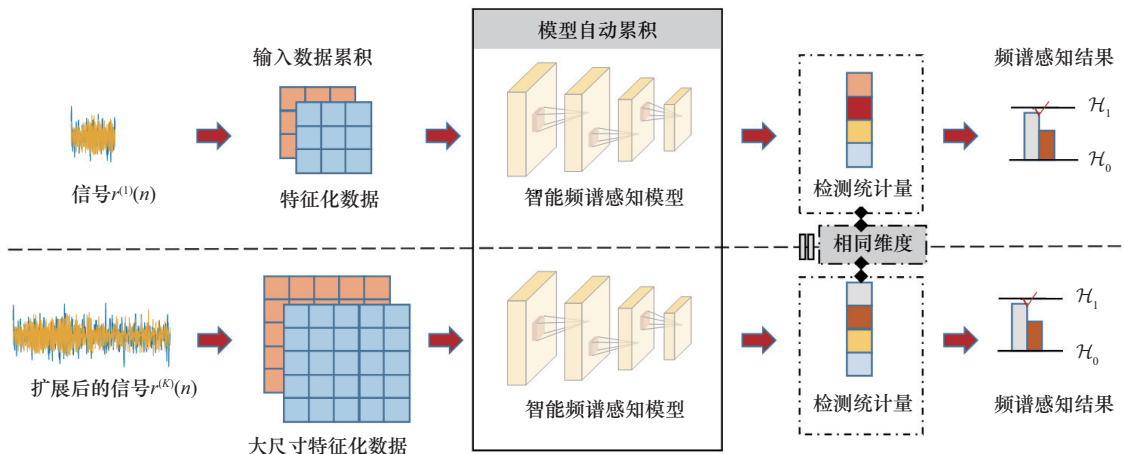


图4 感知模型累积方法基本原理

型累积的固定模型输出尺寸设计思想, 该策略通过多统计量的加权平均实现检测统计量的维度保持。具体来说, 将延长观测时间后的采样信号 $r^{(K)}(n)$ 均匀划分成 K 段, 对每一段单独构建对应的输入样本, 并分别送入感知模型以获得 K 个输出特征。随后, 对这 K 个输出特征进行加权累积, 从而获得最终的检测统计量, 以此进行频谱判决, 算法基本原理如图 5 所示。

具体地, 将 $r^{(K)}(n)$ 切分后获得的 K 个输入样本 $\mathbf{x}_{(k)}$ 分别输入感知模型, 可得到输出特征为

$$\mathcal{F}(\mathbf{x}_{(k)}; \boldsymbol{\Theta}) = \begin{bmatrix} \mathcal{F}_{\mathcal{H}_1}(\mathbf{x}_{(k)}; \boldsymbol{\Theta}) \\ \mathcal{F}_{\mathcal{H}_0}(\mathbf{x}_{(k)}; \boldsymbol{\Theta}) \end{bmatrix}, k = 1, \dots, K \quad (20)$$

那么二元假设检验问题可进一步转化为

$$\begin{cases} \mathcal{H}_0: \sum_{k=1}^K \mathcal{F}_{\mathcal{H}_1}(\mathbf{x}_{(k)}; \boldsymbol{\Theta}) < \lambda \\ \mathcal{H}_1: \sum_{k=1}^K \mathcal{F}_{\mathcal{H}_1}(\mathbf{x}_{(k)}; \boldsymbol{\Theta}) \geq \lambda \end{cases} \quad (21)$$

2.2.4 时间累积增益的评价指标

为量化时间累积策略对低信噪比场景下频谱感知性能的提升效果, 本节定义了“时间累积增益”, 其核心含义为: 在达到相同目标检测概率的前提下, 引入时间累积后所需最小信噪比的改善量。假定在无时间累积 ($K = 1$, 基础观测时长) 情况下, 达到目标检测概率 P_d^* 时所需的最小信噪比为 $\gamma_0(P_d^*)$; 当观测时间延长至 K 倍 ($K > 1$) 并采用时间累积策略后, 达到相同目标检测概率 P_d^* 时所

需的最小信噪比为 $\gamma_K(P_d^*)$ 。那么时间累积增益 G_{TA} 的表达式为

$$G_{TA}(K, P_d^*) = \gamma_0(P_d^*) - \gamma_K(P_d^*) \quad (22)$$

根据式(22)不难看出其物理意义, 若 $G_{TA} > 0$, 表明时间累积策略能够有效降低达到目标检测概率所需的信噪比阈值, 从而提升低信噪比条件下的检测能力, 且 G_{TA} 越大, 性能增益越显著。

2.3 算法复杂度分析

本节对所提出的 3 种时间累积策略以及传统“重新训练感知模型”方法进行了计算复杂度分析, 重点量化数据预处理、模型推理与训练过程 (若涉及) 的核心计算开销, 为实际应用中的策略选择提供量化依据。需要指出的是, 尽管 I/Q、功率谱与协方差 3 类输入对应的网络结构与输入张量形状不同, 导致其单次推理开销存在差异, 但在给定模型与硬件平台下, 该差异可视为与 K 无关的常数因子。因此, 为便于比较不同时间累积策略的工程成本趋势, 本文统一用 M_{inf} 表示单次推理成本, 并重点分析推理成本相对于 K 的标度关系。

2.3.1 输入数据累积

输入数据累积的核心特点是不改变感知模型的输入维度。因此, 无论观测时间延长倍数 K 如何变化, 模型推理阶段始终只需进行一次完整前向传播, 其推理计算复杂度保持为 $O(M_{\text{inf}})$ 。随着观测数据长度的变化, 该策略的额外计算开销主要体现在预处理环节。如 2.2 节所述, 输入数据累积策略只适合协方差模型和功率谱模型, 相应预处理复杂

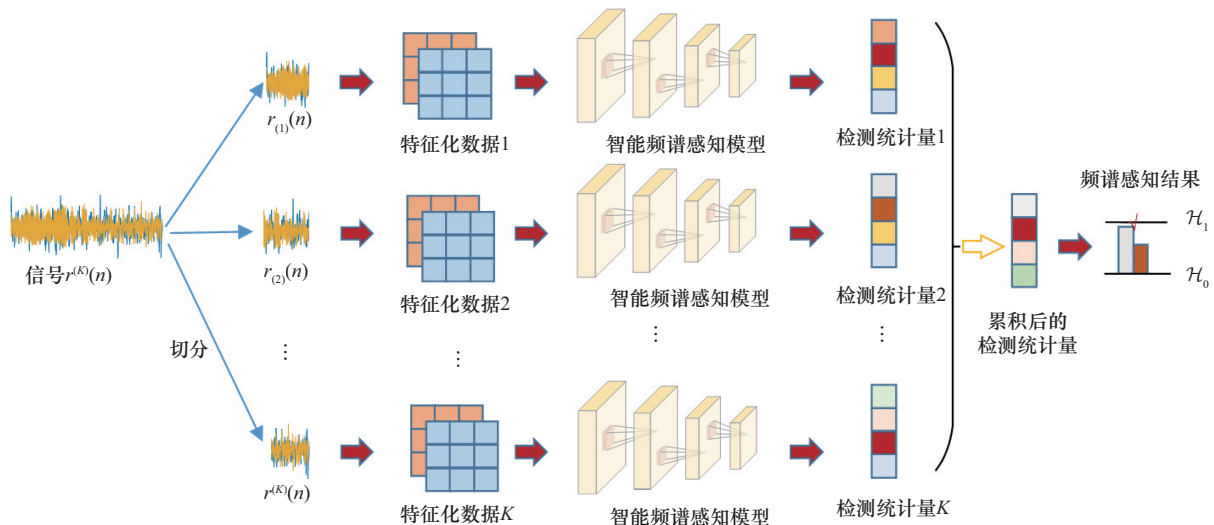


图 5 检测统计量累积方法基本原理

度如下:对于协方差计算,信号长度从 N 延长至 KN 后,以采样点时移的方式构造 L 段 $KN - L + 1$ 长度的信号片段,由于 $KN \gg L$,可近似认为与 KN 同阶。那么,该处理的主导计算为 $L \times KN$ 维度的矩阵乘法运算,其复杂度为 $O(L^2KN)$;对于功率谱计算,将长度为 KN 的信号均匀划分为 K 段,对每段进行谱估计,单段计算复杂度为 $O(N \log N)$,段间谱累积复杂度为 $O(KN)$,因此总预处理复杂度为 $KO(N \log N) + O(KN)$,其中主导项为 $O(KN \log N)$ 。

因此,输入数据累积策略的总复杂度为

$$C_{IA} = \begin{cases} O(L^2KN + M_{inf}), \text{协方差模型} \\ O(KN \log N + M_{inf}), \text{功率谱模型} \end{cases} \quad (23)$$

2.3.2 感知模型累积

感知模型累积策略直接在长度为 KN 的观测信号上构建模型输入,从而不需要对数据进行分段与显式累积。其额外计算开销主要由两部分构成:输入预处理与模型推理。对于I/Q序列模型,预处理计算复杂度为 $O(KN)$;对于功率谱模型,预处理计算复杂度为 $O(KN \log KN)$ 。在感知模型的推理过程中,当计算数据流还未经过全局池化层时,前序特征图在时间维度均会随 K 扩展,而通道维度保持不变。因此卷积层与池化层在时间维度上的滑动次数近似按 K 倍增加。与此同时,全局池化能够将变长特征映射为定长表示,使池化后的全连接层输入维度与 K 无关,其开销可视为常数项。由此,感知模型推理复杂度可近似为 $O(KM_{inf})$ 。

因此,感知模型累积策略的总复杂度为

$$C_{MA} = \begin{cases} O(KN + KM_{inf}), \text{I/Q序列模型} \\ O(KN \log KN + KM_{inf}), \text{功率谱模型} \end{cases} \quad (24)$$

2.3.3 检测统计量累积

检测统计量累积策略将长度为 KN 的观测信号切分为 K 段,分别构建与基础观测时长一致的输入并独立送入感知模型推理,获得 K 个检测统计量,随后进行加权融合。由于每段推理均等价于一次基准推理,则推理计算复杂度可表示为 $KO(M_{inf}) = O(KM_{inf})$;融合阶段仅需对 K 个统计量进行加权平均,计算复杂度为 $O(K)$,显然 $O(KM_{inf}) \gg O(K)$,因此融合开销可视为低阶项并可忽略。与此同时,预处理复杂度取决于输入表征形式,由于该策略对

K 段分别执行预处理,故预处理开销相对基础观测情形近似按 K 倍增长。

因此,检测统计量累积策略的总复杂度为

$$C_{SA} = \begin{cases} O(KN + KM_{inf}), \text{I/Q序列模型} \\ O(KL^2N + KM_{inf}), \text{协方差模型} \\ O(KN \log N + KM_{inf}), \text{功率谱模型} \end{cases} \quad (25)$$

2.3.4 重新训练感知模型

重新训练感知模型是指基于延长观测时间(KN 长度)的信号重新构建数据集并进行模型训练,且训练过程需多次迭代更新参数。在每次迭代中,需要完成一次前向传播(计算损失)和一次反向传播(梯度回传并更新参数),反向传播的复杂度与前向传播同量级,因此总训练复杂度可表示为 $2TO(KM_{inf})$,其中常数2可省略,那么训练复杂度进一步表示为 $O(TKM_{inf})$ 。推理复杂度可表示为进行一次前向传播,相比训练计算量,在此可忽略不计。在该方法下,预处理计算同样在 KN 长度的观测信号上构建感知模型输入数据,3种模型的计算复杂度分别增加至:I/Q序列模型为 $O(KN)$,协方差模型为 $O(L^2KN)$,功率谱模型为 $O(KN \log KN)$ 。

因此,重新训练感知模型策略的总复杂度为

$$C_{RT} = \begin{cases} O(KN + TKM_{inf}), \text{I/Q序列模型} \\ O(L^2KN + TKM_{inf}), \text{协方差模型} \\ O(KN \log KN + TKM_{inf}), \text{功率谱模型} \end{cases} \quad (26)$$

2.3.5 综合对比分析

综上,在以观测数据累积倍数 K 表征时间累积开销时,4类策略的复杂度主导关系可归纳为:输入数据累积仅引入预处理阶段的额外计算,推理阶段始终保持一次前向传播,推理开销与 K 无关,因此在4种策略中总体计算成本最低;感知模型累积与检测统计量累积均使预处理与推理开销随 K 增大而近似线性增长,前者对应“一次长输入推理”,后者对应“多段独立推理并在统计量层融合”;相比之下,重新训练感知模型在具备与感知模型累积相当的单次推理成本基础上,还需进行大量训练迭代优化,训练开销显著主导总成本,因而计算复杂度最高。需要说明的是,算法实际运行时还受硬件并行度与存储访问影响,但不改变上述随 K 的主导标度结论。实际应用中,应在检测性能提升与计算开销约束之间综合权衡,选择与场景需求相匹配的时间累积策略。

3 仿真分析

为验证本文提出的基于时间累积的低信噪比智能频谱感知方法性能, 本节基于仿真数据开展实验并给出结果分析。

3.1 仿真数据

通过计算机仿真随机生成原始比特序列, 并采用 BPSK 调制得到基带符号序列, 随后使用升余弦有限冲激响应滤波器对已调信号进行滤波处理, 滤波器符号跨度为 6, 每符号采样点数为 8, 并在复基带中叠加归一化载波频偏, 范围为 -0.1 到 0.1 。对于未经时间累积 ($K=1$) 的情况, 每个信号包含 64 个符号, 过采样倍数设置为 8, 信噪比范围设置为 -30 dB 至 10 dB, 步进为 1 dB。此外, 数据集还包含与上述信号样本在维度与数量上对应的纯噪声样本, 噪声模型为加性白高斯噪声 (additive white Gaussian noise, AWGN), 信道模型包括 AWGN 信道和瑞利衰落 (Rayleigh) 信道。在时间累积的实验中, 将符号个数增大至 K 倍, 以获得更长时间的采样信号。

3.2 算法性能分析

3.2.1 不同频谱感知方法性能分析

本节对 3 种不同输入表征的深度学习频谱感知模型开展检测性能仿真评估, 并与典型传统信号检测方法 (能量检测、特征值检测、频域熵检测) 以及文献[22]中的 CNN-LSTM 深度学习方法进行对比分析。其中, 在协方差模型、特征值检测中, 构造多通道数据时通道数 L 统一设定为 10。3 种智能频谱感知模型的最大训练轮数设定为 7, 批大小为 128, 初始学习率为 0.01, 并在每训练 2 轮后按 10% 进行学习率衰减, SGDM 算法动量因子为 0.9。达到最大训练轮数后, 选取训练损失最小的模型, 用于最终执行频谱感知任务。

不同频谱感知模型的性能对比如图 6 所示, 其中, 所有方法的虚警概率均设置为 0.01 (下文均按此参数设定)。在低信噪比条件下, 功率谱模型和协方差模型的检测性能整体上明显优于 3 种传统检测方法和 CNN-LSTM 法; I/Q 序列模型与能量检测法和 CNN-LSTM 法的性能较为接近, 且整体优于频域熵检测法。上述结果表明, 通过合理设计输入特征与神经网络结构, 深度学习方法能够有效提升低信噪比条件下的频谱感知性能, 验证了将深度学习方法引入信号检测问题的可行性与有效性。本文

构建的深度学习感知模型在当前主流深度学习方案的性能水平上具有可比性与竞争力, 从而为进一步在该模型框架上引入时间累积机制、挖掘长时观测带来的增益提供了合理的基线支撑与研究必要性。




图6 不同频谱感知模型的性能对比

3.2.2 不同时间累积策略的性能分析

本节针对 3 种不同输入表征的智能频谱感知模型, 分别评估了本文所提时间累积策略的检测性能, 并与多判决投票方法^[28]进行对比。所述多判决投票方法在观测时间延长至 K 倍时, 将连续观测序列按基础观测时长划分为 K 个子段, 对每一子段独立进行主用户存在性判决, 并采用或融合得到最终的频谱感知结果。

1) I/Q 序列模型

对于 I/Q 序列输入的智能频谱感知模型, 可通过感知模型累积和检测统计量累积两种方式提升低信噪比检测性能, 其仿真结果如图 7 所示。结果表明, I/Q 序列模型在引入不同时间累积策略后均能够获得显著的检测性能增益, 且两种累积方式在性能提升幅度上基本一致。以目标检测概率 $P_d = 0.9$ 为例, 当观测时间扩展至原来的 64 倍时, 实现相同检测概率所需的信噪比从约 -6.8 dB 降低至约 -16.3 dB。等价地, 当观测时间每扩展为原来的 4 倍时, 时间累积所带来的检测性能增益均约为 3 dB。这表明即使在较低信噪比场景下, 适当延长观测时间并结合时间累积策略, 仍能有效增强 I/Q 序列输入智能感知模型的检测能力。相比之下, 多判决投票方法在 $K=4$ 时仅带来约 1 dB 的累积增益, 且随着观测时间的进一步延长, 检测增益呈衰减趋势。




图7 I/Q序列模型在不同时间累积策略下的检测性能

2) 协方差模型

对于协方差输入的智能频谱感知模型,可通过输入数据累积和检测统计量累积两种时间累积策略提升低信噪比条件下检测性能,其仿真结果如图8所示。结果表明,在本文提出的时间累积策略下,协方差模型同样能够获得明显的检测性能提升,且整体检测性能优于多判决投票方法,其中,输入数据累积策略的增益整体优于检测统计量累积策略,其原因在于:对于协方差表征而言,输入数据累积把时间延长直接转化为更充分、更稳定的二阶统计估计,从而在输入层完成充分统计;检测统计量累积属于“先压缩后融合”的决策层整合,跨段结构信息更易丢失,其边际增益通常更有限。需要指出的是,虽然未经累积时协方差模型的检测性能优于I/Q序列模型,但在延长观测时间并引入时间累积后,其性能提升幅度低于I/Q序列模型。当观测时间每扩展为原来的4倍时,输入数据累积方式带来检测性能增益约为2 dB。






图8 协方差模型在不同时间累积策略下的检测性能

3) 功率谱模型

功率谱输入的智能频谱感知模型可以适配本文提出的3种时间累积策略,其在不同信噪比下的检测性能如图9所示。为便于观察,本节采用两个子图展示仿真结果:图9(a)展示感知模型累积和检测统计量累积的性能曲线,图9(b)进一步对比了感知模型累积和输入数据累积的检测效果。仿真结果表明,3种时间累积策略均可在不同程度上提升功率谱模型的检测性能,且全面优于多判决投票方法,其中,以感知模型累积获得的性能增益最为显著,检测统计量累积次之。定量来看,当观测时间每扩展为原来的4倍时,感知模型累积策略带来的检测性能增益约为2 dB。不同累积策略性能差异产生的可能原因在于:功率谱属于压缩后的频域统计表征,输入层分段累积主要体现为粗粒度叠加,统计量累积进一步压缩为标量融合,信息损失与段间相关性会限制边际增益;相比之下,感知模型累积可在感知模型内部对更长观测的频域表征进行隐式整合,从而获得更优的检测性能。



(a) 感知模型累积和检测统计量累积策略



(b) 感知模型累积和输入数据累积策略

图9 功率谱模型在不同时间累积策略下的检测性能

综上，功率谱模型和协方差模型在短观测窗内表现出稳定的频谱感知性能，且分别通过感知模型累积和输入数据累积获得可观的性能增益；随着观测时间的延长，I/Q序列模型由于输入信息更完整，具备更充分的累积增益潜力，配合工程实现最为简便的检测统计量累积策略，可进一步提高低信噪比下的检测概率。在实际通信系统部署应用时，应综合考虑算力、存储与回传带宽等资源约束，以及是否采用边缘计算式分布式检测架构和可获取/可交互的数据模态，选择匹配的输入表征感知模型及相应的时间累积策略。

3.2.3 时间累积方法与重新训练感知模型的对比

在延长观测时间的情况下，针对基于深度学习的频谱感知方法，理论上可通过在新观测长度下重新训练感知模型获得最佳检测性能。为此，本节进一步分析了3种输入形式的智能频谱感知模型在“时间累积”与“重新训练”两种方法下的性能差异，以延长观测时间至原来的16倍为例，对比结果如图10所示。由图10(a)可以看出，对于I/Q序列模型，其在采用感知模型累积和检测统计量累积两种时间累积策略时获得的检测性能曲线与在 $K=16$ 情况下重新训练模型获得的性能曲线几乎重合。这一结果充分表明，在不需要额外大规模重新训练的前提下，本文设计的时间累积方法即可在I/Q序列输入场景下逼近重新训练所能达到的最优性能，具有良好的实用性与工程应用价值。

对于协方差输入和功率谱输入的智能频谱感知模型，由图10(b)和图10(c)可知，重新训练方法获得的检测增益优于时间累积方法。具体而言，在 $K=16$ 的情况下，与 $K=1$ 相比，为实现0.9的检测概率所需的信噪比，协方差智能检测由约-9.9 dB降低至约-16.3 dB，功率谱智能检测由约-9.8 dB降低至约-15.4 dB，即当观测时间每扩展为原来的4倍时，模型重新训练带来的检测性能增益约为3 dB。

3.2.4 非理想条件下的性能分析

为验证本文所提时间累积方法的鲁棒性，本节分析了非理想条件下的检测性能。所述非理想条件主要包括3个方面：一是噪声功率不确定性，假设背景噪声功率相对标称值在 ± 3 dB范围内波动；二是瑞利衰落信道，信道参数依据3GPP标准中的EPA模型^[29]进行设置；三是信道时变效应，以 $K=1$ 为最小观测时间块，相邻时间块间重新生成信道系数，以模拟延长观测时间过程中信道随时间变化的情形。




图10 时间累积方法与重新训练频谱感知模型的性能对比

同样以延长观测时间至原来的16倍为例，图11展示了AWGN和瑞利衰落信道下的检测性能对比。结果表明，当未采用时间累积($K=1$)时，3种智能频谱感知模型在瑞利衰落信道下均出现一定程度的性能退化：I/Q序列模型对瑞利衰落的鲁棒性最佳，性能损失总体小于1 dB；协方差模型和功率谱模型的性能损失约为1.5 dB。进一步地，当采用本文提出的时间累积策略($K=16$)时，3种智能感知模型在两类信道条件下的性能差异总体保持稳

定,同时整体检测性能得到可靠提升。上述结果表明,本文方法在噪声功率不确定、瑞利衰落以及信道时变等非理想因素共同作用下仍能保持有效增益,具有良好的鲁棒性与工程应用潜力。

4 结束语

本文面向认知无线电系统中低信噪比信号检测这一关键问题,研究了基于时间累积的智能频谱感知方法。首先,梳理了深度学习频谱感知的整体流程,包括从多样性特征化感知数据构建、智能感知模型训练到检测统计量生成及最终判决输出。其次,在观测时间延长的场景下,构建了基于已训练感知模型与时间累积策略的频谱感知方法,使系统在观测时间变化时仅需利用背景噪声数据重新标定检测门限,而不需要依赖新的信号数据对感知模型进行再训练,并分析了不同时间累积策略的复杂度。最后,仿真实验表明,本文方法对I/Q序列输入、协方差输入以及功率谱输入的智能频谱感知模型均具有良好的适用性,整体性能优于多判决投票方法,且在非理想信道条件下具有良好的鲁棒性。尤其是I/Q序列模型在时间累积策略下获得的检测性能增益与利用延长观测时间后的信号数据重新训练模型达到的性能增益基本相当。上述结果表明,本文方法为未来通信网络中智能检测模型的高效部署与低成本性能提升提供了可行路径,具有良好的实用性与工程应用价值。

参考文献:

- [1] Surekha S, Rahman M Z U. Spectrum sensing and allocation strategy for IoT devices using continuous-time Markov chain-based game theory model[J]. IEEE Sensors Letters, 2022, 6(4): 5500504.
- [2] Mitola J, Maguire G Q. Cognitive radio: making software radios more personal[J]. IEEE Personal Communications, 1999, 6(4): 13-18.
- [3] Haykin S. Cognitive radio: brain-empowered wireless communications[J]. IEEE Journal on Selected Areas in Communications, 2005, 23(2): 201-220.
- [4] Conte E, Lops M, Ricci G. Adaptive matched filter detection in spherically invariant noise[J]. IEEE Signal Processing Letters, 1996, 3(8): 248-250.
- [5] Peng J X, Sang M M, Geng D, et al. Weak signal detection method for space-based ESM based on fractional domain matched filtering[C]//Proceedings of the 2024 3rd International Conference on Electronics and Information Technology (EIT). Piscataway: IEEE Press, 2024: 71-75.
- [6] 梁琴,胡鹏鹏,陈洲,等. 基于FRFT的频域自适应匹配滤波器检测方法[J]. 舰船科学技术, 2024, 46(5): 69-73.
- [7] Liang Q, Hu P P, Chen Z, et al. Frequency domain adaptive matching filter detection method based on FRFT[J]. Ship Science and Technology, 2024, 46(5): 69-73.
- [8] Urkowitz H. Energy detection of unknown deterministic signals[J]. Proceedings of the IEEE, 1967, 55(4): 523-531.
- [9] Digham F F, Alouini M S, Simon M K. On the energy detection of unknown signals over fading channels[J]. IEEE Transactions on Communi-




图11 非理想条件下的检测性能分析

- cations, 2007, 55(1): 21-24.
- [9] Cabric D, Tkachenko A, Brodersen R W. Experimental study of spectrum sensing based on energy detection and network cooperation[C]// Proceedings of the First International Workshop on Technology and Policy for Accessing Spectrum. New York: ACM Press, 2006: 12-20.
- [10] Zeng Y H, Liang Y C. Spectrum-sensing algorithms for cognitive radio based on statistical covariances[J]. IEEE Transactions on Vehicular Technology, 2009, 58(4): 1804-1815.
- [11] Zeng Y H, Liang Y C. Covariance based signal detections for cognitive radio[C]//Proceedings of the 2007 2nd IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks. Piscataway: IEEE Press, 2007: 202-207.
- [12] Zeng Y H, Liang Y C. Maximum-minimum eigenvalue detection for cognitive radio[C]//Proceedings of the 2007 IEEE 18th International Symposium on Personal, Indoor and Mobile Radio Communications. Piscataway: IEEE Press, 2007: 1-5.
- [13] Gu F Y, Zhang L X, Zheng S L, et al. Detection of radar pulse signals based on deep learning[J]. IEEE Open Journal of Signal Processing, 2024, 5: 991-1004.
- [14] Xu M D, Song X K, Zhao Y L, et al. Deep reinforcement learning-based RIS-assisted cooperative spectrum sensing in cognitive radio network[J]. IEICE Transactions on Communications, 2025, 108(4): 404-410.
- [15] 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.
- [16] Chen A Z, Shi Z P, Long Y, et al. CNN-based multiantenna spectrum sensing for hybrid circular and noncircular source signals in cognitive radio[J]. IEEE Sensors Letters, 2023, 7(12): 7007304.
- [17] 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.
- [18] 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.
- [19] 盖建新, 薛宛峰, 南瑞祥, 等. 基于残差密集网络的频谱感知方法[J]. 通信学报, 2021, 42(12): 182-191.
Gai J X, Xue X F, Nan R X, et al. Spectrum sensing method based on residual dense network[J]. Journal on Communications, 2021, 42(12): 182-191.
- [20] Zhang L X, Zheng S L, Qiu K F, et al. MASSnet: deep learning-based multiple-antenna spectrum sensing for cognitive radio-enabled Internet of things[J]. IEEE Internet of Things Journal, 2024, 11(8): 14435-14448.
- [21] Soni B, Patel D K, López-Benítez M. Long short-term memory based spectrum sensing scheme for cognitive radio using primary activity statistics[J]. IEEE Access, 2020, 8: 97437-97451.
- [22] 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.
- [23] Liang Y C, Zeng Y H, Peh E C Y, et al. Sensing-throughput tradeoff for cognitive radio networks[J]. IEEE Transactions on Wireless Communications, 2008, 7(4): 1326-1337.
- [24] Xie J D, Liu C, Liang Y C, et al. Activity pattern aware spectrum sensing: a CNN-based deep learning approach[J]. IEEE Communications Letters, 2019, 23(6): 1025-1028.
- [25] 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.
- [26] Wei F, Zheng S L, Zhou X Y, et al. Detection of direct sequence spread spectrum signals based on deep learning[J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(3): 1399-1410.
- [27] Polyak B T. Some methods of speeding up the convergence of iteration methods[J]. USSR Computational Mathematics and Mathematical Physics, 1964, 4(5): 1-17.
- [28] Chair Z, Varshney P K. Optimal data fusion in multiple sensor detection systems[J]. IEEE Transactions on Aerospace and Electronic Systems, 1986, AES-22(1): 98-101.
- [29] 3GPP. Evolved universal terrestrial radio access (E-UTRA); Base station (BS) radio transmission and reception[S]. Sophia Antipolis: ETSI, 2008.

[作者简介]



张陆鑫 (1996-), 男, 浙江嘉兴人, 电磁空间安全全国重点实验室工程师, 西安电子科技大学博士生, 主要研究方向为频谱感知、智能信号处理、电磁空间安全等。



郑仕链 (1984-), 男, 浙江文成人, 博士, 电磁空间安全全国重点实验室正高级工程师, 主要研究方向为认知无线电、人工智能与信号处理、电磁空间安全等。



齐佩汉 (1986-), 男, 河南永城人, 博士, 西安电子科技大学教授, 主要研究方向为电磁空间智能感知、电磁空间安全与综合利用、通信信号处理与对抗等。



杨小牛 (1961-), 男, 浙江龙游人, 中国工程院院士, 电磁空间安全全国重点实验室研究员, 主要研究方向为信号大数据、人工智能与信号处理等。