



研究与开发

## 基于残差注意力密集网络的协作频谱感知方法

王安义, 朱涛, 龚健超

(西安科技大学通信与信息工程学院, 陕西 西安 710600)

**摘要:** 针对基于卷积神经网络 (convolutional neural network, CNN) 的协作频谱感知算法存在的网络结构简单、特征提取能力不足和感知性能下降等问题, 提出了一种基于残差注意力密集网络 (residual attention dense network, RADN) 的协作频谱感知算法。该算法通过改进基础残差块, 从感受野、通道和空间3个维度引入注意力机制, 结合残差连接和密集连接, 构建了强大的深层特征提取结构——密集残差 (residual in dense, RID), 显著提升了网络的特征提取能力和频谱感知性能。实验结果表明, 相较于传统深度学习方法, RADN算法在低信噪比 (signal-to-noise ratio, SNR) 条件下表现出显著的性能提升。该方法不仅能够适应多种调制方式, 还具备较高的检测概率和良好的鲁棒性。

**关键词:** 协作频谱感知; 卷积神经网络; 注意力机制; 密集连接; 残差连接

**中图分类号:** TN911

**文献标志码:** A

**doi:** 10.11959/j.issn.1000-0801.2025031

## Cooperative spectrum sensing method based on residual attention dense network

WANG Anyi, ZHU Tao, GONG Jianchao

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

**Abstract:** To address the limitations of cooperative spectrum sensing algorithms based on convolutional neural network (CNN), including simple network structures, insufficient feature extraction, and reduced sensing performance, a cooperative spectrum sensing algorithm based on residual attention dense network (RADN) was proposed. The basic residual block was enhanced and attention mechanisms across receptive field, channel, and spatial dimensions were introduced. By integrating residual and dense connections, a powerful deep feature extraction framework was formed, which was termed residual in dense (RID), its feature extraction and sensing performance had been significantly boosted. Experimental results show that under low signal-to-noise ratio (SNR) conditions, the RADN algorithm outperforms traditional deep learning methods, adapting well to various modulation schemes and achieving high detection probability and robustness.

**Key words:** cooperative spectrum sensing, CNN, attention mechanism, dense connection, residual connection

收稿日期: 2024-11-05; 修回日期: 2025-01-17

通信作者: 朱涛, 493237439@qq.com

基金项目: 国家自然科学基金资助项目 (No.62471384)

**Foundation Item:** The National Natural Science Foundation of China (No.62471384)

## 0 引言

随着5G通信的广泛应用及6G通信的快速发展,万物互联与智能连接的时代即将到来<sup>[1]</sup>。然而,由于无线通信业务量的激增,频谱资源已经变得高度稀缺<sup>[2]</sup>。认知无线电(cognitive radio, CR)被认为是缓解频谱资源紧张的有效解决方案<sup>[3]</sup>。CR的概念最早于1999年由Mitola提出,作为一种智能无线电通信系统,CR允许次级用户(secondary user, SU)在不干扰主用户(primary user, PU)的情况下使用授权频谱。频谱感知(spectrum sensing, SS)是CR中的一个关键操作。它的主要目标是实时检测空闲频带,以便SU可以利用它们而不会对PU造成干扰<sup>[4]</sup>。

SS技术可以分为单节点SS和协作频谱感知(cooperative spectrum sensing, CSS)。相比于单节点SS仅依赖单一SU所发送的信号信息来做出判断,CSS通过将各个节点的局部感知信息汇总至融合中心(fusion center, FC),并依据融合规则进行决策,从而能够整合多个SU的特征信息,显著提升SS的性能<sup>[5]</sup>。传统的SS方法主要包括能量检测(energy detection, ED)法<sup>[6]</sup>、循环平稳特征检测法<sup>[7]</sup>、匹配滤波检测法<sup>[8]</sup>和最大似然检测法<sup>[9]</sup>等。然而,传统方法通常面临一些限制,比如检测门限难以确定、需要信号的先验知识等。检测门限的精确性直接影响感知结果,尤其是在低信噪比(signal-to-noise ratio, SNR)条件下,传统方法的检测性能会显著下降。

近年来,人工智能技术在全球范围内迅速崛起,深度学习的发展为SS研究提供了新的思路和方法。深度学习在非线性建模和自适应学习方面具有显著优势,显著提升了SS的检测性能<sup>[10]</sup>。卷积神经网络(convolutional neural network, CNN)作为一种广泛应用于图像处理的技术,能够检测数据中的几何模式,因而在二维图像特征提取方面相较于其他机器学习算法表现出更加优

越的性能<sup>[11]</sup>。鲁华超等<sup>[12]</sup>提出了一种基于CNN和协方差矩阵的CSS算法,与传统方法相比,其显著提高了检测概率。然而,由于该网络结构相对简单,其特征提取能力不足,并且随着网络加深容易出现梯度消失的问题。Chen等<sup>[13]</sup>提出了基于短时傅里叶变换(short time Fourier transform, STFT)和CNN的STFT-CNN方法,虽然提升了SS的性能,但该方法局限于单节点感知,且CNN结构仍然相对简单。Zhen等<sup>[14]</sup>提出了基于小波变换(wavelet transform, WT)和残差网络(residual network, ResNet)的WT-ResNet方法,采用ResNet有效缓解了梯度消失问题,但同样局限于单节点SS。Tan等<sup>[15]</sup>将经典的CNN引入CSS中,验证了其在融合多个SU信息方面的有效性。

为了克服上述局限性,本文提出了一种更加高效的CSS方法。鉴于CNN对图像的强大特征提取能力,通过计算接收到的信号能量向量并将其转化为灰度图像,将SS问题转化为图像二分类问题。为提高CNN的特征提取能力并解决网络加深导致的梯度消失问题,提出了残差注意力密集网络(residual attention dense network, RADN)。具体来说,该方法基于残差注意力单元(residual attention unit, RAU),从感受野、通道和空间3个维度引入注意力机制,增强网络对重要特征的关注,并改进了基础残差块,增强了其特征提取能力。此外,该方法结合密集连接和残差连接的优势,大幅提升了网络的深层特征提取能力,显著提高了频谱感知的性能和鲁棒性。

## 1 频谱感知系统模型

在CR中,SS可以看作一种信号检测问题,其核心在于判断PU是否占用频谱。SS的结果有两种可能性:PU存在或PU不存在。这与经典的二元检测问题相似,因此,SS问题可以转化为一个二分类任务。二分类感知模型如下。



$$H_0 : y(n) = w(n)$$

$$H_1 : y(n) = s(n) + w(n) \quad (1)$$

其中,  $H_0$  表示 PU 不存在;  $H_1$  表示 PU 存在;  $n$  是离散信号的时间序列;  $y(n)$  是接收到的信号;  $s(n)$  是通过瑞利衰落信道从 PU 发射的信号;  $w(n)$  是均值为 0、方差为  $\sigma^2$  的高斯白噪声。

SS 的性能通常用检测概率  $P_d$  和虚警概率  $P_f$  这 2 个指标来评估,  $P_d$  和  $P_f$  可以表示为:

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

## 2 基于 RADN 的协作频谱感知模型

为解决 SS 存在的特征提取能力不足、网络结构简单、感知性能低等问题, 构建基于 RADN 的协作频谱感知模型, 如图 1 所示。该模型由 3 个主要部分组成: 数据预处理、模型训练和频谱感知。

### 2.1 数据预处理

假设在本地第  $i$  个感知节点的接收器处接收到的信号为:

$$y(n) = I(n) + jQ(n) \quad (3)$$

其中,  $I(n)$  和  $Q(n)$  分别代表从 SU 处接收到信号的实部与虚部。第  $i$  个本地感知节点的能量向量和能量矩阵如式 (4) 和式 (5) 所示。

$$E_i(n) = \sqrt{|I(n)|^2 + |Q(n)|^2} \quad (4)$$

$$E_i = [E_i(1), \dots, E_i(n)] \quad (5)$$

将获得的能量向量通过数学表达式 (6) 进行归一化后得到  $\bar{E}_i(n)$ , 并将归一化后的能量矩阵切割重构为  $P_{\bar{E}_i}$ , 其表达式如式 (7) 所示。

$$\bar{E}_i(n) = \frac{E_i(n) - E_{\min}}{E_{\max} - E_{\min}} \quad (6)$$

$$P_{\bar{E}_i} = \begin{bmatrix} \left( \begin{array}{ccc} \bar{E}_i(1) & \dots & \bar{E}_i(M) \\ \vdots & \vdots & \vdots \\ \bar{E}_i[(N-1)M+1] & \dots & \bar{E}_i(NM) \end{array} \right) \end{bmatrix} \quad (7)$$

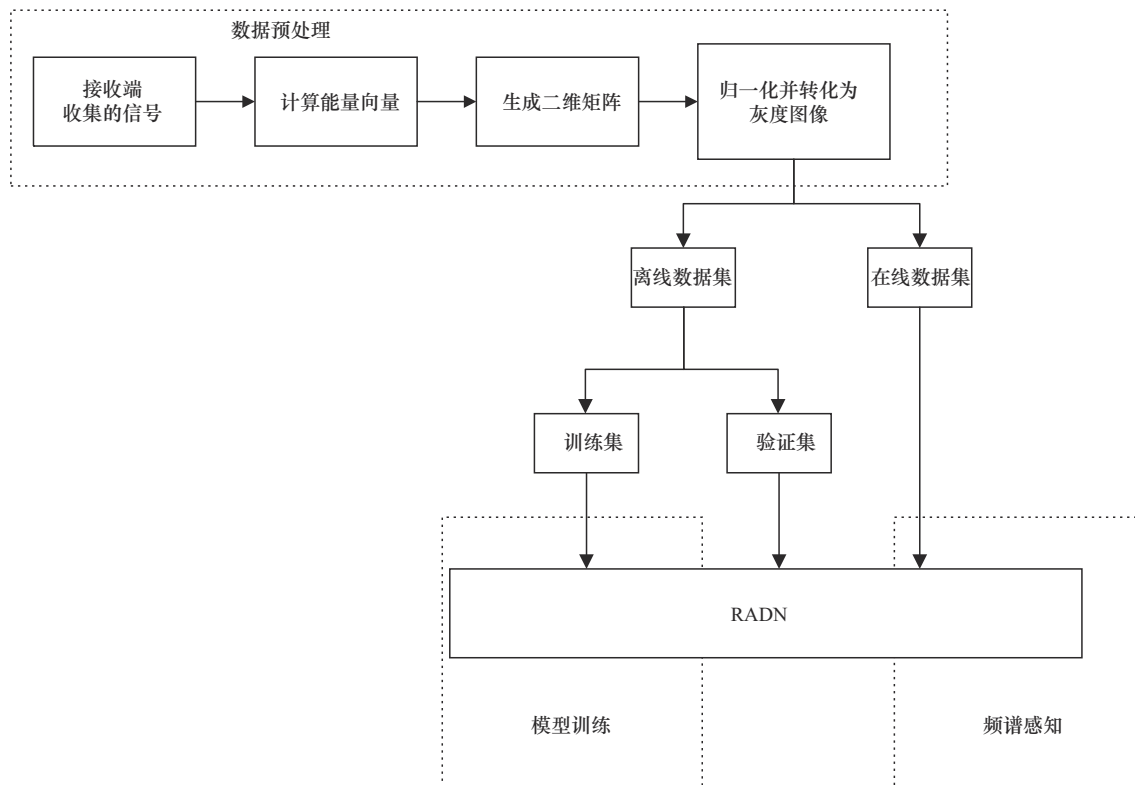



图1 基于 RADN 的协作频谱感知模型

其中,  $M$  和  $N$  分别表示矩阵中的行数和列数,  $E_{\min}$ 、 $E_{\max}$  分别代表  $E_i(n)$  中的最小值与最大值。假设一共有  $k$  个感知节点, 则 FC 处的能量特征矩阵如式 (8) 所示。

$$P_{\bar{E}} = \begin{bmatrix} P_{\bar{E}_1} \\ P_{\bar{E}_2} \\ \vdots \\ P_{\bar{E}_{k-1}} \\ P_{\bar{E}_k} \end{bmatrix} \quad (8)$$

最后将其转化为灰度图像, 如图 2 所示。



(a)  $H_0$  的能量灰度图像 (b)  $H_1$  的能量灰度图像

图 2  $H_0$  和  $H_1$  的能量灰度图像

## 2.2 残差注意力单元

ResNet 最早由 He 等<sup>[16]</sup>引入。为了进一步提高基本特征提取单元的特征提取能力, 提出了 RAU。RAU 包括 4 个组成部分: 改进的残差块 (residual block, RB)、残差核注意力块 (residual kernel attention block, RKAB)、多通道融合块 (multi-channel fusion block, MCFB) 和残差空间注意力块 (residual space attention block, RSAB)。RAU 的结构如图 3 所示。




图 3 RAU 的结构

RAU 的数学表达式为:

$$y_{ru}^i = f_{ru}(x_{ru}^i) + x_{ru}^i \quad (9)$$

其中,  $y_{ru}^i$  代表第  $i$  个 RAU 的输出,  $f_{ru}$  代表特征图

的残差映射,  $y_{ru}^i$  代表第  $i$  个 RAU 的输出。

### 2.2.1 改进的残差块

为了提高特征提取的效率, 在基本的残差块中引入了批量归一化 (batch normalization, BN), 并替换了其中一个卷积核的大小, 增加了在不同感受野下的特征提取。同时使用 LeakyReLU<sup>[17]</sup> 作为激活函数。改进的 RB 的结构如图 4 所示。




图 4 改进的 RB 的结构

改进的 RB 的输入表示为  $F_{ib}$ , 输出表示为  $F_{rb}$ , 则改进的 RB 的数学表达式如下。

$$F_{rb} = W_2(\delta_L B(W_1(F_{ib}))) + F_{ib} \quad (10)$$

其中,  $W_1$  和  $W_2$  分别代表卷积核大小尺寸为  $3 \times 3$  和  $1 \times 1$ ,  $B$  代表 BN 操作,  $\delta_L$  代表 LeakyReLU 激活函数,  $F_{rb}$  是 RKAB 的输入。

### 2.2.2 残差核注意力块

不同大小的卷积核能够提供不同的感受野, 从而提取不同层次的特征。受 Li 等<sup>[18]</sup>的启发, 结合残差连接的优势, 提出了 RKAB, 以融合不同感受野下的特征。假设输入的特征图大小为  $H \times W \times C$ , RKAB 的结构如图 5 所示。首先使用  $3 \times 3$  和  $5 \times 5$  的卷积核提取特征, 可以表示为:

$$F_{3c} = \delta_P W_3(F_{rb}) \quad (11)$$

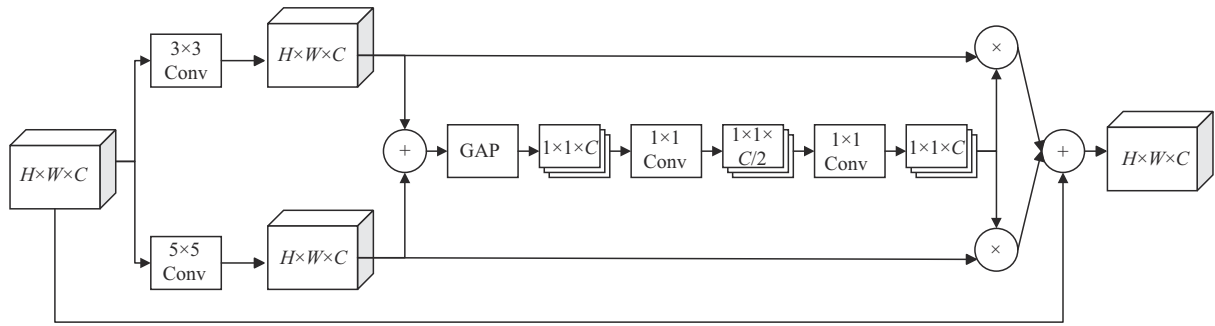


图5 RKAB的结构

$$F_{5c} = \delta_p W_4(F_{rb}) \quad (12)$$

其中,  $W_3$ 、 $W_4$ 分别表示卷积核大小为 $3 \times 3$ 和 $5 \times 5$ 卷积运算,  $\delta_p$ 表示PReLU<sup>[19]</sup>激活函数,  $F_{3c}$ 和 $F_{5c}$ 分别表示2种卷积运算输出的特征图。将这2种特征图进行融合可以表示为:

$$F_{fc} = W_6(W_5(\delta_p(P_{ave}(F_{3c} + F_{5c})))) \quad (13)$$

其中,  $P_{ave}$ 表示全局平均池化(global average pooling, GAP),  $W_5$ 是下采样操作,  $W_6$ 是上采样操作。这2个缩放操作的卷积核大小都是 $1 \times 1$ 。

最后, 将融合后的特征图 $F_{fc}$ 分别乘以 $F_{3c}$ 和 $F_{5c}$ , 并将这2个乘积与RKAB的输入 $F_{rb}$ 相加。输出的结果为 $F_{fr}$ 。这个过程可以表示为:

$$F_{fr} = F_{rb} + F_{fc} \times F_{3c} + F_{fc} \times F_{5c} \quad (14)$$

RKAB利用具有2个不同感受野的卷积, 融合了不同特征信息的特征图。

### 2.2.3 多通道融合块

为了充分提取特征通道中的信息, 设计了MCFB, 其结构如图6所示。通过使用2种不同类型的全局池化, 处理同一特征图中不同频率的空间信息。这些池化操作的输出可以表示为:

$$F_{ave} = P_{ave}(F_{fr}) \quad (15)$$

$$F_{max} = P_{max}(F_{fr}) \quad (16)$$

其中,  $P_{ave}$ 和 $P_{max}$ 分别表示全局平均池化和全局最大池化(global max pooling, GMP)。  $F_{ave}$ 表示GAP输出,  $F_{max}$ 表示GMP输出。这2种池化操作的结果用于生成2种不同的空间特征。然后进行下采样和上采样提取特征, 该过程可以表示为:

$$F_{ac} = W_8(\delta_R(W_7(F_{ave}))) \quad (17)$$

$$F_{mc} = W_8(\delta_R(W_7(F_{max}))) \quad (18)$$

其中,  $W_7$ 是下采样操作, 其卷积核大小为 $1 \times 1$ ;  $\delta_R$ 代表ReLU<sup>[20]</sup>激活函数;  $W_8$ 是一个上采样过程, 其卷积核大小也为 $1 \times 1$ 。

最后, 将这2种特征连接起来, 融合来自不同频率空间的特征。这个过程可以表示为:

$$F_{sp} = P_{cat}(\delta_s(F_{ac}), \delta_s(F_{mc})) \quad (19)$$

其中,  $\delta_s$ 表示Sigmoid激活函数,  $P_{cat}$ 表示级联操作。在通过Sigmoid函数运算之后, 特征映射的2个分支将在通道维度中连接。MCFB的最终特征输出为 $F_{fb}$ , 其数学表达式为:

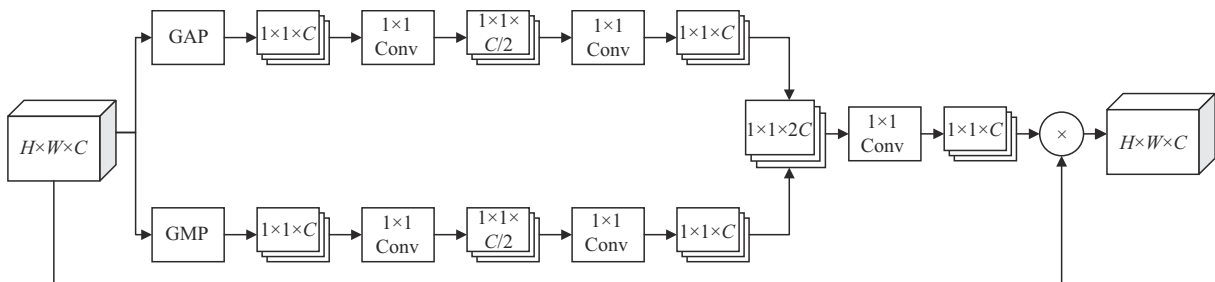


图6 MCFB的结构

$$F_{fb} = W_9(F_{sp}) \times F_{rb} \quad (20)$$

其中,  $W_9$  表示卷积核大小为  $1 \times 1$  卷积运算,  $\times$  表示相乘操作。

MCFB 的目的是关注通道之间的关系, 并通过自适应方式重新校准通道特征。

### 2.2.4 残差空间注意力块

为了整合全局空间信息, 引入了空间注意力机制重校准了空间信息, 提出了 RSAB, 其结构如图 7 所示。

首先, 沿着通道维度应用平均池化和最大池化聚合特征图的通道信息, 生成 2 个特征图, 并将其连接起来以生成有效的特征描述符。然后, 使用通道挤压操作生成空间特征权重图  $F_{cs}$ 。其数学表达式为:

$$F_{cs} = \delta_s(W_{10}(P_{cat}(P_{sgavg}(F_{fb}), P_{sgmax}(F_{fb})))) \quad (21)$$

其中,  $F_{fb}$  为 RSAB 的输入,  $P_{sgave}$  和  $P_{sgmax}$  分别代表通道维度的全局平均池化和全局最大池化,  $P_{cat}$  表示级联操作,  $\delta_s$  表示 Sigmoid 激活函数,

$W_{10}$  代表通道挤压操作, 其使用卷积核大小为  $7 \times 7$  的卷积操作将通道数减少至 1。

另一个分支被设计为进一步提取特征:

$$F_{cv} = W_{11}(F_{fb}) \quad (22)$$

其中,  $W_{11}$  表示  $3 \times 3$  卷积,  $F_{cv}$  是输出特征图。

然后将  $F_{cs}$  与  $F_{fb}$  相乘实现空间特征的重新矫正。之后, 通过残差连接的方式获得最终特征图  $F_{hf}$ :

$$F_{hf} = F_{cv} + F_{fb} \times F_{cs} \quad (23)$$

### 2.3 密集组

为了进一步提升 RAU 的特征提取能力, 受 Zhang 等<sup>[21]</sup>研究的启发, 提出了密集组 (dense group, DG), 其结构如图 8 所示。通过密集连接, 每个模块的输出都能连接到后续模块, 使特征在整个模块内更高效地传播和组合, 确保网络中各层之间的最大信息流, 促进特征再利用。

DG 的数学表达式为:

$$Y_g = W_{12}(G([x_{ru}^1, y_{ru}^1(x_{ru}^1), y_{ru}^2(x_{ru}^2), y_{ru}^3(x_{ru}^3)])) + x_{ru}^1 \quad (24)$$

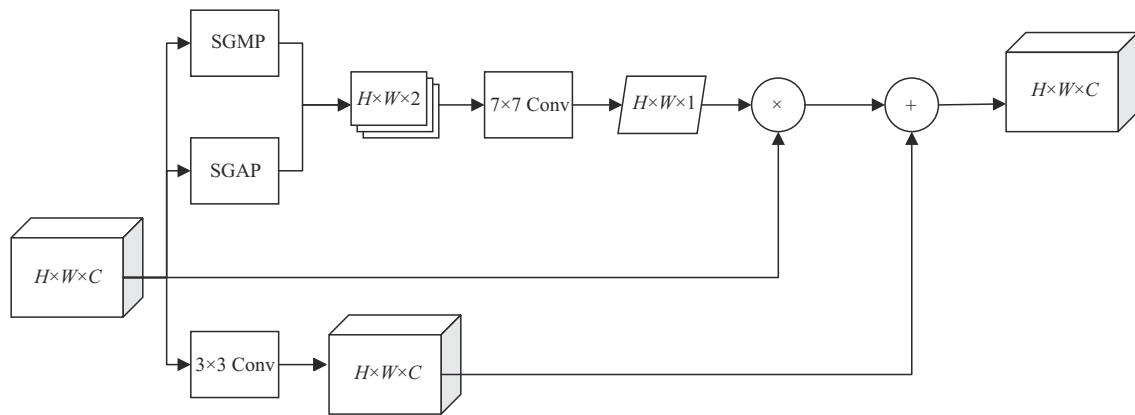


图7 RSAB 的结构




图8 密集组结构



其中,  $x_{ru}^i$  表示输入的特征图,  $y_{ru}^i$  表示第  $i$  个 RAU 的输出特征图,  $[\cdot]$  表示多个输入的级联,  $G(\cdot)$  表示特征图的密集映射,  $Y_g$  表示密集组的输出,  $W_{12}$  表示  $3 \times 3$  的卷积运算。

## 2.4 残差注意力密集网络

RADN 包括 3 个部分: 浅层特征提取模块、由堆叠的 DG 组成的 RID 深层特征提取模块, 以及输出模块。RADN 的结构如图 9 所示。

在 RADN 协作频谱感知算法中, 选择了  $n$  对数据  $\{(S_1, T_1), \dots, (S_n, T_n)\}$  作为训练集,  $m$  对数据作为测试集  $\{(S_{n+1}, T_{n+1}), \dots, (S_{n+m}, T_{n+m})\}$ 。其中,  $S$  表示提取接收到的信号的能量向量, 并归一化后的灰度图像,  $T$  表示接收信号的标签。整个网络的输出映射为:

$$f_{w,b}(S_n) = \hat{T}_n \quad (25)$$

其中,  $w$  和  $b$  代表网络训练后的权重和偏执参数,  $\hat{T}$  代表经过网络后的输出标签。损失函数选择交叉熵损失函数。

交叉熵损失函数的数学表达式为:

$$H = - \sum_{i=1}^2 T_n(i) \log(\hat{T}_n(i)) \quad (26)$$

基于 RADN 的协作频谱检测算法具体操作如下。

(1) 各个 SU 将收集到的信号样本  $X$  发送至 FC, 并经过数据处理转化为能量向量灰度图像  $S$ 。

(2) 训练。使用高斯初始化权重  $\theta$ , 并设置最大迭代次数  $\text{IterMax}$ 。输入训练集样本:  $\{(S_1, T_1), \dots, (S_n, T_n)\}$ , While  $i \leq \text{IterMax} = 200$ 。

通过使用 Adam 优化器对损失函数执行反向传播来更新权重  $\theta$ , 将  $i$  递增 1, 保存损失函数最低的模型权重, Until 最大迭代次数  $\text{IterMax} = 200$ 。

(3) 将训练好的 RADN 模型应用于测试数据集  $\{(S_{n+1}, T_{n+1}), \dots, (S_{n+m}, T_{n+m})\}$ , 并输出分类结果。

(4) 计算  $P_d$  和  $P_f$ 。

## 3 实验分析

仿真实验中使用的硬件为 Intel(R) Core(TM) i7-13650HX, 处理器为 GeForce RTX 4060 GPU。通过 MATLAB 2023a 生成了 BPSK、QPSK、8PSK、64QAM 和 16QAM 5 种主用户信号, 并叠加了加性高斯白噪声。SNR 的范围设为  $-20 \sim 10$  dB, 间隔为 2 dB。针对每种调制类型和每个 SNR 等级, 生成了 1 000 个样本, 采样频率为 200 kHz。实验还考虑了莱斯多径衰落, 以模拟无线信号在多径传播环境中的随机衰减。所得的能量向量灰度图像数据集按照 7:2:1 的比例划分为训练集、验证集和测试集。

### 3.1 采样点的影响

设定 SU 数量为 25, 比较了不同采样点  $N$  下

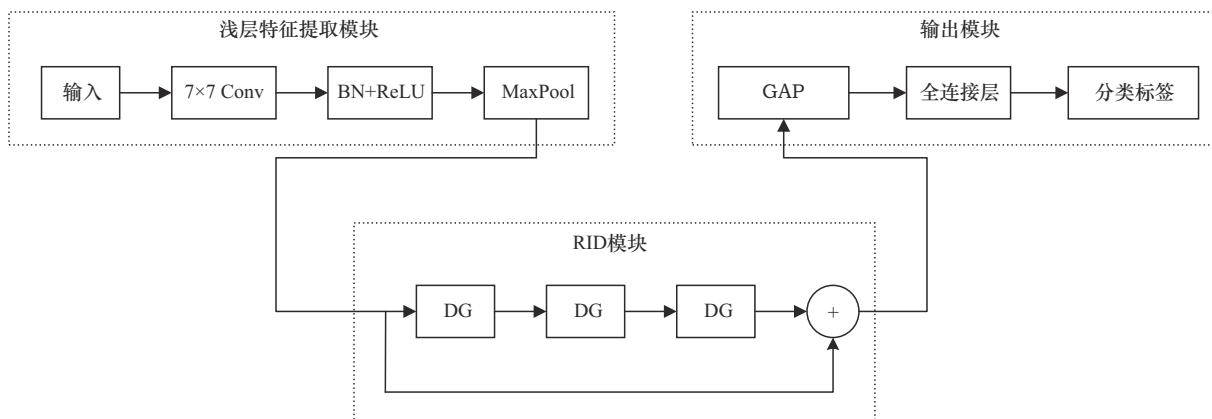


图9 RADN 的结构

的 RADN 频谱感知模型的检测概率随 SNR 的变化, 采样点数的影响如图 10 所示。




图 10 采样点数的影响

实验结果表明, 随着采样点数增加, 检测概率不断提高, 尤其是在低 SNR (-20~-10 dB) 条件下。更多采样点提供了更丰富的信息, 有助于低 SNR 下的信号检测。然而, 增加采样点也带来了更高的计算复杂度。当采样点达到 256 时, 检测概率增长趋缓。综合考虑计算复杂度和检测概率, 选择采样点数  $N=256$ 。

### 3.2 SU 数量的影响

设定采样点数  $N=256$ , 比较了在不同 SU 数量下的 RADN 频谱感知模型的检测概率随 SNR 的变化, SU 数量的影响如图 11 所示。

实验结果表明, RADN 频谱感知算法的  $P_d$  随




图 11 SU 数量的影响

SU 数量增加而上升。随着用户数量增多, 映射到灰度图中的信号特征更丰富, 从而提升了算法性能。更多的 SU 也意味着更高的计算成本。综合考虑性能和计算开销, 选择 SU 数量为 25。

### 3.3 检测概率比较

使用相同数据集, 在  $P_f=0.01$  的条件下, 比较了基于 ED<sup>[6]</sup>、支持向量机 (support vector machine, SVM)、CNN<sup>[22]</sup>、ResNet<sup>[23]</sup>、ResNet-CBAM<sup>[24]</sup>、CNN-Transformer<sup>[1]</sup>和 RADN 的频谱感知算法。评估其在不同 SNR 下的检测概率。检测概率比较如图 12 所示。

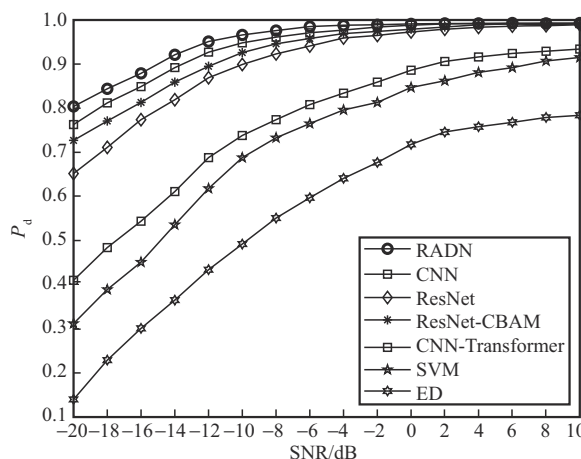


图 12 检测概率比较

实验结果表明, 传统的基于 ED 的频谱感知算法在性能上明显落后于机器学习和深度学习方法。相比于机器学习算法 SVM, 基于 CNN 的频谱感知算法性能有了显著的提升。ResNet 通过引入残差块, 相较 CNN 性能显著提升。在此基础上, 结合 CBAM 注意力机制的 ResNet-CBAM 模型在 -20~0 dB 的检测概率提升了约 6.5%。引入 Transformer 模块的 CNN-Transformer 模型相较于 ResNet-CBAM 在 -20~-10 dB 的检测概率提高了约 2.9%。表现最优的是本文提出的 RADN 模型, 相较 CNN-Transformer 在 -20~-10 dB 的检测概率提高了约 3%。这一结果表明, RADN 在低 SNR 下能够捕捉更复杂的特征信息。



### 3.4 ROC 曲线比较

为了进一步评估RADN的检测性能,在大量频谱感知实验中记录了 $P_d$ 与 $P_f$ ,并通过与基于CNN-Transformer、ResNet-CBAM、ResNet、CNN、SVM和ED的频谱感知方法比较,生成了接收器操作特性(receiver operating characteristic, ROC)曲线。所有实验均在SNR为-14 dB下进行,ROC曲线的比较如图13所示。




图13 ROC曲线的比较

实验结果表明,在固定SNR下,所有模型的 $P_d$ 随 $P_f$ 的增加而提升。在相同 $P_f$ 下,RADN表现出更高的 $P_d$ 。例如,当 $P_f=0.01$ 时,RADN的 $P_d$ 分别比CNN-Transformer、ResNet-CBAM、ResNet、CNN、SVM和ED高出2.9%、6.2%、10.2%、31%、37.9%、55.6%。实验结果验证了RADN在频谱感知任务中的卓越性能。

### 3.5 有效性比较

为了验证RADN算法的有效性,比较了每种算法的离线训练时间和在线感知时间,见表1。

实验结果表明,尽管基于ED的频谱感知算法具备无须训练和感知时间短的优势,但其检测性能相较于深度学习方法有较大差距。传统的机器学习算法SVM相较于深度学习方法有效性较差。所提出的RADN算法虽然感知时间略高于CNN和ED,但在检测概率方面表现出显著提升。

表1 离线训练时间和在线感知时间的比较

算法	离线训练时间/s	在线感知时间/s
ED	—	2.88
SVM	35.11	4.13
CNN	28.53	3.32
ResNet	31.58	3.66
ResNet-CBAM	33.39	3.91
CNN-Transformer	34.41	3.98
RADN	30.77	3.43

相比ED,RADN所需的训练过程仅需训练一次,且额外的感知时间仍在可接受范围内。此外,RADN在有效性和检测概率上均优于CNN-Transformer,展现出较高的感知效率,适用于实际应用需求。

### 3.6 不同调制方式对检测性能的影响

为验证不同调制方式对RADN检测性能的影响,还评估了RADN算法在BPSK、QPSK、8PSK、64QAM和16QAM 5种调制方式下的性能,实验结果如图14所示。




图14 不同调制方式对检测性能的影响

实验结果表明,在不同SNR条件下,RADN对5种调制方式的 $P_d$ 基本一致,性能无显著下降,说明RADN能有效处理不同调制方式。仿真结果验证了RADN对调制阶数不敏感,可适用于多种调制信号类型。

## 4 结束语

本文提出了一种基于RADN的协作频谱感知方法。与传统单节点频谱感知不同,协作频谱感知通过融合多个SU的信号特征,更有效地提升了检测性能。所提出的RADN模型通过改进基础残差块,从感受野、通道和空间3个维度引入相应的注意力机制,并结合密集连接和残差连接的优势,形成了强大的深层特征提取结构RID,极大提升了网络的特征提取能力。实验结果表明,相较于传统深度学习方法,RADN在低SNR下检测性能的提升显著,具备较高的检测概率、强鲁棒性,并适用于多种调制方式,应用前景广阔。

## 参考文献:

- [1] 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.
- [2] ARJOUNE Y, KAABOUCH N. A comprehensive survey on spectrum sensing in cognitive radio networks: recent advances, new challenges, and future research directions[J]. Sensors, 2019, 19(1): 126.
- [3] ZHANG Y X, LUO Z Q. A review of research on spectrum sensing based on deep learning[J]. Electronics, 2023, 12(21): 4514.
- [4] 彭艺,朱楨以,魏翔,等.基于能量检测与Sevcik分形维数的协作频谱感知算法[J].电波科学学报,2022,37(6):1065-1072.  
PENG Y, ZHU Z Y, WEI X, et al. Cooperative spectrum sensing algorithm based on improved energy detection and Sevcik fractal dimension[J]. Chinese Journal of Radio Science, 2022, 37(6): 1065-1072.
- [5] 陈月,张希,艾文宝.基于残差神经网络的频谱感知算法[J].现代电子技术,2022,45(7):1-5.  
CHEN Y, ZHANG X, AI W B. Spectrum sensing algorithm based on residual neural network[J]. Modern Electronics Technique, 2022, 45(7): 1-5.
- [6] ZENG Y H, LIANG Y C, ZHANG R. Blindly combined energy detection for spectrum sensing in cognitive radio[J]. IEEE Signal Processing Letters, 2008, 15: 649-652.
- [7] COHEN D, ELDAR Y C. Compressed cyclostationary detection for cognitive radio[C]//Proceedings of the 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE Press, 2017: 3509-3513.
- [8] BRITO A, SEBASTIÃO P, VELEZ F J. Hybrid matched filter detection spectrum sensing[J]. IEEE Access, 2021, 9: 165504-165516.
- [9] LI Y X, WANG F R, FAN G, et al. A fast estimation algorithm for parameters of multiple frequency-hopping signals based on compressed spectrum sensing and maximum likelihood[J]. Electronics, 2023, 12(8): 1808.
- [10] JANU D, SINGH K, KUMAR S. Machine learning for cooperative spectrum sensing and sharing: a survey[J]. Transactions on Emerging Telecommunications Technologies, 2022, 33(1): e4352.
- [11] KUMAR A, GAUR N, CHAKRAVARTY S, et al. Analysis of spectrum sensing using deep learning algorithms: CNNs and RNNs[J]. Ain Shams Engineering Journal, 2024, 15(3): 102505.
- [12] 鲁华超,赵知劲,尚俊娜,等.利用卷积神经网络和协方差的协作频谱感知算法[J].信号处理,2019,35(10):1700-1707.  
LU H C, ZHAO Z J, SHANG J N, et al. Cooperative spectrum sensing algorithm using convolutional neural networks and covariance[J]. Journal of Signal Processing, 2019, 35(10): 1700-1707.
- [13] CHEN Z B, XU Y Q, WANG H B, et al. Deep STFT-CNN for spectrum sensing in cognitive radio[J]. IEEE Communications Letters, 2021, 25(3): 864-868.
- [14] ZHEN P, ZHANG B N, CHEN Z B, et al. Spectrum sensing method based on wavelet transform and residual network[J]. IEEE Wireless Communications Letters, 2022, 11(12): 2517-2521.
- [15] TAN Y H, JING X J. Cooperative spectrum sensing based on convolutional neural networks[J]. Applied Sciences, 2021, 11(10): 4440.
- [16] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2016: 770-778.
- [17] MAAS A L. HANNUN A Y, NG AY. Rectifier nonlinearities improve neural network acoustic models[C]// Proceedings of the 30th International Conference on Machine Learning. Atlanta: JMLR W&CP, 2013: 16-21.
- [18] LI X, WANG W H, HU X L, et al. Selective kernel networks[C]// Proceedings of the 2019 IEEE/CVF Conference on Computer



- Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2019: 510-519.
- [19] HE K M, ZHANG X Y, REN S Q, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification[C]//Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2015: 1026-1034.
- [20] NAIR V, HINTON G E. Rectified linear units improve restricted Boltzmann machines[C]//Proceedings of the 27th International Conference on International Conference on Machine Learning. New York: ACM, 2010: 807-814.
- [21] ZHANG Y L, LI K P, LI K, et al. Image super-resolution using very deep residual channel attention networks[C]// Computer Vision - ECCV 2018. Cham: Springer International Publishing, 2018: 294-310.
- [22] 张雷霆. 基于深度学习的单节点频谱感知算法[J]. 通信技术, 2021,54(10): 2371-2376.  
ZHANG L T. Single node spectrum sensing algorithm based on deep learning[J]. Communications Technology, 2021, 54(10): 2371-2376.
- [23] 罗聪, 鲁进, 钱琼. 基于小波变换和残差神经网络的全盲频谱感知方法[J]. 电讯技术, 2023,63(6): 775-780.  
LUO C, LU J, QIAN Q. A full-blind spectrum sensing approach based on wavelet transformation and residual neural network[J]. Telecommunication Engineering, 2023,63(6): 775-780.
- [24] 王安义, 孟琦峰, 王明博. 基于残差神经网络和注意力机制的频谱感知方法[J]. 无线电工程, 2024, 54(1): 24-31.

WANG A Y, MENG Q F, WANG M B. Spectrum sensing method based on residual neural network and attention mechanism[J]. Radio Engineering, 2024, 54(1): 24-31.


#### [作者简介]



王安义 (1968- ), 男, 博士, 西安科技大学通信与信息工程学院教授, 主要研究方向为无线通信、深度学习, 以及矿山信息化技术等。



朱涛 (2001- ), 男, 西安科技大学通信与信息工程学院硕士生, 主要研究方向为认知无线电、频谱感知、深度学习。



龚健超 (2002- ), 男, 西安科技大学通信与信息工程学院硕士生, 主要研究方向为认知无线电、频谱感知。