

引用格式: 王颖舒, 王斌, 马缤遥, 等. 基于深度学习的分布式异构频谱感知 [J]. 电子科技大学学报, 2025, 54(6): 875-880.  
WANG Y S, WANG B, MA B Y, et al. Deep learning-enabled distributed heterogeneous spectrum sensing[J]. Journal of University of Electronic Science and Technology of China, 2025, 54(6): 875-880.



## 基于深度学习的分布式异构频谱感知

王颖舒<sup>1</sup>, 王斌<sup>2</sup>, 马缤遥<sup>2</sup>, 韦硕<sup>2</sup>, 张娟娟<sup>1</sup>, 李强<sup>2\*</sup>

(1. 贵州电网有限责任公司 贵阳供电局, 贵阳 550004; 2. 电子科技大学 通信抗干扰全国重点实验室, 成都 611731)

**摘要:** 随着移动互联网的快速发展, 移动设备的数量急剧增加, 导致频谱资源日趋紧张。动态频谱分配是缓解频谱资源紧张的有效途径。动态频谱分配依赖于频谱感知, 即探测出未被占用的频段。传统的频谱感知通常只考虑单个感知节点的情景, 监控范围较小。为了监控较大的地理范围, 须考虑多个节点联合感知的架构, 即分布式频谱感知。由于模数转换器硬件精度不同、感知环境的复杂程度不同等因素, 分布式系统中广泛存在着设备间的异构性。为了解决该问题, 提出一种新的分布式频谱感知架构。该架构包含若干个感知节点, 每个节点上部署一个卷积神经网络, 用于鉴别所监控的频谱是否处于被占用状态。该分布式架构要求不同节点的浅层网络共享权重参数, 而深层网络的参数在节点之间是独立的。这一设计的动机源于浅层网络的特征提取受信噪比影响较小, 因而不同节点共享浅层网络的权重可以提高样本利用率。其次, 深层网络参数受信噪比影响较大, 为了提高感知系统对本地信噪比的鲁棒性, 每个节点应仅使用各自的训练样本来训练其深层网络。仿真表明, 该方法能够显著提高异构感知网络的检测准确性。

**关键词:** 卷积神经网络; 分布式感知网络; 异构性; 频谱感知

中图分类号: TN92

文献标志码: A

DOI: 10.12178/1001-0548.2024224

## Deep learning-enabled distributed heterogeneous spectrum sensing

WANG Yingshu<sup>1</sup>, WANG Bin<sup>2</sup>, MA Binyao<sup>2</sup>, WEI Shuo<sup>2</sup>, ZHANG Juanjuan<sup>1</sup>, and LI Qiang<sup>2\*</sup>

(1. Guiyang Power Supply Bureau, Guizhou Power Grid Co., Ltd., Guiyang 550004, China;

2. National Key Laboratory of Wireless Communications, University of Electronic Science and Technology of China, Chengdu 611731, China)

**Abstract:** With the rapid development of mobile internet, the number of mobile devices has sharply increased, leading to a shortage of spectrum resources. Dynamic spectrum allocation is an effective way to alleviate the shortage of spectrum resources, it relies on spectrum sensing, which detects unoccupied frequency bands. Traditional spectrum sensing methods only consider the scenarios of a single sensing node, which can only monitor a limited geographical scope. In order to monitor a large geographical range, it is necessary to consider the joint sensing architecture, namely, distributed spectrum sensing architecture. Due to the varying hardware accuracy and sensing environment, there exists heterogeneity among devices in a distributed system. To address this issue, this paper proposes a new distributed spectrum sensing architecture. The proposed architecture which consists of several sensing nodes, each equipped with a convolutional neural network (CNN) to identify whether the spectrum is occupied. The proposed distributed architecture requires shallow layers of different nodes to share weight parameters, while the parameters of the deep layers remain independent across nodes. The motivation stems from the fact that feature extraction in shallow layers is less affected by signal-to-noise ratio (SNR), thus sharing the weights of shallow layers among different nodes can improve sample efficiency. The parameters of the deep layers are more significantly affected by the SNR. To enhance the robustness of the perceptual system to the local SNR, each node should train its deep layers using only its own training samples. Simulation shows that the proposed method can significantly improve the detection accuracy of heterogeneous sensing networks.

**Key words:** convolutional neural network; distributed sensing network; heterogeneity; spectrum sensing

收稿日期: 2024-08-20

基金项目: 国家级基金项目 (G022023KP01602)

作者简介: 王颖舒, 高级工程师, 主要从事电力系统 ICT 核心关键技术和数字化转型方面的研究。

\*通信作者 E-mail: liqiang@uestc.edu.cn

随着移动终端设备数量的增加, 频谱资源日趋紧张, 因此设计高效的频谱分配方法非常重要。传统的频谱分配采用静态分配, 即仅允许已授权用户 (primary user, PU) 接入频段, 禁止次要用户 (secondary user, SU) 接入授权频谱。然而, 根据统计数据显示, 大部分时间内频谱都处于未被利用状态, 因为已授权用户并非时时刻刻都在接入网络<sup>[1]</sup>。为了提高频谱利用率, 频谱感知应运而生<sup>[2]</sup>。频谱感知的目标是检测出空闲频谱, 同时允许次要用户接入频谱, 从而提高频谱利用率<sup>[1,3]</sup>。

频谱感知的主要挑战是如何在有噪声情况下准确判断频谱是否被占用。从任务的本质属性上来说, 这是一个二分类问题。传统的频谱感知方法如能量检测<sup>[4]</sup>、匹配滤波器<sup>[5]</sup>及循环平稳特征检测<sup>[6]</sup>的表现与噪声方差及 PU 的发射功率息息相关。文献 [7] 利用广义似然比检测, 将检测统计量表示为接收信号的协方差矩阵的最大特征值与迹的比值, 通过比较接收信号的似然比来判断信号是否存在, 在一定程度上缓解了先验信息缺失的问题。然而上述方法都是模型驱动的, 方法的性能很大程度上取决于假设模型是否与实际环境一致。在复杂的射频环境下, 模型失配会严重影响方法性能。

近年来, 随着深度学习的发展, 基于深度学习的频谱感知方案受到了广泛关注, 研究人员已经对深度神经网络 (deep neural network, DNN) 和频谱感知的结合进行了一系列研究。DNN 作为一种数据驱动方法, 可从大量的数据中学习信号的特征<sup>[8]</sup>。文献 [9] 提出将采样信号的协方差矩阵 (covariance matrix, CM) 看作图像作为神经网络的输入, 将频谱感知构造为一个图像二分类问题。在此基础上, 文献 [10-11] 进一步引入长短期记忆 (long short-term memory, LSTM) 网络并提出了 CNN-LSTM 检测器。该网络架构既可以提取输入信号的空域特征, 又引入时域相干性检测, 可以显著提高噪声环境下的二元检测的准确性。文献 [12] 在此基础上进行改进, 将 CNN-BiLSTM 与自注意力机制结合, 增强网络对 BiLSTM 抽取的重要特征的注意力。然而, 基于深度学习的频谱感知算法也面临着挑战。大部分现有的频谱感知框架, 考虑的是单个感知节点的频谱感知问题<sup>[6,13]</sup>。在实际系统中, 单个节点所能监控的范围比较有限。如果要监控较大的区域或范围, 须考虑多个感知节点联合感知的架构, 即分布式感知架构。在一个感知系统中, 由于模数转换器 (analog-to-digital converter, ADC) 硬

件精度不同、感知环境复杂程度不同等因素, 不同的感知节点拥有不同的感知能力。不同节点感知能力的差异主要是因为采样信噪比不同。采样信噪比受多种因素影响, 包括天线、射频前端、ADC 的质量、信号处理算法及周遭电磁环境等。针对频谱感知系统中广泛存在的设备间的异构性, 本文提出一种新的分布式频谱感知架构。所提出的架构包含若干个感知节点, 每个节点上部署一个卷积神经网络用于鉴别所监控频谱是否处于被占用状态。根据神经网络特征提取的分层特性, 即浅层网络通常提取的是信号的粗特征 (raw features), 而深层网络提取的则是信号的精细特征 (fine features)。所提出的分布式架构要求不同节点的浅层网络共享权值参数, 而节点间的深层参数互相独立。这是因为浅层网络的特征提取受信噪比影响较小, 因而不同节点共享浅层网络的权值可以提高样本利用率。而深层网络参数受信噪比影响较大, 每个节点应仅使用各自的训练样本来训练深层网络, 以此提高对本地信噪比的鲁棒性。仿真表明所提出的方法能够显著提高异构感知网络的检测准确性。

## 1 系统模型

### 1.1 信号与信道模型

假设宽带频谱  $B$  被均匀分为  $N_f$  个频段, 每个子频段都可能被 PU 占用。  $j$  个感知节点分布在一定范围内, 每个节点都与中央处理单元 (central processing unit, CPU) 相连, CPU 负责协调神经网络的训练。

假设 PU 和感知节点都只有单天线。第  $j$  个感知节点的采样信号为:

$$\mathbf{y}^j = \sum_{n=1}^{N_f} \hat{\mathbf{y}}_n^j + \mathbf{w}^j \quad j = 1, 2, \dots, J \quad (1)$$

式中,  $\hat{\mathbf{y}}_n^j$  表示第  $j$  个感知节点采集的第  $n$  个子频段的信号;  $\mathbf{w}^j$  表示噪声。每个节点都可以监控全频段。对时域信号进行处理可以得到对应的功率谱密度  $\mathbf{y}_{\text{PSD}}^j \in \mathbb{C}^{1 \times N_\omega N_f}$ , 其中  $N_\omega$  为每个子频段的采样点数,  $N_f$  为子频段个数。将向量  $\mathbf{y}_{\text{PSD}}^j \in \mathbb{C}^{1 \times N_\omega N_f}$  按频段数重新组合为  $N_\omega \times N_f$  大小的矩阵  $\mathbf{Y}_j$ :

$$\mathbf{Y}_j = \left[ \mathbf{y}_{1,\text{PSD}}^j, \mathbf{y}_{2,\text{PSD}}^j, \dots, \mathbf{y}_{N_f,\text{PSD}}^j \right] \quad (2)$$

式中,  $\mathbf{y}_{n,\text{PSD}}^j \in \mathbb{C}^{N_\omega \times 1}$  表示功率谱密度在第  $n$  个子频段的  $N_\omega$  个采样点的幅值向量, 即:

$$\mathbf{y}_{n,\text{PSD}}^j = \begin{cases} h^j \mathbf{x}_n^j + \mathbf{w}_n^j & H_1 \\ \mathbf{w}_n^j & H_0 \end{cases} \quad (3)$$

式中,  $\mathbf{x}_n^j \in \mathbb{C}^{N_\omega \times 1}$  表示 PU 在第  $n$  个子频段上的发射信号的功率谱密度向量;  $h^j$  表示 PU 和第  $j$  个感知节点之间的信道增益。由于信道相干时间长于感知周期, 假设  $h^j$  在感知周期内保持不变。 $H_0$  和  $H_1$  为假设检验的两个状态, 分别表示频段空闲或被 PU 占用。只要有一个子频段被占用, 即认为此宽带频谱为被占用状态, 即  $H_1$  成立; 只有当所有的子频段都处于空闲状态时,  $H_0$  成立。根据式 (3), 输入信号为以下两类其中之一:

$$\begin{cases} \mathbf{y}_{n,\text{PSD}}^j = h^j \mathbf{x}_n^j + \mathbf{w}_n^j & \exists n \in [1, N_f] \\ \mathbf{y}_{n,\text{PSD}}^j = \mathbf{w}_n^j & \forall n \in [1, N_f] \end{cases} \quad (4)$$

## 1.2 基于卷积神经网络的分类

对于每个感知节点, 采用卷积神经网络来判断频谱是否处于被占用状态。卷积神经网络 (convolutional neural network, CNN) 通常由卷积层、池化层、激活函数、全连接层及输出层组成<sup>[14]</sup>。卷积层通常包含若干个滤波器, 用于提取信号特征。滤波器的参数需要由训练得到。卷积层后面接一个池化层, 池化层的作用是特征筛选, 以降低信号特征的维度从而减少需要学习的参数。池化层后面通常接一个非线性激活函数, 其作用是为网络增加非线性, 提升神经网络的表达能力。卷积层/池化层/激活函数通常会被重复多次, 期间伴随降采样操作, 在提升网络表达能力的同时控制参数的过度增长。在网络的结尾处通常会接入一个全连接层, 其作用是将神经网络提取的高维特征向量映射为一个低维向量以避免过拟合。最后, 全连接层后方会接入 Softmax 激活函数, 其作用是将神经网络输出的特征向量映射为一个概率向量, 以方便完成分类任务。Softmax 函数的表达式为:

$$\text{Softmax}(z_i) = e^{z_i} / \sum_{i=1}^K e^{z_i} \quad (5)$$

式中,  $K$  为分类问题的类别数;  $z_i$  为  $K$  维概率向量  $\mathbf{Z}$  的第  $i$  个元素。常见的池化方式包括平均值池化和最大值池化, 本文采用最大值池化, 而激活函数则选择为 ReLU 函数。

频谱感知的核心问题是判断噪声信号中是否包含通信信号, 即 PU 是否在使用频谱资源。本质上, 这构成了一个含噪信号的二分类问题。给定一组训练数据集, 记为  $\mathbf{D}$ ,  $\mathbf{D}$  中包含  $N$  个功率谱密度

数据  $\mathbf{Y}_n^j \in \mathbb{C}^{N_\omega \times N_f}$  和相应标签  $\mathbf{Z}_n^j = [z_{n1}, z_{n2}]$ , 其中  $z_{nk} \in \{0, 1\}$ ,  $k = 1$  或  $2$ 。即  $\mathbf{Z}_n^j \in \{[0, 1], [1, 0]\}$ , 分别对应频谱被占用与空闲状态:

$$\mathbf{D} = \{(\mathbf{Y}_1^j, \mathbf{Z}_1^j), \dots, (\mathbf{Y}_n^j, \mathbf{Z}_n^j), \dots, (\mathbf{Y}_N^j, \mathbf{Z}_N^j)\} \quad (6)$$

对于第  $j$  个感知节点上的 CNN 网络, 输入  $\mathbf{Y}_n^j$  会得到二维向量输出。通过 Softmax 函数归一化为概率向量, 即  $[f_0(\mathbf{Y}_n^j, \mathbf{W}^j), f_1(\mathbf{Y}_n^j, \mathbf{W}^j)]$ 。若  $f_0(\mathbf{Y}_n^j, \mathbf{W}^j) \leq f_1(\mathbf{Y}_n^j, \mathbf{W}^j)$ , 认为频带处于被占用状态, 其中  $\mathbf{W}^j$  表示神经网络的参数张量; 反之, 则认为频谱处于未被占用状态。基于此, CNN 的损失函数采用交叉熵函数, 其表达式为:

$$l_n(\hat{z}_{nk}) = - \sum_{k=1}^2 z_{nk} \log_2(\hat{z}_{nk}) \quad (7)$$

式中,  $z_{nk}$  为第  $n$  个样本的对应于第  $k$  类的标签;  $\hat{z}_{nk}$  为第  $n$  个样本经过神经网络后输出的样本属于第  $k$  类的概率值。

## 2 分布式多任务频谱感知网络结构

### 2.1 分布式多任务网络结构

由于硬件设备的差异以及周遭电磁环境的不同, 分布式网络中每个感知节点的信噪比通常也不同。如果所有节点共享同一个 CNN 网络, 则判决准确率难以得到保证。为了解决分布式网络中的设备异构性问题, 本文提出部分权值共享的分布式深度学习架构。首先, 假设每个感知节点拥有各自的 CNN 网络, 所有感知节点的神经网络共享浅层网络参数。与此同时, 每个节点的深层网络参数互相独立。这是因为根据神经网络特征提取的分层特性, 浅层网络主要提取信号的粗特征, 提取的特征受信噪比影响较小, 而深层网络提取的则是信号的精细特征, 受信噪比影响较大。不同感知节点间共享浅层网络的权值, 可以提高样本利用率。而受信噪比影响较大的深层网络参数仅采用各自样本训练网络权重, 以提高对本地信噪比的鲁棒性。此外, 对于动态的认知无线电系统, 当有新感知节点想要接入分布式网络时, 可以直接获得浅层网络的共享权值, 仅需要额外对深层网络参数进行训练即可, 极大地降低了训练开销并提升了网络接入的灵活性。所提出的分布式感知架构可以表述为图 1。

每个感知节点的 CNN 的具体架构由图 2 给出。所设计的 CNN 网络包含 3 个卷积层, 后接 1 个全连接输出层。共享层的选择主要基于经验性

判断,并没有严格的理论规定。通常在多层网络情况下,共享前 2~3 层的效果会较好。由于在本文涉及的架构中的卷积层总共只有 3 层,因此共享第 1 层就能够满足需求。所有感知节点的 CNN 网络共享第 1 个卷积层。滤波器的数量和卷积核大小通常决定了模型对特征提取的能力,在实验过程中调整了不同数量的滤波器以及卷积核尺寸,选择了在性能与复杂度之间取得最佳平衡的配置,即 10 个滤波器和  $3 \times 3$  的卷积核尺寸。第 2 个和第 3 个卷积层的结构设计第 1 个卷积层类似。最后 2 个卷积层之间有 1 个  $2 \times 2$  池化层。每个卷积层尾部采用 ReLU 激活函数。全连接层后接 Softmax 激活函数。

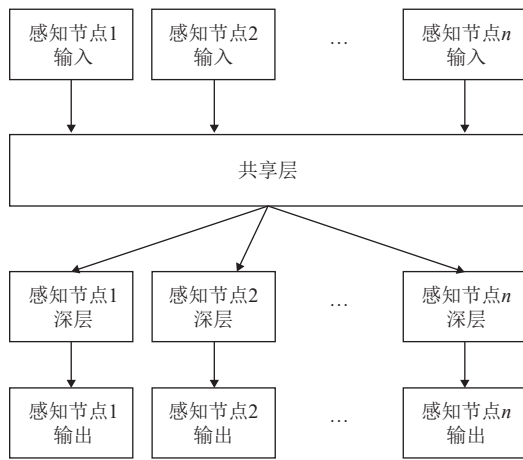


图 1 分布式多任务结构示意图

输入:

采样信号 PSD 数据 (维度:  $N_o \times N_f \times 1$ )

共享层	输出维度
卷积层 1	$(N_o - 2) \times (N_f - 2) \times 10$
ReLU	$(N_o - 2) \times (N_f - 2) \times 10$
深层	输出维度
卷积层 2	$(N_o - 4) \times (N_f - 4) \times 2$
池化层	$\frac{(N_o - 4)}{2} \times \frac{(N_f - 4)}{2} \times 2$
ReLU	$\frac{(N_o - 4)}{2} \times \frac{(N_f - 4)}{2} \times 2$
卷积层 3	$(\frac{(N_o - 4)}{2} - 2) \times (\frac{(N_f - 4)}{2} - 2) \times 2$
ReLU	$(\frac{(N_o - 4)}{2} - 2) \times (\frac{(N_f - 4)}{2} - 2) \times 2$
全连接层	$2 \times 1$
Softmax	$2 \times 1$

输出:

分类向量 (维度:  $2 \times 1$ )

图 2 每个感知节点的 CNN 网络模型及参数

## 2.2 分布式训练过程

训练神经网络即最小化总的损失函数。所提出的训练算法总结为算法 1,在每次迭代开始,每个

感知节点分别采样一部分训练样本,并通过随机梯度下降 (stochastic gradient descent, SGD) 更新参数。得到更新的参数后,每个节点将共享的部分参数上传至 CPU。CPU 求平均后再将所得到的均值向量发送回每个感知节点。以上过程重复若干次迭代直到达到收敛准则。第  $j$  个感知节点处每批次训练取出的  $m$  个 (batch-size) 样本为  $\mathbf{Y}^j = \{\mathbf{Y}_1^j, \mathbf{Y}_2^j, \dots, \mathbf{Y}_m^j\}$ , 其中第  $m'$  个样本  $\mathbf{Y}_{m'}^j$  对应的损失函数为:

$$l_{m'}^j(\mathbf{W}^j; \mathbf{Y}_{m'}^j) = - \sum_{k=1}^2 z_{m'k} \log_2(f_k(\mathbf{Y}_{m'}^j, \mathbf{W}^j)) \quad (8)$$

式中,  $z_{m'k}$  为第  $m'$  个样本的对应于第  $k$  类的标签;  $f_k(\mathbf{Y}_{m'}^j, \mathbf{W}^j) \in \{0, 1\}$  为第  $m'$  个样本经过 CNN 以后输出的概率值 ( $k=1$  或  $2$ );  $\mathbf{W}^j$  为第  $j$  个感知节点处的 CNN 网络参数张量。对于第  $j$  个节点,给定随机选择的  $m$  个样本,根据式 (8) 可以计算出这  $m$  个样本的损失函数,反向传播计算出这  $m$  个样本关于参数的梯度  $\partial l_{m'}^j(\mathbf{Y}_{m'}^j, \mathbf{W}^j) / \partial \mathbf{W}^j$ ,  $m' = 1, 2, \dots, m$ , 则 SGD 第  $t$  次迭代的更新公式为:

$$\mathbf{W}^j(t) = \mathbf{W}^j(t-1) - \eta \left( \frac{1}{m} \sum_{m'=1}^m \frac{\partial l_{m'}^j(\mathbf{Y}_{m'}^j, \mathbf{W}^j)}{\partial \mathbf{W}^j} \right) \quad (9)$$

式中,  $t$  表示第  $t$  次迭代;  $\eta$  为梯度下降的步长参数。由于假设  $\mathbf{W}_1^j$ , 即第 1 个卷积层的参数是共享的,每个感知节点需要将各自的  $\mathbf{W}_1^j(t)$  上传至 CPU, CPU 对  $\mathbf{W}_1^j(t)$  求平均即得到:

$$\overline{\mathbf{W}}_1(t) = \frac{1}{J} \sum_{j=1}^J \mathbf{W}_1^j(t) \quad (10)$$

在每次迭代的结尾, CPU 需要将  $\overline{\mathbf{W}}_1(t)$  发送给每个感知节点,每个感知节点令  $\mathbf{W}_1^j = \overline{\mathbf{W}}_1(t)$  并进入下一次迭代。与此同时,各节点的深层网络参数是独立更新的。每个节点完成一批次训练即为一次迭代,也就是说每个节点使用一个批次的样本训练后,即将其更新的参数上传至 CPU。

算法 1 DSS-PCNN (distributed spectrum sensing with partially-shared CNNs)

随机初始化各节点的 CNN 参数  $\mathbf{W}^j(0)$ ,  $j = 1, 2, \dots, J$ ; 最大迭代次数设为  $T$

for each iteration do

for each node do

根据式 (9) 计算  $\mathbf{W}^j(t)$ ;

节点将  $\mathbf{W}_1^j(t)$  发送给 CPU;

end for

CPU 计算  $\overline{w_1(t)} = \frac{1}{J} \sum_{j=1}^J w_1^j(t)$  并将其广播给

各节点;

end for

### 3 数值仿真

#### 3.1 仿真设置

将带宽  $B$  为 10 MHz 的频谱分为  $N_f = 20$  个子频段, 每个子频段的 PSD 向量长度为  $N_\omega = 64$ , 频点为均匀选取。  $N_f$  个子频段中随机令  $a \in [0, 20]$  个子频段处于占用状态。主用户 PU 的发射功率设定为 20~23 dBm/Hz 之间。根据设定, 只要有一个子频段被占用, 即认为此宽带频谱被占用。感知节点  $J$  的个数设置为 3, 采样信噪比 (SNR) 分别为 -5 dB、-2 dB 和 5 dB, 每个节点有 64 000 个训练样本, 有信号和无信号样本各占一半。图 3 为空闲/占用状态下的采样信号示例。训练时, 每个节点每批次随机采样的样本数  $m = 64$ , 即 batch size = 64。

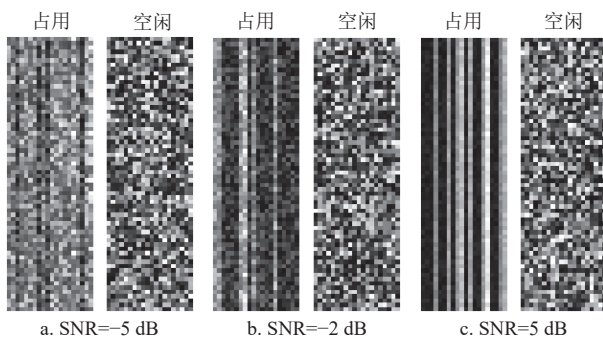


图 3 空闲/占用状态下的采样信号示例

#### 3.2 仿真实施及结果分析

对比算法选取基于独立 CNN 的多节点频谱感知方法 (multi-node spectrum sensing based on independent CNNs, MSS-iCNN), 也即每个感知节点仅使用各自的训练集独立训练 CNN 网络, CNN 参数不共享。为比较两种频谱感知方案的性能, 选取每个节点每轮次 (epoch: 使用训练集对网络进行一次完整训练) 训练及测试的准确率作为指标。

3 个节点处训练集的信噪比分别为 5 dB、-2 dB 以及 -5 dB。图 4 和图 5 分别展示了两种方法在训练集和测试集的准确率。根据图 5, 在采样信噪比 (SNR) 为 5 dB、-2 dB 以及 -5 dB 时, 单节点在测试集的准确率, 分别为 100%、95.98%、95.61%。对比 DSS-PCNN 与 MSS-iCNN, 在信噪比为 -2 dB 以及 -5 dB 时, DSS-PCNN 的准确率比 MSS-iCNN 高了 4.02% 和 4.39%, 经过 130 个训练轮次, 3 个节点准确率几乎都达到 100%。

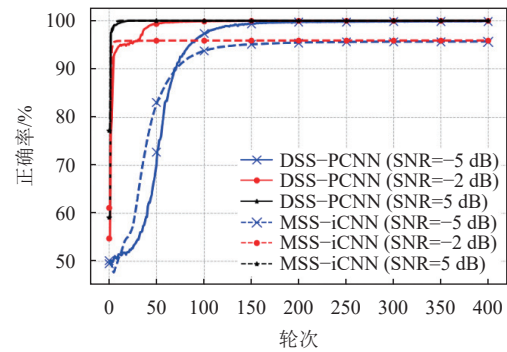


图 4 训练集准确率




图 5 测试集准确率

单节点训练仅提取本地数据集信息, 各节点的训练过程是相互独立的。当信噪比低时, 信号淹没在噪声中, 训练的准确率难以得到保证。采用提出的分布式架构, 即浅层网络的特征提取受信噪比影响较小, 不同节点共享浅层网络的权值提高了样本利用率。同时, 各个感知节点仅使用各自的训练样本来训练深层网络参数, 使得 CNN 能更好地适配本地信噪比。因此, 在相同的训练成本下, 所提出的方法效果更好。

### 4 结束语

本文提出了部分 CNN 权值共享的分布式频谱感知算法 DSS-PCNN。针对分布式频谱感知系统中普遍存在的设备异构性问题, 结合 CNN 神经网络特征提取的分层特性, 要求不同节点的浅层网络共享参数, 而深层网络的参数互相独立, 共享浅层网络的权值可以提高样本利用率。同时, 各节点仅使用本地训练样本来训练深层网络, 以此提高对本地信噪比的鲁棒性。仿真结果显示, 本文方法能显著提高异构网络的检测准确性。

#### 参考文献

- [1] 魏急波, 王杉, 赵海涛. 认知无线网络: 关键技术与研究现状[J]. 通信学报, 2011, 32(11): 147-158.  
WEI J B, WANG S, ZHAO H T. Cognitive wireless

- networks: Key techniques and state of the art[J]. *Journal on Communications*, 2011, 32(11): 147-158.
- [2] MITOLA J. *Cognitive radio: Model-based competence for software radios*[D]. Stockholm: KTH Royal Institute of Technology, 1999.
- [3] 黄庆东, 孙晴, 闫乔乔. 基于 CDS 的分布式协作共识频谱感知方法[J]. *电子科技大学学报*, 2017, 46(5): 660-665.  
HUANG Q D, SUN Q, YAN Q Q. Distributed consensus cooperative spectrum sensing method based on connected-dominating-set[J]. *Journal of University of Electronic Science and Technology of China*, 2017, 46(5): 660-665.
- [4] SONNENSCHNEIN A, FISHMAN P M. Radiometric detection of spread-spectrum signals in noise of uncertain power[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1992, 28(3): 654-660.
- [5] ZHANG X, GAO F, CHAI R, et al. Matched filter based spectrum sensing when primary user has multiple power levels[J]. *China Communications*, 2015, 12(2): 21-31.
- [6] SUTTON P D, NOLAN K E, DOYLE L E. Cyclostationary signatures in practical cognitive radio applications[J]. *IEEE Journal on Selected Areas in Communications*, 2008, 26(1): 13-24.
- [7] WANG P, FANG J, HAN N, et al. Multiantenna-assisted spectrum sensing for cognitive radio[J]. *IEEE Transactions on Vehicular Technology*, 2009, 59(4): 1791-1800.
- [8] 刘丽娜, 王韬, 周一飞, 等. 基于神经网络的配网电气拓扑识别算法[J]. *电子科技大学学报*, 2023, 52(2): 247-253.  
LIU L N, WANG T, ZHOU Y F, et al. Distribution network electrical topology identification algorithm based on neural network[J]. *Journal of University of Electronic Science and Technology of China*, 2023, 52(2): 247-253.
- [9] LIU C, WANG J, LIU X, et al. Deep CM-CNN for spectrum sensing in cognitive radio[J]. *IEEE Journal on Selected Areas in Communications*, 2019, 37(10): 2306-2321.
- [10] XIE J, 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.
- [11] XIE J, 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.
- [12] XING H, QIN H, LUO S, et al. Spectrum sensing in cognitive radio: A deep learning based model[J]. *Transactions on Emerging Telecommunications Technologies*, 2022, 33(1): e4388.
- [13] ZENG Y, LIANG Y C. Maximum-minimum eigenvalue detection for cognitive radio[C]//2007 IEEE 18th International Symposium on Personal, Indoor and Mobile Radio Communications. Athens: IEEE, 2007: 1-5.
- [14] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.

编辑 刘飞阳