

基于 SNR-Means 的分簇协作式频谱感知方法

赵志勇, 潘耀宗, 毛忠阳, 王麓娇, 徐建武

(海军航空大学, 山东 烟台 264001)

摘 要: 以 K-Means 为代表的硬聚类分簇方法对复杂电磁环境适应能力弱, 感知性能易受干扰。针对该问题, 提出基于 SNR-Means 的分簇协作式频谱感知方法。该方法摒弃了空间布局的分簇方式, 从感知环境的电磁频谱特征入手, 以感知节点间的接收信噪比最小误差平方和为目标函数, 将感知节点划分为信噪比等距的多个簇。此外, 综合考虑空间布局、连通性、本地感知性能等多种因素, 合理设置簇头; 以节点的本地频谱感知能力为依据合理分配权重, 加权融合各节点的感知观测数据, 提高了频谱感知性能。所提方法有效降低了干扰对频谱感知结果的影响, 可较好地适用于复杂电磁环境的频谱感知。

关键词: 频谱感知; 分簇; 簇内融合; 协作式感知

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2026055

Clustered cooperative spectrum sensing based on SNR-means

Zhao Zhiyong, Pan Yaozong, Mao Zhongyang, Wang Mengjiao, Xu Jianwu

Naval Aviation University, Yantai 264001, China

Abstract: Hard clustering methods, represented by K-Means, exhibited weak adaptability to complex electromagnetic environments, and their sensing performance was susceptible to the impact of interference. To address this issue, a clustered cooperative spectrum sensing method based on SNR-Means was proposed. This method abandoned the spatial layout-based clustering approach and instead started from the electromagnetic spectrum characteristics of the sensing environment. Using the minimum sum of squared errors of the received signal-to-noise ratio among sensing nodes as the objective function, the sensing nodes were partitioned into multiple clusters with equidistant signal-to-noise ratios. Additionally, factors such as spatial layout, connectivity, and local sensing performance were considered to reasonably designate cluster heads. Based on the local spectrum sensing capability of the nodes, weights were appropriately assigned, and the sensing observation data from each node was weighted and fused, thereby improving spectrum sensing performance. The proposed method significantly reduces the impact of interference on the results of spectrum sensing and can be effectively applied to spectrum sensing in complex electromagnetic environments.

Keywords: spectrum sensing, clustering, intra-cluster fusion, cooperative sensing

0 引言

频谱感知是无线电设备或系统通过实时检测特定频段的使用状态, 识别并利用空闲频谱以实现动态接入的技术过程。通过频谱感知, 可在不

干扰授权用户的前提下, 动态、高效地利用闲置频谱资源, 从而提升整体频谱利用率, 是解决频谱稀缺性与利用率低下矛盾的关键, 是实现智能通信和自主决策的重要基础^[1-3]。相对于单节点频

收稿日期: 2025-12-29; 修回日期: 2026-02-21

通信作者: 赵志勇, mailzzy@126.com

基金项目: 山东省自然科学基金资助项目(No.ZR202204300003)

Foundation Item: The National Natural Science Foundation of Shandong Province (No.ZR202204300003)

谱感知,协作式频谱感知具有覆盖范围广、鲁棒性强、可靠性高的优势,可有效避免隐蔽终端问题。节点分簇、簇内融合和簇间融合是协作式频谱感知的关键环节,对频谱感知性能具有重要影响。

在现有节点分簇方法中,以K-Means为代表的硬聚类分簇方法占据了主导地位^[4-6]。该分簇方法将待感知区域内的节点划分为多个簇,使同一簇内的节点尽可能距离相近,以减少簇内节点间感知观测数据的时延抖动性,解决了Leach分簇方法簇头分布不均匀的问题^[7];为了降低K-Means分簇方法对初始值的敏感问题,文献[8]对K-Means方法进行了改进,提出了K-Means++分簇方法,优化了初始化过程,提高了分簇的收敛速度和稳定性;为了有效降低噪声和离群点对分簇的影响,文献[9]提出了K-Medoids分簇方法,以实际节点替代簇内几何中心点,以节点间距离之和最小化为目标函数进行分簇,提升了对噪声的鲁棒性;为了适应大规模场景感知,文献[10]提出了Mini-Batch K-Means分簇方法,簇内节点迭代不再涉及全部节点,而是随机抽取小批量节点参与,以缩短大规模节点分簇过程。然而,上述分簇算法均是从感知节点的空间布局角度入手进行分簇,并未考虑感知区域内的电磁频谱分布特征;当感知节点部署在复杂电磁环境时,尤其是当待感知区域内存在干扰时,该类方法呈现出了较明显的弊端和应用局限性。复杂电磁环境中的干扰辐射通常具有方向性、干扰强度具有波动性,虽然簇内各节点的空间布局呈现一致性,但各节点间由干扰所带来的噪声不确定性影响差异显著,易导致簇内各节点的感知性能有较大起伏,给最终频谱感知结果带来了不稳定因素。因此,研究复杂电磁环境下的节点分簇方法,合理配置簇内感知节点,对于提高频谱感知结果的准确性和可靠性是非常重要的。

簇内各节点将本地感知结果上报至簇头,簇头采用融合准则计算得到本簇的感知结果,然后再上传至融合中心计算最终感知结果。簇内各节点感知数据融合时,通常假定簇内各节点是同质的,采用等增益合并(equal gain combining, EGC)或以信噪比加权的方式,融合计算节点感知结果。文献[11]将簇内节点的感知数据进行等增益合并,不区分节点感知质量的差异,实现简单,复杂度低,但该方法

用于复杂电磁环境感知时,感知性能易受低质量节点的影响。文献[12]基于节点接收信噪比进行权重分配,并利用优化算法寻找最优权重因子,以提高频谱检测概率,但该方法对信噪比估计准确性依赖较大。事实上,簇内节点通常不是同质的,各节点间在元器件老化程度、接收灵敏度、工作可靠性等方面具有显著区别,从而使各节点的本地频谱感知能力具有较大差异,仅以信噪比为依据分配权重是无法表征该差异性的。因此,当簇内节点受到恶意攻击或发生故障时,采用现有融合准则必然会导致簇内融合结果的可靠性和准确性下降,从而影响整体感知性能。

本文针对复杂电磁环境下的协作式频谱感知方法进行研究,重点研究了节点分簇方法、簇头选择方案和簇内节点感知数据融合方法,以提高协作式频谱感知结果的准确性和可靠性。在分簇方法研究方面,摒弃基于空间布局分簇的方式,从感知环境的电磁频谱特征入手提出了SNR-Means的分簇方法,以感知节点间的接收信噪比最小误差平方和为目标函数,将感知节点划分为信噪比等距的多个簇,以提高对复杂电磁环境感知的适应能力。在簇头选择研究方面,从空间位置、一跳范围邻居节点数和节点感知准确度3个维度入手,综合衡量簇内节点的感知性能,通过计算簇头可用度,选择最佳者为簇头。在簇内节点感知数据融合方法研究方面,本文改进了簇内融合准则,基于节点的多个特征参数综合评价其本地频谱感知能力,并以此为依据合理分配权重,加权融合各节点的感知观测数据,以期准确识别电磁环境的真实状态,降低干扰信号对簇内融合结果的影响。

1 协作式频谱感知算法

本节首先简要介绍了协作式频谱感知的拓扑结构模型,分析了协作式频谱感知的基本过程;然后,分析了节点分簇、簇头设置和簇内融合的重要性,并指出了现有方法存在的不足。

1.1 感知模型

协作式频谱感知具有集中式、分布式和中继转发式3种拓扑结构类型。由于集中式协作具有运行速度快且实时性好的特点,面对复杂电磁环境可实现快速感知,因此,本文采用集中式结构,如图1所示。




图1 协作式频谱感知模型集中式结构

实现协作式频谱感知主要包括4个阶段：节点分簇、簇头设置、簇内融合和簇间融合。下面具体说明。

第一阶段：节点分簇。待感知区域内的节点采用分簇算法划分为多个簇，每个簇的感知观测数据上传至簇头，由簇头采用融合算法计算得到本簇内的感知结果，再上传至融合中心。采用分簇方式进行频谱感知，可拓展频谱感知区域范围，并能有效降低对融合中心的处理要求。

第二阶段：簇头设置。从簇内节点中选取某个节点担任簇头，用于完成簇内节点感知观测数据的融合处理。簇头的选择主要考虑簇内节点的拓扑结构、空间位置、传输时延等因素。科学合理地设置簇头，对于提高簇内感知结果的准确性和可靠性具有重要影响。

第三阶段：簇内融合。在划分好的各个簇内，各节点采用能量检测方式，将获得的观测值与预设的门限阈值进行比较，得到本地感知信息。簇头收集本簇内所有成员节点的本地感知信息，按照一定的融合准则（硬判决融合或软判决融合），将这些信息处理成一个代表本簇的频谱感知判决结果，即簇内融合结果，然后将该结果上报至全局的融合中心。选择合理的融合准则，是对抗远近效应、干扰、节点故障等不利因素的有效方式。

第四阶段：簇间融合。融合中心接收各簇头上报的簇内感知结果，采用融合准则计算得到最终的频谱感知结果。

1.2 问题描述

在协作式频谱感知方法中，采用分簇方式可显著降低通信开销和信道拥塞，能够提升感知速度和时效性，且具有较好的扩展性和鲁棒性。然而，现有协作式频谱感知方法在分簇算法、簇头设置和簇内融合方面还存在不足之处。

1) 分簇算法存在的不足。现有的分簇算法通常是从节点的空间布局角度进行分簇，该类方法适

用于静态网络或节点移动速度慢的场景，当感知网络拓扑结构动态变化或节点是快速移动平台时，会导致频繁重新分簇；由于分簇过程需要节点间交换大量的信息（如地理位置、信道信息等），因而带来较大的开销。采用空间布局分簇的方法，簇内结构也无法反映感知环境的电磁频谱特征，因而不适用于复杂电磁环境感知；复杂电磁环境中干扰信号的辐射方向性和强度波动性，使簇内节点间的感知环境差异性显著，导致同簇内节点的检测门限阈值设置复杂度大幅上升，节点间感知观测数据的准确度也有较大起伏，使频谱感知结果难以反映信道的真实状态。

2) 簇头设置存在的不足。簇头是整个簇的核心，簇头的选择及其性能将直接影响整个感知网络的性能和效率。在现有簇头设置方法中，通常是从簇内节点的空间布局角度入手，选择距离簇内几何中心较近或与融合中心较近的节点作为簇头，以使簇内节点间的通信距离最小化，降低节点感知观测数据的传输开销。然而，这种簇头设置方法未考虑动态网络拓扑结构的变化所引入的影响，也未考虑节点间连通率及本地感知性能对感知结果的影响，簇头的设置必然无法适应动态网络频谱感知的需求。簇头选择应综合考虑空间布局、拓扑结构、连通性、本地感知性能等多种因素，才能保障整个网络的感知性能。

3) 簇内融合存在的不足。在协作式频谱感知方法中，通常是假定簇内节点是同质的，各节点的感知观测数据对簇内感知结果的贡献是相同的，采用等增益的方式或以信噪比加权融合处理簇内各节点的数据，得到簇内感知结果。事实上，簇内各节点并非同质的，节点的本地频谱感知能力也具有较大差异。节点的频谱感知能力与节点的接收灵敏度、元器件老化程度、平均故障间隔时间等因素密切相关^[13-14]。因此，簇头采用无差异融合各节点感知观测数据时，必然会导致簇内融合结果的准确性和可靠性下降。

2 SNR-Means 分簇方法

信噪比（signal to noise ratio, SNR）是描述信道环境最重要的指标之一，其对电磁环境中的干扰也具有量化指示能力。因此，若从节点的接收信噪比角度入手，以节点与簇头间的SNR距离为

度量标准,对待感知区域的节点进行分簇,将各节点划分至相应的簇,即以电磁环境特征相近的各节点为同一个簇,那么各簇间的差异即待感知区域的电磁环境的差异。此时,同一簇内的各节点间受干扰或复杂电磁环境所带来的噪声不确定性影响相近,采用能量检测时同一簇内各节点可配置相同的门限阈值,既降低了复杂度,又使各节点间的检测性能及置信度相近,从而提高了簇内感知结果的可靠性。

2.1 分簇算法

假设各感知节点随机分布在待感知区域内,且各节点均能感知自身的位置信息和接收信噪比,并能够将其分发共享至待感知区域内的其他节点。

本文SNR-Means分簇算法,以感知节点间的接收信噪比最小误差平方和为目标函数,将各感知节点划分至相应的簇内。该分簇算法包括以下步骤。

步骤1 初始参数设置。待感知区域内共有 N 个感知节点,表示为 $\{x_1, x_2, \dots, x_i, \dots, x_N\}$,划分为 K 个簇,分别表示为 $\{C_1, C_2, \dots, C_j, \dots, C_K\}$,随机从 N 个感知节点中选择 K 个感知节点,表示为 $\{y_1, y_2, \dots, y_j, \dots, y_K\}$, K 个感知节点的接收信噪比数值分别对应各个簇的初始簇中心的信噪比, K 个簇中心表示为 $\{\theta_1, \theta_2, \dots, \theta_j, \dots, \theta_K\}$ 。

步骤2 分别计算待感知区域内其他 $(N-K)$ 个节点 $\{z_1, z_2, \dots, z_i, \dots, z_{N-K}\}$ 与 K 个簇中心 $\{\theta_1, \theta_2, \dots, \theta_j, \dots, \theta_K\}$ 之间的接收信噪比距离,其中,节点 z_i 与簇中心 θ_j 间的接收信噪比距离 D 表示为

$$D_{\text{SNR},i}(z_i - \theta_j) = |z_{\text{SNR},i} - \theta_{\text{SNR},j}|^2 \quad (1)$$

其中, $z_{\text{SNR},i}$ 表示节点 z_i 的接收信噪比, $\theta_{\text{SNR},j}$ 表示簇中心 θ_j 的接收信噪比。节点 z_i 与哪个簇中心 θ_j 之间的接收信噪比距离最小,则将 z_i 划入该簇中心所对应的簇中,即对于网内的其他节点 z_i ,寻找簇中心 θ_j ,使 $|z_{\text{SNR},i} - \theta_{\text{SNR},j}|^2$ 最小,将 z_i 划分到满足该条件的簇中心所对应的簇。

步骤3 更新簇中心。对于所构建的每一个簇,重新计算该簇的簇中心,新的簇中心即簇内所有节点接收信噪比的几何中心位置,对于每个簇 C_j ,新的簇中心 θ_j^{new} 表示为

$$\theta_j^{\text{new}} = \frac{1}{M_j} \sum_{\mu_i \in C_j} \mu_{\text{SNR},i} \quad (2)$$

其中, μ_i 表示簇 C_j 中的节点, M_j 表示簇 C_j 中的节点个数, $\mu_{\text{SNR},i}$ 表示簇 C_j 中节点 μ_i 的接收信噪比。

步骤4 将新的簇中心 θ_j^{new} 替代原簇中心 θ_j ,重复执行步骤2;若簇内节点发生变化,则重复执行步骤3;直至簇内节点不再发生变化。

步骤5 形成最终的簇内节点分配结果和 K 个簇中心。

SNR-Means分簇算法如算法1所示。

算法1 SNR-Means分簇算法

输入 set of nodes $\{x_1, x_2, \dots, x_i, \dots, x_N\}$; //设置所有感知节点

输出 set of clusters; //输出分簇 $\{C_1, C_2, \dots, C_j, \dots, C_K\}$

1) creat $\{y_1, y_2, \dots, y_j, \dots, y_K\}$ from $\{x_1, x_2, \dots, x_i, \dots, x_N\}$; //随机从 N 个节点中选取 K 个节点

2) creat $\{\theta_1, \theta_2, \dots, \theta_j, \dots, \theta_K\}$, $\theta_j = y_{\text{SNR},j}$; //初始化簇中心, $y_{\text{SNR},j}$ 表示节点 y_j 的接收信噪比

3) repeat:

4) for ($i=1$ to $N-K$) do

5) for ($j=1$ to K) do

6) $D_{\text{SNR},i}(z_i - \theta_j) = |z_{\text{SNR},i} - \theta_{\text{SNR},j}|^2$; //分别计算各节点与 K 个簇中心的信噪比距离

7) end for

8) end for

9) $C_j = \min(D_{\text{SNR},i}(z_i - \theta_j))$; //将节点 z_i 划入信噪比距离最小的簇中心 θ_j 所对应的簇中

10) $\theta_j^{\text{new}} = \frac{1}{M_j} \sum_{\mu_i \in C_j} \mu_{\text{SNR},i}$; //计算新的簇中心

11) $\theta_j = \theta_j^{\text{new}}$; //更新簇中心

12) until $\{C_1, C_2, \dots, C_j, \dots, C_K\}$ 簇内节点不发生变化或达到最大迭代次数

13) 输出 $\{C_1, C_2, \dots, C_j, \dots, C_K\}$

2.2 簇头设置方法

簇头用于接收簇内节点的感知观测数据,按照融合算法计算得到本簇的感知结果,再上传至融合中心。因此,簇头的选择是否合理准确,对于融合中心计算得到的最终频谱感知结果具有重要影响。

在现有簇头设置方法中,通常是基于节点的空间位置特征设置簇头,所设置的簇头位于空间布局的中心位置或与簇内其他节点平均距离最近的位置。该类簇头设置方法的优势在于簇头与其他节点的连通性好,减少了簇内节点与簇头间的感知观测数据传输距离,减少了传输时间。然而,仅从空间位置单一维度选取簇头,难以保证簇内感知结果的准确性和可靠性。这是因为簇内感知结果不仅与节点的空间布局有关,还与感知网络的拓扑结构、感知观测数据的传输时延、节点感知观测数据处理性能等因素有关。因此,除了空间维度外,还应综合考量邻居节点数、节点感知准确性等多维信息。

为了提高簇内感知结果的准确性和可靠性,本文重点从空间位置、一跳范围邻居节点数和节点感知准确度 3 个维度入手,综合衡量簇内节点的性能及其对簇内感知观测数据处理的影响。通过归一化无量纲数据处理,采用多属性加权融合的方式,科学、合理地评价簇内各节点性能,选择最佳节点为簇头。

空间位置主要考量降低簇内节点与簇头间感知观测数据的传输时延;通过获取簇内各节点的空间位置,计算本簇的空间位置中心,分别计算簇内各节点与所述空间位置中心的欧氏距离,欧氏距离最小,最适宜设置为簇头。其中,第 j 个簇中第 i 个节点与其空间位置中心的欧氏距离表示为

$$D_i^j(p_i - \text{cent}_j) = \sqrt{\sum_{m=1}^M |p_{i,m} - \text{cent}_{j,m}|^2} \quad (3)$$

其中, p_i 表示第 j 个簇内的第 i 个节点, cent_j 表示第 j 个簇内的几何中心, $p_{i,m}$ 表示节点 p_i 的第 m 维空间坐标数值, $\text{cent}_{j,m}$ 表示几何中心 cent_j 的第 m 维空间坐标数值, M 表示空间坐标的维数。对空间位置进行归一化处理,得到空间位置因子,表示为

$$\widetilde{D}_i^j = \frac{D_i^j(p_i - \text{cent}_j)}{\sum_{i=1}^L D_i^j(p_i - \text{cent}_j)} \quad (4)$$

其中, L 表示第 j 个簇的节点个数。

一跳范围内节点数主要考量减少簇内节点与簇头之间感知观测数据传输的中继次数,降低能量消耗和传输时延,可通过接收节点的状态广播信息获得其邻居节点数;一跳范围内邻居节点数越多,越适宜设置为簇头。对一跳范围内节点数进行归一化

处理,得到一跳范围内节点数因子,表示为

$$\widetilde{\text{Num}}_i^j = \frac{\text{Num}_i^j}{\sum_{i=1}^L \text{Num}_i^j} \quad (5)$$

其中, Num_i^j 表示第 j 个簇内第 i 个节点的一跳范围内节点数。

节点感知准确度指单个节点独立、正确地检测目标频段状态的能力,它是衡量节点本地感知性能的重要指标;记录上一个感知周期簇内所有感知节点的历史感知结果和簇内融合结果,通过计算其差值并与簇内融合结果比对,得到节点感知准确度;节点感知准确度越高,节点的置信度越高,越适宜设置为簇头。对节点感知准确度进行归一化处理,得到节点感知准确度因子。其中,第 j 个簇中第 i 个节点的归一化节点感知准确度可表示为

$$\widetilde{\text{Acc}}_i^j = 1 - \frac{|\text{res}_i^j - \text{Res}_j|}{\text{Res}_j} \quad (6)$$

其中, Res_j 表示第 j 个簇的融合结果, res_i^j 表示第 j 个簇中第 i 个节点的感知结果。

通过上述分析可知,簇头的选择与空间位置、一跳范围内节点数及节点感知准确度密切相关,影响因素较多,用定量的方法难以直接描述各因素对簇头选择的影响程度,属于典型的不确定问题下多属性决策问题。层次分析法(analytic hierarchy process, AHP)是一种典型的多属性决策方法^[15-18],通过层次化构建和指标间两两比对,将人为的主观判断转换为定量分析,可实现多属性的加权融合综合评价,为本文簇头选择问题提供了一种解决途径。

将簇头选择问题分解为两级评价指标体系,簇头可用度为一级评价指标,空间位置、一跳范围内节点数和节点感知准确度为二级评价指标,簇头可用度与 3 个二级评价指标间满足关系式,即

$$\text{Cd}_i^j = \alpha \cdot \widetilde{\text{Num}}_i^j + \beta \cdot \widetilde{D}_i^j + \gamma \cdot \widetilde{\text{Acc}}_i^j \quad (7)$$

其中, Cd_i^j 表示第 j 个簇中第 i 个节点的簇头可用度, α 、 β 、 γ 分别表示一跳范围内节点数因子、空间位置因子和节点感知准确度因子的归一化权重,且满足 $\alpha + \beta + \gamma = 1$ 。

采用 AHP 法按“1~9”比例标度,对一跳范围内节点数、空间位置和节点感知准确度 3 个二级评价指标进行重要度赋值,构建一致性判别矩阵 $\mathbf{S}_{n \times n}$,

表示为

$$\mathbf{S}_{n \times n} = \begin{bmatrix} s_{11} & s_{12} & \cdots & s_{1j} & \cdots & s_{1n} \\ s_{21} & s_{22} & \cdots & s_{2j} & \cdots & s_{2n} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ s_{i1} & s_{i2} & \cdots & s_{ij} & \cdots & s_{in} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ s_{n1} & s_{n2} & \cdots & s_{nj} & \cdots & s_{nn} \end{bmatrix} \quad (8)$$

其中, s_{ij} 表示二级评价指标 s_i 相对于 s_j 的重要度赋值。对矩阵 $\mathbf{S}_{n \times n}$ 进行矩阵变换, 得到权重向量 \mathbf{V} 为

$$\mathbf{V} = (v_1, v_2, \cdots, v_i, \cdots, v_n)^T \quad (9)$$

其中, v_i 为

$$v_i = \frac{\sum_{j=1}^n s_{ij}}{\sum_{k=1}^n s_{kj}} \quad (10)$$

权重向量 \mathbf{V} 中的各元素即 3 个二级评价指标的权重, 但还不满足各权重之和等于 1 的要求, 需要再进行归一化处理。归一化权重向量 $\mathbf{\Omega}$ 表示为

$$\mathbf{\Omega} = (\omega_1, \omega_2, \cdots, \omega_i, \cdots, \omega_n)^T \quad (11)$$

其中, ω_i 为

$$\omega_i = \frac{v_i}{\sum_{j=1}^n v_j} \quad (12)$$

此时, 归一化权重向量 $\mathbf{\Omega}$ 中的各元素即二级评价指标的归一化权重。在本文中 $n=3$, $\omega_1 \sim \omega_3$ 的值分别对应于 3 个二级评价指标的归一化权重 α 、 β 、 γ 。

本文中所构建的判别矩阵 $\mathbf{S}_{3 \times 3}$ 表示为

$$\mathbf{S}_{3 \times 3} = \begin{bmatrix} 1 & \frac{1}{5} & \frac{1}{3} \\ 5 & 1 & 3 \\ 3 & \frac{1}{3} & 1 \end{bmatrix} \quad (13)$$

其中, $s_1 \sim s_3$ 分别对应于一跳范围内节点数、空间位置和节点感知准确度, 所计算的归一化权重向量为 $\mathbf{\Omega} = [0.106, 0.634, 0.260]^T$, 判别矩阵 $\mathbf{S}_{3 \times 3}$ 的最大特征根为 $\lambda_{\max} = 3.036$, $CR = \frac{CI}{RI} = 0.031 < 0.1$, 满足一致性检验要求。

按所述归一化权重值分别计算簇内各节点的簇头可用度, 通过比较簇内各节点的簇头可用度值, 选取最大值所对应的节点即簇头。

2.3 算法复杂度与开销

算法复杂度通常用乘法运算次数和加法运算次数衡量。

1) 节点分簇

由算法 1 可知, 其加法运算复杂度为 $O(\epsilon(2K-1)(N-K))$, 乘法运算复杂度为 $O(\epsilon K(N-K))$ 。其中, ϵ 表示迭代次数, N 表示节点总数, K 为分簇个数。与传统的 K-Means 算法相比较, 两者具有相同的加法运算复杂度, 但 K-Means 算法的乘法运算复杂度略高于本文算法, 其乘法运算复杂度为 $O(\epsilon K(N-K+1))$ 。

2) 簇头选择

由上节的簇头设置方法可知, 其加法运算复杂度为 $O(KC_{k_i}^2 + 2N - 1)$, 乘法运算复杂度为 $O(2KC_{k_i}^2 + 2N - 1)$, 其中 k_i 为第 i 个簇的簇内节点个数。在传统的 K-Means 算法中, 通常选用靠近几何空间的中心位置节点为簇头, 其加法运算复杂度为 $O(KC_{k_i}^2)$, 乘法运算复杂度为 $O(K(C_{k_i}^2 + 1))$ 。通过对比可知, 本文分簇算法的簇头选择复杂度略高于传统的 K-Means 算法, 但两者的差距不大, 尤其是在网络规模较小时。

当分簇参数为节点数 $N=100$ 、分簇数 $K=10$ 、迭代次数 $\epsilon=5$ 时, 本文分簇算法的复杂度为 9 199 (加法) + 5 599 (乘法), K-Means 分簇算法的复杂度为 9 000 (加法) + 5 010 (乘法), 两者的差距较小。

算法时间开销是指执行算法所需要的运算时间。考虑到乘法运算复杂度远高于加法运算, 因此, 通常以乘法复杂度为度量依据对比分簇算法的开销性能。通过上述分析可知, 本文算法的节点分簇复杂度略低于传统的 K-Means 算法, 但簇头选择复杂度略高于传统的 K-Means 算法。综合来看, 在相同硬件资源条件下, 两者的开销区别不大。

2.4 网络运行机制

测量 SNR 的核心思想是分离或估计有用信号功率、信道噪声功率和人为干扰功率。节点发射机在发送有用信号的同时, 通过周期性的插入收发双方已知的导频信号或训练序列, 接收机可根据该导频信号或已知序列估计有用信号功率; 节点设备空闲时接收机的实测信号功率即信道噪声功率, 由此可计算得到该工作频点的接收信噪比。当感知区域

内被干扰节点设备发射信号时,接收机可通过实测功率得到干扰功率与信道噪声功率之和,再根据节点间的距离变化调整有用信号功率,由此可得到该被干扰频点的信噪比。接收机通过循环接收其他工作频点和测量信号功率,可得到工作频段内所有频点的信噪比。

在频谱感知的初始阶段,感知区域内的各节点将其接收信噪比和位置信息分发共享至融合中心。融合中心收到所有节点的信噪比信息后,根据上述 SNR-Means 分簇算法选取任意 K 个节点,并以 K 个节点的接收信噪比数值分别作为各个簇的初始簇中心的信噪比。各个节点间两两互通,以接收信噪比最小误差平方和为目标函数,各节点分别划入对应的簇中,形成 K 个初始簇;再通过求解簇内所有节点接收信噪比的几何中心位置,以形成新的簇中心。经多次迭代,最终形成稳定的簇。

簇内各节点通过与其他节点两两交互,感知一跳范围内的邻居节点数,记录节点自身位置信息和上一个感知周期的节点频谱感知结果及簇内融合结果,形成链路表状态信息并分发共享至簇内其他节点。各节点根据空间位置因子、一跳范围邻居节点数因子和节点感知准确度因子的计算公式,分别计算上述参数。再基于二级评价指标的归一化权重,各节点分别计算簇头可用度。根据簇头可用度,选取最优者为簇头。

融合中心根据各簇头上报的接收信噪比及目标检测概率和虚警概率,计算各簇的能量检测门限阈值,然后广播至各簇。在各感知周期内,簇内节点根据所述门限阈值进行频谱感知,并将频谱感知观测数据上报至各簇头。各簇头再采用融合算法计算簇内感知结果,然后上报至融合中心。

在网络运行过程中,当遭受到人为干扰时,会导致节点的接收信噪比发生较大变化。融合中心根据各节点上报的接收信噪比,设置簇动态调整阈值。当接收信噪比波动大于该阈值时,融合中心按照 SNR-Means 分簇算法重新启动分簇及簇头设置过程,以达到适应感知环境动态变化的目的。

3 基于证据理论的簇内融合方法

簇内各节点感知观测数据融合方法是否科学,对簇间感知观测数据融合结果的准确性和可靠性

具有重要影响。然而,在现有方法中,通常假设簇内各节点是同质的,各节点的感知观测数据对簇内融合结果具有相同的贡献值,采用等增益的方式或以信噪比为权重对各节点的感知观测数据进行融合。但事实上,簇内各节点并非同质,簇内各节点的本地频谱感知能力具有较大差异,且该差异性与节点的信号接收性能密切相关,包括接收灵敏度、设备健康度、平均故障间隔时间等因素,都会对节点的本地频谱感知能力产生较大影响,使簇内各节点对当前感知区域内的电磁环境观测数据产生较大偏差,采用现有方法融合时必然会导致簇内融合结果的准确性和可靠性下降。因此,在进行簇内感知观测数据融合时,应科学评价各节点的本地频谱感知能力,并以节点的本地频谱感知能力为依据合理分配簇内各节点的融合权重,在融合计算频谱感知结果时,才能提高簇内感知结果的准确性,使其能够准确反映当前簇内环境的真实状态。

通过上述分析可知,节点的本地频谱感知能力与其接收灵敏度、设备健康度、平均故障间隔时间等多个特征参数有关。如何由多个特征参数综合衡量节点的本地频谱感知能力,可看作是一个多源信息融合问题。证据理论是一种典型的多源信息融合处理方法,能够有效处理多个特征参数产生的不确定性问题^[19-22]。本文将证据理论的多源信息融合优势应用于节点的本地频谱感知能力评价中,并以特征参数的可信度为依据,构建簇内各节点的数据融合权重分配策略。

3.1 特征参数分析及归一化处理

节点的本地频谱感知能力与其接收性能密切相关,影响因素主要包括接收灵敏度、设备健康度、平均故障间隔时间等。为了合理评价簇内节点的本地频谱感知能力,应综合考量上述因素对其频谱感知能力的影响。由于影响因素较多,且各影响因素的量纲和大小差异也较大,需要对各类型的影响因素先进行归一化无量纲处理,再采用证据理论综合评价节点的本地频谱感知能力。

节点的接收机灵敏度用以反映节点能够正常接收处理电磁波信号的最低信号能量强度,该参数直接影响了节点的信号感知能力。该参数属于标量型量纲,经归一化处理后节点 i 的接收机灵敏度 ξ_i 可表示为

$$\zeta_i^t = \begin{cases} 1, & \zeta_i^t \leq \bar{\zeta}_i \\ \frac{\zeta_i^{\max} - \zeta_i^t}{\zeta_i^{\max} - \bar{\zeta}_i}, & \bar{\zeta}_i < \zeta_i^t < \zeta_i^{\max} \\ 0, & \zeta_i^t \geq \zeta_i^{\max} \end{cases} \quad (14)$$

其中, ζ_i^{\max} 表示节点 i 的接收机灵敏度额定最大容限值, ζ_i^t 表示 t 时刻接收机灵敏度的状态值, $\bar{\zeta}_i$ 表示节点 i 的接收机灵敏度标称值。

设备健康度通常用工作月数表示, 用以反映感知节点设备工作了多久, 是监测节点健康状态的重要指标, 是一种典型的负指标数据类型; 工作月数越大, 通常其健康度越低, 反之, 健康度越高。经归一化处理后节点 i 的健康度 jk_i 可表示为

$$jk_i = \begin{cases} 1, & jk_i^t \leq 0 \\ \frac{jk_i^{\max} - \rho_i^t}{jk_i^{\max}}, & 0 < jk_i^t \leq jk_i^{\max} \end{cases} \quad (15)$$

其中, jk_i^t 表示节点 i 在 t 时刻的工作月数状态值, jk_i^{\max} 表示节点 i 的额定最大工作月数容限值。

平均故障间隔时间 (mean time between failures, MTBF) 是反映工作可靠性的重要指标, 其定义为相邻两次故障之间的平均工作时间, 通常用小时、天等时间单位表示, 是一种典型的正向指标数据类型; 平均故障间隔时间越大, 意味着节点的可靠性越高, 反之, 可靠性越低。经归一化处理后节点 i 的平均故障间隔时间 gz_i 可表示为

$$gz_i = \begin{cases} 1, & gz_i^t \geq \bar{gz}_i \\ \frac{\bar{gz}_i - gz_i^t}{\bar{gz}_i}, & gz_i^t < \bar{gz}_i \end{cases} \quad (16)$$

其中, gz_i^t 表示节点 i 在 t 时刻的 MTBF 状态值, \bar{gz}_i 表示节点 i 的 MTBF 额定值。

3.2 簇内节点数据融合权重分配策略

本节以节点的接收灵敏度、设备健康度、平均故障间隔时间 3 个特征参数为依据, 采用证据理论评价节点的可信度, 并以此为依据计算节点的数据融合权重, 用以提高簇内数据融合结果的准确性和可靠性。

将归一化处理后的簇内节点特征参数视为识别框架 Θ 下的证据参数集, 分别记为 $\{e_1, e_2, \dots, e_q\}$, 采用专家评分法, 分别对证据参数集中的数值表现和趋势进行综合考量, 给出评分集 $\{e_j(H_1), e_j(H_2), e_j(H_3), e_j(H_4), e_j(H_5)\}$, 其中, $i=1, 2, \dots, n$, 表示第 i 个

专家, $j=1, 2, \dots, q$, 表示第 j 个证据参数, $\{H_1, H_2, H_3, H_4, H_5\}$ 表示识别框架 Θ ; 评分集中的各元素分别与识别框架 Θ 中各评价指标等级一一对应。将 n 位专家的评分进行平均综合, 得到第 j 个证据参数的基本概率赋值函数, 表示为

$$e_j = \{e_j(H_1), e_j(H_2), e_j(H_3), e_j(H_4), e_j(H_5)\} \quad (17)$$

其中, $\sum_{k=1}^5 e_j(H_k) = 1$, $e_j(H_k)$ 表示对应于识别框架 Θ 中各指标等级的概率赋值。

在协作式频谱感知方法中, 由于簇内感知环境、信道干扰、元器件老化、工作时长等因素的影响, 簇内各节点的本地频谱感知能力存在较大差异, 这种差异体现在节点设备的信号接收能力上, 可用接收灵敏度、设备健康度、平均故障间隔时间这些特征参数进行综合衡量。为了更好地度量各节点间特征参数的差异性, 采用欧氏距离表示特征参数间的差异, 其中, 第 i 个节点与第 j 个节点间第 k 个特征参数的差异 $m_{ij}(e_k)$ 表示为

$$m_{ij}(e_k) = \sqrt{\left[m_i(e_k) - \frac{1}{2} \right] \left[m_j(e_k) - \frac{1}{2} \right] \cdot \left[m_i(e_k) - m_j(e_k) \right]^2} \quad (18)$$

其中, $m_i(e_k)$ 和 $m_j(e_k)$ 分别表示第 i 个节点和第 j 个节点第 k 个特征参数的基本概率赋值函数, $k=1, 2, \dots, n$, n 表示节点的特征参数个数, 在本文中, $n=3$ 。

节点特征参数之间的欧氏距离越小, 表明特征参数之间的相似度越大; 反之, 特征参数之间的相似度越小。基于特征参数的欧氏距离, 建立簇内节点间的特征参数相似度矩阵 \mathbf{XS} , 表示为

$$\mathbf{XS} = \begin{bmatrix} 1 & xs_{12} & \cdots & xs_{1j} & \cdots & xs_{1n} \\ xs_{21} & 1 & \cdots & xs_{2j} & \cdots & xs_{2n} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ xs_{i1} & xs_{i2} & \cdots & xs_{ij} & \cdots & xs_{in} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ xs_{n1} & xs_{n2} & \cdots & xs_{nj} & \cdots & 1 \end{bmatrix} \quad (19)$$

其中, xs_{ij} 表示节点特征参数之间的相似度, 表示为

$$xs_{ij} = 1 - m_{ij}(e_k) \quad (20)$$

其中, $i=1, 2, \dots, L$, $j=1, 2, \dots, L$, L 表示簇内节点个数。

基于特征参数的相似度矩阵 \mathbf{XS} , 可求得簇内第 j 个节点第 k 个特征参数的可信度, 表示为

$$\text{Crd}_j(e_k) = \frac{1}{L-1} \sum_{i=1, i \neq j}^L [1 - m_{ij}(e_k)] \quad (21)$$

特征参数的可信度越高,表明该节点的本地频谱感知能力越强,在进行簇内感知数据融合时,应分配较高的权重;反之,特征参数的可信度越低,表明该节点的本地频谱感知能力越弱,应分配较低的权重。因此,以节点特征参数的可信度为依据,可用于计算簇内节点的数据融合权重。采用几何平均法可计算得到簇内第 j 个节点的数据融合权重,表示为

$$\omega_j = \sqrt[n]{\prod_{k=1}^n \text{Cr}d_j(e_k)} \quad (22)$$

经归一化处理,簇内节点的数据融合权重表示为

$$\tilde{\omega}_j = \frac{\omega_j}{\sum_{k=1}^L \omega_k} \quad (23)$$

由此,可得到簇内各节点的数据融合权重,该权重表征了簇内节点的本地频谱感知能力。

进行簇内节点数据融合时,第 i 个簇的簇内融合结果 Da_i 可表示为

$$Da_i = \sum_{j=1}^{M_i} \tilde{\omega}_j^i \cdot da_j^i \quad (24)$$

其中, da_j^i 表示第 i 个簇的第 j 个节点的感知数据, $\tilde{\omega}_j^i$ 表示其所对应的归一化数据融合权重。由于数据融合权重能够准确反映其频谱感知能力,可有效降低干扰信号对簇内融合结果所带来的扰动,从而使融合结果能够准确反映簇内感知环境的真实状态。

4 仿真结果与分析

为了进一步分析本文分簇协作式频谱感知方法的性能,在上述理论分析的基础上,进行了仿真实验,仿真环境参数如表1所示。

表1 仿真参数	
参数	取值
感知区域	100 m×100 m
节点个数/个	75
分簇个数/个	5
干扰类型	梳状谱干扰
干扰样式	宽带干扰
干扰程度	覆盖32%节点
信噪比/dB	-14~6
信干比/dB	-20~-10

为了验证本文SNR-Means分簇方法的性能,对分簇结构进行了仿真,并将其与Leach方法和K-Means方法进行对比,分簇结构对比如图2所示。

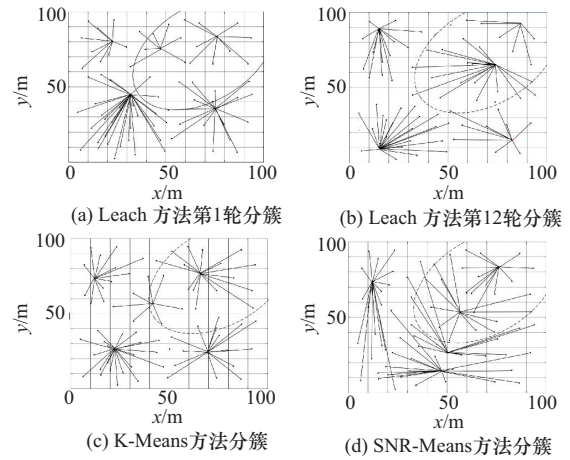


图2 分簇结构对比

图2(a)、图2(b)仿真结果为Leach分簇结构,虚线部分为干扰的覆盖范围。通过分析仿真结果可知,Leach分簇方法在不同轮次中,分簇结构具有较大差异,簇头随机性强且簇内节点数量也不固定;这是由于Leach分簇方法采用概率模型实现分簇,簇头在空间布局上是不均匀的,易造成簇内节点感知观测数据的传输时延长、节点能耗不均,导致分簇效果差。图2(c)仿真结果为K-Means分簇结构,各簇的簇内节点数分别为8、25、16、16、10,节点数差异较大,这是由于该分簇方法的初始簇中心是随机选取的,且仅基于空间布局进行分簇所致。图2(d)仿真结果为SNR-Means分簇结构,各个簇的划分并不是基于空间位置布局,而是基于信噪比分布,且干扰区内的分簇与干扰区外的分簇几乎无交叉节点,这是由于SNR-Means分簇方法是以接收信噪比最小误差平方和为目标函数进行分簇,簇头选择综合考虑了空间位置、邻居节点数、拓扑结构等因素,使分簇达到了较好的效果。

仿真分析了本文簇内融合方法的性能,并与文献[11]的等增益合并方法和文献[12]的信噪比加权融合方法进行对比,不同融合方法的感知性能对比如图3所示。

通过分析图3仿真结果可知,在频谱感知虚警概率相同时,与其他两种簇内融合方法相比,本文融合方法的检测概率明显提升。尤其是在虚警概率为0.1~0.5时,检测概率提高了0.08左右。这主要

是由于本文融合方法充分考虑了簇内节点的接收灵敏度、设备健康度、平均故障间隔时间等多个因素,综合评价簇内节点的频谱感知能力,并以此为依据分配融合权重,有效提高了簇内感知结果的准确性,使其能够准确反映当前簇内环境的真实状态。




图3 不同融合方法的感知性能对比

为了分析噪声干扰对频谱检测性能的影响,本文仿真分析了在虚警概率为0.2时的频谱检测性能,不同信噪比条件下的频谱检测性能如图4所示,其中信噪比的波动范围为-14~6 dB。




图4 不同信噪比条件下的频谱检测性能

通过分析图4仿真结果可知,本文频谱检测性能明显优于现有分簇方法,当信噪比为-8 dB时,本文方法的性能表现最优。本文方法可充分反映感知环境的电磁频谱特征,能够动态适应噪声干扰的影响,从而提升了感知性能;即使在低信噪比条件下,本文方法也具有较高的频谱检测性能。从仿真

结果可以看出,噪声干扰对频谱检测性能具有重要影响,随着通信环境质量的提升,频谱检测性能也随之改善。

本文还仿真分析了频谱检测性能,干扰条件下的感知性能对比如图5所示。在仿真中,干扰为宽带梳状谱干扰,干扰区域如图2虚线范围,30%的节点受到干扰攻击。




图5 干扰条件下的感知性能对比

通过分析图5仿真结果可知,本文方法的频谱检测性能最优,尤其是在虚警概率在0.1~0.4时,相对于文献[7]所提方法,检测概率提高了10%左右。文献[7]所提方法最差,文献[5]和文献[8]所提方法居中。这是由于本文方法在簇头选择时,不仅考虑了节点的空间位置,还综合考虑了邻居节点数和节点感知准确性等因素;在簇内融合时,以节点频谱感知能力为依据进行权重分配,从而提高了对复杂电磁环境的适应能力。

5 结束语

从感知环境的电磁频谱特征入手,以感知节点间的接收信噪比最小误差平方和为目标函数,将感知节点划分为信噪比等距的多个簇,综合考虑空间布局、拓扑结构、连通性、本地感知性能等多种因素,合理设置簇头,可有效提高对复杂电磁环境的适应能力。簇内各节点感知观测数据融合时,基于节点的接收灵敏度、设备健康度、平均故障间隔时间等多个特征参数,综合评价其本地频谱感知能力,并以此为依据设置簇内融合权重,可获得更优异的频谱感知性能。仿真结果表明,本文方法有效提高了对复杂电磁环境的适应能力,大幅降低了干

扰对频谱感知结果的影响,提高了频谱感知的准确性和可靠性,能够准确识别电磁环境的真实状态,为实现智能通信和自主决策提供了技术支持。

参考文献:

- [1] Fang W D, Zhang W X, Chen W, et al. MSCR: multidimensional secure clustered routing scheme in hierarchical wireless sensor networks[J]. *EURASIP Journal on Wireless Communications and Networking*, 2021, 2021: 14.
- [2] 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): 4352-4558.
- [3] Devi V, Monisha M, Meena M, et al. Detection and sensing of cognitive radio spectrum using minimum eigen value and TW distribution method[C]// *AIP Conference Proceedings*. Melville: AIP Publishing LLC, 2022: 20018-20026.
- [4] 梁彦霞, 姜静, 孙长印, 等. 超密集组网下一种基于干扰增量降低的分簇算法[J]. *电子与信息学报*, 2020, 42(2): 495-502.
Liang Y X, Jiang J, Sun C Y, et al. A cluster algorithm based on interference increment reduction in ultra-dense network[J]. *Journal of Electronics & Information Technology*, 2020, 42(2): 495-502.
- [5] 张顶, 张琳. 基于 K-Means 的 WSN 动态信任度双簇头选取算法[J]. *南京邮电大学学报(自然科学版)*, 2020, 40(2): 108-114.
Zhang D, Zhang L. Dual cluster head selection algorithm based on K-Means and dynamic trust degree in WSN[J]. *Journal of Nanjing University of Posts and Telecommunications (Natural Science)*, 2020, 40(2): 108-114.
- [6] 吴春琼, 苗苗. 基于二分 K-Means 的无线传感网络隐含节点同步方法研究[J]. *传感技术学报*, 2025, 38(1): 174-178.
Wu C Q, Miao M. Research on the implicit node synchronization method of wireless sensing network based on bisecting K-means[J]. *Chinese Journal of Sensors and Actuators*, 2025, 38(1): 174-178.
- [7] Sivakumar P, Radhika M. Performance analysis of LEACH-GA over LEACH and LEACH-C in WSN[J]. *Procedia Computer Science*, 2018, 125(1): 248-256.
- [8] Yuchechen A E, Lakkis S G, Caferri A, et al. A cluster approach to cloud cover classification over South America and adjacent oceans using a K-Means/K-Means++ unsupervised algorithm on GOES IR imagery[J]. *Remote Sensing*, 2020, 12(18): 2991.
- [9] Ali Abbas S, Aslam A, Rehman A U, et al. K-means and K-medoids: cluster analysis on birth data collected in city Muzaffarabad, Kashmir[J]. *IEEE Access*, 2020, 8: 151847-151855.
- [10] 胡雅婷, 陈营华, 宝音巴特, 等. 一种增量式 MinMax k-Means 聚类算法[J]. *吉林大学学报(理学版)*, 2021, 59(5): 1205-1211.
Hu Y T, Chen Y H, Baoyin B T, et al. An incremental MinMax k-Means clustering algorithm[J]. *Journal of Jilin University (Science Edition)*, 2021, 59(5): 1205-1211.
- [11] 褚御芝, 郑宝玉, 季薇. 协同频谱感知中的融合策略[J]. *南京邮电大学学报(自然科学版)*, 2010, 30(3): 39-45.
Chu Y Z, Zheng B Y, Ji W. Data fusion schemes based on cooperative spectrum sensing[J]. *Journal of Nanjing University of Posts and Telecommunications (Natural Science)*, 2010, 30(3): 39-45.
- [12] Nguyen-Thanh N, Koo I. An enhanced cooperative spectrum sensing scheme based on evidence theory and reliability source evaluation in cognitive radio context[J]. *IEEE Communications Letters*, 2009, 13(7): 492-494.
- [13] Zhao Z Y, Mao Z Y, Zhang Z L, et al. Collaborative channel perception of UAV data link network based on data fusion[J]. *Electronics*, 2024, 13(18): 3643-3658.
- [14] 秦丹阳, 贾爽, 杨松祥, 等. 基于信任感知的无线传感器网络安全路由机制研究[J]. *通信学报*, 2017, 38(10): 60-70.
Qin D Y, Jia S, Yang S X, et al. Research on trust sensing based secure routing mechanism for wireless sensor network[J]. *Journal on Communications*, 2017, 38(10): 60-70.
- [15] 王珊, 梁敏, 路芳瑞, 等. 一种基于 AHP 的无线传感器网络分簇路由算法[J]. *火力与指挥控制*, 2023, 48(9): 77-81, 91.
Wang S, Liang M, Lu F R, et al. A clustering routing algorithm for wireless sensor networks based on AHP[J]. *Fire Control & Command Control*, 2023, 48(9): 77-81, 91.
- [16] 赵志勇, 毛忠阳, 潘耀宗, 等. 基于 AHP 权重优化的数据链跳频网络信道负载统计算法[J]. *系统工程与电子技术*, 2025, 47(2): 666-672.
Zhao Z Y, Mao Z Y, Pan Y Z, et al. Data link frequency hopping network channel load statistics algorithm based on AHP weight optimization[J]. *Systems Engineering and Electronics*, 2025, 47(2): 666-672.
- [17] 毛忠阳, 张治霖, 刘锡国, 等. 基于动态 AHP 的海上移动节点网络选择算法[J]. *系统工程与电子技术*, 2022, 44(6): 2011-2018.
Mao Z Y, Zhang Z L, Liu X G, et al. Network selection algorithm for maritime mobile nodes based on dynamic AHP[J]. *Systems Engineering and Electronics*, 2022, 44(6): 2011-2018.
- [18] 赵维涛, 尹福平, 胡东超. 基于泰勒展开的二阶层次分析法初探[J]. *计算力学学报*, 2022, 39(5): 655-660.
Zhao W T, Yin F P, Hu D C. Preliminary study of the second order analytic hierarchy process based on Taylor expansion[J]. *Chinese Journal of Computational Mechanics*, 2022, 39(5): 655-660.
- [19] Yao D G, Yuan S G, Lv Z B, et al. An enhanced cooperative spectrum sensing scheme against SSDF attack based on dempster-shafer evidence theory for cognitive wireless sensor networks[J]. *IEEE Access*, 2020, 8: 175881-175890.
- [20] 周莉, 张歆茗, 郭伟震, 等. 基于改进冲突度量的多证据直接融合算法[J]. *电子与信息学报*, 2019, 41(5): 1145-1151.
Zhou L, Zhang X M, Guo W Z, et al. A direct fusion algorithm for multiple pieces of evidence based on improved conflict measure[J]. *Journal of Electronics & Information Technology*, 2019, 41(5): 1145-1151.
- [21] Hao S, Chen Y F, Hu B, et al. A classifier-combined method based on D-S evidence theory for the land cover classification of the Tibetan Plateau[J]. *Environmental Science and Pollution Research*, 2021, 28(13):

16152-16164.

[22] 王程昱, 凌青, 闫文君. 一种基于脉间特征与脉内特征融合的雷达辐射源分类方法[J]. 海军航空大学学报, 2025, 40(2): 278-284.

Wang C Y, Ling Q, Yan W J. A radar emitter classification method based on fusion of inter-pulse features and intra-pulse features[J]. Journal of Naval Aviation University, 2025, 40(2): 278-284.

[作者简介]



赵志勇 (1976-), 男, 山东济南人, 博士, 海军航空大学教授, 主要研究方向为无线通信、数据链网络、信号处理。




潘耀宗 (1984-), 男, 河北衡水人, 博士, 海军航空大学讲师, 主要研究方向为无线通信、数据链网络、人工智能。



毛忠阳 (1979-), 男, 河南新乡人, 博士, 海军航空大学教授、博士生导师, 主要研究方向为无线通信、人工智能、信号处理。



王薨娇 (1998-), 女, 山东烟台人, 海军航空大学助教, 主要研究方向为动态组网与特征提取、无线通信。



徐建武 (1982-), 男, 湖南益阳人, 博士, 海军航空大学副教授, 主要研究方向为无线光通信、信号处理。