

# 一种面向有权重通信网络的关键节点识别方法

刘子彤<sup>1</sup>, 王 威<sup>1</sup>, 丁国如<sup>2</sup>, 吴启晖<sup>1</sup>

(1. 南京航空航天大学电子信息工程学院, 南京 211106; 2. 陆军工程大学通信工程学院, 南京 210007)

**摘要:** 如何在已知网络拓扑的前提下, 快速准确地找到复杂通信网络中的关键节点成为当前的研究热点。本文首先建立了一个有权重网络的关键节点识别系统模型。然后, 提出了基于加权集体影响力的关键节点识别方法。该方法用集体影响力量化节点信息传播能力, 同时结合加权思想, 表征有权重网络节点的关键程度。最后, 分别对5种典型复杂网络模型进行了随机权重和非随机权重的仿真。仿真结果表明所提方法优于原有集体影响力算法的性能, 且算法对球半径的选择不敏感。

**关键词:** 通信网络; 网络拓扑; 关键节点识别; 集体影响力

**中图分类号:** TN92

**文献标志码:** A

## A Key Node Identification Approach for Weighted Communication Networks

LIU Zitong<sup>1</sup>, WANG Wei<sup>1</sup>, DING Guoru<sup>2</sup>, WU Qihui<sup>1</sup>

(1. College of Electronic and Information Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China;  
2. College of Communication Engineering, Army Engineering University, Nanjing 210007, China)

**Abstract:** How to quickly and accurately identify the key nodes in complex communication networks under a known network topology has become a hot spot in recent years. In this paper, we first establish the system model of weighted networks for key node identification. Then, a key node identification method based on weighted collective influence is proposed. In this method, the collective influence is used to quantify the information transmission ability of nodes, and the weighted idea is combined to represent the critical degree of weighted network nodes. Finally, five typical types of complex network models are simulated with random weight and non-random weight, respectively. Simulation results show that the proposed method outperforms the original collective influence algorithm, and the algorithm is not sensitive to the parameter of sphere radius.

**Key words:** communication network; network topology; key node identification; collective influence

## 引 言

随着移动通信和物联网等技术的不断发展, 无线通信网络接入的终端规模日益扩大, 同时由于无线信道的动态性、终端移动性等问题, 使得确定无线网络的关键节点和关键路径成为极具挑战的难题<sup>[1-2]</sup>。如何在已知网络拓扑的前提下, 快速、准确地找到复杂通信网络中的关键节点, 成为近年来人们的研究热点<sup>[3-4]</sup>。一方面, 识别合作方网络中的关键节点, 有利于频谱共享、资源分配和故障排查, 是通

信网络实现智能化管理的关键<sup>[5]</sup>。另一方面,非合作通信网络拓扑识别技术的突破,使得对于非合作通信网络关键节点识别成为可能,有利于后续战场决策的制定,是实现电磁制胜的关键。

目前,关于网络中关键节点普遍认可的定义是:对于一个复杂网络,如果增加某些节点可以使网络的功能得到最大程度的激活,或者删除某些节点可以使网络的功能得到最大程度的削弱,那这些节点就叫关键节点<sup>[6]</sup>。如图1所示,关键节点识别可以解决两类问题:(1)网络拆除问题,其重点在于删除网络中的节点,目标是 minimized 网络中剩余的最大网络组件;(2)网络划分问题,其重点在于选择网络中的节点去划分网络,目标是 minimized 网络中所有组件的链路和。现有的关键节点识别经常可以应用在:(1)破坏复合蛋白质网络的关键肽键<sup>[7]</sup>; (2)逮捕犯罪分子网络中的关键嫌疑人<sup>[8]</sup>; (3)从社交网络中分析识别领域精英<sup>[9]</sup>等。大多数的关键节点识别技术都是面向社交网络而非通信网络的,虽然也有很多研究者尝试将这些方法迁移到通信网络中,但是往往会因为通信网络和社交网络的特征不同而造成性能的差异。例如社交网络大多数建模为无权网络,而在通信网络中,网络流量、传输速率和开销等经常被建模为网络权重,这是社交网络和通信网络的本质区别。

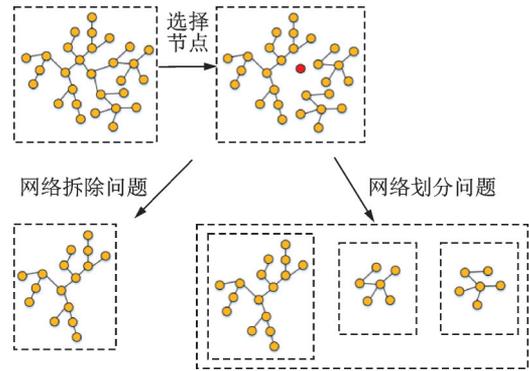


图1 关键节点识别的两类问题

Fig.1 Two kinds of problems of key node identification

本文研究了针对有权重通信网络的关键节点识别问题。首先建立了一个有权重网络的关键节点识别系统模型。然后,提出了一个基于加权集体影响力(Weighted collective influence, WCI)的关键节点识别方法。该方法首先计算每个节点的加权集体影响力,选出影响力最大的节点进行删除,其次,将已经删除过的节点重新插入从而找到最佳的删除策略。最后,针对5种典型的复杂网络模型,分别进行了随机权重和非随机权重的仿真。

## 1 关键节点识别技术研究现状

### 1.1 基于节点中心性的启发式方法

基于节点中心性的方法是最传统的一种方法,节点中心性主要是指度中心性、介数中心性和接近中心性等。文献[10]定义了一个无标度网络上传染病传播的动态模型,利用节点的度中心性为指标发现了流行病阈值的缺失及其相关的临界行为。文献[11]根据点落在其他点之间最短路径上的程度来定义中心性,即介数中心性,该方法去除介数中心性最大的节点,并对剩余节点重新计算介数中心性,在许多相关的网络<sup>[12-14]</sup>中得到了广泛应用。另一种方法是基于接近中心性的关键节点识别方法<sup>[15]</sup>,接近中心性表示节点到其余节点的最短距离之和的倒数,在该方法中先删除最高接近中心性的节点,然后更新其余节点。基于节点中心性可以延伸出一些复杂方法<sup>[16]</sup>。2018年,安徽工业大学的徐翔等<sup>[17]</sup>考虑网络中节点与连边的关联差异,提出基于节点邻接信息熵的网络关键节点识别算法,该算法针对了无权无向、无权有向、加权无向和加权有向4种不同类型的网络。同年,刘彩虹等<sup>[18]</sup>提出了一种邻近H-index的面向社会网络的关键节点识别方法,该方法准确地描述了目标节点的真实传播能力。2019年,文献[19]应用相似性传播(Affinity propagation, AP)聚类来确定聚类中心为相应状态的关键节点。2021年,文献[20]在中心性的基础上使用香农熵测量节点的数量和它们之间的距离,并使用改进的灰狼优化算法解决了关键节点识别问题<sup>[21]</sup>。

不只是社交网络,在交通领域和船舶领域,关键节点识别的应用也非常广泛。国防大学的刘菁

等<sup>[22]</sup>在考虑交通网络节点连通可靠度的基础上,提出了一种新的关键节点识别模型,实验证实了该关键节点识别方法的有效性。东北林业大学的邓红星等<sup>[23]</sup>结合现有公交专用道建设实际情况和道路网节点重要度评估模型,提出了一种基于节点重要度的公交专用道关键节点识别方法。2020年,文献[24]根据船只的互相作用构建复杂网络,用来表征船只行为;同时,在构建关键节点评价体系结合了复杂网络的节点中心性指标;通过节点综合重要程度,对网络中的节点进行节点重要度排序,识别网络中的关键节点。

以上的方法大多数是基于某一种中心性,然而在实际复杂环境下往往需要多种标准一起使用,因此,近年来,基于多属性的关键节点识别方法也成为了大家的研究热点。2015年,文献[25]提出了一种多准则决策算法,用来适应实际的网络结构。2019年华东师范大学的王环等<sup>[26]</sup>为了更准确高效地识别关键节点,提出了扩展K壳和邻居度(Extended K-shell and degree of neighbors, EKSDN)算法,该算法不仅考虑了节点的局部指标,同时还考虑了节点的全局指标加权核值,仿真实验证明了算法的有效性。2019年中南大学的王斌等<sup>[27]</sup>提出节点节点信任度概念,并将其引入到PageRank算法中,构建了一种关键节点识别算法信任网页排名(Trust-pagerank, TPR)。2020年,何铭等<sup>[28]</sup>提出一种综合多属性电网关键节点识别方法,计算电网中节点的重要性排序。同年,文献[29]提出一种基于局部中心性的关键节点识别算法,该方法为使评价指标更加全面,同时考虑了节点在空间和时间上的网络位置和演化特征。2021年,文献[30]从网络节点的全局属性以及局部属性两个层面综合考虑,提出基于多属性的关键节点识别方法。

## 1.2 基于网络拆除和网络划分的方法

网络拆除和网络划分是关键节点识别可以解决的两类问题。在实际的研究过程中,利用网络拆除或是网络划分的基本思想又可以对关键节点识别起到一定的作用。其中基于网络拆除的方法寻求去除最少节点以打破网络中的所有环路,使网络中最大组件最小;基于网络划分的方法是找到最少的节点使得网络中组件和最小。2016年,文献[31]从统计力学的角度出发,提出了一种三阶段最小和算法来有效地拆除网络。文献[32]提出了一种简单快速的二核最高度(2-core highest degree, CoreHD)算法,该算法递归地从网络的两核中去除最高度的节点,以达到网络的拆除。文献[33]将信念传播引导的抽取算法(其时间复杂度近似为线性)应用于网络最优攻击问题,仿真实验证明了该算法的有效性。2019年山西大学的吴志康<sup>[34]</sup>提出了一种基于节点中心性的关键节点识别算法框架,算法利用节点覆盖集的概念,先将节点删除再回添,从而找到符合要求的关键节点。2021年,刘勇<sup>[35]</sup>基于网络拆除的思想提出了一种基于正解相似度的排序方法对网络中的节点重要性进行排序,仿真结果证明所提方法优于基于节点中心性的方法。2021年,邹艳丽等<sup>[36]</sup>提出一种基于子网划分的电网关键节点识别方法。先根据邻域信息将节点划分未子集,然后利用多属性决策法对节点进行排序,从而得到关键节点。此类算法中最具代表性的就是集体影响力算法。2015年,文献[37]以组织大规模流感为原型,通过最小化网络能量以减少网络传播能力,提出集体影响力指标,量化关键节点的重要程度。在此基础上,2016年,文献[38]对集体影响力算法进行了优化,除网络拆除步骤,还为算法增加了节点重插入步骤以求找到节点的最优删除策略。2018年,文献[39]针对集体影响力算法中的节点重插入步骤进行了进一步的改进,提出了一种基于不相交集重插入的新算法,仿真结果表明所提算法优于原集体影响力算法。

## 1.3 基于强化学习的方法

近年来,随着人工智能<sup>[40]</sup>的不断发展,一些基于强化学习的方法被应用到关键节点识别问题中。2020年,电子科技大学的范敏<sup>[41]</sup>设计了基于强化学习的关键节点识别算法,并仿真分析了识别算法中动作选择策略、丢包率等参数对识别结果的影响。同年,文献[42]介绍了一个深度强化学习框架

FINDER,它可以在由玩具模型生成的小型合成网络上进行训练,然后应用于广泛的应用场景。实验结果表明其性能优于其他启发式算法或近似算法。随后,安徽财经大学的汪黎明<sup>[43]</sup>结合网络鲁棒性和网络传播动力学两类方法的优点,提出基于深度Q网络(Deep Q-Network, DQN)的复杂网络关键节点识别方法。先通过DQN奖励矩阵对指标进行整合,训练神经网络参数得到节点之间最优路径策略模型,最后根据DQN的Rank值大小对节点的重要性进行排序,该指标定义为经过某节点的最优路径数目与总路径条数的比值,表示节点对于网络中其他节点的依赖程度<sup>[43]</sup>。虽然基于强化学习的方法才刚刚起步,但是强化学习模型与关键节点识别模型高度契合,因此强化学习有解决关键节点识别问题的巨大潜力。

综上所述,关键节点识别技术的研究现状是:(1)大多数方法仅仅关注了节点的局部特征而忽略了节点在整个网络中所处的位置;(2)现有算法大多数开销较大、所需时间较长,不宜应用在大型复杂的网络中;(3)现有算法大多数是针对社交网络的非权重网络,而很少针对通信网络中的权重网络。

## 2 关键节点识别系统模型

考虑一个未知的无线通信网络和感知网络的场景,例如无人机(Unmanned aerial vehicle, UAV)网络。未知无线通信网络,即目标网络,具有 $N_{\text{node}}$ 个节点。同时,监测目标网络的感知网络将接收目标网络的通信数据。任务是根据感知网络感知到的数据,识别未知网络的关键节点。关键节点识别系统模型如图2所示。数据感知、拓扑推理、关键节点识别、战场决策和网络更新构成一个自闭环,是感知到决策的整个过程。本文主要研究关键节点的识别过程,因此假设目标网络的拓扑和权值已知。虽然在实践中,拓扑结构可能会随着时间而改变,但可以假设拓扑结构在一个小的观测周期内是恒定的。此时,问题就变成了如何从有权重拓扑中推断出网络的关键节点。

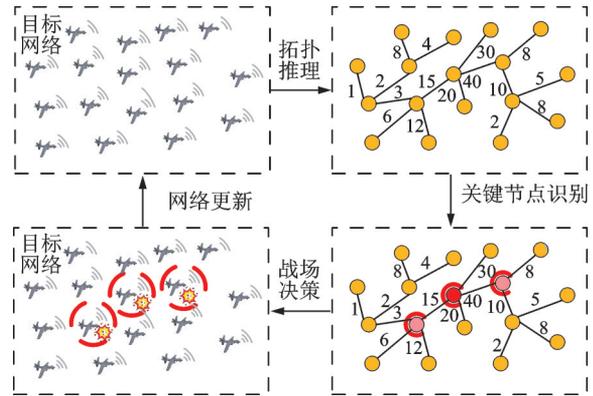


图2 关键节点识别系统模型

Fig.2 Key node identification system model

网络图用符号 $g = \{\nu, \epsilon\}$ 表示,其中, $\nu = \{1, 2, \dots, N_{\text{node}}\}$ 和 $\epsilon = \{a_{ij}\}_{i,j \in \nu}$ 分别表示顶点集和边集。其中, $N_{\text{node}}$ 为元素 $\nu$ 的个数,即网络中节点的个数。邻接矩阵 $A = \{a_{ij}\}_{i,j \in \nu} \in \mathbf{R}^{N_{\text{node}} \times N_{\text{node}}}$ 是一个对称矩阵,其中每一项都代表了对应边的边权重。向量 $\mathbf{n} = n_1, n_2, n_3, \dots, n_N$ 表示哪个节点存在,哪个节点被删除。一般采用的惯例是:如果节点 $i$ 存在则 $n_i = 1$ ,如果节点 $i$ 被移除则 $n_i = 0$ 。因此,被移除节点的百分比用 $q$ 表示<sup>[38]</sup>

$$q = 1 - \frac{1}{N} \sum_{i=1}^N n_i \equiv 1 - \langle \mathbf{n} \rangle \quad (1)$$

用 $G_w(q)$ 表示节点中属于最大连接组件的百分比。则问题就是找到需要移除的最小节点数 $q_c$ ,使得 $G_w(q_c) = 0$

$$q_c = \min \{q \in [0, 1]: G_w(q) = 0\} \quad (2)$$

在实际情况下,如果 $q > q_c$ ,可以完全破坏网络,如果 $q < q_c$ ,将提供最小化 $G_w(q)$ 的被删除节点配置。对于一个给定的节点 $i$ ,如果它没有连接到最大连接组件 $G_w$ ,可能是因为它被删除了,也可能是因为它的邻居被删除了。前者 $n_i = 0$ ,后者 $n_i = 1$ 。因此, $n_i$ 不能告诉节点 $i$ 是否属于或不属于 $G_w$ ,所以需要

要引入另一个变量来表示节点  $i$  是否连接到  $G_w$ 。这个变量是节点  $i$  属于最大连接组件的概率,  $v_i$ 。为了简化问题, 如果  $i \in G_w$ ,  $v_i = 1$ , 否则  $v_i = 0$ 。将其中百分比为  $q$  的节点从网络中移除, 则最大分量中网络权重的比例为

$$G_w(q) = \frac{1}{N_{\text{node}}} \sum_{i=1}^{N_{\text{node}}} \sum_{j=1}^{N_{\text{node}}} v_i a_{ij} \quad (3)$$

实际上, 很难找到最大分量  $G_w$  的显式函数形式。常用的方法是将问题转化为最优渗透问题中特征值的极小化问题, 可用  $n$  显式表示。现在考虑两个连接的节点  $i$  和  $j$ , 用  $v_{i \rightarrow j}$  来表示节点  $j$  删除后  $i$  是否属于  $G_w$ 。然后,  $v_{i \rightarrow j}$  可以用下面的消息传递公式进行数学转换<sup>[39]</sup>

$$v_{i \rightarrow j} = n_i \left[ 1 - \prod_{k \in \partial_{ij}} (1 - v_{k \rightarrow i}) \right] \quad (4)$$

式中:  $\partial_{ij}$  为节点  $i$  除了节点  $j$  以外的邻居集合。因此, 对于所有  $i$ ,  $v_i = 0$ , 从而得到  $G_w = 0$ 。这个方法给出了线性算子的最大特征值, 由定义在有向边  $k \rightarrow l, i \rightarrow j$  上的  $2M \times 2M$  矩阵表示<sup>[39]</sup>

$$\mathcal{M} = \frac{\partial v_{i \rightarrow j}}{\partial v_{k \rightarrow l}} \Big|_{\{v_{i \rightarrow j} = 0\}} \quad (5)$$

式中:  $\lambda(\mathbf{n}; q)$  为  $\mathcal{M}$  的最大特征值, 它依赖于向量  $\mathbf{n}$  和百分比  $q$ 。因此, 给定  $q$  的优化问题可以重新描述为在所有满足  $\langle \mathbf{n} \rangle = 1 - q$  的构型  $\mathbf{n}$  中寻找最优影响者配置  $\mathbf{n}^*$ , 使  $\lambda(\mathbf{n}; q)$  最小, 其中,  $\langle \mathbf{n} \rangle$  表示向量  $\mathbf{n}$  中值为 1 的项数。因此可以得到

$$\lambda(\mathbf{n}^*; q) \equiv \min_{\mathbf{n}: \langle \mathbf{n} \rangle = 1 - q} \lambda(\mathbf{n}; q) \quad (6)$$

则最优阈值  $q_c$  为式(7)的解, 即

$$\lambda(\mathbf{n}^*; q_c) = 1 \quad (7)$$

### 3 基于加权集体影响力的关键节点识别算法

本节提出了一种基于加权集体影响力的关键节点识别方法, 该方法是集体影响力<sup>[37]</sup>(Collective influence, CI)的扩展版本。首先介绍 WCI 的主要思想, 然后详细阐述所提出的算法。该算法包括 2 个步骤(1)从网络中删除节点, 找到最佳分数  $q_c$ , (2)重新插入节点, 找到删除节点的顺序<sup>[38]</sup>。

#### 3.1 加权集体影响力

目标是根据式(7)找到满足最低的  $q_c$  的节点最佳配置  $\mathbf{n}^*$ 。特征值  $\lambda(\mathbf{n})$  (其中省略了  $q$ , 因为它总是保持固定) 决定了矩阵  $\mathcal{M}$  在  $\ell$  次迭代后的能量函数为<sup>[39]</sup>

$$|\mathbf{w}_\ell(\mathbf{n})| = \langle \mathbf{w}_\ell | \mathbf{w}_\ell \rangle^{\frac{1}{2}} = |\mathcal{M}^\ell \mathbf{w}_0| = \left\langle \mathbf{w}_0 \left| (\mathcal{M}^\ell)^\dagger \mathcal{M}^\ell \right| \mathbf{w}_0 \right\rangle^{\frac{1}{2}} \quad (8)$$

式中  $\mathbf{w}_0$  为  $\ell = 0$  时的能量函数。然后用幂次法计算最大特征值为

$$\lambda(\mathbf{n}) = \lim_{\ell \rightarrow \infty} \left[ \frac{|\mathbf{w}_\ell(\mathbf{n})|}{|\mathbf{w}_0|} \right]^{1/\ell} \quad (9)$$

式(9)给出了精确解, 但在实际应用中, 只将影响的代价能量函数  $|\mathbf{w}_\ell(\mathbf{n})|$  对于一个确定的阶数  $\ell$  最小化。当  $\ell \geq 1$ , 可以得到

$$|\mathbf{w}_\ell(\mathbf{n})|^2 = \sum_{i=1}^N (k_i - 1) \sum_{j \in \partial \text{Ball}(i, 2\ell - 1)} \left( \prod_{k \in P_{2\ell-1}(i, j)} n_k \right) (k_j - 1) \quad (10)$$

式中,  $\text{Ball}(i, \ell)$  就是以节点  $i$  为中心,  $\ell$  为半径的球,  $\partial\text{Ball}(i, \ell)$  代表球边界上的节点集合,  $_{\ell}(i, j)$  表示从节点  $i$  到节点  $j$  的最短路径,  $k_i$  表示节点  $i$  的度。

对于  $\ell = 1$ , 可以用空腔法找到解, 但如果  $\ell \geq 2$ , 空腔法就会变得更加复杂, 研究者们总是使用另一种方法, 称为极值优化 (Extremal optimization, EO)。然而, 在大型网络中, EO 无法进行扩展以找到最优配置。文献[37]开发了一种自适应方法, 该方法在实践中表现优异, 保留了 EO 的特点, 并且对当今的大数据具有很高的可扩展性, 称为集体影响力算法。本文工作是将这种方法扩展到了有权重网络, 称为加权集体影响力算法。

本文方法的核心思想是, 关键节点是导致能量函数下降最大的节点。首先, 在每个节点周围明确定义一个半径为  $\ell$  的球, 如图3所示。然后, 考虑球面上的节点  $\partial\text{Ball}(i, \ell)$ , 并赋予节点  $i$  加权集体影响力强度为

$$\text{WCI}_{\ell}(i) = \sum_{j \in \partial\text{Ball}(i, \ell)} \left( \sum_{k \notin i, j} \tau w_{ik}^2 \cdot \sum_{k \notin i, j} \tau w_{jk}^2 \right) \quad (11)$$

加权集体影响力的定义比较抽象, 它衡量了一个节点在球形网络中的信息传播能力, 从直观上可以理解为, 如果某个节点发送信息, 该信息可以尽可能多地传播出去, 那么这个节点的加权集体影响力强度就高, 反之则低。当传播球半径设置为0时, 算法将退化为传统的基于节点度中心性的方法; 当传播球半径设置为无限大时, 算法将遍历整个目标网络。不考虑权重的集体影响力是加权集体影响力的特殊形式, 因此本文所提方法是对原集体影响力方法的扩展版本。

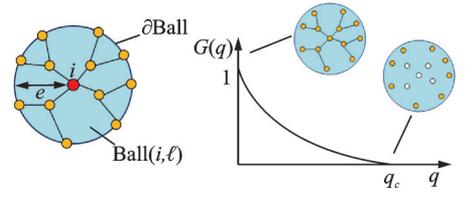


图3 集体影响力算法物理量图示  
Fig.3 Physical quantity diagram of collective influence algorithm

### 3.2 节点移除

算法的第1步为节点删除, 具体做法为根据式(11)计算所有节点的WCI值, 然后依次删除WCI最大的节点即可。具体算法为:

#### 步骤1: 节点移除算法

- (1) 输入: 加权邻接矩阵为  $A$  (尺寸为  $N_{\text{node}} \times N_{\text{node}}$ ); 传播球半径/模型阶数为  $\ell$ ; 最大组件阈值为  $\alpha_G$ ; 每次移除的节点数量为  $N_{\text{batch}}$ 。
- (2) 输出: 要删除的节点集  $N_r$ 。
- (3) 找到以每个节点  $i$  为中心, 半径为  $\ell$  的球上的节点集  $\partial\text{Ball}(i, \ell)$ 。
- (4) 分别计算每个节点  $i$  的加权集体影响力  $\text{WCI}_{\ell}(i)$ ;
- (5) 删除  $\text{WCI}_{\ell}$  值最大的  $N_{\text{batch}}$  节点, 并将节点添加到删除节点集  $N_r$ ;
- (6) 计算最大组件  $G_w$ ;
- (7) 检查最大组件是否小于阈值  $\alpha_G$ 。如果  $G_w < \alpha_G$ , 则可以停止节点删除, 并输出删除节点集  $N_r$ 。否则, 重复步骤(3)~(7)。

- (8) 输出: 要删除的节点集  $N_r$ 。

虽然在理论上,  $q_c$  存在闭式解, 但在实际操作过程中, 计算  $q_c$  往往比较困难, 因此在算法中设置最大组件阈值  $\alpha_G$  来判断算法是否可以停止。

### 3.3 节点重插入

在实际情况中发现, 虽然通过集体影响力可以找到删除节点的比例  $q_c$  和配置  $n^*$ , 但是仅仅依靠节点移除步骤却无法提供最优删除策略。也就是说, 只能通过步骤1得到需要删除的节点集合, 而无法得到需要删除节点的先后顺序。因此需要重插入步骤, 即将已经删除的节点重新插入, 逆序寻找最优的删除策略。

重插入的主要步骤是:(1)对于每个已经删除的节点,计算重新插入该节点最大组件的增加量 $\Delta G_w$ ; (2)插入 $\Delta G_w$ 最小的节点,并将节点加入序列 $N_i$ ; (3)重复步骤(1,2)直到所有节点都被插入,则序列 $N_i$ 的倒序就是删除节点的最优配置。其算法为:

**步骤 2: 节点重插入算法**

- (1) 输入: 加权邻接矩阵  $A$  (尺寸为  $N_{\text{node}} \times N_{\text{node}}$ ); 每次重插入的节点数量,  $N_{\text{batch}}$ 。
- (2) 输出: 节点插入序列,  $N_i$ 。
- (3) 建立一个不相交集, 记录每个节点所属的二叉树的根节点。
- (4) 计算每个节点当前所属组件的大小。
- (5) 对于每个被移除的节点  $i$ , 计算如果重新插入节点, 最大组件的增量为  $\Delta G_w(i)$ 。
- (6) 重新插入  $\Delta G_w(i)$  值最大的  $N_{\text{batch}}$  个节点, 并将节点添加到重新插入节点序列  $N_i$ ;
- (7) 对下一批重新插入的节点重复步骤(3)~(6)直到所有移除的节点被插入到网络中。
- (8) 输出: 节点插入序列  $N_i$ 。

**4 仿真验证**

**4.1 仿真网络设置**

本节首先利用5个常用的网络模型生成大规模网络来模拟无线通信网络的大规模特征,然后分别利用随机权重和非随机权重模拟真实场景下的网络流量特征。下面先对5个网络模型进行简单介绍。

(1) BA 无标度网络: BA 模型由其提出者姓名首字母命名。其生成方法是对于每一个新加入网络的节点, 将其与网络中现有的  $x$  个节点相连, 连接概率为  $f(k_i)$ , 其中,  $k_i$  为节点  $i$  的度。

(2) 随机网络: 由随机过程产生的、具有不确定性的图。其生成方法是确定网络节点数, 节点之间以随机的概率相连。

(3) ER 随机网络: ER 随机图也是由其提出者姓名首字母命名的。其产生方法是给定网络的节点数, 以固定概率  $p$  确定某条边是否存在。

(4) 规则网络: 规则网络是以一定的规则生成的网络。其产生方法是给定网络的节点数, 并设置每个节点的度一定。

(5) 小世界网络: 在小世界网络中, 大多节点只与几个节点相连, 但任意的两个节点都可以通过少数几步到达。

设置一个 1 000 个节点的复杂网络, 分别生成以上的 5 种网络, 如图 4 所示。为了验证所提算法在有权重通信网络中的效果, 手动给上述网络添加边权重。然后, 使用  $G_w-q$  曲线和算法得分 ( $G_w-q$  曲线下的面积) 来衡量算法的有效性。

$G_w-q$  曲线: 横坐标为删除的网络节点占总网络节点的比例, 纵坐标为网络最大组件的大小。曲线下降越快, 说明性能越好。

算法得分:  $G_w-q$  曲线下的面积。面积越小,  $G_w-q$  曲线下降越快, 说明性能越好。

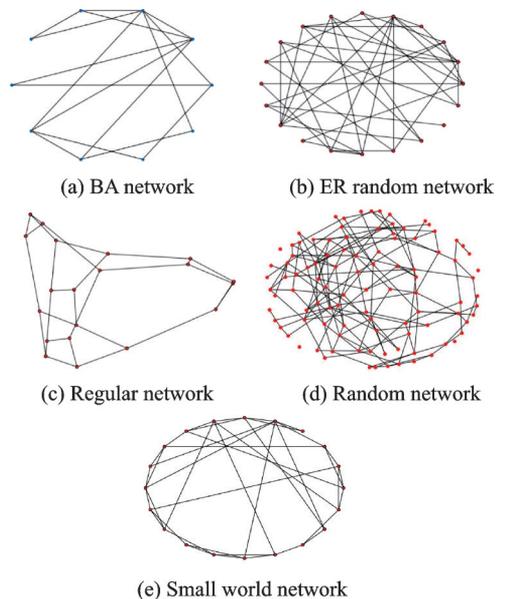


图 4 5 种复杂网络图示

Fig.4 Five complex networks

## 4.2 随机权重网络仿真结果

本节展示了随机权重网络下的仿真结果,即每个网络的节点数为1000,每条边的权重是0-1随机的,其结果如表1所示。表1给出了CI方法和WCI方法的对比,并展示了不同传播球半径下的仿真结果。横向比较5个网络可以发现,其中针对BA网络的效果最好,针对规则网络的效果最差。这是因为BA网络属于最稀疏的网络,因此网络容易拆除;而规则网络中每个网络的度都是一样的,因此网络不容易拆除。纵向比较CI方法和WCI方法可以发现,在ER随机网络、规则网络和随机网络的情况下WCI方法明显优于CI方法,而在BA网络和小世界网络情况下,WCI方法的优势不明显,而且有时候比CI方法更差。这是因为网络链路的随机权重导致边与边之间的权重差别不大。再比较WCI方法下不同球半径的影响可以发现,球半径的选择对算法的效果影响不大,证明算法具有鲁棒性。

表1 5种随机权重复杂网络的仿真结果

Table 1 Simulation results for five randomly weighted complex networks

方法	BA网络	ER随机网络	规则网络	随机网络	小世界网络
CI( $\ell=3$ )	0.010 742	0.175 515 0	0.245 896	0.174 632	0.139 965
WCI( $\ell=3$ )	0.009 489	0.166 787 0	0.215 462	0.162 361	0.148 388
CI( $\ell=2$ )	0.007 618	0.178 789 0	0.246 154	0.172 336	0.139 568
WCI( $\ell=2$ )	0.011 047	0.166 534 0	0.215 717	0.159 821	0.140 242
CI( $\ell=1$ )	0.009 982	0.178 704 0	0.250 061	0.174 428	0.145 415
WCI( $\ell=1$ )	0.010 427	0.167 396 0	0.227 136	0.161 094	0.151 827
CI( $\ell=0$ )	0.006 007	0.179 948 0	0.247 230	0.174 762	0.138 446
WCI( $\ell=0$ )	0.005 945	0.169 054 0	0.225 227	0.163 539	0.146 995

图5是5个随机权重网络的 $G_w$ - $q$ 曲线,可以很直观地看到针对BA网络的效果最好,针对规则网络的效果最差。图6是以ER随机网络为例,不同球半径下的 $G_w$ - $q$ 曲线,可以看到不同球半径下的算法性能相似。图7是以ER随机网络为例,在球半径为2的情况下,WCI方法和CI方法的对比,可以发现WCI算法性能优于CI方法。

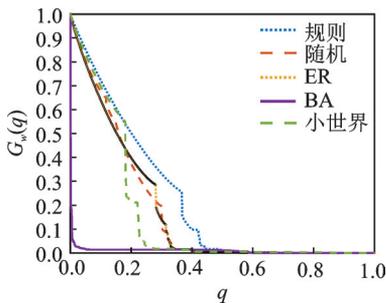


图5 5种随机权重网络的仿真结果对比

Fig.5 Comparison of simulation results for five randomly weighted networks

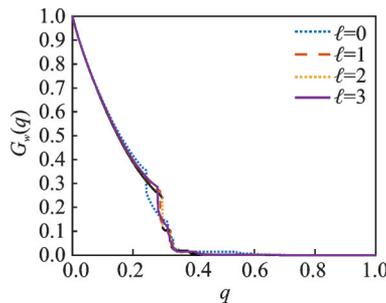


图6 不同参数下对随机权重ER网络的仿真结果对比

Fig.6 Comparison of simulation results under different parameters for randomly weighted ER network

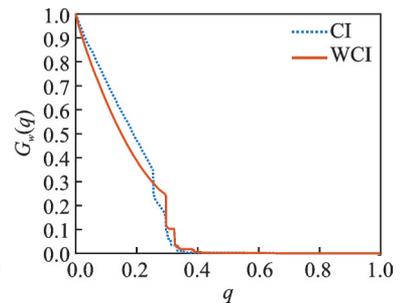


图7 CI和WCI方法对随机权重ER网络仿真结果对比

Fig.7 Comparison of simulation results between CI-based and WCI-based methods for randomly weighted ER network

### 4.3 非随机权重网络仿真结果

本节展示了非随机权重网络下的仿真结果,即每个网络的节点数为1 000,其中90%的边的权重是0-1随机的,另外10%的边权重是0-10随机的,以此来模拟真实情况下某些链路频繁使用的情况,其结果如表2所示。表2给出了CI方法和WCI方法的对比,并展示了不同球半径下的仿真结果。横向比较5个网络可以发现,其中针对BA网络的效果最好,针对规则网络的效果最差。这是因为BA网络属于最稀疏的网络,因此网络容易拆除;而规则网络中每个网络的度都是一样的,因此网络不容易拆除。纵向比较CI方法和WCI方法可以发现,无论是在ER随机网络、规则网络和随机网络的情况下,还是在BA网络和小世界网络情况下,WCI方法都明显优于CI方法。这是因为网络链路的非随机权重导致边与边之间的权重差别较大,此时WCI方法的优势就凸显出来。再比较WCI方法下不同球半径的影响可以发现,球半径的选择对算法的效果影响不大,证明算法具有鲁棒性。

表2 5种非随机权重复杂网络的仿真结果

Table 2 Simulation results for five non-randomly weighted complex networks

方法	BA网络	ER随机网络	规则网络	随机网络	小世界网络
CI( $\ell=3$ )	0.016 159	0.183 754	0.249 719	0.185 854	0.146 354
WCI( $\ell=3$ )	0.010 456	0.103 347	0.123 414	0.100 844	0.106 417
CI( $\ell=2$ )	0.009 797	0.191 877	0.249 287	0.189 567	0.147 04
WCI( $\ell=2$ )	0.010 680	0.101 876	0.122 392	0.104 218	0.110 174
CI( $\ell=1$ )	0.012 557	0.186 416	0.249 479	0.187 491	0.150 153
WCI( $\ell=1$ )	0.009 619	0.114 217	0.178 512	0.138 516	0.125 058
CI( $\ell=0$ )	0.006 874	0.195 714	0.250 512	0.185 611	0.145 573
WCI( $\ell=0$ )	0.007 771	0.111 420	0.124 692	0.128 880	0.105 757

图8是5个非随机权重网络的 $G_w$ - $q$ 曲线,可以很直观地看到BA网络效果最好,规则网络效果最差。图9是以非随机权重ER网络为例,不同球半径下的 $G_w$ - $q$ 曲线,可以看到不同球半径下的算法性能相似。图10是以非随机权重ER网络为例,在球半径为2的情况下,WCI方法和CI方法的对比,可以发现WCI方法性能明显优于CI方法。

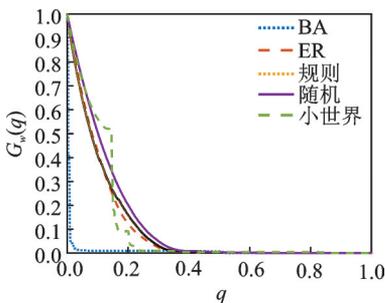


图8 5种非随机权重网络的仿真结果对比

Fig.8 Comparison of simulation results for five non-randomly weighted networks

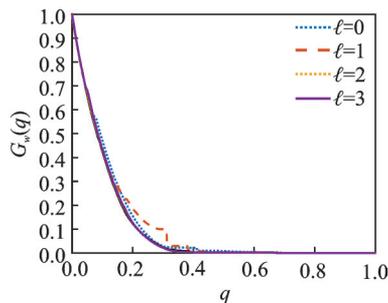


图9 不同参数下对非随机权重ER网络的仿真结果对比

Fig.9 Comparison of simulation results under different parameters for non-randomly weighted ER network

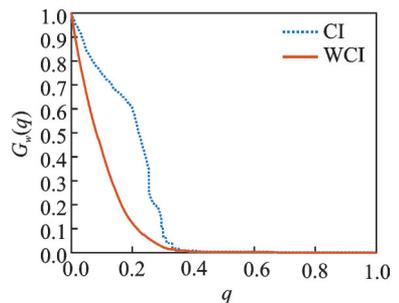


图10 CI和WCI方法对非随机权重ER网络仿真结果对比

Fig.10 Comparison of simulation results between CI-based and WCI-based methods for non-randomly weighted ER network

## 5 结束语

本文探讨了通信网络中的关键节点识别问题,本文的主要贡献总结如下:

(1)提出了一种面向非合作无线网络的关键节点拓扑感知系统模型,在该模型中以通信次数作为节点的边缘权值,并在模型中阐明了拓扑感知和关键节点识别的关系。

(2)提出了一种基于加权集体影响力的关键节点识别方案。首先,先计算网络中每个节点的WCI值,并逐个剔除WCI值最大的节点,直到将最大分量瓦解。其次,将删除的节点重新添加回来,并重建崩溃的网络。

(3)在各种参数配置下对算法进行了深入仿真,结果表明所提算法优于原集体影响力方法,并且算法对于球半径的选择不敏感。

### 参考文献:

- [1] 张治中,毛亚丽,朱磊.5G移动通信测试技术进展与挑战[J].数据采集与处理,2019,34(6):974-985.  
ZHANG Zhizhong, MAO Yali, ZHU Lei. 5G Mobile communication test technology progress and challenges[J]. Journal of Data Acquisition and Processing, 2019, 34(6): 974-985.
- [2] 朱秋明,华博宇,毛开,等.无人机毫米波信道建模进展和挑战[J].数据采集与处理,2020,35(6):1049-1059.  
ZHU Qiuming, HUA Boyu, MAO Kai, et al. Advances and challenges of UAV millimeter wave channel modeling[J]. Journal of Data Acquisition and Processing, 2020, 35(6): 1049-1059.
- [3] SUBRAMANIAN V R, LAMPERSKI A, SALAPAKA M V. Network structure identification from corrupt data streams[J]. IEEE Transactions on Automatic Control, 2021, 66(11): 5314-5325.
- [4] LIU H, LI Y, LI Z, et al. Topology identification of multilink complex dynamical networks via adaptive observers incorporating chaotic exosignals[J]. IEEE Transactions on Cybernetics, 2021(99): 1-14.
- [5] LIU Y, WANG J, HE H, et al. Identifying important nodes affecting network security in complex networks[J]. International Journal of Distributed Sensor Networks, 2021, 17(2): 1-10.
- [6] 李天梅.复杂网络的关键节点识别[D].西安:西安科技大学,2019.  
LI Tianmei. Identification of key nodes of complex networks[D]. Xi'an: Xi'an University of Science and Technology, 2019.
- [7] KUNTZ D I. Structure-based strategies for drug design and discovery[J]. Science, 1992, 257(5073): 1078-1082.
- [8] ARULSELVAN A, COMMANDER C W, ELEFTERIADOU L et al. Detecting critical nodes in sparse graphs[J]. Computers & Operations Research, 2009, 36(7): 2193-2200.
- [9] 李慧.融合拓扑势的有向社交网络关键节点识别模型[J].小型微型计算机系统,2021,42(7):1492-1499.  
LI Hui. Identifying influential nodes in directed social network based on topological potential[J]. Journal of Chinese Computer Systems, 2021, 42(7): 1492-1499.
- [10] PASTOR-SATORRAS R, VESPIGNANI A. Epidemic spreading in scale-free networks[J]. Physical Review Letters, 2000, 86(14): 3200-3203.
- [11] FREEMAN L C. A Set of measures of centrality based on betweenness[J]. Sociometry, 1977, 40(1): 35-41.
- [12] LESKOVEC J, LANG K J, DASGUPTA A, et al. Community structure in large networks: Natural cluster sizes and the absence of large well-defined clusters[J]. Internet Mathematics, 2008, 6(1): 29-123.
- [13] XIA Y, HILL D J. Attack vulnerability of complex communication networks[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2008, 55(1): 65-69.
- [14] CHEN B, PAN C S, WANG Y M, et al. Method of key node identification in command and control networks based on level flow betweenness[J]. International Journal of Computational Science and Engineering, 2019, 19(3): 368.
- [15] ALEX B. Communication patterns in task-oriented groups[J]. The Journal of the Acoustical Society of America, 1950, 22(6): 725-730.
- [16] HUI Y, XI C, LIU Z, et al. Identifying key nodes based on improved structural holes in complex networks[J]. Physica A: Statistical Mechanics and its Applications, 2017, 486(C): 318-327.

- [17] 徐翔. 复杂网络中关键节点识别理论方法研究与应用[D]. 马鞍山:安徽工业大学, 2018.  
XU Xiang. Research and application of key node identification theory and method in complex networks[D]. Ma'anshan: Anhui University of Technology, 2018.
- [18] 刘彩虹, 刘强, 祁瑞华. 一种邻近 H-index 的社会网络关键节点识别技术[J]. 中国科技论文, 2019, 14(3): 296-302.  
LIU Caihong, LIU Qiang, QI Ruihua. Vital node identification technology of social networks using neighbors' H-index values [J]. China Sciencepaper, 2019, 14(3): 296-302.
- [19] CUI X, YUN Z, LIU G. Key node identification of power grid based on AP clustering[C]// Proceedings of the 14th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD). [S.l.]: IEEE, 2019.
- [20] 顾秋阳, 吴宝, 孙兆洋, 等. 基于改进灰狼优化的复杂网络重要节点识别算法[J]. 通信学报, 2021, 42(6): 72-83.  
GU Qiuyang, WU Bao, SUN Zhaoyang, et al. Key node identification algorithm for complex network based on improved grey wolf optimization[J]. Journal on Communications, 2021, 42(6): 72-83.
- [21] LI Y, CAI W, LI Y, et al. Key node ranking in complex networks: A novel entropy and mutual information-based approach[J]. Entropy, 2020, 22(1): 52-74.
- [22] 刘菁, 陈威. 国防交通网络关键节点识别模型研究[J]. 军事运筹与系统工程, 2019, 33(1): 58-62.  
LIU Jing, CHEN Wei. A study on key node recognition of national defense transportation networks[J]. Military Operations Research and Systems Engineering, 2019, 33(1): 58-62.
- [23] 邓红星, 王玮琦. 基于节点重要度的公交专用道关键节点识别[J]. 重庆理工大学学报(自然科学), 2019, 33(4): 161-167.  
DENG Hongxing, WANG Weiqi. Key nodes identification of bus lane based on node importance[J]. Journal of Chongqing University of Technology (Natural Science), 2019, 33(4): 161-167.
- [24] 文元桥, 黄玉宇, 周春辉, 等. 基于复杂网络的区域水上交通关键船舶识别方法[J]. 交通信息与安全, 2020, 38(4): 1-9.  
WEN Yuanqiao, HUANG Yuyu, ZHOU Chunhui, et al. Identification of key nodes of regional water traffic based on complex network[J]. Journal of Transport Information and Safety, 2020, 38(4): 1-9.
- [25] MESGARI I, KERMANI M, HANNEMAN R, et al. Identifying key nodes in social networks using multi-criteria decision-OLS[M]. [S.l.]: Springer International Publishing, 2015.
- [26] 王环, 朱敏. 基于点权的混合 K-shell 关键节点识别方法[J]. 华东师范大学学报(自然科学版), 2019, 3(11): 101-109.  
WANG Huan, ZHU min. Vital nodes identification by the hybrid K-shell method based on vertex strength[J]. Journal of East China Normal University (Natural Science), 2019, 3(11): 101-109.
- [27] 王斌, 王亚云, 盛津芳, 等. 基于节点信任度的复杂网络关键节点识别[J]. 小型微型计算机系统, 2019, 40(11): 2337-2342.  
WANG Bin, WANG Yayun, SHENG Jinfang, et al. Identifying influential nodes of complex networks based on trust-value[J]. Journal of Chinese Computer Systems, 2019, 40(11): 2337-2342.
- [28] 何铭, 邹艳丽, 梁明月, 等. 基于多属性决策的电力网络关键节点识别[J]. 复杂系统与复杂性科学, 2020, 17(3): 27-37.  
HE Ming, ZOU Yanli, LIANG Mingyue, et al. Critical node identification of a power grid based on multi-attribute decision[J]. Complex Systems and Complexity Science, 2020, 17(3): 27-37.
- [29] 李钢, 王聿达, 崔蓉. KiC: 一种结合“结构洞”约束值与 K 壳分解的社交网络关键节点识别算法[J]. 现代情报, 2020, 40(12): 27-35.  
LI Gang, WANG Yuda, CUI Rong. KiC: An extended K-shell decomposition based on improved network constraint coefficient [J]. Journal of Modern Information, 2020, 40(12): 27-35.
- [30] 朱庆存. 基于网络中心性算法的关键节点识别方法研究[D]. 济南: 齐鲁工业大学, 2021.  
ZHU Qingcun. Research on key node recognition method based on network centrality algorithm[D]. Jinan: Qilu University of Technology, 2021.
- [31] BRAUNSTEIN A, DALL'ASTA L, SEMERJIAN G, et al. Network dismantling[J]. Proceedings of the National Academy of Sciences, 2016, 113(44): 12368-12373.
- [32] ZDEBOROV' A L, PAN Zhang, ZHOU Haijun. Fast and simple decycling and dismantling of networks[J]. Scientific Reports, 2016, 6(1): 37954.
- [33] MUGISHA S, ZHOU Haijun. Identifying optimal targets of network attack by belief propagation[J]. Physical Review E,

2016, 94(1): 012305.

- [34] 吴志康. 基于网络局部特征的关键节点识别算法研究[D].太原:山西大学,2019.  
WU Zhikang. Research of the critical node detection problem based on the local characteristic of network[D].Taiyuan: Shanxi University, 2019.
- [35] 刘勇. 一种计算机网络关键节点识别方法[J].电子设计工程, 2021, 29(17): 99-103,108.  
LIU Yong. A method of key nodes identification on computer network[J]. Electronic Design Engineering, 2021, 29(17): 99-103,108.
- [36] 邹艳丽,谭林毅,刘欣妍,等.基于子网划分的电网关键节点识别[J].计算物理,2022,39(3): 361-370.  
ZOU Yanli, TAN Shuyi, LIU Xinyan, et al. Power system critical node identification based on subnetwork partition[J]. Chinese Journal of Computational Physics, 2022,39(3): 361-370.
- [37] MORONE F, MAKSE H. Influence maximization in complex networks through optimal percolation[J]. Nature, 2015, 524: 65-68.
- [38] MORONE F, MIN B, BO L. et al. Collective influence algorithm to find influencers via optimal percolation in massively large social media[J]. Scientific Reports,2016,6: 30062
- [39] ZHU F. Improved collective influence of finding most influential nodes based on disjoint-set reinsertion[J]. Scientific Reports, 2018, 8(1): 14503.
- [40] 吴启晖,邱俊飞,丁国如.面向频谱大数据处理的机器学习方法[J].数据采集与处理, 2015, 30(4): 703-713.  
WU Qihui, QIU Junfei, DING Guoru. Machine learning methods for big spectrum data processing[J]. Journal of Data Acquisition and Processing, 2015, 30(4): 703-713.
- [41] 范敏. 战术网络中关键节点的识别技术研究[D].成都:电子科技大学,2020.  
FAN Min. Research on key node identification technology on tactical network[D]. Chengdu:University of Electronic Science and Technology of China, 2020.
- [42] FAN C, ZENG L, SUN Y, et al. Finding key players in complex networks through deep reinforcement learning[J]. Nature Machine Intelligence, 2020, 2(1): 317-324.
- [43] 汪黎明. 基于深度强化学习的复杂网络关键节点识别[D].蚌埠:安徽财经大学,2020.  
WANG Liming. Identification of vital nodes in complex networks based on deep reinforcement learning[D]. Bengbu: Anhui University of Finance and Economics, 2020.

#### 作者简介:



刘子彤(1997-),女,硕士,研究方向:认知网络、频谱数据挖掘, E-mail: zt\_liu@126.com。



王威(1990-),通信作者,男,博士,研究员,研究方向:无线通信系统安全、电磁频谱安全和区块链,E-mail: weiwang@nuaa.edu.cn。



丁国如(1986-),男,博士,教授,研究方向:认知网络、机器学习和无人机通信, E-mail: dr. guoru. ding@ieee.org。



吴启晖(1970-),男,博士,教授,研究方向:认知信息论、电磁空间频谱智能管控、天地一体化信息网络和无人机集群智能通信, E-mail: wuqihui2014@sina.com。

(编辑:陈琚)