

基于网络模体的轻量级物联网拓扑优化策略研究

陈宁¹⁾ 邱铁¹⁾ 郭得科²⁾ 徐天一¹⁾

¹⁾(天津大学智能与计算学部 天津 300350)

²⁾(国防科技大学系统工程学院 长沙 410073)

摘要 随着第五代移动通信技术(5G)的发展,智慧城市中物联网(Internet of Things, IoT)的应用规模和多样性呈现出爆炸式增长. 海量的智能传感设备组网给高动态的物联网通信服务质量带来了巨大的威胁. 部分关键设备节点的失效以及网络攻击易引发物联网的链锁崩塌效应,影响网络应用的服务质量. 因此,如何优化大规模物联网拓扑的鲁棒能力成为当下的研究挑战. 目前,针对物联网拓扑结构的优化问题,研究者们提出了启发式算法、智能学习机制和多目标优化策略等创新方法提高物联网拓扑结构的鲁棒能力. 但是,这些方法需牺牲巨大的计算资源来获得不成比例的鲁棒性能增益,网络规模越大,该现象越明显. 为了解决这个问题并平衡计算开销和提升鲁棒性能,本文提出了一种基于网络模体(Motif)的轻量级物联网拓扑优化策略 LITOS. 首先利用物联网拓扑结构的社区属性,设计一种基于网络模体的异步社区发现算法,将大规模复杂拓扑结构分解为轻量级局部网络拓扑. 然后,基于CPU多核心的计算资源,设计深度强化学习机制,异步优化轻量级物联网局部拓扑结构,从而降低网络整体优化运行时间,提高拓扑结构鲁棒能力. 在实验方面,与其他先进的优化算法相比,该策略在运行时间方面降低了1~2个数量级,在鲁棒性提升方面,与最优算法相差大约10%.

关键词 物联网;轻量级拓扑优化;异步社区检测;网络模体;深度强化学习;密集网络拓扑

中图分类号 TP391 DOI号 10.11897/SP.J.1016.2023.01121

Research on Lightweight Topology Optimization Strategy of Internet of Things Based on Network Motif

CHEN Ning¹⁾ QIU Tie¹⁾ GUO De-Ke²⁾ XU Tian-Yi¹⁾

¹⁾(College of Intelligence and Computing, Tianjin University, Tianjin 300350)

²⁾(College of Systems Engineering, National University of Defense Technology, Changsha 410073)

Abstract With the development of fifth-generation telecommunication technology (5G) and smart hardware devices, the scale and diversity of Internet of Things (IoT) applications are greatly expanding, like smart buildings, smart agriculture, smart homes, intelligent transportation, and so on. Numerous sensing devices can be networked to provide better network services for all aspects of life. However, the networking of massive intelligent sensing devices has brought a great threat to the quality of service (QoS) of the IoT, where the threat includes communication interrupts, data traffic congestion, and other unexpected factors. The robustness and performance of the IoT topology directly influence the network applications' services and thus are associated with network reliability and resilience. The failure of key device nodes and network cyber-attacks can lead to the collapse of the IoT topology, which affects the QoS of the whole network system. Then, the system will finally fail without the ability to communicate with other network systems,

收稿日期:2022-05-16;在线发布日期:2022-12-29. 本课题得到国家重点研发计划(2019YFB1703601)、国家自然科学基金联合基金重点项目(U2001204)、国家自然科学基金(62272339)、天津市研究生科研创新项目(2021YJSB108)资助. 陈宁,博士研究生,中国计算机学会(CCF)学生会会员,主要研究方向为物联网拓扑鲁棒优化. E-mail: chenning@ieee.org. 邱铁(通信作者),博士,教授,中国计算机学会(CCF)杰出会员,主要研究领域为物联网技术、智慧城市与移动计算、智能大数据分析. E-mail: qiutie@ieee.org. 郭得科,博士,教授,中国计算机学会(CCF)杰出会员,主要研究领域为网络计算与系统、分布式计算与系统、软件定义网络、大数据分析处理、移动计算. 徐天一,硕士,工程师,中国计算机学会(CCF)会员,主要研究方向为智慧物联网、区块链.

where the large-scale IoT applications are broken. Therefore, how to optimize the robustness of large-scale IoT topology is a challenge to maintain maximum communication ability even if some device nodes fail, which draws researchers' attention. Nowadays, methods such as heuristic algorithms and learning mechanisms are proposed to enhance the reliability of IoT topology. These methods can efficiently improve the robustness of IoT applications against cyberattacks and prolong the network lifetime even if part of the topology fails. However, these methods sacrifice huge computing resources to get disproportionately robust performance gains, and the larger the IoT topology scale, the more obvious this phenomenon is. Indeed, in the real world, IoT applications cannot spend so much time executing to produce a suboptimal result. We need a fast robustness optimization method for large-scale IoT applications. To address the problem, in this paper, we propose a Lightweight Topology Optimization Strategy for the IoT based on network motif (LITOS), where network motifs are significant repetition patterns widely spread in the network topology. Through the topology analysis, we found that the IoT topology has community characteristics, and we designed an asynchronous community detection algorithm based on a network motif to decompose the large-scale complex IoT topology into lightweight local network topologies. The devices with multiple roles in the communities are grouped together as a "super community". Then, utilizing CPU multi-core computing resources, we present a deep deterministic reinforcement learning mechanism (DDRL) to asynchronously optimize each local lightweight IoT topology, which can reduce the overall optimization time and improve the robustness of the network topology. Furthermore, we developed a novel robustness metric based on network motifs to measure dynamic changes in IoT topology, where network motifs can reveal hidden functional mechanisms and provide researchers with new perspectives on network topology. The new robustness metric has a better effect of guiding the topology towards more reliability. In terms of experimental results, compared with other state-of-the-art optimization algorithms, the running time of the LITOS is 1–2 orders of magnitude lower than that of the ROCKS and ROSE algorithms and is about 10% lower than these algorithms in robustness improvement, which can greatly improve the optimizing efficiency for large-scale IoT topologies.

Keywords Internet of Things; lightweight topology robustness optimization; asynchronous community detection; network motif; deep reinforcement learning; dense network topology

1 引 言

随着新一代信息通信技术(5G)的蓬勃发展^[1],智慧城市中的物联网应用规模急剧增加^[2],截至2025年将有超过75亿的设备加入到物联网应用中^[3],比如无线传感器网络(Wireless Sensor Network, WSN)^[4]、车联网(Internet of Vehicles, IoV)^[5]、工业物联网(Industrial Internet of Things, IIoT)^[6]、电信网络(Telecommunication Networks)^[1]、电网(Power Grid)^[7]等.这些物联网应用规模的扩张,在提升网络服务质量的同时带来了更大的网络瘫痪风险^[8].网络规模越大,网络面临瘫痪的风险随之增加.网络应用中的设备节点易受到多种因素而失效,

如自然灾害活动、节点自身故障以及恶意攻击等.此外,这些物联网应用相互交叉链接,单个网络的瘫痪极易导致整个智慧城市网络的链锁崩塌^[7].因此,在面临部分设备节点失效的情况下,如何提高复杂物联网应用的服务质量(QoS)与抵抗网络攻击的鲁棒能力^[9],并最大程度地保持网络拓扑的通信能力,成为制约大规模物联网应用发展的瓶颈^[10].

在物联网应用拓扑结构受到攻击时,为了维持其通信连接能力并延长网络生命周期,衡量并优化网络拓扑结构的鲁棒性与可靠性是最小化网络故障风险的重要手段^[11].在物联网拓扑结构鲁棒分析中,研究者们充分利用复杂网络分析手段^[12],探究物联网拓扑结构鲁棒优化对整体应用的影响,发现了物联网拓扑结构优化机理,降低了网络应用链锁

崩塌的风险。

衡量物联网拓扑结构的鲁棒性是优化网络拓扑结构的必要前提。目前大多数研究方法利用网络拓扑的一些全局特征来衡量网络拓扑结构的鲁棒性^[13-14], 比如节点度数分布、网络平均度、最大连通子图、节点中心性等。研究者们利用这些网络低阶连通拓扑特性^[7]来评估网络拓扑结构的鲁棒能力和可靠性。此外, 最新的研究表明复杂网络中存在高阶网络特性, 比如网络模体(Motif)^[15-16]。网络模体是存在于复杂网络拓扑结构中一种特定模式, 在理解复杂网络的架构、功能和网络背后的隐藏机制(从基因连接网络到社交网络到交通网络)方面扮演着重要的角色^[15]。复杂网络中的模体不是偶然和随机存在的, 具有一定的网络功能作用^[16-17]。研究分析网络模体对网络拓扑结构鲁棒性能的影响, 可以从不同的视角发现物联网拓扑结构的优化机理, 从而指导物联网拓扑结构的优化方向。

目前流行的物联网拓扑结构优化方法^[18-19]主要采用最大连通子图作为鲁棒衡量指标来量化和优化网络拓扑结构。由于物联网拓扑结构优化问题属于 NP 难问题^[19], 为了寻求到近似最优解, 大部分物联网拓扑结构优化方法基于启发式算法^[14]。同时, 在复杂网络中, 无标度网络模型^[19]更接近于真实世界的网络结构, 同时该网络模型在抵抗网络随机攻击时(每个设备节点等概率失效或离开网络)具有良好的性能, 但是面对恶意攻击时(重要节点优先失效)易陷入网络瘫痪。因此, 研究者们主要研究如何提高基于无标度网络模型生成的物联网拓扑结构的抵抗恶意攻击能力。比如, 基于边分类的启发式优化算法^[14]、基于多种群协同的遗传优化算法^[19]等。这些优化算法在提高物联网拓扑鲁棒性方面具有良好的性能表现。但是, 当物联网规模增大时, 需要花费大量额外的计算机开销来获得一个不成比例的鲁棒性能提升, 从均衡角度来说, 在一定程度上是不能容忍的。

在本文中, 我们提出了一个基于网络模体的轻量级物联网拓扑优化策略(LITOS), 平衡计算开销与鲁棒提升的关系。在这里需要强调的是, 网络拓扑的鲁棒性概念并不是唯一定义的, 根据不同的网络应用需求可设定不同的鲁棒衡量标准。网络瘫痪的客观验证需要一些关于网络攻击和节点故障时的网络行为真实数据, 但是这些数据由于隐私性和保密性使得我们不能获取这些真实行为数据^[7], 因此本文模拟网络的恶意攻击方式^[10]来验证网络拓扑结

构的鲁棒能力。此外, 通过大量的研究表明, 一个网络的鲁棒性和可靠性可以用其保持网络拓扑结构的原始特性的能力来量化^[15], 比如在网络拓扑功能中扮演重要角色的网络模体^[16]。因此, 在本文中, 我们首先基于网络模体设计一个新的鲁棒衡量指标来表征物联网拓扑结构的鲁棒能力。经典的模块度指标是衡量网络划分社区是否合适的测量指标, 不能够用来衡量网络的鲁棒性。研究表明, 网络模体是网络拓扑结构中重复出现的一种固定模式, 扮演着重要的作用, 其浓度大小深刻影响着拓扑的健壮性与稳定性。其次, 受到社区检测算法^[20]的启发, 并结合网络模体设计新的异步流动社区发现算法, 将大规模的网络拓扑结构^[21]划分为若干个轻量级社区结构, 即若干个网络拓扑子结构。同时, 将具有跨社区活动的节点设置为超级社区。通过设置超级社区来保证所有社区的并集可以构成整体拓扑。然后, 为了进一步加快网络拓扑鲁棒优化效率, 设计实现一个异步式的深度强化学习模型^[11]分别优化每一个社区拓扑结构。同时, 该模型也优化超级社区, 保证提升整体拓扑结构的鲁棒性, 利用多个子社区的自我优化来增加优化的方向并跳出局部最优, 在有限的运行时间内最大程度的提高网络拓扑结构的鲁棒能力。最后, 将所有优化后的社区结构合并, 得到一个具有高鲁棒的大规模物联网拓扑结构。

然后, 为了进一步加快网络拓扑鲁棒优化效率, 设计实现一个异步式的深度强化学习模型^[22]分别优化每一个社区拓扑结构。最后, 将所有优化后的社区结构合并, 得到一个具有高鲁棒的大规模物联网拓扑结构。

本文主要贡献如下:

(1) 提出了基于网络模体的异步发现网络社区结构算法。该算法可以在超大网络拓扑结构中有效地异步检测已存在的相似社区结构。设计基于网络模体的社区发现方法, 在每个社区中尽可能地保留网络的原始特性, 并将大规模复杂网络分解为轻量级网络拓扑结构。LITOS 模型提高网络鲁棒性的同时保证拓扑结构的无标度特性不变。

(2) 设计了一个新颖的衡量网络拓扑结构鲁棒性的测量指标。利用网络模体在物联网拓扑结构中的浓度来表征网络拓扑结构维持自身拓扑原始特性的性能, 即抵抗网络攻击的鲁棒能力。同时, 本文将进一步探索网络模体在物联网拓扑优化中的影响机理。

(3) 提出了一个分布式的深度强化学习的轻量

级优化模型来异步优化具有高模块度的超大规模物联网拓扑结构,该模型可以部署在边缘服务器上.此外,我们还提取出了一个超级社区,它由在社区之间扮演不同角色的节点构成.该超级社区同样被该模型进行优化.再者,设计了一个映射动作操作来将该学习模型中的离散动作转变为连续动作,以便适配该优化模型.

(4) 我们利用真实的电网拓扑数据集与模拟生成的大规模数据集验证 LITOS 策略的性能表现.实验结果表明 LITOS 比已有的物联网拓扑鲁棒优化算法降低了计算开销,平衡鲁棒性能提升与计算开销之间的关系.

文章的主要组织架构如下.在第 2 节,我们主要介绍相关工作,包括拓扑鲁棒优化、社区发现、分布式深度强化学习及该研究工作的先进性;其次,我们在第 3 节引出该研究工作模型,包括其理论模型、研究目标等;然后,在第 4 节,我们具体设计该模型的算法,包括鲁棒指标、社区发现、分布式深度强化学习模型、优化算法等;接着,相关实验结果在第 5 节进行论述;最后,我们对该研究工作进行总结.

2 相关工作

在这个章节,我们会详细介绍当前最新研究工作,包括物联网拓扑结构的鲁棒衡量指标和优化方法、高效的社区发现算法、分布式深度强化学习模型以及本文工作的优势和重点要解决的问题.

2.1 网络拓扑鲁棒优化

复杂网络模型中的无标度网络模型在容忍网络随机故障方面^[23]具有突出的性能,且研究显示现实世界中的大部分网络符合无标度网络的幂律分布^[19].因此,大部分研究者基于无标度网络模型来提高物联网拓扑结构抵抗网络恶意攻击的鲁棒能力^[10-11,16].在优化物联网拓扑结构的鲁棒能力之前,需要定义网络拓扑结构鲁棒能力的衡量指标^[18].不同的网络研究问题关注的拓扑结构不一样,其鲁棒衡量指标各不相同.最常见的物联网拓扑结构鲁棒衡量指标是利用剩余网络中的最大连通子图^[13]所包含的节点数目百分比来表征当前网络中的通信能力^[18].此外,还有诸如自然连通度、平均度数、最小平均路径、节点中心性等网络拓扑结构鲁棒衡量指标^[13-14].然而,这些鲁棒衡量指标关注网络拓扑结构的低阶特性,比如节点、边等,缺乏对动态拓扑变化的感知能力^[7].如何能够全面感知动态网络拓扑变

化,尤其是物联网应用存在着频繁的设备节点加入和退出、通信范围限制等因素制约,成为当前设计鲁棒衡量指标的挑战.随着复杂网络的研究分析发展,很多研究工作发现网络中存在一些固定的拓扑结构,比如网络模体.这些网络模体在网络拓扑中起到了重要的功能作用^[15-16].网络模体是一种特定的拓扑结构,分析其在复杂网络中的影响,不仅可以从低阶角度研究网络拓扑中的节点、边等基础网络特性,而且还可从高阶角度分析和解释全局的网络拓扑特性^[7].因此,在本文中,首次设计基于网络模体的鲁棒衡量指标,旨在可全面动态感知实际物联网应用的拓扑变化.

很多研究者提出了高效的优化算法增强物联网拓扑结构的鲁棒能力.比如,Zhao 等人^[24]充分调研影响物联网拓扑鲁棒性提升的根本原因,并设计线性规划放松给出一个优化近似解,优于之前的优化效率.Zhou 等人^[25]利用文化基因算法优化无标度网络抵抗恶意攻击的鲁棒能力.Rong 等人^[14]对网络中的边进行分类,并利用启发式算法来增强网络拓扑结构的鲁棒能力.Qiu 等人^[18]对物联网拓扑结构设计新的重新连接方式使得其朝着洋葱头结构^[10]方向优化,并设计新的多种群遗传优化算法解决早熟收敛问题增加最优解的搜索空间^[19].此外,Chen 等人^[12]利用神经网络、深度学习模型智能优化物联网拓扑结构,提高了网络拓扑的优化效率.在多目标鲁棒性优化方面,Wang 等人^[26]设计一种由网络属性参数引导的新的并行适配度衡量方法,有效地提高了衡量网络鲁棒性的效率.但是,这些拓扑鲁棒优化方法仍存在一些限制.比如,由于数据隐私保护等原因,不能获取到真实的物联网数据集.对智能优化物联网拓扑结构模型而言,需要带有标签的学习数据集.再者,随着网络规模的增长,现有的优化方法不能实时优化拓扑结构,花费的计算开销与获得的网络拓扑鲁棒提升不成比例,这在资源受限的条件下是不能容忍的.因此,在本文中,为了平衡计算开销和鲁棒提升性能的关系,我们在保证网络拓扑鲁棒能力提升最大的同时,设计轻量级物联网拓扑结构,降低了大规模物联网拓扑优化的计算开销.

2.2 社区发现

社区发现算法^[20]是近年来分析复杂网络的一种重要方法,它能够揭示网络拓扑结构中的一些规律和功能,有助于理解复杂网络的运行规则和机理^[27].一般来说,目前的社区发现算法^[28]根据社区重叠程度可以分为两类:非重叠社区发现(Non-

Overlap Community Detection, NOCD) 和重叠社区发现 (Overlap Community Detection, OCD). 对于 NOCD 来说, 网络中的每个节点都属于一个社区, 每个社区都是相互独立的 (有些边可能不是独立的). 研究者们对网络社区有自己的独特理解, 并基于这些差异的理解提出几种新颖的算法, 包括图划分^[29]、标签传播算法^[30]、模块化算法^[31]、分层聚类算法^[32]等. 然而, 在现实世界中的复杂网络中, 每个节点可能属于不同的社区, 在不同的社区中扮演不同的角色. OCD 更符合现实世界的网络特征. 对于 OCD, 主流算法包括基于动态模型的社区发现算法^[33]、基于网络局部优化的社区发现算法^[34]等. 近年来的一些研究表明, 大规模物联网拓扑是一个异构的复杂结构^[9-10]. 因此, 在本文工作中, 我们只关注节点所属的社区, 而忽略网络的其他部分.

传统的复杂社区发现算法假设大多数节点是独立的, 不同时属于两个社区或多个社区^[35]. 然而, 在现实的物联网应用中, 研究分析节点的多个属性会在优化网络拓扑结构中发现更多的拓扑信息. 比如, Palla 等人^[36]首次提出一种用于 OCD 应用的派系渗透方法. 为了加快社区发现时间, Parés 等人^[21]基于环境中的流体相互作用的思想, 提出了一种具有竞争力、可扩展性和多样性的社区发现算法, 该算法会随着流体的相互作用而扩展和收缩. 在本文中, 我们将网络模体与流体社区发现算法结合, 快速有效地发现大规模物联网拓扑结构中的紧密社区, 并对其分解为多个轻量级网络拓扑结构^[37], 为后续的分布式学习优化模型提供良好的拓扑数据服务.

2.3 深度强化学习

随着智能机器学习技术的兴起, 强化学习技术在智慧城市中有着广泛的应用^[38], 包括链路决策^[39]、路由控制^[40]、交通监控^[41]等. 不同于传统的启发式优化算法, 智能机器学习算法具有优化速度快且易收敛的特点, 在物联网优化方面具有非常多的应用, 是目前物联网研究问题的主要解决手段^[38]. 为了解决之前传统启发式优化算法的搜索空间小、易早熟收敛、迭代量大的缺点, 研究者们探索利用机器学习方法^[11-12]智能优化物联网拓扑结构. 本人的研究团队首次探索利用神经网络来加速优化物联网拓扑结构^[12], 根据已有的标签学习数据, 提取网络拓扑优化过程中的学习特性, 加快了网络拓扑结构的优化效率. 其次, 为了减少对标签学习数据集的依赖, 最新的研究工作^[11]利用深度确定性强化学习方法增加最优解搜索空间, 设计新的网络拓扑表征方式

与新的拓扑结构优化方法, 采用异步式学习模型加快最优解的收敛速度. 异步深度强化学习模型是强化学习方法的应用扩展^[42], 其包含动作网络和评价网络, 分别负责动作选取和评价选取动作的表现. 由于强化学习模型没有网络规模输入的限制, 故充分利用其优势来提高大规模物联网拓扑结构的鲁棒能力. 在本文中, 我们采用分布式深度强化学习机制 (Distributed Deep Reinforcement Learning Mechanism, DDRL) 分别优化每个轻量级物联网拓扑结构, 同时能够处理不同规模社区拓扑结构的输入. 此外, DDRL 具有收敛性^[11]. 为了降低不同社区之间的优化过程中的关联性, 我们采用独立的运算单元分别同时对其进行优化, 并利用两种不同的深度学习模型来训练动作网络和评价网络. 因此, 在本文中, 构建一个适合优化大规模物联网拓扑结构的分布式深度强化学习模型是一项具有挑战性的研究工作.

所提出的 LITOS 模型主要解决现有优化算法不能在可容忍的时间内提高大规模物联网拓扑鲁棒能力的缺点, 从全局优化到局部优化、从集中式优化到分布式优化, 平衡算法运行时间与性能提升之间的关系, 扩展深度强化学习在物联网方面的应用, 为后续的研究探索工作奠定了理论基础.

3 LITOS 模型的建立

在这个部分, 我们主要详细介绍本文 LITOS 模型构建, 包括鲁棒指标、社区发现模型与 DDRL 模型.

3.1 基于网络模体的鲁棒衡量指标

为了能够评估物联网拓扑结构的鲁棒能力, 我们设计了一种基于网络模体的鲁棒衡量指标. 首先定义一个物联网拓扑结构为 $G=(V, E)$, 其中 V 表示网络的节点, E 表示网络的边. 在本文中, 我们假设如果网络中一条边 $e_{uv} \in E$, 那么 $u \neq v$. 每个节点的通信半径定义为 r . 我们用 $D = \frac{E}{V}$ 来表示网络拓扑的边密度, 在本文中网络中每个节点的度数需要保持不变^[18], 维持网络中的基本属性不变. 网络节点 $v \in V$ 的度数表征为该节点的连接数.

网络模体是网络中的一种特定的结构^[15], 一般研究者们主要研究 3 个节点和 4 个节点类型的网络模体^[16]. 在本文中, 我们利用网络模体设计物联网拓扑鲁棒能力衡量指标, 考虑到网络模体在揭示网络局部动态变化与对全局鲁棒优化方面具有重要的功能作用. 采用基于网络模体的鲁棒衡量指标, 关注

点在具有诱导子图性质的重复出现的小的网络结构. 通过统计分析这种网络模体, 能够从局部入手而把握全局网络拓扑的鲁棒性能. 这就是采用网络模体作为鲁棒衡量指标的实际意义. 其次, 之前的基于最大连通片的拓扑优化方法, 因为单一节点的连接关系改变会影响整个拓扑的最大连通子图情况, 所以优化效率较低. 但是, 基于网络模体的拓扑优化方法, 可以利用很小的代价改变局部拓扑关系而不用分析全局拓扑的情况就能够达到优化拓扑鲁棒性的目的. 这也是采用基于网络模体的优势所在.

因此, 在本文中, 定义一个网络模体为 $G' = (V', E')$, 是网络拓扑 G 的一个诱导子图, 该子图具有 $n = |V'|$ 节点, 并需要满足如下条件: (1) 网络模体是一个连通图, 即任意两个节点可达; (2) 网络模体中的任意两个节点都在彼此的通信范围内; (3) $V' \subset V$, $E' \subset E$. 在本文中, 定义如下鲁棒衡量指标:

$$I = \frac{3}{V-2} \sum_{V \geq 3} \frac{MC(k)}{E} \quad (1)$$

其中, $MC(k)$ 表示第 k 轮攻击后, 网络拓扑 G 中所有网络模体包含的边数(去掉重复边), 定义为 motif clique (MC), 如式(2)所示. M_{ij} 表示网络拓扑 G 中的第 i 类型中的第 j 个网络模体.

在本文中, 我们主要考虑两种类型的网络模体, 一个是 3 个节点类型的网络模体, 定义为 M_1 , 另一个是 4 个节点的网络模体, 定义为 M_2 . 网络中的所有网络模体作并集操作, 可以得到 $\bigcup_{i=1}^2 \bigcup_{j=1}^{\eta} M_{ij} \subseteq G$. 因为我们不知道每轮攻击后每一种类型的网络模体的数量有多少, 所以用变量 η 表示. 为了能灵敏的感知网络拓扑的动态变化, 考虑网络中包含的 3 个节点的网络模体 (M_1) 是必要的. M_1 的密度直接影响 MC 的值, 因为网络中包含最多的就是 3 个节点类型的网络模体^[16]. 因为网络数据隐私保护等原因, 我们不能获取网络真实攻击的数据, 所以在本文中, 主要模拟基于度数攻击的方式 (High Degree Attack, HDA). 此外, 网络中的攻击次数 k 是不能够确定的, 因为我们设定的网络攻击停止条件是当网络中没有 3 个节点类型 M_1 的网络模体. 我们将每轮攻击统计的 MC 值累加并归一化, 这样鲁棒衡量指标 I 可以用来比较不同规模的物联网拓扑结构.

$$MC = E \left(\bigcup_{i=1}^2 \bigcup_{j=1}^{\eta} M_{ij} \right) \quad (2)$$

我们需要讨论该指标的合理性与上下界限. 对于一个网络拓扑结构来说, 边密度 D 是影响网络应用鲁棒性的关键因素^[19]. 根据边密度的不同, 我们

分析得出如下定理.

定理 1. 全连接网络拓扑结构的鲁棒性最高, 其鲁棒值为 1, 并具有最高的边密度.

证明. 考虑一个全连接网络拓扑 $G_f = (V_f, E_f)$, 其中 V_f 表示节点, E_f 表示边, 因为 G_f 为全连接网络拓扑结构, 其 V_f 与 E_f 的关系如下:

$$E_f = \frac{1}{2} * V_f * (V_f - 1) \quad (V_f \geq 3) \quad (3)$$

其边密度 $D_f = E_f / V_f = 1/2 * (V_f - 1)$, 该边密度为连通拓扑所具有的最大值. 因此全连接网络拓扑结构 G_f 具有最高的边密度.

此外, 因为 G_f 是全连接网络拓扑结构, 边密度最大, 网络模体浓度最高, 所以其网络鲁棒性最高. 其鲁棒值计算描述如下. 根据本文模拟的最大度数攻击规则 HDA, 网络中的度数最大的节点易受到攻击, 关于全连接网络拓扑 G_f 的鲁棒指标 I_{G_f} 的计算表示如下:

$$\begin{aligned} \Theta_1 &= E_f - (V_f - 1), \\ \Theta_2 &= \Theta_1 - (V_f - 2), \\ &\dots, \\ \Theta_{n-2} &= \Theta_{n-3} - (V_f - (n - 2)) \end{aligned} \quad (4)$$

其中 Θ_1 为攻击第一个节点之后, 网络中存在的所有网络模体组合起来的边数, 即 motif clique $MC(k)$ 统计每轮攻击后的两种类型的网络模体的并集所包含的边数, 如式(4)所示.

鲁棒指标 I_{G_f} 需要统计所有轮攻击的 $MC(k)$ 情况, 如式(5)所示:

$$\begin{aligned} \sum MC(k) &= \Theta_1 + \Theta_2 + \dots + \Theta_{n-2} \\ &= E_f - (V_f - 1) + (\Theta_1 - (V_f - 2)) + \dots + 1 \\ &= \frac{V_f * (V_f - 1) * (V_f - 2)}{6} \quad (V_f \geq 3) \end{aligned} \quad (5)$$

根据鲁棒衡量指标的定义如式(1)所示, G_f 的鲁棒指标 I_{G_f} 为

$$\begin{aligned} I_{G_f} &= \frac{3}{V_f - 2} * \sum \frac{MC(k)}{E_f} \\ &= \frac{3}{V_f - 2} * \frac{2}{V_f * (V_f - 1)} * \frac{V_f * (V_f - 1) * (V_f - 2)}{6} \\ &= 1 \end{aligned} \quad (6)$$

综上证明全连接网络拓扑结构具有最高的边密度, 鲁棒性能最强, 且鲁棒指标为 1. 证毕.

对于边密度最低的网络拓扑结构来说, 我们考虑星型网络, 并有如下定理.

定理 2. 星型网络在所有连通网络里面具有最低的边密度和最小的鲁棒性能, 其鲁棒值为 0.

证明. 考虑一个星型网络拓扑结构 $G_s = (V_s, E_s)$, 并可以得到其边和点的关系, 其 V_s 与 E_s 的关系如下:

$$E_s = V_s - 1 (V_s \geq 3) \quad (7)$$

其边密度 $D_s = E_s/V_s = (V_s - 1)/V_s = 1 - 1/V_s$, 该边密度为一个连通网络拓扑所具有的最小值, 因此星型网络拓扑结构具有最低的边密度.

此外, 因为 G_s 是星型网络拓扑, 边密度最小, 网络模体浓度最低, 所以其网络鲁棒性最小. 其鲁棒值计算如下: 根据本文模拟的最大度数攻击规则 HDA, 首先要攻击网络中度数最大的节点, 又因为星型网络只有一个度数最大的节点, 其他节点度数都为 1. 因此, 当其被攻击后, 该网络就瘫痪了, 不存在任何网络模体, 根据式(2)其 $MC(t)$ 是 0, 同样星型拓扑结构 G_s 的鲁棒指标 I_{G_s} 也是 0.

综上证明星型网络拓扑结构具有最低的边密度, 鲁棒性能最弱, 且鲁棒指标为 0. 证毕.

通过对上述两种不同类型的网络拓扑结构分析, 我们可以得到该鲁棒指标的范围 $I \in [0, 1]$. 随着网络的边密度变化, 网络的鲁棒性在不断的变化. 该指标可以有效地感知网络中连接的动态变化.

3.2 基于网络模体的社区发现模型

社区结构在现实世界网络中是普遍存在的, 比如朋友、联盟、团体及集团等. 在大规模物联网应用中, 也存在着分布广泛的密集社区网络单元. 在这些网络单元之间有着非常重要的和必要的连接. 为了分析这些存在于大规模物联网拓扑中的社区结构信息, 并将其分解为轻量级拓扑结构, 我们初始化 p 个流动社区 $\mathcal{C} = \{c_1, c_2, \dots, c_p\}$, 其中有 $0 < p \leq |V|$, $|V|$ 代表着网络中节点的数量. 每个社区都是随机地从不同的网络顶点开始初始化的. 每个社区都会有一个伴随的密度 d , 该密度初始值为 1.0, 范围为 $(0, 1]$, 指的是社区所包含节点数的倒数, 并定义如下:

$$d(c) = \frac{1}{|v \in c|} \quad (8)$$

其中, $|v \in c|$ 表示 c 社区中的节点数. 需要注意的是, 一个流动社区结构可能只包含一个节点(社区初始化的时候), 那么这种情况下, 我们定义该流动社区的密度具有最大值, 即 $d = 1.0$.

基于网络模体的社区发现模型的工作流程描述如下. 首先, 该模型对网络中的节点随机遍历, 采用社区更新规则对每个节点的归属社区进行更新. 当

在连续两次迭代中, 每个节点所属的社区不在变化时, 该模式收敛并结束运行. 网络中的一个特定节点 v 的更新规则会返回这个节点所在的具有最大聚集密度的一个社区或者几个社区. 更新规则定义如下:

$$C'_v = \arg \max_{c \in \mathcal{C}} \sum_{w \in \{v, \Gamma(v)\}} d(c) \times \delta(c(w), c) \quad (9)$$

其中, v 是需要更新社区的网络节点, C'_v 表示节点 v 的新社区的候选集合, $\Gamma(v)$ 是节点 v 的邻居节点, $d(c)$ 表示社区 c 的密度, $c(w)$ 表示网络节点 w 属于的社区, $\delta(c(w), c)$ 表示 Kronecker delta 并定义如下:

$$\delta(c(w), c) = \begin{cases} 1, & c(w) = c \\ 0, & c(w) \neq c \end{cases} \quad (10)$$

值得注意的是, C'_v 可以包含几个候选社区. 如果 C'_v 包含网络节点 v 的最新社区结构, 那么网络节点 v 不会改变其社区. 但是, 如果 C'_v 没有包含网络节点 v 的最新社区, 那么更新规则会执行一个 FMM 操作 (Find More Motifs, FMM), 让节点 v 加入到一个拥有更多网络模体数量的社区结构中.

首先, 对于 FMM 操作, 我们需要遍历网络拓扑结构每条边获得一个网络模体权重矩阵 \mathcal{W} , 并定义如下:

$$\mathcal{W}_{i,j} = n, \text{ if } e(i,j) \text{ belongs to } n \text{ motifs} \quad (11)$$

其中, $e(i,j)$ 是节点 i, j 的边. 在本文中, 针对社区发现算法, 我们只考虑一种网络模体结构, 即 3 个节点的网络模体 (M_3), 如图 1 所示, 并描述了网络模体权重矩阵的生成过程. 下面具体描述 FMM 操作: 对于 C'_v 没有包含节点 v 最新的社区的情况, 如果 C'_v 里面所有的候选社区的密度 d 是相等的, 那么节点 v 选择并加入其中最大网络模体权重 $\max \mathcal{W}(v)$ 的社区; 如果所有候选社区的密度 d 相等且所有的网络模体权重 $\max \mathcal{W}(v)$ 相等, 那么网络节点 v 随机加入其中一个社区作为其最新的社区. 我们定义 $\max \mathcal{W}(v)$ 是加入节点 v 之后的这些候选社区 C'_v 所包含网络模体的权重值.

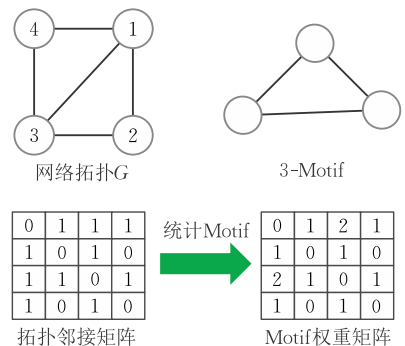


图 1 网络模体权重矩阵的生成

其次,根据定义的 FMM 操作,我们可以给出更新规则的形式化定义:

$$c'(v) = \begin{cases} c(v), & c(v) \in \mathcal{C}'_v \\ \text{FMM}, & c(v) \notin \mathcal{C}'_v \end{cases} \quad (12)$$

其中, $c'(v)$ 是节点 v 下次要更新的社区, \mathcal{C}'_v 是候选社区的集合.当我们随机选择其中一个社区为节点 v 的最新社区时,采用离散均匀分布的随机采样.同时,式(12)保证了在算法迭代过程中没有社区会从图中消失.因为当一个社区 c 被压缩到只有一个节点时,社区 c 根据更新规则会有最大的密度值 $d=1.0$ 保证了社区 $c \in \mathcal{C}'_v$,所以 $c'(v)=c$.

3.3 DDRL 模型的构建

在获得了分解好的轻量级社区结构之后,我们需要将这些社区放入一个分布式深度强化学习模型中,加速网络拓扑结构的优化速度. DDRL 模型的具体框架如图 2 所示.每一个分布式工作单元都会实现一个深度强化学习模型来优化一个单独的社区拓扑结构 c .考虑到网络中一些节点属于不同社区并扮演不同的角色,在本文中,为了能更深层次的优化网络拓扑结构,我们将这些节点组成一个超级社区 S .该超级社区 S 会被另一个工作单元进行优化.最终,当所有工作单元中的学习模型算法收敛后,我们组合这些优化后的社区结构,变成一个具有高鲁棒的大规模物联网拓扑结构.在本文中,我们基于之前的研究工作实现 DDRL^[11].首先我们定义本文中的优化问题如下:

$$\Omega(\theta) = E(r_1 + \rho r_2 + \rho^2 r_3 + \dots | \pi(\cdot, \theta)) \quad (13)$$

其中, r_1 表示第一个动作执行的奖励值, ρ 表示强化学习规则中的折扣因子. $\pi(\cdot, \theta)$ 代表策略函数, θ 表示深度学习神经网络模型的参数. $E(\cdot)$ 是一个期望函数, $\Omega(\theta)$ 表示目标函数,搜索最优的参数 $\pi(\cdot, \theta)$ 并最大化期望函数 $E(\cdot)$.

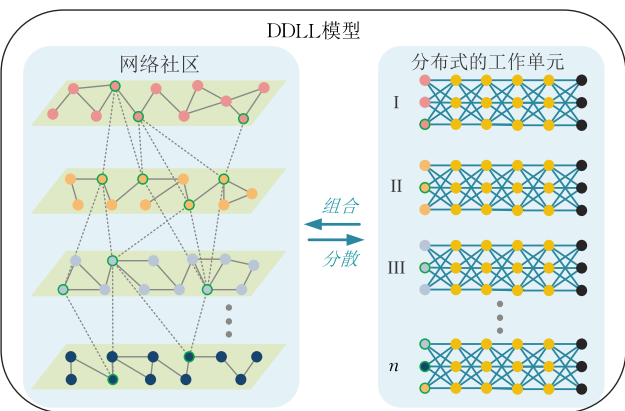


图 2 DDRL 主要框架描述

3.3.1 状态向量格式设计

在真实世界的物联网应用中,每个网络节点都会有其自身的通信范围 r .在本文中,采用真实数据集^[44-45],该数据集来源于电网拓扑结构,经常作为研究网络拓扑结构优化的开源数据集.通常假设节点的通信范围 r 为网络应用中的存在的最长通信距离,可以保证真实数据集中的每条链接关系都是有效的.同时,基于无标度网络模型生成的模拟物联网拓扑结构数据集被应用来验证本文算法的性能.

为了探索拓扑结构的自学习能力,本文中将 DDRL 的状态信息向量输入设置为拓扑环境状态.下面详细描述如何将物联网拓扑结构转换为对应的环境状态向量,如图 3 所示.对于大规模拓扑结构来说,非常有必要减少拓扑结构的存储空间.首先,将拓扑结构转换为一个邻接矩阵,该操作经常在其他物联网应用中使用^[10,19].在本文中,设定物联网拓扑结构是无向连接关系,那么邻接矩阵的上三角部分可以完整表示整个拓扑的信息.通过分析网络拓扑结构与优化动作操作,发现只有在彼此通信范围内的网络节点才可以存在连接关系.因此,在节点通信范围内的其他节点信息具有重要价值.如图 3 所示,节点 a 的上三角关系为 $[1, 0, 0, 1]$,但是因为 a 与 c, d 不在通信范围内,所以有效位置只有 b, e 为 $[1, 1]$;同理, b 节点与节点 d 和节点 e 没有连接关系,所以其有效位置是 c 为 $[1]$; c 节点的有效位置是 d 为 $[0]$; d 节点的有效位置是 e 为 $[1]$, e 节点因为只考虑上三角矩阵,所以没有有效位置.综上所述,最后,拓扑结构按照邻接矩阵的编号顺序链接成为一个环境向量,如图 3 所示为 $[1, 1, 1, 0, 1]$.该向量为 DDRL 模型中的拓扑环境的状态向量,即 DDRL 的状态信息向量,并输入到 DDRL 模型中进行优化操作.




图 3 网络拓扑结构转换为环境向量

3.3.2 回报函数设计

本文主要目的是提升大规模物联网拓扑结构的鲁棒性.因此,DDRL 模型中的回报函数设计,即奖励值设计,与前面论述的物联网拓扑结构鲁棒性衡

量指标 I 有密切关系. 为了得到具有更高鲁棒性的物联网拓扑结构, 回报函数设计如下: 网络拓扑结构状态比上一个拓扑状态的鲁棒性高时, 回报奖励值 r 设置为正值, $+2$, 反之, 回报奖励值 r 设置为负值, -1 . 当前后拓扑状态的鲁棒性没有变化时, 回报奖励值 r 设置为零值. 通过设计该回报函数, DDRL 模型在选取动作时, 倾向于选取网络拓扑结构鲁棒性变大的动作, 提高网络拓扑状态的鲁棒性.

3.3.3 动作-评价网络模型

本文提出的 DDRL 模型算法基于深度确定性策略梯度优化算法 (Deep Deterministic Policy Gradient, DDPG)^[22]. 动作和评价网络模型都是基于深度学习神经网络构建的. 为了更好的解决探索与利用问题 (exploration and exploitation), 动作和评价网络分别拥有两个不同的深度学习神经网络. 对于动作网络模型, 我们定义如下:

$$\mathbf{a}_t = \pi_\theta(s_t | \theta^\pi) \quad (14)$$

其中, \mathbf{a}_t 表示时刻 t 下的确定动作, s_t 表示时刻 t 下的环境状态, 也就是当前拓扑结构状态. θ^π 表示生成确定动作的动作网络的参数. $\pi_\theta(\cdot)$ 是一个最优的动作选择策略, 即根据当前的输入拓扑结构状态 s_t 来对应的输出合适的动作 \mathbf{a}_t .

此外, 评价网络模型需要评价动作网络输出的动作的奖励值是否合理 (s, \mathbf{a}), 并定义如下:

$$Q^\pi(s_t, \mathbf{a}_t) = E[r(s_t, \mathbf{a}_t) + \rho Q^\pi(s_{t+1}, \pi(s_{t+1}))] \quad (15)$$

其中, 评价网络的参数定义为 θ^Q . 根据式 (14), 可得到 $Q^\pi(s_t, \mathbf{a}_t) = Q^\pi(s, \pi(s))$, 表示当拓扑环境在状态 s_t 下利用 π 策略选择了动作 \mathbf{a}_t 时所拥有的奖励期望值. 动作网络产生的动作与当前的环境状态需要依赖评价网络才能计算出即时奖励值.

根据强化学习的框架规则, 真实的奖励值应包含即时奖励值与未来奖励值. 因此, 需要构建另一个目标评价网络 Q' 和目标动作网络 π' , 这两个网络的初始参数与前面提到的评价和动作网络相同. 为了最大化评价网络, 我们基于式 (16) 来最小化网络模型损失并更新该网络模型, 定义如下:

$$\Omega = \frac{1}{n} \sum_{i=0}^n (T_i - Q(s_i, \mathbf{a}_i | \theta^Q))^2 \quad (16)$$

$$T_i = r_i + \rho Q'(s_i, \pi'(s_{i+1} | \theta^{\pi'}) | \theta^Q) \quad (17)$$

其中, T_i 是真实奖励值, 定义如式 (17) 所示. 通过最小化网络损失 Ω , 评价网络参数 θ^Q 会相应更新.

在评价网络更新完成之后, 动作网络也需要相应的修正来产生更好的动作集合, 使得物联网拓扑结构优化具有更好的性能. 动作网络更新规则定义如下:

$$\nabla_{\theta^\pi} \pi \approx E_{\pi'} [\nabla_{\theta^Q} Q(s, \mathbf{a} | \theta^Q) |_{s=s_t, \mathbf{a}=\pi(s_t)} \nabla_{\theta^\pi} \pi(s | \theta^\pi) |_{s_t}] \quad (18)$$

不同于评价网络的更新, 该动作网络模型利用采样策略梯度^[43]来更新网络参数 θ^Q . 然后目标动作和评价网络基于参数 θ^π 和 θ^Q 并利用软更新方法 (soft-update) 分别修正自身网络参数.

3.3.4 动作映射操作

物联网拓扑结构鲁棒性优化是一个复杂的任务, 涉及大量离散优化动作, 导致 DDPG 难以甚至不可能应用. DDPG 善于处理具有连续性动作的应用问题. 因此, 本文中, 我们对离散动作集合进行泛化并将其映射到一个可确定性的连续动作空间中, 这是处理物联网拓扑鲁棒优化任务所必需的. 首先, 定义动作映射操作如下:

$$\mathbb{D}_t = \text{MAP}(\mathbf{a}_t) \quad (19)$$

下面对式 (19) 进行详细说明. 如图 4 所示, 由动作网络 π_θ 产生的确定动作 \mathbf{a}_t 对应于连续空间中的一个值. 首先, 对一个拓扑结构来说, 我们确定其中所包含的离散动作集合, 即可以进行换边操作的组合. 然后, 利用哈希函数对这些离散动作组合生成唯一的有效动作标签. 其次, 这些有效动作标签组合成一个连续动作空间, 方便 DDRL 模型的动作输出. 最后, 当我们确定了需要的输出动作之后, 对物联网拓扑结构进行换边操作, 如图 4 所示, 对一个动作组合来说, 有 3 种不同的换边操作方式.

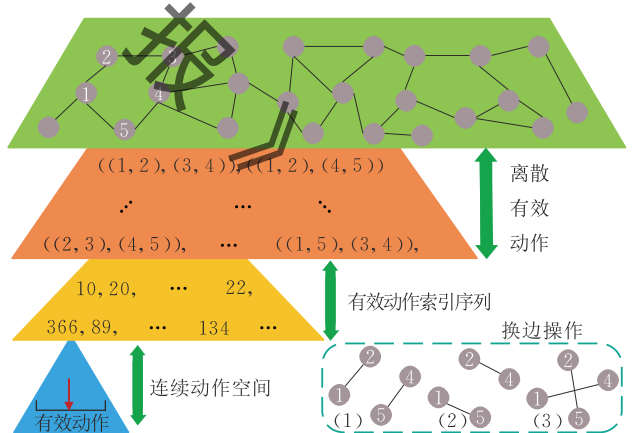


图 4 动作映射操作框架

除了上述内容外, 我们还注意到只有在通信范围内的节点才可以进行换边操作. 由于物联网设备的通信信号的限制, 一些网络节点不能重连其他节点. 因此, 本文中的离散动作集合只包含所有可以互相连接的有效动作组合, 这些节点可以改变原有的连接方式, 重新与其他节点连接. 此外, 动作标签会相应地根据网络拓扑环境状态的变化而更新, 这样

会减少存储与搜索开销. 通过动作映射操作, 包含大量离散动作的物联网拓扑鲁棒优化问题就可以用深度确定性策略来解决了.

4 LITOS 模型的提出

在这部分, 我们提出了 LITOS 模型. 首先, 我们介绍大规模物联网拓扑结构的初始化. 随后, 利用动作映射操作向大规模物联网拓扑优化问题提供良好的动作表示. 然后, 采用社区发现评估方法来分析社区发现的合理性. 再者, 提出 DDRL 模型来提高网络拓扑结构的自学习优化能力. 最后, 我们将所有优化后的社区结构组合成一个具有高鲁棒的大规模物联网拓扑结构.

4.1 拓扑初始化和动作映射

4.1.1 拓扑初始化

我们定义 $G_x(V, E)$ 代表数据集中的第 x 个拓扑结构, 其中 V 和 E 分别表示节点和边的集合. 因为实际数据集的网络节点有坐标位置和通信距离的限制, 超过通信距离范围的节点不能与其他节点连接. 再者, 真实的电网数据拓扑结构^[44-45] 因有线连接方式没有设置一个通信范围. 因此, 在该研究中, 我们利用网络拓扑结构中最长的通信边作为通信半径 r , 并给出形式化定义:

$$r(e) = \arg \max_{e_{ij} \in E} \|e_{ij}\|_{i \neq j} \quad (20)$$

其中, e_{ij} 表示节点 i, j 之间的边, $\|e_{ij}\|$ 表示边 e_{ij} 的距离. 每个拓扑结构的通信范围 r 需分别计算保证所有的连接都是有效的.

在拓扑初始化阶段, 每个拓扑需转换为一个拓扑向量 \mathbf{T}_x . 为了减少拓扑向量存储的冗余信息, 我们只保存每个节点通信范围内的节点信息, 并定义为该节点的候选节点 H :

$$\mathbf{T}_x = [H_1, H_2, \dots, H_n] \quad (21)$$

$$\mathbf{H}_n(i, j) = \begin{cases} 1, & A_{ij} = 1 \\ 0, & \text{其他} \end{cases} \quad (22)$$

其中, \mathbf{H}_n 是节点 n 的通信向量表示, $\mathbf{H}_n(i, j)$ 是该通信向量中的第 j 个位置. A_{ij} 表示的节点 i, j 的连接关系, \mathbf{A} 是该网络拓扑的邻接矩阵, 可由图 3 所示的拓扑转换过程得到.

4.1.2 动作映射操作

考虑初始拓扑结构 $G = (V, E)$, 我们首先获得有效动作空间 V_a 通过搜索所有的连接关系组合. 操作过程 1 描述了动作映射操作的设计细节, 该操作提

高了涉及大量离散动作的优化应用的效率, 如图 4 所示. 算法中使用的变量如下:

- (1) V_a : 网络拓扑结构中的有效动作空间;
- (2) $V_{a_{ind}}$: 有效动作组合的索引;
- (3) $V_{G_{max}}$: 网络拓扑结构中有效动作组合的集合的最大长度.

过程 1. 动作映射操作.

输入: 选择的动作 \mathbf{a}

输出: 离散动作 \mathbb{D}

1. 初始化有效动作空间 AS , 包含网络拓扑 G 的所有节点.
2. 设置有效动作 V_a , 主要存储来自 AS 中的有效动作组合的哈希值.
3. 根据输入的动作 \mathbf{a} 来计算在连续空间中的有效动作的索引, $V_{a_{ind}} = \lfloor \mathbf{a} * V_{G_{max}} \rfloor$.
4. 将 V_a 的长度扩展到 $V_{G_{max}}$.
5. 得到离散动作 $\mathbb{D} \leftarrow AS[V_{a_{ind}}]$.
6. 根据得到的离散动作 \mathbb{D} 更新网络拓扑结构.

算法流程描述如下. 首先, 我们搜索拓扑中的所有可能的动作组合来初始化整个有效动作空间 (第 1 行). 然后, 根据网络拓扑中已存在的边, 设置可以相互交换边的有效动作, 这里主要存储这些有效动作的哈希值 (第 2 行). 为了保持有效动作向量的长度不变, 有效动作向量的长度会扩展到网络拓扑数据集中的有效动作的最大长度, 然后根据输入动作计算离散动作的索引值, 我们得到可相互换边的离散动作组合 (第 3~5 行). 最后, 通过去掉两条连接关系和重新添加两条连接关系, 得到了一个更新后的拓扑结构.

时间复杂度分析. 第 1 行中, 需要对网络拓扑中所有的边进行组合筛选, 换边操作只需要 2 条边, 故该步骤的复杂度为 $O(2^E)$. 第 2 行中, 计算有效动作组合的哈希值的时间复杂度为 $O(1)$. 第 3~5 行中, 我们只是进行了简单数据映射操作, 因此这些步骤的时间复杂度均可在常数时间内完成即 $O(1)$. 综上所述, 该动作映射操作主要在搜寻有效动作组合花费计算资源, 整体计算时间复杂度为 $O(2^E)$. 值得注意的是, 为了降低 LITOS 算法的运行时间, 我们在数据预处理阶段进行动作映射操作, 节省更多的计算资源用于优化网络拓扑结构.

4.2 社区评估

针对社区发现问题, 在本文中, 对划分的社区结构分析评估并判断这些社区是否划分合理. 在社区发现应用中, 研究者们通常用模块度指标来衡量划分社区结构的性能. 在本文中, 我们定义模块度指标

如下：

$$\Psi = \frac{1}{2E} \sum \left[A_{ij} - \frac{k_i k_j}{2E} \right] \delta(c_i, c_j) \quad (23)$$

$$\delta(u, v) = \begin{cases} 1, & \text{when } u = v \\ 0, & \text{其他} \end{cases} \quad (24)$$

其中, A_{ij} 代表节点 i, j 在邻接矩阵中的值, E 表示网络拓扑中的边数, k_i 表示无向网络图中节点 i 的度数, $\frac{k_i k_j}{2E}$ 表征节点 i 连接到节点 j 的概率, $\delta(c_i, c_j)$ 是

一个 Kronecker delta 符号, 即如果节点 i 和节点 j 属于同一个社区, 则 $\delta(c_i, c_j) = 1$, 否则它的值就是 0.

在 LITOS 模型中, 每个划分社区的模块度需要计算, 然后具有最大模块度的社区被选择出来作为 DDRL 模型的输入数据. 计算模块度的详细内容如算法 1 所示.

算法 1. 社区模块度评估.

输入: G

输出: Ψ, C_{best}

1. 初始化 $\Psi_{\text{best}}, C_{\text{best}} \leftarrow 0$
2. $C_{\text{best}} \leftarrow \text{AFC}(G, C_{\text{num}}), \Psi_{\text{best}} \leftarrow \Psi(G, C_{\text{best}})$
3. for i from 1 to Max_{iter} do
4. $C_i \leftarrow \text{AFC}(G, C_{\text{num}})$
5. $\Psi_i \leftarrow \Psi(G, C_i)$
6. if $\Psi_i \geq \Psi_{\text{best}}$ then
7. $\Psi_{\text{best}} \leftarrow \Psi_i$
8. $C_{\text{best}} \leftarrow C_i$
9. end if
10. end for

算法流程描述如下. 首先, 我们初始化最优的模块度 Ψ_{best} 和最优的社区结构 C_{best} 都为 0. 然后, 根据上述式(23)、(24)所示, 可以得到模块度和社区发现的初始最优值(第 2 行), 其中 AFC(Algorithm of Finding Community) 表示社区发现模型功能, 即基于网络模体的社区发现模型算法, C_{num} 表示需要划分的社区数. 为了能更快地选择最优社区结构并提高整个 LITOS 模型的运行效率, 我们重复执行社区模块度评估算法. 最后, 把最优的社区结构且具有最高的模块度值发送给 DDRL 模型来进行优化.

时间复杂度分析: 在这个社区模块度评估算法中, 最重要的是基于网络模体的社区发现模型算法, 即 AFC, 与社区模块度评估方法 Ψ . 关于 AFC, 根据前文的详细描述, 我们需要获取网络拓结构的网络模体权重矩阵, 该操作的最坏情况的复杂度为 $O(3^E)$. 其次, 针对社区发现算法^[21], 需要判断每条边属于哪个社区, 该判断操作可以在线性时间内完

成 $O(E)$. 根据式(23), 模块度评估的时间复杂度为 $O(V)$. 综上所述, 该算法的整体计算时间复杂度为 $O(Max_{\text{iter}} * (E+V))$.

4.3 DDRL 模型与组合操作

算法 2 描述了 DDRL 模型的主要流程, 其目标是增强网络拓扑抵挡网络攻击的鲁棒能力. 具体参数细节设置会在实验性能分析章节详细列出. 该算法使用的变量描述如下:

- (1) RB : 存储先前学习经验的缓冲存储空间;
- (2) $EPISODES$: DDRL 模型的迭代次数;
- (3) $STEPS$: 每一个迭代中的训练次数;
- (4) r_t : 在拓扑结构状态下选择动作 a_t 所获取的奖励值;
- (5) $EXPECT$: 期望提高的鲁棒值;
- (6) M : 设置迭代次数阈值来保证网络拓扑结构已经达到最优状态.

算法 2. DDRL 模型的设计流程.

输入: 初始物联网拓扑结构 G_{ini}

输出: 优化后的物联网拓扑结构 G_{opt}

1. 运行前期操作得到相关数据
2. 获取初始化的 RB
3. for $EPISODES$ do
4. 重启拓扑结构状态 b_t
5. for $STEPS$ do
6. 选择离散动作 D 根据算法过程 1
7. 执行动作和评价网络根据式(18)
8. 将状态 s_t 转换为网络拓扑结构
9. 计算当前拓扑状态的鲁棒值 I_t 根据式(1)
10. $(s_t, a_t, r_t = I_t, s_{t+1}) \rightarrow RB$
11. if $I_t - I > EXPECT$ 且在 M 次迭代中 I_t 没有再变化 then
12. 存储 DDRL 的模型参数
13. end if
14. end for
15. end for

算法流程描述如下. 首先我们基于无标度网络模型生成初始化的物联网拓扑结构, 并初始化 DDRL 模型参数, 执行前期的数据处理阶段(第 1~2 行). 在每一次迭代的过程中, 我们需要重新启动拓扑状态, 即从原始拓扑状态开始优化. 在一次迭代中, 我们首先选择要进行操作的离散动作, 然后根据该动作来更新相对应的动作和评价网络, 最后将更新后的拓扑状态转变为实际的拓扑结构, 并计算当前拓扑状态的鲁棒值(第 6~9 行). 然后, 将当前的学习经验存储到 RB 中, 并开始判断网络拓扑优化是否达到收敛的状态, 如果达到了收敛状态, 即网络鲁棒

能力不再增加,把最终的拓扑信息及网络模型参数都保存。

时间复杂度分析:首先我们初始化 RB ,消耗掉 t_0 时间,第 3~15 行,运行两个循环,循环里面包括,选择离散动作的复杂度为 $O(1)$,动作网络和评价网络的复杂度为 $O(t_a)$ 和 $O(t_c)$,转换网络拓扑结构的时间复杂度为 $O(V)$,即将向量变为网络拓扑邻接矩阵的过程,计算鲁棒值的复杂度为 $O(t_m)$ 。综上所述,该 DDRL 模型的时间复杂度为 $O(EP * STEPS * (t_a + t_c + V + t_m))$,其中 EP 指的是神经网络运行的 $EPISODES$ 数量, $STEPS$ 指的是迭代次数。

5 LITOS 的实验性能分析

5.1 实验参数设置

在本文中,LITOS 模型主要利用真实数据集,其中网络拓扑节点数分别为 200,500,2000。该数据集主要从电网拓扑数据集中获取而来,其特点主要如下:每个节点之间都是通过输电线路连接的,边密度小于 2。充分考虑实际网络部署的经济成本,限定该数据集中的节点的最大传输路径为其中最长的连接线路。其次,为了保证电网系统的稳定运行,利用 LITOS 方法对其进行拓扑结构鲁棒性优化。最后,构建具有高鲁棒的电力网络系统。其次,还有部分模拟的数据集,网络拓扑节点数分别为 200,500,2000。其主要特点如下:每个节点之间的通信范围是固定,且边密度可以任意调节,节点的连接数是固定的。其次,每张拓扑结构的度数分布是不改变的。再者,通过大量实验表明针对不同的拓扑结构,选择不同数量的异步计算单元可以大幅度降低优化算法的运行时间,提高鲁棒提升效率。此外,其他实验参数如表 1 所示,这些参数是经过大量重复实验确定的。

表 1 实验参数设置

符号	符号描述	参数设置
C_{num}	网络拓扑结构需要发现的社区数	6~16
ρ	折扣因子	0.9
d	社区发现算法中的初始密度值	1.0
$Layers_a$	动作网络的神经网络层数	20
$Layers_c$	评价网络的神经网络层数	20
U_a	动作网络的每层神经元个数	100
U_c	评价网络的每层神经元个数	100

此外,本文中的实验结果都是经过 20 次独立重复实验而得到的平均值。

5.2 社区发现结构分析

如图 5 所示,我们对真实电网数据集进行 6 个

社区的发现操作。大部分节点活动在自己的内部社区,少部分节点具有跨社区活动。因此,除了正常的 6 个独立社区外,为了进一步加快优化效率,在本文中设置一个超级社区,包含所有具有跨社区活动的节点。该真实电网数据集具有 200 个节点,246 条边,边密度 $D=1.23$,社区发现的模块度 $\Psi=0.7308$ 。本文利用社区发现的方法,充分挖掘计算资源的多核并行处理能力,提高网络拓扑结构优化效率,平衡优化时间开销与鲁棒提升。针对超大规模拓扑进行社区发现之后,LITOS 对每个社区进行拓扑优化,但还存在一些社区间的节点和边没有进行优化操作,而且这些节点和边具有重要的社区间连接作用,因此对其优化能够显著提升整体拓扑的鲁棒性。为了区别与之前的社区划分,将社区间的节点组成一个超级社区,并放入对应的学习计算单元中进行拓扑优化,采用分布式异步深度强化学习策略,在优化拓扑鲁棒性的同时降低拓扑优化的运行时间。依据已有的研究工作表明^[21],本文中的社区发现算法的收敛性良好,随着社区发现数量的变化,算法迭代次数变化波动不大。




图 5 真实电网数据结构划分为 6 个独立社区以及 1 个超级社区,200 节点,246 条边,其模块度为 0.7308

5.3 社区模块度实验分析

为了评估社区发现是否合理,本文中,我们重复 100 次社区发现算法,根据式(23)选取其中社区评估值最好的一组社区发现结果作为后续轻量级拓扑优化的数据基础。如表 2 所示,我们比较了不同社区发现数量情况下的不同拓扑数据集的模块度评价指标。从表中可以看出来,真实数据集的 Ψ 值比模拟数据的 Ψ 高。真实数据集的 Ψ 波动范围为(0.73, 0.84),模拟数据集的 Ψ 波动范围为(0.49, 0.54)。分析其原因为真实数据集是稀疏网络,网络的社区

属性容易划分;模拟数据集为密集网络,网络的社区属性多样,较难划分.每个数据集中的最大值 Ψ 均加粗显示.结合表 2 分析得知,在真实数据集中,具有最大值 Ψ 的社区发现数量,LITOS 优化时间一般比较低,同时鲁棒提升能力不是最差的.同理,在模拟数据集中,LITOS 的运行时间一般比较低,同时鲁棒优化能力非常高.综上所述,我们可以看出来,网络评估指标与 LITOS 策略的优化时间与网络拓扑的鲁棒提升能力具有一定的关系.本节实验证明设计的社区评估指标对提升网络拓扑鲁棒能力和降低优化时间具有重要的指导意义.此外,本文中的轻量级优化指的是针对超大规模的网络拓扑结构,利用高效的社区发现算法将其划分为较小的网络拓扑结构,采用分布式优化算法分别同时对每个较小的网络拓扑结构进行优化操作,大幅度降低优化操作的计算运行时间.再者是在优化操作过程中,采用高效的异步深度强化学习模型^[11],摒弃了传统的启发式优化算法,充分利用学习模型带来的运行效率优势,加速对较小拓扑结构的优化操作.

表 2 不同拓扑数据集的模块度评价情况

社区发现数量	拓扑数据集					
	真实数据集			模拟数据集		
	V=200	V=500	V=2000	V=200	V=500	V=2000
C=6	0.7308	0.7751	0.7922	0.5357	0.5199	0.4964
C=7	0.7490	0.7941	0.8035	0.5216	0.5208	0.5019
C=8	0.7624	0.7985	0.8064	0.5252	0.5210	0.5071
C=9	0.7638	0.8152	0.8138	0.5203	0.5219	0.5078
C=10	0.7796	0.8122	0.8208	0.5218	0.5221	0.5101
C=11	0.7735	0.8204	0.8247	0.5239	0.5223	0.5084
C=12	0.7735	0.8209	0.8307	0.5076	0.5182	0.5091
C=13	0.7784	0.8247	0.8266	0.5064	0.5163	0.5165
C=14	0.7715	0.8210	0.8323	0.5116	0.5179	0.5099
C=15	0.7760	0.8242	0.8315	0.5000	0.5179	0.5122



(a) 模拟数据集200节点, $D=2, I=0.2237$ (b) 模拟数据集200节点, $D=2, I=0.2810$

图 6 网络拓扑结构优化前后的可视化对比分析

为了进一步验证拓扑优化前后的度数分布保持不变,如图 7 所示,我们对模拟物联网拓扑结构的度数分布进行了统计,发现其满足无标度网络模型的度数幂律分布,保持了良好的抵抗随机攻击的鲁棒能力.

5.4 网络拓扑结构前后优化对比

如图 6 所示,在该小节中,我们对模拟数据集的拓扑结构进行可视化分析,比较其优化前后的网络度数分布情况,更直观地观察网络拓扑优化的变化规律.该物联网拓扑结构数据集采用 Fruchterman Reingold 算法进行可视化布局,不同度数的节点标注不同的颜色.该模拟数据集的规模为 200 节点,边密度为 $D=2$,初始拓扑结构的鲁棒性指标为 $I=0.2237$,从图 6(a)中可以看出,少部分节点的度数比较大,大部分节点的度数都比较小,符合最初的无标度网络模型的特性.从图 6(b)中,优化后的拓扑可以看出,拓扑鲁棒能力提升到了 $I=0.2810$,且无标度特性并没有变化.




图 7 模拟拓扑结构满足无标度网络模型的度数幂律分布

5.5 不同数据集的拓扑优化对比

为了比较不同的社区发现数量对不同的拓扑数据集的影响,该小节中,社区发现数量从 6 至 15,每次实验独立重复 20 次,每次实验选取最优结果,如图 8 所示.为了扩展 LITOS 优化策略的应用范围,本文中分别验证真实电网数据集与模拟数据集的优化时间与鲁棒提升效率.优化时间指的是社区拓扑

结构的优化时间,不包括社区发现的运行时间.鲁棒提升指的是拓扑优化前后的鲁棒能力提升的百分比.从图(a)至(f)看来,社区发现数量越大不一定能提升拓扑优化的运行时间,也不一定更能提升网络拓扑结构的鲁棒能力.所以,根据不同的拓扑数据集,我们需要慎重选择优化方案,平衡优化时间和鲁棒提升效率.

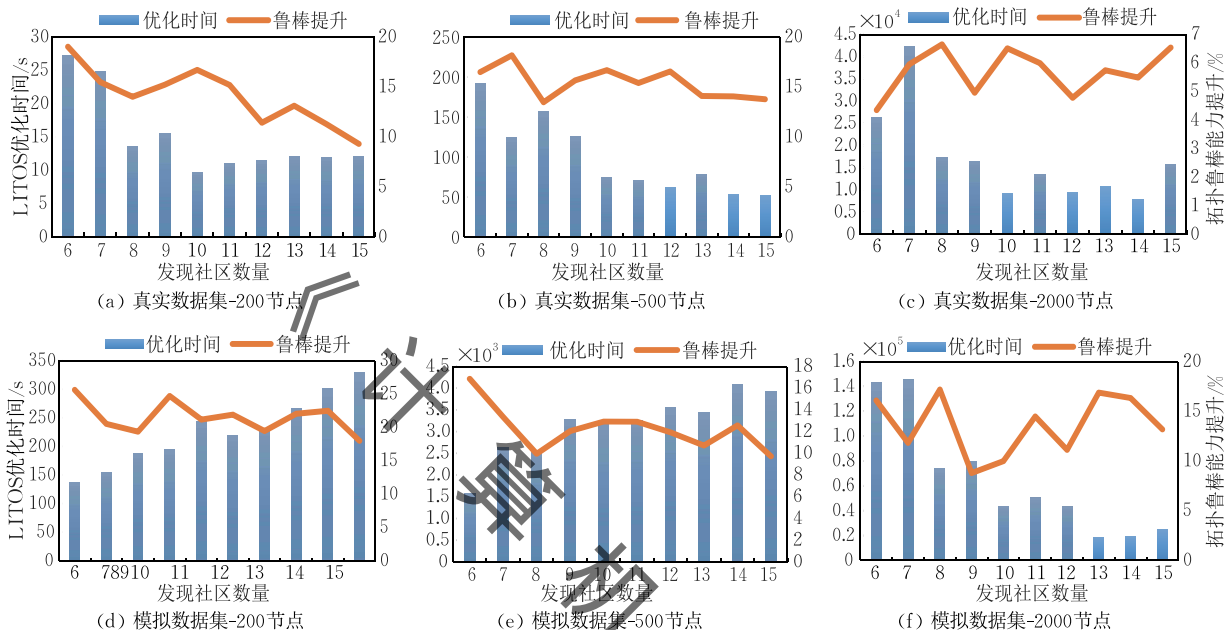


图 8 不同社区发现数量下的算法优化时间与鲁棒提升对比

从真实数据集角度看,随着社区发现数量的增加,算法优化时间在慢慢降低.200 节点的电网数据集,随着社区数量的增加,鲁棒提升能力在下降,优化时间同时也在降低.分析原因是随着社区发现数量的增加,节点分布过于分散,且分布式优化算法缺乏统一协调,具有很大的随机性,导致整体拓扑结构的鲁棒能力在下降.500 节点的电网数据集,随着社区发现数量的增加,算法优化时间在下降,同时鲁棒提升能力在波动,下降趋势不明显.分析原因是节点分布较分散,LITOS 策略在优化社区内部拓扑结构具有优势.2000 节点的电网数据集随着社区发现数量的增加,优化时间在逐步下降,鲁棒提升效率在波动上升.分析原因是,节点分布较均匀,本文算法能够有效地改变拓扑连接关系,提升网络拓扑鲁棒能力.

从模拟数据集角度看,该节实验中所用的拓扑数据集的边密度 $D=2$,随着社区发现数量的增加,优化时间在上升,鲁棒提升能力在波动.分析原因是,真实的拓扑数据集是稀疏网络,我们模拟的数据集是超密集网络,部署在 $500 \times 500 \text{ m}^2$ 的监测区域中.从图中可以看到,LITOS 的分布式优化能力在社区发现数量较低的时候,具有很强的鲁棒提升能

力.分析原因是节点分布较集中,单个独立社区的拓扑优化对整体拓扑的影响较大.不同的拓扑数据集,适合的社区发现数量是不同的.

5.6 不同边密度的网络拓扑鲁棒提升分析

在本节中,为了进一步地验证 LITOS 策略对不同边密度的网络拓扑结构的优化能力,我们采用 6 个社区发现数量,利用不同边密度的网络拓扑结构,如 200 节点,300 节点,500 节点,边密度 D 分别为 (3,4,5,6),其中这些节点都部署在 $500 \times 500 \text{ m}^2$ 的监测区域内.如图 9 所示,y-轴是网络拓扑的鲁棒提升百分比,x-轴是网络的边密度,从图中我们可以看到随着网络的边密度增大,网络的鲁棒提升能力在下降,尤其是 200,500 节点的网络拓扑结构.针对 300 节点的异常情况,分析原因是节点在每个社区中分布较均匀,使得 LITOS 具有良好的优化性能.此外,如表 3 所示,我们还比较了 LITOS 对不同边密度的网络拓扑结构的优化时间.随着边密度上升,优化时间也在上升,其次随着网络规模的增大,算法优化时间开销也在增大.同时,我们观察到,边密度的增大会导致优化时间成指数级的增长,但是网络拓扑鲁棒能力的提升百分比是在下降.综上所




图9 不同边密度的网络拓扑鲁棒提升情况

表3 LITOS 优化时间 (单位:s)

	200 节点	300 节点	500 节点
$D=3$	608.1647	984.3339	6130.3474
$D=4$	980.6369	3922.6555	16742.6391
$D=5$	5499.9528	6766.1961	33519.3360
$D=6$	5527.3748	22421.9191	50680.8818

述,LITOS 算法能够在可容忍的计算开销内提升密集网络拓扑的鲁棒能力。

5.7 LITOS 与其他算法的对比分析

在本节中,为了进一步验证 LITOS 在优化效率上的性能,我们主要对比已有的传统网络拓扑鲁棒优化算法,比如 ROSE^[20]、ROCKS^[21],如表 4 所示。

表4 比较不同的优化算法

	鲁棒提升百分比/%			算法优化运行时间/s			单位时间内鲁棒提升情况		
	ROSE	ROCKS	LITOS	ROSE	ROCKS	LITOS	ROSE	ROCKS	LITOS
$V=200$	31.6003	17.7904	25.6178	2571.4201	7025.8115	136.4441	0.0123	0.0025	0.1878
$V=300$	41.5658	13.7685	15.8538	10849.3187	26395.2822	144.8850	0.0038	0.0005	0.0353
$V=500$	37.6733	147.9737	16.8532	209765.4330	110309.5506	1568.8442	0.0002	0.0013	0.0107

6 结 论

在本文中,针对大规模的密集物联网拓扑结构优化,我们提出了基于网络模体的 LITOS 轻量级拓扑优化算法,创新性地设计了新的社区发现方法、社区评估指标,利用异步深度强化学习设计了学习模型与优化算法等。LITOS 在稀疏的真实网络数据集与密集的模拟网络数据集上均能降低计算开销,并提高网络的鲁棒能力。针对不同密集程度的网络拓扑结构,LITOS 可以在可容忍的时间开销内得到结果,对比其他之前的拓扑优化算法,该算法能平衡优化性能与计算开销,从而为大规模的超密集网络拓扑优化提供了解决思路。

在未来的工作中,我们将继续关注大规模超密

列出了网络拓扑结构的鲁棒提升百分比(%)、算法优化运行的计算时间(s)以及单位时间内的拓扑结构鲁棒提升情况。在实验设置中,所有算法的迭代次数相同、输入拓扑结构数据相同、运行机器相同。因为 ROSE 与 ROCKS 算法随着网络规模的增大,计算开销指数级增长,为了节省更多的计算资源,没有必要在其他大规模的网络拓扑结构上进行实验,我们同样也可以从其他密集物联网拓扑结构中得到相同的结论。即 LITOS 能够平衡网络拓扑结构的鲁棒提升能力与算法优化时间,并且单位时间内的鲁棒提升能力最高。在 $V=200$ 拓扑结构数据集中,ROSE 具有最大的鲁棒提升能力,LITOS 在单位时间内鲁棒提升的能力是其他两种算法的 10~100 倍。在 $V=300$ 拓扑结构数据集中,ROCKS 具有最小的鲁棒提升能力且运行时间最长,这是因为其主要基于遗传算法来优化拓扑结构。在 $V=500$ 拓扑结构数据集中,ROCKS 具有最好的鲁棒提升能力,原因是遗传算法在优化大规模网络拓扑结构上具有优势^[19]。从整体上来看,LITOS 的鲁棒提升能力处于中间水平,但是运行时间比其他两种算法降低了 1~2 个数量级,单位时间内鲁棒提升能力提高了 10~100 倍。

集物联网拓扑优化问题。本文提出的算法随着网络规模增大的同时,计算网络拓扑结构的鲁棒指标会变得困难,因为我们使用独立的计算能力低的 CPU 核心。因此,如何降低计算整体网络拓扑结构的鲁棒指标的复杂度,成为是否能进一步降低大规模物联网拓扑结构的优化时间的关键。我们将探索每个社区计算自身网络拓扑结构的鲁棒指标,然后用简单的数学方法组合这些数值来代表整体网络的鲁棒能力。

参 考 文 献

- [1] Feng Deng-Guo, Xu Jing, Lan Xiao. Study on 5G mobile communication network security. Journal of Software, 2018, 29(6): 1813-1825(in Chinese)
(冯登国,徐静,兰晓. 5G 移动通信网络安全研究. 软件学

- 报, 2018, 29(6): 1813-1825)
- [2] Qadri Y A, Nauman A, Zikria Y B, et al. The future of healthcare Internet of Things: A survey of emerging technologies. *IEEE Communications Surveys & Tutorials*, 2020, 22(2): 1121-1167
- [3] Zhou W, Jia Y, Peng A, et al. The effect of IoT new features on security and privacy: New threats, existing solutions, and challenges yet to be solved. *IEEE Internet of Things Journal*, 2018, 6(2): 1606-1616
- [4] Wang Chen-Yu, Wang Ding, Wang Fei-Fei, et al. Multi-factor user authentication scheme for multi-gateway wireless sensor networks. *Chinese Journal of Computers*, 2020, 43(4): 683-700(in Chinese)
(王晨宇, 汪定, 王菲菲等. 面向多网关的无线传感器网络多因素认证协议. *计算机学报*, 2020, 43(4): 683-700)
- [5] Xu Chuan, Ding Ying-Yi, Luo Li, et al. Personalized location privacy protection for location based services in vehicular networks. *Journal of Software*, 2022, 33(2): 699-716 (in Chinese)
(徐川, 丁颖祎, 罗丽等. 车联网中基于位置服务的个性化位置隐私保护. *软件学报*, 2022, 33(2): 699-716)
- [6] Xu Jiu-Qiang, Guo Xue-Jing, Wang Jin-Fa, et al. Research on CPS resource service model and resource scheduling. *Chinese Journal of Computers*, 2018, 41(10): 2330-2343(in Chinese)
(徐久强, 郭雪静, 王进法等. CPS资源服务模型和资源调度研究. *计算机学报*, 2018, 41(10): 2330-2343)
- [7] Dey A K, Gel Y R, Poor H V. What network motifs tell us about resilience and reliability of complex networks. *Proceedings of the National Academy of Sciences*, 2019, 116(39): 19368-19373
- [8] Yang Yi-Yu, Zhou Wei, Zhao Shang-Ru, et al. Survey of IoT security research: Threats, detection and defense. *Journal on Communications*, 2021, 42(8): 188-205(in Chinese)
(杨毅宇, 周威, 赵尚儒等. 物联网安全研究综述: 威胁, 检测与防御. *通信学报*, 2021, 42(8): 188-205)
- [9] Li Wen-Feng, Fu Xiu-Wen. Survey on invulnerability of wireless sensor networks. *Chinese Journal of Computers*, 2015, 38(3): 625-647(in Chinese)
(李文锋, 符修文. 无线传感器网络抗毁性. *计算机学报*, 2015, 38(3): 625-647)
- [10] Chen N, Qiu T, Lu Z, et al. An adaptive robustness evolution algorithm with self-competition and its 3D deployment for Internet of Things. *IEEE/ACM Transactions on Networking*, 2021, 30(1): 368-381
- [11] Chen N, Qiu T, Mu C, et al. Deep actor-critic learning-based robustness enhancement of Internet of Things. *IEEE Internet of Things Journal*, 2020, 7(7): 6191-6200
- [12] Chen N, Qiu T, Daneshmand M, et al. Robust networking: Dynamic topology evolution learning for Internet of Things. *ACM Transactions on Sensor Networks (TOSN)*, 2021, 17(3): 1-23
- [13] Herrmann H J, Schneider C M, Moreira A A, et al. Onion-like network topology enhances robustness against malicious attacks. *Journal of Statistical Mechanics: Theory and Experiment*, 2011, 2011(1): 1-10
- [14] Rong L, Liu J. A heuristic algorithm for enhancing the robustness of scale-free networks based on edge classification. *Physica A: Statistical Mechanics and Its Applications*, 2018, 503: 503-15
- [15] Milo R, Shen-Orr S, Itzkovitz S, et al. Network motifs: Simple building blocks of complex networks. *Science*, 2002, 298(5594): 824-827
- [16] Milo R, Itzkovitz S, Kashtan N, et al. Superfamilies of evolved and designed networks. *Science*, 2004, 303(5663): 1538-1542
- [17] Roy S, Raj M, Ghosh P, et al. Role of motifs in topological robustness of gene regulatory networks//*Proceedings of the 2017 IEEE International Conference on Communications (ICC)*. Paris, France, 2017: 1-6
- [18] Qiu T, Zhao A, Xia F, et al. ROSE: Robustness strategy for scale-free wireless sensor networks. *IEEE/ACM Transactions on Networking*, 2017, 25(5): 2944-2959
- [19] Qiu T, Liu J, Si W, et al. Robustness optimization scheme with multi-population co-evolution for scale-free wireless sensor networks. *IEEE/ACM Transactions on Networking*, 2019, 27(3): 1028-1042
- [20] Jia J, Wang B, Cao X, et al. Certified robustness of community detection against adversarial structural perturbation via randomized smoothing//*Proceedings of the Web Conference (WWW)*. Taiwan, China, 2020: 2718-2724
- [21] Parés F, Gasulla D G, Vilalta A, et al. Fluid communities: A competitive, scalable and diverse community detection algorithm//*Proceedings of the International Conference on Complex Networks and their Applications*, Springer, Cham, 2017: 229-240
- [22] Mnih V, Badia A P, Mirza M, et al. Asynchronous methods for deep reinforcement learning//*Proceedings of the International Conference on Machine Learning (PMLR)*. New York, USA, 2016: 1928-1937
- [23] Hao Y, Jia L, Wang Y. Edge attack strategies in interdependent scale-free networks. *Physica A: Statistical Mechanics and Its Applications*, 2020, 540: 122759
- [24] Zhao T, Si W, Li W, et al. Optimizing the maximum vertex coverage attacks under knapsack constraint. *IEEE/ACM Transactions on Networking*, 2021, 29(3): 1088-1104
- [25] Zhou M, Liu J. A memetic algorithm for enhancing the robustness of scale-free networks against malicious attacks. *Physica A: Statistical Mechanics and Its Applications*, 2014, 410: 131-143
- [26] Wang S, Liu J, Jin Y. A computationally efficient evolutionary algorithm for multiobjective network robustness optimization. *IEEE Transactions on Evolutionary Computation*, 2021, 25(3): 419-432

- [27] Magnani M, Hanteer O, Interdonato R, et al. Community detection in multiplex networks. *ACM Computing Surveys*, 2021, 54(3): 1-35
- [28] Jin D, Yu Z, Jiao P, et al. A survey of community detection approaches: From statistical modeling to deep learning. *IEEE Transactions on Knowledge and Data Engineering*, 2021, DOI: 10.1109/TKDE.2021.3104155
- [29] Fortunato S. Community detection in graphs. *Physics Reports*, 2010, 486(3): 75-174
- [30] Raghavan U N, Albert R, Kumara S. Near linear time algorithm to detect community structures in large-scale networks. *Physical Review E*, 2007, 76(3): 036106
- [31] Newman M E. Analysis of weighted networks. *Physical Review E*, 2004, 70(5): 056131
- [32] Adhikari D, Jiang W, Zhan J, et al. A comprehensive survey on imputation of missing data in Internet of Things. *ACM Computing Surveys*, 2022, 55(7): 1-38
- [33] Shang J, Liu L, Li X, et al. Targeted revision: A learning-based approach for incremental community detection in dynamic networks. *Physica A: Statistical Mechanics and Its Applications*, 2016, 443: 70-85
- [34] Huang L, Wang C. D, Chao H. Y. HM-Modularity: A harmonic motif modularity approach for multi-layer network community detection. *IEEE Transactions on Knowledge and Data Engineering*, 2019, 33(6): 2520-2533
- [35] Su X, Xue S, Liu F, et al. A comprehensive survey on community detection with deep learning. *IEEE Transactions on Neural Networks and Learning Systems*, 2022: 1-21. DOI:10.1109/TNNLS.2021.3137396
- [36] Palla G, Derényi I, Farkas I, et al. Uncovering the overlapping community structure of complex networks in nature and society. *Nature*, 2005, 435(7043): 814-818
- [37] Qian Ai-Juan, Fan Xin, Dong Xiao-Ju, et al. Network anomaly detection method based on community detection. *Chinese Journal of Computers*, 2022, 45(4): 825-837 (in Chinese)
(钱爱娟, 樊昕, 董笑菊等. 基于社区发现的网络异常检测方
法. *计算机学报*, 2022, 45(4): 825-837)
- [38] Haarnoja T, Tang H, Abbeel P, et al. Reinforcement learning with deep energy-based policies//*Proceedings of the International Conference on Machine (ICML) Learning*. Sydney, Australia, 2017: 1352-1361
- [39] Zhang S, Yin B, Zhang W, et al. Topology aware deep learning for wireless network optimization. *IEEE Transactions on Wireless Communications*, 2022, 21(11): 9791-9805
- [40] Tang F, Mao B, Kawamoto Y, et al. Survey on machine learning for intelligent end-to-end communication toward 6G: From network access, routing to traffic control and streaming adaptation. *IEEE Communications Surveys & Tutorials*, 2021, 23(3): 1578-1598
- [41] Ke Q, Sika J, Wiczorek M, et al. Deep neural network heuristic hierarchization for cooperative intelligent transportation fleet management. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(9): 16752-16762
- [42] Gu S, Holly E, Lillicrap T, et al. Deep reinforcement learning for robotic manipulation with asynchronous off-policy updates//*Proceedings of the 2017 IEEE International Conference on Robotics and Automation (ICRA)*, Marina Bay Sands, Singapore, 2017: 3389-3396
- [43] Silver D, Lever G, Heess N, et al. Deterministic policy gradient algorithms//*Proceedings of the International Conference on Machine Learning (ICML)*. Beijing, China, 2014: 387-395
- [44] Birchfield A B, Xu T, Gegner K M, et al. Grid structural characteristics as validation criteria for synthetic networks. *IEEE Transactions on Power Systems*, 2016, 32(4): 3258-3265
- [45] Birchfield A B, Gegner K M, Xu T, et al. Statistical considerations in the creation of realistic synthetic power grids for geomagnetic disturbance studies. *IEEE Transactions on Power Systems*, 2016, 32(2): 1502-1510
- [46] Qiu T, Chen N, Zhang S. *Robustness Optimization for IoT Topology*. Singapore: Springer Verlag, 2022



CHEN Ning, Ph.D. candidate. His research interest is robustness optimization of IoT topology.

QIU Tie, Ph.D., professor. His current research interests include IoT, smart city and mobile computing, and smart big data analysis.

GUO De-Ke, Ph.D., professor. His research interests include network computing and systems, distributed computing systems, software defined networks, big data analysis and process, and mobile computing.

XU Tian-Yi, Ph.D. candidate. His research interests include the IoT and Blockchain.

Background

5-Network topology optimization^[46] is an emerging research work for the Internet of Things (IoT)^[2], aiming at improving the quality of service and robustness resisting cyber-attacks for complex network applications^[3]. With the development of IoT technology, the network scale is getting larger, more than 7.5 billion devices will join the network by 2025^[3]. The extending of the network scale not only creates valuable network applications but also rises the paralyzing risks^[10]. Therefore, how to optimize the IoT topology to maintain the communication ability and prolong the life when it encounters attacks, is a challenge to be solved^[46].

Most existing topology optimization algorithms^[18-19] generally focus on the global characteristics of networks, such as node degree distribution, maximum connected subgraph, centrality, etc^[46]. Besides, several optimization methods apply maximum connected subgraph as a robustness metric to guide the optimization direction^[7]. Real complex network applications consist of many types of networks, which are with different robustness abilities^[11-12,14]. Existing algorithms^[11-12] are hard to uniformly optimize these heterogeneous network topology. Another shortcoming is that these algorithms use numerous extra computing resources to obtain an un-proportion robustness improvement^[46].

In this paper, we introduce a Light Topology Optimization

Strategy based on network motif (LITOS) for large-scale heterogeneous IoT that overcome some of the above-mentioned caveats of the existing methods. We start by emphasizing that the notion of network robustness is not uniquely defined, and objective validation of vulnerability might require some ground-truth data on network behavior under attacks and failures, which are typically unavailable in many real-world scenarios due to, for example, data privacy and confidentiality. Nevertheless, we argue that a networks' robustness can be quantified in terms of its ability to maintain its original properties — e. g., network motifs^[15-16]. In this paper, inspired by community detection^[21], we first divide the large-scale heterogeneous IoT network into several close communities. Then, a distributed deep reinforcement learning (DDRL) mechanism is implemented to optimize the communities. Finally, the optimized communities are assembled to a high robustness network which is executed with less computing overhead.

This work is supported by the National Key R&D Program of China (No. 2019YFB1703601), the Joint Funds of the National Natural Science Foundation of China (No. U2001204), the National Natural Science Foundation of China (No. 62272339), and the Tianjin Research Innovation Project for Postgraduate Students (No. 2021YJSB108).