



集群无人系统自适应结构建模与预测

张婷婷^{1,2,3*}, 宋爱国^{2*}, 蓝羽石³

1. 中国人民解放军陆军工程大学指挥控制工程学院, 南京 210017

2. 东南大学仪器科学与工程学院, 南京 210017

3. 中国电子科技集团公司第二十八研究所, 南京 210017

* 通信作者. E-mail: 101101964@seu.edu.cn, a.g.song@seu.edu.cn

收稿日期: 2019-08-25; 接受日期: 2019-09-13; 网络出版日期: 2020-02-25

国家自然科学基金 (批准号: 61802428, 61906086)、中国博士后科学基金 (批准号: 2019M651991)、军委科技委国防科技项目基金 (批准号: 3602026) 和陆军装备科研项目 (批准号: KYZYJWJK1702) 资助

摘要 集群无人系统是近年来国内外军事领域的研究重点, 正在推动无人作战样式由“单平台遥控作战”向“智能集群作战”发展, 支撑作战系统在不确定任务和环境下具备协同、自主、灵活的特性. 集群的整体性能取决于其成员系统及成员之间的相互关系, 且随时间、环境变化而动态演化, 系统间交互涌现出新智能. 本文从集群无人系统结构演化机理入手, 构建集群无人系统从底层链路到集群系统再到任务需求的三级结构与关系模型, 并用图神经网络将多维空间关系模型转化为二维的图表示模型, 构建出集群无人系统中系统之间以及层级之间的关系依赖图. 整个图网络以任务为标准分类, 提出了用递归神经网络描述层内关系和层间关系的方法, 并给出了实现算法, 利用训练数据集基于任务的节点属性标签, 对集群无人系统的结构进行预测. 以此为基础, 可以进一步实现对结构依赖关系的权重参数学习, 得到系统或链路损坏对任务层的影响, 实现集群无人系统从作战任务到集群结构的自主决策.

关键词 集群无人系统, 自适应结构, 图神经网络, 演化, 智能涌现, 结构预测

1 引言

集群无人系统 (swarm unmanned system, SUS) 可以看作是一个“网络-物理-智能”的系统^[1], 不单单是固定组件的集合, 而是由传感器、计算机、通信设备和智能执行单元组成的系统, 用于执行实现特定任务目标的任务. 这些系统通常允许其他系统、设备和数据流在执行任务期间根据需要连接/断开连接, 其网络结构动态可变, 形成自适应系统. 最大的特性是涌现性和演化性, 可以实现自组织、自适应和重构机制, 能够达到优良的抗毁性和弹性. “执行单元”在该系统中的角色也是与传统系统有所不同, 不再是完全受控制的角色, 而是有自学习和自演化的功能, 与其他网络物理元素协作, 共同完成

引用格式: 张婷婷, 宋爱国, 蓝羽石. 集群无人系统自适应结构建模与预测. 中国科学: 信息科学, 2020, 50: 347-362, doi: 10.1360/SSI-2019-0180
Zhang T T, Song A G, Lan Y S. Adaptive structure modeling and prediction for swarm unmanned system (in Chinese). Sci Sin Inform, 2020, 50: 347-362, doi: 10.1360/SSI-2019-0180

任务, 并适应不断变化的环境来完成任务目标^[2]. 集群无人系统通过自适应地连接结构调整来应对环境、任务的变化. 因此, 了解集群结构演变至关重要, 系统结构决定了系统的功能, 通过对结构演变的建模与分析, 对演化结果进行预测, 为体系构建提供参考依据. 集群无人系统组件众多, 地域分布广、系统之间信息交互频繁, 由独立的智能系统组合而成, 如果采用线性方法进行描述, 会造成描述空间爆炸. 同时, 如果仅描述系统之间的连接关系, 没有空间结构的依赖关系、节点的特征属性、时间上的结构演化, 就无法预测系统结构的改变应对的系统能力的改变. 集群无人系统是一种具有复杂动态特性的大型复杂系统, 每个无人系统作为一个智能体必须依据不断变化的态势并依据一定的准则调整自己的策略, 比如个体之间的合作、与对方的博弈等. 因此, 在充分分析无人集群演化过程特点及其内涵的基础上, 理解集群无人系统对抗的非线性动态过程演化机制, 利用系统动力学和复杂系统理论建立各种因素的相互作用以及信息传递关系的系统架构, 有利于对无人系统对抗过程的定量和定性分析. 比如分析集群无人系统在高对抗战场环境下的鲁棒性、可靠性、适应性以及节点或网络故障对整个系统的影响.

同时, 网络拓扑结构可以对高动态、空间中海量、多维、复杂结构和问题更具有有一般性抽象^[3~5], 可以有效抽象出复杂系统中有价值的特征与潜在规律, 描述系统的动态演化过程, 比如新节点的加入和一些节点的消失, 节点间的连接强度的变化. 通过分析发现集群无人系统复杂的结构难以表示和量化、网络结构时序多变的演化过程增加了系统结构的分析难度. 本文主要解决集群无人系统网络结构空间复杂和网络演化时序多变等条件下网络拓扑结构自适应调整建模和预测问题.

针对以上问题, 本文通过对集群无人系统三层动态系统结构建模来分析系统间的依赖关系, 从而进一步预测未来时刻节点的系统结构, 帮助人们提前进行预警和决策. 主要结果如下.

(1) 提出集群无人系统节点关系依赖模型. 描述集群无人系统结构空间的构成, 用图神经网络表示集群无人系统节点间依赖关系的静态模型, 从而实现定性分析出节点损坏对任务的影响.

(2) 提出递归神经网络学习算法, 预测集群无人系统结构自适应演化结果.

2 集群无人系统结构建模方法

在集群无人系统结构自适应调整、集群网络建模、集群结构演化预测的相关研究工作中, 目前常用图论或复杂网络表示大规模系统的网络拓扑结构, 利用复杂网络进行系统动态分析, 但是面临的主要问题是设计多大的网络、选择什么样的拓扑结构可以表示一个相互作用的复杂动力系统, 隐藏的重要关系有没有直接表现在内在结构中^[6]. 例如, 社交网络的结构可能影响信息和灾害传播速度, 金融网络的拓扑可能会对冲击造成不同程度的放大, 电力网络的不同配置可以影响电力传输的鲁棒性和稳定性, 如何更好地建立一个集群的同构网络结构模型是研究的关键. 为了研究真实网络的拓扑结构, 诸多学者提出了许多网络演化模型, 这些重要的网络模型包括: 随机网络^[7]、小世界网络^[8]、随机聚类网络^[9,10]、无标度网络和核心-边缘网络^[11~13]. 总的来说, 使用网络拓扑模型对集群无人系统进行建模表征, 对集群的功能和性能进行分析研究, 是当前集群无人系统结构研究的主要方向.

在集群结构自适应调整方面, 文献^[14]提供群行为和网络拓扑之间的集合的解决方案, 实现集群内无人机数量的高可扩展性和群内自适应网络拓扑结构, 该方法提供了一种自适应、可靠的网络结构, 保持了群的连通性和通信能力. 文献^[15]采用复杂网络理论对无人机群的特征进行了研究, 为构建多层无人机集群网络提供建模框架. 该网络可以进一步分析无人机集群系统在高对抗战场环境下的性能以及自组网级联故障对系统的影响. 文献^[16]研究了机器人集群在目标区域内的拓扑设计和控制问题, 提出了一种以参考点为中心的多级结构, 在此基础上可以形成许多不同的形状, 开发了一种基于势

函数的控制器,在避免相互碰撞的同时实现所需的形状。

在网络结构预测方面,文献 [3,17] 提出了基于潜在角色的动态网络结构预测方法,该方法克服了已有基于转移矩阵方法忽略历史信息的不足,提高了网络结构预测的准确性。

当前比较热门的机器学习技术通过使用预处理来处理图结构数据,预处理将图结构信息映射到更简单的表示,例如实数向量^[18,19]。也就是说,预处理步骤首先将图形结构化数据“压扁”成实数向量,然后使用基于列表的数据处理技术处理预处理数据。而网络拓扑结构是对节点及节点之间关系分析的表示,传统的机器学习方法对重要的信息,如信息对节点 n 的拓扑依赖,可能会在预处理阶段丢失。诸多学者对此问题进行了研究,并提出各种各样的方法,文献 [20,21] 试图在处理数据之前尽可能长时间地保持数据的图结构特性。在这些最近的方法中,主要思想是使用图节点之间的拓扑关系编码底层图结构数据,从而将图结构信息合并到数据处理步骤中。递归神经网络^[22,23] 和马尔可夫 (Markov) 链^[24,25] 属于这种技术,在图论和节点聚焦问题中都得到了广泛的应用。

系统结构是一种不规则的数据结构,这种结构属于非欧氏空间的数据,可以说是无限维的一种数据,每一个节点的周围结构可能都是独一无二的。很多学者从 20 世纪就开始研究如何对这类数据进行节点分类、图分类和边预测。文献 [26] 提出了图神经网络 (graph neural network, GNN), 它既适用于图论应用,又适用于节点关系的应用。这个新模型将这两个现有模型统一到一个公共框架中,不仅可以对图进行分析还可以对节点进行分类和编码。图神经网络是一种连接模型,它通过图节点间的消息传递来捕获图之间的依赖关系。与标准神经网络不同,图神经网络保留了一种状态,这种状态可以表示任意深度的邻域信息,也可以从集群数据中挖掘出更多的结构以及相互依赖关系进行分析。集群本质上是由离散部分 (如节点和边) 组成的组合结构,而许多常见的机器学习 (machine learning, ML) 方法 (如神经网络) 倾向于对连续向量的分析。图神经网络解决了 ML 很难表示离散向量的问题,采用图嵌入方法学习图的连续向量空间,并将图中的每个节点 (和/或边) 分配到向量空间中的特定位置。由于图神经网络在对图形中节点间的依赖关系进行建模方面能力强大,因此, GNN 在各个领域越来越受欢迎,包括集群、链接预测、隐私等方面都有应用。

集群无人系统结构和应用环境动态特性变成系统边界的模糊性和不确定性,系统任务需求、组成单元、总体架构处在不断演化中,如何构建从任务到系统结构之间的关系模型,使得集群系统能够自适应地进行结构调整? 本文利用 GNN 特性对集群无人系统结构依赖关系建模,给出递归算法实现基于任务的集群无人系统结构预测。

3 集群无人系统演化机理

集群无人系统是一种复杂系统,主要的的能力是灵活调度、群智涌现、结构最优化和路由选择。借鉴狼群扑食行为发现,狼群行为策略与环境信息和历史信息具有相关性^[27], Cassidy 等^[28] 通过长期的实证观察和分析提出群规模、成员组成和空间移动方向与狼群狩猎过程存在相关性,其中群结构方式是影响其猎扑攻击效率的主要因素。因此为了研究集群系统的自适应性,首先,将集群无人系统从任务到系统结构到网络拓扑结构的结构关系建立抽象模型,然后,把集群系统的各层上的数据和系统结构用一个等效图神经网络进行描述,将集群结构的自适应调整 (如节点的加入、删除,边集合动态调整) 转化为二维数据的图问题进行特征提取和分类,从而实现集群结构的自动建立和调整,为节点损失对任务层的影响度构建了分析基础。进一步分析,基于任务要求,每一种任务对应一种初始的系统结构,该结构决定了无人系统的连接关系、系统规模、系统的功能和能力。随着任务的改变和环境的变化,集群无人系统自适应调整其结构。因此,首先要了解集群无人系统的构成要素,以及构成网络结构演

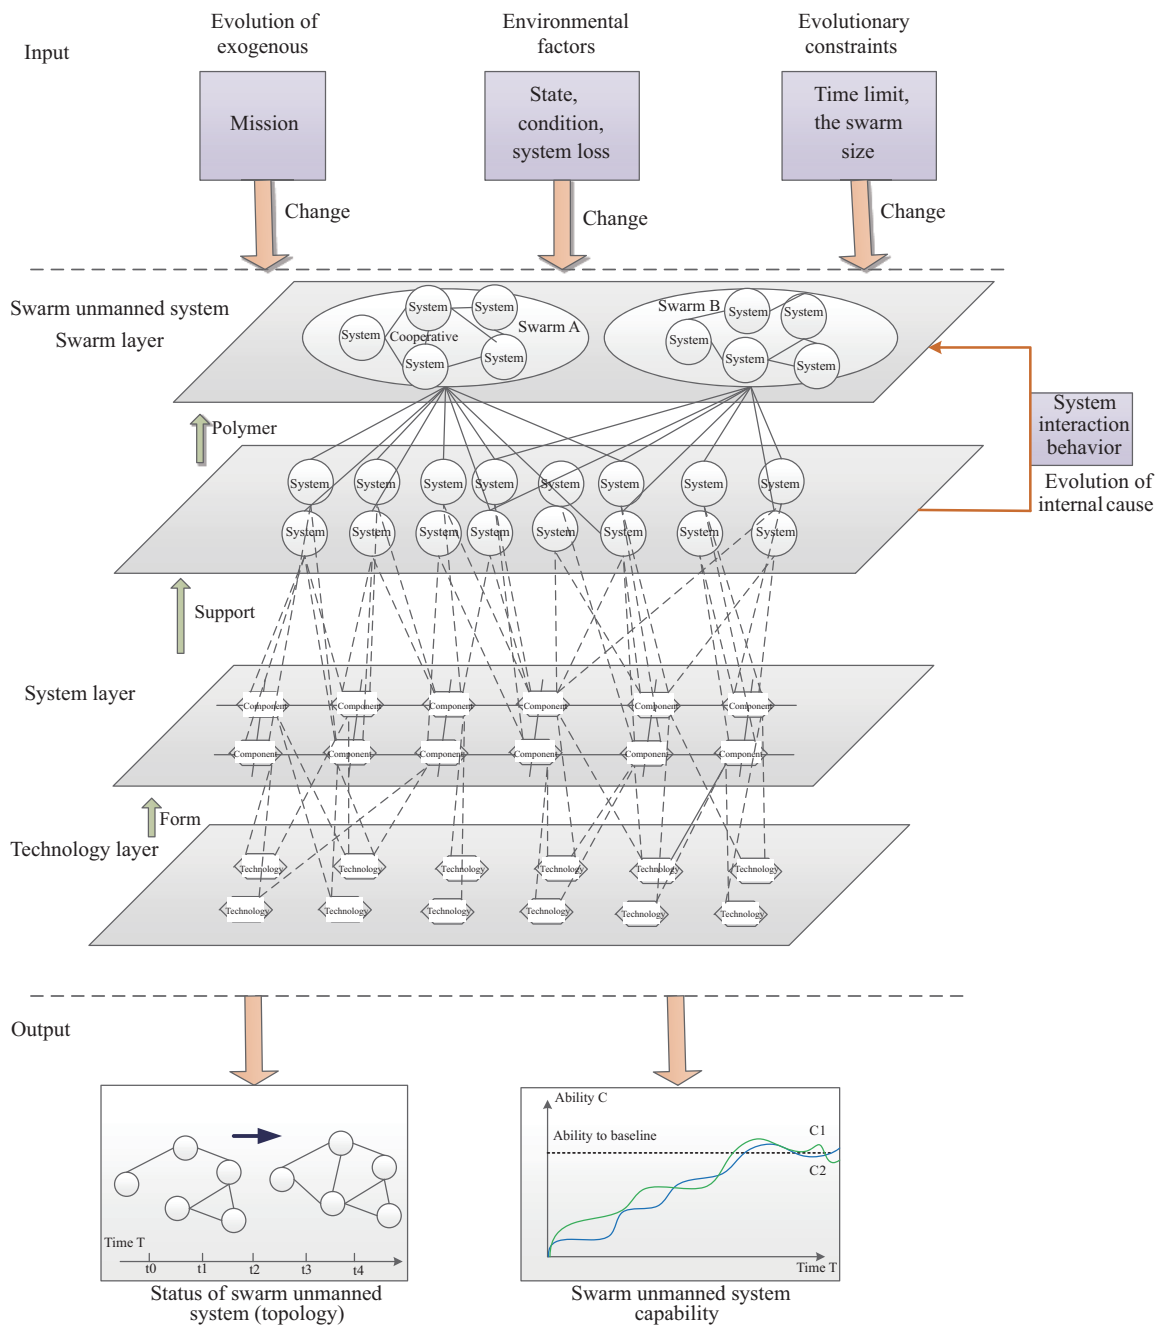


图 1 (网络版彩图) 集群无人系统结构演化机理分析

Figure 1 (Color online) Structure evolution analysis of swarm unmanned system

化的机理. 归纳起来集群无人系统演化的动因主要有: 使命任务变化、态势和状态改变、系统损失或退出、链路损坏. 演化的约束条件有: 结构调整时间、集群规模. 系统之间通过频繁地信息交互, 系统间紧密配合, 快速响应构建出集群系统. 在构建过程中集群结构不断调整以应对环境的变化. 如图 1 所示.

4 集群无人系统结构依赖模型

为了实现集群无人系统结构自适应调整,需要建立从系统的链路到集群的功能再到任务的相互关系依赖模型,然后构建基于时间片的结构预测框架和预测算法。

系统依赖关系可以理解为集群无人系统中最重要的样本之间的基于任务的系统间协作关系,底层链路靠网络拓扑支撑。其中,系统结构能够以一种交互的方式对局部或者全局结构进行编码,但是想要从系统结构中提取以向量表示的数据,而且想让系统结构能尽可能多地编码更多的信息,在系统结构中进行循环建模是一项不容易完成的任务,一个很自然的问题是我们如何把集群无人系统中非结构化或者向量表示的数据构建到系统结构中。对于集群无人系统内部的结构之间的相互作用和动态关系,这些非欧空间数据转化成欧氏空间结构数据,目前图神经网络可以给出很好的描述,用图神经网络来描述集群结构及各类数据,将系统结构和系统领域数据嵌入到图中,可以对集群内系统进行关系建模,并通过特征分析进行优化。根据文献 [29] 的方法, GNN 层通过聚合来自其邻居的特性信息封装每个节点的隐藏表示。在特征聚合后,对输出结果进行非线性变换。通过叠加多个层,每个节点的最终隐藏表示形式将接收来自更远的邻域的消息。

4.1 集群无人系统三层结构描述

集群无人系统也是一种指挥控制系统,是一种分层式控制与交互系统,层级之间具有依赖、顺序和抽象的等级关系。

借鉴文献 [15] 提到的集群无人系统的复杂网络表示方法,本文以任务为视角,设定集群无人系统由 3 个相互依赖的层级组成,即,任务层、集群层、系统层,分别用 G_c , G_b , G_a 表示。(1) 任务层,将总体任务划分为子任务,是集群无人系统需要完成的目标。(2) 集群层,指按照任务领域的逻辑关系和特征实现不同系统的功能集成,形成满足使命任务要求的集群能力。(3) 系统层,指系统所能提供的功能和链路的链接。虽然系统的能力聚合为集群提供能力支撑,但是集群能力并非是系统能力的简单叠加,而是希望良性的智能涌现。

根据任务层需求要求集群层收集可以提供这些能力的系统集,每个系统能力都来源于系统层中系统功能的聚集。集群能力可以看作是系统组合优化的涌现能力。通过层次的划分,单独系统发生损坏或者增加、减少,相应的功能会发生改变,从而可以清晰地分析出系统及链路的变化对集群能力的影响。3 个层级及层间关系可以描述如下。

任务层: 集群完成的总任务划分为若干个子任务,从实际情况考虑各子任务的完成是相互独立的,但子任务间会有配合和依赖关系,本文只考虑简单的完成顺序。任务决定了能力需求,任务与能力之间有映射关系^[30]。建模时将总任务需求划分为各个领域子任务需求。某个子任务记为节点,边记为同类任务之间的连接,记为 E_c 。因此,可以写成 $G_c = (V_c, E_c)$, 其中 V_c 是节点集, $V_c = \{V_{c1}, V_{c2}, \dots, V_{cn}\}$ 。 E_c 是边的集合,表示节点为同一个任务, $E_c = \{E_{c1}, E_{c2}, \dots, E_{cn}\}$ 。

集群层: 是逻辑层,包括单独系统之间的信息交互关系、空间分布、系统关系结构、群间组织结构。这些集群内的信息指挥控制点记为节点,边记为集群内部的信息交互关系,权重记为系统间的涌现能力。集群层 G_b 可以定义为 $G_b = (V_b, E_b, W_b)$, 其中 V_b 是节点集,表示信息指挥控制点, $V_b = \{V_{b1}, V_{b2}, \dots, V_{bn}\}$ 。 E_b 是边的集合,表示节点间的信息交互关系, $E_b = \{E_{b1}, E_{b2}, \dots, E_{bn}\}$ 。权重记为 W_b , 其中 $W_b = \{W_{b1}, W_{b2}, \dots, W_{bn}\}$ 。

系统层: 系统是集群无人系统的执行单元,该层中通信点表示为节点,节点之间形成通信网络,边表示节点之间的通信链路,记为 $G_a = (V_a, E_a, W_a)$, 其中 V_a 是节点集合,表示系统, $V_a = \{V_{a1}, V_{a2}, \dots,$

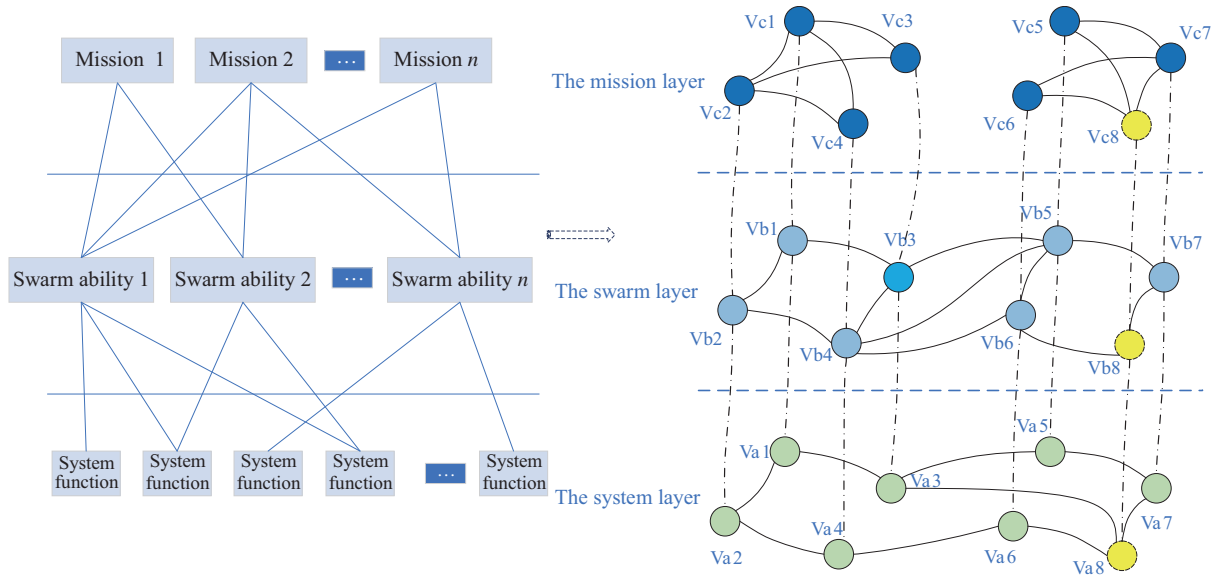


图 2 (网络版彩图) 集群无人系统 3 层结构
 Figure 2 (Color online) Three tier layers of swarm unmanned system

V_{an} }. E_a 是边的集合, 表示节间之间的通信关系, $E_a = \{E_{a1}, E_{a2}, \dots, E_{an}\}$. 通信网络的变化影响链路的通信质量, 因此, 将系统层定义为加权网络, 权值为 W_a , 其中 $W_a = \{W_{a1}, W_{a2}, \dots, W_{an}\}$.

层间关系: 将集群无人系统的层间关系进行简单设定, 具体为 3 层系统节点之间的支撑依赖关系. $L(a-b)_i, i = \{1, 2, 3, \dots, n\}$ 和 $L(b-c)_i, i = \{1, 2, 3, \dots, n\}$ 分别定义为系统层与集群层、集群层与任务层之间的层间关系. 3 级关系如图 2 所示, 其中一层中节点的删除将导致其他层中节点的删除以及边的删除 (图 2 中的黄色节点代表节点损坏).

例如, 为了完成使命任务“对敌方区域进行大面积侦查并消除敌方特定目标”, 由 5 个系统构成一个集群无人系统: 地球同步人造卫星、三个无人机 (unmanned aerial vehicle, UAV) 和一个地面控制台. 地球同步人造卫星监视敌方区域, UAV-1 是一个不携带武器的监视器, 同步人造卫星与 UAV-1 实现目标识别. UAV-2 和 UAV-3 携带基础照相机用于目标确认, 并配备武器实现目标打击, 地面控制台用于通信传输和指挥控制. 地球同步人造卫星联合 UAV-1, UAV-2 和 UAV-3 的功能为集群提供 3 个主要能力: (1) 区域监视, (2) 目标识别, (3) 目标打击, 从而完成使命任务. UVA 与人造卫星连接构成系统网络提供集群层面的能力, 使得集群无人系统不仅能提供大区域监视功能, 而且提供高清晰成像能力, 是单一系统无法实现的. 由此看来集群的能力是由系统提供的功能聚合而成的. 给出的实例如图 3 所示.

4.2 基于图神经网络的集群无人系统结构模型

根据图神经网络的基本原理, 将图结构用 D 表示, 设 $D = G \times N$, 这里 G 是图描述, N 是图中的节点集合. 每个节点都有自己的特征, 我们设这些节点的特征组成一个 $N \times M$ 维的特征矩阵 X . 各个节点之间的关系也会形成一个 $N \times N$ 维的矩阵 A , 也称为邻接矩阵 (adjacency matrix). X 和 A 作为模型输入, 通过若干层 GNN, 每个节点的特征从 X 变成了 Z , 但是, 无论中间有多少层, 节点之间的连接关系, 即 A , 都是共享的, 保证了集群结构特征的完整性. 本文通过引入节点和弧 (边) 标签来标识集群无人系统的结构. 标签包括所有与节点相关的对象特征和对象之间关系特征. 下面给出 3 层结

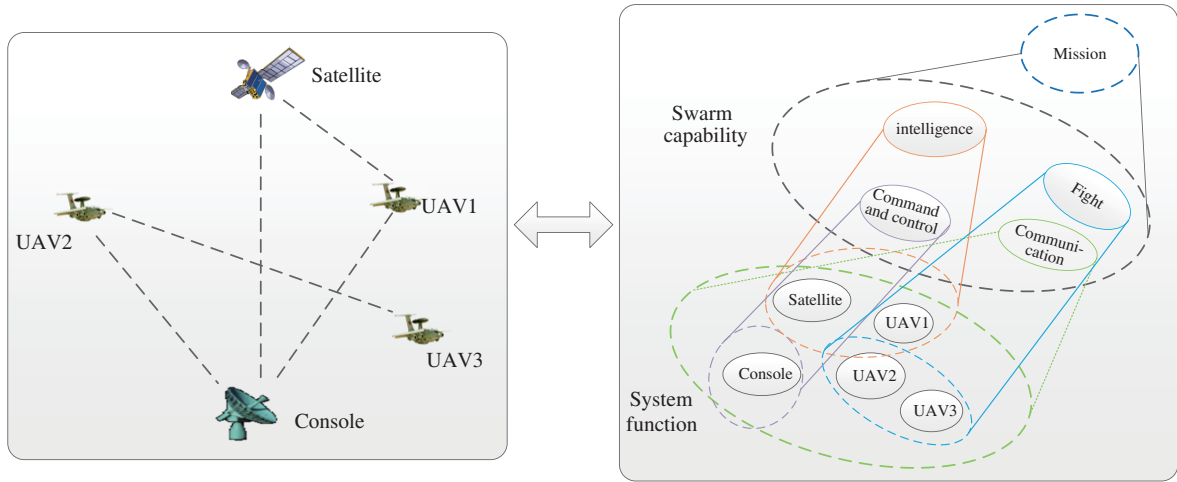


图 3 (网络版彩图) 集群无人系统的层次实例
 Figure 3 (Color online) Example of swarm unmanned system

构中层内与层间节点、弧(边)的标签定义,通过确定标签属性要素,从而建立层内与层间节点间相互依赖关系的具体含义。

定义1 任务层 G_c 定义的是完成任务所要具备的能力集合 $C = (C_1 + C_2 + \dots + C_n)$. 每个能力 C_i 作为任务层的一个节点 n_{i,G_c} , 节点之间的弧(边)是表示能力的实现交付给哪些系统实现, 由此将 G_c 与 G_b 层建立了依赖的关系。

任务层节点信息为 $G_c x_i = f_w(l_{i,G_c}, l_{G_c_co[n]}, x_{G_c_ne[n]}, l_{G_c_ne[n]})$. l_{i,G_c} 为集群层节点 n_{i,G_c} 标签向量: $l_{i,G_c} = (l_{i,G_c_id}, l_{i,G_c_value})$, 其中 l_{i,G_c_id} 表示节点编号, l_{i,G_c_value} 表示权重, 即 n_{i,G_c} 的能力值, 为简化问题, 任务层的每个能力值均赋值为 1. $l_{G_c_co[n]}$ 表示以 n_{i,G_c} 为顶点的一组弧(边)的属性标签向量: $l_{G_c_co[n]} = (l_{G_c_co_id}, l_{G_c_co_value}, l_{G_c_co_direction})$, 其中 $l_{G_c_co_id}$ 表示弧的编号, $l_{G_c_co_value}$ 表示每条弧的权重, 即每个连接的无人系统可以提供的能力值, $l_{G_c_co_direction}$ 表示弧的方向, 指向 n_{i,G_c} 为 1, 离开 n_{i,G_c} 为 0, 任务层的弧都是指向节点 n_{i,G_c} 的, 这里 $l_{G_c_co_direction} = 1$. $x_{G_c_ne[n]}$ 表示节点 n_{i,G_c} 的邻节点属性向量: $x_{G_c_ne[n]} = (x_{G_c_ne_connct}, x_{G_c_ne_evolument})$, 其中 $x_{G_c_ne_connct}$ 是 $[0, 1]$ 布尔值, 0 表示不可以为任务层节点 n_{i,G_c} 提供能力, 1 表示可以为任务层节点 n_{i,G_c} 提供能力, $x_{G_c_ne_evolument}$ 表示演化能力在不同阶段的标志. $l_{G_c_ne[n]}$ 表示节点 n_{i,G_c} 的所有邻居节点的原子标签向量: $l_{G_c_ne[n]} = (l_{G_c_ne_id}, l_{G_c_ne_layer})$, 其中 $l_{G_c_ne_id}$ 表示邻居节点编号, $l_{G_c_ne_layer}$ 表示邻节点所属的层级。

定义2 集群层 G_b 定义的是集群内部系统关系构成以及该层节点与邻域的任务层和系统层节点之间的依赖关系. 每个无人系统作为集群层的一个节点 n_{i,G_b} , 节点之间的边 l_{G_b} 表示系统之间的信息交互的逻辑关系, 与任务层 G_c 和系统层 G_a 之间的关系。

集群层节点信息为 $G_b x_i = f_w(l_{i,G_b}, l_{G_b_co[n]}, x_{G_b_ne[n]}, l_{G_b_ne[n]})$. l_{i,G_b} 为集群层节点 n_{i,G_b} 标签向量: $l_{i,G_b} = (l_{i,G_b_id}, l_{i,G_b_function})$, 其中, l_{i,G_b_id} 表示节点编号, $l_{i,G_b_function}$ 表示系统功能, $l_{i,G_b_function} = 1$ 表示系统可以提供功能, $l_{i,G_b_function} = 0$ 表示系统不能提供功能. $l_{G_b_co[n]}$ 表示以 n_{i,G_b} 为顶点的一组弧(边)的属性向量: $l_{G_b_co[n]} = (l_{G_b_co_id}, l_{G_b_co_value}, l_{G_b_co_direction})$, 其中, $l_{G_b_co_id}$ 表示弧的编号, $l_{G_b_co_value}$ 表示每条弧的权重, $l_{G_b_co_direction}$ 表示弧的方向, 指向节点 n_{i,G_b} 为 1, 离开节点 n_{i,G_b} 为 0.

$x_{G_b_ne[n]}$ 表示节点 $n_{i_{G_b}}$ 的邻节点属性向量: $x_{G_b_ne[n]} = (x_{G_b_ne_connect}, x_{G_b_ne_evoluement}, x_{G_b_ne_function})$, 其中 $x_{G_b_ne_connect}$ 是 $[0, 1]$ 布尔值, 0 表示不为节点 $n_{i_{G_c}}$ 提供能力, 1 表示为节点 $n_{i_{G_c}}$ 提供能力. $x_{G_b_ne_evoluement}$ 表示演化能力在不同阶段的标志, $x_{G_b_ne_function}$ 表示系统的功能, $x_{G_b_ne_function} = 1$ 表示系统具备功能, $x_{G_b_ne_function} = 0$ 表示系统不具备功能 (或已损坏). $l_{G_b_ne[n]}$ 表示节点 $n_{i_{G_c}}$ 的所有邻居节点的原子标签向量, $l_{G_b_ne[n]} = (l_{G_b_ne_id}, l_{G_b_ne_layer})$, 其中 $l_{G_b_ne_id}$ 表示邻居节点编号, $x_{G_b_ne_layer}$ 表示邻居节点所属层级.

定义3 系统层 G_a 定义的是系统之间的网络拓扑关系, 每个系统的一个通信点作为该层的节点 $n_{i_{G_a}}$, 节点之间的边 l_{G_a} 表示系统之间的通信链路关系, 与任务层 G_c 节点和集群层 G_b 节点有边关系, 表示系统层通信链路对集群层有支撑关系.

系统层节点信息为 $G_a x_i = f_w(l_{i_{G_a}}, l_{G_a_co[n]}, x_{G_a_ne[n]}, l_{G_a_ne[n]})$. $l_{i_{G_a}}$ 为集群层节点 $n_{i_{G_a}}$ 标签向量: $l_{i_{G_a}} = (l_{i_{G_a_id}}, l_{i_{G_a_function}})$, 其中 $l_{i_{G_a_id}}$ 表示节点编号, $l_{i_{G_a_function}}$ 表示节点功能, $l_{i_{G_a_function}} = 1$ 表示系统通信正常, $l_{i_{G_a_function}} = 0$ 表示系统通信失败. $l_{G_a_co[n]}$ 表示以 $n_{i_{G_a}}$ 为顶点的一组弧 (边) 的属性向量: $l_{G_a_co[n]} = (l_{G_a_co_id}, l_{G_a_co_value}, l_{G_a_co_direction})$, 其中 $l_{G_a_co_id}$ 表示弧的编号, $l_{G_a_co_value}$ 表示每条弧的权重, $l_{G_a_co_direction}$ 表示弧的方向, 指向节点 $n_{i_{G_a}}$ 为 1, 离开节点 $n_{i_{G_a}}$ 为 0. $x_{G_a_ne[n]}$ 表示节点 $n_{i_{G_a}}$ 的邻节点属性向量, $x_{G_a_ne[n]} = (x_{G_a_ne_connect}, x_{G_a_ne_function})$, 其中 $l_{G_a_ne_connect}$ 是 $[0, 1]$ 布尔值, 取值 0 表示节点 $n_{i_{G_a}}$ 不可以建立链接, 取值 1 表示为节点 $n_{i_{G_a}}$ 建立链接. $x_{G_a_ne_function}$ 表示节点的功能, $x_{G_a_ne_function} = 1$ 表示节点具备功能, $x_{G_a_ne_function} = 0$ 表示节点不具备功能 (或已损坏). $l_{G_a_ne[n]}$ 表示节点 $n_{i_{G_a}}$ 的所有邻居节点的原子标签向量, $l_{G_a_ne[n]} = (l_{G_a_ne_id}, l_{G_a_ne_layer})$, 其中 $l_{G_a_ne_id}$ 表示邻居节点编号, $x_{G_a_ne_layer}$ 表示邻居节点所属层级.

4.3 集群无人系统结构状态计算与预测

4.2 小节中, $l_i, l_{co[n]}, x_{ne[n]}, l_{ne[n]}$ 都是节点 n_i 的标签向量, 设函数 f_w 为节点 n 对其邻域的依赖关系, 将集群无人系统结构用节点对其邻域的依赖关系描述, 称为转换函数:

$$x_n = (f_w l_n, l_{co[n]}, x_{ne[n]}, l_{ne[n]}). \quad (1)$$

给出输出函数 g_w , 描述如何得到当前的关于节点 n_i 的所有关系结构输出. 将转换函数 f_w 和原子节点作为输入, 给出输出函数 g_w , 得到需要的输出 o_n :

$$o_n = (g_w f_w, l_n). \quad (2)$$

将 3 个层级的所有节点邻域依赖关系为所有变量 x_n 叠加而成的向量, 见式 (3):

$$x_n = \sum_{u \in ne[n]} (f_w l_n, l_{(n,u)}, x_u, l_u), \quad n \in N. \quad (3)$$

比如, 整个 N 的标签向量矩阵为

$$x_n = \begin{bmatrix} x_1 & (1, 1) & (1, 2, 3, 1, 1, 4, 6, 1) & (1, 0, 0, 1) & (0, 1, 1, 1) & (1, 2, 3, 4, 5) & (3, 3, 3, 2, 2) \\ x_2 & (2, 0) & (1, 2, 3, 1, 1, 4, 6, 1) & (0, 1, 0, 1) & (0, 1, 1, 1) & (1, 2, 3, 4, 5) & (2, 3, 3, 3, 2) \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ x_n & \dots & \dots & \dots & \dots & \dots & \dots \end{bmatrix}.$$

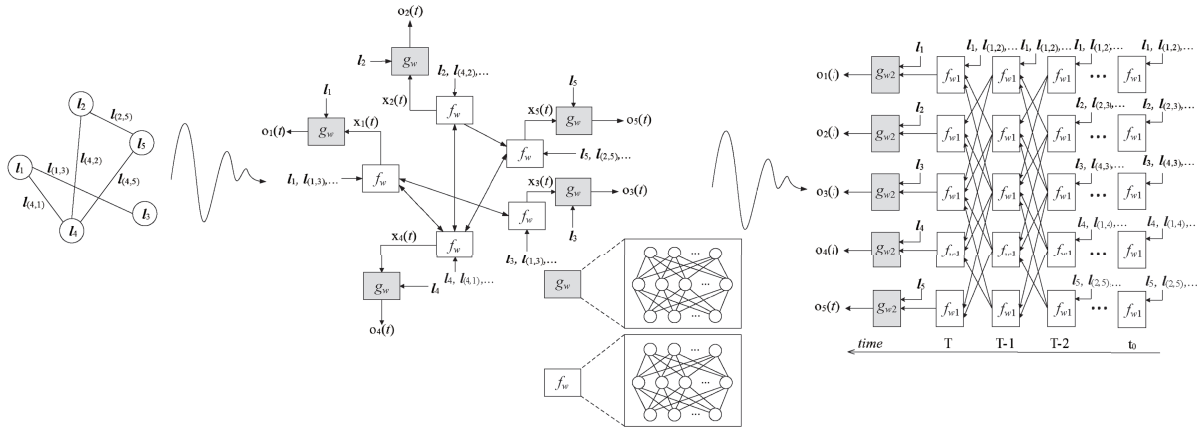


图 4 集群无人系统结构的图神经网络

Figure 4 GNN of swarm unmanned system structure

将 x_n 和 l_n 作为输入, 再求解式 (2), 参数 w 是通过训练数据集中包含的例子来估计的值. 当采用静态神经网络实现 f_w 和 g_w 时, 编码网络是一个递归神经网络, 神经元之间的连接可以分为内部连接和外部连接. 内部连接由用于实现该单元的神经网络体系结构决定, 外部连接依赖于处理后的图的边.

根据 Banach 不动点定理^[31], 我们可以认为 $x_n(t)$ 是由过渡函数 f_w 更新的状态, 可以通过迭代计算输出和状态, 实现集群无人系统结构预测.

$$\begin{cases} x_n(t+1) = (f_w l_n, l_{co[n]}, x_{ne[n]}, l_{ne[n]}), \\ o_n(t) = g_w(x_n(t), l_n), \quad n \in N. \end{cases} \quad (4)$$

状态 $x_n(t)$ 由式 (4) 迭代更新, 直到 t 时刻, 状态 $x_n(t)$ 趋于式 (2) 的不动点解: $x_n(t) \approx x$; 每个单元存储节点 n 的当前状态 $x_n(t)$, 当被激活时, 它使用节点标签和存储在附近的信息计算 $x_n(t+1)$ 的状态. 单元重复激活产生式 (3) 所述的行为, 节点 n 的输出由另一个实现 g_w 的单元产生. 为了构建编码网络, 可以用计算函数 f_w 的单元替换图中的每个节点. 编码网络从时间 t 展开到初始时间 t_0 . 根据集群无人系统的层次实例, 给出如图 4 所示的分层网络. 每个层对应一个时间实例, 并包含编码网络的所有单元 f_w 的副本. 两个连续层的单元按照图的连通性进行连接. 时间对应的最后一层也包括 g_w 单元, 计算网络的输出.

设定一个学习框架 $\tau = \{G_i, n_{i,j}, t_{i,j} | G_i = (N_i, E_i) \in \emptyset; n_{i,j} \in N_i; t_{i,j} \in \mathbb{R}^m\}$, $n_{ij} \in N_i$, 即 $\tau = (G, \Gamma)$, 这里 $G = (N, E)$ 表示集群的结构图, τ 表示节点及权重 $\{(n_i, t_i) | n_i \in N, t_i \in \mathbb{R}^m, 1 \leq i \leq q\}$. 可以对图网络模型中每个节点进行监视. 该学习算法基于梯度下降策略, w 根据梯度更新, 输出和状态可以通过迭代计算.

算法采用递归神经网络进行学习, 由一个主程序和 forward(), backward() 两个函数组成, 主程序更新权值 w , w 影响学习网络的速度, w 可以取 $[0, 1)$ 的随机初始化值, w 值越大收敛速度越快, 本文算法中选取最小值 $w = 0$, 直到输出达到期望的精度或达到其他一些停止准则. 参考文献 [26], 本文结合集群无人系统结构特征, 给出集群无人系统结构预测学习算法, 见图 5.

| | | | | |
|------------------------------------------------------------|-------------------------------------------------|-------------------------------------------------|--------------------------------------------------------------------------------------|------------------------|
| Input: $x_n = f_w(l_n, l_{co[n]}, x_{ne[n]}, l_{ne[n]})$ | forward(w) | /feed-learning. | backward(x, w) | /back propagation. |
| Output: $o_n(t) = g_w x_n(t), l_n$ | { | | { | |
| main() | initialize | $x(0), t = 0;$ | $o = g_w(x, l_N);$ | /output graph network. |
| { | while($\ x(t) - x(t-1)\ \leq \varepsilon f$) | $A = \frac{\partial f_w}{\partial x} = (x, l);$ | /relation matrix of nodes. | |
| $w = 0;$ | /initialize $w.$ | { | $b = \frac{\partial e_w}{\partial x} \cdot \frac{\partial f_w}{\partial x}(x, l_n);$ | |
| $x = \text{forward}(w);$ | | $x(t+1) = f_w(x(t), l);$ | initialize | $z(0), t = 0;$ |
| $n = 0;$ | | $t = t + 1;$ | while($\ z(t-1) - z(t)\ \leq \varepsilon b$) | |
| while($n == 100$) | /iterations. | } | { | |
| { | | return $x(t);$ | $z(t) = z(t+1) \cdot A + b;$ | |
| $\frac{\partial e_w}{\partial w} = \text{backward}(x, w);$ | } | | $t = t - 1;$ | |
| $w = w - \lambda \cdot \frac{\partial e_w}{\partial w};$ | /gradient; | | } | |
| $x = \text{forward}(w);$ | | | $c = \frac{\partial e_w}{\partial o} \cdot \frac{\partial g_w}{\partial x}(x, l_n);$ | |
| $n++;$ | | | $d = z(t) \cdot \frac{\partial f_w}{\partial w}(x, l);$ | |
| } | | | $\frac{\partial e_w}{\partial w} = c + d;$ | |
| return $w;$ | | | return $\frac{\partial e_w}{\partial w};$ | |
| } | | | } | |

图 5 集群无人系统结构预测学习算法

Figure 5 Swarm unmanned system structure prediction learning algorithm

5 实验仿真

整个图网络可以实现将集群结构以任务为标准的分类, 即每种任务对应一类具体集群无人系统结构. 任务的变化会导致集群结构的自适应改变.

将战略预警与打击无人系统作为应用案例进行分析, 该系统主要用于准确、快速地获取与处理所属区域的情报, 以有效提高预警和打击的快速反应能力. 假设任务是侦察和打击敌方目标. 战略预警与打击无人系统能力需求对 1000 km 的范围进行监察, 预警时间大于 1 h, 目标发现概率大于 0.96, 系统虚警概率小于 0.7, 攻击目标时间小于 0.1 h, 失误率小于 0.2. 装备储备有 1000 架无人机 (UAV)、100 颗卫星和 10 个地面控制站. 本次可调拨的装备有 100 台无人机、20 颗卫星、8 台地面控制站. 实验设定同一种设备之间的连接方式: (1) 无人机的连接方式为全连接, (2) 卫星的连接方式为环形, (3) 地面控制站的连接方式为二维网格或社区连接方式, 需要根据实际情况来决定. 设备连接方式的示意图如图 6 所示.

实验用 TensorFlow 搭建图神经网络学习框架, 在 GPU 集群服务器上进行网络训练. 目前集群无人系统在我军没有实际应用, 处于技术论证阶段. 本实验根据专家经验人工构建训练集, 给节点建立标签, 实验中有部分无标签数据参与网络训练, 所以, 神经网络实现的是一个半监督学习^[32]. 其中, 图网络中节点的关系通过连接关系矩阵来描述. 例如, 对于包含 11 个节点的图网络, 通过建立 11×11 的矩阵来描述不同节点之间是否有联系. 数据集主要包括: (1) 标签, 根据不同任务来划分, 本文实验设定的任务标签分别是打击和侦察两类. (2) 节点特征矩阵, 主要目的是描述不同节点特征, 图网络根据节点特征以及节点之间不同的连接关系来区分不同任务类型. 数据集划分为训练集和测试集, 训练集主要用来完成网络参数的优化. 训练过程的算法描述详见图 5, 主要分为网络前向传播和网络反向传播, 前向传播完成特征提取, 反向传播完成图网络的参数优化.




图 6 (网络版彩图) 同一类型设备之间的连接方式

Figure 6 (Color online) Connection of the same type of equipments. (a) Ground control station graph; (b) satellite graph; (c) UAV graph

根据需求, 任务层将任务目标分为侦察、打击两类, 同一任务目标认为是一种类型任务. 集群层根据任务类型自适应地实现集群结构. 系统层关注的是系统的功能是否完好, 系统之间是否建立通信链路. 任务层节点、集群层节点和系统层节点属性标签见表 1.

节点的图表示为 $G = (V, E, A)$, 节点 $V_i \in V$, $e_{i,j} = (v_i, v_j) \in E$.

(1) 该案例的邻接矩阵 A_i (即节点间的边) 为

$$A_i = \begin{pmatrix} & v_s & v_u & v_g & v_m \\ v_s & 0 & 0 & 1 & 1 \\ v_u & 1 & 0 & 1 & 1 \\ v_g & 1 & 1 & 0 & 1 \\ v_m & 1 & 1 & 1 & 1 \end{pmatrix},$$

其中, 如果 $e_{ij} \in E$, 则 $A_{ij} = W_{ij}$, 否则 $A_{ij} = 0$.

(2) 卫星特征矩阵为

$$X_s = \begin{pmatrix} s_{r1} & s_{a1} & s_{j1} \\ s_{r2} & s_{a2} & s_{j2} \\ \dots & \dots & \dots \\ s_{r100} & s_{a100} & s_{j100} \end{pmatrix}.$$

表 1 层节点属性标签
Table 1 Label property of layer nodes

| Layer | Node | Label |
|------------------------------------------------------------------|-------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------|
| Mission layer G_c | Mission target (V_T) | (1) Reconnaissance |
| | | (2) Attack |
| | Mission (V_M) | (1) Resource consumption (electricity, fuel oil, fire power) (2) Completion time (warning time + decision time + attack time) (3) Degree of attack |
| Swarm layer G_b | Satellite (V_S) | (1) Reconnaissance scope S_r |
| | | (2) Accuracy S_a |
| | | (3) Relative target position S_l |
| | UAV (V_U) | (1) Firepower U_f |
| (2) Operational time U_t (3) Relative target position U_l | | |
| Ground control station (V_G) | (1) Communication rate G_s | |
| | (2) Command and control G_c | |
| System layer G_a | System function (V_F) | (1) Yes |
| | | (2) No |
| | Communication link (V_L) | (1) Yes |
| | | (2) No |

无人机特征矩阵为

$$X_u = \begin{pmatrix} U_{f1} & U_{t1} & U_{l1} \\ U_{f2} & U_{t2} & U_{l2} \\ \dots & \dots & \dots \\ U_{f1000} & U_{t1000} & U_{l1000} \end{pmatrix}.$$

地面控制站特征矩阵为

$$X_g = \begin{pmatrix} G_{s1} & G_{c1} \\ G_{s2} & G_{c2} \\ \dots & \dots \\ G_{s10} & G_{c10} \end{pmatrix}.$$

(3) 集群空间图表示为 $G = (V, E, A, X)$, $X \in \mathbb{R}^{T \times N \times D}$. 给定需求, 任务目标 V_T 是 (0, 1) 布尔值, 用于任务分类, 属于该任务记为 1, 否则标记为 0.

下面是给出的实验验证结果. 图 7 是给定基本任务时, 集群构建者根据专家经验, 初始地连接了需要的节点. 从可调配的装备库中实际调拨 20 个无人机分成 3 个群组、10 颗卫星和 8 个地面站组成集群无人系统以及相互连接结构. 图 7 中一个黄色圆点表示一架无人机 (UAV), 一个蓝色圆点表示一颗卫星 (S), 一个绿色圆点表示一个地面站 (G).

图 8 是明确任务后, 任务 V_M 是函数收敛的标准, 将变量值代入式 (1) 和 (2), 通过图 5 给出的递归神经网络算法, 实现在系统层约束下, 自动建立满足任务要求的集群无人系统的结构. 最终根据提

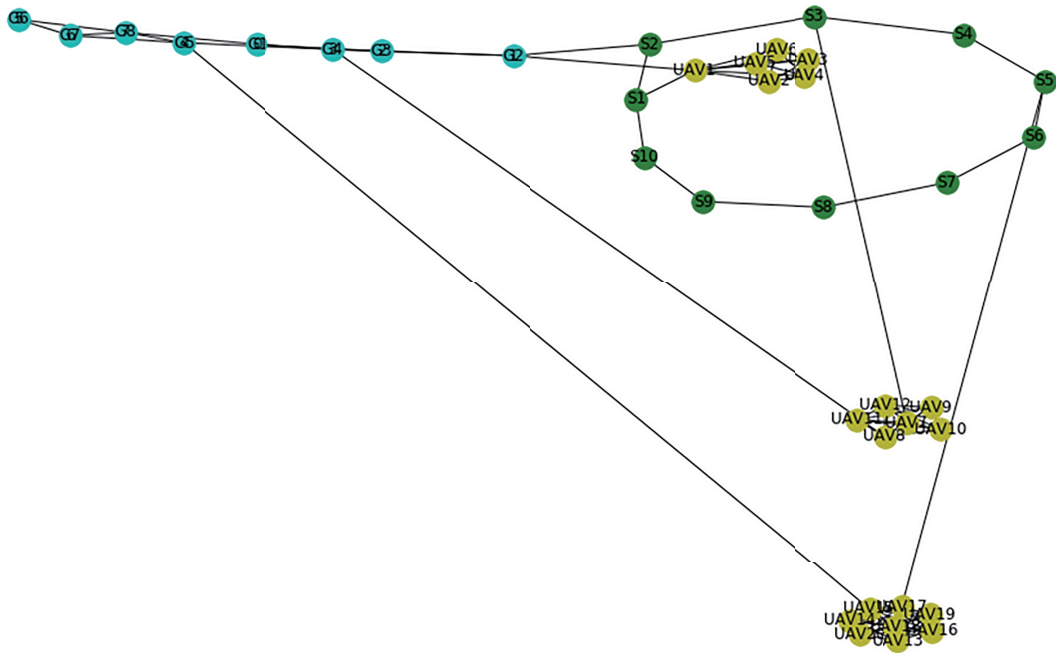


图 7 (网络版彩图) 初始的集群无人系统结构及依赖关系
 Figure 7 (Color online) Initial structure of SUS and dependency relationship




图 8 (网络版彩图) 自适应建立的集群无人系统
 Figure 8 (Color online) Adaptive structure of SUS

供的训练标签数据, 得到 3 个无人机集群、5 个卫星和 3 个地面站的连接结构. 图 8 上方的无人机集群中有一个无人机同时与地面站和卫星连接, 形成火力打击结构模式, 集群内无人机是全连接. 左边

和右边的无人机集群中分别有一台无人机与地面站连接, 集群中另一台无人机与卫星连接, 形成侦查结构模式. 实验发现, 自主生成的集群结构中, 完成侦查任务的集群无人机没有全连接, 只需使用部分无人机连接就可以完成任务, 比专家经验构建集群节省了无人机装备资源. 图 8 中黄色圆点表示无人机, 蓝色圆点表示卫星, 绿色圆点表示地面站.

6 结论与讨论

本文提出将图神经网络用于集群无人系统结构预测. 给定任务需求, 构建集群系统内的节点标签和节点领域标签, 形成层级内部和层级之间节点之间的相互依赖关系, 并将该标签矩阵作为输入, 通过递归的神经网络参数估计学习算法, 得到集群无人系统结构. 在以后的研究中可以在集群无人系统的图递归神经网络中加入节点权重和边权重实例数据, 计算系统的可靠性等性能指标, 分析出节点损失对任务层的影响. 另外, 由于集群无人系统节点状态标签属性数据量大, 后期计划利用分布式 GPU 集群对该方法进行算法效率分析, 以进一步了解该方法的可行性.

参考文献

- 1 Scharre P. *Army of None: Autonomous Weapons and the Future of War*. Lansing: WW Norton & Company, 2018
- 2 *Cyber Vision 2025. United States Air Force Cyberspace Science and Technology Vision 2012-2025*. SAF/PA Public Release Case No. 2012-0439/460/715
- 3 Li C, Feng B Q, Li Y M, et al. Role-based structure evolution and prediction in dynamic information networks. *J Softw*, 2017, 28: 663-675 [李川, 冯冰清, 李艳梅, 等. 动态信息网络中基于角色的结构演化与预测. *软件学报*, 2017, 28: 663-675]
- 4 Albert R, Barabási A L. Statistical mechanics of complex networks. *Rev Mod Phys*, 2002, 74: 47-97
- 5 Wang X F, Li X, Chen G R. *Complex Network Theory and Its Application*. Beijing: Tsinghua University Press, 2006 [汪小帆, 李翔, 陈关荣. *复杂网络理论及其应用*. 北京: 清华大学出版社, 2006]
- 6 Silva T C. *Machine Learning Method Based on Complex Network*. Beijing: Machinery Industry Press, 2018 [Silva T C. *基于复杂网络的机器学习方法*. 北京: 机械工业出版社, 2018]
- 7 Barabási A L, Albert R, Jeong H. Scale-free characteristics of random networks: the topology of the world-wide web. *Phys A-Stat Mech Its Appl*, 2000, 281: 69-77
- 8 Nowak M A. Five rules for the evolution of cooperation. *Science*, 2006, 314: 1560-1563
- 9 Dorogovtsev S N, Mendes J F F, Samukhin A N. Structure of growing networks with preferential linking. *Phys Rev Lett*, 2000, 85: 4633-4636
- 10 Newman M E J, Moore C, Watts D J. Mean-field solution of the small-world network model. *Phys Rev Lett*, 2000, 84: 3201-3204
- 11 Newman M E J. The structure and function of complex networks. *SIAM Rev*, 2003, 45: 167-256
- 12 Newman M E J, Watts D J. Renormalization group analysis of the small-world network model. *Phys Lett A*, 1999, 263: 341-346
- 13 Barabási A L, Albert R, Jeong H. Mean-field theory for scale-free random networks. *Phys A-Stat Mech Its Appl*, 1999, 272: 173-187
- 14 Brust M R, Strimbu B M. A networked swarm model for UAV deployment in the assessment of forest environments. In: *Proceedings of 2015 IEEE 10th International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP)*, Singapore, 2011
- 15 Wang L Z, Lu D W, Zhang Y, et al. A complex network theory-based modeling framework for unmanned aerial vehicle swarms. *Sensors*, 2018, 18: 3434

- 16 Yan X, Chen J, Sun D. Multilevel based topology design and formation control of robot swarms. In: Proceedings of the 2011 IEEE International Conference on Robotics and Biomimetics, Phuket, 2011
- 17 Feng B Q, Hu S L, Guo D, et al. Dynamic information network structure evolution analysis based on role discovery. *J Softw*, 2019, 30: 537–551 [冯冰清, 胡绍林, 郭栋, 等. 基于角色发现的动态信息网络结构演化分析. *软件学报*, 2019, 30: 537–551]
- 18 Gong C, Tao D C, Liu W, et al. Label propagation via teaching-to-learn and learning-to-teach. *IEEE Trans Neural Netw Learn Syst*, 2017, 28: 1452–1465
- 19 Gong C, Tao D C, Chang X J, et al. Ensemble teaching for hybrid label propagation. *IEEE Trans Cybern*, 2019, 49: 388–402
- 20 Frasconi P, Gori M, Sperduti A. A general framework for adaptive processing of data structures. *IEEE Trans Neural Netw*, 1998, 9: 768–786
- 21 Brin S, Page L. The anatomy of a large-scale hypertextual web search engine. In: Proceedings of the 7th World Wide Web Conference, 1998
- 22 Sperduti A, Starita A. Supervised neural networks for the classification of structures. *IEEE Trans Neural Netw*, 1997, 8: 714–735
- 23 Hagenbuchner M, Sperduti A, Tsoi A C. A self-organizing map for adaptive processing of structured data. *IEEE Trans Neural Netw*, 2003, 14: 491–505
- 24 Kleinberg J M. Authoritative sources in a hyperlinked environment. *J ACM*, 1999, 46: 604–632
- 25 Tsoi A C, Morini G, Scarselli F, et al. Adaptive ranking of web pages. In: Proceedings of the 12th World Wide Web Conference, Budapest, 2003
- 26 Scarselli F, Gori M, Tsoi A C, et al. The graph neural network model. *IEEE Trans Neural Netw*, 2009, 20: 61–80
- 27 Duan H B, Zhang D F, Fan Y M, et al. From Wolf pack intelligence to drone swarm collaborative decision-making. *Sci Sin Inform*, 2019, 49: 112–118 [段海滨, 张岱峰, 范彦铭, 等. 从狼群智能到无人机集群协同决策. *中国科学: 信息科学*, 2019, 49: 112–118]
- 28 Cassidy K A, MacNulty D R, Stahler D R, et al. Group composition effects on aggressive interpack interactions of gray wolves in Yellowstone National Park. *Behav Ecol*, 2015, 26: 1352–1360
- 29 Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks. In: Proceedings of the International Conference on Learning Representations, 2017
- 30 Zhang T T. Research on the Capability Evolution of Network Information System. Beijing: Science Press, 2018 [张婷婷. 网络信息体系能力演化分析方法研究. 北京: 科学出版社, 2018]
- 31 Zhang G Q, Ling Y Q. Functional analysis handout. Beijing: Peking University Press, 2013 [张恭庆, 林源渠. 泛函分析讲义. 北京: 北京大学出版社, 2013]
- 32 Gong C, Tao D C, Maybank S J, et al. Multi-modal curriculum learning for semi-supervised image classification. *IEEE Trans Image Process*, 2016, 25: 3249–3260

Adaptive structure modeling and prediction for swarm unmanned system

Tingting ZHANG^{1,2,3*}, Aiguo SONG^{2*} & Yushi LAN³

1. College of Command and Control Engineering, Army Engineering University of PLA, Nanjing 210017, China;

2. College of Instrumental Science and Engineering, Southeast University, Nanjing 210017, China;

3. The 28th Research Institute of China Electronics Technology Group Corporation, Nanjing 210017, China

* Corresponding author. E-mail: 101101964@seu.edu.cn, a.g.song@seu.edu.cn

Abstract In recent years, swarm unmanned systems (SUSs) have become crucial in the military field, both at home and abroad. This has promoted the evolution of the unmanned combat mode from single-platform remote-control to intelligent-swarm combat. SUSs support the cooperative, autonomous, and flexible characteristics of the combat system under uncertain tasks and environments. The overall swarm performance depends on the system and structure among its members and also dynamically evolves with the time and the environment. Thus, new intelligence emerges from the interaction among systems. Starting from the evolution of the SUS structure, this paper proposes the model of a three-layer structure and a relationship involving the data-link layer, the SUS, and the task requirements. The multidimensional spatial relationship model is transformed into a two-dimensional graphical representation model by using a graph neural network; then, the dependency graph of the relationships of the systems and layers of the SUS is constructed. The integral network is classified according to a task-based standard. The recursive neural network algorithm is derived from the intra- and interlayer relationships. The SUS structure is predicted via some examples of training data sets and the attribute labels of task-based nodes. The impact of the system or data layer damage can be evaluated according to the weight parameters of the structure dependence relationship. Finally, the autonomous decision of the SUS from the task to the swarm structure is realized.

Keywords swarm unmanned system, adaptive structure, graph neural network, evolution, intelligent emergence, structure prediction



Tingting ZHANG is an associate professor of computer and military software engineering at the Army Engineering University of PLA, Nanjing, China, where she received the B.S. and M.S. degrees in computer science and information technology in 2003 and 2007, respectively, and the Ph.D. degree in military communication, in 2016. She is currently a post-doctoral fellow at Southeast University and the 28th Research Institute of China Electronics

Technology Group Corporation. Her major research interests are evolutionary computing, intelligent computing, swarm unmanned system, software engineering, system and systems engineering, and system engineering.



Aiguo SONG received the B.S. degree in automatic control and the M.S. degree in measurement and control from Nanjing University of Aeronautics and Astronautics, in 1990 and 1993, respectively, and the Ph.D. degree in measurement and control from Southeast University in 1996. He is currently a professor at the School of Instrument Science and Engineering, Southeast University. His current interests concentrate on teleoperation, haptic display, Internet telerobotic, and distributed measurement systems.



Yushi LAN is a researcher of the 28th Research Institute of China Electronics Technology Group Corporation, Nanjing, China. He received the B.S. degree in computer science and information technology from Shandong University in 1982. His major research interests are swarm unmanned system, distributed systems, information system engineering, system and systems engineering, and system engineering.