

# 基于 ShapeNet 的非合作无人机自组织网络通联拓扑推理技术

侯长波<sup>1,2</sup>, 艾琦迅<sup>1</sup>, 周志超<sup>1</sup>, 钮振宇<sup>1</sup>, 宋振<sup>1</sup>

(1. 哈尔滨工程大学信息与通信工程学院, 黑龙江 哈尔滨 150001;

2. 哈尔滨工程大学先进船舶通信与信息技术工业和信息化部重点实验室, 黑龙江 哈尔滨 150001)

**摘要:** 针对非合作场景下的无人机 (UAV) 自组织通信网络拓扑推理问题, 提出了一种基于可解释神经网络 ShapeNet 的拓扑推理方法。首先, 构建了非合作无人机自组织网络拓扑推理系统模型, 并阐述了拓扑推理机理; 然后, 基于时间序列中的形状特征子序列 (Shapelets) 设计了一种通信状态时间序列分类算法, 根据分类结果还原网络拓扑结构; 最后, 设计并搭建了 ShapeNet 模型以进一步加快拓扑推理速度。实验结果表明, ShapeNet 模型能够分辨出通信状态时间序列间的“伪因果关系”, 并可以利用 GPU 的并行处理机制实现拓扑推理加速。相较于基准方法, 所提方法表现出了最高推理精度与最少推理耗时。

**关键词:** 自组织通信网络; ShapeNet; 拓扑推理; 形状特征; Shapelets

中图分类号: TN971

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025220

## Communication topology inference technology for non-cooperative UAV self-organizing networks based on ShapeNet

HOU Changbo<sup>1,2</sup>, AI Qixun<sup>1</sup>, ZHOU Zhichao<sup>1</sup>, NIU Zhenyu<sup>1</sup>, SONG Zhen<sup>1</sup>

1. College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China

2. Key Laboratory of Advanced Marine Communication and Information Technology, Ministry of Industry and Information Technology, Harbin Engineering University, Harbin 150001, China

**Abstract:** To solve the problem of topology inference in unmanned aerial vehicle (UAV) self-organizing communication networks under non-cooperative scenarios, a topology inference method based on the interpretable neural network named ShapeNet was proposed. Firstly, a topology inference system model of the non-cooperative UAV self-organizing network was established to describe the topology inference mechanism. Then, a time-series classification algorithm for communication states based on the shape features (Shapelets) of subsequences in time-series was developed, and the network topology structure was reconstructed according to the classification results. Finally, the ShapeNet model was developed to further enhance the efficiency of the topology inference process. The experimental results show that the ShapeNet model can distinguish the “pseudo-causality relationships” among communication-state time-series and leverage the parallel processing mechanism of the GPU to accelerate topology inference. Compared with baseline methods, the proposed approach achieves the highest inference accuracy and the least inference time.

**Keywords:** self-organizing communication network, ShapeNet, topology inference, shape feature, Shapelets

收稿日期: 2025-07-22; 修回日期: 2025-11-04

通信作者: 艾琦迅, 323080079@hrbeu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.U23A20271); 中央高校基本科研业务费专项资金资助项目 (No.3072025ZN0801)

**Foundation Items:** The National Natural Science Foundation of China (No.U23A20271), The Fundamental Research Funds for the Central Universities (No.3072025ZN0801)

## 0 引言

当前, 无人机 (UAV, unmanned aerial vehicle) 产业发展势头正盛, 各种先进的无人机技术层出不穷, 促进了其在军事领域的应用<sup>[1-3]</sup>。无人机集群系统作为一种先进的军事作战力量, 其能够克服单架无人机系统在计算资源、通信能力等方面存在的局限, 通过内部节点之间的协同工作来完成复杂的战场作战任务<sup>[4-6]</sup>。无人机集群系统的正常运行依赖于其内部组建的无线通信网络, 而无人机自组织网络凭借其高灵活性、强抗毁性与易于部署等性能优势<sup>[7-9]</sup>, 能够更好地应用于复杂作战场景, 已经成为无人机集群系统中广泛采用的通信网络形式。

虽然无人机自组织通信网络技术目前已非常成熟并在军事上得到了广泛应用, 但从电子对抗的角度来看, 关于战场非合作场景下无人机自组织网络认知技术的相关研究却相对不足, 特别是对网络通联拓扑这一高级语义层面的推理认知<sup>[10-11]</sup>。网络通联拓扑承载了网络中节点间的通信链路信息, 有效推理敌方目标无人机自组织网络通联拓扑能够了解网络中各节点的基本通信情况, 进而帮助对目标网络的干扰方案制定与战术策略实施。因此, 研究非合作场景下无人机自组织网络通联拓扑推理技术, 对于提高无人机集群网络认知能力与水平和抢占战场信息主动权具有重要意义。

近年来, 许多学者在非合作通信网络拓扑推理领域开展了大量研究工作。文献[12]提出了一种基于 K 近邻算法的无线通信网络拓扑推理方法, 通过多传感器收集网络中各节点属性信息, 以此作为特征并用 K 近邻算法作为分类器推理网络拓扑结构。文献[13]提出了一种基于临界传输距离的无线自组织网络拓扑推理方法, 在节点数量、节点位置和部署区域信息已知的情况下推导出具有临界传输距离的网络拓扑结构。文献[12-13]均需要通过获取各种网络中的节点属性信息作为先验信息来进行拓扑推理, 这在非合作场景中通常难以实现, 并且推理性能也很大程度上受限于这些先验信息的准确性。

文献[14]提出了一种针对无线竞争类多路访问控制 (MAC, multiple access control) 协议通信网络的拓扑推断方法, 采用密度聚类算法对采集到的信号进行接续关系的匹配, 从而直接获得网络中存在的通信链路。文献[15]提出了一种基于压缩感知的

通信网络拓扑推断方法, 利用数据与响应信号之间的接续关系构造压缩感知方程, 再通过稀疏向量重构算法对压缩感知方程进行求解, 进而推理出网络拓扑结构。文献[14-15]仅通过分析网络中各节点发射的通信信号来实现网络拓扑结构推理, 减少了所需先验信息的节点种类与数量, 从而能够更好地适用于非合作场景。但对于通信信号数量较多的情况, 这种拓扑推理方法的计算复杂度也会随之增大, 从而极大地降低了拓扑推理的效率。

文献[16]研究了一种基于格兰杰因果检验的无线通信网络拓扑推理方法, 利用网络中各节点发射信号数据包的时间戳序列构建线性自回归模型并求解获得节点间的通联关系。文献[17]提出了一种无线网络拓扑盲推理框架, 该框架首先对信号进行了盲源分离, 然后对分离后的整段时间序列应用格兰杰因果检验、转移熵、神经网络等多种因果关系推理方法计算出网络拓扑结构。文献[18]分别研究了相关性分析、格兰杰因果检验、转移熵与多维霍克斯过程方法在非合作场景无人机通信网络拓扑推理上的应用, 并通过理论分析与仿真实验说明了各方法在所构建场景下的拓扑推理性能。文献[19]提出了一种无人机通信网络拓扑推理方法, 首先采用多维霍克斯过程方法对网络中的通信事件序列建模, 然后结合滑动时间窗口机制与最大加权似然估计算法实现网络拓扑推理。文献[16-19]通过分析网络中每个节点对对应通信时间序列或通信事件序列间的相关性与因果性来判断它们之间是否存在通联关系, 进而推理出整个网络拓扑结构。这种方法相较于逐一分析通信信号的拓扑推理方法能够大幅减小推理的计算复杂度, 并且适用于非合作场景。但是这种方法的推理精度受节点间的通信行为影响较大, 并且推理的计算复杂度受网络节点数量和时间序列长度影响较大, 导致该方法的推理鲁棒性较差, 限制了其在实际场景中的应用与部署。

基于上述拓扑推理方法存在的问题, 本文提出了一种基于 ShapeNet 的非合作无人机自组织网络通联拓扑推理方法。首先构建由飞行自组网 (FANET, flying ad-hoc network) 与拓扑感知系统组成的非合作无人机自组织网络拓扑推理系统模型, 并将由节点间的通信响应机制所形成的形状特征子序列 Shapelets 作为推理依据。然后设计了一种基于 Shapelets 的拓扑推理算法, 该算法通过计算每

个组合时间序列与 Shapelets 的最小欧氏距离来判断节点对间是否存在通信链路,并在此基础上搭建了一种可解释神经网络 ShapeNet,其能够实现 Shapelets 特征的自动提取与关键字序列的自动定位,最终实现时间序列分类与网络拓扑推理。最后仿真结果显示,ShapeNet 模型相较于基线方法表现出了最好的推理精度与推理速度性能。

## 1 基本原理

### 1.1 系统模型

考虑如图 1 所示的物理场景,包括一个无人机自组织网络和一个拓扑感知系统,其中无人机自组织网络采用 FANET 通信架构,网络内各节点根据相关协议形成通联拓扑关系并进行信号传输,从而实现节点间的相互通信。拓扑感知系统的主要功能是侦察截获目标无人机自组织网络节点发射信号,并在不对信号进行解码分析的情况下实现网络拓扑结构的推理。下面将进一步对 FANET 模型与拓扑感知系统模型进行介绍。

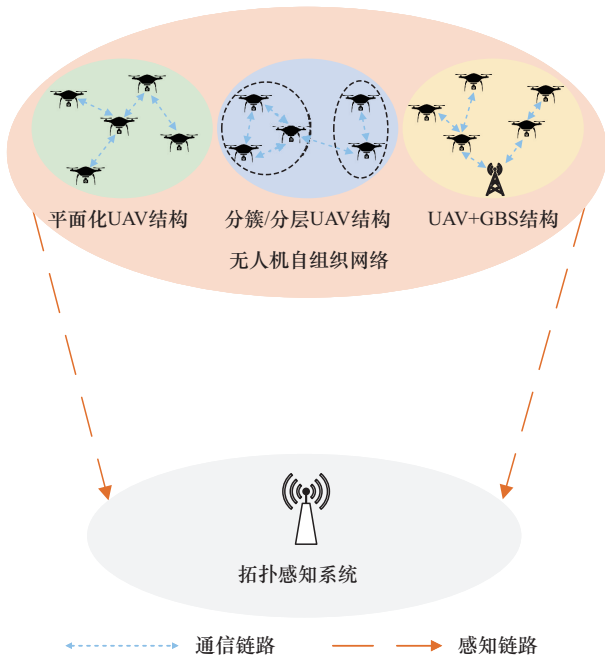


图 1 非合作无人机自组织网络拓扑推理场景

#### 1.1.1 FANET 模型

现有 FANET 模型结构主要包括平面化 UAV、分簇/分层 UAV 和 UAV+地面基站 (GBS, ground based station) 结构。由于 FANET 模型的具体结构与本文算法的原理无关,不会对算法推理效果与性

能产生任何影响,因此本文对此不作限制,即 FANET 模型可以基于上述任意结构进行构建<sup>[20-22]</sup>。

在本文所构建的拓扑推理场景中,FANET 的所有节点是通过物理层信号的发送与接收来进行相互通信的。而 MAC 层作为物理层的上一层,其主要负责信道接入的管理与协调任务,控制着信号的发送时间、发起节点和帧结构,对物理层信号的正常传输具有重要作用。因此,针对 FANET 的 MAC 层协议,本文选择 802.11 协议的 MAC 层中经典的带有冲突避免的载波侦听多址接入 (CSMA/CA, carrier sense multiple access with collision avoidance) 协议作为研究对象并对其展开分析。

CSMA/CA 协议主要是以分布式协调功能实现源节点和目的节点之间的通信过程,原理如图 2 所示,其中, DIFS 为分布式帧间间隔, SIFS 为短帧间间隔, RTS 为请求发送, CTS 为清除发送, NAV 为网络分配向量。从图 2 中可以看出,采用 CSMA/CA 协议的 FANET 在进行通信时其内部各节点发射的物理层信号在时序上具有一定的关系和规律,即源节点与目的节点之间存在响应机制,源节点发送的数据帧与目的节点发送的 ACK 帧在整个时序上呈现出严格的先后对应关系。基于上述分析,本文后续将通过这一关系和规律来挖掘无人机自组织网络中各节点的通联关系,从而推理出网络拓扑结构。

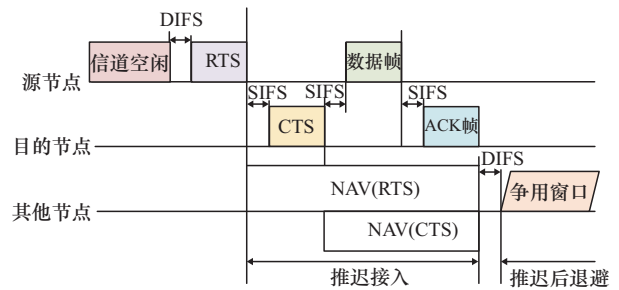


图 2 CSMA/CA 协议原理

#### 1.1.2 拓扑感知系统模型

在非合作场景下,拓扑感知系统与目标无人机自组织网络之间是 2 个相互独立的系统,目标无人机自组织网络的相关通信参数信息对于拓扑感知系统是未知的,因此拓扑感知系统想要通过解析接收到的目标网络发射的数据包信息来推断其网络拓扑结构是非常困难的。因此,本文所构建的拓扑感知系统是通过侦察到的物理层时序信号来实现拓扑推

理的, 这种物理层时序信号通常易于被侦察获取, 所以更适用于非合作场景。

拓扑感知系统由一个信号侦察子系统、一个数据预处理子系统和一个拓扑推理子系统构成, 其中信号侦察子系统负责在一定时间内感知采集拓扑推理场景中存在的电磁信号, 获得相应的信号时序数据并传递给数据预处理子系统。需要说明的是, 关于利用信号侦察子系统采集目标无人机自组织网络中各个节点对应信号的可靠性与可行性, 本文进一步通过在真实环境下实采的信号时序公开数据集对其进行分析与验证<sup>[23]</sup>, 该数据集包括信号侦察子系统接收机直接采集的原始信号时序数据以及该数据中所有有用信号对应的发送节点编号。通过该公开数据集可以发现, 即使是在复杂的真实环境下, 信号侦察子系统依然能够准确获得目标无人机自组织网络中各个节点相应的信号时序数据, 从而证明了信号侦察子系统在接收目标无人机自组织网络中各个节点对应信号方面具有较高的可靠性与可行性。对于数据预处理子系统, 其首先需要完成对接收信号时序数据的个体识别与源分离, 得到目标网络中各节点的发射信号时间序列。然后将每个发射信号时间序列按照长度为  $T_s$  的感知时隙进行划分, 划分成  $N$  个时隙, 并通过幅值检测寻找每一数据包对应信号的结束时刻, 将该时刻所在的时隙赋值为 1, 其余时隙均赋值为 0, 从而消除可变数据帧长度对后续拓扑推理的影响。该处理过程可以具体表示为

$$t'_n = \begin{cases} 1, & (n-1)T_s \leq k < nT_s, n \leq N \\ 0, & \text{其他} \end{cases} \quad (1)$$

其中,  $n$  表示时隙的索引,  $t'_n$  表示对信号时间序列

划分后第  $n$  个时隙的值,  $k$  表示数据包对应信号的结束时刻索引, 其满足式(2)所示关系。

$$t_k \geq \delta, t_{k+1} < \delta \quad (2)$$

其中,  $\delta$  表示幅值检测的阈值,  $t_k$  与  $t_{k+1}$  分别表示未划分信号时间序列在  $k$  与  $k+1$  时刻的幅值大小。通过上述过程, 可以将发送信号时间序列转换为一段二进制通信结束状态时间序列用于后续分析, 图 3 展示了通信结束状态时间序列的生成过程。

在数据预处理子系统生成所有节点对应的通信结束状态时间序列后, 将它们输入拓扑推理子系统进行计算分析, 最终由拓扑推理子系统输出目标无人机自组织网络的通联拓扑结构。

### 1.2 推理机理

在分析本文对目标无人机自组织网络的拓扑推理机理之前, 首先假设拓扑感知系统已完成了对目标无人机自组织网络发射通信信号的侦察采集与数据预处理工作, 得到了各节点对应的通信结束状态时间序列。

本文将待推理的目标无人机自组织网络拓扑分为静态拓扑和动态拓扑 2 种, 其中静态拓扑是指在整个观测周期内网络通联关系始终保持不变的拓扑, 动态拓扑是指在整个观测周期内网络通联关系会发生变化的拓扑。对于静态拓扑, 本文的推理目标是直接得到其对应的单一拓扑结构形式。而对于动态拓扑, 其可以看作是由多段小观测周期内的静态拓扑组成的拓扑序列, 本文的推理目标是得到动态拓扑对应全部静态拓扑的多种拓扑结构形式, 并将它们组成拓扑序列作为拓扑推理结果。因此, 对静态拓扑与动态拓扑的推理实际上都是通过静态




图 3 通信结束状态时间序列的生成过程

拓扑的推理实现的,故后续主要以静态拓扑为推理目标进行推理机理的介绍,该推理机理在动态拓扑情况下也同样适用。

本文 1.1.1 节阐述了所构建 FANET 模型中各节点发射的物理层信号在时序上存在一定的规律,即源节点发送的数据帧会引起目的节点在固定时间后发送 ACK 帧,使源节点和目的节点的发送信号在时序上存在严格的先后对应关系。基于此,本文利用这种关系来推理无人机自组织网络的通联拓扑结构。对于网络中任意 2 个节点对应的通信结束状态时间序列  $T_i$  与  $T_j$ , 将它们相加组合为该节点对的通信结束状态时间序列  $T_{ij} = T_i + T_j$ 。本文定义通信链路是指通信节点对物理相邻并能够直接相互通信所建立的连接,对于节点对之间进行单跳或多跳间接通信的情况,它们之间存在多条通信链路。当该节点对之间存在通信链路时,  $T_{ij}$  会表现出“数据帧请求-ACK 帧响应”的通信行为模式,即  $T_{ij}$  中存在由数据帧结束状态时隙开始到 ACK 帧结束状态时隙结束的特征时间子序列  $S$ , 其可以表示为

$$S = [1, 0, 0, \dots, 0, 1] \in \mathbb{R}^L \quad (3)$$

其中,特征时间子序列  $S$  中开始位置处的“1”表示数据帧结束状态时隙的对应值,结尾位置处的“1”表示 ACK 帧结束状态时隙的对应值,  $L$  表示  $S$  的长度,其满足式(4)所示关系。

$$L = l_{\text{SIFS}} + l_{\text{ACK}} + 1 \quad (4)$$

其中,  $l_{\text{SIFS}}$  表示 SIFS 长度对应的时隙数量,  $l_{\text{ACK}}$  表示 ACK 帧长度对应的时隙数量。而当该节点对之间不存在通信链路时,  $T_{ij}$  中不会存在  $S$ 。因此,对无人机自组织网络的拓扑推理问题可以转化为对网络中每对节点对应通信结束状态时间序列的二分类问题,若时间序列中存在  $S$  则识别为一类,说明该节点对之间存在通信链路;若时间序列中不存在  $S$  则识别为另一类,说明该节点对之间不存在通信链路。

采用无向图  $G = (V, E)$  表示目标无人机自组织网络的拓扑结构,其中  $V$  与  $E$  分别表示  $G$  中含有的顶点集合与边集合,分别对应目标无人机自组织网络含有的节点与通信链路。根据本文采用的拓扑推理机理,对于一个含有  $N$  个节点的  $G$ , 推理过程可以用其邻接矩阵  $A = [a_{ij}] \in \mathbb{R}^{N \times N}$  表示为

$$a_{ij} = \begin{cases} 1, & i \neq j \text{ 并且 } S \text{ 存在于 } T_{ij} \\ 0, & i = j \text{ 或者 } S \text{ 不存在于 } T_{ij} \end{cases} \quad (5)$$

其中,  $T_{ij}$  表示第  $i$  个节点与第  $j$  个节点对应的组合通信结束状态时间序列,  $S$  表示特征时间子序列。若  $a_{ij} = 1$ , 则两节点之间存在连边关系;若  $a_{ij} = 0$ , 则两节点之间不存在连边关系。本文认为每个节点与自身之间不存在连边关系,即当  $i = j$  时,  $a_{ij}$  恒等于 0。因此,通过对  $G$  中所有节点对进行式(5)所示的分析,最终获得相应的邻接矩阵  $A$  作为推理出的目标无人机自组织网络的拓扑结构。

## 2 算法设计

### 2.1 基于 Shapelets 的拓扑推理算法

Shapelets 的概念最初由 Ye 等<sup>[24]</sup>提出,其是指时间序列数据中的最大可区分序列。对于含有  $N$  个节点的目标无人机自组织网络,将其中每 2 个节点对应通信结束状态时间序列进行相加组合,得到相应的时间序列集合  $X$  为

$$X = \{T_{0,1}, T_{0,2}, \dots, T_{ij}, \dots, T_{(N-1),N}\} \quad (6)$$

其中,  $T_{ij}$  表示节点  $i$  与节点  $j$  对应信号时间序列的相加组合,共有  $\frac{N(N-1)}{2}$  种组合方式。对于每一个  $T_{ij} = [t_0, t_1, \dots, t_{m-1}]$ , 其中  $m$  表示  $T_{ij}$  的长度,根据 1.2 节中阐述的推理机理,将由数据帧结束状态时隙开始到 ACK 帧结束状态时隙结束的特征时间子序列  $S$  作为 Shapelets, 并按照  $S$  的长度  $L$  对  $T_{ij}$  进行划分,得到划分后的时间子序列为

$$x_{ij}^{(h)} = [t_h, t_{h+1}, \dots, t_{h+L-1}] \quad (7)$$

其中,  $h$  表示时间子序列的数据起始点索引,其满足关系  $0 \leq h \leq m - L$ 。对于每个时间子序列  $x_{ij}^{(h)}$ , 计算其与  $S$  的欧氏距离为

$$\text{dist}(x_{ij}^{(h)}, S) = \sqrt{\sum_{l=1}^L (x_{ij}^{(h)}[l] - S[l])^2} \quad (8)$$

采用  $T_{ij}$  中每个  $x_{ij}^{(h)}$  与  $S$  的最小欧氏距离作为判别依据,其被定义为

$$d(T_{ij}, S) = \min_{h=0}^{m-L} \text{dist}(x_{ij}^{(h)}, S) \quad (9)$$

最后,对于  $X$  中的每个  $T_{ij}$  计算其与  $S$  的最小欧氏距离,得到推理出的拓扑结构为

$$a_{ij} = \begin{cases} 1, & d(\mathbf{T}_{ij}, \mathbf{S}) = 0 \\ 0, & d(\mathbf{T}_{ij}, \mathbf{S}) \neq 0 \end{cases} \quad (10)$$

其中, 若  $d(\mathbf{T}_{ij}, \mathbf{S}) = 0$  则表示第  $i$  个节点与第  $j$  个节点之间有连边关系; 若  $d(\mathbf{T}_{ij}, \mathbf{S}) \neq 0$  则表示第  $i$  个节点与第  $j$  个节点之间没有连边关系。综上, 基于 Shapelets 的拓扑推理算法如算法 1 所示。

#### 算法 1 基于 Shapelets 的拓扑推理

给定目标无人机自组织网络所含节点数  $N$ , 每个节点对的组合通信结束状态时间序列长度  $m$ , 所有节点对的组合通信结束状态时间序列集合  $\mathbf{X}$ , 长度为  $L$  的特征时间子序列  $\mathbf{S}$ 。初始化目标无人机自组织网络拓扑结构  $a_{ij} = 0, 0 \leq i \leq N - 1, 0 \leq j \leq N - 1$

- 1) 循环
- 2) for  $\mathbf{T}_{ij}$  in  $\mathbf{X}$
- 3) 给定  $\mathbf{T}_{ij} = [t_0, t_1, \dots, t_{m-1}]$ , 初始化  $\mathbf{T}_{ij}$  的子序列与  $\mathbf{S}$  的距离集合  $\mathbf{x}_{ij} = \{\}$
- 4) 循环
- 5) for  $h=0:1:(m-L)$
- 6)  $\mathbf{x}_{ij}^{(h)} = [t_h, t_{h+1}, \dots, t_{h+L-1}]$
- 7)  $\text{dist}(\mathbf{x}_{ij}^{(h)}, \mathbf{S}) = \mathbf{x}_{ij}^{(h)} \oplus \mathbf{S}$
- 8)  $x_{ij} = x_{ij} \cup \{\text{dist}(\mathbf{x}_{ij}^{(h)}, \mathbf{S})\}$
- 9) end for
- 10)  $d(\mathbf{T}_{ij}, \mathbf{S}) = \min(x_{ij})$
- 11) if  $d(\mathbf{T}_{ij}, \mathbf{S}) = 0$
- 12)  $a_{ij} = 1$
- 13) end if
- 14) end for

从算法 1 可以看出, 基于 Shapelets 的拓扑推理算法需要对所有节点对对应的通信结束状态时间序列及其子序列进行逐一遍历, 导致其计算复杂度很高, 难以在实际场景中直接应用。

## 2.2 基于 ShapeNet 的拓扑推理算法

针对基于 Shapelets 的拓扑推理算法计算复杂度高的问题, 本文结合深度学习理论, 提出了一种基于 ShapeNet 的拓扑推理算法。首先, 本文认为 Shapelets 方法中对时间子序列的遍历可以等效为一维卷积层中与时间子序列长度相同的卷积核以步长为 1 在时间序列上的滑动。对于含有  $N$  个节点的目标无人机自组织网络, 所有节点对的组合时间序列向量  $\mathbf{T}$  可以表示为

$$\mathbf{T} = [\mathbf{T}_{0,1}, \mathbf{T}_{0,2}, \dots, \mathbf{T}_{ij}, \dots, \mathbf{T}_{(N-1),N}]^{\left(\frac{N(N-1)}{2}\right) \times m} \quad (11)$$

其中,  $\mathbf{T}_{ij}$  表示第  $i$  个节点与第  $j$  个节点对应通信结束状态时间序列的相加组合,  $m$  表示  $\mathbf{T}_{ij}$  的长度。对  $\mathbf{T}$  进行一维卷积的计算过程可以表示为

$$\mathbf{Y}_h = \mathbf{T}[:, h:h+L-1] \cdot \mathbf{W} \quad (12)$$

其中,  $h$  表示时间子序列的数据起始点索引,  $L$  表示卷积核的长度,  $\mathbf{T}[:, h:h+L-1] \in \mathbb{R}^{\left(\frac{N(N-1)}{2}\right) \times L}$  表示  $\mathbf{T}$  中所有组合时间序列在以  $h$  为起始点的时间子序列向量,  $\cdot$  表示向量的批量点积运算,  $\mathbf{W} \in \mathbb{R}^{n_{\text{out}} \times L}$  表示卷积核的可学习权重,  $n_{\text{out}}$  表示输出特征维度大小,  $\mathbf{Y}_h \in \mathbb{R}^{\left(\frac{N(N-1)}{2}\right) \times n_{\text{out}}}$  表示对  $\mathbf{T}[:, h:h+L-1]$  进行卷积计算输出的特征向量。对  $\mathbf{T}$  中每个特征时间子序列向量卷积得到的  $\mathbf{Y}_h$  沿最后一个维度拼接, 得到最终的输出特征向量  $\mathbf{Y} \in \mathbb{R}^{\left(\frac{N(N-1)}{2}\right) \times n_{\text{out}} \times (m-L+1)}$ 。

其次, 对于卷积核的可学习权重  $\mathbf{W}$ , 令  $n_{\text{out}} = 1$ , 则  $\mathbf{W} \in \mathbb{R}^L$  可以通过训练学习来拟合特征时间子序列  $\mathbf{S}$ , 从而使卷积输出  $\mathbf{Y}_h$  近似等于  $\mathbf{S}$  与输入时间子序列向量  $\mathbf{T}[:, h:h+L-1]$  的欧氏距离, 即

$$\mathbf{Y}_h \approx \text{dist}(\mathbf{T}[:, h:h+L-1], \mathbf{S}) \quad (13)$$

最后, 将 Shapelets 方法中计算时间序列的所有子序列与特征子序列的最小欧氏距离作为判别依据, 本文考虑采用全局最大池化层进行替代。对于向量  $\mathbf{Y}_h$ , 全局最大池化计算可以表示为

$$\mathbf{Z} = \text{GlobalMaxPooling}(\forall_{h \in [0, m-L]} \mathbf{Y}_h) \quad (14)$$

其中,  $\mathbf{Z} \in \mathbb{R}^{\left(\frac{N(N-1)}{2}\right) \times 1}$  表示全局最大池化层的输出特征向量,  $\text{GlobalMaxPooling}(\cdot)$  表示计算所有输入特征向量中的最大值。通过上述分析可知, 通过对权重的训练与学习可以使  $\mathbf{Y}_h$  等同于时间子序列向量与特征子序列之间的欧氏距离, 为了使全局最大池化层输出所有向量  $\mathbf{Y}_h$  中的最小值, 需要将式(14)重新改写为

$$\mathbf{Z}' = -\text{GlobalMaxPooling}(-\forall_{h \in [0, m-L]} \mathbf{Y}_h) \quad (15)$$

其中,  $\mathbf{Z}' \in \mathbb{R}^{\left(\frac{N(N-1)}{2}\right) \times 1}$  为输出特征向量, 代表所有输入特征向量的最小值。因此可以看出, 式(15)的计算形式与式(9)相同, 最终输出的特征向量  $\mathbf{Z}'$  表示所有时间子序列与特征子序列之间的最小欧氏

距离, 可以作为是否存在通信链路的判断依据。

根据上述推导过程, 本文设计了用于推理目标无人机自组织网络拓扑结构的 ShapeNet 模型, 该模型结构如图 4 所示。其中第 1 层一维卷积层用于提取输入时间序列中长度为  $L$  的各时间子序列与特征子序列之间的欧氏距离。在完成卷积操作后, 通过全局最大池化层提取输入各通道对应时间子序列与特征子序列之间欧氏距离的最小值。最后再将全局最大池化层的输出特征输入全连接层, 实现二元分类。全连接层的计算式为

$$\mathbf{C} = \mathbf{Z}'\mathbf{W}' + \mathbf{b} \quad (16)$$

其中,  $\mathbf{C} \in \mathbb{R}^{\left(\frac{N(N-1)}{2}\right) \times 2}$  表示全连接层的输出向量,  $\mathbf{W}'$  表示全连接层的权重矩阵,  $\mathbf{b}$  表示全连接层的偏置向量。通过  $\mathbf{C}$  可得到推理出的网络拓扑结构为

$$a_{ij} = \begin{cases} 1, & \text{argmax}(\mathbf{C}[h]) = 1 \\ 0, & \text{argmax}(\mathbf{C}[h]) = 0 \end{cases} \quad (17)$$

$$h = \frac{i(2N - i - 1)}{2} + (j - i - 1) \quad (18)$$

其中,  $\text{argmax}(\cdot)$  表示输入向量中最大值对应的索引, 若  $\text{argmax}(\mathbf{C}[h]) = 1$  则表示第  $i$  个节点与第  $j$  个节点之间有连边关系; 若  $\text{argmax}(\mathbf{C}[h]) = 0$  则表示第  $i$  个节点与第  $j$  个节点之间没有连边关系。基于 ShapeNet 的拓扑推理算法如算法 2 所示。

#### 算法 2 基于 ShapeNet 的拓扑推理

给定目标无人机自组织网络所含节点数  $N$ , 组合通信结束状态时间序列长度  $m$ , 组合通信结束状态时间序列向量  $\mathbf{T}$ , 特征子序列长度  $L$ , 训练后的 ShapeNet 模型权重文件为  $\mathbf{D}$ , 其中包括卷积层的权重矩阵  $\mathbf{W}$  与全连接层的权重矩阵  $\mathbf{W}'$ 。初始化 ShapeNet 模型为  $\mathbf{M}$ , 目标无人机自组织网络拓扑结构  $a_{ij} = 0, 0 \leq i \leq N - 1, 0 \leq j \leq N - 1$

- 1) 加载模型权重文件  $\mathbf{D}$ , 并导入模型  $\mathbf{M}$
- 2) with torch.no\_grad(), 即禁止梯度计算与更

新, 其含义是令  $\mathbf{M}$  进入推理阶段,  $\mathbf{M}$  参数在后续步骤中始终保持不变

- 3) 将  $\mathbf{T}$  输入  $\mathbf{M}$
- 4) 循环
- 5) for  $h=0:1:(m-L)$
- 6) 利用卷积核提取  $\mathbf{T}$  的时间子序列  $\mathbf{T}[:, h:h+L-1]$
- 7)  $\mathbf{Y}_h = \mathbf{T}[:, h:h+L-1] \cdot \mathbf{W}$
- 8) end for
- 9)  $\mathbf{Z}' = -\text{GlobalMaxPooling}(-\forall_{h \in [0, m-L]} \mathbf{Y}_h)$
- 10)  $\mathbf{C} = \mathbf{Z}'\mathbf{W}' + \mathbf{b}$
- 11) 初始化  $i=0, j=1$
- 12) 循环
- 13) for  $i=0:1:(N-2)$
- 14) 循环
- 15) for  $j=(i+1):1:(N-1)$
- 16)  $h = \frac{i(2N - i - 1)}{2} + (j - i - 1)$
- 17) if  $\text{argmax}(\mathbf{C}[h]) = 1$
- 18)  $a_{ij} = 1$
- 19) end if
- 20) end for
- 21) end for

### 3 计算复杂度分析

对于基于 Shapelets 的拓扑推理算法, 由算法 1 可知, 其计算复杂度为  $O(mN^2)$ , 其中  $N$  表示输入无人机自组织网络中的节点个数,  $m$  表示组合通信结束状态时间序列的长度。而对于基于 ShapeNet 的拓扑推理算法, 由算法 2 可知, 其计算复杂度也为  $O(mN^2)$ , 由此可以看出, 基于 Shapelets 的拓扑推理算法与基于 ShapeNet 的拓扑推理算法在理论上的计算复杂度相同。然而, 基于 ShapeNet 的拓扑推理算法可以通过 GPU 对输入时间序列矩阵进

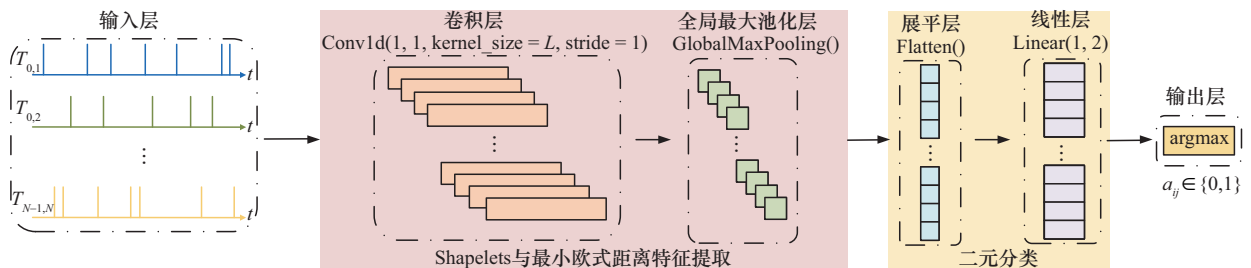


图 4 ShapeNet 模型结构

行并行处理,从而能够大幅减少推理时间。因此,本文拟将算法2中的ShapeNet模型部署在GPU上,通过硬件加速手段来体现算法2在拓扑推理速度上的优势。

## 4 仿真分析

### 4.1 参数设置

为进一步验证本文算法的有效性,采用NS-3网络模拟器进行无人机自组织网络的通信行为模拟,初始化时无人机自组织网络中的各节点与拓扑感知节点随机分布在[1 000 m, 1 000 m]的矩形平面区域,同时保证网络处于完全连通状态,拓扑感知节点可以探测到网络中所有节点发射的物理层信号,其余仿真参数设置如表1所示。最终基于1.2节的推理机理,分别通过参数设置与仿真执行、通信日志文件生成、通信日志文件中的关键字段提取与记录、时隙划分与二值化赋值以及各节点对对应通信结束状态时间序列的相加组合来生成组合通信结束状态时间序列数据,并多次重构无人机自组织网络拓扑形式后重复执行上述步骤,将所有生成的组合通信结束状态时间序列数据进行整合形成所需的通联拓扑推理数据集<sup>[25]</sup>。值得说明的是,该数据集可以进一步转化为静态或动态网络拓扑推理数据集,其中静态网络拓扑推理数据集中的每条数据对应一种拓扑类型,包含该拓扑类型下所有组合通信结束状态时间序列数据。而动态网络拓扑推理数据集中的每条数据对应多种拓扑类型,各种拓扑类型下所有组合通信结束状态时间序列数据集共同构成一个集合序列作为每条数据的表现形式。但无论是静态拓扑推理数据集还是动态拓扑推理数据集,就本文的推理机理而言,对它们进行拓扑推理的目的都是识别出其包含各个组合通信结束状态时间序列对应的通信链路存在情况,对于推理结果与性能也是以每个组合通信结束状态时间序列对应的单条通信链路为单位进行获取与分析的,因此本文在后续的实验设计与结果分析中,将不会对静态与动态拓扑的情况分别进行讨论与说明,而是以每条组合通信结束状态时间序列作为分析对象来统一说明。

根据表1所设置的仿真参数,参考IEEE 802.11b网络标准,网络的物理层速率为1 Mbit/s, SIFS为10  $\mu$ s, DIFS为50  $\mu$ s,并使MAC层通过CSMA/CA协议实现各节点的信道接入。

表1 仿真参数设置

仿真参数	参数值
操作系统	Ubuntu16.04
软件版本	3.27
无人机节点数目	11~31
探测节点数目	1
最大通信距离/m	500
感知范围(最小感知距离)/m	1 000 $\sqrt{2}$
信道模型	电磁波传播时延、范围传播损失模型
传输层协议	UDP
网络层协议	最短路由协议
网络标准	IEEE 802.11b
应用层协议	ServerApps, ClientApps
数据分组发送速率/(bit·s <sup>-1</sup> )	10 240
数据分组大小/B	1 024
节点移动模型	固定位置模型
仿真时长/s	50
感知时隙/ $\mu$ s	50
观测时长/s	0.2~1.0
特征子序列长度	8

另外,根据1.1.2节所构建拓扑感知系统模型,其是由一个信号侦察子系统、一个数据预处理子系统和一个拓扑推理子系统构成的。当拓扑感知系统模型需要获取目标无人机自组织网络的节点数据时,信号侦察子系统首先会被动侦察目标网络发射信号的相关参数,然后利用该侦察到参数实现对目标网络发射时序信号的被动采集。在完成信号采集后,数据预处理子系统会对输入的采集时序信号进行时域能量检测,分离出其中的有用信号,然后进一步对分离出的所有有用信号进行个体识别与源分离,获得无人机自组织网络中各节点对应的发射物理层时序信号数据,最后再基于1.2节所阐述的推理机理,将该物理层时序信号数据转化为拓扑推理子系统所需的组合通信结束状态时间序列数据,即本文所制作的拓扑推理数据,则完成了拓扑感知系统获取无人机自组织网络节点数据的全部过程。对于拓扑推理子系统,将ShapeNet模型作为其核心算法来实现对所有输入的组合通信结束状态时间序列数据的计算与处理,输出所有节点对之间的通信链路存在情况,进而构建出目标无人机自组织网络

对应的网络拓扑结构作为拓扑推理结果。对于 ShapeNet 模型的训练, 本文从通联拓扑推理数据集中选择了 10 000 条观测时长为 2 s 的组合通信结束状态时间序列数据作为训练集, 其中有一半数据对应节点对间存在通信链路的情况, 另外一半数据对应节点对间不存在通信链路的情况。ShapeNet 模型训练超参数设置如表 2 所示。

表 2 ShapeNet 模型训练超参数设置

超参数	参数值
深度学习框架	Pytorch
GPU	NVIDIA GeForce RTX 3070 Ti
batchsize	256
迭代轮数	200
损失函数	交叉熵损失函数
优化器	Adam
学习率	0.01

## 4.2 基线方法

本文采用的对比基线方法包括。

1) 滞后相关性分析<sup>[18]</sup>。该方法通过对网络中每对节点对应时间序列进行互相关性计算, 根据互相关程度推理它们之间的通联关系。后续实验统一设置该方法的滞后系数  $\tau$  与特征子序列长度相同, 即  $\tau = 8$ 。

2) 格兰杰因果检验<sup>[16-18]</sup>。该方法通过判断网络每对节点中一个节点对应时间序列是否有助于预测另一个节点对应时间序列来推理它们之间的通联关系。后续实验同样设置该方法的滞后系数  $\tau = 8$ 。

3) 转移熵<sup>[17-18]</sup>。该方法通过判断网络每对节点中一个节点对应时间序列过去值是否能够降低对另一个节点对应时间序列未来值预测的不确定性来推理它们之间的通联关系。后续实验设置该方法需考虑的滞后系数  $\tau = 8$ 。

4) 多维霍克斯过程<sup>[18-19]</sup>。该方法将各节点对应时间序列视作由一系列通信事件与时刻组成的点过程, 并通过建模各节点对之间事件发生的相互影响强度推理它们之间的通联关系。后续实验设置该方法的激励函数的系数为  $\beta = 4 \times 10^{-4}$ 。

## 4.3 性能指标

本文选取 4 种性能指标来评估算法的拓扑推理性能, 具体包括。

1) 准确率 (Acc, accuracy)。推理准确率即连边关系推理正确的数量与全部连边关系数量的比值, 取值范围在 0~1, 其计算方式可以表示为

$$\text{Acc} = \frac{\sum_{ij \in [0, N-1]} \mathbb{I}[a_{ij} = \hat{a}_{ij}]}{N^2} \quad (19)$$

其中,  $N$  表示目标网络的节点数量,  $a_{ij}$  表示算法推理出的网络拓扑结构中第  $i$  个节点与第  $j$  个节点之间的连边关系,  $\hat{a}_{ij}$  表示真实网络拓扑结构中第  $i$  个节点与第  $j$  个节点之间的连边关系,  $\mathbb{I}[\cdot]$  表示指示函数, 该指示函数里面的内容若为真则返回 1, 否则返回 0。Acc 与算法的拓扑推理性能呈正相关关系。

2) 真阳性率 (TPR, true positive rate)。TPR 也称召回率, 指正确识别出的连边数量与真实存在连边的节点对数量的比值, 取值范围在 0~1。TPR 的计算方式可以表示为

$$\text{TPR} = \frac{\sum_{ij \in [0, N-1]} \mathbb{I}[a_{ij} = 1 \wedge \hat{a}_{ij} = 1]}{\sum_{ij \in [0, N-1]} \mathbb{I}[\hat{a}_{ij} = 1]} \quad (20)$$

其中,  $\wedge$  表示“与”运算符号, 当符号两边的条件均成立时则判定为真, 否则判定为假。TPR 与算法的拓扑推理性能呈正相关关系。

3) 假阳性率 (FPR, false positive rate)。FPR 也称虚警率, 指错误识别出的连边数量与真实不存在连边的节点对数量的比值, 取值范围在 0~1。FPR 的计算方式可以表示为

$$\text{FPR} = \frac{\sum_{ij \in [0, N-1]} \mathbb{I}[a_{ij} = 1 \wedge \hat{a}_{ij} = 0]}{\sum_{ij \in [0, N-1]} \mathbb{I}[\hat{a}_{ij} = 0]} \quad (21)$$

FPR 与算法的拓扑推理性能呈负相关关系。

4) 消耗时间。消耗时间即从输入时间序列数据到输出目标网络拓扑结构所用的时间。消耗时间与算法的拓扑推理性能呈负相关关系。

## 4.4 实验结果分析

### 4.4.1 特征提取效果展示

首先, 本文对 ShapeNet 模型的特征提取效果进行分析。图 5 展示了 ShapeNet 模型中卷积层权重的可视化结果。从图 5 可以看出, 卷积层权重与式(3)所示的特征子序列趋势相同, 因此可以说明 ShapeNet 模型中的卷积层权重实现了对特征子序列的拟合, 并使输出结果近似等于与输入时间子序列与特征子序列的欧氏距离。




图5 ShapeNet模型中卷积层权重值

之后对 ShapeNet 模型中全局最大池化层的特征提取结果进行分析，得到其输出特征向量对应原始组合通信结束状态时间序列中的索引位置如图 6 所示。从图 6 可以看出，全局最大池化层可以实现对原始时间序列中与特征子序列之间欧氏距离最小的子序列的定位，从而得到与式(9)相同的计算结果。由此可以说明，ShapeNet 模型可以自动提取时间序列中的 Shapelets 特征，进而根据该特征完成时间序列的分类与通联关系的判断。




图6 ShapeNet模型中卷积核提取的关键位置特征

### 4.4.2 拓扑推理效果分析

本节主要完成对各个算法拓扑推理效果的分析与比较。图 7 展示了由 11 个节点组成的目标无人机自组织网络的真实通联拓扑结构、相应的邻接矩阵及部分通信状态时间序列数据，其中  $n_1, n_2, \dots, n_{11}$  表示各节点对应的索引编号。图 8 展示了各算法对图 7 所示的目标网络进行推理得到的邻接矩阵可视化结果。从图 8 可以看出，滞后相关性分析、Shapelets 与 ShapeNet 方法推理出目标网络拓扑结构结果完全正确，而格兰杰因果检验、转移熵与多维霍克斯过程方法会存在将无边关系推理为有边关系，导致“虚警”的情况，这是无人机自组织网络中 2 个互相不在彼此通信范围内的节点未监测到信道占用而在一个长度小于滞后系数  $\tau$  的时间窗口内均发送了数据帧或 ACK 帧信号，造成它们对应时间序列之间产生了 3 种方法无法辨别的“伪因果关系”所引起的<sup>[26]</sup>。而滞后相关性分析、Shapelets 与 ShapeNet 方法由于仅分析各节点对应时间序列在固定时间窗口内的起始时隙值与结束时隙值间的对应关系来推理连边情况，忽略了时间窗口内中间时隙值的干扰，所以它们能够有效避免“虚警”推理的发生，实现更好的拓扑推理效果。

### 4.4.3 拓扑推理性能分析

本文从推理精度与推理耗时两方面对各方法的拓扑推理性能进行分析。图 9 与图 10 分别展示了节点数量与观测时长对 100 种无人机自组织网络拓扑结构平均推理 Acc、TPR 与 FPR 的影响曲线，其中图 9 设置固定观测时长为 0.2 s，图 10 设置固定节点数量为 11。由于滞后相关性分析与本文所提 Shapelets 与 ShapeNet 方法本质上都是通过寻找通信节点对发射物理层信号在时序上表现出




图7 目标无人机自组织网络的真实通联拓扑结构及相应的邻接矩阵可视化展示

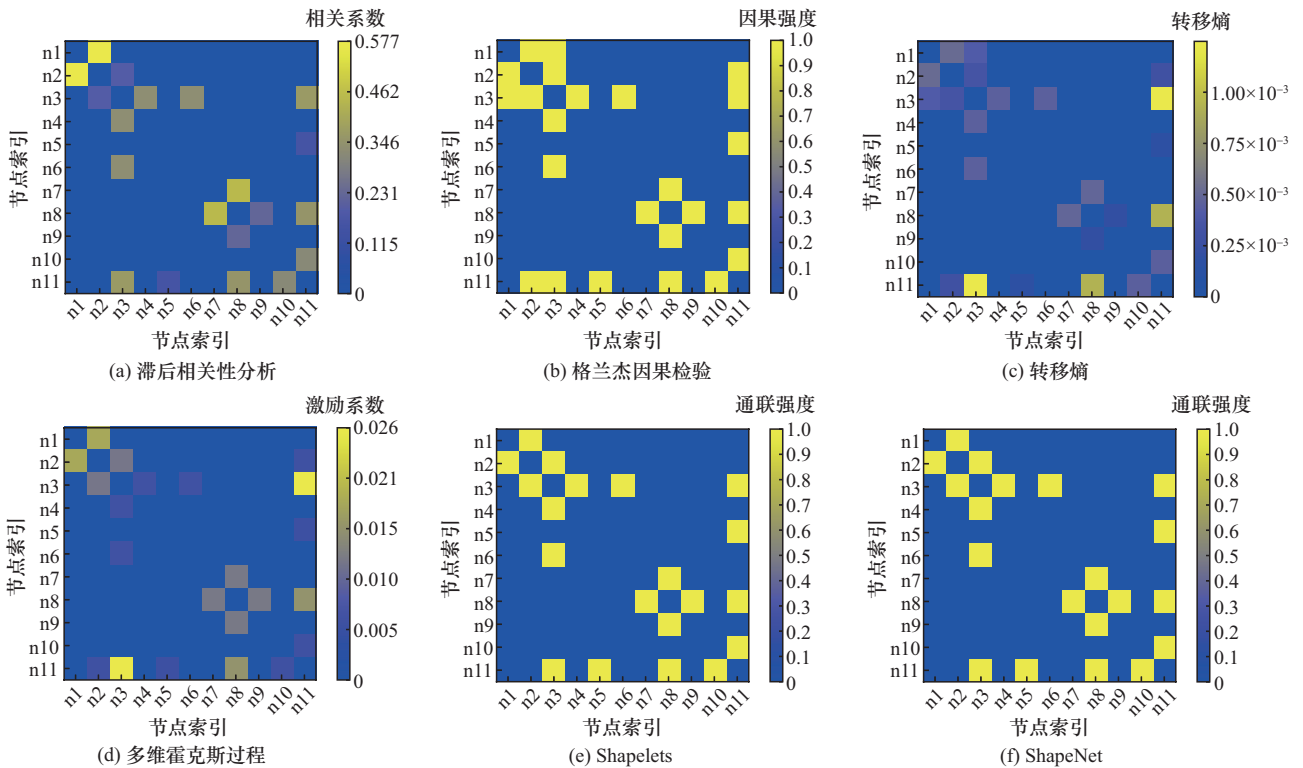


图 8 各方法拓扑推理得到的邻接矩阵可视化展示

的因果响应关系所对应形成的具有固定长度的特征子序列来推理节点间的通信链路存在情况，因此这 3 种方法的拓扑推理精度性能在各种节点数量与观测时长的情况下都是完全相同的。而格兰杰因果检验与转移熵方法本质上是寻找小于固定长度的所有特征子序列来推理通信链路存在情况的，因此这 2 种方法的拓扑推理精度性能在各种节点数量与观测时长的情况下都是完全相同的。为了便于观察与分析各方法的拓扑推理精度性能测试结果，在图 9 与图 10 中将性能完全相同的方法对应的推理精度影响曲线进行了合并显示。从图 9 与图 10 可以看出，滞后相关性分析、Shapelets 与 ShapeNet 方法在不同节点数量与观测时长下均具有最高的平均推理 Acc、TPR 以及最低的平均推理 FPR，说明这 3 种方法的推理精度性能更加优秀，其原因已在 4.4.2 节中进行阐述。此外，图 9 显示各方法的平均 TPR 会随着节点数量的增加而减小，这是因为网络中节点数量越多其对应的连边数量也随之增加，但是在固定观测时长对应的时序序列中存在的“数据帧-ACK 帧”通信事件数量相对固定，因此无法观测到更多增加连边对应的通信事件信息而导致推理 TPR 下降。

图 10 显示各方法的平均 TPR 会随着观测时长的增加而增加，这是因为观测时长越长其对应的时序序列中存在的“数据帧-ACK 帧”通信事件数量越多，但是在固定节点数量时网络对应的连边数量不变，因此能够观测到更多连边对应的通信事件信息而导致推理 TPR 提升。值得进一步说明的是，图 9 与图 10 虽然显示出本文方法相较于基线方法在拓扑推理精度方面性能有所提升，但提升相对有限，因为所有方法本质上都是通过寻找通信节点对在发射物理层时序信号上表现出的因果响应关系所对应形成的特征子序列来判断它们之间通信链路存在情况的，所以各方法的拓扑推理召回率几乎相同，造成本文方法推理精度性能更加优秀的原因是 4.4.2 节中阐述的“伪因果关系”以及算法参数设置问题不会对该方法产生任何影响，但会对格兰杰因果检验、转移熵与多维霍克斯过程方法产生影响而使拓扑推理虚警率增加，从而降低拓扑推理准确率。不过根据 4.1 节所设置的仿真参数，由于无人机自组网中各节点的分布范围相对较小，而节点之间的最大通信距离相对较大，因此在进行拓扑推理时出现“伪因果关系”以及算法参数设置问题的情况相对较少，从而造成本

文方法相较于基线方法在拓扑推理精度方面性能提升有限。基于以上分析，本文认为在无人机自组网中各节点的分布范围相对较大、节点间最大通信距离相对较小的场景下，即“伪因果关系”以及算法参数设置问题频繁发生的情况下，本文方法相较于基线方法在拓扑推理精度方面性能将会有更加明显的提升效果。




图9 节点数量对各方法推理精度的影响




图10 观测时长对各方法推理精度的影响

图 11 与图 12 分别展示了节点数量与观测时长对各方法推理消耗时间的影 响曲线，其中图 11 设置固定观测时长为 0.2 s，图 12 设置固定节点数量为 11 个。从图 11 与图 12 可以看出，各方法的推理消耗时间会随着节点数量与观测时长的增加而提高，这是因为它们的计算复杂度均与节点数量和观测时长呈正相关关系。而 ShapeNet 方法在不同节点数量与观测时长下均具有最小的平均消耗时

间, 根据第 3 节的分析, 这是因为 ShapeNet 方法可以通过 GPU 硬件加速手段来减小对时间序列矩阵的计算时间, 从而具有更加优秀的拓扑推理速度性能。




图 11 节点数量对各方法推理消耗时间的影响




图 12 观测时长对各方法推理消耗时间的影响

## 5 结束语

本文针对非合作场景下无人机自组织网络通联拓扑推理问题, 提出了一种基于 ShapeNet 的拓扑推理方法。考虑所构建的拓扑推理系统模型, 该方法首先根据数据帧与 ACK 帧之间的响应机制构建了形状特征子序列 Shapelets。然后结合 Shapelets 的长度设计并搭建了一种可解释神经网络 ShapeNet, 其能够自动识别各节点对之间的通联关系, 进而完成对整个网络拓扑结构的推理。最后分析了本文方法的计算复杂度。仿真结果表明, 本文方法在拓扑推理精度与速度方面均具有更加优秀的性能表现。然而, 本文研究仍存在着一定的局限性, 主要包括没有给出无线信号侦察采集与预处理这些拓扑推理

前置工作的具体方案来去掉这一假设, 以及尚未在真实环境中对本文方法进行验证与应用。因此在未来的工作中, 将致力于完成本文研究的全流程与工程化实现, 进一步研究信号被动侦察与处理技术, 并通过真实 FANET 或硬件在环仿真对相关技术方案进行验证, 从而提升本文方法的技术完整性与实际应用价值。

## 参考文献:

- [1] LAGHARI A A, JUMANI A K, LAGHARI R A, et al. Unmanned aerial vehicles: a review[J]. *Cognitive Robotics*, 2023, 3: 8-22.
- [2] GARGALAKOS M. The role of unmanned aerial vehicles in military communications: application scenarios, current trends, and beyond[J]. *The Journal of Defense Modeling and Simulation: Applications, Methodology, Technology*, 2024, 21(3): 313-321.
- [3] 张笋, 朱昱, 代李菟, 等. 军用无人机技术发展历程、现状及未来应用研究[J]. *舰船电子工程*, 2021, 41(6): 9-13.  
ZHANG S, ZHU Y, DAI L T, et al. Research on development, current situation and future application of military UAV technology[J]. *Ship Electronic Engineering*, 2021, 41(6): 9-13.
- [4] 毕文豪, 张梦琦, 高飞, 等. 无人机集群任务分配技术研究综述[J]. *系统工程与电子技术*, 2024, 46(3): 922-934.  
BI W H, ZHANG M Q, GAO F, et al. Review on UAV swarm task allocation technology[J]. *Systems Engineering and Electronics*, 2024, 46(3): 922-934.
- [5] ZHU X N. Analysis of military application of UAV swarm technology[C]// *Proceedings of the 2020 3rd International Conference on Unmanned Systems (ICUS)*. Piscataway: IEEE Press, 2020: 1200-1204.
- [6] 秦潜聪, 吴冠霖, 高原, 等. 面向战场条件的无人机集群分布式存储方法[J]. *西南交通大学学报*, 2024, 59(4): 942-958.  
QIN Q C, WU G L, GAO Y, et al. Distributed storage methods for unmanned aerial vehicle clusters in battlefield[J]. *Journal of Southwest Jiaotong University*, 2024, 59(4): 942-958.
- [7] YAN Y J, WU B, YANG H, et al. Overview of UAV swarm communication and cooperative operation in denial environment[C]// *Proceedings of 2023 7th Chinese Conference on Swarm Intelligence and Cooperative Control*. Singapore: Springer, 2024: 72-83.
- [8] CAMPION M, RANGANATHAN P, FARUQUE S. UAV swarm communication and control architectures: a review[J]. *Journal of Unmanned Vehicle Systems*, 2019, 7(2): 93-106.
- [9] NAWAZ H, ALI H M, LAGHARI A A. UAV communication networks issues: a review[J]. *Archives of Computational Methods in Engineering*, 2021, 28(3): 1349-1369.
- [10] 邢强, 贾鑫, 朱卫纲, 等. 无人机群组认知电子战概述及关键技术[J]. *现代防御技术*, 2017, 45(6): 173-177.  
XING Q, JIA X, ZHU W G, et al. Overview and key technology of cognitive electronic warfare based UAV group[J]. *Modern Defence Technology*, 2017, 45(6): 173-177.
- [11] 张君毅, 李淳, 杨勇. 认知通信对抗关键技术研究[J]. *无线电工程*, 2020, 50(8): 619-623.

- ZHANG J Y, LI C, YANG Y. A study on key techniques in cognitive communication countermeasures[J]. *Radio Engineering*, 2020, 50(8): 619-623.
- [12] CHEN R, CHANG L L, HUI Y L, et al. Noncooperative topology inference of wireless networks with monitoring sensors[J]. *IEEE Internet of Things Journal*, 2023, 10(21): 19282-19295.
- [13] NIU Z, LI Q, MA T, et al. Research on non-cooperative topology inference method based on node location information[C]//*Proceedings of the 2018 IEEE 18th International Conference on Communication Technology (ICCT)*. Piscataway: IEEE Press, 2018: 271-275.
- [14] 郭珈岐. 无线竞争类 MAC 协议网络的拓扑推断与干扰波形设计[D]. 四川: 电子科技大学, 2022.
- GUO J Q. Topology inference and interference waveform design of wireless competition MAC protocol network[D]. *Sichuan: University of Electronic Science and Technology of China*, 2022.
- [15] 邵豪, 王论文. 基于压缩感知的无线通信网络拓扑推断方法[J]. *探测与控制学报*, 2020, 42(2): 92-98.
- SHAO H, WANG L W. Topology inference method for wireless communication networks based on compressed sensing[J]. *Journal of Detection & Control*, 2020, 42(2): 92-98.
- [16] DU W B, TAN T, ZHANG H J, et al. Network topology inference based on timing meta-data[J]. *IEEE Transactions on Communications*, 2023, 71(6): 3263-3273.
- [17] TESTIE, GIORGETTIA. Blind wireless network topology inference[J]. *IEEE Transactions on Communications*, 2021, 69(2): 1109-1120.
- [18] 宋叶辉, 丁国如, 徐承龙, 等. 面向非合作无人机通信网络的通联拓扑推理技术[J]. *电子与信息学报*, 2022, 44(3): 924-939.
- SONG Y H, DING G R, XU C L, et al. Communication topology inference technology for non-cooperative UAV communication network[J]. *Journal of Electronics & Information Technology*, 2022, 44(3): 924-939.
- [19] SONG Y H, DING G R, SUN J C, et al. Topology tracking of dynamic UAV wireless networks[J]. *Chinese Journal of Aeronautics*, 2022, 35(11): 322-335.
- [20] BEKMEZCI İ, SAHINGOZ O K, TEMEL Ş. Flying ad-hoc networks (FANETs): a survey[J]. *Ad Hoc Networks*, 2013, 11(3): 1254-1270.
- [21] 文少杰, 黄传河. FANET 中时延感知的跨层优化方法[J]. *通信学报*, 2018, 39(4): 1-12.
- WEN S J, HUANG C H. Delay-aware cross-layer optimization method for FANET[J]. *Journal on Communications*, 2018, 39(4): 1-12.
- [22] 刘亚群, 谢钧, 邢长友, 等. 飞行自组网拓扑控制研究综述[J]. *通信学报*, 2023, 44(8): 195-214.
- LIU Y Q, XIE J, XING C Y, et al. Comprehensive survey on topology control for flying ad-hoc network[J]. *Journal on Communications*, 2023, 44(8): 195-214.
- [23] HOU C B, SONG Z, ZHOU Z C, et al. WCNA-SS: wireless communication network awareness and signal separation dataset[D]. 2025.
- [24] YE L X, KEOGH E. Time series shapelets: a new primitive for data mining[C]//*Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM Press, 2009: 947-956.
- [25] 高思颖, 毛中杰, 李东, 等. 无人机自组织网络组网与接入技术的仿真设计与实现[J]. *上海师范大学学报(自然科学版)*, 2019, 48(1): 56-63.
- GAO S Y, MAO Z J, LI D, et al. Simulation design and implementation of networking and access technology for unmanned aerial vehicle self-organized network[J]. *Journal of Shanghai Normal University (Natural Sciences)*, 2019, 48(1): 56-63.
- [26] KOSEK-SZOTT K. A survey of MAC layer solutions to the hidden node problem in ad-hoc networks[J]. *Ad Hoc Networks*, 2012, 10(3): 635-660.

## [作者简介]



侯长波 (1986-), 男, 湖北孝感人, 博士, 哈尔滨工程大学教授、博士生导师, 主要研究方向为人工智能、深度学习、多模态感知与智能通信对抗等。



艾琦迅 (2001-), 男, 吉林松原人, 哈尔滨工程大学硕士生, 主要研究方向为深度学习、信号识别、通信网络拓扑认知等。



周志超 (1999-), 男, 江西宜春人, 哈尔滨工程大学博士生, 主要研究方向为图表示学习、通信网络拓扑认知等。



钮振宇 (2000-), 男, 江苏宿迁人, 哈尔滨工程大学博士生, 主要研究方向为无线网络通信、卫星通信等。



宋振 (2001-), 男, 山东泰安人, 哈尔滨工程大学博士生, 主要研究方向为深度学习、信号处理等。