

基于 DGNN 的巨型星座星地跟踪任务规划

谭沸泓, 刘 蕾

(中国电子科技集团 第 15 研究所, 北京 100083)

摘要: 随着低轨星座的规模日益扩大, 地面测控站所承担的测控任务量也相应增加, 这些任务的执行不仅需要与卫星建立星地连接, 还需要对卫星进行精确的跟踪; 对如何设计高效的规划算法并制定有效的星地连接策略进行了研究; 通过剖析巨型星座网络的特性, 提出了一种基于可见时间窗划分的离散动态图建模策略, 然后采用了动态图神经网络 (DGNN) 的关键技术和方法, 表现和处理其复杂的空间动态关系; 通过公开的 OneWeb 星座数据进行模拟仿真, 设计实验验证方案的可行性; 多个 DGNN 的实验结果表明, 巨型星座的星地跟踪数据的动态变化能够通过 DGNN 有效地捕获和学习, 且该网络在对星地跟踪的未来时间点进行预测时表现出了较高的准确性。

关键词: 巨型星座; 星地跟踪; 任务规划; 神经网络; 动态图神经网络

Planning of Giant Constellation Satellite and Earth Tracking Mission Based on DGNN

TAN Feihong, LIU Lei

(The 15th Research Institute of China Electronics Technology Group Corporation, Beijing 100083, China)

Abstract: With the increasing scale of low-orbit constellation, the measurement and control tasks undertaken by ground T&C stations increases accordingly. This tasks require not only the establishment of satellite-earth connection with satellites, but also the accurate tracking of satellites. This paper studies how to design an efficient planning algorithm and formulate an effective satellite-earth connection strategy. Based on the analysis of giant constellation network features, a discrete dynamic modeling strategy based on visible time window is proposed. Then, the key technology for dynamic graph neural network (DGNN) is adopted to represent and deal with its complex spatial dynamic relationship. Through the simulation of open OneWeb constellation data, it designs experiments to verify the feasibility of the scheme. Experimental results of multiple DGNNs show that the dynamic changes of the giant constellation star-earth tracking data can be effectively captured and learned by the DGNN, and the network has a high accuracy in predicting the future time of star-earth tracking.

Keywords: giant constellations; satellite and earth tracking; task planning; neural network; dynamic graph neural network

0 引言

近年来, 随着低轨卫星技术和规模的不断发展, 全球范围内正兴起一股热潮, 聚焦于构建高密度、巨型规模的低轨卫星星座。通过部署成千上万颗小型卫星于近地轨道, 这些星座如 Starlink 和 OneWeb 旨在实现全球无缝覆盖, 提供高速、低延迟、高可靠性的网络连接服务, 为偏远地区、航空航海、应急响应及物联网等广泛应用场景带来前所未有的便捷与效率。

测控技术作为星座系统高效运维与管理的核心支撑技术, 它负责航天器轨道与姿态调整、星载载荷控制和模块状态监控, 是航天器正常运作与任务完成的基础。测控任务的执行需要地面测控站的天线与在轨卫星建立

星地连接并跟踪卫星一段时间。星地跟踪任务规划, 即在满足卫星使用约束的前提下, 制订有效的星地连接方案, 使卫星利益最大化地执行测控任务。在轨运行的低轨卫星的增多, 给有限数量的地面测控站执行测控任务带来了压力。当前研究的重点在于如何设计高效的规划算法, 以统筹兼顾地安排各类卫星及其相关配置资源。这一算法旨在通过优化资源分配和任务调度, 最大程度地满足多样化的任务需求, 同时提升星座资源的利用率。这不仅要求算法能够适应动态变化的太空环境和任务需求, 还需要能够预测并适应未来可能出现的新挑战, 确保星座的长期稳定运行和效益最大化。

目前在星座任务规划方面的研究如下。

基于经典数学模型的方法, 论文 [1] 提出了一种

收稿日期: 2024-07-30; 修回日期: 2024-09-11。

作者简介: 谭沸泓 (2000-), 男, 硕士。

引用格式: 谭沸泓, 刘 蕾. 基于 DGNN 的巨型星座星地跟踪任务规划[J]. 计算机测量与控制, 2025, 33(1): 218-225.

两阶段无冲突测控请求任务数最大化的方法。论文 [2] 提了一种非线性泛函优化模型。论文 [3] 以卫星可见弧段为调度元素建立了一种新的可分解为多个具有约束关系的子优化问题模型。

结合机器学习算法的方法, 论文 [4] 文章研究了单天线地面站系统任务调度问题, 建立了考虑任务权重和天线转换时间的调度模型。论文 [5] 设计了各类 Agent 模型, 构建了混合式层次结构的测控资源调度 MAS 模型。论文 [6] 提出了基于多智能体强化学习的规划算法以求解多地面站联合协同任务分配问题。

以上方法在解决中小规模的任务规划问题时能够得到最优或近似最优解, 然而, 当应对大规模任务集, 如巨型星座中的众多任务时, 受限于时间和空间资源的约束, 其性能表现往往难以达到理想状态。巨型星座任务规划本质上是一个具有众多约束条件的复杂组合优化问题。在解决此类优化问题的传统方法中, 启发式搜索算法虽然有效, 但是常因为无法得到最优解且时间和空间需求过大而收到限制。此外, 强化学习 [7] 在训练阶段会产生误差累积、动作空间过大、奖励信号稀疏等问题。近年来, 采用非自回归网络架构的神经网络求解组合优化问题, 展现出了巨大潜力, 成为研究的热点 [8-10], 其能够有效地规避上述方法产生的问题。非自回归网络的特点是只需一次前向传播即可获得全部决策变量, 有效避免了传统自回归网络中常见的误差累积、奖励信号稀疏和排列不变性难以刻画等问题。此外, 非自回归网络作为一种成熟的架构, 其在速度和精度方面已在计算机视觉等多个领域得到了广泛验证。

面对巨型星座任务规划这一特定的应用场景, 选择合适的神经网络模型至关重要。考虑到巨型星座任务规划问题的特点, 包括其高度的约束性、大规模的搜索空间以及动态变化的任务需求, 采用何种神经网络来处理巨型星座任务规划问题呢?

星座网络数据的结构和数据内关系随时间动态变化且变化复杂。经典的神经网络如卷积神经网络 (CNN, convolutional neural network) [11] 只能处理欧几里得数据, 且无法学习随时间变化的规律。而循环神经网络 (RNN, recurrent neural network) [12] 通过增加记忆能力能够处理时序数据, 但无法处理非欧式空间数据的问题还是无法解决。对比之下, 适用于处理非欧式空间数据——图的图神经网络 (GNN, graph neural network) [13] 是个不错的选择。星座网络天然是个图结构, 卫星与地面站作为节点, 星地连接作为图中的边。除去基本的关系特征, 星座网络还有动态特征, 其拓扑结构随时间不断变化。鉴于静态图神经网络在表达动态复杂网络结构上的局限性, 动态图神经网络 (DGNN, dynamic graph neural network) [14] 以其能够融入时间维度信息的能力,

成为更适用于表现动态星座网络的方法。神经网络间对比见表 1 所示。如何将巨型星座复杂的网络结构建模为图, 并将星座基础信息融入神经网络中, 最终通过 DGNN 表现和处理其复杂的空间动态关系, 是本文研究的重点。

表 1 神经网络间对比结果

	非欧式空间数据	数据动态变化
卷积神经网络	×	×
循环神经网络	×	✓
静态图神经网络	✓	×
动态图神经网络	✓	✓

本文首先对巨型星座网络的特征进行了深入分析, 随后基于可见时间窗作为时间分割的依据, 将该网络建模为离散动态图。这一建模方法为巨型星座网络在神经网络应用领域提供了一种全新的视角。进一步地, 本文详细设计了一套切实可行的方案, 旨在将该网络模型有效地应用于神经网络分析中。最终, 通过一系列的模拟实验, 本文验证了所提方案的可行性与有效性, 为后续相关研究和实际应用奠定了坚实的基础。

1 动态图神经网络

1.1 图神经网络

图数据的核心挑战在于如何有效地将组合结构的复杂性转换为数字表示, 以供模型进行深入处理和精确预测。图表示学习以数据驱动的方式解决该问题, 通过学习一个映射函数, 将图中的丰富关系信息编码为一个紧凑的特征向量。这一特征向量不仅捕捉了原始图的结构特征, 还融合了图中节点或边的标签信息, 从而为图的分析 and 理解提供了一个信息密集且高效的表示。

图神经网络 (GNN) 是一类深度学习技术, 它们在处理图结构数据方面表现出卓越的能力。GNN 的核心机制是通过消息传递, 将每个节点的局部特征与其邻居节点的特征进行有效聚合, 从而生成每个节点的更新表示。这一过程不仅能够捕捉图中的复杂关系和依赖性, 而且能够揭示节点间的隐含模式。

在众多 GNN 模型中, 图卷积网络 (GCN, graph convolutional network) [15] 因其直观的设计和优异的性能而成为应用最为广泛的方法之一。此外, 图注意力网络 (GAT, graph attention network) [16] 通过引入注意力机制, 能够灵活地学习不同邻居节点对中心节点的不同影响权重, 从而增强了模型的表达能力。

GraphSAGE [17] 则通过采样固定大小的邻居子集, 并利用聚合和连接操作来更新节点的表示, 有效地扩展了 GNN 的应用范围, 使其能够处理大规模图数据。此外, 基于随机游走的节点嵌入学习策略 [18-20], 为捕捉图中的局部和全局结构提供了一种有效的手段。

这些方法的共同点在于，它们都旨在通过不同的机制来增强对图结构的理解，从而在各种图数据分析任务中实现更准确的预测和更深入的洞察。

1.2 动态图神经网络

与传统的静态图神经网络不同，动态图神经网络能够捕捉和学习图中节点和边的动态变化，这些变化可以是节点的增减、边的连接或断开，或者是节点特征的更新。

根据表示形式的不同，动态图可以分为连续时间动态图 (C-TDG, continuous-time dynamic graph)^[21-22] 和离散时间动态图 (D-TDG, discrete-time dynamic graph)^[23-24]。D-TDG 由一系列随时间变化的静态图 (快照) 表示，每个快照提供图形在特定时间 t 的状态图。这种表示方式便于观察和分析图结构在离散时间点上的变化。C-TDG 由包含特定时间戳的事件组成的图表示，在时间表示上更细粒度，但事实上，只有新的事件能被观测到。所以，它在处理节点删除等图结构的更复杂的变化表现上，可能不如 D-TDG 直观和有效。由于快照之间的拓扑变化可能非常复杂，D-TDG 因其能够清晰地展示图结构随时间的演变而更适合于分析那些结构随时间频繁变化的动态图。

2 问题建模

2.1 星座网络模型

图 1 展示了本文研究的巨型星座系统网络架构。该系统主要由分布在不同地理位置的数个地面测控站和大量低轨卫星组成。卫星周期性地地在既定轨道上运动，在可见弧段内与地面站的天线进行星地连接，进而完成具体的指令上注和数据回传等任务。一个地面站有多个天线，一次可以连接多颗可见的卫星，但每根天线一次只能连接和跟踪一颗卫星。由于本文主要探讨星地之间的通信，所以卫星之间的通信与地面站之间的通信就暂不考虑。

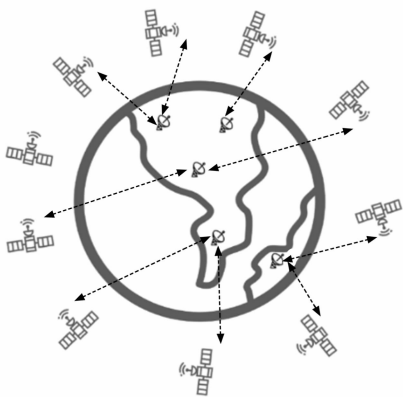


图 1 巨型星座系统网络架构

2.2 星地跟踪任务规划问题建模

在实际的星地跟踪任务规划中，地面站天线必须在

卫星进入其视线范围的可见时间窗内，才能与卫星建立并维持星地连接，进而跟踪卫星的运动轨迹。天线的观测能力受限于其视线范围，仅能观测到该范围内的天体目标。卫星进入这一视线范围的时段，定义为可见时间窗，是地面站进行星地通信和跟踪的关键时段。地面站在可见时间窗内，进行实际星地跟踪任务之前，会有一段天线准备时间。这一准备过程涉及对天线姿态的精确调整，确保在任务执行期间能够准确定位并跟踪卫星。值得注意的是，天线准备时间的长短会根据不同的观测条件和卫星特性而有所不同。此外，在星地跟踪任务规划的流程中，任务规划的完成与任务执行的开始之间，以及任务执行的结束与下一次任务规划的开始之间，均需预留一定的时间。前者用于天线和其他相关设备的准备工作，后者则用于资源的回收和系统状态的重置，确保下一次任务的顺利进行。星地跟踪流程如图 2 所示。




图 2 星地跟踪流程

星地跟踪任务涉及多个关键要素：1) 任务指定的卫星与地面站。任务所涉及的卫星仅在接收到地面站发出的指令后，才会执行相应的操作。这一指令的接收与执行是任务规划和执行流程的基础。2) 任务收益。鉴于星地跟踪任务的数量庞大，且各任务的紧急程度存在差异，优先级被广泛采用作为量化任务紧急性的关键参数。优先级不仅体现了任务执行的紧迫性，也隐含了完成该任务所能带来的相对收益或价值，是任务规划中的重要考量因素。3) 任务完成的时间窗。每个星地跟踪任务的执行都必须在预定的时间内完成，这一时间窗通常被限定在卫星与地面站的可见时间窗内。确保任务在规定时间内完成，对于保障任务的时效性和成功率至关重要。

具体表示为：假设系统中存在的 N_G 个测控地面站 $GS = \{gs_1, gs_2, \dots, gs_i, \dots, gs_{N_G}\}$ 和 N_s 颗低轨卫星 $SAT = \{sat_1, sat_2, \dots, sat_i, \dots, sat_{N_s}\}$ ， N_s 一般为几百至几千颗。在一天 24 小时内，设地面站 gs_i 可

观测到卫星 sat_j 的可见时间窗为 $T_{ij} = \{t_{ij}^1, t_{ij}^2, \dots, t_{ij}^{n_j}\}$, n_j 为不连续的时间窗的数量, 其中的时间窗 $t_{ij}^k = [s_{ij}^k, e_{ij}^k]$ 为连续的时间段, 其中 $1 \leq k \leq n_j$, s_{ij}^k, e_{ij}^k 表示可见时间窗的开始时间和结束时间。

在时间 t 待规划的星地跟踪任务 $Task_t = \{Task_1, Task_2, \dots, Task_l, \dots, Task_{N_t}\}$ 。其中的任务 $Task_l = \langle gs_i, sat_j, u_l, t_{ij}^k \rangle$, 分别表示参与该跟踪任务对应的地面站 gs_i , 卫星 sat_j , 完成该任务所能获得的收益以及完成任务所占用的可见时间窗资源 $t_{ij}^k = [s_{ij}^k, e_{ij}^k]$ 。显然, t_{ij}^k 必须在 T_{ij} 中一个时间窗如 t_{ij}^k 的范围内, 即 $t_{ij}^k \cap t_{ij}^k = t_{ij}^k$ 。任务规划的目标就是: 选择任务集合 $Task_t$ 。

2.3 动态图神经网络模型

将一个动态图形表述为一系列静态图快照 $G = \{g^1, g^2, \dots, g^T\}$, T 是时间步数, 如图 3 所示。每个快照是一个在时间步 t 的图 $g^t = (V^t, \mathbf{e}^t, X^t)$, V^t 是节点集 $\mathbf{e}^t \subseteq V^t \times V^t$ 是边集, $N^t = |V^t|$ 是在时间步 t 的节点数量。 v 是 g 中出现的所有节点的集合 $N = |V|$ 是所有节点的数量。 $A^t \in \mathbb{R}^{N \times N}$ 为图 (加权) 邻接矩阵。 $X^t \in \mathbb{R}^{N \times d_0}$ 表示节点特征矩阵, 其中 d_0 为节点初始特征维度。每个节点有一个 d_0 维的输入特征向量, 对应于 X^t 中的一行。动态图神经网络的目标是训练一个模型 $\omega(\cdot)$ 学习节点嵌入和预测器 $p(\cdot)$ 来预测链接或节点标签。也就是 $H^{1:t} = \omega(g^{1:t})$ 还有 $\hat{Y}^t = p(H^{1:t})$ 。 $H^t \in \mathbb{R}^{N \times d}$ 为节点嵌入矩阵, 其中 d 为节点嵌入维数。 \hat{Y}^t 表示存在一条用于链路预测的边, 以及与每个节点相关联的类标签。

3 基于 DGNN 的巨型星座星地跟踪任务规划

图 4 详细展示了巨型星座系统的星地跟踪任务规划流程。该流程图由两个主要部分构成: 图建模和动态图神经网络。首先将巨型星座系统进行图建模, 得到动态图。待规划任务集合根据图建模的结果进行筛选得到任务集合。最终通过动态图神经网络得到规划结果。

3.1 巨型星座系统的图建模

根据建模方式的不同设计出 3 个方案。

1) 静态图方案: 将包含所有卫星和地面站的星座网络构建一个大的静态图, 可见时间窗的约束是多个离散连续范围。

通过神经网络计算约束时很麻烦且最后的结果可能会出现不满足约束的情况, 而且多个不可见的卫星节点参与当前时间规划的计算除了增加不必要的计算资源以外还会对网络计算产生影响。

2) 多动态图方案: 针对每个地面站独立构建星座网络图。每个地面站以其可见范围为边界, 边界内随时间变化的可见卫星以动态图的形式呈现。

很多时候地面站之间的可见区域存在重叠, 地面站独立规划导致上层任务的制定和资源的协调不太方便, 且作为一个整体的系统, 各地面站在实际工作中并不是孤立的, 相互协作共同执行任务是常出现的情况。随着地面站数量的增加, 整个系统在规划消耗的多余且不必要的资源也会显著增加。

3) 单动态图方案: 以所有地面站的可见范围作为图的边界构建单个动态图。将所有地面站和其所有可见卫星视为整体进行规划。对于出现某些地面站与卫星的不可见情况时, 可以通过制定不可连接约束在任务制定前就做出限制。该约束表现为不可见卫星与地面站的任务无法执行, 直接从待规划的任务集中筛选出无法建立星地跟踪的任务。

综合上述方案的特征, 最后采取单动态图方案。建模结果如图 5 所示。

基于 DGNN 的巨型星座星地跟踪任务规划, 首先将星座的可见时间窗数据转化成动态图神经网络可以使用的数据类型 G 。 V 中的节点由所有地面站和低轨卫星组成即 GS 与 SAT 的并集, 统一编号后得出:

$$V = \{sat_1, \dots, sat_j, \dots, sat_N, gs_1, \dots, gs_i, \dots, gs_{N_c}\} \quad (1)$$

G 以可见时间窗分隔, 把所有可见时间窗的开始时间与结束时间作为时间步进行分隔。先获得所有时间, 将所有可见时间窗并起来并按时间前后对时间点进行排序。得到的时间步集合表示为:

$$T' = \text{sort}(\bigcup_{i \in GS, j \in SAT} T_{ij}) \quad (2)$$

T' 可能为:

$$T' = \{s_{11}, s_{12}, e_{12}, \dots, s_{ij}, \dots, e_{ij}, \dots\} \quad (3)$$

$T = |T'|$ 即为时间步数, 在时间步 t 的快照 G^t 中包含的节点为出现在当前时间的地面站与卫星。 $G^t = (V^t, \mathbf{e}^t, X^t)$, $t \in T'$ 。根据 T_{ij} 中的时间区间, 给每个




图 3 动态图神经网络模型

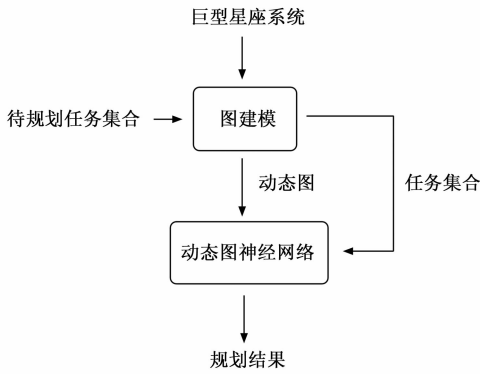


图 4 任务规划流程




图 5 巨型星座系统的图建模

对应时间步 (如 s_{ij} , e_{ij}) 的快照的节点集 V^t 添加卫星节点 sat_i 。所有时间步都包含所有地面站节点, 所以 V^t 可表示为:

$$V^t = \{sat_1, sat_2, \dots, sat_{N_s}, gs_1, gs_2, \dots, gs_5, \dots, gs_{N_g}\} \quad (4)$$

其中: N_s 是时间步 t 的快照 G^t 所包含的卫星数量, 即在当前时间所有地面站可见的卫星数量, 每个编号 sat_j 也对应了具体的卫星。可能存在 \mathcal{E}^t 为边集, 代表了当前存在的节点连接, 即已经确定被规划但还未结束的星地跟踪的结果。 X^t 则是特征向量, 能反映具体卫星或地面站的特征。

3.2 基于 DGNN 的链接预测

经过一个动态图神经网络模型 $\omega(\cdot)$ 学习节点嵌入后, 得到节点嵌入矩阵 H^t , 矩阵中每一行对应一个节点的嵌入。具体表示如下, 新一层 l 的节点状态 $H_l^{(l)}$ 取决于较低层次的节点状态 $\tilde{H}_l^{(l)}$ 和历史节点状态 $H_{l-1}^{(l)}$

$$H_l^{(l)} = \text{RNN}(H_{l-1}^{(l)}, \tilde{H}_l^{(l)}) \quad (5)$$

$$\tilde{H}_l^{(l)} = \text{GNN}^{(l)}(H_l^{(l-1)}) \quad (6)$$

RNN 一般采用 GRU。其中 $H_{l-1}^{(l)}$ 为隐藏状态, $\tilde{H}_l^{(l)}$ 为 GRU 单元的输入:

$$R_l = \sigma(W_R H_{l-1}^{(l)} + U_R \tilde{H}_l^{(l)} + B_R)$$

$$Z_l = \sigma(W_Z H_{l-1}^{(l)} + U_Z \tilde{H}_l^{(l)} + B_Z)$$

$$H_l = \tanh[W_H H_{l-1}^{(l)} + U_H (R_l \circ \tilde{H}_l^{(l)} + B_H)]$$

$$H_l^{(l)} = (1 - Z_l) \circ \tilde{H}_l^{(l)} + Z_l \circ H_l \quad (7)$$

GNN 一般采用 GCN:

$$\tilde{H}_l^{(l)} = \sigma(\bar{D}^{-1/2} \tilde{D} \bar{D}^{-1/2} H_l^{(l-1)} W^{(l)}) \quad (8)$$

节点 u 在 GCN 的第 $(l+1)$ 层的输出计算为:

$$x_u^{l+1} = W_o x_u^l + W_1 \sum_{v \in N_s} \frac{1}{\sqrt{\deg(v) \deg(u)}} x_v^l \quad (9)$$

想要预测下一个时间步 gs_i 与 sat_j 是否存在星地跟踪的连接, 需要将两节点的嵌入 $h_{i+N_s}^t, h_j^t$ 拼接起来通过如多层感知机 (MLP, multilayer perceptron) 的解码器得到边存在的概率 \hat{y}_{ij}^t :

$$\hat{y}_{ij}^t = \sigma\{\text{MLP}[\text{concat}(h_{i+N_s}^t, h_j^t)]\} \quad (10)$$

预测两节点是否存在边便是预测星地跟踪任务是否执行, 最终选取概率排名最高的数 $task_l$, 或者选取概率大于 0.5 的 $task_l$ (具体值也根据实际情况而定)。

4 仿真实验

4.1 模拟仿真

在本研究的仿真实验中, 我们选取了 OneWeb 星座作为巨型低轨星座的模板。该星座由 637 颗卫星组成, 部署在高度为 1 200 公里、倾角为 87.9° 的 18 个轨道面上。每个轨道面上均匀分布着约 40 颗卫星, 相邻轨道面之间的间隔为 9° , 整个星座的通信容量高达 7 Tbit/s。有关这些卫星的详细数据, 可以参考 CelesTrak 提供的当前标准轨道元素集 CelesTrak: Current GP Element Sets。

仿真场景中选择的的地面站位置, 分布在中国境内六个不同地理位置的城市, 具体的地面站位置数据在如表 2 所示。然后通过 STK (satellite tool kit) 软件模拟仿真场景中的星座布局和地面站分布, 并生成 24 小时内的星地可见时间窗数据。如图 6 所示。

表 2 地面站位置数据

	纬度/ $^\circ$	经度/ $^\circ$
北京	39.928 9	116.388
成都	30.572 5	104.067
三亚	18.252 9	109.512
上海	31.082 7	121.419
拉萨	29.874 6	89.863 8
西安	34.288 6	109.281

接下来, 通过算法将生成的可见时间窗数据转化为适用于动态图的输入格式。转化后的离散动态图包含了大约 4 万多个时间步, 每个时间步对应的快照包含大约




图 6 STK 仿真模拟结果

有 60 至 70 个节点。这一转换过程是实现动态图神经网络学习的基础。

为了模拟星地跟踪任务的动态特性,我们进一步假设每个地面站配备有 20 根天线,从而能够在每个时间步中与 20 颗卫星建立连接。在每个时间步,我们为每个地面站节点生成了连接至 20 个随机卫星的边,以模拟星地连接的建立和断开。

在连续的时间步快照之间,节点和边的状态都在不断地动态变化。节点的变化反映了卫星在轨道上的运动特性,而边的变化则模拟了星地跟踪任务的执行过程及其结束。这种模拟不仅捕捉了星地跟踪任务的时序特性,而且为动态图神经网络提供了丰富的时变信息,使其能够学习并预测星地跟踪任务的执行情况。

4.2 基准模型

本次验证实验选取了一系列当前主流的离散时间动态图神经网络基准模型进行测试,包括 DynGESN^[25]、EvolveGCN-H^[26]、EvolveGCN-O^[26]、GCLSTM^[27] 和 LRGCN^[28]。它们使用不同的体系结构,专注于不同的应用场景。

DynGESN 使用扩展了 Graph Echo 的堆栈架构,通过使每个循环层中计算新的顶点特征,将状态网络转移到时域。GCLSTM 和 LRGCN 使用将 GCN 模型嵌入进 LSTM^[29] 模型的嵌入架构,都关注于链路预测任务。GCLSTM 将 GCN 嵌入进 LSTM,充分利用 GCN 学习隐藏状态和单元状态下的网络结构,并通过 LSTM 模型学习时间特征。LRGCN 通过 Relational GCN^[30] 分别学习当前步骤的节点表示和前一步的节点嵌入,然后将这些嵌入信息输入到 LSTM 中。

EvolveGCN 采用了一种创新的架构,将图的演化映射到所使用的 GNN 的参数的演化上。它使用 RNN 来演化 GCN 的参数,因此只训练 RNN 的参数。原作者设计有两点版本,取决于节点特性是否提供信息。EvolveGCN-H 将 GCN 权值作为 GRU 的隐藏状态,同时将节点嵌入作为 GRU 的输入和隐藏状态。而 EvolveGCN-O 则将 GCN 权值直接作为 LSTM 模型的

输入。

4.3 实验设置

本研究选取了前 200 个时间步的数据进行模拟验证。在模型训练阶段,我们采用了基于时间窗的序列学习方法。具体而言,时间窗被设定为 10 个时间步,其中每个时间窗口的前 70% 数据被用作训练集,形成一个训练批次;接下来的 15% 数据被用作验证集,用以评估模型在训练过程中的性能;剩余的 15% 数据则作为测试集,用以最终评估模型的预测能力。

在进行星地链路预测时,我们采用了负抽样的方法,即从下一个时间步的快照中随机选取与现有链路数量相等的非链路,以平衡正负样本的比例。模型训练过程中,我们使用了 Adam 优化器,并进行了 200 轮迭代更新。为了评估模型的稳定性和鲁棒性,我们对模型进行了 5 次独立的训练,每次使用不同的权重初始化,并最终报告了这些独立实验结果的平均值。

在链接预测任务中,我们将问题视为二分类问题。为了衡量链接预测的准确率,我们选择了 AUROC (area under the receiver operating characteristic curve), 准确度 (accuracy), 平均精确率的平均值 (MAP, mean average precision) F1 作为评价指标。AUROC 通过计算 ROC 曲线下的面积来评估分类器的性能,它能够反映分类器在不同判定阈值下的性能表现,具有不受特定阈值选择影响的优点。

4.4 验证结果

将模拟的巨型星座的星地跟踪数据划分后的训练数据通过动态图神经网络基准模型进行训练。训练完成后,我们进一步利用剩余的测试数据对模型进行了评估。得到仿真模拟数据的验证结果如图 7 所示。




图 7 验证结果

根据图中的实验结果,我们可以观察到,在所比较的 5 个模型中,有 4 个模型展现出了卓越的性能。这一现象表明,动态图神经网络在预测动态图中的链接变化方面具有显著的优势,它们能够有效地捕捉和学习动态

图拓扑结构的演变规律。特别地,对于巨型星座的星地跟踪数据,动态图神经网络不仅能够准确地捕捉其动态变化,而且在对未来时间点的星地跟踪任务进行预测时,也显示出了较高的准确性。这些结果进一步证实了动态图神经网络在处理此类具有时空依赖性的复杂数据集时的有效性。

此外,这一发现不仅验证了我们所采用方法的科学性和实用性,而且为未来的星座资源管理和任务规划提供了一种创新的技术手段。动态图神经网络的应用,为优化星地跟踪任务的执行策略、提高资源利用率和响应效率提供了可能。

综上所述,本研究的实验结果不仅为动态图神经网络在星地跟踪数据预测领域的应用提供了实证支持,也为后续的相关研究和实际应用奠定了坚实的基础。

5 结束语

本研究成功地将巨型低轨星座的星地跟踪任务规划问题转化为动态图神经网络的链接预测问题,并通过实证研究验证了这一转化策略的可行性与高效性。尽管实际应用中的场景可能包含更多的复杂性和不确定性,但神经网络的可扩展性为应对这些挑战提供了强大的灵活性和适应性。鉴于此,研究者可以依托于神经网络的这一特性,针对具体的应用问题,进一步探索和优化解方案。这不仅包括算法的调整和模型的改进,也涉及到对不同太空任务需求和环境条件的深入分析。通过这种方式,可以开发出更加精准和灵活的策略,以适应太空任务的动态变化和不断演进的技术需求。

此外,本研究的发现为未来在星座资源管理、任务规划以及相关领域的研究开辟了新的道路。随着技术的不断进步和数据的日益丰富,动态图神经网络有望在解决实际问题中发挥更大的作用,为太空探索和利用提供强有力的技术支持和决策辅助。

参考文献:

[1] ARBABI M, GARATE J A, KOCHER D F. Interactive real time scheduling and control [C] // Summer Computer Simulation Conference, 1985: 271 - 277.

[2] 金光, 武小悦, 高卫斌. 卫星地面站资源调度优化模型及启发式算法 [J]. 系统工程与电子技术, 2004, 26 (12): 1839 - 1841.

[3] 张娜, 柯良军, 冯祖仁. 一种新的卫星测控资源调度模型及其求解算法 [J]. 宇航学报, 2009, 30 (5): 2140 - 2145.

[4] 刘洋, 陈英武, 谭跃进. 卫星地面站系统任务调度的动态规划方法 [J]. 中国空间科学技术, 2005, 25 (1): 44 - 47.

[5] 杜红梅, 柯宏发. 基于多智能体技术的航天测控资源调度

模型设计 [C] // 系统仿真技术及其应用 (第 16 卷), 2015: 78 - 81.

[6] 刘阳, 周笛, 盛敏, 等. 面向巨型星座系统的多地面站协同测控技术 [J]. 天地一体化信息网络, 2023, 4 (1): 2 - 11

[7] SUTTON, RICHARD S., and ANDREW G. Barto. Reinforcement learning: An introduction [J]. *Robotica* 17. 2, 1999: 229 - 235.

[8] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // *Comput. Vis. Pattern Recog.*, 2016: 770 - 778.

[9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C] // *Comput. Vis. Pattern Recog.*, 2016: 779 - 788.

[10] ZHANG S, WEN L, LEI Z, et al. Refinedet++: Single-shot refinement neural network for object detection [J]. *Trans. Circ. and Syst. for Video Tech.*, 2020, 31 (2): 674 - 687.

[11] LECUN, YANN, et al. Gradient-based learning applied to document recognition [J]. *Proceedings of the IEEE* 86. 11, 1998: 2278 - 2324.

[12] LIPTON Z C, BERKOWITZ J, ELKAN C. A critical review of recurrent neural networks for sequence learning [J]. *arXiv preprint arXiv: 1506.00019*, 2015.

[13] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32 (1): 4 - 24.

[14] GRAVINA, ALESSIO, and DAVIDE BACCIU. Deep learning for dynamic graphs: models and benchmarks [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024: 11788 - 11801.

[15] THOMAS N KIPF and MAX WELLING. Semi-supervised classification with graph convolutional networks [C] // *ICLR*, 2017.

[16] VELI KOVI P, CUCURULL G, CASANOVA A, et al. Graph Attention Networks [C] // *International Conference on Learning Representations*, 2018.

[17] HAMILTON W, YING Z, LESKOVEC J. Inductive representation learning on large graphs [J]. *Advances in Neural Information Processing Systems*, 2017, 30.

[18] ADITYA GROVER and JURE LESKOVEC. node2vec: Scalable feature learning for networks [C] // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016: 855 - 864.

[19] TOMAS MIKOLOV, KAI CHEN, GREG CORRADO, et al. Efficient estimation of word representations in vector space [C] // *ICLR*, 2013.

- [20] BRYAN PEROZZI, RAMI AL-RFOU, STEVEN SKIE-NA. Deepwalk; Online learning of social representations [C] // Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2014: 701–710.
- [21] ROSSI E, CHAMBERLAIN B, FRASCA F, et al. Temporal graph networks for deep learning on dynamic graphs [J]. arXiv preprint arXiv: 2006, 10637, 2020.
- [22] RAKSHIT TRIVEDI, MEHRDAD FARAJTABAR, PRASENJEET BISWAL, et al. Dyrep: Learning representations over dynamic graphs [C] // International Conference on Learning Representations, 2019.
- [23] JIAXUAN YOU, TIANYU DU, and JURE LESK-OVEC. ROLAND: graph learning framework for dynamic graphs [C] // Proceedings of the 28th ACM SIGKDD conference on knowledge discovery and data mining, 2022: 2358–2366.
- [24] ARAVIND SANKAR, YANHONG WU, LIANG GOU, et al. Dysat: Deep neural representation learning on dynamic graphs via self-attention networks [C] // Proceedings of the 13th international conference on web search and data mining. 2020: 519–527.
- [25] ALESSIO MICHELI and DOMENICO TORTORELLA. Discrete-time dynamic graph echo state networks [J]. *Neurocomputing* 496, 2022: 85–95.
- [26] ALDO PAREJA, GIACOMO DOMENICONI, JIE CHEN, et al. Evolvegc: Evolving graph convolutional networks for dynamic graphs [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2020 (34): 5363–5370.
- [27] JINYIN CHEN, XUEKE WANG, and XUANHENG XU. GC-LSTM: Graph convolution embedded LSTM for dynamic network link prediction [J]. *Applied Intelligence*, 2022: 1–16.
- [28] JIA LI, ZHICHAO HAN, HONG CHENG, et al. Predicting path failure in time-evolving graphs [C] // Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining. 2019: 1279–1289.
- [29] SEPP HOCHREITER and JÜRGEN SCHMIDHUBER. Long short-term memory [J]. *Neural computation* 9, 8. 1997: 1735–1780.
- [30] MICHAEL SCHLICHTKRULL, THOMAS N KIPF, PERER BLOEM, et al. Modeling relational data with graph convolutional networks [C] // The semantic web: 15th international conference, ESWC 2018, Heraklion, Crete, Greece, June 3–7, 2018, proceedings 15. Springer International Publishing, 2018: 593–607.
- 上接第 217 页
- [15] LI F, ZHANG H, LIU S, et al. DN-DET-R: Accelerate DETR training by introducing query DeNoising [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 46 (4): 2239–2251.
- [16] ZHAO Y, LV W Y, XU S L, et al. DETRs beat YOLOs on real-time object detection [C] // 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 16965–16974.
- [17] 田野, 丁赤飏, 张福博, 等. 一种基于深度学习的 SAR 城市建筑区域叠掩精确检测方法 [J]. *雷达学报*, 2023, 12 (2): 441–455.
- [18] WEI S, ZENG X, QU Q, et al. HRSID: A High-Resolution SAR images dataset for ship detection and instance segmentation [J]. *IEEE Access*, 2020, 8: 120234–120254.
- [19] REN S, HE K, GIRSHICK R, et al. Faster RCNN: Towards Real-Time object detection with region proposal networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39 (6): 1137–1149.
- [20] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks [C] // Venice, Italy: 2017 IEEE International Conference on Computer Vision (ICCV), 2017: 764–773.
- [21] JOCHER G, et al. (2021). YOLOv5. [EB/OL]. Available: <https://github.com/ultralytics/yolov5>.
- [22] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [J]. Vancouver, BC, Canada; 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 7464–7475.
- [23] JOCHER G, et al. (2023). YOLOv8n. [EB/OL]. Available: <https://github.com/ultralytics/ultralytics>
- [24] ZHAO Y, ZHAO L, XIONG B, et al. Attention receptive pyramid network for ship detection in SAR images *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 2738–2756.
- [25] ZHANG T, ZHANG X, SHI J, et al. Balance scene learning mechanism for offshore and inshore ship detection in SAR Images [J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1–5.
- [26] REN X Z, BAI Y W, ZHANG Z H, et al. SEFRNet: An SAR ship target detection network with effective feature representation [J]. *IEEE Sensors Journal*, 2024, 24 (6): 8539–8550 4.
- [27] YU C, SHIN Y. An efficient YOLO for ship detection in SAR images via channel shuffled reparameterized convolution blocks and dynamic head [J]. *ICT Express*, 2024, 10 (3): 673–679.