



指挥与控制学报

Journal of Command and Control

ISSN 2096-0204, CN 14-1379/TP

《指挥与控制学报》网络首发论文

题目：面向动态环境的网络链路预测方法
作者：潘志强，蔡飞，张鑫，陈皖玉，邵太华，陈洪辉
收稿日期：2026-02-05
网络首发日期：2026-04-22
引用格式：潘志强，蔡飞，张鑫，陈皖玉，邵太华，陈洪辉. 面向动态环境的网络链路预测方法[J/OL]. 指挥与控制学报.
<https://link.cnki.net/urlid/14.1379.tp.20260422.1421.003>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

面向动态环境的网络链路预测方法

潘志强^{1,*} 蔡飞¹ 张鑫¹ 陈皖玉² 邵太华³ 陈洪辉¹

(1. 国防科技大学 信息系统工程全国重点实验室, 长沙 410073; 2. 国防科技大学 电子对抗学院, 合肥 230037; 3. 信息工程大学 数据与目标工程学院, 郑州 450001)

摘要 针对动态战场环境下作战体系建模与动态演化分析的需求, 提出一种基于互注意力图混合器的动态网络链路预测方法。该方法通过互注意力机制显式建模源节点与目标节点之间的关联关系, 并结合多层感知机混合器对历史邻居序列特征进行有效融合, 从而实现对动态网络中未来链路的准确预测。在两个真实数据集上的仿真实验结果表明, 该算法在“节点数量固定”的直推式设定和“节点数量随网络演化增加”的归纳式设定下, 均能保持较高的预测准确性, 性能优于现有主流方法, 展现了该算法良好的泛化能力与适用性。同时, 明确了算法应用场景及约束条件, 支持实际部署。

关键词 动态环境, 动态网络, 链路预测, 互注意力

DOI j.cnki.jc2.2096-0204.2026.0045

Network Link Prediction Method for Dynamic Environments

PAN Zhiqiang^{1,*} CAI Fei¹ ZHANG Xin¹ CHEN Wanyu² SHAO Taihua³ CHEN Honghui¹

(1. National Key Laboratory of Information Systems Engineering, National University of Defense Technology, Changsha 410073, China; 2. College of Electronic Countermeasures, National University of Defense Technology, Hefei 230037, China; 3. Institute of Data and Target Engineering, Information Engineering University, Zhengzhou 450001, China)

Abstract Aiming at the demand of combat system modeling and dynamic evolutionary analysis in dynamic battlefield environments, this paper proposes a dynamic network link prediction method based on the Co-Attentive Graph Mixer. This method explicitly models the correlations between source node and target node through a co-attention mechanism, and effectively integrates the features of historical neighbor sequences using the MLP Mixer, thereby achieving accurate prediction of future links in dynamic networks. Simulation results on two real-world datasets demonstrate that the algorithm maintains high prediction accuracy under both the transductive setting with “fixed number of nodes” and the inductive setting with “increasing number of nodes as the network evolves.” It outperforms existing mainstream methods, showcasing the algorithm’s strong generalization capability and applicability. Meanwhile, the application scenarios and constraint conditions of the algorithm are clarified to support practical deployments.

Key words dynamic environment, dynamic network, link prediction, co-attention mechanism

在现代联合作战体系中, 指挥控制系统作为作战体系的核心, 其效能直接关系到战场态势感知、决策制定与作战行动的实时性与精确性^[1-2]。随着作战任务的多样化和战场环境的动态演变, 传统的指控系统往往难以适应复杂、非线性、时变的作战体系演变过程^[3-4]。因此, 构建能够动态反映系统运行状态、可支持实时运用与未来状态可预测的作战体系, 成为提升指挥控制系统智能化水平与自适应能力的关键。

图网络作为一种有效建模实际复杂系统关系的工具, 已广泛应用于现代战争中的作战体系建模与分析。通过将作战单元抽象为节点, 并将单元间的指挥、协同与信息交互等关系抽象为边, 图网络能够直观表征作战体系的结构特征与动态演化规律^[5-7]。例如, 在敌方作战体系分析中, 可通过识别关键指挥节点、通信链路与火力协同关

系, 支撑体系破击与效能评估决策。然而, 战场环境中节点与关系的动态性、不确定性以及新生作战实体的不断涌现, 使得静态或简单时序的图模型难以准确描述体系的真实演化过程, 亟需发展面向动态环境的网络链路预测方法, 以支持对未来作战关系的预见性分析。

动态网络链路预测通过从历史动态图数据进行学习, 感知动态网络的演变规律, 从而对动态网络未来的结构状态精准预测^[8-9]。目前动态网络链路预测任务主要可以分为两类, 即基于图快照的动态链路预测和连续图动态链路预测。其中, 基于图快照的动态链路预测将动态网络切分为不同的图快照, 从而建模图快照之间的时序关联并进行预测^[10-11], 而连续图动态链路预测则考虑了更为精细的链路时序信息, 把每条动态链路各自的时间戳均考虑进来^[12]。

考虑到连续图动态链路预测更贴近实际的真实场景, 本文主要对连续图动态链路预测进行研究。目前, 该问题的研究较为广泛。例如, Trivedi等^[13]提出将表示学习视作一个潜在的中介过程,

收稿日期 2026-02-05 录用日期 2026-03-18

国家自然科学基金(62372458, 62302511), 河南省自然科学基金(252300420989)资助

*通讯作者简介 潘志强(1998—), 男, 安徽亳州人, 博士, 讲师。

其同时考虑了网络拓扑结构的演变和网络上节点间的活动。Xu 等^[14]提出了一种时序图注意力网络, 通过设计连续时间编码技术和堆叠时序图注意力层, 对节点的时序拓扑邻域特征进行有效聚合。此外, Wang 等^[15]提出了提出因果匿名游走, 通过抽取时序邻居游走, 以匿名方式对节点间的结构近邻关系进行有效感知。另外, Cong 等^[16]基于 MLP-Mixer 模型, 设计了一个轻量级的预测框架, 能够有效地从节点的单跳历史邻居中学习节点的动态表示。然而, 尽管现有研究对连续图动态链路预测的研究已经较为充分, 目前的方法总体上在建模过程中主要聚焦于单个节点自身的特征, 对节点之间丰富的关联关系考虑不充分, 导致在节点动态表示学习过程中未能捕获节点间关联, 预测效果不高^[16-18]。

因此, 为了解决上述问题, 本文针对连续时间动态网络链路预测展开研究, 提出了一种基于互注意力图混合器 (co-attentive graph mixer, CAGMixer) 的预测方法。具体来说, 给定需要预测是否会产生链路的源节点和目标节点, 本文首先采样源节点和目标节点的最近交互的一阶历史邻居序列作为其各自的邻居集合, 并通过结合节点特征、链路特征以及时序特征, 生成每个邻居的动态表示; 其次, 为了更好地将源节点和目标节点间的关联关系考虑进来, 一方面基于互注意力机制, 在计算源节点和目标节点的邻居注意力分数时, 互相考虑了对方的信息, 另一方面基于多层感知机混合器 (multilayer perceptron mixer, MLP-Mixer) 对源节点和目标节点各自的不同位置的邻居信息进行混合, 再将混合后的邻居表示根据互注意力机制计算得到的注意力分数结合起来, 生成源节点和目标节点的最终动态节点表示。最后, 将二者结合起来并输入多层感知机中进行动态链路生成概率的预测。

综上所述, 本文的创新点可简要概括为:

(1) 首次提出在动态网络链路预测过程中基于互注意力机制计算源节点和目标节点的邻居注意力分数, 充分考虑二者间的丰富关联关系;

(2) 提出了一种基于互注意力图混合器的动态网络链路预测方法, 在采样单跳历史邻居序列的条件下, 基于互注意力机制和多层感知机混合器, 实现源节点和目标节点的有效动态表示生成, 从而进行准确的动态网络链路预测;

(3) 通过在两个真实数据集上进行实验并与常见的基线模型进行性能对比, 验证了所提出的

CAGMixer 方法的有效性, 并通过展现邻居数目对性能的影响分析了 CAGMixer 的参数敏感性。

1 问题定义

首先给出连续图动态链路预测的形式化定义。具体来说, 给定动态网络表示为 $\mathcal{G} = \{\mathcal{N}, \mathcal{E}\}$, 其中 $\mathcal{N}$ 和 $\mathcal{E}$ 分别是动态网络中不断演变的节点集合和链路集合。每条动态链路 $(v_s, v_t, t_{st}) \in \mathcal{E}$ 表示节点 v_s 与节点 v_t 在时间戳 t_{st} 进行了交互。动态网络链路预测旨在预测网络中未来可能出现的动态链路, 包括直推式链路和归纳式链路。具体来说, 历史数据中出现过的节点集合可记作可见节点 $\mathcal{N}_{seen}$, 未来出现的节点可记作不可见节点 $\mathcal{N}_{unseen} = \mathcal{N} \setminus \mathcal{N}_{seen}$ 。直推式动态链路预测 (transductive dynamic link prediction, TDLP) 旨在预测连接了两个已见节点的直推式动态链路, 可表示为 $\mathcal{E}_T = \{(v_s, v_t, t_{st}) | v_s, v_t \in \mathcal{N}_{seen}\}$; 归纳式动态链路预测 (Inductive Dynamic Link Prediction, IDLP) 旨在预测连接了至少一个不可见节点的归纳式动态链路, 可表示为 $\mathcal{E}_I = \{(v_s, v_t, t_{st}) | v_s \in \mathcal{N}_{unseen} \parallel v_t \in \mathcal{N}_{unseen}\}$ 。

2 模型设计

基于互注意力图混合器的预测方法的总体框架如图 1 所示, 主要包括三个主要模块, 即节点动态信息抽取、互注意力式节点特征融合和预测生成及模型优化。首先, 在节点动态信息抽取模块中, 抽取源节点和目标节点的节点特征、链路特征以及时间特征; 其次, 在互注意力式节点特征融合, 基于互注意力机制对源节点和目标节点间的关联关系进行充分建模, 并生成二者的动态节点表示; 最后, 提供结合源节点和目标节点的动态表示, 生成未来链路的预测分数。

2.1 节点动态信息抽取

给定需预测的在时间戳可能生成链路的源节点 v_s 和目标节点 v_t , 首先从动态网络中抽取两个节点各自的邻居集合进行节点的动态表示生成。现有方法已经验证了, 在动态网络链路预测中, 抽取节点的一跳邻居集合, 即一跳邻居序列, 能够实现相较于多跳邻居更准确的预测^[15,16]。因此, 为了同时兼顾准确性和效率, 这里参照现




图 1 CAGMixer 框架总体示意图

Fig. 1 The overall framework of CAGMixer

有方法^[15,16],抽取节点的单跳邻居序列。参照文献^[15],采用一种简单且有效的采样方式,即直接采用最近交互的邻居。将采样的邻居序列设为 K ,则源节点和目标节点的历史邻居序列可分别表示为 $N_s = \{v_1^s, v_2^s, \dots, v_K^s\}$ 和 $N_t = \{v_1^t, v_2^t, \dots, v_K^t\}$ 。

然后,对于每个邻居,可以直接从动态网络特征数据中获取该邻居的节点特征和相关的链路特征,即每个源节点的邻居 $v_i^s \in N_s$ 的节点特征和链路特征可以分别表示为 $\mathbf{x}_i^s \in \mathbb{R}^{d_N}$ 和 $\mathbf{e}_i^s \in \mathbb{R}^{d_E}$,其中 d_N 和 d_E 分别是节点特征维度和链路特征维度。同理,每个目标节点的邻居 $v_i^t \in N_t$ 的节点特征和链路特征可以分别表示为 $\mathbf{x}_i^t \in \mathbb{R}^{d_N}$ 和 $\mathbf{e}_i^t \in \mathbb{R}^{d_E}$ 。

同时,考虑到动态网络不断演化的特点,进一步将动态网络中的时序信息,即每个邻居的交互时间戳信息,考虑进来。具体来说,对于每个源节点的邻居 $v_i^s \in N_s$,使用连续时间编码函数将当前时间戳和交互时间戳之间的时间间隔进行嵌入编码,如下所示:

$$\mathbf{t}_i^s = \mathcal{F}_{time}(\Delta t_i^s) = \mathcal{F}_{time}(t_{st} - t_i^s) \\ = [\cos(w_1 \Delta t_i), \sin(w_1 \Delta t_i), \dots, \cos(w_d \Delta t_i), \sin(w_d \Delta t_i)]$$

其中 $\mathbf{t}_i^s \in \mathbb{R}^{d_T}$ 是生成的邻居 v_i^s 的时序编码向量, d_T 是时序编码向量的维度, $[w_1, w_2, \dots, w_d]$ 是时序编码函数 $\mathcal{F}_{time}$ 中的参数,其中 $\mathcal{F}_{time}$ 利用随机傅里叶特征 (Random Fourier Features, RFF) 进行定义。同理,每个目标节点的邻居 $v_i^t \in N_t$ 的时序编码向量可生成 $\mathbf{t}_i^t \in \mathbb{R}^{d_T}$ 。

2.2 互注意力式节点特征融合

在抽取了节点的动态信息之后,将每个邻居

的节点特征、链路特征以及时序特征进行拼接,作为邻居的最终动态表示。具体来,每个源节点的邻居 $v_i^s \in N_s$ 的最终动态表示可以生成:

$$\mathbf{f}_i^s = \mathbf{W}_1[\mathbf{x}_i^s, \mathbf{e}_i^s, \mathbf{t}_i^s] + \mathbf{b}_1$$

其中, $\mathbf{W}_1 \in \mathbb{R}^{d \times (d_N + d_E + d_T)}$ 为可训练参数, $\mathbf{b}_1 \in \mathbb{R}^d$ 是偏差向量, $\mathbf{f}_i^s \in \mathbb{R}^d$ 为源节点的邻居 $v_i^s \in N_s$ 的拼接后的表示。类似地,每个目标节点的邻居 $v_i^t \in N_t$ 的最终动态表示可以生成 $\mathbf{f}_i^t = \mathbf{W}_1[\mathbf{x}_i^t, \mathbf{e}_i^t, \mathbf{t}_i^t]$ 。

在获得了每个邻居的动态表示后,即源节点邻居动态表示为 $\mathbf{F}^s = \{\mathbf{f}_1^s, \mathbf{f}_2^s, \dots, \mathbf{f}_K^s\}$ 以及目标节点动态表示为 $\mathbf{F}^t = \{\mathbf{f}_1^t, \mathbf{f}_2^t, \dots, \mathbf{f}_K^t\}$,需要将不同邻居的动态表示进行有效融合,作为源节点和目标节点的融合特征表示。以往的方法在进行特征融合时,往往只对源节点进行融合或只对目标节点进行融合,未能考虑二者之间丰富的关联关系。因此,本文提出如图 2 所示的互注意力式节点特征融合策略,有效探索源节点 v_s 和目标节点 v_t 的邻居动态表示间的相互关联关系。




图 2 互注意力分数计算框架

Fig. 2 Framework of co-attention score calculation

首先,给定源节点邻居动态表示 $\mathbf{F}^s = \{\mathbf{c}_1^s, \mathbf{c}_2^s, \dots, \mathbf{c}_K^s\}$ 和目标节点动态表示

$\mathbf{F}^t = \{\mathbf{c}_1^t, \mathbf{c}_2^t, \dots, \mathbf{c}_K^t\}$, 首先计算二者之间的协同关联矩阵, 如下所示:

$$\mathbf{C} = \tanh(\mathbf{F}^{sT} \mathbf{W}_c \mathbf{F}^t)$$

其中 $\mathbf{W}_c$ 是可训练参数。在计算了协同关联矩阵之后, 采用其将源节点邻居表示空间转化到目标节点邻居表示空间, 如下所示:

$$\tilde{\mathbf{H}}^s = \tanh(\mathbf{W}^s \mathbf{F}^s + (\mathbf{W}^t \mathbf{F}^t) \mathbf{C}^T)$$

然后, 利用计算得到的源节点邻居协同关联表示计算每个源节点邻居的注意力权重, 如下:

$$\alpha^s = \text{softmax}(\mathbf{w}_s^T \tilde{\mathbf{H}}^s)$$

其中, $\alpha^s \in \mathbb{R}^K$ 是生成的源节点邻居注意力权重, $\mathbf{w}_s \in \mathbb{R}^{d_N + d_E + d_T}$ 是可训练参数。

同理, 可以利用协同关联矩阵将目标节点邻居表示空间转化到源节点邻居表示空间, 如下:

$$\tilde{\mathbf{H}}^t = \tanh(\mathbf{W}^t \mathbf{F}^t + (\mathbf{W}^s \mathbf{F}^s) \mathbf{C})$$

然后, 利用计算得到的目标节点邻居协同关联表示计算其每个邻居的注意力权重, 如下:

$$\alpha^t = \text{softmax}(\mathbf{w}_t^T \tilde{\mathbf{H}}^t)$$

其中, $\alpha^t \in \mathbb{R}^K$ 是生成的目标节点邻居注意力权重, $\mathbf{w}_t \in \mathbb{R}^{d_N + d_E + d_T}$ 是可训练参数。

另外, 参照文献[16], 采用两层的 MLP-Mixer 对节点历史邻居序列不同位置的邻居动态表示 (即源节点邻居动态表示 $\mathbf{F}^s = \{\mathbf{f}_1^s, \mathbf{f}_2^s, \dots, \mathbf{f}_K^s\}$ 和目标节点邻居动态表示 $\mathbf{F}^t = \{\mathbf{f}_1^t, \mathbf{f}_2^t, \dots, \mathbf{f}_K^t\}$) 进行混合。具体来说, 每层 MLP-Mixer 可以形式化表示为:

$$\mathbf{H}_{to} = \mathbf{H}_{in} + \mathbf{W}_{to}^2 \text{GeLU}(\mathbf{W}_{to}^1 \text{LayerNorm}(\mathbf{H}_{in}))$$

$$\mathbf{H}_{ch} = \mathbf{H}_{to} + \text{GeLU}(\text{LayerNorm}(\mathbf{H}_{to}) \mathbf{W}_{ch}^1) \mathbf{W}_{ch}^2$$

其中, in 、 to 、 ch 分别为 input、token、channel 的缩写, $\mathbf{H}_{in} \in \mathbb{R}^{K \times d}$ 、 $\mathbf{H}_{to} \in \mathbb{R}^{K \times d}$ 、 $\mathbf{H}_{ch} \in \mathbb{R}^{K \times d}$ 分别为对应位置的节点邻居表示。

以源节点为例, $\mathbf{H}_{in}^s$ 由 $\mathbf{F}^s$ 转化而来, 即 $\mathbf{H}_{in}^s = \mathbf{W}_{in} \mathbf{F}^s$, 其中 $\mathbf{W}_{in} \in \mathbb{R}^{d \times d}$ 是可训练参数, 经过两层 MLP-Mixer 后输出的 $\mathbf{H}_{ch}^s \in \mathbb{R}^{K \times d}$ 为源节点 v_s 在混合不同位置后的邻居动态表示, 可记为 $\mathbf{H}_{out}^s = \mathbf{H}_{ch}^s \in \mathbb{R}^{K \times d}$ 。同理, 经过两层 MLP-Mixer 后输出的 $\mathbf{H}_{ch}^t \in \mathbb{R}^{K \times d}$ 为源节点 v_t 在混合不同位置后的邻居动态表示, 可记为 $\mathbf{H}_{out}^t = \mathbf{H}_{ch}^t \in \mathbb{R}^{K \times d}$ 。

最后, 在通过互注意力机制获得了源节点邻居注意力权重 $\alpha^s \in \mathbb{R}^K$ 和目标节点邻居注意力权重 $\alpha^t \in \mathbb{R}^K$, 以及通过两层 MLP-Mixer 获得了源节点混合位置邻居动态表示 $\mathbf{H}_{out}^s \in \mathbb{R}^{K \times d}$ 和目标节点混合位置邻居动态表示 $\mathbf{H}_{out}^t \in \mathbb{R}^{K \times d}$ 后, 基于节点邻居注意力权重将源节点和目标节点各自的混合位置邻

居动态表示进行结合, 生成源节点 v_s 和目标节点 v_t 最终的动态表示:

$$\mathbf{o}^s = \sum_{i=1}^K \alpha_i^s \mathbf{h}_{outi}^s$$

$$\mathbf{o}^t = \sum_{i=1}^K \alpha_i^t \mathbf{h}_{outi}^t$$

其中, $\mathbf{o}^s \in \mathbb{R}^d$ 和 $\mathbf{o}^t \in \mathbb{R}^d$ 分别为最终生成的源节点 v_s 和目标节点 v_t 的动态节点表示。

2.3 预测生成及模型优化

在获得了源节点 v_s 的动态节点表示 $\mathbf{o}^s$ 和目标节点 v_t 的动态节点表示 $\mathbf{o}^t$ 后, 将二者结合起来, 这里采用拼接后输入多层感知机 (Multilayer Perceptron, MLP) 的方式, 来计算源节点 v_s 和目标节点 v_t 之间未来形成动态链路的概率:

$$y_{st} = \text{MLP}([\mathbf{o}^s, \mathbf{o}^t]) = \mathbf{W}_3 (\text{ReLU}(\mathbf{W}_2 [\mathbf{o}^s, \mathbf{o}^t] + \mathbf{b}_2)) + \mathbf{b}_3$$

其中, $\mathbf{W}_2 \in \mathbb{R}^{d \times 2d}$ 和 $\mathbf{W}_3 \in \mathbb{R}^{1 \times d}$ 是可训练参数, $\mathbf{b}_2, \mathbf{b}_3 \in \mathbb{R}^d$ 是偏差向量。

最后, 将预测分数与链路存在的真实标签进行对比, 采用交叉熵函数作为优化目标, 并采用反向传播算法对整体模型进行训练。

3 实验与讨论

3.1 实验设定

3.1.1 研究问题

通过针对以下两个研究问题进行实验验证以及分析讨论, 验证 CAGMixer 方法的有效性:

- 所提出的 CAGMixer 方法在动态网络链路预测任务上的预测效果能否超过有竞争力的基线模型并实现当前最优的效果?
- 当采样的历史邻居序列长度不同时, CAGMixer 方法的效果会发生怎样的变化? 即 CAGMixer 方法对采样历史邻居序列长度的参数敏感性如何?

3.1.2 验证数据集

为验证所提出的 CAGMixer 方法的有效性, 通过在两个动态网络数据集, 即 Enron 和 UCI, 上进行实验, 来比较 CAGMixer 方法和不同基线模型的效果。采用的两个数据集的细节描述如下:

- Enron: Enron 数据集包含约 50,000 封电子邮件, 这些邮件在 3 年间由一家能源公司 Enron 内部的员工相互发送。
- UCI: UCI 数据集是一个类似脸书

(Facebook) 的社交网络平台, 加州大学尔湾分校的学生们在此匿名进行在线交流。UCI 数据集包含了秒级时间戳, 时间粒度较为精细。

另外, 两个数据集中的动态链路均按照时间的前后顺序, 以 70%、15%、15% 的比例划分为训练集、验证集和测试集。采用的两个数据集的统计信息如表 1 所示。

表 1 实验中采用的 Enron 和 UCI 两个数据集的统计信息
Table 1 Statistics of the Enron and UCI datasets adopted in our experiments

统计 数据	节点 数目	链路 数目	平均节 点度	时间 跨度
Enron	184	125,235	680.63	3 年
UCI	1,899	59,835	31.51	196 天

表 2 在直推式动态链路预测任务上的仿真结果

Table 2 Simulation results on the transductive dynamic link prediction task

采样方式	数据集	评价指标	DyRep	TGAT	TCL	GraphMixer	CAGMixer
Random	Enron	AP	<u>82.38$\pm$3.36</u>	71.12 $\pm$ 0.97	79.70 $\pm$ 0.71	82.25 $\pm$ 0.16	83.65$\pm$1.27
		AUC	<u>84.89$\pm$3.00</u>	68.89 $\pm$ 1.10	75.74 $\pm$ 0.72	84.38 $\pm$ 0.21	85.49$\pm$0.53
	UCI	AP	65.14 $\pm$ 2.30	79.63 $\pm$ 0.70	89.57 $\pm$ 1.63	<u>93.25$\pm$0.57</u>	93.37$\pm$0.43
		AUC	68.77 $\pm$ 2.34	78.53 $\pm$ 0.74	87.82 $\pm$ 1.36	91.81$\pm$0.67	<u>91.46$\pm$0.61</u>
Historical	Enron	AP	71.19 $\pm$ 2.76	64.07 $\pm$ 1.05	70.66 $\pm$ 0.39	77.98$\pm$0.92	<u>77.17$\pm$2.63</u>
		AUC	74.69 $\pm$ 3.55	61.85 $\pm$ 1.43	67.95 $\pm$ 0.88	<u>75.27$\pm$1.14</u>	76.08$\pm$1.57
	UCI	AP	55.10 $\pm$ 3.14	68.27 $\pm$ 1.37	80.25 $\pm$ 2.74	<u>84.11$\pm$1.35</u>	86.07$\pm$0.55
		AUC	57.91 $\pm$ 3.12	58.89 $\pm$ 1.57	72.25 $\pm$ 3.46	<u>77.54$\pm$2.02</u>	80.23$\pm$0.96
Inductive	Enron	AP	67.79 $\pm$ 1.53	63.94 $\pm$ 1.36	71.29 $\pm$ 0.32	75.01$\pm$0.79	<u>74.34$\pm$1.91</u>
		AUC	68.73 $\pm$ 1.34	60.45 $\pm$ 2.12	67.64 $\pm$ 0.86	<u>71.53$\pm$0.85</u>	72.49$\pm$1.22
	UCI	AP	54.79 $\pm$ 1.76	68.67 $\pm$ 0.84	76.01 $\pm$ 1.11	<u>80.10$\pm$0.51</u>	80.94$\pm$0.21
		AUC	54.25 $\pm$ 2.01	60.80 $\pm$ 1.01	70.05 $\pm$ 1.86	<u>74.59$\pm$0.74</u>	76.09$\pm$0.33

表 3 在归纳式动态链路预测任务上的仿真结果

Table 3 Simulation results on the inductive dynamic link prediction task

采样方式	数据集	评价指标	DyRep	TGAT	TCL	GraphMixer	CAGMixer
Random	Enron	AP	74.55 $\pm$ 3.95	67.05 $\pm$ 1.51	<u>76.14$\pm$0.79</u>	75.88 $\pm$ 0.48	77.89$\pm$1.43
		AUC	76.34 $\pm$ 4.20	64.63 $\pm$ 1.74	72.33 $\pm$ 0.99	<u>76.51$\pm$0.71</u>	78.10$\pm$1.00
	UCI	AP	57.48 $\pm$ 1.87	79.54 $\pm$ 0.48	87.36 $\pm$ 2.03	<u>91.19$\pm$0.42</u>	91.82$\pm$0.13
		AUC	58.08 $\pm$ 1.81	77.64 $\pm$ 0.38	84.49 $\pm$ 1.82	<u>89.30$\pm$0.57</u>	90.01$\pm$0.22
Historical	Enron	AP	62.08 $\pm$ 2.27	61.40 $\pm$ 1.31	67.11 $\pm$ 0.62	<u>72.37$\pm$1.37</u>	73.21$\pm$2.74
		AUC	61.50 $\pm$ 2.50	57.84 $\pm$ 2.18	64.06 $\pm$ 1.02	<u>68.20$\pm$1.62</u>	70.35$\pm$1.24
	UCI	AP	52.47 $\pm$ 2.06	70.52 $\pm$ 0.93	76.71 $\pm$ 1.00	<u>81.66$\pm$0.49</u>	82.74$\pm$0.13
		AUC	51.25 $\pm$ 2.37	62.32 $\pm$ 1.18	70.46 $\pm$ 1.94	<u>75.98$\pm$0.84</u>	77.61$\pm$0.31
Inductive	Enron	AP	62.08 $\pm$ 2.27	61.40 $\pm$ 1.30	67.11 $\pm$ 0.62	<u>72.37$\pm$1.38</u>	73.22$\pm$2.76
		AUC	61.50 $\pm$ 2.50	57.83 $\pm$ 2.18	64.05 $\pm$ 1.02	<u>68.19$\pm$1.63</u>	70.36$\pm$1.26
	UCI	AP	52.47 $\pm$ 2.09	70.49 $\pm$ 0.93	76.65 $\pm$ 0.99	<u>81.64$\pm$0.49</u>	82.77$\pm$0.14
		AUC	51.26 $\pm$ 2.40	62.29 $\pm$ 1.17	70.42 $\pm$ 1.93	<u>75.97$\pm$0.85</u>	77.64$\pm$0.31

3.1.3 基线模型

为对 CAGMixer 的效果进行有效验证, 选择了当前动态网络链路预测的 4 个代表性方法作为基线模型, 包括 DyRep、TGAT、TCL、GraphMixer, 这些方法的详细描述如下所示:

- DyRep 采用了一种循环网络架构, 能够在每次节点间交互发生时更新节点状态。该模型还包含一个时序注意力聚合模块, 用以捕捉动态图中不断演化的结构信息^[13]。
- TGAT 通过基于自注意力机制聚合每个节点的

时序拓扑邻居特征来计算节点的动态表示。该方法还首先设计了连续时间编码函数, 以有效捕捉动态网络中的时序模式^[14]。

- TCL 首先通过在时序依赖交互子图上进行广度优先搜索, 生成每个节点的交互序列, 同时提出了一种同时考虑图拓扑结构与时序信息的图 Transformer 学习节点表示, 并引入了交叉注意力机制, 以建模节点之间的相互依赖关系^[19]。

- GraphMixer 研究表明, 固定的时间编码函数比可训练版本表现更优, 该方法将固定时间编码函数与基于 MLP-Mixer 的链路编码器结合, 从而

从时序链路中学习特征。同时,通过采用带有邻居均值池化的节点编码器来聚合节点特征^[16]。

3.1.4 实验设定

为验证所提出的 CAGMixer 方法的有效性,将 CAGMixer 和基线模型在两种动态网络链路预测设定上进行比较,包括:(1)直推式设定,预测的链路所连接的两个节点均为可见节点;(2)归纳式设定,预测的链路所连接的两个节点中至少有一个是不可见节点。另外,参照文献^[16,20],在三种负样本采样设定下对模型性能进行评估,包括:(1)随机采样(Random sampling),从动态网络的所有链路中随机采样负样本;(2)历史采样(Historical sampling),从动态网络的所有链路中的已观测链路中选取负样本;(3)归纳式采样(Inductive sampling),从动态网络的归纳式链路中的已观测链路中选取负样本。另外,采用平均精度(Average Precision, AP)和 ROC 曲线下面积(Area Under the Receiver Operating Characteristic Curve, AUC)作为评价指标,来测试 CAGMixer 模型和基线模型在直推式动态链路预测任务和归纳式动态链路预测任务上的性能。

3.2 总体表现

本节实验内容比较了 CAGMixer 模型与基线模型在 AP 指标和 AUC 指标上的性能,以检验本文提出的 CAGMixer 模型的有效性。不同模型在直推式动态链路预测任务上的实验结果见表 2,另外在归纳式动态链路预测上的实验结果见表 3。两个表中效果最优的模型均用加粗进行标识,效果次优的基线模型均用下划线进行标识。

通过观察表 2 和表 3,首先可以发现 CAGMixer 方法在直推式动态链路预测任务上的大多数场景下效果优于所有基线模型,在归纳式动态链路预测任务上的所有场景下效果优于所有基线模型,验证了所提出的 CAGMixer 方法的有效性。同时可以发现 CAGMixer 方法相较于基线模型在归纳式动态链路预测任务上提升更为明显。预测归纳式动态链路相较于预测直推式动态链路难度更高,因为存在不可见节点。而所提出的 CAGMixer 方法在归纳式动态链路预测任务上更为有效,说明了其的高度泛化能力以及在实际应用场景下的有效性。另外,可以看到基线模型中 GraphMixer 方法表现最好,这可能是优于其采用了 MLP-Mixer 模型对源节点和目标节点的邻居信息进行有效融合,从而生成准确的动态节点表示。然而,GraphMixer 方法未能考虑源节点和目

标节点间的关联关系,导致性能仍欠佳,通过解决该问题,CAGMixer 方法有效地提升了直推式动态链路预测和归纳式动态链路预测的性能。

3.3 参数分析

为了检验 CAGMixer 方法对采样邻居数目的敏感性,本节分析了邻居数目的影响。具体来说,将邻居数目在{5, 10, 15, 20, 25, 30}范围内进行调整,来测试 CAGMixer 方法的效果。直推式动态链路预测任务和归纳式动态链路预测任务上的 AP 指标实验结果如图 3 和图 4 所示,分别展现了 Enron 数据集上的结果和 UCI 数据集上的结果。

从图 3 和图 4 可以观察到,随着邻居数目的变化,CAGMixer 方法在 Enron 数据集上的效果波




图 3 在 Enron 数据集上的仿真结果

Fig. 3 Experimental Results on the UCI dataset




图 4 在 UCI 数据集上的仿真结果

Fig. 4 Experimental Results on the Hepth dataset

动较为明显,且 CAGMixer 方法效果在不同邻居数目下的标准差都较大。然而,不同的是,在 UCI 数据集上,随着邻居数目的变化,CAGMixer 方法的效果较为平稳,且标准差在不同邻居数目下普遍较小。两个数据集上的实验结果差异可能是由于两个数据集上节点的平均节点度不同。具体来说,如表 1 所示,Enron 数据集上的平均节点度为 680.63,UCI 数据集上的平均节点度为 31.51。也

就是说,在 Enron 数据集上,由于平均节点度较高,采样邻居数目较为有限,采样邻居中可能存在的噪声邻居会对模型效果造成更明显的影响。

4 应用场景与约束条件分析

为确保本文所提 CAGMixer 方法在指挥控制领域的有效应用,本节从应用场景和模型约束两个维度对方法的部署条件进行系统分析。

4.1 典型应用场景

结合动态战场环境的实际特点,CAGMixer 方法可适用于以下四类典型作战场景:

1) 敌方通信网络动态重构研判:在城市巷战等强对抗环境中,敌方通信网络因节点损毁或干扰而频繁重构。本方法通过互注意力机制捕捉节点间的动态关联变动,可实时预判敌方指挥关系变化,支撑动态目标瞄准决策。

2) 无人集群协同链路动态维持:无人集群作战中单元频繁出入、拓扑持续演化。本方法的归纳式预测能力可处理新节点涌现场景,快速预测其可能建立的协同关系,支撑集群拓扑优化。

3) 联合作战体系演化趋势推演:将作战单位抽象为节点、指挥协同关系抽象为边,利用本方法学习体系演化规律,推演战役不同阶段的结构状态,辅助识别体系脆弱点与关键枢纽。

4) 战场态势感知链路补盲预测:复杂战场环境下,部分传感器节点可能因干扰或损毁等导致通信链路中断,形成感知盲区。本方法可根据历史交互模式,预测盲区节点与周边节点的潜在连接路径,为通信中继部署或无人侦察平台路径规划提供参考,提升战场感知体系的鲁棒性。

4.2 模型约束条件

尽管 CAGMixer 在实验中表现优异,但其在实际部署中仍受限于若干前提条件,CAGMixer 的有效应用需满足以下约束:

1) 数据质量约束:模型依赖历史交互序列的完整性,冷启动节点仅能依靠初始特征,预测精度受限,且数据噪声过大将导致性能下降,实际战场环境中需确保数据采集的可靠性。

2) 网络稀疏约束:模型在节点交互过于稀疏的网络中难以捕获足够的历史模式,可能导致节点表示学习不充分。实际应用中若网络平均度较低,可考虑引入外部辅助数据弥补信息不足。

3) 演化规律假设约束:模型假设历史交互模式可反映未来趋势。在通信完全中断或执行欺骗性机动的极端场景下,动态链路变化失去规律

性,可能导致模型有效性难以保证。

4) 节点特征完备性约束:归纳式预测依赖节点属性的判别力。若节点特征为随机初始化或全零向量,互注意力机制的效果将受制约,建议结合领域知识构建有意义的初始特征。

5 结论

本文面向作战体系建模与动态演化分析的动态性特征,提出了一种基于互注意力图混合器的动态网络链路预测方法。该方法通过互注意力机制显式建模源节点与目标节点间的关联关系,并结合多层感知机混合器对历史邻居序列进行有效融合,从而实现对动态网络中未来链路的准确预测。在两个真实数据集上的实验表明,CAGMixer 方法在直推式动态链路预测与归纳式动态链路预测两种设定下均能取得优于现有基线模型的性能,尤其在包含未见节点的归纳式预测任务中表现出更强的泛化能力。本文工作不仅为动态网络链路预测提供了一种充分建模节点间丰富关联关系的新思路,也为指挥控制系统中动态作战体系的精准建模与演化分析提供了可行的技术途径。

References

1. 王维平,李小波,杨松,等.智能化多无人集群作战体系动态自适应机制设计方法[J].系统工程理论与实践,2021,41(5):1096-1106.
WANG W P, LI X B, YANG S, et al. Design Method of Dynamic Adaptive Mechanism for Intelligent Multi-Unmanned Swarm Combat System[J]. Systems Engineering — Theory & Practice, 2021, 41(5): 1096-1106. (in Chinese)
2. 张晓松,鞠卓亚,阳东升,等.反无人集群作战指挥控制体系动态构建方法[J].指挥与控制学报,2025,11(1):23-30.
ZHANG X S, JU Z Y, YANG D S, et al. Dynamic Construction Method of Command and Control System for Counter-Unmanned Swarm Operations[J]. Journal of Command and Control, 2025, 11(1): 23-30. (in Chinese)
3. 张连怡,沈喜生,卿杜政,等.基于信息熵的复杂作战网络动态演化研究[J].系统仿真学报,2022,34(12):2605-2618.
ZHANG L Y, SHEN X S, QING D Z, et al. Research on Dynamic Evolution of Complex Combat Networks Based on Information Entropy[J]. Journal of System Simulation, 2022, 34(12): 2605-2618. (in Chinese)
4. 秦长江,吴克宇,成清,等.基于杀伤网贡献率的动态体系节点重要度评估[J].系统工程与电子技术,2023,45(6):1732-1742.
QIN C J, WU K Y, CHENG Q, et al. Importance Evaluation of Dynamic System Nodes Based on Kill-Chain Contribution Rate[J]. Systems Engineering and Electronics, 2023, 45(6): 1732-1742. (in Chinese)
5. 焦鹏飞,刘欢,吕乐,等.基于对比学习的全局增强动态

异质图神经网络[J]. 计算机研究与发展, 2023, 60(8): 1808-1821.

JIAO P F, LIU H, LÜ L, et al. Global-enhanced Dynamic Heterogeneous Graph Neural Network via Contrastive Learning[J]. Journal of Computer Research and Development, 2023, 60(8): 1808-1821. (in Chinese)

6. 陆耀, 陈奕帆, 杨淇然, 等. 网络科学赋能人工智能: 现状与展望[J]. 指挥与控制学报, 2025, 11(5): 540-549.

LU Y, CHEN Y F, YANG Q R, et al. Network Science Empowering Artificial Intelligence: Current Status and Prospects[J]. Journal of Command and Control, 2025, 11(5): 540-549. (in Chinese)

7. 刘靖旭, 于茹, 蒋秉川. 基于贝叶斯网络的动态战场环境效应评估[J]. 军事运筹与评估, 2024, 39(6): 36-41.

LIU J X, YU R, JIANG B C. Dynamic Battlefield Environment Effect Evaluation Based on Bayesian Network[J]. Military Operations Research and Assessment, 2024, 39(6): 36-41. (in Chinese)

8. 尹彦婷, 吴雅婧, 杨雪冰, 等. 基于时空正则化流的动态链路预测[J]. 中国科学: 信息科学, 2024, 54(7): 1692-1708.

YIN Y T, WU Y J, YANG X B, et al. Dynamic Link Prediction via Spatio-Temporal Regularized Flows[J]. SCIENCE CHINA Information Sciences, 2024, 54(7): 1692-1708. (in Chinese)

9. 李峰. 基于网络时空特征的链路预测方法研究[D]. 四川大学, 2023.

LI F. Research on Link Prediction Methods Based on Spatio-Temporal Features of Networks[D]. Sichuan University, 2023. (in Chinese)

10. 刘琳岚, 冯振兴, 舒坚. 基于时序图卷积的动态网络链路预测[J]. 计算机研究与发展, 2024, 61(2): 518-528.

LIU L L, FENG Z X, SHU J. Dynamic Network Link Prediction Based on Temporal Graph Convolution[J]. Journal of Computer Research and Development, 2024, 61(2): 518-528. (in Chinese)

11. 陈冠男, 焦鹏飞, 张新勋, 等. 基于时序信息对比的动态图链接预测方法[J]. 指挥与控制学报, 2025, 11(5): 611-618.

CHEN G N, JIAO P F, ZHANG X X, et al. Dynamic Graph Link Prediction Method Based on Temporal Information Contrast[J]. Journal of Command and Control, 2025, 11(5): 611-618. (in Chinese)

12. 韩忠明, 王宇航, 陈福宇, 等. 基于学习连续时间事件序列的动态网络链路预测[J]. 中国科学: 信息科学, 2023, 53(2): 234-249.

HAN Z M, WANG Y H, CHEN F Y, et al. Dynamic Network Link Prediction via Learning Continuous-Time Event Sequences[J]. SCIENCE CHINA Information Sciences, 2023, 53(2): 234-249. (in Chinese)

13. Trivedi R, Farajtabar M, Biswal P, et al. DyRep: Learning Representations over Dynamic Graphs [C]//Proceedings of the 7th International Conference on Learning Representations, New Orleans, LA, USA. 2019.

14. Xu D, Ruan C, Kärpeoglu E, et al. Inductive represen-

tation learning on temporal graphs [C]//Proceedings of the 8th International Conference on Learning Representations, Addis Ababa, Ethiopia. 2020.

15. Wang Y, Chang Y-Y, Liu Y, et al. Inductive Representation Learning in Temporal Networks via Causal Anonymous Walks [C]//Proceedings of the 9th International Conference on Learning Representations, Virtual Event, Austria. 2021.

16. Cong W, Zhang S, Kang J, et al. Do We Really Need Complicated Model Architectures For Temporal Networks? [C]//Proceedings of the Eleventh International Conference on Learning Representations, Kigali, Rwanda. 2023.

17. 李聪, 季新生, 刘树新, 等. 基于节点匹配度的动态网络链路预测方法[J]. 网络与信息安全学报, 2022, 8(04): 131-143.

LI C, JI X S, LIU S X, et al. Dynamic Network Link Prediction Method Based on Node Matching Degree[J]. Chinese Journal of Network and Information Security, 2022, 8(04): 131-143. (in Chinese)

18. 袁子轩, 张峰, 许岗, 等. 融合 MAML 和 TGAT 的机会网络动态链路预测模型[J]. 小型微型计算机系统, 2024, 45(12): 2957-2963.

YUAN Z X, ZHANG F, XU G, et al. Dynamic Link Prediction Model for Opportunistic Networks Integrating MAML and TGAT[J]. Journal of Chinese Computer Systems, 2024, 45(12): 2957-2963. (in Chinese)

19. Wang L, Chang X, Li S, et al. TCL: Transformer-based Dynamic Graph Modelling via Contrastive Learning [J]. arXiv preprint arXiv:2105.07944. 2021.

20. Yu L, Sun L, Du B, et al. Towards Better Dynamic Graph Learning: New Architecture and Unified Library [C]//Proceedings of the Advances in Neural Information Processing Systems, New Orleans, LA, USA. 2023.