



基于异构图神经网络的可解释兵棋态势预测方法

陈露 尚家兴 刘大江 张玉芳 倪晚成

An Interpretable Wargame Situation Prediction Method Based on Heterogeneous Graph Neural Networks

CHEN Lu, SHANG Jia-Xing, LIU Da-Jiang, ZHANG Yu-Fang, NI Wan-Cheng

在线阅读 View online: <https://doi.org/10.16383/j.aas.c240468>

您可能感兴趣的其他文章

融合目标定位与异构局部交互学习的细粒度图像分类

Fine-grained Image Classification by Integrating Object Localization and Heterogeneous Local Interactive Learning

自动化学报. 2024, 50(11): 2219–2230 <https://doi.org/10.16383/j.aas.c230507>

兵棋推演的智能决策技术与挑战

Intelligent Decision Making Technology and Challenge of Wargame

自动化学报. 2023, 49(5): 913–928 <https://doi.org/10.16383/j.aas.c210547>

面向对抗样本的深度神经网络可解释性分析

Interpretability Analysis of Deep Neural Networks With Adversarial Examples

自动化学报. 2022, 48(1): 75–86 <https://doi.org/10.16383/j.aas.c200317>

面向入侵检测的元图神经网络构建与分析

Construction and Analysis of Meta Graph Neural Network for Intrusion Detection

自动化学报. 2023, 49(7): 1530–1548 <https://doi.org/10.16383/j.aas.c200819>

基于时序图推理的设备剩余使用寿命预测

Remaining Useful Life Estimation of Facilities Based on Reasoning Over Temporal Graphs

自动化学报. 2024, 50(1): 76–88 <https://doi.org/10.16383/j.aas.c230014>

卷积神经网络表征可视化研究综述

Representation Visualization of Convolutional Neural Networks: A Survey

自动化学报. 2022, 48(8): 1890–1920 <https://doi.org/10.16383/j.aas.c200554>

基于异构图神经网络的可解释兵棋态势预测方法

陈露^{1,2} 尚家兴^{1,2} 刘大江^{1,2} 张玉芳^{1,2} 倪晚成^{3,4}

摘要 复杂多变的现代兵棋模拟中, 精准的战局预测与战场态势解读是提高决策质量的关键. 针对兵棋推演中复杂态势表达困难和模型可解释性不足的挑战, 提出基于异构图神经网络的可解释兵棋预测模型 WarGraph, 模型由多关系图建模、时序分析、预测解释三个模块构成. 首先综合复盘数据与先验知识, 将环境与算子之间的多元复杂关系建模为多关系异构图, 从而捕捉作战单元之间以及与环境复杂交互关系, 实现复杂推演态势的表征; 然后利用 Transformer 时序分析方法, 动态捕捉整体态势演变, 并通过注意力机制抽取关键决策时刻. 该模型不仅能在复盘推演中精准预测战局胜负, 而且注意力机制的引入能更好地解释决策中的关键因素. 以“庙算·智胜”实时兵棋对抗平台 2021 年的 108 场陆战对局复盘数据作为实验数据集, 结果显示本文提出的模型预测准确率可达 90.91%, 相比其他模型提高大约 9.09%. 通过对注意力系数的可视化分析, 模型在决策过程中捕捉到关键时刻, 进一步验证了模型的可解释性.

关键词 兵棋推演, 态势预测, 图神经网络, 可解释分析, 深度学习

引用格式 陈露, 尚家兴, 刘大江, 张玉芳, 倪晚成. 基于异构图神经网络的可解释兵棋态势预测方法. 自动化学报, 2025, 51(6): 1248–1260

DOI 10.16383/j.aas.c240468 **CSTR** 32138.14.j.aas.c240468

An Interpretable Wargame Situation Prediction Method Based on Heterogeneous Graph Neural Networks

CHEN Lu^{1,2} SHANG Jia-Xing^{1,2} LIU Da-Jiang^{1,2} ZHANG Yu-Fang^{1,2} NI Wan-Cheng^{3,4}

Abstract In complex and changeable modern wargame simulations, accurate battlefield situation prediction and interpretation are crucial for high-quality decision-making. To address the challenges of difficult expression of complex situations and insufficient model interpretability in wargame deduction, this paper proposes an interpretable wargame prediction model WarGraph based on heterogeneous graph neural networks. The model consists of three modules: Multi-relational graph modeling, temporal analysis, and interpretable prediction. We first combine replay data with prior knowledge to construct a multi-relational heterogeneous graph, effectively modeling the intricate relationships between the environment and the operators. This enables capturing the complex interactions between combat units and the environment, realizing the representation of complex deduction situations. Then by leveraging Transformer-based temporal analysis, we dynamically track the overall situation evolution and use attention mechanisms to identify key decision-making moments. This model can not only accurately predict the outcome of battles in wargame replays, but also the introduction of the attention mechanism enables a better explanation of the key factors in decision-making. Using replay data of 108 matches from the “MiaoSuan·ZhiSheng” wargame platform in 2021, the results show that the proposed model achieves a prediction accuracy of up to 90.91%, about 9.09% higher than the baseline models. Visualization of the attention coefficients demonstrates that the model captures critical moments in the decision-making process, which further validates its interpretability.

Key words Wargame deduction, situation prediction, graph neural network, interpretable analysis, deep learning

Citation Chen Lu, Shang Jia-Xing, Liu Da-Jiang, Zhang Yu-Fang, Ni Wan-Cheng. An interpretable wargame situation prediction method based on heterogeneous graph neural networks. *Acta Automatica Sinica*, 2025, 51(6): 1248–1260

收稿日期 2024-07-01 录用日期 2025-02-14

Manuscript received July 1, 2024; accepted February 14, 2025
中国科学院自动化研究所复杂系统认知与决策实验室开放基金 (CASIA-KFKT-10) 资助

Supported by Open Fund of the Laboratory of Cognition and Decision Making for Complex Systems, Institute of Automation, Chinese Academy of Sciences (CASIA-KFKT-10)

本文责任编辑 左旺孟

Recommended by Associate Editor ZUO Wang-Meng

1. 重庆大学计算机学院 重庆 400044 2. 信息物理社会可信服务计算教育部重点实验室 重庆 400044 3. 中国科学院自动化研究所 北京 100190 4. 中国科学院大学 北京 100049

现代兵棋推演作为一种战争模拟手段, 其目的在于通过策略推演平台, 模拟现实战场情境, 以提高指挥官对战术决策的洞察力. 实际应用中指挥官通过模拟战场操作, 深入分析作战单元能力及战术

1. College of Computer Science, Chongqing University, Chongqing 400044 2. Key Laboratory of Dependable Service Computing in Cyber Physical Society, Ministry of Education, Chongqing 400044 3. Institute of Automation, Chinese Academy of Sciences, Beijing 100190 4. University of Chinese Academy of Sciences, Beijing 100049

协同机制,但在面对现代战场的多变性与复杂性时,现有兵棋推演系统面临着准确性和可解释性的双重挑战。在此背景下,战场态势的精确预测和深入解读对于提升决策质量具有重要意义。

近几年部分学者从不同角度对兵棋推演过程中的建模难问题以及有效决策信息分析问题进行了探究^[1-5]。文献 [6-9] 自 2017 年对兵棋推演做了开创性的研究,指出现代兵棋最显著的特点在于认知建模,并梳理兵棋推演系统存在的主要难题,包括克服数据样本获取和生成的问题以及模拟人类的认知决策过程难题,指出未来兵棋智能化的发展方向。此后,文献 [10-11] 利用多维分析和深度学习模型构建兵棋推演过程中基于特征项的评估特征空间,克服人为因素和缺乏动态对抗的影响,通过模拟实验的方式更大程度还原战场真实情况,但研究中没有讨论实际战场环境中存在多个因素交互作用的问题,对战场环境的建模仍处于理想化状态。邢思远等^[12] 基于回合制兵棋复盘数据,利用频繁模式挖掘算法,分析不同地形下战局双方的武器效用,研究使用战果致因分析,即通过分析不同的攻击单位与目标之间的关联性来评估不同作战属性对战果的影响,然而兵棋的推演过程是动态演化的,利用 Apriori 关联规则往往难以捕捉细粒度的动态关系。尹奇跃等^[13] 分析和综述兵棋推演中智能决策主流技术的发展前景,比如在提高决策效率^[14-15] 方面利用强化学习和博弈论的原理来设计和优化智能系统,研究的重点包括探索博弈学习的理论保证、可解释性,以及在处理复杂多变的战场环境^[16-17] 等方面的巨大潜力。除此之外,文献 [18-19] 也从强化学习智能化决策方面开展研究,讨论如何利用强化学习改进兵棋中的行为反馈,以及如何使用多属性决策方法,比如熵-权重方法,来评估战争游戏中的目标威胁等级。然而在利用强化学习进行智能化决策时,奖励和反馈信号可能非常稀疏,影响策略的评估效果,不仅如此,研究指出部分智能决策中兵棋面临的局限与瓶颈,如数据质量与依赖性问题^[14-16]、多任务协同与动态环境适应性挑战^[20-24] 等。近年也有学者探索如何利用深度学习相关方法对战场建模并且分析兵棋态势,对推演过程中的态势信息经过简化和采样后输入到深度学习框架中进行自适应学习,并且构建相适应的训练数据集。例如,文献 [20-21, 23] 提出基于对比预测编码和 LSTM 模型的深度学习架构,实现较高精度的兵棋算子意图识别,在宏观上捕捉到战局动态演变特点,但是在作战单元交互上却没有进行深入建模。

兵棋研究中重要的一环是对战场形势和战局走

向的预测, Sun 等^[25] 从用户操作策略的层面构建行为特征数据集,利用多种机器学习方法预测玩家获胜的习惯性策略行为。Ma 等^[26] 针对兵棋中大量模糊和不确定环境下的路线选择问题,提出模糊动态路线选择模型,实现自动路径选择预测。Wang 等^[27] 针对传统路径规划算法在处理动态复杂战场环境时的局限性,提出 MFSCD* lite 算法,旨在使用改进的启发式函数在搜索速度与路径优化之间取得平衡,然而由于实际战场环境的复杂交互性、不确定性等影响,导致算法的实际表现可能与理论研究结果存在差异。除此之外,国内外也有部分团队将兵棋研究成果应用到国家安全以及国防教育中^[28-29]。

为解决原始非结构化兵棋态势数据难以分析的问题,张大永等^[30] 通过建立映射模型,将复盘数据集梳理成适合机器学习分析的结构化数据集,显著提高了数据的易用性。然而,兵棋推演过程中充斥着大量复杂的战场信息,简单将其处理为结构化数据的做法往往会丢失较多的有用信息,尤其是战场上的复杂交互信息。为此,余晓晗等^[31] 首次将兵棋数据与图论相关联,将态势转化为图结构,并提出基于变分自编码器的敌方算子位置预测方法。但是该工作只考虑算子之间的简单交互而忽略了地图要素,导致其模型在处理复杂地形和环境因素时表现不佳。同年该团队借助基于注意力机制的模型来预测陆战兵棋中算子的实时位置^[32],利用多头自注意力机制将算子位置预测问题转化为稀疏特征下的多分类问题,能在一定程度上捕获长距离依赖,提高模型的预测准确度。然而,上述方法也缺乏对战场全局态势的动态表征,使得模型在推演具有长时间序列特性的战局变化时效果有限。除此之外,大多数模型侧重于对结果的预测,而忽略了对预测结果的解释分析,导致模型难以根据预测结果挖掘相应的决策知识。

为解决上述问题,本文提出基于异构图神经网络的可解释兵棋预测模型 WarGraph。首先,针对复杂态势表征难题,利用多关系异构图建模算子之间以及算子与环境的复杂交互关系。其次,针对推演态势的动态变化特点,借助 Transformer 时序模型捕捉其动态性,提升模型预测性能。最后,引入注意力机制捕获影响战局胜负的关键时刻,即对当前局势和战局预测结果有显著影响或推动作用的时刻点,为模型提供可解释性。

本文的主要贡献如下:

- 1) 以多关系异构图为载体,基于动态推演数据建立算子、地图、关键位置对象之间的复杂关系,并将指挥决策相关先验知识、推演规则、态势信息有

机融合到异构图中, 构建基于同构/异构图的态势表征, 并利用图神经网络进行推演态势表征学习.

2) 借助 Transformer 的时序分析思想, 提出一种基于时间序列的表征学习方法, 能够动态捕捉战局的整体演变过程. 通过引入注意力机制, 模型可以识别并抽取关键决策时刻, 从而实现对预测结果的解释分析.

3) 基于 2021 年“庙算·智胜”分队级人-人对抗比赛的复盘数据进行验证, 实验结果表明, 所提出的模型预测准确率达 90.91%, 相比其他模型提高大约 9.09%. 注意力系数的可视化分析结果进一步表明模型能有效捕捉推演过程中的决策关键时刻, 具有较好的可解释性.

1 基于多关系异构图的态势建模

兵棋复盘数据包含从兵棋推演开始至结束的多帧离散时间过程数据, 这些数据不仅包括各类地形、算子状态和战术部署, 还涉及各个作战单位在战局中的实时动作和策略变化. 同时, 兵棋棋盘模拟真实的战场环境, 通常采用比例缩小的战术六角格地图表示, 地图上每个六角格都标有地形类型、道路状况、桥梁、河流等关键地理要素, 这些要素作为静态因子会对战局结果产生重要影响. 图 1 所示即为某一时刻的兵棋地图, 在对复盘数据的分析中, 首先将动态的战场状态视作一连串离散时间步的静态图, 每一张图代表一个特定时间点的战局快照. 在这些静态图中, 由于考虑到实际战局中双方初步部署的时间消耗, 以及战局在接近结束时基本已成定局, 部分时段的态势数据存在重复和冗余, 为了能够更有效地捕捉战局中关键的变化, 在预处理时过滤这部分数据. 同时, 为了能更加全面地捕捉战局态势变化, 在态势数据处理部分将其分为地图静态数据和算子动态数据, 前者涵盖了静态地理要素, 后者融合了算子的行动等动态因素, 由此综合把控战场静态数据不变性和动态数据的演化特点. 本节




图 1 某一时刻兵棋战场

Fig.1 Wargame battlefield at a specific moment

主要介绍兵棋复盘数据分类处理以及关系图的构建.

1.1 数据分类

1) 地图静态数据

在兵棋地图中, 六角格作为地图最小结构单位, 由唯一的 ID 进行标识, 其作为图中的静态节点, 包含七个特征: ID, 坐标, 高程, 隐蔽情况, 地形, 道路情况, 河流情况. 通常假定六角格的静态属性从战局推演开始到结束不发生改变.

2) 算子动态数据

针对战场中瞬息变化的动态演化模式, 模型通过算子的位置、属性等变化去把握战局的动态演化. 在同一时间步中, 由当前战场上的算子特征来反映战局的当前态势, 所提取的特征涵盖地形利用、路线规划、时机把握、兵力部署等方面, 支持进攻、防守侦察等任务, 比如算子类型、血量、装甲属性、机动能力等.

为了进一步分析提取的特征在战场不同阶段的变化趋势, 以及验证特征提取的有效性, 避免特征之间存在多重冗余的情况, 利用 Pearson 相关系数计算部分特征之间的相关性. 如图 2 所示的热力图中, 展示了战局初始时刻、中间时刻、末尾时刻的相关性情况, 可以看出某些特征的重要性以及相关性随着战局推演逐渐变化. 例如, 在战局进行到中间阶段, 作战单位的存活时间与装甲类型的相关性有逐渐增强的趋势, 以及在激烈战斗阶段, 某些算子

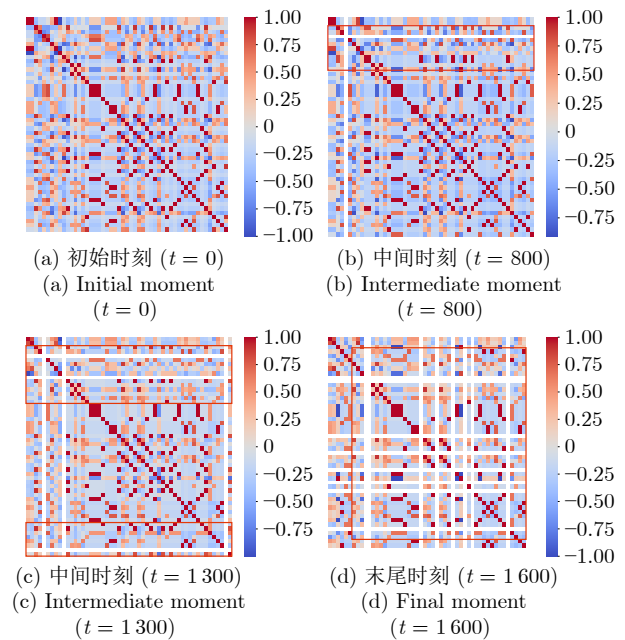


图 2 不同阶段特征相关性变化

Fig.2 Changes in feature correlations at different stages

可能因为被摧毁或失去功能导致特征数据不再更新, 如相关性热力图中逐渐增多的空白区域所示, 由此验证了模型对所提取特征进行分析的必要性。

1.2 多关系异构图构建

基于多关系异构图的态势表征, 其关键在于以多关系异构图为载体, 建立算子、地图、关键位置之间的复杂关系, 将指挥决策相关先验知识和态势信息有机融合到图信息中, 特别是在具有战争迷雾的兵棋态势中, 棋盘呈现的每个节点的状态信息独立, 算子复杂的关联隐藏在状态信息中, 为了解析这些关联, 本文将非结构化态势转化为图结构来捕获潜在信息。

基于上述思路, 本文将兵棋中的地图六角格和算子两类关键对象当作节点, 它们之间的多种关系当作异构图中的边, 利用异构图来有效构建节点间的连接. 异构图结构表示为 $G = (V, E, A, R)$, 其中 V, E 分别表示图的节点集和边集, A, R 描述节点类型集合和边类型集合, $|A| + |R| > 2$. 特别地, 当 $|A| = 1, |R| = 1$ 时, 异构图转化为同构图。

推演过程中算子之间以及算子与环境之间存在多种直接或间接关联. 例如算子与算子之间的直瞄打击、间瞄打击、引导打击、雷场打击以及巡飞弹侦察等关系. 算子与环境之间也存在隐蔽、特殊地形利用、夺控区占领等关联. 它们之间的综合作用引导战局的走势, 但是对每一种细粒度的关系一一进行建模和训练将会产生高昂的人工和时间成本, 且存在数据稀疏性问题, 影响模型性能. 故在提出的模型中综合考虑影响战局的关键因素, 在保持模型性能的同时降低建模复杂度. 具体来说, 模型构建四种节点关系图: 六角格节点之间的通视关系图 G_{map} , 算子节点之间的侦察关系图 G_{see} , 算子与六角格之间的隶属关系图 G_{stay} , 以及算子节点之间的打击关系图 G_{attack} .

具体而言, 六角格间通过无向边表示通视和邻居关系, 若彼此通视则有边连接. 对于算子节点, 存在侦察关系时创建有向边, 由侦察算子指向被侦察算子; 存在打击行为时创建有向边, 由实施打击的算子指向被打击算子. 当算子位于某六角格上时, 连接边表示算子与六角格的隶属关系, 四种关系图描述如图 3 所示。

对于上述关系构成的图结构, 采用图卷积神经网络 (Graph convolutional network, GCN) 和图自编码器 (Graph auto-encoder, GAE) 的方法从空间拓扑和节点属性两方面提取战场关键潜在信息。

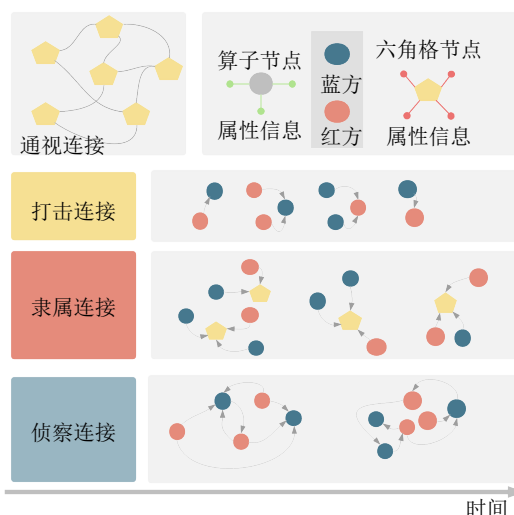


图 3 四种关系图描述

Fig.3 Graph description of four relations

2 基于图神经网络的态势表征学习

本节主要利用图神经网络学习前述四种复杂关系图的潜在表征. 实际的兵棋推演中, 下一时刻的决策及最后胜负不只跟节点间的某一类连接相关, 更多是综合汇集了当前以及历史态势的所有重要连接. 由此, 模型的第一步是对每种异构图分别进行学习, 而后将各部分图表征有机地融合, 形成代表当前时刻战场局势的态势向量, 作为后续时间序列的样本输入。

2.1 六角格通视图表征

兵棋推演过程中, 当战场的想定一旦确定, 地图属性也随之固定, 六角格之间的通视关系可以抽象成静态的同构图, 具有态势变化中唯一的不变性质. 本文利用图卷积神经网络^[33]来捕获富含空间拓扑结构以及节点属性的同构网络信息, 图 4 所示即为某一陆战想定下六角格节点之间的通视关系, 图 5 为利用 GCN 学习通视关系图中的潜在结构和内容信息, 将高维空间的信息转化为低维嵌入向量。

如图 5 所示, 输入层接收包含特征向量的六角格节点集合, 模型通过两层卷积对节点特征进行消息传递处理, 在第一层卷积中使用中间状态局部聚合特征信息, 每个六角格不仅考虑自身的属性, 同时加权聚合其一阶近邻的特征, 权重由邻接矩阵和度矩阵共同决定, 经过非线性激活函数对其转换后传入下一层卷积, 如式 (1) 所示. 由此每个节点的更新反映了周围环境的综合影响。

$$H_m^{(l+1)} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H_m^{(l)} W^{(l)} \right) \quad (1)$$




图 4 通视同构图

Fig.4 Intervisibility homogenous graph

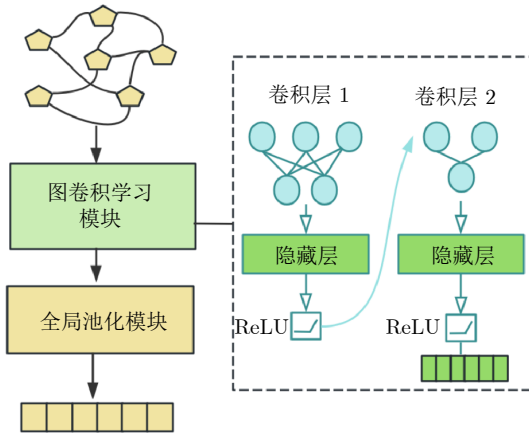


图 5 基于 GCN 的通视关系表征学习模块

Fig.5 GCN-based intervisibility relation representation learning module

$$H_{map} = \frac{1}{N} \sum_{i=1}^N H_{mi} \quad (2)$$

其中, $H_m^{(l+1)}$ 表示节点在第 $l+1$ 层的表征向量. 当网络层数 $l=0$ 时, $H_m^{(0)}$ 初始化为节点的特征矩阵 X , \tilde{A} 是添加自环的邻接矩阵, \tilde{D} 是经过归一化的度矩阵, 权重矩阵 W 用于转换节点特征至潜在维度空间, σ 代表激活函数对图卷积层的输出进行非线性变换. 本模型使用 ReLU 激活函数, 第二个卷积层进一步对特征进行转换, 经过非线性转化后得到每个节点的图表示向量 (32 维). 为了获得全局态势, 增加全局平均池化模块, 将节点特征聚合为图级表示 $H_{map} \in \mathbf{R}^{1 \times 32}$, 如式 (2) 所示. 整个过程中, 图卷积层的作用是利用图的结构信息和节点特征来学习节点的新特征表示, 从而捕获图数据的拓扑结构和特征信息.

2.2 算子间交互图表征

1) 侦察图表征

随着战局推进, 对局双方从部署到交战阶段直

至战争结束, 算子间的侦察行为交互频率通常呈现出“稀疏-密集-稀疏”的动态变化规律, 不同时刻战场上算子数量也以不同幅度消弭, 故本文提出的模型在捕捉每帧侦察关系时, 对邻居节点采样进行消息聚合和信息传递, 减轻由不同时刻邻居数量不同引起的误差. 本文参考 GraphSage 归纳式模型^[34] 的邻居采样思想, 在侦查图中随机采样算子节点进而聚合传递得到节点图表征. 为得到全局特征, 模型使用自适应平均池化 (AdaptiveAvgPool), 根据输出大小自动调整池化窗口, 将节点特征维度聚合到特定大小 (32 维), 计算过程如式 (3) ~ 式 (5) 所示.

$$A_{si}^{(l)} = \text{Agg}^{(l)} \left(\{H_{sj}^{(l)} \mid \forall j \in S(i)\} \right) \quad (3)$$

$$H_{si}^{(l+1)} = \sigma \left(W^{(l)} \times \text{CONCAT} \left(H_{si}^{(l)}, A_{si}^{(l)} \right) \right) \quad (4)$$

$$H_{see} = \text{A_AvgPool2d}(\text{reshape}(H_{si})) \quad (5)$$

对于侦察图 $G_{see} = (V_{ops}, E_{see}, F_{ops})$, V_{ops} , E_{see} , F_{ops} 分别表示节点集合、边集合以及节点特征. 首先模型从节点 i 邻居中采样得到 $S(i)$, 即采样后的邻居集合, 使用聚合函数 Agg 聚合邻居特征信息, 记为 A_{si} , 将节点 i 在第 l 层的特征 $H_{si}^{(l)}$ 与 $A_{si}^{(l)}$ 通过 CONCAT 拼接函数组合, 通过线性变换以及激活函数来更新节点 i 的特征, 接着使用 reshape 函数调整每个节点特征的维度, 最后利用自适应池化 A_AvgPool2d 获得反映全局侦察图结构和节点属性的综合特征向量 H_{see} , 侦察图表征学习模块如图 6 所示.

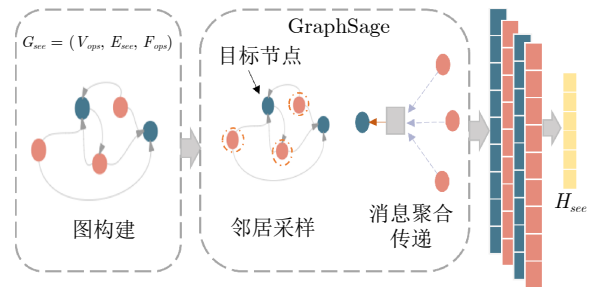


图 6 侦察图表征学习模块

Fig.6 Scout graph representation learning module

2) 打击图表征

在兵棋复盘和决策分析中, 学习算子间的打击关系对于判断战场态势和预测战局结果极其重要. 在算子打击关系图中, 除了算子本身的节点特征向量, 还包括打击连接的权重向量, 该权重描述双方交战火力的打击程度以及压制程度. 借助编/解码器的思想, 在这一模块使用两个编码器分别对节点特征及边特征编码, 将其分别转换到低维嵌入表示, 节点编码器的计算可以表示为:

$$z^{(1)} = \sigma(W_{node}^1 \times X + b_{node}^1) \quad (6)$$

$$h_{node} = \sigma(W_{node}^2 \times z^{(1)} + b_{node}^2) \quad (7)$$

其中, W_{node} , b_{node} 表示线性映射矩阵和偏置向量, h_{node} 是经过网络输出的节点表征. 模型使用两层编码器结构, 在第一层中, 输入特征 X 经过两层全连接网络, 即通过带偏置的线性变换后应用 ReLU 激活函数得到中间特征表示 $z^{(1)}$, 目的是将原始的高维特征映射到新的特征空间. 第二层结构与第一层类似, 分别使用不同的映射矩阵 W_{node}^2 与偏置向量 b_{node}^2 . 节点编码器的思想应用到边特征上, 利用 W_{edge} , b_{edge} 作为边嵌入的线性映射矩阵与偏置向量, 经过与节点嵌入 X_{node} 相同的运算后得到边的嵌入表示 h_{edge} . 在解码器阶段结合节点和边的嵌入来重构原始的节点特征, 过程表示为:

$$z_{dec}^{(1)} = \sigma(W_{dec}^1 \times (h_{node} + h_{edge}) + b_{dec}^1) \quad (8)$$

$$\hat{X}_{node} = \sigma(W_{dec}^2 \times z_{dec}^{(1)} + b_{dec}^2) \quad (9)$$

其中, W_{dec} , b_{dec} 分别为解码器的线性映射矩阵和偏置向量; \hat{X}_{node} 为图重构后的特征, 主要用于缩小训练过程中的特征表示差异, 优化模型参数, 确保编码器能够有效捕获节点和边的局部信息; 打击关系表征 $H_{attack} \in \mathbf{R}^{1 \times 32}$ 由当下时刻所有节点和边的嵌入表示进行加权求和得到, 如式 (10) 所示.

$$H_{attack} = \sum_{i=1}^n h_{node_i}^{weighted} + \sum_{j=1}^m h_{edge_j}^{weighted} \quad (10)$$

其中, $h_{node_i}^{weighted}$, $h_{edge_j}^{weighted}$ 表示加权后的节点嵌入和边嵌入. 打击表征模块如图 7 所示, 图中 W 表示运

算中的映射矩阵. 图构建部分由原始图 $G_{attack} = (V, E, W_E)$ 、节点特征矩阵 X_{node} 和边权重矩阵 X_{edge} 组成, 其中 W_E 是打击边的权重, 作为输入进入编码器-解码器模块.

2.3 算子-六角格隶属关系表征

算子在被击毁之前, 在任意时刻一定会位于地图中某一六角格中, 周围环境和所在地形影响算子当前状态. 例如, 算子若处于城镇和丛林地, 算子的隐蔽性提高而不易被敌方打击. 算子在公路、铁路上的机动速度远远大于在水域行进的速度. 由此模型单独将算子与六角格之间的隶属关系提取出来, 且某一时刻下该图为非连通异构图, 与第 2.2 节中学习打击关系模型类似, 利用编/解码器结构重构隶属图, 优化损失后得到隶属图低维空间向量表示. 使用两层编码器和解码器, 编码器分别对算子节点和六角格节点作嵌入表示, 在反向传播时, 优化均方误差损失 (Mean squared error loss, MSE), 同时利用图注意力池化层将编码器输出转化为隶属图表示, 过程如下所示.

$$\begin{cases} h_{op} = \sigma(W_{enc}^1 \times X_{op} + b_{enc}^1) \\ h_{hex} = \sigma(W_{enc}^2 \times X_{hex} + b_{enc}^2) \end{cases} \quad (11)$$

$$\begin{cases} \hat{X}_{op} = W_{dec}^1 \times h_{op} + b_{dec}^1 \\ \hat{X}_{hex} = W_{dec}^2 \times h_{hex} + b_{dec}^2 \end{cases} \quad (12)$$

其中, W_{enc} , b_{enc} 表示编码器使用的映射矩阵与偏置向量, X_{op} , X_{hex} 分别为算子和六角格的原始特征, \hat{X}_{op} , \hat{X}_{hex} 分别为算子和六角格重构后的特征. 再利用损失函数 L_{total} 减小重构特征和原始特征差

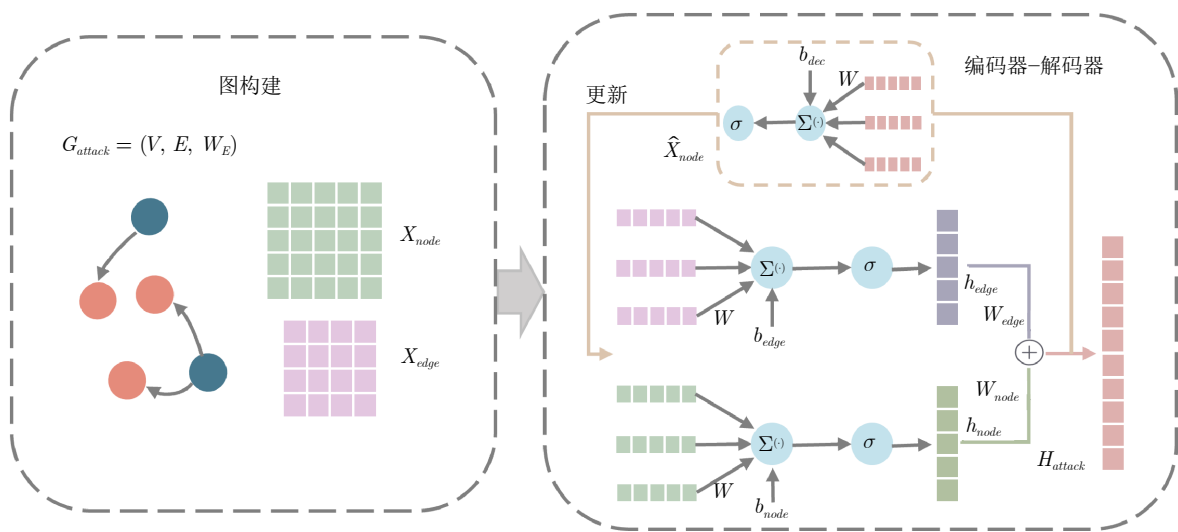


图 7 打击图表征编/解码器模块

Fig. 7 Encoder/decoder module of attack graph representation

异,使得输出的信息更加准确,重构损失包括算子和六角格两部分 (L_{op} 和 L_{hex}),通过权重因子 λ_1, λ_2 有机结合,用于控制不同部分的影响程度,如式 (13) 所示.

$$\begin{cases} L_{op} = \frac{1}{n} \sum_{i=1}^n (\hat{X}_{op}^i - X_{op}^i)^2 \\ L_{hex} = \frac{1}{m} \sum_{j=1}^m (\hat{X}_{hex}^j - X_{hex}^j)^2 \\ L_{total} = \lambda_1 L_{op} + \lambda_2 L_{hex} \end{cases} \quad (13)$$

为了区分异构图中的不同节点类型,进一步捕获全局图信息,这里使用图注意力池化层计算两种节点表征的注意力权重,加权聚合后得到隶属图的最终表示,计算过程如下.

$$Att = h_{op} \times h_{hex}^T \quad (14)$$

$$S_{op}^i = \frac{e^{A_i}}{\sum_{k=1}^n e^{A_{ik}}}, S_{hex}^j = \frac{e^{A_j^T}}{\sum_{k=1}^m e^{A_{jk}^T}} \quad (15)$$

$$H_{stay} = \text{Linear}(S_{op}^T \times h_{op}) \parallel \text{Linear}(S_{hex}^T \times h_{hex}) \quad (16)$$

首先利用编码后的两种特征值计算注意力得分矩阵 Att , 分别计算算子对于六角格以及六角格对于算子之间的注意力分布 S_{op} 和 S_{hex} , 加权后求和得到对应的池化表征, 经过线性转换 $\text{Linear}(\cdot)$ 和拼接后得到隶属图表征 H_{stay} .

2.4 图融合模块

不同类型关系往往反映战场上不同的复杂交互,单独考虑这些关系会限制解读战场态势.因此,模型在图表征的最后阶段将学习到的四种图表示 [$H_{map}, H_{see}, H_{attack}, H_{stay}$] 通过一个融合层形成统一的表示,作为兵棋动态演化模式分析的基础,这里使用多头自注意力机制捕捉关系之间的关联性,增强模型的表达能力.首先将四种表示堆叠成矩阵 $H \in \mathbf{R}^{4 \times 32}$, 利用注意力层进行融合,如式 (17) 所示, $A \in \mathbf{R}^{n \times d}$ 为注意力层的输出,利用线性转换将维度对齐,再沿着序列长度的维度聚合得到 $Output_{sum}$ 即为最终的融合表示,用于表征当前时刻下的态势.

$$\begin{cases} A = \text{softmax} \left(\frac{H \times H^T}{\sqrt{d}} \right) H \\ Output_i \in \mathbf{R}^{n \times d} = \text{Linear}(A) \\ Output_{sum} \in \mathbf{R}^d = \sum_{i=1}^n Output_i \end{cases} \quad (17)$$

3 时序依赖与预测

兵棋推演是一个动态过程,胜负的关键决策往往蕴含在这一动态演变中,而不仅仅依赖于单一时刻的静态表征.为了捕捉这种动态性,本文提出的模型使用时间序列分析方法,从宏观角度提取时间步之间的依赖关系,建立层次化表征分析,以更准确地反映推演过程中的动态态势.

具体而言,由于 Transformer 模型^[35] 的自注意力机制能够同时关注多个时间步的数据,在捕捉长依赖关系方面表现出卓越的性能,因此本文通过其自注意力机制和编/解码器结构对兵棋态势的长距离时间序列进行建模,最终获得包含序列数据相互依赖信息的时间序列表征.图 8 展示了兵棋动态演化模式表征学习的整体过程.

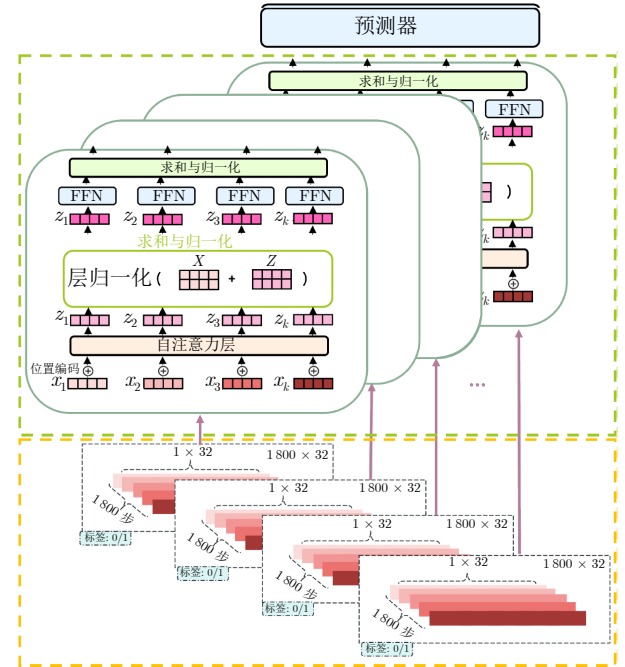


图 8 动态演化模式学习框架

Fig. 8 Dynamic evolution pattern learning framework

对任意比赛样本,通过图嵌入学习已经获得融合表征 [$Output_{sum1}, Output_{sum2}, \dots, Output_{sumk}$], 其中 k 表示帧数.作为 Transformer 模块的序列输入,即对于每个比赛样本而言,通过图嵌入学习后生成的包含兵棋不同时刻态势信息的时序特征序列 $\{x_1, x_2, \dots, x_k\}$, 反映不同时刻的空间和交互特性.将其与位置编码相加后得到嵌入向量,使得序列中每个元素能够表达元素位置的时序信息.

首先对输入序列进行线性变换,将其映射到新的嵌入空间,如式 (18) 所示.其中, E' 表示融合表征,即 [$Output_{sum1}, Output_{sum2}, \dots, Output_{sumk}$],

W_{embed} , b_{embed} 为线性映射的权重矩阵和偏置向量.

$$X = E'W_{embed} + b_{embed} \quad (18)$$

接着, 为标记输入序列中的时序信息, 使得模型能够捕捉到各个时间步中的位置信息, 引入位置编码来提供时序信息, 即将位置向量 P 添加到嵌入向量 X 中. 位置编码采用正弦余弦函数生成, 其定义如下所示.

$$P_{(pos, 2i)} = \sin\left(\frac{pos}{10\,000^{\frac{2i}{d_{model}}}}\right) \quad (19)$$

$$P_{(pos, 2i+1)} = \cos\left(\frac{pos}{10\,000^{\frac{2i}{d_{model}}}}\right) \quad (20)$$

$$X' = X + P \quad (21)$$

其中, $P_{(pos, 2i)}$, $P_{(pos, 2i+1)}$ 分别为偶数与奇数位置编码, pos 表示位置索引, d_{model} 为嵌入向量的维度, i 为维度索引, X' 即为带有位置信息的嵌入向量. 这种编码方式使得模型能够学习到不同时间步之间的相对顺序以及全局时间依赖结构.

在自注意力层, 计算每个元素对其他元素的影响权重, 计算加权和得到注意力层的输出, 如式 (22) 所示, 其中 Q , K , V 是输入 X' 经过不同线性变换得到的矩阵. 通过对不同时间步之间的注意力权重进行动态学习, 模型能够聚焦对战局结果更为重要的时刻. 在式 (22) 中, softmax 用于对注意力权重进行归一化处理, 将相似性分数转化为归一化后的权重分布, 确保每个时间步的权重总和为 1, 使得模型可以自动调节在多个时间步之间的关注度. $\sqrt{d_k}$ 是缩放因子, 使得 softmax 函数的梯度更加稳定.

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (22)$$

注意力层输出向量 $\{z_1, z_2, \dots, z_k\}$ 经过残差连接和层归一化 LayerNorm 后得到 Z_1 表征, 再通过一个简单的全连接前馈网络将输出向量作线性变换生成 Z_2 表征, 这有助于避免在深层网络中的梯度消失问题, 如式 (23)、式 (24) 所示.

$$Z_1 = \text{LayerNorm}(X' + \text{Attention}(Q, K, V)) \quad (23)$$

$$Z_2 = \text{LayerNorm}(Z_1 + \text{FFN}(Z_1)) \quad (24)$$

其中, $\text{Attention}(\cdot)$, $\text{FFN}(\cdot)$ 分别表示自注意力和全连接前馈网络. 为了得到固定大小的序列表示, 模型进一步采用池化操作对时间维度进行平均, 将整个序列的信息压缩到一个特定维度的向量中, 该向量综合推演过程中每一帧算子与环境之间的交互图特征以及全局的态势演变趋势特征, 池化后的向量

作为预测器的输入, 用于后续的预测任务. 同时模型通过均方根误差损失函数来反向传播优化表征.

4 实验

4.1 实验设置

本文基于中国科学院自动化研究所开放的 2021 年“庙算·智胜”兵棋战局 108 场比赛复盘数据进行实验, 对战局最终胜负进行预测, 并基于预测结果利用注意力机制捕捉战局推演过程中的重要决策时刻, 进一步挖掘出影响兵棋决胜的关键因素.

在 108 场比赛的复盘数据中, 每场比赛抽取 1800 帧的态势数据, 共处理 108×1800 个全局态势表征图, 每个表征图包括当前时刻六角格通视图、算子之间侦察图、打击图、算子与六角格隶属关系图的综合. 在算子与算子关系图中, 由于兵力编成的限制, 最多有 14 个算子节点, 提取的六角格节点属性如表 1 所示. 同时, 对于算子节点, 提取原始特征数 53 列, 使用 One-Hot 编码器对算子类型、装甲类型等离散分类特征进一步编码, 对连续型特征使用最大最小归一化. 处理后的特征包含 72 列, 表 2 展示了提取的部分算子节点属性. 其中, 本实验随机选择 80% 的数据集样本作训练集, 20% 的样本作测试集. 由于构建的关系图在 0 ~ 1800 时刻内是动态变化的, 可能在某一时刻由于算子被消灭, 态势图

表 1 六角格节点属性
Table 1 Features of hexagonal lattice node

| 参数名 | 数据类型 | 说明 |
|-----------|------|---------|
| pos | 整型 | 4 位整数坐标 |
| elev | 整型 | 高程 |
| node_id | 整型 | ID |
| cond | 整型 | 地形 |
| can_hide | 整型 | 是否可掩蔽 |
| has_road | 整型 | 有无道路 |
| has_river | 整型 | 有无河流 |

表 2 算子节点属性
Table 2 Features of operator node

| 参数名 | 数据类型 | 说明 |
|-------------|------|--------|
| op_id | 整型 | 算子 ID |
| color | 整型 | 算子阵营 |
| type | 整型 | 算子类型 |
| sub_type | 整型 | 算子细分类型 |
| basic_speed | 整型 | 基础速度 |
| armor | 整型 | 装甲类型 |
| speed | 整型 | 当前机动速度 |

结构也随之改变,但当前时刻下的表征图至少存在一个静态地图节点关系,其他不存在的图表征采用零填充处理.

本文使用 Pytorch 框架完成上述实验,设置图表征建模的融合表示维度为 16、32、64、128、256,学习率 (Learning rate, LR) 设置为 0.001、0.005、0.01、0.05,激活函数采用 ReLU、tanh、sigmoid,训练的批量 batch 以及迭代次数 epoch 作为敏感性因子,在优化模型的损失上实验采用 Adam 优化器. 本文实验方法包括两个阶段: 时间序列表征学习 (TSL) 阶段和预测器 (Predictor) 阶段. WarGraph 在 TSL 和 Predictor 阶段,选择 Transformer 作为骨干网络,因为其在处理序列数据上有显著的性能优势,能有效捕捉长距离依赖关系. 作为对比算法,本文选择 LSTM 和 Encoder/Decoder 结构,并在这些模型中加入自注意力机制 (分别用 LSA 和 ESA 表示),以获得更好的时序表征. 在 Predictor 阶段使用 CNN 和 MLP 网络进行对比,Transformer、LSTM、CNN 等方法在处理时序数据和预测分析的主流方法,通过此设计以评估不同模型在时序预测任务中的表现,不仅能够验证本文方法的性能优势,还能在不同算法之间进行全面比较,确保结果的可靠性和普适性. 由此,实验采用的对比模型分为八组,分别是 Trans-CNN、Trans-MLP、LSA-Trans、LSA-CNN、LSA-MLP、ESA-Trans、ESA-CNN、ESA-MLP,总共进行 162 组对比实验,并使用分类指标 Accuracy 作为准确性评估指标.

4.2 实验结果

表 3 为 epoch 在 20、40、60,学习率 LR 设置为 0.01、0.005 下不同对比设置的实验结果,其中最优结果加粗显示. 可以看到,无论 epoch 取何值,当模型采用 Transformer 作为时间序列学习器和分类器的情况下,实验结果往往比利用 LSTM 和 Encoder/Decoder 的结果更优. 特别地,在迭代次数处于 40 或 60 时,本文提出的模型预测准确率高达 90.91%,比相同迭代次数 (epoch = 60) 下的其他模型准确率高约 9.09%,说明兵棋战局推进过程中,同时捕获长距离依赖和短距离依赖有助于分析战局的胜负决策. LSTM 加自注意力机制的预测结果整体上比简单的编/解码器堆叠结果更好,原因可能在于 LSTM 也能捕捉到一段时间范围内的兵棋态势之间的依赖关系,能够学习到一部分决策知识. 在预测器部分,不同的网络对结果的影响程度较小,即,在获得预测样本表示向量的基础上,结合二分类标签做监督学习任务,所采用的不同对比方法都能取得较为良好的分类结果.

表 3 不同 LR 和 epoch 下的对比实验结果 (%)
Table 3 Comparative experimental results under different LR and epoch settings (%)

| LR | 模型 | Accuracy (epoch = 20) | Accuracy (epoch = 40) | Accuracy (epoch = 60) |
|-------|-----------|--------------------------|--------------------------|--------------------------|
| 0.01 | WarGraph | 81.82 | 86.36 | 90.91 |
| | Trans-CNN | 54.55 | 77.27 | 72.73 |
| | Trans-MLP | 45.45 | 81.82 | 81.82 |
| | LSA-Trans | 72.73 | 68.18 | 77.27 |
| | LSA-CNN | 81.82 | 77.27 | 63.64 |
| | LSA-MLP | 36.36 | 81.82 | 81.82 |
| | ESA-Trans | 68.18 | 54.55 | 50.00 |
| | ESA-CNN | 50.00 | 63.64 | 63.64 |
| 0.005 | WarGraph | 81.82 | 90.91 | 86.36 |
| | Trans-CNN | 77.28 | 81.82 | 72.73 |
| | Trans-MLP | 68.18 | 81.82 | 81.82 |
| | LSA-Trans | 68.18 | 77.27 | 81.82 |
| | LSA-CNN | 63.64 | 81.82 | 77.27 |
| | LSA-MLP | 54.54 | 81.82 | 81.82 |
| | ESA-Trans | 54.54 | 40.90 | 45.45 |
| | ESA-CNN | 63.64 | 54.55 | 63.64 |
| | ESA-MLP | 36.36 | 50.00 | 54.55 |

4.3 可解释分析

根据注意力机制的特性学习动态变化的注意力权重,可以捕捉到不同时刻战局双方实施的关键行为. 对所使用的 108 个样本的 0 ~ 1800 帧得到注意力权重. 如图 9 所示,随机选取 30 场比赛,将其中 1800 时间步按照 25 步为单元段进行分段可视化. 注意力权重由浅入深表示权重由小到大,在所有样本中可以看出,比赛前期显现很稀疏的决策行为在比赛中后段更为密集,有部分比赛显示出比较均匀的权重变化,大部分比赛的重要决策时刻呈现紧凑-稀疏-紧凑的布局,反映了战场的实际推进规律.

这里选择四场比赛对模型进一步分析,图 10 为随机选取的 4 场比赛在 1 ~ 1800 时间步中关键时刻热力图. 可以看出,在战局推演过程中,每场比赛影响决胜的关键行为基本分布在战局中期和接近 1300 步的时候,此外所有决策行为在战局中的影响程度在热力分布图中以不同颜色展示,但分析其中影响决胜最为重要的决策时刻对于兵棋复盘和指导更具实际意义,因此此处选择前 K 个关键时刻回到战局本身进一步分析. 当 K = 10 时,以上提到的四场比赛关键时刻如图 11 所示. 结果展示出比赛在 300 ~ 500 步的时候战局从平稳推进到关键交锋期,对于比赛 un7vxMJg 来说,关键时刻主要集中在前半段,特别是在 400 ~ 1000 步之间,可能意

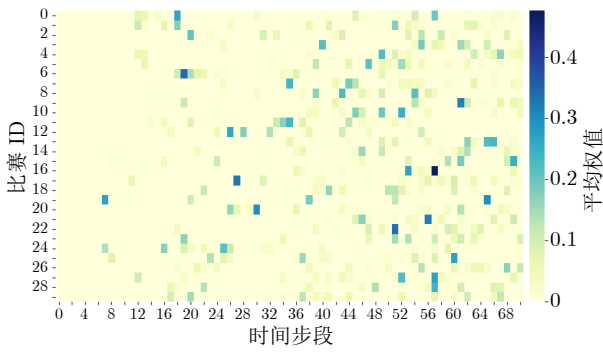


图 9 部分比赛关键时刻权重分布

Fig.9 Weight distribution at critical moments of partial wargames




图 10 四场比赛对应的注意力权重

Fig.10 Attention weights corresponding to four matches




图 11 关键时刻趋势图

Fig.11 Trend chart at critical moments

意味着在推演初期, 双方进行了频繁的战或策略调整, 双方争夺关键夺控点或者资源. 随后关键时刻的密度减小, 表明战局局势趋于稳定. 而对于比赛 UjQ-PL2Tt, 其关键时刻分布较为分散, 在 468 ~ 1266 时间步之间, 对战双方经过很长一段时间的拉锯僵持状态, 才进入到 1200 ~ 1600 时间步之间的密集交锋时刻.

4.4 超参数敏感性

本文系统地分析多个关键超参数对模型的影响, 包括图嵌入表征的最终维度、激活函数的选取、批大小、学习率和迭代次数. 通过设置不同范围的

超参数并结合可视化结果,进一步对模型性能进行参数优化,通过控制变量的方法进行多组实验,表 4 列出了所选择的超参数以及选取的范围,图 12、图 13 展示了在不同超参数下模型能获得的较优准确率。

表 4 超参数选择
Table 4 Selection of hyperparameters

| 超参数 | 选取范围 |
|---------|--------------------------|
| 图融合表征维度 | 16, 32, 64, 128, 256 |
| 激活函数 | ReLU, sigmoid, tanh |
| 批大小 | 8, 16, 32 |
| 学习率 | 0.001, 0.005, 0.01, 0.05 |
| 迭代次数 | 10, 20, 30, 40, 50, 60 |




图 12 图嵌入维度及迭代次数敏感性
Fig.12 Graph embedding dimensionality and epoch sensitivity




图 13 激活函数-批大小-学习率敏感性
Fig.13 Activate function-batch-LR sensitivity

可以看出,当图融合表征维度为 64 时,最终预测准确率相比较更优,当维度更高时,表征蕴含的图信息更加丰富,对于二分类预测有良好的指示作用.迭代次数的不同范围对应的模型性能呈现一定波动,在 20~50 的迭代次数下能够收敛到全局最优。

图 13 中在时间序列捕获全局信息时使用的不同激活函数对整体结果影响不明显,批大小呈现出振荡状态,原因可能与数据样本容量小有关联,相

比较选取的多个学习率,当 $LR = 0.01$ 时,模型往往呈现出更好的结果。

4.5 消融实验

本节进一步通过消融实验来证明所提出模型的每个关键模块对预测结果的作用,不同迭代次数下的可视化结果如图 14 所示.具体来讲,本文设计了三个变体:

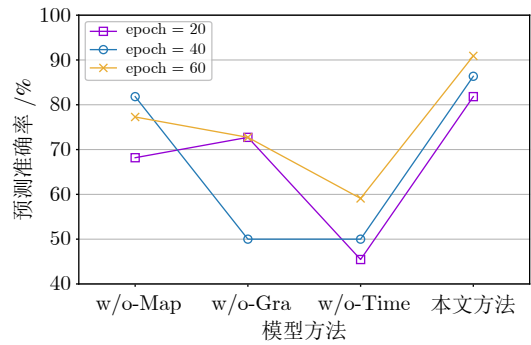


图 14 不同 epoch 下各模型变体性能
Fig.14 Model variants performance under different epochs

1) 去除静态地图表征模块 (w/o-Map). 在态势建模部分,取消图融合模块中地图的表征,只综合考虑战局中机动算子的交互关系(动态表征),结果整体相比于其他模型变体对实验影响程度略小,但综合性能比提出的模型下降约 4%~8%。

2) 去除全局图表征学习模块 (w/o-Gra). 使用取平均的方法对每一帧下所有算子节点的属性(作为当前态势)进行聚合,与地图属性进行拼接,将最终维度压缩形成当前帧的态势表征,作为时序学习的输入.从图中可看出,当 epoch = 40 时, w/o-Gra 性能陡然下降,说明图建模方法对兵棋复杂态势的表征有重要意义。

3) 去除时间序列学习模块 (w/o-Time). 在获得图建模的输出融合表征后,将每场比赛的 1800 个带有时序意义的表征做平均池化得到预测器的输入.整体而言 w/o-Time 在所有模型变体中对性能影响最大,物理意义上兵棋的推演本身具有时空特点,说明从静态角度去捕捉战场局势往往是不够的。

5 结束语

本文提出一种新颖的基于异构图神经网络的兵棋复杂态势建模方法,并有效结合动态推演变化模式,对兵棋胜负进行预测,进一步解释分析影响决胜的重要时刻因素,旨在应对现代兵棋模拟中态势表达复杂性和模型可解释性不足的问题.通过结合

多关系图建模、时序分析和预测解释三大模块, 准确捕捉战场中的复杂交互关系, 并在兵棋推演中实现高准确率的态势预测。

除了在人-人对抗复盘数据集上的实验结果外, WarGraph 具备在其他类型战场推演中应用的潜力。由于不同战场环境的数据集在结构和特征上具有较强的共性, 通常由战场状态和态势数据构成, 并采用统一的数据格式和接口规范, 因此模型在不同场景中的扩展性和适用性具有理论基础。在未来工作中, 将进一步研究模型的可解释性和可扩展性, 以提升其在实际应用中的效果。

References

- Mittal V, Davidson A. Combining wargaming with modeling and simulation to project future military technology requirements. *IEEE Transactions on Engineering Management*, 2020, **68**(4): 1195-1207
- Ouriques L, Barbosa C E, Xexéo G. Understanding military collaboration in wargames. In: Proceedings of the 26th International Conference on Computer Supported Cooperative Work in Design (CSCWD). Piscataway, USA: IEEE, 2023. 1920-1925
- Li L, Yang R, Li H, Lv M, Yue L, Wu A. Unsupervised contrastive learning for automatic grouping of aerial swarms. *IEEE Transactions on Vehicular Technology*, 2024, **73**(5): 6249-6258
- Rosen A M, Kerr L. Wargaming for learning: How educational gaming supports student learning and perspectives. *Journal of Political Science Education*, 2024, **20**(2): 318-335
- Yao Chang-Hua, Bi Shan-Ning, Ma Ru-Fei, Yu Xiao-Han, Li Jia-Qiang, Chen Jin-Li. Method for dynamic coalition formation of wargame agent for force cooperation. *Journal of System Simulation*. DOI: 10.16182/j.issn1004731x.joss.24-0058 (姚昌华, 毕珊宁, 马茹飞, 余晓峰, 李家强, 陈金立. 兵棋智能体兵力协同动态联盟形成方法. 系统仿真学报, DOI: 10.16182/j.issn1004731x.joss.24-0058)
- Hu Xiao-Feng, Qi Da-Wei. Intelligent wargaming system: Change needed by next generation need to be changed. *Journal of System Simulation*, 2021, **33**(9): 1997-2009 (胡晓峰, 齐大伟. 智能化兵棋系统: 下一代需要改变的是什么. 系统仿真学报, 2021, **33**(9): 1997-2009)
- Hu Xiao-Feng, He Xiao-Yuan, Tao Jiu-Yang. AlphaGo's breakthrough and challenges of wargaming. *Science & Technology Review*, 2017, **35**(21): 49-60 (胡晓峰, 贺筱媛, 陶九阳. AlphaGo 的突破与兵棋推演的挑战. 科技导报, 2017, **35**(21): 49-60)
- Cao Zhan-Guang, Tao Shuai, Hu Xiao-Feng, He Lv-Long. Research progress of wargaming simulation methods and system abroad. *Journal of System Simulation*, 2021, **33**(9): 2059-2065 (曹占广, 陶帅, 胡晓峰, 何吕龙. 国外兵棋推演及系统研究进展. 系统仿真学报, 2021, **33**(9): 2059-2065)
- Wu Lin, Hu Xiao-Feng, Tao Jiu-Yang, He Xiao-Yuan. Wargaming eco-system for intelligence growing. *Journal of System Simulation*, 2021, **33**(9): 2048-2058 (吴琳, 胡晓峰, 陶九阳, 贺筱媛. 面向智能成长的兵棋推演生态系统. 系统仿真学报, 2021, **33**(9): 2048-2058)
- Liu Hai-Yang, Tang Yu-Bo, Hu Xiao-Feng, Qiao Guang-Peng. Research on evaluation framework of COA based on wargaming. *Journal of System Simulation*, 2018, **30**(11): 4115-4123 (刘海洋, 唐宇波, 胡晓峰, 乔广鹏. 基于兵棋推演的联合作战方案评估框架研究. 系统仿真学报, 2018, **30**(11): 4115-4123)
- Liu Hai-Yang, Tang Yu-Bo, Hu Xiao-Feng, Liu Rong-Xiang, Cui Wen-Hua. Wargaming experiment oriented evaluation of joint operations. *Journal of Command and Control*, 2018, **4**(4): 272-280 (刘海洋, 唐宇波, 胡晓峰, 刘戎翔, 崔文华. 面向联合作战评估的兵棋推演实验研究. 指挥与控制学报, 2018, **4**(4): 272-280)
- Xing Si-Yuan, Ni Wan-Cheng, Zhang Hai-Dong, Yan Ke. Mining of weapon utility based on the replay data of war-game. *Journal of Command and Control*, 2020, **6**(2): 132-140 (邢思远, 倪晚成, 张海东, 闫科. 基于兵棋复盘数据的武器效用挖掘. 指挥与控制学报, 2020, **6**(2): 132-140)
- Yin Qi-Yue, Zhao Mei-Jing, Ni Wan-Cheng, Zhang Jun-Ge, Huang Kai-Qi. Intelligent decision making technology and challenge of wargame. *Acta Automatica Sinica*, 2023, **49**(5): 913-928 (尹奇跃, 赵美静, 倪晚成, 张俊格, 黄凯奇. 兵棋推演的智能决策技术与挑战. 自动化学报, 2023, **49**(5): 913-928)
- Chen L, Zhang Y, Feng Y, Zhang L, Liu Z. A human-machine agent based on active reinforcement learning for target classification in wargame. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, **35**(7): 9858-9870
- Zhou Lei, Yin Qi-Yue, Huang Kai-Qi. Game-theoretic learning in human-computer gaming. *Chinese Journal of Computers*, 2022, **45**(9): 1859-1876 (周雷, 尹奇跃, 黄凯奇. 人机对抗中的博弈学习方法. 计算机学报, 2022, **45**(9): 1859-1876)
- Sun Y, Yuan B, Xiang Q, Zhou J, Yu J, Dai D, et al. Intelligent decision-making and human language communication based on deep reinforcement learning in a wargame environment. *IEEE Transactions on Human-machine Systems*, 2022, **53**(1): 201-214
- Liu Man, Zhang Hong-Jun, Cheng Kai, Hao Wen-Ning, Wang Zhi-Teng. Framework design and application for tactical-level wargame behavior decision-making based on complementary knowledge and data. *Journal of Command and Control*, 2023, **9**(2): 182-191 (刘满, 张宏军, 程恺, 郝文宁, 王之腾. 知识与数据互补的战术级兵棋行为决策框架设计与实现. 指挥与控制学报, 2023, **9**(2): 182-191)
- Xue Y, Sun Y, Zhou J, Peng L, Zhou X. Multiattribute decision-making in wargames leveraging the entropy-weight method in conjunction with deep reinforcement learning. *IEEE Transactions on Games*, 2024, **16**(1): 151-161
- Xu Xiao, Li Dong, Guo Sheng-Ming, Wu Lin, Hu Xiao-Feng. An intelligent decision-making modeling architecture for joint operation-oriented wargaming. *Journal of Command and Control*, 2023, **9**(4): 449-456 (许霄, 李东, 郭圣明, 吴琳, 胡晓峰. 面向联合作战兵棋推演的智能决策建模框架. 指挥与控制学报, 2023, **9**(4): 449-456)
- Chen L, Liang X, Feng Y, Zhang L, Yang J, Liu Z. Online intention recognition with incomplete information based on a weighted contrastive predictive coding model in wargame. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, **34**(10): 7515-7528
- Sun D, Qi S. Relation extraction on the wargame based on pre-trained models. In: Proceedings of the 9th International Conference on Dependable Systems and Their Applications (DSA). Urumchi, China: IEEE, 2022. 941-944
- Liu X, Zhao M, Dai S, Yin Q, Ni W. Tactical intention recognition in wargame. In: Proceedings of the 6th International Conference on Computer and Communication Systems (ICCCS). Chengdu, China: IEEE, 2021. 429-434
- Sun Yu-Xiang, Zhao Jun-Jie, Xie Yu-Xuan, Yu Che-Cheng, Zhou Xian-Zhong. Self generated wargame AI: Double layer agent task planning based on large language mode. *Control and Decision*, 2024, **39**(12): 3927-3936 (孙宇祥, 赵俊杰, 解宇轩, 喻车澄, 周献中. 自生成兵棋 AI: 基于大语言模型的双层 Agent 任务规划. 控制与决策, 2024, **39**(12): 3927-3936)
- Dong L, Li N, Yuan H, Gong G. Accelerating wargaming reinforcement learning by dynamic multi-demonstrator ensemble. *Information Sciences*, 2023, **648**: Article No. 119534
- Sun Y, Sun Y, Yu J, Li Y, Zhou X. Predicting wargame outcomes and evaluating player performance from an integrated strategic and operational perspective. *IEEE Transactions on Games*, 2024, **16**(4): 770-782

- 26 Ma R, Liu S, Xu Z, Zhang Y, Ni Y. Research on fuzzy dynamic route choice model and algorithm of wargame. *International Journal of Machine Learning and Cybernetics*, 2024, **15**: 2863–2880
- 27 Wang T, Dai S, Liu X, Zhao M, Zhang H, Yin Q. MFSCD* lite: A situation-based path planning algorithm for agent in wargame. In: Proceedings of the 6th International Symposium on Computer Science and Intelligent Control (ISCSIC). Beijing, China: IEEE, 2022. 244–249
- 28 Jensen B, Valeriano B, Whitt S. How cyber operations can reduce escalation pressures: Evidence from an experimental wargame study. *Journal of Peace Research*, 2024, **61**(1): 119–133
- 29 Huang Hong-Yuan. A brief discussion on the development and military applications of wargaming systems. *Defence Industry Conversion in China*, 2022(16): 53–55
(黄洪原. 浅议兵棋系统的发展及军事运用. 中国军转民, 2022(16): 53–55)
- 30 Zhang Da-Yong, Yang Jing-Yu, Ma Jun, Song Chen-Ye. Construction of machine learning data set for the analysis of the replay of the wargaming. *Journal of System Simulation*, 2024, **36**(3): 608–624
(张大水, 杨镜宇, 马骏, 宋晨烨. 面向兵棋推演复盘分析的机器学习数据集构建. 系统仿真学报, 2024, **36**(3): 608–624)
- 31 Yu Xiao-Han, Wang Qi-Di, Yu Kun. A wargame situation prediction method based on a graph neural network GraphVAE. *Command Control & Simulation*, 2023, **45**(5): 129–136
(余晓晗, 王启迪, 于坤. 基于图神经网络 GraphVAE 的兵棋态势预测方法. 指挥控制与仿真, 2023, **45**(5): 129–136)
- 32 Chen Jin-Yang, Hao Wen-Ning, Jin Da-Wei, Chen Gang, Yu Xiao-Han. Research on the prediction method of wargame confrontation situation based on attention mechanism. *Fire Control & Command Control*, 2023, **48**(3): 18–24
(陈锦阳, 郝文宁, 靳大尉, 陈刚, 余晓晗. 基于注意力机制的兵棋对抗态势预测方法. 火力与指挥控制, 2023, **48**(3): 18–24)
- 33 Kipf T, Welling M. Semi-supervised classification with graph convolutional networks. arXiv preprint arXiv: 1609.02907, 2016.
- 34 Hamilton W L, Ying R, Leskovec J. Inductive representation learning on large graphs. In: Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc., 2017. 1025–1035
- 35 Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N, et al. Attention is all you need. In: Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc., 2017. 6000–6010



陈 露 重庆大学计算机学院硕士研究生. 主要研究方向为数据挖掘.
E-mail: percy_cl@foxmail.com
(**CHEN Lu** Master student at the College of Computer Science, Chongqing University. Her main research interest is data mining.)



尚家兴 重庆大学计算机学院教授. 主要研究方向为数据挖掘, 行业大数据分析 and 可解释人工智能. 本文通信作者. E-mail: shangjx@cqu.edu.cn
(**SHANG Jia-Xing** Professor at the College of Computer Science, Chongqing University. His research interest covers data mining, industrial big data analytics, and explainable artificial intelligence. Corresponding author of this paper.)



刘大江 重庆大学计算机学院副教授. 主要研究方向为可重构计算, 编译优化. E-mail: liudj@cqu.edu.cn
(**LIU Da-Jiang** Associate professor at the College of Computer Science, Chongqing University. His research interest covers reconfigurable computing and compiler optimization.)



张玉芳 重庆大学计算机学院教授. 主要研究方向为数据挖掘, 集群系统和计算机网络.
E-mail: zhangyf@cqu.edu.cn
(**ZHANG Yu-Fang** Professor at the College of Computer Science, Chongqing University. Her research interest covers data mining, cluster systems, and computer networks.)



倪晚成 中国科学院自动化研究所研究员. 主要研究方向为数据挖掘与知识发现, 复杂系统建模, 群体智能博弈决策平台与评估.
E-mail: wancheng.ni@ia.ac.cn
(**NI Wan-Cheng** Researcher at the Institute of Automation, Chinese Academy of Sciences. Her research interest covers data mining and knowledge discovery, complex system modeling, and platform and evaluation of swarm intelligence gaming and decision making.)