

DOI:10.19651/j.cnki.emt.2520294

# 基于时空图注意力网络的空中编队意图识别

牛景琦 杨风暴 王肖霞

(中北大学信息与通信工程学院 太原 030051)

**摘要:** 针对现有意图识别方法未考虑编队空间特性所导致的单元间动态交互缺失的问题,本文引入时空耦合机制,提出了一种结合动态图注意力机制与时空建模的编队意图识别方法。首先,依据编队中目标类型属性确定全局交互骨干网,并结合 Top-K 近邻策略动态生成邻接矩阵,从而将动态演化的编队态势转化为结构化的时序图;其次,通过在图注意力网络(GAT)中引入协同演化注意力池机制,自适应地学习不同目标间交互的差异化权重,以快速捕捉动态编队时序图中空间协同特征;最后,通过多尺度注意力机制增强的双向门控循环单元(BiGRU),对经 GAT 提取的包含空间协同信息的节点状态序列进行时序分析,建立了一种时空特征深度融合的意图识别模型(STGAT-BiGRU)。仿真实验结果表明,所提方法与现有主流方法相比,在准确率和 F1 分数上平均提升了 8.78% 和 8.9%,证明了所提方法的有效性,并为掌控态势演变、获取决策先机提供了技术支撑。

**关键词:** 意图识别;编队目标;时空特征建模;图注意力网络;门控循环单元

**中图分类号:** TN911.7 **文献标识码:** A **国家标准学科分类代码:** 510.4050

## Airborne formation intention recognition based on spatio-temporal graph attention network

Niu Jingqi Yang Fengbao Wang Xiaoxia

(College of Information and Communications Engineering, North University of China, Taiyuan 030051, China)

**Abstract:** To address the issue of missing dynamic interactions between units caused by existing intent recognition methods failing to account for formation spatial characteristics, this paper introduces a spatiotemporal coupling mechanism and proposes a formation intent recognition method that integrates dynamic graph attention mechanisms with spatiotemporal modeling. First, a global interaction backbone network is established based on target attributes within the formation, combined with a Top-K nearest neighbor strategy to dynamically generate an adjacency matrix. This transforms the dynamically evolving formation state into a structured temporal graph. Second, a Graph Attention Network (GAT) enhanced with a Co-evolution Aware Pooling mechanism is employed to adaptively learn differentiated interaction weights between different targets, enabling rapid capture of spatial coordination features in the dynamic formation temporal graph. Finally, a Bidirectional Gated Recurrent Unit (BiGRU) augmented with a Multi-Scale Attention mechanism is introduced to perform temporal analysis on the node state sequences extracted by GAT, which contain spatial coordination information. This establishes an intent recognition model that deeply integrates spatiotemporal features (STGAT-BiGRU). Simulation results show that, compared to existing methods, the proposed approach achieves average improvements of 8.78% and 8.9% in accuracy and F1 score, respectively, demonstrating its effectiveness and providing technical support for mastering situation evolution and gaining decision-making initiative.

**Keywords:** intent recognition; formation targeting; spatio-temporal feature modeling; graph attention network; gated recurrent unit

## 0 引言

近年来,随着传感器探测、人工智能与信息处理等技术的快速发展与广泛应用,智能化与体系化已成为态势感知

领域的重要研究方向<sup>[1]</sup>。在此背景下,多智能体协同作业<sup>[2-3]</sup>模式日益普遍,对其整体行为意图的识别也成为关键研究课题。准确识别多智能体编队的行为意图,在航空领域<sup>[4]</sup>可支撑无人机机群的自主协同与航路优化;在群体行

为识别<sup>[5]</sup>场景中,可用于理解和预测团队的战术配合与协作策略;在工业自动化<sup>[6]</sup>领域,则可实现机器人集群的协同搬运装配等复杂任务,有效提升生产效能。编队并非单一对象的简单集合,而是具有高度协同性与动态演化能力的有机整体,其行为模式往往体现出较强的组织性与策略性<sup>[7]</sup>。在任务执行过程中,意图的实现往往依赖于队形变换和协同机动<sup>[8]</sup>等关键手段。因此,对编队整体意图的准确判断,远比识别单个目标意图更为复杂,也更具有理论与应用价值。

现有编队意图识别方法可以分为知识驱动和数据驱动两大类。饶佳人等<sup>[9]</sup>提出了基于规则的空中编队识别方法,通过规则方式提炼和运用空中编队知识,并实时匹配空中战场数据以快速识别目标编队。乔殿峰等<sup>[10]</sup>在贝叶斯网络的基础上,提出了基于多实体分层贝叶斯网络的群目标意图识别与预测方法,该方法在航母群的活动规律分析示例中展现了有效性。杨锐等<sup>[11]</sup>采用动态序列贝叶斯网络,构建了一个空地协同作战意图识别整体模型,用于描述空中和地面编队之间的协同行动过程,将不同战场域的事件及其相关概率关系进行融合,实现协同作战意图的识别。李泽鹏等<sup>[12]</sup>考虑集群目标的通信协同以及属性信息,将单目标的意图结果转化为各自对集群意图的支持向量,并通过 D-S 证据理论(dempster-shafer, D-S)进行集群意图融合,构建了集群目标的分层识别意图方法。上述知识驱动的意图识别方法具有较好的可解释性和高效的算法执行效率,但是该类方法往往存在先验知识不完备、获取知识较困难等问题,同时仅仅依靠现有知识难以在更大的解空间范围内实现全局搜索,相关模型无法通过不断的学习实现更新与进化。

数据驱动通过从数据中挖掘经验,自动学习编队行为与意图之间复杂的非线性映射关系。马钰棠等<sup>[13]</sup>提出了一种基于注意力机制的双向门控循环单元网络的群组意图识别方法,可以有效解决样本不平衡情况下的空中群组意图识别问题。王宇航等<sup>[14]</sup>为了解编队目标各特征之间的重要性差异,构建了结合注意力机制的长短期记忆网络模型(long short-term memory, LSTM)该网络通过注意层学习编队目标各特征的权重,以增强对编队关键信息的学习和利用。He 等<sup>[15]</sup>将编队的意图识别问题表述为时间序列特征学习问题,提出了一种基于时序卷积网络的方法,能够识别信息不完整的编队运动意图。上述数据驱动的意图识别方法简化了问题的建模,且在意图识别准确性上相对出色,但这些方法大多将编队视为一个整体或独立的时间序列集合,其改进集中于时间维度的特征学习,普遍忽视了编队内部目标间动态的空间交互与合作行为。

尽管上述方法取得了较好的意图识别效果,但均存在时空特征耦合不足的共性问题,尤其缺乏对编队单元间动态交互关系的有效建模。本质上,编队本身是一个由多个交互单元构成的时空动态系统,在时间上演化为连续的任

务执行序列,在空间上则表现为个体间的协同部署与动态构型,其拓扑结构天然适合用图模型来进行表征。近年来,图神经网络(graph neural network, GNN)及其变体在时空序列建模任务中展现出强大的潜力,为编队意图识别提供了新的解决思路。Bai 等<sup>[16]</sup>提出一种注意力时序图卷积网络(graph convolutional network, GCN)模型用于交通预测,通过自适应学习节点间关联来捕捉复杂空间依赖,但其图结构学习以全连接图为假设,在处理编队目标时会引入冗余连接并模糊关键协同关系;欧洋等<sup>[17]</sup>通过 GCN 与 LSTM 构建协同空战决策框架,利用图结构建模无人机间交互,提升了多机协同的战术决策能力,但边的构建仅依赖通信范围这一单一物理因素,忽略了执行不同任务中编队的内部组成和协调关系的差异;Zhang 等<sup>[18]</sup>提出一种意图识别时空网络(spatio-temporal network for intention recognition, STIRNet),将空中编队抽象为图结构并利用时空卷积与注意力机制识别意图,验证了时空图学习范式的可行性,但其空间特征提取采用的 GCN 本质是对邻居节点进行平等加权聚合,无法区分不同节点间交互的重要性差异;同时,时间卷积模块侧重局部模式,难以有效捕捉长期时序依赖。

图注意力网络(graph attention network, GAT)是由 Veličković 等<sup>[19]</sup>提出的一种基于注意力的节点分类网络,相较于传统的 GNN 和 GCN, GAT 摆脱了对拉普拉斯矩阵的依赖,不再平等地看待所有邻居,而是通过可学习的注意力机制,自适应地聚焦于关键交互对象。为此,本文提出了一种基于时空图注意力网络(spatio-temporal graph attention network with bidirectional gated recurrent units, STGAT-BiGRU)的意图识别方法,将编队空间结构与行为随时间演化的动态特性进行深度耦合,构建了统一的端到端时空图学习框架,主要贡献如下:

1)将动态演化的空中编队态势信息转化为时序图数据,提出一种动态图结构构建方法。通过识别并连接关键枢纽节点,构造编队的指挥控制骨干网,同时采用 Top-K 近邻策略动态建立空间连接。

2)在 GAT 中引入协同演化注意力池机制,通过融合节点对的演化趋势一致性信息来校准空间注意力权重,从而更精准地建模非对称的空间协同关系;同时,在 BiGRU 中嵌入多尺度注意力机制,实现对节点行为序列中局部机动细节与全局任务演进模式的自适应融合,从而在多层次上挖掘时序依赖关系,最终实现空间协同特征与时间演化特征的深度耦合。

3)通过系统的对比与消融实验验证了模型及各组件的有效性。实验结果表明,所提模型在识别准确率、精确率、召回率及 F1 分数上均取得了良好效果。消融实验进一步证实,本文提出的融合架构,能够更充分地挖掘数据中的关键时空信息,在处理复杂的编队动态行为方面展现出优越性能。

## 1 编队意图识别问题描述

编队意图识别旨在基于传感器观测到的时间序列数据,推断由多个协同单元组成的群体所实施的集体行为意图<sup>[20]</sup>。与单目标意图不同,编队意图强调整体性,是其内部各单元时空交互行为所呈现出的宏观行为模式。因此该问题可被形式化为一个时空图分类任务:即构建一个动态演化的群体时空图,并学习一个映射函数,将该图序列映射到最终的群体意图。

具体而言,在任一时刻 $t$ ,一个由 $N$ 个单元构成的编队可表示为一个图 $G_t = (V_t, X)$ 。其中, $V_t = (v_t^1, v_t^2, \dots, v_t^N)$ 表征了群体内各单元在 $t$ 时刻的状态属性(如位置、速度等);边集 $X$ 则是其对应的邻接矩阵,定义了单元间的空间交互关系。编队在一段时序 $T$ 内的行为可由图序列 $G = \{G_1, G_2, \dots, G_T\}$ 描述。意图识别的

目标是构建分类函数,将该序列映射到意图空间 $I = \{I_1, I_2, \dots, I_M\}$ , $M$ 为意图类别数,并输出概率最大的意图标签。

### 1.1 编队意图空间描述

已有研究从不同协同场景出发,对群体行为模式进行了划分,例如刘祥雨等<sup>[21]</sup>对编队目标的属性及任务进行了详细描述,将意图空间划分为进攻扫荡、侦察预警和干扰压制;Teng等<sup>[22]</sup>在无人机执行任务背景下,将行为意图划分为{攻击、渗透、监视、侦察、佯攻、撤退和电子干扰};苟先太等<sup>[23]</sup>通过结合群组通信事件特征与外部监测状态信息特征,建立的意图空间为侦察、进攻、防御和电子战。基于协同任务系统中群体行为模式,并参考既有研究对群体行为策略的划分,本文将编队整体的行为意图空间定义为以下6种基本类型:突进、搜索、干扰、巡逻、迂回和撤离。编队6种意图的详细描述如表1所示。

表1 编队意图空间的详细描述

Table 1 Detailed description of the formation intent space

意图	描述
突进	编队形成具有明确前进方向的密集队形(如楔形、纵队),以高速向特定目标或区域挺进。其空间特征表现为高聚合度和方向一致性,时间上表现为持续的高速接近。
搜索	编队在特定任务区域进行系统性、搜索式飞行,以获取情报。其空间特征表现为队形相对松散,覆盖范围广,时间上表现为规律性的搜索航线。
干扰	编队通过一系列非常规机动或信号辐射,旨在扰乱或欺骗外部观测系统。其空间特征表现为在特定区域内的不规则、欺骗性机动,时间上常呈现间歇性或周期性的活跃模式。
巡逻	编队在指定区域或路径上进行周期性的、例行性移动,以维持存在或持续监控。其空间特征表现为在固定路线或空域内的规律性运动,队形稳定,时间上呈现高度可预测的循环特征。
迂回	编队为规避正面障碍或风险区域,采取弧线或折线路径向目标侧翼或后方机动。其空间特征表现为整体前进方向不变,但运动轨迹呈现明显的侧向弧形规避;时间上表现为一种渐进式的、非直接的接近过程。
撤离	编队整体脱离当前任务区域,进行协同疏散。其空间特征表现为队形在移动中保持适度的松散结构,同时所有成员的速度矢量高度背离原任务区域;时间上表现为持续且协调的远离运动,整体速度通常维持在较高水平以确保效率。

### 1.2 编队意图特征分析

由于编队意图的规律性,不同的目标特征状态可以反映出不同的结果。与单目标类似,编队目标的意图特征包含数值型特征和非数值型特征。数值型特征包括经度、纬度、高度、速度、航向角、俯仰角及距离,它们可以被表示为连续的数值。非数值型特征则包括编队组成、雷达工作状态与电子干扰状态等,被表示为离散类别或状态信息。具体编队目标意图特征的分类情况如图1所示。为进一步明确各类特征的具体含义,上述11种编队目标意图特征的详细描述如表2所示。

为消除数值型特征量纲的影响,需要对数据进行 $\min\text{-max}$ 标准化处理,将不同类型特征的数据统一在同一个分布空间内。具体公式如下:

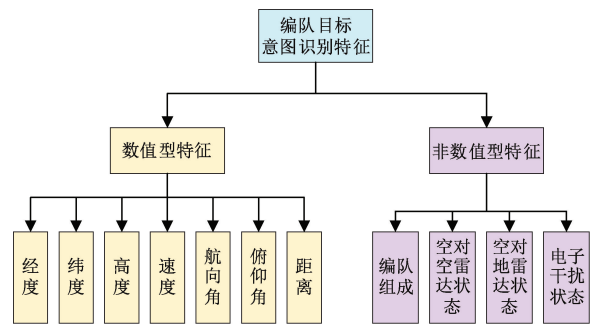


图1 编队目标的意图特征

Fig. 1 Intent characteristics of formation targets

$$x'_{ik} = \frac{x_{ik} - \min X_i}{\max X_i - \min X_i} \quad (1)$$

表 2 编队目标意图特征的详细描述

Table 2 Detailed description of formation target intent characteristics

意图特征	描述
经度/(°)	编队中目标所处位置的经度
纬度/(°)	编队中目标所处位置的纬度
高度/km	编队中目标相对海平面的飞行高度
速度/(km·h <sup>-1</sup> )	编队中目标的飞行速度
航向角/(°)	地球北极方向到编队中目标飞行方向之间的角度
俯仰角/(°)	编队中目标与海平面的夹角
距离/km	编队中目标与任务区域中心之间的距离
编队组成	编队中目标类型[战斗机(0)、侦察机(1)、电子干扰机(2)、预警机(3)、运输机(4)]
空对空雷达状态	编队中目标的空对空雷达是否开启[关闭(0)、开启(1)]
空对地雷达状态	编队中目标的空对地雷达是否开启[关闭(0)、开启(1)]
电子干扰状态	编队中目标的电子干扰装置是否开启[关闭(0)、开启(1)]

其中,  $X_i = (x_{i1}, x_{i2}, \dots, x_{im}) (i = 1, 2, \dots, 7)$  为第  $i$  种数值型数据,  $m$  为第  $i$  种特征的个数,  $\min X_i$  为某一特征  $X_i$  的最小值;  $\max X_i$  为某一特征  $X_i$  的最大值;  $x'_{ik}$  为原始数据  $x_{ik}$  映射到区间  $[0, 1]$  的数值。

为捕捉编队行为的时序演化规律, 采用滑动窗口方法从连续时序数据中提取片段, 从而获得比单时间步长更多的特征表示:

$$\mathbf{X}^{(t)} = \{\mathbf{x}^{(t)}, \mathbf{x}^{(t+1)}, \dots, \mathbf{x}^{(t+L-1)}\} \quad (2)$$

其中,  $L$  为滑窗大小,  $\mathbf{x}^{(t)}$  为在第  $t$  时刻  $N$  个目标的  $D$  维特征向量。

## 2 编队意图识别模型构建

### 2.1 基于邻接矩阵的自适应图构建

本文将动态编队目标的意图识别问题形式转化为一个时空图学习问题, 其核心在于将动态演化的编队态势转化为结构化的时序图数据。对于空中编队来说, 其中的每个目标都可以看作是图的一个节点, 该节点的特征就是编队成员的状态特征。图的拓扑结构由邻接矩阵定义, 该矩阵精确表征了编队内部各单元之间的空间关联与交互关系, 其构建的合理性是准确识别编队意图的重要基础。

为有效捕捉编队内部协同机制并适应其队形的动态演化, 本文设计了一种自适应的邻接矩阵构建流程。首先, 考虑到不同机型在编队中通常承担不同的功能角色。若编队中存在体型较大、功能特殊的节点(如预警机、运输机), 在协同中往往发挥着更为核心的组织与支撑作用, 通常负责全局态势感知、指挥协调和核心资源保障等关键功能。因此首先基于机型属性识别出此类关键节点, 并将其与编队内所有其他节点建立连接, 以构建一个稳定的全局交互骨干网。

其次, 为克服传统基于固定距离阈值的邻接关系构建方法在语义表达上的局限性, 本文采用自适应 Top-K<sup>[24]</sup> 近邻策略动态建立其他目标之间的空间连接。具体而言, 对

于每一对节点, 基于其状态特征  $\mathbf{h}_i$  与  $\mathbf{h}_j$ , 包括位置、速度、航向 3 种信息, 计算一个关联评分, 动态评估编队中任意两节点  $v_i$  与  $v_j$  在当前时刻的关联强度:

$$s_{ij} = \exp\left(-\frac{\|\mathbf{h}_i - \mathbf{h}_j\|^2}{2\sigma^2}\right) \quad (3)$$

其中,  $\sigma$  为高斯核带宽,  $\|\cdot\|$  表示向量的范数。

在此基础上, 对于每个节点  $v_i$ , 保留与其关联评分最高的前  $K$  个节点作为其有效邻居, 即:

$$\mathcal{N}(i) = \text{TopK}(\{s_{ij} \mid j \neq i\}) \quad (4)$$

最后, 根据上述步骤中定义的连接关系, 创建一个大小为  $N \times N$  的矩阵  $\mathbf{A}$ , 其中行和列表示编队中的单个目标, 矩阵中元素表示单个目标之间的关系。如果编队中两个目标之间存在连接, 则相应位置的值为 1; 否则, 相应位置的值为 0。随后, 为该矩阵添加自环, 即将主对角线元素全部设为 1, 以确保节点在信息聚合时能保留自身特征。

如图 2 所示, 通过融合表征时间动态的窗口序列与表征空间结构的邻接矩阵, 完整构建了空中编队的时空依赖关系, 为后续意图识别提供了关键输入。

### 2.2 融合 CAP 机制的图注意力空间建模

本模型 GAT 层以动态图结构作为输入, 该结构包含两个核心要素: 一是节点特征矩阵  $\mathbf{H}$ , 其中每一行  $\vec{\mathbf{h}}_i$  代表编队中单个目标的状态属性; 二是邻接矩阵  $\mathbf{A}$ , 明确了图中哪些节点之间存在可供信息流通的连接。GAT 的信息聚合始于对所有节点特征的共享线性变换, 通过一个可学习的权重矩阵  $\mathbf{W}$  将每个节点的原始特征  $\vec{\mathbf{h}}_i$  投射到一个新的特征空间  $\mathbf{W}\vec{\mathbf{h}}_i$ 。继而, 模型为每一对由邻接矩阵  $\mathbf{A}$  所定义的相连节点  $(i, j)$  计算一个未归一化的注意力系数  $e_{ij}$ 。该系数通过一个由可学习参数向量  $\vec{\mathbf{a}}$  参数化的单层前馈网络获得, 其计算公式为:

$$e_{ij} = \text{LeakyReLU}(\vec{\mathbf{a}}^T [\mathbf{W}\vec{\mathbf{h}}_i \parallel \mathbf{W}\vec{\mathbf{h}}_j]) \quad (5)$$




图2 时序图建模过程

Fig. 2 Sequence diagram modeling process

其本质是衡量邻居节点  $j$  相对于中心节点  $i$  的潜在重要性。随后,为确保注意力系数在直接邻居间计算,模型利用邻接矩阵  $\mathbf{A}$  进行掩码操作,仅保留有效连接处的  $e_{ij}$  值,并对每个节点  $i$  的所有有效系数使用 Softmax 函数进行归一化,从而得到标准化的注意力权重  $\alpha_{ij}$ ,如图3所示。

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(\vec{\mathbf{a}}^T[\mathbf{W}\mathbf{h}_i \parallel \mathbf{W}\mathbf{h}_j]))}{\sum_{k \in N(i)} \exp(\text{LeakyReLU}(\vec{\mathbf{a}}^T[\mathbf{W}\mathbf{h}_i \parallel \mathbf{W}\mathbf{h}_k]))} \quad (6)$$

其中,  $\text{LeakyReLU}(\cdot)$  为泄露整流线性单元激活函数;

$N(i)$  为中心节点  $i$  的邻居节点个数;  $\vec{\mathbf{h}}_k$  为第  $k$  个节点的特征向量;  $\parallel$  表示特征拼接操作。

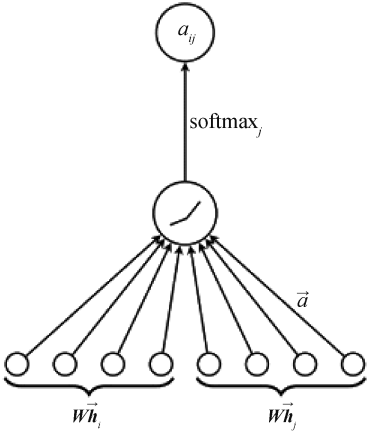


图3 单头注意力计算

Fig. 3 Single-head attention calculation

传统的注意力机制,如式(5)主要依赖于节点  $i$  与  $j$  在当前时刻的静态特征相似性。然而,在动态编队场景中,单元间的真实协同关系不仅体现在瞬时状态上,更反映在行为演化的时间一致性上。为将此时序协同先验注入空间注意力计算,本文提出一种协同演化注意力池机制(co-evolution aware pooling, CAP)。

对于任意一对相连的节点  $(i, j)$ , CAP 机制首先提取其近期行为演化趋势。记节点  $i$  在最近  $L$  个时间步的特征序列为  $\{\vec{\mathbf{h}}_i^l, \vec{\mathbf{h}}_i^{l-1}, \dots, \vec{\mathbf{h}}_i^{l-L+1}\}$ 。本文通过一个轻量的全连

接层  $\text{MLP}_{\text{trend}}$  将其映射为低维的演化趋势向量  $\vec{\mathbf{t}}_i$  :

$$\vec{\mathbf{t}}_i = \text{MLP}_{\text{trend}}(\vec{\mathbf{h}}_i^l \parallel \vec{\mathbf{h}}_i^{l-1} \parallel \dots \parallel \vec{\mathbf{h}}_i^{l-L+1}) \quad (7)$$

同理可得节点  $j$  的趋势向量  $\vec{\mathbf{t}}_j$ 。随后, CAP 机制通过一个可学习的协同性评估函数  $f_{co}$  对两个趋势向量进行池化,生成一个标量形式的协同性系数  $c_{ij}$  :

$$c_{ij} = f_{co}(\vec{\mathbf{t}}_i, \vec{\mathbf{t}}_j) = \text{Sigmoid}(\vec{\mathbf{v}}^T \cdot (\vec{\mathbf{t}}_i \odot \vec{\mathbf{t}}_j) + b) \quad (8)$$

其中,  $\vec{\mathbf{v}}$  为可学习权重向量,  $b$  为偏置项,  $\odot$  表示逐元素乘法。  $c_{ij} \in (0, 1)$  量化了节点  $i$  与  $j$  在近期行为模式上的协同程度,值越接近 1 表示协同演化越一致。

最终,利用协同性系数  $c_{ij}$  对原始注意力系数  $e_{ij}$  进行调制,得到校准后的注意力系数  $e'_{ij}$  :

$$e'_{ij} = e_{ij} \cdot (1 + \gamma \cdot c_{ij}) \quad (9)$$

其中,  $\gamma$  为一个可学习的缩放参数,用于控制协同性影响的强度。此操作使得那些在时间维度上展现出高度一致演化模式的节点对获得更强的注意力连接,反之则减弱。校准后的系数  $e'_{ij}$  将替代原始  $e_{ij}$  参与式(6)的归一化过程,从而得到融合了时空协同信息的最终注意力权重  $\alpha_{ij}$ 。

节点  $i$  更新后的特征通过对所有邻居节点变换后的特征进行加权求和而得:

$$\vec{\mathbf{h}}'_i = \sigma\left(\sum_{j \in N(i)} \alpha_{ij} \mathbf{W}\mathbf{h}_j\right) \quad (10)$$

其中,  $\sigma$  为非线性激活函数。

为了增强模型学习的稳定性及其捕获多种协同模式的能力,本模型进一步引入了多头注意力机制,如图4所示。令  $K$  个独立的注意力头并行执行上述包括 CAP 机制的全部过程,每个头拥有各自的参数集  $\mathbf{W}^k$  和  $\vec{\mathbf{a}}^k$ , 最终将各头输出的特征向量进行拼接,形成节点  $i$  的最终空间特征表示:

$$\vec{\mathbf{h}}'_i = \parallel_{k=1}^K \sigma\left(\sum_{j \in N(i)} \alpha_{ij}^k \mathbf{W}^k \mathbf{h}_j\right) \quad (11)$$

### 2.3 嵌入 MSA 机制的双向门控时序建模

经过 GAT 处理后,编队目标在每一时刻的状态均被编码为融合了空间协同关系的高阶特征。然而,编队意图




图 4 多头注意力计算

Fig. 4 Multi-head attention computation

的识别不仅需要理解时空依赖关系,更需捕捉不同时间尺度下的行为模式差异。在实际编队行为中,短期内的机动调整与长期的任务演进共同构成了意图判别的关键依据:前者如搜索意图下的局部航线调整、干扰意图中的突发机动变向,虽持续时间短却包含关键判别信息;后者如突进意图的持续高速接近、巡逻意图的周期性航线循环,则体现了任务执行的宏观规律。为此,本文提出一种多尺度注意力机制(multi-scale attention, MSA),对 BiGRU 进行改进,构建能够同时捕捉局部细节与全局趋势的时序建模模块。

GRU 作为一种高效的循环神经网络,因其在处理时序数据依赖关系上的优势而被广泛应用<sup>[25]</sup>。而 BiGRU<sup>[26]</sup>则通过前向与后向两个 GRU 层,分别从序列的首尾两端处理信息,能够集成完整的时序上下文。在时刻  $t$  的输出计算过程如下:

$$\begin{cases} \vec{h}_t = f(w_1 x_t + w_2 \vec{h}_{t-1}) \\ \leftarrow h_t = f(w_3 x_t + w_5 \leftarrow h_{t+1}) \\ h_t = g(w_4 \vec{h}_t + w_6 \leftarrow h_t) \end{cases} \quad (12)$$

其中, BiGRU 在  $t$  时刻的状态  $h_t$  可以由前向隐藏层的

状态  $\vec{h}_t$  和后向隐藏层的状态  $\leftarrow h_t$  得到。其中,  $w_i (i = 1, 2, \dots, 6)$  表示从一个细胞层到另一个细胞层的权重矩阵,  $f$  为 GRU 单元的复合计算函数,  $g$  为用于融合双向状态的激活函数。

对于 BiGRU 输出的隐藏状态序列  $\mathbf{H} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_{10}] \in \mathbf{R}^{10 \times D}$ 。MSA 机制首先通过两种不同尺度的卷积操作提取多尺度特征:

$$\begin{cases} \mathbf{H}^{(3)} = \text{Conv1D}_{k=3}(\mathbf{H}) \\ \mathbf{H}^{(10)} = \text{Conv1D}_{k=10}(\mathbf{H}) \end{cases} \quad (13)$$

其中,  $\mathbf{H}^{(3)}$  对应局部尺度,聚焦近 3 步内的编队瞬时机动细节;  $\mathbf{H}^{(10)}$  对应全局尺度,覆盖整个 10 步观测窗口,反映任务整体演进模式。

对于每一尺度特征  $\mathbf{H}^a (a \in \{3, 10\})$ , 计算其注意力输出。如图 5 所示,为提升相似度计算的准确性,将查询矩阵  $\mathbf{Q}$  与键矩阵  $\mathbf{K}$  映射至同一特征空间;同时将值矩阵  $\mathbf{V}$

映射至更高维空间以增强表征能力:

$$\mathbf{Q}^a = \mathbf{W}_{\text{QK}}^a \mathbf{H}^a, \mathbf{K}^a = \mathbf{W}_{\text{QK}}^a \mathbf{H}^a, \mathbf{V}^a = \mathbf{W}_V^a \mathbf{H}^a \quad (14)$$

$$\text{Atten}^{(a)} = \text{Softmax}\left(\frac{\mathbf{Q}^a (\mathbf{K}^a)^T}{\sqrt{d_k}}\right) \mathbf{V}^a \quad (15)$$

通过共享投影  $\mathbf{W}_{\text{QK}}^a$ , 使查询与键在可比对的特征空间中计算相似度,提高了注意力权重分配的合理性;而将值映射至高维空间则增强了特征的判别能力。

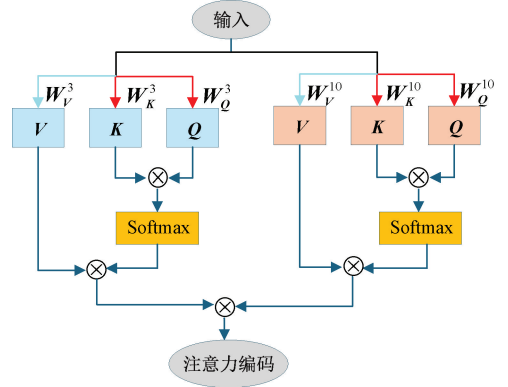


图 5 MSA 机制示意图

Fig. 5 Schematic diagram of the MSA mechanism

考虑到不同尺度注意力对最终意图识别的贡献随编队行为模式动态变化,本文通过可学习的门控权重进行自适应融合:

$$\alpha = \sigma(\mathbf{W}_g \cdot [\text{MeanPool}(\text{Atten}^3) \parallel \text{MeanPool}(\text{Atten}^{10})]) \quad (16)$$

其中,  $\sigma$  为 Sigmoid 函数,  $\parallel$  表示向量拼接,  $\alpha \in [0, 1]$  为局部尺度注意力的融合权重,  $1 - \alpha$  为全局尺度注意力权重。多尺度融合后的特征为:

$$\mathbf{H}_M = \alpha \cdot \text{Attn}^3 + (1 - \alpha) \cdot \text{Attn}^{10} \quad (17)$$

改进后的 BiGRU 结构如图 6 所示, MSA 机制通过多尺度特征提取与自适应融合,使模型能够同时捕捉编队行为的局部机动协同与全局任务演进,为意图识别提供了更全面、更稳健的时序特征表示。

## 2.4 输出层

对于编队中的  $N$  个目标,模型获得  $N$  条独立的时序数据,每条数据表征了单个目标在时空交互影响下的状态演化。BiGRU 并行处理所有这些序列,为每个目标  $i$  输出一个融合了长期双向依赖的最终特征表示  $\mathbf{h}_i^M$ 。为从所有个体的时序特征中凝练出编队的整体意图,模型采用全局池化层对所有节点的最输出进行聚合:

$$\mathbf{h}_f = \frac{1}{N} \sum_{i=1}^N \mathbf{h}_i^M \quad (18)$$

该编队级特征向量  $\mathbf{h}_f$  凝聚了整个编队在一段时间内的时空行为模式。最后,将该特征输入一个全连接层,并通过 Softmax 函数计算其属于各意图类别的概率:

$$P(y = j | \mathbf{h}_f) = \frac{\exp(\mathbf{W}_j \mathbf{h}_f + b_j)}{\sum_{k=0}^5 \exp(\mathbf{W}_k \mathbf{h}_f + b_k)} \quad (19)$$




图6 MSA机制改进的BiGRU结构

Fig. 6 BiGRU architecture enhanced with MSA mechanism

其中,  $j \in \{0, 1, 2, 3, 4, 5\}$  表示意图类别的索引, 与 1.1 节中定义的 6 种意图空间一一对应。 $\mathbf{W}_j$  和  $b_j$  分别为对应于第  $j$  类意图的可学习权重和偏置项。最终, 模型通过  $\text{Argmax}$  函数选取概率最大的类别作为编队整体意图的识别结果:

$$\hat{y} = \underset{j \in \{0, \dots, 5\}}{\text{Argmax}} P(y = j | \mathbf{h}_f) \quad (20)$$

## 2.5 时空图注意力网络模型

本文提出的 STGAT-BiGRU 模型框架如图 7 所示, 模型以时序图序列为输入, 首先通过融合 CAP 机制的 GAT 对每一时刻的图结构进行编码, 自适应地聚合邻居节点信息, 以提取关键的空间协同特征。随后, Dropout 层被用于对该空间特征进行正则化, 以抑制过拟合。处理后的特征序列被送入 MSA 机制改进的 BiGRU, 该模块通过正向与反向解码序列的时序依赖关系, 捕捉编队行为的动态演化模式。最终, 模型通过全连接层与 Softmax 函数, 将融合后的时空特征映射为意图类别的概率分布, 并输出最终的识别结果。

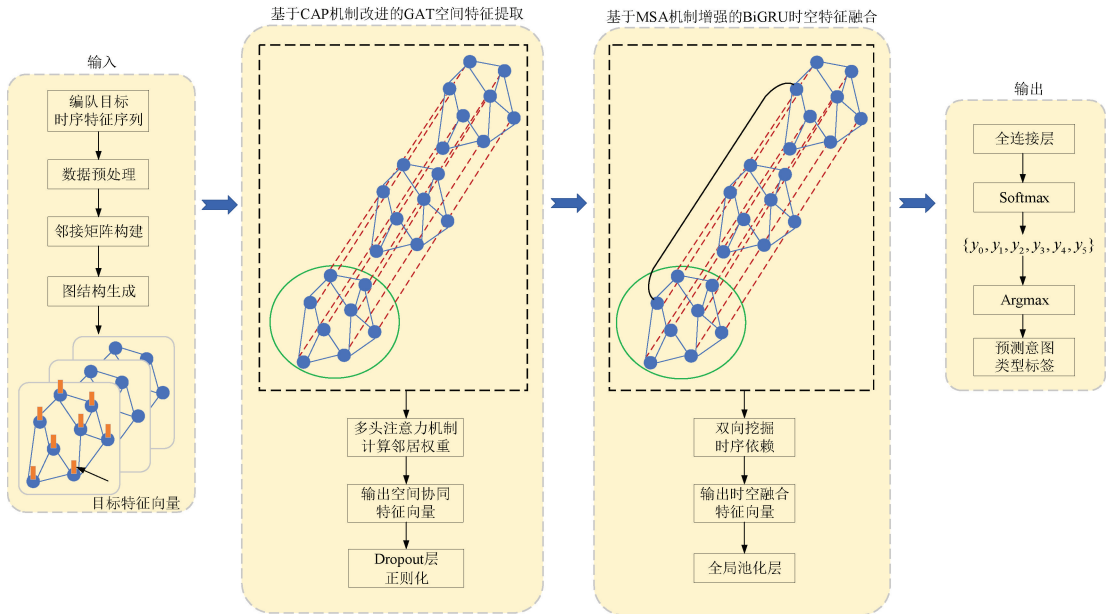


图7 STGAT-BiGRU模型总体框架

Fig. 7 Overall framework of the STGAT-BiGRU model

## 3 实验仿真分析

### 3.1 实验数据与环境

本实验以战斗机、电子干扰机、预警机、侦察机、运输机为仿真目标对象, 在其多目标联合执行演习任务的背景下, 通过仿真系统, 模拟选取了 15 000 组样本数据, 按照 7:3 的比例划分训练集和测试集, 其中 10 500 组作为训练集, 4 500 组作为测试集, 每个类别的意图占 16.7%。

本实验使用的平台硬件规格为: 64 位 Windows 11 操作系统, CPU 为 Intel Xeon W-2245 CPU@3.90 GHz、内存为 32 GB, GPU 为 NVIDIA RTX A2000 GPU, 并使用

PyTorch 深度学习框架, 在 Python 3.9 开发环境下实现。具体模型实验参数如表 3 所示。

### 3.2 意图识别结果及分析

为验证模型的有效性, 本文在测试集上进行了编队目标意图识别实验, 混淆矩阵结果如图 8 所示。定量评估结果如表 4 所示。从混淆矩阵可以看出, “搜索”意图存在被误判为“干扰”的倾向, 误判率约为 2.8%。因两者均采用松散队形, 运动轨迹特征存在相似性; 而“突进”凭借密集队形和高速定向机动, 识别效果良好。表 4 数据表明, “撤离”意图结果表现突出, 精确率达 98.2%、F1 分数 97.6%, 这得益于其明确的方向一致性和速度特征; “巡

表 3 实验参数设置

Table 3 Experimental parameter settings

参数	取值
损失函数(loss function)	交叉熵损失函数
训练周期(epoch)	80
学习率(learningrate)	0.000 5
优化器(optimizer)	Adam
正则化参数(dropout)	0.3
批量大小(batch_size)	32
特征通道数(transform_channels)	256
图注意力头数(Heads)	8
近邻数(Top-K)	3
滑动窗口长度(Window Size)	10

势,在相同训练集、测试集下,设计了对比实验。对比实验中参数采用文献中对应的参数,实验结果如表 5 所示。

表 5 对比实验结果

Table 5 Comparison of experimental results %

模型	准确率	精确率	召回率	F1 分数
GCN-DQN <sup>[17]</sup>	82.1	82.7	81.5	82.1
STIRNet <sup>[18]</sup>	89.2	89.5	88.7	89.1
CNN-LSTM <sup>[27]</sup>	80.5	82.1	80.0	81.4
HRGPA <sup>[28]</sup>	87.0	85.5	88.2	86.7
DynGN <sup>[29]</sup>	92.4	92.2	92.3	92.5
STGAT-BiLSTM	90.3	90.0	90.5	90.2
STGAT-BiGRU	<b>95.7</b>	<b>95.5</b>	<b>96.3</b>	<b>95.9</b>

由表 5 可知,CNN-LSTM 作为一种时序-空间融合模型,通过卷积层提取局部空间模式并结合 LSTM 捕捉时间依赖,能够初步建模编队的运动序列,但由于其本质上将编队视为一组无序的独立轨迹,忽略了单元间的拓扑协同关系,因此性能受限,准确率仅为 80.5%;GCN-DQN 在图结构中引入深度强化学习机制,其图卷积层能够建模单元间的空间交互,从而将准确率提升至 82.1%,但该模型图结构服务于即时奖励最大化,在理解长期、宏观的编队意图方面存在一定局限;HRGPA 采用层次化递归网络与图策略注意力机制,从不同粒度解析集群行为,提升了模型对复杂模式的覆盖能力,准确率达到 87.0%,但其层次化结构在融合多尺度特征时可能会引入信息冗余与噪声;STIRNet 通过构建时空图并结合卷积运算,验证了时空图学习范式在意图识别上的有效性,但其空间特征提取采用的 GCN 本质是对邻居节点进行平等加权聚合,无法区分不同节点间交互的重要性差异;STGAT-BiLSTM 作为本文架构的对比变体,在图注意力机制的基础上使用时序模块 BiLSTM,验证了在本文提出的动态图注意力架构下,采用 BiGRU 进行时序建模能够更有效地捕捉编队意图的演化模式;DynGN 通过实时演化的图结构捕捉单元间交互的动态性,将准确率提升至 92.4%,证明了动态拓扑是理解编队行为的关键。

相比上述几种方法,本文提出的 STGAT-BiGRU 模型能够自适应地捕捉编队内非对称的空间协同特征,同时深度挖掘其随时间演化的行为模式,在理解和处理复杂的时空动态行为方面表现出较强的性能。与其他意图识别模型相比,在准确率、精确率、召回率和 F1 分数上平均提升分别了 8.78%、8.5%、9.43% 和 8.9%。

### 3.4 消融实验结果及分析

为了分析和评估模型中各部件或模块对整体意图识别性能的影响,在此进行消融实验,结果如表 6 所示。

由表 6 可以看出,本文提出的完整 STGAT-BiGRU 模型准确率达到 95.7%,F1 分数达到 95.9%;与基础时空融

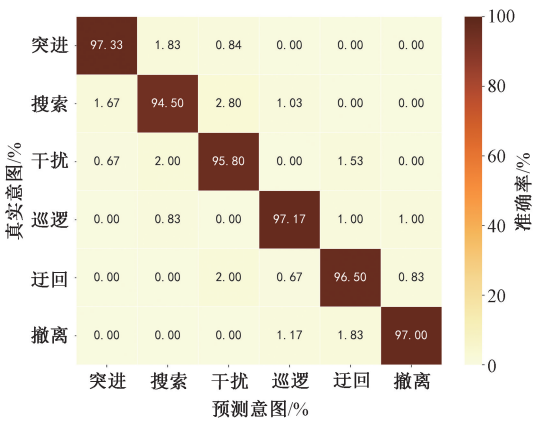


图 8 编队意图识别混淆矩阵

Fig. 8 Formation intent recognition confusion matrix

“巡逻”识别稳定,精确率、召回率均超 96%,体现模型对其规律性运动模式的有效学习;“迂回”F1 分数 96.1%,说明模型对侧向规避机动的捕捉能力较好。此外,“搜索”和“干扰”两种意图虽然存在相互混淆,但 F1 分数仍保持在 94.9%、95.1% 的较高水平,反映出模型在处理相似时空特征行为时的强判别能力。

表 4 编队意图识别结果

Table 4 Formation intent recognition results %

意图类型	精确率	召回率	F1 分数
突进	97.6	97.3	97.5
搜索	95.2	94.5	94.9
干扰	94.5	95.8	95.1
巡逻	96.0	97.2	96.6
迂回	95.7	96.5	96.1
撤离	98.2	97.0	97.6

### 3.3 对比实验结果及分析

为了进一步验证模型在识别空中编队意图方面的优

表6 消融实验结果  
Table 6 Ablation experiment results

模型中各组成结构				准确率	精确率	召回率	F1 分数
GAT	CAP	MSA	BiGRU				
—	—	—	√	85.1	84.8	85.5	85.1
√	—	—	√	90.3	90.9	90.1	90.2
√	√	—	√	91.5	92.0	91.2	91.4
√	—	√	√	92.8	93.3	92.6	92.7
√	√	√	√	<b>95.7</b>	<b>95.5</b>	<b>96.3</b>	<b>95.9</b>

合模型(GAT+BiGRU)相比,准确率提升 5.4%,F1 分数提升 5.7%。这表明各创新模块的引入对模型性能均有显著贡献。仅使用 BiGRU 的模型致力于处理时间序列数据,可以有效捕捉空中编队中节点自身的时序演化特征,但缺乏对空间协同关系的建模能力,识别精度为 85.1%。而引入 GAT 构成的基础时空融合模型,能够同时考虑空中编队目标的空间邻居信息和时间依赖性,将识别准确率提高到 90.3%。在此基础上引入 CAP 机制(GAT+CAP+BiGRU),通过将节点间时间演化一致性融入空间注意力计算,准确率进一步提升至 91.5%,验证了该机制在捕捉动态协同关系方面的有效性。引入 MSA 机制(GAT+MSA+BiGRU)则通过多尺度时序建模增强了对局部机动与全局模式的捕捉能力,准确率达到 92.8%。完整 STGAT-BiGRU 模型融合了 CAP 与 MSA 机制,准确率达到 95.7%,显著高于任一单独改进方案,说明二者具有互补协同效应。

本文提出的 STGAT-BiGRU 形成了一种分层递进的时空特征学习架构,能够动态演化空间交互拓扑并实现多尺度时空模式融合,因而在应对空中编队复杂协同机动行为时表现出显著优势。

## 4 结 论

本文聚焦空中编队意图识别核心需求,针对现有方法忽略单元间动态交互、时空特征融合不足导致识别精度受限的问题,提出了一种时空图注意力网络模型 STGAT-BiGRU。该模型首先通过自适应图结构构建方法,将动态编队态势转化为结构化时序图;随后引入 CAP 机制,将节点对的时间演化一致性信息融入图注意力计算,以精准捕捉非对称空间协同特征;接着设计了 MSA 机制增强的 BiGRU,实现对局部机动细节与全局任务演进模式的同时建模。实验结果表明,所提方法在意图识别准确率与 F1 分数上分别达到 95.7%和 95.9%,较现有主流方法平均提升 8.78%和 8.90%,验证了模型在复杂时空动态行为识别中的显著优势。当前研究主要面向中小规模编队场景,未来将进一步探索模型在大规模编队中的扩展性与实用性,并研究更高效的训练策略,以支撑实际系统中实时、精准的编队意图识别。

## 参考文献

- [1] 王慧琴,苗国英,孙英博. 基于多智能体强化学习值分解的优化算法[J]. 电子测量技术, 2023, 46(7): 73-79.  
WANG H Q, MIAO G Y, SUN Y B. Optimization algorithm based on value decomposition of multi-agent reinforcement learning [J]. Electronic Measurement Technology, 2023, 46(7): 73-79.
- [2] 李海青,雷宇斌,戴盈盈,等. 基于车路云协同感知的车辆驾驶意图识别方法[J]. 电子测量与仪器学报, 2025, 39(11): 98-107.  
LI H Q, LEI Y CH, DAI Y Y, et al. Vehicle driving intention recognition method based on vehicle-road-cloud collaborative perception [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(11): 98-107.
- [3] 吕相谊,赵东辉,丁嘉辉,等. 基于辅助喂食全过程意图识别的多模态安全交互方法研究[J]. 仪器仪表学报, 2025, 46(1): 351-362.  
LYU X Y, ZHAO D H, DING J H, et al. A multimodal safe interaction method based on intention recognition in the whole process of assisted feeding[J]. Chinese Journal of Scientific Instrument, 2025, 46(1): 351-362.
- [4] LI H Y, LI P Y, ZHANG W, et al. Blockchain-enabled dynamic formation control and reorganization for intelligent UAV swarms[J]. Pervasive and Mobile Computing, 2025, 115: 102129.
- [5] 万宁,张美珠. 考虑多尺度时空因果特征的排球群体行为识别[J]. 电子测量技术, 2025, 48(4): 80-90.  
WAN N, ZHANG M ZH. Volleyball group behavior recognition method considering causality[J]. Electronic Measurement Technology, 2025, 48(4): 80-90.
- [6] SAMHABER S, LEITNER M. Collaborative patterns for workflows with collaborative robots [C]. International Conference on Cooperative Information Systems. Cham: Springer International Publishing, 2022, 13591: 131-148.
- [7] 邵凯. 基于无人机群的任务意图预测与路径推荐系统[D].

- 大连:大连理工大学, 2024.
- SHAO K. Mission intention prediction and path recommendation system based on UAV[D]. Dalian: Dalian University of Technology, 2024.
- [8] 刘罡, 李小雨, 吴焯, 等. 基于跨模态协同感知的双流融合动作识别模型[J]. 电子测量技术, 2025, 48(21): 87-97.
- LIU G, LI X Y, WU Y, et al. Dual-stream fusion action recognition model based on cross-modal co-sensing [J]. *Electronic Measurement Technology*, 2025, 48(21): 87-97.
- [9] 饶佳人, 孙世庆, 李婷婷. 基于规则的空中作战编队识别[J]. 指挥信息系统与技术, 2021, 12(3): 19-22, 29.
- RAO J R, SUN SH Q, LI T T. Rule-based formation identification of air combat[J]. *Command Information System and Technology*, 2021, 12(3): 19-22, 29.
- [10] 乔殿峰, 梁彦, 马超雄, 等. 多域作战下的群目标意图识别与预测[J]. 系统工程与电子技术, 2022, 44(11): 3403-3412.
- QIAO D F, LIANG Y, MA CH X, et al. Recognition and prediction of group target intention in multi-domain operations [J]. *Systems Engineering and Electronics*, 2022, 44(11): 3403-3412.
- [11] 杨锐, 杨继龙, 刘晓凡, 等. 基于动态序列贝叶斯网络的空地协同作战意图识别[J]. 指挥控制与仿真, 2024, 46(3): 75-85.
- YANG R, YANG J L, LIU X F, et al. Air-ground cooperative operations intention recognition based on dynamic series bayesian network [J]. *Command Control & Simulation*, 2024, 46(3): 75-85.
- [12] 李泽鹏, 吉琳娜, 杨风暴. 基于 GTN 与证据理论的集群目标意图分层识别方法[J]. 国外电子测量技术, 2025, 44(1): 22-29.
- LI Z P, JI L N, YANG F B. A hierarchical identification method of cluster target intent based on gated-transformer-network and evidence theory [J]. *Foreign Electronic Measurement Technology*, 2025, 44(1): 22-29.
- [13] 马钰棠, 孙鹏, 张杰勇, 等. 样本不平衡下的空中群组意图识别方法[J]. 系统工程与电子技术, 2022, 44(12): 3747-3755.
- MA Y T, SUN P, ZHANG J Y, et al. Air group intention recognition method under imbalance samples[J]. *Systems Engineering and Electronics*, 2022, 44 ( 12 ): 3747-3755.
- [14] 王宇航, 董宝良, 公超, 等. 基于意图识别的空中群目标动态威胁评估[J]. 计算机与现代化, 2023, (12): 100-104, 111.
- WANG Y H, DONG B L, GONG CH, et al. Dynamic threat assessment of air swarm targets based on intent recognition [ J ]. *Computer and Modernization*, 2023, (12): 100-104, 111.
- [15] HE CH, LUO J J, YANG ZH Q, et al. Intention recognition for spacecraft formation based on two-layer temporal convolutional network-self attention [J]. *Aerospace Science and Technology*, 2025, 158: 109939.
- [16] BAI J D, ZHU J W, SONG Y J, et al. A3t-gcn: Attention temporal graph convolutional network for traffic forecasting[J]. *ISPRS International Journal of Geo-Information*, 2021, 10(7): 485.
- [17] 欧洋, 郭正玉, 罗德林, 等. 基于图卷积深度强化学习的协同空战机动决策方法[J]. 工程科学学报, 2024, 46(7): 1227-1236.
- OU Y, GUO ZH Y, LUO D L, et al. Collaborative air combat maneuvering decision-making method based on graph convolutional deep reinforcement learning [J]. *Chinese Journal of Engineering*, 2024, 46 ( 7 ): 1227-1236.
- [18] ZHANG CH H, ZHOU Y, LI H Q, et al. STIRNet: A spatio-temporal network for air formation targets intention recognition[J]. *IEEE Access*, 2024, 12: 44998-45010.
- [19] VELIČKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks [C]. *International Conference on Learning Representations (ICLR)*, 2018, 1050: 4.
- [20] 刘健. 基于多源信息的海上编队目标意图识别[D]. 哈尔滨: 哈尔滨工业大学, 2023.
- LIU J. Intention recognition for maritime formation targets using multi-source information[D]. Harbin: Harbin Institute of Technology, 2023.
- [21] 刘祥雨, 王刚, 王思远, 等. 数据-知识双驱动的编队目标意图识别方法[J]. 航空学报, 2026, 47(2): 288-308.
- LIU X Y, WANG G, WANG S Y, et al. A data-knowledge dual-driven method for formation target intention recognition [ J ]. *Acta Aeronautica et Astronautica Sinica*, 2026, 47(2): 288-308.
- [22] TENG F, SONG Y F, GUO X P. Attention TCN BiGRU: An air target combat intention recognition model[J]. *Mathematics*, 2021, 9(19): 2412.
- [23] 苟先太, 吴南方. 基于 GRU-Attention 神经网络的空中群组态势识别方法[J]. 计算机与现代化, 2019(10): 11-16, 33.

- GOU X T, WU N F. Air group situation recognition method based on GRU-attention neural network[J]. Computer and Modernization, 2019(10): 11-16,33.
- [24] LIU J Y, WANG X S, XIE F Q, et al. Condition monitoring of wind turbines with the implementation of spatio-temporal graph neural network [J]. Engineering Applications of Artificial Intelligence, 2023, 121: 106000.
- [25] 赵杰, 解则晓, 刘世萱. 基于能量熵 VMD 最优分解与 GRU 循环神经网络的潮汐预测精度提升方法研究[J]. 仪器仪表学报, 2023, 44(12): 79-87.
- ZHAO J, XIE Z X, LIU SH X. Tide prediction accuracy improvement method research based on VMD optimal decomposition of energy entropy and GRU recurrent neural network [J]. Chinese Journal of Scientific Instrument, 2023, 44(12): 79-87.
- [26] WANG W, RUAN W H, MENG X F. MODE-Bi-GRU: Orthogonal independent Bi-GRU model with multiscale feature extraction [J]. Data Mining and Knowledge Discovery, 2024, 38(1): 154-172.
- [27] CHEN J Y, WANG X H, CHEN X. Track correlation algorithm based on CNN-LSTM for swarm targets [J]. Journal of Systems Engineering and Electronics, 2024, 35(2): 417-429.
- [28] WEI X L, CUI W P, HUANG X L, et al. Hierarchical RNNs with graph policy and attention for drone swarm[J]. Journal of Computational Design and Engineering, 2024, 11(2): 314-326.
- [29] AN Y, LIU AO, LIU H, et al. Multidimensional trajectory prediction of UAV swarms based on dynamic graph neural network [J]. IEEE Access, 2024, 12: 57033-57042.

### 作者简介

牛景琦, 硕士研究生, 主要研究方向为信息融合、意图识别。

E-mail: 15027702515@163.com

杨风暴(通信作者), 博士, 教授, 博士生导师, 主要研究方向为信息融合、信息探测与处理、光电信息技术与系统。

E-mail: yfeNgb@163.com

王肖霞, 博士, 副教授, 硕士生导师, 主要研究方向为多模态目标智能识别与检测技术。

E-mail: wangxiaoxia@muc.edu.cn