

# 控制与决策

Control and Decision

## 揭示生物集群系统内部信息耦合机制的深度网络模型

刘磊, 黄景然, 赵佳佳, 黄宇玲, 高岩

引用本文:

刘磊, 黄景然, 赵佳佳, 黄宇玲, 高岩. 揭示生物集群系统内部信息耦合机制的深度网络模型[J]. *控制与决策*, 2023, 38(5): 1403–1411.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1079>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 鱼群涌现机制下集群机器人运动强化的迁移控制

Transfer control of swarm robotics motion reinforcement employing fish schooling emergency mechanism  
*控制与决策*. 2023, 38(3): 621–630 <https://doi.org/10.13195/j.kzyjc.2021.1554>

#### 基于多智能体深度强化学习的船舶协同避碰策略

Ship cooperative collision avoidance strategy based on multi-agent deep reinforcement learning  
*控制与决策*. 2023, 38(5): 1395–1402 <https://doi.org/10.13195/j.kzyjc.2022.1159>

#### 基于偏差的图注意力神经网络推荐算法

A bias-based graph attention neural network recommender algorithm  
*控制与决策*. 2022, 37(7): 1705–1712 <https://doi.org/10.13195/j.kzyjc.2020.1626>

#### 基于多尺度残差注意网络的轻量级行人属性识别算法

Lightweight pedestrian attribute recognition algorithm based on multi-scale residual attention network  
*控制与决策*. 2022, 37(10): 2487–2496 <https://doi.org/10.13195/j.kzyjc.2021.0411>

#### 基于深度学习的仿生集群运动智能控制

Intelligent control of bionic collective motion based on deep learning  
*控制与决策*. 2021, 36(9): 2195–2202 <https://doi.org/10.13195/j.kzyjc.2020.0071>

# 揭示生物集群系统内部信息耦合机制的深度网络模型

刘磊<sup>1,2†</sup>, 黄景然<sup>1</sup>, 赵佳佳<sup>1</sup>, 黄宇灵<sup>1</sup>, 高岩<sup>1</sup>

(1. 上海理工大学管理学院, 上海 200093; 2. 上海理工大学光电信息与计算机工程学院, 上海 200093)

**摘要:** 生物集群在自然界中广泛存在, 如鱼群、鸟群、兽群等, 这些集群通过内部的信息耦合能涌现出有序的协同行为。但是, 集群内部交互复杂、情况多变, 导致微观层面的行为分析还缺乏行之有效的标准工具。对此, 以鱼群运动数据为研究对象, 借助图注意力网络对鱼群中的单体行为进行自动化建模, 目的是提炼出适于复杂系统分析的通用网络工具。首先将单体的感知信息映射到高维状态空间, 然后生成软注意力数值以表征单体之间的交互强度, 再对所生成的软注意力数值规范化, 所得规范结果既可作为多邻居信息耦合的关键指标, 又可通过解码器将所抽取的注意力信息稀疏解耦为运动决策。实验结果表明: 所生成的注意力数值不但能揭示群体内部的信息耦合关系, 还能进一步对隐藏交互强度可视化, 从而为鱼群的视觉交互理论提供新的科学证据。所提出分析工具拥有信息耦合可解释、交互强度可显现、系统规模可缩放、状态偏移可泛化等优良特性, 有望发展成为复杂系统解耦分析的标准范式, 在社会行为分析、机器人集群控制以及智能交通系统安全性评价等方面具有潜在的应用价值。

**关键词:** 集群运动建模; 图注意力机制; 多主体交互解耦; 复杂系统分析; 集群智能涌现; 多智能体协同

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1079

引用格式: 刘磊, 黄景然, 赵佳佳, 等. 揭示生物集群系统内部信息耦合机制的深度网络模型[J]. 控制与决策, 2023, 38(5): 1403-1411.

## Analysis model for revealing mechanism of internal information coupling in biological collective systems based on deep network

LIU Lei<sup>1,2†</sup>, HUANG Jing-ran<sup>1</sup>, ZHAO Jia-jia<sup>1</sup>, HUANG Yu-ling<sup>1</sup>, GAO Yan<sup>1</sup>

(1. School of Management, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

**Abstract:** The biological collective motion exists wildly in the natural world, such as fish schooling, birds flocking, herds migrating, etc. These species can emerge cooperative behavior orderly through internal information coupling. However, due to the complexity of the internal interaction and ever-changing environment, there is still a lack of effective tools for behavioral analysis at the micro level. In this work, an embedded graphical attention deep network is employed for automatically building the model of the individual information interactions from the data of fish schooling, aiming to extract a general network tool suiting for the complex system analysis. This research maps the low-dimensional individual observations to the high-dimensional states space followed by the generation of soft attention values to represent the interaction strength between the individuals. These soft attention values are numerically normalized, which can be used as a key indicator for the information coupling of multi-neighbors. A decoder network is designed for transforming the extracted attention information into the motion decision of individuals. The experimental results show that the obtained attention value can not only reveal the hidden coupling relationship of the information interactions in collective systems, but also visualize the information interactions of the individuals, which can be used as scientific evidence for proving the visual communication theory on fish schooling. The presented analysis tool has the following excellent characteristics: First, the coupling of internal information can be explained; Second, the interaction strength of individuals can be visualized; Third, the quantity of individuals in the system can be scaled; Forth, the model can be generalized to the different distribution of collective states. In conclusion, the proposed tool is promising to become a standard artificial intelligence paradigm for decoupling analysis of complex systems, which has potential application values in the behavior analysis of social systems, distributed control of swarm robotics, and safety evaluation for intelligent transportation systems.

**Keywords:** collective motion modeling; graph attention mechanism multi-agents interaction decoupling; complex system analysis; collective intelligence emergence; multi-agents collaboration

收稿日期: 2022-06-20; 录用日期: 2022-11-24.

基金项目: 上海市自然科学基金项目(22ZR1443300); 国家自然科学基金项目(72071130).

责任编辑: 杨涛.

†通讯作者. E-mail: liulei@usst.edu.cn.

## 0 引言

集群运动在自然界中普遍存在,例如鱼类群游、鸟群编队、昆虫聚集等.在这类系统中,单体通过局部信息交互可以自发地形成有序的耗散结构,继而自组织出协同行为,这两种涌现使得生物系统能呈现出令人惊叹的集群智能,从而保证种群的长久续存.尽管在微观层面对生物集群的内部信息分析充满了挑战,但是,该领域研究能够极大地启发人工集群系统的分布式控制设计.

已有研究多数使用图或网络来揭示生物集群功能与单体关联机制,如文献[1]将大型食草动物建成有向社会网络,发现兽群交互具有长期记忆效应,说明集群底层的信息传播具有网络稳定性.进一步的研究发现,动物集群网络还具有丰富的等级层次<sup>[2]</sup>,表明在微观层面单体需要面对瞬息万变的外部态势;同时,高层集群智能还会在底层争夺单体的控制权,造成单体的运动决策既要符合集群意志,又需根据周围的态势随机应变.另一方面,受制于单体的信息不完全感知和有限的处理能力,焦点单体如何稀疏解耦局部信息来涌现集群行为仍是悬而未解的科学难题<sup>[3]</sup>,所以亟待设计出一种新型的动态网络工具以应对单体的信息解耦工作.

目前,著名的生物集群系统分析模型包括 Vicsek 模型<sup>[4]</sup>、Couzin 模型<sup>[5]</sup>、Boid 模型<sup>[6]</sup>等,这类模型都可以形成较为稳定的集群行为,但模型需要单体感知过多邻居信息,导致单体对大量信息的融合难度增加,不利于人工确定模型的数学结构,所以该领域亟需发展针对集群数据的自动解耦建模方法.随着深度学习技术突飞猛进,生物运动数据的获取难度也在持续降低,上述两方面因素的叠加所导致基于大数据的复杂系统自动建模正逐渐成为可能.如近期本课题组利用数据驱动技术对鱼群运动进行了行为交互建模<sup>[7]</sup>,实现了中小规模的集群运动涌现;相同数据再利用深度神经网络学习,进一步实现了大规模集群运动的人工智能控制<sup>[8]</sup>.但是,由于深度网络“黑盒”特性,模型的可解释性方面还存在不足.为探寻深度学习的可解释性,以图神经网络(GNN)、图卷积网络(GCN)以及图注意力网络(GAT)<sup>[9]</sup>为代表的图模型工具正逐渐被用于复杂系统分析,如复杂物理系统网络<sup>[10]</sup>、蛋白质结构网络<sup>[11]</sup>、智能交通网络<sup>[12]</sup>等.其中 GAT 能挖掘出信息网络的注意力结构和交互作用函数,若能将其嵌入集群运动的信息交互模型中,则能使 GAT 方法具备泛化的集群数据处理能力<sup>[13]</sup>,而利用该机理生成的集群信息交互模型有望成为复杂系

统解耦分析的标准工具.不失一般性,本文以鱼群运动数据为对象,借鉴 GAT 来设计深度网络嵌入模型,以期有效应对复杂生物系统的信息交互解析任务.

## 1 集群运动的自动建模原理

### 1.1 单体注意力交互网络

鱼群系统能够自组织形成群体智能,属于典型的复杂系统.研究表明,鱼群中某些单体的随机行为会通过邻居逐级放大,最终将以波浪形式向外传播强化,从而涌现出整体的有序运动<sup>[14]</sup>.可见集群运动的形成伴随有不稳定、非线性、强耦合等复杂的时空运动特性,所以需要在微观层面建立局部动态网络模型来进行单体的交互行为分析.为此,根据 GAT 网络原理,本文有针对性地设计一种新型的网络工具,将其命名为单体注意力交互网络(Individual Attention Network, IAT),用以对鱼群系统进行数据驱动解耦.

考虑  $t$  时刻  $N$  个单体构成的集群,全局动态网络拓扑可用图  $G = (V^t, W^t, E^t)$  表示.其中:节点集  $V^t$  表示所有单体的全局位置  $\{v_i^t | i = 1, 2, \dots, N\}$ ; 边集  $E^t$  表示单体之间的规范交互关系  $\{e_{ij}^t | i \neq j\}$ ;  $W^t$  为单体之间的交互强度矩阵,其内部元素  $w_{ij}^t$  代表  $t$  时刻节点  $v_j^t$  对节点  $v_i^t$  施加的影响,因为鱼群的交互具有各项异性<sup>[8]</sup>,所以  $w_{ij}^t \neq w_{ji}^t, i \neq j$ .根据上述定义,单体在系统内的位置演化可表示为

$$v_i^{t+1} = v_i^t + \Delta v_i^t, \quad (1)$$

$$\Delta v_i^t = \sum_{j=1}^N w_{ij}^t e_{ij}^t(v_j^t), \quad (2)$$

其中  $\Delta v_i^t \in \Delta V^t$  为单体  $i$  的位置增量.虽然全局网络模型可以通过观测鱼群运动数据  $V^t$ 、 $\Delta V^t$  来还原单体间的规范交互关系  $E^t$  以及关系权重矩阵  $W^t$ ,但是,由于交互函数  $e_{ij}^t(v_j^t)$  具有较强烈的非线性<sup>[7]</sup>,人工机理建模极具挑战,需在微观层面设计 IAT 模型来对单体的局部交互进行数据驱动分析.

由于单体的信息选择耦合与集群行为具有高度的相关性,而与耦合信息交互后再生成的行为又会继续助推单体选择类似的信息进行强化耦合,这就使得重点邻居的信息会以波浪的形式在群体中串联传递<sup>[14]</sup>.为更好地分析这类信息的选择交互机制,IAT 模型被设计成类图神经网络的消息传递框架(message passing neural network, MPNN)<sup>[15]</sup>,以便通过注意力模块来挖掘生物集群内部的信息选择策略.然而,现有图注意力研究大多是对所有节点进行同步分析与数据更新,这与鱼群内部的信息异步处理机制不兼容<sup>[16]</sup>.为此,IAT 模型拟采用网络节点局部

感知、并行处理、级联传递、异步更新的方法来保证该工具符合生物集群的行为解耦分析。

定义焦点单体  $i$  的邻居标号集合为  $N_i$ , 则  $t$  时刻焦点单体  $i$  观测邻居 (不包含自身) 的位置为  $[X_{i1}^t, \dots, X_{ij}^t, \dots, X_{iN}^t]$ ,  $i \neq j$ , 感知自身的位置为  $X_i^t$ . 将这些原始测量转换为高维的隐式信息, 具体可通过如下信息编码实现:

$$h_{ij}^t = f_{\text{ENC}}(X_{ij}^t), j \in N_i; \quad (3)$$

$$h_i^t = f_{\text{ENC}}(X_i^t). \quad (4)$$

其中:  $f_{\text{ENC}}(\cdot)$  为编码器函数;  $N_i$  为焦点单体  $i$  的邻居标号集合, 个数为  $N - 1$ , 即去除焦点单体标号  $i$  的其他智能体标号集合. 接着进行焦点单体对所有隐式信息的聚合操作, 因为单个生物处理信息的能力有限, 所以会对所有邻居的观测信息进行稀疏选择<sup>[17]</sup>. 为此, 在 IAT 模型内部引入“软性”信息选择机制<sup>[18]</sup>, 用注意力系数  $k_{ij}^t$  和  $k_i^t$  来表征, 即

$$k_{ij}^t = \sigma(f_{\text{MLP}}(h_{ij}^t, h_i^t)), j \in N_i; \quad (5)$$

$$k_i^t = \sigma(f_{\text{MLP}}(h_i^t, h_i^t)). \quad (6)$$

其中:  $f_{\text{MLP}}(\cdot)$  为注意力识别网络,  $\sigma(\cdot)$  为输出层激活函数. 式(5)、(6)将  $h_{ij}^t$ 、 $h_i^t$  的隐式高维信息匹配为注意力数值输出, 反映了单体对不同信息的选择偏好. 传统集群模型对邻居信息的聚合通常采用求和或均值方法<sup>[7]</sup>, 但是, 上述方法会造成节点对异常信息的高度敏感, 破坏模型的输出稳定性<sup>[16]</sup>. 而利用注意力网络进行嵌入操作, 就会有效滤除异常信息干扰, 保证焦点单体只注意集群内部的重点信息, 使得信息耦合更加灵活稳定<sup>[19]</sup>.

考虑到生物体的注意力总量有限, 为使焦点单体的注意力总量保持一致, 增加 IAT 模型对生物集群行为的可解释性, 添加了注意力规范化操作. 定义焦点单体对邻居和环境的规范注意力权重为  $w_{ij}^t$ 、 $w_i^t$ , 具体计算方法为

$$w_{ij}^t = \frac{k_{ij}^t}{\sum_{j \in N_i} k_{ij}^t + k_i^t}, \quad (7)$$

$$w_i^t = \frac{k_i^t}{\sum_{j \in N_i} k_{ij}^t + k_i^t}. \quad (8)$$

将注意力权重  $w_{ij}^t$ 、 $w_i^t$  与高维隐式信息  $h_{ij}^t$ 、 $h_i^t$  相结合, 便可生成焦点单体  $i$  用于决策的注意力筛选信息  $h'_{ij}$  和  $h'_i$ , 具体计算公式如下:

$$h'_{ij} = w_{ij}^t h_{ij}^t, j \in N_i; \quad (9)$$

$$h'_i = w_i^t h_i^t. \quad (10)$$

再将这两个信息连接, 利用解码器  $f_{\text{DEC}}(\cdot)$  输出  $t$  时刻焦点单体  $i$  的运动决策  $\Delta \hat{x}_i^t$ , 即

$$\Delta \hat{x}_i^t = f_{\text{DEC}}(h'_{ij} \oplus h'_i). \quad (11)$$

最后, 对鱼群实验数据进行处理, 还原出第  $\tau$  次决策焦点单体  $i$  的邻居观测数据  $X_{ij}^\tau (j \in N_i)$ 、自身位置数据  $X_i^\tau$  和对应的运动决策输出  $\Delta \hat{x}_i^\tau$ . 设计如下损失函数  $L$  进行端对端地训练 IAT 模型:

$$L = \frac{1}{N} \sum_{i=1}^N \frac{1}{T_i} \sum_{\tau=1}^{T_i} (\Delta \hat{x}_i^\tau - \Delta x_i^\tau)^2. \quad (12)$$

其中:  $T_i$  为单体  $i$  的全部决策样本数,  $\Delta x_i^\tau$  为决策样本标签,  $(\Delta \hat{x}_i^\tau - \Delta x_i^\tau)$  为 IAT 模型的输出误差.

## 1.2 模型训练数据及其预处理方法

鱼群数据采用文献[7]中的11小时5条红鼻剪刀鱼的运动数据, 实验环境如图1(a)所示, 由于剪刀鱼运动具有突然加速转向、直线减速滑行的特点<sup>[20]</sup>, 利用小波变换进行多尺度提取每条鱼的速度谷点. 文献[7]指出, 速度的局部极小位置可看作剪刀鱼的运动决策点, 通过该位置分割, 焦点单体的运动决策可被交替表示成突然的朝向角度变化  $\delta \phi_i$  和一个紧随的直线运动距离  $l_i$ , 所以运动轨迹会被决策点间隔为一系列的直线段. 图1(d)显示了决策线段长度  $l_i^\tau$  与朝向角变化  $\delta \phi_i^\tau$ .

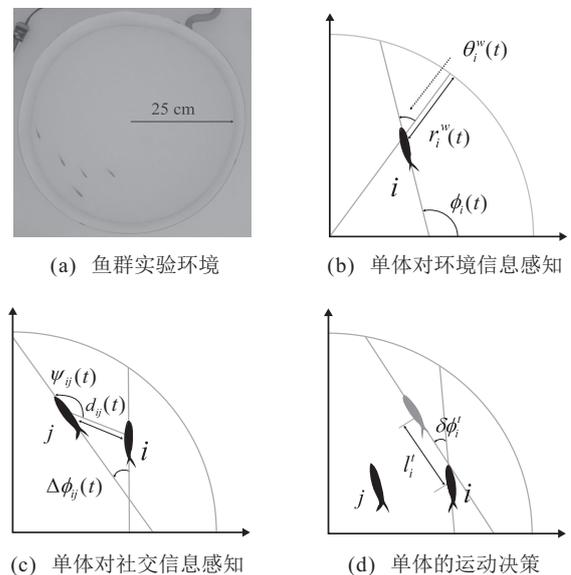


图1 鱼群实验以及相关运动参数

经决策分割、低速滤除、镜像操作后<sup>[7]</sup>, 11小时的鱼群实验总共分离出6万余条训练样本用于 IAT 模型训练. 考虑焦点单体在决策时刻的环境和邻居观测, 为获取邻居与环境的位置数据, 可将全局数据  $\{(x_i(t), y_i(t)) | i = 1, 2, \dots, N\}$  进行转换, 分离出自身位置信息  $X_i^t = [r_i^w(t), \theta_i^w(t), 0]^T$  (如图1(b)所示). 其中: 0 元素为占位符, 目的是使其符合  $f_{\text{ENC}}(\cdot)$  编

码器的输入结构;  $r_i^w(t)$  为焦点单体  $i$  到边界的距离;  $\theta_i^w(t)$  为焦点单体  $i$  相对边界的角度. 全局数据还能分离出邻居  $j$  的相对信息, 如图 1(c) 所示, 焦点单体  $i$  对邻居  $j$  的测量信息为  $X_{ij}^t = \{d_{ij}(t), \psi_{ij}(t), \Delta\phi_{ij}(t) | j \in N_i\}$ . 其中:  $d_{ij}(t)$  为焦点单体  $i$  到邻居  $j$  的距离,  $\psi_{ij}(t)$  为焦点单体  $i$  观测邻居  $j$  的视角,  $\Delta\phi_{ij}(t)$  表示邻居  $j$  相对于焦点单体  $i$  的航向角差. 转换公式分别为

$$r_i^w(t) = R_w - \sqrt{x_i(t)^2 + y_i(t)^2}, \quad (13)$$

其中  $R_w$  为实验边界半径;

$$\theta_i^w(t) = \phi_i(t) - \arctan(y_i(t)/x_i(t)); \quad (14)$$

$$d_{ij}(t) = \sqrt{(x_j(t) - x_i(t))^2 + (y_j(t) - y_i(t))^2}; \quad (15)$$

$$\psi_{ij}(t) = \arctan\left(\frac{-(x_j(t) - x_i(t)) \sin(\phi_i(t)) + (y_j(t) - y_i(t)) \cos(\phi_i(t))}{(x_j(t) - x_i(t)) \cos(\phi_i(t)) + (y_j(t) - y_i(t)) \sin(\phi_i(t))}\right); \quad (16)$$

$$\Delta\phi_{ij}(t) = \phi_j(t) - \phi_i(t). \quad (17)$$

$\phi_i(t)$  和  $\phi_j(t)$  分别为  $t$  时刻焦点单体  $i$  与邻居  $j$  的朝向

角; 焦点单体  $i$  变化后的朝向角  $\phi_i(t + \Delta t)$  可由相邻两决策时刻单体  $i$  的位置计算, 即

$$\phi_i(t + \Delta t) = \arctan\left(\frac{y_i(t + \Delta t) - y_i(t)}{x_i(t + \Delta t) - x_i(t)}\right), \quad (18)$$

$(t + \Delta t)$  时刻为  $t$  时刻决策的后续决策时间. 以上数据为 IAT 模型的输入信息. 文献 [20] 研究表明, 单体的转向决策比距离决策更重要, 因此, 本文采用与文献 [7] 相同的随机方法生成直线运动距离  $l_i^t$ , 则 IAT 模型的决策输出的  $\Delta x_i^t$  仅包括朝向角度变化  $\delta\phi_i^t$ , 即

$$\delta\phi_i^t = \phi_i(t + \Delta t) - \phi_i(t). \quad (19)$$

## 2 深度网络模型结构与训练方法

根据上节介绍的 IAT 原理设计模型的具体网络结构, 如图 2 所示, 主要包括信息输入编码器网络、图注意力网络、信息筛选聚合单元以及决策输出解码器网络等 4 个部分. IAT 的模型输入为决策时刻焦点单体测量自身的位置信息与邻居的相对信息, 模型输出为焦点单体的转角决策. 训练开始时, 焦点单体可以与所有邻居交互, 随着训练的深入, IAT 模型将会逐渐筛选出高注意力的重点邻居, 最终实现重点邻居的稀疏交互.

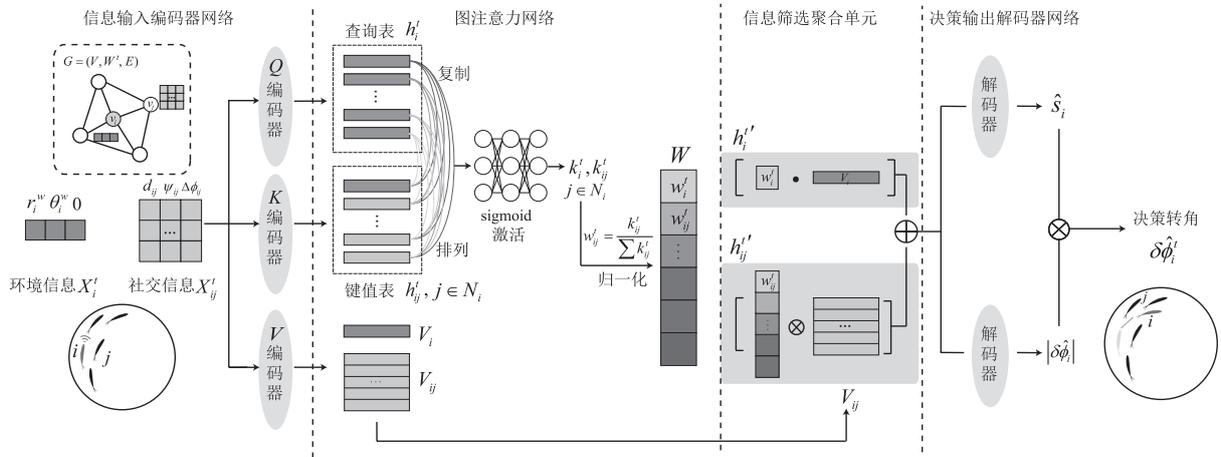


图 2 单体注意力交互网络的模型结构

### 2.1 IAT 模型的编码器结构

IAT 的输入编码器网络对应于原理式 (3) 和 (4). 首先需要将观测数据  $X_i^t$  和  $X_{ij}^t$  ( $j \in N_i$ ) 按顺序排成列表, 然后依次输入到编码器中生成高维隐式向量. 编码器采用 3 层深度网络结构, 每层神经元分别为 3、128、40. 首层 3 个神经元对应于输入信息的维度, 末层 40 个神经元代表编码后的输出向量维度. 神经元之间使用如下的 Mish 激活函数:

$$y = x \cdot \tanh(\ln(1 + e^x)). \quad (20)$$

该函数具有较好的平滑特性, 有助于网络模型训练与高维隐式信息输出 [21].

考虑到后续焦点单体  $i$  需要利用注意力匹配自身位置与邻居位置, 因此, IAT 模型在编码器设计上借鉴了 Transformer 网络 [22], 配置了 3 个同构的编码器, 分别为键编码器  $K$ 、查询编码器  $Q$  和值编码器  $V$ . 其中: 查询编码器  $Q$  用于将自身位置  $X_i^t$  编码成高维隐式查询信息  $h_i^t$ , 复制查询信息  $h_i^t$   $N$  次便可构建查询表; 键编码器  $K$  用于将邻居相对位置  $X_{ij}^t$  升维转化为  $h_{ij}^t$ , 联合一个  $h_i^t$  与所有  $h_{ij}^t$  可以形成  $N$  元素键值表; 最后将  $X_i^t$  和  $\{X_{ij}^t | j \in N_i\}$  输入到  $V$  编码器中, 分别获得焦点单体  $i$  的隐式高维值  $V_i$  和邻居隐式高维值  $V_{ij}$ ,  $j \in N_i$ , 用于注意力决策交互. 将查询表与键

值表拼合,然后根据原理式(5)和(6),利用注意力网络分别生成注意力权重 $k_i^t$ 和 $k_{ij}^t$ , $j \in N_i$ .值得指出的是,为了减少 $Q$ 、 $K$ 编码器的干扰,专门设计两个 $V$ 编码器,分别生成 $V_{ij}$ 和 $V_i$ 来代替原理式(3)、(4)的 $h_{ij}^t$ 和 $h_i^t$ ,能使后续信息聚合单元的信息解耦程度更高,重要信息的传播路径更清晰.

## 2.2 IAT注意力信息聚合下的解码机制

设计原理式(5)所对应的深度注意力网络,采用4层前馈神经网络结构,每层神经元分别为80、64、32、1.为保证收敛速度,选择 $\tanh(\cdot)$ 作为中间层激活函数,其中输入神经元数80对应于40维的查询表与键值表拼合所形成的向量组 $(h_i^t \oplus h_i^t)$ 和 $(h_{ij}^t \oplus h_{ij}^t)$ , $j \in N_i$ .网络输出为焦点单体 $i$ 的注意力系数 $k_i^t$ 和 $k_{ij}^t$ ,表征了查询表与键值表之间每行元素的相关性.接着利用原理式(7)、(8)计算规范化注意力权重 $w_i^t$ 和 $w_{ij}^t$ ,其中注意力网络输出层的激活函数 $\sigma(\cdot)$ 选用sigmoid函数<sup>[8]</sup>.

获取注意力权重后,焦点单体就可以利用注意力筛选出重点邻居用于决策.IAT模型利用信息筛选聚合单元配合解码器来输出转角决策 $\delta\hat{\phi}_i^t$ ,即图1(d)所示的朝向角变化.生物学研究发现,鱼类头部处于特定朝向时,负责解码转向的神经细胞就会持续活跃<sup>[23]</sup>.因此,根据原理式(9)、(10)、(11),经多次实验测试,利用两套相同结构的解码器分别输出转角的符号 $\hat{S}_i$ 与大小 $|\delta\hat{\phi}_i^t|$ ,有利于获取最优的模型训练效果,为此设计如下的转向决策网络结构:

$$\hat{S}_i = \text{sign}\left(f_{\text{DEC1}}\left(w_i^t V_i \oplus \sum_{j=1, j \neq i}^N w_{ij}^t V_{ij}\right)\right), \quad (21)$$

$$|\delta\hat{\phi}_i^t| = \left|f_{\text{DEC2}}\left(w_i^t V_i \oplus \sum_{j=1, j \neq i}^N w_{ij}^t V_{ij}\right)\right|. \quad (22)$$

其中: $\text{sign}(\cdot)$ 为符号函数; $f_{\text{DEC1}}(\cdot)$ 为转角符号的解码网络,左转输出为1,右转输出为-1; $f_{\text{DEC2}}(\cdot)$ 为转角大小的解码网络.两解码网络采用相同的神经元结构,每层神经元数目分别为80、128、128、64、1,其中输入维度80反映了信息筛选聚合单元的输出向量 $\left(w_i^t V_i \oplus \sum_{j=1, j \neq i}^N w_{ij}^t V_{ij}\right)$ 维度.

## 2.3 IAT注意力信息聚合下的解码机制

根据原理式(12)和IAT模型输出(21)、(22)设计损失函数,由于模型含有两个输出,总损失 $f_{\text{loss}}$ 可以分解为两部分输出的损失之和,即

$$f_{\text{loss}} = f_{\text{loss1}} + f_{\text{loss2}}. \quad (23)$$

其中:转角符号输出 $\hat{S}_i^t$ 的损失函数为 $f_{\text{loss1}}$ ,转角大小

输出 $|\delta\hat{\phi}_i^t|$ 的损失函数为 $f_{\text{loss2}}$ .因转角符号输出属于分类问题,故可采用交叉熵损失函数,有

$$f_{\text{loss1}} = -\sum_{t=1}^T s_i^t \log(\hat{s}_i^t), \quad (24)$$

其中 $T$ 为训练样本总数.因转角大小输出属于回归问题,故选用均方误差函数作为损失函数,有

$$f_{\text{loss2}} = \frac{1}{N} \sum_{t=1}^T (|\delta\hat{\phi}_i^t| - |\delta\phi_i^t|)^2. \quad (25)$$

使用留出法随机地将样例的20%标记为测试集,剩余的数据作为训练集.使用Pytorch深度网络框架编写IAT模型,训练主机为Dell T630服务器,配置NVIDIA GeForce RTX 2080 Ti GPU.使用AdamW优化器来最小化损失函数,学习率为 $5e-5$ ,同时采用小批量梯度下降策略,批量大小设置为1024,AdamW优化器中的权重衰减设为0.0005,在训练过程中采用早停法.

## 3 网络模型的集群运动仿真分析

为验证所提出IAT交互分析模型的集群运动生成能力,基于LabVIEW程序编写了多智能体仿真程序.该程序通过自主通讯协议,在单智能体 $i$ 的决策时刻 $\tau$ 向Python编写的IAT模型发送所有邻居信息 $X_{ij}^\tau$ 以及自身位置信息 $X_i^\tau$ ,IAT输出转向决策 $\delta\hat{\phi}_i^\tau$ 及注意力权重 $w_{ij}^\tau$ .根据文献[20]的方法,利用伽马分布随机生成直线运动长度 $l_i^\tau$ ,朝向角 $\phi_i(t)$ 更新为 $\phi_i(t) + \delta\hat{\phi}_i^\tau$ ,然后进入仿真循环.每个仿真周期所有智能体仿真运动长度设为 $\Delta l = 0.2 \text{ mm}$ ,于是焦点单体的位置按下式更新:

$$\begin{bmatrix} x_i(t + \Delta t) \\ y_i(t + \Delta t) \\ L_i(t + \Delta t) \end{bmatrix} = \begin{bmatrix} x_i(t) \\ y_i(t) \\ L_i(t) \end{bmatrix} + \begin{bmatrix} \Delta l \cdot \cos(\phi_i(t)) \\ \Delta l \cdot \sin(\phi_i(t)) \\ -\Delta l \end{bmatrix}. \quad (26)$$

当运动距离变量 $L_i(t) \leq 0$ 时,重新向IAT模型发送智能体的观测信息,开启新一轮的决策运动.如果仿真运动中式(13)的边界距离 $r_i^w(t)$ 小于鱼类身长(30 mm)时,则根据文献[8]方法强制 $L_i(t) = 0$ ,使智能体 $i$ 开启新一轮决策运动,以保证单体对撞墙动作的及时调整,保存所有智能体的仿真运动轨迹和朝向数据以备后续分析.

### 3.1 智能体成对仿真结果分析

由于IAT模型使用5条鱼的运动数据训练而成,为验证该交互模型的有效性,本文使用两智能体进行IAT模型交互仿真.

记录1小时的仿真运动数据,并与真实两鱼实

验数据的概率密度函数(probability density function, PDF)进行对比,如图3所示. 图3(a)展示了智能体的转角决策 $\delta\phi$ 分布. 曲线表明,IAT模型仿真与真鱼实验的转向决策角峰值均出现在 $\pm 20^\circ$ ,但IAT仿真输出的分布更陡峭,这是因为真鱼决策具有随机性,所以分布趋于平缓,而深度网络模型能滤除鱼群数据噪声,消除单体的个性化决策,还原了集群运动的决策机理,从而使输出更加确定. 图3(b)显示了两智能体运动的对齐性 $\lambda$ ,其被定义为邻居 $j$ 位置连线与焦

点单体 $i$ 轴线之间的夹角 $\varphi_{ij}$ (锐角), $0^\circ$ 表示邻居在焦点单体的轴线上, $90^\circ$ 表示邻居在焦点单体的垂直侧线上. 该图表明,无论是仿真还是真鱼,邻居大多出现在焦点单体的前、后方向 $\varphi_{ij} \approx 0^\circ$ ,较少出现在焦点单体的两侧 $\varphi_{ij} \approx 90^\circ$ . 同样,IAT模型仿真的对齐性分布也相对于真鱼集中. 图3(c)和图3(d)表明,两智能体(鱼)具有相似的边界距离 $r_w$ 和边界角度 $\theta_w^+ = |\theta_w|$ 分布,说明运动体都靠近边界,运动方向与圆边界切线平行.

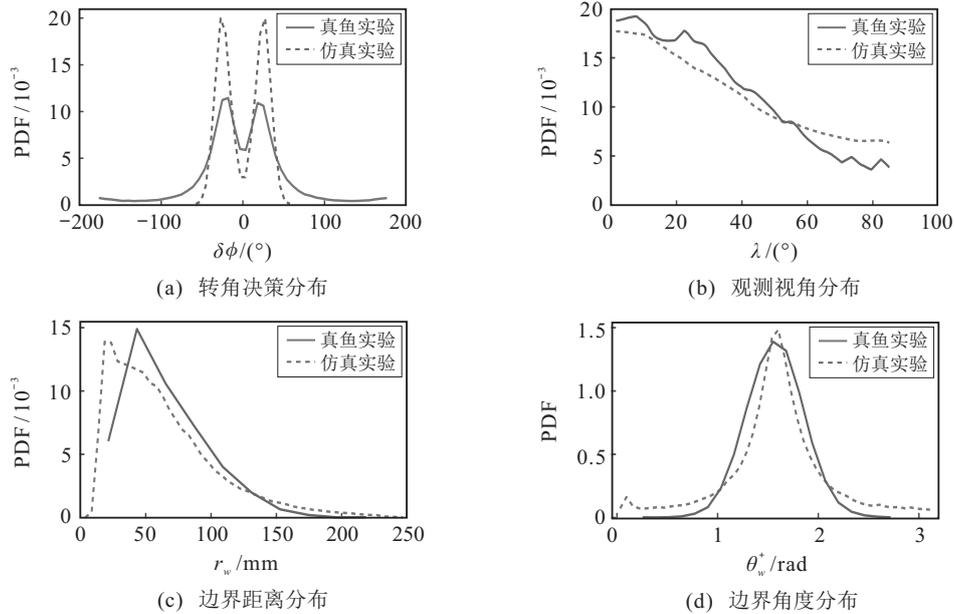


图3 两智能体仿真与两鱼运动实验的集群特征分布

虽然权威生物学研究认定鱼类的集群运动涌现源于视觉交互<sup>[5]</sup>,但是这一论断一直缺乏有效的科学证据. 为揭示鱼群运动的交互机理,对两智能体的IAT模型进行参数敏感性分析. 将焦点单体固定在仿真环境中心,在实验边界内任意改变邻居的相对位置,可视化IAT网络的注意力权重 $w_{12}$ ,如图4(a)所示,浅色区域的注意力较大,深色区域的注意力较小. 需要指出的是,IAT模型的注意力权重在输出前进行过规范化操作,所以取值范围在(0,1)区间. 图4中显示:在焦点单体前方形成了浅色的高注意力扇形区域,越靠近焦点单体,注意力越高;焦点单体的后方是低注意力区域. 与文献[24]所做的鱼类视觉研究对比发现,鱼类的视觉范围大致被分成3部分:前方的锥形空间是高注意力区域,周边是一般注意力区域,后端是视觉遮挡区域,如图4(b)所示. 但由于缺乏行之有效的数据分析工具,文献[24]并没有给出注意力的精确形状,而利用所提出的IAT工具就可以通过集群数据精确地挖掘出微观层面单体隐藏的注意力机制. 另外,该结果也表明生物的视觉交互与机器学习的注

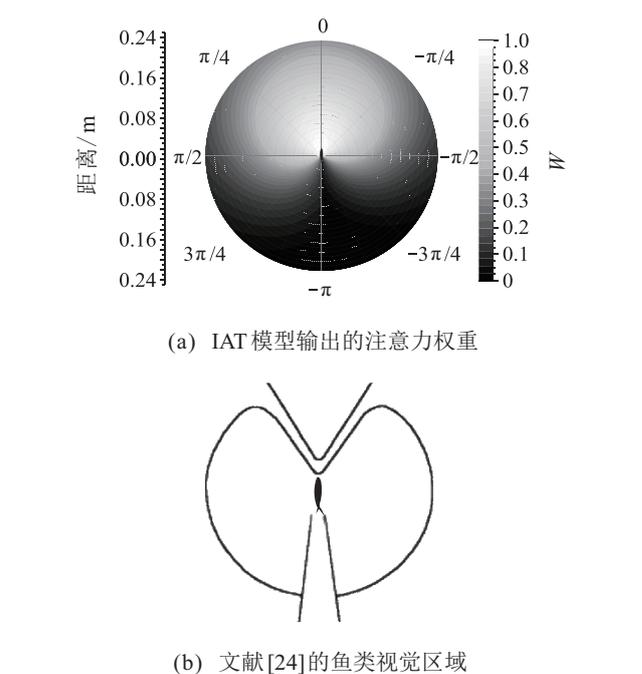


图4 网络工具输出与生物实验研究的视觉注意区域对比. 注意力之间具有较强的相关性. 可见IAT网络工具有效解耦复杂运动数据,还原单体耦合决策,自动生成

交互模型,具有作为复杂系统解耦分析标准工具的潜力,可用于揭示整体与元素之间的跨尺度交互关系。

### 3.2 网络模型的泛化能力分析

为分析IAT模型的泛化能力,将5鱼运动数据训练得到的IAT模型应用于不同规模的智能体仿真,因为IAT模型的输入对邻居信息 $X_{ij}^t(j \in N_i)$ 的排序没有要求,所以理论上可以进行任意数量的集群运动仿真。为此,进行2~100智能体规模的仿真实验来验证所提出工具的泛化性能。

下面定义2个集群运动宏观指标:集群大小和集群极性,以观测不同集群规模下宏观指标的变化。首先考虑集群重心位置 $p_B = (x_B(t), y_B(t))$ 以及群体重心速度 $v_B = (v_B^x(t), v_B^y(t))$ ,两者计算公式如下:

$$x_B(t) = \frac{1}{N} \sum_{i=1}^N x_i(t), y_B(t) = \frac{1}{N} \sum_{i=1}^N y_i(t); \quad (27)$$

$$v_B^x(t) = \frac{1}{N} \sum_{i=1}^N v_i^x(t), v_B^y(t) = \frac{1}{N} \sum_{i=1}^N v_i^y(t). \quad (28)$$

其中:单体速度是由单体位置向后一步差分得到, $N$ 是集群智能体总数。于是集群极性定义为

$$P(t) = \frac{1}{N} \left\| \sum_{i=1}^N e_i(t) \right\|, P(t) \in [0, 1]. \quad (29)$$

其中 $e_i(t) = (\cos(\phi_i(t)), \sin(\phi_i(t)))$ 表示智能体 $i$ 朝向的单位向量:当 $P(t) = 1$ 时,表示所有智能体的航向相同;当 $P(t) = 0$ 时,表示所有智能体发散。

另一指标群体大小定义为

$$C(t) = \sqrt{\frac{1}{N} \sum_{i=1}^N \|p_i - p_B\|^2}, \quad (30)$$

其中 $\|p_i - p_B\|$ 是智能体 $i$ 到多智能体重心 $B$ 的距离。 $C(t)$ 越小表示群体越紧密,反之群体越分散。

分别进行1小时 $N = 2, 3, 7, 10, 20, 30, 50, 60, 80, 100$ 的智能体集群运动仿真,统计集群极性 $P$ 与集群大小 $C$ 的变化曲线如图5所示。图5(a)的实线显示,集群极性的数据方差随着群体规模的扩大而逐渐变小,并且在 $N = 10$ 开始集群极性就始终接近于1,表明随着群体规模的增大,系统的宏观指标逐渐变得确定,具有整体结构涌现加强的趋势;图5(a)的虚线显示,集群大小和集群极性的数据方差随集群规模的扩大而变小,虽然小规模集群涌现的聚集效应不明显,但汇聚作用会随着群体规模的扩大而愈发强化。

图5(b)显示了集群所有单体的距墙距离(实线)和距墙角度绝对值(虚线)的统计。结果表明,无论集群规模如何变化,所有单体的运动方向基本平行于边界,均值保持在 $90^\circ$ 附近,方差稳定。距墙距离表明,随

着规模的扩大,指标方差逐渐收缩,在 $N = 10$ 处开始稳定,并能一直保持较稳定的运动集群。

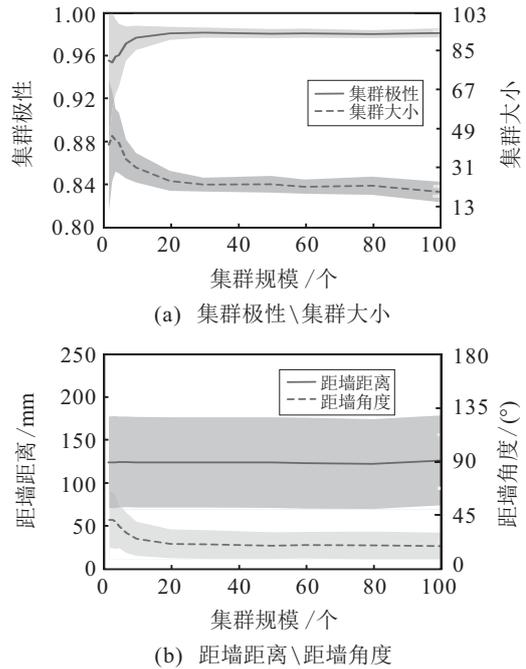


图5 不同规模集群运动指标分析

### 3.3 不同集群交互模型的仿真对比

为观测模型的集群运动效果,分别将经典Vicsek模型<sup>[4]</sup>、最强视觉DNN模型<sup>[8]</sup>、最大影响力模型<sup>[7]</sup>以及IAT模型进行不同规模的仿真实验,统计集群运动的宏观指标,仿真结果如表1所示。由表1可见:在集群规模 $N$ 为2、3、4时,最强视觉DNN模型的集群极性最好,集群最紧凑;在集群规模超出5以后,所提出的IAT模型的宏观指标最优,不但集群极性高,紧凑性还好,而且具有较小的统计方差,表明IAT模型具有较强的集群运动迁移能力。最强视觉DNN模型之所以在小规模集群运动中有较好的效果是因为该模型训练数据是2鱼运动数据,并且学习的都是“反应式”决策,所以在还原小规模集群( $N < 5$ )时能够涌现出较好的运动效果;但随着集群规模的扩大,最强视觉DNN模型的性能就会持续下降。而IAT模型训练来自5鱼运动数据,并且从中学习到了更高层的“慎思式”注意力决策,所以集群规模在 $N > 5$ 以后就逐渐保持了最好的性能,并且随着规模的扩大,系统的集群运动稳定性也越加强化,符合复杂系统的涌现特性。

经典的Vicsek模型主要针对无约束的物理自推进粒子仿真而设计,属于连续交互模型,需要单体时刻给出交互决策,高频控制输出,所以不适合分布式控制器设计。针对剪刀鱼群的运动模式,由于存在环境边界限制、鱼类非完整性约束以及决策、运动交替

表1 不同集群运动模型仿真的集群极性与大小

N	Vicsek 模型 <sup>[4]</sup>		最大影响力模型 <sup>[7]</sup>		最强视觉DNN模型 <sup>[8]</sup>		IAT模型	
	P	C	P	C	P	C	P	C
2	(0.48±0.29)	(929.77±285.71)	(0.95±0.07)	(297.07±189.27)	<b>(0.99±0.01)</b>	<b>(52.8±30.41)</b>	(0.95±0.07)	(297.07±189.27)
3	(0.58±0.22)	(836.64±224.83)	(0.94±0.05)	(314.24±123.6)	<b>(0.99±0.01)</b>	<b>(81.62±34.89)</b>	(0.94±0.05)	(314.24±123.6)
4	(0.59±0.23)	(783.33±264.14)	<b>(0.99±0.01)</b>	(164.89±3.66)	(0.97±0.04)	<b>(124.55±73.95)</b>	(0.95±0.04)	(284.62±100.52)
5	(0.5±0.25)	(878.74±247.59)	<b>(0.98±0.04)</b>	(261.49±55.4)	(0.89±0.18)	(200.7±151.4)	(0.96±0.02)	<b>(247.58±69.44)</b>
7	(0.44±0.16)	(936.38±143.04)	(0.86±0.23)	(401.54±222.09)	(0.83±0.13)	(296.42±117.86)	<b>(0.97±0.02)</b>	<b>(219.21±48.84)</b>
10	(0.42±0.15)	(958.43±118.77)	(0.88±0.15)	(404.25±174.65)	(0.91±0.06)	(209.13±72)	<b>(0.98±0.01)</b>	<b>(180.3±41.59)</b>
20	(0.62±0.14)	(752.65±139.82)	(0.53±0.25)	(736.52±174.58)	(0.45±0.09)	(506.49±46.74)	<b>(0.98±0.01)</b>	<b>(146.18±23.31)</b>
30	(0.68±0.05)	(661.15±60.6)	(0.26±0.12)	(869.37±70.8)	(0.79±0.03)	(319.32±35.96)	<b>(0.98±0.01)</b>	<b>(148.22±17.68)</b>
50	(0.73±0.04)	(606.95±48.18)	(0.18±0.09)	(881.13±57.03)	(0.75±0.05)	(343.03±37.22)	<b>(0.98±0.01)</b>	<b>(151.67±34.9)</b>
60	(0.64±0.03)	(726.07±30.68)	(0.16±0.08)	(884.31±43.93)	(0.76±0.03)	(343.78±25.31)	<b>(0.98±0.01)</b>	<b>(163.36±48.03)</b>
80	(0.72±0.03)	(624.3±47.46)	(0.13±0.06)	(876.62±46.9)	(0.88±0.01)	(230.81±15.33)	<b>(0.98±0.01)</b>	<b>(174.94±85.99)</b>
100	(0.62±0.03)	(766.17±21.12)	(0.1±0.05)	(868.6±48.96)	(0.84±0.01)	(287.95±13.19)	<b>(0.98±0.01)</b>	<b>(202.23±117.81)</b>

等特点,使得经典Vicsek模型的性能在同类方法中表现较差,基本无法对稀疏决策集群形成汇聚作用.最大影响力模型利用2鱼运动模型进行叠加输出决策,其原理与最强视觉DNN模型相似,所以在小规模集群中具有一定的性能优势,但随着规模的扩大,仅利用2鱼运动数据训练的模型都会在汇聚力方面出现较大缺陷.而IAT模型能利用编码器网络将单体的观测数据映射到高维空间,提升了模型层次,有利于后续的图注意力网络筛选出邻居间的交互强度,从而合理安排高层次的运动分配,胜任对更多邻居信息聚合的迁移性解释;将筛选出的聚合信息解码到低维决策空间,有利于生成稳定的大规模集群运动.

### 3.4 大规模集群的汇聚过程分析

随机生成100个智能体的初始位置、朝向,观测仿真运动群体极性和大小的时间序列曲线,如图6所示.结果表明,IAT模型可以在3min以内涌现出有序汇聚,并且可以长时间保持汇聚的高极性与紧凑性,体现了大规模集群收敛的稳定性.

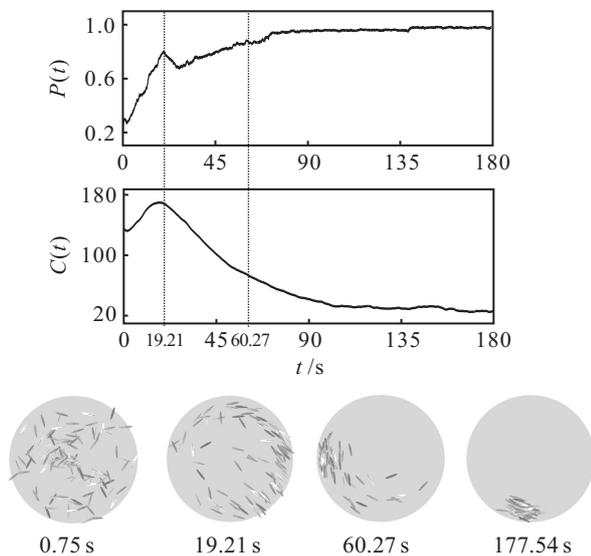


图6 100个智能体集群运动的汇聚过程

需要指出的是,IAT模型训练使用的是5鱼平稳运动数据,原始鱼群数据分布始终保持在较高的极性和较汇聚的状态,这与图6的实验初始分布完全不同.根据统计学习理论,机器学习模型难以在不同分布条件下实现泛化迁移,得益于创新的软性注意力抽取,可以在较高层次上获取数据的汇聚因果关系.尽管底层数据存在较大的分布偏移,但由于注意力模型提取了较高层次的信息耦合机制,使得模型即使在严苛随机的初始条件下也能获得较好的集群性能,说明IAT网络具备高层信息交互的可解释性,能应对复杂系统运动的因果机制挖取.

## 4 结论

不失一般性,本文设计了一种基于IAT网络的鱼群运动分析工具,该工具既能解析生物集群内部稀疏的信息耦合机制,又能挖掘出复杂系统内部单体之间的隐性交互关系.IAT网络将焦点单体的环境与社交信息区别处理、异步更新,所以与生物学中的隐式注意力研究<sup>[18]</sup>具有较强的相关性,使得IAT在复杂系统自动建模领域实现了生物注意力机制,能将鱼群内部单体的稀疏选择交互解释为注意力权重,在一定程度上解决了复杂系统深度学习模型的可解释性问题<sup>[25]</sup>,因而能应对复杂系统自组织研究的宏观-微观跨尺度机理分析,可以作为一种人工智能标准工具应用于多种复杂系统行为研究.

多智能体运动仿真表明,所提出的IAT网络能形成较为稳定的集群运动.两智能体仿真的可视化结果印证了鱼类生理视觉模型<sup>[24]</sup>.2~100智能体仿真结果表明,IAT具有较强的多尺度泛化能力,相较于其他多智能体交互模型,在大规模尺度上具有更好的集群运动特性.100智能体运动的瞬态分析表明,IAT模型具有高效、稳定的汇聚性能.

综上所述,IAT既可以作为系统学科分析自然集

群的标准工具,同样其框架也可以应用在经济社会、集群机器人、智能交通系统等实际人工复杂系统上。因此,本课题组下一阶段将在自主知识产权的微型集群机器人上进行IAT网络的控制研究。一种思路是将所得的软注意力转换为硬注意力,目标是让单体机器人仅与1、2台高注意力邻居交互,就能生成稳定的运动机群,并针对更复杂的运动环境进行探索,以期促进集群机器人的大规模应用。

### 参考文献(References)

- [1] Xu X K, Small M, Pérez-Barberia F J. Uncovering interaction patterns of multi-agent collective motion via complex network analysis[C]. 2014 IEEE International Symposium on Circuits and Systems. Melbourne, 2014: 2213-2216.
- [2] Finn K R, Silk M J, Porter M A, et al. The use of multilayer network analysis in animal behaviour[J]. *Animal behaviour*, 2019, 149: 7-22.
- [3] Rosenthal S B, Twomey C R, Hartnett A T, et al. Revealing the hidden networks of interaction in mobile animal groups allows prediction of complex behavioral contagion[J]. *PNAS*, 2015, 112(15): 4690-4695.
- [4] Vicsek T, Czirók A, Ben-Jacob E, et al. Novel type of phase transition in a system of self-driven particles[J]. *Physical Review Letters*, 1995, 75(6): 1226-1229.
- [5] Couzin I D, Krause J, James R, et al. Collective memory and spatial sorting in animal groups[J]. *Journal of Theoretical Biology*, 2002, 218(1): 1-11.
- [6] Reynolds C W. Flocks, herds and schools: A distributed behavioral model[C]. *Proceedings of the 14th Annual Conference on Computer Graphics and Interactive Techniques*. New York: ACM, 1987: 25-34.
- [7] Lei L, Escobedo R, Sire C, et al. Computational and robotic modeling reveal parsimonious combinations of interactions between individuals in schooling fish[J]. *PLoS Computational Biology*, 2020, 16(3): e1007194.
- [8] 刘磊, 孙卓文, 陈令仪, 等. 基于深度学习的仿生集群运动智能控制[J]. *控制与决策*, 2021, 36(9): 2195-2202.  
(Liu L, Sun Z W, Chen L Y, et al. Intelligent control of bionic collective motion based on deep learning[J]. *Control and Decision*, 2021, 36(9): 2195-2202.)
- [9] Velikovi P, Cucurull G, Casanova A, et al. Graph attention networks[J/OL]. 2017, arXiv: 1710.10903.
- [10] Kipf T, Fetaya E, Wang K C, et al. Neural relational inference for interacting systems[J/OL]. 2018, arXiv: 1802.04687.
- [11] Jumper J, Evans R, Pritzel A, et al. Highly accurate protein structure prediction with AlphaFold[J]. *Nature*, 2021, 596(7873): 583-589.
- [12] Cavallari S, Poria S, Cambria E, et al. An attention-based model for learning dynamic interaction networks[C]. 2019 International Joint Conference on Neural Networks. Budapest, 2019: 1-8.
- [13] Wang R, Fang F T, Cui J M, et al. Learning self-driven collective dynamics with graph networks[J]. *Scientific Reports*, 2022, 12: 500.
- [14] Wu Z H, Pan S R, Chen F W, et al. A comprehensive survey on graph neural networks[J/OL]. 2019, arXiv: 1901.00596.
- [15] Ttanas A A, Cavagna A, Castello L D, et al. Emergence of collective changes in travel direction of starling flocks from individual birds fluctuations[J]. *Journal of the Royal Society Interface*, 2015, 12(108): 20150319.
- [16] Gilmer J, Schoenholz S S, Riley P F, et al. Neural message passing for quantum chemistry[J/OL]. 2017, arXiv: 1704.01212.
- [17] Riley D, Leith C R. Multidimensional psychophysics and selective attention in animals[J]. *Psychological Bulletin*, 1976, 83(1): 138-160.
- [18] Lindsay G W. Attention in psychology, neuroscience, and machine learning[J]. *Frontiers in Computational Neuroscience*, 2020, 14: 29.
- [19] Zaheer M, Kottur S, Ravanbakhsh S, et al. Deep sets[J/OL]. 2017, arXiv: 1703.06114.
- [20] Calovi D S, Litchinko A, Lecheval V, et al. Disentangling and modeling interactions in fish with burst-and-coast swimming reveal distinct alignment and attraction behaviors[J]. *PLoS Computational Biology*, 2018, 14(1): e1005933.
- [21] Misra D. Mish: A self regularized non-monotonic activation function[J/OL]. 2019, arXiv: 1908.08681.
- [22] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]. *Advances in Neural Information Processing Systems*. Long Beach, 2017: 5998-6008.
- [23] Vinepinsky E, Cohen L, Perchik S, et al. Representation of edges, head direction, and swimming kinematics in the brain of freely-navigating fish[J]. *Scientific Reports*, 2020, 10(1): 14762.
- [24] Sandström A. Visual ecology of fish — A review with special reference to percids[J]. *Fiskeriverket Rapport*, 1999, 2: 45-80.
- [25] Heuillet A, Couthouis F, Díaz-Rodríguez N. Collective eXplainable AI: Explaining cooperative strategies and agent contribution in multiagent reinforcement learning with shapley values[J]. *IEEE Computational Intelligence Magazine*, 2022, 17(1): 59-71.

### 作者简介

刘磊(1982—),男,副教授,博士,从事群机器人控制、集群智能涌现等研究, E-mail: liulei@usst.edu.cn;  
黄景然(1997—),男,硕士生,从事深度学习、集群智能涌现等研究, E-mail: h.jingran@foxmail.com;  
赵佳佳(1997—),女,硕士生,从事深度学习、多智能体集群运动等研究, E-mail: 157856595@qq.com;  
黄宇灵(2001—),女,本科生,从事多智能体智能控制的研究, E-mail: 1617483130@qq.com;  
高岩(1962—),男,教授,博士生导师,从事非光滑优化、生存控制等研究, E-mail: gaoyan@usst.edu.cn.

(责任编辑:李君玲)