

基于硬注意力机制下的鱼群涌现自动建模方法

刘磊^{1,2}, 陶宇², 高岩¹

(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: 生物集群的协同智能可用于启发人工复杂系统调控, 但是现有的自动建模方法往往不符合生物集群信息的处理特点, 导致单体的信息交互建模仍充满挑战。不失一般性, 借助红鼻剪刀鱼的集群运动数据设计符合生物硬注意力机制的深度网络模型, 该结构能强制单体考虑至多两个以内的邻居信息, 并能显现出高影响力邻居经常出没的隐藏位置, 说明硬注意力模型符合生物集群的信息处理机制。实验结果表明: 所提硬注意力模型具有较为良好的稀疏信息解耦能力、较为鲁棒的集群运动指标以及较为优秀的集群规模泛化性能, 为复杂系统的多层次行为分析提供了有力的工具支撑, 该方法对集群机器人的分布式控制具有较强的启发意义。

关键词: 生物集群智能; 复杂系统控制; 硬注意力模型; 集群机器人

中图分类号: TP 273 **文献标志码:** A

Automatic modeling method of fish schooling emergence based on hard attention mechanism

LIU Lei^{1,2}, TAO Yu², GAO Yan¹

(1. Business School, 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 study of biological collaborative intelligence can be used to inspire the regulation of artificial complex systems. However, most existing automated modelling approaches do not match the characteristics of biological collective information processing. The information mechanisms for modelling individual interaction are still full of challenges. Without loss of generality, a deep network model conforming to the biological hard attention mechanism was designed based on the collective motion data of hemigrammus rhodostomus. The designed model structure forced the individual to consider less than two neighbors information. In spite of such little information, the model could reveal

收稿日期: 2022-11-12

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

第一作者: 刘磊(1982-), 男, 副教授。研究方向: 复杂系统控制。E-mail: Liulei@usst.edu.cn

引文格式: 刘磊, 陶宇, 高岩. 基于硬注意力机制下的鱼群涌现自动建模方法[J]. 上海理工大学学报, 2024, 46(3): 347-356.

DOI: 10.13255/j.cnki.jusst.20221112003

Citation: LIU Lei, TAO Yu, GAO Yan. Automatic modeling method of fish schooling emergence based on hard attention mechanism[J]. Journal of University of Shanghai for Science and Technology, 2024, 46(3): 347-356.

the hidden place, where the high-impact neighbors located frequently. Thus, the hard attention model coincided with the information processing mechanism of biological collective interaction. The experimental results showed that the proposed hard attention model had better sparse information decoupling capability, more robust collective motion metrics and better collective scale generalization performance. The proposed model provides a powerful tool to support multi-levels behavior analysis of complex systems. Moreover, this method had strong inspirational significance for distributed controller design of swarm robotics.

Keywords: *biological collective intelligence; complex systems control; hard attention model; swarm robotics*

自然界中的生物集群会通过自组织产生有序的宏观结构，如细胞群极性排列^[1]，鱼群集体巡游、鸟群编队飞行^[2-3]，兽群协同迁徙等^[4-5]，这些集群中的单体都能凭借与周边信息的交互使群体生成具有特定功能的宏观“图样”，从而确保种群具有更强的生存繁衍能力。一直以来，生物集群协同研究可以深度启发人工复杂系统的分布式控制策略，相较于经典控制理论^[6]，生物集群协同控制模型能使人工集群系统运动更具鲁棒性与灵活性^[7]，所以能作为复杂系统调控的重要参考。

然而分析生物集群的内部信息传递与交互策略极具挑战，究其原因在于还无法直接解释生物体应对复杂集群场景时的真实脑神经信号处理机制，导致现有的集群运动研究多采用主观性较强的人工模型设计方案，如著名的 Vicsek 模型。该模型假定单体能与周边所有邻居进行交互，可以形成稳定的集群运动^[8]，但是其应用于实际人工集群控制却极为困难^[9]，需要依赖专家经验花费大量时间来进行模型调整。Couzin 模型^[10]以及图网络模型^[11]等类似方法同样要求单体具有多源信息处理能力，这明显与生物单体有限的脑进化水平相矛盾，可见如何解释单体有目地的选择多邻居信息进行交互仍充满挑战。领域专家 Theraulaz Guy 近期研究认为鱼类集群中的单体应仅与少量邻居交互就能保持足够的群体凝聚力^[12]。文献 [13] 也表明：鱼类单体最多选择两个邻居交互就能形成稳定的集群运动，但是重点交互邻居的选择方法却比较复杂，可见采用传统的建模方法还不足以应对这类开放的科学难题。

由于交互数据会随着集群规模的扩张而呈指数性增长，目前只有基于大数据的机器学习方法才有能力对抗这种规模的复杂性，现在正处于深度学习方法逐渐向各研究领域全面渗透的时期，

于是出现了一些集群运动相关的深度网络模型，如通过两鱼实验数据提出的最强视觉 DNN 模型^[14-15]。该模型具有一定的生物集群控制效果，并能应用于集群机器人实际，但这类交互模型受限于深度网络臭名昭著的“黑箱”特性，使得模型内部的交互机理还不具备可解释性。如何从数据之中客观解耦出单体关注的重点邻居，并量化交互强度仍是未解的科学难题，所以亟需设计一种可解释的自动建模方法来帮助挖掘生物体的信息交互机理，以明晰集群内部的信息传递路径。为此，尝试设计一种硬注意力模型结构来生成微观层面单体的交互行为，其中硬注意力机制会考虑两个以内的邻居信息，从而在物理层面约束了集群交互的计算负荷，并能找出单体影响力最大的邻居，以期解耦鱼类神经响应行为的内在本质。

1 实验方法与数据处理

1.1 集群实验设计与相关运动参数

红鼻剪刀鱼体型小巧、行动敏捷，成年体长约 3 cm，有良好的集群特性，即使少量单体也能产生较强的集群运动效果。将该鱼作为实验对象，放置在半径为 25 cm 的浅水圆环内，使用高清摄像机记录 5 条鱼累计 11 h 的运动视频，如图 1(a) 所示，利用软件识别提取出鱼群的运动轨迹。实验数据分析发现，剪刀鱼具有瞬间转向加速、直线滑行的运动模式^[16]，为方便决策建模，可将单体运动简化为连续交替的转向-直游运动决策，最终将 5 条鱼的运动轨迹离散化为 5 组决策线段，单体在线段的端点处进行决策转向。由于实验鱼群多数时间处于休息状态，不利于集群运动的机器学习模式提取，所以保留鱼群单体速度大于 6.6 cm/s (约每秒 2 倍体长) 的轨迹数据，最后总共




图1 鱼群运动实验和相关运动参数

Fig.1 The fish schooling experiment and related parameters

提取出 6 万余条合格数据用于模型训练。

1.2 实验数据预处理

将轨迹的坐标系原点设定在圆形实验环境中心, 环境半径 R_W 为 25 cm, 如图 1(a) 所示。规定

$$\psi_{ij}(t) = \arctan \left(\frac{-(x_j(t) - x_i(t)) \sin(\phi_i(t)) + (y_j(t) - y_i(t)) \cos(\phi_i(t))}{(x_j(t) - x_i(t)) \cos(\phi_i(t)) + (y_j(t) - y_i(t)) \sin(\phi_i(t))} \right) \quad (4)$$

$$\Delta\phi_{ij}(t) = \phi_j(t) - \phi_i(t) \quad (5)$$

单体 i 在获取环境与社交信息后, 会在决策时刻生成新一次的转向角度和直游距离, 以满足集群运动的需要。假定 t 时刻为单体 i 的决策时刻, 如图 1(d) 所示。 δ_i^t 表示单体 i 的转角决策, 体现了单体决策前后的航向角变化, l_i^t 为单体 i 的直游距离, 即该单体到达下一次决策位置的直行距离, η_i^t 为单体 i 的游动时长, 体现为到达下一决策的运动时间, 所以 $(t + \eta_i^t)$ 为决策时刻 t 相邻的下次决策时刻。在下次决策之前, 单体 i 保持航向角不变的直线游动, 具体航向可用 $\phi_i(t + \eta_i^t)$ 表示, 由前后两次决策单体 i 的位置计算得到, 即

$$\phi_i(t + \eta_i^t) = \arctan \left(\frac{y_i(t + \eta_i^t) - y_i(t)}{x_i(t + \eta_i^t) - x_i(t)} \right) \quad (6)$$

根据式 (6) 可得出单体 i 的转角决策

$$\delta_i^t = \phi_i(t + \eta_i^t) - \phi_i(t) \quad (7)$$

直游决策可由决策位置的变化计算得到, 即

鱼群逆时针运动方向为正, 如图 1(b) 所示。在 t 时刻, 单体 i 与单体 j 的位置分别为 $(x_i(t), y_i(t))$ 和 $(x_j(t), y_j(t))$, 单体 i 的航向角为 $\phi_i(t)$ 。 $r_i^w(t)$ 为单体 i 相对边界的距离, $\theta_i^w(t)$ 为单体 i 相对边界的角度, 这两个参数在微观层面决定了单体的环境交互行为, 可由单体 i 的位姿与环境半径 R_W 计算得到, 即

$$r_i^w(t) = R_W - \sqrt{x_i(t)^2 + y_i(t)^2} \quad (1)$$

$$\theta_i^w(t) = \phi_i(t) - \arctan(y_i(t)/x_i(t)) \quad (2)$$

单体的社会交互如图 1(c) 所示, 在 t 时刻, 单体 i 通过视觉观察来探测邻居 j 的信息, 其中, $d_{ij}(t)$ 为单体 i 相对邻居 j 的距离, $\psi_{ij}(t)$ 为单体 i 观察邻居 j 的视角, $\Delta\phi_{ij}(t)$ 为邻居 j 相对单体 i 的航向角差, 该参数用于表征两单体之间的对齐程度, 特别当 $\Delta\phi_{ij} = 0$ 时表明两鱼平行, 从而具有较一致的运动方向, 是鱼群协同运动的主要方式。上述 3 个参数对建模单体的社会交互行为至关重要, 具体计算方法如下

$$d_{ij}(t) = \sqrt{(x_j(t) - x_i(t))^2 + (y_j(t) - y_i(t))^2} \quad (3)$$

$$l_i^t = \sqrt{(x_i(t + \eta_i^t) - x_i(t))^2 + (y_i(t + \eta_i^t) - y_i(t))^2} \quad (8)$$

2 硬注意力网络模型结构与训练方法

鱼群交互行为的硬注意力网络模型如图 2 所示, 根据网络功能可将整体结构划分为两个独立单元: 转向网络和直游网络。此二者共享相同的硬注意力结构, 如图 2 所示的核心网部分, 核心网的上下两侧分别为输入数据与输出解码网络。其中, 转向网络的输入数据包括焦点单体 i 对环境的感知 $X_i^t = [r_i^w(t), \theta_i^w(t), 0]$ (0 为三元组占位符) 以及对其邻居的位置观察 $X_{ij}^t = [d_{ij}, \psi_{ij}, \Delta\phi_{ij}]$, $j \in N_i$, N_i 为单体 i 所有邻居的标号; 转向网络的输出为单体 i 的转角决策 δ_i^t , 如图 1(d) 所示, 获取转角决策 δ_i^t 后单体 i 进行转动, 则单体 i 对环境的感知角度信息被更新为

$$X_i^t = [r_i^w(t), \theta_i^w(t) + \delta_i^t, 0] \quad (9)$$




图2 硬注意力模型结构

Fig.2 Structure of hard attention model

与之对应，其邻居的观察角信息也被修正为

$$X'_{ij} = [d_{ij}, \psi_{ij} - \delta_i^t, \Delta\phi_{ij} - \delta_i^t], j \in N_i \quad (10)$$

将式(9)~(10)作为数据输入直游网络，上述操作相当于将直游网络串联在转向网络后方，先更新焦点单体 i 的航向，然后再输出直游距离 l_i^t 和游动时长 η_i^t 决策。由于两决策单元均采用了相同的硬注意力核心结构，该结构用于对焦点单体 i 关注的邻居进行稀疏提取，所以具有集群信息交互的可解释性。

2.1 硬注意力模型的核心网结构

图2中的核心网是进行集群硬注意力解耦的关键，是整个自动建模方法的核心，分别被嵌入在转向网络和直游网络中，核心网包括编码器

网、图注意力网、信息聚合组件以及预解码网四部分，其中编码器网部分借鉴了Transformer结构^[17]，该部分接收环境信息 X_i^t 和邻居信息 X'_{ij} ， $j \in N_i$ ，将这些信息排列组合成 $N_i + 1$ 个3元组列表，列表的第一项代表焦点单体自身，其余项表征邻居信息，然后将输入列表复制到3个同构的全连接网络：分别为查询编码器 Q 、键值编码器 K 以及数值编码器 V 。这三组编码器采用了相同的结构参数[3, 128, 40]，其中，输入层3神经元代表网络输入为三元组，输出层40神经元用于将输入信息提升到高维编码空间，各隐藏层之间使用Mish激活函数，即

$$y = x \cdot \tanh(\ln(1 + e^x)) \quad (11)$$

该激活函数具有类 Relu 函数特点,可保证有较深的梯度传播能力。同时,该函数还具有拐点光滑、正向单调的特性,既能较好地保持模型的输出稳定性,又能避免反向传播的梯度消失,有利于节点导数计算,所以适于复杂系统的可解释自动建模。环境数据(可看作焦点单体信息)经查询编码器 Q 升维并复制 $N_i + 1$ 次可构成查询表 $[Q_i, Q_{i1}, \dots, Q_{iN_i}]$, 输入列表经键值编码器 K 处理后会生成具有 $N_i + 1$ 项的键值表 $[K_i, K_{i1}, \dots, K_{iN_i}]$, 输入列表会被数值网络 V 转换成 $N_i + 1$ 项的高维值向量 $[V_i, V_{i1}, \dots, V_{iN_i}]$ 。

由于鱼类的脑神经系统具有有限的信息处理能力^[18], 这导致单体在集群之中无法同时处理所有邻居的信息, 根据文献^[13]给出的研究结论: 单体仅与一到两个邻居交互即可生成集群运动, 所以在核心网中设计硬注意力单元来强制单体仅与两个以内的重点邻居交互, 同时要保证单体基于少量邻居信息做出的决策还能符合宏观有序集群运动的生成。为此, 将查询表 $[Q_i, Q_{i1}, \dots, Q_{iN_i}]$ 与键值表 $[K_i, K_{i1}, \dots, K_{iN_i}]$ 拼接, 按行输入到负责注意力识别的全连接网络 $f_{MLP}(\cdot)$ 中, 该网络各层的神经元数目设置为 $[80, 64, 32, 1]$ 。由于 Tanh 激活函数的收敛速度较快, 所以隐藏层之间使用 Tanh 激活函数。为将注意力值映射到 $(0,1)$ 之间, 输出层采用 Sigmoid 激活函数 $\sigma(\cdot)$, 其中输入维度 80 代表查询表与键值表拼接后的元组维度。该网络经数据训练后能解析出焦点单体 i 对环境的注意力 k_i 和 N_i 个对邻居的注意力 k_{ij} 为

$$k_i = \sigma(f_{MLP}(K_i, Q_i)) \quad (12)$$

$$k_{ij} = \sigma(f_{MLP}(K_{ij}, Q_{ij})), j \in N_i \quad (13)$$

式中, k_{ij} 反映了单体 i 对不同邻居 j 的注意力程度。

为将鱼类整体的注意力约束在一个固定容量, 设计注意力归一化过程, 即将单体 i 的注意力总和 $\mathbf{W}_i + \sum_{j \in N_i} \mathbf{W}_{ij}$ 规范为 1, 具体方法为

$$\mathbf{W}_i = \frac{k_i}{\sum_{j \in N_i} k_{ij} + k_i} \quad (14)$$

$$\mathbf{W}_{ij} = \frac{k_{ij}}{\sum_{j \in N_i} k_{ij} + k_i} \quad (15)$$

找出邻居注意力权重 $\mathbf{W}_{ij}$ 最大的两个邻居(当

只有 1 个邻居时选 1 个), 最终得到焦点单体 i 对环境和两个邻居的权重 $[\mathbf{W}_i, \mathbf{W}_{ij_{\max 1}}, \mathbf{W}_{ij_{\max 2}}]$ (只有 1 个邻居就使用 1 个 $\mathbf{W}_{ij}$) 用于后续信息融合, 具体可根据硬注意力权重 $[\mathbf{W}_{ij_{\max 1}}, \mathbf{W}_{ij_{\max 2}}]$ 的邻居标号选出数值网络 V 对应的输出值 $V_{ij}, j \in \{j_{\max 1}, j_{\max 2}\}$ (只有 1 个邻居就使用 1 个 V_{ij}), 然后融合得出焦点单体 i 用于网络决策解码的信息强度 h_i 和 H_i 为

$$h_i = \mathbf{W}_i h_i \quad (16)$$

$$H_i = \mathbf{W}_{ij_{\max 1}} V_{ij_{\max 1}} + \mathbf{W}_{ij_{\max 2}} V_{ij_{\max 2}} \quad (17)$$

最后将拼接 $h_i \oplus H_i$ 强度输入到预解码网络中来获取决策解码的输入信息, 其中, 预解码网络的神经元参数被设计成 $[80, 128, 128]$ 。输入神经元维度 80 代表聚合环境与邻居的信息 $h_i \oplus H_i$ 的拼合维度, 输出神经元维度 128 的设计目的是为了将单体 i 的聚合信息推升高维, 以便后续具体的转向和直游决策解码具有较高的训练灵活性。由于解码器会根据决策输出采用不同的设计, 所以相同结构的预解码器可提高代码的复用能力。

2.2 硬注意力模型的决策解码器

由于深度神经网络在应对多层次、多模态输出时具有较差的学习性能, 对转角决策而言, 转角方向与转角大小分别属于定性与定量两层次的输出, 为此转向网络解码器被设计成两个独立的全连接神经网络, 即转向分类网络和转角回归网络。其中, 转向分类网络用于解码单体 i 在 t 时刻的转角方向 S_i^t , 而转角回归网络用于量化转角的大小 $|\delta_i^t|$ 。转向分类网的神经元参数为 $[128, 64, 3]$, 输出层 3 神经元分别代表左转、直游、右转, 转角回归网络的参数结构为 $[128, 64, 1]$, 用于输出转角的绝对值。两转角解码网的输入层都是 128 神经元, 用于承接上节聚合单元的预解码网络输出, 所以得出转向网络的两个具体解码器为

$$S_i^t = \max_{\text{IDX}}(f_{\text{DEC1}}(f_{\text{PRE}}(h_i \oplus H_i))) \quad (18)$$

$$|\delta_i^t| = |f_{\text{DEC2}}(f_{\text{PRE}}(h_i \oplus H_i))| \quad (19)$$

式中: $f_{\text{PRE}}(\cdot)$ 为预解码网络; $f_{\text{DEC1}}(\cdot)$ 和 $f_{\text{DEC2}}(\cdot)$ 分别代表转向分类网和转角回归网; $\max_{\text{IDX}}(\cdot)$ 表示选出 $f_{\text{DEC1}}(\cdot)$ 3 个数值最大输出的索引标号, 然后再将右转, 直行, 左转分别赋值 $-1, 0, 1$ 给 S_i^t 。通过上述转换, 焦点单体 i 的转角可由下式决定:

$$\delta_i^t = S_i^t |\delta_i^t| \quad (20)$$

由于焦点单体的航向角会根据式 (20) 的决策发生改变, 所以需要根据式 (9) 和 (10) 更新直游网络的输入数据。其中, 直游网络解码器使用两个同构的全连接神经网络, 分别输出单体 i 的直游距离 l_i^t 和游动时长 η_i^t 。解码网络的神经元参数为 [128, 64, 1], 则直游网络输出可以表示为

$$l_i^t = f_{\text{DEC3}}(f_{\text{PRE}}(h_i \oplus H_i)) \quad (21)$$

$$\eta_i^t = f_{\text{DEC4}}(f_{\text{PRE}}(h_i \oplus H_i)) \quad (22)$$

式中: $f_{\text{DEC3}}(\cdot)$ 和 $f_{\text{DEC4}}(\cdot)$ 分别为直游距离 l_i^t 和游动时长 η_i^t 的解码网络。对比网络决策 $[\delta_i^t, l_i^t, \eta_i^t]$ 与数据提取的决策差异 (损失), 即可端对端地训练所提网络模型。

2.3 网络模型的损失函数与超参数

由于转向网络有转角方向和大小两输出, 则总损失 $\mathcal{L}_\delta$ 被设计成转向损失 $\mathcal{L}_S$ 与转角损失 $\mathcal{L}_{|\delta|}$ 的均值

$$\mathcal{L}_\delta = \frac{\mathcal{L}_S + \mathcal{L}_{|\delta|}}{2} \quad (23)$$

同理直游网络也有直游距离和时长两输出, 所以总损失 $\mathcal{L}_L$ 为距离损失 $\mathcal{L}_l$ 与时长损失 $\mathcal{L}_\eta$ 的均值

$$\mathcal{L}_L = \frac{\mathcal{L}_l + \mathcal{L}_\eta}{2} \quad (24)$$

转向分类输出采用交叉熵函数计算损失

$$\mathcal{L}_S = - \sum_{i=1}^T S_i^t \log(S_i^t) \quad (25)$$

转角回归值、直游距离和游动时长采用均方误差函数作为损失

$$\mathcal{L}_{|\delta|} = \frac{1}{S} \sum_{i=1}^S (|\delta_i^t|_{\text{real}} - |\delta_i^t|)^2 \quad (26)$$

$$\mathcal{L}_l = \frac{1}{S} \sum_{i=1}^S (l_{i \text{ real}}^t - l_i^t)^2 \quad (27)$$

$$\mathcal{L}_\eta = \frac{1}{S} \sum_{i=1}^S (\eta_{i \text{ real}}^t - \eta_i^t)^2 \quad (28)$$

式中: $|\delta_i^t|_{\text{real}}$, $l_{i \text{ real}}^t$ 和 $\eta_{i \text{ real}}^t$ 由式 (7) 和 (8) 根据 t 时刻的真实鱼群实验数据来计算; S 为每批训练大小, 具体选取 1024 来约束显卡的使用容量。使用留出法随机选取总样本 80% 作训练集, 20% 作测试集, 利用 Pytorch 框架编写硬注意力网络模型, 训练硬件采用 Dell T630 服务器, 配置 GPU 为

NVIDIA GeForce RTX 3080, 训练采用批量梯度下降策略, 并且使用 AdamW 优化器最小化损失函数, 初始学习率设置为 $5e-5$, 权重衰减设为 0.0005。为避免过拟合, 采用 Dropout 来提高模型的泛化能力, 利用 pytorch 函数 torch.nn.dropout() 具体实现。Dropout 的比率为 20%, 神经元被保留的概率为 80%, 模型训练使用早停法选择最优参数, 当模型在验证集测试误差上升时, 立即停止模型训练, 将此时的权重作为网络的最终参数。

3 硬注意力模型仿真实验

利用自主研发的仿真平台来验证硬注意力模型的集群运动效果。其中, 仿真程序由 LabView 编写, 使用自主通信协议与 Python 编写的网络模型通信。在单体决策时刻 t , LabView 仿真环境, 发送单体 i 的环境信息 X_i^t 和邻居信息 X_{ij}^t 给硬注意力模型, 通过网络计算输出单体 i 的决策转角 δ_i^t 、直游距离 l_i^t 和游动时长 η_i^t 并回传 LabView, 这时会在仿真中设置单体 i 的运动计时器值 T_i^t 为 η_i^t , 航向角 $\phi_i(t)$ 变为 $\phi_i(t) + \delta_i^t$, 然后每仿真周期 Δt 按式 (29) 更新一次单体 i 的全局状态进行仿真循环, 直到 $T_i^t < 0$ 开启新一轮协议通信

$$\begin{bmatrix} x_i(t + \Delta t) \\ y_i(t + \Delta t) \\ T_i^t(t + \Delta t) \end{bmatrix} = \begin{bmatrix} x_i(t) \\ y_i(t) \\ T_i^t(t) \end{bmatrix} + \begin{bmatrix} V_i^t \cdot \cos(\phi_i(t)) \\ V_i^t \cdot \sin(\phi_i(t)) \\ -\Delta t \end{bmatrix} \quad (29)$$

式中, $V_i^t = l_i^t / \eta_i^t$ 为运动网络输出的平均速度。

如果单体 i 的决策被验证可能会发生撞墙, 则将运动计时器强制清零。采用文献 [13] 的方法向转角输出加入高斯噪声重新决策, 筛选出安全决策以保证及时调整避墙动作, 保存所有仿真轨迹及航向角信息用于结果分析。

3.1 两智能体仿真的交互分析

集群运动的基础为两体交互, 文献 [13] 实验得出结论: 将两体交互叠加可以涌现集群运动, 所以验证模型的两体交互性能至关重要。虽然硬注意力模型使用 5 鱼训练数据得出, 但是得益于独特的模型数据输入方式, 硬注意力模型可以适应任意群体规模的集群仿真。为此使用模型进行两智能体仿真实验 1 h, 将仿真数据与真实两鱼运动数据的概率密度函数进行对比。如图 3 所示, 各子图分别对比了两鱼数据 (红色) 与两智能体模型控制输出 (蓝色) 的概率密度曲线。图 3(a) 显示




图3 两智能体硬注意力模型仿真与真实两鱼实验对比

Fig.3 Comparison between two-agent simulation with hard attention model and two-fish experiment

了转角变化 δ 的分布曲线,表明真实两鱼与模型决策的转角变化峰值都处于 $\pm 20^\circ$ 附近,但是模型输出的转角曲线更陡峭,说明硬注意力模型可以滤除鱼群数据中的个性化噪声,还原出有利于鱼群组织的共性化决策。

图3(b)对比了直游距离分布,该图表明真实鱼的移动距离峰值大约在60 mm,而模型仿真输出的距离峰值在100 mm,但是两者曲线的均值较一致。峰值偏移的主要原因在于前述LabView仿真的避墙机制,在某些极端情况下,模型会被重新触发计算来远离边界,具体统计结果如图3(e)所示,从而给出了较长的运动距离。

图3(c)显示的游动时长对比表明,模型仿真与真鱼数据相似,峰值更高表示模型输出的确定性更强。图3(d), (f), (g)图分别对比了两鱼(智能体)的航向角差 $\Delta\phi$ 、对墙角度的绝对值 $|\theta^w|$ 和相对距离 d ,真鱼数据的3条曲线与模型仿真结果较一致,分别表明两鱼(智能体)具有明显的对齐特性、沿墙运动特性以及安全距离保持特性。

多数文献认为鱼类交互主要通过视觉感知^[19-20],但是目前并没有真实客观的工具来验证上述假说。为揭示鱼类交互的信息选用机理,可以使用真实鱼群数据训练的硬注意力模型来对两智能体的交互进行分析。具体做法是在仿真环境中心固定焦点智能体,然后在环境内任意位置摆放另一

邻居,将模型输出的硬注意力权重 W 可视化。由于式(15)的归一化处理使得交互强度的范围被约束在(0,1)之间,如图4所示,注意力权重较大的区域标记为红色,小的区域标记为蓝色。该图表明焦点智能体前方形成了一个小范围的高注意力椭圆扇形区域,这与鱼类的视觉重点区域类似,也符合人类驾驶行为的视觉观察习惯。




图4 两智能体交互机理分析

Fig.4 Analysis of interaction mechanism of two agents

3.2 硬注意力模型的泛化性能分析

首先定义集群运动有序性的两个指标:群体极性(P 值)和群体大小(C 值),以量化评价智能体的集群运动效果,定义多智能体的重心位置为 $p_G = (x_G(t), y_G(t))$,多智能体重心的速度为 $v_G =$

$(v_G^x(t), v_G^y(t))$ ，具体计算方法如下

$$x_G(t) = \frac{1}{N} \sum_{i=1}^N x_i(t), y_G(t) = \frac{1}{N} \sum_{i=1}^N y_i(t) \quad (30)$$

$$v_G^x(t) = \frac{1}{N} \sum_{i=1}^N v_i^x(t), v_G^y(t) = \frac{1}{N} \sum_{i=1}^N v_i^y(t) \quad (31)$$

式中：智能体 i 的速度由向后一步差分定义，即 $v_i^x(t) = \frac{x_i(t) - x_i(t - \Delta t)}{\Delta t}$ ， $v_i^y(t) = \frac{y_i(t) - y_i(t - \Delta t)}{\Delta t}$ ； N 为智能体总数； Δt 为仿真周期。集群重心给出了群体的集中特性信息，有助于集群运动的指标设定，群体极性 P 值可被定义为

$$P(t) = \frac{1}{N} \left\| \sum_{i=1}^N (\cos(\phi_i(t)), \sin(\phi_i(t))) \right\|, P(t) \in [0, 1] \quad (32)$$

式中： $\phi_i(t) = \arctan \frac{v_i^y(t)}{v_i^x(t)}$ 表示智能体 i 的航向角； $P = 1$ 代表多智能体的航向一致， $P = 0$ 代表多智能体的航向各不相同。接着定义群体大小 C 值

$$C(t) = \frac{1}{N} \sum_{i=1}^N \|\vec{p}_i - \vec{p}_B\| \quad (33)$$

式中， $\|\vec{p}_i - \vec{p}_B\|$ 代表智能体 i 相对离重心位置 G 的距离。 C 值越小表示多智能体越紧密，反之越分散。

为表现硬注意力模型在大规模集群下的泛化能力，随机生成 100 个不同初始位置、朝向的智能体参与集群运动，随时计算仿真集群的 P 值和 C 值，如图 5 所示。初始时刻集群无序散乱，硬注意力模型能在 5 min 内控制群体形成稳定有序的运动模式。 P 值曲线随时间变化逐渐趋向于 1，表明集群能收敛到一致的运动方向； C 值曲线逐渐接近于 25 mm，说明集群运动趋向于紧凑。所有单体仅需在 99 个邻居中挑选 2 个邻居交互，就能使群体自组织出宏观秩序，这与自然界生物集群类似，有限脑神经的处理能力仅能允许单体关注少量邻居。而硬注意力模型训练仅使用 5 鱼运动数据就能实现 100 个智能体的集群协同，体现了该模型设计具有较强的自组织能力。文献 [12] 表明，鱼群中的单体仅与少量重点邻居交互就足以保持群体凝聚力，单体的信息选择耦合与集群行为具有高度相关性，某些单体的随机行为会通过邻居逐级放大，与耦合信息交互后生成的行为会继续助推单体选择类似的信息进行强化耦合，使得重点邻居信息会波浪式的在群体中级联传递^[21]，




图 5 100 智能体集群汇聚过程

Fig.5 Collective convergence progress of 100 agents

从而通过正反馈机制涌现出整体的有序运动。

接着验证模型在不同规模下的集群仿真性能。取智能体个数 $N=[2, 5, 7, 10, 20, 30, 50, 60, 80, 100, 150, 200, 300, 500, 800]$ 分别进行运动仿真，集群指标如图 6 所示，黄色实线和绿色实线分别代表 P 值和 C 值曲线。其中， P 值一直保持在较高水平，并随着规模扩大越来越接近于 1，方差也在逐渐减小，表明硬注意力模型能随着规模的扩大逐渐强化集群的对齐作用。虽然两智能体仿真时的 C 值稍大，但随着群体规模的扩大， C 值逐步稳定。

对比经典集群运动的 Viseck 模型^[8]、最大影响力模型^[13]和最强视觉 DNN 模型^[14]，硬注意力模型属于自动建模方法，具有客观、直接的微观分析效果。将上述 4 种模型写入仿真系统，进行相同规模的集群运动对比实验 1 h，记录集群运动指标。表 1 展示了 P 值和 C 值的仿真结果。在智能体个数 $N = 2$ 时，最强视觉 DNN 模型的 P 值较高，能形成较紧凑的 C 值。当智能体规模 $N \geq 5$ 时，硬注意力模型的两个宏观指标最优。小规模集群下，最强视觉 DNN 模型占优的原因在于该模型是由两鱼运动数据训练而成，所以在 2 个智能体仿真时能有最优的宏观表现。但随着智能体的增加，其性能皆弱于硬注意力模型，这是因为硬注意力模型是由 5 鱼运动数据训练而成，其中内嵌的硬注意力核心网络能保证焦点单体只与重点邻居交互，获得了较为稳定的交互策略，有利于在大规模集群中形成鲁棒的集群运动。而且，随着智能体规模的增加，硬注意力模型的两个指标都越来越强化稳定，符合集群行为涌现的正反馈机制。由于经典 Vicsek 模型主要针对无约束自推进粒子




图 6 不同规模智能体的集群运动指标

Fig.6 Collective motion indexes of agents with different scales

表 1 不同集群运动模型仿真的群体 P 值和 C 值

Tab.1 P-value and C-value of groups simulated by different collective motion models

N	Vicsek模型 ^[8]		最大影响力模型 ^[13]		最强视觉DNN模型 ^[14]		硬注意力模型	
	P	C/mm	P	C/mm	P	C/mm	P	C/mm
2	(0.48±0.29)	(160.31±49.26)	(0.95±0.07)	(51.22±32.63)	(0.99±0.01)	(9.1±5.24)	(0.986±0.012)	(32.22±7.41)
5	(0.5±0.25)	(151.51±42.69)	(0.98±0.04)	(45.08±9.55)	(0.89±0.18)	(34.6±26.1)	(0.991±0.006)	(17.89±5.72)
7	(0.44±0.16)	(161.44±24.66)	(0.86±0.23)	(69.23±38.29)	(0.83±0.13)	(51.11±20.32)	(0.992±0.004)	(15.65±4.23)
10	(0.42±0.15)	(165.25±20.48)	(0.88±0.15)	(69.7±30.11)	(0.91±0.06)	(36.06±12.41)	(0.992±0.004)	(15.83±4.12)
20	(0.62±0.14)	(129.77±24.11)	(0.53±0.25)	(126.99±30.1)	(0.45±0.09)	(87.33±8.06)	(0.993±0.003)	(15.42±3.96)
30	(0.68±0.05)	(113.99±10.45)	(0.26±0.12)	(149.89±12.21)	(0.79±0.03)	(55.06±6.2)	(0.993±0.002)	(17.32±3.98)
50	(0.73±0.04)	(104.65±8.31)	(0.18±0.09)	(151.92±9.83)	(0.75±0.05)	(59.14±6.42)	(0.994±0.002)	(17.81±4.84)
60	(0.64±0.03)	(125.18±5.29)	(0.16±0.08)	(152.47±7.57)	(0.76±0.03)	(59.27±4.36)	(0.994±0.002)	(16.98±4.44)
80	(0.72±0.03)	(107.64±8.18)	(0.13±0.06)	(151.14±8.09)	(0.88±0.01)	(39.79±2.64)	(0.994±0.001)	(15.39±2.8)
100	(0.62±0.03)	(132.1±3.64)	(0.1±0.05)	(149.76±8.44)	(0.84±0.01)	(49.65±2.27)	(0.995±0.002)	(14.26±3.78)

设计，属于连续控制模型，需要智能体每周期给出交互决策，不符合剪刀鱼的转向-直游决策方式，使得 Vicsek 模型的性能表现较差，无法形成良好的集群运动。最大影响力模型的原理与最强视觉 DNN 模型类似，都是利用两鱼运动数据来生成交互模型，但需要人工设计多邻居交互的叠加策略，随着邻居规模的增加，集群汇聚能力方面具有较大缺陷。

4 结 论

所提硬注意力模型能在物理层面约束焦点单体的交互邻居数量，并在端对端的数据训练后获得泛化能力较强的宏观集群运动涌现，该模型能

在微观层面解析出单体鱼的交互行为，并可显著降低单体交互的计算负荷，符合自然界生物集群特征，有利于启发人工集群系统的分布式控制器设计。可见，所提硬注意力模型具有较为良好的信息稀疏解耦能力、较为鲁棒的集群运动指标以及较为优秀的集群规模泛化性能，对复杂系统的多层次行为机制探寻提供了有力支撑，为复杂系统的机器学习控制探索提供了有益尝试。下阶段，课题组拟利用自主知识产权的集群机器人来实现集群的硬注意力控制器设计。

参考文献:

[1] WEN H S, ZHU Y, PENG C H, et al. Collective motion of cells modeled as ring polymers[J]. *Soft Matter*, 2022,

- 18(6): 1228–1238.
- [2] GIANNINI J A, PUCKETT J G. Testing a thermodynamic approach to collective animal behavior in laboratory fish schools[J]. *Physical Review E*, 2020, 101(6): 062605.
- [3] HASSANALIAN M, MIRZAEINIA A, BAWANA N, et al. Energy management of echelon flying northern bald ibises with different wingspans and variable wingtip spacing[J]. *Journal of Bionic Engineering*, 2022, 19(1): 44–61.
- [4] KUBELKA V, SANDERCOCK B K, SZÉKELY T, et al. Animal migration to northern latitudes: environmental changes and increasing threats[J]. *Trends in Ecology & Evolution*, 2022, 37(1): 30–41.
- [5] 汪秉宏, 杨涵新. 人类的迁徙行为与社群合作之演化[J]. *上海理工大学学报*, 2011, 33(1): 24–29, 88.
- [6] 吴垠, 刘忠信, 陈增强, 等. 迭代学习在多智能体编队中的控制研究[J]. *上海理工大学学报*, 2016, 38(1): 87–92.
- [7] 王伟嘉, 郑雅婷, 林国政, 等. 集群机器人研究综述[J]. *机器人*, 2020, 42(2): 232–256.
- [8] 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.
- [9] VÁSÁRHELYI G, VIRÁGH C, SOMORJAI G, et al. Optimized flocking of autonomous drones in confined environments[J]. *Science Robotics*, 2018, 3(20): eaat3536.
- [10] 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.
- [11] 王瑞, 崔佳梅, 张越, 等. 基于图网络的集群运动预测研究[J]. *电子科技大学学报*, 2021, 50(5): 768–773.
- [12] WANG W J, ESCOBEDO R, SANCHEZ S, et al. The impact of individual perceptual and cognitive factors on collective states in a data-driven fish school model[J]. *PLoS Computational Biology*, 2022, 18(3): e1009437.
- [13] 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.
- [14] 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.
- [15] 刘磊, 张浩翔, 陈若妍, 等. 鱼群涌现机制下集群机器人运动强化的迁移控制[J]. *控制与决策*, 2023, 38(3): 621–630.
- [16] ESCOBEDO R, LECHEVAL V, PAPASPYROS V, et al. A data-driven method for reconstructing and modelling social interactions in moving animal groups[J]. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 2020, 375(1807): 20190380.
- [17] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31th International Conference on Neural Information Processing Systems. Long Beach: NIPS, 2017: 6000–6010.
- [18] GILMOUR K M, BARD B. Social buffering of the stress response: insights from fishes[J]. *Biology Letters*, 2022, 18(10): 20220332.
- [19] LUKAS J, ROMANCZUK P, KLENZ H, et al. Acoustic and visual stimuli combined promote stronger responses to aerial predation in fish[J]. *Behavioral Ecology*, 2021, 32(6): 1094–1102.
- [20] SOVRANO V A, VICIDOMINI S, POTRICH D, et al. Visual discrimination and amodal completion in zebrafish[J]. *PLoS One*, 2022, 17(3): e0264127.
- [21] ATTANASI A, CAVAGNA A, DEL CASTELLO L, 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.

(编辑: 黄 娟)