

杜常金, 刘磊. 基于 Attention 注意力机制下的鱼群韧性研究[J]. 智能计算机与应用, 2024, 14(4): 209-214. DOI: 10.20169/j.issn.2095-2163.240434

基于 Attention 注意力机制下的鱼群韧性研究

杜常金¹, 刘磊^{1,2}

(1 上海理工大学 管理学院, 上海 200093; 2 上海理工大学 光电学院, 上海 200093)

摘要: 生物集群运动可以自组织实现群体涌现行为, 但是在外界因素的影响之下, 生物集群是否能够保持韧性, 单体是否能够根据当前信息重新交互仍然面临巨大的挑战。在攻击体的干扰之下, 本文根据红鼻剪刀鱼的运动数据, 设计 Attention 注意力模型。模型考虑到单体鱼与攻击体和周围邻居鱼之间的信息交互, 预测下一时刻单体出现的具体位置, 说明 Attention 注意力模型能够使生物的集群韧性与自组织运动保持一致。实验结果表明, 所提的 Attention 注意力模型能够较好的解释生物集群韧性, 增强生物集群韧性的鲁棒性和灵活性, 为复杂系统解释内外部之间的联系提供了有力的支撑, 该方法对生物控制领域的分布式管理也有很好的借鉴作用。

关键词: 复杂系统控制; Attention 注意力模型; 生物集群韧性

中图分类号: TP242.6

文献标志码: A

文章编号: 2095-2163(2024)04-0209-06

Research on fish resilience based on attention mechanism

DU Changjin¹, LIU Lei^{1,2}

(1 Business School, University of Shanghai for Science and Technology, Shanghai 200093, China;

2 School of Optical-Electrical, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Biological cluster movement can self-organize to realize group emergence behavior, but under the influence of external factors, whether biological cluster can maintain resilience and whether monomer can interact according to current information still face great challenges. Under the interference of the attack body, the Attention attention model was designed according to the movement data of the red-nose scissor fish. The model takes into account the information interaction between the monomer fish and the attacking body and the surrounding neighbor fish, and predicts the specific location of the monomer appearance at the next moment, indicating that the Attention attention model can keep the cluster toughness of the organism consistent with the self-organized movement. The experimental results show that the proposed Attention attention model can better explain the resilience of biological clusters, enhance the robustness and flexibility of biological cluster resilience, and provide strong support for complex systems to explain the internal and external links. This method also has a good reference for distributed management in the field of biological control.

Key words: complex system control; Attention attention model; biological cluster resilience

0 引言

近年来, 对于生物集群运动的研究受到众多学者青睐, 鸟群、鱼群、兽群等生物系统通过有序的自组织管理进行生存和繁衍, 群体中的单体通过与周围邻居的信息交互和协同合作形成具有特定结构和功能的群体, 保证群体拥有灵活的判断和决策。相较于传统的控制理论而言, 生物集群运动的协同控

制, 能够揭示复杂系统^[1]内部的信息交互, 使人工系统更有灵活性和鲁棒性, 更好的调控复杂系统内外部之间的关系。

研究生物集群运动过程中存在很多问题, 比如生物体应对复杂场景或突发情况时的真实脑神经信号和脑电波图像人们无法获取, 无法解释这一现象背后更深层次的原因。神经网络模型^[2]的结果可以对生物体内部的信息交互和集群运动进行模拟和

作者简介: 杜常金(1996-), 男, 硕士研究生, 主要研究方向: 集群运动, 复杂系统。

通讯作者: 刘磊(1982-), 男, 博士, 副教授, 硕士生导师, 主要研究方向: 复杂系统控制, 机器人集群智能。Email: liulei@usst.edu.cn

收稿日期: 2023-11-24

哈尔滨工业大学主办 ◆ 科技创新与应用

预测,但如果生物集群运动受到外部因素的干扰甚至冲击,生物群体还能不能恢复成原来的自组织模式,这个结论还不得而知。在上面理论基础之上,对生物集群运动进行人工建模^[3]的设计方案极具挑战,很多模型构建时主观性较强,参数设定困难,需要依赖专家学者花费时间和精力进行调整。如 Viseck 模型^[4]、Couzin 模型^[5]、Chaté 模型^[6]等,虽然在这些模型的构造之下,单体能够自组织形成集群运动,但是上述模型都存在很多相似的问题。第一,这些模型需要单体同时处理周围几个甚至几十个邻居的交互信息,过多的冗杂信息不利于单体对周围信息的判断,导致单体感知能力下降,单体在下一时刻的决策出现失误,不利于大规模集群运动的分布式控制;第二,上述模型所需数据量巨大,实验周期较长,要求实验者具有多元信息处理能力。鱼类集群运动研究领域专家 Theraulaz Guy^[7-8] 近期研究表明,鱼类群体中的单体应仅与少量邻居交互就能很好融入集群运动体系之中,从而形成自组织涌现行为。文献也表明: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,若群体遇到外部因素的干扰,群体的韧性就会受到冲击,可能集群运动就会被打破,因此采用传统的建模方法还不足以应对复杂的生物系统。

随着机器学习^[9]、强化学习^[10]的迅速发展,为了应对呈指数爆炸增长的单体交互数据,研究者提出一些复杂深度网络模型,如通过两鱼实验数据提出的最强视觉 DNN 模型^[11],在该模型的指导之下,具有一定的生物集群控制效果,但是模型内部的交互机制仍不能得到解释,当外部因素干扰鱼群运动后,群体的韧性机制被打破,能不能恢复成原状尚不能得到验证,更不能明确群体内部之间的信息传递路径和反馈机制。针对上述问题,本文尝试设计 Attention 注意力模型来挖掘生物单体之间的信息交互,并考虑在遭受外部袭击之后群体的韧性能不能恢复,从而更好解释群体的交互运动。

Attention 注意力模型会以两条鱼和一个攻击体为研究对象,考虑邻居之间的交互信息,找出对单体鱼的运动影响最大的是邻居鱼还是攻击体,通过信息耦合^[12-13]共同应对攻击体的冲击并保持群体的韧性,一段时间后,单体鱼之间能够再次协同合作完成群体的涌现行为。

1 实验方法

1.1 鱼群实验方案

本文实验对象是红鼻剪刀鱼,在进行实验时,发现红鼻剪刀鱼具有瞬间转向变速、直线滑行的运动模式^[14],为判断单体鱼在下一时刻的决策,可将单体运动简化为连续交替的转向-直游运动决策,最终将两鱼运动轨迹离散化为多组决策线段,单体在线段的端点处进行决策转向。单体鱼直线运动距离 l_i , 运动轨迹会被决策点间隔为一系列的直线段。由于 idtrackerai 不能识别出鱼群的位置,对数据中含有 Nan 的部分进行插值处理,当数据中出现两鱼串动和轨迹交换情况时,需要开发一个自动软件进行数据跟踪修正。原始数据时间间隔不稳定,大约 1 秒 16 张左右,需要使用插值方法,对鱼群位置按照每秒 20 张照片位置补足数据,对于位置抖动数据,需要加入滤波,消除数据噪声。对于攻击数据,需要有效截断攻击前与攻击后的连续时间标记,保留鱼群单体速度大于 6.6 mm/s (约每秒 2 倍体长) 的轨迹数据,最后总共提取出 22 万余条合格数据用于模型训练。

1.2 鱼群相关运动参数

以圆心为原点建立平面直角坐标系,逆时针为角度正方向,其中 $x_i^w(t)$ 代表单体鱼或者攻击体的横向位置; $y_i^w(t)$ 代表单体鱼或者攻击体的纵向位置; $v_i^x(t)$ 代表单体鱼或者攻击体的横向速度; $v_i^y(t)$ 代表单体鱼或者攻击体的纵向速度; $r_i(t)$ 代表单体鱼或者攻击体到墙边界的距离; $d_{01}(t)$ 代表攻击体到第一条鱼的距离; $d_{02}(t)$ 代表攻击体到第二条鱼的距离; $d_{12}(t)$ 代表第一条鱼到第二条鱼的距离; $\Delta\phi_{ij}(t)$ 为邻居 j 相对单体 i 的朝向角差,当 $\Delta\phi_{ij} = 0$ 且 $d_{12} \geq 0$ 时表明两鱼平行,相对运动方向比较一致,鱼群仍然能够协同运动,保持集群的韧性特征。其中,

$$\phi_i(t) = \arctan\left(-\frac{(x_j(t) - x_i(t)) + (y_j(t) - y_i(t))}{(x_j(t) - x_i(t)) + (y_j(t) - y_i(t))}\right) \quad (1)$$

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

$$v_{ij}(t) = \left| \sqrt{(v_j^x(t))^2 + (v_j^y(t))^2} - \sqrt{(v_i^x(t))^2 + (v_i^y(t))^2} \right| \quad (3)$$

$$\Delta\phi_{ij}(t) = \phi_j(t) - \phi_i(t) \quad (4)$$

红鼻剪刀鱼的群体规模无论大小,在受到外界干扰之后,单体 i 感知相邻邻居之间的信息,在整面涌现出集群韧性的特征。鱼群运动实验和相关运动参数如图 1 所示。

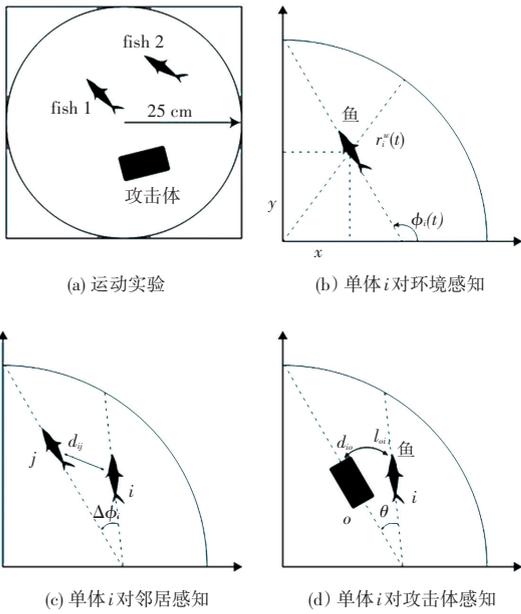


图 1 鱼群运动实验和相关运动参数

Fig. 1 Fish schooling experiment and related parameters

2 Attention 注意力模型结构与训练方法

2.1 Attention 注意力模型核心网结构

本文以两条鱼的实验数据和一个攻击体数据为基础,由文献[15]可知,两条鱼的交互运动在不受外界干扰时能够自组织形成集群运动。本实验增加干扰因素一攻击体,建立深度网络 Attention 注意力模型,模型增加攻击体的干扰这一外界因素。本文神经网络的结构特征是根据运动模型的特点设计出的,其结构如图 2 所示,包含编码器、核心网、信息处理网络和解码器网络^[16]。其中,解码器网络又分为初始解码器网络和最终解码器网络。单体 i 对周围环境的感知信息为 $X_i^t [r_i^w, \phi_i^w, 0]$ (其中 0 为三元组占位符),相邻邻居 $X_{ij}(t) = [d_{ij}, v_{ij}, \Delta\phi_{ij}] j \in N_i$, 其中 N_i 为单体 i 的邻居。单体 i 将此时位置网络更新为输出单体 i 在下一时刻运动网络中的 S_i^t 和时间 KT_i^t 2 项决策信息。其中 $KT_i^t = t_{n+1}^d - t_n^d, t_{n+1}^d$ 代表下一时刻滑行的决策时间。

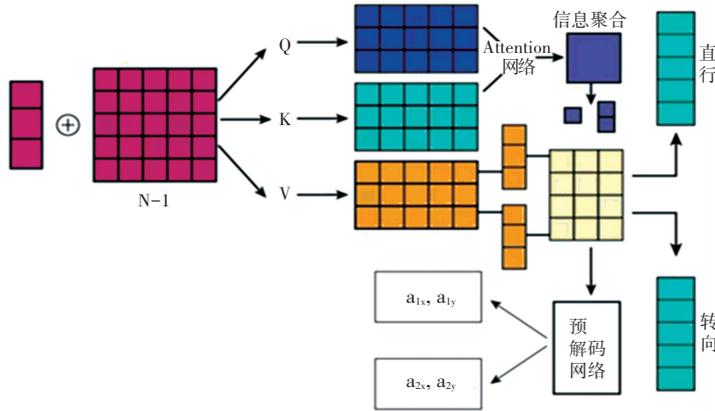


图 2 Attention 注意力模型结构

Fig. 2 Structure of attention model

在整个全连接网络中周围邻居信息 $X_{ij}(t)$, 组合形成运动网络和时间决策网络,运动网络包含滑行偏角变化网络和滑行距离变化网络。该网络的输入为 $[x_i^w(t_n^d), y_i^w(t_n^d), v_i^w(t_n^d), v_j^w(t_n^d), r_i^w(t_n^d)]^T$ 和 $[d_{ij}(t_n^d) + \Delta\phi_{ij}(t_n^d), v_{ij}^w(t_n^d), a_{ij}(t_n^d)]^T$ 。编码器网络第一行代表攻击体的自身信息,其余各行数为鱼群信息,将其排列整齐分配到全连接网络。输入层有 5 个神经元,隐含层有 3 层,神经元的参数为 $[3, 90, 40]$, 将编码器输入升维到 40 编码的子空间,隐藏层的激活函数为 Relu 函数^[17]。Relu 函数作为深度学习模型的激活函数,仅需比较输入值和 0 的大小,即可确定输出值形

式,这与生物神经元的激活方式较为相近,能够更好地提供生物神经系统优化策略。编码器 Q 升维并复制 N_i 可以构成查询表 $[Q_i, Q_{i1}, \dots, Q_{iN_i}]$, 邻居数据经过编码器 K 处理之后就会上升成为 N_i 的键值表 $[K_i, K_{i1}, \dots, K_{iN_i}]$, 将周围的信息与邻居的信息输入网络 V, 形成高维度向量表 $[V_i, V_{i1}, \dots, V_{iN_i}]$ 。

对于 Attention 注意力模型网络各层的神经元,将其参数可以设置成为 $[80, 64, 32, 1]$, 隐藏层之间使用的激活函数是 sigmoid 激活函数^[18], 其中输入维度是 80 维。80 神经元为拼接后的输入维度,一个神经元是识别网络解码出的结果,然后再使用 sigmoid 作

为激活函数。单体 i 对周围环境以及邻居的感知系数,我们设置为 W_{ij} :

$$W_{ij} = \sigma(f_M(K_{ij}, Q_i)) \quad (5)$$

W_{ij} 反映单体 i 对周围邻居的关注程度,要对关注程度进行归一化处理,单体 i 对外界关注程度的总权重为 Z_{ij} , 计算公式为

$$Z_{ij} = \frac{W_{ij}}{\sum_{j \in N_i} W_{ij} + W_i} \quad (6)$$

根据上述权重 Z_{ij} 筛选出较大权重的邻居信息,得到单体 i 对环境和交互邻居的权重 $[Z_i, Z_{ij_{\max 1}}, Z_{ij_{\max 2}}, Z_{ij_{\max 3}}]$ 用于后续的信息决策。

Attention 注意力模型的核心网结构需要处理并进行整合信息,单体 i 需要对周围环境进行判断然后与已知环境信息融合,对应进入网络决策的输出。根据周围邻居的关注以及在干扰情况下挑选出数值网络 V 中的最大值,然后再根据所谓的权重 $[Z_{ij_{\max 1}}, Z_{ij_{\max 2}}, Z_{ij_{\max 3}}]$, 整合当前干扰,进行网络决策的解码。决策后续判断的信息强度为 hi 跟 HG, 将 hi 跟 HG 拼接,然后输入得到预解码网络来获取当前时刻以及下一时刻的信息决策。

$$b_i \text{ 和 } B_i: B_i = Z_i b_i \quad (7)$$

$$B_i = Z_{ij_{\max 1}} V_{ij_{\max 1}} + Z_{ij_{\max 2}} V_{ij_{\max 2}} + Z_{ij_{\max 3}} V_{ij_{\max 3}} \quad (8)$$

$$B_i = \sum_{w=1}^m Z_{ij_{\max w}} V_{ij_{\max w}}, m = \begin{cases} 1, & N = 2 \\ 2, & N > 2 \end{cases} \quad (9)$$

最后将拼接形成的 $b_i \oplus B_i$ 强度输入到预解码网络中来获取决策解码的输入信息,使得抗干扰效果比较显著。

预解码网络的神经元的参数是 $[80, 128, 128]$, 当前是一个全连接的网络,全连接的网络是将周围干扰环境的信息输入整合 $b_i \oplus B_i$, 输出 128 维的神经元。单体 i 维度升高之后,有利于后续的转向决策和滑行距离决策,获取更优化的信息整合。

解码器环节首先要进行的是预解码器操作,在干扰情况下将以上交互信息,输入到预解码网络,然后升维到 128 维便于后续的解码,其中预解码器结构为 $[80, 128, 128]$ 的全连接网络,最终解码器再利用结构为 $[128, 64, 1]$ 的全连接网络将高维预解码信息分别转换成鱼 1 的横向加速度、纵向加速度 $[a_{1x}, a_{1y}]$ 以及鱼 2 的横向加速度、纵向加速度 $[a_{2x}, a_{2y}]$ 。

2.2 Attention 注意力模型的损失函数与超参数

本实验中的精炼数据随机选取总样本 70% 作为训练集,30% 作为测试集,利用 Pytorch 框架编写

Attention 注意力网络模型,训练硬件采用 DellT630 服务器,配置 GPU 为 NVIDIA GeForce RTX 3080,批量大小 (Batch-size) 为 202400,先读取模型的结构然后在读取优化器,读取学习率调整器,使用 AdamW 优化器修正最小化损失函数,可以让学习力自动进行调节。初始学习率设置为 $5e-5$,权重衰减设为 0.0005。

根据上述参数设置,设计 loss 函数分别为交叉熵损失函数和均方损失函数。其中交叉熵损失函数中自带 Softmax 将标签分为 label(0, 1, 2),进而得出航向角变化的方向。将其总损失值设置为:

$$\mathcal{L}_S = - \sum_{i=1}^T S_i^t \log(S_i^t) \quad (10)$$

$$\mathcal{L}_l = \frac{1}{S} \sum_{i=1}^S (l_{i_{\text{real}}}^t - l_i^t)^2 \quad (11)$$

均方损失函数代表回归横向角变化的绝对值,采用 admw 优化器。

$$\mathcal{L}_{KT} = \frac{1}{S} \sum_{i=1}^S (KT_{i_{\text{real}}}^t - KT_i^t)^2 \quad (12)$$

由于模型含有两条鱼横向加速度与纵向加速度的输出,则总损失 f_{loss} 可以分解为两部分输出的损失之和:

$$f_{\text{loss}} = f_{\text{loss1}} + f_{\text{loss2}} \quad (13)$$

第一条鱼的损失函数为 f_{loss1} , 第二条鱼的损失函数为 f_{loss2} , 其中第一条鱼可采用交叉熵损失函数:

$$f_{\text{loss1}} = - \sum_{i=1}^T s_i^t \log(\hat{s}_i^t) \quad (14)$$

其中 T 为训练样本总数,由于转角大小输出属于回归问题,所以第二条鱼的输出可选用均方误差函数作为损失函数:

$$f_{\text{loss2}} = \frac{1}{N} \sum_{i=1}^T (|\delta\phi_i^t| - |\delta\hat{\phi}_i^t|)^2 \quad (15)$$

3 Attention 注意力模型仿真实验

上述模型在 Python 程序中可实现所需要的特定功能与结构,为验证实际鱼群运动抗干扰能力,需要编写多智能体仿真程序,仿真平台由 Python 和 Labview 计算语言共同来填写,采用自主设计的通信协议。服务器为 Python 软件,Labview 作为单体下一时刻决策请求的输出,与真鱼具有相同的运动周期。该程序通过自主通讯协议,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 , 通过网络计算输出单体 i 的滑行距离 $d_{ij}(t_n^d)$ 、偏移角度 $\phi_i(t_n^d)$ 和游动时长 $KT_i(t_n^d)$ 回传

Labview,这时会在仿真中设置单体 i 的运动计时器值 $KT_i(t_n^d)$ 为 $KT_i(t_{n+1}^d)$, 航向角 $\phi_i(t_n^d)$ 变为 $\phi_i(t_{n+1}^d) + \theta_i$, 每仿真周期所有智能体仿真运动长度设为 $\Delta l = 0.15 \text{ mm}$, 则焦点单体 i 的位置按下式更新:

$$\begin{bmatrix} x_i(t + \Delta t) \\ y_i(t + \Delta t) \\ L_i(t + \Delta t) \end{bmatrix} = \begin{bmatrix} x_i(t) \\ y_i(t) \\ L_i(t) \end{bmatrix} + \begin{bmatrix} \Delta l \cdot \cos(\phi_i(t_n^d)) \\ \Delta l \cdot \sin(\phi_i(t_n^d)) \\ -\Delta l \end{bmatrix} \quad (16)$$

$$\begin{bmatrix} v_i^x(t + \Delta t) \\ v_i^y(t + \Delta t) \end{bmatrix} = \begin{bmatrix} v_i^x(t) \\ v_i^y(t) \end{bmatrix} + \begin{bmatrix} \Delta v \cdot \cos(\phi_i(t_n^d)) \\ \Delta v \cdot \sin(\phi_i(t_n^d)) \end{bmatrix}$$

在受到干扰条件下,如果单体 i 的决策被验证可能会发生鱼撞鱼或者是直接撞到边界的情况,则将运动计时器强制清零,边界距离 $r_i^w(t)$ 小于鱼类身长 (50 mm) 时,可以通过强制的命令开启新一轮决策运动,以保证单体对可能发生的行为进行预判和调整,保证所有智能体在外界因素的干扰之下能够模拟出真实的运动方向和加速度数据。

3.1 两智能体仿真的交互分析

首先,两条真实鱼交互数据与智能体模型能够决策输出偏移决策角度 ϕ_i 、决策执行距离 d_{ij} 、决策时间 KT_i 的真实曲线。其中通过智能体的决策情况、Attention 注意力模型训练和仿真结果表明,对比最强视觉 DNN 模型,仿真模型显示了鱼群决策转角变化和智能体决策转角变化有高度的一致性,在当前时刻和下一时刻,其转角的变化都趋于 18° 。

深度网络模型能够过滤出真实鱼群不同个体的特征,使得模型输出训练转角变化峰值和仿真的决策偏移曲线更为陡峭。在模型当中可以去掉一些干扰波和噪音的影响,有利于还原真实鱼群有自组织的、相互协同的决策。本文对比了智能体执行决策距离,表明了鱼群偏移的距离大概在 52 mm,而仿真机器输出在 55 mm,两者曲线走势比较一致。在干扰因素的影响之下,在某些极端的情况下,人们可以看到由于碰撞机制或者是远离机制的影响,鱼群表现出较长的偏移距离和偏移的速度。通过运动决策时间对比表明,增加干扰条件下的模型仿真与真鱼 DNN 模型仿真相比更真实,数据更为相似,输出鲁棒性更为准确与稳定。

仿真通过对比了真实鱼群、Attention 注意力模型、DNN 模型对齐与相互协同运动的移动情况,对比表明,Attention 注意力模型相对于 DNN 模型有高效的交互特征,与真实鱼群更为一致,领导者具有更

大视觉。鱼 1、鱼 2 在运动过程中会根据智能体以及干扰环境的移动而进行改变。无论是 Attention 注意力模型还是其仿真模型,两智能体与真实实验的预测始终保持一致,Attention 注意力模型相较于其它模型更具有对齐性,且在对齐过程中与真实鱼群数据高度一致。

3.2 ATT 模型的泛化性能分析

在干扰因素的加持之下,本文采用两个宏观判定,来判断集群运动的韧性和自组织能力。集群极性 P 和群体大小 C , 群体的重心位置为 $p_C = (x_C(t), y_C(t))$, 群体重心的速度为 $v_C = (v_C^x(t), v_C^y(t))$, 具体计算方法如下:

$$x_C(t) = \frac{1}{N} \sum_{i=1}^N x_i(t), y_C(t) = \frac{1}{N} \sum_{i=1}^N y_i(t) \quad (17)$$

$$v_C^x(t) = \frac{1}{N} \sum_{i=1}^N v_i^x(t), v_C^y(t) = \frac{1}{N} \sum_{i=1}^N v_i^y(t) \quad (18)$$

然后计算集群中心 M 的位置 $p_M = (x_M, y_M)$, 计算集群秩序指标:

(1) 群体极性 P :

$$P = \frac{1}{N} \sum_{i=1}^N \| (\cos \phi_i, \sin \phi_i) \|, P \in [0, 1] \quad (19)$$

其中 $P = 1$ 代表所有单体的朝向一致, $P = 0$ 则表示所有单体朝向各不相同。

(2) 群体大小 C :

$$C = \frac{1}{N} \sum_{i=1}^N \| p_i - p_M \| \quad (20)$$

其中 $\| p_i - p_M \|$ 代表单体 i 相对群体重心的距离, C 值越小表示群体越紧凑,反之越分散。

Attention 注意力模型仿真的 p 、 c 曲线时间序列如图 3 所示,在干扰因素下,集群大小与集群极性的数据偏差跟群体的规模成反比,群体数量规模小于 30 时,小规模集群涌现的聚集效应不显著,各单体的自组织能力较弱,但是随群体规模的扩大,各单体的汇聚能力愈发集中。以多条单体鱼的仿真运动为例,群体极性与大小的时间序列曲线如图(3)所示。结果表明:当运动时间超过 2 min 以后,Attention 注意力模型的仿真鱼将会首次出现有序汇聚现象,5 min 以后鱼群将保持高度聚合状态,群体的收敛度较为稳定,可以在较高层次上保持稳定的输入与输出,Attention 注意力模型提取了较为准确的转向与滑行数据,所以使得模型即使在干扰条件下也能获得较好的集群性能,体现集群运动的鲁棒性,能够很好地解释外界复杂系统和内在稳定系统的嵌合关系。

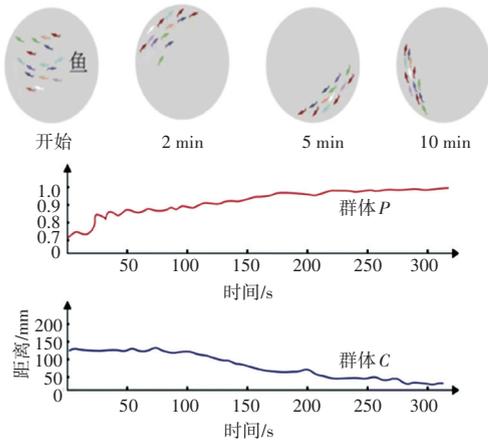


图3 多智能体集群汇聚过程

Fig. 3 Collective convergence progress of agents

4 结束语

Attention 注意力模型网络将焦点单体在干扰环境下的信息处理和下一时刻运动决策同步更新,将鱼群内部单体的交互选择在 DNN 模型的基础上增添韧性特征,提高鱼群处理信息的灵活性和鲁棒性。同时这与生物学中的注意力研究有很强的关联性,在复杂系统面对外界冲击或者破坏的情况下实现了再集群的自组织管理。

多智能体运动仿真表明:本文的 Attention 注意力网络模型能形成较为稳定的集群运动。两智能体仿真的结果表明鱼 1 能够影响鱼 2 的速度和加速度输出,在鱼群交互模型基础之上具有更强的运动特征;2-100 智能体仿真结果表明:韧性机制不但适用于简单的集群运动,同时也使泛化能力强的群体在短时间内由缓慢整合到快速聚合,比其它交互模型更具有合理性;100 智能体运动的瞬态分析表明:Attention 注意力模型具有稳定和高效率的集群韧性。

对于自然系统和人工系统而言,本文所提的方法和模型可以为集群运动的韧性提供了可选择的处理方案,对复杂系统的多层次分析提供了有力保障,以此为起点将这套体系应用于实际的场景,比如无人机飞行的协同方案和自动化模式,提高军工复杂系统的智能化和理想化,无人机在受到外界环境的威胁之后能够重新聚集,实现高水平的控制和应用。

参考文献

[1] 李耕,狄增如,韩战钢. 集群运动:唯像描述与动力学机制[J]. 复杂系统与复杂性科学, 2016, 13(2): 1-13.

[2] HA S, JEONG H. Unraveling hidden interactions in complex systems with deep learning[J]. Scientific Reports, 2021, 11(1): 1-13.

[3] KIM H, SHIN S, JANG J, et al. Counterfactual fairness with disentangled causal effect variational autoencoder [C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2021: 8128-8136.

[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.

[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] CHATÉ H, GINELLI F, GRÉGOIRE G, et al. Modeling collective motion: Variations on the Vicsek model[J]. European Physical Journal B, 2008, 64(3-4): 451-456.

[7] THERAULAZ G, 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.

[8] THERAULAZ G, 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.

[9] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.

[10] SUTTON R S, BARTO A G. Reinforcement learning: An introduction[J]. IEEE Transactions on Neural Networks, 1998, 9(5): 1054.

[11] 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.

[12] TANNER H. Flocking with obstacle avoidance in switching networks of interconnected vehicles [C]//Proceedings of IEEE International Conference on Robotics and Automation. 2004.DOI: 10.1109/ROBOT.2004.1307518.

[13] SCHULTZ K, VILLAFANE-DELGADO M, REILLY E P, et al. Analyzing collective motion using graph fourier analysis[J]. arXiv preprint arXiv:2103.08583, 2021.

[14] 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.

[15] 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.

[16] 成科扬,孟春运,王文杉,等. 解耦表征学习研究进展[J]. 计算机应用, 2021, 41(12): 3409-3418.

[17] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//Proceedings of Advance in Neural Information Processing Systems. Long Beach: NIPS, 2017: 5998-6008.

[18] SCARSELLI F, GORI M, TSOI A C. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2009, 20(1): 61-80.