

基于注意力网络与生物机械混杂实验的 韧性交互模型

刘磊^{1,2}, 崔圣光¹, 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: 现有的自动建模方法与生物集群信息处理特点不匹配, 导致单体信息交互建模难以实现。为此, 自主设计生物机械混杂系统以启发人工复杂系统调控, 该系统通过将生物组织与机械元件结合, 开展受控生物实验。在2鱼实验中, 通过引入受控机械单体观察鱼类在威胁环境下的交互行为, 并基于注意力机制构建2鱼韧性交互模型, 以挖掘高影响力的时空信息特征。为验证模型复现鱼类避障行为的能力, 对单体行为、整体秩序及交互运动进行仿真分析, 并将仿真结果与原始数据进行对比。最后, 通过机器威胁的参数敏感性分析验证模型的可解释性。实验结果表明: 注意力机制能有效捕捉2鱼在机械靠近时的规避反应, 揭示了威胁环境下生物交互行为的内在规律, 为理解更大规模生物群体在威胁环境中的交互机制提供了重要建模基础。所提方法有望在复杂对抗环境下的集群机器人系统中得到应用。

关键词: 生物机械混杂系统; 社会性交互; 韧性交互模型; 集群躲避运动; 复杂系统控制
中图分类号: TP 273 **文献标志码:** A

Resilient interaction model based on attention networks and biomechanical hybrid experiment

LIU Lei^{1,2}, CUI Shengguang¹, 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 existing automated modeling methods do not match the information processing characteristics of biological swarms, making it difficult to realize the interactive modeling of individual information. To address this, a biomechanical hybrid system to inspire the regulation of artificial complex systems was designed. This system integrated biological tissues with mechanical components

收稿日期: 2024-06-12

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)

通信作者: 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, 崔圣光, 高岩. 基于注意力网络与生物机械混杂实验的韧性交互模型[J]. 上海理工大学学报, 2025, 47(4): 449-460.

Citation: LIU Lei, CUI Shengguang, GAO Yan. Resilient interaction model based on attention networks and biomechanical hybrid experiment[J]. Journal of University of Shanghai for Science and Technology, 2025, 47(4): 449-460.

to conduct controlled biological experiments. In the two-fish experiment, controlled mechanical units were introduced to observe the interactions of fish in a threatening environment. An interaction model based on the attention mechanism was developed to extract high-impact spatiotemporal features. To validate the model's ability to replicate fish avoidance behaviors, simulations of individual behaviors, overall order, and interactive motion were performed, and the simulation results were compared with the original data. Finally, a sensitivity analysis of machine-induced threat parameters was conducted to verify the model's interpretability. The experimental results show that the attention mechanism effectively captures the avoidance responses of the fish when the mechanical units approach, revealing the underlying patterns of biological interactions in a threatening environment. This provides a crucial modeling foundation for understanding the interaction mechanisms of larger-scale biological swarms in threat environments. The proposed method holds promise for applications in swarm robotic systems in complex adversarial environments.

Keywords: *biomechanical hybrid system; social interaction; resilient interaction model; swarm avoidance motion; complex system control*

生物机械混杂系统是一种将生物组织和机械群体相结合的混合交互系统,旨在通过受控生物实验,揭示生物群体对机械干扰的响应及其交互行为的规律。该系统可为理解自然生物的社会交互行为提供确定性的实验激励,从而为理解生物群体在威胁环境下的社会交互行为提供基础。生物体的社会交互可以涌现集群行为,如昆虫群居^[1]、鱼类群游^[2]、鸟类结队^[3]、线虫聚集^[4]等。研究生物集群行为不仅可以揭示生物单体社会交互的奥秘,也能为人工集群的功能设计提供灵感^[5]。然而,在干扰环境中解析单体的社会性交互行为还存在很多困难。

生物在环境干扰下普遍具有集群韧性,而集群由多个具有社会交互作用的单体组成,如生物集群、机器人集群、计算节点网络等,在面对干扰、挑战或变化时,系统能保持整体功能、结构的稳定。集群韧性研究正在引起科学界和产业界的广泛关注^[6],特别是在军事安全领域具有重大意义,不仅对无人系统的设计至关重要,还对集群管理的效率和安全有着深刻的影响^[7]。

关于集群韧性单体社会交互行为的研究早期大多采用诸如 Viscek 模型、Couzin 模型、Reynolds 模型、Helbing 模型等专家建模方法^[8],这些模型在一定条件下能产生整体的行为相变与耗散结构涌现。但面对复杂环境威胁时,这些集群模型的条件假设和交互规则过于苛刻,难以表征生物面临的多元复杂性。为此,基于数据驱动的集群交

互建模方法开始崭露头角^[9]。利用大数据的先进计算模型,可以提供更大规模集群行为的灵活解释,同时也增强了单体的环境适应力^[10],如基于实验室鱼群数据的图注意力建模^[11]、利用强化学习技术迁移的生物模型^[12]等方法,为预测和理解复杂集群行为提供了崭新视角。尽管这些研究为理解群体行为提供了有价值的见解,但在群体面临威胁时如何保持集群秩序的韧性,对于这方面的研究仍然不足。

当前的集群韧性研究主要集中在群体的协同避让控制方面,如浙江大学湖州研究院的无人机群在自然非结构化环境中能成功编队避障飞行^[13]。无人机群可在人工智能的辅助下,通过态势感知和集群预测,成功实现集群的精确运动规划,特别是在空间受限的环境中能计算出优化路径。然而,随着环境复杂度的提升,传统的路径规划方法所需的算力呈指数增长,难以有效生成实时韧性策略。与之截然不同的技术路线是抽取生物集群在复杂环境中的运动策略来启发人工集群的宏观韧性。这是因为生物集群规则具有社会交互的灵活鲁棒性、规模伸缩性和组织涌现性。因此,通过生物集群韧性实验进行社会性交互建模具有重要意义,能为规划算法在复杂威胁环境下的应用提供有益参考。

为深入理解生物群体在威胁环境下的集群韧性,首先需要构建可控的生物机械混杂系统。康奈尔大学的集群行为实验室和英国伦敦帝国理工

学院的空中机器人实验室通过构建机器鱼群^[14]和机器鸟群^[15]混杂系统,为可重复地获取集群运动数据作了有益的探索。随着深度学习技术的发展和生物运动数据的获取难度持续下降,基于大数据的复杂系统自动建模逐渐成为可能,借助深度神经网络学习,已成功实现了大规模集群运动的人工智能控制^[16]。然而,传统深度神经网络模型难以有效解析输入数据各组分之间的相互作用关系,需要引入新的交互机制来实现输入信息的关联性处理,深度神经网络模型工具日渐成为分析复杂系统的利器,如图神经网络、图卷积网络和图注意力网络^[17]等。这些技术已在诸多领域展现出巨大潜力,如社交网络分析、生物蛋白设计、交通运输控制、金融风险评估等^[18]。其中,图注意力网络模型能够深入挖掘出信息网络中的注意力结构,通过将其嵌合到集群运动数据的训练过程中,可极大增强模型在处理集群数据方面的泛用性^[19]。因此,该机制生成的集群信息交互模型有望成为解决复杂系统中相互依赖关系的标准模型。

生物机械混杂系统作为一个由众多异质单体组成的复杂系统,其内部单体间存在较为复杂的相互作用关系,而传统模型难以捕捉这些关系的动态性和复杂性。在深度学习技术中,图注意力网络的Transformer结构具有较强的注意力获取能力,在处理复杂且动态的交互系统时具有显著的优势^[20]。注意力机制可使模型聚焦于最为关键的输入特征,这对分析异种生物集群的时间序列轨迹尤为重要。这是因为集群轨迹序列对单体决策的影响具有不同的权重,注意力机制能在不同个体之间动态地分配权重,更加精确地捕获学习群体内的复杂交互模式。基于此机制进行自动建模有助于深入探索群体间的相互作用,如文献^[11]利用注意力机制来探索同种个体的集群行为。而对于异种具有对抗关系的集群行为,其交互建模难度更大。因此,将注意力机制应用于机器-生物混杂系统的运动建模中,是解析单体交互行为的重要创新。

集群韧性行为复杂,因此,本文从基础的2鱼受控威胁实验获取鱼群交互模型,为更大规模的集群威胁躲避行为提供基础解释。本文的贡献在于借助深度学习技术对自主研发的生物机械混杂系统进行2鱼实验数据分析,以初步探索鱼群在复杂威胁环境下的交互行为与适应韧性。

1 生物机械混杂系统实验

1.1 混杂系统实验设计

选用红鼻剪刀鱼(Hemigrammus)^[21]作为集群运动的实验对象,这种小型鱼类体长约为3~4 cm,以其群体高度的和谐共处和独特的运动模式受到研究者的关注。如图1(a)所示,实验将红鼻剪刀鱼放置于直径50 cm、高度10 cm、水温24℃的亚克力圆环内。该圆环边界位于水位高3 cm、边长1 m的玻璃方缸正中心。玻璃缸下方装配有十字导轨机械平台,通过磁耦合连接在可控的3D打印方块上来模拟环境威胁,如图1(b)所示。通过顶部的高清摄像机可以记录鱼群与机器方块的运动轨迹。实验设计为每次随机选取2条被试鱼放入实验环境中,静置10 min后,开始连续控制机器方块顺时针运动接近被试鱼,2鱼会在躲避机器的同时保持紧凑的距离。为了保证鱼群的实验活力和自然行为,将每对鱼与机器交互的时间限制在10 min内,总共记录15 d约10 h的运动录像。利用Yolo算法^[22]追踪鱼群和机器人的轨迹,用于设备控制。本实验严格遵守伦理审查规定,确保所有实验操作的合法性和对参与生物的权益保护。

1.2 实验数据探索与处理

利用idtracker软件^[23]对视频中的鱼群行为进行轨迹跟踪和数据获取,从视频中提取出运动体的二维轨迹数据,并将跟踪数据导出为CSV格式文件。idtracker在某些特定条件下无法准确识别出鱼的位置,如光照波动、机器遮挡、2鱼接近以及光线反射等情况,这些都可能造成跟踪错误。此外,数据中还有2鱼跟踪轨迹的串动交换问题。为解决上述问题,自制软件将运动轨迹进行分段处理,分割出每次机器接近2鱼的攻击行为,具体方法如下:以机器最接近任一鱼的时刻为中心,保留前后5.5 s的轨迹数据,以方便数据对齐修正,同时能保证数据记录的威胁过程完整性。由于原始数据的采样周期不稳定,每秒约有16帧左右的记录,采用样条插值法对原始数据进行重采样处理,精确产生每秒25帧的轨迹记录,即重采样周期为 $\Delta t = 0.04$ s,从而提高数据分析运动体的速度精度,再对人工挑选的分段数据进行数字低通滤波来消除轨迹的抖动噪声。

鱼群实验的不确定性会导致实验边界内不同




图1 生物机械混杂系统实验

Fig.1 Biomechanical hybrid system experiment

区域的机器鱼群交互片段不均匀。因此,将所有数据集以实验台中心为原点按八等分旋转复制,确保训练片段在整个实验空间内均匀分布,训练数据的密度分布如图1(c)所示。该图表明,机器与2鱼交互的位置主要处于圆环半径的中段区域,即远离实验中心与边界。将韧性交互模型迁移到课题组自主研发的集群机器人^[24]上进行分布式控制,令实验圆环半径 $R=25\text{ cm}$ 为1个单位,对所有数据进行规范化,从而方便后续机器人变尺度地使用韧性交互模型。

图1(d)展示了鱼群实验的运动参数,具体为鱼1、鱼2和机器 r 相互之间的交互信息。其中: $o(0,0)$ 为原点; ϕ_1 、 ϕ_2 为2鱼的航向角; $\Delta\phi$ 为航向角差; ψ 为邻居观测角; θ_{1w} 为鱼1对墙角度; d 为2鱼距离; d_{r1} 、 d_{r2} 为机器与2鱼的相对距离; v_1 、 v_2 为2鱼速度。 t 时刻机器、鱼1和鱼2的位置分别为 $(x_r(t), y_r(t))$ 、 $(x_1(t), y_1(t))$ 和 $(x_2(t), y_2(t))$,对应速度矢量则为 $(v_{rx}(t), v_{ry}(t))$ 、 $(v_{1x}(t), v_{1y}(t))$ 和 $(v_{2x}(t), v_{2y}(t))$,其中

$$v_{ix}(t) = (x_i(t) - x_i(t - \Delta t)) / \Delta t, \quad i = 1, 2, r \quad (1)$$

$$v_{iy}(t) = (y_i(t) - y_i(t - \Delta t)) / \Delta t, \quad i = 1, 2, r \quad (2)$$

定义机器、鱼1、鱼2到边界的距离为 r_{rw} 、 r_{1w} 和 r_{2w} , 计算如下:

$$r_{iw}(t) = R - \sqrt{x_i(t)^2 + y_i(t)^2}, \quad i = 1, 2, r \quad (3)$$

定义 t 时刻机器、鱼1和鱼2相互之间的距离 $d_{r1}(t)$ 、 $d_{r2}(t)$ 和 $d_{12}(t)$ 为

$$d_{r1}(t) = \sqrt{(x_1(t) - x_r(t))^2 + (y_1(t) - y_r(t))^2} \quad (4)$$

$$d_{r2}(t) = \sqrt{(x_2(t) - x_r(t))^2 + (y_2(t) - y_r(t))^2} \quad (5)$$

$$d_{12}(t) = \sqrt{(x_2(t) - x_1(t))^2 + (y_2(t) - y_1(t))^2} \quad (6)$$

对上述数据综合, 获得18维的训练数据属性矩阵:

$$\mathbf{s} = [x_r, y_r, v_{rx}, v_{ry}, r_{rw}, x_1, y_1, v_{1x}, v_{1y}, r_{1w}, x_2, y_2, v_{2x}, v_{2y}, r_{2w}, d_{r1}, d_{r2}, d_{12}]^T$$

该矩阵包括机器、鱼1和鱼2的位置、速度、相对边界距离以及相互距离, 训练数据的标签为2条鱼下一时刻 $t + \Delta t$ 的加速度, 鱼1的加速度为 $\mathbf{a}_1(t + \Delta t) = (a_{1x}(t + \Delta t), a_{1y}(t + \Delta t))^T$, 鱼2的加速度为 $\mathbf{a}_2(t + \Delta t) = (a_{2x}(t + \Delta t), a_{2y}(t + \Delta t))^T$ 。 $a_x a_y$ 为 x 和 y 轴方向的加速度大小, 实验汇集了28万条数据

供深度网络训练。

1.3 基于注意力的韧性交互模型

设计如图2所示的韧性交互网络模型, 该模型包括4个核心组件: 编码网络、图注意力网络、信息聚合网络以及解码网络。交互模型引入

注意力机制的主要目的是高效处理时间序列数据, 尤其针对复杂交互系统的动态输入, 注意力机制能动态筛选单体周围不同层次的时空信息, 并较为精确地量化输入时序轨迹的交互权重, 从而为模型端对端训练的行为预测提供合理的处理机制。




图2 韧性交互模型结构

Fig.2 The resilient interaction model structure

该设计核心借鉴了图注意力领域的 Transformer 架构^[25], 旨在捕捉 2 鱼交互作用的时间序列影响。文献^[26]中指出: 红鼻剪刀鱼的平均决策周期约为 0.15 s, 所以采用决策时刻 t 之前的 4 个采样周期 0.16 s 内 5 个连续时刻的状态 $s(t-4\Delta t)$, $s(t-3\Delta t)$, $s(t-2\Delta t)$, $s(t-\Delta t)$, $s(t)$ 数据作为网络模型的输入, 利用注意力机制产生 2 鱼的加速度决策 $a_1(t+\Delta t)$ 和 $a_2(t+\Delta t)$ 。该模型首先利用编码网络对输入的状态时间序列进行编码处理; 随后的图注意力网络根据编码后的信息计算不同时刻状态间的注意力强度, 以便挖掘出对当前时刻决策影响最大的历史时刻数据; 信息聚合网络利用相互注意力强度整合状态的时间序列, 过滤出单体决策的重要信息; 最后, 解码网络则基于过滤后的信息输出 2 鱼的加速度。

具体数据流程为: 将批量为 B 的不同时刻 5 个状态序列组织成维度为 $[B, 5, 18]$ 的信息张量, 接着将该张量输入至 3 个同构的全连接编码网络中, 网络结构均为 $[18, 128, D_{ATT}]$ 。其中: 18 为输入神经元维度; D_{ATT} 为注意力编码维度。根据作用的不同, 分别将这 3 个网络命名为查询编码器 Q 、键编码器 K 和值编码器 V , 编码网络采用了 Mish 激活函数:

$$y = x \cdot \tanh(\ln(1 + e^x)) \quad (7)$$

由于 Mish 激活函数具有类似 ReLU 函数的优点, 它不仅保证了良好的梯度传播能力, 同时还

具备光滑的转折点和单调递增的特性, 有助于保持输出的稳定性, 同时, 又能避免梯度消失问题的发生。其中, 当前时刻的状态 $s(t)$ 被复制 5 次输入到查询编码器 Q , 形成查询表 $[Q_t, Q_t, Q_t, Q_t, Q_t]^T$, Q_t 维度为 D_{ATT} 。

$s(t-4\Delta t)$, $s(t-3\Delta t)$, $s(t-2\Delta t)$, $s(t-\Delta t)$, $s(t)$ 分别被键值编码器 K 、数值编码器 V 转化为与查询表同维度的键值表 $[K_t, K_{t-\Delta t}, \dots, K_{t-4\Delta t}]^T$ 和数值表 $[V_t, V_{t-\Delta t}, \dots, V_{t-4\Delta t}]^T$, 将查询表与键值表合并输入到图注意力网络中。该网络采用多层感知器 (MLP) 架构, 神经元维度为 $[2D_{ATT}, 64, 32, 1]$, 目的是逐步提取当前时刻与之前时刻状态的综合相关性。其中, MLP 的中间层采用 Tanh 激活函数, 因其导数在 $-1 \sim 1$ 之间, 能有效防止梯度消失, 从而促进模型在训练过程中的稳定收敛。注意力网络的输出层选用 Sigmoid 激活函数 $\sigma(\cdot)$, 可将网络输出限制在 $(0, 1)$ 区间内, 有助于后续信息加权聚合, 注意力网络输出不同时刻对当前决策的关联强度为

$$k_{t'} = \sigma(f_{MLP}(K_{t'}, Q_t)), t' = t, t-\Delta t, \dots, t-4\Delta t \quad (8)$$

为防止信息聚合出现饱和, 对上述权值进行归一化处理来保证不同历史时刻对当前决策输出的统一约束, 注意力强度归一化后形成聚合权值:

$$W_{t'} = k_{t'} \left/ \sum_{t'=t}^{t-4\Delta t} k_{t'} \right., t' = t, t-\Delta t, \dots, t-4\Delta t \quad (9)$$

聚合权值反映了各历史时刻对当前决策的重要性, 可将这些权重值与数值表进行加权综合。

将当前时刻状态的加权值 $W_t V_t$ ，以及历史时刻状态的加权平均值 $\sum_{t'=t-\Delta t}^{t-4\Delta t} W_{t'} V_{t'}$, $t' = t - \Delta t, \dots, t - 4\Delta t$ 拼接在一起输入到两个解码网络中，分别得到 2 鱼的下一时刻加速度预测 $\mathbf{a}_1(t + \Delta t)$ 和 $\mathbf{a}_2(t + \Delta t)$ 。解码网络采用两个结构相似的 MLP 结构，网络维度为 $[2D_{\text{ATT}}, 128, 2]$ ，输入层维度代表当前时刻加权值与历史加权平均值的拼接，输出维度代表单体鱼的两个垂直方向的加速度。

由于需要预测单体鱼下一时刻的加速度数值，所以选取均方误差 (MSE) 作为模型的训练损失函数：

$$\ell_{\text{MSE}} = \frac{1}{E} \sum_{e=1}^E (\mathbf{Y}_e - \hat{\mathbf{Y}}_e)^2, e = 1, 2, \dots, E \quad (10)$$

式中， $\mathbf{Y}_e$ 为第 $e+1$ 状态下的加速度真值：

$$\mathbf{Y}_e = (a_{1x}(e+1), a_{1y}(e+1), a_{2x}(e+1), a_{2y}(e+1))^T, e = 1, 2, \dots, E \quad (11)$$

实验使用的训练主机为 Dell Precision 3660，GPU 配置为 NVIDIA GeForce RTX 3090。数据集采用留出法进行划分，网络模型利用 PyTorch 框架编写，并通过 Dropout 和早停法这两种策略来防止过拟合。模型训练参数具体如下：批大小为 20480，模型维度为 50，学习率为 0.00005，权重衰减率为 0.0005，输入维度为 18，留出率为 0.7。

2 韧性交互模型仿真实验分析

构建基于 LabView 的多智能体仿真程序，该程序可实现多智能体的受控运动。同模型训练一致，令仿真环境圆环的半径为 1，机器智能体采用圆周轨道以实验相同的速度靠近两个类鱼智能体。将仿真周期定为模型训练数据采样周期 Δt ，考虑仿真时刻 t ，两个类鱼智能体的位置为 x_{it} 和 y_{it} ，速度为 $v_{ix,t}$ 和 $v_{iy,t}$ ，环境信息为 $r_{iw,t}$ ，以及距离信息为 $d_{r1,t}, d_{r2,t}, d_{12,t}$ ，构成 18 维状态 $\mathbf{s}(t)$ 。结合历史数据，在将最近 4 采样周期的历史数据 $\mathbf{s}(t-4), \mathbf{s}(t-3), \mathbf{s}(t-2), \mathbf{s}(t-1), \mathbf{s}(t)$ 打包成 Json 字符串，通过自制通信协议发送给 Python 编写的韧性交互模型。训练固化后的交互模型，随即计算出两个类鱼智能体下一时刻的加速度决策输出 $(a_{1x}(t+1), a_{1y}(t+1), a_{2x}(t+1), a_{2y}(t+1))^T$ ，并将决策信息打包成 json 字符串反馈至仿真平台。

仿真软件根据如下公式更新两个类鱼智能体的速度与位置：

$$v_{ix}(t+1) = v_{ix}(t) + a_{ix}(t+1) \quad (12)$$

$$v_{iy}(t+1) = v_{iy}(t) + a_{iy}(t+1) \quad (13)$$

$$v_i(t+1) = \|[v_{ix}(t+1), v_{iy}(t+1)]^T\| \quad (14)$$

$$\phi_i(t+1) = \arctan \frac{v_{iy}(t+1)}{v_{ix}(t+1)} \quad (15)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \cos(\phi_i(t+1)) \Delta t \quad (16)$$

$$y_i(t+1) = y_i(t) + v_i(t+1) \sin(\phi_i(t+1)) \Delta t \quad (17)$$

式中， $i = 1, 2$ 。

由于加速度 $(a_{ix}(t+1), a_{iy}(t+1))$ 是网络模型输出，所以速度更新公式将模型输出的加速度当作 $t+1$ 时刻的速度差分增量，直接与 t 时刻的速度相加来更新速度矢量。根据类鱼智能体更新后的位置 $(x_i(t+1), y_i(t+1))$ ，可实时确定机器智能体的圆形运动轨道。与生物-机械混杂实验类似，机器智能体动态交互类鱼智能体的仿真可分为 3 个阶段：接近、交互、远离。初始状态时，两个类鱼智能体被随机放置在距离机器智能体较远的位置，随着仿真机器的顺时针接近运动，距离最近的类鱼智能体距离达到阈值 d_{TH} 时，启动 Python 模型决策，将机器智能体状态与类鱼智能体状态发送到韧性交互模型，进入模型的交互过程。在此期间，仿真机器继续根据动态的圆形轨道匀速运行，两个类鱼智能体按模型输出决策更新运动。当机器远离最近的类鱼智能体时，结束该仿真流程，继续在空间中重新随机生成新的两个类鱼智能体，类鱼智能体的位置、朝向公式为

$$\theta = 2\pi g \quad (18)$$

$$r = 0.8 + \gamma(g - 0.5) \quad (19)$$

$$x_i = r \sin(\theta + \gamma(g - 0.5)) \quad (20)$$

$$y_i = r \cos(\theta + \gamma g) \quad (21)$$

$$\phi_i = 2\pi g \quad (22)$$

式中： g 为 0~1 之间的随机变量； γ 为噪声幅度。

根据图 1(c) 中 2 鱼游动所在的高密度区域位置，在仿真实验中取距边界 0.3 的距离作为类鱼智能体的初始位置，以保证初始位置符合混杂实验条件要求。重复使用模型验证程序 1 h，记录实验

数据, 仿真参数 d_{TH} 取 0.3, 符合生物-机械混杂实验中机器和鱼交互的一般距离。由于仿真半径 1 对应真实混杂实验的 25 cm 边界半径, 阈值 d_{TH} 相当于机器距离鱼的真实距离 7.5 cm, 大约是红鼻剪刀鱼的 2 倍身长。混杂实验数据表明, 当机器靠近单体达 2 倍身长左右时, 单体的平均响应游速会超过自由状态下的基本游速值 7 cm/s^[26]。

记录每仿真周期机器智能体、类鱼智能体的位置, 以供与生物-机械混杂实验数据进行对比。对比参数除了之前定义的系统状态以外, 还包括 2 鱼各自测量邻居的航向角差 $\Delta\phi_i$, 以及观测邻居的视角 ψ_i , 如图 1(d) 所示。其中, 速度、对墙距离 r_{iw} 和对墙角度 θ_{iw} 可用于评价单体的个性化行

为, 而 2 鱼距离 d 、航向角差 $\Delta\phi_i$ 和视角 ψ_i 等参数则描述了 2 单体之间的交互性。机器与鱼的互动参数包括相对机器距离 d_{ir} 、相对机器运动的航向角差 $\Delta\phi_{ir}$ 、观测机器视角 ψ_{ir} 等参数。

2.1 机器混杂条件下的单体行为分析

2 鱼之间的交互可用相对间距 d_{12} 、航向角差异 ϕ_{12} 以及邻居观测视角 ψ_{12} 进行表征, 这些参数的概率密度分布如图 3 所示。其中, 黑线为混杂实验数据, 红线为模型仿真数据。图 3(a) 展示的 2 鱼距离概率密度图显示了 2 鱼运动的社会性, 即多数时间 2 鱼倾向于保持较为紧密的联系, 2 鱼距离为 0.16 时, 混杂实验(黑线)的概率密度到达峰值, 维持在 2 倍身长以内。




图 3 2 鱼交互行为数据统计分析

Fig.3 Statistical analysis of interaction behavior data between two fish

图 3(a) 表明, 模型仿真的结果(红线)显示 2 鱼的距离更加紧凑, 这表明韧性交互模型能够较好地复现鱼类的社会性运动, 剥离了一些鱼类独立的个体行为。黑色曲线具有胖尾特性, 表明真实鱼类的独立行为更加丰富。图 3(b) 黑色曲线在航向角差 0°附近达到峰值, 表明 2 鱼有较强的对齐行为, 模型仿真(红线)的结果更加陡峭, 意味着模型的 2 鱼韧性运动相较于真实鱼类具有更高的联动性, 滤除了鱼类的自由行为, 凸显了数据的共性交互行为。图 3(c) 表明, 邻居视角的概率密度具有三峰形态, 中锋为跟随者视角分布, 两侧峰为领导者视角分布。其中, 领导者被定义为视角 $|\psi| > \pi/2$ 的鱼; 跟随者被定义为邻居观察视角 $|\psi| \leq \pi/2$ 的鱼。图 3(c) 曲线在 $\pm 90^\circ$ 附近有凹陷, 说明 2 鱼倾向于前后主从运动。由于机器一直是顺时针接近鱼类, 所以 2 鱼一般会出现顺时针的逃逸偏态, 仿真模型相较于真鱼实验, 更有把握应对机器逃逸, 所以分布偏态更明显。

鱼与机器之间的交互可用相对间距 d_r 、航向角

差异 $\Delta\phi_r$ 以及观测机器视角 ψ_r 来表征, 如图 4 所示。其中, 黑线为混杂实验统计, 红线为模型仿真统计。图 4(a) 表明在鱼与机器近距交互($d_r < 0.5$)时, 领导者由于率先对机器进行避让, 相对跟随者距机器的峰值距离稍远。由于目的明确, 领导者相对跟随者的速度峰值更高, 跟随者采用随动策略, 距离机器的距离相对靠近, 距离峰值也较底。需要特别指出的是: 由于真实鱼群与机械之间具有物理作用, 当机器与真实鱼群较近时, 机器运动的水波会自动推开靠近的鱼群, 反映在图 4(a) 中模型仿真的 d_r 参数相较于真实鱼类要小; 当机器远离鱼群时($d_r > 0.5$), 鱼群倾向于自由运动, 模型训练出来的结果较真鱼相比会因动力学系统保持一定的逃逸惯性, 与真实实验相比, 与机器的距离更大, 具有更强的交互安全性。图 4(b) 为模型仿真与混杂实验中单体相对机器的航向角差, 由图可见, 单体相对机器运动方向的统计峰值为顺时针锐角。这表明当机器顺时针接近鱼类时, 单体多数采用顺时针远离边界的方向躲避机器冲




图4 鱼与机器交互行为数据统计

Fig.4 Statistical analysis of interaction behavior data between fish and machine

击，以获取更大的运动空间。 $\Delta\phi_r=0$ 说明，也有部分情况下单体与机器运动方向一致，形成机器对鱼的追击逃逸。图4(c)的鱼群观察机器视角曲线具有 $\pm 180^\circ$ 的峰值，表明机器人多数出现在单体的右后方，与图4(b)的结果可以相互印证。

2.2 2 鱼韧性运动的整体性秩序分析

为探索生物体与机器之间的速度相关性，定义函数 $C(t)$ 来表征机器与鱼群之间的速度时序关联：

$$C_n(\tau) = \frac{1}{2} \sum_{i=1}^2 \sum_{t=0}^T (v_{ix}(t)v_{ix}(t+\tau) + v_{iy}(t)v_{iy}(t+\tau)), \quad n \in N, \tau \in T \quad (23)$$

式中， N 为机器(机器智能体)与实验鱼(类鱼智能体)总的交互次数。考虑第 n 次交互，在机器接近

的过程中，当 $t=0$ 时，机器与某单体鱼距离最近，开始利用式(22)计算 T 个时刻内机器的速度矢量与 τ 时刻的单体速度矢量的平均点积，以此来表征机器与单体的运动相关性。计算 N 次交互相关性 $C_n(t), n \in N$ 的均值与方差， $T=30$ 时，采样周期为 $\Delta t=0.04$ ，整体时间约为1.2 s，基本能覆盖鱼类韧性躲避机器的全过程。取真鱼实验交互与模型仿真交互次数为 $N=300$ ，统计结果如图5(a)所示。该图表明，无论是模型仿真还是真实实验，在 $\tau=0$ 时，机器与鱼类的运动速度最相关。单体先顺着机器的运动方向给出响应，然后改变方向逃离机器，使得在1.2 s的交互时间内，机器与单体的运动相关性逐渐降低，完成韧性躲避。仿真模型相较于混杂实验而言，逃逸模式更加确定，方差较小，但曲线均值趋势一致。




图5 鱼类-机器运动的相关性与协调性

Fig.5 Correlation and coordination of fish-machine movement

为评估2鱼运动的协调性，对2单体的运动极性量化为 P 值，该参数可用于集群运动一致性的评定指标^[21]，具体如下：

$$P(t) = \frac{1}{M} \left\| \sum_{i=1}^M \frac{\mathbf{v}_i}{\|\mathbf{v}_i\|} \right\| \quad (24)$$

式中： M 为智能体个数，由于为2鱼研究，该值取2； $\mathbf{v}_i = (v_{ix}, v_{iy})^T$ 为第 i 单体的速度矢量； $\|\cdot\|$ 表示向量长度。 $P(t)$ 在 $(0, 1)$ 区间取值，当 $P=1$ 时，2鱼航向一致， $P=0$ 时，代表2鱼航向相反。

以机器接近真鱼和类鱼智能体距离最小开

始, 记录 3.2 s 的模型仿真与混杂实验的极性值, 统计结果如图 5(b) 所示。该图表明, 无论模型仿真还是混杂实验, 2 单体的极性值在记录时间序列中的首尾位置均保持了较高的极性水平, 并都在中部呈现出 P 值凹陷的特征。这说明模型仿真与真鱼行为的整体秩序都受到了机器影响, 并在远离机器的过程中逐渐恢复整体的运动秩序, 体现了集群秩序涌现的韧性。这是一个吸收外部干扰、消化内部影响、整合内外信息、弹性缓冲恢复的过程。由于模型汇集了大部分韧性数据的平均特征, 并经过 Loss 函数的启发优化, 韧性运动的极性越高, 受影响的方差越小, 逃离的动作越准确, 运动秩序恢复得越迅速。而真实鱼具有生物

运动的随机性, 因此, 方差较大, 极性也略低。

2.3 机器鱼类模型的交互运动分析

从混杂实验中选取 3 种典型的运动状态, 分别为机器靠近单体、单体逃离机器、单体运动靠近边界。从真实实验数据中选取 4 个典型的运动场景, 保留起始的 5 个采样周期运动序列, 同时输入到所提韧性交互模型中进行对比。迭代模型产生 3 周期的仿真控制轨迹, 再与混杂实验的后续 3 个采样周期真值结果进行对比, 结果如图 6 所示。图中, 红色方块代表机器, 橙色和蓝色鱼体代表交互单体, 黑色线段为真实混杂实验的运动轨迹, 前 5 点为初始运动轨迹, 模型对橙鱼与蓝鱼的运动决策输出分别使用橙、蓝线段表征。




图 6 典型场景下的混杂实验与模型仿真轨迹分析

Fig.6 Trajectory analysis of hybrid experiments and model simulations in typical scenarios

图 6(a) 和 (b) 分别展示了机器从不同方位接近鱼群。图 6(a) 显示了机器从右侧靠近蓝鱼, 蓝鱼的模型预测曲线(蓝色线段)与真实实验轨迹(黑色线段)相比, 向远离机器的方向偏移, 说明模型通过学习, 能够获得较为安全的运动策略。另外, 由于橙鱼相对蓝鱼而言距离机器较远, 模型预测轨迹(橙色线段)与真实实验轨迹(黑色线段)较一致。图 6(b) 展示了机器从左侧靠近 2 鱼, 由于机


器运动方向指向橙鱼, 造成橙鱼模型输出曲线(橙色线段)相较于实际轨迹, 略微远离机器。这种偏转同时影响到蓝鱼, 使得蓝鱼运动相较于实际轨迹也远离机器。图 6(c) 展示了机器追击鱼群时, 2 鱼靠近边界时的模型响应。由于橙鱼更加靠近边界, 模型输出曲线相较于真实数据曲线, 更偏于内部运动。而由于蓝鱼距边界较远, 模型轨迹输出受边界的影响略小, 蓝色线段基本与实际轨迹

黑色线段一致。图6(d)也是显示机器对鱼群的追击,但是由于远离边界,单体交互的模型输出基本不受机器与边界的影响,具体表现为橙、蓝2鱼的模型输出轨迹与真实轨迹一致。综合上述4种典型场景的模型-实验轨迹对比发现,韧性交互模型能够有效抓取单体与机器、邻居、边界的交互特征,在滤出鱼类的个性化随机运动后,可以应对机器的冲击,并同时符合边界约束,还能保持整体的协同运动秩序,体现了模型高度的社交韧性。


2.4 机器威胁的参数敏感性分析

在所获决策网络模型的基础上,将2鱼固定在运动的典型位置上,分析不同机器威胁情况下鱼类单体的影响机制,从而利用模型来提升鱼群避让协同行为的可解释性,为后续大规模集群威胁下运动建模提供依据。图7(a)设计了机器威胁

2鱼的4种不同情况,分别为机器迎击焦点鱼,红色箭头所示,机器追击用绿色箭头表示,机器左右侧击分别用蓝色箭头和紫色箭头表示。保持2鱼位置固定,令机器从各箭头远端0.3的位置开始,到距离焦点鱼0.02位置处停止。在4箭头每个方向上均匀布置12个点作为机器威胁,位置为 $u_m^F, u_m^B, u_m^L, u_m^R, m=1, 2, \dots, 12$,上标F, B, L, R分别表示前、后、左、右4个方向。在每个位置处,机器以固定速度0.01沿4箭头方向接近焦点鱼,同时产生相应的历史位置。保持机器速度与2鱼当前的历史状态不变,按从远及近的顺序推进机器,远端 $m=1$,近端 $m=12$,并推算模型输入的其他信息,包括机器距墙距离和机器距2鱼距离,输入所提模型,记录模型在不同机器位置处输出的焦点鱼加速度 $a_x^H(m), a_y^H(m), H=F, B, L, R$,并分别计算不同方向模型输出的加速度增量,具体为



(a) 机器和焦点鱼交互轨迹示意图



(b) 机器和焦点鱼交互过程的加速度变化

图7 机器威胁的参数敏感性分析

Fig.7 Parameter sensitivity analysis of machine threat

$$|\Delta a^H(m)| = \left| \sqrt{(a_x^H(m))^2 + (a_y^H(m))^2} - \sqrt{(a_x^H(m-1))^2 + (a_y^H(m-1))^2} \right|,$$

$$m=1, 2, \dots, 12, H=F, B, L, R, \quad (25)$$

鱼从距离目标0.325的位置出发,模型输出结果如图7(b)所示。

由图7(b)可以发现:随着机器从4个方向逐渐接近焦点单体,模型输出的焦点单体加速度变化 Δa 逐渐增大,迎击方向机器距焦点单体约0.12时出现快速变化,表明焦点鱼对正面威胁的机器响应较早,并且整体的逃离行为曲线也比其他方向的高;与之对应的是,当机器追击焦点单体时,需要靠近到0.04左右才能触发焦点单体

的响应,与迎击方向相比,焦点单体对迎击方向更加敏感,这是由于鱼类视觉盲区在背后而导致的;总体而言,侧面威胁的单体响应介于正面威胁与后面威胁之间,并且从边界出发的威胁与从中心出发的威胁相比,焦点单体对中心攻击路线(紫色方向)更敏感。这可能是因为边界作为障碍,与机器在一侧时,焦点与对边界已经有了一定的避让初值,导致蓝色攻击方向的加速度改变较小,与之对应从中心过来的威胁(紫色方向)拥有更强的冲击响应。

3 韧性交互模型的集群秩序

生物机械混杂系统具有高度的控制复杂性,

引入真鱼实验来研究系统的韧性交互，模型能充分考虑单体交互过程中的全部时空数据，并通过注意力机制来解析时空信息的潜在关联，涌现出了较为稳定的集群躲避行为。所提模型能对环境中的关键时空信息进行动态加权，从而实现对鱼群韧性运动的精确复现。与传统自由运动鱼群数据的深度学习解析方法相比，生物-机械混杂系统中的单体遭受了更严苛的环境考验，较难实现鱼群运动的协同行为。为此，对比一些典型的自由鱼群数据驱动建模方法，观察这些模型在2鱼运动仿真下的整体运动秩序，记录1 h 仿真实验的统计结果，如表1所示。选取的集群运动模型有2鱼自由运动的最大影响力模型^[27]、IAT模型^[11]、最强视觉DNN模型^[28]、硬注意力模型^[29]以及本文韧性交互模型。对比模型都是在自由状态下的协同仿真，本文所提模型是在机器冲击下的协同仿真，运动协同性的统计参数包括集群运动极性 P 值、2鱼间距 d_{12} 、2鱼航向角差 ϕ_{12} 和跟随者观察领导者的视角 ψ_F ，这些参数体现了2鱼运动的社会交互协同行为。

表1中的极性 P 值能衡量2鱼运动的一致性，

数值越接近1表示2鱼的运动方向越相同。其中，最强视觉模型表现出了极高的均值和极低的方差，这是因为该模型利用了自由运动的2鱼数据训练；DNN模型能充分复现自由运动的整体秩序；硬注意力模型采用自由多鱼运动数据训练，也能产生较好的运动极性；最大影响力模型利用的是数学公式建模，由于具有一定的主观性，所以整体极性相较于深度学习模型有略微下降；基于图神经网络的IAT模型由于内部考虑的连接系数更多，所以性能也与最大影响力模型接近。这些自由模型的极性均能达到0.95，而所提韧性交互模型能在受机器干扰的情况下保持0.95以上的极性，表明所提模型的抗干扰能力达到了较高水平。在韧性运动的过程中，2鱼的运行间距 d_{12} 、航向角差 ϕ_{12} 也是处于众多集群运动模型的平均水平，表明所提韧性模型能够在复杂威胁环境下提供较为稳定的运动秩序。韧性交互模型跟随者观察领导者的视角 ψ_F 的方差较大，表明鱼类再受威胁干扰的情况下会出现较大的行为波动，但是韧性模型的跟随均值与其他模型持平，说明跟随者对领导者的跟踪较为稳定。

表1 不同集群运动模型仿真的运动协同性

Tab.1 Movement coordination in simulations of different swarming models

指标	最大影响力模型 ^[27]	IAT模型 ^[11]	最强视觉DNN模型 ^[28]	硬注意力模型 ^[29]	韧性交互模型
P	[0.95±0.07]	[0.95±0.03]	[0.99±0.01]	[0.986±0.012]	[0.954±0.034]
d_{12}	[0.10±0.08]	[0.10±4.26]	[0.02±0.16]	[0.06±0.22]	[0.09±0.0028]
ϕ_{12}	[(2.73e-17)±0.33]	[(8.71e-18)±0.44]	[0±0.07]	[(4.08e-18)±0.11]	[(6.27e-05)±0.19]
ψ_F	[0.0052±0.043]	[-0.22±0.33]	[-0.029±0.51]	[0.15±0.036]	[-0.07±0.52]

4 结 论

综合上述实验数据分析，韧性交互模型揭示了两个智能体在复杂环境交互下的单体控制策略。注意力机制可以较好地应对时间序列的前后关联，支撑了单体生物在面临外在威胁时的行为模式生成，并能在整体上呈现较强韧的运动秩序。在此基础上，定量分析了机器威胁对鱼类单体的影响作用，为理解单体韧性交互行为提供了科学依据。所提模型能使单体正确应对环境威胁，并能根据邻居状况作出较为一致的运动响应，为下阶段构建更大规模群体在威胁环境下的韧性运动提供理论支撑。通过模型验证，注意力机制可有效获取多体复杂交互的时空关系，可作

为大规模威胁集群运动模型的主干网络，通过模型的扩展，将更多邻居信息输入到所提模型编码器中，就可以直接获得较大规模集群的焦点单体决策。通过实验发现单体对机器威胁的响应具有各向异性，这为后续设计大规模集群交互模型的机器避让结构提供重要线索。如可将三角函数和指数衰减函数嵌入到注意力框架之中，通过端对端的训练还原单体决策网络内部的可解释结构。

生物机械混杂实验数据深度网络交互模型有望应用于真实的集群机器人系统控制，与基于控制理论的优化方法相比，生物启发集群技术具有更强的鲁棒灵活性。生物单体在威胁情况下掉队、死亡和加入不会影响整体的任务性能，所以采用生物-机器混杂实验数据可获得的单体决策模

型具有更强的自然协同性,在集群机器人领域具有广泛的应用潜力。例如:在军事对抗方面,模仿鱼群协调行为的无人机、无人艇、机器狗群,在威胁条件下可以实现集群的韧性协同;在军事辅助方面,利用仿生机械系统模拟自然集群行为,可有效产生自然集群的雷达特征,有利于侦察、搜救和监视任务执行;在智能交通方面,所提方法可以指导自动驾驶车队有效应对其他车辆的恶意驾驶行为,提升系统的群体协调性;在集群物流方面,机器人集群能有效避让操作工人的干扰,合作搬运货物;在混杂养殖方面,该模型可用于分析鱼群行为,评估鱼群的建康状况。综上所述,所提方法有助于模拟、分析、管理、干预复杂集群系统的运动行为,在未来集群智能调控方面具有较为广阔的应用前景。

参考文献:

- [1] ISLAM M S, FARUQUE I A. Insect visuomotor delay adjustments in group flight support swarm cohesion[J]. *Scientific Reports*, 2023, 13(1): 6407.
- [2] JHAWAR J, MORRIS R G, AMITH-KUMAR U R, et al. Noise-induced schooling of fish[J]. *Nature Physics*, 2020, 16(4): 488–493.
- [3] 何明, 陈浩天, 韩伟, 等. 无人机仿鸟群协同控制发展现状及关键技术[J]. *航空学报*, 2024, 45(20): 190–212.
- [4] PESHKOV A, MCGAFFIGAN S, QUILLEN A C. Synchronized oscillations in swarms of nematode *Turbatrix acetii*[J]. *Soft Matter*, 2022, 18(6): 1174–1182.
- [5] 刘小峰, 陈果, 刘宇, 等. 动物集群行为的机制和应用[J]. *科学通报*, 2023, 68(23): 3063–3076.
- [6] MOU Z Y, GAO F F, LIU J, et al. Resilient UAV swarm communications with graph convolutional neural network[J]. *IEEE Journal on Selected Areas in Communications*, 2022, 40(1): 393–411.
- [7] DORIGO M, THERAULAZ G, TRIANNI V. Swarm robotics: past, present, and future[J]. *Proceedings of the IEEE*, 2021, 109(7): 1152–1165.
- [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] MANNONE M, SEIDITA V, CHELLA A. Modeling and designing a robotic swarm: a quantum computing approach[J]. *Swarm and Evolutionary Computation*, 2023, 79: 101297.
- [10] ZHANG H, LIU L. Intelligent control of swarm robotics employing biomimetic deep learning[J]. *Machines*, 2021, 9(10): 236.
- [11] 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.
- [12] 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.
- [13] ZHOU X, WEN X Y, WANG Z P, et al. Swarm of micro flying robots in the wild[J]. *Science Robotics*, 2022, 7(66): eabm5954.
- [14] JIAN X, ZOU T. A review of locomotion, control, and implementation of robot fish[J]. *Journal of Intelligent & Robotic Systems*, 2022, 106(2): 37.
- [15] ZUFFEREY R, SIDDALL R, ARMANINI S F, et al. Between sea and sky: aerial aquatic locomotion in miniature robots[M]. Cham: Springer, 2022.
- [16] 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.
- [17] 普常, 轶鸣赵, 曼玉云, 等. 知识图谱与图神经网络助力智慧城市的可持续发展[J]. *智能城市应用*, 2025, 8(2): 124–128.
- [18] NA S, NIU H L, LENNOX B, et al. Bio-inspired collision avoidance in swarm systems via deep reinforcement learning[J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(3): 2511–2526.
- [19] 王健宗, 孔令炜, 黄章成, 等. 图神经网络综述[J]. *计算机工程*, 2021, 47(4): 1–12.
- [20] HAN K, XIAO A, WU E, et al. Transformer in transformer[J]. *Advances in Neural Information Processing Systems*, 2021, 34: 15908–15919.
- [21] LAFOUX B, MOSCATELLI J, GODOY-DIANA R, et al. Illuminance-tuned collective motion in fish[J]. *Communications Biology*, 2023, 6(1): 585.
- [22] JIANG P, ERGU D, LIU F, et al. A review of Yolo algorithm developments[J]. *Procedia Computer Science*, 2022, 199: 1066–1073.
- [23] ROMERO-FERRERO F, BERGOMI M G, HINZ R C, et al. idtracker. ai: tracking all individuals in small or large collectives of unmarked animals[J]. *Nature Methods*, 2019, 16(2): 179–182.
- [24] 刘磊, 陶杰, 尹钟, 等. 微型机器人以及群机器人系统[P]. 中国, 107175649A. 2017-09-19.
- [25] NIU Z Y, ZHONG G Q, YU H. A review on the attention mechanism of deep learning[J]. *Neurocomputing*, 2021, 452: 48–62.
- [26] 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.

on Systems, Man, and Cybernetics: Systems, 2018, 48(9): 1421–1428.

[17] MUKHERJEE S, LARKIN C, CORBET S. Cryptocurrency Ponzi schemes[M]//CORBET S. Understanding Cryptocurrency Fraud. Berlin: De Gruyter, 2021: 111–120.

[18] HU H W, BAI Q L, XU Y D. SCSGuard: deep scam detection for ethereum smart contracts[C]//Proceedings of the IEEE Conference on Computer Communications Workshops. New York: IEEE, 2022: 1–6.

[19] ALARAB I, PRAKONWIT S, NACER M I. Competence of graph convolutional networks for anti-money laundering in Bitcoin blockchain[C]//Proceedings of the 2020 5th International Conference on Machine Learning Technologies. Beijing: ACM, 2020: 23–27.

[20] YUAN Q, HUANG B Y, ZHANG J, et al. Detecting phishing scams on Ethereum based on transaction records[C]//Proceedings of 2020 IEEE International Symposium on Circuits and Systems. Sevilla: IEEE, 2020: 1–5.

[21] KUTE D V, PRADHAN B, SHUKLA N, et al. Deep learning and explainable artificial intelligence techniques applied for detecting money laundering—a critical review[J]. IEEE Access, 2021, 9: 82300–82317.

[22] SOMEALLI G, GOLDBLUM M, SCHWARZSCHILD A, et al. SAINT: improved neural networks for tabular data via row attention and contrastive pre-training[DB/OL]. [2021-06-02] <https://arxiv.org/abs/2106.01342>.

[23] ELMOUGY Y, LIU L. Demystifying fraudulent transactions and illicit nodes in the Bitcoin network for financial forensics[C]//Proceedings of 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Long Beach: ACM, 2023: 3979–3990.

(编辑:董伟)



(上接第460页)

[27] 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: Association for Computing Machinery, 1987: 25–34.

[28] 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.

[29] 刘磊,葛振业,林杰,等.基于鱼群涌现行为启发的集群机器人硬注意力强化模型[J].计算机应用研究,2024,41(9):2737–2744.

(编辑:丁红艺)