

# 控制与决策

Control and Decision

## 基于深度学习的仿生集群运动智能控制

刘磊, 孙卓文, 陈令仪, 高岩, 王富正, 王亚刚

引用本文:

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.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0071>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 大规模固定翼无人机集群编队控制方法

Formation control of large-scale fixed-wing unmanned aerial vehicle swarms

控制与决策. 2021, 36(9): 2063–2073 <https://doi.org/10.13195/j.kzyjc.2020.0076>

### 基于动态蚁群劳动分工模型的多AUV任务分配方法

A multi-AUV dynamic task allocation method based on antcolony labor division model

控制与决策. 2021, 36(8): 1911–1919 <https://doi.org/10.13195/j.kzyjc.2019.1312>

### 基于MCPDDPG的智能车辆路径规划方法及应用

The method and application of intelligent vehicle path planning based on MCPDDPG

控制与决策. 2021, 36(4): 835–846 <https://doi.org/10.13195/j.kzyjc.2019.0460>

### 微小卫星集群在有界空间表面的均匀分布策略

Uniform distribution strategy of microsatellite swarm on bounded space surface

控制与决策. 2020, 35(12): 2931–2938 <https://doi.org/10.13195/j.kzyjc.2018.1761>

### 微型无人机集群低时延组网规划方法

A low delay networking planning method for micro UAV swarm

控制与决策. 2020, 35(11): 2696–2706 <https://doi.org/10.13195/j.kzyjc.2018.1549>

# 基于深度学习的仿生集群运动智能控制

刘磊<sup>1,2†</sup>, 孙卓文<sup>2</sup>, 陈令仪<sup>2</sup>, 高岩<sup>1</sup>, 王富正<sup>1</sup>, 王亚刚<sup>2</sup>

(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:** 集群运动的自组织控制相较于控制理论方法更具鲁棒性与灵活性, 其中具有强大自组织特性的生物种群多表现为单体的等级交互, 其特点是交互双方各自影响互不对称, 由于信息交互繁杂导致构建等级交互模型仍充满挑战. 鉴于此, 使用深度学习技术分析红鼻鱼的集群运动实验数据, 构建多参数输入的单体等级交互模型, 有针对性地设计成对交互的深度网络结构, 并进行合理训练以获取交互模型, 基于视觉压力挑选出关键邻居, 将此模型用于该邻居的等级交互, 相较于其他邻居选择方式, 所提出智能控制方法与真实鱼类的集群运动具有较一致的宏观特性. 仿真实验表明: 所提出方法能扩展到更大规模的集群聚合运动控制中, 使得单体仅利用局部信息即可实现大规模的集群运动; 该方法具有使用简单、规模灵活、计算快速的特点, 在多机器人控制、智能交通系统、饱和集群攻击以及多智能体物流等领域具有广阔的应用前景.

**关键词:** 集群运动; 等级交互; 深度网络; 智能控制; 自组织

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0071

开放科学(资源服务)标识码(OSID):



**引用格式:** 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.

## Intelligent control of bionic collective motion based on deep learning

LIU Lei<sup>1,2†</sup>, SUN Zhuo-wen<sup>2</sup>, CHEN Ling-yi<sup>2</sup>, GAO Yan<sup>1</sup>, WANG Fu-zheng<sup>1</sup>, WANG Ya-gang<sup>2</sup>

(1. School of Management, 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:** Compared with the method of automatic control theory, the self-organized control for collective motion is more robust and flexible. The strong self-organizing collective motion of biological species is related with individual hierarchical interactions, which is characterized by the asymmetrical influence of the pairwise interaction. Due to the complexity of interaction information, the construction of analytical models of hierarchical interactions is still full of challenges. Based on the deep learning technology, the experimental data of the collective motion of *Hemigrammus rhodostomus* fish is analysed to construct the individual interaction model with multi-parameter inputs. A deep network structure for pair interaction is designed, and the interaction model is obtained by means of proper training. Based on visual pressure, the individual identifies the key neighbour, which is used for hierarchical interaction built by deep neural networks. Compared with other neighbour selection methods, the macro characteristics are more consistent between the proposed intelligent control method and real fish collective motion experiment. Simulation shows that the proposed method can be extended to larger-scale groups for aggregation control with collective motion, so that the individual can take advantage of local information to achieve large-scale collective motion. The proposed control method is simple to use, flexible for different scale, and fast for calculation. Thus, it has broad application prospects in the fields of multi-robot control, intelligent transportation systems, saturated cluster attacks, and multi-agent logistics.

**Keywords:** collective motion; hierarchical interactions; deep neural network; intelligent control; self-organization

## 0 引言

集群运动广泛存在于动物种群中, 单体仅凭借简单的局部交互即可使群体具有更强的环境适应能力, 如捕食者防御、交配繁殖、规模集结、集体迁移等<sup>[1]</sup>, 这些优良的自组织特性引起了研究者的广泛

兴趣. Buhl 等<sup>[2]</sup> 在实验环境下研究了沙漠蝗虫的集群运动, 并讨论了集群迁移的原理; Cavagna 等<sup>[3]</sup> 利用先进测量技术捕获了紫翅琼鸟集群飞行的空中数据, 为鸟群的运动分析提供了坚实的数据基础; 受 Helbing 启发<sup>[4]</sup>, 有学者发现了蚁群逃逸的对称破缺

收稿日期: 2020-01-15; 修回日期: 2020-04-11.

基金项目: 上海市自然科学基金项目(17ZR1419000).

责任编辑: 林崇.

†通讯作者. E-mail: liulei@usst.edu.cn.

性质,为探寻集群运动背后的自组织机理提供了新的思路.上述文献表明,个体之间的局部交互确实可以导致整体的自组织行为,从而使集群具有更强的有序性<sup>[1]</sup>,与多智能体运动的人工控制方法相比<sup>[5-7]</sup>,通过单体的社会性交互而形成的自组织调控更具鲁棒性和灵活性,符合复杂系统的智能控制期望<sup>[8]</sup>.

单体的社会性交互是指单体对分布式信息的传递和使用,主要具有两种结构:等级结构和扁平结构.自然界中的哺乳动物,如人群、兽群多采用等级结构交互,反之,简单生物如细菌、病毒等多采用扁平结构,鸟群、鱼群和昆虫群落基本介于两者之间.扁平结构互动模型比较简单,类似单体之间的物理交互<sup>[9]</sup>,然而多数动物集群会形成领导者与跟随者这样的等级关系<sup>[10]</sup>.因此,从Couzin等<sup>[11]</sup>引领潮流的自组织群体等级关系建模开始,等级交互模型逐渐被研究者认可,并显示出强大的自组织性能<sup>[10,12]</sup>.但是,等级结构研究具有如下难度:1)群体中交互双方的各自影响互不对称,难以进行理论分析;2)等级模型的相关参数较多,建立交互的解析模型仍十分困难<sup>[13]</sup>.因此,构建大规模集群运动的等级交互模型仍是一个开放且具有挑战的问题.

为克服上述困难,尝试建立基于真实鱼群运动数据的深度网络模型,以期获得较好的集群运动智能控制效果.当前深度学习技术蓬勃发展,通过构建有针对性的深度学习网络结构,解析单体的等级交互模型,从而为实现更大规模的灵活分布式控制奠定基础.集群运动的灵活性体现领导者与跟随者关系可以随时改变<sup>[14]</sup>,规模可以自由缩放.

要实现大规模集群运动,现有的集群运动研究通常认为:单体需要受到其邻域内所有邻居的影响,如Vicsek模型<sup>[15]</sup>、Aoki模型<sup>[16]</sup>和Couzin模型<sup>[17]</sup>等,其中Vicsek认为单体的运动方向应与其附近固定距离内所有邻居的平均方向对齐,但也有学者认为单体的社会交互应仅依赖于有限数量的邻居,从而符合单体的有限信息处理能力<sup>[18-19]</sup>.

本文贡献在于:根据真实鱼群数据建立单体的深度网络等级交互模型,并将此模型用于某一个特定邻居的等级交互,从而实现大规模的集群运动.采用深度网络模型的动机在于:以往研究多是基于相对位置建立交互模型<sup>[13,15]</sup>,但是生物交互模型的参数较多,导致建立成对交互的解析模型仍十分困难,所以如何将单体的速度、朝向、位置以及环境、邻居信息全部建入解析模型,便需要借助深度学习技术,从真实鱼群实验数据出发,建立多信息输入的单体等级交

互网络模型.在此基础上,提出了3种单一领导者假设用于融合成对交互模型来生成集群运动,与真实鱼群实验数据进行对比,验证了其中最优的单一领导者假设.

## 1 成对交互的深度网络模型

实验采用两红鼻鱼(*hemigrammus rhodostomus*)的运动数据训练等级交互深度学习模型,该鱼类物种具有突然加速-直线滑行的游泳模式.此模式表明:红鼻鱼会因目标改变在短时间内耗费能量调整航向,增加游速,然后直线滑行<sup>[13]</sup>,意味着可以将单体游动轨迹分解成多个直线运动集合,在直线运动的开端,单体会根据本地信息作出决策,包括滑行距离、滑行持续时间以及航向变化.

使用边长为1.2,高0.2的正方形玻璃鱼缸作为实验平台,在内积蓄7cm水,池中放置一个半径为250mm白色亚克力圆环作为鱼群运动环境,如图1(a)所示.鱼的轨迹由高清摄像机记录,每秒25帧,共进行30小时的两鱼实验用于深度模型训练,11小时的五鱼实验用于集群运动模型验证,idTracker软件<sup>[20]</sup>被用来从录制视频中提取鱼群的运动轨迹.

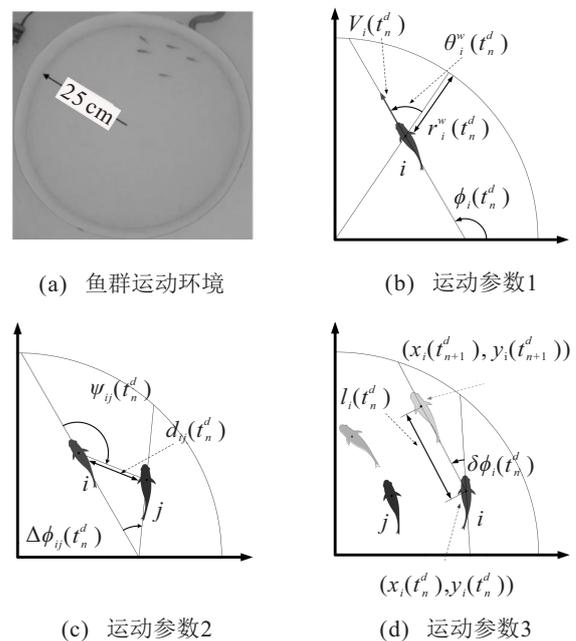


图1 实际鱼群实验装置和相关运动参数

互网络模型.在此基础上,提出了3种单一领导者假设用于融合成对交互模型来生成集群运动,与真实鱼群实验数据进行对比,验证了其中最优的单一领导者假设.

鱼在实验的过程中通常不会一直移动,当一条鱼连续60帧的移动距离小于30像素,即平均速度小于6.6 mm/s时,认定该鱼处于非运动状态.提取所有实验鱼连续运动20 s的轨迹序列,并根据突然加速-直线滑行的运动假设对轨迹分段.对于两鱼实验,共获取147 776条合格的决策分段记录用于深度网络训练;对于五鱼实验,共获得60 312个直线运动分段用于深度网络模型验证.

使用两鱼实验数据建立深度网络模型,相关运动参数如图1(b)~(d)所示,全局坐标系原点建立在实验环境圆心,逆时针为角度正方向.  $r_i^w$  为单体  $i$  相对于环境边界(以下简称墙)的距离,  $\phi_i$  为单体  $i$  的航向角,即运动方向;  $\theta_i^w$  为单体  $i$  相对墙的角度;  $d_{ij}$  为单体  $i$  与邻居  $j$  之间的距离;  $\psi_{ij}$  为单体  $i$  观察邻居  $j$  的视角(注意  $\psi_{ij} \neq \psi_{ji}$ );  $\Delta\phi_{ij}(t) = \phi_j(t) - \phi_i(t)$  为两条鱼的航向角之差,航向角  $\phi_i$  为单体  $i$  的速度矢量与全局坐标水平线之间的角度,速度分量由向后差分计算,有

$$v_i^x(t) = \frac{x_i(t) - x_i(t - \Delta t)}{\Delta t}, \quad (1)$$

$$v_i^y(t) = \frac{y_i(t) - y_i(t - \Delta t)}{\Delta t}. \quad (2)$$

$p_i = (x_i(t), y_i(t))$  为单体  $i$  的位置,间隔  $\Delta t$  为 0.04 s,则单体  $i$  的绝对速度为  $V_i(t) = \sqrt{v_i^x(t)^2 + v_i^y(t)^2}$ . 根据单体  $i$  的位置  $(x_i(t), y_i(t))$ 、姿态  $\phi_i(t)$  以及环境边界半径  $R_w$ ,可以计算出图1所示的环境参数及邻居参数. 除了上述信息,单体  $i$  在  $t_n^d$  时刻的决策还需要考虑邻居的相对速度,由于该值实时变化,选取单体  $i$  两个连续决策时刻  $t_{n-1}^d, t_n^d$  之间的平均相对速度,其反映了单体  $i$  对焦点邻居  $j$  位置变化的关注,定义如下:

$$\Delta V_{ij}(t_n^d) = \frac{d_{ij}(t_n^d) - d_{ij}(t_{n-1}^d)}{t_n^d - t_{n-1}^d}. \quad (3)$$

单体  $i$  在时刻  $t_n^d$  的决策包括航向角变化  $\delta\phi_i$ 、直线滑动距离  $l_i$  以及滑动持续时间  $KT_i$ ,可通过两次连续决策时刻  $t_n^d, t_{n+1}^d$  的位置进行推算,有

$$\delta\phi_i(t_n^d) = \phi_i(t_{n+1}^d) - \phi_i(t_n^d), \quad (4)$$

$$l_i(t_n^d) = \sqrt{(x_i(t_{n+1}^d) - x_i(t_n^d))^2 + (y_i(t_{n+1}^d) - y_i(t_n^d))^2}, \quad (5)$$

$$KT_i(t_n^d) = t_{n+1}^d - t_n^d, \quad (6)$$

其中  $t_{n+1}^d$  为下一回合的决策时间.

基于两鱼实验轨迹建立单体的成对交互模型,训练数据包括单体  $i$  的局部环境、邻居信息以及对应的决策输出,其中墙壁信息属于静态环境,邻居信息可看作动态环境,两鱼由于各自环境、相对视角以及决策时间的不同,各自的决策输出也不相同,文献[13]表明,跟随者受领导者的影响要大于领导者受跟随者的影响,可见两鱼之间的成对交互具有等级结构,所以构建信息到决策的交互映射具有复杂性,仅使用数学解析函数很难建立两者之间的关系. 因此,基于 TensorFlow 构建深度网络等级交互模型,如图2所示.

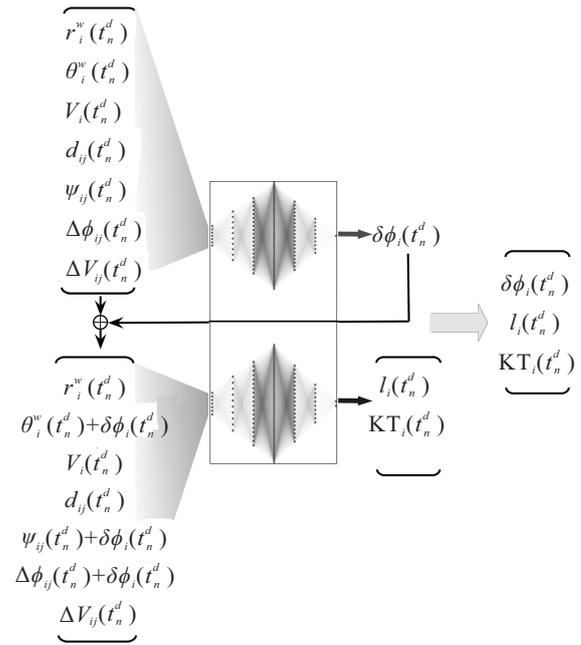


图2 单体  $i$  相对邻居  $j$  的成对交互深度网络模型结构

为建立该模型,需要根据红鼻鱼的游泳特点来确定具体结构. 红鼻鱼的运动决策可划分为两阶段: 1) 调整运动航向, 2) 确定滑行距离、时间<sup>[13]</sup>. 基于该特性,设计如图2所示的深度网络模型,模型包括对应的两部分,分别为位于上半部分的角度变化决策网络(简称角度网络)以及位于下半部分的滑动长度和持续时间决策网络(简称滑行网络),其中角度网络接收单体  $i$  的原始环境信息

$$[r_i^w(t_n^d) \ \theta_i^w(t_n^d) \ V_i(t_n^d)]^T$$

和邻居  $j$  的相对信息

$$[d_{ij}(t_n^d) \ \psi_{ij}(t_n^d) \ \Delta\phi_{ij}(t_n^d) \ \Delta V_{ij}(t_n^d)]^T$$

在决策时刻  $t_n^d$  输出单体  $i$  的航向角度变化  $\delta\phi_i$ . 由于变化后的航向角会影响直线滑行长度和滑行持续时间,将原始信息角度  $\delta\phi_i$  进行修正输入滑行网络,此时网络的输入则为

$$[r_i^w(t_n^d) \ \theta_i^w(t_n^d) + \delta\phi_i(t_n^d) \ V_i(t_n^d)]^T$$

和

$$[d_{ij}(t_n^d) \ \psi_{ij}(t_n^d) + \delta\phi_i(t_n^d) \ \leftarrow \Delta\phi_{ij}(t_n^d) + \delta\phi_i(t_n^d) \ \Delta V_{ij}(t_n^d)]^T.$$

两个网络的输入层和隐藏层结构相同,输入层有7个神经元,隐含层有5层,每层神经元分别为10、20、50、20、10,采用全连接网络结构. 两网络的不同之处在于,滑行网络的输出层包含两个神经元,分别为滑行距离  $l_i(t_n^d)$  和滑行持续时间  $KT_i(t_n^d)$ ,而角度网络的输出层只有1个. 将 Relu 函数设置为所有隐藏层的激活函数,可以有效避免梯度爆炸或消失问题,由于

角度网络的输出为范围  $[-\pi, \pi]$  内的连续值, 适用线性函数作为角度网络的输出激活函数. 因为滑行网络的输出为大于零的连续值, 所以将 Relu 函数作为滑行网络的输出激活函数.

使用实验数据训练神经网络, 以均方误差作为角度网络和滑行网络训练的损失函数, 经过对两鱼实验数据的清洗, 随机选取 10 万条记录用于训练, 训练硬件采用 Dell T7910 工作站, 配置 2 块 24 核心 Xeon E5-2670 CPU, 128 GB 内存, NVIDIA GeForce RTX 2080 Ti GPU. 深度学习模型开发框架采用 TensorFlow-GPU 软件, 训练采用小批量梯度下降 (mini-batch gradient descent, MBGD) 策略, 批量大小 (batch-size) 设置为 128, 网络训练优化器使用 Adam 优化器最小化损失函数, 学习率设置为 0.0005. 虽然使用交叉验证法划分样本可以保证训练集、测试集的数据分布一致, 但是训练数据规模较大, 使用简单的留出法也能保证该一致性, 所以随机地将样本的 20% 标记为测试集. 为防止过拟合, 采用 Dropout 算法<sup>[21]</sup> 提高模型的泛化能力, 利用 Tensorflow 提供的接口函数 `tf.layers.dropout()` 具体实现, Dropout 的比率 (dropout-rate) 为 20%, 神经元被保留的概率 (keep probability) 为 80%, 使用早停法 (early stopping) 结束训练过程, 角度网络训练的迭代次数为 1034 次, 滑行网络训练的迭代次数为 1202 次.

## 2 多体交互的关键邻居选择法

在成对交互模型的基础上, 需要合适的多邻居交互方法才能实现集群运动, 多数研究建议对 (局部范围内) 所有邻居进行交互, 然后取决策的平均值或加权值<sup>[16-18, 22]</sup>, 少数文献提出个体只关注少数邻居<sup>[22]</sup> 即可形成集群运动, 这使得个体能够克服信息量处理的自然限制. 但是少量多体的交互机理还不明确, 探讨单体仅与某个邻居交互就能形成整体的有序集群运动具有挑战性, 为此测试 3 种不同的单一邻居挑选假设进行模型仿真, 以研究所建立的成对互动模型对集群运动的有效性. 3 种邻居选择假设分别为: 1) 选择群体中最近的邻居作为交互对象, 因为最近的邻居对单体具有潜在的最大威胁, 简称最近邻假

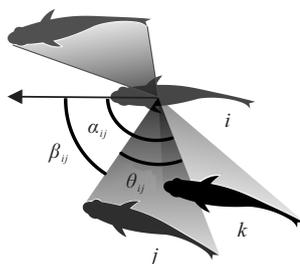


图3 邻居的视觉压力角

设; 2) 在群体中随机选取一个邻居作为交互对象, 简称随机邻假设; 3) 在群体中选择最大视觉压力的邻居, 简称大视压邻假设. 大视压邻假设表明单体  $i$  将选择视觉压力最大的邻居作为领导者, 这是因为鱼类视觉具有较高的重要性<sup>[23]</sup>. 将视觉压力定义为邻居的可视角度, 如图3所示, 邻居的视觉压力角越大, 施加在单体上的视觉压力越大.

为简化视觉压力角的计算, 将邻居视为直线段. 如图3所示, 以单体  $i$  为中心建立相对坐标系, 由于集群运动中的大量个体聚集在有限空间, 以身体中心而不是头部位置建立视觉压力模型对于安全避障而言更具实际意义, 定义  $\alpha_{ij}$ 、 $\beta_{ij}$  分别为单体  $i$  相对于邻居  $j$  的终止视角和起始视角, 计算方法为

$$\alpha_{ij} = \arctan \frac{d_{ij} \sin \psi_{ij} + \frac{BL}{2} \sin \Delta \phi_{ij}}{d_{ij} \cos \psi_{ij} + \frac{BL}{2} \cos \Delta \phi_{ij}}, \quad (7)$$

$$\beta_{ij} = \arctan \frac{d_{ij} \sin \psi_{ij} - \frac{BL}{2} \sin \Delta \phi_{ij}}{d_{ij} \cos \psi_{ij} - \frac{BL}{2} \cos \Delta \phi_{ij}}, \quad (8)$$

其中 BL 是鱼的平均体长, 实验用的红鼻鱼平均体长为 30 mm. 邻居  $j$  的视觉压力角  $\theta_{ij}$  计算如下:

$$\theta_{ij} = |\alpha_{ij} - \beta_{ij}|. \quad (9)$$

值得注意的是, 鱼  $j$  的视觉压力角与鱼  $k$  重叠, 似乎应将鱼  $j$  视觉压力角的重叠部分进行扣除, 然而鱼类是具有想象力的物种, 文献表明鱼类至少能够想象出短暂遮挡猎物的轨迹<sup>[24]</sup>, 所以尽管某个邻居存在部分遮挡, 但是当单体聚焦于该邻居时, 仅部分可见也能想象出该邻居的整体. 此外, 由于实验池是立体而非平面, 与纯 2D 空间实验相比, 焦点鱼应该可以看到更多的邻居身体, 不需要扣除视觉遮挡部分的角度, 这与文献[23]的做法有明显不同.

## 3 多智能体仿真平台介绍

神经网络模型需要构建多智能体仿真平台进行验证, 平台由 Python 和 LabView 计算机语言编写, 使用自主设计的通信协议. Python 软件作为服务器, 接收来自 LabView 客户机单体对象的决策请求, 仿真时钟周期  $\Delta t$  为 0.04 s, 与真实鱼实验中使用的相机采样周期相同. 在仿真软件的全局坐标系中, 单体  $i$  的全局状态可表示为

$$[x_i(t) \ y_i(t) \ \phi_i(t)]^T.$$

在决策时刻  $t_n^d$ , 单体  $i$  发送其局部环境信息

$$[r_i^w(t_n^d) \ \theta_i^w(t_n^d) \ V_i(t_n^d)]^T$$

和所有邻居信息

$$[d_{ij}(t_n^d) \ \psi_{ij}(t_n^d) \ \Delta\phi_{ij}(t_n^d) \ \Delta V_{ij}(t_n^d)]^T, j \in J$$

到Python服务器,其中 $J$ 为单体 $i$ 的所有邻居索引集合. 执行邻居选择任务后, TensorFlow 计算输出决策,并下载决策结果

$$[\delta\phi_i(t_n^d) \ l_i(t_n^d) \ \text{KT}_i(t_n^d)]^T$$

到单体 $i$ , LabView 设置单体 $i$ 的计时器 $T_i^t(t)$ 为新值 $\text{KT}_i(t_n^d)$ ,同时设置 $\phi_i$ 为 $\phi_i(t_n^d) + \delta\phi_i(t_n^d)$ . 然后在每个仿真周期 $\Delta t$ 更新单体 $i$ 的全局状态,直到 $T_i^t(t) < 0$ ,全局状态与定时器更新公式如下所示:

$$\begin{bmatrix} x_i(t + \Delta t) \\ y_i(t + \Delta t) \\ T_i^t(t + \Delta t) \end{bmatrix} = \begin{bmatrix} x_i(t) \\ y_i(t) \\ T_i^t(t) \end{bmatrix} + \begin{bmatrix} V_i^d \cos \phi_i \\ V_i^d \sin \phi_i \\ -\Delta t \end{bmatrix}, \quad (10)$$

其中 $V_i^d = l_i(t_n^d)/\text{KT}_i(t_n^d)$ 为滑动网络输出的平均滑动速度. 当单体 $i$ 的计时器值小于零( $T_i^t(t) < 0$ )时,单体 $i$ 将当前时刻设为新的决策时刻 $t_{n+1}^d$ ,并同时向服务器询问新的运动决策;当单体 $i$ 按式(10)更新状态时,如果距墙距离过小,则强制定时器清零,有

$$r_i^w < BL \Rightarrow T_i^t(t) = 0, \quad (11)$$

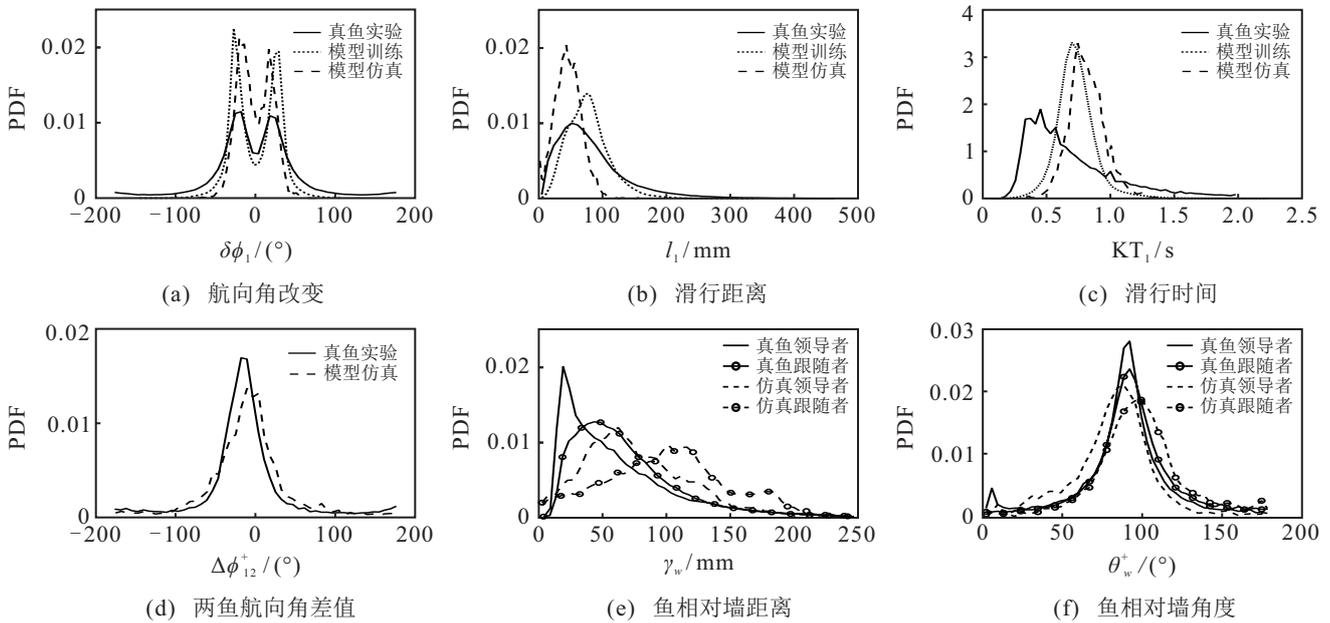


图4 深度网络模型与真实鱼类单体成对交互决策分布比较及空间参数分布比较

图4(d)~(f)比较了模型仿真与真鱼实验的对齐情况和等级位置,结果表明网络模型具有等级交互性质,其中领导者被定义为具有较大视角的单体 $i = 1, |\psi_{12}(t)| \in [0, 180^\circ]$ . 值得注意的是,领导者和跟随者角色在实验中并不稳定,两者会根据相对位置的变化而改变. 图4(d)展示了两单体的航向角之差 $\Delta\phi_{12}^+(t) = \Delta\phi_{12} \times \text{sign}(\theta_i^w)$ ,结果表明无论是真鱼实

从而触发神经网络模型进行新一轮决策,以保证单体对撞墙动作的及时调整.

#### 4 模型训练与模型仿真分析

使用所训练的成对交互深度网络模型进行两智能体仿真,记录1h的仿真轨迹数据,通过统计单体运动参数与真实两鱼实验进行对比,图4(a)~(c)展示了成对交互单体决策(航向角改变、滑行距离以及滑行时间)的概率密度(PDF)曲线,将真实鱼类单体局部信息 $[r_1^w, \theta_1^w, V_1, d_{12}, \Delta\phi_{12}, \Delta V_{12}]^T$ 输入到网络模型中,模型训练可看作相对于真实鱼类单体决策(实线)的训练误差. 由图4(a)~(c)可见,神经网络仿真和训练数据输出的决策分布都比真鱼实验要窄得多,这是因为要防止过拟合,当测试误差变得稳定并再次出现上升便停止训练迭代,使得网络模型可以表征数据的一般特性,并过滤出个体的特殊特征,导致网络输出分布比真鱼实验结果更集中. 真鱼实验和网络仿真输出的滑行长度峰值均约为60 mm(两倍身长),滑行持续时间均值较接近,模型仿真与真鱼实验的航向角决策分布相似.

验还是模型仿真,两单体始终保持对齐. 图4(e)分别显示了领导者(不带标记的实线或虚线)与跟随者(带圆标记的实线或虚线)到墙壁的距离,结果表明无论真鱼实验还是模型仿真领导者都比跟随者更靠近墙壁,但是由于交互模型存在安全机制(11),模型仿真比真鱼实验更加安全保守. 图4(f)显示了领导者和跟随者对墙角度绝对值 $\theta_w^+$ ,结果表明无论是真鱼实验

还是网络仿真几乎所有角度分布都集中在 $90^\circ$ (与墙平行),因为领导者距墙更近,所以比跟随者更平行于墙壁,角度集中程度更高.仿真结果验证了所建立的等级交互模型的有效性,下面通过仿真验证多体交互集群运动的情况.

进行5智能体集群运动分析前,需要定义一些宏观指标以方便仿真与实验数据对比,为此选择6个集群运动宏观统计量,有些统计量以全局坐标系为参考,另一些则以群体重心为参考,群体重心位置 $p_B = (x_B(t), y_B(t))$ 计算如下:

$$x_B(t) = \frac{1}{N} \sum_{i=1}^N x_i(t), \quad y_B(t) = \frac{1}{N} \sum_{i=1}^N y_i(t), \quad (12)$$

其中 $N$ 为群体总数.根据重心位置,重心速度 $(v_B^x(x), v_B^y(t))$ 采用向后差分定义,即

$$v_B^x(t) = \frac{x_B(t) - x_B(t - \Delta t)}{\Delta t},$$

$$v_B^y(t) = \frac{y_B(t) - y_B(t - \Delta t)}{\Delta t}.$$

进而重心运动方向定义为

$$\phi_B(t) = \arctan \frac{v_B^y(t)}{v_B^x(t)}.$$

在集群重心上定义坐标系,单体相对中心的位置和速度分别为

$$\mathbf{p}_i^B = \mathbf{p}_i - \mathbf{p}_B = (x_i^B(t), y_i^B(t)),$$

$$\mathbf{v}_i^B = \left( \frac{x_i^B(t) - x_i^B(t - \Delta t)}{\Delta t}, \frac{y_i^B(t) - y_i^B(t - \Delta t)}{\Delta t} \right).$$

在全局参考系统中,使用如下统计量:

1) 单体到墙壁的距离 $r_w = \{r_i^w(t) | i = 1, 2, \dots, N\}$ .

2) 单体相对墙的角度 $\theta_w^+ = \{\theta_i^w(t) | i = 1, 2, \dots, N\}$ .

以上两个属性统计值表征了单体相对于全局环境的位置.

3) 群体极性

$$P_t \in [0, 1], \quad P(t) = \frac{1}{N} \sum_{i=1}^N e_i(t), \quad (13)$$

其中 $\mathbf{e}_i(t) = (\cos(\phi_i(t)), \sin(\phi_i(t)))$ 是代表单体 $i$ 方向的单位向量,当 $P(t) = 1$ 时所有单体航向相同,当值接近0时所有单体航向发散.

4) 群体大小

$$C(t) = \frac{1}{N} \sum_{i=1}^N \|\mathbf{P}_i - \mathbf{P}_B\|, \quad (14)$$

其中 $\|\mathbf{P}_i - \mathbf{P}_B\|$ 为单体 $i$ 与重心 $B$ 的距离. $C(t)$ 值越小表示群体越紧密,越大表示空间越分散.

相对集群重心的两个统计量为:

1) 集体反旋和正旋指数

$$Q(t) \in [-1, 1],$$

$$Q(t) =$$

$$\left( \frac{1}{N} \sum_{i=1}^N \sin(\gamma_i^B(t)) \right) \times \text{sign} \left( \frac{1}{N} \sum_{i=1}^N \sin(\theta_i^w(t)) \right).$$

其中:相对速度角 $\gamma_i^B(t)$ 为相对位置 $\mathbf{P}_i^B$ 和相对速度 $\mathbf{v}_i^B$ 的向量夹角; $\frac{1}{N} \sum_{i=1}^N \sin(\theta_i^w(t)) > 0$ 为多数单体绕环境中心逆时针运动,反之如果该值小于零,则表明多数单体绕环境中心顺时针运动; $\sum_{i=1}^N \sin(\gamma_i^B(t))$ 为单体围绕群体重心的转动方向,如果多数单体围绕环境中心与围绕群体重心的方向相同,则表现为群体正旋 $Q(t) > 0$ ,反之如果运动方向相反,则表现为群体反旋 $Q(t) < 0$ ;  $\text{sign}(\cdot)$ 为符号函数.

2) 相对重心的速度

$$\Delta V(t) = \frac{\|\mathbf{P}_i(t) - \mathbf{P}_B(t)\| - \|\mathbf{P}_i(t - \Delta t) - \mathbf{P}_B(t - \Delta t)\|}{\Delta t},$$

其中 $i = 1, 2, \dots, N$ .

相对于最近邻和随机邻假设,大视压邻假设可以形成稳定的集群运动,且群体相对集中,如图5(d)所示, $C(t) \approx 25$  mm.多数文献使用的最近邻假设表明,仅参考1个最近邻居无法形成凝聚群体运动,随机邻假设形成运动的群体大小分布较宽,大于真鱼实验的群大小分布.图5(c)表明除最近邻假设外,其他假设仿真和真鱼实验的集群运动都是高度极化的,即所有单体都能保证同方向运动,且在 $P \approx 1$ 处存在峰值.

图5(a)和(b)表明模型仿真与真鱼实验的单体都能靠近墙壁,基本保持对墙距离为 $r_w \approx 50$  mm,且与墙平行( $\theta \approx 90^\circ$ ).进一步分析群体的反旋特性,图5(e)表明,最近邻假设为正旋,真鱼实验为反旋,其中大视压假设与真鱼数据最相似.通过实验视频和仿真录像分析可知,反旋行为的原因是位于集群前方的领导者更贴近墙壁,墙障碍要求领导者的速度减慢,而集群后方的跟随者距墙较远,不但空间相对自由导致速度较快,而且内圈超越路径较短,如此反复形成领导者角色的不停轮换,从而导致单体围绕集群重心旋转,而旋转方向与相对环境的运动方向相反,呈现出反旋特征.图5表明,大视压邻假设比真鱼实验集群运动的群大小更小,极性更高,相对速度更一致,相对环境位置分布更集中,集群运动的稳定性也更高,充分表明所提出假设可以滤除真鱼集群运动数据的个性化特征,是一般集群运动交互规则的有效归纳.

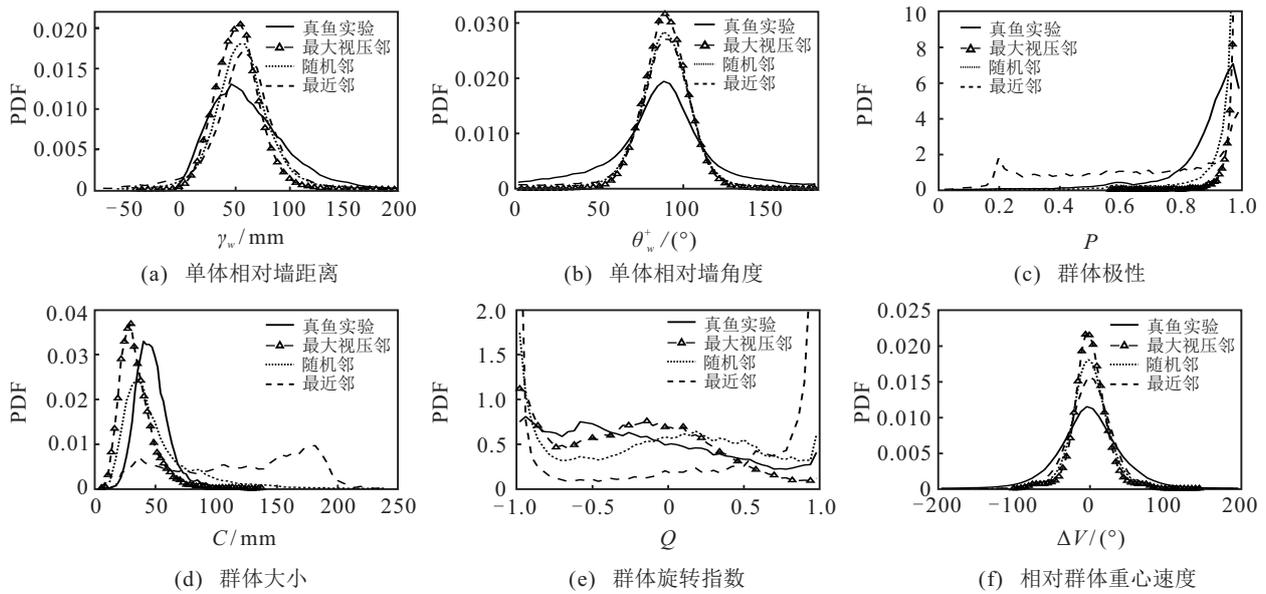


图5 不同邻居选择假设下5智能体模型仿真与5条鱼实验集群运动特征分布比较

使用最大视压邻假设,对50个智能体进行模型仿真,图6仿真过程表明,在1 min左右群体可以从较分散的运动状态聚合为稳定的集群运动,可见所提出集群运动智能控制方法具有较强的规模缩放适应性.

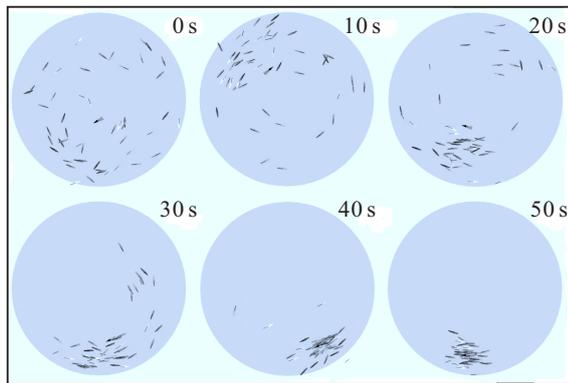


图6 50个智能体仿真验证

### 5 结论

模型仿真与真鱼实验表明,所提出深度网络结构与多体交互假设能有效生成集群运动,如果将圆形环境边界虚拟化,所提出方法则可用于群体的自旋集结,在此基础上再改变虚拟环境形状,如将圆形空间改为通道空间,便能形成集群导引.反旋特性的存在使得集群领导者经常变换,个别领导者的丢失不会影响整体集群运动,使得自组织出的集群运动具有较强的控制鲁棒性,为无人机集群控制、多导弹集结饱和攻击、大规模交通运输系统的协调控制提供了新的思路.

与传统集群运动研究相比,得益于深度网络模型的强大解释能力,所提出模型参数信息输入丰富,模型仿真效果接近真实鱼类实验;相比于大量文献认

为集群运动中的单体必须时刻关注多个邻居才能形成集群共识<sup>[17,25]</sup>,所提出最大视觉压力邻居假设则印证了只需要关注某一单体便能形成集群运动,相比于传统的集群交互模型,所提出交互模式具有计算负载低、实时性好的优点,这为下阶段课题组的多机器人实验奠定了坚实基础,也为大规模集群智能控制提供了可能.

### 参考文献(References)

- [1] Couzin I D, Krause J. Self-organization and collective behavior in vertebrates[J]. *Advances in the Study of Behavior*, 2003, 32: 1-75.
- [2] Buhl J, Sumpter D J T, Couzin I D, et al. From disorder to order in marching locusts[J]. *Science*, 2006, 5778(312): 1402-1406.
- [3] Cavagna A, Cimarelli A, Giardina I, et al. Scale-free correlations in starling flocks[J]. *Proceedings of the National Academy of Sciences*, 2010, 107(26): 11865-11870.
- [4] Helbing D, Farkas I, Vicsek T. Simulating dynamical features of escape panic[J]. *Social Science Electronic Publishing*, 2000, 6803(407): 487-490.
- [5] 李春光, 刘国栋, 娄柯. 二阶多智能体系统量化蜂拥控制[J]. *控制与决策*, 2015, 30(3): 541-545. (Li C G, Liu G D, Lou K. Quantized flocking control of multiple agents with second-order dynamics[J]. *Control and Decision*, 2015, 30(3): 541-545.)
- [6] 刘金琨, 王树青. 多智能体系统联合行动的形式化研究及其应用[J]. *控制与决策*, 2000, 15(1): 6-10. (Liu J K, Wang S C. Formal research and application of joint action of multi-agent system[J]. *Control and Decision*, 2000, 15(1): 6-10.)

- [7] 王帅磊, 张金春, 曹彪, 等. 双类型多智能体蜂拥控制目标跟踪算法[J]. 控制工程, 2019, 26(5): 935-940. (Wang S L, Zhang J C, Cao B, et al. Target tracking algorithm for dual-type multi-agent swarm control[J]. Control Engineering of China, 2019, 26(5): 935-940.)
- [8] 王飞跃, 魏庆来. 智能控制: 从学习控制到平行控制[J]. 控制理论与应用, 2018, 35(7): 939-948. (Wang F Y, Wei Q L. Intelligent control: from learning control to parallel control[J]. Control Theory and Applications, 2018, 35(7): 939-948.)
- [9] Cristián H, Ferrante E, Wenseleers T, et al. Scale-free correlations in flocking systems with position-based interactions[J]. Journal of Statistical Physics, 2015, 158(3): 549-562.
- [10] Zafeiris A, Vicsek T. Why we live in hierarchies?[M]. Berlin: Springer, 2018: 89-105.
- [11] Couzin I D, Krause J, Franks N R, et al. Effective leadership and decision-making in animal groups on the move[J]. Nature, 2005, 7025(433): 513-516.
- [12] Zafeiris A, Vicsek T. Group performance is maximized by hierarchical competence distribution[J]. Nature Communications, 2013, 4(9): 2484.
- [13] Calovi D S, Alexandra L, Valentin L, 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.
- [14] 罗小元, 李旭, 李绍宝, 等. 分布式离散多智能体系统在固定和切换拓扑下的编队控制[J]. 控制与决策, 2013, 28(12): 1869-1873. (Luo X Y, Li X, Li S B, et al. Distributed discrete-time formation control of multi-agent systems under fixed and switching topologies[J]. Control and Decision, 2013, 28(12): 1869-1873.)
- [15] Vicsek T, Zafeiris A. Collective motion[J]. Physics Reports, 2012, 517(3/4): 71-140.
- [16] Aoki I. A simulation study on the schooling mechanism in fish[J]. Nippon Suisan Gakkaishi, 1982, 48(8): 1081-1088.
- [17] 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.
- [18] Vicsek T, Czirok 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.
- [19] Jiang L, Giuggioli L, Perna A. Identifying influential neighbors in animal flocking[J]. PLOS Computational Biology, 2017, 13(11): e1005902.
- [20] Pérez E A, Vicente P J, Hinz R C, et al. Tracker: Tracking individuals in a group by automatic identification of unmarked animals[J]. Nature Methods, 2014, 11(7): 743-748.
- [21] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: A simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15: 1929-1958.
- [22] Katz Y, Tunstrom K, Ioannou C C, et al. Inferring the structure and dynamics of interactions in schooling fish[J]. Proceedings of the National Academy of Sciences, 2011, 108(46): 18720-18725.
- [23] 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]. Proceedings of the National Academy of Sciences, 2015, 112(15): 4690-4695.
- [24] Lanchester B S, Mark R F. Pursuit and prediction in the tracking of moving food by a teleost fish (*acanthaluteres spilomelanurus*)[J]. Journal of Experimental Biology, 1975, 63(3): 627-645.
- [25] 陆兴远, 袁卫锋. 鱼类群体运动的元胞自动机模型中的最小势能原理[J]. 自动化学报, DOI: 10.16383/j.aas.c190568. (Lu X Y, Yuan W F. Principle of minimum potential energy in cellular automata model of fish swarm movement[J]. Acta Automatica Sinica, DOI: 10.16383/j.aas.c190568.)

## 作者简介

刘磊(1982—), 男, 副教授, 博士, 从事多智能体智能控制、机器人自动控制等研究, E-mail: liulei@usst.edu.cn;

孙卓文(1995—), 男, 硕士生, 从事多智能体智能控制、深度学习等研究, E-mail: 1374206329@qq.com;

陈令仪(1997—), 女, 本科生, 从事自组织的研究, E-mail: 1198438237@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;

王富正(1968—), 男, 教授, 博士, 从事新能源汽车控制、模型预测控制等研究, E-mail: fcw@ntu.edu.tw;

王亚刚(1967—), 男, 教授, 博士, 从事过程控制、自动化系统辨识等研究, E-mail: ygwang@usst.edu.cn.

(责任编辑: 郑晓蕾)