计算机系统应用 ISSN 1003-3254, CODEN CSAOBN
Computer Systems & Applications,2023,32(9):230−238 [doi: 10.15888/j.cnki.csa.009231]
©中国科学院软件研究所版权所有.
E-mail: csa@iscas.ac.cn
http://www.c-s-a.org.cn
Tel: +86-10-62661041

基于 PPO 算法的仿生鱼循迹智能控制①

李云飞[1,3], 严　娜[4], 张来平[2,3], 邓小刚[2], 邹舒帆[4]

[1](四川大学 计算机学院, 成都 610207)
[2](军事科学院, 北京 100071)
[3](四川大学 天府工程数值模拟与软件创新中心, 成都 610207)
[4](国防科技大学 空天科学学院, 长沙 410003)
通信作者: 邹舒帆, E-mail: sfzou@nudt.edu.cn

摘　要: 仿生鱼具有广阔的工程应用前景, 对于仿生鱼的控制, 首先要解决的是循迹问题. 然而, 现有的基于 CFD 方式和传统控制算法的鱼游控制方法存在训练数据获取成本高、控制不稳定等缺点. 本文提出了基于 PPO 算法的仿生鱼循迹智能控制方法: 使用代理模型替代 CFD 方式产生训练数据, 提高数据的产生效率; 引入高效的 PPO 算法, 加快策略模型的学习速度, 提高训练数据的效用; 引入速度参数, 解决鱼体在急转弯区域无法顺利循迹的问题. 实验表明, 我们提出的方法在多种类型的路径上均具有更快的收敛速度和更加稳定的控制能力, 在仿生机器鱼的智能控制方面具有重要的指导意义.

关键词: 深度强化学习; 仿生鱼; 智能控制; 代理模型; PPO

引用格式: 李云飞,严娜,张来平,邓小刚,邹舒帆.基于 PPO 算法的仿生鱼循迹智能控制.计算机系统应用,2023,32(9):230–238. http://www.c-s-a.org.cn/1003-3254/9231.html

Intelligent Control of Bionic Fish Tracking Based on PPO Algorithm

LI Yun-Fei[1,3], YAN Lang[4], ZHANG Lai-Ping[2,3], DENG Xiao-Gang[2], ZOU Shu-Fan[4]

[1](College of Computer Science, Sichuan University, Chengdu 610207, China)
[2](Academy of Military Science, Beijing 100071, China)
[3](Tianfu Engineering-oriented Numerical Simulation & Software Innovation Center, Sichuan University, Chengdu 610207, China)
[4](College of Aerospace Science and Engineering, National University of Defense Technology, Changsha 410003, China)

Abstract: Bionic fish has broad prospect for engineering application. For the control of bionic fish, the first thing to solve is the tracking problem. However, the existing fish control methods based on CFD methods and traditional control algorithms feature high training data acquisition costs and unstable control. This study proposes an intelligent control method based on the PPO algorithm for bionic fish tracking. The surrogate model is employed instead of CFD to generate training data to improve the data generation efficiency. The efficient PPO algorithm is introduced to accelerate the learning speed of the strategy model and improve the utility of the training data. The speed parameter is introduced to solve the problem that the fish cannot track smoothly in the sharp turning area. Experiments show that the proposed method has faster convergence speed and more stable control ability in various paths, with guiding significance for the intelligent control of bionic robotic fish.

Key words: deep reinforcement learning; bionic fish; intelligent control; proxy model; proximal policy optimization (PPO)

① 基金项目: 国家重大专项 (GJXM92579)
收稿时间: 2023-02-22; 修改时间: 2023-03-22; 采用时间: 2023-04-07; csa 在线出版时间: 2023-07-14
CNKI 网络首发时间: 2023-07-17

© 中国科学院软件研究所 http://www.c-s-a.org.cn

与普通的水下推进器相比, 鱼游具有推进效率高、机动性能好、隐蔽性能好等显著优点. 仿生机器鱼结合了鱼类推进机理和机器人技术, 为研制水下推进器提供了新思路, 具有重要的研究价值和应用前景[1]. 对于仿生鱼的控制, 首先要解决的是循迹问题, 即鱼体能够自主、准确地沿规定路线游动, 这需要引入合适的闭环控制算法.

比例积分微分 (PID) 算法被广泛应用于传统的机器人控制领域, 该算法通过减少目标与实际情况的偏差完成任务, 对于流程清晰的问题非常有效. 然而, 在复杂流动环境中, 仿生鱼不同时刻执行同一动作指令时, 所产生的位移并不相同, 导致 PID 算法无法进行稳定的控制, 因此, 需要使用更加智能的控制算法. 最近的研究成果表明, 强化学习算法在一定程度上具备解决复杂问题的通用智能, 已被用于解决多种复杂的机器控制问题, 这为仿生鱼控制提供了新的研究方向.

本文提出了一种基于强化学习的仿生鱼智能控制方法, 用以解决仿生鱼的循迹问题. 该方法有两个显著优势: 第一, 鱼体不需要对环境有任何先验知识, 而是通过试错对环境信息进行采样, 从而完成自主学习; 第二, 该方法能够解决鱼体游动中存在随机扰动的问题, 从而精准控制鱼体沿规定路线游动. 在多个场景中的实验结果表明, 本文提出的方法对探索鱼类在复杂环境中的游动机制与仿生鱼智能控制方面有着重要的指导意义.

1 相关工作

仿生鱼的控制属于学科交叉问题, 包括计算流体动力学 (CFD) 和控制算法两部分. 其中, CFD 用于计算鱼体的受力情况, 而控制算法用于闭环控制, 使鱼体可以根据设定好的目标自行选择自己的游动方式[2–5].

许多传统算法[6] 都可以实现自动控制, 但在鱼游控制中表现不佳. Tian 等人[7] 通过反馈控制方式实现了鱼体的自主游动控制, 但生成的迹线波动较大, 不够平滑. Khan 等人[8] 使用 PID 算法控制机器鱼的下沉深度, 发现即使经过适当的增益调优, PID 控制器仍存在一定的局限. 而在人工智能领域, Novati 等人[9] 使用深度强化学习 (DRL) 算法实现对水下 2D 椭圆型模型的控制, 他们发现使用 DRL 生成的迹线更加光滑, 并且比传统的控制优化算法更加稳定. Zhu 等人[10] 使用深度循环 Q 网络获取鱼游的序列信息, 控制鱼体完成了静水中捕猎、流动水中维持自身位置等任务. Yan 等人[11,12] 使用 DRL 训练鱼体完成循迹任务, 在使用直线完成训练后, 鱼体可以沿着曲线游动, 同时能够完成简单的避障游动, 说明经过训练后的鱼体具有一定的泛化能力.

强化学习为解决仿生鱼游动的控制问题提供了智能方案, 但仍然存在一些问题. 在 CFD 中, 为了得到流体对鱼作用力的精确值, 需要进行鱼体模型离散化, 网格量达到数十万乃至百万, 导致完成一次数值解算非常耗时; 同时, 由于鱼体在流体中的游动是连续的, 鱼体在水中的每一时刻的运动状态都必须使用 CFD 的方式计算得到. 这两个因素叠加, 使得 CFD 模拟的时间成本巨大, 难以满足强化学习对大量训练数据的需求.

为了解决上述问题, 本文从两方面进行改进: 一是提高训练数据的产生效率, 用代理模型代替数值模拟产生训练数据, 提升训练效率; 二是提高训练数据的效用, 通过引入更加高效的强化学习算法 PPO 和训练策略, 加快策略模型的学习速度, 减少对训练数据的需求.

此外, 文献 [11] 中发现仿生鱼容易在急转弯区域偏移过度直至越界, 导致循迹任务的失败, 并通过增加转弯处的边界宽度以避免这一问题. 本文引入对速度参数的训练, 使鱼体学习在急转弯区域主动减速, 从而顺利通过该区域.

2 模型和算法

如图 1 所示, 强化学习的基本结构由环境 (Environment)、智能体 (Agent) 和策略 (Policy) 这 3 部分组成. 环境用于产生训练数据, 它根据当前状态 (State) 和智能体的动作 (Action), 利用状态转移函数得到下一状态. 智能体利用大量的训练数据更新策略 (Policy), 以获取更高的奖励值. 在鱼游问题中, 环境指的是鱼体所处的流体环境, 训练数据指的是鱼体的游动数据.

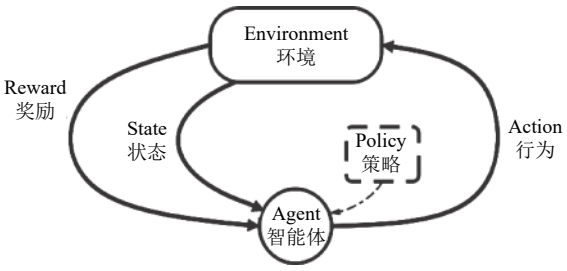

图 1 强化学习模型示意图

© 中国科学院软件研究所 http://www.c-s-a.org.cn

2.1 代理模型

过往的研究中大多采用 CFD 方法模拟流体环境, 得到的训练数据真实可靠, 与真实场景误差很小, 但时间成本十分高昂. 本文使用代理模型对鱼游环境进行建模, 提高数据的产生效率, 同时兼顾了数据精度. 代理模型包括鱼体动作数据库和雷达系统两部分.

2.1.1 鱼体动作数据库

鱼体动作数据库储存了鱼体所有动作能够产生的位移效果, 用于描述环境的状态转移函数. 构建该数据库的步骤如下.

首先, 建立 2D 鱼体几何模型, 对模型生成计算域的初始重叠网格并分区, 图 2 中展示了鱼体不同动作下生成的网格及分区情况.

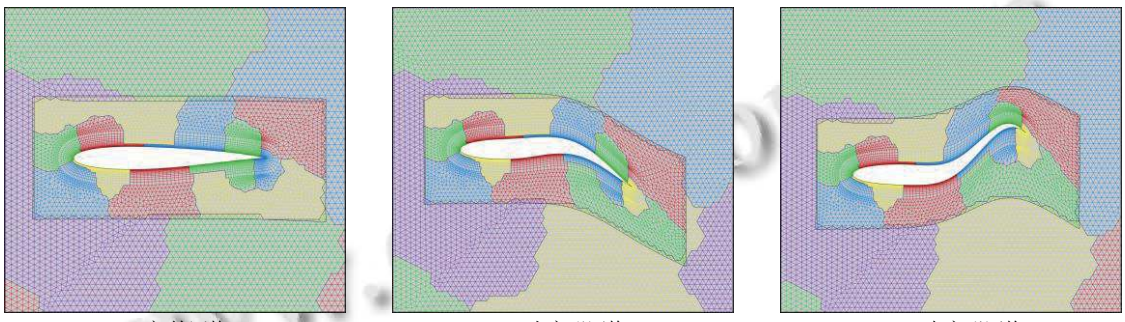

(a) 初始网格 (b) 小变形网格 (c) 大变形网格

图 2 仿生鱼网格分区示意图

然后, 使用 CFD 软件在鱼体模型上完成对 N-S 方程[13,14] 的求解, 计算初始流场信息, 从而获取鱼体在流体中游动时所受到的压力和阻力信息.

最后, 结合动力学/运动学方程, 求得鱼体在某一状态下使用某动作能够得到的位移和转角, 并将对应结果存储在数据库中.

在本文中, 共计算了 25 个鱼体动作, 每个动作包括整周期和半周期两个状态. 实际训练中, 为了模拟流体环境的非定常特性, 要在数据库的数据上叠加一个随机值 (噪声), 使得鱼体每一次的动作都会在一定范围内产生不确定的位移和转角.

代理模型通过上述方式, 仅在数据准备阶段进行一次 CFD 计算, 并在之后的训练中使用该结果, 从而在可接受的误差范围内, 大大降低了时间成本. 由于 CFD 的原理并不是本文的重点, 这里只简要叙述, 更详细的介绍可以查阅文献 [11,12].

2.1.2 雷达系统

鱼体使用雷达系统获取环境状态信息, 如图 3 所示, 中间的实线是轨迹, 鱼体将学习如何沿着该轨迹平滑游动. 点 P 表示鱼的质心在轨迹上的投影, 点 Q 表示雷达范围与轨迹的交点, 鱼体在游动时总是将此点视为目标点, d 表示鱼体偏移轨迹的距离, v 表示鱼体当前的速度.

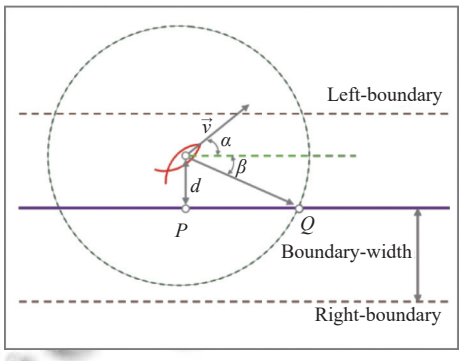

图 3 雷达系统示意图

鱼体游动过程中, 使用雷达系统获取当前状态信息并传递给鱼体. 鱼体将获得的环境信息作为输入, 利用策略模型从数据库中选取动作, 每个动作都使鱼体完成一定的位移和转向, 并到达新的位置, 雷达系统再次获取新的状态信息. 重复以上步骤, 即可控制鱼体完成游动过程.

2.2 训练算法

在鱼游问题中, 产生训练数据花费的时间占总训练时间的 90% 以上. 因此, 提高数据的效用, 加快策略模型的学习速度, 可以减少对训练数据的需求, 节省大量时间成本. 为了提高训练数据的效用, 本文使用近端策略优化 (PPO) 算法作为鱼体的训练算法.

© 中国科学院软件研究所 http://www.c-s-a.org.cn

2.2.1 PPO 算法

PPO 算法[15] 是基于 AC 架构[16] 的算法, 可以解决离散动作空间和连续动作空间的强化学习问题[17]. 如图 4 所示, AC 架构的算法一般由两个神经网络组成: Actor 网络和 Critic 网络. Actor 网络的输入为状态, 输出为策略 π; Critic 网络的输入为状态, 输出为状态的价值. AC 算法的训练中, Critic 网络的学习目标是尽可能准确地评价当前状态的价值; 而 Actor 网络的学习目标是找到最优策略 π*, 使得 Critic 网络的输出最大化.

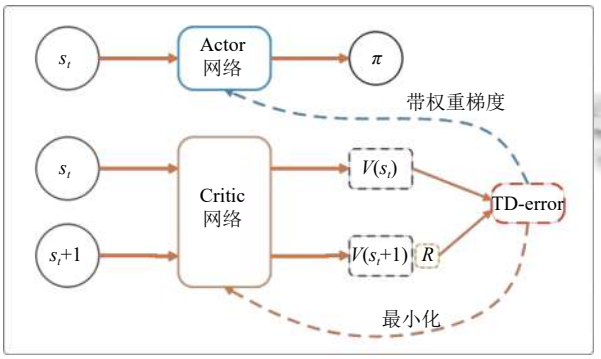

图 4 AC 算法的一般框架

相比 AC 算法, PPO 算法有两个改进.

第一, 使用 TD(n) 算法取代 TD(0) 算法, 增强了算法的前向探索能力, 使得对动作的效果评估更加准确, 提高了算法泛化性. 具体做法是使鱼体按照当前策略运动 n 步, 得到 n 步后的价值, 再往回反推每一步的价值.

第二, 解决了 AC 算法的 on-policy 问题, 使算法可以重复利用训练数据, 从而提高了数据利用率, 加快算法收敛速度. 具体方法是使用重要性采样: 计算得到优势函数$\widehat{A}_t$和重要性权值$r_t(\theta)$的值, 将二者相乘用于更新 Actor 网络.

$r_t(\theta)$的计算是以目标策略出现动作的概率值除以行为策略出现同一动作的概率值, 定义如下:

$$r_t(\theta)=\frac{\pi_\theta(a_t|s_t)}{\pi_{\theta_{\text{old}}}(a_t|s_t)} \tag{1}$$

优势函数$\widehat{A}_t$相当于 AC 算法中的 TD-error, 定义如式 (2) 所示, 其中G_t表示 TD(n) 算法下的折扣回报, 定义如式 (3) 所示, n 为向前探索的步数.

$$\widehat{A}_t=G_t-V(s_t) \tag{2}$$

$$G_t=r_{t+1}+\gamma r_{t+2}+\cdots+\gamma^{n-1}V(s_n) \tag{3}$$

综上, 更新 Actor 网络的损失函数如式 (4) 所示, 其中 *clip* 函数用于将重要性权重的值限制在 $(1-\varepsilon,1+\varepsilon)$ 范围内.

$$L^{clip}(\theta)=\widehat{E}_t[\min(r_t(\theta)\widehat{A}_t,clip(r_t(\theta),1-\varepsilon,1+\varepsilon)\widehat{A}_t)] \tag{4}$$

而 Critic 网络的更新方法是: 将折扣回报G_t与 Critic 网络预测值$V(s_t)$的均方误差 MSE 作为损失函数, 执行梯度下降算法.

2.2.2 状态、动作空间和奖励函数

状态空间中共有 5 个状态特征: 包括 4 个空间特征和 1 个时间特征. 空间特征变量的示意图如图 3 中的雷达系统所示, 各特征变量的含义如表 1 所示.

表 1 模型中状态变量含义

状态	含义
α	鱼体速度方向与轨迹方向的夹角
β	鱼体到目标点的连线与轨迹方向的夹角
d	鱼体质心偏离轨迹的距离
v	鱼体游动速度
T_t	时间特征值 (整周期为0, 半周期为1)

鱼体的动作空间包含 25 个离散值, 分别对应鱼体动作数据库中存储的 25 个动作的索引值.

算法的训练目标是使鱼体能够以平滑的路线沿着特定轨迹游动并到达终点, 游动过程中尽可能减少鱼体距离迹线的偏差和时间花费, 并规避越界情况的发生. 为达到这一目的, 奖励函数的设计包括距离奖励R_1和越界惩罚R_2两部分. R_1的定义如式 (5) 所示, 其中$|d|$为鱼体与轨迹的距离, $boundary_width$为边界与轨迹的距离. 在游动过程中, 鱼体每执行一个动作, 获得一个奖励值, 获得的奖励值与$|d|$成反比.

$$R_1=1-\frac{|d|}{boundary\_width} \tag{5}$$

R_2表示鱼体执行一个动作导致超出边界时, 获得惩罚值 (−50), 并结束本轮训练.

2.3 引入速度参数

现有的模型条件下, 鱼体在急转弯处表现不佳, 很容易偏离轨迹并越界, 无法完成寻迹任务. 然而, 这种急转弯广泛存在于鱼类的真实运动轨迹中, 鱼类面对障碍、捕食或遇到天敌时, 都需要急速转弯机动. 若无法实现对急转弯曲线的循迹, 会极大限制仿生鱼的机动性能. 为解决这一问题, 需要在现有模型中加入对速度参数的训练.

© 中国科学院软件研究所 http://www.c-s-a.org.cn

2.3.1 速度参数

对动作空间进行改进, 在鱼体 25 个动作的基础上, 增加一个减速标志, 并且使用另一个网络 Actor2 完成训练. 减速标志是一个布尔值, True 表示执行减速动作, False 表示不对速度进行干扰.

代理模型中不考虑减速时, 鱼体速度 v 的定义如式 (6) 所示, 其中v_0是鱼体游速的上限值, n 为鱼体游动步数, 初始值为 1 并不断增大. θ是为了模拟流体的非定常特性而增加的随机因子, 其值为 0.9–1.1 之间的随机值. 可以看出, 随着鱼体游动, n 越来越大, 速度 v 随之增大, 最后在上限值v_0处波动.

$$v = v_0 \cdot \left(1 - \frac{1}{1.15^n}\right) \cdot \theta \tag{6}$$

考虑减速机制时, 为了简化问题, 当代理模型从 Actor2 网络中获取到的减速标志为 True 时, 将 n 重置为 1, 使鱼体速度 v 恢复为初始状态, 并在之后的游动中根据式 (6) 逐渐增大.

为了防止出现 Reward Hacking 问题 (鱼体为了获得更高的奖励而全程低速游动), 需要引入新的奖励函数 R_3. R_3 表示当鱼体执行减速动作时, 获得一个惩罚值 (−5), 且训练不终止.

2.3.2 训练策略

引入速度参数后的算法总体框架如图 5 所示. 其中 Actor1 网络输出动作, Actor2 网络输出减速标志, Critic 网络输出对鱼体所处环境状态的评价.

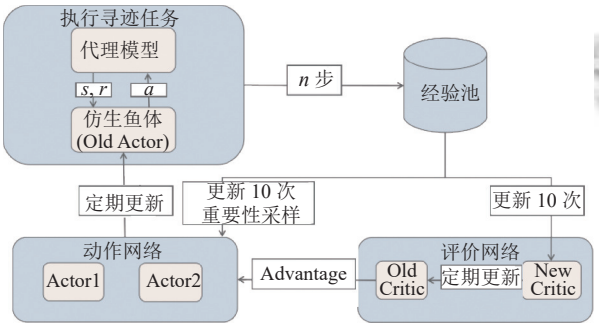

图 5 引入速度参数的鱼体循迹训练算法框架

训练策略如下, 首先在直线和曲线上训练 Actor1 网络和 Critic 网络, 使鱼体学习根据偏移情况选择正确的动作, 此时 Actor2 网络固定输出 False, 不参与训练; 之后, 在包含急转弯区域的矩形中训练 Actor2 网络和 Critic 网络, 使鱼体学习在急转弯区域主动减速, 此时 Actor1 网络只利用, 不探索. 两个 Actor 网络分别训练完成后, 即可以控制鱼体完成在直线、曲线和急转弯区域上的循迹任务.

引入速度参数后, PPO 算法的训练流程如算法 1 所示.

算法 1. 鱼体循迹控制训练算法

输入: Actor 网络和 Critic 网络使用同一组输入向量, 5 个状态特征: α、β、d、v、T_t.
输出: 鱼体动作和减速标志.

训练过程:
1) **for** 迭代次数=1, 2, ⋯, N **do**
2) 将代理模型重置为随机初始状态 s_0
3) **while** 鱼体未超出边界且未到达终点 **do**
4) 使用π_{old}执行循迹任务, 并将状态 s、动作 a、奖励 r 存入经验池
5) **if** 经验池内数据达到容量 **then**
6) 利用重要性采样, 计算 Loss 值
7) 连续更新多次 Actor1 和 Critic 网络
8) $\pi_{\text{new}} \to \pi_{\text{old}}$
9) 清空经验池
10) **end if**
11) **end while**
12) **end for**
13) 对于 Actor2 网络的训练, 重复步骤 1–12

3 直线与曲线实验分析

强化学习中有两个评价算法性能的指标, 一是算法达到收敛所需的训练轮数, 用于衡量算法的收敛速度; 二是算法收敛后所能获取的 Episode Reward 值, 用于衡量智能体的学习效果. 本节实验的目标是使鱼体能够选取正确的动作以完成循迹任务, 同时使用评价指标评估所提算法模型的性能, 并与文献 [11] 中使用的 AC 算法进行对比.

3.1 实验设置

本节设置了直线和曲线两种循迹路线, 如图 6 所示, 中间虚线为鱼体跟随的轨迹, 两侧虚线表示边界, 当鱼体发生越界时, 循迹任务失败, 结束本轮训练并开始下一轮的训练.

由于本节不考虑急转弯区域的循迹控制, 因此只对 Actor1 网络和 Critic 网络进行训练, Actor2 网络固定输出 False. 实验参数配置如下: batch-size 设置为 32, Actor 学习率为 0.001, Critic 学习率为 0.01, 折扣率为 0.9, PPO-clip 参数为 0.2, 鱼体的游动速度上限v_0为 0.5.

© 中国科学院软件研究所 http://www.c-s-a.org.cn

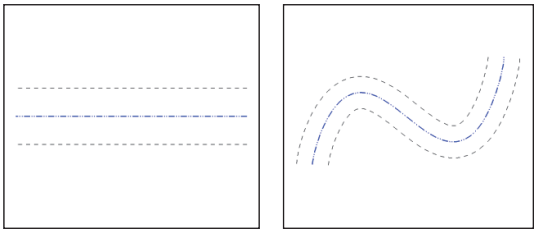

图 6 实验场景示意图

3.2 直线训练

图 7 展示了两种算法在直线上的训练过程, 可以看出 PPO 算法在收敛速度上有明显的提升, 在 Episode Reward 方面也有轻微的提升, 并且算法的训练过程十分稳定. 从图 8 和图 9 中可以看到, 在训练到 100 轮时, PPO 算法已经能够控制鱼体到达终点, 而使用 AC 算法控制的鱼体在中途就发生越界.

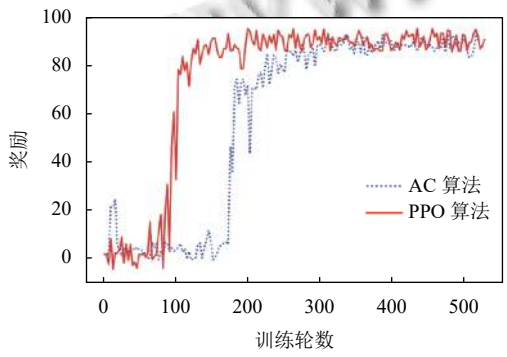

图 7 直线训练中奖励随训练轮数变化曲线

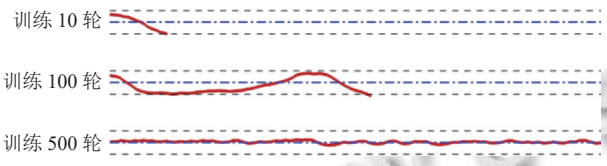

图 8 不同训练轮数下 PPO 算法轨迹展示

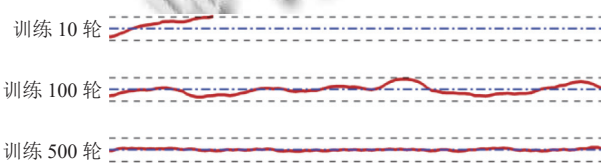

图 9 不同训练轮数下 AC 算法轨迹展示

3.3 曲线训练

在成功控制鱼体完成直线上的循迹任务后, 为了进一步验证算法的有效性, 我们使用直线训练后的 DRL 模型继续在曲线上进行训练.

如图 10 所示, 经过直线训练后的策略模型一开始在曲线上表现不佳, 获得的奖励不高, 而随着训练轮数的增加, 鱼体能够获取的奖励值也越来越高, 说明鱼体渐渐学会根据路径弯曲程度调整自身的动作. 从评价指标上看, PPO 算法对 Episode Reward 值的提升并不明显, 但收敛速度非常快, 在 100 轮就基本收敛, 且后续训练非常稳定; 而 AC 算法在 200 轮才收敛, 且在之后有一定的震荡.

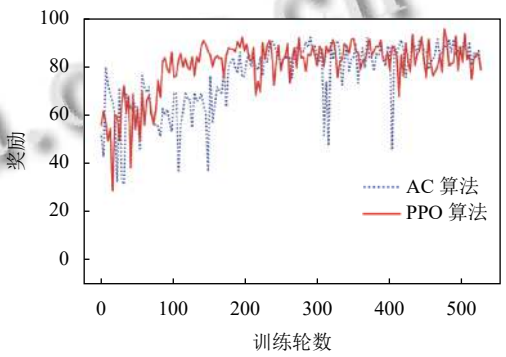

图 10 曲线训练中奖励随训练轮数变化曲线

在成功控制鱼体完成曲线上的循迹任务后, 使用 CFD 环境替换代理模型以产生真实的游动数据, 对策略模型进行测试. 如图 11 所示, 经过代理模型训练后的鱼体在 CFD 环境下也能顺利完成循迹任务. 花费时间方面, 使用代理模型完成一次测试只需要 30 s, 而使用 CFD 方式完成一次测试需要 5.3 h. 综上可以得出结论, 使用代理模型可以在保证训练有效的前提下, 大大提升训练的效率.

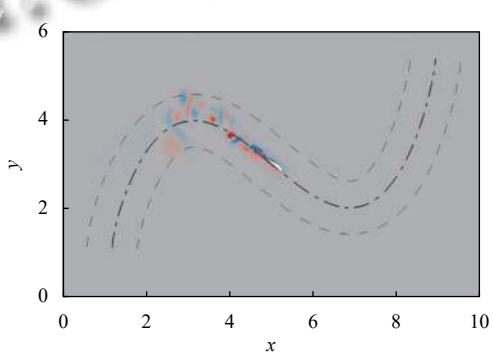

图 11 鱼体在曲线中游动的涡度图

3.4 小结与讨论

在本节中, 我们对比了采用 PPO 算法与 AC 算法在直线和曲线上的循迹实验效果, 并最终在 CFD 环境中测试了策略模型. 实验结果表明, PPO 算法在 Episode

© 中国科学院软件研究所 http://www.c-s-a.org.cn

Reward 方面比 AC 算法表现略好, 且在收敛速度上有明显的提升, 能够有效提高数据的效用; 同时证明代理模型能够在保证训练有效的前提下, 大大提升训练数据的产生速度.

4 急转弯实验分析

本节实验的目标是使鱼体能够在急转弯区域完成循迹任务, 因此需要对控制鱼体速度的 Actor2 网络进行训练, 并固定 Actor1 网络 (不参与训练), 实验参数的设置与第 3 节一致.

4.1 矩形训练

在矩形轨迹上对鱼体进行训练时, 鱼体需要在 3 个转角处完成 90°的转向, 因此需要加入对速度的训练, 使鱼体在急转弯时能主动减速, 从而规避越界风险.

使用之前在直线和曲线上训练后的 DRL 模型继续在矩形上训练. 训练过程如图 12(c) 所示, 可以看到, 未引入减速机制的 PPO 算法在训练中不断震荡, 始终无法收敛, 而引入速度参数的 PPO 算法在经过 300 轮的训练后, 鱼体学会在急转弯处减速, 获取的 Episode Reward 值也稳定在 80 以上.

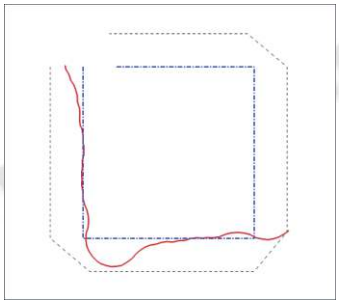

(a) PPO 算法控制下鱼体发生越界

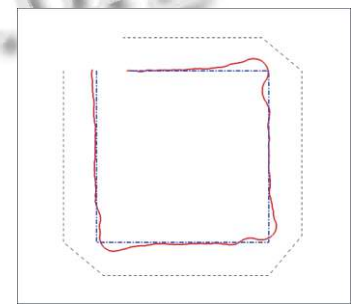

(b) 引入速度参数后鱼体成功完成循迹

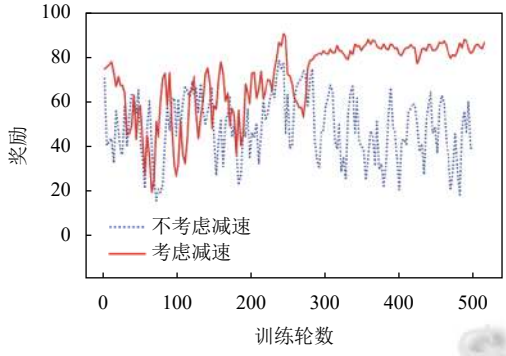

(c) 两算法在矩形训练中的奖励曲线

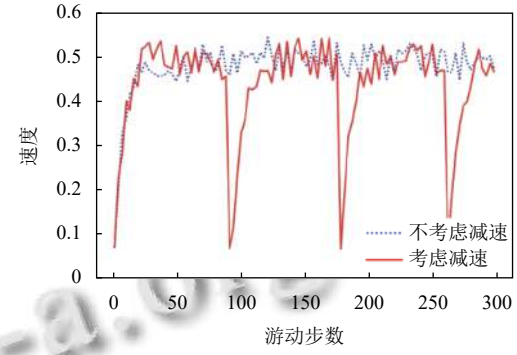

(d) 两算法在矩形路径上的速度曲线

图 12 在折角曲线上训练

图 12(a) 和图 12(b) 分别为引入速度参数前后的 PPO 算法的循迹结果. PPO 算法控制的鱼体在急转弯处发生越界, 无法完成循迹; 而引入速度参数后, 鱼体在转弯处主动减速, 从而顺利到达终点. 图 12(d) 是两个算法在训练 500 轮后鱼体从起点游到终点的速度, 可以看到, 引入速度参数后的 PPO 算法能够控制鱼体在矩形的 3 个转角处主动进行减速.

4.2 五角星路线测试

更进一步, 为了评估控制算法的泛化能力, 需要测试鱼体在未见过的路径上的循迹能力. 本文使用正五角星作为测试路径, 如图 13(a) 所示, 红点为起点, 黑点为终点. 鱼体在每个转角需要完成 144 度的转向才能通过, 因此必须正确识别到转角并完成减速动作.

经过测试, 使用带减速机制的 PPO 算法训练得到的策略模型, 在测试集上的 Episode Reward 稳定在 80 左右 (如图 13(c) 所示), 鱼体游完全程的成功率为 98%, 且在 4 个转角处都完成了减速动作 (如图 13(d) 所示). 使用不考虑减速的 PPO 算法时, 鱼体基本无法到达终点, 如图 13(b) 所示, 其奖励也一直在 20 附近震荡 (如图 13(c) 所示).

© 中国科学院软件研究所 http://www.c-s-a.org.cn

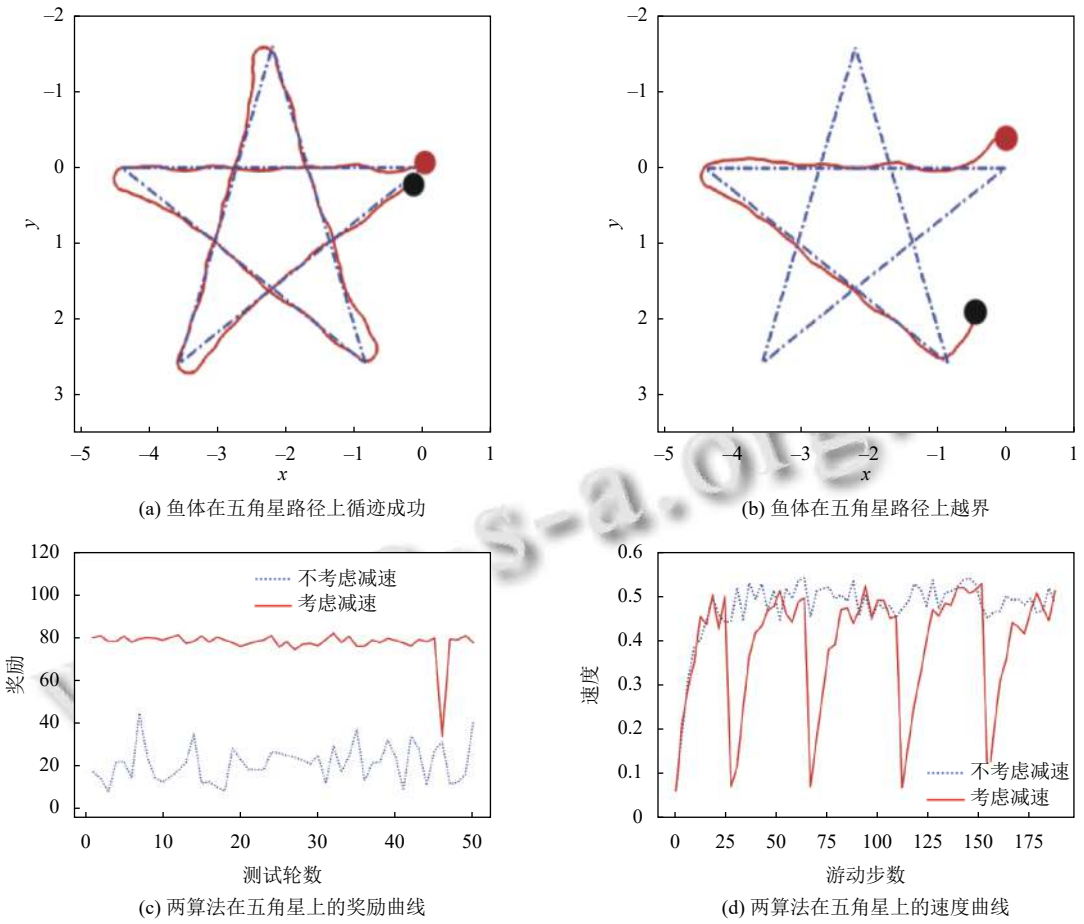

(a) 鱼体在五角星路径上循迹成功 (b) 鱼体在五角星路径上越界

(c) 两算法在五角星上的奖励曲线 (d) 两算法在五角星上的速度曲线

图 13 鱼体在五角星上的测试结果

表 2 不同算法在不同轨迹上的成功率比较

轨迹类型	AC		PPO		引入速度参数的PPO
	收敛步数	成功率 (%)	收敛步数	成功率 (%)	成功率 (%)
直线	400	100	150	100	100
S型曲线	200	90	100	96	100
矩形	—	29	—	33	99
正五角星(测试)	—	2	—	0	98

4.3 小结与讨论

在本节中, 我们使用引入速度参数的算法框架, 在矩形上对鱼体进行训练, 并在五角星路线上对模型进行测试. 实验结果表明, 与无速度参数的 PPO 算法相比, 引入速度参数的算法框架可以控制鱼体完成急转弯区域的循迹任务, 在矩形与五角星曲线上都达到接近 100% 的成功率.

表 2 是不同算法在不同轨迹上的成功率比较, 可以看出, 新的算法框架可以有效控制仿生鱼完成各种类型曲线上的循迹任务.

5 结论与展望

本文中使用代理模型替代 CFD 环境产生训练数据, 大大节省了研究鱼游问题的时间成本, 并保证了训练的有效性; 同时引入新的训练算法, 提高了数据的效用, 在收敛速度和奖励获取上都表现出更好的性能; 最后, 引入速度参数, 使得仿生鱼在直线、曲线与急转弯区域上的循迹任务都获得了成功.

未来的工作中, 我们将进一步引入更加成熟的代理模型来进一步优化结果; 同时还可以使用原始感官输入 (如图像、声呐等) 代替雷达系统完成鱼体对环境的感知, 减少人工干预, 实现真实环境下的循迹、避障等智能行为.

参考文献

1 林海. 仿生机器鱼机构设计及力学分析 [硕士学位论文].

© 中国科学院软件研究所 http://www.c-s-a.org.cn

西宁: 青海大学, 2015.
2 Gao A, Triantafyllou MS. Independent caudal fin actuation enables high energy extraction and control in two-dimensional fish-like group swimming. Journal of Fluid Mechanics, 2018, 850: 304–335. [doi: 10.1017/jfm.2018.456]
3 Gazzola M, Hejazialhosseini B, Koumoutsakos P. Reinforcement learning and wavelet adapted vortex methods for simulations of self-propelled swimmers. SIAM Journal on Scientific Computing, 2014, 36(3): B622–B639. [doi: 10.1137/130943078]
4 Novati G, Verma S, Alexeev D, *et al*. Synchronisation through learning for two self-propelled swimmers. Bioinspiration & Biomimetics, 2017, 12(3): 036001. [doi: 10.1088/1748-3190/aa6311]
5 Verma S, Novati G, Koumoutsakos P. Efficient collective swimming by harnessing vortices through deep reinforcement learning. Proceedings of the National Academy of Sciences the United States of America, 2018, 115(23): 5849–5854. [doi: 10.1073/pnas.1800923115]
6 皮骏, 李想, 张志力, 等. 基于神经模糊 PID 控制的四旋翼飞行器算法. 计算机系统应用, 2021, 30(5): 228–233. [doi: 10.15888/j.cnki.csa.007933]
7 Tian RY, Li L, Wang W, *et al*. CFD based parameter tuning for motion control of robotic fish. Bioinspiration & Biomimetics, 2020, 15(2): 026008. [doi: 10.1088/1748-3190/ab6b6c]
8 Khan S, Javed S, Naeem N, *et al*. Performance analysis of PID and state-feedback controller on the depth control of a robotic fish. Proceedings of the 2017 International Conference on Frontiers of Information Technology (FIT). Islamabad: IEEE, 2017. 7–11. [doi: 10.1109/FIT.2017.00009]
9 Novati G, Mahadevan L, Koumoutsakos P. Controlled gliding and perching through deep-reinforcement-learning. Physical Review Fluids, 2019, 4(9): 093902. [doi: 10.1103/PhysRevFluids.4.093902]
10 Zhu Y, Tian FB, Young J, *et al*. A numerical study of fish adaption behaviors in complex environments with a deep reinforcement learning and immersed boundary-lattice Boltzmann method. Scientific Reports, 2021, 11(1): 1691. [doi: 10.1038/s41598-021-81124-8]
11 Yan L, Chang XH, Tian RY, *et al*. A numerical simulation method for bionic fish self-propelled swimming under control based on deep reinforcement learning. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2020, 234(17): 3397–3415. [doi: 10.1177/0954406220915216]
12 Yan L, Chang XH, Wang NH, *et al*. Learning how to avoid obstacles: A numerical investigation for maneuvering of self-propelled fish based on deep reinforcement learning. International Journal for Numerical Methods in Fluids, 2021, 93(10): 3073–3091. [doi: 10.1002/fld.5025]
13 Hirt CW, Amsden AA, Cook JL. An arbitrary Lagrangian-Eulerian computing method for all flow speeds. Journal of Computational Physics, 1997, 135(2): 203–216. [doi: 10.1006/jcph.1997.5702]
14 Zhang LP, Wang ZJ. A block LU-SGS implicit dual time-stepping algorithm for hybrid dynamic meshes. Computers & Fluids, 2004, 33(7): 891–916. [doi: 10.1016/j.compfluid.2003.10.004]
15 Schulman J, Wolski F, Dhariwal P, *et al*. Proximal policy optimization algorithms. arXiv:1707.06347, 2017.
16 Konda VR, Tsitsiklis JN. Actor-citic algorithms. Proceedings of the 12th International Conference on Neural Information Processing Systems. Cambridge: MIT Press, 1999. 1008–1014
17 李茹杨, 彭慧民, 李仁刚, 等. 强化学习算法与应用综述. 计算机系统应用, 2020, 29(12): 13–25. [doi: 10.15888/j.cnki.csa.007701]

(校对责编: 孙君艳)

© 中国科学院软件研究所 http://www.c-s-a.org.cn