

适用于强化学习惯性环境的分数阶改进 OU 噪声

王 涛, 张卫华, 蒲亦非

(四川大学计算机学院, 成都 610065)

摘 要: 本文将 DDPG 算法中使用的 Ornstein-Uhlenbeck (OU) 噪声整数阶微分模型推广为分数阶 OU 噪声模型, 使得噪声的产生不仅和前一步的噪声有关而且和前 K 步产生的噪声都有关联. 通过在 gym 惯性环境下对比基于分数阶 OU 噪声的 DDPG 和 TD3 算法和原始的 DDPG 和 TD3 算法, 我们发现基于分数阶微积分的 OU 噪声相比于原始的 OU 噪声能在更大范围内震荡, 使用分数阶 OU 噪声的算法在惯性环境下具有更好的探索能力, 收敛得更快.

关键词: DDPG 算法; TD3 算法; 分数阶微积分; OU 噪声; 强化学习

中图分类号: TP39 **文献标识码:** A **DOI:** 10.19907/j.0490-6756.2023.022001

An improved Ornstein-Uhlenbeck exploration noise based on fractional order calculus for reinforcement learning environments with momentum

WANG Tao, ZHANG Wei-Hua, PU Yi-Fei

(College of Computer Science, Sichuan University, Chengdu 610065, China)

Abstract: In this paper, the integer-order Ornstein-Uhlenbeck (OU) noise model used in the deep deterministic policy gradient (DDPG) algorithm is extended to the fractional-order OU noise model, and the generated noise is not only related to the noise of the previous step but also related to the noise generated in the previous K steps in the proposed model. The DDPG algorithm and twin delayed deep deterministic (TD3) algorithm using the fractional-order OU noise model were compared with the original DDPG algorithm and TD3 algorithm in the gym inertial environment. We found that, compared with the original OU noise, the fractional-order OU noise can oscillate in a wider range, and the algorithm using the fractional-order OU noise had better exploration ability and faster convergence in inertial environment.

Keywords: Deep deterministic policy gradient; Twin delayed deep deterministic; Fractional calculus; Ornstein-Uhlenbeck process; Reinforcement learning

1 引 言

深度 Q 网络(DQN)^[1]的提出开创了深度学习和强化学习结合的先例, DQN 算法直接使用了深度神经网络来拟合强化学习中的 $Q(s, a)$ 函数, 并根据贪心策略选择下一步需要执行的动作, 这一工

作使得算法在 Atari 游戏上达到了近似人类玩家的水平.

基于 DQN 的工作, 后续还有人还提出了 DDQN^[2], Dueling DQN^[3], Rainbow DQN^[4]等工作, 这些工作极大地改进了基于值函数估计类算法的效果. 不过, 这些工作的动作空间都是离散的, 智

收稿日期: 2022-03-26

基金项目: 四川省科技计划(2022YFQ0047)

作者简介: 王涛(1997-), 男, 硕士研究生, 四川资阳人, 研究方向为分数阶微积分与强化学习. E-mail: 2647877536@qq.com

通讯作者: 张卫华. E-mail: zhangweihua@scu.edu.cn

能体每次只能选择有限的几个动作. 然而, 在实际的应用场景下, 更多的是需要强化学习算法处理连续控制任务. 比如无人机追逃控制^[5], 飞行器高度控制^[6], 机械臂轨迹规划^[7,8], 无人机航迹规划^[9]等.

对于连续控制任务则无法直接使用 DQN 系列的算法, 研究人员参考 DQN 系列算法值函数估计的思想, 提出了 DDPG 算法^[10], 在 DDPG 算法的基础上又提出了改进的 TD3 算法^[11]、SAC 算法^[12]和 D4PG 算法^[13]. 这些算法的提出弥补了基于值函数估计算法在连续空间任务的空白, 但是却有着探索能力差的问题, 尤其是 DDPG 算法, 由于算法每次输出一个确定性的动作而不是像 PPO^[14]这样的基于策略梯度的算法一样输出一个正态分布, 探索能力会很差.

DDPG 系列算法在实际连续控制任务中的使用往往会受到算法探索能力不足的影响, 对于一些需要探索的任务, 直接使用 DDPG 系列算法效果并不好. 本文结合分数阶微积分理论, 对整数阶 OU 过程进行分数阶推广, 使得噪声的产生能够和前 K 步相关联. 实验表明, 本文提出的分数阶推广 OU 噪声模型产生的噪声能够在惯性控制环境下促进 DDPG 和 TD3 算法的探索, 加快算法收敛, 有利于算法在实际控制环境中的应用.

2 相关工作

2.1 DDPG 算法

DQN 及其衍生算法很好地解决了离散动作空间的强化学习任务, 但是却无法处理连续动作空间的任務, 如果强行使用这一系列的算法需要对动作空间进行离散化, 而离散化又会面临离散动作过多的问题. DDPG 算法的作者认为 DQN 很好地解决了过去一直不看好的使用神经网络拟合 $Q(s, a)$ 函数的问题, 于是在 DDPG 中借鉴了 DQN 的离线训练和目标 Q 网络的思想.

对于离散动作空间的控制, 获得了 $Q(s, a)$ 函数后可以使用 ϵ -greedy 策略选取动作, 但是在连续空间使用这样的策略却是几乎不可能的事情, 为了进行动作选取, DDPG 算法借鉴了 DPG 算法的 actor-critic 思想, 使用策略梯度更新 actor, 使用贝尔曼等式来更新 critic.

由于 DDPG 的动作选取是一个确定性策略, 而不是输出一个策略分布, 在连续控制问题上会面临探索不足的问题, 文章作者提出了使用 Uhlen-

beck-Ornstein 过程产生的噪声来辅助探索.

OU 噪声在惯性环境下的探索能力要强于正态噪声, 但是, 我们发现通过对 OU 过程进行分数阶推广产生的分数阶 OU 噪声在惯性环境下甚至具有更好的探索能力, 能够使得离线更新的算法更快地收敛.

2.2 TD3 算法

DDPG 算法已经能够解决很多连续控制问题, 但是除了探索能力不足之外还有错误估计的问题, 也就是 critic 会高估某个状态的 Q 值, 这种估计误差又会进一步地放大, 最终影响算法的表现.

TD3 算法参考了 double-Qlearning^[15] 的双 critic 的思想, 使用裁剪双 Q 学习的技巧, 也就是通过对两个 critic 的值取最小值来解决算法高估状态带来的偏差, 虽然这样可能会带来低估的问题, 但是相比于高估状态带来的后果, 低估的问题是可以接受的.

TD3 的作者认为, 如果算法对状态价值的估计不准确会导致策略网络表现不佳, 而较差的策略网络又会进一步导致价值估计不准从而导致算法性能不佳. 为了解决这个问题, TD3 提出了延迟策略更新(Delayed Policy Update)的技巧, 也就是让 critic 的更新频率高于策略网络的更新频率, 通过首先减少 critic 的估计误差然后再训练策略网络的思想提高算法的性能.

DDPG 这样的确定性策略算法每次只输出一个确定性的动作而不是动作分布, 这样的算法很容易受到 critic 估计的误差的影响而导致算法性能下降, 为了解决这个问题, TD3 借鉴了 SARSA 算法^[16]的思想, 首先对动作增加噪声, 然后再进行裁剪, 使得算法不容易受到 critic 的误差影响.

TD3 算法很好地解决了 DDPG 算法值函数估计的问题, 但是并没有根本上解决 DDPG 探索不足的问题, 文章使用的独立正态噪声能够一定程度上解决探索问题, 但是在惯性环境下, 独立的正态噪声的探索能力仍然不足, 本文提出的分数阶 OU 噪声能够促进算法在惯性环境下更好地探索收敛得更快.

2.3 分数阶微积分

分数阶微积分是传统的整数阶微积分的推广, 和整数阶微积分相比, 分数阶微积分更加具有一般性. 分数阶微积分有多种定义形式, 研究中一般使用 Grnwald-Letnikov^[17], Riemann-Liouville^[18] 和 Caputo^[19] 定义式. 分数阶微积分具有非局部特性

和长时记忆性,使用分数阶微积分推广的模型相比于整数阶的数学模型在图像处理 and 信号处理^[20-22]中往往具有更好的效果。

由于 Riemann-Liouville 和 Caputo 定义式是积分形式不易离散化,文章使用 G-L 定义式来推广 OU 噪声. 离散形式的函数 $f(x)$ 的 v 阶导数的 G-L 定义式如式(1).

$$G-LD_x^v f(x) = \lim_{K \rightarrow \infty} \left\{ \frac{\left(\frac{x-a}{k}\right)^{-v}}{\Gamma(-v)} \sum_{k=0}^{K-1} \frac{\Gamma(k-v)}{\Gamma(k+1)} f\left[x-k\left(\frac{x-a}{K}\right)\right] \right\} \quad (1)$$

其中, $G-LD_x^v$ 表示 G-L 定义式中分数阶微分运算符; v 代表任意的实数, $f(x)$ 表示可微分积分的函数; $[a, x]$ 是 $f(x)$ 的定义域; K 表示把定义域划分为 K 段; k 表示取第 k 段; $\Gamma(\alpha) = \int_0^\infty e^{-x} x^{\alpha-1} dx$ 表示 gamma 函数.

令 $\Delta x = \frac{x-a}{k}$, $\Delta x \rightarrow 0$ 表示定义域 $f(x)$ 的离散间隔, 根据式(1), 函数 $f(x)$ 在定义域 $[x-K\Delta x, x]$ 上 v 阶 G-L 分数阶微分如式(2).

$$G-L \text{ Diff}_x^v f(x) = \frac{1}{\Delta x^v} \sum_{k=0}^K \frac{\Gamma(k-v)}{\Gamma(-v)\Gamma(k+1)} f(x-k\Delta x) = \frac{1}{\Delta x^v} \left[f(x) + \sum_{k=1}^K \frac{\Gamma(k-v)}{\Gamma(-v)\Gamma(k+1)} f(x-k\Delta x) \right] \quad (2)$$

令 $v=1$, 式(2)变为式(3), 也就是 $f(x)$ 的一阶微分. 这表明, 分数阶微积分正是整数阶微积分的推广.

$$G-L \text{ Diff}_x^1 f(x) = \frac{1}{\Delta x} [f(x) - f(x-\Delta x)] \quad (3)$$

对比式(1)和式(2)可以看出, 当 $v \neq 1$ 时, $f(x)$ 的分数阶微分是无限项求和, 正因为此, G-L 定义式定义的分数阶微分相比于整数阶微分具有长时记忆性的特点.

2.4 OU 噪声

OU 噪声通过 Ornstein-Uhlenbeck 过程^[23]产生, Ornstein-Uhlenbeck 过程的微分方程如式(4). OU 过程的离散形式如式(5), 其中 ε 表示噪声的均值, θ 控制噪声回复到均值的速度, σ 控制随机扰动的大小, w 表示维纳过程.

$$dx_t = \theta(\mu - x_t)dt + \sigma\Delta w_t \quad (4)$$

$$x_{n+1} = x_n + \theta(\mu - x_n)\Delta t + \sigma\Delta w_n \quad (5)$$

可以看出, 整个 OU 噪声就是在围绕均值进行前后相关的波动, 与高斯噪声不同, OU 噪声的产生和上一次的噪声相关, 在具有惯性的控制系统中, 比如 LunarlanderContinuous-v2, 环境要求算法控制火箭喷射器的方向和力道, 由于飞行器的运动要受惯性影响, 后一步的动作在上一步的动作的惯性下可能并不能带来明显的改变, 但是如果一直选择反向的动作, 就可以抵消掉前一步的惯性影响.

OU 噪声在这样的环境下, 相比于独立生成的正态噪声, 更有可能因为前后相关的噪声使得算法能更好地探索, 具有更好的收敛性.

3 分数阶 OU 噪声

对于式(5), 令 $\Delta t = 1$, 可得式(6), 可见, 左边即是 $x(t+1)$ 一阶微分. 将该一阶微分使用 G-L 定义式推广为 v 阶的分数阶微分形式可得式(7), 其中 N 表示独立的 $0, 1$ 正态分布.

$$\frac{x(t+1) - x(t+1-\Delta t)}{\Delta t} = -\theta(x(t) - \varepsilon) + \sigma N \quad (6)$$

$$G-L \text{ Diff}_x^v x(t+1) = -\theta(x(t) - \varepsilon) + \sigma N \quad (7)$$

根据式(2)定义的 v 阶离散 G-L 分数阶微分定义式, 将式(7)左边展开为式(8).

$$G-L \text{ Diff}_x^v x(t+1) = x(t+1) + \sum_{k=1}^{K-1} \frac{\Gamma(k-v)}{\Gamma(-v)\Gamma(k+1)} x(t+1-k) \quad (8)$$

结合式(7)和式(8)可得 v 阶分数阶 OU 噪声产生的迭代式(9).

$$x(t+1) = -\theta(x(t) - \varepsilon) - \sigma N - \sum_{k=1}^{K-1} \frac{\Gamma(k-v)}{\Gamma(-v)\Gamma(k+1)} x(t+1-k) \quad (9)$$

可见, 分数阶 OU 噪声的产生不仅和前一步的噪声有关, 还和前 K 步的噪声都相关联, 这样的噪声使得算法在具有惯性的环境中能够更好地探索. 噪声生成步骤如算法 1.

算法 1 分数阶 OU 噪声产生算法

Begin

设定参数 $\theta, \varepsilon, \sigma, K, v$

初始化数组 $x[K] = N(0, 1)$, $\text{mask}[K] = 0$, $\text{index} = 0$

For $k = 1:K$

$\text{mask}[k] = \frac{\Gamma(k-v)}{\Gamma(-v)\Gamma(k+1)}$

End For

$$x[index] = -\theta(x[t] - \epsilon) - \sigma N - mask \otimes x$$
$$index = (index + 1) \% K$$

End

算法 1 首先初始化全局的长度为 K 的数组 x 用于存放生成的噪声,由于初始时刻 x 中并没有保存历史数据,初始化设定为从标准正态分布中采样. 长度为 K 的数组 $mask$ 用于存放分数阶权重模板,初始化为 0. 计算出权重模板后根据式(9)计算下一个噪声并存入当前 $index$ 指向的位置. 其中, $mask \otimes x$ 表示权重模板和历史噪声进行卷积, N 表示对标准正态分布进行采样 $x[t]$ 表示上一次的噪声数据. 最后对 $index$ 进行更新重复利用数组 x .

4 实验与分析

分数阶 OU 噪声是一种探索策略,为了测试这种噪声的探索能力,本文选择了离线策略(off-policy)连续控制的经典算法 DDPG 以及基于 DDPG 的改进算法 TD3 进行实验. 需要注意的是,我们不选择 PPO 这样的在线(on-policy)算法是因为探索策略和训练策略差异很大的时候在线算法根本不能训练.

为了证明分数阶 OU 噪声在具有惯性的环境下能够使得算法更好地探索,本文选择了 gym 强化学习环境中的经典控制游戏 Pendulum-v0 和 Mountain Car Continuous-v0 以及 box2d 的 Lunar Lander Continuous-v2. Pendulum-v0 任务要求将一根自然垂下的钟摆立起来,环境的输入状态是钟摆的角度和角速度,环境的动作是驱动钟摆旋转的力矩大小. Lunar Lander Continuous-v2 的任务是控制着陆器的火箭喷口的方向和力道使得着陆器着陆,消耗的能量越少越好. Mountain Car Continuous-v0 则是控制一辆动力不足的小车利用惯性冲上山坡. 这个环境是三个环境中最需要探索的一个环境. 如果探索得不好,算法将学不到任何关于环境的有用知识,算法控制的小车将会在原点不断地徘徊.

由于 DDPG 算法性能一般,选择 Pendulum-v0 环境进行对比实验即可. 图 1 是选取 $k=3, v=0.75, \sigma=0.2$ 的分数阶 OU 噪声和 $\sigma=0.2$ 的原始 OU 噪声随机选取 5 个种子运行 10 万次的结果. 曲线比较平滑是因为图 1 中是对模型进行无噪声评估的数据,不是原始的训练数据,下同.




图 1 使用 DDPG 算法在 Pendulum-v0 环境下对比分数阶 OU 噪声和原始 OU 噪声
Fig. 1 Compare fractional OU noise with original OU noise under Pendulum0-v0 using DDPG

图 1 展示了在 Pendulum-v0 环境下的对比实验,由于环境本身比较简单,使用分数阶 OU 噪声的 DDPG 智能体和使用原始 OU 噪声的智能体表现没有明显的差异.

TD3 算法选择在 LunarLanderContinuous-v2 和 MountainCarContinuous-v2 作为对比环境. TD3 算法在 LularLanderContinuous-v2 上随机选取 5 个种子运行 50 万次的数据如图 2. 实验选取 $\sigma=1.2, \theta=0.15, k=3, v=0.75$ 的分数阶 OU 噪声, $\sigma=0.2$ 的 OU 噪声和 $\sigma=0.2$ 的原始正态噪声进行对比实验.




图 2 使用 TD3 算法在 LunarLanderContinuous-v2 环境下对比分数阶 OU 噪声,原始 OU 噪声和原始正态噪声
Fig. 2 Compare fractional OU noise with original OU and normal noise under LunarLanderContinuous-v2 using TD3

图 2 展示了在 LunarLanderContinuous-v2 环

境下的结果, 相比于 Pendulum-v0, 该环境要复杂许多, 智能体需要更多的探索. 从结果可以看出, 使用分数阶 OU 噪声的 TD3 智能体表现超过了使用 OU 噪声和原始正态噪声的智能体, 算法收敛得更快.

TD3 算法在 MountainCarContinuous-v2 上随机选取 5 个种子运行 30 万次的结果如图 3 所示. 实验选取 $k=3, v=0.75, \sigma=0.6$ 的分数阶 OU 噪声和 $\sigma=0.6$ 的原始 OU 噪声以及 $\sigma=0.6$ 的原始正态噪声进行对比实验.




图 3 使用 TD3 算法在 Mountain Car Continuous-v0 环境下对比分数阶 OU 噪声、原始 OU 噪声和原始正态噪声

Fig. 3 Compare fractional OU noise with original OU noise and normal noise under MountainCarContinuous-v0 using TD3

图 3 展示了在 MountainCarContinuous-v0 环境下的对比结果. 该环境是三个环境中最难的一个, 需要最多的探索. 从图 3 中我们可以看到, 使用正态噪声的 TD3 智能体在很长时间内几乎学不到任何知识, 获得的奖励一直接近 0. 而使用分数阶 OU 噪声和原始 OU 噪声的智能体则表现得更好更多. 可以看出, 基于分数阶微积分的 OU 噪声能够在具有惯性的环境中更好地鼓励强化学习智能体进行探索并更快地学习.

为了探究分数阶 OU 噪声、OU 噪声和正态噪声在惯性环境下的探索能力区别的原因, 本文生成了 $\sigma=0.6$ 的三种噪声如图 4a~4c.

分析三种噪声可以发现: 正态噪声围绕原点在正负两个方向上分布, 且靠近原点的噪声点要多于远离原点的噪声点. 这表明, 如果将正态噪声应用在动作空间上, 算法会大量地探索输出动作附近正负两个方向的动作空间, 但是对于偏远处动作则很少探索到.




图 4 (a) $\sigma=0.6$ 采样 100 次的正态噪声; (b) $\sigma=0.6$ 采样 100 次的 OU 噪声; (c) $\sigma=0.6, k=3, v=0.75$ 采样 100 次的分数阶 OU 噪声

Fig. 4 (a) Normal noise with location=0.0, scale=0.6 sampled 100 time steps; (b) OU noise with $\sigma=0.6$ sampled for 100 time steps; (c) fractional OU noise with $\sigma=0.6, k=3, v=0.75$, sampled for 100 time steps

由微分方程可见,OU 噪声是一种前后相关的带有回归性质的噪声,也就是说噪声偏离原点越多,下一个噪声就越有可能回归到原点.同时也要注意,OU 噪声虽然会回归到原点,但是在较长的时间段内都是在同一个方向探索.这就决定了使用 OU 噪声的算法能够在预测动作的某一个方向进行很好地探索,但是对于另一个方向却容易出现欠缺探索的问题.

对于分数阶 OU 噪声,综合上述图的分析可以发现,分数阶 OU 噪声不仅具有类似于 OU 噪声的前后相关和回归性质,还克服了 OU 噪声容易只探索一个方向的问题.分数阶 OU 噪声围绕原点进行大范围的且前后相关的探索的性质就决定了使用分数阶 OU 噪声的算法能够在预测动作的两侧进行足够的探索,在具有惯性的环境下表现得更好.

5 结 论

本文将 DDPG 算法中使用的基于 Ornstein-Uhlenbeck 过程的 OU 噪声进行分数阶推广得到探索能力更强的分数阶 OU 噪声.通过在 Pendulum-v0、LunarLanderContinuous-v2 以及 MountainCarContinuous-v0 环境下进行对比实验,我们发现基于 Ornstein-Uhlenbeck 过程的 OU 噪声使得 DDPG 和 TD3 算法在惯性环境下比正态噪声具有更好探索能力.而基于分数阶微积分的推广 Ornstein-Uhlenbeck 过程的分数阶 OU 噪声,在使得 DDPG 和 TD3 算法在惯性环境下更好地探索.这一点上做得比原始 OU 噪声更好,且使用分数阶 OU 噪声的 TD3 算法在惯性环境下能够更好地探索从而更快地学习.

本文还通过分析分数阶 OU 噪声、原始 OU 噪声和正态噪声的采样点构成的曲线得出了分数阶 OU 噪声在惯性环境下探索的更好的原因是分数阶 OU 噪声能够围绕原点进行自相关的、大范围的探索.

参考文献:

- [1] Volodymyr M, Koray K, David S, *et al.* Human-level control through deep reinforcement learning [J]. *Nature*, 2015, 518: 529.
- [2] Hasselt H V, Guez A, Silver D. Deep reinforcement learning with double Q-learning [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, CA: AAAI Press, 2018: 2094.
- [3] Wang Z, Schaul T, Hessel M, *et al.* Dueling network architectures for deep reinforcement learning [C]//International Conference on Machine Learning. SAN DIEGO, CA: JMLR, 2016: 2939.
- [4] Hessel M, Modayil J, Van Hasselt H, *et al.* Rainbow: combining improvements in deep reinforcement learning [C]//Thirty-second AAAI Conference on Artificial Intelligence. Palo Alto, CA: AAAI Press, 2018: 3215.
- [5] 符小卫, 徐哲, 王辉. 基于 DDPG 的无人机追捕任务泛化策略设计[J]. *西北工业大学学报*, 2022, 40: 9.
- [6] 刘安林, 时正华. 基于 DDPG 策略的四旋翼飞行器目标高度控制[J]. *陕西科技大学学报*, 2021, 39: 7.
- [7] 张浩博, 仲志丹, 乔栋豪, 等. DDPG 优化算法的机械臂轨迹规划[J]. *组合机床与自动化加工技术*, 2021, 12: 37.
- [8] 张良安, 唐锴, 李鹏飞, 等. 基于复合摆线轨迹的四足机器人稳定性分析[J]. *江苏大学学报: 自然科学版*, 2022, 43: 62.
- [9] 高敬鹏, 胡欣瑜, 江志烨. 改进 DDPG 无人机航迹规划算法[J]. *计算机工程与应用*, 2022, 58: 264.
- [10] Lillicrap T P, Hunt J J, Pritzel A, *et al.* Continuous control with deep reinforcement learning [J/OL]. [2022-01-28]. <https://arxiv.org/abs/1509.02971>.
- [11] Fujimoto S, Hoof H, Meger D. Addressing function approximation error in actor-critic methods [C]//International Conference on Machine Learning. San Diego, CA: JMLR, 2018: 2587.
- [12] Haarnoja T, Zhou A, Abbeel P, *et al.* Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor [C]//International Conference on Machine Learning. San Diego, CA: JMLR, 2018: 2976.
- [13] Barth-Maron G, Hoffman M W, Budden D, *et al.* Distributed distributional deterministic policy gradients[C]//Proceedings of the 6th International Conference on Learning Representations. La Jolla, CA: OpenReview.net, 2018.
- [14] Schulman J, Wolski F, Dhariwal P, *et al.* Proximal policy optimization algorithms [EB/OL]. <https://arxiv.org/abs/1707.06347>.
- [15] Hasselt H. Double Q-learning [C]//Proceedings of the 23rd International Conference on Neural Information Processing Systems. La Jolla, CA: NIPS, 2010.
- [16] Sutton R S, Barto A G. Introduction to reinforcement learning [M]. Cambridge, MA: MIT Press, 2018.

ment learning [M]. Cambridge: MIT Press, 1998.

[17] Oldham K B, Spanier J. The fractional calculus: integrations and differentiations of arbitrary order [M]. New York: Academic press, 1974: 47.

[18] Samko S G, Kilbas A A, Marichev O I. Fractional integrals and derivatives: theory and applications [M]. Yverdon-les-Bains, Switzerland: Gordon and Breach Science Publishers, 1993: 28.

[19] Podlubny I. Fractional differential equations: an introduction to fractional derivatives, fractional differential equations, to methods of their solution and some of their applications [M]. San Diego: Elsevier Science & Technology, 1998: 41.

[20] 蒲亦非. 将分数阶微分演算引入数字图像处理[J]. 四川大学学报: 工程科学版, 2007, 39: 9.

[21] 彭朝霞, 蒲亦非. 基于分数阶微分的卷积神经网络人脸识别[J]. 四川大学学报: 自然科学版, 2022, 59: 35.

[22] 蒲亦非, 余波, 袁晓. 类脑计算的基础元件: 从忆阻元到分忆抗元[J]. 四川大学学报: 自然科学版, 2020, 57: 8.

[23] Uhlenbeck G E, Ornstein L S. On the theory of the brownian motion[J]. Phys Rev, 1930, 5: 823.

引用本文格式:

中 文: 王涛, 张卫华, 蒲亦非. 适用于强化学习惯性环境的分数阶改进 OU 噪声 [J]. 四川大学学报: 自然科学版, 2023, 60: 022001.

英 文: Wang T, Zhang W H, Pu Y F . An improved Ornstein-Uhlenbeck exploration noise based on fractional order calculus for reinforcement learning environments with momentum [J]. J Sichuan Univ: Nat Sci Ed, 2023, 60: 022001.