


Multi-Critic DDPG Method and Double Experience Replay 多critic的DDPG算法和双经验池结构

吴蛟* 王瑞 李瑞英 张慧 胡晓惠

*通讯方式: 15611537585 | wujiao2016@iscas.ac.cn

背景

强化学习方法(Deep Reinforcement Learning, DRL)在人工智能和自动控制等领域得到了广泛的关注和研究。在DRL过程中,智能体与环境进行交互来尽可能的获得更多的累计奖励,通常可建模成马尔科夫决策过程。




- 连续决策过程
- 无监督, 只有奖励信号反馈
- 反馈通常是延迟的
- 数据相关, 并不独立

创新点

① 多critic的DDPG算法

多个独立且不同的critic的平均值代替DDPG算法中的Q值, 提高训练过程的稳定性和智能体的表现。



误差:

$$L(\theta_i) = (r(s_t, a_t) + \gamma Q'(s_{t+1}, a_{t+1} | \theta_i^-) - Q(s_t, a_t | \theta_i))^2$$

$$L_{avg}(\theta) = (r(s, a) + \gamma Q_{avg}^{target}(s, a | \theta^-) - Q_{avg}(s, a | \theta))^2$$


$$C(\theta_i) = (Q_i(s, a | \theta_i) - Q_{avg}(s, a | \theta))^2$$

损失函数:

$$Loss(\theta_i) = \tau L(\theta_i) + (1 - \tau) L_{avg}(\theta) + \beta C(\theta_i),$$

$$\tau, \beta \in (0, 1)$$

② 双经验池结构



- 额外的经验池用来保存特别好或特别差的经验信息。
- 抽样时依照比例, 分别从两个经验池抽取一批数据。
- 目的在于加快收敛过程。


DDPG算法

(Deep Deterministic Policy Gradient)


确定性动作 $a = \mu(s | \omega)$

确定性策略梯度:

$$\nabla_a Q(s, a) = \nabla_a Q(s, a | \theta) |_{a=\mu(s | \omega)} \nabla_\omega \mu(s | \omega)$$



实验结果



图(a)表明更高更稳定的Q值; 图(b)表明完美的波动性对比; 图(c)和图(d)表明损失函数的收敛范围更小更稳定; 图(e)表明收敛过程的加速。

总结与展望

- 证明多critic的DDPG算法具有更好的稳定性和性能提升。
- 双经验池结构的加速收敛作用得到验证。
- 研究展望: 超参数 τ, β 随着训练自动调整; 经验数据的汰换方式的改进。