本章目录

单智能体强化学习经典算法

第十章 集群协同与博弈对抗

10.1 集群协同基础与控制架构

10.2 一致性与编队控制

10.3 智能博弈与强化学习基础

10.4 单智能体强化学习经典算法

10.5 多智能体强化学习与规模扩展

10.6 集群关键技术与挑战

10.7 RflySim集群框架与接口

10.8 本章实验案例与综合验证

10.9 习题与课堂讨论

本节 4 个教学单元

10.4.1 Q-Learning
教材对应：第10.1.3.4节第1项

10.4.2 深度Q网络DQN
教材对应：第10.1.3.4节第2项

10.4.3 Actor-Critic与DDPG
教材对应：第10.1.3.4节第3–4项

10.4.4 改进算法与选型
教材对应：第10.1.3.4节第5项

10.4.1 Q-Learning：任务与经验

从已知模型到采样学习

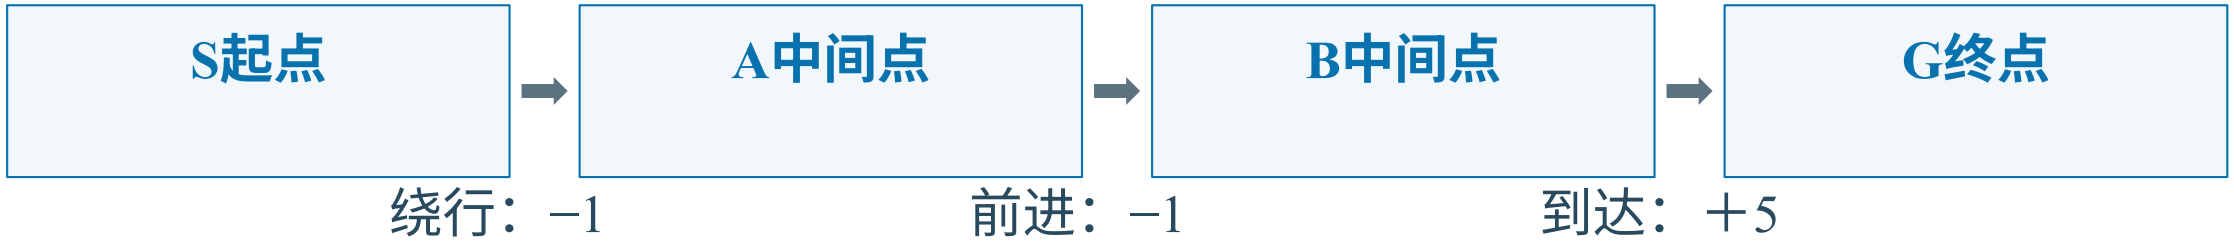

- **教学模型：** S有直接／绕行两个动作，A与B仅能前进，G终止；折扣为0.9。
- **经验：** 一条状态、动作、奖励、下一状态与终止标志，来自实际访问的转移。
- **对照答案：** S直接动作价值为2，绕行为2.15；本节检查估计如何接近这些值。

10.4.1 Q-Learning：式10.30–10.31

Q-Learning用TD误差修正一个表项

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha\delta_t \tag{10.30}$$

$$\delta_t = r_{t+1} + \gamma \max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t) \tag{10.31}$$

$$y_t = r_{t+1} + \gamma(1 - d_{t+1}) \max_{a'} Q(s_{t+1}, a')$$

$d_{t+1} = 1$表示真正终止，此时目标仅为本次奖励；$0 < \alpha \leq 1$。

10.4.1 Q-Learning：可复算更新

一次Q更新的三个数

S起点
执行绕行

→ 奖励：−1分

A下一状态
未终止

经验与估计	给定值
S绕行的旧Q值	1
A的最大Q值	3.5
折扣／学习率	0.9／0.5

目标值

$$y = -1 + 0.9 \times 3.5 = 2.15$$

TD误差

$$\delta = 2.15 - 1 = 1.15$$

更新后的Q值

$$1 + 0.5 \times 1.15 = 1.575$$

只更新本次访问的S绕行表项；其他表项保持原值。

10.4.1 Q-Learning：终止目标

普通转移与终止样本的更新

终止转移

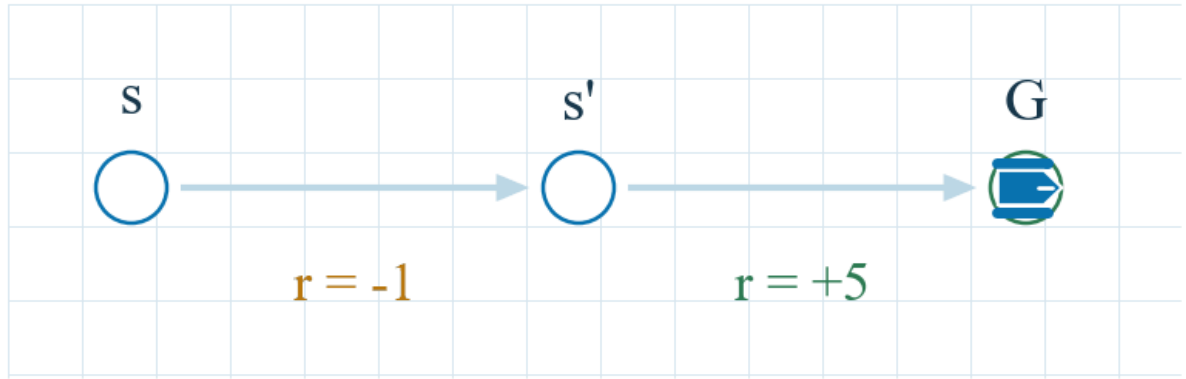

s: 2 → 2.3　　s': 4 → 4.5

终点不引导后续价值

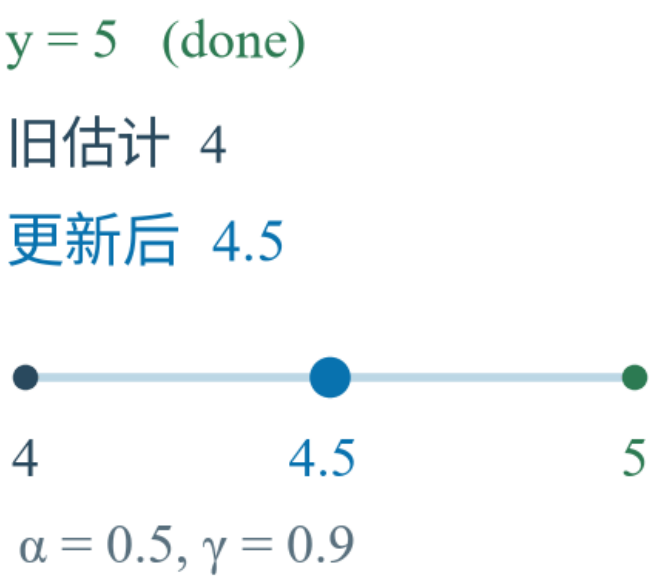

图：普通转移与终止样本的Q值更新动画

独立一步算例，非四状态导航轨迹；真正终止时不引导后续价值。

10.4.1 Q-Learning：异策略与探索

探索策略可以不同于学习目标

概念	作用	例子
行为策略	产生实际经验	探索时偶尔选当前较差动作
目标策略	定义正在学习的行为	目标选择下一状态最高Q
异策略off-policy	行为与目标策略可以不同	历史转移可用于更新
同策略on-policy	学习数据对应当前或近期采样策略	PPO使用本轮收集的数据批次

两个动作、唯一贪婪动作且 $\varepsilon = 0.2$：贪婪动作概率为 $0.8 + 0.2/2 = 0.9$。

10.4.1 Q-Learning：导航Q表收敛过程

完整采样循环与学习结果

采样轮次	S绕行	A前进	B到G	S直接
0	0	0	0	0
1	−0.5000	−0.5000	2.5000	1.0000
4	−0.2906	2.1562	4.6875	1.8750
8	1.6002	3.3457	4.9805	1.9922
16	2.1418	3.4988	4.9999	2.0000
32	2.1500	3.5000	5.0000	2.0000

每轮顺序：S→A、A→B、B→G、S→G。全零初值，学习率0.5，折扣0.9。

10.4.1 Q-Learning：采样与路径选择

持续采样，让起点逐渐看见绕行的收益

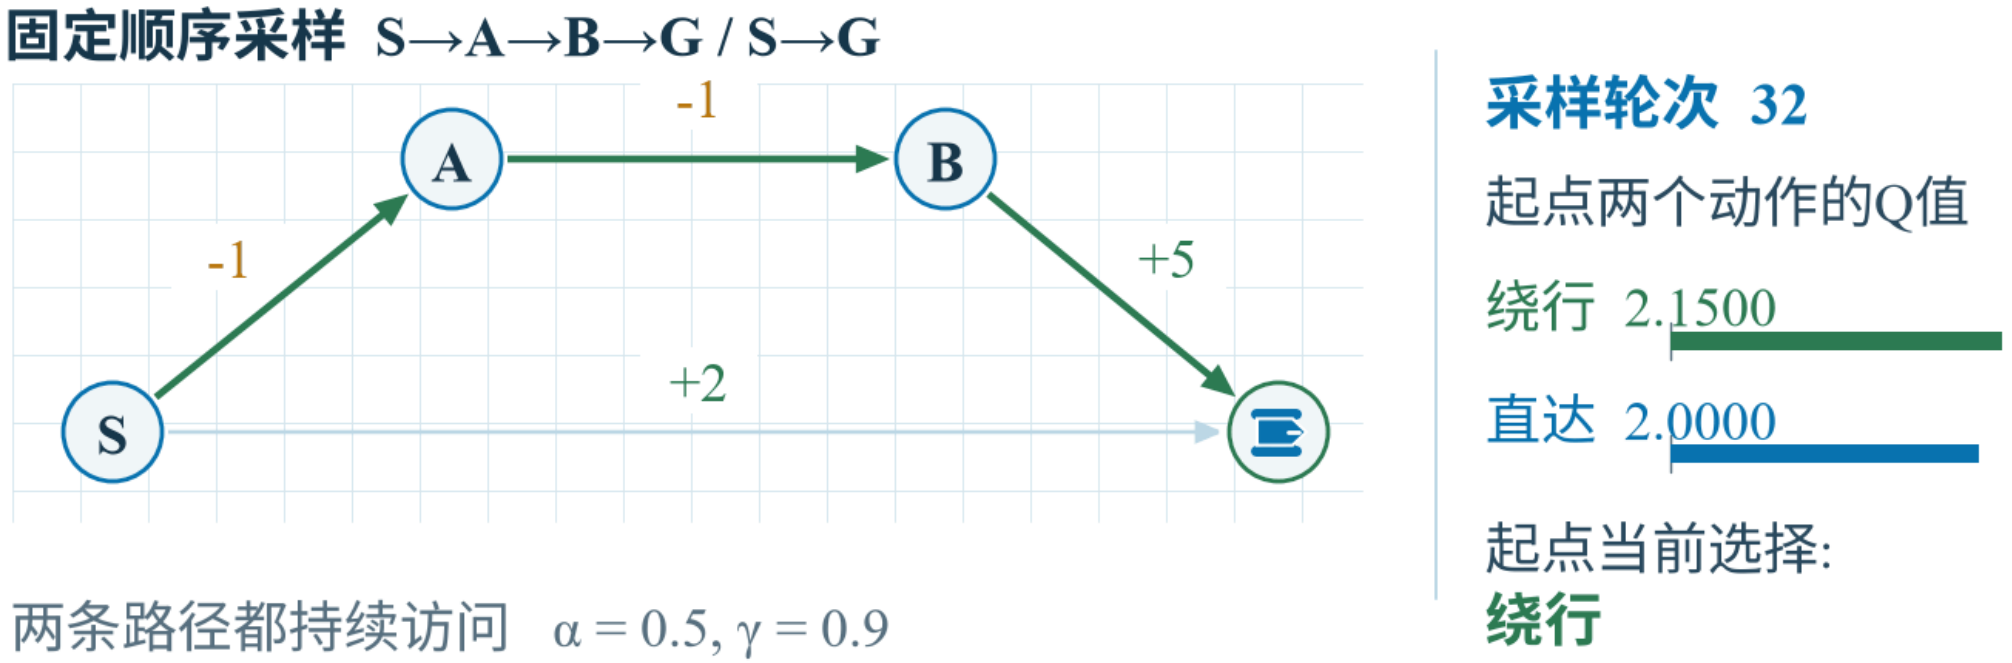

图：固定顺序覆盖两条路径；展示第1、4、8、16、32轮，未展示轮次也参与计算

第8轮仍偏向直达，第16轮转向绕行；当前较差的动作也要获得样本。

10.4.1 Q-Learning：适用范围

收敛条件与终止处理

- **表格适用：**状态动作可枚举；每个表项存储一个独立估计，高维连续状态不适合逐项建表。
- **随机收敛条件：**有限平稳MDP、有界奖励、充分访问，以及适当衰减的学习率。

$$\sum_k \alpha_k(s,a) = \infty, \qquad \sum_k \alpha_k^2(s,a) < \infty$$

真实终止：target＝本次奖励。仅时间截断：用截断前的末状态估计后续价值。

本章目录

单智能体强化学习经典算法

第十章 集群协同与博弈对抗

10.1 集群协同基础与控制架构

10.2 一致性与编队控制

10.3 智能博弈与强化学习基础

10.4 单智能体强化学习经典算法

10.5 多智能体强化学习与规模扩展

10.6 集群关键技术与挑战

10.7 RflySim集群框架与接口

10.8 本章实验案例与综合验证

10.9 习题与课堂讨论

本节 4 个教学单元

10.4.1 Q-Learning

教材对应：第10.1.3.4节第1项

10.4.2 深度Q网络DQN

教材对应：第10.1.3.4节第2项

10.4.3 Actor-Critic与DDPG

教材对应：第10.1.3.4节第3–4项

10.4.4 改进算法与选型

教材对应：第10.1.3.4节第5项

10.4.2 深度Q网络DQN：图10.6

Q表与神经网络怎样估计价值

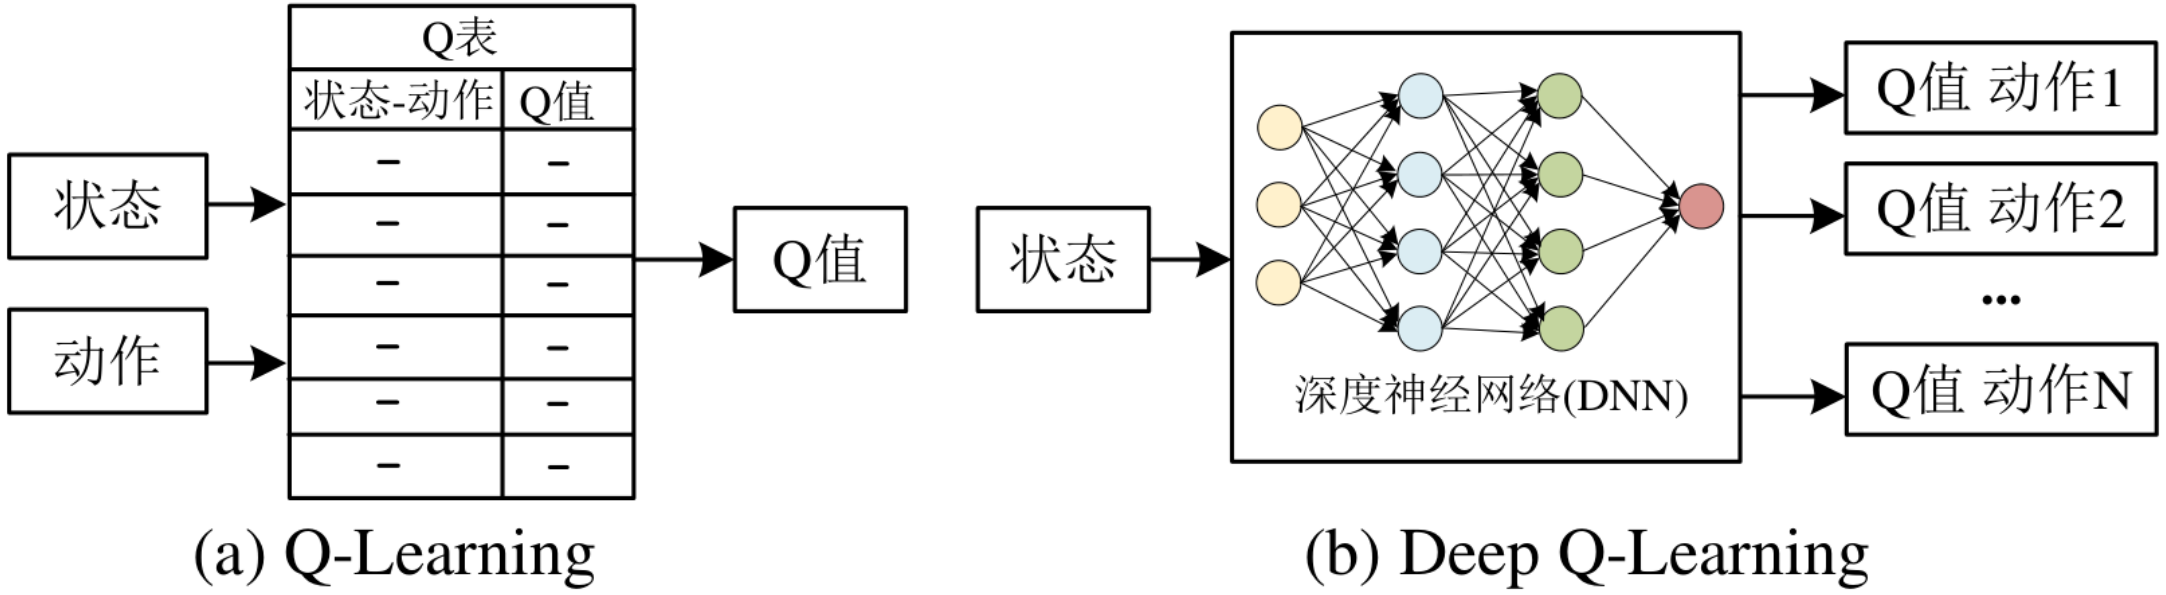

图10.6 Q-Learning和DQN在Q值估计的区别

DQN用共享参数近似Q值；输入可高维，标准输出对应有限离散动作。

10.4.2 深度Q网络DQN：状态、输出与选择

网络输出Q值，再由比较得到动作

状态输入
位置／图像／速度 → 主Q网络
估计三个动作价值 → 动作选择
比较或加入探索

$$Q(s,\cdot;\theta) = [1.2,\ 2.4,\ 0.8]$$

动作	左	前	右
Q值	1.2	2.4	0.8
贪婪选择	否	是	否

10.4.2 深度Q网络DQN：稳定训练机制

回放池与目标网络各管一件事

环境转移
存入经验池D
→
随机小批量
旧样本可重复使用
→
目标网络算y
主网络拟合y

$$D: (s, a, r, s', d)$$

- **回放池：**减少相邻样本相关性，重复利用已发生的经验；没有覆盖的动作仍缺少证据。
- **目标网络：**参数暂时保持或缓慢变化，让主网络拟合的目标不立即跟着自己变化。

10.4.2 深度Q网络DQN：式10.32–10.33

DQN的目标与平方误差

$$\mathcal{L}(\theta) = \mathbb{E}_{(s,a,r,s')\sim D}[(y - Q(s,a;\theta))^2] \tag{10.32}$$

$$y = r + \gamma \max_{a'} Q(s', a'; \theta^-) \tag{10.33}$$

$$y = r + \gamma(1-d) \max_{a'} Q(s', a'; \theta^-)$$

式10.33为非终止情形，最后一式用于混合批次；目标在本次更新中固定。

10.4.2 深度Q网络DQN：式10.34与一步计算

梯度下降把预测推向目标

$$\theta \leftarrow \theta - \alpha \nabla_\theta (y - Q(s,a;\theta))^2 \tag{10.34}$$

$$Q = \theta = 1, \quad y = 2.15, \quad \mathcal{L} = 1.3225$$

$$\nabla_\theta \mathcal{L} = 2(\theta - y) = -2.3$$

$$\theta_{\text{new}} = 1 - 0.1(-2.3) = 1.23$$

教学假设：只有一个标量参数；一般神经网络按链式法则计算参数梯度。

10.4.2 深度Q网络DQN：回放与目标冻结

随机回放旧样本，目标网络分段冻结

经验池

e_1	e_2	e_3
S → A	A → B	B → G
e_4	e_5	e_6
S → G	A → B	S → A

已完成 8　　$k = 8$

均匀抽样序列

1　5　4　3　3　6　1　5

参数快照

主网 θ

S→A	A→B	B→G	S→G
1.503	3.241	4.360	1.200

目标冻结 θ^-

1.382	3.320	4.360	1.200

第3、6步后复制

第6步：y 不变

固定探针 S→A

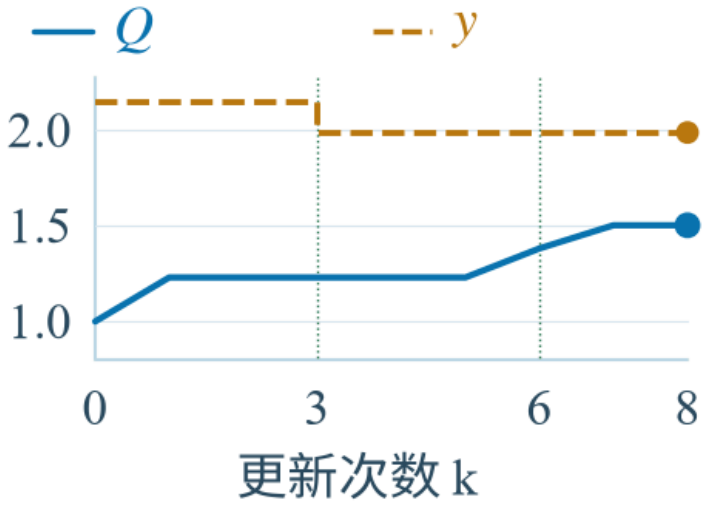

$Q = 1.503$　　$y = 1.988$

图：线性Q单样本算例（折扣0.9，学习率0.1）；目标网络每3步硬同步

初始Q按S绕行、A前进、B到G、S直接为1、3.5、4、1；G终止。

六条样本的奖励依次为−1、−1、5、2、−1、−1；蓝线仅跟踪S绕行。

10.4.2 深度Q网络DQN：完整算法流程

DQN训练与执行的数据流

初始化两网络
目标复制自主网络
→
探索采样入池
随机抽取批次
→
目标算y、主网更新
定期同步目标

阶段	需要的对象	动作如何选择
训练	主网络、目标网络、回放池、环境	主网络Q值＋探索策略
评估／执行	固定主网络、当前状态、控制接口	通常取最大Q值对应动作

目标网络按间隔硬复制；训练停止依据独立评估指标、预算与稳定性。

10.4.2 深度Q网络DQN：Double、Dueling与优先回放

DQN改进分别针对不同问题

改进	针对的问题	主要机制
Double DQN	最大值估计容易偏高	主网络选下一动作，目标网络评价该动作
Dueling DQN	状态好坏与动作差异纠缠	状态价值分支与动作优势分支合成Q值
优先经验回放	平均抽样可能低效	按绝对TD误差等确定优先级并修正偏差

优势表示某动作相对该状态通常水平的好坏；高TD误差也可能来自噪声。

本章目录

单智能体强化学习经典算法

第十章 集群协同与博弈对抗

10.1 集群协同基础与控制架构

10.2 一致性与编队控制

10.3 智能博弈与强化学习基础

10.4 单智能体强化学习经典算法

10.5 多智能体强化学习与规模扩展

10.6 集群关键技术与挑战

10.7 RflySim集群框架与接口

10.8 本章实验案例与综合验证

10.9 习题与课堂讨论

本节 4 个教学单元

10.4.1 Q-Learning
教材对应：第10.1.3.4节第1项

10.4.2 深度Q网络DQN
教材对应：第10.1.3.4节第2项

10.4.3 Actor-Critic与DDPG
教材对应：第10.1.3.4节第3–4项

10.4.4 改进算法与选型
教材对应：第10.1.3.4节第5项

10.4.3 Actor-Critic与DDPG：Actor-Critic框架

Actor选动作，Critic提供评价



经验用于训练Critic
评价信号指导Actor

- **Actor**：改变动作选择，使长期目标改善。
- **Critic**：用奖励和后续估计学习价值，提供策略优化的方向。

10.4.3 Actor-Critic与DDPG：A2C与A3C

优势函数衡量动作相对水平

$$A_\mu(s,a) = Q_\mu(s,a) - V_\mu(s)$$

策略等概率选直接或绕行：$V_\mu(S) = 0.5 \times 2 + 0.5 \times 2.15 = 2.075$

$$A_\mu(S,\text{via}) = 2.15 - 2.075 = 0.075$$

方法	采样与更新组织	共同内容
A2C	多个环境采样后同步更新	Actor依据优势改进策略
A3C	多个工作线程异步更新	Critic估计价值，减少梯度方差

10.4.3 Actor-Critic与DDPG：图10.7(a)总览

DDPG训练包含四个网络

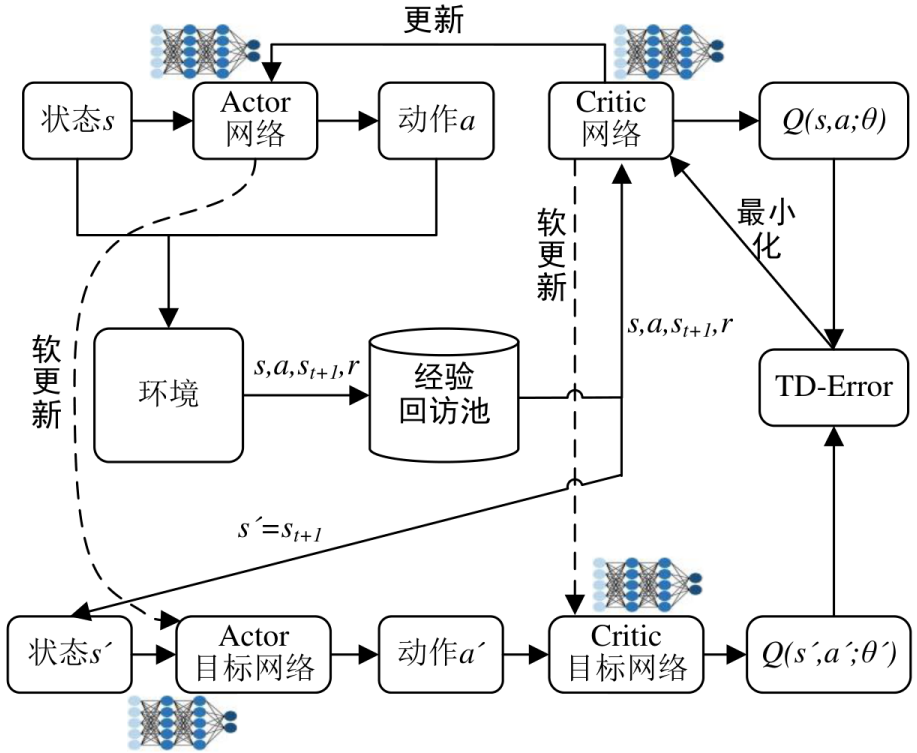

(a) DDPG训练框架

图10.7(a) DDPG训练框架

- **在线Actor：**从状态生成连续动作。
- **在线Critic：**估计当前状态动作价值。
- **两个目标网络：**共同构造学习目标。

在线Actor→目标Actor、在线Critic→目标Critic：分别按式10.37软更新。

10.4.3 Actor-Critic与DDPG：图10.7(a)在线分支

在线网络采样并学习动作价值



Actor更新时沿Critic对动作的梯度改进；Critic本身用经验的TD目标训练。

10.4.3 Actor-Critic与DDPG：图10.7(a)目标分支

目标Actor和目标Critic构造后续值

经验中的下一状态 → 目标Actor 生成下一动作 → 目标Critic 估计后续动作价值

$$s' \longrightarrow \mu'(s') \longrightarrow Q'(s', \mu'(s'))$$

- **输入关系：** 目标Critic同时接收下一状态和目标Actor生成的动作。
- **更新关系：** 两目标网络仅按式10.37由各自在线网络软更新，不互相梯度更新。

10.4.3 Actor-Critic与DDPG：式10.35

Actor最大化Critic给出的价值

$$J(\theta^{\mu}) = \mathbb{E}_{s\sim D}[Q(s,\mu(s;\theta^{\mu});\theta^{Q})] \tag{10.35}$$

$$\nabla_{\theta^{\mu}} J \approx \mathbb{E}[\nabla_a Q(s,a)|_{a=\mu(s)} \nabla_{\theta^{\mu}} \mu(s)]$$

- **更新方向：** Actor做梯度上升以增大Q；优化器可通过最小化负的平均Q实现。
- **固定对象：** 这一步固定Critic参数，但保留它对动作的梯度，才能传回Actor。

10.4.3 Actor-Critic与DDPG：式10.36

Critic拟合带目标动作的TD目标

$$\mathcal{L}(\theta^Q) = \mathbb{E}_{(s,a,r,s')\sim D}[(y - Q(s,a;\theta^Q))^2] \tag{10.36}$$

$$y = r + \gamma Q'(s', \mu'(s'))$$

$$y = r + \gamma(1-d)Q'(s', \mu'(s'))$$

第二行是教材非终止目标，第三行补入终止标志；目标Actor和Critic均不参与此步梯度更新。

10.4.3 Actor-Critic与DDPG：式10.37

软更新让目标网络缓慢跟随

$$\theta^{Q'} \leftarrow \tau\theta^{Q} + (1-\tau)\theta^{Q'} \tag{10.37}$$

$$\theta^{\mu'} \leftarrow \tau\theta^{\mu} + (1-\tau)\theta^{\mu'}$$

$$\theta_{\text{target,new}} = 0.01 \times 2 + 0.99 \times 1 = 1.01$$

软更新比例越小，目标跟随越慢；两个目标网络分别跟随自己的在线网络。

10.4.3 Actor-Critic与DDPG：式10.38

训练探索与执行动作不同

$$a_t = \mu(s_t; \theta^{\mu}) + \mathcal{N}_t \tag{10.38}$$

$$a_t = \mathrm{clip}(\mu(s_t) + \mathcal{N}_t, a_{\min}, a_{\max})$$

阶段	动作生成	用途
训练	策略输出＋噪声，再限幅	探索并生成覆盖更广的经验
固定策略评估	策略输出，再执行相同限幅	比较策略本身的任务表现

10.4.3 Actor-Critic与DDPG：标量Actor-Critic算例

连续动作的评价与改进可以手算

$$Q(a) = 4 - (a - 0.5)^2, \quad a \in [-1,1], \quad a_0 = 0$$

本例固定状态与Critic；Actor参数就是动作，学习率为0.1。

$$a_{k+1} = a_k + 0.1[-2(a_k - 0.5)] = 0.8a_k + 0.1$$

更新次数	动作	固定Critic给出的Q值
0	0	3.7500
1	0.1000	3.8400
5	0.3362	3.9732
10	0.4463	3.9971

10.4.3 Actor-Critic与DDPG：动作梯度

Actor沿着Critic曲线提高动作评价

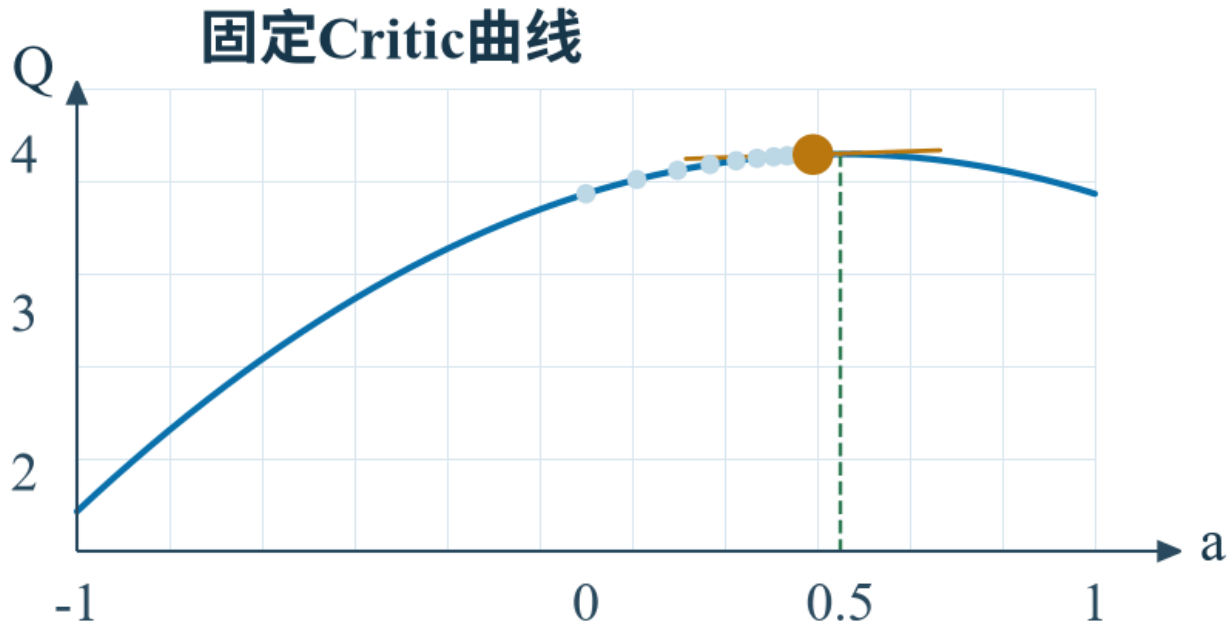

参数更新次数 10

Actor输出 0.4463

Q(a) = 3.9971

dQ/da = 0.1074

a* = 0.5

图：固定Critic的十次梯度上升；金色切线表示当前位置的斜率

靠近曲线峰值时斜率变小，动作更新也随之缩小；本例只更新Actor。

10.4.3 Actor-Critic与DDPG：采样、学习与评估

DDPG的完整训练循环

采样并入回放池
保存实际执行动作 → 目标网络算y
在线Critic更新 → Actor上升平均Q
两个目标软更新

循环环节	参数怎样变化	检查对象
Critic更新	只更新在线Critic	TD误差、终止mask、目标冻结
Actor更新	只更新在线Actor	动作梯度、限幅与Q估计偏差
独立评估	全部策略参数固定	回报、成功率与约束违反次数

本章目录

单智能体强化学习经典算法

第十章 集群协同与博弈对抗

10.1 集群协同基础与控制架构

10.2 一致性与编队控制

10.3 智能博弈与强化学习基础

10.4 单智能体强化学习经典算法

10.5 多智能体强化学习与规模扩展

10.6 集群关键技术与挑战

10.7 RflySim集群框架与接口

10.8 本章实验案例与综合验证

10.9 习题与课堂讨论

本节 4 个教学单元

10.4.1 Q-Learning
教材对应：第10.1.3.4节第1项

10.4.2 深度Q网络DQN
教材对应：第10.1.3.4节第2项

10.4.3 Actor-Critic与DDPG
教材对应：第10.1.3.4节第3–4项

10.4.4 改进算法与选型
教材对应：第10.1.3.4节第5项

10.4.4 改进算法与选型：双Critic与延迟更新

TD3针对价值高估与策略振荡

- **双Critic：**对同一目标动作估值并取较小值，减少过估计被Actor放大的机会。
- **延迟更新：**Critic更新多次后再更新Actor，使策略使用相对稳定的评价。
- **目标平滑：**目标动作加入限幅噪声，再对动作限幅，减弱尖锐虚高Q峰的影响。

策略会利用评价误差，改进评价也是改进决策。

10.4.4 改进算法与选型：随机策略与探索

SAC同时优化收益与策略熵

随机Actor
产生动作分布
→
环境奖励＋策略熵
兼顾收益与探索
→
Critic评价
更新策略和价值

- **熵：**衡量动作分布的随机程度；分布越集中，通常熵越低。
- **温度：**决定熵项权重，可按目标熵调整探索强度。
- **梯度：**将采样写成参数与随机噪声的可微组合，使策略参数可以得到梯度。

10.4.4 改进算法与选型：概率比剪裁

PPO用剪裁目标抑制过大更新

$$\rho_t = \frac{\pi_\theta(a_t \mid s_t)}{\pi_{\text{old}}(a_t \mid s_t)}$$

$$L^{\text{clip}} = \mathbb{E}[\min(\rho_t A_t, \text{clip}(\rho_t, 1-\epsilon, 1+\epsilon)A_t)]$$

- **方向：**最大化剪裁目标；ρ_t为新旧动作概率（密度）比。
- **参数：**A_t为旧策略优势估计，ϵ为剪裁宽度。
- **流程：**采样后以GAE（广义优势估计）加权多步TD信息，折中偏差与方差；同批有限次更新再采样。

$$A_t = 1, \quad \epsilon = 0.2, \quad \rho_t = 1.5: \quad \min(1.5,1.2) = 1.2$$

该正优势样本的目标项在概率比超过1.2后不再增加。

10.4.4 改进算法与选型：PPO单样本目标

正负优势的剪裁平台位于不同一侧

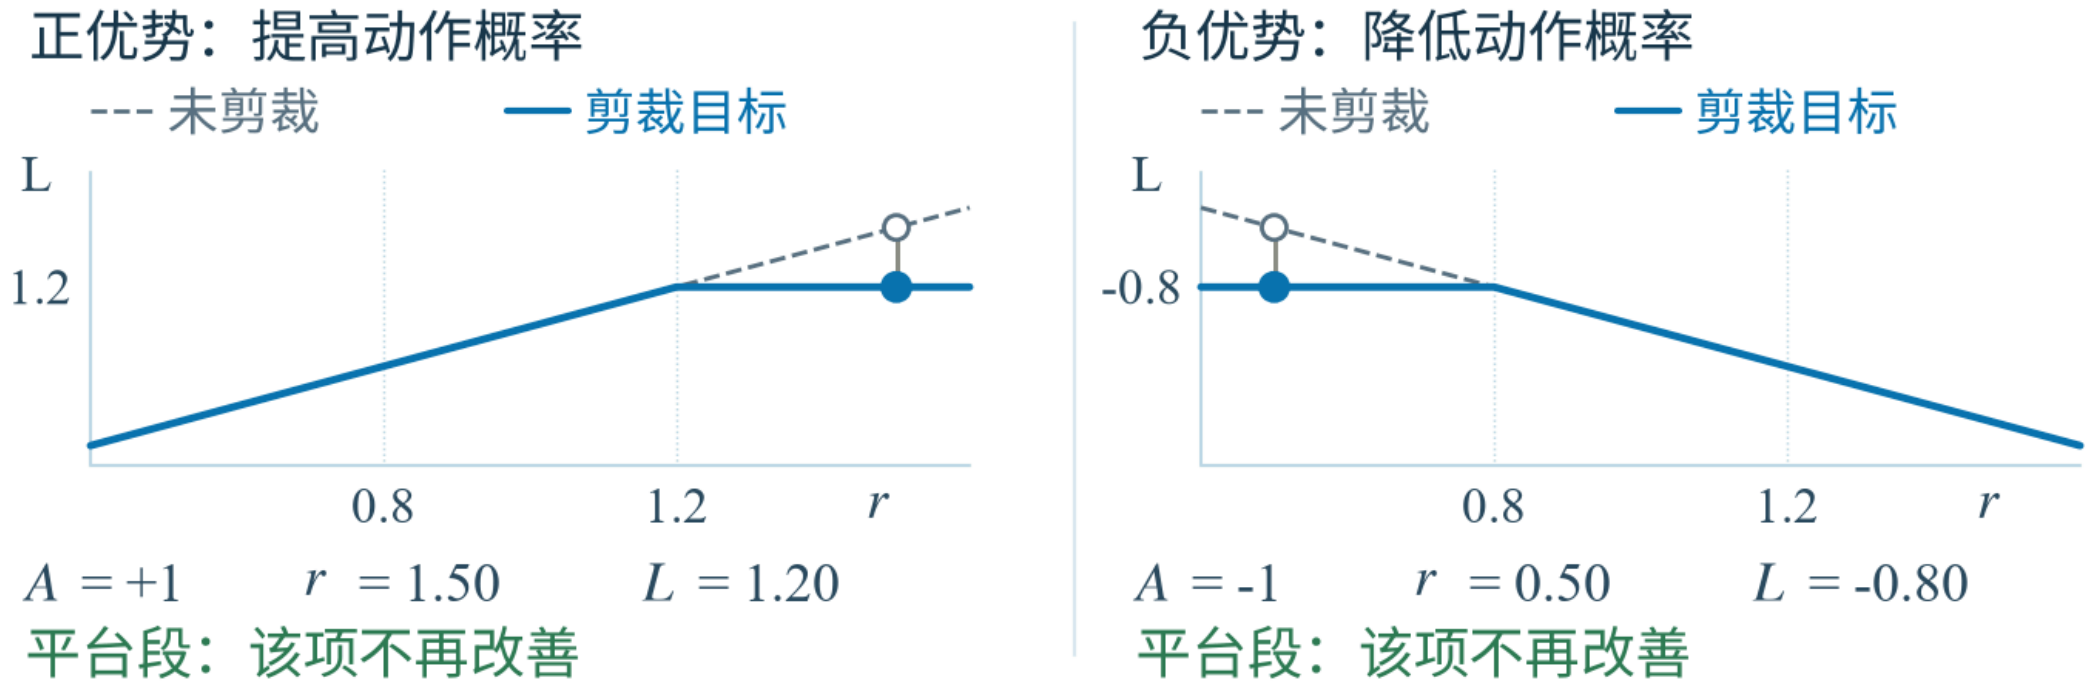

图：r为前页概率比，剪裁宽度0.2；实心点为取较小值后的目标

正优势在右侧变平，负优势在左侧变平；实际概率比不被硬限幅。

10.4.4 改进算法与选型：TD-MPC与TD-MPC2

TD-MPC在学习模型中规划短期轨迹

状态编码
进入潜在空间 → 模型滚动预测
比较动作序列 → 奖励＋终端价值
选择并执行第一步

- **TD-MPC：**学习任务相关的动态模型、奖励与终端价值，在潜在空间做滚动规划。
- **TD-MPC2：**引入可扩展世界模型、多任务嵌入、Q值集成和价值尺度处理。
- **计算取舍：**执行时需要模型内规划；模型误差与规划时延会直接影响决策。

10.4.4 改进算法与选型：算法对照

按动作空间、数据与执行预算选型

方法	常见动作空间	数据与执行特点
Q表／DQN	有限离散动作	异策略；执行时比较各动作Q值
DDPG／TD3	连续动作	异策略回放；确定性Actor前向计算
SAC	常见为连续动作	异策略回放；随机策略与熵目标
PPO	离散或连续动作	近期策略数据；一批数据有限次更新
TD-MPC(2)	连续动作	学习潜在模型；执行时还要滚动规划

10.4.4 改进算法与选型：材料与任务边界

RflySim的单机PPO资料对应什么

资料目录（完整版及以上，按发布包核对）
10.RflySimSwarm/3.CustExps/e0.CustApiExps/3.MARLExps

文件	读取时关注什么
Readme.pdf	Genesis＋RflySim四旋翼加速度悬停控制的任务与依赖
train/env_acc.py	观测、动作、奖励与终止如何定义
train/train_acc.py	PPO训练配置与并行采样
sil/rfAcc.py	固定策略如何转换为SITL控制输入

并行单机环境为PPO提供经验；多智能体协作需要多个智能体在同一任务中交互。

10.4.4 改进算法与选型：继续学习

算法原理与实现阅读入口

DDPG目标、终止处理与完整伪代码
https://spinningup.openai.com/en/latest/algorithms/ddpg.html

PPO剪裁目标与策略更新机制
https://spinningup.openai.com/en/latest/algorithms/ppo.html

TD-MPC2论文、世界模型与实现入口
https://www.tdmpc2.com/

练习与讨论

课堂练习：目标值与网络职责

- **问题1：**终止奖励5，旧Q为2，学习率0.5。下一状态网络输出100，新Q是多少?
- **问题2：**在线参数2，目标参数1，软更新比例0.1。更新后的目标参数是多少?
- **问题3：**DDPG固定策略执行时，是否必须运行Critic、目标网络和回放池?
- **问题4：**同一PPO策略在100个独立单机环境采样，是否就是100智能体协同?

参考要点

参考要点：终止后没有未来回报

$$y = 5, \qquad Q_{\text{new}} = 2 + 0.5(5 - 2) = 3.5$$

$$\theta'_{\text{new}} = 0.1 \times 2 + 0.9 \times 1 = 1.1$$

- **问题3参考：** 固定Actor、观测预处理、动作限幅和接口参与执行；Critic等通常只供训练。
- **问题4参考：** 这是并行单机采样；多智能体在共同环境中形成相互影响的决策。

本节小结

价值学习与连续动作优化

- **Q-Learning与DQN：**按样本修正动作价值；网络近似使样本互相影响，需管理数据与目标。
- **Actor-Critic与DDPG：**策略生成动作，Critic评价；连续动作可沿价值梯度优化。
- **算法选择：**比较动作空间、经验利用、探索方式与执行计算预算，再设计评估。
- **易错点：**终止目标无后续项；目标网络不随损失反传；评估参数与探索规则固定。