



# 高级机器学习

## 强化学习

(reinforcement learning)



# 大纲

---

□ 强化学习简介

□ 多臂老虎机

□ 有模型学习

□ 无模型学习

□ 模仿学习

□ 深度强化学习

---

# 强化学习

**nature**  
THE INTERNATIONAL WEEKLY JOURNAL OF SCIENCE

**LEARNING CURVE**

INNOVATIONS IN  
The microverse

Self-taught AI software attains human-level performance in video games  
PAGES 486 & 529

**EPIDEMIOLOGY**  
**SHARE DATA IN OUTBREAKS**  
Forge open access to sequences and more  
PAGE 477

**COSMOLOGY**  
**A GIANT IN THE EARLY UNIVERSE**  
A supermassive black hole at a redshift of 6.3  
PAGES 488 & 512

**QUANTUM PHYSICS**  
**TELEPORTATION FOR TWO**  
Transferring two properties of a single photon  
PAGES 491 & 516

NATURE.COM/NATURE  
26 February 2015  
Vol. 518, No. 7542

**nature**  
THE INTERNATIONAL WEEKLY JOURNAL OF SCIENCE

At last — a computer program that can beat a champion Go player **PAGE 484**

**ALL SYSTEMS GO**

**CONSERVATION**  
**SONGBIRDS À LA CARTE**  
Illegal harvest of millions of Mediterranean birds  
PAGE 452

**RESEARCH ETHICS**  
**SAFEGUARD TRANSPARENCY**  
Don't let openness backfire on individuals  
PAGE 459

**POPULAR SCIENCE**  
**WHEN GENES GOT 'SELFISH'**  
Dawkins's calling card 40 years on  
PAGE 462

NATUREASIA.COM  
28 January 2016  
Vol. 529, No. 7587



# 例子：瓜农种西瓜

---

种下瓜苗后：（仅考虑浇水和不浇水两个动作，不考虑施肥、除草等）



- 多步决策过程
- 过程中包含状态、动作、反馈（奖赏）等
- 需多次种瓜，在过程中不断摸索，才能总结出较好的种瓜策略

抽象该过程：序贯决策任务 (Sequential Decision Making)

---

# 两种人工智能任务类型

---

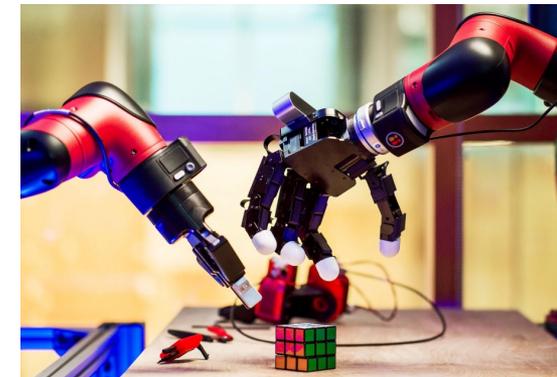
## □ 预测型任务

- 根据数据特征预测对应标注（有监督学习）
- 根据输入数据输出所需新的数据（无监督学习）



## □ 决策型任务

- 在动态环境中采取行动（强化学习）
  - 转变到新的状态
  - 获得即时奖励
  - 随着时间的推移最大化累计奖励
  - Learning from interaction in a trial-and-error manner



# 决策和预测的不同

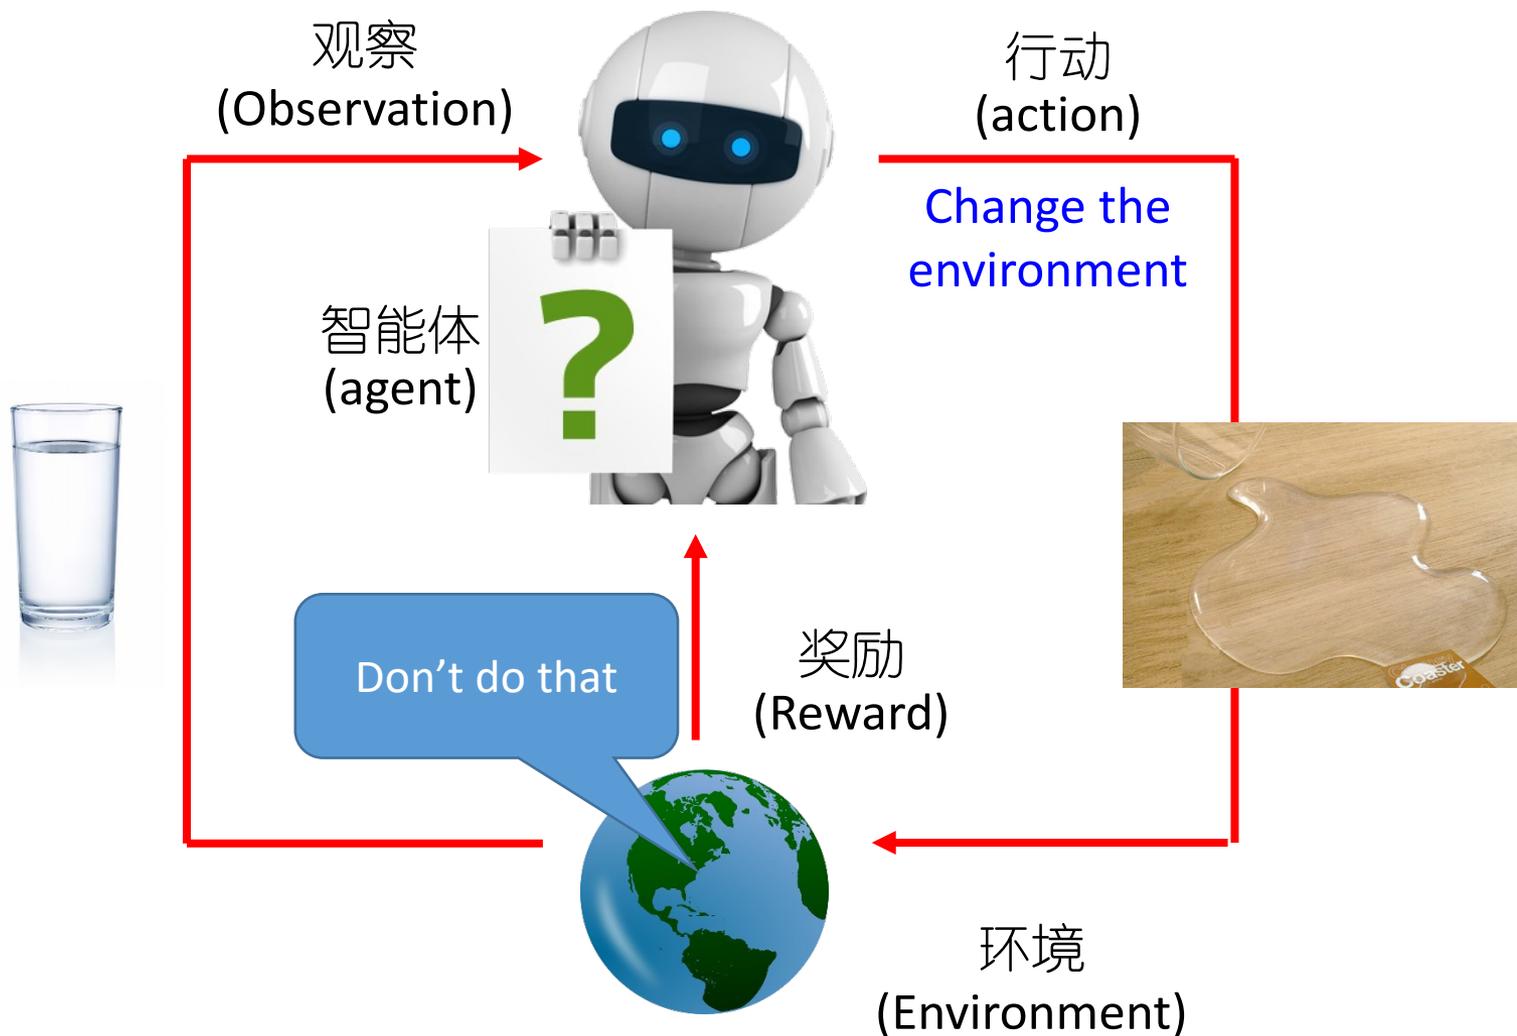
---

- 预测仅产生信号，不考虑环境的改变
  - 预测的信号是否用、怎么用，不需要考虑
- 决策下达到环境中，直接改变环境
  - 未来发展随之改变
  - “做决策，担责任”
- 序贯决策
  - 决策者序贯地做出一个个决策，并接续看到新的观测，直到最终任务结束

绝大多数序贯决策问题，可以用强化学习来解

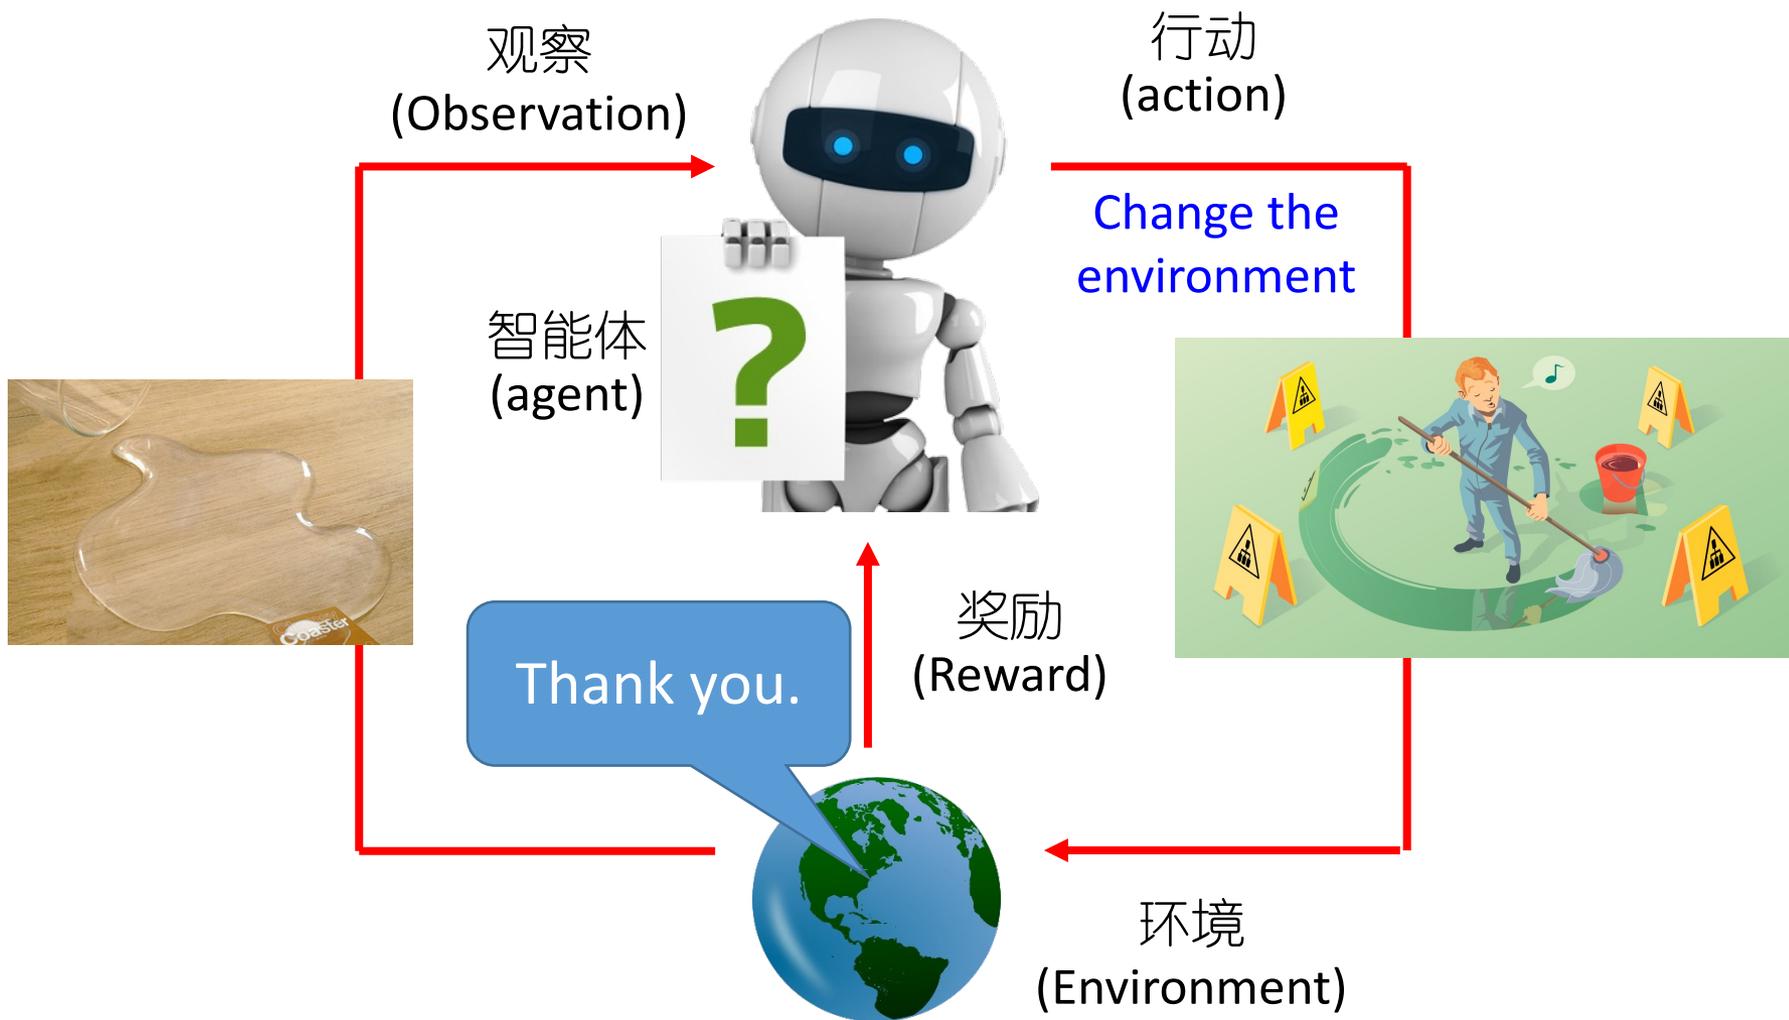
---

# 强化学习



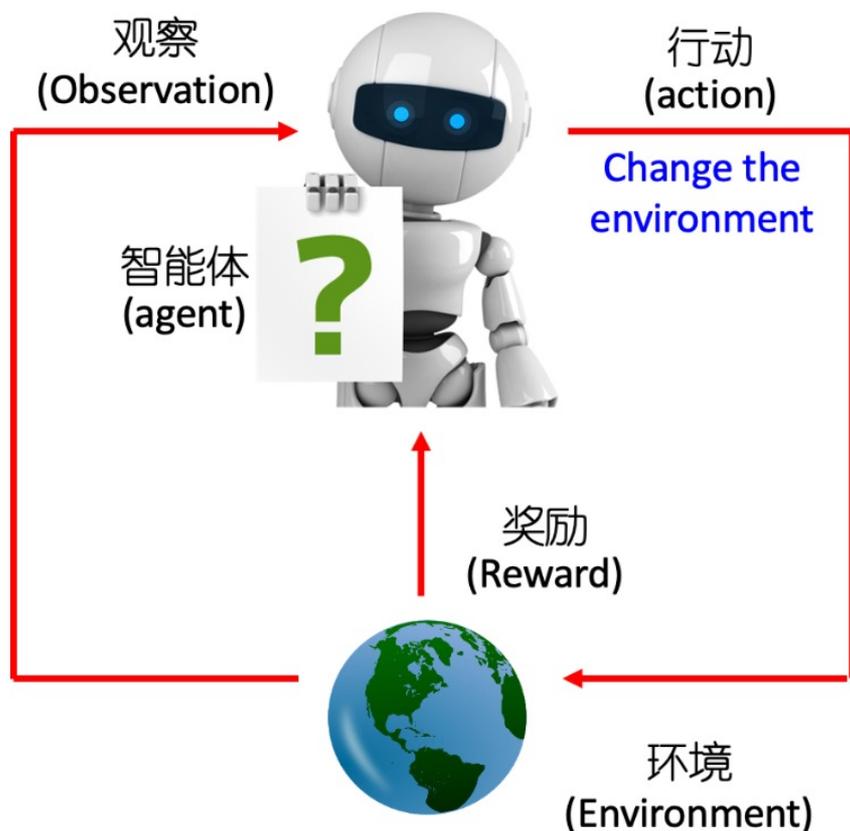
# 强化学习

智能体从交互中学习得到最大化累计奖励的行动



# 强化学习的定义

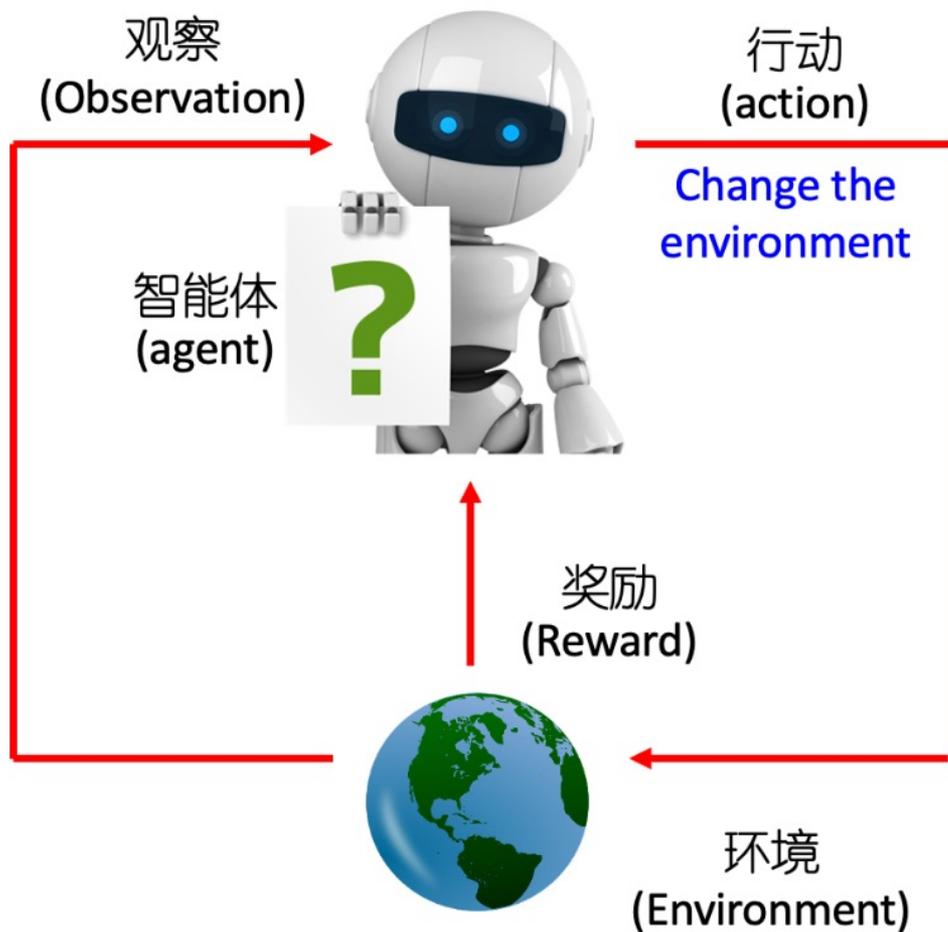
通过与环境不断交互来实现目标的计算方法



• 三个方面:

- **感知**: 在某种程度上感知环境的状态
- **行动**: 可以采取行动来影响状态或者达到目标
- **目标**: 随着时间推移最大化累积奖励

# 强化学习的交互过程



□ 在每一步  $t$ , 智能体:

- 获得观察  $O_t$
- 获得奖励  $R_t$
- 执行行动  $A_t$

□ 环境:

- 获得行动  $A_t$
- 给出观察  $O_{t+1}$
- 给出奖励  $R_{t+1}$

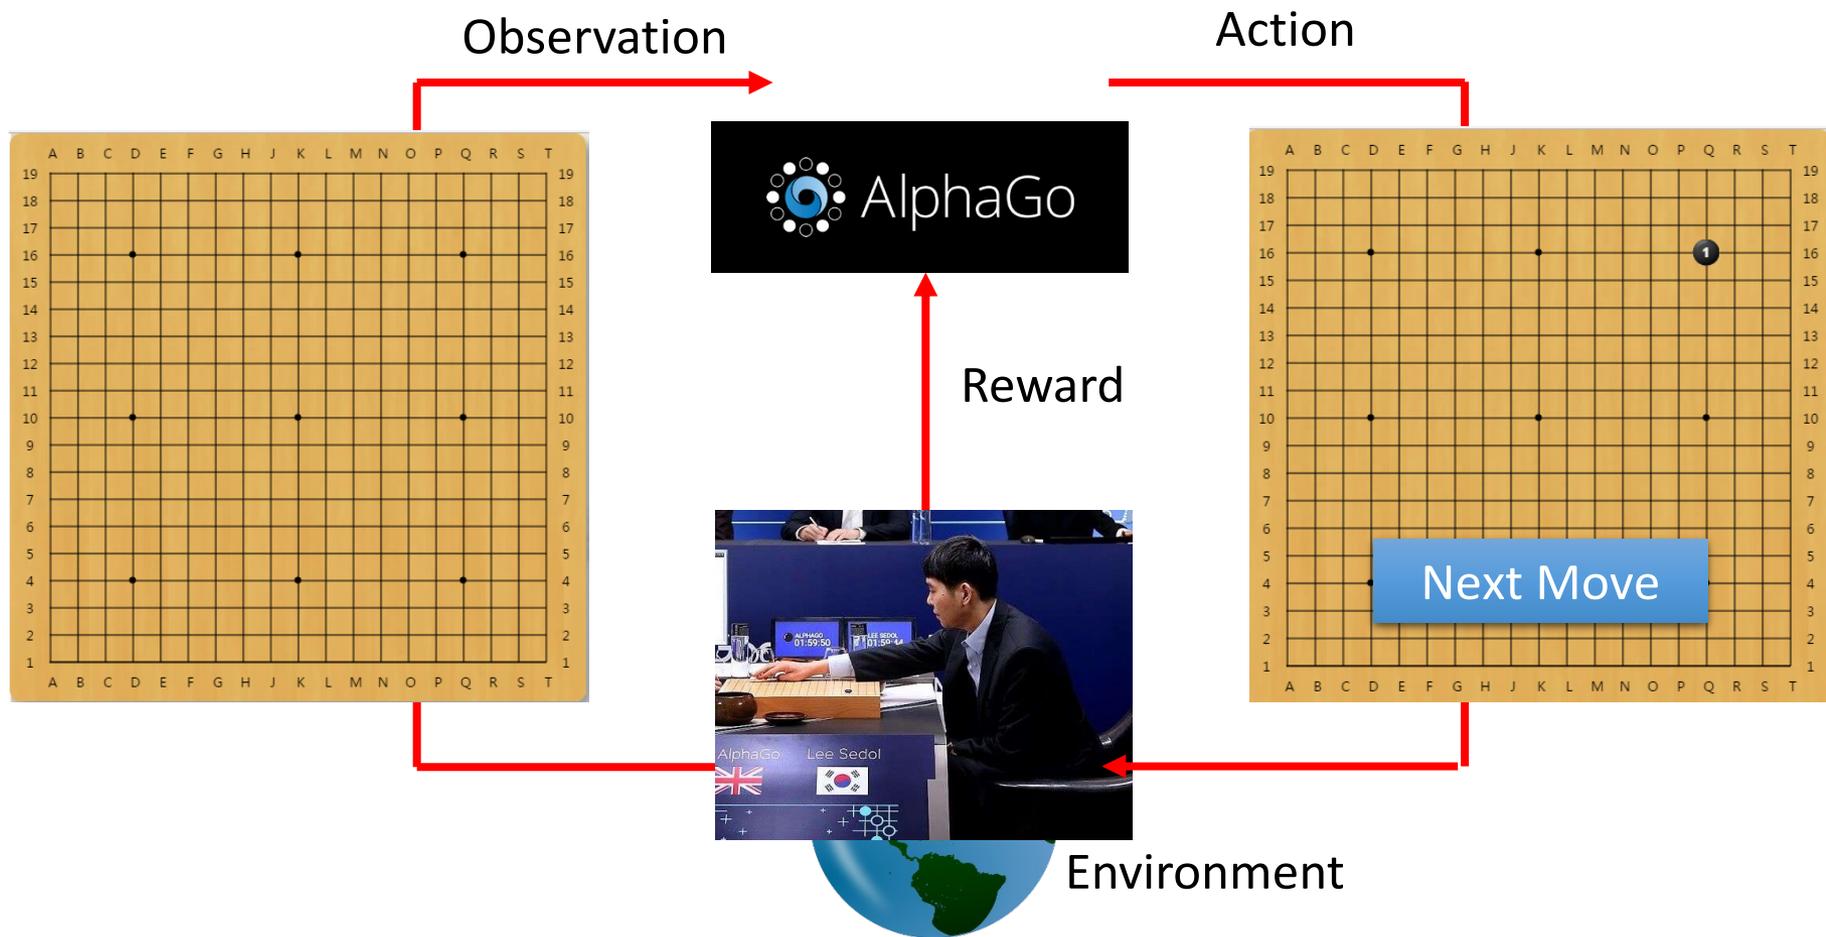
□  $t$  在环境这一步增加

# 强化学习的关键要素

---

- 智能体所处的环境 $E$ 
    - 例如，种西瓜任务中，环境是西瓜生长的自然世界
  - 状态的集合 $X$ ： $x \in X$ 是智能体感知到的环境的描述
    - *西瓜长势的描述*
  - 智能体所能采取的动作集合 $A$ 
    - *浇水、施肥等*
  - 策略(policy)  $\pi: X \rightarrow A$  (或 $\pi: X \times A \rightarrow \mathbb{R}$ )
    - *例如，瓜苗状态是缺水时，返回动作浇水*
  - 状态转移概率 $P: X \times A \times X \rightarrow \mathbb{R}$ 
    - 瓜苗当前状态缺水，选择动作浇水，有一定概率恢复健康，也有一定概率无法恢复
  - 奖励函数： $R: X \times A \times X \mapsto \mathbb{R}$  (或 $R: X \times X \rightarrow \mathbb{R}$ )
    - 瓜苗健康对应奖赏+1，瓜苗凋零对应奖赏-10
-

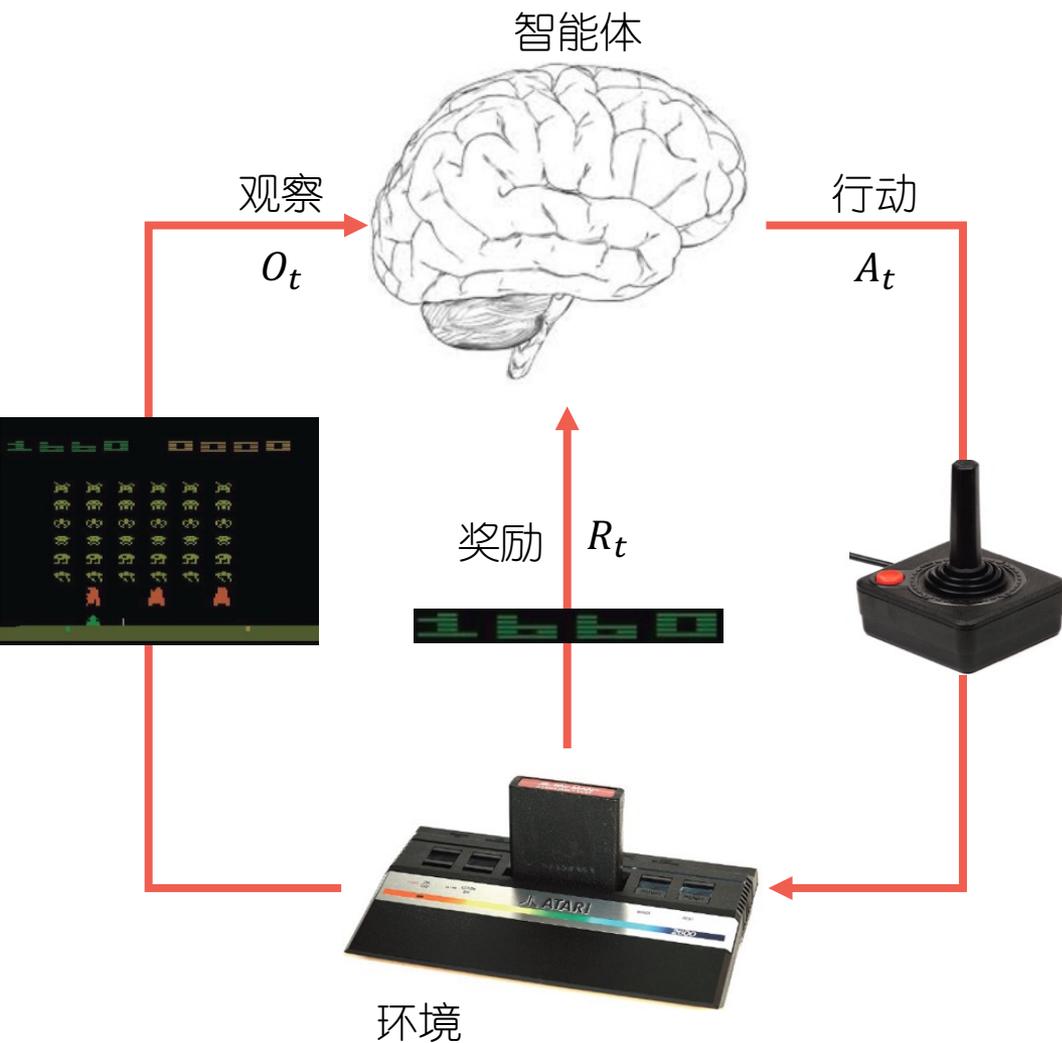
# 强化学习-围棋



# 强化学习-围棋



# 强化学习-游戏

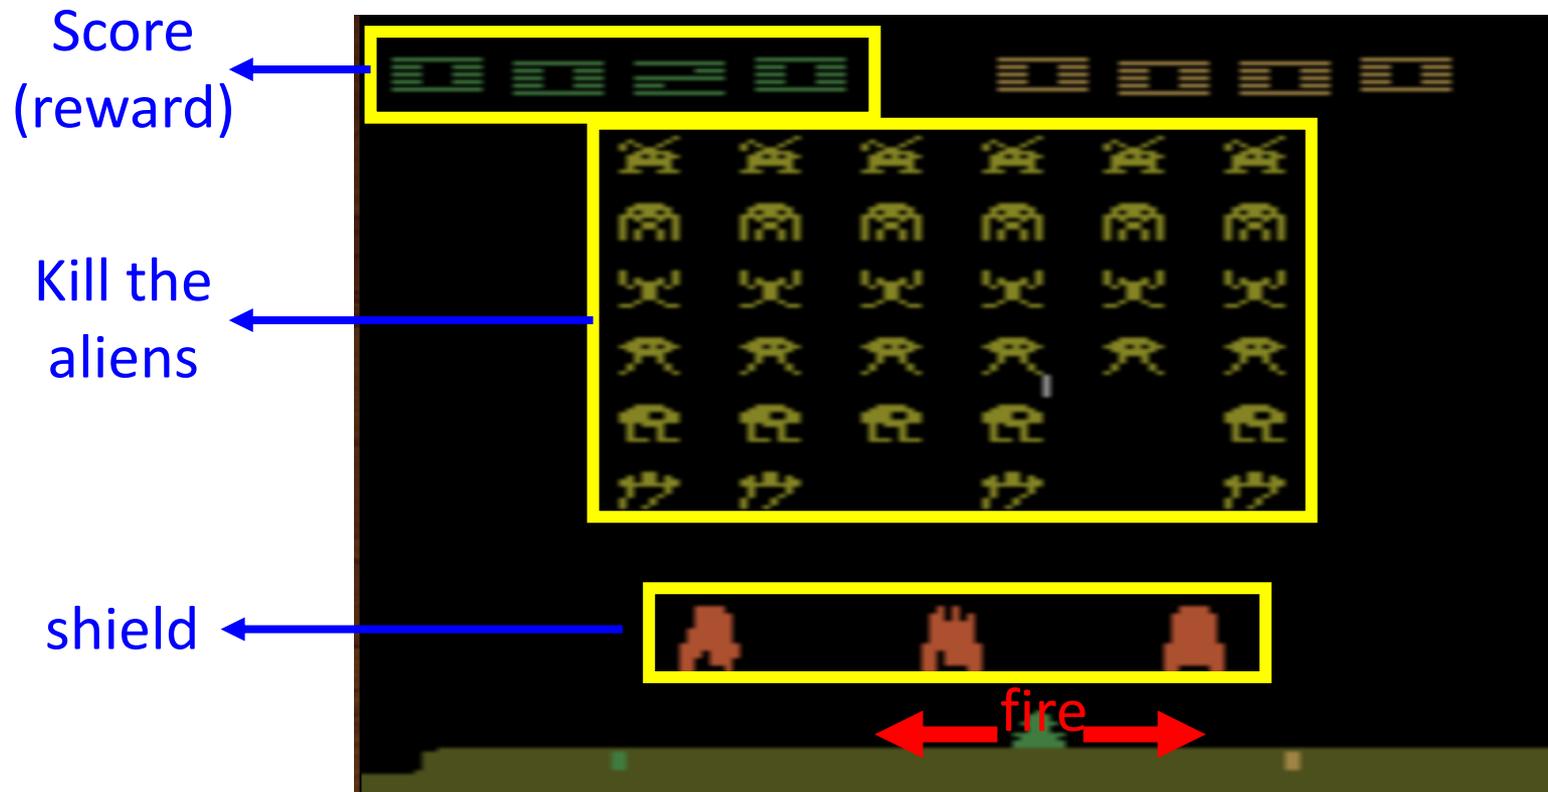


- 游戏规则未知
- 从交互游戏中进行学习
- 在操纵杆上选择行动并查看分数和像素画面

# 强化学习-游戏

- Space invader

Termination: all the aliens are killed, or your spaceship is destroyed.



# 强化学习-游戏

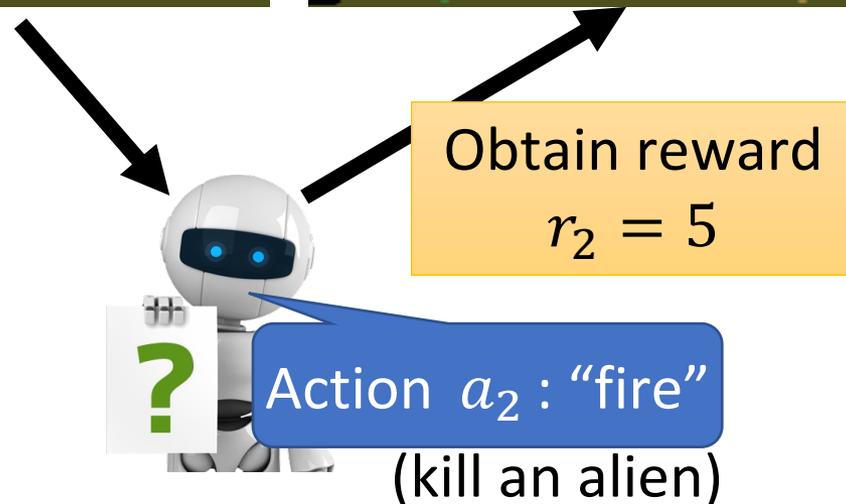
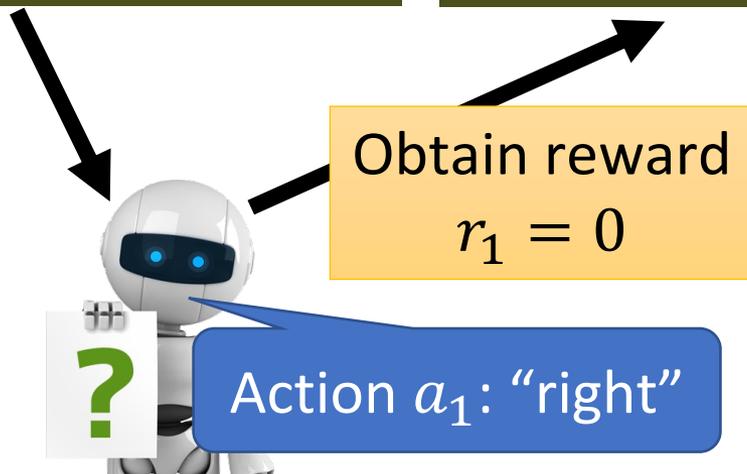
Start with  
observation  $s_1$



Observation  $s_2$



Observation  $s_3$



# 强化学习-游戏

Start with  
observation  $s_1$



Observation  $s_2$



Observation  $s_3$



After many turns



Action  $a_T$



Obtain reward  $r_T$

This is an *episode*.

agent学习每个episode  
最大化奖励的行动

# 强化学习的特点

- 监督学习：给定有标记样本

Learning from teacher



Next move:  
“5-5”



Next move:  
“3-3”

- 强化学习：没有有标记样本，通过执行动作之后反馈的奖赏来学习

Learning from experience

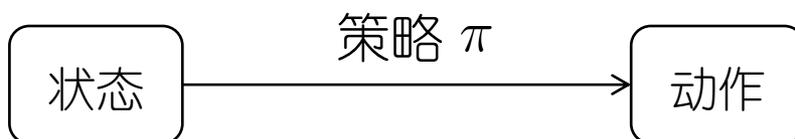
First move → ..... many moves ..... → Win!  
(Two agents play with each other.)

# 强化学习的特点

---



- 强化学习：没有有标记样本，通过执行动作之后反馈的奖赏来学习



强化学习在某种意义上可以认为是具有“延迟标记信息”的监督学习

---

# 强化学习的特点

---

有监督、无监督学习

Model ←



Fixed Data

强化学习

Agent ↔



Dynamic Environment

Agent不同，交互出的数据也不同！

---

# 强化学习应用案例：无人驾驶小车

---



In this experiment, we are going to demonstrate a reinforcement learning algorithm learning to drive a car.

# 更多应用

---

- Flying Helicopter

- <https://www.youtube.com/watch?v=0JL04JJjocc>

- Driving

- <https://www.youtube.com/watch?v=0xo1Ldx3L5Q>

- Robot

- <https://www.youtube.com/watch?v=370cT-OAzzM>

- Text generation

- <https://www.youtube.com/watch?v=pbQ4qe8EwLo>
-

# 扩展阅读

---

- Sutton's book:
    - <http://incompleteideas.net/sutton/book/the-book.html>
  - David Silver's Lecture:
    - <https://www.davidsilver.uk/teaching/>
  - 动手学强化学习:
    - <https://hrl.boyuai.com/chapter/intro>
  - OpenAI GYM:
    - <https://github.com/openai/gym>
    - <https://openai.com/blog/universe/>
-

# 大纲

---

□ 强化学习简介

□ 多臂老虎机

□ 有模型学习

□ 无模型学习

□ 模仿学习

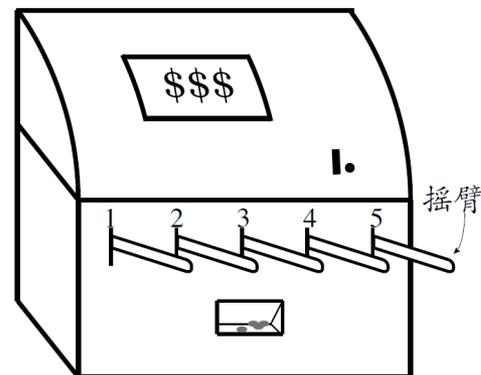
□ 深度强化学习

---

# K-摇臂赌博机

---

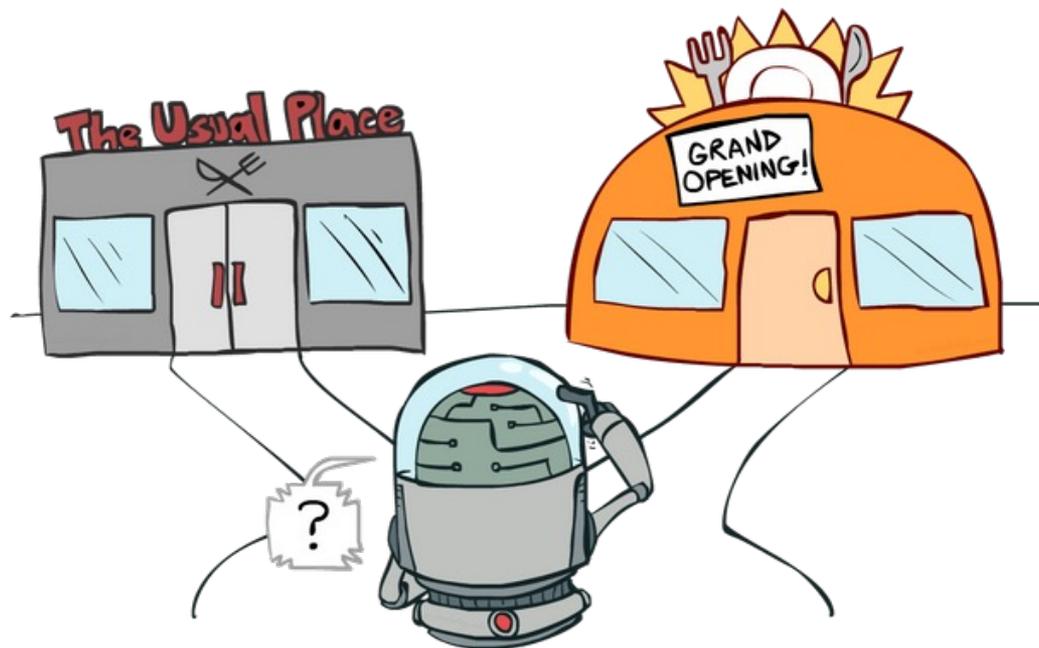
- K-摇臂赌博机 (K-Armed Bandit)
  - 只有一个状态,  $K$ 个动作
  - 每个摇臂的奖赏服从某个期望未知的分布
  - 执行有限次动作
  - 最大化累积奖赏
  
- 强化学习面临的主要困难: 探索-利用窘境 (Exploration-Exploitation dilemma)
  - 探索(Exploration): 估计不同摇臂的优劣 (奖赏期望的大小)
  - 利用(Exploitation): 选择当前最优的摇臂



# 探索-利用窘境

---

- 基于目前策略获取已知最优收益还是尝试不同的决策
  - **Exploitation**: 执行能够获得已知最优收益的决策
  - **Exploration**: 尝试更多可能的决策, 不一定会是最优收益



# 策略探索的一些原则

---

- 朴素方法 (Naïve Exploration)
    - 添加策略噪声  $\epsilon$ -greedy
  - 积极初始化 (Optimistic Initialization)
  - 基于不确定性的度量 (Uncertainty Measurement)
    - 尝试具有不确定收益的策略, 可能带来更高的收益
  - 概率匹配 (Probability Matching)
    - 基于概率选择最佳策略
-

# 策略探索的一些原则

---

- $\epsilon$ -贪心
  - 以 $\epsilon$ 的概率探索：均匀随机选择一个摇臂
  - 以 $1 - \epsilon$ 的概率利用：选择当前平均奖赏最高的摇臂
- **Softmax**：基于当前已知的摇臂平均奖赏来对探索与利用折中
  - 若某个摇臂当前的平均奖赏越大，则它被选择的概率越高
  - 概率分配使用**Boltzmann**分布：

$$P(k) = \frac{e^{\frac{Q(k)}{\tau}}}{\sum_{i=1}^K e^{\frac{Q(i)}{\tau}}}$$

- 两种算法都有一个折中参数 $(\epsilon, \tau)$ ，算法性能孰好孰坏取决于具体应用问题
-

# 大纲

---

□ 强化学习简介

□ 多臂老虎机

□ 有模型学习

□ 无模型学习

□ 模仿学习

□ 深度强化学习

---

# 马尔可夫决策过程

---

□ 马尔可夫过程 (Markov Process) 是具有马尔可夫性质的随机过程

□ 状态 $S_t$ 是马尔可夫的, 当且仅当

$$\mathbb{P}[S_{t+1}|S_t] = \mathbb{P}[S_{t+1}|S_1, \dots, S_t]$$

□ 马尔可夫决策过程 (Markov Decision Process, MDP)

- 提供了一套为在结果部分随机、部分在决策者的控制下的决策过程建模的数学框架

$$\mathbb{P}[S_{t+1}|S_t] = \mathbb{P}[S_{t+1}|S_1, \dots, S_t]$$

$$\mathbb{P}[S_{t+1}|S_t, A_t]$$

---

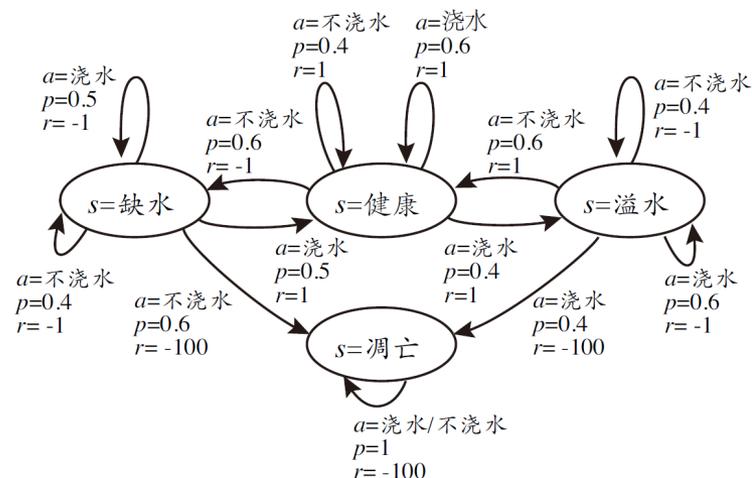
# 强化学习对应了马尔可夫四元组

□ 强化学习对应了四元组：(S, A, P, R)

□ 强化学习的目标

机器通过在环境中不断尝试从而学到一个策略 $\pi$ ,

使得长期执行该策略后得到的累积奖赏最大



$$T\text{步累积奖赏: } \mathbb{E} \left[ \frac{1}{T} \sum_{t=1}^T r_t \right]$$

$$\gamma\text{折扣累积奖赏: } \mathbb{E} \left[ \sum_{t=0}^{+\infty} \gamma^t r_t \right]$$

# 有模型学习

---

- MDP的动态性如下所示：

- 从状态 $x_0$ 开始，智能体选择某个动作 $a_0 \in A$ ，智能体得到奖励 $R(x_0, a_0)$
- MDP随机转移到下一个状态 $s_1 \sim P_{s_0 a_0}$
- 这个过程不断进行

$$x_0 \xrightarrow{a_0, R(x_0, a_0)} x_1 \xrightarrow{a_1, R(x_1, a_1)} x_2 \xrightarrow{a_2, R(x_2, a_2)} x_3 \dots$$

- 智能体的总回报为

$$R(x_0, a_0) + \gamma R(x_1, a_1) + \gamma^2 R(x_2, a_2) + \dots$$

- 有模型学习(model-based learning)：

- 假设 $S, A, P, R$ 均已知
  - 方便起见，假设状态空间和动作空间均为有限的
-

# 有模型学习

---

- 目标：选择能够最大化累积奖励期望的动作

$$\mathbb{E}[R(s_0) + \gamma R(s_1) + \gamma^2 R(s_2) + \dots]$$

- $\gamma \in [0,1]$ 是未来奖励的折扣因子，使得和未来奖励相比起来智能体更重视即时奖励
  - 以金融为例，今天的\$1比明天的\$1更有价值

- 给定一个特定的策略  $\pi(s): S \rightarrow A$ ，即在状态  $s$  下采取动作  $a = \pi(s)$

- 给策略 $\pi$ 定义价值函数：状态值函数和状态动作值函数

$$V^\pi(s) = \mathbb{E}[R(s_0) + \gamma R(s_1) + \gamma^2 R(s_2) + \dots | s_0 = s]$$

$$Q(s, a) = \mathbb{E}[R(s_0) + \gamma R(s_1) + \gamma^2 R(s_2) + \dots | s_0 = s, a_0 = a]$$

---

# 策略评估

---

## □ 价值函数

$$V^\pi(s) = \mathbb{E}[R(s_0) + \underbrace{\gamma R(s_1) + \gamma^2 R(s_2) + \dots}_{\gamma V^\pi(s_1)} \mid s_0 = s, \pi]$$

$$= R(s) + \gamma \sum_{s' \in \mathcal{S}} P_{s\pi(s)}(s') V^\pi(s')$$

↑  
立即奖励

↑  
状态转移

↑  
时间折扣

↑  
下一个状态的价值

Bellman等式

# 策略改进

---

- 最优策略对应的值函数称为**最优值函数**

$$V^*(s) = \max_{\pi} V^{\pi}(s)$$

- 最优价值函数的Bellman等式

$$V^*(s) = R(s) + \max_{a \in A} \gamma \sum_{s' \in S} P_{sa}(s') V^*(s')$$

- 最优策略

最优Bellman等式

$$\pi^*(s) = \arg \max_{a \in A} \sum_{s' \in S} P_{sa}(s') V^*(s')$$

- 非最优策略的改进方式：**将策略选择的动作改为当前最优的动作**
-

# 价值迭代和策略迭代

---

- 价值函数和策略相关

$$V^\pi(s) = R(s) + \gamma \sum_{s' \in \mathcal{S}} P_{s\pi(s)}(s') V^\pi(s')$$

$$\pi(s) = \arg \max_{a \in A} \sum_{s' \in \mathcal{S}} P_{sa}(s') V^\pi(s')$$

- 可以对最优价值函数和最优策略执行迭代更新
    - 价值迭代
    - 策略迭代
-

# 价值迭代

---

- 对于一个动作空间和状态空间有限的MDP

$$|S| < \infty, |A| < \infty$$

- 价值迭代过程
  1. 对每个状态 $s$ , 初始化  $V(s)=0$
  2. 重复以下过程直到收敛 {  
对每个状态, 更新

$$V(s) = R(s) + \max_{a \in A} \gamma \sum_{s' \in S} P_{sa}(s') V(s')$$

}

---

# 策略迭代

---

- 对于一个动作空间和状态空间有限的MDP

$$|S| < \infty, |A| < \infty$$

- 策略迭代过程
  1. 随机初始化策略  $\pi$
  2. 重复以下过程直到收敛 {
    - a) 让  $V := V^\pi$
    - b) 对每个状态, 更新

$$\pi(s) = \arg \max_{a \in A} \sum_{s' \in S} P_{sa}(s') V(s')$$

}

---

# 有模型学习

---

## □ 有模型学习小结

- 强化学习任务可归结为基于动态规划的寻优问题
- 与监督学习不同，这里并未涉及到泛化能力，而是为每一个状态找到最好的动作

## □ 问题：如果模型未知呢？

- 从“经验”中学习一个MDP模型
  - 不学习MDP，从经验中直接学习价值函数和策略：
    - 模型无关的强化学习（Model-free Reinforcement Learning）
-

# 大纲

---

□ 强化学习简介

□ 多臂老虎机

□ 有模型学习

□ 免模型学习

□ 模仿学习

□ 深度强化学习

---

# 免模型强化学习(Model-free RL)

---

- 在现实问题中，通常没有明确地给出状态转移和奖励函数
  - 例如，我们仅能观察到部分片段 (episodes)

$$\text{Episode 1: } s_0^{(1)} \xrightarrow[R(s_0)^{(1)}]{a_0^{(1)}} s_1^{(1)} \xrightarrow[R(s_1)^{(1)}]{a_1^{(1)}} s_2^{(1)} \xrightarrow[R(s_2)^{(1)}]{a_2^{(1)}} s_3^{(1)} \dots s_T^{(1)}$$

$$\text{Episode 2: } s_0^{(2)} \xrightarrow[R(s_0)^{(2)}]{a_0^{(2)}} s_1^{(2)} \xrightarrow[R(s_1)^{(2)}]{a_1^{(2)}} s_2^{(2)} \xrightarrow[R(s_2)^{(2)}]{a_2^{(2)}} s_3^{(2)} \dots s_T^{(2)}$$

- 模型无关的强化学习直接从经验中学习值 (value) 和策略 (policy)，而无需构建马尔可夫决策过程模型 (MDP)
  - 关键步骤： (1) 估计值函数； (2) 优化策略
-

# 免模型强化学习(Model-free RL)

---

- 在有模型的强化学习中，值函数能够通过动态规划计算获得

$$\begin{aligned} V^\pi(s) &= \mathbb{E}[R(s_0) + \gamma R(s_1) + \gamma^2 R(s_2) + \dots | s_0 = s, \pi] \\ &= R(s) + \gamma \sum_{s' \in \mathcal{S}} P_{s\pi(s)}(s') V^\pi(s') \end{aligned}$$

- 在免模型的强化学习中：
  - 我们无法直接获得  $P_{sa}$  和  $R$
  - 但是，我们拥有一系列采样轨迹

Episode 1:  $s_0^{(1)} \xrightarrow[R(s_0)^{(1)}]{a_0^{(1)}} s_1^{(1)} \xrightarrow[R(s_1)^{(1)}]{a_1^{(1)}} s_2^{(1)} \xrightarrow[R(s_2)^{(1)}]{a_2^{(1)}} s_3^{(1)} \dots s_T^{(1)}$

Episode 2:  $s_0^{(2)} \xrightarrow[R(s_0)^{(2)}]{a_0^{(2)}} s_1^{(2)} \xrightarrow[R(s_1)^{(2)}]{a_1^{(2)}} s_2^{(2)} \xrightarrow[R(s_2)^{(2)}]{a_2^{(2)}} s_3^{(2)} \dots s_T^{(2)}$

---

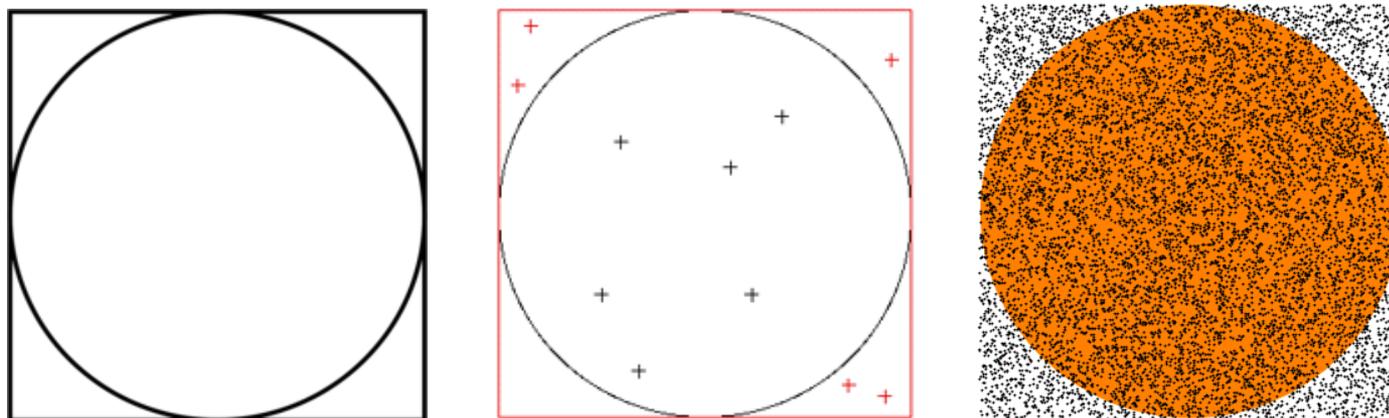
# 蒙特卡洛方法

---

□ 蒙特卡洛方法 (Monte-Carlo methods) 是一类广泛的计算算法。

- 依赖于重复随机抽样来获得数值结果

□ 例如，计算圆的面积

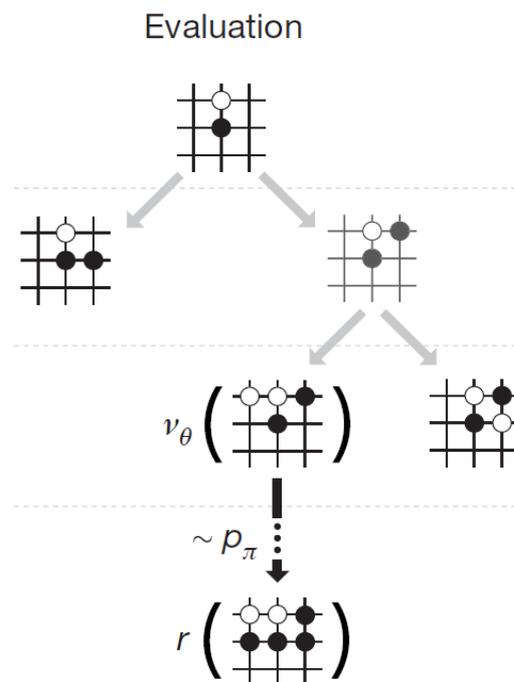
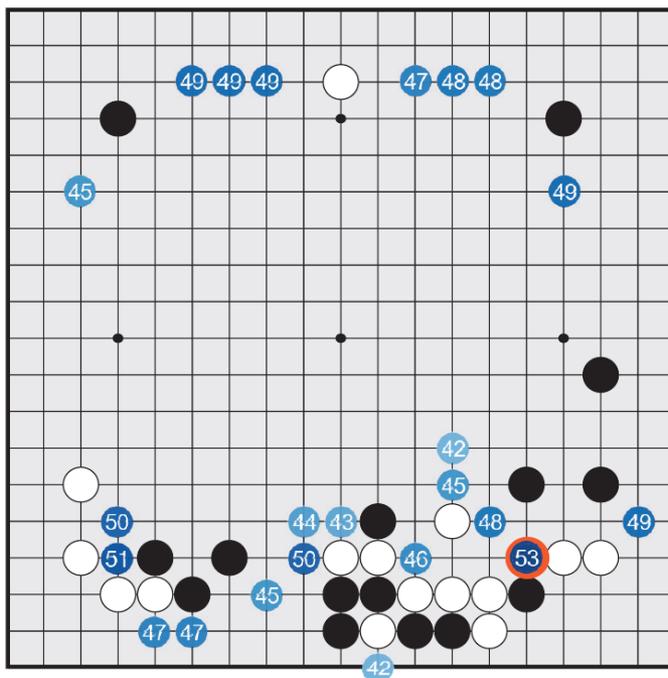


$$\text{Circle Surface} = \text{Square Surface} \times \frac{\text{\#points in circle}}{\text{\#points in total}}$$

---

# 蒙特卡洛方法

- 围棋对弈：估计当前状态下的胜率



$$\text{Win Rate}(s) = \frac{\text{\#win simulation cases started from } s}{\text{\#simulation cases started from } s \text{ in total}}$$

# 蒙特卡洛价值估计方法

- 目标：从策略 $\pi$ 下的经验片段学习  $V^\pi$

$$s_0^{(i)} \xrightarrow[R_1^{(i)}]{a_0^{(i)}} s_1^{(i)} \xrightarrow[R_2^{(i)}]{a_1^{(i)}} s_2^{(i)} \xrightarrow[R_3^{(i)}]{a_2^{(i)}} s_3^{(i)} \dots s_T^{(i)} \sim \pi$$

- 累计奖励是总折扣奖励

$$G_t = R_{t+1} + \gamma R_{t+2} + \dots \gamma^{T-1} R_T$$

- 值函数是期望累计奖励

$$\begin{aligned} V^\pi(s) &= \mathbb{E}[R(s_0) + \gamma R(s_1) + \gamma^2 R(s_2) + \dots | s_0 = s, \pi] \\ &= \mathbb{E}[G_t | s_t = s, \pi] \\ &\simeq \frac{1}{N} \sum_{i=1}^N G_t^{(i)} \end{aligned}$$

- 使用策略 $\pi$ 从状态 $s$ 采样 $N$ 个片段
- 计算平均累计奖励

- 蒙特卡洛策略评估使用经验均值累计奖励而不是期望累计奖励

# 蒙特卡洛价值估计方法

---

- 实现：使用策略 $\pi$ 采样片段

$$s_0^{(i)} \xrightarrow[R_1^{(i)}]{a_0^{(i)}} s_1^{(i)} \xrightarrow[R_2^{(i)}]{a_1^{(i)}} s_2^{(i)} \xrightarrow[R_3^{(i)}]{a_2^{(i)}} s_3^{(i)} \dots s_T^{(i)} \sim \pi$$

- 在一个片段中的每个时间步长 $t$ 的状态都被访问
  - 增量计数器  $N(s) \leftarrow N(s) + 1$
  - 增量总累计奖励  $S(s) \leftarrow S(s) + G_t$
  - 价值被估计为累计奖励的均值  $V(s) = S(s)/N(s)$
  - 由大数定率有

$$V(s) \rightarrow V^\pi(s) \text{ as } N(s) \rightarrow \infty$$

---

# 时序差分学习

---

- 蒙特卡罗强化学习的缺点：低效
    - 求平均时以“批处理式”进行
    - 在一个完整的采样轨迹完成后才对状态-动作值函数进行更新
  
  - 克服缺点的办法：
    - 时序差分 (temporal difference, TD) 学习
-

# 增量蒙特卡洛更新

---

- 每个片段结束后逐步更新 $V(s)$
- 对于每个状态 $S_t$  和对应累计奖励 $G_t$

$$N(S_t) \leftarrow N(S_t) + 1$$
$$V(S_t) \leftarrow V(S_t) + \frac{1}{N(S_t)} (G_t - V(S_t))$$

- 对于非稳定的问题（即，环境会随时间发生变化），我们可以跟踪一个现阶段的平均值（即，不考虑过久之前的片段）

$$V(S_t) \leftarrow V(S_t) + \alpha (G_t - V(S_t))$$

---

# 时序差分学习

---

$$G_t = R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \dots = R_{t+1} + \gamma V(S_{t+1})$$

$$V(S_t) \leftarrow V(S_t) + \alpha (R_{t+1} + \gamma V(S_{t+1}) - V(S_t))$$

↑                    ↑  
观测值            对未来的猜测

- 时序差分方法直接从经验片段中进行学习
- 时序差分更新当前预测值使之接近估计累计奖励（非真实值）：

$$R_{t+1} + \gamma V(S_{t+1})$$

---

# 时序差分学习

---

- 从知道什么是好的：估计  $V^\pi(S_t)$

$$V(S_t) \leftarrow V(S_t) + \alpha(G_t - V(S_t))$$

$$V(S_t) \leftarrow V(S_t) + \alpha(R_{t+1} + \gamma V(S_{t+1}) - V(S_t))$$

- 基于  $V$  函数，如何做好行动？

$$\pi(s) = \arg \max_{a \in A} \sum_{s' \in S} P_{sa}(s') V(s')$$

↑  
需要知道环境模型

- 基于  $Q$  函数如何选择好的行动？

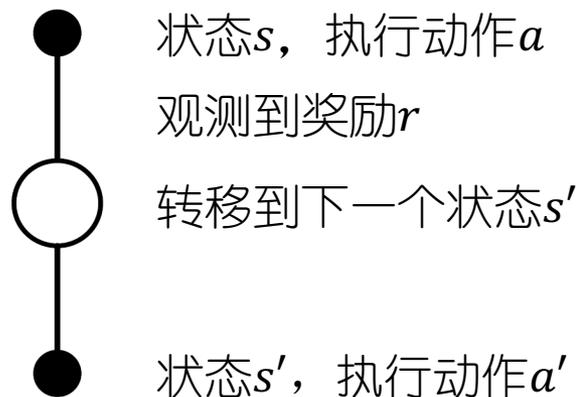
$$\pi(s) = \arg \max_{a \in A} Q(s, a)$$

---

# SARSA

---

- 对于当前策略执行的每个（状态-动作-奖励-状态-动作）元组



- SARSA更新状态-动作值函数为

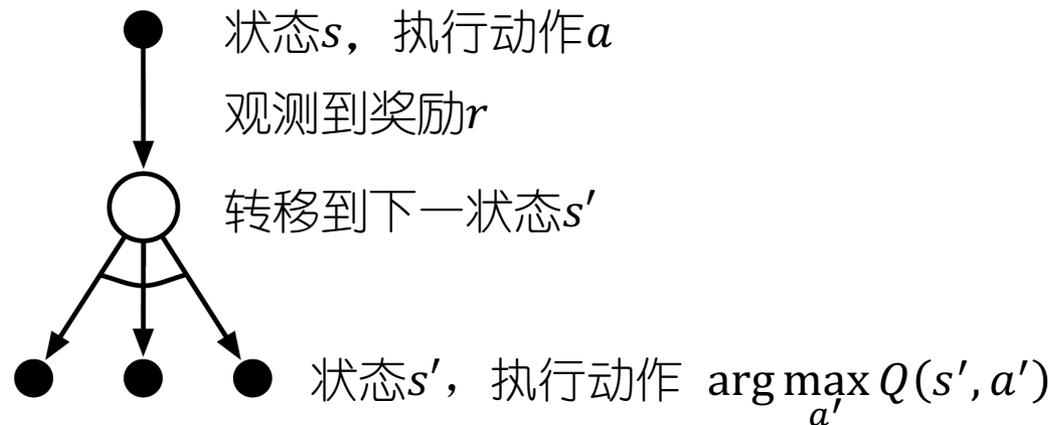
$$Q(s, a) \leftarrow Q(s, a) + \alpha(r + \gamma Q(s', a') - Q(s, a))$$

---

# Q-Learning

---

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha(r_{t+1} + \gamma \max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t))$$



# 大纲

---

□ 强化学习简介

□ 多臂老虎机

□ 有模型学习

□ 无模型学习

□ 模仿学习

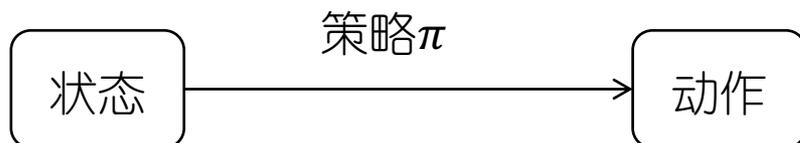
□ 深度强化学习

---

# 模仿学习(Imitation Learning)

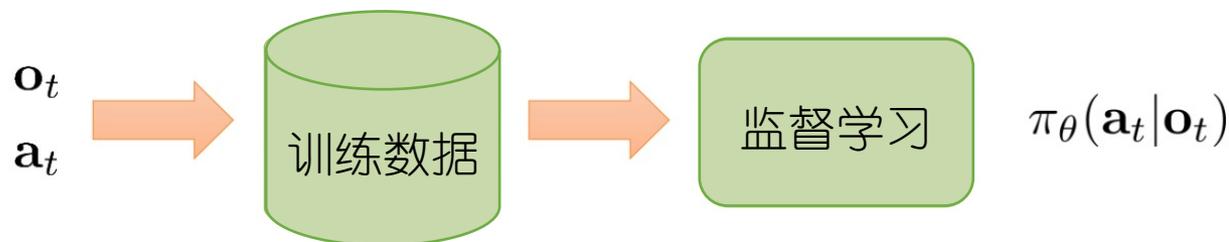
---

- 模仿学习：直接模仿人类专家的状态-动作对来学习策略
  - 相当于告诉机器在什么状态下应该选择什么动作
  - 引入了监督信息来学习策略



# 模仿学习(Imitation Learning)

- 直接模仿学习
  - 利用专家的决策轨迹，构造训练数据：状态作为特征，动作作为标记
  - 利用数据集，使用分类/回归算法即可学得策略
  - 将学得策略作为初始策略
  - 策略改进，从而获得更好的策略



# 模仿学习(Imitation Learning)

---

- 强化学习任务中，设计合理的符合应用场景的奖赏函数往往相当困难
  - 缓解方法：从人类专家提供的范例数据中反推出奖赏函数
  - 逆强化学习 (inverse reinforcement learning)
    - 基本思想：寻找某种奖赏函数使得范例数据是最优的，然后即可使用这个奖赏函数来训练策略
-

# 大纲

---

□ 强化学习简介

□ 多臂老虎机

□ 有模型学习

□ 无模型学习

□ 模仿学习

□ 深度强化学习

---

# 深度强化学习

---

AI = Deep Learning + Reinforcement Learning

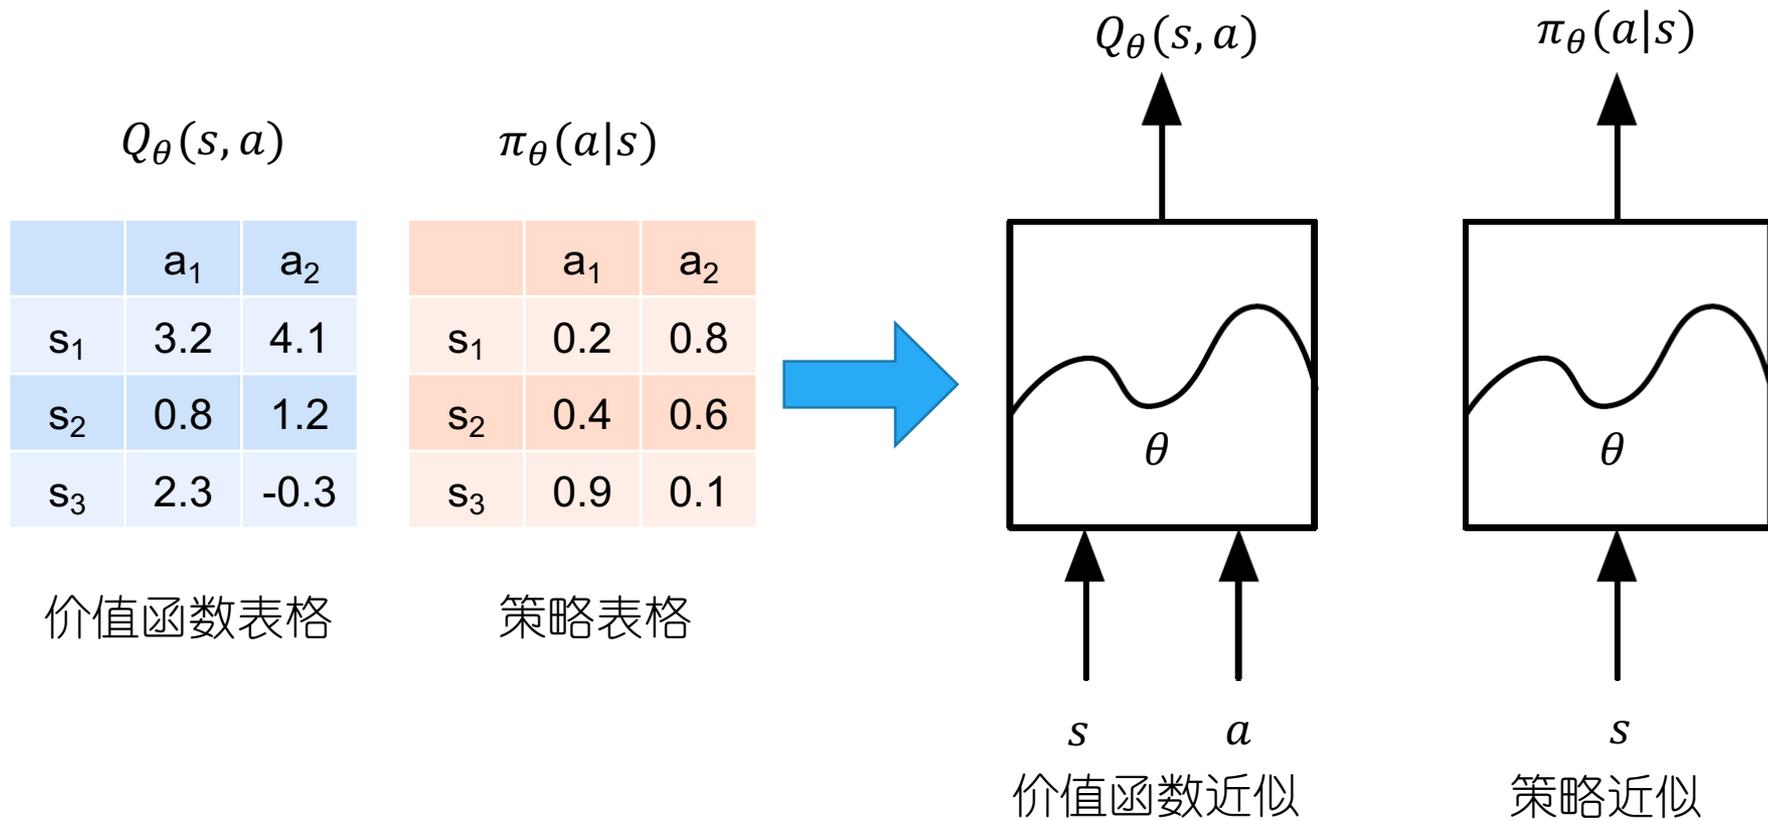


Deep Reinforcement Learning

---



# 深度强化学习



- 假如我们直接使用深度神经网络建立这些近似函数呢？
- 深度强化学习！

# 深度强化学习

---

- 2012年AlexNet在ImageNet比赛中大幅度领先对手获得冠军
- 2013年12月，第一篇深度强化学习论文出自NIPS 2013 Reinforcement Learning Workshop

---

## Playing Atari with Deep Reinforcement Learning

---

**Volodymyr Mnih   Koray Kavukcuoglu   David Silver   Alex Graves   Ioannis Antonoglou**

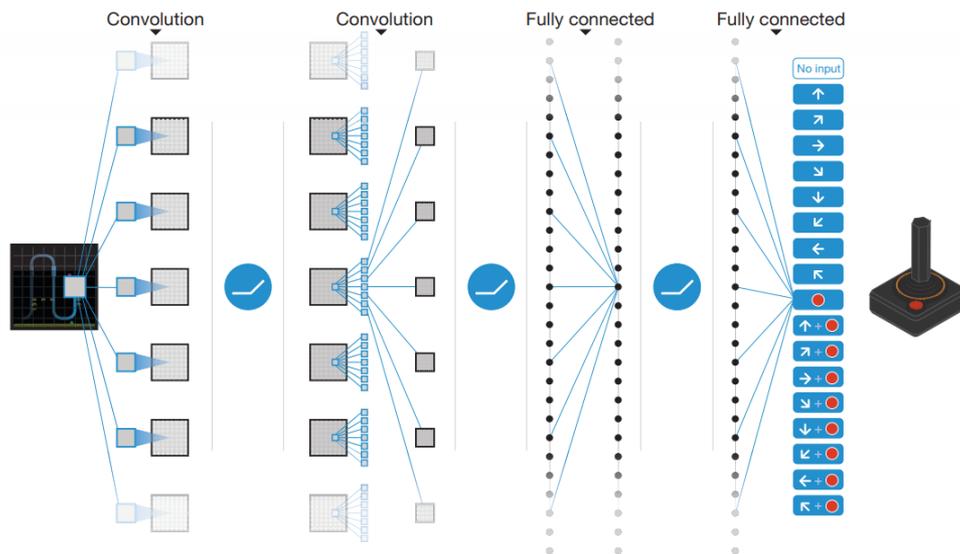
**Daan Wierstra   Martin Riedmiller**

DeepMind Technologies

{vlad,koray,david,alex.graves,ioannis,daan,martin.riedmiller} @ deepmind.com

---

# 深度强化学习

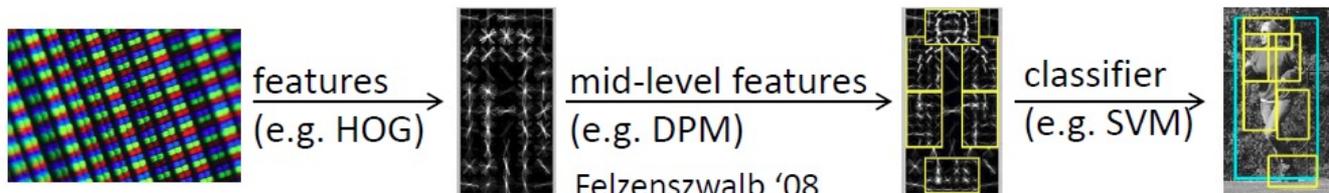


$$\nabla_{\theta_i} L_i(\theta_i) = \mathbb{E}_{s, a \sim \rho(\cdot); s' \sim \mathcal{E}} \left[ \left( r + \gamma \max_{a'} Q(s', a'; \theta_{i-1}) - Q(s, a; \theta_i) \right) \nabla_{\theta_i} Q(s, a; \theta_i) \right]$$

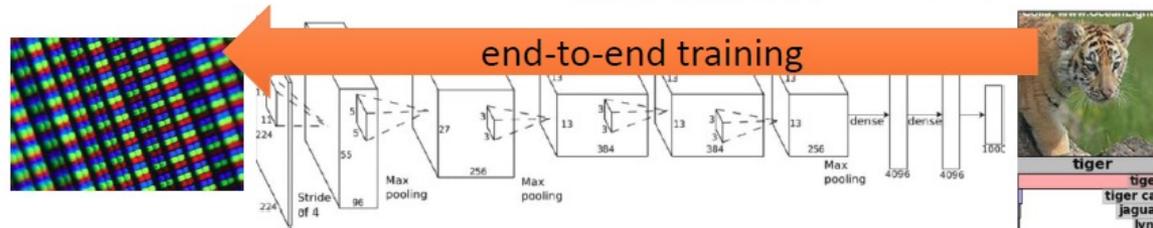
Q函数的参数通过神经网络反向传播学习

# 深度强化学习

标准 (传统)  
计算机视觉



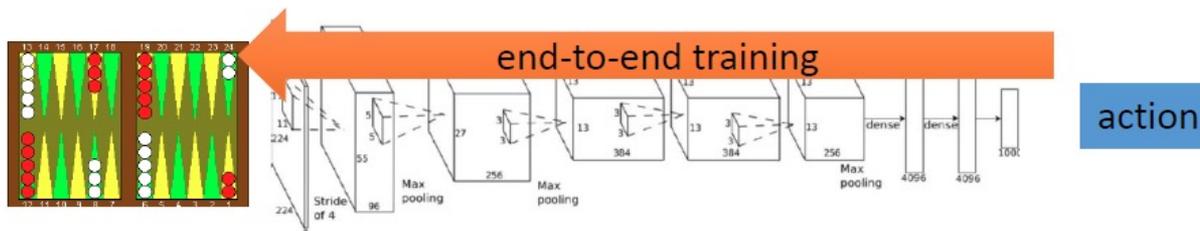
深度学习



标准 (传统)  
强化学习



深度强化学习



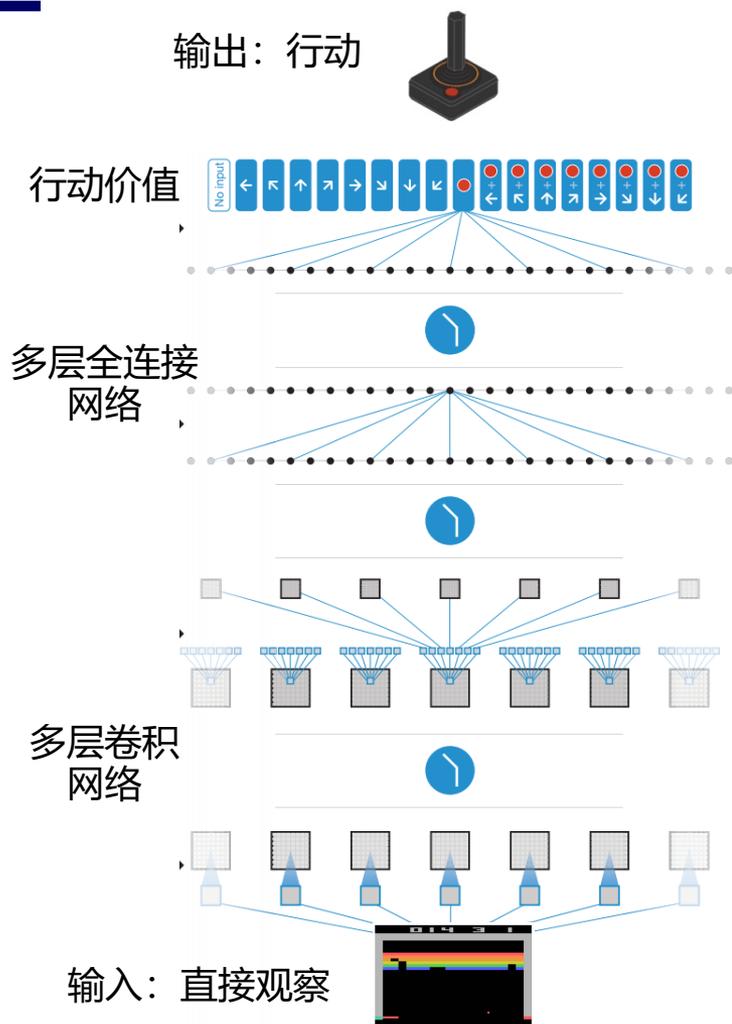
# 深度强化学习的趋势



Google搜索中词条“深度强化学习（deep reinforcement learning）”的趋势

# 深度强化学习

- 将深度学习（DL）和强化学习（RL）结合在一起会发生什么？
  - 价值函数和策略变成了深度神经网络
  - 相当高维的参数空间
  - 难以稳定地训练
  - 容易过拟合
  - 需要大量的数据
  - 需要高性能计算
  - CPU（用于收集经验数据）和GPU（用于训练神经网络）之间的平衡
  - ...
- 这些新的问题促进着深度强化学习算法的创新



# 深度强化学习的研究前沿



## 基于模拟模型的强化学习

- 模拟器的无比重要性



## 目标策动的层次化强化学习

- 长程任务的中间目标是桥梁的基石



## 模仿学习

- 无奖励信号下跟随专家做策略学习



## 多智能体强化学习

- 分散式、去中心化的人工智能

# 深度强化学习的落地场景

---

- 无人驾驶
- 游戏AI
- 交通灯调度
- 网约车派单
- 组合优化
- 推荐搜索系统
- 数据中心节能优化
- 对话系统
- 机器人控制
- 路由选路
- 工业互联网场景
- ...



# 小结

---

- 强化学习：序列决策任务，两个特点：延迟反馈、agent的动作会影响环境
  - 有模型学习：MDP模型已知
  - 无模型学习：利用采样去评估价值函数和价值动作函数，了解SARSA和Q-Learning的基本思想
  - 模仿学习：模仿人类专家的“状态-动作对”，或者基于人类专家数据反推奖赏函数
  - 深度强化学习：利用神经网络建模值函数
-