

陈平决策过程 (Champion Decision Process) 与赢化学习 (Winning Learning)

引言

赢理论及其变体的生成, 使得Vietnamese的麻指数日益增大, Vietnam稳中向好。这得益于[@知本](#) et al. 对于赢函数的定义¹, 以及[@Deserter](#) et al.²在比较赢理论上的创新。此外, [@loy](#) et al.³将赢学引入量子论的成功也让学者们看到了赢学的潜质。

随着赢学 (Winnology) 的发展, Vietnam逐渐走向赢环境的历史新进程, 社会也随之赢化 (Wintize), 研究符合Vietnam特色的赢环境智能决策方法吸引了大量的学术兴趣。在本工作中, 我们首先定义了赢环境的特性, 称为陈平决策过程 (Champion Decision Process)。随后为赢环境提出了赢化学习, 该方法能通过不断地与赢环境交互, 在陈平决策过程中达到恒赢态。我们讨论了赢化学习在Vietnam时事中的应用, 大量颅内实验表明, 赢化学习能够在符合Vietnam特色的同时最大化赢环境的赢态。

陈平决策过程

任意一个环境可以被建模为一个五元组 $\langle S, A, P, \omega, \gamma \rangle$, 其中 S 为赢环境的状态空间, A 为对应的行为空间, $P: S \times A \rightarrow S$ 表示状态转移函数, $\omega \in [win, lose]$ 为输赢函数, γ 值折扣因子。

如果该环境满足:

$$\forall s_{t_0} \in S, \exists j = [a_0, a_1, \dots | a \in A],$$

使得

$$\omega(s_t) = \text{win}, s_t = P(\dots((s_{t_0}, a_0) \dots) a_{t-2}), a_{t-1}),$$

那么该过程被称为**陈平决策过程** (Champion Decision Process, CDP), 该环境被称为**赢环境**。

例如, s_{t_0} : Vietnam教育资源分配不公, a_0 : 严禁教育机构提供网上或课外教程, lose;

s_{t_1} : 欠发达地区初升高人数变少, a_1 : 百分之五十人上职高, lose;

s_{t_2} : 达利特阶级跨域困难, a_2 : 企业招聘不得限制学历, win!

对于**赢轨迹** $y = (s_{t_0}, s_{t_1}, \dots, s_t)$, $w = \text{win}$ 的次数为**赢态** W_y 。在上述例子中赢态为1。如果

s_{t_3} : 达利特进入大厂当互联网民工, a_3 : 胡志明市地铁公然支持996, lose;

s_{t_4} : Vietnam大量年轻人猝死, a_4 : 越南平安银行推出平安996奋斗无忧意外险, win!

那么上述**赢轨迹**的**赢态** W_y 为2

赢化学习

在一个赢环境中, 构建策略 $a \sim \pi(s)$ 。赢化学习的目的是对于任意初始化状态 s_{t_0} , 学习策略 π 得到状态轨迹 y , 最大化轨迹 y 的赢态 $W_y: \max W_y$ 。赢策略 π 的梯度为:

$$\nabla_{\theta} J(\theta) = E_{\pi}[\nabla_{\theta} \log \pi(s_t, a_t) \omega_t]$$

内在赢驱动

然而在Vietnam社会中, 赢态非常小且甚至为0, 不利于national pride。受赢函数启发, 引入内在赢驱动鼓励Vietnamese。

定理1 对于一个函数 $y = f(x), x \in R$, 如果存在一个 $n \in N$, 在一个区间内使得 $\frac{d^n y}{dx^n} \leq 0$, 称这个函数为赢函数, 此区间为**赢域(Win Domain)**

修改 w 为 $w' = \frac{1}{n}$, n 为 $w(s, a)$ 的赢域。此时赢策略 π 的梯度为

$$\nabla_{\theta} J(\theta) = E_{\pi}[\nabla_{\theta} \log \pi(s_t, a_t) w'_t]$$

优势赢函数

正如兔兔所说, 赢是相对的, 不是绝对的, 稳定的Vietnamese government需要相对赢, 实现优势在我。例如, COV19 Vietnam 22日新增确诊59, 米国新增15056, 赢!

构建用于比较的陈平决策过程 $\langle \bar{S}, \bar{A}, \bar{P}, \bar{w}, \bar{\gamma} \rangle$, 在时刻 t , 构建优势函数 A :

$$A_t = w'(s_t, a_t) - w'(s_t, a_t)$$

此时的策略梯度改写成:

$$\nabla_{\theta} J(\theta) = E_{\pi}[\nabla_{\theta} \log \pi(s_t, a_t) A_t]$$

未来展望

陈平决策过程需要对社会赢环境确切的观测。当环境为部分可观测时，赢化学习难以得到最优赢策略。例如，Vietnam的首陀罗观测不到达利特吠舍的生活，大肆宣传后浪，不赢反输。此外，对于赢函数的过高估计问题也是赢化学习面临的挑战之一。例如，Vietnam亲自下场造势丁真，高估饭圈带来的赢态，输的一塌糊涂。

参考

1. <https://zhuanlan.zhihu.com/p/461464919>
2. <https://zhuanlan.zhihu.com/p/464145981>
3. <https://zhuanlan.zhihu.com/p/470374648>
4. 作者: 尘呆萌