

FSNet learning in partially-observable stochastic environments

Артем Сорокин, Михаил Бурцев

МФТИ

DeepHackLab

Обучение целенаправленному поведению


Миссия

- Агент должен достичь определенных целей в мире
- Агент
 - воспринимает мир
 - может совершать действия
 - изначально ничего не знает о влиянии действий на состояния мира



Обучение с подкреплением

- Цели задаются, как состояния мира в которых получается награда - *подкрепление*





MDP

Markov Decision Process (MDP)

$\langle \mathcal{S}, \mathcal{A}, \mathcal{T}, \mathcal{R} \rangle$, где:

- $\mathcal{S}$ множество состояний мира
- $\mathcal{A}$ множество действий
- $\mathcal{T} : \mathcal{S} \times \mathcal{A} \times \mathcal{S} \rightarrow [0, 1]$ вероятности переходов
- $\mathcal{R} : \mathcal{S} \times \mathcal{A} \rightarrow \mathbb{R}$ подкрепление

Агент ограничен в восприятии мира




POMDP

Partially Observable Markov Decision Process (POMDP)


$\langle \mathcal{S}, \mathcal{A}, \mathcal{T}, \mathcal{R}, \Omega, \mathcal{B} \rangle$, где:

- $\mathcal{S}$ множество состояний мира
- $\mathcal{A}$ множество действий
- $\mathcal{T} : \mathcal{S} \times \mathcal{A} \times \mathcal{S} \rightarrow [0, 1]$ вероятности переходов
- $\mathcal{R} : \mathcal{S} \times \mathcal{A} \rightarrow \mathbb{R}$ подкрепление
- Ω множество наблюдений
- $\mathcal{B}$ множество убеждений

POMDP



b



Основная идея

- На основе предыдущего опыта выбираем действия, которые скорее всего ведут к цели

$$\pi(b, o) = \operatorname{argmax}_{a \in \mathcal{A}} (b \cdot Q(o, a))$$

- После каждого действия проверяем в каком «мире» находимся

$$m(b, o, a) \neq o'$$

- Быстро приводим убеждения в соответствии с наблюдениями

$$b_i = 0$$

Обучение

- В отличие от табличного RL создаем «сеть» из FS элементов аппроксимирующих ценность действия $Q(o, a)$ и модель $m(b, o, a)$
 - если для данного наблюдения не существует FS элемента, то выбираем действие случайно
 - если случайное действие привело в состояние для которого существует хотя бы один FS элемент, то добавляем в сеть новый FS элемент. «запоминающий» действие $Q(o, a)$ и предсказание $m(b, o, a)$
 - после достижения цели обновляем ценности FS элементов способом похожим на Q-learning

$$Q(o, a) \leftarrow Q(o, a) + \alpha(r + \max_{a \in \mathcal{A}}(b' \cdot Q(o', a)) - Q(o, a))$$


Модель среды

- 2D решетка
 - агент обучается в серии попыток проходить из стартового состояния в целевое
 - 25% переходов имеют вес равный 1
 - оставшимся 75% переходов присваивается вес из равномерного распределения на $(0,1)$
 - веса задают вероятность сэмплирования перехода:



1. в каждой попытке (trial upd)

2. при смене состояния (state upd)


3. после каждого действия (MDP upd)




Решетка 10 на 10





Решетка 10 на 10




Решетка 10 на 10





Решетка 10 на 10





FSNet не зависит от периода обновления «мира»





Решетка: 25, 100 и 400 состояний



Случайный граф (Erdős–Rényi)




Сеть малого мира (Watts–Strogatz)




соцсети, трофические цепи, электросети, метаболические сети, структура мозга

Безмасштабная сеть (Barabási–Albert)




интернет, WWW




Все топологии 400 состояний



FSNet не зависит от периода
изменения среды во всех
топологиях





На безмасштабной топологии
достигается максимальная разница
со случайным блужданием



Нейросетевая реализация




Нейросетевая реализация




Выводы


- Введение механизма быстрого переключения между альтернативными действиями, позволяет решать задачу обучения целенаправленному поведению в частично наблюдаемых средах.



- Neural Information Processing Systems (NIPS), 1987 -
- Information processing in nervous system, Leiden, 1962



Основная идея теории функциональных систем



Open loop
vs
Closed loop

Функциональная система

