

Применение обучения с подкреплением для персонализации семантического поиска при полуавтоматическом составлении тематических подборок научных статей

Гришанов Алексей

Московский физико-технический институт
Физтех-школа прикладной математики и информатики
Факультет управления и прикладной математики
Кафедра «Интеллектуальные системы»

Научный руководитель д.ф.-м.н., К. В. Воронцов

Научный консультант, А. О. Янина

Москва 2021 г.

Заданы:

- $U = \{u_j | u_j \in \mathbb{R}^k, j \in 1, \dots, n_{users}\}$ — множество субъектов (пользователей/users), для удобства преобразованных в векторы.
- $I = \{i_j | i_j \in \mathbb{R}^k, j \in 1, \dots, n_{items}\}$ — множество объектов (рекомендуемых фильмов/items), преобразованных в векторы той же размерности, что и пользователи.
- $R = \|r_{ui}\|$ — матрица рейтингов размера $n_{users} \times n_{items}$, $r_{ui} \in \overline{1, 5}$

Для каждого пользователя $u \in U$ требуется построить список объектов $y = \{y_j\}_{j=1}^N$, ранжированных по релевантности.

Критерии качества:

$$HR@p(y) = \sum_{j=1}^p rel_{y_j}; \quad DCG@p(y) = \sum_{j=1}^p \frac{rel_{y_j}}{\log_2(j+1)},$$

где $rel_{y_j} = 1$, если объект y_j релевантен ($r_{ui} > 3$), иначе 0.

Постановка задачи для обучения с подкреплением

Заданы: множество \mathcal{S} состояний среды, множество \mathcal{A} доступных действий агента, функция награды $\mathcal{R} : \mathcal{S} \times \mathcal{A} \times \mathcal{S} \rightarrow \mathbb{R}$.

В момент времени t агент наблюдает состояние среды $s_t \in \mathcal{S}$, совершает действие $a_t \in \mathcal{A}$ в соответствии со своей стратегией (политикой, policy) $\pi : \mathcal{S} \times \mathcal{A} \rightarrow [0, 1] = \mathbb{P}(a_t | s_t)$, переходит в состояние s_{t+1} и получает награду r_t .

Цель:

$$J(\theta) = \mathbb{E}_{\pi_\theta} \left[\sum_{k=0}^{\infty} \gamma^k r_{t+k} \right] \rightarrow \max_{\pi_\theta}$$

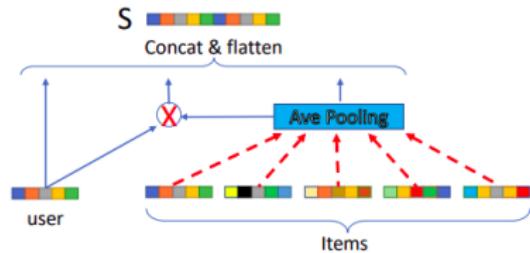
где $\gamma \in [0, 1]$ — параметр, гарантирующий, что бесконечная сумма не будет расходиться при конечных значениях награды.

Рекомендательная среда

1 Состояние

$$s = [u, u \otimes \{w_l i_l \mid l = 1, \dots, n\}, \{w_l i_l \mid l = 1, \dots, n\}] \in \mathbb{R}^{3k},$$

где w_l — веса понижающего размерность слоя, а символом \otimes обозначено поэлементное произведение.



2 Рекомендуется объект, скалярное произведение которого с вектором a наибольшее:

Actions is defined with parameters vector $a \in \mathbb{R}^k$.

$$i = \operatorname{argmax}_{i_j \in \mathcal{A}} i_j a^T$$

3

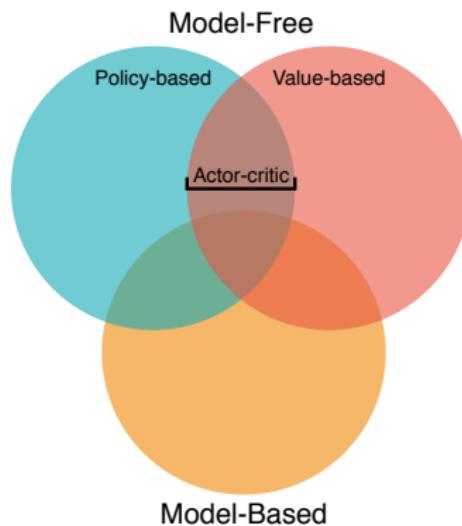
$$r = \begin{cases} 1, & \text{if } rating > 3 \\ 0, & \text{else} \end{cases}$$

здесь $r_t \in \mathcal{R}$, $r_{ui} \in R$.

Методы обучения с подкреплением

Агенты в обучении с подкреплением моделируют хотя бы одну из трёх компонент:

- политика (policy)
- функция ценности (value function)
- модель среды (environment model)



Преимущество детерминированной политики

Введём функцию ценности:

$$V^\pi(s) = \mathbb{E}_\pi \left[\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \mid s_t = s \right]$$

и Q-функцию:

$$Q^\pi(s, a) = \mathbb{E}_\pi \left[\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \mid s_t = s, a_t = a \right]$$

$\nabla_\theta J(\theta)$ можно рассчитать следующим образом (считая π_θ дифференцируемой по θ):

$$\nabla_\theta J(\theta) = \mathbb{E}_{s \sim \rho^\pi, a \sim \pi_\theta} [\nabla_\theta \log \pi_\theta(a|s) Q^\pi(s, a)],$$

где $\rho^\pi(s) = \sum_{t=1}^{\infty} \gamma^{t-1} \mathbb{P}(s_t = s | s_0, \pi)$

Детерминированная политика требует интегрирования только по состояниям среды:

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

DDPG with noise

Algorithm 1 Deep Deterministic Policy Gradient (DDPG).

- 1: Инициализировать критик $Q_{\theta^Q}(s, a)$ весом θ^Q и актор $\pi_{\theta^\pi}(s)$ весом θ^π
- 2: Инициализировать Q' весом $\theta^{Q'} = \theta^Q$ и π' весом $\theta^{\pi'} = \theta^\pi$
- 3: Инициализировать буфер B
- 4: **for** episode = 1, ..., M **do**
- 5: **for** $t = 1, \dots, N$ **do**
- 6: Выбрать действие $a_t = \text{GetNoisyAction}(\pi_{\theta^\pi}(s_t))$ в соответствии с текущей политикой и добавочным шумом
- 7: Сделать действие a_t , получить награду r_t , перейти в состояние s_{t+1}
- 8: Сохранить (s_t, a_t, r_t, s_{t+1}) в B
- 9: Сэмплировать N штук (s_i, a_i, r_i, s_{i+1}) из B
- 10: Вычислить $y_i = r_i + \gamma Q'(s_{i+1}, \pi'(s_{i+1}))$
- 11: Обновить критик, минимизируя $L = \frac{1}{N} \sum_i (y_i - Q_{\theta^Q}(s_i, a_i))^2$
- 12: Обновить актор, используя сэмплированный градиент политики:

$$\nabla_{\theta^\pi} J \approx \frac{1}{N} \sum_i \nabla_a Q(s, a)|_{s=s_i, a=\pi(s_i)} \nabla_{\theta^\pi} \pi(s)|_{s=s_i}$$

- 13: Обновить веса:

$$\begin{aligned}\theta^{Q'} &= \tau \theta^{Q'} + (1 - \tau) \theta^Q \\ \theta^{\pi'} &= \tau \theta^{\pi'} + (1 - \tau) \theta^\pi\end{aligned}$$

- 14: **end for**
 - 15: **end for**
-

- Action space noise

- ➊ Gaussian noise

$$\text{GetNoisyAction}(\pi_{\theta^\pi}(s_t)) = \pi_{\theta^\pi}(s_t) + \mathcal{N}(0, \sigma^2 \mathbf{I})$$

- ➋ Ornstein-Uhlenbeck noise

$$\text{GetNoisyAction}(\pi_{\theta^\pi}(s_t)) = \pi_{\theta^\pi}(s_t) + \mathcal{OU}(\sigma)$$

- Parameter space noise

$$\text{GetNoisyAction}(\pi_{\theta^\pi}(s_t)) = \text{GetNoisyAction}(\pi_{\tilde{\theta}^\pi}(s_t))$$

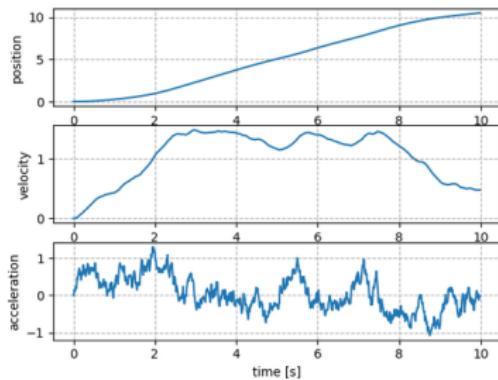
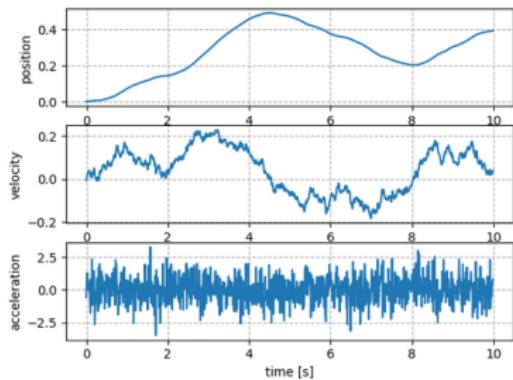
$$\tilde{\theta}^\pi = \theta^\pi + \mathcal{N}(0, \sigma^2 \mathbf{I})$$

Семейство случайных процессов для шума

Процесс Орнштейна-Уленбека может быть задан следующей системой дифференциальных уравнений:

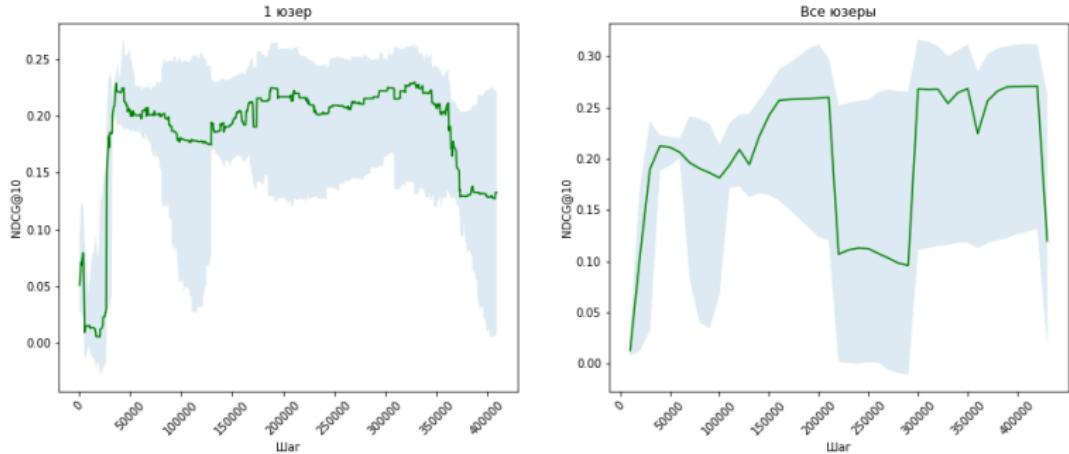
$$dP_t = \theta(\mu - P_t) dt + \sigma dW_t$$

где $\theta > 0$, $\sigma > 0$ и $\mu \in \mathbb{R}$ — параметры и W_t — винеровский процесс.



Сравнение гауссовского шума (слева) и шума из процесса
Орнштейна — Уленбека (адаптировано с сайта quora.com)

Пример графиков обучения (OY , $\sigma = 0.2$)



Слева качество измерялось по рейтингам одного случайного фиксированного пользователя, справа — по всем тестовых данных. Голубое затемнение — стандартное отклонение по 3 запускам.